

Estimativa de Distância com Wi-Fi FTM em Ambiente de Floresta Amazônica Utilizando Filtragem Digital e Calibração

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

Resumo—A estimativa precisa de distância na floresta amazônica é prejudicada pela atenuação de sinal e multipercursos, limitando métodos baseados em RSSI. Este trabalho avalia o Wi-Fi Fine Time Measurement (FTM, IEEE 802.11mc) usando dispositivos ESP32-S3 de baixo custo em cenários reais LOS e NLOS. Filtros digitais (Kalman, média móvel simples e IIR), com calibração de ganho e ajuste de offset, foram aplicados para reduzir o ruído e o viés. Os resultados mostram que, em LOS, a acurácia melhora significativamente, atingindo erro submétrico (0,52 m MAE) em curtas distâncias. Em NLOS, apesar da redução da variância, persistem erros elevados (27,76 m MAE) devido a obstruções.

Palavras-Chave—Fine Time Measurement; IEEE 802.11mc; Estimação de Distância; Ambientes Florestais; Wi-Fi; ESP32-S3.

Abstract—Accurate distance estimation in the Amazon rainforest is challenged by signal attenuation and multipath, limiting RSSI methods. This work evaluates Wi-Fi Fine Time Measurement (FTM, IEEE 802.11mc) using low-cost ESP32-S3 devices in real LOS and NLOS scenarios. Digital filters (Kalman, SMA, IIR) with gain calibration and offset correction were applied to reduce noise and bias. Results show that, in LOS, accuracy improves significantly, achieving sub-meter error (0.52 m MAE) at short distances. In NLOS, although variance is reduced, large errors persist (27.76 m MAE) due to obstruction. These findings highlight both the potential and limitations of FTM in dense tropical forest environments.

Keywords—Fine Time Measurement; IEEE 802.11mc; Distance Estimation; Forest Environments; Wi-Fi; ESP32-S3.

I. INTRODUÇÃO

A demanda por localização precisa em ambientes onde o *Global Positioning System* (GPS) é indisponível ou degradado, como ambientes florestais ou internos, tem impulsionado uma mudança de paradigma na pesquisa em sensoriamento sem fio. No contexto específico da Amazônia, a vegetação densa e o “efeito cânion” causado por árvores de grande porte tornam os sinais de satélite praticamente inutilizáveis para operações táticas. Essa situação pode resultar em erros de localização. Nesse cenário, utilizar a infraestrutura Wi-Fi pode ser uma alternativa prática e de baixo custo para fornecer informações espaciais em ambientes remotos, sendo avaliada neste trabalho por meio do microcontrolador ESP32-S3 – um *System on a Chip* (SoC) de baixo custo e baixo consumo energético, com suporte nativo a Wi-Fi de banda dupla e compatibilidade com o protocolo IEEE 802.11mc [1].

Tradicionalmente, a localização baseada em Wi-Fi apoia-se em métricas de *Received Signal Strength* (RSS), devido à sua simplicidade e suporte nativo em dispositivos sem fio. No entanto, técnicas de *fingerpringing* com RSS são instáveis [2]. Em florestas tropicais, essa instabilidade é acentuada

pela alta umidade relativa e variações térmicas, que atuam como atenuadores dinâmicos [3]. Além disso, a propagação multipercursos, onde sinais são refletidos em troncos e folhagens, introduz variações na potência do sinal, limitando a precisão da estimativa de distância nesses ecossistemas [4]. Esse ambiente torna as abordagens baseadas em RSS inadequadas para aplicações que exigem maior precisão.

Para superar essas limitações, o padrão IEEE 802.11mc introduziu o protocolo *Fine Time Measurement* (FTM), focando na estimativa baseada no tempo de voo do sinal de rádio [5]. Ao medir o *Round Trip Time* (RTT) entre uma *Station* (STA) e um *Access Point* (AP), o FTM alcança precisão métrica baseada na troca de pacotes FTM (*Action frames*) entre STA e AP, permitindo a medição do tempo de voo sem que a STA efetivamente ingresse na rede daquele AP (processo de *handshake* completo com autenticação e obtenção de endereço IP), o que reduz a sobrecarga de sinalização e viabiliza medições rápidas com múltiplos pontos de referência [6]. Apesar desse potencial, há escassez de estudos sobre o FTM em floresta densa do tipo tropical, utilizando dispositivos de baixo custo, nos quais a dispersão e a obstrução da linha de visada direta (LOS) e sem linha de visada (NLOS) pela vegetação impõem desafios distintos de cenários urbanos [7].

