

Uma Abordagem para Localização em Ambientes Internos baseada em Impressão Digital do sinal de Wi-Fi e Aprendizagem de Máquina

Fábio de Albuquerque Silva



CENTRO DE INFORMÁTICA
UNIVERSIDADE FEDERAL DA PARAÍBA

João Pessoa
2020

Fábio de Albuquerque Silva

Uma Abordagem para Localização em Ambientes Internos baseada em Impressão Digital do sinal de Wi-Fi e Aprendizagem de Máquina

Dissertação apresentada ao Mestrado em Informática do Centro de Informática, da Universidade Federal da Paraíba, como requisito para a obtenção do grau de Mestre em Informática.

Prof. Orientador: Dr. Rostand Edson Oliveira Costa

João Pessoa
2020

Catálogo na publicação
Seção de Catalogação e Classificação

S586a Silva, Fabio de Albuquerque.

Uma abordagem para localização em ambientes internos baseada em impressão digital do sinal de Wi-Fi e aprendizagem de máquina / Fabio de Albuquerque Silva. - João Pessoa, 2020.

71 f. : il.

Orientação: Rostand Edson Oliveira Costa.
Dissertação (Mestrado) - UFPB/CI.

1. Informática. 2. Sinal de Wi-Fi. 3. Aprendizagem de máquina. 4. Serviço de localização. I. Costa, Rostand Edson Oliveira. II. Título.

UFPB/BC

CDU 004(043)



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA



Ata da Sessão Pública de Defesa de Dissertação de Mestrado de Fábio de Albuquerque Silva, candidato ao título de Mestre em Informática na Área de Sistemas de Computação, realizada em 29 de julho de 2020.

1 Aos vinte e nove dias do mês de julho do ano de dois mil e vinte, às quatorze horas e trinta
2 minutos, por meio de videoconferência, reuniram-se os membros da Banca Examinadora
3 constituída para julgar o trabalho do sr. Fábio de Albuquerque Silva, vinculado a esta
4 Universidade sob a matrícula nº 20181000626, candidato ao grau de Mestre em Informática,
5 na área de “Sistemas de Computação”, na linha de pesquisa “Computação Distribuída”, do
6 Programa de Pós-Graduação em Informática, da Universidade Federal da Paraíba. A
7 comissão examinadora foi composta pelos professores: Rostand Edson Oliveira Costa
8 (PPGI-UFPB) Orientador e Presidente da Banca, Thaís Gaudencio do Rêgo (PPGI-UFPB),
9 Examinadora Interna, Tiago Pereira do Nascimento (PPGI-UFPB), Examinador Interno,
10 Francisco Dantas Nobre Neto (IFPB), Examinador Externo à Instituição. Dando início aos
11 trabalhos, o Presidente da Banca cumprimentou os presentes, comunicou aos mesmos a
12 finalidade da reunião e passou a palavra ao candidato para que o mesmo fizesse a
13 exposição oral do trabalho de dissertação intitulado: “Uma Abordagem para Localização em
14 Ambientes Internos baseada em Impressão Digital do sinal de Wi-Fi e Aprendizagem de
15 Máquina”. Concluída a exposição, o candidato foi arguido pela Banca Examinadora que
16 emitiu o seguinte parecer: “**aprovado**”. Do ocorrido, eu, Ruy Alberto Pisani Altafim,
17 Coordenador do Programa de Pós-Graduação em Informática, lavrei a presente ata que vai
18 assinada por mim e pelos membros da banca examinadora. João Pessoa, 29 de julho de
19 2020.


Prof. Dr. Ruy Alberto Pisani Altafim

Prof. Rostand Edson Oliveira Costa
Orientador (PPGI-UFPB)

Prof. Thaís Gaudêncio do Rego
Examinadora Interna (PPGI-UFPB)

Prof. Tiago Pereira do Nascimento
Examinador Interno (PPGI-UFPB)

Prof. Francisco Dantas Nobre Neto
Examinador Externo à Instituição (IFPB)


Thaís Gaudêncio do Rego


Francisco Dantas Nobre Neto

*Dedico este trabalho aos professores do
Centro de Informática da UFPB que, com seu
exemplo de dedicação à educação superior e à
pesquisa científica, conseguem formar
excelentes profissionais e moldar
pesquisadores aptos a enfrentar os grandes
desafios que a humanidade enfrenta neste
momento.*

AGRADECIMENTOS

Agradeço aos meus familiares, em especial aos meus pais e esposa, a paciência e a compreensão nos momentos em que não pude estar presente, nem de corpo nem de alma, para conseguir concluir as atividades de final de período e a escrita deste trabalho de pesquisa.

Agradeço também ao meu Orientador, Prof. Dr. Rostand Edson Oliveira Costa, pela dedicação em me mostrar como uma pesquisa deve ser conduzida, abordando desde o levantamento bibliográfico, passando pela necessidade de um método estatístico e culminando nos achados e conclusões. Ainda, pela paciência em ver os prazos se esgotando e as atividades ainda por concluir. No final, deu tudo certo.

RESUMO

Os serviços baseados em localização interna (*Indoor Location Based Services – ILBS*) vêm atraindo muita atenção nos últimos anos por causa de seu potencial social e comercial, com um valor estimado de mercado de US\$ 10 bilhões em 2020. Como os sinais de satélite (GPS) e celular (GSM) não conseguem penetrar bem em ambientes internos, com paredes externas e obstáculos internos, o uso do sinal do Wi-Fi, para localização interna, ganhou muita importância, tanto na área acadêmica quanto na área industrial devido à grande penetração de LANs sem fio (WLANs) e dispositivos móveis habilitados para Wi-Fi. Em particular, a técnica baseada em impressão digital da intensidade do sinal recebido (*Received Signal Strength fingerprint – RSS fingerprint*) tem atraído muita atenção, por amenizar o problema de *multipath* (múltiplos caminhos percorridos pelo sinal entre o emissor e receptor) agravado pela existência de paredes e objetos em ambientes internos. Diante deste cenário, motivados pela busca de um ILBS eficiente e eficaz, propomos neste trabalho o uso combinado da impressão digital do Wi-Fi (*RSS fingerprint*) com algoritmos de Aprendizagem de Máquina, com o objetivo de identificar qual a abordagem mais adequada para localização em ambientes internos e uso racional de recursos em dispositivos móveis, considerando o erro médio de estimativa de localização próximo de 1 (um) metro. Ao contrário de outros trabalhos relacionados, que concentram esforços apenas em uma das fases do *RSS fingerprint*, nossa pesquisa buscou melhorias tanto na fase de construção do mapa de sinais do ambiente (fase *offline*) quanto na fase de localização do dispositivo móvel no ambiente interno (fase *online*). Neste sentido, foi realizado um projeto de experimentos com dois cenários (2D e 3D) e os resultados obtidos apresentaram erro médio mínimo de 2m no Experimento 2D, com apenas 5 medições na fase *offline*, e 1,08m no Experimento 3D, utilizando uma Rede Neural e informações da posição anterior na fase *online* de localização.

Palavras-chave: Serviços baseados em localização interna, Impressão digital do sinal de Wi-Fi, Aprendizagem de Máquina.

ABSTRACT

Indoor Location Based Services (ILBS) have attracted a lot of attention in recent years because of their social and commercial potential, with an estimated market value of \$10 billion by 2020. As satellite (GPS) and cellular (GSM) can't penetrate indoors, with external walls and internal obstacles, the use of the Wi-Fi signal, for internal location, has gained a lot of importance in both academic and industrial areas due to the large penetration of wireless LANs (WLANs) and Wi-Fi-enabled mobile devices. In particular, the fingerprint of the received signal strength (RSS fingerprint) has attracted a great deal of attention by alleviating the multipath problem (multiple paths traveled by the signal between the sender and receiver) aggravated by the existence of walls and indoor objects. Given this scenario, motivated by the search for an efficient and effective ILBS, we propose the combined use of Wi-Fi fingerprint with Machine Learning algorithms in order to identify the approach more suitable for indoor localization and rational use of resources in mobile devices, considering the average error estimate of about 1 (one) meter. Unlike other related works, which concentrate efforts only on one of the phases of the RSS fingerprint, our research sought improvements both in the construction phase of the environment signal map (offline phase) and in the phase of locating the mobile device in the indoor environment (online phase). In this sense, one Design of Experiments was carried out with two scenarios (2D and 3D) and the results obtained showed a minimum average error of 2m in the 2D experiment, with only 5 measurements in the offline phase, and 1.08m in the 3D experiment, using a Neural Network and information from the previous position in the online location phase.

Key-words: Indoor Location Based Services, Wi-Fi fingerprint, Machine Learning.

LISTA DE FIGURAS

Figura 1: Sinais utilizados em sistemas de posicionamento

Figura 2: Técnicas de localização

Figura 3: Fases offline e online do RSS fingerprint

Figura 4: Trabalhos relacionados à técnica RSS fingerprint

Figura 5: Diagrama de blocos da metodologia utilizada

Figura 6: Distribuição dos pontos de acesso – PAs (APn) e pontos de referência – PRs (centro dos quadrados marcados com X) - Experimento 2D

Figura 7: Distribuição dos pontos de acesso – PAs (APn) e pontos de referência – PRs (centro dos quadrados marcados com X) - Experimento 3D

Figura 8: Recorte do mapa RSS obtido para os pontos de referência (PRs) medidos na fase offline - Experimento 2D. Figura 9: Distribuição dos pontos de interesse (PIs) e trajetória percorrida para medição dos vetores de RSS - Experimento 2D.

Figura 9: Distribuição dos pontos de interesse (PIs) e trajetória percorrida para medição dos vetores de RSS - Experimento 2D

Figura 10: Distribuição dos pontos de interesse (PIs) e trajetória percorrida para medição dos vetores de RSS - Experimento 3D

Figura 11: Identificação das informações apresentadas nas tabelas de resultados

Figura 12: Efeitos principais e das interações no Bloco nº1 do Experimento 2D

Figura 13: Efeitos principais e das interações no Bloco nº2 do Experimento 2D

Figura 14: Efeitos principais e das interações no Bloco nº3 do Experimento 2D

Figura 15: Efeitos principais e das interações no Bloco nº4 do Experimento 2D

Figura 16: Efeitos principais e das interações do Experimento 3D

Figura 17: Mapa de calor para os tratamentos realizados no DoE

Figura 18: Variação dos resultados obtidos em cada experimento

LISTA DE TABELAS

Tabela 1: Fatores e níveis para o Bloco nº1 do Experimento 2D

Tabela 2: Fatores e níveis para o Bloco nº2 do Experimento 2D

Tabela 3: Fatores e níveis para o Bloco nº3 do Experimento 2D

Tabela 4: Fatores e níveis para o Bloco nº4 do Experimento 2D

Tabela 5: Fatores e níveis para o Experimento 3D

Tabela 6: Parâmetros de execução utilizados

Tabela 7: Fatores, níveis e efeitos dos Fatores (A, B e C) para o Bloco nº1 do Experimento 2D

Tabela 8: Fatores, níveis e efeitos dos Fatores (A, B e C) para o Bloco nº2 do Experimento 2D

Tabela 9: Fatores, níveis e efeitos dos Fatores (A, B e C) para o Bloco nº3 do Experimento 2D

Tabela 10: Fatores, níveis e efeitos dos Fatores (A, B e C) para o Bloco nº4 do Experimento 2D

Tabela 11: Fatores, níveis e efeitos dos Fatores (A, B e C) para o Experimento 3D

Tabela 12: Erro médio mínimo e máximo associado ao eixo Z do Experimento 3D

LISTA DE ABREVIATURAS

AP	-	Access Point
AOA	-	Angle of Arrival
BLE	-	Bluetooth Low Energy
CNN	-	Convolutional Neural Network
DBN	-	Deep Belief Networks
DL	-	Deep Learning
GPR	-	Gaussian Process Regression
GPS	-	Global Positioning System
GSM	-	Global System for Mobile Communications
IDW	-	Inverse Distance Weighted
ILBS	-	Indoor Location Based Services
IMU	-	Inertial Measurement Unit
IPS	-	Indoor Positioning System
IPIN	-	International Conference on Indoor Positioning and Indoor Navigation
IoT	-	Internet of Things
KNN	-	K-Nearest Neighbor
LDA	-	Linear Discriminant Analysis
LoS	-	Line-Of-Sight
LBS	-	Location Based Services
MLP	-	Multilayer Perceptron
MWMF	-	Multi-Wall Multi-Floor
NIST	-	National Institute of Standards and Technology
NLoS	-	No-Line-Of-Sight
PA	-	Ponto de Acesso
PI	-	Ponto de Interesse
PR	-	Ponto de Referência
PDF	-	Probability Distribution Function
RF	-	Random Forest
RFB	-	Ranked Based Fingerprinting
RFID	-	Radio Frequency Identification
RSS	-	Received Signal Strength
RMSE	-	Root Mean Square Error
SVM	-	Support Vector Machine
TDOA	-	Time Difference of Arrival
TOA	-	Time of Arrival
UPINLBS	-	Ubiquitous Positioning, Indoor Navigation and Location-Based Service

SUMÁRIO

INTRODUÇÃO	12
Problema	14
Objetivo geral	15
Objetivos específicos	15
Estrutura da dissertação	16
FUNDAMENTAÇÃO TEÓRICA	17
Técnicas para Obtenção da Localização	17
Modelos de propagação de sinais de rádio	19
Posicionamento Interno por RSS fingerprint	20
Métodos para Obtenção da Localização Interna	22
TRABALHOS RELACIONADOS	25
Fase Offline: Mapeamento	25
Fase Online: Localização	27
METODOLOGIA	34
Abordagem utilizada para localização interna	35
Configuração do Ambiente Interno	35
Execução dos Experimentos	38
Obtenção do Mapa RSS (fase offline)	38
Estimação da Posição (fase online)	39
Métrica de interesse	41
Projeto de Experimentos	42
Experimento 2D	43
Experimento 3D	45
Parâmetros de execução	46
APRESENTAÇÃO E ANÁLISE DOS RESULTADOS	48
Resultados	48
Experimento 2D	49
Experimento 3D	55
CONCLUSÕES E TRABALHOS FUTUROS	59
APÊNDICE A - Análise descritiva do mapa RSS (experimento 2D)	69

1. INTRODUÇÃO

Atualmente, disponibilizar e usar informações sobre a localização tornou-se um fator chave em sistemas e aplicativos, principalmente, devido à proliferação de dispositivos móveis como *tablets*, *smartphones* e *smartwatches*, e ao surgimento de diversos serviços baseados em localização (*Location Based Services* – LBS) [7].

Em ambientes externos, a posição de um dispositivo móvel é obtida com relativa precisão graças ao sistema de posicionamento global (*Global Positioning System* – GPS) [8] ou, em menor precisão, através dos sistemas globais para comunicações móveis (*Global System for Mobile Communications* – GSM) [9]. No entanto, o problema do GPS e do GSM é que, em ambientes internos (*indoor*), os sinais de satélite, principalmente, e da rede de telefonia celular, conseguem penetrar, mas não indicados para localização interna devido a fraca intensidade e/ou intermitência do sinal.

Como os sinais de GPS e GSM não conseguem penetrar bem em ambientes internos, com paredes externas e obstáculos internos, vários outros sinais foram investigados para fins de localização interna [55]. Como pode ser visto na Figura 1, esses sinais incluem: Wi-Fi, Bluetooth (*Bluetooth Low Energy* – BLE), rádio FM, identificação por radiofrequência (*Radio Frequency Identification* – RFID), ultrassom ou som, luz, campo magnético (medido através do *Inertial Measurement Unit* - IMU - disponível em *smartphones*), etc [3]. Dentre esses, o uso do sinal do Wi-Fi tem atraído atenção crescente em ambos os meios, acadêmico e industrial, devido à grande proliferação das redes sem fio e dispositivos móveis habilitados para Wi-Fi.




Figura 1: Sinais utilizados em sistemas de posicionamento: Fonte: Adaptado de [22].

Devido ao crescimento da Internet, pontos de acesso Wi-Fi podem ser encontrados em quase toda parte, em campi universitários, em hotéis e *shopping centers*. Essa ampla infraestrutura disponível oferece a possibilidade de localizar dispositivos móveis de maneira ubíqua e econômica.

Assim, os sistemas de localização baseados em Wi-Fi tornaram-se uma alternativa de posicionamento, operacionalmente viável, para ambientes internos, onde os sinais de GPS e GSM podem ser fracos, devido à atenuação de sinal ou ao efeito de sombreamento, que ocorrem quando o sinal é obstruído por prédios, montanhas ou até mesmo pela vegetação.

