



**INSTITUTO
FEDERAL**
Piauí

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS TERESINA CENTRAL
TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE SISTEMAS**

KAIO GABRIEL DE SOUSA CARVALHO

**DETECÇÃO AUTOMATIZADA DE ARRITMIA CARDÍACA POR MEIO DE ESP32
E ALGORITMOS DE APRENDIZADO DE MÁQUINA**

TERESINA, PIAUÍ

2026

KAIO GABRIEL DE SOUSA CARVALHO

DETECÇÃO AUTOMATIZADA DE ARRITMIA CARDÍACA POR MEIO DE ESP32
E ALGORITMOS DE APRENDIZADO DE MÁQUINA

Trabalho de Conclusão de Curso (artigo científico) apresentado como exigência parcial para obtenção do diploma do Curso de Tecnologia em Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Teresina Central.

Orientador: Prof. Me. Francisco Marcelino Almeida Araújo.

TERESINA, PIAUÍ

2026

DETECÇÃO AUTOMATIZADA DE ARRITMIA CARDÍACA POR MEIO DE ESP32 E ALGORITMOS DE APRENDIZADO DE MÁQUINA

Kaio Gabriel de Sousa Carvalho ¹

Francisco Marcelino Almeida Araújo ²

RESUMO

Este trabalho apresenta o desenvolvimento de um sistema embarcado para monitoramento cardíaco em tempo real, integrando técnicas de aprendizado de máquina e Internet das Coisas. A proposta consiste em um protótipo de baixo custo, baseado no microcontrolador ESP32, capaz de adquirir sinais de eletrocardiograma, processá-los localmente e disponibilizar os resultados em uma interface de visualização. A fundamentação teórica considera a aplicação de inteligência artificial embarcada em sistemas conectados, evidenciando seu potencial para o monitoramento cardiovascular contínuo e para a detecção automatizada de alterações no ritmo cardíaco. A metodologia adotada organiza a solução em camadas de hardware, firmware e software de monitoramento, possibilitando a leitura dos sinais, a execução do modelo de classificação e a transmissão dos dados em tempo real. Como resultado, busca-se obter uma solução funcional, documentada e replicável, capaz de demonstrar a viabilidade da integração entre dispositivos embarcados, aprendizado de máquina e ferramentas de visualização de dados. Conclui-se que essa combinação representa uma alternativa promissora para o desenvolvimento de aplicações em saúde conectada, com potencial para ampliar a eficiência do monitoramento cardíaco.

Palavras-chave: monitoramento cardíaco; internet das coisas; aprendizado de máquina; esp32; ad8232.

ABSTRACT

This paper presents the development of an embedded system for real-time cardiac monitoring, integrating machine learning techniques and the Internet of Things. The proposed solution consists of a low-cost prototype based on the ESP32 microcontroller, capable of acquiring electrocardiogram signals, processing them locally, and displaying the results through a visualization interface. The theoretical foundation considers the application of embedded artificial intelligence in connected systems, highlighting its potential for continuous cardiovascular monitoring and automated detection of heart rhythm abnormalities. The adopted methodology structures the solution into hardware, firmware, and monitoring software layers, enabling signal acquisition, model execution, and real-time data transmission. As a result, the project seeks to provide a functional, documented, and replicable solution that demonstrates the feasibility of integrating embedded devices, machine learning, and data visualization tools. It is concluded that this applications, with the potential to improve the efficiency of cardiac monitoring.

Keywords: cardiac monitoring; internet of things; machine learning; esp32; ad8232.

¹ Graduando em Tecnologia em Análise e Desenvolvimento de Sistemas. Instituto Federal do Piauí (IFPI). E-mail: kkaiogabrielk@gmail.com.

² Doutorando em Engenharia Elétrica (UTAD). Mestre em Biotecnologia (UFPI). Professor efetivo do IFPI e coordenador do LABIRAS. E-mail: francisco.marcelino@ifpi.edu.br.