No contexto da *Internet of Forest Things* (IoFT), fornecer posicionamento preciso em tempo real é essencial para o rastreamento de fauna. No entanto, as limitações de hardware de dispositivos de Internet das Coisas (*Internet of Things* - IoT) frequentemente comprometem a precisão do protocolo. Dessa forma, a aplicação de técnicas de calibração, como ajustes de ganho e *offset*, combinadas com filtragem digital, torna-se necessária para mitigar os vieses sistemáticos do FTM sob condições adversas de propagação [8], onde erros podem ultrapassar 20–30 m em condições NLOS.

Com isso, este trabalho avalia a viabilidade da estimativa de distância baseada em FTM utilizando o ESP32-S3 em ambiente real da floresta amazônica, diferindo de outros trabalhos existentes, que se concentram predominantemente em ambientes internos ou urbanos, utilizando hardware de baixo custo e analisando explicitamente cenários LOS e NLOS. Os resultados indicam que é possível alcançar erros submétricos (0,5 m) em condições LOS, enquanto erros superiores a dezenas de metros persistem em cenários NLOS. As contribuições incluem uma avaliação sistemática de cenários LOS/NLOS, uma análise comparativa entre os filtros Kalman, IIR e Média Móvel, e a validação de configurações de baixo consumo para aplicações de longa duração em campo.

II. FINE TIME MEASUREMENT

O protocolo FTM calcula a distância entre dispositivos Wi-Fi medindo o RTT (*Round Trip Time*) com alta precisão, utilizando os tempos de chegada (*Time of Arrival* - ToA) e de partida (*Time of Departure* - ToD) amostrados na ordem de nanossegundos [9].

A Figura 1 ilustra essa troca de pacotes. Após o reconhecimento da requisição inicial, o respondedor (*Responder*) transmite um pacote FTM no instante t_1 . Ao recebê-lo em t_2 , o iniciador (*Initiator*) devolve um pacote ACK no instante t_3 , o qual chega ao respondedor em t_4 . O RTT médio para um conjunto de n medições (*bursts*) é calculado usando a Equação (1). Por fim, a distância é obtida multiplicando o RTT pela velocidade da luz (c) e dividindo por dois, conforme a Equação (2).




Fig. 1. Demonstração de operação do FTM [9].

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

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

III. TRABALHOS RELACIONADOS

As pesquisas científicas sobre localização usando sinais Wi-Fi começaram com cálculos simples de intensidade do sinal e agora utilizam sistemas mais elaborados que se apoiam em informações sobre os dados e tempo de propagação. Com o avanço do Wi-Fi 8 (o padrão IEEE 802.11bn), a prioridade é conseguir medir distâncias de forma mais precisa, o que é fundamental para aplicações de monitoramento à distância [9]. Apesar de o FTM conseguir ser bem preciso, medindo distâncias com menos de um metro, interferências físicas e dessincronismo nos relógios dos dispositivos e tempos de processamento do sinal, podem fazer a precisão ficar por volta de um metro na frequência de 2,4 GHz [17].

Para rastreamento de objetos, técnicas como filtragem de Kalman e aprendizado com sensores ajudam a suavizar as medições de distância [10]. No entanto, essas soluções exigem hardware caro e pouco escalável para o monitoramento florestal em larga escala. Em contrapartida, implementações em microcontroladores de baixo custo, como o ESP32-S3, mostraram que os efeitos de múltiplos caminhos em ambientes

obstruídos geram erros, destacando a necessidade de calibração específica [6], [14].