Essa abordagem, com base no sinal do Wi-Fi, além do bom desempenho em ambientes internos, quando em comparação com outras tecnologias de posicionamento (por exemplo, GPS, GSM e *Bluetooth*), também tem a vantagem de ser baseada em uma infraestrutura existente, o que não requer a instalação de *software* ou *hardware* adicional. De fato, a rede local sem fio (do inglês, *Wireless Local Area Networks* – WLAN) pode ser usada como uma tecnologia de localização promissora, não apenas devido à infraestrutura onipresente, mas também devido à facilidade de coletar a intensidade do sinal recebido (do inglês, *Received Signal Strength* – RSS) em dispositivos móveis habilitados para Wi-Fi [21].

O posicionamento e navegação em ambientes internos (*Indoor Positioning System – IPS*) [10], para dispositivos móveis, é um mercado com tamanho estimado em 10 bilhões de dólares em 2020 [3]. Mecanismos confiáveis, amigáveis e precisos para posicionamento e navegação *indoor* são de muita utilidade e podem alavancar o surgimento de novas aplicações e, conseqüentemente, de novas oportunidades de negócios em uma grande diversidade de cenários, além de ser primordiais para a realização da visão da Internet das Coisas (*Internet of Things – IoT*) [1].

Dentre as possibilidades de aplicação que os serviços baseados em localização *indoor* (*Indoor Location Based Services - ILBS*) podem gerar, é possível destacar:

- Monitoramento de crianças ou idosos em casa ou em grandes centros comerciais;
- Localização de dispositivos ou equipamentos em empresas ou instituições, como hospitais;
- Direcionamento de usuários para a loja de destino em um *shopping* ou prédio comercial;
- Orientação de convidados em feiras comerciais até o estande de interesse;
- Navegação dentro de estações de metrô complexas, com várias entradas e saídas ou com diversos pavimentos;
- Notificação sobre promoções com base na proximidade de uma loja, tipicamente em aplicações de páginas amarelas móveis;
- Localização de chamadas de emergência, como 192 (SAMU) e 193 (Bombeiro).

1.1. Problema

Apesar das inúmeras aplicações para os ILBS, os ambientes internos são bem complexos, caracterizados por não ter linha de visão (do inglês, *Line-of-Sight – LoS*) dos objetos de referência, presença de obstáculos, flutuação de sinal ou ruído (efeitos de múltiplos caminhos, nível de umidade relativa, movimento de pessoas e portas abertas/fechadas [3]), mudanças ambientais (por exemplo, adição ou remoção de paredes/divisórias ou mesmo pontos de acesso), etc.

Além da complexidade inerente aos ambientes internos, os ILBS exigem métodos avançados de processamento de sinais, junção de várias abordagens, métodos, técnicas e algoritmos inteligentes de fusão de informações, para explorar os sinais provenientes das redes locais sem fio. Devido a estes fatores, a alta precisão de localização (com erro médio dentro da faixa de 1 metro), oferecido por um ILBS, ainda é esperada, para que novas aplicações e oportunidades de negócios, associadas à Internet das Coisas, se popularizem.

1.2. Objetivo geral

Diante deste cenário, o objetivo geral deste trabalho de pesquisa é: identificar qual a abordagem mais adequada para prover um serviço baseado em localização para dispositivos móveis em ambientes internos (ILBS), com erro médio dentro da faixa de 1 metro, utilizando a técnica de mapeamento das impressões digitais (RSS *fingerprint*) dos sinais de Wi-Fi, no ambiente interno de interesse, e algoritmos de aprendizagem de máquina.

Ao contrário de outros trabalhos relacionados, que concentram esforços apenas em uma das fases da técnica RSS *fingerprint*, nossa pesquisa traz contribuições, tanto para a fase de construção do mapa de sinais do ambiente (fase *offline*), quanto para a fase de localização do dispositivo móvel no ambiente interno (fase *online*).

1.3. Objetivos específicos

Desta forma, para alcançar o objetivo geral deste trabalho, foram identificados os seguintes objetivos específicos, subprodutos a serem obtidos através da execução do mesmo:

- Obter uma abordagem simplificada para coleta do banco de dados de impressões digitais do Wi-Fi, na fase *offline* de mapeamento dos sinais de rádio em ambientes internos;
- Identificar os fatores de maior influência na minimização do erro médio, para localização interna de dispositivos móveis, em ambas as fases *offline* e *online*; e,
- Identificar os algoritmos de aprendizagem de máquina mais eficientes e eficazes, para localização interna de dispositivos móveis na fase *online*.

1.4. Estrutura da dissertação

Na Seção 2, são apresentados os conceitos básicos empregados na localização em ambientes externos ou internos, e também uma visão geral das abordagens, métodos e técnicas comumente adotadas para fins de posicionamento interno. A Seção 3 apresenta uma revisão da literatura, com ênfase na discussão de trabalhos que utilizam o método de impressão digital do Wi-Fi, para localização em ambientes internos. A Seção 4 contém o detalhamento do projeto de experimentos, composto de cenários para: identificação de um mecanismo simplificado para coleta do banco de dados de impressões digitais do Wi-Fi (fase *offline*); e, análise dos fatores principais e algoritmos de aprendizagem de máquina mais eficientes e eficazes para determinar a localização de dispositivos móveis em ambientes internos (fase *online*), seja em ambientes de um único pavimento (experimento 2D - em duas dimensões - eixos X e Y) ou com vários andares (experimento 3D - considerando os 3 eixos: X, Y e Z). A Seção 5 apresenta os resultados obtidos pelo projeto de experimentos realizado e a análise dos resultados. Na Seção 6, são apresentadas as conclusões da pesquisa e sugestões de trabalhos futuros neste campo de pesquisa promissor.

2. FUNDAMENTAÇÃO TEÓRICA

Nesta seção, são apresentados os conceitos básicos empregados na localização em ambientes externos ou internos, e também, uma visão geral dos métodos e técnicas comumente adotadas para fins de posicionamento interno.

2.1. Técnicas para Obtenção da Localização

As técnicas principais para obtenção da localização de dispositivos móveis estão ilustradas na Figura 2 e podem ser categorizadas da seguinte forma [21]:




Figura 2: Técnicas de localização: Proximidade (a), Trilateração (b), Triangulação (c), Correspondência de impressões digitais (d). Fonte: [21].

a) Proximidade: A localização do dispositivo móvel (*Mobile System* - MS) é estimada pela localização (x_i, y_i) conhecida do transmissor (*Base Station* - BS_i) mais próximo ($d_i < d_{i+1}, d_{i+2}$), como o ponto de acesso (PA) ou dispositivo BLE mais próximo. Uma limitação aqui é a precisão da localização, que depende da densidade dos dispositivos de transmissão existentes.

b) Tempo de Chegada (*Time of Arrival* – TOA): É usado quando um sinal é transmitido pelo dispositivo móvel e recebido em múltiplos PAs para estimar as distâncias, com base na velocidade de propagação do sinal de rádio. Cada distância estimada define um círculo, no qual o dispositivo móvel pode estar. Na localização em 2D, o posicionamento pode ser deduzido a partir da interseção de pelo menos três círculos. Nesse caso, a técnica é

conhecida como trilateração; o termo multilateração se aplica quando mais PAs são utilizados. O problema com essa técnica, é a necessidade de sincronização de relógio precisa entre os PAs. Diferença de Hora de Chegada (*Time Difference of Arrival* – TDOA) pode ser usada para resolver este problema. Tipicamente, um dos PAs é tomado como referência e usado para obter medições de TDOA dos PAs restantes.

c) Ângulo de chegada (*Angle of Arrival* – AOA): Com o auxílio de antenas diretivas ou matrizes de antena, a técnica AOA usa relações geométricas simples, para estimar a localização do dispositivo móvel como sendo a interseção das linhas, formadas pela medição dos ângulos de chegada dos sinais de rádio trocados entre o dispositivo móvel e os PAs. Essa técnica é conhecida como triangulação e necessita, no mínimo, de dois PAs para determinar a localização 2D.

d) Correspondência de impressão digital (*Fingerprint matching*): As leituras de RSS no dispositivo móvel podem ser usadas para estimar as distâncias dos PAs através de modelos matemáticos (conhecidos como modelos de propagação de sinais de rádio), que descrevem a atenuação do sinal como uma função logarítmica da distância. Essa abordagem é afetada pela imprecisão inerente dos modelos de propagação, bem como pela ausência de linha de visão (*No-Line-Of-Sight* – NLoS) e múltiplos caminhos (*multipath*), devido à reflexão e difração do sinal em obstáculos existentes em ambientes internos complexos, levando à imprecisão na localização estimada.

A correspondência de impressão digital (*RSS fingerprint*), também conhecida como Análise de Cena, trata as limitações acima juntando RSSs com as informações de localização associadas e armazenando-as juntas, em um banco de dados (fase *offline*), comumente conhecido como mapa de rádio (*radiomap*). A localização pode ser posteriormente determinada (fase *online*), a partir da melhor correspondência entre o RSS medido pelo dispositivo móvel e as impressões digitais no mapa de rádio, usando métodos/algoritmos de reconhecimento de padrões.

Devido à facilidade de implantação, além da ampla rede existente, e à adequação ao ambiente interno, o posicionamento *indoor*, baseado em Wi-Fi, vem sendo bastante explorado nas últimas décadas. As principais abordagens empregadas para o posicionamento em

ambientes internos, através do uso do sinal de Wi-Fi, utilizam modelos de propagação de sinais de rádio e *RSS fingerprint*.

2.2. Modelos de propagação de sinais de rádio

Modelos de propagação descrevem o RSS como uma função da distância do PA. Uma suposição padrão é que o sinal atenua de forma logarítmica, dependendo da distância entre o PA e o dispositivo móvel a ser localizado (dispositivo alvo). Além desta suposição, um modelo de propagação possui vários parâmetros, que devem ser determinados antes da fase de posicionamento. Um modelo comumente usado [22] é:

$$RSS = A - 10n \log_{10} \|x - m\| + w \quad (1)$$

onde A é a potência de transmissão, n é um parâmetro que representa as propriedades de atenuação do ambiente, m é a localização do PA, x é a localização do dispositivo móvel e w é uma variável Gaussiana aleatória, de média zero, usada para modelar o efeito de sombreamento.

Diversas técnicas baseadas em modelos de propagação foram propostas para o posicionamento em ambientes internos. Primeiramente, é utilizada uma fórmula matemática para estimar a distância entre o emissor do sinal e o dispositivo móvel receptor. Em seguida, é aplicada a técnica de triangulação ou trilateração - quando não se utiliza informação sobre o ângulo de recepção do sinal de rádio, para estimar a localização do dispositivo móvel, usando pelo menos 3 (três) emissores distintos. Entretanto, abordagens baseadas em modelos de propagação, requerem um modelo de sensor explícito, para prever a propagação dos sinais entre o emissor e o receptor [1]. Infelizmente, é impossível encontrar um modelo universal para caracterizar as propagações de sinal em ambientes internos, devido a sombreamento e efeitos de atenuação, causados por *multipath* - múltiplos caminhos entre o emissor e o receptor, o que degrada consideravelmente a precisão destes modelos.

2.3. Posicionamento Interno por RSS *fingerprint*

Uma alternativa aos modelos de propagação de rádio, e sua ideia de conversão explícita da medição do RSS em distância, é a comparação das medições do dispositivo alvo com os dados de um mapa de sinais de rádio do ambiente de interesse.

Em vez de usar RSS, para inferir a distância do dispositivo móvel para os PAs, outra abordagem é armazenar essas impressões digitais, como dados brutos em um banco de dados e, em seguida, empregar algoritmos de reconhecimento de padrões para obter a localização do dispositivo móvel, dados os valores de RSS observados na posição alvo. Essa abordagem atraiu o interesse da comunidade acadêmica após o trabalho inicial de Bahl e Padmanabhan, da Microsoft Research, que introduziu o sistema de localização e rastreamento chamado RADAR em 2000 [21]. Desde então, foram realizadas várias pesquisas em todo o mundo, com as impressões digitais de Wi-Fi, e um grande número de artigos foi apresentado em eventos científicos, desde então.

Em particular, a técnica baseada em impressão digital da intensidade do sinal do Wi-Fi (RSS *fingerprint*), tem atraído muita atenção, principalmente, por amenizar o problema de *multipath*, ou seja, múltiplos caminhos percorridos pelo sinal entre o emissor e receptor, agravado pela existência de paredes e objetos em ambientes internos.

A técnica RSS *fingerprint* é dividida em duas fases, como pode ser observado na Figura 3-a: uma fase *offline* (ou fase de coleta e montagem da base de dados) e uma fase *online* (ou de operação).

A fase *offline*, que é a fase de pesquisa do site (*Site Survey*), cria um mapa RSS (*Fingerprint Database*) ou mapa de rádio (*radiomap*), para um conjunto de localizações ou pontos de referência (PRs). São coletadas e armazenadas a localização (*Location*) e amostras da intensidade do sinal (*Fingerprint*) oriundos dos PAs, em cada ponto de referência (PR, do inglês *Reference Point* - RP) desejado, dentro da área de interesse. Por exemplo, na posição i , cujas coordenadas cartesianas X , Y são conhecidas, obtemos a amostra PR_i (RSS_1 , RSS_2 , ... RSS_n), coletando a intensidade do sinal na posição i para os n PAs (ver Figura 3-b). Assim, além de não ser necessário conhecer as localizações exatas dos pontos de acesso Wi-Fi, o

mapa RSS não requer medição de distância nem de ângulo para os PAs, o que simplifica o processo.




Figura 3: Fases *offline* e *online* do RSS fingerprint: Fonte: [3].

Normalmente, escolhem-se os PAs com maior força de sinal para a região de interesse como um todo. A principal preocupação na fase *offline* é equilibrar a precisão de localização com o esforço necessário para criação do mapa RSS. Quanto mais pontos de referência, mais medições serão necessárias em pontos distintos da área de interesse.

A criação de mapas de rádio para grandes edifícios é uma tarefa tediosa e demorada, pois muitas impressões digitais precisam ser coletadas, manualmente, para um grande conjunto de PRs. Além disso, quanto mais denso é o conjunto de PRs e quanto maior o número de RSS coletados em cada PR, melhor é a precisão das estimativas de posição, o que exige ainda mais trabalho na construção dos *radiomaps* [21].

Reduzir este esforço, de mapeamento inicial da impressão digital dos sinais de Wi-Fi em um ambiente interno de interesse, pode dar uma contribuição significativa para o crescimento no uso dos ILBS.

Na fase *online*, que é a fase de localização (*Location Estimation*), o vetor RSS (RSS_1 , RSS_2 , ... RSS_n), com a força do sinal recebido (*Signal Measurement*) dos PAs pelo dispositivo móvel na posição alvo, será comparada com as amostras existentes no banco de dados (mapa RSS) coletadas na fase *offline*, utilizando um algoritmo de localização (*Location Algorithm*).

Usando alguma métrica de similaridade, como, por exemplo, a distância Euclidiana (Equação 2), o vetor RSS da posição alvo, na fase *online*, é comparado com as impressões digitais armazenadas no banco de dados durante a fase *offline*. A posição alvo é então estimada, por exemplo, com base nos "vizinhos" mais próximos, dentre todos os PRs existentes na base de impressões digitais (*radiomap*). Esta abordagem se baseia na observação de que posições próximas têm valores de RSS mais semelhantes do que aquelas localizações mais distantes.

$$d = \sqrt{\sum_{k=1}^n (RSS_k - SS_k)^2} \quad (2)$$

O principal objetivo na fase *offline* da abordagem de impressões digitais é a construção de um mapa de rádio confiável, de forma eficiente e econômica, abordando desafios relacionados a dispositivos móveis heterogêneos, densidade de PAs e PRs - que influenciam diretamente na precisão da localização, e o tamanho do mapa de rádio, que deve ser o menor possível [21].

2.4. Métodos para Obtenção da Localização Interna

Para localização em ambientes internos, os métodos tradicionais utilizados para RSS *fingerprint* incluem: algoritmos determinísticos e probabilísticos [3].

Algoritmos determinísticos usam uma métrica de similaridade, ou distância, para determinar a localização mais aproximada, comparando os sinais obtidos na fase *online* com os dados de impressões digitais armazenados no mapa RSS durante a fase *offline*.

Exemplos de algoritmos determinísticos incluem o algoritmo do vizinho mais próximo (*Nearest Neighbor* - NN) e suas generalizações: KNN (*K-Nearest Neighbor*) e WKNN (*K-Weighted Nearest Neighbor*). No método *1-Nearest Neighbor* (1-NN), a posição da impressão digital mais similar no mapa de rádio é considerada a estimativa de posição para o dispositivo móvel em questão. Alternativamente, no *K-Nearest Neighbor* (K-NN), as *K* impressões digitais mais similares podem ser usadas para estimar a posição como o centróide

das posições correspondentes. O WKNN, ao calcular o centróide de K vizinhos mais próximos, usa a distância Euclidiana como o peso para cada vizinho. Nessa abordagem, K é um parâmetro de design que pode ser alterado para obter melhor precisão. Normalmente, quando a densidade do mapa de rádio é alta, K deve ser pequeno. Para casos típicos, o valor ideal de K fica entre 3 e 4 [22].

