



UNIVERSIDADE FEDERAL DO AMAZONAS
FACULDADE DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Localização em Ambientes Semiabertos com Redução
de Esforço por Super-Resolução e Fusão de Sinais Wi-Fi
e FM Baseada na Distribuição Nakagami-m

David Alan de Oliveira Ferreira

Orientador
Prof. Dr. Celso Barbosa Carvalho

Manaus - AM
2024

David Alan de Oliveira Ferreira

Localização em Ambientes Semiabertos com Redução
de Esforço por Super-Resolução e Fusão de Sinais Wi-Fi
e FM Baseada na Distribuição Nakagami-m

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Doutor em Engenharia Elétrica na área de concentração Controle e Automação de Sistemas.

Orientador
Prof. Dr. Celso Barbosa Carvalho

Manaus - AM
2024

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

F383l Ferreira, David Alan de Oliveira
Localização em ambientes semiabertos com redução de esforço por super-resolução e fusão de sinais Wi-Fi e FM baseada na distribuição Nakagami-m / David Alan de Oliveira Ferreira . 2024
68 f.: il. color; 31 cm.

Orientador: Celso Barbosa Carvalho
Tese (Doutorado em Engenharia Elétrica) - Universidade Federal do Amazonas.

1. Localização indoor e semiaberta. 2. Fusão de dados. 3. Redes neurais convolucionais. 4. Super-resolução de imagens. 5. Sistemas de posicionamento Wi-Fi. I. Carvalho, Celso Barbosa. II. Universidade Federal do Amazonas III. Título



Ministério da Educação
Universidade Federal do Amazonas
Coordenação do Programa de Pós-Graduação em Engenharia Elétrica

FOLHA DE APROVAÇÃO

Poder Executivo Ministério da Educação
Universidade Federal do Amazonas
Faculdade de Tecnologia
Programa de Pós-graduação em Engenharia Elétrica

Pós-Graduação em Engenharia Elétrica. Av. General Rodrigo Octávio Jordão Ramos, nº 3.000 - Campus Universitário, Setor Norte - Coroado, Pavilhão do CETELI. Fone/Fax (92) 99271-8954 Ramal:2607. E-mail: ppgee@ufam.edu.br

DAVID ALAN DE OLIVEIRA

LOCALIZAÇÃO EM AMBIENTES SEMIABERTOS COM REDUÇÃO DE ESFORÇO POR SUPER-RESOLUÇÃO E FUSÃO DE SINAIS WI-FI E FM BASEADA NA DISTRIBUIÇÃO NAKAGAMI-M

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Doutor em Engenharia Elétrica na área de concentração Controle e Automação de Sistemas.

Aprovada em 20 de dezembro de 2024.

BANCA EXAMINADORA

Prof. Dr. Celso Barbosa Carvalho- Presidente
Prof. Dr. Raimundo da Silva Barreto - Membro Titular 1 - Externo
Prof. Dr. Juan Gabriel Colonna - Membro Titular 2 - Externo
Prof. Dr. Waldir Sabino da Silva Júnior - Membro Titular 3 - Interno
Prof. Dr. Kenny Vinente dos Santos - Membro Titular 4 - Interno

Documento assinado eletronicamente

Manaus, 09 de dezembro de 2024.



Documento assinado eletronicamente por **Raimundo da Silva Barreto, Professor do Magistério Superior**, em 14/01/2025, às 15:16, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Juan Gabriel Colonna, Professor do Magistério Superior**, em 03/02/2025, às 17:24, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Celso Barbosa Carvalho, Professor do Magistério Superior**, em 06/02/2025, às 10:33, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Kenny Vinente dos Santos, Professor do Magistério Superior**, em 06/02/2025, às 11:07, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Waldir Sabino da Silva Júnior, Professor do Magistério Superior**, em 07/02/2025, às 15:28, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufam.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2365078** e o código CRC **B8DB3AD0**.

Av. Octávio Hamilton Botelho Mourão - Bairro Coroadó 1 Campus Universitário Senador Arthur Virgílio Filho,
Setor Norte - Telefone: (92) 3305-1181
CEP 69080-900 Manaus/AM - mestrado_engletrica@ufam.edu.br

Referência: Processo nº 23105.051154/2024-72

SEI nº 2365078

Criado por [31183646291](#), versão 3 por [31183646291](#) em 09/12/2024 15:13:48.

Agradecimentos

Em primeiro lugar ao meu Deus, por ter me dado a vida e por me fortalecer para enfrentar os desafios.

Ao meu orientador Prof. Dr. Celso Barbosa Carvalho, pela oportunidade, orientação e incentivo, fazendo com que este trabalho pudesse ser realizado.

Aos meus queridos pais, Ednaldo e Marta. À minha esposa Carla e meu filho Abner por todo amor e carinho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes) pelo apoio financeiro.

Finalmente, a todos aqueles que tiveram contribuição direta ou indireta para a realização deste trabalho.

Resumo

A localização em ambientes internos e semiabertos é um campo de crescente interesse devido à ampla aplicação em sistemas inteligentes, como navegação em locais fechados, gestão logística e monitoramento de pacientes. No entanto, métodos tradicionais de construção de mapas de fingerprints, baseados em medições extensivas, enfrentam desafios relacionados ao alto custo de coleta e manutenção dos dados. Esta tese propõe um método inovador que combina técnicas de super-resolução de imagens e fusão de dados para otimizar a construção de *fingerprints*, reduzindo significativamente o esforço de coleta. O estudo integra medições de diferentes tecnologias, como redes Wireless Fidelity ([Wi-Fi](#)) e estações de rádio de frequência modulada ou Frequency Modulation ([FM](#)), para melhorar a robustez e precisão do sistema em cenários onde fontes de dados são limitadas ou inconsistentes. A metodologia envolve o uso de redes neurais convolucionais ou Convolutional Neural Network ([CNN](#)) previamente treinadas para processar dados do indicador de intensidade do sinal recebido ou Received Signal Strength Indicator ([RSSI](#)), permitindo a modelagem e previsão da propagação de sinal com maior detalhamento. Além disso, técnicas de fusão de dados são aplicadas para integrar informações de múltiplas fontes, maximizando a confiabilidade da localização em condições desafiadoras. Os experimentos foram conduzidos em 716 pontos de referência em um ambiente controlado, com avaliação de desempenho comparativo entre os métodos tradicionais e o modelo proposto. Os resultados demonstraram redução no esforço de coleta de dados, mantendo uma alta precisão de localização, com erro médio próximo a 1,31 metros utilizando menos da metade das redes [Wi-Fi](#) pré-definidas. Conclui-se que a abordagem proposta oferece uma solução eficiente para a construção de mapas de *fingerprints*, com potencial de aplicação em diversos cenários práticos. Este estudo avança o estado da arte em localização indoor e semiaberta, abrindo novos caminhos para o uso de aprendizado profundo e combinação de dados em sistemas de localização.

Palavras-chave: localização indoor e semiaberta, fusão de dados, redes neurais convolucionais, super-resolução de imagens, sistemas de posicionamento [Wi-Fi](#), mapeamento de [RSSI](#).

Abstract

Localization in indoor and semi-open environments is a field of growing interest due to its wide application in intelligent systems, such as indoor navigation, logistics management, and patient monitoring. However, traditional methods for constructing fingerprint maps, based on extensive measurements, face challenges related to the high cost of data collection and maintenance. This thesis proposes an innovative method that combines image super-resolution and data fusion techniques to optimize fingerprint construction, significantly reducing the collection effort. The study integrates measurements from different technologies, such as Wireless Fidelity ([Wi-Fi](#)) networks and Frequency Modulation ([FM](#)) radio stations, to improve the robustness and accuracy of the system in scenarios where data sources are limited or inconsistent. The methodology involves the use of previously trained Convolutional Neural Network ([CNN](#)) to process Received Signal Strength Indicator ([RSSI](#)) data, allowing the modeling and prediction of signal propagation in greater detail. In addition, data fusion techniques are applied to integrate information from multiple sources, maximizing localization reliability under challenging conditions. The experiments were conducted on 716 reference points in a controlled environment, with comparative performance evaluation between traditional methods and the proposed model. The results demonstrated a reduction in data collection effort, while maintaining high location accuracy, with an average error close to 1.31 meters using less than half of the pre-defined [Wi-Fi](#) networks. It is concluded that the proposed approach offers an efficient solution for the construction of fingerprint maps, with potential for application in several practical scenarios. This study advances the state of the art in indoor and semi-open localization, opening new paths for the use of deep learning and data combination in localization systems.

Keywords: indoor and semi-open localization, data fusion, convolutional neural networks, image super-resolution, [Wi-Fi](#) positioning systems, [RSSI](#) mapping.

Artigos Desenvolvidos

1. Ferreira, D.; Souza, R.; Carvalho, C. QA-kNN: Indoor Localization Based on Quartile Analysis and the kNN Classifier for Wireless Networks. *Sensors*, 2020, 20, 4714, doi: 10.3390/s20174714.
2. Ferreira, D., da Silva Júnior, W.; Carvalho, C. Localização em Ambientes Internos Baseada em Aprendizado Supervisionado Utilizando Estações de Rádio FM. *Anais da VIII Escola Regional de Informática de Goiás*, (pp. 101-114), 2020, Goiás. doi:10.5753/erigo.2020.13865. **Prêmio de terceiro melhor artigo completo.** (Artigo científico com resultados do Capítulo 3).
3. Ferreira, D.; Carvalho, C. Localização em ambientes internos baseada em regressão kNN utilizando beamforming. XXXIX Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT 2021), 2021. Fortaleza. doi:10.14209/sbrt.2021.1570734205. (Artigo científico com resultados do Capítulo 4).
4. Ferreira, D., da Silva Júnior, W.; Carvalho, C. Effort Reduction in Fingerprint Construction for Localization Using Super-Resolution. 1st International Conference on Advance Communication & Computational Devices (ICACCD 2024), 2024, Bangalore. **Os anais do ICACCD 2024 serão publicados na Springer Nature. Série de livros "Algorithms for Intelligent Systems"**(<https://www.springer.com/series/16171>). (Artigo científico com resultados do Capítulo 5).