Data de aprovação: 26/06/2026

1 INTRODUÇÃO

As arritmias cardíacas correspondem a alterações no ritmo normal dos batimentos do coração e representam um importante desafio para a saúde pública, especialmente por sua associação com complicações graves e, em alguns casos, com morte súbita (Mundim et al., 2023). Esses distúrbios podem surgir de forma intermitente e apresentar sintomas inespecíficos, como palpitações, tontura, mal-estar e dor torácica, o que dificulta a identificação precoce e o acompanhamento adequado (Mundim et al., 2023). Diante disso, a investigação de métodos mais acessíveis e eficientes para o monitoramento cardíaco torna-se cada vez mais necessária.

Ao longo do tempo, o diagnóstico dessas alterações evoluiu de observações clínicas simples para exames mais sofisticados, como o eletrocardiograma e o Holter 24 horas (Clínica Viver, 2022). Embora esses recursos sejam amplamente utilizados, eles ainda apresentam limitações importantes, sobretudo quando o objetivo é detectar episódios curtos, intermitentes ou que ocorrem fora do ambiente de monitoramento (Clínica Viver, 2022). Além disso, esses exames normalmente dependem de estrutura especializada, o que pode dificultar o acesso em determinadas realidades.

Nesse contexto, a integração entre Internet das Coisas e inteligência artificial surge como uma alternativa promissora para ampliar a capacidade de monitoramento contínuo e em tempo real (Valsalan, Tariq & Hussain, 2020). Dispositivos embarcados conectados permitem a coleta de sinais fisiológicos com baixo custo, enquanto modelos de aprendizado de máquina possibilitam a análise automática desses dados, contribuindo para a identificação precoce de padrões anormais (Ferreira, Ferreira & Leite, 2025). Essa combinação favorece soluções mais rápidas, portáteis e acessíveis para aplicações na área da saúde (Yasmin, 2024).

A utilização de sistemas embarcados, como o ESP32, associada a sensores de ECG, como o AD8232, permite a construção de protótipos capazes de captar e processar sinais cardíacos de forma local (Arduino Libraries, 2025) (Analog Devices,

2025). Quando esses sinais são tratados por modelos TinyML, torna-se possível realizar inferências diretamente no dispositivo, reduzindo a dependência de servidores externos e diminuindo a latência na resposta (Arduino Libraries, 2025). Além disso, a integração com plataformas de visualização, como o Grafana, oferece ao usuário uma interface prática para acompanhar os resultados de maneira clara e imediata (Grafana Labs, 2025).

Dessa forma, este trabalho propõe um sistema embarcado para detecção em tempo real de possíveis arritmias cardíacas, utilizando ESP32, sensor AD8232 e aprendizado de máquina no contexto da Internet das Coisas. A proposta busca unir baixo custo, portabilidade e análise automatizada para apoiar o monitoramento cardiovascular.

2 REFERENCIAL TEÓRICO

A inteligência artificial teve seus primeiros fundamentos consolidados ao longo do século XX, com contribuições importantes como o neurônio de McCulloch e Pitts e o Teste de Turing, que ajudaram a estabelecer bases para o desenvolvimento de sistemas capazes de simular aspectos do raciocínio humano (McCulloch & Pitts, 1943). Após um período de menor investimento conhecido como inverno da IA, a área voltou a crescer com o avanço do aprendizado de máquina, do poder computacional e da disponibilidade de dados, tornando-se parte central de diversas aplicações atuais, inclusive em saúde e diagnóstico assistido por computador (IBM, 2024).

Internet das Coisas evoluiu a partir da ideia de conectar objetos físicos à rede, permitindo a coleta e o compartilhamento de dados entre dispositivos. Esse avanço ampliou o uso de sensores, conectividade e automação em diferentes áreas, com destaque para a saúde, onde soluções baseadas em IoT passaram a apoiar o monitoramento remoto e contínuo de pacientes (Chaves, 2025; Desafios. . . , 2025). A convergência entre IoT e inteligência artificial deu origem à AIoT, combinação que permite maior autonomia aos dispositivos, com processamento local e tomada de decisão mais rápida (Solidpixels, 2025).