A principal vantagem dos métodos determinísticos é sua facilidade de implementação e baixa complexidade computacional. Alguns algoritmos determinísticos mais avançados, como a máquina de vetor de suporte (*Support Vector Machine* – SVM) e a análise discriminante linear (*Linear Discriminant Analysis* – LDA), apresentam melhor precisão na localização, mas com um custo computacional mais alto [3].

Algoritmos probabilísticos se baseiam na inferência estatística entre a medição do sinal pelo dispositivo móvel na posição alvo e a impressão digital armazenada. Aqui, a posição alvo é estimada calculando a probabilidade de se obter o valor de RSS medido em cada local, com base na função de distribuição de probabilidade (*Probability Distribution Function* – PDF) dos valores de RSS na área de interesse. Durante a fase *offline*, o histograma dos valores de RSS medidos, para cada PA em cada PR, é usado para modelar a função de distribuição de probabilidade (PDF) de se observar um dado valor de RSS em cada local. Na fase *online*, a posição estimada é obtida como sendo o PR com a maior probabilidade de observar o RSS mensurado [21].

Algoritmos probabilísticos, como a rede bayesiana, maximização de expectativa, divergência de Kullback-Leibler, processo gaussiano e campo aleatório condicional, exigem um número maior de instâncias do conjunto de dados do que os algoritmos determinísticos [3].

Já o filtro de partículas, para modelos não-gaussianos e não-lineares, é um método sequencial de Monte Carlo que gera amostras aleatórias, conhecidas como partículas, de acordo com modelos de movimento e estima suas densidades de probabilidade mais relevantes, para o estado do dispositivo móvel, melhorando a precisão de rastreamento [5].

A localização de grade (do inglês *Grid Localization*) obtém a posição posterior, mais provável, usando um filtro de histograma (do qual é derivado) sobre uma decomposição, invariável no tempo, em forma de grade, todas com o mesmo tamanho, do espaço de

localizações. Uma representação mais detalhada produz localizações mais precisas, mas às custas de um maior processamento computacional [5].

A principal desvantagem dos métodos de filtro é sua alta complexidade computacional. Infelizmente, esta carga computacional não é adequada em dispositivos móveis para fornecer localização em tempo real.

O modelo probabilístico e o modelo determinístico alcançam precisão de posicionamento similar para objetos estáticos, mas o modelo probabilístico é mais preciso do que o modelo determinístico para objetos se movimentando com rapidez [45].

Os ILBS possuem complexidade em termos de software, hardware e fatores operacionais. Especificamente, a complexidade do software envolve os cálculos em um algoritmo de posicionamento. Se um servidor central realiza os cálculos, a estimativa de localização é rápida, devido à grande capacidade de processamento. No entanto, se os cálculos forem realizados no dispositivo móvel, a dificuldade aumenta, uma vez que estes possuem recursos limitados. Assim, para localização em dispositivos móveis, algoritmos de posicionamento com baixa complexidade são preferidos, uma vez que estes têm poder de processamento e vida útil da bateria limitados.

Outras abordagens usam algoritmos de fusão de informações para navegação inercial (IMU), onde o deslocamento de um dispositivo é determinado pela junção de medições frequentes de aceleração e direção, usando bússola magnética e acelerômetro, presentes na maioria dos *smartphones*. No entanto, esta deve ser complementada com outra técnica de localização, para evitar o acúmulo de erro proveniente da calibragem imprecisa destes sensores de movimento [2].

3. TRABALHOS RELACIONADOS

A revisão da literatura realizada, com ênfase na discussão de trabalhos que utilizam o método de impressão digital do Wi-Fi para localização interna, se concentrou em artigos (*Survey*) relevantes e referenciados que abordaram as tecnologias para localização ou posicionamento em ambientes internos entre 2015 e 2020, e em artigos publicados nas conferências IPIN (*International Conference on Indoor Positioning and Indoor Navigation*) e UPINLBS (*Ubiquitous Positioning, Indoor Navigation and Location-Based Services*).

Como os objetivos específicos da nossa pesquisa se dividem, principalmente, em obter uma abordagem simplificada para coleta do banco de dados de impressões digitais do Wi-Fi na fase *offline*, e identificar os fatores e algoritmos de aprendizagem de máquina de maior influência na minimização do erro médio na fase *online*; agrupamos os trabalhos relacionados de acordo com a fase da abordagem RSS *fingerprint*, ou seja, se referente à fase *offline* ou *online* da técnica de impressão digital do sinal do Wi-Fi para localização interna.

3.1. Fase Offline: Mapeamento

A ampla adoção de sistemas de posicionamento em ambientes internos baseados em impressões digitais do Wi-Fi é atualmente prejudicada pelos esforços necessários na coleta de medições durante a fase *offline*. A fim de resolver a carga de trabalho necessária para a construção do banco de dados de impressões digitais, diversas propostas foram apresentadas [46], [31], [43], [33], [21] e [22].

O trabalho em [46] apresenta o ViFi, um sistema de posicionamento interno que se baseia na previsão de RSS com base no modelo de propagação Multi-Wall Multi-Floor (MWMF) para gerar um mapa de rádio RSS discreto (impressões digitais virtuais). Resultados experimentais extensos, obtidos através de vários bancos de teste independentes, mostram que o ViFi supera os sistemas virtuais de impressão digital adotando modelos de propagação mais simples em termos de precisão e permite uma redução de sete vezes no

número de medições a serem coletadas, obtendo a mesma precisão de um sistema tradicional de impressões digitais implantado no mesmo ambiente. Entretanto, o uso do MWMF requer um conjunto inicial de medições M e, para cada medição ($m = 1, 2, \dots, M$), as informações sobre cardinalidade, tipo e posições de objetos obstruindo o caminho direto entre o emissor (PA) e o dispositivo móvel. Assim, a desvantagem desta abordagem está na identificação dos tipos e quantidade de objetos obstruindo o caminho, necessários para o uso do modelo de propagação MWMF. Alguns destes parâmetros necessários são:

- Número de famílias diferentes de objetos 2D;
- Número de tipos de objetos 2D considerados para a família n ; e,
- Número de objetos 2D obstruindo o caminho direto da família n e tipo i .

Para estimar o RSS de pontos desconhecidos, usando a força do sinal dos PRs conhecidos, [31] estudou quatro métodos de interpolação (Ponderada por Distância Inversa - do inglês *Inverse Distance Weighted* – IDW, Bilinear, Regressão de Processo Gaussiano - do inglês *Gaussian Process Regression* – GPR e Kriging). A diferença de resultados de posicionamento (erro médio de estimativa) entre o banco de dados de interpolação e o banco de dados original, usando os quatro métodos, foi: 1,69m (original), 1,58m (IDW), 1,68m (Bilinear), 1,54m (GPR) e 1,53m (Kriging), o que demonstra a aplicabilidade da técnica para diminuição do esforço de criação do *radiomap* na fase *offline*.

No nosso projeto de experimentos, um dos cenários aplicados na fase *offline* (Bloco nº3 do Experimento 2D, Seção 5.1.1) para previsão do mapa RSS, utilizou o modelo lognormal de propagação de sinal, como em [46], e também o modelo de interpolação ponderada, como em [31], para obter as impressões digitais virtuais, a partir de um subconjunto de impressões digitais reais de RSS. Entretanto, os resultados obtidos com o banco de dados (mapa RSS) de interpolação não foram melhores do que usando o banco de dados original, que contém medições de cada metro quadrado do ambiente de interesse.

Para reduzir a carga de trabalho na obtenção do mapa de impressões digitais, [43] aplicou o Deep Belief Networks (DBN, também conhecido como *AutoEncoders*) a medições de RSS não rotuladas para extrair características ocultas das impressões digitais e, assim, minimizar a coleta do mapa RSS na fase *offline*. Essas características são usadas como entradas em técnicas de regressão convencionais, como SVM e KNN. Os experimentos mostraram que essa abordagem melhora a precisão da localização em 1,9 m (de 8,7m para

6,8m) ao usar apenas 10% das impressões digitais rotuladas, em comparação com a abordagem básica mais próxima que usou 100% das impressões digitais rotuladas.

O UILoc [33], um esquema de localização interna não supervisionado, que usa uma combinação de sensores do *smartphone*, iBeacons e impressões digitais do Wi-Fi para localização interna confiável e precisa, constrói o banco de dados de impressões digitais automaticamente, sem qualquer pesquisa de site na fase *offline*. Um novo método, que combina a abordagem de impressão digital do Wi-Fi e o modelo de propagação do sinal iBeacon, é proposto para melhorar a precisão da localização inicial. Os resultados experimentais mostraram um erro médio de localização de 1,1m no estado estacionário e um erro máximo de 2,77m.

O Locus é um sistema de localização, rastreamento e navegação em interiores baseado em heurística para edifícios de vários andares que determina o piso e a localização usando os locais dos pontos de infraestrutura e sem a necessidade de mapas de rádio [21]. Os resultados experimentais iniciais em um espaço interno abrangendo 53.000 m² mostram que Locus pode determinar o piso com 99,97% de precisão e a localização com um erro médio de localização de 7m.

Um dos cenários aplicados na fase *offline* (Bloco nº4 do Experimento 2D, Seção 5.1.1) do nosso projeto de experimentos, utilizou as leituras de RSS a 1m dos pontos de acesso, como em [21], usando os locais dos pontos de infraestrutura, para obter as impressões digitais virtuais a partir de medições reais mínimas. Os resultados experimentais em um espaço interno de 400 m² mostram um erro médio mínimo de localização de 2m.

3.2. Fase Online: Localização

Alguns estudos, como referenciados em [21], [22], [36] e [44], investigaram abordagens para problemas típicos relacionados aos sinais de Wi-Fi, como: a volatilidade causada pela atenuação do sinal ou efeito de *multipath*, agravado em ambientes internos pela existência de paredes e objetos; RSS diferentes obtidos por dispositivos distintos num mesmo local; ou RSS diferentes obtidos por um mesmo dispositivo em um mesmo local em orientações diferentes.

[21] apud Kim *et. al.* realizaram um estudo experimental onde mediram a precisão de um sistema de posicionamento para várias densidades do mapa de rádio, realizando um número diferente de impressões digitais recolhidas em cada PR. Eles concluíram que a precisão aumenta significativamente à medida que mais impressões digitais são coletadas em cada PR.

No nosso projeto de experimentos, um dos cenários aplicados na fase *online* (Bloco nº1 do Experimento 2D - Seção 5.1.1) para previsão da localização do dispositivo alvo, analisou o impacto do número de PAs e de leituras RSS colhidas em cada PR, como em [21], para verificar a influência desses fatores no erro médio de localização. Verificamos que a precisão aumenta à medida que mais PAs são utilizadas e mais leituras RSS são coletadas em cada PR.

[22] apud Chapre *et. al.* mediram o RSS em um laptop estacionário para 13 PAs em um ambiente de escritório típico. Os dados foram coletados para 4 direções distintas, como leste, oeste, norte e sul durante 24 horas em um local fixo. Os resultados mostram que a variação do RSS para as diferentes direções é em média de 3dBm, que é a unidade de medida para o RSS.

A impressão digital com base em classificação (*Ranked Based Fingerprinting* – RBF) usa apenas índices dos PAs ordenados pelo sinal mais forte, em vez de valores reais de RSS de Wi-Fi, para tornar o algoritmo independente de dispositivo. Um componente chave do algoritmo RBF é a medida de similaridade, que é usada para comparar e encontrar as impressões digitais mais próximas. Em [44], um teste com um banco de dados público de posicionamento interno, usando 49 medidas de similaridade, mostrou que a precisão de posicionamento varia de 15,80m a 55,22m. As 3 principais medidas de similaridade foram Lorentzian (15,80m), Hamming (17,571m) e Jaccard (17,57m) para o algoritmo KNN com $K = 5$. RFB baseia-se na percepção de que a classificação ou a ordem dos IDs de APs detectados em determinado local, classificados por valores de RSS, devem permanecer os mesmos entre dispositivos diferentes.

Em [36] é apresentado um método de posicionamento adaptativo usando K -vizinhos mais próximos ponderado (WKNN) com base na impressão digital omnidirecional (que inclui a posição, orientação e a sequência do indicador de intensidade média do sinal recebido em cada PR) e agrupamento de propagação por afinidade, considerando a orientação do usuário.

Resultados experimentais mostraram que o método proposto apresenta erro médio de 2,2m e erro médio quadrático de 1,5m.

Um dos cenários aplicados na fase *online* (Bloco nº2 do Experimento 2D, Seção 5.1.1) do nosso projeto de experimentos, para previsão da localização do dispositivo alvo, utilizou filtros RSS ordenados pelo PA com sinal mais forte recebido, como em [44], para restringir a área de busca no mapa RSS aos valores RSS próximos (+/- o erro padrão associado ao PA em questão). Outro cenário analisado no Bloco nº2 do Experimento 2D (Seção 5.1.1), empregou um método de posicionamento adaptativo considerando a posição anterior (coordenadas XY) do dispositivo alvo. Resultados experimentais mostraram que esse último método utilizado apresentou o menor erro médio de 1,31m.

Um método de posicionamento 2.5D interno baseado em SVM é apresentado em [32]. O método usa SVM e o sinal de Wi-Fi de cada piso para identificar o andar. Em seguida, o algoritmo WKNN é aplicado para a estimativa de localização 2D sobre um conjunto de localizações usando impressões digitais do Wi-Fi. Assim, o posicionamento tridimensional é realizado. Através de um método para seleção dos APs, a precisão do posicionamento 2D foi aprimorada e o erro médio de cada ponto de localização ficou abaixo de 1m.

Um dos experimentos aplicados com foco na fase *online* (experimento 3D), realizou o posicionamento tridimensional, como em [32], para analisar a precisão da nossa abordagem em ambientes com vários andares. Através da adição do eixo Z, a precisão do posicionamento 2D foi aprimorada e o menor erro médio de localização ficou em 1,07m.

Uma abordagem combinada para localização pela impressão digital do Wi-Fi, composta de vetores RSS em dois pontos e um vetor de deslocamento entre eles, foi proposta em [34]. Uma SVM e florestas aleatórias (*Random Forest* – RF) foram usadas para construir modelos de regressão, com erro médio quadrático (*Root Mean Square Error* – RMSE) da estimativa da posição alvo em 2,35m e 0,80 m, respectivamente.

A Análise de Componentes Principais (*Principal Component Analysis* - PCA) foi utilizada por [47] para melhorar o desempenho e reduzir o custo de computação dos sistemas de localização interna com base em abordagens de aprendizagem de máquina, usando os classificadores KNN, Árvore de Decisão, RF e SVM. Os resultados mostram que o tempo de

computação foi reduzido em 70% ao usar o classificador RF no modo estático e em 33% ao usar o KNN no modo dinâmico. O erro médio ficou abaixo de 1,5m com o RF.

Um método de impressão digital do Wi-Fi para localização de veículos inteligentes em estacionamentos cobertos, foi proposto por [27]. Embora o método em si seja uma abordagem popular para aplicação em localização interna, adaptá-lo à velocidade dos veículos requer tratamento diferente. Usando uma Rede Neural para a classificação de impressões digitais do Wi-Fi, experimentos mostraram resultados promissores, com erro médio de localização de 0,6m.

Algoritmos clássicos de Aprendizagem de Máquina, como KNN e SVM, têm sido intensivamente estudados na literatura nas últimas duas décadas [32], [34], [36], [43] e [47]. Por outro lado, abordagens para localização usando as impressões digitais baseadas em arquiteturas de Aprendizagem Profunda (do inglês, *Deep Learning* – DL), como Perceptron Multicamadas (do inglês, *Multilayer Perceptron* – MLP), Autoencoders e Redes Neurais Convolucionais (do inglês, *Convolutional Neural Networks* – CNN), foram introduzidas apenas recentemente [26], [27], [30], [37], [43] e [48].

DL é um subconjunto de algoritmos de Aprendizagem de Máquina que tenta imitar a estrutura e funcionalidade do cérebro humano. Ao contrário do KNN e do SVM, os algoritmos DL são paramétricos; o que significa que o número de parâmetros do algoritmo é independente do número de exemplos de treinamento. Essa propriedade é particularmente útil na fase *online*, reduzindo significativamente o tempo de previsão, o que os torna atraentes para o rastreamento de dispositivos móveis em tempo real [26].

O trabalho de [37] propõe uma solução de posicionamento interno baseada nas redes DL, com a fusão de dados de múltiplas fontes: dados geomagnéticos e iBeacon do ambiente interno. Assim, a dimensão dos dados de entrada é aumentada e a estabilidade do sistema de posicionamento interno é melhorado. O resultado do experimento mostrou um erro de posicionamento médio de 0,29m e máximo de 1,59m. O erro de posicionamento ficou 96,33% em 1m e 100% dentro de 2m, o que atende ao requisito de posicionamento para ambientes internos.