Lista de Acrônimos

5G	Fifth Generation
AoA	Angle of Arrival
AP	Access Point
BSSID	Basic Service Set Identifier
CDF	Cumulative Distribution Function
CNN	Convolutional Neural Network
CSV	Comma-Separated Values
DSSS	Direct Sequence Spread Spectrum
EDSR	Enhanced Deep Residual Network for Single Image Super-Resolution
ESPCN	Efficient Sub-Pixel Convolutional Neural Network
ESSID	Extended Service Set Identifier
FHSS	Frequency Hopping Spread Spectrum
FM	Frequency Modulation
FSRCNN	Fast Super-Resolution Convolutional Neural Network
GNB	Gaussian Naive Bayes
GNSS	Global Navigation Satellite System
GP	Gaussian Process
GPS	Global Positioning System
IEEE	Institute of Electrical and Electronics Engineers
IoT	Internet of Things
IQR	Intervalo Interquartil
ISM	Industrial, Scientific and Medical
kNN	k-Nearest Neighbors
LBS	Location-Based Service
LoRa	Long Range
LOS	Line of Sight

LR	Low Resolution
LTE	Long Term Evolution
MAC	Media Access Control
MCAR	Missing Completely at Random
MICE	Multiple Imputation by Chained Equations
MIMO	Multiple-Input Multiple-Output
ML	Machine Learning
MLP	Multilayer Perceptron
MSE	Mean Squared Error
MU-MIMO	Multi-User Multiple Input Multiple Output
MVF	Multivariable Fingerprints
NLOS	Non-line of sight
NN	Neural Network
OSI	Open System Interconnection
PCA	Principal Component Analysis
PDF	Probability Density Function
PHY	Physical Layer
PSNR	Peak Signal-to-Noise Ratio
QA	Quartile Analysis
QuaDRiGa	Quase Deterministic RadIo channel GenerAtor
RP	Reference Point
RSRP	Reference Signal Received Power
RSRQ	Reference Signal Received Quality
RSSI	Received Signal Strength Indicator
RTLS	Real Time Location System
SDR	Software Defined Radio
SINR	Signal-to-noise and Interference Ratio
SNR	Signal-to-Noise Ratio
SSIM	Structural Similarity Index Measure

SSS	Secondary Synchronization Signal
SR	Super-Resolution
SVM	Support Vector Machine
ToA	Time of Arrival
TP	Test Point
UWB	Ultra-Wide Band
Wi-Fi	Wireless Fidelity

Lista de Figuras

Figura 1	Receptor RTL-SDR ISDB-T da Knup (KP-T2).	19
Figura 2	Técnica de <i>Beamforming</i>	20
Figura 3	Arquitetura da rede ESPCN. Fonte: Shi et al. 2016 [20].	23
Figura 4	Técnica de Fingerprint.	24
Figura 5	Cenário experimental com coordenadas dos pontos de referência.	29
Figura 6	Influência do número de características no erro médio.	32
Figura 7	CDF dos erros para (a) 3, (b) 6 e (c) 8 características.	34
Figura 8	Posicionamento dos receptores e do transmissor (TX).	37
Figura 9	Fluxograma da metodologia desenvolvida.	38
Figura 10	Influência do número de características no erro médio.	39
Figura 11	CDF (<i>Cumulative Distribution Function</i>) dos erros.	40
Figura 12	Cenário experimental e setup para coleta.	42
Figura 13	Cenário experimental.	43
Figura 14	Movimento durante a aquisição de dados.	44
Figura 15	Porcentagem de dados ausentes abaixo de 30%.	45
Figura 16	Erro médio obtido pelo algoritmo de regressão kNN. Estratégias de peso: (a) Uniforme e (b) Distância.	46
Figura 17	Medições, histograma e função Nakagami-m.	47
Figura 18	Cenário experimental com menos pontos de referência.	47
Figura 19	Testes com uma amostra.	49
Figura 20	Testes do SSIM com incremento no número de amostras.	50
Figura 21	Testes do PSNR com incremento no número de amostras.	51
Figura 22	Testes do SSIM com incremento no número de amostras utilizando todas as redes Wi-Fi.	52
Figura 23	Testes do PSNR com incremento no número de amostras utilizando todas as redes Wi-Fi.	53
Figura 24	Diagrama de fluxo da metodologia proposta.	57
Figura 25	Distribuição dos testes conforme o número de APs Wi-Fi disponíveis.	58
Figura 26	Erro médio de localização em função da quantidade de pontos de acesso Wi-Fi disponíveis.	59
Figura 27	Função de distribuição acumulada dos erros de localização.	60
Figura 28	Tempo para aquisição das amostras de RSSI.	61

Lista de Tabelas

Tabela 1	Padrões IEEE 802.11.	20
Tabela 2	Indicadores de desempenho para 3 características.	32
Tabela 3	Indicadores de desempenho para 6 características.	33
Tabela 4	Indicadores de desempenho para 8 características.	33
Tabela 5	Desempenho dos métodos I e II utilizando 3 características.	39

Sumário

1	INTRODUÇÃO	16
1.1	Objetivo Geral	17
1.2	Objetivos Específicos	17
2	REFERENCIAL TEÓRICO	18
2.1	Tecnologias de Comunicação Sem Fio	18
2.1.1	Rádio FM	18
2.1.2	Redes Wi-Fi	19
2.2	Aprendizado de Máquina	20
2.2.1	Classificador k -Nearest Neighbors	21
2.2.2	Regressor k -Nearest Neighbors	21
2.2.3	Classificador Gaussian Naive Bayes	22
2.2.4	Modelo de Super-Resolução	23
2.3	Fingerprinting	24
2.3.1	Fase Off-line	24
2.3.2	Fase On-line	24
2.4	Análise de Quartis	25
2.5	Análise de Componentes Principais	25
2.6	Distribuição Nakagami-m	26
3	LOCALIZAÇÃO EM AMBIENTES INTERNOS BASEADA EM APRENDIZADO SUPERVISIONADO UTILIZANDO ESTAÇÕES DE RÁDIO FM	27
3.1	Introdução	27
3.2	Material e Métodos	28
3.2.1	Cenário experimental e aquisição de dados	28
3.2.2	Pré-processamento e transformação de dados	29
3.2.3	Seleção do modelo de classificação	30
3.3	Resultados	31
3.4	Conclusões	34
4	LOCALIZAÇÃO EM AMBIENTES INTERNOS BASEADA EM REGRESSÃO KNN UTILIZANDO <i>BEAMFORMING</i>	35
4.1	Introdução	35
4.2	Material e Métodos	36
4.2.1	Cenário experimental e banco de dados	36
4.2.2	Extração de características	37
4.2.3	Métrica de desempenho	38
4.3	Resultados	38
4.4	Conclusões	40
5	REDUÇÃO DE ESFORÇO NA CONSTRUÇÃO DE <i>FINGERPRINTS</i> PARA LOCALIZAÇÃO USANDO SUPER-RESOLUÇÃO	41
5.1	Introdução	41
5.2	Material e Métodos	42
5.2.1	Cenário experimental	42
5.2.2	Aquisição de dados	43

5.2.3	Pré-processamento de dados	44
5.2.4	Geração de imagens de fingerprints	46
5.2.5	Métricas de desempenho	48
5.3	Resultados	48
5.4	Conclusões	53
6	LOCALIZAÇÃO EM AMBIENTES SEMIABERTOS UTILIZANDO FUSÃO DE DADOS	54
6.1	Introdução	54
6.2	Material e Métodos	56
6.3	Resultados	58
6.4	Conclusões	61
7	CONSIDERAÇÕES FINAIS	63
	REFERÊNCIAS	64

1 Introdução

A operabilidade de um sistema de localização em tempo real ou Real Time Location System (**RTLS**) é imprescindível para as funcionalidades dos serviços baseados em localização ou Location-Based Service (**LBS**). São exemplos destes serviços: o controle de veículos autônomos a fim de evitar colisões, classificado em serviços e aplicações de mapa/navegação; e o compartilhamento da localização de pacientes para monitoramento por profissionais de saúde e/ou familiares, classificado em serviços e aplicações de emergência [1]. Uma vez que as aplicações **RTLS** apresentam sistemas críticos como os exemplos supracitados, uma eventual indisponibilidade ou falta de precisão do sistema **RTLS** deve ser contornada por estratégias, como por exemplo, a utilização de um sistema substituto ou sistemas de maior precisão, que garantam a operação do sistema sem ou com índice reduzido de interrupções. Desta forma, são necessárias soluções que determinem com precisão a localização de um objeto ou indivíduo.

Um **RTLS** baseado em cálculos de triangulação ou trilateração possui, normalmente, baixa complexidade computacional para estimar os parâmetros utilizados, porém apresenta baixa precisão, uma vez que para determinar a localização de um dispositivo sem fio, fazem correlação diretamente proporcional entre a potência do sinal recebido e a distância, o que nem sempre ocorre, principalmente devido à existência de obstáculos e multipercurso do sinal [2]. Por isso, outros sistemas [3], [4] têm como base algoritmos de aprendizado de máquina que, por sua vez, analisam amostras da potência de sinais eletromagnéticos previamente coletados em posições conhecidas, a fim de identificar suas características e, conseqüentemente, aumentar a precisão e reduzir a complexidade na etapa de localização. Contudo, a atualização periódica do conjunto de amostras é mandatória para que o sistema tenha conhecimento do contexto atual do ambiente.

Além disso, a utilização de uma única tecnologia de comunicação sem fio pode limitar o uso do serviço de **RTLS** a um único tipo de ambiente, seja ambiente interno, semiaberto ou externo, por exemplo, a localização fornecida pelo sistema de posicionamento global ou Global Positioning System (**GPS**) é adequada para ambientes externos, mas este sistema utiliza sinais transmitidos por satélites, o que compromete a precisão da localização, devido à dificuldade dos sinais transporem obstáculos, quando os objetos e indivíduos encontram-se em ambientes internos, ambientes semiabertos ou até mesmo em ambientes externos com muitos obstáculos constituídos por prédios ou em locais com céu encoberto por nuvens [5], [6].

Diante das limitações impostas por obstáculos na localização em tempo real, a integração/fusão de dados de outras tecnologias de comunicação em um **RTLS** mostra-se uma alternativa com intuito de adequar o sistema aos diversos contextos e contornar as limitações.

A problemática central abordada nesta tese é a dificuldade em alcançar precisão e eficiência em **RTLS** em ambientes internos e semiabertos, onde obstáculos e as limitações das tecnologias de comunicação sem fio comprometem a qualidade da localização. Embora o uso de tecnologias como Wireless Fidelity (**Wi-Fi**) e Frequency Modulation (**FM**) tenha mostrado resultados promissores, a interação complexa entre os sinais e as características do ambiente exige uma abordagem mais robusta e dinâmica, que se adapte às diferentes condições de propagação e reduza a carga de trabalho durante a fase de treinamento.

Essa necessidade de uma solução flexível e eficiente motiva o desenvolvimento de uma metodologia que combina múltiplas tecnologias de comunicação sem fio e técnicas avançadas de aprendizado de máquina e pré-processamento de dados. A sequência dos capítulos foi estrutu-

rada para explorar, de forma incremental, o potencial dessas tecnologias e métodos, de modo a melhorar a acurácia do sistema, enquanto simplifica o processo de configuração e treinamento. O Capítulo 3 introduz a utilização de sinais de rádio FM para localização, explorando a integração de aprendizado de máquina supervisionado para otimizar a precisão. O Capítulo 4 aprofunda-se no uso de Wi-Fi com tecnologia *beamforming*, visando o aprimoramento da precisão e a adaptabilidade do sistema. O Capítulo 5 propõe o uso de técnicas de super-resolução para otimizar a base de fingerprints, o que facilita a coleta de dados e a representação mais precisa do ambiente. Por fim, o Capítulo 6 foca na fusão de dados heterogêneos, criando uma solução integrada que combina Wi-Fi e sinais de rádio FM, permitindo um ajuste dinâmico dos dados e aumentando a robustez do sistema.

Essa abordagem integrada não apenas busca melhorar a acurácia da localização em ambientes desafiadores, mas também visa otimizar o processo de configuração e treinamento, tornando o sistema mais adaptável a diferentes cenários e mais eficiente em termos de recursos.

1.1 OBJETIVO GERAL

Propor uma estratégia para aprimorar a localização de objetos estáticos e móveis em ambientes internos e semiabertos, utilizando mapas de rádio com assinaturas do indicador de intensidade do sinal recebido ou Received Signal Strength Indicator (RSSI) dos sinais de rádio transmitidos. O objetivo é aumentar a precisão da localização e reduzir o esforço necessário para o treinamento dos modelos de localização, empregando diferentes tecnologias de redes sem fio e a fusão de dados provenientes dessas tecnologias.

