

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS DE ENERGIA

ANGELA CRISTINA EYNG

**SISTEMA HÍBRIDO DE LOCALIZAÇÃO PARA  
AMBIENTES INTERNOS ASSISTIDO POR FILTRO DE  
KALMAN E FUSÃO DE VETORES DE ESTADO**

DISSERTAÇÃO

CURITIBA

2020

ANGELA CRISTINA EYNG

**SISTEMA HÍBRIDO DE LOCALIZAÇÃO PARA  
AMBIENTES INTERNOS ASSISTIDO POR FILTRO DE  
KALMAN E FUSÃO DE VETORES DE ESTADO**

Dissertação apresentada ao Programa de Pós-graduação em Sistemas de Energia da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do título de “Mestre em Engenharia Elétrica” – Área de Concentração: Automação e Sistemas de Energia.

Orientador: Prof. Dr. Ohara Kerusauskas  
Rayel

Coorientador: Prof. Dr. Elder Oroski

CURITIBA  
2020

#### **Dados Internacionais de Catalogação na Publicação**

Eyng, Angela Cristina

Sistema híbrido de localização para ambientes internos assistido por filtro de Kalman e fusão de vetores de estado [recurso eletrônico] / Angela Cristina Eyng. -- 2020.

1 arquivo eletrônico (59 f.): PDF; 703 KB.

Modo de acesso: World Wide Web.

Texto em português com resumo em inglês.

Dissertação (Mestrado) - Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Sistemas de Energia. Área de Concentração: Automação e Sistemas de Energia. Linha de pesquisa: Sistemas de Automação e Instrumentação, Curitiba, 2020.

Bibliografia: f. 55-58.

1. Sistemas de energia elétrica - Dissertações. 2. Sistemas de posicionamento interno (Localização sem fio). 3. Sistemas híbridos. 4. Impressões digitais. 5. Tecnologia bluetooth. 6. Kalman, Filtragem de. 7. Fusão de dados multisensores. 8. Serviços baseados em localização. 9. Sistemas de comunicação sem fio. 10. Internet das coisas. 11. Métodos de simulação. I. Rayel, Ohara Kerusauskas, orient. II. Oroski, Elder, coorient. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Sistemas de Energia. IV. Título.

CDD: Ed. 23 -- 621.31

**Biblioteca Central do Câmpus Curitiba - UTFPR**  
**Bibliotecária: Luiza Aquemi Matsumoto CRB-9/794**

## TERMO DE APROVAÇÃO DE DISSERTAÇÃO

A Dissertação de Mestrado intitulada “**Sistema Híbrido de Localização para Ambientes Internos Assistido por Filtro de Kalman e Fusão de Vetores de Estado**”, defendida em sessão pública pelo candidato(a) **Angela Cristina Eyng**, no dia 20 de fevereiro de 2020, foi julgada para a obtenção do título de Mestre em Engenharia Elétrica, **Área de concentração** Automação e Sistemas de Energia, **Linha de pesquisa** Sistemas de Automação e Instrumentação, e aprovada em sua forma final, pelo Programa de Pós-Graduação em Sistemas de Energia.

### BANCA EXAMINADORA:

Prof. Dr. Ohara Keraususkas Rayel – Presidente – UTFPR

Prof. Dr. Marcelo Eduardo Pellenz – PUCPR / UFPR

Prof. Dr. Guilherme Luiz Moritz – UTFPR

A via original deste documento encontra-se arquivada na Secretaria do Programa, contendo a assinatura da Coordenação após a entrega da versão corrigida do trabalho.

Curitiba, 20 de fevereiro de 2020.

---

Carimbo e Assinatura do(a) Coordenador(a) do Programa

## AGRADECIMENTOS

Gostaria de expressar meus agradecimentos a todos que, das mais variadas formas, contribuíram para a realização deste trabalho, em especial:

aos meus pais, Margarida e José Augusto, por serem os maiores incentivadores dos meus sonhos;

ao meu marido, Thiago, e aos meus sogros, Bernardete e Siegfried, pelo apoio e carinho incomparáveis;

ao meu orientador, Professor Doutor Ohara Kerusauskas Rayel, por toda dedicação e paciência com a qual me mostrou o caminho a ser seguido neste trabalho. Muito obrigada por ter me corrigido quando necessário sem nunca me desmotivar;

ao Professor Doutor Elder Oroski pela disponibilidade em aceitar fazer parte desse projeto e, de maneira primorosa, acrescentar ideias imprescindíveis para o presente resultado;

ao Professor Doutor João Luiz Rebelatto, pelas valiosas colaborações na publicação realizada;

aos Professores Doutores Guilherme Moritz e Marcelo Pellenz, pela participação na banca examinadora e que juntos com os supracitados são exemplos de profissionais, pelos quais mantenho profunda admiração;

a minha amiga e colega de profissão, Paola Botega, pelo auxílio nas revisões e palavras de incentivo;

aos meus grandes amigos e amigas, que possuo nas mais diversas esferas de minha vida, pela amizade, compreensão e companheirismo.

*“A tarefa não é tanto ver aquilo que ninguém viu, mas pensar o que ninguém ainda pensou sobre aquilo que todo mundo vê.”*  
— Arthur Schopenhauer

## RESUMO

EYNG, Angela C.. Sistema Híbrido de Localização para ambientes internos assistido por Filtro de Kalman e Fusão de Vetores de Estado. 58 f. Dissertação – Programa de Pós-graduação em Sistemas de Energia, Universidade Tecnológica Federal do Paraná. Curitiba, 2020.

Neste trabalho propõe-se um Sistema Híbrido de Localização para Ambientes Internos (H-IPS, do inglês *Hybrid Indoor Positioning System*) baseado no mecanismo de *beacons* do Bluetooth Low Energy (BLE). Realiza-se a fusão das técnicas de *Fingerprinting* (FP) e Multilateração (MLT), ambas baseadas no Indicador de Intensidade de Sinal Recebido (RSSI, do inglês *Received Signal Strength Indicator*). O objetivo é estimar a localização de um objeto móvel em um ambiente fechado, considerando que este segue um modelo de movimento com velocidade constante. Aplica-se um Filtro de Kalman (FK) para cada saída (FP e MLT), com o objetivo de suavizar o erro associado a cada técnica. Finalmente, é realizada a fusão dos vetores de estado obtidos após a filtragem, para reduzir a incerteza do posicionamento obtido. Os resultados indicam que o esquema proposto apresenta um aumento na precisão da estimativa de posição de 46%, quando comparado com a técnica de FP, e de aproximadamente 54%, quando comparado com a técnica de MLT. Além disso, analisou-se a influência do tamanho da grade utilizada para estruturar o banco de dados de *fingerprinting*, o número de Pontos de Acesso (APs, do inglês *Access Points*) e como o número de amostras utilizadas afeta a precisão do esquema apresentado. Por fim, os resultados mostram que a probabilidade de que o erro de distância do H-IPS desenvolvido seja menor do que 2 m é 92%, enquanto que para FP e MLT a mesma probabilidade é de 43% e 47%, respectivamente.

**Palavras-chave:** *Fingerprinting*, Multilateração, Sistema de Localização para Ambientes Internos, Internet das Coisas, Filtro de Kalman, Fusão Sensorial

## ABSTRACT

EYNG, Angela C.. Kalman Filtering and State Vector Fusion-Aided Hybrid Indoor Positioning System. 58 f. Dissertação – Programa de Pós-graduação em Sistemas de Energia, Universidade Tecnológica Federal do Paraná. Curitiba, 2020.

In this work it was considered the Bluetooth Low Energy (BLE) beaconing mechanism to propose an Hybrid Indoor Positioning System (H-IPS) that fuses both multilateration (MLT) and fingerprinting (FP) RSSI-based approaches. The aim is to estimate the localization of an indoor target node, which is assumed to follow a uniform motion model. It was adopted Kalman Filtering (KF) to diminish the MLT and FP errors while performing a track-to-track fusion (TTF) of the two KF outputs to further improve the performance. The results indicate that the proposed H-IPS improves the estimation accuracy when individually compared to the standalone FP scheme in up to 46% in the considered scenarios, while the standalone MLT is outperformed in approximately 54%. Moreover, some insights on the influence of parameters such as the FP grid size, number of access points (APs) and number of samples on the accuracy of the proposed scheme are provided. Finally, it is shown that the probability that the distance error of the proposed H-IPS is lower than 2 m is 92%, while for the FP and MLT the same probability is 43% and 47%, respectively.

**Keywords:** Fingerprinting, Multilateration, Indoor Positioning System, Internet of Things, Kalman Filtering, Sensor Fusion

## LISTA DE FIGURAS

Figura 1	– A visão geral da IoT, enfatizando os mercados verticais e sua integração horizontal. ....	14
Figura 2	– Áreas de aplicação de Serviços Baseados em Localização. ....	15
Figura 3	– Exemplo de trilateração considerando que os círculos representam o a distâncias estimadas para cada AP. A interseção resulta em uma área onde se estima que o nó esteja localizado. ....	27
Figura 4	– a) Fluxo básico do sistema e b) Mapa do ambiente em um sistema de localização interna baseado em Wi-Fi. $[-52, -60, -65, -71]$ representa os níveis de sinal, em dBm, dos 4 APs. ....	30
Figura 5	– Algoritmo original da fusão dos vetores de estado. ....	36
Figura 6	– Algoritmo modificado da fusão dos vetores de estado. ....	37
Figura 7	– Arquitetura típica para sistemas baseados em iBeacon. ....	38
Figura 8	– Modelo do diagrama do H-IPS proposto auxiliado por FK e fusão de vetores de estado. ....	40
Figura 9	– Posição real no cenário $l = 60$ m, $w = 40$ m, $N = 8$ , tamanho da grade dos FRPs é $5$ m $\times$ $5$ m. ....	47
Figura 10	– Posição real, FP, MLT e H-IPS para $l = 60$ m, $w = 40$ m, $N = 8$ , tamanho da grade dos FRPs é $5$ m $\times$ $5$ m e 200 passos ao longo do caminho, com marcadores a cada 4 passos. ....	47
Figura 11	– Erro médio versus o tamanho da grade, para $N = 8$ APs. ....	48
Figura 12	– Tamanho do banco de dados versus o tamanho da grade, para $N = 8$ APs. ....	49
Figura 13	– Erro médio em função do número de amostras. ....	51
Figura 14	– Função de Distribuição Cumulativa (CDF) do erro da distância para $N = 8$ APs e tamanho de grade dos FRPs igual a $5$ m $\times$ $5$ m. ....	51

## LISTA DE TABELAS

Tabela 1	–	Parâmetros do Sistema. ....	46
Tabela 2	–	Erro médio (em metros) para diferentes números de APs ....	50
Tabela 3	–	$r$ que minimiza o erro médio do FK ....	50

## LISTA DE SIGLAS

AoA	Ângulo de Chegada, do inglês, <i>Angle of Arrival</i>
AoI	Área de Interesse, do inglês, <i>Area of Interest</i>
AP	Ponto de Acesso, do inglês, <i>Access Point</i>
BLE	Bluetooth de Baixo Consumo, do inglês, <i>Bluetooth Low Energy</i>
CDF	Função de Distribuição Cumulativa, do inglês, <i>Cumulative Distribution Function</i>
FK	Filtro de Kalman
FP	Impressão Digital, do inglês, <i>Fingerprinting</i>
FRP	Ponto de Referência do <i>Fingerprinting</i> , do inglês, <i>Fingerprinting Reference Point</i>
GNSS	Sistema de Navegação Global por Satélite, do inglês, <i>Global Navigation Satellite System</i>
GPS	Sistema de Posicionamento Global, do inglês, <i>Global Positioning System</i>
H-IPS	Sistema Híbrido de Localização para Ambientes Internos, do inglês, <i>Hybrid Indoor Positioning System</i>
IoT	Internet das Coisas, do inglês, <i>Internet of Things</i>
IPS	Sistemas de Posicionamento em Ambientes Internos, do inglês, <i>Indoor Positioning System</i>
ISM	Industriais, Científicas e Médicas, do inglês, <i>Industrial Scientific and Medical</i>
KNN	$\kappa$ Vizinhos Mais Próximos, do inglês, <i>K-Nearest Neighbours</i>
LoS	Linha de Visada, do inglês, <i>Line of Sight</i>
MLT	Multilateração
NN	Vizinho Mais Próximo, do inglês, <i>Nearest Neighbour</i>
PDU	Unidade de Dados do Protocolo, do inglês, <i>Protocol Data Unit</i>
PR	Ponto de Referência
QR	Resposta Rápida, do inglês, <i>Quick Response</i>
RFID	Identificação por Radiofrequência, do inglês, <i>Radio-Frequency Identification</i>
RSSI	Indicador de Intensidade do Sinal Recebido, do inglês, <i>Received Signal Strength Indication</i>
SVM	Máquina de Vetores de Suporte, <i>Support Vector Machine</i>
TDoA	Diferença nos Tempo de Chegada, do inglês, <i>Time Difference of Arrival</i>
ToA	Tempo de Chegada, do inglês, <i>Time of Arrival</i>
ToF	Tempo de Voo, do inglês, <i>Time of Flight</i>
UUID	Identificador Universal Exclusivo, do inglês, <i>Universally Unique Identifier</i>
UWB	Banda Ultra Larga, do inglês, <i>Ultra Wide Band</i>
WKNN	K Vizinhos Mais Próximos com Peso, do inglês, <i>K Weighted Nearest Neighbour</i>
WLAN	Rede Local Sem Fios, do inglês, <i>Wireless Local Area Network</i>
WSN	Rede de Sensores Sem Fio, do inglês, <i>Wireless Sensor Network</i>

## LISTA DE SÍMBOLOS

$\text{RSSI}_n$	RSSI no $n$ -ésimo AP
$\text{RSSI}_{n,d_0}$	RSSI no $\text{AP}_n$ quando o nó está a uma distância de referência $d_0$
$d_0$	distância de referência
$d_n$	distância entre $\text{AP}_n$ e o nó
$\alpha$	expoente de perda de percurso
$X_\sigma$	sombreamento sofrido pelo sinal
$\sigma$	desvio padrão do sombreamento
$\hat{d}_n$	distância estimada entre o $\text{AP}_n$ e o nó
$(x, y)$	coordenadas do nó
$\hat{p}_{\text{MLT}}$	posição estimada pelo esquema MLT
$D_m$	Distância entre a RSSI do $\text{FRP}_m$ , do $\text{AP}_n$ para a RSSI medida
$\mathbf{x}_k$	vetor de estado
$\mathbb{R}$	conjuntos dos números reais
$p$	número de estados do sistema
$j$	número de estados medidos
$\mathbf{H}$	modelo de medição
$\mathbf{v}_k$	ruído de medição
$\mathbf{R}$	matriz de covariância da medição
$\mathcal{N}(a, b)$	a distribuição normal com média $a$ e variância $b$
$\mathbf{I}_i$	matriz identidade $i \times i$
$r$	valor associado a covariância da medida
$\mathbf{A}$	modelo de transição de estado
$\mathbf{P}_{k k-1}$	matriz de covariância a priori que coleta o desvio nas estimativas no tempo $k$ dada a matriz de covariância a posteriori no tempo $k-1$
$\mathbf{Q}$	matriz de covariância do modelo de transição
$q$	valor associado a covariância do modelo
$\mathbf{G}_k$	Ganho de Kalman
$\mathbf{z}_k$	vetor de medição pelos sensores no momento $k$
$\mathbf{P}_{k k}$	matriz de covariância de erro no tempo $k$
$\hat{\mathbf{x}}_{k k}^m$	vetor de estado resultante da fusão
$m$	número dos diferentes sensores ( $m = 1, 2$ )
$\mathbf{P}_{k k}^{12}$	matriz de covariância cruzada entre os vetores de estado do sensor 1 do sensor 2
$\mathbf{G}_k^1$	Ganho de Kalman para o sensor 1
$\mathbf{G}_k^2$	Ganho de Kalman para o sensor 2
$\mathbf{z}_k^1$	vetor de medição do sensor 1 no momento $k$
$\mathbf{z}_k^2$	vetor de medição do sensor 2 no momento $k$
$N$	número de pontos de acesso
$P$	número de amostras utilizadas para realizar a média do RSSI
$M$	número de pontos de referência
$\hat{p}_{\text{FP}}$	posição estimada pelo esquema FP

$\kappa$	números de pontos de referência usados na técnica KNN
$\hat{p}_{f+\text{FK}}$	coordenadas 2D obtidas após o FK para o esquema $f \in \{\text{MLT}, \text{FP}\}$
$\hat{x}_{f+\text{FK}}$	coordenada $x$ obtida após o FK para o esquema $f \in \{\text{MLT}, \text{FP}\}$
$\hat{y}_{f+\text{FK}}$	coordenada $y$ obtida após o FK para o esquema $f \in \{\text{MLT}, \text{FP}\}$
$\text{AP}_n$	$n$ -ésimo ponto de acesso

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>13</b>
1.1 INTRODUÇÃO AO PROBLEMA .....	18
1.2 MOTIVAÇÃO .....	20
1.3 OBJETIVOS .....	20
1.3.1 Objetivo Geral .....	20
1.3.2 Objetivos Específicos .....	21
1.4 PUBLICAÇÕES .....	21
1.5 ESTRUTURA DO TRABALHO .....	21
<b>2 REVISÃO DA LITERATURA</b> .....	<b>22</b>
2.1 TÉCNICAS PARA ESTIMATIVA DE DISTÂNCIA .....	23
2.1.1 Tempo e ângulo de chegada .....	23
2.1.2 Técnicas por Intensidade de Sinal Recebido .....	24
2.1.2.1 Modelo de perda de percurso e distância .....	25
2.2 TÉCNICAS DE LOCALIZAÇÃO .....	26
2.2.1 Trilateração .....	26
2.2.2 Multilateração .....	27
2.2.3 <i>Fingerprinting</i> .....	29
2.2.3.1 Fase <i>offline</i> .....	29
2.2.3.2 Fase <i>online</i> .....	29
2.2.4 Fusão de técnicas de localização .....	31
2.3 TÉCNICAS DE FILTRAGEM ESTOCÁSTICA .....	32
2.3.1 Filtro de Kalman .....	33
2.3.1.1 Atualização do tempo .....	34
2.3.1.2 Atualização da medição .....	35
2.3.2 Fusão Sensorial com Filtro de Kalman .....	35
2.4 BLUETOOTH - BEACON .....	37
<b>3 SOLUÇÃO PROPOSTA</b> .....	<b>40</b>
<b>4 SIMULAÇÕES E RESULTADOS</b> .....	<b>46</b>
<b>5 COMENTÁRIOS FINAIS E TRABALHOS FUTUROS</b> .....	<b>53</b>
<b>REFERÊNCIAS</b> .....	<b>55</b>