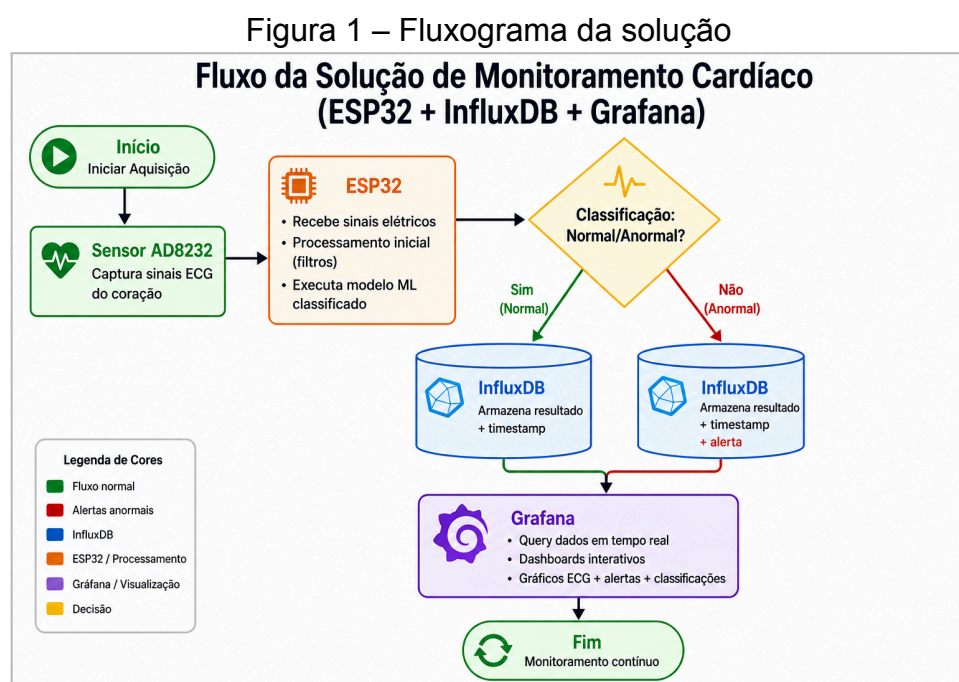
No contexto desta pesquisa, o uso de AIoT é aplicado ao monitoramento cardíaco por meio da aquisição de sinais de eletrocardiograma e da classificação automática de possíveis arritmias, destacando-se por integrar sensoriamento,

processamento e comunicação em uma solução compacta, de baixo custo e com potencial para inferência local. Os trabalhos correlatos reforçam essa viabilidade, pois Conceição et al. (2023) mostraram que o uso do sensor AD8232 com o ESP32 possibilita um sistema portátil de monitoramento cardíaco em tempo real (Conceição et al., 2023), Toledo evidenciou a viabilidade da tomada de decisão local em dispositivos IoT vestíveis com ESP32 (Toledo, 2024), e Rocha (2024) demonstrou que modelos de inteligência artificial podem ser executados em dispositivos embarcados com bom desempenho (Rocha, 2024).

3 METODOLOGIA

3.1 ARQUITETURA E FLUXO DE DESENVOLVIMENTO

A solução adota uma arquitetura em três camadas principais, aquisição de sinais, processamento embarcado e visualização em tempo real, desenvolvida iterativamente para garantir integração eficiente. O desenvolvimento iniciou com a integração do hardware, como apresentado na Figura 1, que mostra o microcontrolador ESP32 utilizado neste trabalho. O sensor AD8232, por sua vez, foi adotado por ser voltado à aquisição e ao condicionamento de sinais de ECG, permitindo a captação do eletrocardiograma com maior estabilidade.




Fonte: Elaborada pelo autor (2026).

Depois, os sinais captados são transmitidos ao ESP32 para processamento inicial e execução do modelo de classificação treinado e otimizado para ambiente embarcado. Os resultados são enviados a um banco de dados com timestamps e recuperados pela interface de monitoramento para exibição em painel interativo em tempo real. Essa estrutura promove baixa latência e autonomia, ideal para aplicações edge em saúde.