1.2 OBJETIVOS ESPECÍFICOS

- Propor e avaliar o uso de medições de RSSI de sinais de rádio FM para localização em ambientes internos, explorando diferentes técnicas de pré-processamento de dados e algoritmos de aprendizado de máquina supervisionado, como k-Nearest Neighbors (kNN) e Gaussian Naive Bayes (GNB);
- Desenvolver e avaliar um método de localização baseado em sinais de redes Wi-Fi com tecnologia *beamforming*, viabilizando a redução do número de pontos de acesso necessários;
- Construir uma base de dados de sinais de Wi-Fi e rádio FM, utilizando redimensionamento de imagens para modelar ambientes semiabertos e reduzir o esforço na coleta de dados;
- Analisar o desempenho da localização por meio da fusão de dados de Wi-Fi e FM, empregando um método automático para seleção e combinação das informações.

2 Referencial teórico

2.1 TECNOLOGIAS DE COMUNICAÇÃO SEM FIO

As tecnologias de comunicação sem fio (*wireless*) englobam diversas soluções para comunicação sem a necessidade de cabos. Elas são utilizadas em redes de computadores, telecomunicações, automação, internet das coisas ou Internet of Things ([IoT](#)) e diversas outras aplicações. No desenvolvimento de sistemas de localização, diversas tecnologias de comunicação sem fio, como Wireless Fidelity ([Wi-Fi](#)), Bluetooth, Frequency Modulation ([FM](#)), Ultra-Wide Band ([UWB](#)), Long Range ([LoRa](#)), redes móveis de quinta geração ou Fifth Generation ([5G](#)) e Zigbee, são amplamente utilizadas [6]. Nesse sentido, a posição pode ser estimada por diferentes métodos, incluindo a análise do indicador de intensidade do sinal recebido ou Received Signal Strength Indicator ([RSSI](#)), tempo de chegada ou Time of Arrival ([ToA](#)), ângulo de chegada ou Angle of Arrival ([AoA](#)) e *fingerprinting*. Essas abordagens permitem a adaptação dos sistemas a diferentes cenários, abrangendo desde ambientes internos até áreas urbanas e rurais.

Os tópicos seguintes detalham as tecnologias de comunicação sem fio utilizadas neste trabalho.

2.1.1 Rádio FM

A Rádio [FM](#) é a modalidade de serviço de radiodifusão sonora por meio de modulação [FM](#). A modulação [FM](#) é muito utilizada por codificar o sinal de áudio com alta fidelidade, menos ruído e sintonia em dispositivos móveis, como tablets e smartphones. Para cada estação transmissora, é alocada uma frequência central (f_c) e uma largura de banda de 200 kHz situada no espectro de radio-frequências entre 87,8 MHz e 108 MHz (legislação local). Assim, uma estação pode operar na faixa de $f_c \pm 100$ kHz.

Neste trabalho foi utilizado o dongle RTL-SDR para a aquisição de dados. Este dispositivo tem um custo monetário de até 3 vezes menor que os módulos XBee, considerando o valor de mercado nacional. Além disso, é necessária a aquisição de apenas um único dongle RTL-SDR. A Figura 1 ilustra este dispositivo, originalmente projetado para ser um receptor de TV digital (sistema ISDB-T). Este dispositivo é compatível com o desenvolvimento de rádio definido por software ou Software Defined Radio ([SDR](#)), visto que pode receber sinais de radiofrequência na faixa de 48,25 MHz a 863,25 MHz.



Figura 1: Receptor RTL-SDR ISDB-T da Knup (KP-T2).

2.1.2 Redes Wi-Fi

As redes [Wi-Fi](#), também conhecidas como redes IEEE 802.11, oferecem uma alternativa às redes Ethernet cabeadas, proporcionando as mesmas funcionalidades de forma flexível e móvel, o que facilita a conectividade de múltiplos dispositivos eletrônicos [7]. As redes [Wi-Fi](#) são compostas por uma série de especificações que devem ser adotadas na camada física ou Physical Layer ([PHY](#)) e de controle de acesso ao meio ou Media Access Control ([MAC](#)) do modelo Open System Interconnection ([OSI](#)), com o objetivo de atender às exigências para transmissões sem fio. A interface para as camadas superiores da arquitetura é idêntica à das redes cabeadas, garantindo, assim, a interoperabilidade [8].


Após anos de desenvolvimento, a primeira versão do IEEE 802.11 foi lançada em 1997 pelo Institute of Electrical and Electronics Engineers ([IEEE](#)). Inicialmente, o padrão operava com Frequency Hopping Spread Spectrum ([FHSS](#)) e Direct Sequence Spread Spectrum ([DSSS](#)), oferecendo taxas de dados de 1 e 2 Mbps na banda de 2,4 GHz. Com o passar dos anos, novas variantes do padrão original foram oficializadas, como o 802.11g, que foi desenvolvido com base em novas tecnologias de multiplexação para proporcionar maiores taxas de transmissão [9]. A Tabela 1 apresenta alguns dos principais padrões IEEE 802.11 [10].

2.1.2.1 Beamforming

O *beamforming* é uma técnica utilizada em redes sem fio para direcionar o sinal de transmissão de forma mais eficiente. Em vez de irradiar o sinal igualmente em todas as direções, como ocorre em transmissões omnidirecionais, essa técnica ajusta dinamicamente a fase e a amplitude dos sinais emitidos por múltiplas antenas para concentrar a energia na direção específica do receptor, conforme é ilustrado na Figura 2. Isso melhora a qualidade do enlace de comunicação, reduzindo interferências e aumentando a relação sinal-ruído ou Signal-to-Noise Ratio ([SNR](#)). O *beamforming* pode ser implementado de forma explícita, quando o transmissor e o receptor trocam informações para otimizar o feixe de sinal, ou de forma implícita, quando o transmissor estima a posição do receptor sem comunicação direta.

Tabela 1: *Padrões IEEE 802.11.*

Padrão	Ano	Frequência	Taxa máxima (Mbps)
802.11	1997	2,4 GHz	2
802.11b	1999	2,4 GHz	11
802.11a	1999	5 GHz	54
802.11g	2003	2,4 GHz	54
802.11n (Wi-Fi 4)	2009	2,4/5 GHz	600
802.11ac (Wi-Fi 5)	2014	5 GHz	1300+
802.11ax (Wi-Fi 6)	2019	2,4/5 GHz	9600
802.11be (Wi-Fi 7)	2024	2,4/5/6 GHz	30000+

**Figura 2:** *Técnica de Beamforming.*

Com o avanço das técnicas de *beamforming* e a introdução do padrão IEEE 802.11ac (Wi-Fi 5), e versões superiores, foi possível alcançar maiores velocidades de transmissão de dados. Nessas versões, o Access Point (AP) utiliza múltiplas antenas para identificar a posição relativa dos dispositivos móveis conectados, permitindo transmissões direcionadas [11] e tornando os sinais mais intensos em direções específicas.

O *beamforming* se tornou uma tecnologia essencial para aprimorar a eficiência da rede, especialmente em ambientes com alta densidade de usuários. Ao direcionar os sinais para dispositivos específicos, a rede pode atender mais usuários simultaneamente, melhorar a cobertura e reduzir o consumo de energia. Além disso, quando combinado com Multi-User Multiple Input Multiple Output (MU-MIMO), o *beamforming* permite a transmissão simultânea de múltiplos fluxos de dados para diferentes dispositivos, otimizando a capacidade da rede sem fio.

2.2 APRENDIZADO DE MÁQUINA

O aprendizado de máquina ou Machine Learning (ML) tem se consolidado como uma ferramenta essencial para a extração de padrões e a otimização de processos em diversas áreas do conhecimento. A capacidade de aprendizado a partir de dados permite que algoritmos descubram relações complexas entre variáveis sem a necessidade de modelagem explícita. Essa abordagem

tem sido amplamente aplicada em problemas que envolvem grandes volumes de informações e características não lineares, proporcionando maior precisão e eficiência na análise dos dados.

Os algoritmos de ML podem ser categorizados em supervisionados e não supervisionados, dependendo da forma como os dados são utilizados no processo de treinamento. No aprendizado supervisionado, o modelo é treinado com um conjunto de dados rotulado, onde cada entrada possui uma saída conhecida, permitindo que o algoritmo aprenda a mapear corretamente as relações entre variáveis. Essa abordagem é amplamente utilizada em tarefas de classificação e regressão, como reconhecimento de padrões e previsão de valores numéricos [12]. Entre os algoritmos supervisionados, destacam-se o Classificador k -Nearest Neighbors (kNN), que categoriza dados ao comparar um novo ponto com seus vizinhos mais próximos, e o Regressor kNN , que estima valores contínuos com base na média ponderada dos k vizinhos mais próximos. Outro método amplamente empregado em classificação é o Classificador Gaussian Naive Bayes (GNB), que utiliza o Teorema de Bayes para calcular probabilidades, assumindo independência entre as variáveis preditoras.

Já no aprendizado não supervisionado, o modelo recebe apenas dados não rotulados e deve identificar automaticamente estruturas ou padrões ocultos, sem um resultado previamente definido. Uma das técnicas mais conhecidas neste contexto é o Agrupamento k Means, que segmenta os dados em grupos (*clusters*) baseados nas semelhanças entre as instâncias, onde cada instância é atribuída ao cluster mais próximo de sua média [13]. Essa abordagem é útil para identificar tendências e padrões sem conhecimento prévio sobre as categorias existentes nos dados.

Os tópicos seguintes detalham os algoritmos utilizados neste trabalho.

2.2.1 Classificador k -Nearest Neighbors

O classificador kNN é um dos algoritmos de classificação mais simples no âmbito da aprendizagem supervisionada [14]. É não-paramétrico, ou seja, não necessita que os dados apresentem distribuição específica (ex.: gaussiana ou exponencial) e possui como hiperparâmetro o número de vizinhos mais próximos (k). Em geral, um grande número de vizinhos pode reduzir ou aumentar o desempenho do algoritmo, estando sujeito à extração de características discriminantes para representação dos dados. Ou seja, se houver muito ruído nos dados, um valor alto para o k tornará o classificador muito sensível ao ruído. Por outro lado, se os dados são eficientes, um valor alto para o k irá minimizar a sensibilidade ao pouco ruído.

No treinamento, o modelo de classificação é criado por um conjunto de instâncias (ou vetores de características) previamente classificadas e o valor de k é definido empiricamente para uma melhor precisão. Na classificação, uma instância de teste (nova instância) é introduzida no classificador treinado. Tradicionalmente, o classificador examina as classes das k instâncias de treino mais próximas (similares) à instância de teste, baseando-se em métricas de distância, como Manhattan, Euclidiana ou Minkowski. Posteriormente, atribui a instância de teste à classe majoritária, ou seja, à classe mais representada pelas k instâncias de treino [12].

2.2.2 Regressor k -Nearest Neighbors

O algoritmo kNN é geralmente utilizado em problemas de classificação, como em [15], entretanto, ele também pode ser utilizado em problemas de regressão. O kNN realiza a predição de novos valores a partir de medidas de similaridade entre as variáveis preditoras (x_i). Diferentemente do classificador que utiliza o valor modal, a saída y do regressor é calculada como o valor médio dos

valores da variável dependente (y_i) dos vizinhos mais similares [16]. Esta média aritmética pode ser simples ou ponderada pelo inverso da similaridade.

