

Dispositivo IoMT Vestível de Baixo Consumo com Sensoriamento Biométrico e Wi-Fi FTM para Zonas Restritas

Leandro Henrique de Souza Carrascosa, Rubens de Andrade Fernandes, Waldir Sabino da Silva Júnior e Celso Barbosa Carvalho

Resumo—Este trabalho apresenta uma arquitetura vestível de *Internet of Medical Things* (IoMT) de baixo consumo baseada no ESP32-S3, integrando monitoramento de sinais vitais e detecção de proximidade via Wi-Fi *Fine Time Measurement* (FTM). O sistema utiliza o sensor MAX30102 para aquisição biométrica e o acelerômetro LIS3DH como gatilho de ativação do coprocessador ULP RISC-V, permitindo sensoriamento contínuo com baixo consumo energético. Resultados experimentais demonstraram consumo mínimo de 0,015 mA em *Deep Sleep* e 15,19 mA durante monitoramento utilizando ULP, MAX30102 e LIS3DH, sem ativação do núcleo principal. As medições FTM apresentaram correlação linear moderada para estimativa de distância entre 1 m e 7 m, obtendo coeficiente de determinação $R^2 = 0,3712$, com erro médio absoluto (MAE) de 1,42 m e erro quadrático médio (RMSE) de 1,78 m. Os resultados validam a viabilidade da arquitetura para aplicações IoMT de monitoramento contextual com elevada eficiência energética.

Palavras-Chave—Internet das Coisas Médicas (IoMT), Wi-Fi *Fine Time Measurement*, ESP32-S3, Dispositivos Vestíveis, Eficiência Energética, Estimativa de Distância.

Abstract—This work presents a low-power wearable *Internet of Medical Things* (IoMT) architecture based on the ESP32-S3, integrating vital sign monitoring and proximity detection through Wi-Fi *Fine Time Measurement* (FTM). The system employs the MAX30102 sensor for biometric acquisition and the LIS3DH accelerometer as a trigger for activating the ULP RISC-V co-processor, enabling continuous low-power sensing. Experimental results demonstrated a minimum current consumption of 0.015 mA during *Deep Sleep* and 15.19 mA during monitoring using the ULP, MAX30102, and LIS3DH without waking the main CPU. FTM measurements showed a moderate linear correlation for distance estimation between 1 m and 7 m, achieving a coefficient of determination of $R^2 = 0.3712$, a mean absolute error (MAE) of 1.42 m, and a root-mean-square error (RMSE) of 1.78 m. The results validate the feasibility of the proposed architecture for contextual IoMT monitoring applications requiring high energy efficiency.

Keywords—Internet of Medical Things (IoMT), Wi-Fi *Fine Time Measurement*, ESP32-S3, Wearable Devices, Energy Efficiency, Distance Estimation.

I. INTRODUÇÃO

O crescimento da *Internet of Medical Things* (IoMT) tem impulsionado o desenvolvimento de dispositivos vestíveis de baixo custo voltados ao monitoramento contínuo de parâmetros fisiológicos em ambientes não clínicos. Esses sistemas permitem a aquisição em tempo real de sinais biomédicos, como frequência cardíaca (FC) e saturação periférica de oxigênio (SpO_2), sendo fundamentais para aplicações de acompanhamento remoto, supervisão assistiva e detecção de situações de risco ocorridas em ambientes internos, como hospitais, clínicas, laboratórios e áreas industriais de acesso controlado,

nos quais a propagação de sinais de rádio é degradada por reflexões, difração e absorção causadas por paredes, mobiliário e o próprio corpo humano.

Em zonas restritas, como enfermarias, centros cirúrgicos e alas de isolamento, o monitoramento convencional depende de cabos ou de pessoal de enfermagem presente fisicamente ao lado do paciente. Essa abordagem limita a mobilidade do usuário, aumenta o custo operacional e pode falhar em detectar rapidamente eventos críticos durante deslocamentos internos. Um dispositivo vestível capaz de monitorar sinais vitais e estimar proximidade de forma autônoma representa, portanto, uma solução de alto valor clínico e operacional.