Para implementar um sistema livre de orientação e livre de infraestrutura, [30] propõe um esquema de posicionamento baseado em aprendizagem profunda e CNN, usando

informações de campo magnético e intensidade do sinal de Wi-Fi (RSS). Testes demonstraram um erro médio de 5m em 80% dos casos avaliados. Já um método baseado em CNN para um sistema de posicionamento *indoor* por *smartwatch*, usando apenas impressão digital de campo geomagnético, é apresentado por [26]. Resultados experimentais, em um ambiente interno formado por três corredores de diferentes comprimentos e três salas de tamanhos distintos, mostraram um erro médio de localização de 0,136m.

Embora a maioria dos estudos envolvendo abordagens para localização em ambientes internos utilize o erro médio de localização como métrica para avaliar sua precisão, como pode ser visto através do quadro resumo dos trabalhos relacionados apresentado na Figura 4, esta não é suficiente para comparar o desempenho de sistemas de localização avaliados em ambientes de tamanhos e configurações internas diferentes.

Referência	Fase	Método	Erro médio (m)
[46] ViFi	Offline	previsão de RSS com base no modelo de propagação do Wi-Fi	-
[33] UILoc	Offline	modelo de propagação do sinal iBeacon	1,10
[31]	Offline	quatro métodos de interpolação:	
		- Ponderada por Distância Inversa - IDW,	1,58
		- Bilinear,	1,68
		- Regressão de Processo Gaussiano - GPR, e	1,54
		- Kriging.	1,53
[43]	Offline	Autoencoders	6,80
[21] Locus	Offline	loais dos pontos de infraestrutura e sem a necessidade de radiomaps	7,00
[44]	Online	medidas de similaridade:	
		- Lorentzian,	15,80
		- Hamming, e	17,571
		- Jaccard.	17,57
[36]	Online	posição, orientação e a sequência do indicador de intensidade média do RSS em cada ponto	2,20
[32]	Online	SVM para o andar e WKNN para localização 2D, seleção dos APs	0,99
[34]	Online	SVM	2,35
		Random Forest	0,80
[47]	Online	PCA	
		KNN	
		SVM	
		Decision Tree	
		Random Forest	1,50
[27]	Online	Rede Neural	0,60
[37]	Online	Deep Learning	0,29
[30]	Online	CNN - Wi-Fi e campo magnético	5 - 80%
[26]	Online	CNN - Só campo magnético	0,136

Figura 4: Trabalhos relacionados à técnica RSS fingerprint. Fonte: Autor (2020).

O interesse na avaliação de desempenho de sistemas de localização *indoor*, sob condições reais, ficou evidente com o padrão ISO/IEC 18305: 2016 e competições relacionadas, incluindo o Microsoft Indoor Localization Competition, o concurso EvAAL

para avaliação de ambientes e sistemas de assistência à autonomia no domicílio (*Ambient Assisted Living – AAL*), realizado em conjunto com a conferência IPIN, e, mais recentemente, a competição PerfLoc, para aplicativos de localização *indoor* para *smartphone*, anunciada pelo Instituto Nacional de Padrões e Tecnologia dos EUA (*National Institute of Standards and Technology – NIST*) [21].

Duas competições de localização *indoor* vêm sendo realizadas anualmente nos últimos anos. A primeira [38], realizada em conjunto com a Conferência de Posicionamento Interno e Navegação Interna (IPIN, do inglês *Indoor Positioning and Indoor Navigation*) do IEEE desde 2011. A segunda é a Microsoft Indoor Localization Competition [39], realizada em conjunto com a Conferência IEEE de Processamento de Informação em Redes de Sensores (IPSN, do inglês *Information Processing in Sensor Networks*) desde 2014. Em 2018, a competição promovida pela Microsoft foi realizada em duas faixas: (i) 2D Track e (ii) 3D Track. Os sistemas que competiram na 2D Track usaram tecnologias, como: PDR (do inglês, *Pedestrian Dead Reckoning*), câmera e impressão digital do Wi-Fi. Os sistemas concorrentes foram avaliados com base no erro médio de localização horizontal e o melhor sistema alcançou um erro médio de 2,3m. O melhor sistema da 3D Track integrou o UWB e o ARKit [40] para alcançar um erro médio de 27cm. O Concurso IPIN de 2017 foi realizado em quatro faixas: (i) Baseado em *Smartphone*, (ii) Posicionamento via PDR, (iii) Baseado em *Smartphone* (Fora do Local) e (iv) PDR para Coleta de Armazém (Fora do Local). A área de avaliação foi de cerca de 1.500 m² usando dois andares. Os melhores nas pistas 1 e 3 foram 8,8m e 3,68m, respectivamente.

O Instituto Nacional de Padrões e Tecnologia dos EUA (NIST, do inglês *National Institute of Standards and Technology*) criou e realizou o PerfLoc Prize Competition [41] de março de 2017 a abril de 2018. O NIST usou quatro telefones Android de diferentes marcas (LG G4, Motorola Nexus 6, OnePlus 2 e Samsung Galaxy S6) para coletar dados de sensores, como acelerômetro, giroscópio, magnetômetro e barômetro, bem como o Indicador de Força de Sinal Recebido (RSSI) do Wi-Fi, os pontos fortes dos sinais recebidos de estações de base de celular e Correções de GPS que estavam disponíveis ocasionalmente em 4 edifícios. A área total nos quatro edifícios tinha mais de 30.000 m². Os edifícios foram selecionados com base na orientação da norma internacional ISO/IEC 18305, Teste e Avaliação de Sistemas de Localização e Rastreamento, cujo desenvolvimento o próprio NIST liderou de 2012 à 2016. O

desempenho do aplicativo de localização *indoor* do PerfLoc, que ganhou o primeiro prêmio, ficou com erro médio de localização 3D de 2,63m.

Comparar resultados de desempenho de competições distintas não é indicado [41]. Mesmo se compararmos sistemas similares, por exemplo, aplicativos para *smartphone* que usam impressão digital do Wi-Fi, ainda deve-se levar em conta as diferenças nas áreas de avaliação. O que pode ser feito é comparar vários sistemas avaliados no mesmo conjunto de edifícios ao mesmo tempo.

Neste sentido, a primeira tentativa formal de definir uma metodologia padrão para avaliar sistemas de localização em ambientes internos é a norma internacional ISO/IEC 18305: 2016, que define uma estrutura completa para a realização de testes e avaliação de sistemas de localização e rastreamento [42]. A norma apresenta até 14 cenários (correndo, andando para trás, engatinhando, etc.) diferentes e 5 tipos de construções (casa unifamiliar, prédio de escritórios, armazém, aço alto-relevo, subterrâneo) onde o teste deve ser realizado, e até 30 métricas para avaliar o desempenho em cada caso de teste. Algumas das métricas sugeridas pela norma estão listadas abaixo:

- Probabilidade de detecção de piso - para edifícios com múltiplos andares
- Probabilidade de detecção de zona - se as zonas estiverem definidas
- Média de erro - polarização 3D geral
- Matriz de covariância de erro - uma matriz de 3 por 3
- Covariância de erro - o traço da matriz acima
- Média de erro absoluto - um vetor 3D
- Média e desvio padrão da magnitude do erro
- Média e desvio padrão da magnitude do erro horizontal
- Média e desvio padrão da magnitude do erro vertical
- Raiz média quadrada de magnitude do erro e seus componentes - xyz, x, y, z, xy
- Mediana da magnitude do erro - SEP (erro esférico provável)
- 95º percentil de magnitude do erro - SE95
- Mediana da magnitude do erro horizontal - CEP (erro circular provável)
- 95º percentil de magnitude do erro horizontal - CE95
- Mediana da magnitude do erro vertical - VEP (erro vertical provável)
- 95º percentil de magnitude do erro vertical - VE95

4. METODOLOGIA

Nesta seção, apresentamos a metodologia empregada para identificação de um mecanismo simplificado para obtenção do banco de dados (mapa RSS) de impressões digitais do Wi-Fi (fase *offline*); e, análise dos fatores principais e algoritmos de aprendizagem de máquina mais eficientes e eficazes para determinar a localização de dispositivos móveis em ambientes internos (fase *online*) de um único pavimento (experimento em duas dimensões - Experimento 2D) ou com vários andares (experimento 3D). A Figura 5 apresenta o diagrama de blocos da metodologia empregada, destacando as abordagens analisadas para localização, o ambiente interno utilizado para coleta das impressões digitais dos sinais de Wi-Fi e os cenários (blocos) de execução do projeto de experimentos realizado considerando as fases *Offline* e *Online* do método *RSS Fingerprint*.




Figura 5: Diagrama de blocos da metodologia utilizada. Fonte: Autor (2020).

4.1. Abordagem utilizada para localização interna

Inicialmente, tentou-se a utilização de uma abordagem baseada em modelos de propagação de sinal, para calcular a distância entre os PAs e o dispositivo móvel, para, em seguida, utilizar trilateração entre os PAs para obter a localização do dispositivo alvo.

Infelizmente, os modelos testados – modelo de Sombreamento Lognormal [6] e o modelo Hata-Okumara [4] – se mostraram ineficientes para representar as propagações de sinal em ambientes internos, principalmente, por serem modelos adequados para utilização em ambientes abertos, sem ocorrência de obstáculos e efeitos do *multipath*, característicos dos ambientes internos.

Como a abordagem de localização interna, usando modelos de propagação de sinais de Wi-Fi, não apresentou resultados que demonstrassem a sua eficácia, inclusive sabendo que as fórmulas utilizadas para o cálculo da distância do ponto de acesso (PA) variam de forma não linear, como demonstrado no trabalho de Atreyi Bose e Chuan Heng Foh [4], adotamos nos experimentos seguintes, a abordagem RSS *fingerprint* conjugada com algoritmos de aprendizagem de máquina, como o método WKNN, para cálculo da distância entre o vetor RSS medido na fase *online* e o mapa RSS armazenado na fase *offline*.

4.2. Configuração do Ambiente Interno

Os experimentos em questão, foram realizados no LASER - Laboratório de Sistemas, Engenharia e Robótica - da UFPB, localizado no campus Mangabeira em João Pessoa/PB.

No primeiro experimento, que passamos a referenciar apenas como 2D, realizado exclusivamente no andar térreo do LASER, o layout dos pontos de acesso (do inglês *Access Points* – APs) e dos locais das medições dos pontos de referência (PRs) pode ser visto na Figura 6. O objetivo do Experimento 2D foi realizar uma validação de conceitos e conhecimento das variáveis importantes nas fases *online* e *offline*, separadamente, pertinentes ao método RSS *fingerprint*.




Figura 6: Distribuição dos pontos de acesso – PAs (APn) e pontos de referência – PRs (centro dos quadrados marcados com X) - Experimento 2D. Fonte: Autor (2020).

O segundo experimento, que chamaremos de 3D, realizado nos pavimentos térreo e 1º andar do LASER, cujo layout dos APs e PRs pode ser visto na Figura 7, para ambos os andares, teve como objetivos principais: a ampliação da localização interna em duas dimensões (2D) para três dimensões (3D), expandindo a capacidade do ILBS em questão para ambientes internos com vários níveis; e, a verificação da acurácia do ILBS quanto à independência de dispositivo, ou seja, quando da utilização de outro dispositivo na fase *online*, diferente do equipamento que fez as medições para obtenção do mapa RSS na fase *offline*.




Figura 7: Distribuição dos pontos de acesso – PAs (APn) e pontos de referência – PRs (centro dos quadrados marcados com X) - Experimento 3D. Fonte: Autor (2020).

Como a precisão de posicionamento depende muito dos ambientes e posicionamento dos PAs [21], foram adotadas algumas recomendações para implantar sistemas de posicionamento eficientes baseados em impressão digital do Wi-Fi. Com o layout adotado (Figuras 6 e 7) para os APs, a radiação dos sinais não fica distribuída em um círculo e a variação do RSS entre os pontos de referência (Xs) aumenta, resultando em melhoria na precisão da localização. Estes cuidados visam reduzir a influência de ruídos e minimizar a ocorrência de outros fatores que influenciam na volatilidade do RSS, como a atenuação de sinal e o *multipath*.

4.3. Execução dos Experimentos

4.3.1. Obtenção do Mapa RSS (fase *offline*)

Na fase *offline* do Experimento 2D, dividimos a área de interesse em quadrados de tamanho 1m x 1m, para cada metro quadrado do vão livre do andar térreo e de duas salas existentes no térreo do LASER. O experimento foi realizado numa área de 20m x 19m, com 262 PRs obtidos, conforme distribuição dos quadrados marcados com um X no centro (Figura 6).

Já na fase *offline* do Experimento 3D, medimos cada metro quadrado de uma área comum e de uma sala em ambos os pavimentos (térreo e 1º andar) do LASER. O experimento foi realizado numa área de 10m x 8m, com 98 PRs obtidos, conforme distribuição dos quadrados marcados com um X no centro (Figura 7).

Quando um dispositivo objetiva estimar sua posição através de sinais de Wi-Fi, são necessárias medições repetidas de RSS dos PAs, isto, para minimizar o erro de posicionamento decorrente da variação característica do sinal de Wi-Fi. Os erros devem-se principalmente à volatilidade do sinal e à presença de diferentes localizações com RSS semelhantes, causadas pela propagação dinâmica característica dos sinais de rádio [5].

Assim, conforme Fórmula 3 abaixo, em cada um dos 360 PRs, 262 do Experimento 2D e 98 do 3D, obtivemos 5 medições de RSS para cada um dos 5 PAs fixos – AP1, AP2, AP3, AP4 e AP5. Desta forma, foram realizadas 9000 leituras de RSS e inseridas no banco de dados de impressão digital (mapa RSS).

$$360 \text{ (PRs)} \times 5 \text{ (medições RSS)} \times 5 \text{ (PAs)} = 9000 \quad (3)$$

Assim, o conjunto das leituras dos PRs contém o local (em coordenadas X e Y) seguido por 5 leituras de RSS para cada um dos 5 PAs instalados no ambiente interno de interesse. A Figura 8 apresenta um recorte do mapa RSS obtido na fase *offline* do Experimento 2D. Um mapa RSS similar foi obtido também para o Experimento 3D. A diferença nesse último, reside na adição da coordenada cartesiana Z (altura), que foi assumida como sendo 1,5m para o andar térreo e 4,5m para o primeiro andar. Alturas intermediárias

(2m, 2,5m, 3m, 3,5m e 4m) foram adotadas para o trajeto realizado na escada de acesso ao primeiro andar.