Para realizar a predição desses valores, seguem-se os passos:

1. Calcular a distância entre o ponto de teste ou Test Point (TP) e cada um dos pontos de referências ou Reference Point (RP), conforme a Equação 1

$$D(TP, RP) = \sqrt{\sum_{i=1}^m (x_{TP_i} - x_{RP_i})^2}, \quad (1)$$

onde m é o número de variáveis preditoras, x_{TP_i} é o valor da variável i para o TP , e x_{RP_i} é o valor da variável i para o RP .

2. Selecionar os k RPs que estão mais próximos do TP.
3. Calcular a média entre os k valores contínuos da variável dependente, conforme a Equação 2

$$\hat{y} = \frac{1}{k} \sum_{i=1}^k y_i \quad (2)$$

2.2.3 Classificador Gaussian Naive Bayes

O classificador Gaussian Naive Bayes (GNB) é um algoritmo probabilístico muito utilizado no aprendizado de máquina. Este algoritmo possui alta eficiência computacional e fundamenta-se no teorema de Bayes desenvolvido por Thomas Bayes (1701-1761).

As predições são realizadas a partir das probabilidades a posteriori de uma instância de teste pertencer a cada classe e, em seguida, atribuindo a instância à classe de maior probabilidade [17]. A probabilidade $P(c_i|X)$ da classe c_i , dado uma instância de teste ou vetor de características $X = (x_1, x_2, \dots, x_n)$, é definida como:

$$P(c_i|X) = \frac{P(X|c_i)P(c_i)}{P(X)} \quad (3)$$

Considerando que as probabilidades a priori de todas as classes são iguais, tem-se $P(c_i) = 1/m$, em que m é o número de classes; e dado que a probabilidade $P(X)$ está associada apenas a instância de teste, a função de decisão pode ser reduzida e representada como:

$$\hat{c} = \underset{c_i}{\operatorname{argmax}} \prod_{j=1}^n P(x_j|c_i), \quad (4)$$

onde n é o número de características contidas no vetor X , j é o índice da j -ésima característica x_j , e a classe c_i que maximiza esta função corresponde a classe estimada $\hat{c}$.

Pressupondo que os dados apresentem distribuição gaussiana, utiliza-se a função de densidade de probabilidade ou Probability Density Function (PDF) da distribuição normal para estimar $P(x_j|c_i)$:

$$P(x_j|c_i) = \frac{1}{\sigma_{c_i} \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x_j - \mu_{c_i}}{\sigma_{c_i}} \right)^2} \quad (5)$$

A medida que as características extraídas tendem a descrever uma distribuição mais próxima da normal, e que não existe uma correlação entre elas, melhor é o desempenho do algoritmo [18].

2.2.4 Modelo de Super-Resolução

A super-resolução ou Super-Resolution (SR) é uma técnica utilizada para reconstruir imagens de alta resolução a partir de versões de baixa resolução, permitindo a recuperação de detalhes perdidos e aprimorando a qualidade visual. Esse processo é fundamental em diversas aplicações, como imagens médicas, monitoramento por câmeras de vigilância, restauração de fotografias e processamento de imagens de satélite. O objetivo da SR é compensar limitações impostas por sensores de captura, condições ambientais ou restrições computacionais, melhorando a interpretação e a análise das imagens [19].

Os métodos tradicionais de SR incluem técnicas baseadas em interpolação, como bilinear, bicúbica e Nearest Neighbors. Essas abordagens utilizam informações locais da imagem para estimar novos pixels, mas frequentemente resultam em imagens suavizadas ou com artefatos visuais. Alternativamente, métodos baseados em ML, como Convolutional Neural Network (CNN), têm demonstrado um desempenho superior ao aprender representações mais sofisticadas para reconstrução de imagens [20].

Com o avanço do aprendizado profundo, surgiram modelos como Fast Super-Resolution Convolutional Neural Network (FSRCNN) [20], Enhanced Deep Residual Network for Single Image Super-Resolution (EDSR) [21] e Efficient Sub-Pixel Convolutional Neural Network (ESPCN) [20], que exploram arquiteturas convolucionais para aumentar a resolução das imagens de forma mais eficiente. Essas abordagens modernas conseguem preservar texturas e bordas, reduzindo artefatos indesejados e melhorando a nitidez das imagens reconstruídas.

O FSRCNN é uma rede rápida e eficiente que utiliza convolução sub-pixel para aprimorar imagens de baixa resolução ou Low Resolution (LR) em tempo real [22]. O EDSR é uma rede aprimorada que preserva detalhes em imagens ampliadas, apresentando bom desempenho em SR [23]. O ESPCN é uma rede leve e eficiente que recupera rapidamente imagens de alta resolução a partir de entradas de baixa resolução, sendo ideal para dispositivos com recursos limitados [24]. A Figura 3 apresenta a arquitetura da rede ESPCN, que consiste em duas camadas convolucionais para extração de características e uma camada de convolução de sub-pixel responsável por agregar os mapas de características do espaço de baixa resolução e gerar a imagem de alta resolução em um único passo.




Figura 3: Arquitetura da rede ESPCN. Fonte: Shi et al. 2016 [20].

A SR tem sido amplamente aplicada em cenários onde a aquisição de imagens de alta resolução é inviável devido a limitações de hardware ou custo. Em áreas como astronomia e

imagens médicas, essa técnica permite obter maior nível de detalhe sem a necessidade de sensores mais sofisticados. Com o avanço das redes neurais e o aumento da capacidade computacional, é possível que a [SR](#) continue desempenhando um papel essencial no aprimoramento de imagens em diversas áreas [21].

2.3 FINGERPRINTING

O *fingerprinting* é uma técnica amplamente utilizada para localização em ambientes internos e externos. Diferente de métodos como trilateração e triangulação, que dependem de distâncias e ângulos calculados, essa abordagem cria um mapeamento dos sinais no ambiente para inferir a posição de um dispositivo. O processo envolve a medição de parâmetros como o [RSSI](#), [ToA](#) e [AoA](#). Essa técnica apresenta alta precisão, especialmente em ambientes internos, e não requer linha de visada direta, tornando-se funcional mesmo em cenários com obstáculos. No entanto, o alto custo de coleta de dados e a necessidade de atualizações frequentes representam desafios significativos. Para aumentar sua confiabilidade, pode ser combinado com técnicas de fusão de sensores, melhorando a precisão e adaptabilidade em diferentes cenários.

2.3.1 Fase Off-line

A etapa de coleta de dados é fundamental para a construção do banco de *fingerprints*. As medições de sinal são realizadas em pontos de referência distribuídos no ambiente, como ilustra a Figura 4, registrando características como intensidade do sinal e variações espaciais. Essa coleta pode ser influenciada por fatores como interferências, presença de obstáculos e condições ambientais.

Após a coleta, os dados são armazenados e processados para formar um banco de *fingerprints*. Esse banco pode ser estruturado em tabelas de [RSSI](#) ou modelos mais complexos, como representações probabilísticas e modelos para redes neurais.




Figura 4: Técnica de Fingerprint.

2.3.2 Fase On-line

Na fase *on-line*, a localização do dispositivo é estimada comparando-se os sinais recebidos em tempo real com os registros armazenados na fase *off-line*. O algoritmo de localização identifica

o *fingerprint* mais semelhante e determina a posição do usuário. Métodos de aprendizado de máquina, como Support Vector Machine (SVM), [knn](#) e [CNN](#), são empregados para estimar as coordenadas, inclusive em posições não amostradas dentro da região, aprimorando a precisão do sistema. A eficiência desse processo depende da qualidade da base de dados e da robustez do método de correspondência adotado.

2.4 ANÁLISE DE QUARTIS

A análise de quartis ou Quartile Analysis ([QA](#)) é um método estatístico utilizado para avaliar a tendência central, a dispersão e a posição das observações nos dados. Os quartis particionam um conjunto parcialmente ordenado (poset) em quatro partes iguais. O primeiro quartil ($Q_{1/4}$) ou quartil inferior delimita as 25% menores observações, o segundo quartil ($Q_{2/4}$) ou mediana separa as 50% menores das 50% maiores observações, e o terceiro quartil ($Q_{3/4}$) ou quartil superior delimita as 25% maiores observações [25].

São encontradas na literatura diversas definições para o cálculo dos quartis [26]. Dessa forma, uma equação generalizada para o cálculo computacional/estatístico dos quartis é definida neste trabalho. A partir de um poset $(S, \leq)$, o valor do quartil Q_p é estimado através de regressão linear, entre os elementos $x_{[i]}$ e $x_{[i]+1}$, em que a posição $[i]$ é determinada em função da porcentagem de observações p , conforme a equação:

$$Q_p = x_{[i]} + (x_{[i]+1} - x_{[i]})(i - [i]) \quad (6)$$

com

$$i = (n - 1) \times p + 1, \quad (7)$$

onde n é o número de elementos em $(S, \leq)$ e $[i]$ é a parte inteira do índice i . Para dados altamente assimétricos e/ou afetados por outliers, o $Q_{2/4}$ é mais eficiente que a média, e não necessita, previamente, de uma análise exploratória. Além disso, o Intervalo Interquartil ([IQR](#)) ($IQR = Q_{3/4} - Q_{1/4}$) é uma medida estatística relativamente robusta frente ao desvio padrão [27].

2.5 ANÁLISE DE COMPONENTES PRINCIPAIS

A análise de componentes principais ou Principal Component Analysis ([PCA](#)) foi introduzida por Karl Pearson em 1901 e, atualmente, é um método estatístico amplamente utilizado para analisar dados multivariados [28]. A [PCA](#) determina as direções que apresentam as maiores variações dos dados em um espaço m -dimensional, em que m é o número de variáveis iniciais que descrevem o conjunto de dados. Estas direções ou componentes são dispostas em ordem decrescente de acordo com suas variações, onde a componente de maior variação possui maior importância. Com isso, pode-se eliminar as componentes de menor importância e minimizar a dimensão dos dados [29].

De forma geral, a [PCA](#) transforma um conjunto de variáveis correlacionadas/redundantes em um novo conjunto de variáveis não-correlacionadas [30]. Para o cálculo da [PCA](#), as n observações de cada variável do conjunto de dados ($D_{n \times m}$) são centralizadas subtraindo-se a média nas respectivas variáveis x e y , em seguida, calcula-se a matriz de covariância ($C_{m \times m}$) entre estas variáveis. A covariância entre duas variáveis quaisquer x e y é definida pela Equação 8.

$$\sigma_{xy}^2 = \frac{1}{n} \sum_{i=1}^n ((x_i - \mu_x)(y_i - \mu_y)), \quad (8)$$

onde μ_x e μ_y são as médias das variáveis x e y , respectivamente.

Posteriormente, calculam-se os autovalores (λ) e os autovetores (v) da matriz $C_{m \times m}$. Os autovalores representam a variância de cada componente e os autovetores organizados em colunas ($V_{m \times m}$) representam as transformações lineares. Assim, o novo conjunto de variáveis ($P_{n \times m}$) é calculado a partir da combinação linear das m variáveis correlacionadas e dos coeficientes/elementos de cada autovetor ($P = D \times V$).

2.6 DISTRIBUIÇÃO NAKAGAMI-M

A PDF da distribuição Nakagami-m pode ser utilizada para descrever o comportamento estatístico do desvanecimento em pequena escala. Esta função é definida como:

$$PDF(h) = 2 \left(\frac{m}{\Omega} \right)^m \frac{1}{\Gamma(m)} h^{(2m-1)} e^{-\frac{mh^2}{\Omega}}, \forall h \geq 0, \quad (9)$$

em que $m \geq 0,5$ é o parâmetro de forma, $\Omega > 0$ é o parâmetro de escala e $\Gamma(.)$ é a PDF Gama. O valor do parâmetro m , também conhecido como figura de desvanecimento, é definido como:

$$m = \frac{\Omega^2}{Var(h^2)} \quad \text{com} \quad \Omega = E[h^2], \quad (10)$$

onde h representa o coeficiente de desvanecimento e $Var(.)$ representa o operador de variância.