3.2 HARDWARE E SOFTWARE EMPREGADOS

O ESP32 foi escolhido por reunir conectividade Wi-Fi, baixo consumo de energia e capacidade de processamento adequada para aplicações embarcadas (Espressif Systems, 2025). Na Figura 2, apresenta-se a imagem do microcontrolador utilizado neste trabalho. O sensor AD8232, por sua vez, foi adotado por ser voltado à aquisição e ao condicionamento de sinais de ECG, permitindo a captação do eletrocardiograma com maior estabilidade (Analog Devices, 2025). A Figura 2 mostra o sensor empregado na implementação do sistema.

Figura 2 – Microcontrolador ESP32 e sensor AD8232



Fonte: Elaborada pelo autor (2026).

O firmware foi desenvolvido com base no ecossistema Arduino para ESP32, facilitando a leitura dos sensores e a comunicação com a interface (Arduino Libraries, 2025). A estrutura de processamento do código segue uma abordagem incremental de detecção de picos R, extração de intervalos cardíacos e cálculo de métricas derivadas. Inicialmente, o sinal é corrigido por um offset e comparado com uma janela de três amostras para identificar máximos locais; quando o pico

ultrapassa um limiar e respeita o período refratário, ele é considerado uma onda R válida. A partir da detecção de dois picos R consecutivos, o algoritmo calcula o intervalo RR pela diferença entre seus instantes de ocorrência, e a frequência cardíaca é obtida por $BPM = 60000/RR$, considerando o intervalo em milissegundos. Além disso, o código aplica filtros de consistência para rejeitar intervalos fora da faixa esperada e variações abruptas entre batimentos, reduzindo falsas detecções. Com o RR validado, são estimadas outras métricas, como o intervalo QRS, fixado em 100 ms, e o intervalo QT, aproximado por $QT = 0,35 \cdot RR$, limitado entre 250 e 450 ms. Esses valores, juntamente com suas versões anteriores, compõem o vetor de características utilizado pelo classificador.

Para a execução do modelo embarcado, foi utilizada a biblioteca TensorFlow Lite (TensorFlow, 2025). Os dados gerados pelo sistema são armazenados e organizados em séries temporais por meio do InfluxDB, que atua como banco de dados para recebimento e consulta dos registros (InfluxData, 2026). Em seguida, a visualização foi implementada com o Grafana, permitindo exibir os sinais de ECG e os resultados da classificação em tempo quase real (Grafana Labs, 2025).

3.3 DATASET E TREINAMENTO

O modelo foi treinado com base no ECG Arrhythmia Classification Dataset, derivado da MIT-BIH Arrhythmia Database (The . . . , 2001). O conjunto de dados contém atributos extraídos de sinais de ECG, como intervalos RR, duração do complexo QRS e intervalo QT, usados na classificação binária entre batimentos normais e arritmias (Sakib, Fouda & Fadlullah, 2021).

Para tratar o desequilíbrio de classes no dataset ECG Arrhythmia Classification Dataset, onde a classe majoritária 'N' (normal) continha 644.711 amostras contra apenas 66.713 de arritmias, aplicou-se downsampling sem reposição da classe normal até igualar o número de amostras da classe minoritária, resultando em 133.426 instâncias balanceadas. Essa estratégia foi essencial para evitar viés do modelo em favor da classe dominante, melhorando a sensibilidade na detecção de arritmias clinicamente críticas. O modelo para ESP32 foi treinado como um aluno aprendendo com um professor mais experiente: o modelo grande (professor) primeiro analisou os dados e deu dicas mais detalhadas (soft targets) sobre como classificar; depois o modelo pequeno (aluno) aprendeu combinando


essas dicas do professor (70%) com as respostas certas originais (30%). Priorizaram-se as métricas AUC, recall, precision e perda, pois o AUC avalia a capacidade discriminatória global do modelo em cenários desbalanceados, o recall (sensibilidade) garante a detecção crítica de arritmias sem falsos negativos perigosos em triagem médica, a precision minimiza falsos positivos que sobrecarregariam sistemas embarcados, e a perda monitora convergência; essas métricas são essenciais para validar desempenho confiável em dispositivos de borda com restrições computacionais.