## 1 INTRODUÇÃO

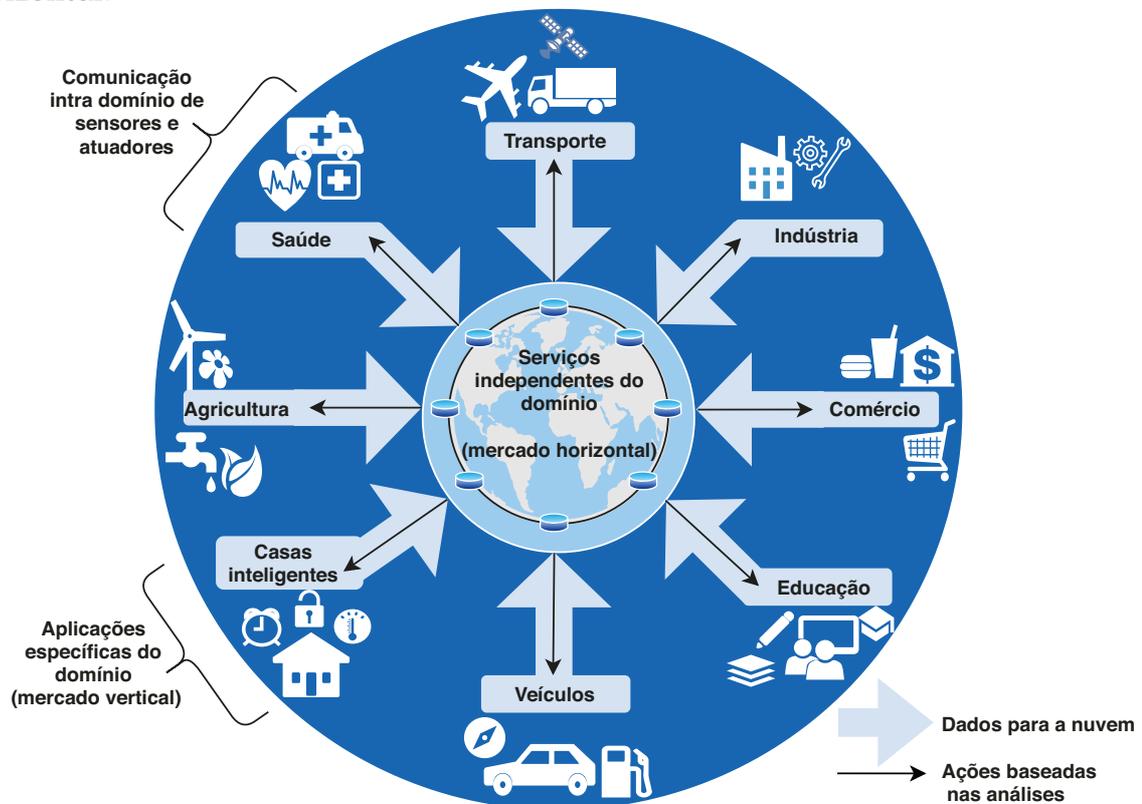
Os avanços da tecnologia nas últimas décadas trouxeram mais facilidade e segurança para a sociedade. Em um cenário ideal a maior parte dos dispositivos possuirão uma conexão com a internet, possibilitando que objetos colem, troquem e armazenem uma enorme quantidade de dados. Essa crescente demanda pela conexão de objetos físicos com a rede convergiu para o conceito de Internet das Coisas (IoT, do inglês *Internet of Things*) (AL-FUQAHA et al., 2015).

Ao realizar-se a interconexão entre os objetos, um dos principais objetivos é alavancar a qualidade de vida das pessoas, propiciando por exemplo que ambientes tenham inteligência artificial e não necessitem de instruções diretas. Recentemente empresas e universidades têm dedicado cada vez mais tempo para desenvolver recursos e aplicativos que viabilizem esses projetos (PERERA et al., 2015). Um importante resultado destes esforços é a sucessiva redução de tamanho, peso, consumo de energia e custo de sensores e dispositivos que utilizam tecnologias sem fio. Quando estes dispositivos se interconectam, é formada uma rede de sensores sem fio (WSN, do inglês *Wireless Sensor Network*) (JEON et al., 2018). Esse cenário favorável estimulou a implantação em larga escala desses sensores, o que tem gradativamente aumentado a troca de informações, e possivelmente permitirá a integração de diversos objetos (PERERA et al., 2014).

Aplicações para IoT estão cada vez mais presentes na rotina das pessoas, contribuindo não só para o aumento na qualidade de vida, mas também para o crescimento da economia mundial (PERERA et al., 2015). A Internet das Coisas está presente nas mais variadas áreas, como agricultura, segurança, saúde e indústria. É possível visualizar seu potencial promissor analisando-se a Figura 1. Domínios específicos de cada mercado vertical não interagem exclusivamente com serviços pertinentes a ele, mas também se beneficiam de sensores e atuadores de domínios adjacentes. Isso resulta em uma integração horizontal de serviços que colaboram entre si através do fluxo de informações. As casas inteligentes podem, por exemplo, abrir o portão da garagem automaticamente quando os residentes estão se aproximando. Essas casas podem também utilizar as informações disponíveis sobre o trânsito para calcular o tempo estimado para a chegada dos moradores, e assim realizar um controle ideal de temperatura e luminosidade ambiente (AL-FUQAHA et al., 2015).

Nesse cenário, surgiu a demanda para associar dinamicamente a posição de um usuário a informações sensíveis ao contexto sobre o ambiente que o circunda. Serviços

Figura 1 – A visão geral da IoT, enfatizando os mercados verticais e sua integração horizontal.

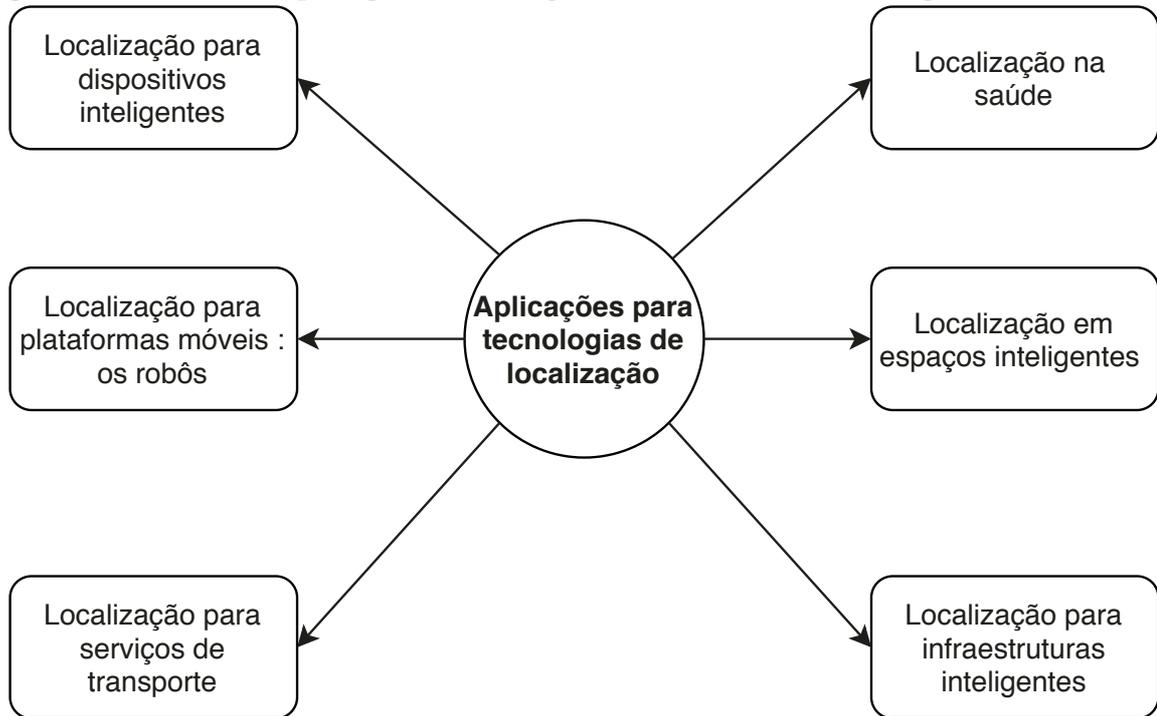


Fonte: Adaptado de (AL-FUQAHA et al., 2015).

Baseados em Localização são comumente utilizados aplicações IoT, como apresenta a Figura 2. Dispositivos inteligentes, tais como celulares, *tablets*, relógios, entre outros, são comumente utilizados como fonte de informação para a localização do usuário (PERERA et al., 2014). A precisão necessária para os diferentes serviços varia de acordo com a implementação, podendo variar de centímetros para aplicativos de jogos, por exemplo, metros para geolocalização em ambientes fechados e análise comportamental do cliente, até dezenas de metros como no envio de recomendações e propagandas em *shoppings* e pavilhões (PAHLAVAN et al., 2015).

Uma grande variedade de robôs voadores e de solo, de diferentes tamanhos, vem sendo desenvolvidos para dar subsídio a diversas aplicações, tais como: gerenciamento de armazéns, fabricação de produtos, missões militares, segurança, entrega comercial, fotografia aérea e saúde (PAHLAVAN et al., 2015). No entanto, uma informação sobre o robô é sempre primordial: sua localização. Assim, o robô deve possuir um sistema de localização e mapeamento (CHEN, 2011). Em algumas situações, como por exemplo um robô em uma missão médica navegando dentro de um corpo humano, a precisão

**Figura 2 – Áreas de aplicação de Serviços Baseados em Localização.**



**Fonte:** Adaptado de (PAHLAVAN et al., 2015).

exigida é de milímetros, contando apenas com uma câmera e comunicação sem fio com o controlador (MATEEN et al., 2017).

Nos hospitais, existem inúmeras aplicações de localização, desde localização de médicos, pacientes, bebês recém-nascidos, enfermeiros e visitantes até a localização de equipamentos comumente usados, como cadeiras de rodas, e ferramentas especializadas, como equipamentos cirúrgicos dentro da sala de cirurgia.

Nas WSNs, determinar a localização de nós desconhecidos é uma tarefa crítica, pois essa informação afeta muitos protocolos e aplicativos que dependem do reconhecimento do local (HAN et al., 2016). Como em um hospital, onde é possível saber a localização de um paciente, usando a rede de sensores ambiente para que, em uma situação de emergência, o médico mais próximo possa atendê-lo de forma mais eficiente (SADOWSKI; SPACHOS, 2018) (BANERJEE; SHETH, 2017).

Ao considerar o cenário IoT de transporte, espaços e infraestrutura inteligentes é possível associar aplicações diretas que necessitam de informações de localização como o rastreamento de animais, pessoas e ativos valiosos, informações do tráfego, infraestrutura de monitoramento e sistemas de posicionamento em ambientes internos (IPS do inglês *Indoor Positioning System* (YASSIN et al., 2017), sendo este último, o foco deste projeto.

As técnicas para IPS consistem em métodos utilizados para localizar objetos ou seres vivos em um recinto onde o Sistema de Navegação Global por Satélite (GNSS do inglês *Global Navigation Satellite System*) não pode ser usado. Apesar de ser amplamente difundido para ambientes externos, os sistemas GNSS, tais como o Sistema de Posicionamento Global (GPS do inglês *Global Positioning System*), GLONASS e COMPASS, possuem uma série de desvantagens no cenário IoT (YASSIN et al., 2017).

Em áreas internas, a funcionalidade do GNSS fica completamente comprometida, uma vez que o sinal proveniente dos satélites é relativamente fraco para atravessar as paredes das construções. Além disso, essa tecnologia possui um alto custo de implementação para o cenário IoT (SADOWSKI; SPACHOS, 2018). Apesar do preço de módulos GNSS ter diminuído ao longo dos últimos anos, ele ainda não é adequado para produção em massa de dispositivos de baixo custo. Acrescenta-se aos fatores já citados, o fato de sua utilização demandar um espaço maior no *hardware* e uma disponibilidade maior de energia devido ao seu alto consumo, sendo esses dois fatores críticos em placas de sensores miniaturizadas (ELFADIL et al., 2017).

Para realizar a comunicação e fornecer conectividade entre bilhões de dispositivos, diversas tecnologias sem fio foram propostas e testadas na literatura. As técnicas mais comumente utilizadas para a localização em ambientes internos são, (ZAFARI et al., 2019): Bluetooth, tecnologias Ultra Wide Band (UWB do inglês *Ultra Wide Band*), ZigBee e Wi-Fi. Quando se trata de selecionar uma tecnologia de comunicação sem fio, há alguns fatores que precisam ser levados em consideração como o alcance, e a taxa de transmissão, requisitos de consumo de energia, tamanho e custo (PATERNA et al., 2017).

Comparando as tecnologias mencionadas, módulos Wi-Fi ou Bluetooth tendem a ter tamanhos reduzidos e um custo menor. Embora o Wi-Fi tenha a maior taxa de transmissão, as demais tecnologias mencionadas fornecem taxa suficiente para que ocorra a troca básica de dados pertinentes à localização. Com relação à eficiência energética, o Bluetooth de baixo consumo (BLE do inglês *Bluetooth Low Energy*) e o Zigbee, apresentam menor consumo de energia, enquanto o Wi-Fi tem o pior desempenho em termos energéticos (SADOWSKI; SPACHOS, 2018).

O protocolo BLE foi introduzido a partir da versão 4.0 do Bluetooth, em 2010 (PALATTELLA et al., 2016). Ele opera na faixa de frequências de 2,4 GHz, banda dedicada a aplicações Industriais, Científicas e Médicas (ISM, do inglês *Industrial Scientific and Medical*), que para aplicações BLE possui quarenta canais, sendo três de *advertising*, com 2 MHz de espaçamento entre eles. Esse arranjo estratégico na faixa ISM

evita que, em alguns canais, os sinais BLE se sobreponham aos do Wi-Fi comum (JEON et al., 2018).

Estudos indicam um futuro promissor referente ao crescimento econômico de serviços baseados em IoT. Previsões indicam que até 2021 aproximadamente 27 bilhões de equipamentos estarão conectados à internet (CISCO, 2019). Algumas aplicações precisam de transmissões seguras e uma fonte contínua de energia, enquanto outras demandam um armazenamento local para transmissões rápidas, um baixo tempo de resposta e protocolos de economia de energia para aumentar o tempo de vida da rede implementada (DIN et al., 2018). O BLE é compatível com requisitos fundamentais de dispositivos IoT: baixo consumo de energia, baixo custo e tamanho reduzido. Devido a isto, sua adoção tem crescido expressivamente (JEON et al., 2018) e espera-se que o BLE se torne um padrão de fato para serviços de IoT de curto alcance (PALATTELLA et al., 2016).

Com o mercado em amplo crescimento, diversos produtos foram lançados nos últimos anos. Os dispositivos baseados em *beacons* BLE são alguns dos mais promissores a se destacarem no mercado, por ser uma tecnologia de baixa taxa de dados com eficiência energética, adequada para aplicações de IoT com restrição de energia (JEON et al., 2018). Os *beacons* são pequenos pacotes de dados que podem ser recebidos por outros dispositivos compatíveis com BLE. Através da interpretação das características físicas do pacote recebido, é possível por exemplo estimar a localização do dispositivo que está transmitindo o *beacon*. Este, por sua vez, através das respostas recebidas pode adquirir informações importantes sobre o ambiente ao seu redor (ZAFARI et al., 2019).

Em Sistemas de Posicionamento em Ambientes Internos, os dispositivos baseados em *beacons* do BLE são chamados de nós sem fio, usualmente de baixo custo e consumo de energia, limitados em capacidade de processamento e tamanho de memória. Esses nós podem possuir sensores específicos para a aplicação, que capturam e processam dados do ambiente ao seu redor e os enviam para o usuário através da rede BLE (AL-FUQAHA et al., 2015).

Para estimar a posição de um nó, nos sistemas supracitados, as técnicas implementadas frequentemente se enquadram em duas metodologias distintas: modelagem da propagação por rádio e Impressão Digital (FP, do inglês *Fingerprinting*) (LI et al., 2016). Para o primeiro caso, o modelo de propagação das ondas de rádio é comumente usado para calcular a distância de um ponto desconhecido até o Ponto de Acesso (AP, do inglês *Access Point*). Em seguida, o posicionamento do ponto desconhecido é realizado, por exemplo, pelo método dos mínimos quadrados, como nas técnicas de Trilateração e

Multilateração (MLT) (PATERNA et al., 2017).

A técnica por Impressões Digitais subdivide a Área de Interesse (AoI, do inglês *Area of Interest*) em quadrantes e cria uma relação entre o ponto central desses quadrantes, também chamados de Pontos de Referência do Fingerprinting (FRP, do inglês *Fingerprinting Reference Point*) e sua assinatura de rádio correspondente (YADAV et al., 2019). Cada FRP tem uma combinação única quando comparada com outros pontos no mapa. Essa característica permite associar os sinais de rádio do transmissor móvel com o local mais próximo possível que corresponda a uma posição já conhecida (YASSIN et al., 2017).

Embora essas técnicas de posicionamento possam ser exploradas em ambientes internos, há limitantes práticos que as afetam e conseqüentemente acometem a precisão máxima que esses sistemas conseguem alcançar (YASSIN et al., 2017). Pode-se relacionar isso ao fato do comportamento dos sinais de rádio, na prática, não ser exatamente o mesmo que o dado pelo modelo teórico genérico, devido a efeitos do mundo real que podem não ser contemplados nas expressões (MIRANDA et al., 2013).

Ao analisar o cenário atual e a crescente demanda por um IPS eficiente, o objetivo deste trabalho é avaliar e propor um esquema de localização em ambientes internos visando diminuir a taxa de incerteza associada à estimativa de posição. Para este fim, serão implementadas em conjunto técnicas de localização e filtragem estocástica, visando obter um aumento de precisão do sistema.