O protocolo FTM se distingue dos métodos baseados em *Received Signal Strength Indicator* (RSSI) por empregar medições temporais de *Round-Trip Time* (RTT), reduzindo a sensibilidade a flutuações rápidas do canal [14], [20]. Embora soluções *Ultra-Wideband* (UWB) possam oferecer maior precisão para localização em ambientes fechados [16], [17], o Wi-Fi FTM apresenta menor custo de implantação e compatibilidade com dispositivos Wi-Fi modernos que suportam o IEEE 802.11mc. Dessa forma, o FTM torna-se uma alternativa atrativa para aplicações IoMT vestíveis.

Além do monitoramento fisiológico, aplicações IoMT modernas demandam mecanismos de percepção contextual capazes de identificar mobilidade, proximidade e mudanças de comportamento do usuário. Nesse contexto, sensores inerciais como acelerômetros triaxiais permitem detectar a atividade corporal com baixo consumo energético, enquanto técnicas de estimativa de distância em ambientes internos possibilitam supervisão baseada em proximidade.

Como sistemas GNSS apresentam baixa eficiência em ambientes internos e soluções UWB possuem maior custo e complexidade de implantação [22], o protocolo Wi-Fi *Fine Time Measurement* (FTM), padronizado no IEEE 802.11mc, surge como uma alternativa promissora para estimação de distância utilizando infraestrutura Wi-Fi convencional. Entretanto, medições FTM são fortemente afetadas por propagação multipercurso, obstruções e condições *Non-Line-of-Sight* (NLOS), o que pode degradar significativamente a precisão em cenários reais.

Diante deste contexto, este trabalho propõe uma arquitetura vestível IoMT de baixo consumo baseada no ESP32-S3, integrando aquisição biométrica, detecção de movimento e estimação de proximidade. O sistema utiliza o sensor óptico MAX30102 para monitoramento contínuo de FC e SpO_2 , enquanto o acelerômetro LIS3DH é empregado como mecanismo de interrupção e classificação inicial de atividade. A partir da detecção de movimento, o coprocessador ULP RISC-V do

ESP32-S3 executa uma etapa intermediária de sensoriamento de baixo consumo, ativando o protocolo FTM apenas sob condições contextuais relevantes.

A arquitetura proposta adota uma estratégia hierárquica de gerenciamento energético baseada em eventos, reduzindo o tempo de ativação do rádio Wi-Fi e minimizando o consumo energético associado às operações de *ranging*. Além disso, técnicas de processamento digital de sinais são aplicadas para reduzir artefatos de movimento nos sinais biométricos e suavizar flutuações nas medições FTM causadas por multipercursos.

Os resultados experimentais demonstram uma correlação linear consistente para estimativa de distância entre 1 m e 7 m, obtendo $R^2 = 0,3712$ em condições reais de propagação. Adicionalmente, a estratégia orientada a eventos permitiu reduzir o consumo energético do sistema, mantendo apenas os módulos essenciais ativos durante períodos de inatividade.

As principais contribuições deste trabalho são: (i) o desenvolvimento de um dispositivo vestível IoMT integrando monitoramento biométrico, detecção de movimento e estimação de proximidade baseada em Wi-Fi FTM; (ii) a implementação de uma arquitetura hierárquica de baixo consumo utilizando interrupções do LIS3DH e o coprocessador ULP RISC-V do ESP32-S3; e (iii) a avaliação experimental do sistema em condições reais de propagação, validando sua viabilidade para aplicações de supervisão contextual em ambientes internos.