Para obtenção do mapa RSS, nos Experimentos 2D e 3D, foi implementado um algoritmo em Python 3.7, que faz a carga do layout do ambiente de interesse (Figuras 6 e 7 acima) e coleta as informações dos PRs, como: as coordenadas cartesianas (x,y) relativas à imagem carregada e a obtenção das 5 leituras de RSS para cada um dos 5 PAs no ambiente de interesse, utilizando os recursos do sistema operacional para a captura dos RSSs.

```
[[1.4734211721944566, 19.440191387559807], [-59, -58, -59, -61, -61], [-42, -44, -45, -47, -46], [-73, -73, -72, -74, -73], [-64, -64, -63, -64, -64], [-53, -53, -50, -51, -51]],
[[2.4766015447523846, 19.535885167464116], [-62, -61, -62, -65, -64], [-43, -42, -42, -42, -42], [-74, -78, -80, -77, -80], [-70, -69, -68, -68, -70], [-56, -60, -60, -59, -58]],
[[3.4379827351203995, 19.535885167464116], [-59, -63, -61, -63, -60], [-56, -54, -56, -56, -56], [-82, -81, -88, -85, -85], [-73, -73, -71, -68, -70], [-62, -68, -61, -58, -61]],
[[4.482962289888242, 19.535885167464116], [-61, -63, -63, -63, -63], [-55, -53, -54, -54, -54], [-77, -76, -78, -77, -76], [-75, -69, -72, -72, -73], [-59, -60, -62, -59, -61]],
[[5.444343480236256, 19.535885167464116], [-63, -64, -62, -64, -66], [-64, -60, -58, -58, -57], [-78, -79, -81, -81, -81], [-68, -69, -69, -69, -69], [-64, -63, -63, -61, -63]],
[[6.40572467060427, 19.535885167464116], [-63, -62, -61, -61, -62], [-63, -61, -62, -63, -63], [-76, -76, -77, -76, -77], [-67, -70, -71, -70, -71], [-67, -66, -65, -65, -65]],
[[7.408905043162198, 19.63157894736842], [-58, -57, -57, -58, -58], [-61, -62, -58, -59, -61], [-73, -75, -77, -76, -73], [-69, -77, -74, -77, -74], [-61, -58, -58, -59, -59]],
[[8.495683780099954, 19.535885167464116], [-65, -67, -65, -64, -62], [-60, -59, -59, -58, -59], [-76, -80, -79, -80, -80], [-64, -66, -66, -66, -67], [-58, -56, -65, -56, -57]],
[[9.415285788278054, 19.63157894736842], [-63, -60, -61, -60, -60], [-58, -62, -59, -59, -60], [-74, -79, -77, -77, -75], [-75, -68, -65, -67, -68], [-54, -57, -56, -55, -55]],
[[10.418446160835984, 19.583732057416267], [-61, -63, -64, -62, -60], [-62, -64, -65, -65, -65], [-82, -80, -78, -79, -81], [-68, -69, -69, -69, -68], [-65, -81, -61, -90, -62]],
[[11.463425715583824, 19.535885167464116], [-65, -63, -70, -67, -68], [-62, -63, -59, -60, -61], [-75, -75, -79, -76, -79], [-62, -67, -65, -64, -63], [-65, -60, -62, -59, -61]],
[[12.424806905951838, 19.583732057416267], [-54, -53, -54, -53, -53], [-72, -62, -63, -63, -63], [-76, -75, -75, -75, -77], [-61, -62, -60, -60, -60], [-63, -61, -63, -64, -64]],
[[13.511585642889594, 19.440191387559807], [-56, -54, -56, -53, -53], [-68, -66, -66, -66, -66], [-81, -77, -75, -75, -74], [-65, -67, -64, -65, -63], [-62, -65, -64, -66, -64]],
[[14.431167651067694, 19.535885167464116], [-56, -55, -55, -55, -54], [-74, -70, -70, -70, -68], [-82, -82, -80, -79, -79], [-63, -64, -64, -64, -64], [-63, -52, -60, -60, -60]],
[[15.476147205815538, 19.583732057416267], [-56, -57, -56, -56, -57], [-69, -69, -69, -68, -68], [-77, -86, -85, -85, -82], [-58, -58, -58, -58, -59], [-60, -63, -64, -63, -65]],
[[16.479327578373464, 19.535885167464116], [-51, -50, -86, -52, -53], [-70, -73, -73, -73, -73], [-77, -77, -80, -81, -81], [-63, -65, -65, -66, -66], [-62, -62, -62, -58, -57]],
[[17.398909586551564, 19.583732057416267], [-52, -52, -51, -52, -52], [-63, -68, -70, -69, -68], [-81, -81, -81, -78, -80], [-48, -48, -49, -49, -49], [-56, -62, -59, -57, -57]],
[[18.402089959109492, 19.48803827751196], [-56, -52, -55, -55, -54], [-71, -70, -72, -72, -75], [-76, -76, -76, -79, -77], [-46, -44, -43, -43, -43], [-58, -56, -54, -54, -54]],
[[19.447069513857336, 19.535885167464116], [-58, -57, -59, -51, -54], [-70, -69, -69, -68, -44], [-83, -83, -85, -84, -84], [-35, -40, -39, -39, -40], [-59, -58, -57, -83, -59]],
[[20.450249886415264, 19.583732057416267], [-77, -61, -64, -64, -62], [-72, -72, -73, -73, -72], [-83, -87, -85, -85, -86], [-40, -44, -42, -44, -44], [-67, -58, -63, -59, -60]]]
```

Figura 8: Recorte do mapa RSS obtido para os pontos de referência (PRs) medidos na fase *offline* - Experimento 2D.

4.3.2. Estimação da Posição (fase *online*)

Na fase *online*, são utilizados algoritmos de aprendizagem de máquina, como o WKNN, para estimar a localização atual do dispositivo móvel em 64 pontos de interesse (PIs) distintos no Experimento 2D e 31 PIs no Experimento 3D.

Para cada PI medido nos experimentos 2D e 3D, identificados nas Figuras 9 e 10, respectivamente, através de um círculo colorido, foi capturada a posição real na área de interesse e estimada a localização do dispositivo móvel, ambas em termos de coordenadas cartesianas (x,y), a partir do vetor RSS ($RSS_1, RSS_2, \dots, RSS_n$) com a força do sinal recebido dos PAs pelo dispositivo móvel na posição alvo.




Figura 9: Distribuição dos pontos de interesse (PIs) e trajetória percorrida para medição dos vetores de RSS - Experimento 2D.




Figura 10: Distribuição dos pontos de interesse (PIs) e trajetória percorrida para medição dos vetores de RSS - Experimento 3D.

4.3.3. Métrica de interesse

Para avaliação da eficácia do método de localização interna, como regra geral, calcula-se, para cada PI medido na fase *online*, o erro entre a posição real e a estimada. Para obtenção deste erro, utiliza-se o Teorema de Pitágoras, para cálculo da hipotenusa (c) do triângulo formado entre as coordenadas cartesianas (x,y) da posição real (a) e da posição estimada (b), conforme a fórmula (4).

$$c = \sqrt{a^2 + b^2} \quad (4)$$

Onde: $a = X_r - X_e$ e $b = Y_r - Y_e$

De posse do erro para cada um dos PIs estimados, calcula-se a média deste erro para obtenção do **erro médio** para a execução do experimento realizado.

4.4. Projeto de Experimentos

A metodologia aplicada para a realização dos testes se baseou na pesquisa quantitativa (Projeto de Experimentos, do inglês *Design of Experiments* - DOE) do **erro médio** (variável de resposta) entre a posição real e a estimada pelo ILBS, considerando as relações entre as variáveis (fatores) que podem influenciar no experimento, como: número de PAs, número de leituras em cada PR, informação da posição inicial/anterior, algoritmo de aprendizagem de máquina utilizado, entre outros.

Um DOE é um conjunto de ferramentas estatísticas para planejar um experimento, de forma que se possa tirar o maior número de informações possíveis, utilizando o mínimo de recursos e tempo. DOE é uma metodologia básica dos cursos de estatística, mas, há algum tempo, vem sendo utilizado não só pela indústria, mas por qualquer profissional que deseja identificar quais são os fatores (variáveis) que mais influenciam em seu comportamento e como utilizá-los a seu favor, ou seja, quais são os efeitos principais e de interação do processo analisado. As abordagens do DOE se originam nos estudos de Ronald Fisher [49], em sua maioria. Por meio de uma série de experimentações, ele mostrou que o planejamento estratégico e minucioso de determinada experiência e de sua execução reduz significativamente a incidência de falhas. Com base no trabalho de Fisher, alguns conceitos-chave se tornaram importantes para fornecer uma base para a experimentação sistemática:

- **variável de resposta:** chamada de variável dependente, é uma característica da qualidade ou uma medida de desempenho;
- **fator:** chamada de variável independente ou causal, pode ser qualitativa ou quantitativa, e serve para observar o impacto na variável resposta;
- **bloco:** grupo de unidades experimentais que são tratados de forma semelhante;
- **nível:** um valor, ou um ajuste no fator, que pode ser fixado de acordo com certos valores de interesse ou seleção de possíveis valores;
- **efeito:** é a alteração no valor da variável de resposta que ocorre conforme uma variável independente (fator) muda de um nível para outro. É possível obter os efeitos

principais, quando consideramos os fatores isoladamente, e de interação entre os fatores no processo sendo estudado.

Neste sentido, foram realizados 2 experimentos sequenciais, os quais denominamos de 2D e 3D, ambos do tipo 2^k fatorial, com 3 fatores cada (2^3 fatorial), para validação de conceitos e conhecimento das variáveis (fatores) e interações importantes para o método de impressão digital do Wi-Fi (RSS *fingerprint*). Desta forma, foram realizados 8 cenários (tratamentos) em cada bloco dos experimentos, para avaliar a influência dos níveis (valores) dos fatores (variáveis independentes) correspondentes e suas interações na variável resposta (variável dependente) - o **erro médio**.

4.4.1. Experimento 2D

O Experimento 2D foi dividido em 4 blocos, com o objetivo principal de avaliar o efeito de fatores ligados à fase *online* e *offline*, separadamente. As Tabelas 1 e 2 apresentam os níveis e fatores considerados nas blocagens nº1 e nº2, que contêm fatores relacionados, exclusivamente, à fase *online* do método RSS *fingerprint*.

Tabela 1: Fatores e níveis para o Bloco nº1 do Experimento 2D

Fator	Nível (-)	Nível (+)
Número de PAs	2	5
Número de leituras RSS	2	5
Algoritmo de aprendizagem de máquina	WKNN	Rede Neural

Os resultados do Bloco nº1 do Experimento 2D foram utilizados para fixação de parâmetros nos blocos e experimentos seguintes. A divisão em blocos foi motivada pela redução dos cenários (tratamentos) gerados a serem analisados a cada rodada do experimento.

Além do WKNN, outros métodos determinísticos, como Árvores de Decisão e Redes Neurais Artificiais, adequados para obtenção de modelos que não possuem uma distribuição normal ou gaussiana, foram utilizados na busca por erros médios menores na localização interna da fase *online*.

Informações temporais e espaciais podem ser usadas para restringir e corrigir a localização baseada em impressão digital de Wi-Fi. A última medição dos sinais (RSS) e sua consequente localização inferida, em termos de coordenadas cartesianas (x,y), ou seja, a posição anterior, pode ser utilizada como parâmetro se uma nova solicitação de localização for feita em seguida, como no Bloco nº2 do Experimento 2D. Pode-se utilizar este princípio para localização dinâmica de dispositivos móveis em tempo real, com o objetivo de melhorar a precisão da localização.

Tabela 2: Fatores e níveis para o Bloco nº2 do Experimento 2D

Fator	Nível (-)	Nível (+)
Medida de centralidade	Média	Mediana
Heurística de localização	Filtro RSS	Posição Anterior
Algoritmo de aprendizagem de máquina	Rede Neural	Floresta Randômica

Os Blocos nº3 e nº4 do Experimento 2D (Seção 5.1.1) foram definidos para avaliar o efeito de fatores ligados à fase *offline*, exclusivamente. O objetivo aqui foi identificar os fatores que mais influenciam na obtenção simplificada do mapa RSS (*radiomap*) na fase *offline*, visto que, o esforço empregado para obter o mapa dos sinais RSS do ambiente interno de interesse é um dos principais desafios para a ampla adoção desta abordagem para localização em ambientes internos. As Tabelas 3 e 4 apresentam os níveis e fatores considerados nas blocagens nº3 e nº4 do Experimento 2D.

Tabela 3: Fatores e níveis para o Bloco nº3 do Experimento 2D

Fator	Nível (-)	Nível (+)
Abordagem para leitura simplificada do <i>radiomap</i>	Radial	Central
Função de distância KNN para derivação do <i>radiomap</i>	Ponderada	Lognormal
Algoritmo de aprendizagem de máquina	WKNN	Floresta Randômica

Padrões espaciais estão relacionados à distribuição geográfica de sinais, além da simples representação do vetor RSS. Esses padrões incluem a ordem dos PAs no vetor RSS (PAs com sinal mais forte são listados primeiro), pontos de referência de sinal (próximos dos APs as medições de RSS são mais fortes) e cobertura de sinal, pois, a intensidade do sinal a certa distância do PA é geralmente semelhante.

Além disso, ponderar o sinal recebido dos PAs, tanto no *radiomap* quando no vetor obtido na fase *online*, como utilizado nos blocos nº3 e nº4 do Experimento 2D, pode reduzir o erro de localização causado pela semelhança dos sinais recebidos entre PAs distintos. Por exemplo, o vetor RSS composto por [-65, -75, -45] (PA1, PA2, PA3) tem a mesma distância do vetor representado por [-45, -75, -65], quando considerada a distância Euclidiana utilizada no método KNN, embora, no primeiro vetor, o ponto de interesse esteja mais próximo do PA3 que do PA1.

Tabela 4: Fatores e níveis para o Bloco nº4 do Experimento 2D

Fator	Nível (-)	Nível (+)
Abordagem para leitura simplificada do <i>radiomap</i>	Maior RSS	Coordenada XY
Função de distância KNN para derivação do <i>radiomap</i>	Ponderada	Lognormal
Algoritmo de aprendizagem de máquina	Rede Neural	WKNN

Ambientes internos maiores possuem variações de andares, acima e abaixo (subsolos). Desta forma, métodos adequados para localização interna devem considerar este fator no momento da estimação da posição de dispositivos móveis rastreados. Neste sentido, ampliamos o escopo do trabalho para considerar a localização em diversos andares no ambiente de interesse.

4.4.2. Experimento 3D

Neste sentido, o Experimento 3D utilizou os resultados relevantes do Experimento 2D realizado, para avaliar o efeito de novos fatores, como: a dependência de dispositivo entre as

fases *offline* e *online*; e, a ampliação da localização para 3 dimensões (coordenadas X, Y e Z). A Tabela 5 apresenta os níveis e fatores considerados no Experimento 3D, ligados exclusivamente à fase *online* do método RSS *fingerprint*.

Tabela 5: Fatores e níveis para o Experimento 3D

Fator	Nível (-)	Nível (+)
Dispositivo utilizado nas fases <i>offline</i> e <i>online</i>	Mesmo	Diferente
Tipo de localização	2D	3D
Algoritmo de aprendizagem de máquina	Rede Neural	Floresta Randômica

4.5. Parâmetros de execução

Para executar os cenários propostos no projeto de experimentos, foi implementado um algoritmo em Python 3.7 e utilizados os métodos KNeighborsRegressor, MLPRegressor e RandomForestRegressor da biblioteca sklearn. Alguns parâmetros passados aos métodos foram fixados após uma varredura realizada (ver Tabela 6), com o objetivo de obter melhores resultados para as medidas de interesse desejadas, como: o **erro médio** de localização (eficácia do método) e o tempo de processamento (eficiência no consumo de recursos) necessário para execução de cada cenário.

Estes cenários foram executados num computador HP pavilion com 12 GB de RAM e processador Intel dual core de 2.2GHz com sistema operacional Ubuntu 18.06.

Tabela 6: Parâmetros de execução utilizados

Método	Parâmetro	Valor
KNeighborsRegressor	n_neighbors (k)	(1 à 30)
KNeighborsRegressor	weights (w)	distance
KNeighborsRegressor	metric (m)	cosine
MLPRegressor	activation (a)	relu
MLPRegressor	solver (s)	lbfgs
MLPRegressor	hidden_layer_sizes (l)	25x25
MLPRegressor	random_state (r)	(1 à 30)
RandomForestRegressor	n_estimators (e)	50
RandomForestRegressor	random_state (r)	(1 à 30)

Ainda, em cada cenário realizado, fez-se uma varredura de parâmetros no método utilizado, para identificar, entre 1 e 30 (trinta), o K ideal para o `KNeighborsRegressor` e a semente de inicialização r mais eficaz, para os métodos `MLPRegressor` e `RandomForestRegressor`. Métodos campeões de competições, que utilizam Árvores de Decisão otimizadas, como Gradient Boosting, Histogram-Based Gradient Boosting, XGBoost, LigthGBM e CatBoost [50], não foram utilizados devido a limitação de matrizes unidimensionais para os valores da classe de resposta (y). Nos nossos experimentos, as classes de resposta são bidimensionais (coordenadas X e Y) e tridimensionais (coordenadas X , Y e Z).

Os resultados destes experimentos são apresentados na seção seguinte e servirão de base para a análise dos resultados obtidos.

5. APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

Nesta seção, são apresentados os resultados obtidos pelo projeto de experimentos detalhado na seção anterior e realizada a análise destes resultados.

5.1. Resultados

Através do DoE, foi possível analisar o efeito dos dois Níveis, valor menor (-) e valor maior (+), das Variáveis Aleatórias (Fatores A, B e C) utilizadas em cada um dos 4 blocos do Experimento 2D e do cenário único do Experimento 3D, sobre uma das variáveis de resposta do sistema: o **erro médio** da localização na fase *online* da abordagem de impressão digital do sinal de Wi-Fi (RSS *fingerprint*).

Os resultados são apresentados nas Tabelas 7 à 11, com diversas informações consolidadas, conforme discriminadas na Figura 11. Essa, apresenta os Tratamentos (cenários) considerados em cada Bloco, os Fatores (A, B e C) utilizados e seus respectivos Níveis (valores) menor (-) e maior (+), assim como, o efeito de cada fator e da interação entre eles na variável de resposta - o **erro médio**.

Tratamento nº	Fator A	Fator B	Fator C	Erro médio localização	Tempo de processamento
1	-	-	-	metro	0:00:00,000000
2	+	-	-	metro	0:00:00,000000
3	-	+	-	metro	0:00:00,000000
4	+	+	-	metro	0:00:00,000000
5	-	-	+	metro	0:00:00,000000
6	+	-	+	metro	0:00:00,000000
7	-	+	+	metro	0:00:00,000000
8	+	+	+	metro	0:00:00,000000
Efeito Principal	Fator A	Fator B	Fator C	-	-
Interação entre Fatores	AB	BC	AC	ABC	-

Figura 11: Identificação das informações apresentadas nas tabelas de resultados.

O tempo de processamento foi considerado também devido às limitações de recursos computacionais existentes em dispositivos móveis, o que pode ajudar na análise e escolha de fatores importantes para implementação de ILBS mais eficientes.