## 1.1 INTRODUÇÃO AO PROBLEMA

Sistemas de posicionamento interno são baseados principalmente em tecnologias de comunicação sem fio. Os sinais transmitidos e utilizados por essas tecnologias sofrem atenuações da amplitude inerentes ao meio de transmissão. Os principais fatores são: (i) o sombreamento, (ii) as perdas de percurso e (iii) a propagação por múltiplos caminhos (WU et al., 2012). O trajeto do sinal entre um transmissor e um receptor muitas vezes possui diversos bloqueios por diversos obstáculos, como pessoas, móveis e paredes. Essa variação aleatória do sinal, causada pela obstrução destes objetos, é chamada de sombreamento (ZANELLA; BARDELLA, 2014).

As variáveis aleatórias que descrevem o fenômeno do sombreamento sofrem influências a partir do movimento que ocorre através da obstrução, ou ao redor dela (Obeidat et al., 2019). Na prática, o sombreamento faz com que, considerando

uma mesma distância entre o receptor e o transmissor, a potência de sinal recebida seja diferente, pois frequentemente alguns locais têm sombreamento mais severo que outros (MIRANDA et al., 2013). Para considerar os efeitos do sombreamento, que podem ocorrer em ambientes internos, pode-se adicionar ao sistema uma variável Gaussiana aleatória com média zero e desvio padrão entre 2 e 6 dB (GOLDSMITH, 2005).

A perda de caminho caracteriza a relação da intensidade do sinal com a distância. Quanto maior a distância entre o transmissor e o receptor, maior a atenuação no sinal, além do efeito do desvanecimento do sinal. O desvanecimento também está associado a propagação por múltiplos percursos e corresponde a uma rápida flutuação devido aos vários caminhos que o sinal percorre entre o transmissor e o receptor (ZANELLA; BARDELLA, 2014). A reflexão e a difração ocasionada por objetos, incluindo paredes e chão, são alguns exemplos de fatores que geram várias cópias de um sinal através da propagação por múltiplos percursos. O espalhamento dessas cópias causam variações de fase e amplitude gerando atenuações do sinal recebido (WU et al., 2012).

Como a variação do sinal recebido pode em geral ser caracterizada como uma variável aleatória, para minimizar esses efeitos negativos é possível realizar a filtragem estocástica das medidas obtidas, o que pode proporcionar um aumento significativo da relação sinal-ruído do sinal presente no sistema (ELFADIL et al., 2017). A utilização de filtros pode ser utilizada para auxiliar nos problemas encontrados devido a esses efeitos negativos e podem proporcionar uma atenuação expressiva nos erros associados a técnicas de localização sem fio (HE; CHAN, 2016).

Considerando os aspectos negativos e as limitações que a implementação de sistemas que utilizam as técnicas MLT e FP separadamente apresentam, o algoritmo de localização proposto é baseado em uma combinação do método de *Fingerprinting* com o método de Multilateração. O filtro de Kalman (FK) será utilizado não só nas técnicas isoladamente, como também será implementado em um algoritmo de fusão de sensores, sendo que cada técnica representa um elemento “sensor”. Além disso, as entradas de controle provenientes das medições das técnicas de localização serão combinadas com um modelo dinâmico do sistema.

Esta abordagem será utilizada em sistemas de posicionamento baseados em dispositivos de baixo custo, alcançando níveis de precisão superiores aos apresentados pela implementação de técnicas de localização isoladas.

## 1.2 MOTIVAÇÃO

A proliferação em larga escala de telefones inteligentes e dispositivos portáteis com recursos de comunicação sem fio tornou possível a localização e o rastreamento dos usuários e seus pertences (HE; CHAN, 2016). Esse cenário resultou no desenvolvimento de uma ampla variedade de aplicativos e serviços relacionados. Pode-se mencionar alguns setores que usufruem dessas comodidades, tais como o setor de saúde, indústria, gerenciamento de desastres, gerenciamento de edifícios, vigilância e vários outros setores. Para atender às necessidades do usuário, essas informações de pessoas ou bens são primordiais e precisam ser independentes dos ambientes em que estejam implementadas (ZAFARI et al., 2019).

Há muitos desafios em desenvolver um sistema de localização para ambientes internos. Nas WSNs, determinar os locais dos nós desconhecidos é uma tarefa fundamental e está diretamente relacionada com o propósito das aplicações na qual a informação de localização é primordial para que os nós sensores possam tomar decisões coerentes (HAN et al., 2016). Portanto, obter soluções que aumentem a precisão da localização em ambientes fechados é fundamental em um mundo no qual pessoas e objetos estão cada vez mais interconectados.

Para citar alguns cenários ou serviços que o presente projeto poderia ser aplicado, destaca-se: (i) o rastreamento de ativos em uma empresa onde os trabalhadores os movem entre as salas e deseja-se garantir que todos os ativos estão onde deveriam estar. (ii) A localização de pessoas dentro de um prédio onde, por razões de segurança, é mandatório ter o controle de onde as pessoas estão a todo momento. (iii) O rastreamento de clientes em um shopping para que seja possível conhecer as preferências dos usuários e oferecer a eles os produtos nos quais eles estão interessados. O IPS pode ser usado para rastrear o caminho dos clientes e com as informações obtidas, as empresas do shopping podem, por exemplo, redistribuir as diferentes lojas de maneira mais confortável para os clientes ou reunir lojas que geralmente são visitadas em sequência.

## 1.3 OBJETIVOS

### 1.3.1 Objetivo Geral

Desenvolver um sistema híbrido de localização para ambientes internos (H-IPS do inglês *Hybrid Indoor Positioning System*) visando aumentar a precisão da localização em

um ambiente fechado simulado, realizando a filtragem estocástica dos resultados obtidos de técnicas de localização baseadas em RSSI (multilateração e impressões digitais) e em seguida a fusão dos resultados obtidos.

### 1.3.2 Objetivos Específicos

- Coletar informações do estado da arte sobre as técnicas *fingerprinting* e multilateração assim como sobre fusão de sensores e filtro de Kalman;
- Desenvolver um sistema de localização utilizando a técnica *fingerprinting*;
- Desenvolver um sistema de localização utilizando a técnica de multilateração;
- Aplicar os sistemas de localização em um ambiente simulado baseado nas características de uma rede Bluetooth low energy;
- Avaliar o efeito do filtro de Kalman nas técnicas anteriores;
- Realizar a fusão sensorial do resultado filtrado das técnicas anteriores;
- Comparar e analisar os dados resultantes de cada combinação de processos;
- Comparar o método proposto a esquemas existentes, de modo a validá-lo.

## 1.4 PUBLICAÇÕES

Este trabalho gerou um artigo aceito Eyng et al. (2020) para publicação na conferência intitulada *2020 IEEE 91st Vehicular Technology Conference: VTC2020-Spring*.

## 1.5 ESTRUTURA DO TRABALHO

Além desta introdução, esta dissertação contém mais 4 capítulos. O Capítulo 2 abrange a revisão da literatura e apresenta os conceitos das técnicas utilizadas neste trabalho. A solução proposta é apresentada no Capítulo 3, incluindo o modelo do sistema e os algoritmos desenvolvidos. No Capítulo 4 os resultados são apresentados, comparados e discutidos. Por fim, no Capítulo 5, são apresentadas as conclusões e comentários finais desta dissertação, assim como algumas propostas para trabalhos futuros.

## 2 REVISÃO DA LITERATURA

Segundo (ELFADIL et al., 2017), os sistemas de localização podem ser divididos em três componentes: (i) a estimativa da distância, (ii) o cálculo do posicionamento e (iii) o algoritmo de localização. O primeiro é responsável por estimar informações de distâncias e ângulos entre um Ponto de Acesso e o Terminal Móvel. Já o cálculo do posicionamento computa a posição do objeto baseando-se nas informações da etapa anterior. Enquanto o algoritmo de localização, sendo este o principal componente de um sistema de localização, determina como as informações obtidas serão manipuladas para que os objetos tenham suas posições estimadas precisamente.

São três também os principais métodos para estimar distância: os baseados no tempo de percurso (ToF, do inglês *Time of Flight*), no ângulo de chegada (AoA, do inglês *Angle of Arrival*) ou no indicador de intensidade do sinal recebido (RSSI, do inglês *Received Signal Strength Indication*) (SADOWSKI; SPACHOS, 2018). Sistemas de localização baseados em RSSI normalmente incluem um modelo de perda de percurso para estimar, com base nos RSSIs recebidos nos sinais, as distâncias dos pontos de acesso (ou nós âncora) (KOO; CHA, 2011). Entretanto, o sistema precisa considerar que o RSSI está submetido a efeitos inerentes às transmissões de radiofrequência, como sombreamento e propagação de múltiplos percursos, além de ser tipicamente variável no tempo e sujeito à interferências de outros dispositivos operando em frequências próximas (GOLDSMITH, 2005).

Nos cenários em que o nó alvo está em movimento e recebendo sinais periódicos transmitidos dos pontos de acesso, é possível melhorar a precisão da localização. Para tanto, pode-se combinar a saída do IPS baseado em RSSI com o padrão de modelagem dos movimentos desses nós móveis. Isso pode ser feito, por exemplo, utilizando o filtro de Kalman (KALMAN, 1960) que é um processo matemático iterativo frequentemente aplicado para realizar inferências sobre um sistema dinâmico linear, como a estimativa de posição (LI et al., 2016).

Nas próximas seções, as técnicas de posicionamento, filtragem estocástica e fusão sensorial serão abordadas com maior detalhamento.

## 2.1 TÉCNICAS PARA ESTIMATIVA DE DISTÂNCIA

Algumas técnicas conhecidas de localização são baseadas na indicação de intensidade do sinal recebido (RSSI), no registro do tempo de chegada (ToA, do inglês *Time of Arrival*), diferença dos instantes de chegada (TDoA, do inglês *Time Difference of Arrival*) e ângulo de chegada (AoA), entre as quais aquelas que são baseadas em RSSI são geralmente adotadas no escopo de redes sem fio de sensores, já que as outras técnicas normalmente exigem hardware adicional ou mecanismos de sincronização avançados (YASSIN et al., 2017).

As seções a seguir detalham diferentes técnicas existentes na literatura, exemplificam e comparam seus desempenhos para justificar as escolhas acerca do tema escolhido.

### 2.1.1 Tempo e ângulo de chegada

Nos métodos de ToF, tais como o ToA ou TDoA, o tempo de propagação dos pacotes de dados pode ser traduzido instantaneamente em distância, com base na velocidade de propagação do sinal entre o transmissor e o receptor através de referências de tempo sincronizadas (ELFADIL et al., 2017). Diferentemente das técnicas de ToA em que a sincronização é necessária entre o transmissor e o receptor, no caso TDoA somente a sincronização entre os transmissores é necessária. Além disso, a técnica TDoA explora a diferença nos tempos de propagação dos sinais de diferentes transmissores, medidos no receptor. O ToA, por sua vez, considera o tempo absoluto de propagação do sinal (ZAFARI et al., 2019).

O método AoA estima o ângulo em que os sinais são recebidos e faz uso das relações geométricas para calcular a posição do nó. A direção do sinal pode ser fornecida por antenas de rádio direcionais ou matrizes de receptores, geralmente três ou mais, que são uniformemente separados, o que exige a instalação de circuitos adicionais nos nós. A exigência do uso de antenas direcionais torna este método menos viável para aplicação em rede de sensores sem fio de baixo custo (YASSIN et al., 2017).

Em Hara e Anzai (2008) realizou-se um estudo comparativo do desempenho utilizando medições com TDoA e RSSI. Para o caso no qual não havia pessoas no ambiente, a localização baseada em TDoA teve um desempenho melhor do que a localização baseada em RSSI, embora as taxas de sucesso na entrega dos pacotes tenham sido mais baixas utilizando TDoA. No entanto, no cenário com pessoas andando pela área de interesse,

a localização baseada no RSSI apresentou um erro de estimativa  $\geq 3,8$  m com 100% de taxa de êxito na entrega dos pacotes, enquanto o erro associado ao TDoA foi  $\geq 4,2$  m com uma taxa de sucesso de entrega  $\geq 70\%$ .

### 2.1.2 Técnicas por Intensidade de Sinal Recebido

A intensidade do sinal recebido é uma das métricas usadas para estimar a qualidade do link dos canais sem fio, trata-se de um indicador numérico da potência do sinal recebido pelo receptor sem fio, usualmente medido em dBm (YADAV et al., 2019). Essa técnica de localização relaciona a potência do sinal recebido com uma referência de distância, tornando possível calcular a distância da localização do dispositivo que enviou o sinal. Quanto mais forte o sinal, maior será a confiabilidade da medida e mais alta vai ser a precisão do valor real equivalente à distância entre o ponto de referência e o dispositivo a ser rastreado (SADOWSKI; SPACHOS, 2018).

A utilização da intensidade do sinal recebido para a implementação de redes de sensores tem sido debatida há muito tempo pela comunidade científica. A abordagem é atraente porque essa informação é disponibilizada prontamente por todos os transceptores comuns sem fio (ZANELLA; BARDELLA, 2014). O RSSI pode ser medido a partir de sinais transmitidos periodicamente como *beacons* de um ponto de acesso BLE, ou em pacotes transmitidos a um único destino, do inglês, *unicast* (PATERNA et al., 2017).

A análise do RSSI pode ser realizada de duas formas principais: mapeando as perdas de propagação devido à distância de acordo com o modelo de propagação implementado e por meio de técnicas de impressão digital, original do inglês *fingerprinting*. No primeiro caso, é considerado que o sinal é transmitido conforme o modelo adotado e que a distância é obtida isolando-a no sistema de equações.

Sabendo a potência transmitida, é possível calcular as perdas de propagação, pois a intensidade do sinal é inversamente proporcional à distância de seu deslocamento no meio de propagação. O principal problema desta abordagem é a dificuldade de escolher qual modelo de propagação é o mais apropriado (PATERNA et al., 2017). A desvantagem do método de mapeamento de perdas é a baixa precisão da localização utilizando-se da distância de três pontos de referência (PR).

Para melhorar a precisão, é possível calcular a distância a vários PRs, e não apenas três, aplicando técnicas de Multilateração (HE; CHAN, 2017). Multilateração é uma técnica para determinar a posição de um dispositivo móvel a partir de um conjunto

de pontos de referência cujas posições são conhecidas, com base nas distâncias medidas entre os pontos de referência e o dispositivo, através dos modelos mencionados (KOO; CHA, 2011).

Já o método *fingerprinting* consiste na formação de um banco de dados que contém uma série de medidas a serem tomadas em posições estratégicas, de modo que exista um mapa pré-estabelecido dos valores que relacionam distância-RSSI. Com esta abordagem, a precisão do sistema tende a ser maior em comparação com a anterior, mas é preciso realizar uma caracterização do espaço. Além disso, o método é bastante suscetível a qualquer alteração, o que resulta na necessidade de recharacterizar o local (HE; CHAN, 2016).

#### 2.1.2.1 Modelo de perda de percurso e distância

É possível medir uma distância específica usando um modelo de perda de percurso. Considerando que a distância geográfica da linha de visada (LoS, do inglês *Line of Sight*) entre os nós transceptores seja  $d_n$ , a  $\text{RSSI}_n$  (em dBm) no  $n$ -ésimo AP pode ser calculada pelo modelo de propagação log-normal (GOLDSMITH, 2005) através da seguinte equação:

$$\text{RSSI}_n = \text{RSSI}_{n,d_0} - 10\alpha \log_{10}(d_n/d_0) + X_\sigma, \quad (1)$$

onde  $\text{RSSI}_{n,d_0}$  é o RSSI (em dBm) no  $\text{AP}_n$  quando o nó está a uma distância de referência  $d_0$ ,  $d_n$  é a distância entre  $\text{AP}_n$  e o nó,  $\alpha$  é o expoente de perda de percurso,  $X_\sigma \sim \mathcal{N}(0, \sigma^2)$  representa o sombreamento (em dB).

Além de os sinais sem fio se tornarem mais fracos na proporção do logaritmo das distâncias percorridas, o RSSI é afetado principalmente pela variação das características intrínsecas dos diferentes modelos de transmissores e do receptores, assim como pela orientação da antena. Em ambientes internos que são complexos e impactados por reflexão, refração e obstáculos para o sinal, o valor do RSSI apresenta um erro ainda maior devido à grande flutuação instantânea do nível de sinal, o que afeta a precisão na utilização dessa métrica para localização (LI et al., 2016)

## 2.2 TÉCNICAS DE LOCALIZAÇÃO

Devido as suas características, redes locais sem fios (WLAN, do inglês *Wireless Local Area Network*) e dispositivos móveis habilitados para Wi-Fi, são tradicionalmente tecnologias utilizadas como fonte do RSSI em ambientes fechados (LI et al., 2016; HE; CHAN, 2016). Apesar da implantação de sistemas de posicionamento Wi-Fi ser econômica, por não apresentar a necessidade de investimento adicional em infraestrutura, é mostrado em Sadowski e Spachos (2018) que os IPS baseados em BLE fornecem uma precisão de localização comparável à do Wi-Fi e apresentam um consumo de energia significativamente menor. Os resultados do estudo demonstram que enquanto o Wi-Fi apresentou um consumo médio de 216,71 mW o BLE apresentou um consumo médio de apenas 0,367 mW. Sustentadas por dispositivos portáteis, a bateria e que enviam pacotes *beacons*, tais redes também podem ser facilmente distribuídas a baixo custo.

### 2.2.1 Trilateração

A trilateração é uma técnica utilizada para determinar a localização relativa de um usuário, medindo distâncias com o uso da geometria e o conhecimento de três posições de referência. Esses PRs representam os nós de transmissão (APs) do sistema e devem ser configurados para transmitir pacotes continuamente. Isso permite que o receptor do nó obtenha qualquer transmissão que ocorra no meio e registre os valores da RSSI dos pacotes. Os valores do RSSI recebidos são então convertidos na medida que representa a distância estimada  $\hat{d}_n$  entre o  $AP_n$  e o nó (SADOWSKI; SPACHOS, 2018).