II. TRABALHOS RELACIONADOS

O rápido avanço das tecnologias de IoMT tem catalisado o desenvolvimento de sistemas vestíveis de saúde. A literatura recente demonstra uma tendência clara em direção à integração de sensoriamento multiparamétrico e processamento de baixo consumo, utilizando predominantemente a família de microcontroladores ESP32 e o sensor de fotopletismografia (PPG) MAX30102 como base de hardware [2], [3], [10], [12], [13]. Estudos complementares [6], [7], [11] exploram o desenvolvimento de pulseiras IoT para monitoramento contínuo de SpO_2 e FC em ambientes não clínicos.

A escolha das unidades de processamento evoluiu de módulos *dual-core* padrão para arquiteturas mais especializadas ou distribuídas. Por exemplo, [5] e [8] empregam o XIAO ESP32-C3, baseado na arquitetura RISC-V, para priorizar a miniaturização, enquanto [12] utiliza o ESP32 como nó de aquisição de dados para um Raspberry Pi central. De maneira semelhante, [4] propõe uma arquitetura de monitoramento em saúde focada no ESP32, com integração a ambientes de computação em nuvem. Em contextos especializados, [1] demonstra o uso de microcontroladores *single-chip* para execução de algoritmos sob restrições rigorosas de recursos.

Além do monitoramento vital básico, a fusão de sensores tem expandido as capacidades de diagnóstico. Pesquisadores integraram o MAX30102 à resposta galvânica da pele (GSR) para detecção de estresse [3], módulos de eletrocardiograma (ECG) para perfilamento cardíaco [2] e Unidades de Medida Inercial (IMU) para monitoramento postural [1], [9]. No entanto, esses trabalhos frequentemente carecem de localização de alta precisão em ambientes internos, dependendo majoritariamente de estimativas imprecisas de proximidade baseadas em RSSI ou operando sem qualquer tipo de rastreamento espacial.

A estimação de distância em cenários internos representa um desafio recorrente devido a multipercursos, obstruções

físicas e condições NLOS. Métodos tradicionais baseados em RSSI apresentam elevada variabilidade temporal e forte dependência do ambiente, tornando-se inadequados para percepção contextual confiável [20], [17]. Nesse cenário, o protocolo IEEE 802.11mc FTM tem emergido como alternativa superior para *ranging* nesses ambientes, permitindo estimativas de distância baseadas no RTT entre dispositivos Wi-Fi [14].

Trabalhos recentes demonstram que o FTM pode alcançar melhor estabilidade em aplicações de rastreamento em ambientes internos [15], [21]. Entretanto, a maior parte das implementações concentra-se em *smartphones*, âncoras estáticas ou plataformas de navegação robótica, negligenciando os desafios específicos de integração centrada no ser humano — como a interferência corporal — e as restrições energéticas severas de dispositivos vestíveis [17], [16], [18]. Poucos trabalhos investigam estratégias de gerenciamento energético baseadas em interrupção por movimento ou ativação sob demanda do rádio Wi-Fi [19].

Diferentemente das abordagens convencionais, este trabalho propõe uma arquitetura vestível de baixo consumo baseada no ESP32-S3 que integra *ranging* Wi-Fi FTM, sensoriamento inercial (LIS3DH) e processamento via coprocessador ULP RISC-V. Na montagem do *setup* experimental, o próprio ESP32-S3 também atua como nó respondedor (*responder*), garantindo infraestrutura homogênea para os testes de protocolo em cenários NLOS. A Tabela I apresenta o comparativo entre as contribuições deste trabalho e a literatura vigente.

III. Fine Time Measurement (FTM)

O protocolo FTM estima as distâncias entre dispositivos Wi-Fi por meio do cálculo do RTT, utilizando marcações de tempo em nanossegundos [14]. O processo de troca de sinais, ilustrado na Fig. 1, envolve o registro dos instantes de partida e chegada (t_1 a t_4) entre os nós *initiator* e *responder*.