4 RESULTADOS E DISCUSSÃO

4.1 ASPECTOS PRINCIPAIS DO HARDWARE

A implementação embarcada foi desenvolvida na plataforma ESP32, escolhida por integrar processamento, ADC, Wi-Fi e inferência em borda em um único chip — características essenciais para monitoramento cardíaco em tempo real. A seleção priorizou o equilíbrio entre custo, consumo energético, memória, latência e periféricos biomédicos.

Figura 3 – Montagem física do sistema



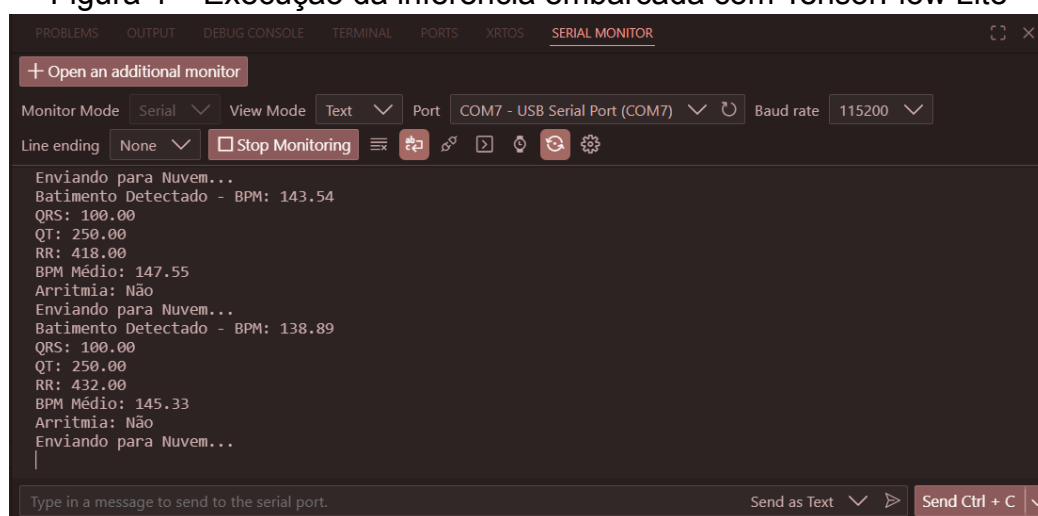
Fonte: Elaborada pelo autor (2026).

A aquisição do sinal ECG utiliza GPIO34 (ADC1) com 12 bits e atenuação de 11 dB. O ADC1 foi escolhido por operar independentemente do Wi-Fi, ao contrário do ADC2 que sofre contenção quando a conectividade está ativa. O ADC do ESP32

é sensível a ruído, exigindo calibração e filtragem para sinais ECG de baixa amplitude.

O processamento local divide-se em duas etapas: (1) ECGMetrics — detecção de picos R e cálculo de RR, QRS, QT, BPM instantâneo e médio; (2) ECGClassifier — inferência com TensorFlow Lite Micro. Essa estratégia reduz a entrada do modelo para 6 características numéricas, diminuindo operações e demanda de memória.

Figura 4 – Execução da inferência embarcada com TensorFlow Lite




Fonte: Elaborada pelo autor (2026).

O TensorFlow Lite Micro utiliza arena estática de 16 KB (tensor_arena) e interpretador estático, evitando alocação dinâmica em heap. Os atributos são quantizados para int8, reduzindo consumo de memória e custo computacional. A destilação de conhecimento transfere comportamento de modelo professor robusto para aluno menor, operando no ESP32 com menor latência e memória, sem cloud.