Quanto menor o parâmetro m , maiores são as distorções do canal, o que significa que a porção de linha de visada ou Line of Sight (LOS) é menor. Assim, um canal com m próximo de 1, caracterizando um link sem linha de visada ou Non-line of sight (NLOS), apresenta mais erros do que um canal com $m = 2$ ou $m = 4$. Se o valor de m for grande, $m \geq 6$, pode-se inferir que há uma porção significativa de LOS [31].

Dado um conjunto de medições de potência de um sinal, os parâmetros da distribuição de desvanecimento podem ser estimados. Primeiro, a realização de desvanecimento h é extraída de cada valor de potência de acordo com:

$$h = \sqrt{\frac{P_r}{\bar{P}_r}}, \quad (11)$$

onde P_r é a potência recebida e $\bar{P}_r$ é a potência média recebida.

3 Localização em ambientes internos baseada em aprendizado supervisionado utilizando estações de rádio FM

Para a localização de dispositivos móveis em redes sem fio, deve-se instalar três ou mais dispositivos fixos, cujos sinais transmitidos são utilizados como parâmetros de localização. O problema desta abordagem é o aumento dos custos energético e monetário. Assim, o objetivo deste Capítulo é propor um método de localização utilizando estações de rádio Frequency Modulation (FM) com vistas ao baixo custo e alta acurácia. Foram realizados testes em ambiente doméstico com aproximadamente 30 m^2 e 15 pontos de referência. Como resultados dos testes, o método proposto QA-PCA-kNN destacou-se ao utilizar 6 características dos sinais FM, provendo a localização com erro médio de 0,0688 metros e desvio padrão de $\sigma = 0,2536$ e, apresentando acurácia de 86,80%.

3.1 INTRODUÇÃO

A localização de dispositivos em ambientes internos é um tema de grande interesse no âmbito das redes sem fio, visto que pode contribuir para o aprimoramento de serviços baseados em localização ou Location-Based Service (LBS) em diversas áreas, como doméstica, industrial e hospitalar, entre outras [32]. Embora a localização fornecida pelo Global Positioning System (GPS) seja adequada para ambientes externos, este sistema utiliza sinais transmitidos por satélites, o que compromete a acurácia da localização quando os dispositivos encontram-se em ambientes fechados [33].

A localização em ambientes internos é atualmente alvo de diversos trabalhos, muitos destes apresentam propostas baseadas em redes Wireless Fidelity (Wi-Fi) (padrões IEEE 802.11b/g/n), devido à ampla presença dessas redes em locais públicos e privados [34]–[36]. No entanto, a fim de se obter um erro aceitável, estas propostas utilizam como parâmetros de localização o posicionamento de no mínimo três Access Point (AP) e o Received Signal Strength Indicator (RSSI) destes AP [37], resultando em um sistema de localização com maior consumo de energia e recursos.

Além disso, as redes Wi-Fi operam na faixa de frequência Industrial, Scientific and Medical (ISM). Esta faixa de frequência é aberta e, portanto, é amplamente utilizada [38]. Com isso os sinais Wi-Fi são expostos a interferências de outras tecnologias de rádio, como Zigbee e Bluetooth, além de outros equipamentos eletrônicos, como telefone sem fio operando na faixa de 2,4 GHz e fornos de microondas [11], [39]. As interferências tornam o sistema de localização ainda mais vulnerável a falhas, pois o RSSI em um canal sem fio é previamente caracterizado por flutuações, nomeadamente: perda por percurso (*path loss*), sombreamento (*shadowing*) e multipercursos (*multipath*).

Em [40], os autores investigaram a viabilidade de um sistema de localização baseado em sinais transmitidos por estações de rádio FM, aproveitando-se da infraestrutura previamente existente e dos sintonizadores disponíveis em muitos dispositivos móveis. Foram avaliados os algoritmos k-Nearest Neighbors (kNN), Support Vector Machine (SVM) e Gaussian Process (GP) para classificação e regressão de vetores com valores médios de RSSI. Cada valor médio foi calculado a partir de 10 medições e normalizado na faixa de 0 a 1. No ambiente com área de 50 m $\times$ 25 m, o

melhor resultado foi obtido com a utilização do classificador **kNN**, utilizando o **RSSI** de 45 estações de rádio **FM** e estimando 52% das posições com erro médio de localização nulo. No ambiente com área de 12 m $\times$ 6 m, o **kNN** também apresentou o melhor resultado, utilizando 50 estações de rádio **FM** e estimando 40% das posições com erro médio de localização nulo. Em experimentos adicionais constatou-se que os receptores de **FM** têm um consumo energético de 2,6 a 5,5 vezes menor que os módulos **Wi-Fi**.

Em [15], os autores propuseram um método de localização em ambientes internos utilizando redes **Wi-Fi**. O objetivo foi melhorar a precisão de localização, que é comprometida pela instabilidade das medições de **RSSI**. O método emprega a análise de quartis ou Quartile Analysis (**QA**) na representação dos dados e o algoritmo **kNN**. Em um ambiente com área de 3,5 m $\times$ 3,56 m, 100% das posições testadas foram identificadas com erro médio de localização nulo a partir de 4 APs, $k = 1$ e 10 medições de **RSSI** por AP para o cálculo dos quartis. O resultado alcançado com $k = 1$ mostra que o método é uma contribuição importante e promissora na área de localização.

Em [41], utilizou-se a Principal Component Analysis (**PCA**) para transformar o conjunto dos valores de **RSSI** em um conjunto com novas características, a fim de eliminar características com menor importância. O desempenho do método proposto foi testado utilizando os classificadores **kNN**, **SVM**, *Decision Tree* e *Random Forest*. Os experimentos foram conduzidos em um ambiente real com 45 Reference Points (**RP**s) utilizando smartphones para a coleta dos valores de **RSSI** de 6 APs. Os resultados mostram que o **kNN** com $k = 2$ e utilizando as três primeiras características obteve o melhor desempenho nos experimentos dinâmicos, apresentando um erro médio de localização de 1,71 m com precisão de 60% e de 3,0 m com precisão de 79%. A localização foi calculada pela média ponderada das coordenadas (centróide) dos k vizinhos mais próximos. Este cálculo permite localizar objetos em posições coincidentes com os **RP**s e em posições aleatórias.

O trabalho de [40] contribui para uma abordagem de baixo custo, visto que os gastos com a instalação de dispositivos fixos são suprimidos. Os trabalhos de [15], [41] apresentam, respectivamente, a **QA** e a **PCA** como abordagens estatísticas para o tratamento de dados com intuito de alcançar melhores resultados. Estas abordagens estatísticas combinadas podem ajudar na caracterização do comportamento dos sinais de rádio **FM** em um cenário de localização.

Diante do exposto, este trabalho propõe um método de localização em ambientes internos utilizando sinais de estações de rádio **FM**, explorando sua ampla disponibilidade e baixo custo operacional. As principais contribuições deste capítulo incluem a combinação de **QA** e **PCA** para aprimorar a seleção de características dos sinais, melhorando a robustez das medições. O método proposto foi avaliado experimentalmente em um ambiente real, demonstrando um desempenho competitivo. Por fim, evidenciamos a viabilidade do uso de dispositivos embarcados sem infraestrutura adicional, tornando esta solução uma alternativa acessível e eficiente para aplicações de localização indoor.

3.2 MATERIAL E MÉTODOS

3.2.1 Cenário experimental e aquisição de dados

Para o desenvolvimento deste trabalho, foram conduzidos experimentos em um ambiente interno com dimensões de 6,10 m $\times$ 4,80 m, contendo 15 **RP**s, conforme ilustrado na Figura 5. Ao invés das medições de **RSSI**, o dongle RTL-SDR disponibiliza o ganho de potência (G_p) de cada estação. No entanto o G_p corresponde a uma relação entre a potência recebida (P_{rx}) e a potência de transmissão (P_{tx}), e é definido como:

$$G_p[dB] = 10 \log_{10} \frac{P_{rx}[W]}{P_{tx}[W]} \quad (12)$$

Dispondo do espectro eletromagnético disponível, foram selecionadas as oito (8) estações de maior potência em coletas preliminares para os experimentos. O dongle foi realocado sequencialmente em todos os **RP**s, e permaneceu imóvel ao longo de 2 minutos em cada **RP**. Foram coletadas 2000 medições do G_p de cada estação durante o tempo de imobilidade em cada **RP**. Após a coleta em todos os 15 **RP**s, os dados foram mesclados em um único arquivo de texto Comma-Separated Values (**CSV**), resultando em uma tabela (conjunto de dados) com 30000 linhas e 8 colunas. Sendo 2000 linhas por **RP**.




Figura 5: Cenário experimental com coordenadas dos pontos de referência.

3.2.2 Pré-processamento e transformação de dados

O principal objetivo desta fase é melhorar a qualidade dos dados coletados, visto que os dados podem apresentar problemas como uma grande quantidade de dados ausentes (*missing data*) e valores discrepantes (*outliers*), possivelmente decorrentes das interferências no sinal de radiofrequência. Adicionalmente, buscou-se extrair características e reduzir a dimensionalidade dos dados a fim de obter uma representação com características/atributos discriminantes.

Analisando o conjunto de dados, constatou-se que 8,6% do total de observações são dados ausentes. Entende-se que essas perdas esporádicas do sinal são interferências de fatores externos, como características da antena de recepção e obstáculos em uma determinada posição. Então, realizou-se uma imputação múltipla por equações encadeadas ou Multiple Imputation by Chained

Equations (MICE) considerando o mecanismo completamente aleatório dos dados ausentes ou Missing Completely at Random (MCAR) [42], [43]. Após a obtenção de um conjunto de dados completo, as observações dos atributos foram normalizadas utilizando a fórmula Min-Max:

$$x_{normalizado} = \frac{x - x_{min}}{x_{max} - x_{min}}, \quad (13)$$

onde x é uma observação a ser normalizada e x_{min} e x_{max} são os valores mínimos e máximos dentre as observações do atributo, respectivamente. Esta fórmula corresponde a uma transformação linear do atributo em uma escala de 0 a 1 e mantém a distribuição das observações.

No tratamento de *outliers* e extração de características/atributos, criou-se um conjunto de instâncias (vetores de características) utilizando a QA. A cada 10 linhas correspondentes a um RP do conjunto de dados coletados, calculou-se os quartis de cada coluna, ou seja, uma instância baseia-se em 10 observações do G_p de cada estação. Uma instância é associada a um único RP e é representada por um vetor X de 24 características, ou seja, três (3) características para cada estação:

$$X = [\overbrace{Q_{\frac{1}{4}}, Q_{\frac{2}{4}}, Q_{\frac{3}{4}}}^{STA_1}, \overbrace{Q_{\frac{1}{4}}, Q_{\frac{2}{4}}, Q_{\frac{3}{4}}}^{STA_2}, \dots, \overbrace{Q_{\frac{1}{4}}, Q_{\frac{2}{4}}, Q_{\frac{3}{4}}}^{STA_8}] \quad (14)$$

Como o conjunto de dados coletados possui 2000 observações de cada estação em cada RP, foram criadas 200 instâncias para cada um dos 15 RPs. Esta abordagem elimina os *outliers* e extrai características que denotam o comportamento das medições brutas.