Fig. 1. Procedimento operacional do protocolo FTM e cálculo do RTT.

$$RTT = \frac{1}{n} \sum_{k=1}^n [(t_4(k) - t_1(k)) - (t_3(k) - t_2(k))] \quad (1)$$

$$d = \frac{RTT \times c}{2} \quad (2)$$

Para mitigar ruídos e efeitos de multipercursos, o sistema realiza n rajadas (*bursts*) consecutivas de medição, nas quais cada *burst* consiste em uma troca completa de quadros FTM entre os nós. A média dos RTTs obtidos nas n rajadas subtrai o atraso de processamento interno do *initiator* (Equação 1). A distância física d é então obtida multiplicando o RTT

TABELA I

ANÁLISE COMPARATIVA DE SISTEMAS IoMT COM FOCO EM MONITORAMENTO, LOCALIZAÇÃO E ESTRATÉGIAS DE EFICIÊNCIA ENERGÉTICA.

Características	[1–4]	[5, 7, 8, 12]	[6, 10, 13, 14]	[20], [15]	[19], [18]	Este Trabalho
Microcontrolador	X	X	X			X
Sinais Vitais	X	X	X			X
Proximidade/Estimativa	X		X			X
Sensoriamento Inercial	X		X	X	X	X
Localização em Ambientes Internos				X	X	X
Calibração	X		X	X	X	X
Otimização Energética (ULP)						X

médio pela velocidade da luz c sobre dois (Equação 2). Nos experimentos deste trabalho foram utilizadas $n = 5$ rajadas por estimativa de distância.

Nota sobre o Modelo de Estimativa de Distância

O *ranging* FTM foi avaliado por meio de regressão linear ordinária entre a distância real e a distância estimada. Reconhece-se que distâncias assumem valores estritamente positivos, o que, em rigor, violaria o pressuposto de suporte irrestrito do modelo linear clássico. Contudo, na faixa avaliada (1 m a 7 m), as estimativas FTM apresentam dispersão simétrica em torno de um valor central positivo, sem concentração de valores próximos a zero, condição na qual a assimetria do suporte se torna relevante. Nesse cenário, a regressão linear é amplamente adotada na literatura de *ranging* Wi-Fi em ambientes internos para quantificar tendência e dispersão [15], [21]. Complementarmente, métricas diretas de erro, MAE e RMSE, são reportadas nas seções de resultados para fornecer uma avaliação interpretável e independente de pressupostos distributivos.

IV. MATERIAIS

Esta seção detalha os componentes de *hardware* e *software* utilizados para desenvolver o nó vestível IoMT e estabelecer a infraestrutura de medição. O *setup* experimental completo é ilustrado na Fig. 2.




Fig. 2. Setup experimental para perfilamento de consumo energético. (1) ESP32-S3 (*initiator*); (2) Nordic PPK2 em modo *source meter*; (3) ESP32-S3 respondedor; (4) sensor MAX30102; (5) acelerômetro LIS3DH.

A. Nó Vestível e Sensoriamento Biométrico

O núcleo do sistema é baseado no microcontrolador ESP32-S3, selecionado por seu suporte nativo ao protocolo IEEE 802.11mc FTM [14]. A aquisição de dados biométricos, especificamente FC e SpO₂, é realizada pelo sensor MAX30102. Este módulo emprega LEDs vermelho (660 nm)

e infravermelho (880 nm) junto com fotodetectores de alta sensibilidade para medir variações no volume sanguíneo via PPG. Além disso, o sensor possui conversor analógico-digital (ADC) interno de 18 bits e sensor de temperatura integrado para compensação térmica, comunicando-se com o microcontrolador pelo barramento I²C.

B. Infraestrutura de Rede e Medição

A infraestrutura de rede emprega um ESP32-S3 adicional configurado como nó *responder* FTM dedicado, garantindo estrita homogeneidade de *hardware* com o *initiator*. Para a caracterização de energia, um Nordic *Power Profiler Kit II* (PPK2) opera em modo *source meter*, permitindo avaliação do consumo de corrente com precisão de microssegundos. Todo o *firmware* foi desenvolvido utilizando o *Espressif IoT Development Framework* (ESP-IDF) para gerenciar eficientemente a pilha Wi-Fi e a persistência em Memória Não Volátil (NVS).