Robustez operacional é garantida por: `esp_reset_reason()` (motivo de reset), verificação de heap antes da inferência e inicialização sequencial (sensor → inferência → comunicação). Práticas essenciais para validação em campo, evitando reinicializações e exaustão de memória.

A conectividade Wi-Fi envia métricas para InfluxDB, distribuindo carga: ESP32 realiza aquisição, extração e inferência local; infraestrutura externa armazena e visualiza dados. Arquitetura coerente com edge intelligence, com sincronização via NTP para integridade temporal.

Figura 5 – Interface do InfluxDB para consulta das métricas




Fonte: Elaborada pelo autor (2026).

O hardware é elemento estruturante da solução. Decisões como ADC1, arena de 16 KB, quantização int8 e transmissão seletiva demonstram projeto orientado por restrições reais. A destilação de conhecimento é necessidade arquitetural para viabilizar IA confiável em dispositivo de baixo custo.

4.2 ASPECTOS PRINCIPAIS DO SOFTWARE E VISUALIZAÇÃO

A visualização utiliza InfluxDB e Grafana em containers Docker, facilitando implantação e replicabilidade. Arquitetura adequada para monitoramento cardíaco por registrar dados como séries temporais em painéis interativos. Configuração via arquivo Docker: InfluxDB persiste dados com volumes dedicados; Grafana visualiza; variáveis de ambiente centralizam credenciais e bucket. InfluxDB armazena em séries temporais, permitindo consultas flexíveis via linguagem Flux sobre BPM, intervalos fisiológicos e arritmia. Grafana constrói o painel principal com: série temporal de frequência cardíaca, indicador de arritmia e intervalos fisiológicos.

Figura 6 – Dashboard principal do Grafana



Fonte: Elaborada pelo autor (2026).

Essa composição facilita a leitura rápida e identificação de variações no sinal. A solução separa claramente aquisição/processamento local (ESP32) de armazenamento/visualização (InfluxDB/Grafana), melhorando a escalabilidade e eficiência do monitoramento contínuo.


4.3 ASPECTOS PRINCIPAIS DO MODELO

O modelo professor, caracterizado por arquitetura profunda com cinco camadas densas, maximizou a capacidade discriminativa através de regularização L2, MaxNorm, normalização por lotes (Batch Normalization) e Dropout progressivo. O treinamento foi realizado por 95 épocas utilizando otimizador Adam adaptativo e EarlyStopping para evitar overfitting. Na validação, alcançou AUC de 0,9697, perda de 0,2330, precisão de 94,2% e recall de 88,2%, estabelecendo uma baseline robusta que gerou soft labels de alta qualidade para o processo de destilação de conhecimento.

O modelo aluno, otimizado para as restrições embarcadas do ESP32, possui arquitetura compacta de quatro camadas com aproximadamente 70% menos parâmetros que o professor. Empregou regularização L2 moderada e Dropout ajustado, sendo treinado via destilação de conhecimento com função de perda híbrida composta por 70% de MSE (Mean Squared Error) dos soft labels do professor e 30% de binary crossentropy dos hard labels originais. No conjunto de teste independente de 13.343 amostras, resultou em AUC de 0,9579, precisão de

92,94%, recall de 84,87%, F1-score de 0,8873 e especificidade de 93,56%, demonstrando que a compressão arquitetural manteve a discriminação global apesar da drástica redução de complexidade computacional.

Figura 7 – Comparação de métricas de desempenho entre o modelo professor e o modelo aluno no conjunto de teste (13.343 amostras)




Fonte: Elaborada pelo autor (2026).

A AUC de 0,9579 evidencia excelente capacidade discriminativa do modelo aluno compacto, particularmente relevante em cenários clínicos onde a separação entre ritmos normais e arritmias enfrenta desafios devido à variabilidade inter-paciente dos sinais eletrocardiográficos. Essa métrica global valida a efetividade da destilação de conhecimento, demonstrando que mesmo com redução de aproximadamente 70% nos parâmetros, o aluno preservou 98,2% da habilidade discriminativa do professor, mantendo distinção clara entre classes no espaço de características.