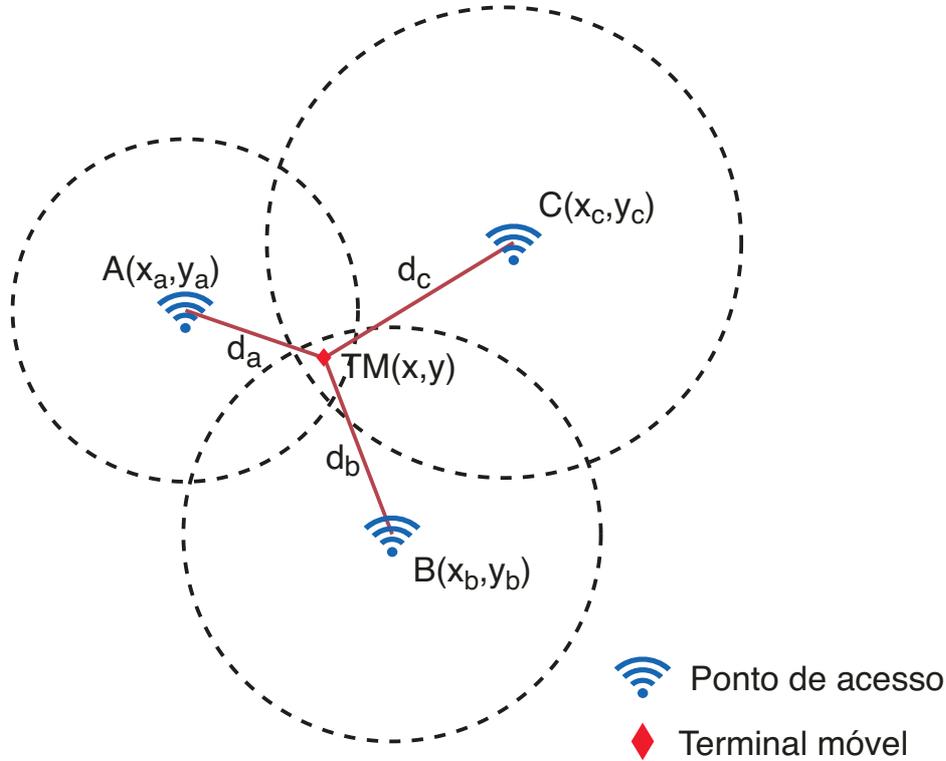
Isolando  $d_n$  em (1), obtém-se,

$$\hat{d}_n = d_0 10^{(RSSI_{n,d_0} - RSSI_n)/10\alpha}. \quad (2)$$

Conforme a Figura 3 apresenta, assumindo-se que a coordenada de um nó seja  $(x, y)$ , e as coordenadas dos APs de referência, A, B e C, sejam  $(x_a, y_a)$ ,  $(x_b, y_b)$  e  $(x_c, y_c)$  respectivamente, a interseção dos três círculos com os raios  $d_a$ ,  $d_b$  e  $d_c$ , encontrados utilizando a equação (2), representa a posição estimada do nó.

As relações geométricas entre os APs e o nó podem ser expressas pelo seguinte sistema de equações (HAN et al., 2016):

**Figura 3** – Exemplo de trilateração considerando que os círculos representam o a distâncias estimadas para cada AP. A interseção resulta em uma área onde se estima que o nó esteja localizado.



Fonte: Adaptado de (PATERNA et al., 2017).

$$d_a = \sqrt{(x - x_a)^2 + (y - y_a)^2} , \quad (3)$$

$$d_b = \sqrt{(x - x_b)^2 + (y - y_b)^2} , \quad (4)$$

$$d_c = \sqrt{(x - x_c)^2 + (y - y_c)^2} . \quad (5)$$

Resolvendo o sistema encontra-se as coordenadas  $(x, y)$  do alvo.

### 2.2.2 Multilateração

A extensão da trilateração, também conhecida como a estimativa da máxima probabilidade, a multilateração é uma técnica amplamente difundida e utilizada para estimar a localização de um nó com base em suas medições de distância a  $N \geq 3$  APs não colineares. A distância entre o AP<sub>*n*</sub> e o nó localizado nas coordenadas  $(x, y)$  é calculada

da seguinte maneira (HAN et al., 2016):

$$d_n = \sqrt{(x - x_n)^2 + (y - y_n)^2}. \quad (6)$$

As intensidades de sinal recebidas de todos os pontos de acesso existentes são calculadas e depois convertidas em distâncias conforme a equação (2). Assumindo que  $\hat{d}_n \simeq d_n$ , sendo  $\hat{d}_n$  o resultado de (2) e  $d_n$  o resultado de (6), igualando os dois termos, elevando ao quadrado e subtraindo a  $N$ -ésima equação da  $n$ -ésima equação, onde  $N$  é o número total de APs e  $n = 1, 2, 3, \dots, N$ , reorganizando os termos, encontra-se uma função linear de  $x$  e  $y$  (KOO; CHA, 2011):

$$\begin{aligned} -x_n^2 - y_n^2 + x_N^2 + y_N^2 + (\hat{d}_n)^2 - (\hat{d}_N)^2 = \\ x(-2x_n + 2x_N) + y(-2y_n + 2y_N). \end{aligned} \quad (7)$$

Representando as  $N$  equações como  $\mathbf{b} = \mathbf{A}\mathbf{p}$ , em que  $\mathbf{p} = [x \ y]^T$  descreve as coordenadas que devem ser determinadas, encontra-se:

$$\begin{bmatrix} -x_1^2 - y_1^2 + x_N^2 + y_N^2 + (\hat{d}_1)^2 - (\hat{d}_N)^2 \\ -x_2^2 - y_2^2 + x_N^2 + y_N^2 + (\hat{d}_2)^2 - (\hat{d}_N)^2 \\ \vdots \\ -x_{N-1}^2 - y_{N-1}^2 + x_N^2 + y_N^2 + (\hat{d}_{N-1})^2 - (\hat{d}_N)^2 \end{bmatrix} = \begin{bmatrix} -2x_1 + 2x_N & -2y_1 + 2y_N \\ -2x_2 + 2x_N & -2y_2 + 2y_N \\ \vdots & \vdots \\ -2x_{N-1} + 2x_N & -2y_{N-1} + 2y_N \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix}. \quad (8)$$

Uma vez que  $\{\hat{d}_n\}_{n=1}^N$  está sujeito a erros devido ao efeito de sombreamento, obtém-se a estimativa pelos mínimos quadrados  $\hat{p}_{\text{MLT}}$  da seguinte forma

$$\hat{p}_{\text{MLT}} = \hat{\mathbf{p}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b}, \quad (9)$$

para que seja possível minimizar  $\sum_{n=1}^N (d_n - \hat{d}_n)^2$  (KOO; CHA, 2011).

Assim como o método da trilateração, a multilateração apresenta erro em sua estimativa, que deve-se às incertezas no cálculo das distâncias para os pontos de

referência. Essa imprecisão está associada a diversos fatores como simplificação excessiva ou incertezas paramétricas nos modelos de propagação interna, às perdas pelo múltiplos caminhos ou desvanecimento do sinal e ainda ao fato que, em ambientes internos, os pontos de referência não possuem LoS (HE; CHAN, 2017).

### 2.2.3 *Fingerprinting*

O método de localização por impressão digital é uma técnica de correspondência de padrões capaz de melhorar o desempenho do IPS baseado no RSSI. A técnica de *fingerprinting* encontra uma estimativa de posição baseada nos valores do RSSI e divide-se em duas fases: fase de calibração, também conhecida como fase *offline*, e fase de localização, também conhecida como fase *online* (LI et al., 2016).

#### 2.2.3.1 Fase *offline*

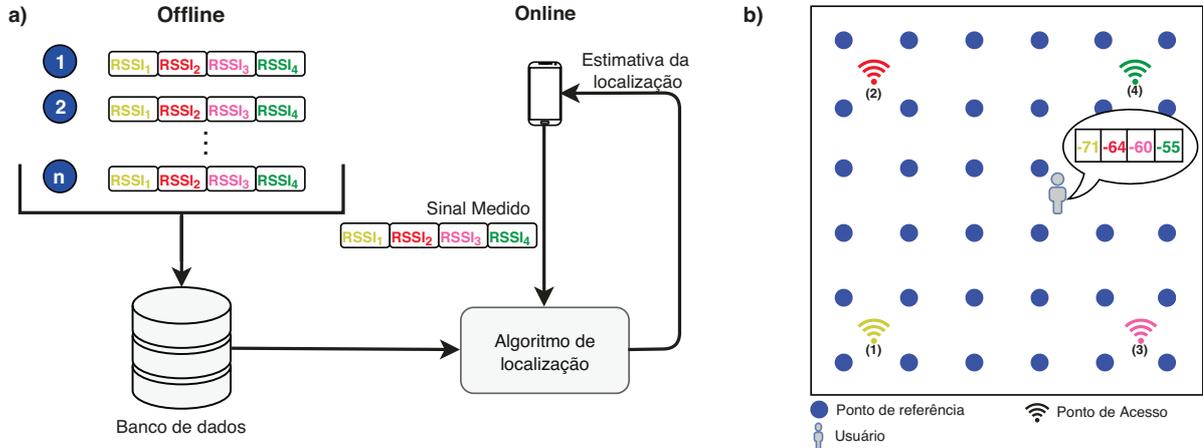
Nessa fase, a área especificada é coberta por uma correspondência um-para-um entre os RSSIs medidos e a localização desses pontos. Sendo assim, para cada impressão digital, uma medição de interesse e sua localização devem ser coletadas realizando-se uma aquisição preliminar de impressões de rádio em todo o local destinado à navegação no qual cada segmento no mapa é associado a atributos únicos (FANG et al., 2017).

Uma sequência de medições é necessária para que seja considerado um valor médio para cada ponto medido. A intenção com essa prática é de estatisticamente utilizar um valor mais confiável, uma vez que a intensidade do sinal recebido pode ser influenciada por diversos fatores. A Figura 4a mostra um esquema geral da fase de aquisição de informação. Cada ponto medido, possui uma respectiva lista de nós de referências que assimila o valor da potência do sinal recebido naquela medição. Esses dados ficarão disponíveis na base de dados, em formato de um histograma da informação para cada PR, comumente chamado de *radio maps* (FARAGHER; HARLE, 2015).

#### 2.2.3.2 Fase *online*

O banco de dados estruturado na fase *offline* é usado durante a fase *online* para comparar com os RSSIs de posições desconhecidas, medidos pelo transmissor móvel, com o objetivo de encontrar o ponto de calibração conhecido mais próximo (LI et al., 2016). A posição em questão será aquela associada à impressão digital da melhor correspondência

Figura 4 – a) Fluxo básico do sistema e b) Mapa do ambiente em um sistema de localização interna baseado em Wi-Fi.  $[-52, -60, -65, -71]$  representa os níveis de sinal, em dBm, dos 4 APs.



Fonte: Adaptado de (HE; CHAN, 2016).

ou à média geométrica das posições das  $K$  impressões digitais mais próximas do nó.

Para realizar a análise e comparação com o banco de dados utilizam-se os algoritmos de localização, sendo os três mais adotados: o algoritmo do vizinho mais próximo (NN, do inglês *Nearest Neighbour*), que usa apenas um ponto de referência para estimar a posição do nó (FANG et al., 2017); o algoritmo que utiliza  $\kappa$  vizinhos mais próximos (KNN, do inglês *K-Nearest Neighbour*) sendo  $\kappa$  o número de pontos de referência considerados para formar um polígono cujo centróide é a saída do algoritmo (LI et al., 2016). Por fim, o algoritmo que utiliza  $\kappa$  vizinhos mais próximos com peso atribuído (WKNN, do inglês *K Weighted Nearest Neighbour*) que funciona como o KNN, diferenciando-se ao associar diferentes pesos para os diferentes pontos de referência (FANG et al., 2017).

O KNN tem a menor complexidade, enquanto a precisão é comparável com técnicas mais sofisticadas (HOANG et al., 2018). O KNN trabalha de maneira determinística e baseia-se na menor distância física entre os pontos de referência presentes no banco de dados ( $RSSI_{m,n}$ ) e a posição-alvo ( $RSSI_n$ ). Esse algoritmo se baseia na distância euclidiana e é representado pela equação (YADAV et al., 2019)

$$D_m = \sqrt{\sum_{n=1}^N (RSSI_n - RSSI_{m,n})^2}, \quad (10)$$

onde  $D_m$  é a Distância entre a RSSI do FRP $_m$ , do AP $_n$  para a RSSI medida. As  $M$  distâncias são classificadas em ordem crescente, e os  $\kappa$  primeiros pontos são considerados

para o cálculo da estimativa da posição (YADAV et al., 2019). No entanto, devido ao efeito de sombreamento, o RSSI se comporta como uma variável aleatória (HARA; ANZAI, 2008). Isso leva à seleção de Pontos de Referência do *Fingerprinting* que não são necessariamente os  $\kappa$  vizinhos mais próximos, afetando a precisão dos métodos baseados no RSSI, como é o caso das impressões digitais e da multilateração. Uma das principais desvantagens da implantação de localização interna baseada em impressão digital, é que essa técnica funciona apenas para a área onde as impressões digitais foram previamente coletadas.

No entanto, pesquisadores têm se dedicado no objetivo de reduzir o esforço de criação do *radio map*. Como em (LUO; HSIAO, 2018), que propôs um processo automatizado de atualização de banco de dados, no qual um robô móvel está configurado para coletar continuamente dados de medição RSSI na área de interesse para atualizar automaticamente o banco de dados. Outra maneira encontrada na literatura de contornar as desvantagens das técnicas de localização é interpolar o RSSI em locais ausentes usando diferentes métodos de interpolação como em (TALVITIE et al., 2015).

Infelizmente, a maioria dessas técnicas exige um custo adicional de hardware ou de processamento. Uma outra metodologia utilizada para lidar com os problemas de interferência de caminhos múltiplos em ambientes dinâmicos internos, os quais resultam em erros significativos nas medidas do RSSI, são os filtros estocásticos, tais como o filtro de Kalman e o filtro de Partículas. Essas técnicas aprimoram o sistema através da fusão de informações de diferentes fontes (BELMONTE-HERNÁNDEZ et al., 2017).

#### 2.2.4 Fusão de técnicas de localização

A combinação de diferentes técnicas de localização é uma prática usual em aplicações que demandam maior precisão. Em (MARI et al., 2018), por exemplo, desenvolveu-se uma associação das técnicas de trilateração e de *fingerprinting*. Durante a etapa de localização, uma posição encontrada com base no modelo de perda de caminho, servirá como base para o algoritmo do KNN, que buscará correspondência de impressões digitais dentro de um raio de dois metros do local retornado pelo algoritmo de trilateração (MARI et al., 2018). O sistema proposto apresenta uma melhora de 25% quando comparado ao método de FP sozinho, chegando a 1,8 m de precisão.

Apesar de comumente as medições do RSSI serem utilizadas diretamente na etapa de atualização do FK, em (GIOVANELLI et al., 2018) esses dados foram utilizados para

estimar a velocidade do alvo, calculando a derivada da posição. A abordagem adotada neste artigo baseia-se em na fusão dos valores de distância obtidos do RSSI e do ToF das mensagens BLE. O filtro Kalman explora as características complementares do RSSI e ToF para estimação da distância. O valor médio do erro diminuiu em cerca de 50% quando comparado ao cenário onde apenas o RSSI foi considerado.

A utilização de variadas fontes de dados também é frequentemente aplicada. Em (SUN et al., 2017), implementou-se um sistema de localização para ambientes internos, usando o mapeamento do ambiente com Wi-Fi e imagens de uma câmera panorâmica. No entanto, mesmo que os métodos que usam câmeras pareçam uma abordagem prática para a solução de rastreamento humano, é preciso considerar, além do custo associado à compra dos equipamentos, a preocupação com a privacidade, uma vez que as imagens das pessoas são capturadas. Como resultado, a probabilidade de que o erro de distância do sistema seja menor do que 2 m é de apenas 43%.

Multilateração e *Fingerprinting* são dependentes do número de APs utilizados, quanto menos APs, menor será a precisão da estimativa. Métodos probabilísticos, por outro lado, além de considerarem as saídas geradas pela utilização das técnicas, utilizam também um tratamento matemático para fazer uma combinação das informações coletadas, com isso, o resultado da localização estimada é melhorada (BELMONTE-HERNÁNDEZ et al., 2017). Assim, a filtragem de Kalman, por exemplo, pode ser utilizada para atenuar o efeito prejudicial da aleatoriedade inerente ao canal sem fio, considerando um modelo de movimento uniforme, conforme será detalhado na Seção 2.3.

### 2.3 TÉCNICAS DE FILTRAGEM ESTOCÁSTICA

Existem diferentes métodos de filtragem estocástica, por exemplo os filtro de Kalman e de partículas, além de suas variantes (HE; CHAN, 2016; BELMONTE-HERNÁNDEZ et al., 2017). Esses métodos de filtragem lineares e não-lineares são as abordagens mais amplamente usadas para remover o ruído e melhorar a precisão da localização. O filtro de Kalman é geralmente usado com modelos lineares e gaussianos, enquanto o filtro de partículas é usado com modelos não lineares (YADAV et al., 2019). Embora o filtro de partículas resulte em estimativa de trajetória significativamente melhor da posição em medições ruidosas e imprecisas, requer mais poder de computacional do que o filtro de Kalman. Além disso, também exige uma complexidade maior para implementação (KO; KIM, 2012).

Em aplicações IoT com dispositivos portáteis, considerando as limitações de dispositivos pequenos e baratos, como o uso de memória, consumo de energia e capacidade de processamento, o filtro de Kalman é amplamente utilizado para remover ruídos e estimar com precisão a localização (YADAV et al., 2019). O Filtro de Kalman é uma formulação típica para descrever um sistema discreto no tempo. Assumindo o conhecimento do modelo de movimento do transmissor móvel com um ruído gaussiano aditivo, o filtro de Kalman convencional pode efetivamente melhorar a estimativa da localização de um nó, especialmente se este estiver em um modelo de movimento linear (HE; CHAN, 2016).

Um das abordagens frequentemente encontradas na literatura é adotar o Filtro de Kalman para obter um valor RSSI com menor incerteza, para só então aplicar as técnicas de localização. Em (LAM et al., 2018), os autores propõem uma abordagem otimizada de máquina de vetores de suporte (SVM, do inglês *Support Vector Machine*), que é classificador linear binário não probabilístico usado para estimativa de distância, com medidas do RSSI, provenientes de *beacons* Bluetooth, previamente filtradas através de um FK. O algoritmo desenvolvido apresentou erro de distância inferiores a 1 m 80% do tempo. Esse desempenho em tempo real é desejável para a maioria aplicativos iterativos sensíveis ao atraso.