V. MÉTODOS

A metodologia experimental integra monitoramento fisiológico com gatilhos de eventos baseados em proximidade para maximizar a eficiência energética e minimizar a latência de resposta da rede. O cenário operacional é ilustrado na Fig. 3.



Fig. 3. Cenário experimental para teste de rotina.

A. Calibração Biométrica e Persistência

Para acomodar a variabilidade fisiológica individual, uma fase inicial de calibração é conduzida via *Bluetooth Low Energy* (BLE). Um aplicativo Android complementar permite ao usuário definir limiares específicos de FC para três estados distintos: repouso ($FC < 70$ bpm), em pé ($70 \leq FC \leq 100$ bpm) e em caminhada ($FC > 100$ bpm). Esses parâmetros são gravados na NVS do ESP32-S3, garantindo que a configuração persista através de ciclos de energia sem necessidade de recalibração diária.

B. Lógica Hierárquica e Gerenciamento de Conectividade

O dispositivo implementa uma estratégia de economia de energia, mantendo o microcontrolador em modo *Deep Sleep* durante períodos de inatividade. Conforme detalhado no Algoritmo 1, o fluxo de inicialização é inteiramente orientado a eventos: o deslocamento físico do usuário dispara uma interrupção por *hardware* no acelerômetro LIS3DH, acordando exclusivamente o coprocessador ULP para realizar amostragem biométrica de baixo consumo (FC) via MAX30102.

Os núcleos principais do ESP32-S3 só são despertados se o ULP confirmar uma transição fisiológica ativa ($FC > \text{Limiar}_{Em_Pe}$). Esse mecanismo em cascata aciona uma associação rápida com o Ponto de Acesso (AP) — que, por reutilizar as credenciais previamente armazenadas na NVS, reduz a latência de conexão de aproximadamente 3 s (reinicialização completa) para menos de 500 ms — executa o *ranging* FTM com $n = 5$ rajadas e sincroniza o *buffer* local B . Concluída a rotina, o Wi-Fi é desconectado e a CPU retorna ao *Deep Sleep*. Caso o sinal biométrico seja zerado ($FC \approx 0$), o processador principal é imediatamente acordado pelo ULP para disparar um alarme de segurança.

C. Detecção de Proximidade e Perfilamento Energético

O *setup* experimental considera a atenuação dinâmica do sinal: uma porta fechada introduz condições NLOS, aumentando o RTT, enquanto uma porta aberta proporciona *Line-of-Sight* (LOS). Um “evento de saída” é acionado autonomamente quando a distância estimada d se aproxima de um limiar de proximidade predefinido próximo a zero. Por fim, o Nordic PPK2 captura transientes de corrente com precisão de microssegundos durante o sensoriamento, a reconexão rápida do Wi-Fi e as rajadas de medição FTM.

Algorithm 1 Lógica Hierárquica Orientada a Eventos

Require: Int. LIS3DH, FC, RTT
Ensure: Sync, Alarmes

```

1: NVS Load;  $B \leftarrow \emptyset$ ; Iniciar em Deep Sleep
2: while Sistema Ativo do
3:   Aguardar LIS3DH  $\rightarrow$  Acordar ULP e amostrar FC em B
4:   if  $FC \approx 0$  then
5:     Acordar CPU Principal; Acionar AlarmeSeguranca
6:   else if  $FC > \text{Limiar}_{Em\_Pe}$  then
7:     Acordar CPU Principal; if offline then Conectar Wi-Fi
8:     Executar FTM ( $d, n = 5$  rajadas); Sincronizar buffer B
9:     if  $d \rightarrow 0$  e LOS then Acionar AlarmeSaída
10:    Limpar B; Desconectar Wi-Fi; Retornar CPU ao Deep Sleep
11:   else
12:     Retornar ULP ao Deep Sleep  $\triangleright$  Falso positivo ou repouso
13:   end if
14: end while
    
```

VI. RESULTADOS E DISCUSSÃO

O desempenho do dispositivo vestível IoMT proposto foi avaliado com foco na precisão da estimativa de distância, propagação do sinal e eficiência energética.