5.1.1. Experimento 2D

O Bloco nº1 do Experimento 2D considerou, para cada um dos 262 PRs do ambiente de interesse, 5 medições de RSS para cada um dos 5 PAs fixos – AP1, AP2, AP3, AP4 e AP5, sem utilização de média ou mediana das 5 medições de RSS feitas em sequência. Assim, foram utilizadas 1310 entradas no banco de dados de impressão digital (*radiomap*).

$$262 \text{ (PRs)} \times 5 \text{ (medições RSS)} = 1310 \quad (5)$$

Para a escolha dos 2 PAs no nível menor (-) do fator “Número de PAs”, foi feita uma varredura de parâmetros para identificar a combinação que apresentasse o melhor resultado no erro médio de localização. Desta forma, foram utilizados os PAs 1 e 2 - AP1 e AP2 (ver Figura 6). Já para o nível menor do fator “Número de leituras RSS”, foram utilizadas as 2 primeiras medições de RSS, para cada um dos PAs fixos do tratamento em questão.

De posse dos resultados apresentados na Tabela 7, podemos identificar os fatores principais e interações entre estes fatores com maior efeito na variável resposta de interesse - o **erro médio** de localização.

Tabela 7: Fatores, níveis e efeitos para o Bloco nº1 do Experimento 2D

Tratamento	Número de PAs	Número de leituras RSS	Algoritmo de aprendizagem	Erro médio localização	Tempo de processamento
1	2	2	WKNN	4,50	0:00:00,127319
2	5	2	WKNN	2,35	0:00:00,161739
3	2	5	WKNN	4,50	0:00:00,586045
4	5	5	WKNN	2,36	0:00:00,619738
5	2	2	Rede Neural	3,46	0:00:09,229822
6	5	2	Rede Neural	2,45	0:00:09,427446
7	2	5	Rede Neural	3,50	0:00:17,918568
8	5	5	Rede Neural	2,39	0:00:18,191312
Efeito	-1,6025	-0,0025	-0,4775	-	-
Interação	-0,0225	-0,0075	0,5425	0,0640	-

Observa-se pelo gráfico da Figura 12 que o Fator A - Número de PAs - foi o que teve o maior efeito na redução da variável de resposta. Quando utilizou-se todas as 5 PAs do ambiente, o erro médio foi reduzido em 1,6m. Desta forma, quanto mais PAs puderem ser utilizadas nas medições de RSS, menor será o erro médio de localização na fase *online*.




Figura 12: Efeitos principais e das interações dos Fatores (A, B e C) no Bloco nº1 do Experimento 2D.

Efeito semelhante ocorreu com o Fator C - Algoritmo de aprendizagem. Ao utilizarmos uma Rede Neural, no lugar do método WKNN, ocorreu uma redução de 0,47m no erro médio de localização. Além disso, a interação importante que ocorreu entre os Fatores A e C, sugere a utilização de mais PAs em conjunto com uma Rede Neural. Nestas condições, o menor erro médio foi de 2,39m, obtido no Tratamento nº8. Diante destes resultados, o Bloco nº2 do Experimento 2D, utilizou todas as 5 PAs disponíveis no ambiente interno de interesse e manteve a Rede Neural como um dos níveis do fator “Algoritmo de aprendizagem”.

Quanto ao tempo de processamento, observa-se que o mesmo aumenta à medida que mais PAs e mais leituras de RSS são utilizadas e que há um aumento nesta variável de resposta secundária quando se utiliza Rede Neural, em vez do método WKNN, como algoritmo de aprendizagem de máquina.

O Bloco nº2 do Experimento 2D considerou, para cada um dos 262 PRs do ambiente de interesse da fase *offline*, a Média ou a Mediana das 5 medições de RSS para cada um dos 5

PAs fixos – AP1, AP2, AP3, AP4 e AP5, dependendo do nível (-/+) do fator “Medida de centralidade” no tratamento em questão. Assim, foram utilizadas apenas 262 entradas no *radiomap*.

O nível “Filtro RSS” do fator “Heurística de localização” considerou, inicialmente, para cada PI da fase *online*, a PA com maior intensidade do RSS, e, a partir daí, filtrou as entradas no *radiomap* para aquelas em que o valor do RSS estivesse dentro da faixa do desvio padrão associado ao PA em questão. Uma análise descritiva completa foi realizada previamente (ver APÊNDICE A), para obtenção do desvio padrão associado a cada um dos 5 PAs fixos – AP1, AP2, AP3, AP4 e AP5 – obtendo os seguintes valores: 10,29; 8,53; 8,32; 9,23; e, 7,13, respectivamente. Utilizamos o desvio padrão por representar o quanto as medições de RSS obtidas para o PA em questão estão dispersas no ambiente de interesse. Assim, PAs com sinais mais dispersos, tiveram faixas maiores consideradas para aplicação do filtro RSS.

Para o nível “Pos.Anterior” do fator “Heurística de localização”, foi adicionada a posição anterior, em termos de coordenadas cartesianas (x,y), tanto nas entradas do mapa RSS da fase *offline*, seguindo a sequência de leitura dos PRs, quanto para os PIs da fase *online*. Nesse último caso, a atribuição da posição anterior foi feita de forma dinâmica, ou seja, para cada PI a ter a posição determina, adicionava-se a posição anterior, obtida pelo próprio método no passo anterior. Para o primeiro PI, consideramos a coordenada cartesiana (xy) correspondente à entrada principal do LASER.

Observa-se pela Tabela 8 e no gráfico da Figura 13, que o Fator B - Heurística de localização - foi o único com efeito importante na redução da variável de resposta. Ao se utilizar a posição anterior, em termos de coordenadas cartesianas (x,y), tanto nas entradas do mapa de rádio da fase *offline*, quanto para os PIs da fase *online*, o erro médio foi reduzido em 0,79m. Considerando este nível do Fator B, o menor erro médio foi de 1,31m, obtido no Tratamento nº7. Diante desta constatação, o Experimento 3D utilizou a posição anterior, tanto na fase *offline*, quanto na fase *online*, para realização dos tratamentos (cenários) considerados.

Tabela 8: Fatores, níveis e efeitos para o Bloco nº2 do Experimento 2D

Tratamento	Medida de centralidade	Heurística de localização	Algoritmo de aprendizagem	Erro médio localização	Tempo de processamento
1	Média	Filtro RSS	Rede Neural	2,18	0:05:14,204663
2	Mediana	Filtro RSS	Rede Neural	2,09	0:04:51,732322

3	Média	Pos.anterior	Rede Neural	1,32	0:00:05,477242
4	Mediana	Pos.anterior	Rede Neural	1,33	0:00:05,413971
5	Média	Filtro RSS	F.Randômica	2,10	0:03:34,107759
6	Mediana	Filtro RSS	F.Randômica	2,08	0:03:13,414442
7	Média	Pos.anterior	F.Randômica	1,31	0:00:03,792240
8	Mediana	Pos.anterior	F.Randômica	1,34	0:00:03,637888
Efeito	-0,0175	-0,7875	-0,0225	-	-
Interação	0,0375	-0,0225	-0,0225	0,0103	-




Figura 13: Efeitos principais e das interações dos Fatores (A, B e C) no Bloco nº2 do Experimento 2D.

Além da pouca eficácia do “Filtro RSS” como “Heurística de localização”, o tempo de processamento obtido, acima de 3 minutos, inviabiliza a sua utilização em ILBS para localização dinâmica (em tempo real) de dispositivos móveis.

O Bloco nº3 do Experimento 2D, voltado para a obtenção de um modelo simplificado para coleta e geração do *radiomap* na fase *Offline*, a partir de leituras mínimas de RSS em locais específicos do ambiente e derivação das demais medições a partir da aplicação do algoritmo KNN, considerou, para o nível “Radial” do fator “Abordagem do *radiomap*”, apenas as medidas de RSS para os cantos (*corners*) do vão principal e das duas salas do ambiente de interesse. Já o nível “Central” do mesmo fator, considerou apenas as medições centrais (linha reta ao centro de cada ambiente) do vão principal e das duas salas do ambiente.

Já o Fator “Função de distância KNN”, foi empregado para avaliar a métrica mais eficaz para geração do *radiomap*, se: a “Ponderada” pelo PA com base no desvio padrão; ou,

a função “Lognormal”, que se aproxima mais do efeito de atenuação sofrido pelos sinais de rádio.

Observa-se pela Tabela 9 e no gráfico da Figura 14, que o Fator A - Abordagem do *radiomap* - foi o que teve o maior efeito na redução da variável de resposta. Na abordagem Central, onde apenas as medições centrais (linha reta ao centro de cada ambiente) do vão principal e das duas salas do ambiente foram consideradas, o erro médio foi reduzido em 0,55m.

Tabela 9: Fatores, níveis e efeitos para o Bloco nº3 do Experimento 2D

Tratamento	Abordagem do radiomap	Função de distância knn	Algoritmo de aprendizagem	Erro médio localização	Tempo de processamento
1	Radial	Ponderada	WKNN	2,83	0:00:00,171332
2	Central	Ponderada	WKNN	2,57	0:00:00,122054
3	Radial	Lognormal	WKNN	3,11	0:00:00,265581
4	Central	Lognormal	WKNN	3,03	0:00:00,119881
5	Radial	Ponderada	F.Randômica	3,83	0:00:07,650510
6	Central	Ponderada	F.Randômica	2,75	0:00:07,755975
7	Radial	Lognormal	F.Randômica	3,62	0:00:07,625519
8	Central	Lognormal	F.Randômica	2,83	0:00:07,765500
Efeito	-0,5525	0,1525	0,3725	-	-
Interação	0,1175	-0,2175	-0,3825	0,0603	-




Figura 14: Efeitos principais e das interações dos Fatores (A, B e C) no Bloco nº3 do Experimento 2D.

Efeito semelhante ocorreu com o Fator C - Algoritmo de aprendizagem. O método WKNN, teve um desempenho de 0,37m melhor que a Floresta Randômica, na obtenção do erro médio de localização. Além disso, a interação importante que ocorreu entre os Fatores A e C, sugere a utilização da abordagem Central de obtenção do mapa RSS em conjunto com WKNN, como algoritmo de aprendizagem. Nestas condições, o menor erro médio foi de 2,57m, obtido no Tratamento nº2.

Quanto ao tempo de processamento, observa-se que o método WKNN possui uma execução quase que instantânea, abaixo de 1s, enquanto que a Floresta Randômica, leva mais de 7s para finalizar o processamento, considerando os valores discriminados na Seção 4.5 - Parâmetros de execução.

O Bloco nº4 do Experimento 2D, também voltado para a obtenção de um modelo simplificado para coleta e geração do *radiomap*, considerou, para o nível “Maior RSS” do fator “Abordagem do *radiomap*”, apenas as medidas de RSS a 1m de cada uma das 5 PAs no ambiente de interesse, por apresentarem, geralmente, a maior medida de RSS para o PA em questão. Já o nível “Coord. XY” do mesmo fator, além de utilizar a maior medida de RSS, adicionou a posição anterior, em termos de coordenadas cartesianas (x,y), tanto nas entradas do mapa de rádio da fase *offline*, quanto para os PIs da fase *online*.

Observa-se pela Tabela 10 e no gráfico da Figura 15, que o Fator A - Abordagem do *radiomap* - foi o único com efeito importante na redução da variável de resposta. Ao se utilizar a posição anterior, em termos de coordenadas cartesianas (x,y), tanto nas entradas do mapa de rádio da fase *offline*, quanto para os PIs da fase *online*, o erro médio foi reduzido em 1,21m. Considerando este nível do Fator A, o menor erro médio foi de 2,00m, obtido no Tratamento nº6.

Tabela 10: Fatores, níveis e efeitos para o Bloco nº4 do Experimento 2D

Tratamento	Abordagem do radiomap	Função de distância knn	Algoritmo de aprendizagem	Erro médio localização	Tempo de processamento
1	Maior RSS	Ponderada	Rede Neural	3,57	0:00:11,361985
2	Coord. XY	Ponderada	Rede Neural	2,04	0:00:12,086642
3	Maior RSS	Lognormal	Rede Neural	3,52	0:00:11,949605
4	Coord. XY	Lognormal	Rede Neural	2,15	0:00:11,815475
5	Maior RSS	Ponderada	WKNN	3,03	0:00:00,114876
6	Coord. XY	Ponderada	WKNN	2,00	0:00:00,124699
7	Maior RSS	Lognormal	WKNN	3,24	0:00:00,162806
8	Coord. XY	Lognormal	WKNN	2,31	0:00:00,125676

Efeito	-1,2150	0,1450	-0,1750	-	-
Interação	0,0650	0,1150	0,2350	0,0518	-




Figura 15: Efeitos principais e das interações dos Fatores (A, B e C) no Bloco nº4 do Experimento 2D.

Novamente, o método WKNN apresentou uma execução quase que instantânea, abaixo de 1s, enquanto que a Rede Neural levou mais de 11s para finalizar o processamento, considerando os valores informados na Seção 4.5 - Parâmetros de execução.

5.1.2. Experimento 3D

O Experimento 3D se beneficiou dos níveis e fatores que tiveram o melhor efeito na diminuição do erro médio de localização da fase *online*. Desta forma, foram utilizadas todas as 5 PAs disponíveis no ambiente interno de interesse e mantida a Rede Neural como um dos níveis do fator “Algoritmo de aprendizagem”, além de utilizar a posição anterior, tanto na fase *offline*, quanto na fase *online*, como forma de ratificar os resultados obtidos nos Blocos nº1 e nº2 do Experimento 2D.

Aqui, dois dispositivos distintos foram empregados para verificar a eficácia do método, mesmo utilizando um dispositivo, na fase *online*, diferente do que fez a obtenção do mapa RSS na fase *offline*.

Ainda, verificou-se a manutenção da eficácia do método para localização em 3 dimensões, através da adição da coordenada Z nas entradas do *radiomap* e adaptação dos algoritmos de regressão da fase *online* para gerar resultados em 3 dimensões - eixos X, Y e Z.

Observa-se pela Tabela 11 e no gráfico da Figura 16, que o Fator A - Dispositivo utilizado - foi o que teve o maior efeito na variável de resposta. Ao utilizar um outro dispositivo móvel, diferente do que fez a obtenção do *radiomap*, o erro médio foi maior em 0,13m.

Tabela 11: Fatores, níveis e efeitos para o Experimento 3D

Tratamento	Dispositivo utilizado	Tipo de localização	Algoritmo de aprendizagem	Erro médio localização	Tempo de processamento
1	Mesmo	2D	Rede Neural	1,08	0:00:04.441581
2	Diferente	2D	Rede Neural	1,18	0:00:04.167611
3	Mesmo	3D	Rede Neural	1,15	0:00:04.417994
4	Diferente	3D	Rede Neural	1,18	0:00:04.667663
5	Mesmo	2D	F.Randômica	1,11	0:00:02,960969
6	Diferente	2D	F.Randômica	1,32	0:00:02,809078
7	Mesmo	3D	F.Randômica	1,07	0:00:02,963999
8	Diferente	3D	F.Randômica	1,27	0:00:02.849630
Efeito	0,1350	-0,0005	0,0450	-	-
Interação	-0,0200	-0,0400	0,0700	0,0013	-




Figura 16: Efeitos principais e das interações dos Fatores (A, B e C) do Experimento 3D.

Outro efeito a destacar foi o do Fator C - Algoritmo de aprendizagem. A Rede Neural teve um desempenho de 0,05m melhor que a Floresta Randômica no erro médio de

localização. Como esse efeito é muito pequeno no erro médio de localização, apenas 5cm, a interação importante que ocorreu entre os Fatores A e C sugere a utilização do mesmo dispositivo nas fases *offline* e *online* em conjunto com uma Rede Neural ou Floresta Randômica. Nestas condições, o menor erro médio foi de 1,08m, obtido no Tratamento nº1 com uma Rede Neural, e 1,07m no Tratamento nº7 ao utilizar uma Floresta Randômica.

A diferença maior entre esses dois métodos de aprendizagem de máquina está no tempo de processamento, onde observa-se que a Rede Neural possui uma execução duas vezes mais demorada que a Floresta Randômica, considerando os valores discriminados na Seção 4.5 - Parâmetros de execução.

Embora o fator “Tipo de localização” - 2D ou 3D - não tenha apresentado efeito considerável sobre o erro médio de localização, verificamos que o erro médio máximo individual associado ao eixo Z, na localização em 3 dimensões (3D), não chegou a 1m (ver Tabela 12), o que não seria suficiente para configurar um erro na identificação do andar, visto que o pé direito dos pavimentos do LASER chega a 3m.

Tabela 12: Erro médio mínimo e máximo associado ao eixo Z do Experimento 3D

Tratamento	Dispositivo utilizado	Algoritmo de aprendizagem	Erro mínimo Eixo Z	Erro máximo Eixo Z
3	Mesmo	Rede Neural	0,31	0,62
4	Diferente	Rede Neural	0,38	0,94
7	Mesmo	F.Randômica	0,08	0,14
8	Diferente	F.Randômica	0,15	0,24

As Figuras 17 e 18 consolidam os resultados obtidos nos 4 blocos do Experimento 2D e no Experimento 3D.