Em (HUANG et al., 2014), utilizou-se uma combinação de diferentes técnicas para aumentar a precisão do IPS proposto, com a identificação por radiofrequência (RFID, do inglês *Radio-Frequency IDentification*). Além de empregar o código de resposta rápida (QR, do inglês *Quick Response*), posicionado-os em alguns pontos críticos da área de interesse, para adquirir uma coordenada de localização precisa e confiável e, assim, redefinir a posição atual e aplicou-se, também, um Filtro de Kalman. O FK foi utilizado para filtrar as maiores oscilações do RSSI na fase da aquisição do sinal. Isto resultou em um menor erro ao relacionar o RSSI medido com a distância do transmissor. Comparando com o a técnica de trilateração, o algoritmo proposto apresentou uma melhora de aproximadamente 46% (HUANG et al., 2014).

### 2.3.1 Filtro de Kalman

O Filtro Kalman é o filtro mais utilizado para fusão de sensores e estimativa de posição. Trata-se de um algoritmo que usa um conjunto de dados ruidosos observado ao longo do tempo, proveniente dos sensores, para produzir estimativas dos valores reais das grandezas medidas (LI et al., 2015). Para isso, afere-se as incertezas associadas ao valor

medido e ao valor predito, de acordo com um modelo dinâmico de um sistema, e calcula-se uma média ponderada entre eles (KO; KIM, 2012). Os cálculos necessários não exigem grande poder computacional. O resultado gerado é uma nova estimativa do estado, que se localiza entre o estado predito e o estado medido, apresentando uma menor incerteza associada (LI et al., 2015).

Considerando o modelo de processo para lidar com objetos em movimento em um ambiente, o vetor de estado  $\mathbf{x}_k \in \mathbb{R}^{p \times 1}$  é definido como o vetor que contém os valores verdadeiros do número  $p$  de variáveis de estado no momento  $k$ , pertencentes ao conjunto dos números reais. O processo de filtragem por Kalman é baseado na minimização do erro médio quadrático e consiste em duas etapas: a atualização do tempo, na qual ocorre a previsão e a atualização da medida em que acontece a correção. A função de atualização da medição é calculada como (BELMONTE-HERNÁNDEZ et al., 2017):

$$\mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k, \quad (11)$$

sendo  $\mathbf{z}_k \in \mathbb{R}^{j \times 1}$  sendo  $j$  o número de estados medidos pelos sensores.  $\mathbf{H} \in \mathbb{R}^{j \times p}$  é o modelo de medição e  $\mathbf{v}_k \in \mathbb{R}^{j \times 1} \sim \mathcal{N}(0, \mathbf{R})$ , sendo  $\mathcal{N}(a, b)$  a distribuição normal com média  $a$  e variância  $b$ ,  $\mathbf{R} = r\mathbf{I}_j \in \mathbb{R}^{j \times j}$  a matriz de covariância do ruído de medição, sendo  $\mathbf{I}_i$  uma matriz identidade  $i \times i$  e  $r \in \mathbb{R}$ .

### 2.3.1.1 Atualização do tempo

A partir de uma estimativa inicial da matriz de covariância, para cada observação  $\mathbf{z}_k$ , a estimativa é atualizada por (CHEN, 2011):

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{A}\hat{\mathbf{x}}_{k-1|k-1}, \quad (12a)$$

$$\mathbf{P}_{k|k-1} = \mathbf{A}\mathbf{P}_{k-1|k-1}\mathbf{A}^T + \mathbf{Q}, \quad (12b)$$

onde  $\hat{\mathbf{x}}_{k|k-1} \in \mathbb{R}^{p \times 1}$  é a estimativa do estado a priori no momento  $k$  dada a estimativa do estado a posteriori no momento  $k-1$ ,  $\mathbf{A} \in \mathbb{R}^{p \times p}$  é o modelo de transição de estado,  $\mathbf{P}_{k|k-1} \in \mathbb{R}^{p \times p}$  é uma matriz de covariância a priori que coleta o desvio nas estimativas no tempo  $k$  dada a matriz de covariância a posteriori no tempo  $k-1$ .  $\mathbf{Q}$  é a matriz de covariância do modelo de transição sendo  $\mathbf{Q} = q\mathbf{I}_j \in \mathbb{R}^{j \times j}$  e  $q \in \mathbb{R}$ .

### 2.3.1.2 Atualização da medição

Essa etapa combina as informações da previsão atual com as informações obtidas da observação atual para refinar a estimativa do estado (CHEN, 2011). Usando o valor medido e o valor previsto, uma estimativa do estado a posteriori é gerada incorporando a medição como em (12a), isto é, a estimativa ótima do estado atual (BELMONTE-HERNÁNDEZ et al., 2017):

$$\mathbf{G}_k = \mathbf{P}_{k|k-1} \mathbf{H}^T (\mathbf{H} \mathbf{P}_{k|k-1} \mathbf{H}^T + \mathbf{R})^{-1}, \quad (13a)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{G}_k (\mathbf{z}_k - \mathbf{H} \hat{\mathbf{x}}_{k|k-1}), \quad (13b)$$

$$\mathbf{P}_{k|k} = (\mathbf{I}_j - \mathbf{G}_k \mathbf{H}) \mathbf{P}_{k|k-1}, \quad (13c)$$

sendo  $\mathbf{G}_k \in \mathbb{R}^{p \times j}$  o Ganho de Kalman, responsável por ajustar a comutação entre a previsão e a medição atual,  $\hat{\mathbf{x}}_{k|k}$  a estimativa do estado a posteriori, dadas as medidas até o tempo  $k$ ,  $\mathbf{z}_k \in \mathbb{R}^{j \times 1}$  é o vetor de medição pelos sensores no momento  $k$  e  $\mathbf{P}_{k|k}$  é a matriz de covariância de erro a posteriori no tempo  $k$ .

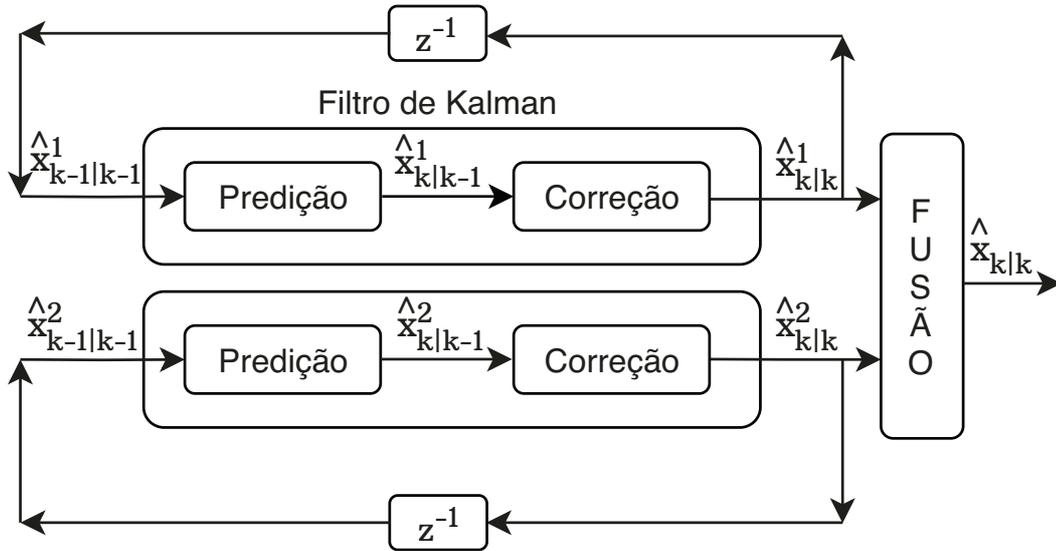
Por meio dos algoritmos de FK e suas variações, as saídas contêm as informações das variáveis de estados com um menor erro associado se comparado às medições do sistema. O FK torna-se uma ferramenta para, apesar das medições ruidosas provenientes dos sensores, gerar informações precisas sobre o sistema. Considerando um sistema de posicionamento, algumas informações comumente desejáveis são as coordenadas da localização do objeto, a velocidade e as trajetórias dos objetos em movimento (CHEN, 2011).

### 2.3.2 Fusão Sensorial com Filtro de Kalman

A associação de diferentes fontes de informação no processo de decisão exige uma combinação precisa dos dados para que o algoritmo forneça uma única resposta que tenha menos incerteza do que as soluções individuais. Esse processo é geralmente chamado de fusão de vetores e a Figura 5 mostra um algoritmo de fusão dos vetores de estado que é frequentemente utilizado (GAO; HARRIS, 2002).

Nesse método, a fusão de vetores de estado é realizada fundindo as estimativas de estado  $\hat{\mathbf{x}}_{k|k}^1$  e  $\hat{\mathbf{x}}_{k|k}^2$  dos sensores 1 e 2, respectivamente, para uma nova e mais precisa

Figura 5 – Algoritmo original da fusão dos vetores de estado.



Fonte: Adaptado de (GAO; HARRIS, 2002).

estimativa do vetor de estado (GAO; HARRIS, 2002):

$$\hat{\mathbf{x}}_{k|k}^1 = \hat{\mathbf{x}}_{k|k}^1 + [\mathbf{P}_{k|k}^1 - \mathbf{P}_{k|k}^{12}][\mathbf{P}_{k|k}^1 + \mathbf{P}_{k|k}^2 - \mathbf{P}_{k|k}^{12} - \mathbf{P}_{k|k}^{21}]^{-1}(\hat{\mathbf{x}}_{k|k}^2 - \hat{\mathbf{x}}_{k|k}^1), \quad (14)$$

sendo  $\mathbf{P}_{k|k}^m$  é a matriz de covariância para a estimativa do vetor resultante da fusão  $\hat{\mathbf{x}}_{k|k}^m$ , sendo  $m$  a medida dos diferentes sensores ( $m = 1, 2$ ).  $\mathbf{P}_{k|k}^{12} = (\mathbf{P}_{k|k}^{21})^T$  é a matriz de covariância cruzada entre  $\hat{\mathbf{x}}_{k|k}^1$  e  $\hat{\mathbf{x}}_{k|k}^2$ . A matriz de covariância cruzada é dada pela seguinte equação recursiva:

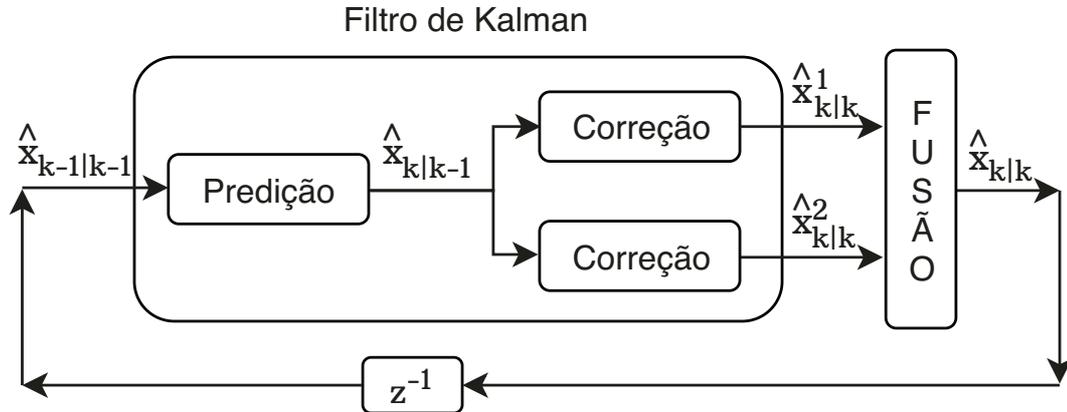
$$\begin{aligned} \mathbf{P}_{k|k}^{12} = & (\mathbf{I}_p - \mathbf{G}_k^1 \mathbf{H}_k^1) \mathbf{A}_{k-1} \mathbf{P}_{k-1|k-1}^{12} \mathbf{A}_{k-1}^T (\mathbf{I}_p - \mathbf{G}_k^2 \mathbf{H}_k^2)^T \\ & + (\mathbf{I}_p - \mathbf{G}_k^1 \mathbf{H}_k^1) \mathbf{v}_{k-1} \mathbf{Q}_{k-1} \mathbf{v}_{k-1}^T (\mathbf{I}_p - \mathbf{G}_k^2 \mathbf{H}_k^2)^T, \end{aligned} \quad (15)$$

sendo  $\mathbf{G}_k^1$  e  $\mathbf{G}_k^2$  o ganho do filtro de Kalman para o sensor 1 e 2 respectivamente, no tempo  $k$ .

A equação (14) representa a solução ótima de um estimador linear, o que faz desse método uma excelente alternativa para combinação de vetores de estado. Esse método ainda apresenta um menor custo computacional quando comparado à fusão de medições (GAO; HARRIS, 2002) provenientes das técnicas de localização, por exemplo.

Outro método de fusão, apresentado na Figura 6, propõe que o vetor resultado da fusão é utilizado para realimentar o sistema, que agora possui apenas um único estágio de previsão. A saída dessa etapa é então a entrada do estágio de correlação, associada a cada medida individualmente (GAO; HARRIS, 2002).

Figura 6 – Algoritmo modificado da fusão dos vetores de estado.



Fonte: Adaptado de (GAO; HARRIS, 2002).

Nesse modelo modificado da fusão dos vetores de estados, a previsão  $\hat{\mathbf{x}}_{k|k-1}$  é combinada com as medidas  $\mathbf{z}_k^1$  e  $\mathbf{z}_k^2$  individualmente, gerando assim dois novos vetores de estados  $\hat{\mathbf{x}}_{k|k-1}^1$  e  $\hat{\mathbf{x}}_{k|k-1}^2$ , que serão combinados na próxima interação.

Em Gao e Harris (2002) realizou-se um estudo comparativo entre os dois métodos mencionados e os resultados demonstraram que, em cenários que combinam sensores ou medidas com unidades semelhantes, o algoritmo original da fusão dos vetores de estados apresenta uma performance superior ao modificado. O algoritmo modificado por sua vez, supera o original em aplicações com medidas de unidades diferentes.

Isso acontece, pois, no sistema da Figura 6, ao fundir também a etapa de previsão, as informações dos sensores diferentes são combinadas e realimentadas para a próxima etapa da estimativa. No entanto, este procedimento não fornecerá mais informações sobre a fusão no caso de sensores semelhantes. O artigo ainda demonstra que, ao utilizar o modelo modificado com sensores similares, a covariância estimada do algoritmo converge para um valor de estado estacionário.

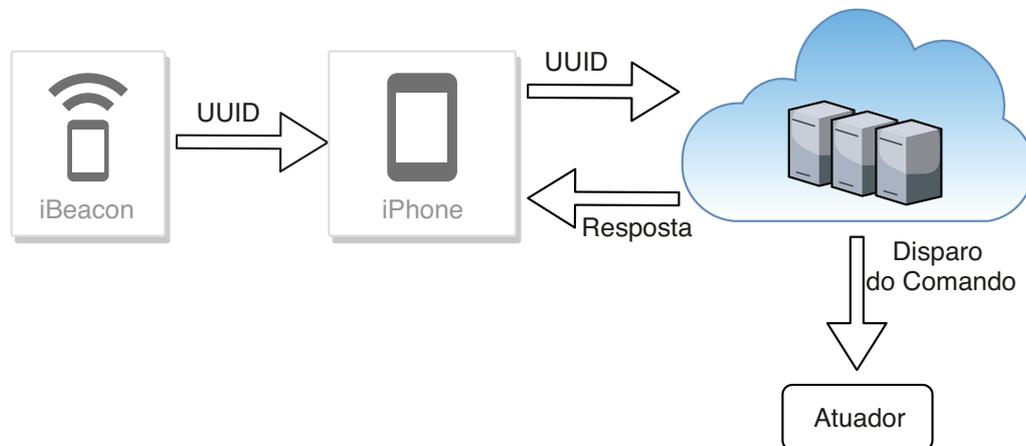
## 2.4 BLUETOOTH - BEACON

Com o avanço da IoT, novos produtos de baixo custo e eficiência energética, como dispositivos *beacons* BLE foram desenvolvidos. Um equipamento *beacon* BLE pode ser definido como um dispositivo que transmite mensagens de *beacon* em *broadcast* para todos os dispositivos que estejam em um raio de cerca de 100 metros (valor considerando LoS) e possuam a função BLE ativada (ZAFARI et al., 2015).

O conceito de *beacon* foi amplamente difundido por um produto lançado pela empresa *Apple*, o *iBeacon*. Trata-se de um protocolo específico baseado na tecnologia do BLE e se destina a ser usado como um *BLE Beacon* com enfoque nos dispositivos com o sistema operacional utilizado pelos *smartphones* da marca (ZAFARI et al., 2015). Este tipo de produto despertou o interesse do mercado após a empresa afirmar que opera por meses ou até anos com uma bateria de célula tipo moeda (JEON et al., 2018). Esse baixo consumo de energia é possível devido ao hardware ter sido desenvolvido para ser energeticamente eficiente e também ao pequeno tamanho da unidade de dados do protocolo (PDU, do inglês *Protocol Data Unit*) dos pacotes de *advertising*.

A arquitetura típica de um sistema baseado em *beacons* está representada na Figura 7. Depois de receber uma mensagem do *iBeacon*, o dispositivo móvel do usuário, geralmente *smartphone*, consulta um servidor ou a nuvem para identificar a ação relacionada com o pacote de dados recebido. A ação pode ser enviar um cupom de desconto para o dispositivo do usuário, abrir uma porta ou exibir algum conteúdo interativo em um monitor (atuador) com base na proximidade do usuário a um ponto específico (ZAFARI et al., 2019).

**Figura 7 – Arquitetura típica para sistemas baseados em iBeacon.**



**Fonte:** Adaptado de (ZAFARI et al., 2019).

A estrutura de um pacote *iBeacon* contém um total de 46 bytes de comprimento. O Identificador Universal Exclusivo (UUID, do inglês *Universally Unique Identifier*) possui 16 bytes e é o identificador desse *beacon* pois todos os nós sensores precisam ser identificados dentro de uma WSN (GOROVYI et al., 2017). Há também os campos *major* e *minor*, que possuem 2 bytes e são utilizados para identificar um *iBeacon* com maior precisão (SADOWSKI; SPACHOS, 2018). Trata-se de um pequeno espaço para dados específicos do fabricante. Tanto a *Apple* quanto o *Google* manipularam esse pequeno

pedaço de informação encapsulado na PDU e introduziram seus próprios perfis populares de *beacon*, o *iBeacon* e *Eddystone*, respectivamente (JEON et al., 2018).

O último campo de informação desse pacote representa o RSSI a 1 m de distância, que é primordial para o cálculo da distância do nó através de (2). Essa estrutura de pacotes não apenas permite a identificação conveniente desses dispositivos de maneira individual, mas também fornece à indústria um padrão universal para o desenvolvimento de aplicativos (JEON et al., 2018).