A. Precisão do FTM e Análise Estatística

A correlação entre a distância real e a estimativa FTM foi quantificada por regressão linear, resultando em $R^2 = 0,3712$ e equação de regressão $\hat{y} = 0,76x + 3,12$. Complementarmente, o MAE foi de 1,42 m e o RMSE de 1,78 m na faixa de 1 m a 7 m. Esses valores são coerentes com a literatura de *ranging* FTM em ambientes internos com condições NLOS:

trabalhos como [15] e [21] reportam R^2 entre 0,30 e 0,55 em cenários com obstruções físicas e interferência corporal, destacando que o FTM, mesmo com variância residual elevada, mantém tendência positiva superior à do RSSI para aplicações de detecção de proximidade.

O valor de $R^2 = 0,3712$ reflete a variância causada por desafios reais de propagação, multipercursos, condições NLOS e atenuação provocada pelo corpo humano. Apesar do ruído no sinal, a inclinação positiva de 0,76 demonstra tendência confiável para detecção de proximidade na faixa avaliada.

Enquanto as medições de RSSI exibiram alta instabilidade e degradação não linear entre -34 dBm e -61 dBm, o protocolo FTM manteve correlação linear superior, validando seu uso como métrica principal de localização. A não linearidade do RSSI está relacionada a flutuações rápidas das características do canal, *shadowing* e efeitos de multipercursos em ambientes internos. Estes resultados justificam a necessidade da Lógica Orientada a Eventos proposta, garantindo que os alarmes sejam acionados apenas mediante rajadas RTT de alta confiabilidade.




Fig. 4. Regressão linear da estimativa FTM e degradação do RSSI em função da distância.

B. Análise de Consumo Energético

O perfilamento energético realizado com o Nordic PPK2 confirmou que a fase de sensoriamento biométrico é o estado ativo menos intensivo, consumindo 58,34 mA (MAX30102 ativo com CPU principal operando a plena frequência). A ativação do protocolo FTM eleva esse consumo para 74,62 mA, representando um aumento de 28,6% em relação à linha de base do sensoriamento. A operação simultânea de FTM, BLE e MAX30102 atinge pico de 111,65 mA, tipicamente durante as fases iniciais de calibração e sincronização de dados.

TABELA II
CONSUMO DE CORRENTE POR MODO OPERACIONAL

Modo Operacional	Corrente Média (mA)
<i>Deep Sleep</i>	0,015
ULP + <i>Deep Sleep</i> [†]	0,428
LIS3DH + MAX30102 + <i>Deep Sleep</i> [‡]	1,57
LIS3DH + MAX30102 + ULP*	15,19
Sensoriamento (MAX30102)	58,34
Sensoriamento (LIS3DH)	26,81
BLE (Calibração/Ativo)	67,89
FTM (<i>Ranging</i> apenas)	74,62
FTM + BLE (Combinado)	102,34
FTM + BLE + MAX30102 + LIS3DH	111,65

Estas medições comprovam a eficácia da estratégia orientada a eventos. Ao manter o rádio Wi-Fi em modo estação (STA) desconectado e acionar as rajadas FTM estritamente

após alterações fisiológicas, o sistema evita a sobrecarga contínua de 74,62 mA. Conforme sumarizado na Tabela I, esta arquitetura se destaca por integrar detecção de proximidade mais estável e monitoramento vital em plataforma de baixo custo, superando os limites de precisão dos sistemas tradicionais baseados exclusivamente em RSSI.