Tratamento	Bloco nº1	Bloco nº2	Bloco nº3	Bloco nº4	3D
1	4,50	2,18	2,83	3,57	1,08
2	2,35	2,09	2,57	2,04	1,18
3	4,50	1,32	3,11	3,52	1,15
4	2,36	1,33	3,03	2,15	1,18
5	3,46	2,10	3,83	3,03	1,11
6	2,45	2,08	2,75	2,00	1,32
7	3,50	1,31	3,62	3,24	1,07
8	2,39	1,34	2,83	2,31	1,27

Figura 17: Mapa de calor para os tratamentos realizados no DoE.




Figura 18: Variação dos resultados obtidos em cada experimento.

Através da Figura 17, que apresenta um mapa de calor com os erros médios obtidos em cada um dos tratamentos realizados, fica fácil identificar os cenários com os melhores resultados, destacados com fundo verde. A Figura 18 apresenta um gráfico de box plot, representando as variações do erro médio obtido em cada bloco do Experimento 2D e no bloco único do Experimento 3D.

6. CONCLUSÕES E TRABALHOS FUTUROS

O objetivo geral deste trabalho de pesquisa foi, através de um projeto de experimentos, identificar a abordagem mais adequada para prover um serviço baseado em localização interna - ILBS - para dispositivos móveis, com **erro médio** dentro da faixa de 1 metro, utilizando a técnica de impressão digital do sinal de Wi-Fi - RSS *fingerprint* - no ambiente interno de interesse e algoritmos de aprendizagem de máquina.

Conforme pode ser verificado através das Figuras 17 e 18, os resultados obtidos (**Erro médio de 1,08m, obtido no Tratamento nº1 do Experimento 3D, e de 1,07 no Tratamento nº7**) apontam para uma precisão de posicionamento compatível com as técnicas de localização em ambientes internos que usam Wi-Fi *fingerprint* (ver Figura 4) e com o objetivo geral da pesquisa - obter uma abordagem para ILBS com **erro médio** dentro da faixa de 1 metro.

Para chegar nestes resultados, analisamos os fatores (e interações entre eles) com maior influência na minimização do erro médio para localização interna e utilizamos este aprendizado na execução dos experimentos seguintes. Fatores relevantes, como o número de PAs utilizado e a informação da posição anterior, tanto na montagem do mapa RSS da fase *offline*, quanto na localização dinâmica da fase *online*, contribuíram significativamente para sairmos de um erro médio máximo de 4,5m, obtido no Bloco nº1 do Experimento 2D (ver Figura 18), para 1,07m de erro médio mínimo, obtido no Experimento 3D.

Os motivos para os blocos do Experimento 2D terem apresentado um erro médio maior, se comparado ao Experimento 3D, devem-se principalmente à volatilidade do sinal em um ambiente com um área bem mais ampla e à maior quantidade de localizações diferentes com RSS semelhantes, derivadas da propagação característica dos sinais de rádio. Neste sentido, experimentos adicionais podem ser realizados para verificar o efeito da diminuição do espaço amostral do *radiomap* para as entradas próximas da localização atual/anterior conhecida.

Algoritmos de aprendizagem de máquina, como WKNN, Redes Neurais Artificiais e Árvore de Decisão (Floresta Randômica), foram avaliados quanto a sua eficiência (tempo de

processamento) e eficácia (**erro médio**), para localização de dispositivos móveis na fase *online*, sendo os dois últimos, os que apresentaram os melhores resultados para redução do erro médio - 1,08m e 1,07m, respectivamente, no Experimento 3D (ver Figura 17).

Uma limitação a ser destacada, é o tempo de processamento necessário para utilização de uma Rede Neural ou Floresta Randômica, aproximadamente 5min e 3min, respectivamente, obtidos no Bloco nº2 do Experimento 2D (ver Tabela 8), o que pode inviabilizar sua utilização em sistemas dinâmicos de localização em tempo real. Em contrapartida, o método WKNN, utilizado no Bloco nº1 do Experimento 2D (ver Tabela 7), mesmo com um *radiomap* maior (1310 entradas), entregou os resultados de forma quase instantânea, próximo de 0,5s. Outro ponto a favor do método WKNN é a simplicidade do seu algoritmo, o que permite a sua implementação em dispositivos móveis com limitação de recursos e sem a necessidade de utilização de bibliotecas de terceiros.

Um ponto de atenção no uso do método WKNN, é quanto ao seu desempenho ao utilizar um *radiomap* com muitas entradas, já que o mesmo faz o cálculo de distância para cada entrada no banco de dados de impressões digitais. Nesta situação, Redes Neurais de Aprendizagem Profunda (do inglês *Deep Learning*), como CNN e LSTM, podem ser empregadas para verificar a sua eficiência e eficácia na fase *online* de localização, visto que são métodos não paramétricos, ou seja, independem da quantidade de entradas no *radiomap*, e a fase de treinamento destas redes, que demanda tempo e recursos de processamento, pode ser feita em um servidor dedicado e a rede, já treinada, importada para o dispositivo móvel que irá utilizar o ILBS.

Experimentos complementares podem ser realizados com o objetivo de encontrar os parâmetros ideais para a Rede Neural e a Floresta Randômica, tornando-as especializadas na localização em tempo real e com tempos de processamento aceitáveis para posicionamento dinâmico.

Ao contrário de outros trabalhos relacionados, que concentram esforços apenas em uma das fases do RSS *fingerprint*, nossa pesquisa buscou contribuições, tanto na fase de localização do dispositivo móvel no ambiente interno (fase *online*), quanto na fase de construção do mapa de sinais do ambiente (fase *offline*).

Neste sentido, identificamos uma abordagem simplificada para coleta do *radiomap* na fase *offline*, o que pode facilitar o uso da técnica de impressão digital do Wi-Fi, visto que esta etapa consome muito tempo e recursos para ser executada.

Um erro médio próximo de 2m foi obtido no Bloco nº4 do Experimento 2D (ver Tabela 10), após apenas 5 leituras à 1m de cada um dos 5 PAs disponíveis no ambiente interno de interesse e utilizando a informação da posição anterior, o que representa uma excelente abordagem na redução do esforço necessário para obtenção do *radiomap* na fase *offline*.

Experimentos adicionais podem ser planejados para avaliar outros métodos de aprendizagem de máquina e identificar os mais adequados para geração dos pontos virtuais do *radiomap*, a partir de pontos reais mínimos, medidos no ambiente de interesse.

No Experimento 3D, a abordagem utilizada se mostrou adequada para tratar a variação na intensidade do sinal de Wi-Fi recebido (RSS), que pode ocorrer entre dispositivos móveis diferentes, pois, o incremento no erro médio ao utilizar dispositivos diferentes, na fase *offline* e *online*, foi de apenas 13cm.

Ainda no Experimento 3D, pudemos verificar a validade do método para ambientes com vários níveis ou andares, pois houve um efeito negativo no erro médio de 5cm apenas. Assim, a dimensão dos dados de entrada foi aumentada e a estabilidade do sistema de posicionamento interno foi melhorada.

Ainda, analisando o erro médio apenas para o eixo Z, observou-se um valor máximo de 0,94m, o que não configura uma localização equivocada de andar, comprovando sua total aplicabilidade para detecção de pavimento em ambientes com mais de um nível.

Os resultados do Experimento 3D (ver Figura 18) apresentaram os menores erros entre os cenários analisados (1,07m) e mostrou um erro de posicionamento máximo de 1,32m. O erro de posicionamento ficou 75% em 1,20m e 100% dentro de 1,3m, o que atende ao requisito de posicionamento para ambientes internos com vários pavimentos. Ainda, foi o cenário que apresentou a menor variação entre os valores máximos e mínimos obtidos.

Assim, verificamos que nosso trabalho trouxe contribuições significativas para utilização de abordagens de localização interna, tanto para ambientes menores com vários andares (casas e apartamentos), como no Experimento 3D, onde o erro médio ficou próximo

de 1m; quanto para ambientes maiores e mais amplos (edifícios e shopping centers), onde a abordagem de medição proporcional ao número de PAs disponíveis no ambiente de interesse, apresentou um erro médio próximo de 2m, o que reduz enormemente o esforço de mapeamento dos sinais na fase *offline*.

Análises comparativas adicionais, utilizando bases de dados de impressões digitais públicas, contendo erros médios obtidos por outros métodos, podem ser conduzidas para verificar a eficácia da nossa abordagem em relação aos métodos empregados por outros pesquisadores.

Outro experimento para execução em trabalhos futuros, é a utilização da impressão digital do campo magnético gerado pela infraestrutura dos ambientes internos, por ser menos suscetível a variações que os sinais do Wi-Fi. Como apresentado em trabalhos relacionados que utilizaram esta informação, além da impressão digital do Wi-Fi, espera-se que o erro médio de localização pode ser reduzido até a faixa de centímetros.

REFERÊNCIAS

- [1] Ali Yassin, Youssef Nasser, Mariette Awad, Ahmed Al-Dubai, Ran Liu, Chau Yuen, Ronald Raulefs, and Elias Aboutanios. 2017. Recent Advances in Indoor Localization: A Survey on Theoretical Approaches and Applications. *IEEE COMMUNICATIONS SURVEYS & TUTORIALS*, VOL. 19, NO. 2, SECOND QUARTER 2017, 1327–1346.
- [2] Long Vu-Hoang, Hung Nguyen-Manh, Chinh Phan-Duy, Dung Le-Quang, Thanh Do-Van, Vinh Tran-Quang. 2014. A New Technique to Enhance Accuracy of WLAN Fingerprinting Based Indoor Positioning System, 2014 IEEE 5th International Conference on Communications and Electronics, *IEEE ICCE* 2014.
- [3] Suining He, Student Member, IEEE, and S.-H. Gary Chan. 2016. Wi-Fi Fingerprint-Based Indoor Positioning: Recent Advances and Comparisons. *IEEE COMMUNICATIONS SURVEYS & TUTORIALS*, VOL. 18, NO. 1, FIRST QUARTER 2016, 466-490.
- [4] Atreyi Bose and Chuan Heng Foh. A Practical Path Loss Model For Indoor WiFi Positioning Enhancement. School of Computer Engineering. Nanyang Technological University. Singapore.
- [5] Sebastian Thrun, Wolfram Burgard and Dieter Fox. Probabilistic Robotics. The MIT Press. Cambridge, Massachusetts. London, England.
- [6] Jung S Lee C Han D. 2011. Wi-Fi fingerprint-based approaches following log-distance path loss model for indoor positioning. 2011 IEEE MTT-S International Microwave Workshop Series on Intelligent Radio for Future Personal Terminals, *IMWS-IRFPT* 2011.
- [7] Junglas, Iris & Watson, Richard. (2008). Location-based services. *Commun. ACM*. 51. 65-69. 10.1145/1325555.1325568.
- [8] Upadhyaya, S.D. & Pettygrove, Stuart & W. Oliveira, J & R. Jahn, B. (2018). AN INTRODUCTION - GLOBAL POSITIONING SYSTEM.
- [9] Jörg, Eberspächer & Vögel, Hans-Jörg & Bettstetter, Christian & Hartmann, Christian. (2009). *GSM - Architecture, Protocols and Services* (3. ed.).

- [10] Mainetti, Luca & Patrono, Luigi & Sergi, Ilaria. (2015). A survey on indoor positioning systems. 2014 22nd International Conference on Software, Telecommunications and Computer Networks, SoftCOM 2014. 111-120. 10.1109/SOFTCOM.2014.7039067.
- [11] "Insiteo," 2015. [Online]. Disponível em: <http://www.insiteo.com/>
- [12] "Wifarer," 2015. [Online]. Disponível em: <http://www.wifarer.com/>
- [13] "Pole star," 2015. [Online]. Disponível em: www.polestar.eu/en/
- [14] "Infsoft," 2015. [Online]. Disponível em: <http://www.infsoft.com/>
- [15] "Navizon," 2015. [Online]. Disponível em: <https://www.navizon.com/>
- [16] "Skyhook," 2015. [Online]. Disponível em: <http://www.skyhookwireless.com/>
- [17] P. Bahl and V. N. Padmanabhan, "RADAR: An in-building RF-based user location and tracking system," Microsoft Research , 2005
- [18] T. King, S. Kopf, T. Haenselmann, C. Lubberger, and W. Effelsberg, "COMPASS: A probabilistic indoor positioning system based on 802.11 and digital compasses," in Proc. 1st ACM Int. Workshop Wireless Netw. Testbeds Exp. Eval. Characterization (WiNTECH) , Los Angeles, CA, USA, 2006, pp. 34–40.
- [19] Zebra Technology Company. 2008 [Online]. Disponível em: <http://www.wherenet.com/>
- [20] Vladislav Tananaev, Denis Tananaev e Oksana Kutkina. Localization with Deep Learning. Master project. Albert Ludwigs University of Freiburg. September 2016.
- [21] C. Laoudias, A. Moreira, S. Kim, S. Lee, L. Wirola and C. Fischione, "A Survey of Enabling Technologies for Network Localization, Tracking, and Navigation," in *IEEE Communications Surveys & Tutorials*, vol. 20, no. 4, pp. 3607-3644, Fourthquarter 2018.
- [22] P. Davidson and R. Piché, "A Survey of Selected Indoor Positioning Methods for Smartphones," in *IEEE Communications Surveys & Tutorials*, vol. 19, no. 2, pp. 1347-1370, Secondquarter 2017.

- [23] F. Pereira, A. Moreira, and M. Ricardo, "Evaluating location fingerprinting methods for underground GSM networks deployed over leaky feeder," in *Proc. Int. Conf. Indoor Position. Indoor Navig. (IPIN)*, 2011, pp. 1–6.
- [24] J. Torres-Sospedra, R. Montoliu, S. Trilles, Ó. Belmonte, and J. Huerta, "Comprehensive analysis of distance and similarity measures for Wi-Fi fingerprinting indoor positioning systems," *Expert Syst. Appl.*, vol. 42, no. 23, pp. 9263–9278, 2015.
- [25] M. Youssef and A. Agrawala, "The Horus WLAN location determination system," in *Proc. 3rd ACM Int. Conf. Mobile Syst. Appl. Services (Mobisys)*, 2005, pp. 205–218.
- [26] F. Al-homayani and M. Mahoor, "Improved indoor geomagnetic field fingerprinting for smartwatch localization using deep learning," *2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Nantes, 2018, pp. 1-8.
- [27] D. Nguyen, R. D. Charette, F. Nashashibi, T. Dao and E. Castelli, "Wifi fingerprinting localization for intelligent vehicles in car park," *2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Nantes, 2018, pp. 1-6.
- [28] X. Gan, B. Yu, S. Li, Q. Jiang and L. Huang, "Object recognition and simultaneous indoor location algorithm with stereo camera," *2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*, Wuhan, 2018, pp. 1-6.
- [29] W. Liu, J. Li, Z. Deng and X. Fu, "Fusion algorithm of improved fingerprinting/PDR/Map based on Extended Kalman Filter (EKF)/Particle Filter(PF)," *2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*, Wuhan, 2018, pp. 1-8.
- [30] W. Shao, H. Luof, F. Zhao, C. Wang, A. Crivello and M. Z. Tunio, "DePos: Accurate orientation-Free Indoor Positioning with Deep Convolutional Neural Networks," *2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*, Wuhan, 2018, pp. 1-7.
- [31] Y. Tao, L. Zhao, Q. Zhang and Z. Chen, "Wi-Fi Fingerprint Database Refinement Method and Performance Analysis," *2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*, Wuhan, 2018, pp. 1-6.
- [32] S. Zhang, J. Guo, W. Wang and J. Hu, "Indoor 2.5D Positioning of WiFi Based on SVM," *2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*, Wuhan, 2018, pp. 1-7.

- [33] Y. Zhang, J. Chen and W. Xue, "Unsupervised indoor localization based on Smartphone Sensors, iBeacon and Wi-Fi," *2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*, Wuhan, 2018, pp. 1-8.
- [34] T. Takayama, T. Umezawa, N. Komuro and N. Osawa, "An Indoor Positioning Method Based on Regression Models with Compound Location Fingerprints," *2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*, Wuhan, 2018, pp. 1-7.
- [35] S. Li *et al.*, "TDOA-based passive localization of standard WiFi devices," *2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*, Wuhan, 2018, pp. 1-5.
- [36] J. Bi, Y. Wang, X. Li, H. Qi, H. Cao and S. Xu, "A novel adaptive weighted K-nearest neighbor positioning method based on omnidirectional fingerprint database and twice affinity propagation clustering," *2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*, Wuhan, 2018, pp. 1-9.
- [37] H. lu, G. Xingli, L. shuang, Z. heng, L. Yaning and Z. Ruihui, "Indoor Positioning Technology based on Deep Neural Networks," *2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*, Wuhan, 2018, pp. 1-6.
- [38] Evaluating AAL Systems through Competitive Benchmarking [online] Available: <http://evaal.aalooa.org/>.
- [39] Microsoft Indoor Localization Competition [online] Available: <https://www.microsoft.com/en-us/research/event/microsoft-indoor-localization-competition-ipsn-2018/>.
- [40] ARKit [online] Available: <https://developer.apple.com/arkit/>.
- [41] N. Moayeri, C. Li and L. Shi, "PerfLoc (Part 2): Performance Evaluation of the Smartphone Indoor Localization Apps," *2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Nantes, 2018, pp. 1-8.
- [42] F. Potortì, A. Crivello, P. Barsocchi and F. Palumbo, "Evaluation of Indoor Localisation Systems: Comments on the ISO/IEC 18305 Standard," *2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Nantes, 2018, pp. 1-7.
- [43] D. V. Le, N. Meratnia and P. J. M. Havinga, "Unsupervised Deep Feature Learning to Reduce the Collection of Fingerprints for Indoor Localization Using Deep Belief

Networks," 2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN), Nantes, 2018, pp. 1-7.