A camada de hardware também é crucial para a precisão do FTM. Conversores de Tempo para Digital (*Time-to-Digital Converters* - TDCs) em FPGAs alcançam resolução de picossegundos, mas são suscetíveis a variações de processo e temperatura [18], muitas vezes exigindo *machine learning* para autocalibração [12], [19]. Estudos recentes também utilizam Modelos de Linguagem de Grande Escala (*Large Language Models* - LLMs) para processar telemetria Wi-Fi e inferir relações espaciais [17]. Contudo, essa alta demanda computacional e energética torna elas inadequadas para dispositivos IoT com recursos limitados.

A Tabela 1 resume os trabalhos da literatura, evidenciando que quase todos foram realizados em ambientes fechados e controlados. Fica clara a escassez de pesquisas focadas em cenários florestais que utilizem simultaneamente equipamentos de baixo custo e alta eficiência energética.

Métodos híbridos que unem o FTM a Informações de Estado de Canal (*Channel State Information* - CSI) ou Sinais de Oportunidade (*Signals of Opportunity* - SoOp) também ganharam destaque. O CSI detalha o ambiente de múltiplos caminhos e reduz o erro para cerca de 0,3 metros [13], [17], mas seu alto custo computacional o inviabiliza para nós IoT de baixa potência [20]. Adicionalmente, o rastreamento multimodal tem sido proposto para manter o posicionamento quando os sinais primários sofrem obstrução total [15].

Avaliações práticas em ambientes desafiadores, como fábricas [16], [21], revelam que limitações de *firmware* frequentemente impedem o acesso aos dados brutos necessários para análises profundas dos sinais [11]. Apesar disso, além da localização, o FTM já é aplicado com sucesso na detecção de presença humana e de micromovimentos, como a respiração, usando análise Doppler em hardware comercial [22].

Como resumido na Tabela I, nenhum dos trabalhos analisados combina, simultaneamente, avaliação em ambiente florestal, calibração, testes em LOS e NLOS, caracterização de consumo de energia e uso de MCUs de recursos limitados – lacuna que este trabalho busca preencher, conforme detalhado na metodologia a seguir.

IV. MATERIAIS E MÉTODOS

A metodologia desenvolvida para avaliar o desempenho e a viabilidade do protocolo FTM no desafiador ambiente da floresta Amazônica foi estruturada em um *pipeline* composto por quatro etapas principais: (1) Configuração Experimental, (2) Coleta de Dados, (3) Processamento de Sinais e (4) Calibração e Análise Estatística. O hardware consistiu em dois microcontroladores ESP32-S3. Estes dispositivos foram programados utilizando o *framework* ESP-IDF e o sistema operacional de tempo real FreeRTOS, com um dispositivo configurado como AP e o outro como STA.

As campanhas de medição foram conduzidas na Base de Instrução Plácido de Castro, em Manaus (AM), um cenário que permitiu capturar com fidelidade os severos efeitos de atenuação do sinal e a intensa propagação em múltiplos caminhos (*multipath*) característicos da densa vegetação real. Para uma análise abrangente, os testes contemplaram cenários de LOS e NLOS, conforme ilustrado na Fig. 2 e na Fig. 3.

Durante a fase de coleta, diversas configurações de rádio foram exaustivamente testadas para compreender seu impacto

TABELA I
COMPARAÇÃO DE TRABALHOS RELACIONADOS COM BASE EM FATORES-CHAVE.

Referência	[3], [4]	[6], [7], [8]	[10]	[11], [12], [13]	[14], [15]	[5]	[16]	Este Trabalho
Ambiente Florestal								X
Calibração	X	X			X	X		X
LOS e NLOS		X	X	X		X	X	X
Consumo de Energia					X	X		X
MCU com Recursos Limitados				X	X	X	X	X

na precisão, incluindo variações na largura de banda (20 MHz e 40 MHz), diferentes níveis de potência de transmissão e ajustes no tamanho dos *bursts* de medição. Paralelamente, o consumo e a sustentabilidade energética do sistema foram monitorados rigorosamente utilizando um *Power Profiler Kit II* (PPK2), permitindo mapear a demanda de energia nos diferentes estados de operação do ESP32-S3.