Em seguida, utilizou-se a PCA para garantir características relevantes e não correlacionadas/redundantes. O algoritmo da PCA, utilizado para transformação dos dados, retorna novas características que seguem uma ordem de importância. A ordem de importância diz respeito aos dados transformados, e não se pode inferir sobre a ordem de importância das características reais, pois não há referência entre os dados reais e dados transformados. Esta ordenação viabilizou a redução de dimensionalidade dos dados, onde se selecionou as 8 características mais relevantes.

Nos experimentos utilizou-se 75% das instâncias para treinamento e 25% para testes, visando impedir qualquer influência (viés) nos resultados, pois os dados de teste não devem ser utilizados no treino. Com intuito de obter um conjunto de treinamento balanceado, isto é, com o mesmo número de instâncias entre as classes, foi realizada uma amostragem aleatória estratificada (*stratified random sampling*).

3.2.3 Seleção do modelo de classificação

Para estimar as coordenadas associadas à instância de teste, ou seja, identificar a localização propriamente dita, foram considerados e avaliados os algoritmos de aprendizado supervisionado kNN e Gaussian Naive Bayes (GNB) utilizando o software MATLAB®. Em ambos os modelos, as coordenadas $(\hat{x}_l, \hat{y}_l)$ são estimadas a partir do centróide:

$$(\hat{x}_l, \hat{y}_l) = \left(\frac{\sum_{i=1}^k w_i x_i}{\sum_{i=1}^k w_i}, \frac{\sum_{i=1}^k w_i y_i}{\sum_{i=1}^k w_i} \right), \quad (15)$$

onde k é o número de RPs selecionados, (x_i, y_i) são as coordenadas dos RPs e w_i é o peso de cada RP. O cálculo do centróide permite localizar objetos em posições aleatórias dentro do ambiente. Nota-se que, neste trabalho busca-se estimar as coordenadas de posições coincidentes com os RPs,

e considera-se que estas posições também podem ser testadas como quaisquer outras posições aleatórias, assumindo que quaisquer posições testadas são equiprováveis.

O **kNN** estima as coordenadas a partir dos **RP**s associados aos $k = 4$ vizinhos mais próximos, ponderados pelo inverso das distâncias Euclidianas calculadas $w_i = 1/d_i$; e o **GNB** utiliza os $k = 4$ **RP**s com maiores probabilidades, ponderados pelas probabilidades calculadas $w_i = P(c_i|X)$. Estes modelos de classificação foram testados de forma empírica e o erro médio (EM) de localização foi utilizado como métrica de desempenho, a fim de medir a distância média entre as coordenadas reais e as coordenadas estimadas. O EM é dado em metros e definido como:

$$EM = \frac{1}{N} \sum_{i=1}^N \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2}, \quad (16)$$

onde N é o número total de testes realizados.

A fim de obter uma conformidade entre erro de localização e baixo custo computacional, buscou-se determinar o número ótimo de características. Para tanto, o número de características utilizadas variou de 3 a 8. O desempenho do método proposto é comparado com a simples abordagem de médias no pré-processamento, denotada pela letra maiúscula M . Nesta abordagem, as médias de 10 medições são normalizadas pela fórmula Min-Max como em [40], [44]. O uso da média para reduzir as variações das medições reduz o erro quadrático das medições, mas não necessariamente extraem características discriminantes.

3.3 RESULTADOS

Inicialmente, o desempenho dos métodos foi analisado observando-se a influência do número de características no EM de localização. O número de características, necessário para minimizar o EM, está relacionado diretamente com o conhecimento adquirido para discriminação dos **RP**s. Os resultados de desempenho, em função do número de características, são apresentados na Figura 6.




Figura 6: Influência do número de características no erro médio.

Nota-se nas curvas de avaliação de desempenho que houve maior redução no valor de EM quando a quantidade de características varia de 3 a 6. Utilizando de 3 e 6 características, o menor valor do EM foi alcançado pelo método QA-PCA-*k*NN com 0,0688 m, sendo superado apenas pelo método M-GNB com EM de 0,0399 m, utilizando 7 e 8 características. De 3 a 5 características, os métodos M-GNB e M-kNN obtiveram os piores desempenhos com EM de até 0,6168 e 0,6400 m, respectivamente. O método QA-PCA-GNB obteve o segundo melhor desempenho de 3 a 5 características, mas obteve o pior desempenho com 7 e 8 características com EM de 0,1058 m.

Em seguida, buscou-se inferir a confiabilidade dos métodos testados a partir do desvio padrão das estimativas. As Tabelas 1, 2 e 3 apresentam as estatísticas das estimativas de localização utilizando 3, 6 e 8 características, respectivamente.

Tabela 2: Indicadores de desempenho para 3 características.

Método	Erro médio (EM)	Desvio padrão (σ)	Mínimo	Máximo
M-kNN	0,6400	0,8900	0	4,1060
M-GNB	0,6168	0,7611	0	3,8056
QA-PCA-kNN	0,3074	0,5518	0	3,7802
QA-PCA-GNB	0,3741	0,5413	0	3,7373

Tabela 3: Indicadores de desempenho para 6 características.

Método	Erro médio (EM)	Desvio padrão (σ)	Mínimo	Máximo
M-kNN	0,1391	0,4042	0	3,3879
M-GNB	0,1284	0,3553	0	2,8976
QA-PCA-kNN	0,0688	0,2536	0	3,2451
QA-PCA-GNB	0,1297	0,3232	0	3,2357

Tabela 4: Indicadores de desempenho para 8 características.

Método	Erro médio (EM)	Desvio padrão (σ)	Mínimo	Máximo
M-kNN	0,0474	0,2244	0	2,5022
M-GNB	0,0399	0,2057	0	3,2112
QA-PCA-kNN	0,0463	0,2069	0	3,2451
QA-PCA-GNB	0,0986	0,3146	0	3,2297

Observa-se que à medida que número de características aumenta, todos os métodos mostram-se mais robustos, com os desvios padrão cada vez menores. Nos testes com 3 e 6 características, destaca-se que os métodos baseados nos quartis e nas componentes principais (QA-PCA- k NN e QA-PCA-GNB) expressam os menores desvios padrão. Nos testes com 8 características, o método M-GNB obteve as melhores estatísticas.

Em fim, buscou-se a proporção de estimativas com erros nulos (0 m), ou simplesmente acurácia. As Figuras 7a e 7b apresentam a Cumulative Distribution Function (CDF) dos erros para vetores de 3 e 6 características, respectivamente.




Figura 7: CDF dos erros para (a) 3, (b) 6 e (c) 8 características.

Nestas CDFs, os métodos baseados no algoritmo **kNN** apresentaram as maiores acurácias. O QA-PCA-*kNN* alcançou a estimativa de 86,80% das posições com erro de localização nulo, enquanto o M-*kNN* estimou 80,27% das posições. A partir de um vetor de tamanho 8, o M-*kNN* com 91,87% superou a acurácia do QA-PCA-*kNN* de 90,80%, conforme ilustrado na Figura 7c. No entanto, a baixa dimensão dos vetores de características viabiliza ainda mais a utilização de sistemas embarcados, com menor capacidade de memória e baixo poder de processamento, como dispositivos de localização.

3.4 CONCLUSÕES

Neste Capítulo foi proposto um método de localização em ambientes internos utilizando canais de rádio **FM**. Para isso, foram combinadas duas diferentes abordagens estatísticas na representação dos dados: **QA** e **PCA**. E avaliadas duas diferentes abordagens de aprendizado supervisionado para a tarefa de classificação: **kNN** e **GNB**.

A partir dos resultados obtidos nos experimentos, pode-se validar o método QA-PCA-*kNN* para estimar a localização utilizando o centróide, uma vez que se destacou com vetores de até seis (6) características. Além de apresentar um erro médio de localização mínimo satisfatório de 0,0688 metros com desvio padrão de $\sigma = 0,2536$ para a base de dados.

4 Localização em ambientes internos baseada em regressão kNN utilizando *beamforming*

Para localizar dispositivos móveis em redes sem fio, pode-se instalar três ou mais dispositivos fixos, cujos sinais transmitidos são utilizados como parâmetros para localização. O problema desta abordagem é o aumento dos custos energético e monetário. Assim, neste Capítulo é proposto um método de localização utilizando um único transmissor com múltiplas antenas. Neste trabalho, realizaram-se testes estáticos em ambiente simulado de 100 m^2 com 361 pontos de referência para medições de potência do sinal. Como resultados dos testes, o método proposto apresentou melhor desempenho ao utilizar somente duas (2) características dos sinais, provendo a localização com erro médio de 0,7979 m, desvio padrão de $\sigma = 0,9703\text{ m}$, e acurácia de aproximadamente 89% para erros abaixo da distância de 2 metros.

4.1 INTRODUÇÃO

A localização de objetos móveis é um tema de grande relevância no campo de desenvolvimento da internet das coisas ou Internet of Things (IoT) [45], uma vez que tal informação pode contribuir para a funcionalidade de aplicações cientes de contexto nos mais diversos setores [32], tais como, indústrias, residências, comércios e hospitais.

Embora o sistema de posicionamento global ou Global Positioning System (GPS) forneça dados aceitáveis da localização física em ambiente externo, a precisão e utilidade da localização baseada em satélites ficam comprometidas à medida que os espaços habitados pelos objetos tornam-se fechados [33]. Por estar relacionada com o desenvolvimento de novas aplicações, a localização em ambientes internos é atualmente alvo de diversos trabalhos, muitos destes apresentam propostas baseadas em redes padrão IEEE 802.11b/g/n (Wi-Fi), devido à ampla presença dessas redes em locais públicos e privados, e utilizam o Received Signal Strength Indicator (RSSI) como parâmetro para determinar a localização [37]. Estas propostas concentram-se em minimizar os erros de localização e a complexidade computacional [3], [4], [37], [46]–[48].

Os erros de localização estão relacionados, principalmente, com a instabilidade das medições de RSSI. Pois um canal sem fio normalmente é caracterizado por três componentes que não devem ser omitidas em cenários de localização, nomeadamente: perda por percurso (*path loss*), sombreamento (*shadowing*) e multipercurso (*multipath*). Assim, muitos autores [49]–[51] têm procurado utilizar a técnica de *beamforming* nos sistemas de localização, visando obter sinais mais fortes em direções específicas, e reduzir as interferências nos sinais transmitidos e o número de Access Points (APs) necessários.

Em [49] é apresentado uma abordagem baseada em triangulação explorando a propriedade de diretividade do *beamforming* nos lados do transmissor e do receptor. Diferente das abordagens de localização convencionais, o sistema utiliza a transmissão e recepção em múltiplos APs para reduzir o efeito de multipercurso. Com base nos resultados de simulação, a precisão de localização foi satisfatória. Porém, há um custo considerável na aquisição de múltiplos APs com *beamforming*.

Os trabalhos que utilizam os métodos tradicionais de localização, como triangulação e trilateração, apontam para a necessidade de pelo menos três APs a fim de se obter um erro médio aceitável [52]. Porém, é mais usual a instalação de apenas um AP em ambientes realistas. Ainda

que seja possível encontrar sinais de múltiplos APs de ambientes adjacentes, a ampla distância entre os ambientes resultará em maior variabilidade nos sinais e, eventualmente, em uma baixa acurácia de localização.