- [44] G. Minaev, A. Visa and R. Piché, "Comprehensive survey of similarity measures for ranked based location fingerprinting algorithm," *2017 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Sapporo, 2017, pp. 1-4.
- [45] F. Dwiya and M. Lim, "A survey of problems and approaches in wireless-based indoor positioning," *2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Alcalá de Henares, 2016, pp. 1-7.
- [46] G. Caso, L. De Nardis, F. Lemic, V. Handziski, A. Wolisz and M. Di Benedetto, "ViFi: Virtual Fingerprinting WiFi-based Indoor Positioning via Multi-Wall Multi-Floor Propagation Model," in *IEEE Transactions on Mobile Computing*.
- [47] A. H. Salamah, M. Tamazin, M. A. Sharkas and M. Khedr, "An enhanced WiFi indoor localization system based on machine learning," *2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Alcalá de Henares, 2016, pp. 1-8.
- [48] J. Jang and S. Hong, "Indoor Localization with WiFi Fingerprinting Using Convolutional Neural Network," *2018 Tenth International Conference on Ubiquitous and Future Networks (ICUFN)*, Prague, 2018, pp. 753-758.
- [49] Entenda o que é DOE – Design of Experiments [Online]. Disponível em: <https://www.escolaedti.com.br/entenda-o-que-e-doe>
- [50] Gradient Boosting with Scikit-Learn, XGBoost, LightGBM, and CatBoost. Jason Brownlee on April 1, 2020 in Ensemble Learning [Online]. Disponível em: <https://machinelearningmastery.com/gradient-boosting-with-scikit-learn-xgboost-lightgbm-and-catboost/>
- [51] Q. Liang e M. Liu, "An Automatic Site Survey Approach for Indoor Localization Using a Smartphone", em *IEEE Transactions on Automation Science and Engineering* , vol. 17, não. 1, pp. 191-206, janeiro de 2020, doi: 10.1109 / TASE.2019.2918030.
- [52] Y. Yu et al., "Precise 3D Indoor Localization Based on Wi-Fi FTM and Built-in Sensors," in *IEEE Internet of Things Journal*, doi: 10.1109/JIOT.2020.2999626.
- [53] F. Liu et al., "Survey on WiFi-based indoor positioning techniques," in *IET Communications*, vol. 14, no. 9, pp. 1372-1383, 26 2020, doi: 10.1049/iet-com.2019.1059.

- [54] S. Dai, L. He and X. Zhang, "Autonomous WiFi Fingerprinting for Indoor Localization," 2020 ACM/IEEE 11th International Conference on Cyber-Physical Systems (ICCPS), Sydney, Australia, 2020, pp. 141-150, doi: 10.1109/ICCPS48487.2020.00021.

- [55] X. Zhu, W. Qu, T. Qiu, L. Zhao, M. Atiquzzaman and D. O. Wu, "Indoor Intelligent Fingerprint-based Localization: Principles, Approaches and Challenges," in IEEE Communications Surveys & Tutorials, doi: 10.1109/COMST.2020.3014304.

APÊNDICE A - Análise descritiva do mapa RSS (experimento 2D)

Após a obtenção do mapa RSS do Experimento 2D, foram feitas análises sobre a distribuição dos sinais dos 5 PAs no ambiente de interesse. Para facilitar esta análise, foi utilizada a mediana das 5 leituras sucessivas realizadas em cada um dos 262 pontos de referência. Foi utilizada a mediana por ser menos sensível a valores extremos (*outliers*). O resultado desta análise descritiva pode ser vista nas figuras 1 à 5 abaixo. Os tons de verde denotam valores maiores do RSS obtido na posição em questão, enquanto que os tons de vermelho apresentam valores mais baixos de RSS, o que sugere pontos de referência (PRs) mais distantes do PA em análise.

Medições de RSS são valores negativos. Assim, valores de RSS maiores indicam maior proximidade de um determinado PA (por exemplo, RSS de -65 representa uma distância mais próxima de um determinado PA, comparado ao RSS de -85).

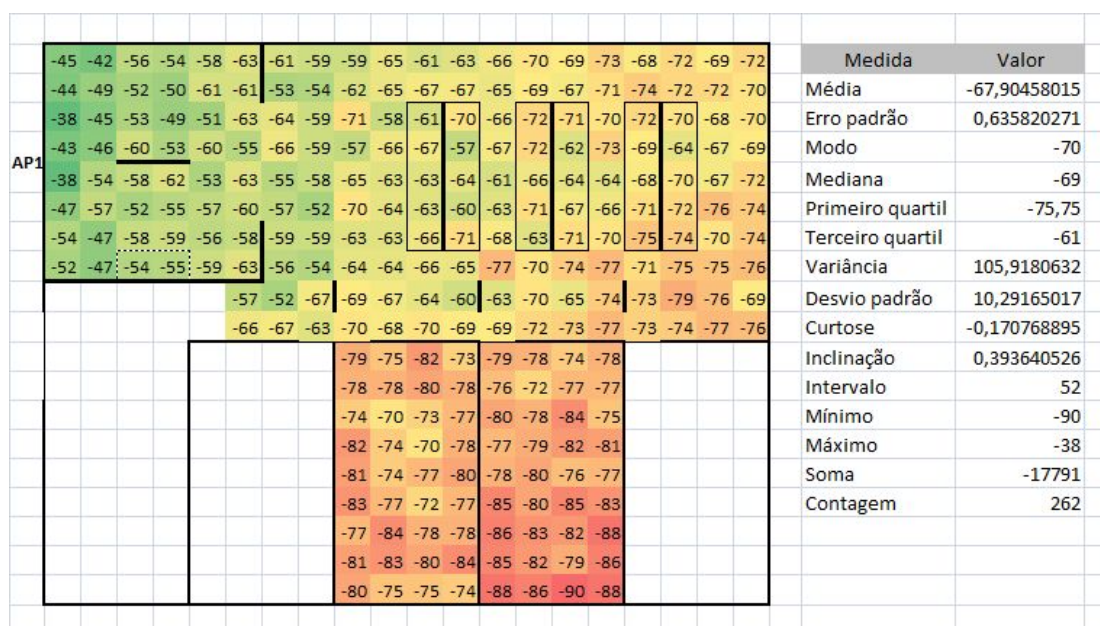


Figura 1: Análise descritiva das medições de RSS para o PA1.

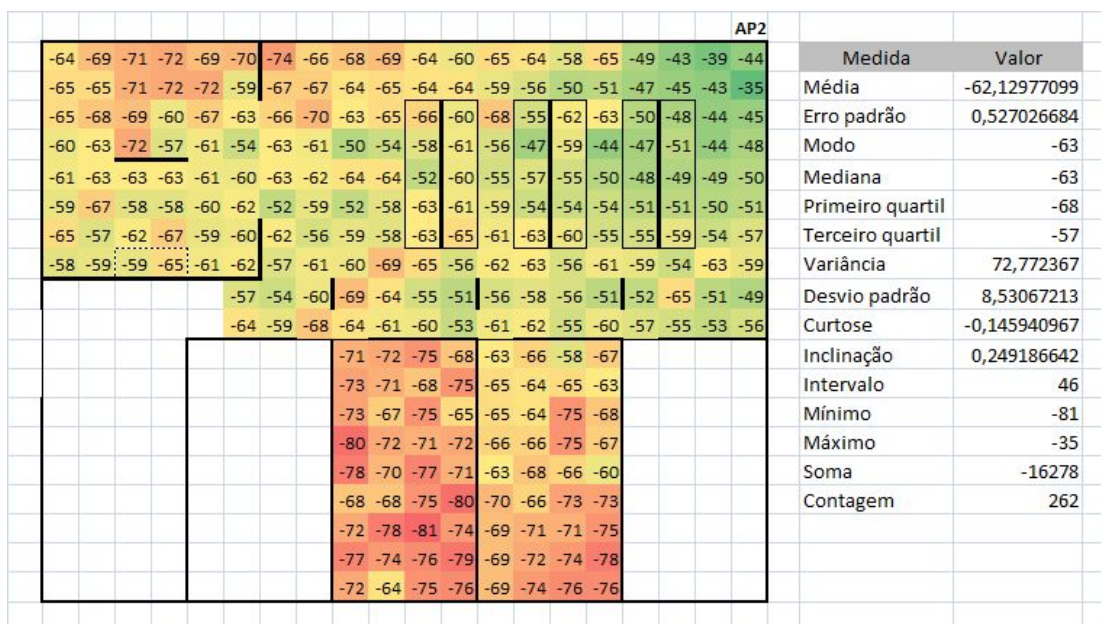


Figura 2: Análise descritiva das medições de RSS para o PA2.

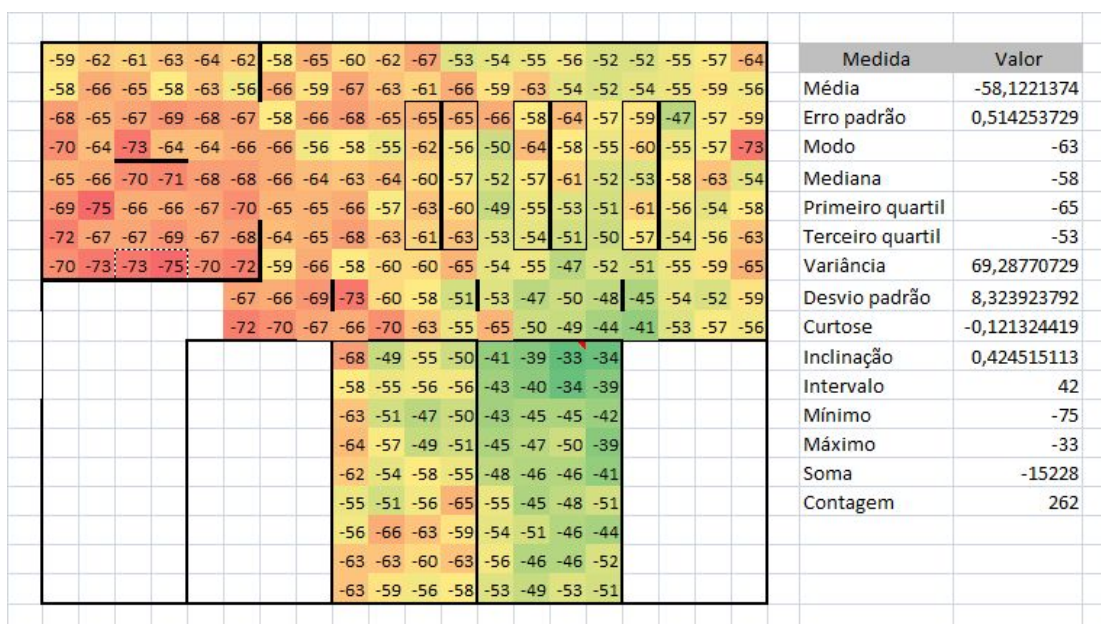


Figura 3: Análise descritiva das medições de RSS para o PA3.

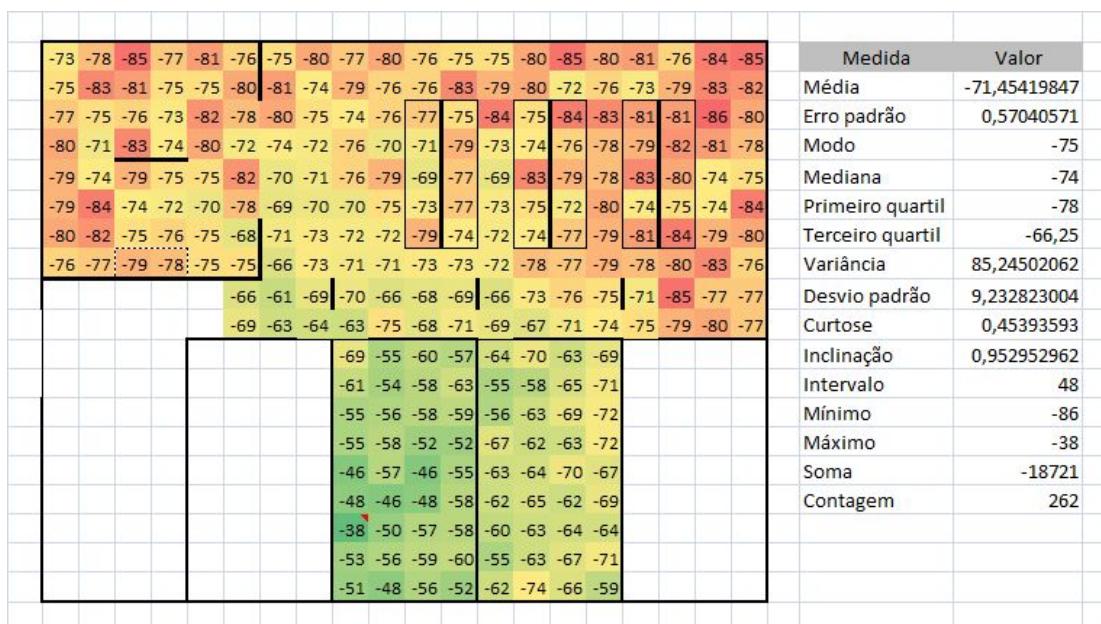


Figura 4: Análise descritiva das medições de RSS para o PA4.

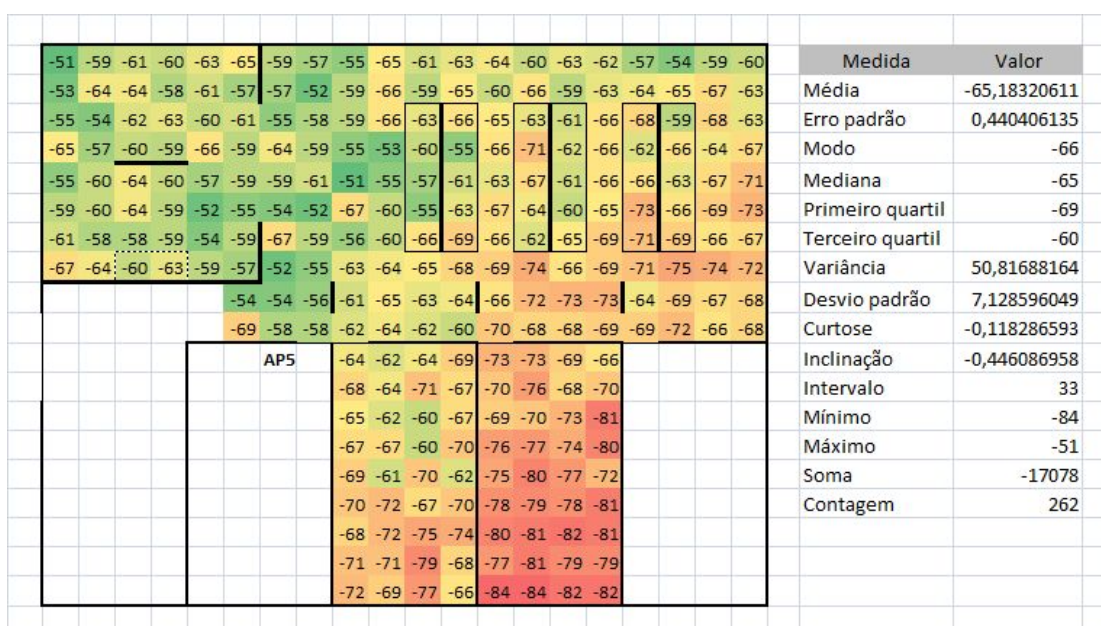


Figura 5: Análise descritiva das medições de RSS para o PA5.

Desta análise foi possível verificar que a propagação dos sinais de Wi-Fi, para todos os 5 PAs utilizados no experimento, não segue uma distribuição padrão ou uniforme, o que corrobora com a inadequação dos modelos baseados em distância para estimar a posição de um dispositivo móvel em ambientes internos, com móveis, paredes entre os ambientes e/ou pessoas circulando.