Fig. 2. Operação do FTM sob condições LOS em ambiente florestal.



Fig. 3. Operação do FTM sob condições NLOS em ambiente florestal.

O processo de estimativa bruta de distância, fundamentado no cálculo do *Round Trip Time* (RTT) a partir da troca de *timestamps* entre os dispositivos na ordem de nanossegundos, é formalizado no Algoritmo 1. Contudo, os dados brutos de FTM são sabidamente ruidosos e sujeitos a vieses sistemáticos causados por atrasos inerentes ao hardware. Para mitigar esse problema, implementou-se um modelo de calibração baseado em uma transformação linear, definido na Equação (3). Os parâmetros dessa calibração foram ajustados para os cenários LOS e NLOS, refletindo a diferença comportamental do sinal em cada tipo de ambiente:

$$d_{cal} = \alpha \cdot d_{est} + \beta \quad (3)$$

onde d_{est} representa a distância bruta estimada pelo FTM (em metros), d_{cal} é a distância final calibrada (em metros), α (adimensional) atua como o fator de ganho e β (em metros) representa o *offset*. Os parâmetros de calibração empregados nos testes, obtidos por regressão linear entre a distância de referência e a distância bruta estimada, são apresentados na Tabela II: $\alpha = 0,373$ e $\beta = 2,657$ m para o cenário LOS, e $\alpha = 0,052$ e $\beta = 9,238$ m para o cenário NLOS.

Algorithm 1 Estimativa de Distância Baseada no Protocolo FTM

Require: Número de medições (*bursts*) N

Ensure: Conjunto de distâncias estimadas $\mathcal{D}$

- 1: Inicializar $\mathcal{D} \leftarrow \emptyset$
- 2: **for** $i \leftarrow 1$ até N **do**
- 3: Transmitir requisição FTM da STA para o AP
- 4: Registrar e receber as marcas de tempo (timestamps) t_1, t_2, t_3, t_4
- 5: Calcular o Tempo de Ida e Volta (RTT): $RTT \leftarrow (t_4 - t_1) - (t_3 - t_2)$
- 6: Converter o tempo em distância física: $d \leftarrow \frac{RTT \cdot c}{2}$
- 7: Adicionar d ao conjunto $\mathcal{D}$
- 8: **end for**
- 9: **return** $\mathcal{D}$

A. Métricas de Avaliação

A precisão da estimativa de distância baseada em FTM foi avaliada utilizando métricas que quantificam a magnitude do erro e a qualidade do ajuste entre as distâncias de referência (y_i) e as estimadas ($\hat{y}_i$).

Erro Absoluto Médio (MAE): Mede a magnitude média do erro de estimativa em metros, tratando as diferenças de forma equivalente e fornecendo uma interpretação direta da acurácia do sistema:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

Erro Médio Absoluto Percentual (MAPE): Compara erros proporcionais em diferentes faixas de distância. Uma constante pequena ϵ evita instabilidade quando y_i se aproxima de zero:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{\max(\epsilon, y_i)} \right| \quad (5)$$

Raiz do Erro Quadrático Médio (RMSE): Enfatiza erros maiores devido ao termo quadrático, sendo útil para identificar desvios causados por múltiplos caminhos de propagação:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

Coefficiente de Determinação (R^2): Avalia o quão bem os valores estimados explicam a variabilidade dos dados medidos (onde $\bar{y}$ é a média das referências). Valores próximos de 1 indicam forte concordância:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

B. Técnicas de Filtragem Digital

Como as medições brutas de FTM apresentaram alta variabilidade, aplicamos filtros digitais para estabilizar as estimativas. Foram avaliados três filtros que oferecem diferentes compensações entre poder de processamento e responsividade, tornando-os apropriados para dispositivos IoT de baixo consumo de energia.