Os produtos baseados em *beacons* são dispositivos periféricos de comunicação e não devem ser utilizados para trabalhar com grandes volumes de dados, mas sim para transmitir pequenas mensagens contendo a informação desejada. A capacidade de envio das mensagens é de no máximo 1 Mbps e destaca-se como vantagem desse dispositivo BLE o fato que nenhum pareamento de dispositivos é necessário para receber os sinais transmitidos (JEON et al., 2018).

Devido ao baixo custo desses produtos BLE, colocar vários dispositivos que se comunicam através de um sinal *beacon* em torno de um ambiente pode ser mais viável e barato do que reorganizar o hardware existente, como os roteadores Wi-Fi, e usá-los para localização. Em (FARAGHER; HARLE, 2015) os autores mostram que os IPS baseados em BLE são realmente capazes de superar a precisão dos baseados em Wi-Fi, dependendo da densidade da rede BLE. Foram montados 19 dispositivos *beacons* em uma área de escritório e obteve-se erro de  $\geq 1,36$  m 66% do tempo, considerando que os dispositivos foram implantados a cada 30 m<sup>2</sup>, superando o erro de  $\geq 3,1$  m para o mesmo intervalo, alcançado pela rede Wi-Fi.

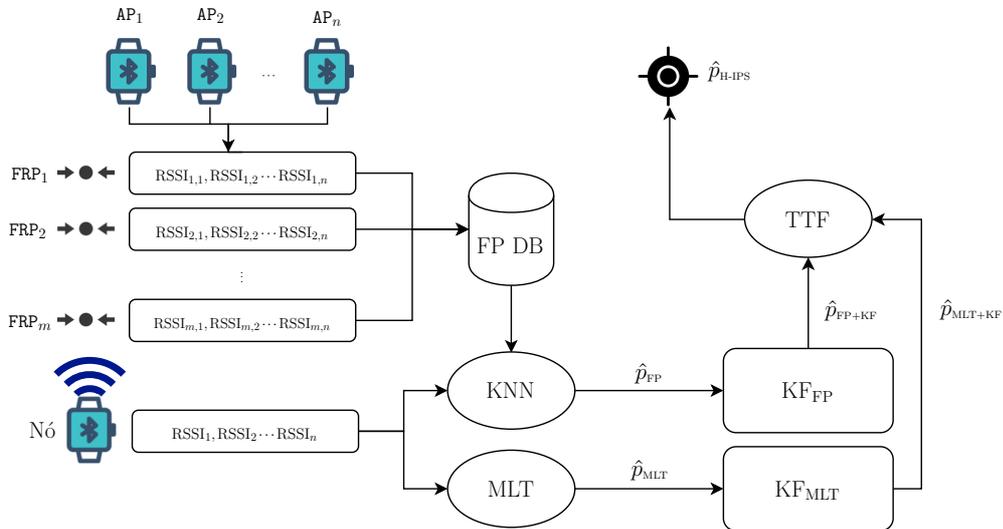
Para aplicações de IPS há três fatores importantes a serem levados em consideração: a organização dos transmissores e receptores, a análise RSSI e a tecnologia sem fio (por exemplo, Wi-Fi, BLE) que serão usadas para a implantação (PATERNA et al., 2017). Quanto ao arranjo de utilização desses dispositivos, existem dois cenários possíveis. Um baseado em considerar que os pontos de acessos transmitem os sinais *beacons* para o dispositivo a ser localizado e outro onde esses pontos de acessos recebem os sinais dos dispositivos a serem rastreados (PATERNA et al., 2017).

### 3 SOLUÇÃO PROPOSTA

O objetivo da presente solução é estimar a posição de um transmissor móvel que se move de acordo com um modelo de movimento de velocidade constante. O transmissor móvel transmite periodicamente um sinal *beacon*, contendo seu endereço Bluetooth (BD\_ADDR), que está sujeito aos efeitos de perda de caminho, sombreamento e desvanecimento do sinal (GOLDSMITH, 2005). Para isso, considerou-se uma área de interesse retangular com dimensões  $l \times w$  metros, sendo  $N$  pontos de acesso estacionários  $\{\text{AP}_n\}_{n=1}^N$  foram colocados em coordenadas conhecidas  $(x_n, y_n) \in \text{AoI}$ .

Os efeitos do desvanecimento rápido podem ser removidos através da média de um conjunto suficientemente grande de amostras independentes (Obeidat et al., 2019), de tamanho  $P$ , o RSSI (em dBm) no  $n$ -ésimo AP é estimado conforme o modelo de propagação log-normal (1). Com essa medida de RSSI aplica-se, para cada ponto medido, duas técnicas de localização, conforme a Figura 8.

**Figura 8 – Modelo do diagrama do H-IPS proposto auxiliado por FK e fusão de vetores de estado.**



**Fonte: Autoria própria.**

Para a técnica de *fingerprinting*, na fase de calibração é gerado um banco de dados que consiste nas medidas  $\text{RSSI}_{m,n}$ , que representam os valores medidos no  $\{\text{AP}_n\}_{n=1}^N$  dos pacotes enviados por um dispositivo que envia *beacons* em um número preestabelecido de  $M$  pontos de referência distribuídos de forma equidistante  $\{\text{FRP}_m\}_{m=1}^M$ , posicionados nas coordenadas  $(x_m, y_m) \in \text{AoI}$ .

Portanto, a saída da fase de calibração é composta pela identificação dos  $\text{AP}_n$

e  $\text{FRP}_m$ , associados com suas localizações  $(x_n, y_n)$  e  $(x_m, y_m)$ , assim como a medida do  $\text{RSSI}_{m,n}$  associado  $\forall n \in \{1, \dots, N\}, \forall m \in \{1, \dots, M\}$  (DUAN et al., 2019; LI et al., 2016). Presume-se que esse banco de dados seja armazenado em um servidor de localização conectado aos APs, que será responsável por estimar a posição do nó na fase de localização *online*.

Na fase *online*, o nó transmite sinais periódicos, cujo RSSI é estimado pelos APs. Esse conjunto de RSSIs é comparado com os valores armazenados no banco de dados. Como comumente adotado na literatura, para o trabalho proposto, considera-se um algoritmo não paramétrico para lidar com esses conjuntos de dados. Esse algoritmo baseia-se na distância euclidiana para calcular a distância entre o conjunto de valores RSSI do banco de dados ( $\text{RSSI}_{m,n}$ ) e a impressão digital atual medida pelo dispositivo que está sendo rastreado ( $\text{RSSI}_n$ ), como na equação (10) (LI et al., 2016).

O resultado é um conjunto de distâncias  $\mathcal{D} = \{D_1, \dots, D_m, \dots, D_M\}$ , com  $|\mathcal{D}| = M$ . A posição estimada do transmissor móvel, referenciada como  $\hat{p}_{\text{FP}} = (\hat{x}_{\text{FP}}, \hat{y}_{\text{FP}})$ , é então obtida através da técnica KNN, cuja saída é o centróide  $\hat{p}_{\text{FP}}$  do polígono formado pelos  $\kappa$  FRPs com o menor  $D_m$ , isto é, os primeiros  $\kappa$  elementos do conjunto  $\mathcal{D}_{\text{sort}} = \text{sort}(\mathcal{D})$ , em que  $\text{sort}()$  corresponde à função de classificação em ordem crescente (YADAV et al., 2019). Para o presente estudo utilizou-se  $\kappa = 4$ , de acordo com os valores adotados na literatura (Song et al., 2018), além de ter sido verificado através de simulações como um valor que estabelece uma boa relação de compromisso entre precisão e complexidade.

Para a aplicação da técnica de multilateração, com o indicador de intensidade de sinal recebido do *beacon* enviado pelo dispositivo que está sendo rastreado ( $\text{RSSI}_n$ ), através de (2), é possível estimar uma distância entre o nó e o AP que recebeu o pacote. Assim, cada um dos  $N$  pontos de acesso estabelece um raio com a distância estimada, de modo que diversos pontos de interseção entre estes círculos pode ocorrer. Para minimizar  $\sum_{n=1}^N (d_n - \hat{d}_n)^2$ , a estimativa da posição  $\hat{p}_{\text{MLT}}$  é obtida através do método dos mínimos quadrados.

Essas posições estimadas  $\hat{p}_{\text{MLT}}$  e  $\hat{p}_{\text{FP}}$ , produzidas respectivamente pela multilateração e *fingerprinting*, são consideradas entradas para dois Filtros de Kalman, um associado a cada técnica. O vetor  $\mathbf{z}_k \in \mathbb{R}^{2 \times 1}$  de cada um dos filtros contém as coordenadas de  $\hat{p}_{\text{MLT}}$  e  $\hat{p}_{\text{FP}}$ . Relacionando a posição estimada a um modelo de movimento de velocidade constante, há uma suavização na aleatoriedade inerente às medidas RSSI e consequentemente um aumento na precisão da estimativa. Para isso, foram projetados dois filtros de segunda ordem sem entradas de controle externo. O vetor de estado considerado

foi  $\mathbf{x}_k = [x(k) \quad y(k) \quad v_x(k) \quad v_y(k)]^T$ , sendo  $x(k)$ ,  $y(k)$ ,  $v_x(k)$ ,  $v_y(k)$  coordenadas e as velocidades nas direções  $x$  e  $y$ , respectivamente. As saídas são um par de coordenadas 2D  $\hat{p}_{f+\text{FK}} = (\hat{x}_{f+\text{FK}}, \hat{y}_{f+\text{FK}})$ ,  $f \in \{\text{MLT}, \text{FP}\}$ .

Para os valores das matrizes de covariância do ruído da medição ( $\mathbf{R} = r\mathbf{I}_2 \in \mathbb{R}^{2 \times 2}$ ) e do erro associado ao modelo de transição ( $\mathbf{Q} = q\mathbf{I}_4 \in \mathbb{R}^{4 \times 4}$ ), desenvolveu-se uma função que realiza uma busca exaustiva para minimizar o erro médio. Considerando valores mínimos e máximos de  $r$  e  $q$ , assim como o passo de incremento, os valores de  $r$  e  $q$  considerados sintonizados são os que resultam no menor valor médio da distância euclidiana entre a saída do filtro de Kalman e o valor real da posição. Essa etapa foi arbitrada como uma etapa de calibração do sistema, pois as matrizes de covariância são mutáveis conforme variáveis dos cenários, como a precisão das técnicas que variam de acordo com o número de APs disponíveis na AoI. O objetivo com esse passo foi buscar os valores de  $r$  e  $q$  que melhor representem a imprecisão dos sensores e as informações de incerteza associada ao modelo, respectivamente.

Finalmente, para extrair a máxima precisão e exatidão possível das informações sobre a localização do nó, no esquema proposto H-IPS, combina-se  $\hat{p}_{\text{MLT}+\text{FK}}$  e  $\hat{p}_{\text{FP}+\text{FK}}$  através da técnica de fusão dos vetores de estado através de (14). Os valores de  $r$  e  $q$  definidos na etapa anterior, são utilizados no filtro de Kalman associado a cada uma das técnicas.

O Algoritmo 1 apresenta a implementação realizada para simulação da RSSI, conforme mencionado na Seção 2.1.2.1.

---

**Algoritmo 1: Simulação do RSSI em cada ponto**


---

**Entrada:**  $d_0, d_n, \alpha, \text{RSSI}_{n,d_0}, \sigma$

**Saída:**  $\text{RSSI}_n/P$

```

1 início
2   RSSIn = 0;
3   P = 1000;
4   para j=0:1:P-1 faça
5     se resto(j,100)== 0 então
6       | Xσ ← N(0,σ2);
7       fim
8       RSSIn ← RSSIn+ o resultado de (1);
9   fim
10  retorna RSSIn/P;
11 fim

```

---

O Algoritmo 2 apresenta a implementação técnica de localização por multilateração, conforme mencionado na Seção 2.2.2.

---

**Algoritmo 2: Multilateração**


---

**Entrada:**  $\text{RSSI}_n, d_0, \alpha, \text{RSSI}_{n,d_0}$

**Saída:**  $\hat{p}_{\text{MLT}}$

```

1 início
2   inicialização;
3   para n=1:1:N faça
4     | estima a distância entre o nó e o APn através de (2);
5   fim
6   aplica mínimos quadrados no sistema (9);
7   retorna  $\hat{p}_{\text{MLT}}$ ;
8 fim

```

---

O Algoritmo 3 apresenta a implementação técnica de localização por *Fingerprinting*, conforme mencionado na Seção 2.2.3.

---

**Algoritmo 3: Fingerprinting**


---

**Entrada:**  $\kappa$ ,  $\text{RSSI}_n$  e  $\text{RSSI}_{m,n} \forall n \in \{1, \dots, N\}, \forall m \in \{1, \dots, M\}$

**Saída:**  $\hat{p}_{\text{FP}}$

```

1 início
2   | inicialização;
3   | para  $m=1:1:M$  faça
4   |   | calcula  $D_m$  através de (10);
5   |   | adiciona  $D_m$  ao vetor  $\mathcal{D}$ ;
6   | fim
7   | ordena o vetor  $\mathcal{D}$  em ordem crescente;
8   | forma o polígono com os FRPs associados aos  $\kappa$  menores  $D_m$ ;
9   | se pontos colineares então
10  |   | retorna o ponto médio da reta;
11  | senão
12  |   | retorna o centróide do polígono figura formado;
13  | fim
14 fim

```

---

O Algoritmo 4 apresenta o Filtro de Kalman executado conforme mencionado na Seção 2.3.1.

---

**Algoritmo 4: Filtro de Kalman**


---

**Entrada:**  $\hat{p}_j, \mathbf{H}, \mathbf{R}, \mathbf{Q}, \mathbf{A}$

**Saída:**  $\hat{p}_{j+\text{FK}}$

```

1 início
2   | inicialização;
3   |  $\mathbf{z}_k = \hat{p}_j$ ;
4   |  $\mathbf{x}_k \leftarrow [x(k) \ y(k) \ v_x(k) \ v_y(k)]^T$ ;
5   | calcula  $\hat{\mathbf{x}}_{k|k-1}$  através de (12a);
6   | calcula  $\mathbf{P}_{k|k-1}$  através de (12b);
7   | calcula  $\mathbf{G}_k$  através de (13a);
8   | adiciona o vetor  $\mathbf{z}_k$  para calcular  $\hat{\mathbf{x}}_{k|k}$  através de (13b);
9   | calcula  $\mathbf{P}_{k|k}$  através de (13c);
10  |  $\hat{\mathbf{x}}_{k|k-1} = \hat{\mathbf{x}}_{k|k}$ ;
11  | retorna  $\hat{p}_{j+\text{FK}}$ ;
12 fim

```

---

O Algoritmo 5 apresenta a metodologia da fusão sensorial do vetor de estados de

acordo a Figura 5.

---

**Algoritmo 5:** Fusão de vetores de estado

---

**Entrada:**  $\hat{p}_{\text{MLT+FK}}, \hat{p}_{\text{FP+FK}}, \mathbf{H}, \mathbf{R}, \mathbf{Q}, \mathbf{A}$

**Saída:**  $\hat{p}_{j+\text{FK}}$

**1 início**

**2** | inicialização;

**3** |  $\mathbf{P}_{k|k}^{12} = 0;$

**4** |  $\mathbf{P}_{k|k}^{21} = 0;$

**5** |  $\hat{\mathbf{x}}_{\text{H-IPS}} \leftarrow$  o resultado de (14);

**6** | **retorna**  $\hat{\mathbf{x}}_{\text{H-IPS}};$

**7 fim**

---

## 4 SIMULAÇÕES E RESULTADOS

Para realizar as avaliações, os valores de RSSI foram simulados através da equação (1), e a variável aleatória representando  $X_\sigma$  é atualizada a cada 100 medições do RSSI, conforme apresentado no Algoritmo 1. Para criação do banco de dados de fingerprinting, foi simulado o RSSI de  $P = 1.000$  *beacons* em cada FRP durante a fase de calibração, bem como na fase de localização, com o objetivo de atenuar os efeitos do desvanecimento rápido. O número de amostras (passos) ao longo do caminho foi escolhido como 200, pois verificou-se por meio de simulações ser um valor que estabelece uma boa relação de compromisso entre o erro e a complexidade associada.

**Tabela 1 – Parâmetros do Sistema.**

Parâmetro	Valor
Coefficiente de perda de percurso ( $\alpha$ )	1,8 *
Desvio padrão do sombreamento ( $\sigma$ )	4,57 dB †
Velocidade no eixo $x$ ( $v_x$ )	1,18 m/s
Velocidade no eixo $y$ ( $v_y$ )	1,62 m/s
Comprimento do ambiente ( $l$ )	60 m
Largura do ambiente ( $w$ )	40 m
Distância de referência ( $d_0$ )	1 m
RSSI medido em $d_0$ ( $\text{RSSI}_{n,d_0}$ )	-52,36 dBm
Amostras ao longo do caminho	200

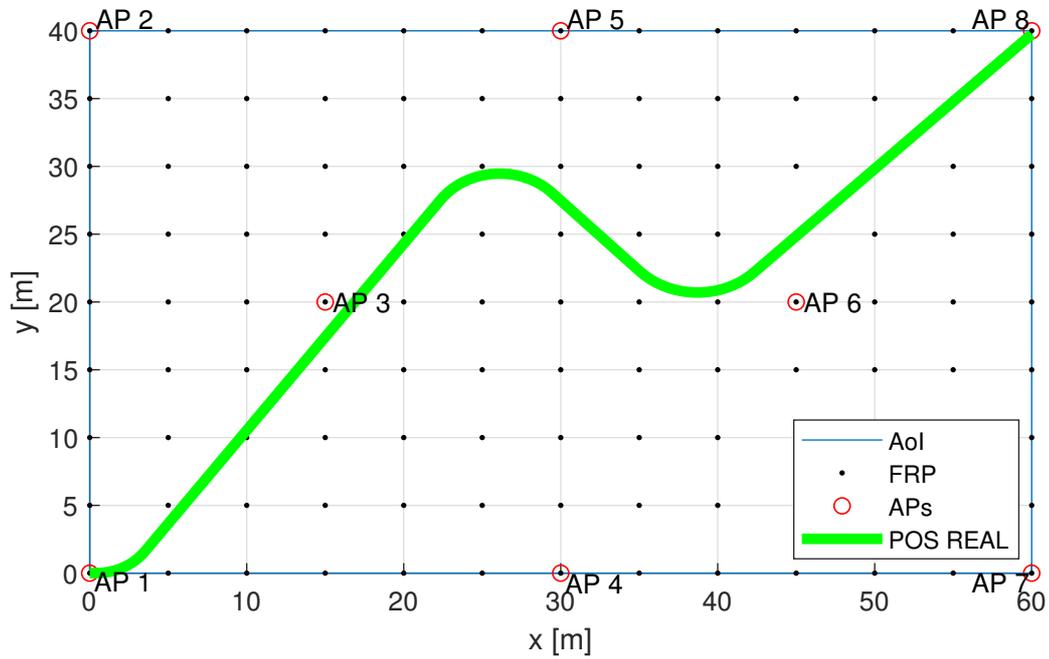
Fonte: \*(LAARAIEDH et al., 2009), †(ZANELLA; BARDELLA, 2014)

Os parâmetros do sistema adotados nesta seção são os apresentados na Tabela 1. A Figura 9 apresenta o cenário base para as simulações apresentadas neste capítulo e mostra o caminho verdadeiro percorrido pelo transmissor móvel. Considerou-se uma área de interesse de 60 m de comprimento e 40 m de largura com  $N = 8$  APs, distribuídos com uma distância média entre si, e tamanho da grade dos FRPs  $5 \text{ m} \times 5 \text{ m}$ , conforme resultados das simulações a seguir.