C. Simulação de Autonomia e Durabilidade da Bateria

Para validar a viabilidade do dispositivo como vestível IoMT, estimou-se a autonomia teórica para uma bateria Li-Po de 200 mAh sob quatro perfis. As frações de tempo de cada modo foram definidas com base nos perfis típicos de mobilidade hospitalar descritos na literatura de IoMT [19], [4]: pacientes internados permanecem em repouso entre 85% e 95% do tempo, com episódios curtos de mobilidade.

- **Cenário A — Operação Contínua:** Rádio (FTM), BLE e sensores ativos durante 100% do tempo (111,65 mA). A autonomia seria de apenas 1,79 horas.
- **Cenário B — Uso Típico:** Modela a mobilidade intermitente com 90% do tempo em espera com sensores em modo autônomo (1,57 mA), 8% em aquisição biométrica ativa via CPU (58,34 mA) e 2% em localização FTM (111,65 mA) — frações compatíveis com rotinas hospitalares de monitoramento a cada 5 a 10 minutos. A corrente média de 8,31 mA resulta em 24,06 horas de autonomia.
- **Cenário C — Repouso Prolongado:** Representa o uso noturno com 98% em ULP + *Deep Sleep* (0,428 mA) e 2% em medições periódicas (58,34 mA), compatível com ciclos de medição a cada 30 minutos. O consumo médio de 1,58 mA permite 126 horas ($\approx 5,2$ dias) de operação.
- **Cenário D — Monitoramento Reativo via ULP:** Estratégia de eficiência máxima, com 99% do tempo em *Deep Sleep* com interrupção externa (0,015 mA) e 1% em leitura via ULP (15,19 mA) sem despertar o núcleo principal — adequado a cenários em que o dispositivo só acorda mediante detecção inercial de movimento. A corrente média cai para 0,167 mA, estendendo a autonomia para aproximadamente 50 dias (1199,4 horas).

Essas projeções quantificam o impacto da arquitetura hierárquica. O chaveamento dinâmico entre os estados de energia permite que uma bateria diminuta atenda aos requisitos de telemetria de saúde e localização contextual, superando a barreira energética do protocolo FTM em dispositivos restritos.

D. Resumo Comparativo

Este trabalho integra uma plataforma de baixo custo para monitoramento vital e detecção de proximidade por FTM. Diferentemente das abordagens baseadas em RSSI, a arquitetura proposta utiliza a temporização de *hardware* do ESP32-S3 para obter estimativas de proximidade mais estáveis em ambientes internos, mantendo eficiência energética por meio de operação orientada a eventos.

VII. CONCLUSÕES

A adoção do protocolo Wi-Fi FTM em dispositivos vestíveis IoMT apresenta-se como uma alternativa confiável para detecção de proximidade em ambientes internos, com correlação linear consistente entre 1 m e 7 m ($R^2 = 0,3712$, MAE = 1,42 m, RMSE = 1,78 m) em condições reais de propagação NLOS, valores compatíveis com resultados reportados na literatura para

cenários similares [15], [21]. Embora a exigência energética do rádio Wi-Fi imponha um desafio significativo, evidenciado pelo Cenário A (Operação Contínua), no qual o sistema esgota a bateria em apenas 1,79 horas, a arquitetura hierárquica orientada a eventos contorna efetivamente essa limitação. Ao implementar a estratégia de interrupção inercial via LIS3DH e processamento via ULP RISC-V, o sistema alcança sua maior eficiência no Cenário D (Monitoramento Reativo), reduzindo a corrente média para 0,167 mA e elevando a autonomia máxima para 1199,4 horas (aproximadamente 50 dias) com uma bateria Li-Po de apenas 200 mAh. Esses resultados validam a viabilidade de unir localização espacial e telemetria contínua de saúde em uma plataforma IoMT de baixo custo para supervisão de zonas restritas.