Filtro de Kalman: Um estimador recursivo linear que minimiza o erro por meio de predição e atualização, equilibrando incertezas do modelo e da medição. Sem entrada de controle conhecida ($u_k = 0$), a predição é dada por:

$$\hat{x}_{k|k-1} = F_k \hat{x}_{k-1|k-1} \quad (8)$$

$$P_{k|k-1} = F_k P_{k-1|k-1} F_k^T + Q_k \quad (9)$$

sendo $\hat{x}_{k|k-1}$ o estado predito, F_k a matriz de transição de estado, $P_{k|k-1}$ a covariância do erro de predição e Q_k a covariância do ruído de processo. A atualização, a partir da medição z_k , é dada por:

$$K_k = P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1} \quad (10)$$

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k (z_k - H_k \hat{x}_{k|k-1}) \quad (11)$$

$$P_{k|k} = (I - K_k H_k) P_{k|k-1} \quad (12)$$

onde H_k é a matriz de observação e R_k a covariância do ruído de observação. R_k e Q_k foram fixados empiricamente a partir da variância dos dados de calibração; se mal estimados, o filtro pode divergir, sobretudo em NLOS, onde o ruído é altamente não estacionário.

Média Móvel Simples (SMA): Uma técnica passa-baixas de simples processamento que suaviza o sinal pela média das amostras em uma janela M . Embora reduza flutuações, introduz atraso à medida que M aumenta:

$$\hat{y}_k = \frac{1}{M} \sum_{i=0}^{M-1} y_{k-i} \quad (13)$$

Filtro IIR: Uma abordagem recursiva de baixo custo computacional, onde α é o fator de suavização:

$$\hat{y}_k = \alpha y_k + (1 - \alpha) \hat{y}_{k-1} \quad (14)$$

V. RESULTADOS E DISCUSSÃO

Esta seção apresenta uma análise quantitativa e qualitativa dos experimentos realizados na Base de Instrução Plácido de Castro, em Manaus. Os dados foram examinados sob as perspectivas de estabilidade temporal, precisão métrica e viabilidade energética, comparando o comportamento do protocolo FTM bruto frente às técnicas de mitigação propostas.

A. Análise do Comportamento do Sinal em Ambientes Florestais

Os resultados indicam que a propagação de radiofrequência (RF) em 2,4 GHz no bioma amazônico impõe severas restrições ao protocolo FTM devido à vegetação densa. As medições brutas exibiram uma vulnerabilidade intrínseca ao espalhamento e à absorção eletromagnética. Em cenários de visada direta (LOS), embora uma correspondência inicial entre a distância estimada e a distância real tenha sido observada,

uma tendência consistente de superestimativa surgiu além dos 6 metros.

Em distâncias LOS de 10 m, 11 m e 12 m, foram registrados valores de pico superiores a 20 m, resultando em um MAE de 13,48 m para uma distância real de 13 m. Em condições de visada obstruída (NLOS), os erros intensificaram-se drasticamente: para uma distância real de 11 m, o MAE bruto atingiu 39,44 m, com um Erro Médio Absoluto Percentual (MAPE) crítico de 358,57%. Esse fenômeno valida a premissa de que o ambiente florestal atua como um meio altamente refrativo e difuso, onde o RTT é severamente impactado por reflexões de múltiplos caminhos em troncos e folhagens.

B. Eficácia de Filtros Digitais na Atenuação de Ruído

A filtragem digital provou ser essencial para mitigar a natureza estocástica dos sinais RTT em folhagem densa. Em condições LOS, a filtragem aumentou significativamente a estabilidade métrica. Em uma distância real de 7 m, a telemetria bruta exibiu um MAE de 0,80 m e um MAPE de 11,42%. O filtro de Kalman superou os demais ao ajustar dinamicamente o ganho de estimativa com base na covariância da medição. Essa abordagem recursiva refinou as estimativas para um MAE de 0,52 m e um MAPE de 7,51%. Ao contrário do IIR, que calcula a média de estados passados, a etapa preditiva do filtro de Kalman manteve a responsividade ao movimento do nó, enquanto suprimia outliers induzidos por multicaminhos, típicos do solo da floresta.




Fig. 4. Estimativa de distância FTM sob condições LOS com filtros digitais.