O perfil clínico estabelecido pela precisão de 92,94% e recall de 84,87% é equilibrado para monitoramento embarcado contínuo. Com apenas 430 falsos positivos em 6.672 amostras normais (taxa de 6,44%), minimiza-se a fadiga de supervisão médica, enquanto a detecção de 85% das arritmias reais prioriza a sensibilidade crítica, onde falsos negativos poderiam comprometer intervenções oportunas em sistemas autônomos de borda. A especificidade de 93,56% é particularmente relevante para implantações de longa duração, reduzindo interrupções desnecessárias e mantendo confiança no sistema. O F1-score de 0,8873 equilibra precisão e recall, representando métrica composta ideal para

validação do modelo embarcado.

Figura 8 – Matriz de confusão detalhada do modelo ESP32 no conjunto de teste



Fonte: Elaborada pelo autor (2026).

A distribuição dos erros revela uma limitação clínica do modelo, caracterizada pelo predomínio de falsos negativos (1.009) sobre falsos positivos (430), indicando que o sistema prioriza a especificidade em detrimento da sensibilidade. Em monitoramento cardíaco autônomo, falsos negativos representam maior risco clínico, pois arritmias não detectadas podem comprometer intervenções oportunas, enquanto os 430 falsos positivos ainda são clinicamente gerenciáveis. Essa assimetria constitui limitação do modelo atual que poderia ser mitigada com treinamento adicional, datasets mais amplos ou ajuste fino da função de perda para elevar o recall acima de 90%, mantendo a viabilidade embarcada via quantização int8 e TensorFlow Lite Micro.

5 CONSIDERAÇÕES FINAIS

O sistema embarcado desenvolvido demonstrou viabilidade técnica completa para monitoramento cardíaco contínuo, integrando aquisição de sinais ECG via AD8232, inferência local de arritmias com modelo destilado (AUC 0,9579, F1-score 0,8873) no ESP32 e visualização em tempo real via InfluxDB/Grafana. A estratégia de destilação de conhecimento preservou 98% do desempenho clínico do modelo

professor apesar da redução de 70% nos parâmetros, validando a abordagem edge intelligence para aplicações de saúde com restrições computacionais severas. A quantização int8 e arena estática de 16 KB asseguraram execução determinística, enquanto a transmissão seletiva de métricas (1-2 pontos/segundo) otimizou banda e armazenamento, consolidando uma solução funcional, replicável e de baixo custo.

Para trabalhos futuros, propõem-se validações clínicas em ambiente hospitalar com pacientes reais, desenvolvimento de protótipo wearable via modelagem 3D para conforto prolongado, aprimoramento do modelo com arquiteturas transformer leves e busca por datasets mais recentes, visando recall maior que 90% e certificação ANVISA. Essas evoluções posicionaram a solução como alternativa competitiva aos Holter tradicionais, ampliando o acesso ao monitoramento cardíaco de alta precisão em cenários ambulatoriais e telemedicina.

REFERÊNCIAS

Analog Devices. **AD8232 Datasheet and Product Info**. 2025. Acesso em: 3 dez. 2025. Disponível em: <<https://www.analog.com/en/products/ad8232.html>>.

Arduino Libraries. **ESP32**. 2025. Acesso em: 2 dez. 2025. Disponível em: <<https://www.arduino-libraries.info/architectures/esp32>>.

CHAVES, L. E. **Você conhece a história da Internet das Coisas (IoT)?** 2025. Acesso em: 2 dez. 2025. Disponível em: <<http://engenhariahibrida.com.br/post/historia-internet-das-coisas-iot>>.

Clínica Viver. **Exame Holter 24 horas: como é feito e para que serve?** 2022. Acesso em: 4 abr. 2026. Disponível em: <<https://clinicaviver.com/exame-holter-como-e-feito-e-para-que-serve/>>.