Considerando o cenário mencionado, a Figura 10 indica as estimativas de localização correspondentes fornecidas pelas técnicas MLT, FP e H-IPS, com o valor sintonizado obtido numericamente de  $r$ . Pode-se observar que o H-IPS proposto é capaz de suavizar os erros provenientes das técnicas isoladas, fornecendo uma estimativa significativamente mais próxima da posição real.

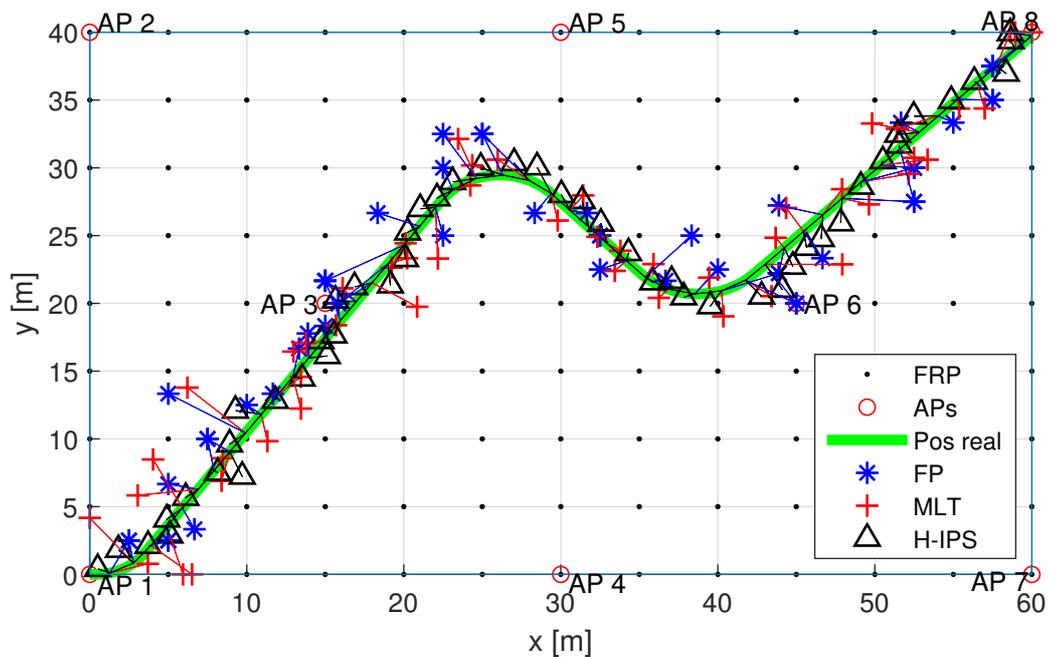
A influência do tamanho da grade do FRP no erro médio é avaliada na Figura 11, considerando  $N = 8$  APs e os seguintes tamanhos de grade:  $10 \text{ m} \times 10 \text{ m}$ ,  $8 \text{ m} \times 8 \text{ m}$ ,

Figura 9 – Posição real no cenário  $l = 60$  m,  $w = 40$  m,  $N = 8$ , tamanho da grade dos FRPs é  $5$  m  $\times$   $5$  m.



Fonte: Autoria própria.

Figura 10 – Posição real, FP, MLT e H-IPS para  $l = 60$  m,  $w = 40$  m,  $N = 8$ , tamanho da grade dos FRPs é  $5$  m  $\times$   $5$  m e 200 passos ao longo do caminho, com marcadores a cada 4 passos.

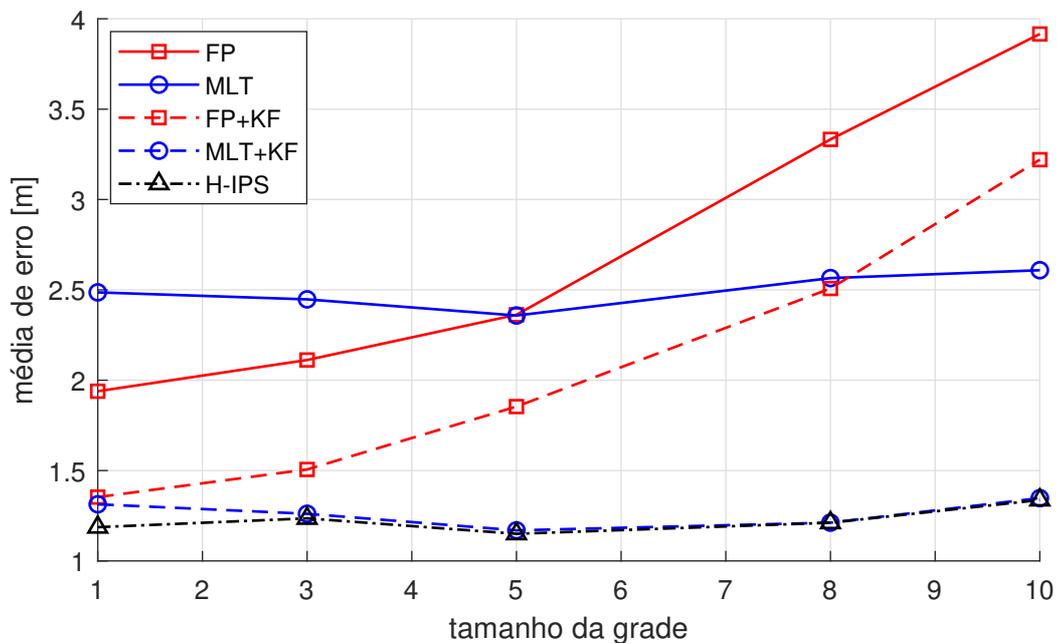


Fonte: Autoria própria.

5 m × 5 m, 3 m × 3 m e 1 m × 1 m. Ao analisar a Figura, é possível notar, uma redução do tamanho da grade de 10 m × 10 m para 1 m × 1 m diminui o erro em 50,71% e 57,98% para o FP e FP+FK, respectivamente. Por outro lado, conforme a Figura 12, o número de amostras de RSSI armazenadas no banco de dados, para o mesmo cenário, aumenta de 280 para 20008, ~10000% maior. Observa-se que embora a precisão das técnicas baseadas em FP aumente quando o tamanho da grade é reduzido, o tamanho do banco de dados aumenta exponencialmente, o que demanda um alto custo computacional.

Nota-se, também na Figura 11 que, para  $N = 8$  APs, a precisão do esquema proposto, H-IPS, apresenta uma pequena variação no tamanho da grade, seguindo o esquema MLT, que não depende do tamanho da grade. É preciso considerar que a fusão das técnicas de localização será mais eficaz quando a variação do erro médio das técnicas isoladas não apresentarem uma grande variação entre si. Pode-se observar que para o tamanho da grade 10 m × 10 m o H-IPS se aproxima dos valores de MLT+FK pois efetua a compensação do alto valor do erro médio atribuído a técnica de FP+KF. Por outro lado, para o tamanho da grade 1 m × 1 m, o H-IPS apresenta um erro menor do que as demais, por ser a situação onde a precisão das técnicas MLT+FK e FP+KF mais se aproximam.

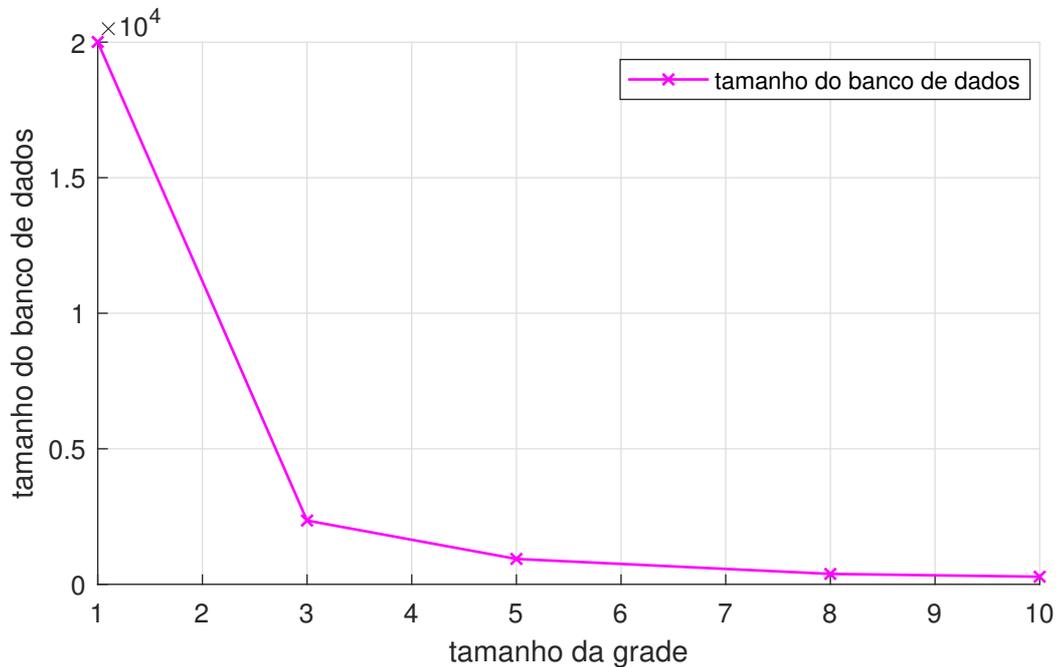
**Figura 11 – Erro médio versus o tamanho da grade, para  $N = 8$  APs.**



**Fonte: Autoria própria.**

A Tabela 2 avalia a influência do número de APs no erro médio de posição do IPS para um tamanho de grade de 3 m × 3 m. Essa tabela relaciona o “FP+FK sintonizado”

Figura 12 – Tamanho do banco de dados versus o tamanho da grade, para  $N = 8$  APs.



Fonte: Autoria própria.

e o “MLT+FK sintonizado” que referem-se, respectivamente, aos esquemas FP + FK e MLT + FK ao adotar os valores sintonizado de  $r$  e  $q$ , que são obtidos numericamente e fornecidos na Tabela 3. Os resultados do cenário anteriormente considerado ( $r = 10$  e  $q = 10$ ) também são apresentados. Esses valores mínimos de erro das medidas e do modelo foram empiricamente determinados para servir de ponto de partida pois é de conhecimento a presença de ruídos em ambos. Para o modelo o erro associado se justifica no fato da trajetória definida conter curvas e o modelo utilizado considerar aceleração constante. Para as medidas, há os ruídos gerados ao trabalhar-se com o RSSI e técnicas de localização.

Conforme mencionado na Seção 3, os valores de  $r$  e  $q$  considerados foram encontrados através da busca exaustiva do menor erro associado. Nesse cenário, o ruído das medidas se mostraram maiores quando comparado ao do modelo, sendo assim, fixou-se o valor de  $q = 10$  e buscou-se o  $r$  que melhor representa-se o sistema. Com isso, é possível constatar que a busca do valor de  $r$  que represente as inexatidões das medidas, aumenta significativamente a precisão dos esquemas com Filtro de Kalman. Além disso, também observa-se que o esquema H-IPS proposto, que utiliza o resultado sintonizado das técnicas, apresentou um melhor desempenho independentemente do número de pontos de acesso.

Tabela 2 – Erro médio (em metros) para diferentes números de APs

# APs	3	4	5	6	7	8	9
FP	4,17	3,93	3,21	2,56	2,31	2,11	<b>2,10</b>
FP+FK	3,59	2,95	2,42	2,06	1,79	1,75	1,65
FP+FK sintonizado	2,97	1,84	1,70	1,63	1,69	1,51	1,26
MLT	5,25	4,32	3,46	3,20	2,69	2,45	<b>2,50</b>
MLT+FK	3,94	3,10	2,46	2,26	1,84	1,78	1,79
MLT+FK sintonizado	2,72	1,74	1,64	1,46	1,23	1,26	1,25
H-IPS proposto	<b>2,69</b>	1,60	1,50	1,35	1,22	1,24	<b>1,14</b>

Fonte: Autoria própria.

Tabela 3 –  $r$  que minimiza o erro médio do FK

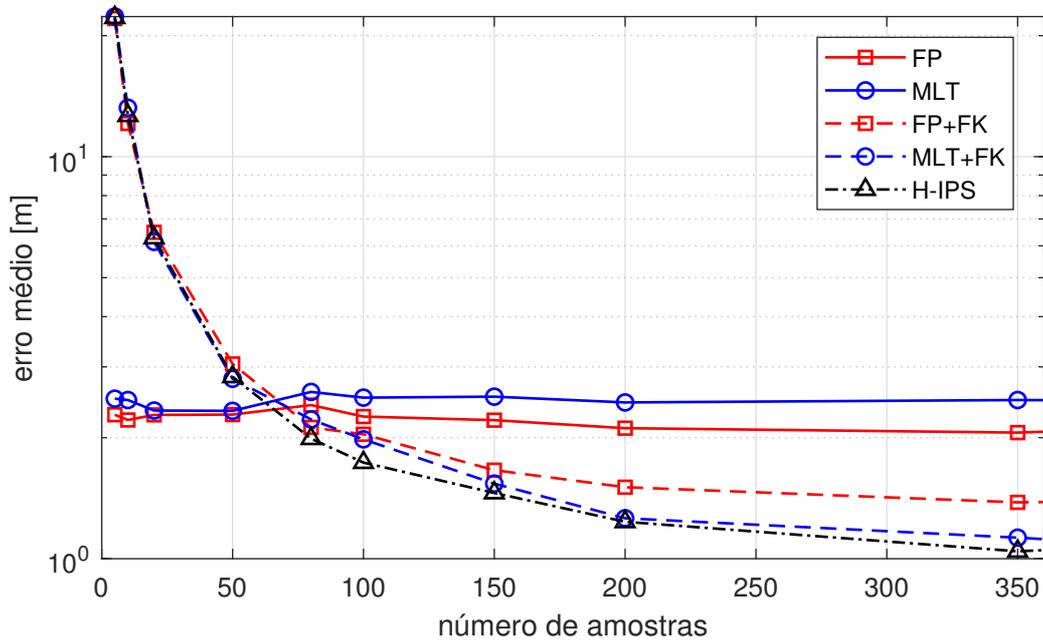
# APs	3	4	5	6	7	8	9
$r_{\text{opt,FP}}$	40	70	40	30	20	30	20
$r_{\text{opt,MLT}}$	50	60	20	20	20	20	20

Fonte: Autoria própria.

Além disso, pode-se observar também que o H-IPS proposto com apenas  $N = 3$  APs pode alcançar um nível de desempenho semelhante ao dos esquemas autônomos de MLT e FP com  $N = 7$  e  $N = 6$  APs, respectivamente. Esse número reduzido de pontos de acesso necessários para atingir o mesmo nível de desempenho leva a um tamanho reduzido do banco de dados e do tempo de processamento. Por outro lado, a precisão do H-IPS proposto com  $N = 9$  APs supera as técnicas autônomas de MLT e FP em aproximadamente 54% e 46%, respectivamente. Esses valores estão destacados em negrito na Tabela 2.

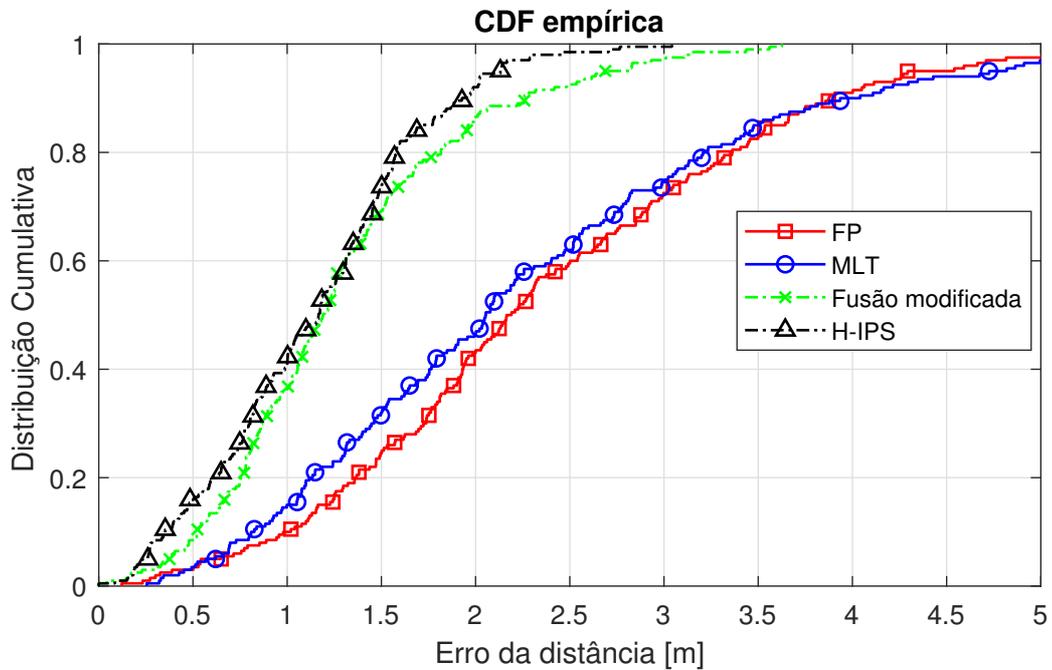
Para avaliar o regime transitório do FK, é mostrada na Figura 13 a variação do erro em função do número de amostras utilizadas ao longo do caminho, ou seja, o número de passos que o nó percorre. Como esperado, os esquemas FP e MLT praticamente não apresentam variações de desempenho com o número de amostras, já que em cada passo já é realizada uma média de 1.000 pacotes, suavizando o efeito do desvanecimento rápido. As pequenas oscilações do erro médio, presente na Figura para essas técnicas, são justificadas devido a quantidade de simulações consideradas para o cálculo da média. Para os esquemas que passam pelo Filtro de Kalman o erro é maior nos cenários com poucas amostras, mas pode-se observar que a precisão aumenta exponencialmente com o número de amostras, devido à convergência da matriz de covariância de erro. No entanto, para  $\geq 200$  amostras, a taxa de redução de erro é significativamente reduzida, o que motivou a utilização de 200 amostras nas simulações.