Em contrapartida, os cenários NLOS exibiram altos níveis de erro devido ao espalhamento eletromagnético da biomassa arbórea. Aos 11 m, a telemetria bruta atingiu um MAE de 39,44 m. Como ilustrado na Fig. 5, o filtro de Kalman proporcionou uma mitigação mais eficaz sob obstrução, reduzindo o erro para um MAE de 27,76 m. Embora a filtragem não consiga eliminar o viés sistemático causado pela vegetação, a implementação de Kalman reduziu a variância do sinal e agrupou as estimativas.

C. Impacto da Calibração de Ganho e Offset

A calibração via regressão linear corrigiu a superestimativa sistemática das medições FTM. Conforme a Tabela II, os parâmetros LOS (ganho 0,373; offset 2,657 m) contrastam com o cenário NLOS (offset 9,238 m; ganho 0,052), onde o espalhamento e reflexões causam atrasos severos. Esse ajuste rotacionou as curvas para a tendência linear ideal, eliminando o efeito de *error-climbing* e garantindo o alinhamento das estimativas com a realidade física antes da etapa de filtragem.




Fig. 5. Estimativa de distância FTM sob condições NLOS com filtros digitais.

 TABELA II
PARÂMETROS DE CALIBRAÇÃO PARA CENÁRIOS LOS E NLOS.

Parâmetro	Calibração LOS	Calibração NLOS
Ganho α (adimensional)	0,373	0,052
Offset β (m)	2,657	9,238

D. Análise de Consumo Energético e Autonomia

O perfil de potência do ESP32-S3 foi caracterizado com um PPK2 (100 kHz) para avaliar o consumo em sessões FTM nos modos AP e STA (20/40 MHz). Conforme a Tabela III, o uso de um conversor *DC/DC Buck* reduziu a corrente média para 68,52 mA, superando o regulador de baixa queda de tensão (*Low-Dropout Regulator* - LDO), que consumiu 92,76 mA. O modo STA em 20 MHz mostrou-se o mais eficiente, enquanto o modo AP consumiu até 88,12 mA devido ao *overhead* de *beacons*. Com uma bateria de 2400 mAh, estima-se uma autonomia de 21,2 horas no modo STA otimizado, validando o ESP32-S3 para coleta contínua de dados espaciais em campo, mesmo antes da aplicação de estratégias de *sleep*.

 TABELA III
CONSUMO MÉDIO DE CORRENTE.

Modo	Largura de Banda	Corrente Média (mA)
AP	40 MHz	88,12
AP	20 MHz	85,34
STA	40 MHz	72,45
STA	20 MHz	68,52

VI. CONCLUSÕES

Este estudo valida a aplicação do protocolo FTM IEEE 802.11mc para estimativa de distância na floresta amazônica densa utilizando o hardware ESP32-S3, estabelecendo uma estrutura experimental para sistemas IoFT. A pesquisa demonstrou que a elevada biomassa e umidade do bioma intensificam a interferência por multicaminhos e a atenuação do sinal, gerando erros nas medições, sobretudo em cenários NLOS. Para mitigar tais imprecisões, foi essencial aplicar uma calibração baseada em ajustes de ganho e *offset* ($\alpha = 0,373$ e $\beta = 2,657$ m para LOS; $\alpha = 0,052$ e $\beta = 9,238$ m para NLOS), em conjunto com um filtro de Kalman recursivo. Essa abordagem reduziu o erro médio absoluto (MAE) para 0,52 m em condições LOS a 7 m, atingindo um MAE global de 0,8 m e RMSE de 0,93 m, superando significativamente os métodos baseados em RSSI em termos de acurácia e estabilidade para o rastreamento de ativos. Complementarmente, a caracterização energética realizada com o PPK2 validou a viabilidade de

operação remota, apontando o modo STA em 20 MHz com conversor *DC/DC Buck* como a configuração mais eficiente, com consumo médio de 68,52 mA e autonomia aproximada de 21 horas com uma bateria de 2400 mAh.