CONCEIÇÃO, J. Souza da et al. **Monitoramento cardíaco em tempo real com sensor ecg ad8232 e esp32**. In: Anais do XXVII INIC, XXIII EPG, XVII INIC Jr, XIII INID, III ENEXUN. São José dos Campos: Universidade do Vale do Paraíba, 2023. p. 1–6. Disponível em: <https://www.inicepg.univap.br/cd/INIC_2023/anais/arquivos/0951_0993_01.pdf>.

DESAFIOS IoT: **como a Internet das Coisas afeta a cibersegurança**. 2025. Acesso em: 2 dez. 2025. Disponível em: <<https://www.manageengine.com/br/blog/general/desafios-iot-como-a-internet-das-coisas-afeta-a-ciberseguranca.html>>.

Espressif Systems. **ESP32 Datasheet**. 2025. Acesso em: 2 dez. 2025. Disponível em: <https://documentation.espressif.com/esp32_datasheet_en.html>.

FERREIRA, V. M. d. S.; FERREIRA, T. d. S.; LEITE, A. M. d. O. **Uso de inteligência artificial na predição de arritmia cardíaca: Do algoritmo ao batimento**. Interference: A Journal of Audio Culture, v. 11, n. 2, p. 6135–6144, 2025.

Grafana Labs. **Grafana Documentation**. 2025. Acesso em: 2 dez. 2025. Disponível em: <<https://grafana.com/docs/grafana/latest/>>.

IBM. **Deep Blue**. 2024. Acesso em: 1 dez. 2025. Disponível em: <<https://www.ibm.com/history/deep-blue>>.

InfluxData. **InfluxDB Documentation**. 2026. Acesso em: 22 abr. 2026. Disponível em: <<https://docs.influxdata.com>>.

MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. The Bulletin of Mathematical Biophysics, v. 5, n. 4, p. 115–133, 1943.

MUNDIM, H. et al. **Cardiac arrhythmia: analysis of the epidemiological profile of patients care at a pediatric cardiology outpatient**. Residência Pediátrica, v. 13, n. 4, 2023. Em português. Disponível em: <<https://residenciapediatria.com.br/detalhes/1450/arritmia%20cardiaca%20-%20analise%20do%20perfil%20epidemiologico%20dos%20pacientes%20atendidos%20em%20ambulatorio%20de%20cardiologia%20pediatria>>.

ROCHA, E. P. F. **Trabalho de Conclusão de Curso em Engenharia Mecatrônica**. 2024. Universidade Federal de Santa Catarina, Centro Tecnológico de Joinville. Trabalho de Conclusão de Curso.

SAKIB, S.; FOUDA, M. M.; FADLULLAH, Z. M. **Harnessing artificial intelligence for secure ecg analytics at the edge for cardiac arrhythmia classification**. In: CRC Press eBooks. [S.l.]: CRC Press, 2021. p. 137–153.

Solidpixels. **AIoT or Artificial Intelligence of Things**. 2025. Acesso em: 2 dez. 2025. Disponível em: <<https://www.asnplus.com/blog/aiot-or-artificial-intelligence-of-things>>.

TensorFlow. **TensorFlow Lite**. 2025. Acesso em: 2 dez. 2025. Disponível em: <<https://www.tensorflow.org/lite/guide?hl=pt-br>>.

THE Impact of the MIT-BIH Arrhythmia Database: History, Lessons Learned, and Its Influence on Current and Future Databases. 2001. Acesso em: 2 dez. 2025. Disponível em: <<http://ecg.mit.edu/george/publications/mitdb-embs-2001.pdf>>.

TOLEDO, A. B. **Viabilidade da tomada de decisão local em dispositivos IoT vestíveis com ESP32**. 2024.

VALSALAN, P.; TARIQ, A.; HUSSAIN, A. **IoT based health monitoring system**. Journal of Critical Reviews, 2020.

YASMIN. Dispositivos IoT estão transformando a saúde, desde wearables que monitoram sinais vitais até a gestão inteligente de medicamentos. 2024.

Acesso em: 4 abr. 2026. Disponível em: <<https://shre.ink/jKSQ>>.