REFERÊNCIAS

- [1] L. H. D. S. Carrascosa *et al.*, “Fine time measurement protocol for distance estimation: practical analysis and experimental evaluation in industrial environments,” *Proc. INDUSCON*, 2025.
- [2] R. Jurdi *et al.*, “WhereArtThou: A WiFi-RTT-based indoor positioning system,” *IEEE Access*, vol. 12, pp. 41084–41101, 2024.
- [3] L. Qi *et al.*, “Current status and future trends of meter-level indoor positioning technology: A review,” *Remote Sens.*, vol. 16, p. 398, 2024.
- [4] M. Khafief *et al.*, “Design health care monitoring system using ESP32 controller based on cloud computing,” *Proc. IEEE PuneCon*, 2025.
- [5] J. G. U. Palacios-Campos *et al.*, “Monitoreo inteligente para la rehabilitación pulmonar: un enfoque innovador con PPG,” *TeCEO*, vol. 6, no. 12, pp. 151–169, 2024.
- [6] A. Komarudin *et al.*, “Design of an IoT-based patient bracelet for monitoring SpO₂, heart rate, and body temperature,” *Electromedic J.*, 2021.
- [7] A. M. Putra and V. Nurdinawati, “Pulse oximeter prototype equipped with monitoring on Android,” *Electromed. J. Med. Electron.*, 2025.
- [8] M. I. P. Pratama *et al.*, “Design and evaluation of an IoT-enabled ESP32 photoplethysmography monitor for heart rate and SpO₂,” *J. Tek. Elektro Komput. TRIAC*, 2025.
- [9] K. Rajguru *et al.*, “Design and implementation of IoT-based sleep monitoring system for insomniac people,” *Proc. 2nd ICAIS*, 2022.
- [10] N. A. Amirudin *et al.*, “Heart rate sensor with IoT features,” *E3S Web Conf.*, 2024.
- [11] U. Umiatin *et al.*, “Development of smart band for vital signs monitoring system based on internet of things,” *J. Phys. Conf. Ser.*, 2024.
- [12] N. V. V. Belmonte *et al.*, “Development of a cost-effective modular vital signs monitoring system for educational and remote healthcare applications,” *Proc. ENC*, 2025.
- [13] H. Amhenrior and P. Eragbe, “Design and implementation of an IoT-based patient’s health monitoring system,” *J. Eng. Res. Innov. Sci. Dev.*, 2024.
- [14] K. Konopko *et al.*, “Implementation of vital signs detection algorithm for supervising the evacuation of individuals with special needs,” *Sensors*, 2025.
- [15] F. Guan *et al.*, “Autonomous wireless positioning system using crowd-sourced Wi-Fi fingerprinting and self-detected FTM stations,” *Expert Syst. Appl.*, vol. 255, p. 124566, 2024.
- [16] M. A. Tjitra *et al.*, “A wireless noninvasive blood pressure measurement system using MAX30102 and random forest regressor for photoplethysmography signals,” *Computers*, 2024.
- [17] G. Tyuleberdinova *et al.*, “Development of a stress monitoring system architecture for heart rate measurement,” *Eng. Technol. Appl. Sci. Res.*, 2025.
- [18] R. Xu *et al.*, “RTT-LIO: A Wi-Fi RTT-aided LiDAR-inertial odometry via tightly-coupled factor graph optimization in complex scenes,” *IEEE Internet Things J.*, 2026.
- [19] J. Liu *et al.*, “Indoor localization methods for smartphones with multi-source sensors fusion: Tasks, challenges, strategies, and perspectives,” *Sensors*, vol. 25, 2025.
- [20] A. A. Kafsheen *et al.*, “Spider IoT-based wearable remote health monitoring system using machine learning,” *Proc. 13th JAC-ECC*, 2025.
- [21] K. J. Raja and P. D. Groves, “WiFi-RTT indoor positioning using particle, genetic and grid filters with RSSI-based outlier detection,” *J. Navig.*, 2025.
- [22] Z. Cui *et al.*, “Development and Performance Validation of a UWB-IMU Fusion Tree Positioning Device with Dynamic Weighting for Forest Resource Surveys,” 2025, doi: 10.3390/f16111703.