Em [50] é proposto um método de localização que utiliza um único AP baseado em redes 802.11ac com *beamforming*. O trabalho utiliza a estimativa de parâmetros para o cálculo da distância, como o Time of Arrival (ToA) e Angle of Arrival (AoA) do sinal recebido pelo AP, a partir da resposta do dispositivo conectado. Foram alcançados resultados com precisão, porém, no cenário modelado, foi omitido o efeito de sombreamento e considerada a linha de visada direta (LOS) entre o AP e o dispositivo móvel a todo o momento. Portanto, a proposta pode não apresentar resultados satisfatórios em cenários realistas.

Sistemas de localização indoor baseados em cálculos de triangulação ou trilateração possuem, normalmente, alta complexidade computacional para estimar os parâmetros utilizados. Dessa forma, outros sistemas baseiam-se na análise de assinaturas (*fingerprint*) ou em algoritmos de aprendizado de máquina supervisionado que, por sua vez, utilizam uma base de dados com amostras de RSSI previamente coletadas, reduzindo a complexidade na etapa de localização [3], [4].

Os autores de [51] propõem um sistema de localização interna usando um único AP Wireless Fidelity (Wi-Fi) de quinta geração (5G), ou padrão IEEE 802.11ad. O método utiliza as impressões digitais das potências de cada feixe formado pelo transmissor. Os autores utilizam modelos de classificação baseados em k-Nearest Neighbors (kNN) e no teorema de Bayes. Nas simulações baseadas nas melhores amostras de feixe, pôde-se localizar o dispositivo móvel do usuário estacionário com erro médio inferior a 2,5 metros, mostrando-se um método promissor.

Assim, neste Capítulo, busca-se aprimorar os conceitos propostos em [51] utilizando métodos estatísticos para reduzir a quantidade de características (feixes utilizados) aplicadas como preditores para localização. Este trabalho propõe uma abordagem de localização em ambientes internos utilizando um único transmissor com múltiplas antenas e a técnica de beamforming, com o objetivo de reduzir a complexidade computacional e os custos de implementação.

A principal contribuição deste estudo é a aplicação de abordagens estatísticas para extrair características discriminantes dos sinais de RSSI, diminuindo o número de feixes necessários para estimar a localização. Além disso, um modelo de regressão baseado em kNN é introduzido. O estudo, simulado com MATLAB®, também contribui para o aprimoramento do desempenho de sistemas de localização em cenários realistas, levando em conta a interferência no sinal e a necessidade de um número reduzido de pontos de acesso.

4.2 MATERIAL E MÉTODOS

4.2.1 Cenário experimental e banco de dados

Para o desenvolvimento deste trabalho, foi utilizada o framework Quase Deterministic Radio channel GenerAtor (QuaDRiGa) para a modelagem de canais de rádio Multiple-Input Multiple-Output (MIMO) [53]. Além dos parâmetros das antenas de transmissão e de recepção, o QuaDRiGa permite a simulação de ambientes rurais, urbanos, industriais e internos. A Figura 8 ilustra o ambiente interno simulado com dimensões de 10 m × 10 m, contendo 361 Reference Points (RPs) para o posicionamento dos receptores durante o experimento. Neste cenário foi simulada a existência de um (1) ou mais receptores, dispositivos a serem localizados, posicionados no RPs e equipados com uma antena omnidirecional e, ainda a existência de um (1) transmissor equipado

com múltiplas antenas. No transmissor, as múltiplas antenas são utilizadas para a geração de 128 feixes, gerados na banda de 60 GHz.




Figura 8: Posicionamento dos receptores e do transmissor (TX).

No cenário da Figura 8, foi simulada a transmissão de sinais realizada pelo dispositivo transmissor e, a medição de valores de RSSI dos sinais recebidos a partir de dispositivos receptores, quando posicionados nos RPs. Os valores de RSSI, de cada feixe, medidos pelos receptores posicionados em cada RP foram determinados a partir dos coeficientes de canal, estimados a partir da função `get_lo_channels()` do simulador QuaDRiGa com adição de ruído gaussiano.

Utilizou-se os valores de RSSI, de cada feixe, medidos pelos receptores para gerar um banco de dados, ou mapa de rádio do ambiente. Em uma fase de treinamento, realizou-se medições de 20 valores de RSSI em 180 RPs uniformemente distribuídos, ou seja, em posições alternadas no cenário. Para o conjunto de teste, foram realizadas 20 medições de RSSI em todos os 361 RPs.

4.2.2 Extração de características

Nesta fase, buscou-se encontrar características discriminantes para melhorar a acurácia de localização. Para cada um dos 128 feixes (B_i) em cada RP, calculou-se os quartis a partir das 20 medições de RSSI, resultando em um único vetor (X) com 384 características para cada um dos RPs e Test Points (TPs), conforme a Equação 17.

$$X = [\overbrace{Q_{\frac{1}{4}}, Q_{\frac{2}{4}}, Q_{\frac{3}{4}}}^{B_1}, \overbrace{Q_{\frac{1}{4}}, Q_{\frac{2}{4}}, Q_{\frac{3}{4}}}^{B_2}, \dots, \overbrace{Q_{\frac{1}{4}}, Q_{\frac{2}{4}}, Q_{\frac{3}{4}}}^{B_{128}}], \quad (17)$$

onde B_i , com $i = [1; 2; \dots; 128]$, são os feixes para o qual são calculados os quartis.

Dado que a dimensionalidade dos dados é triplicada, considera-se a aplicação da Principal Component Analysis (PCA) para selecionar as 128 melhores características.

4.2.3 Métrica de desempenho

Para avaliar o modelo de regressão **kNN** com abordagens estatísticas na extração de características, foi considerado o Erro Médio (EM) como medida de desempenho. O EM, dado pela Equação 18, é a soma de todos os desvios/distâncias (D) encontrados entre as posições reais (P) dos **TPs** e as posições preditas ($\hat{P}$), dividida pelo número total (N) de **TPs**. Um valor mais próximo de 0 indica melhor acurácia preditiva.

$$EM = \frac{1}{N} \sum_{i=1}^N D(P, \hat{P}) \quad (18)$$

O desempenho do método proposto, chamado de método I, foi comparado diretamente com a utilização da média (método II) como extrator de características para cada **RP**. Neste segundo método, as médias foram calculadas a partir das 20 medições de **RSSI** de cada feixe. O uso da média para reduzir as variações das medições reduz o erro quadrático das medições, mas não necessariamente extraem características discriminantes. Ambos os métodos I e II foram avaliados com a mesma base de dados gerada pelo simulador **QuaDRiGa**.

O fluxograma da implementação metodológica pode ser observada no fluxograma da Figura 9.




Figura 9: Fluxograma da metodologia desenvolvida.

4.3 RESULTADOS

Inicialmente, o desempenho dos métodos foi analisado observando-se a influência do número de características no EM de localização. O número de características, necessário para minimizar o EM, está relacionado diretamente com o conhecimento adquirido para discriminação dos **RPs**. O EM em função do número de características, são apresentados na Figura 10.




Figura 10: Influência do número de características no erro médio.

Nota-se nas curvas de avaliação de desempenho que à medida que número de características aumenta, o método II mostra-se mais robusto. Utilizando entre 1 e 61 características, o método II obteve o EM variando em torno de 3 e 3,25 metros. O melhor resultado alcançado por este método foi com EM de 1,1366 metros, onde todas as 128 características foram utilizadas. O método proposto (método I) alcançou o melhor resultado nos experimentos, com o EM de 0,7979 metros, a partir de 2 características dos sinais. O método I manteve estabilidade em torno de 1,13 metros de EM ao utilizar entre 11 e 128 características.

Em seguida, buscou-se inferir a confiabilidade dos métodos testados a partir do desvio padrão (σ) das estimativas. A Tabela 5 apresenta as estatísticas das estimativas de localização utilizando 2 e 128 características, respectivamente para os métodos I e II.

Tabela 5: Desempenho dos métodos I e II utilizando 3 características.

Método	Número de características	Erro médio (EM)	Desvio padrão (σ)	Mínimo	Máximo
I	2	0,7979	0,9703	0,0119	6,0168
II	128	1,1366	1,0051	0,0203	6,0120

Nos experimentos, destaca-se que o método proposto baseado em Quartile Analysis (QA) e PCA expressa o menor desvio padrão, sendo este igual a $\sigma = 0,9703$. O desvio padrão apresentado pelo método II, em seu melhor desempenho com 128 características, foi de $\sigma = 1,0051$. O desvio padrão em torno de um (1) metro é considerado satisfatório, dado que se tem um cenário com 100 m^2 .

Enfim, buscou-se a proporção de estimativas de localização com erros abaixo de dois (2) metros. A Figura 11 apresenta a Cumulative Distribution Function (CDF) dos erros com duas (2) características para o método I e com 128 características para o método II.




Figura 11: *CDF (Cumulative Distribution Function) dos erros.*

Nestas CDFs, o método I proposto apresentou a maior acurácia, visto que alcançou a estimativa de aproximadamente 89% das posições com erro de localização abaixo de dois (2) metros, enquanto o método II estimou em torno de 84% das posições, conforme ilustrado na Figura 11. A baixa dimensão dos vetores com duas (2) características, utilizada pelo método proposto, viabiliza ainda mais a utilização da proposta em sistemas embarcados, com menor capacidade de memória e baixo poder de processamento, como dispositivos de localização.

4.4 CONCLUSÕES

Neste Capítulo foi proposto um método de localização em ambientes internos utilizando um único transmissor com múltiplas antenas. Para isso, foram combinados dois métodos estatísticos para representação dos dados: QA e PCA. Foi considerado o regressor kNN para estimar as coordenadas de localização dos pontos de teste.

A partir dos resultados obtidos nos experimentos, pode-se validar o método proposto (Método I) para estimar a localização utilizando o regressor kNN, uma vez que apresentou melhor desempenho ao utilizar somente duas (2) características. Além de apresentar um erro médio de localização satisfatório de 0,7979 metros com desvio padrão de $\sigma = 0,9703$ para a base de dados gerada com o software QuaDRiGa.

5 Redução de esforço na construção de *fingerprints* para localização usando super-resolução

Este trabalho investiga o uso de técnicas de super-resolução para otimizar imagens de *fingerprints* em ambientes internos e semiabertos. O objetivo é reduzir a necessidade de pontos de referência, facilitando a coleta de dados e permitindo uma representação mais precisa do ambiente. O modelo Enhanced Deep Residual Network for Single Image Super-Resolution ([EDSR](#)) alcançou os melhores resultados, com um Peak Signal-to-Noise Ratio ([PSNR](#)) de 30,21 dB com 12 amostras e desempenho ideal com 13 amostras, resultando em um Structural Similarity Index Measure ([SSIM](#)) de aproximadamente 0,786. Esses resultados destacam a eficácia do [EDSR](#) na otimização de bases de dados para sistemas de posicionamento e a importância das técnicas de super-resolução para melhorar a precisão em aplicações de localização.

5.1 INTRODUÇÃO

A localização de dispositivos em ambientes internos e semiabertos é um tema de grande relevância nas redes sem fio, pois pode aprimorar os serviços baseados em localização ou Location-Based Service ([LBS](#)) em várias áreas, como residencial, industrial e de saúde [32]. Embora o sistema de posicionamento global ou Global Positioning System ([GPS](#)) seja eficaz para ambientes externos, sua dependência de sinais transmitidos por satélites compromete a precisão da localização em espaços fechados e semiabertos [33]. Portanto, é essencial explorar alternativas que melhorem a precisão de localização nessas condições, enfrentando os desafios específicos apresentados por esses cenários.