Figura 13 – Erro médio em função do número de amostras.



Fonte: Autoria própria.

Figura 14 – Função de Distribuição Cumulativa (CDF) do erro da distância para  $N = 8$  APs e tamanho de grade dos FRPs igual a  $5 \text{ m} \times 5 \text{ m}$ .



Fonte: Autoria própria.

Na Figura 14 é apresentada a função de distribuição cumulativa (CDF, do inglês *Cumulative Distribution Function*) do erro da distância para o FP, MLT e o esquema H-IPS proposto, considerando  $N = 8$  APs e o tamanho da grade dos FRPs de  $5 \text{ m} \times 5 \text{ m}$ . Pode-se observar que a probabilidade de o erro ser menor que 2 m é 92% para o algoritmo proposto, enquanto para o FP e MLT a mesma probabilidade é 43% e 47%, respectivamente.

Além disso, na Figura 14 é possível comparar o desempenho dos dois métodos de fusão de vetores de estado apresentados na Seção 2.3.2. Os resultados confirmam que em cenários em que os sensores medem o mesmo tipo de grandeza o algoritmo original da fusão dos vetores de estados apresenta desempenho superior ao modificado, com erro médio 11,7% menor.

## 5 COMENTÁRIOS FINAIS E TRABALHOS FUTUROS

Localização *indoor* é um tema que desperta interesse devido a sua alta variedade de aplicações. Os produtos que transmitem *beacons* Bluetooth estão presentes cada vez mais em diversos setores. Esses dispositivos estão sendo amplamente utilizados para resolver problemas essenciais de negócios e trazer novos recursos para sistemas existentes. O preço relativamente mais baixo das soluções baseadas em Bluetooth é fundamental para sua adoção em larga escala em vários domínios, como navegação interna, segurança do trabalhador, atendimento a idosos e rastreamento de ativos a preços acessíveis.

Tendo em vista todas as vantagens do Bluetooth, neste trabalho considerou-se a aplicação de técnicas que são consolidadas na literatura para localização em ambientes internos a partir da conversão do RSSI dos *beacons* recebidos em distância. É o caso da multilateração e do *fingerprinting*, que em conjunto com a filtragem estocástica e fusão sensorial, apresentaram desempenho significativamente superior quando comparado às técnicas separadamente. O modelo proposto foi batizado de sistema híbrido de posicionamento interno (H-IPS).

Os resultados indicam que o H-IPS melhora a precisão da estimativa quando comparado individualmente ao esquema FP independente em até 46%, enquanto a técnica isolada de MLT é superada em aproximadamente 54%. Também são fornecidas informações sobre a influência de parâmetros como o tamanho da grade FP, número de pontos de acesso (APs) e número de amostras sobre a precisão do esquema proposto. Finalmente, mostra-se que a probabilidade de o erro de distância do esquema proposto ser menor que 2 m é 92%, enquanto que considerando as técnicas isoladas de FP e MLT, a mesma probabilidade é de 43% e 47%, respectivamente.

Como trabalhos futuros, há três pontos distintos a serem trabalhados. O primeiro é relacionado à busca dos fatores  $r$  e  $q$  sintonizados, tanto para as técnicas isoladas, quanto para os valores considerados durante a fusão dos modelos. Os resultados obtidos mostraram que considerar os valores que melhor representam a covariância do erro associado às medidas e ao modelo é uma maneira eficaz de melhorar o resultado filtragem de Kalman. Portanto, desenvolver um modelo em tempo real de busca desses valores sintonizados poderia resultar em uma precisão ainda maior da localização. Uma alternativa a ser desenvolvida é trabalhar com a interação de múltiplos modelos. Dessa forma, será possível intercalar entre os modelos que representem as diferentes condições de linha de visada, causadas pela presença de obstáculos dinâmicos, e definir de maneira

mais precisa os valores da variáveis que representem o ambiente em tempo real.

O segundo ponto seria desenvolver, através do SVM, um classificador para substituir o KNN. Para problemas práticos, o KNN poderia apresentar uma insuficiência na escalabilidade. Estima-se que ao treinar o classificador será possível aumentar a precisão do sistema, diminuindo o tempo de resposta e assim obter um melhor desempenho em tempo real.

Por fim, também vislumbra-se validar o presente estudo com a implementação prática. Como todos os valores de RSSI utilizados neste trabalho foram produto de simulação computacional, desenvolver uma aplicação prática contribuiria para validar o modelo proposto, além de verificar a viabilidade da técnica para produtos e serviços de localização para ambientes internos.

## REFERÊNCIAS

- AL-FUQAHA, A.; GUIZANI, M.; MOHAMMADI, M.; ALEDHARI, M.; AYYASH, M. Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications. **IEEE Communications Surveys and Tutorials**, IEEE, v. 17, n. 4, p. 2347–2376, 2015. ISSN 1553877X.
- BANERJEE, T.; SHETH, A. Iot quality control for data and application needs. **IEEE Intelligent Systems**, IEEE, v. 32, n. 2, p. 68–73, 2017.
- BELMONTE-HERNÁNDEZ, A.; HERNÁNDEZ-PEÑALOZA, G.; ÁLVAREZ, F.; CONTI, G. Adaptive Fingerprinting in Multi-Sensor Fusion for Accurate Indoor Tracking. **IEEE Sensors Journal**, v. 17, n. 15, p. 4983–4998, 2017. ISSN 1530437X.
- CHEN, S. Kalman filter for robot vision: a survey. **IEEE Transactions on Industrial Electronics**, IEEE, v. 59, n. 11, p. 4409–4420, 2011.
- CISCO. **Cisco Visual Networking Index: Global Mobile Data Traffic Forecast Update, 2017–2022**. Fev. 2019. White Paper. Disponível em: <<https://www.cisco.com/c/en/us/solutions/collateral/service-provider/visual-networking-index-vni/white-paper-c11-738429.pdf>>.
- DIN, I. U.; GUIZANI, M.; HASSAN, S.; KIM, B.-S.; KHAN, M. K.; ATIQUZZAMAN, M.; AHMED, S. H. The internet of things: A review of enabled technologies and future challenges. **IEEE Access**, IEEE, v. 7, p. 7606–7640, 2018.
- DUAN, Y.; LAM, K. Y.; LEE, V. C.; NIE, W.; LIU, K.; LI, H.; XUE, C. J. Data Rate Fingerprinting: A WLAN-Based Indoor Positioning Technique for Passive Localization. **IEEE Sensors Journal**, v. 19, n. 15, p. 6517–6529, 2019. ISSN 1530437X.
- ELFADIL, O. M.; ALKASIM, Y. M.; ABBAS, E. B. Indoor navigation algorithm for mobile robot using wireless sensor networks. **Proceedings - 2017 International Conference on Communication, Control, Computing and Electronics Engineering, ICCCEE 2017**, p. 3–7, 2017.
- EYNG, A. C.; RAYEL, O. K.; OROSKI, E.; REBELATTO, J. L. Kalman Filtering-Aided Hybrid Indoor Positioning System with Fingerprinting and Multilateration. In: **Proc. IEEE Veh. Technol. Conf., VTC Spring'2020**. 2020. p. 1–5.
- FANG, X.; NAN, L.; JIANG, Z.; CHEN, L. Multi-channel fingerprint localisation algorithm for wireless sensor network in multipath environment. **IET Communications**, v. 11, n. 15, p. 2253–2260, 2017. ISSN 17518628.
- FARAGHER, R.; HARLE, R. Location fingerprinting with bluetooth low energy beacons. **IEEE Journal on Selected Areas in Communications**, IEEE, v. 33, n. 11, p. 2418–2428, 2015. ISSN 07338716.

- GAO, J.; HARRIS, C. Some remarks on Kalman filters for the multisensor fusion. **Inf. Fusion**, v. 3, n. 3, p. 191 – 201, 2002. ISSN 1566-2535.
- GIOVANELLI, D.; FARELLA, E.; FONTANELLI, D.; MACII, D. Bluetooth-based Indoor Positioning through ToF and RSSI Data Fusion. In: IEEE. **2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN)**. 2018. p. 1–8.
- GOLDSMITH, A. **Wireless Communications**. Cambridge University Press, 2005.
- GOROVYI, I.; ROENKO, A.; PITERTSEV, A.; CHERVONYAK, I.; VOVK, V. Real-time system for indoor user localization and navigation using bluetooth beacons. In: IEEE. **2017 IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON)**. 2017. p. 1025–1030. ISSN 9781509030064.
- HAN, G.; JIANG, J.; ZHANG, C.; DUONG, T. Q.; GUIZANI, M.; KARAGIANNIDIS, G. K. A Survey on Mobile Anchor Node Assisted Localization in Wireless Sensor Networks. **IEEE Communications Surveys and Tutorials**, v. 18, n. 3, p. 2220–2243, 2016. ISSN 1553877X.
- HARA, S.; ANZAI, D. Experimental Performance Comparison of RSSI- and TDOA-Based Location Estimation Methods. In: **VTC Spring 2008 - IEEE Veh. Technol. Conf.** 2008. p. 2651–2655.
- HE, S.; CHAN, S. H. Wi-Fi fingerprint-based indoor positioning: Recent advances and comparisons. **IEEE Communications Surveys and Tutorials**, IEEE, v. 18, n. 1, p. 466–490, 2016. ISSN 1553877X.
- HE, S.; CHAN, S. H. INTRI: Contour-Based Trilateration for Indoor Fingerprint-Based Localization. **IEEE Transactions on Mobile Computing**, IEEE, v. 16, n. 6, p. 1676–1690, 2017. ISSN 15361233.
- HOANG, M. T.; ZHU, Y.; YUEN, B.; REESE, T.; DONG, X.; LU, T.; WESTENDORP, R.; XIE, M. A soft range limited k-nearest neighbors algorithm for indoor localization enhancement. **IEEE Sensors Journal**, IEEE, v. 18, n. 24, p. 10208–10216, 2018.
- HUANG, C.-H.; LEE, L.-H.; HO, C. C.; WU, L.-L.; LAI, Z.-H. Real-time RFID indoor positioning system based on Kalman-filter drift removal and Heron-bilateration location estimation. **IEEE Transactions on Instrumentation and Measurement**, IEEE, v. 64, n. 3, p. 728–739, 2014.
- JEON, K. E.; SHE, J.; SOONSAWAD, P.; NG, P. C. BLE beacons for Internet of Things applications: Survey, challenges, and opportunities. **IEEE Internet of Things Journal**, IEEE, v. 5, n. 2, p. 811–828, 2018.
- KALMAN, R. E. A New Approach to Linear Filtering and Prediction Problems. **J. Basic Eng.**, v. 82, n. 1, p. 35–45, 03 1960. ISSN 0098-2202.
- KO, N. Y.; KIM, T. G. Comparison of Kalman filter and particle filter used for localization of an underwater vehicle. In: IEEE. **2012 9th international conference on ubiquitous robots and ambient intelligence (URAI)**. 2012. p. 350–352.
- KOO, J.; CHA, H. Localizing WiFi access points using signal strength. **IEEE Communications Letters**, IEEE, v. 15, n. 2, p. 187–189, 2011. ISSN 10897798.

- LAARAIEDH, M.; AVRILLON, S.; UGUEN, B. Hybrid data fusion techniques for localization in uwb networks. In: IEEE. **2009 6th Workshop on Positioning, Navigation and Communication**. 2009. p. 51–57.
- LAM, C. H.; NG, P. C.; SHE, J. Improved Distance Estimation with BLE Beacon using Kalman Filter and SVM. In: IEEE. **2018 IEEE International Conference on Communications (ICC)**. 2018. p. 1–6.
- LI, Q.; LI, R.; JI, K.; DAI, W. Kalman filter and its application. In: IEEE. **2015 8th International Conference on Intelligent Networks and Intelligent Systems (ICINIS)**. 2015. p. 74–77.
- LI, Q.; LI, W.; SUN, W.; LI, J.; LIU, Z. Fingerprint and assistant nodes based Wi-Fi localization in complex indoor environment. **IEEE Access**, IEEE, v. 4, p. 2993–3004, 2016. ISSN 21693536.
- LUO, R. C.; HSIAO, T. J. Dynamic Wireless Indoor Localization Incorporating With an Autonomous Mobile Robot Based on an Adaptive Signal Model Fingerprinting Approach. **IEEE Transactions on Industrial Electronics**, IEEE, v. 66, n. 3, p. 1940–1951, 2018.
- MARI, S. K.; KIONG, L. C.; LOONG, H. K. A hybrid trilateration and fingerprinting approach for indoor localization based on wifi. In: IEEE. **2018 Fourth International Conference on Advances in Computing, Communication & Automation (ICACCA)**. 2018. p. 1–6.
- MATEEN, H.; BASAR, R.; AHMED, A. U.; AHMAD, M. Y. Localization of wireless capsule endoscope: A systematic review. **IEEE Sensors Journal**, IEEE, v. 17, n. 5, p. 1197–1206, 2017.
- MIRANDA, J.; ABRISHAMBAF, R.; GOMES, T.; GONÇALVES, P.; CABRAL, J.; TAVARES, A.; MONTEIRO, J. Path loss exponent analysis in wireless sensor networks: Experimental evaluation. In: IEEE. **2013 11th IEEE International Conference on Industrial Informatics (INDIN)**. 2013. p. 54–58.
- Obeidat, H.; Alabdullah, A. A. S.; Ali, N. T.; Asif, R.; Obeidat, O.; Bin-Melha, M. S. A.; Shuaieb, W.; Abd-Alhameed, R. A.; Excell, P. Local Average Signal Strength Estimation for Indoor Multipath Propagation. **IEEE Access**, v. 7, p. 75166–75176, 2019.
- PAHLAVAN, K.; KRISHNAMURTHY, P.; GENG, Y. Localization challenges for the emergence of the smart world. **IEEE Access**, IEEE, v. 3, p. 3058–3067, 2015.
- PALATTELLA, M. R.; DOHLER, M.; GRIECO, A.; RIZZO, G.; TORSNER, J.; ENGEL, T.; LADID, L. Internet of Things in the 5G Era: Enablers, Architecture, and Business Models. **IEEE Journal on Selected Areas in Communications**, IEEE, v. 34, n. 3, p. 510–527, 2016. ISSN 07338716.
- PATERNA, V. C.; AUGÉ, A. C.; ASPAS, J. P.; BULLONES, M. A. P. A bluetooth low energy indoor positioning system with channel diversity, weighted trilateration and kalman filtering. **Sensors (Switzerland)**, v. 17, n. 12, 2017. ISSN 14248220.
- PERERA, C.; LIU, C. H.; JAYAWARDENA, S.; CHEN, M. A Survey on Internet of Things from Industrial Market Perspective. **IEEE Access**, IEEE, v. 2, p. 1660–1679, 2015. ISSN 21693536.

PERERA, C.; ZASLAVSKY, A.; CHRISTEN, P.; GEORGAKOPOULOS, D. Context aware computing for the internet of things: A survey. **IEEE Communications Surveys and Tutorials**, IEEE, v. 16, n. 1, p. 414–454, 2014. ISSN 1553877X.

SADOWSKI, S.; SPACHOS, P. RSSI-based indoor localization with the internet of things. **IEEE Access**, v. 6, p. 30149–30161, 2018.

Song, Q.; Guo, S.; Liu, X.; Yang, Y. CSI Amplitude Fingerprinting-Based NB-IoT Indoor Localization. **IEEE Internet of Things Journal**, v. 5, n. 3, p. 1494–1504, June 2018.

SUN, Y.; MENG, W.; LI, C.; ZHAO, N.; ZHAO, K.; ZHANG, N. Human localization using multi-source heterogeneous data in indoor environments. **IEEE Access**, IEEE, v. 5, p. 812–822, 2017.

TALVITIE, J.; RENFORS, M.; LOHAN, E. S. Distance-based interpolation and extrapolation methods for RSS-based localization with indoor wireless signals. **IEEE transactions on vehicular technology**, IEEE, v. 64, n. 4, p. 1340–1353, 2015.

WU, K.; XIAO, J.; YI, Y.; CHEN, D.; LUO, X.; NI, L. M. Csi-based indoor localization. **IEEE Transactions on Parallel and Distributed Systems**, IEEE, v. 24, n. 7, p. 1300–1309, 2012.

YADAV, R. K.; BHATTARAI, B.; GANG, H.-S.; PYUN, J.-Y. Trusted K Nearest Bayesian Estimation for Indoor Positioning System. **IEEE Access**, v. 7, p. 51484–51498, 2019.

YASSIN, A.; NASSER, Y.; AWAD, M.; AL-DUBAI, A.; LIU, R.; YUEN, C.; RAULEFS, R.; ABOUTANIOS, E. Recent Advances in Indoor Localization: A Survey on Theoretical Approaches and Applications. **IEEE Communications Surveys and Tutorials**, IEEE, v. 19, n. 2, p. 1327–1346, 2017. ISSN 1553877X.

ZAFARI, F.; GKELIAS, A.; LEUNG, K. K. A survey of indoor localization systems and technologies. **IEEE Communications Surveys & Tutorials**, IEEE, 2019.

ZAFARI, F.; PAPAPANAGIOTOU, I.; CHRISTIDIS, K. Microlocation for internet-of-things-equipped smart buildings. **IEEE Internet of Things Journal**, IEEE, v. 3, n. 1, p. 96–112, 2015.

ZANELLA, A.; BARDELLA, A. RSS-based ranging by multichannel RSS averaging. **IEEE Wireless Commun. Lett.**, IEEE, v. 3, n. 1, p. 10–13, 2014. ISSN 21622345.