Como observado na Seção IV-C, a estabilidade do filtro de Kalman depende diretamente de uma boa estimativa das covariâncias de ruído de observação (R_k) e de processo (Q_k), que neste trabalho foram fixadas empiricamente. Em cenários NLOS, onde o ruído é fortemente não estacionário, essa dependência pode levar à divergência do filtro. Trabalhos futuros deverão, portanto, investigar o uso de um subfiltro de Kalman linear dedicado à estimação recursiva e em tempo real de R_k e Q_k a partir das próprias observações, o que tende a ser particularmente útil para reduzir a divergência em condições NLOS. Além disso, pretende-se explorar o treinamento de modelos de aprendizado de máquina na borda e a fusão de sensores com informações de estado do canal (CSI), visando soluções escaláveis e energeticamente eficientes para o monitoramento de biomassa, rastreamento de vida selvagem e segurança operacional em ecossistemas tropicais.

REFERÊNCIAS

- [1] K. Pahlavan and P. Krishnamurthy, "Evolution and Impact of Wi-Fi Technology," Springer, 2021.
- [2] L. Polak et al., "RSS Fingerprinting-Based Indoor Localization Using Machine Learning," *Sensors*, vol. 21, 2021.
- [3] O. Hashem, K. A. Harras, and M. Youssef, "Accurate Indoor Positioning Using IEEE 802.11mc Round Trip Time," *Pervasive and Mobile Computing*, vol. 75, 101416, 2021.
- [4] A. Karamyshev et al., "A Tutorial on Wi-Fi 8," *Problems of Information Transmission*, vol. 61, no. 2, 2025.
- [5] "Wi-Fi RTT (IEEE 802.11mc)," Android Source, 2021.
- [6] V. Barral Vales et al., "FTM for IoT Using ESP32," *IEEE IoT Journal*, vol. 9, no. 19, 2022.
- [7] K. Jiokeg, G. Jakllari, A. Tchana, and A.-L. Beylot, "When FTM Discovered MUSIC: Accurate Wi-Fi-based Ranging in the Presence of Multipath," *IEEE INFOCOM*, 2020.
- [8] M. Stenner et al., "Adaptive Filtering for WiFi FTM Distance Measurements," *UbiComp Companion*, 2025.
- [9] L. H. D. S. Carrascosa et al., "FTM Distance Estimation: Experimental Evaluation," *IEEE INDUSCON*, 2025.
- [10] J. Choi, "Enhanced Wi-Fi RTT Ranging Using Sensor-Aided Learning," *IEEE Trans. Vehicular Technology*, vol. 71, no. 4, 2022.
- [11] M. Ibrahim et al., "Accuracy Evaluation of WiFi FTM," *ACM MobiCom*, 2018.
- [12] Y. Huang et al., "FPGA-Based TDC for Time Synchronization," *Sensors*, vol. 26, no. 5, 2026.
- [13] Y. Yang and C. Toth, "Fusion of SoOp and Photogrammetry for Indoor Positioning," *Measurement*, 2025.
- [14] A. Zubow et al., "Simulation of WiFi FTM in NS-3," *Computer Communications*, vol. 210, 2023.
- [15] H. Zhang et al., "Multimodal Tracking and Sensor Fusion," *IEEE TPAMI*, 2025.
- [16] S. Xu et al., "Two-Step Fusion Method for WiFi FTM Indoor Positioning," *Sensors*, vol. 22, 2022.
- [17] N. S. Bhatia et al., "Indoor Localization Using Transformer Models," *arXiv*, 2025.
- [18] I. M. Protchenko and V. N. Malyshev, "Localization of WiFi Nodes Based on FTM," *Information and Control Systems*, 2025.
- [19] A. A. Bardpareh et al., "FPGA-Based TDC with ML Self-Calibration," *HardwareX*, vol. 18, 2026.
- [20] F. Nikseresht and B. Campbell, "FTM-Sense: Sensor-free Occupancy via WiFi FTM," *ACM BuildSys*, 2023.
- [21] M. W. Abdulrazzaq et al., "FTM in Indoor Factory Environments," *IEEE ICETI*, 2024.
- [22] J. Sanson et al., "Human Presence Detection via Wi-Fi Doppler Spectrum," *arXiv*, 2026.