Os *fingerprints* são essenciais para a localização em ambientes internos e semiabertos, oferecendo várias vantagens. Elas proporcionam maior precisão em comparação com métodos tradicionais, como o [GPS](#), que não funciona bem em espaços fechados. Isso ocorre devido ao uso de medições de sinal, como Received Signal Strength Indicator ([RSSI](#)), em pontos específicos para gerar um mapa de intensidade de sinal [15], [54]. Além disso, as *fingerprints* são mais resistentes a interferências, como reflexões e obstruções físicas, que são comuns nesses ambientes.

Quanto mais pontos de referência são coletados, menor tende a ser o erro de localização em metros. Uma maior densidade de amostras resulta em uma representação mais precisa do ambiente, o que aumenta a precisão do mapa de [RSSI](#). No entanto, aumentar fisicamente o número de pontos pode exigir um esforço considerável na coleta de dados. Esse processo demanda mais tempo e recursos, pois envolve deslocamentos por várias áreas e repetição de medições, o que pode ser exaustivo e requer planejamento cuidadoso para garantir que as amostras sejam representativas e precisas.

Uma solução promissora para otimizar imagens de *fingerprints* com um baixo número de pontos de referência é o uso de técnicas de super-resolução, que aumentam a resolução das imagens, melhorando sua qualidade e detalhes. Essas técnicas dividem-se em dois tipos: métodos tradicionais, como interpolação bilinear, bicúbica e Nearest Neighbors, que estimam novos *pixels* a partir dos existentes, e métodos de aprendizado de máquina, que utilizam redes neurais para gerar imagens de alta resolução a partir de versões de baixa resolução. Exemplos incluem Fast Super-Resolution Convolutional Neural Network ([FSRCNN](#)), que realiza *upscaling* rápido;

EDSR, que preserva detalhes; e Efficient Sub-Pixel Convolutional Neural Network (ESPCN), que é computacionalmente eficiente [22]–[24]. Essas abordagens são utilizadas em diversas aplicações, como imagens médicas, monitoramento por câmeras de vigilância, restauração de fotografias e processamento de imagens de satélite.

Este capítulo apresenta contribuições relevantes para o avanço dos sistemas de localização baseados em *fingerprints*, com foco na redução do esforço de construção dessas bases de dados, especialmente em ambientes internos e semiabertos. A aplicação de técnicas de super-resolução, como o modelo EDSR, visa aprimorar a qualidade das imagens de *fingerprints*, proporcionando uma melhor definição espacial com um número reduzido de pontos de coleta, além de uma representação mais precisa do ambiente. Além disso, são discutidas estratégias para simplificar a coleta e a utilização de dados, como o uso do Multiple Imputation by Chained Equations (MICE) para imputação de valores ausentes e a consideração de modelos de propagação de sinal, como o Nakagami-m, para garantir a precisão da coleta. Essas contribuições representam uma abordagem para tornar os sistemas de localização mais eficientes e acessíveis, com um menor custo de implementação.

5.2 MATERIAL E MÉTODOS

5.2.1 Cenário experimental

Os experimentos foram conduzidos no Centro de Convivência do Setor Norte da Universidade Federal do Amazonas (UFAM), sendo um espaço semi-aberto, Figura 12.



Figura 12: *Cenário experimental e setup para coleta.*

No cenário experimental, 720 pontos de referência foram definidos, espaçados horizontalmente por 1,42 metros e verticalmente por 1,45 metros, resultando em uma grade com 24 colunas e 30 linhas. A área total para a realização do experimento foi de $32,66 \times 42,05$ metros quadrados (m^2). A Figura 13 ilustra uma representação dos pontos de referência em suas respectivas coordenadas cartesianas.

Entre os pontos definidos, quatro (4) foram desconsiderados por estarem ocupados por obstáculos fixos. Esses pontos estavam nas coordenadas (4,26; 21,75), (5,68; 21,75), (28,4; 21,75)

e (29,82; 21,75). Esses obstáculos correspondem às bases de duas das colunas de suporte da cobertura do ambiente.




Figura 13: *Cenário experimental.*

5.2.2 Aquisição de dados

A coleta de dados começou no ponto inferior esquerdo (0,00; 42,05) e terminou no ponto superior direito (32,66; 0,00). O trajeto seguido pode ser comparado a um movimento em zigue-zague na direção vertical, subindo e descendo ao longo do eixo Y, conforme ilustrado na Figura 14.




Figura 14: *Movimento durante a aquisição de dados.*

Nesse cenário, 229 pontos de acesso ou Access Points (**APs**) foram detectados, e 50 medições de RSSI foram coletadas de cada ponto de acesso em cada ponto de referência (**RP**). Um script bash foi desenvolvido para execução em um computador com sistema operacional Linux (Ubuntu 20.04.4 LTS) visando automatizar a coleta e organização dos dados em pastas. No script de coleta de dados, o comando "iwlist [interface] scanning" foi utilizado para recuperar informações da interface de rede sem fio [55].

Neste trabalho foi utilizado um dongle RTL-SDR para captura dos dados de potência dos sinais de rádio **FM** que serão utilizados no próximo capítulo. Diversos *smartphones* possuem chip de rádio **FM** ativado e incorporado na placa-mãe. No entanto, necessita-se de acesso ao root do sistema para a aquisição das potências recebidas de cada estação. Esta permissão de acesso pode ser avaliada em pesquisas futuras.

Para a construção do banco de dados, foram coletados o Identificador do Conjunto de Serviços Estendido ou Extended Service Set Identifier (**ESSID**), o Identificador do Conjunto de Serviços Básico ou Basic Service Set Identifier (**BSSID**) e o **RSSI** dos pontos de acesso detectados. Posteriormente, os dados coletados, organizados em pastas, foram formatados em um arquivo Comma-Separated Values (**CSV**) para facilitar a leitura dos dados.

5.2.3 Pré-processamento de dados

Seleção de Pontos de Acesso Wi-Fi: Através da análise exploratória dos dados, foi avaliado o percentual de dados ausentes para cada uma das 229 colunas, correspondentes aos pontos de acesso. Foi constatado que a ausência de dados chegou a até 96% em muitas das colunas. Consequentemente foram selecionados os pontos de acesso com percentual de dados ausentes abaixo de 30%. A Figura 15 mostra os índices das colunas para os 26 pontos de acesso escolhidos para uso nas etapas subsequentes.




Figura 15: Porcentagem de dados ausentes abaixo de 30%.

Imputação de Dados: Após a seleção dos pontos de acesso Wireless Fidelity ([Wi-Fi](#)), três técnicas de imputação de dados foram avaliadas: imputação pela média, imputação pela mediana e imputação multivariada por equações encadeadas ([MICE](#)). Esta imputação é necessária, pois ocorrem perdas esporádicas de dados, causadas por fatores externos (ex.: interferências nos sinais). A avaliação das técnicas de imputação foi realizada utilizando o algoritmo de regressão k-Nearest Neighbors ([kNN](#)).

Para isso, 80% dos dados foram utilizados para criar o modelo de regressão e 20% para a estimativa das coordenadas cartesianas. No algoritmo de regressão kNN, além de variar o hiperparâmetro k , que indica o número de amostras para a regressão, um peso maior pode ser atribuído a amostras mais próximas com base no inverso do valor da distância. A métrica de distância euclidiana, apresentada na Equação 19, foi utilizada nos testes.

$$d(p, q) = \frac{1}{N} \sum_{i=1}^N \sqrt{(q_i - p_i)^2}, \quad (19)$$

onde p é um vetor de amostras de referência e q é um vetor com novas amostras de um ponto a ser localizado. A Figura 16 apresenta os resultados dos testes.

Conforme observado na Figura 16, a técnica de imputação [MICE](#) apresentou os melhores resultados, como esperado, uma vez que essa técnica avalia os métodos de imputação mais básicos e utiliza os melhores dados estimados para complementar o conjunto de dados. Independentemente da técnica utilizada, os melhores resultados foram alcançados com k próximo de 1. Ambas as estratégias de ponderação do modelo de regressão produziram o mesmo resultado para k igual a 1, que foi aproximadamente 0,5 metros. No entanto, o uso da estratégia de ponderação por distância resultou nos menores erros médios para todos os valores de k utilizados.




Figura 16: Erro médio obtido pelo algoritmo de regressão kNN . Estratégias de peso: (a) Uniforme e (b) Distância.

Linha de Visada ou Line of Sight (LOS): A Figura 17 ilustra as medições de RSSI da rede sem fio de número 10 no ponto de referência de coordenada (32,66; 14,50), onde o parâmetro m da Probability Density Function (PDF) Nakagami-m foi estimado como sendo 3,8108.

Após analisar os dados combinados de todos os pontos de acesso em relação aos pontos de referência, foi encontrado que os valores de m variam de aproximadamente 0,7248 a 300. Isso indica casos que vão desde quase Non-line of sight (NLOS) até LOS completa, incluindo situações de LOS parcial. Este experimento tem como objetivo descrever os dados coletados e demonstrar que a imputação de dados usando a técnica MICE não distorceu as informações.

5.2.4 Geração de imagens de fingerprints

Para reduzir o esforço de criação de impressões digitais na fase de modelagem do ambiente, o banco de dados coletado foi reduzido. Para compor o conjunto de dados que será utilizado na modelagem, foi realizada uma amostragem dos pontos de referência definidos no cenário experimental. A Figura 18 apresenta os pontos selecionados para a modelagem do ambiente.




Figura 17: *Medições, histograma e função Nakagami-m.*




Figura 18: *Cenário experimental com menos pontos de referência.*

Após selecionar os pontos de referência para a modelagem do ambiente, uma imagem de impressão digital foi gerada a partir das amostras de [RSSI](#) do ponto de acesso de índice 2, que necessitou de uma menor imputação de dados. Para reduzir o erro quadrático médio das medições, a média aritmética foi calculada a partir de 20 amostras de [RSSI](#) em cada ponto da impressão digital. Os valores de [RSSI](#) foram então mapeados para uma escala de 0 a 255, onde -110 dBm representou o valor mínimo e 30 dBm o valor máximo. Ao final desse processo, obteve-se uma imagem de 10×8 pixels.

Com o objetivo de validar o uso de técnicas de super-resolução ou Super-Resolution ([SR](#)) para aprimorar imagens de impressões digitais, foram realizados testes utilizando tanto métodos tradicionais de redimensionamento quanto redes neurais ([NN](#)). Entre os métodos tradicionais, foram aplicadas as técnicas de interpolação bilinear, bicúbica e Nearest Neighbors. No caso das redes neurais focadas em super-resolução, foram testados os modelos [FSRCNN](#), [EDSR](#) e [ESPCN](#), comparando seu desempenho na melhoria da qualidade da imagem.

5.2.5 Métricas de desempenho

O desempenho dos métodos foram analisados usando métricas de qualidade de imagem, como índice de similaridade estrutural ([SSIM](#)), calculado pela Equação 20; e pico da relação sinal-ruído ([PSNR](#)), calculado pela Equação 21.

$$SSIM = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}, \quad (20)$$

onde x e y representam, respectivamente, a imagem original e a reconstruída; μ_x e μ_y são médias dos valores de x e y ; σ_x^2 e σ_y^2 são variâncias de x e y ; σ_{xy} é a covariância entre x e y ; $C_1 = (k_1 R)^2$ e $C_2 = (k_2 R)^2$ são constantes dependentes do valor máximo de pixel ($R = 2^8 - 1 = 255$). Os valores de k_1 e k_2 são 0,01 e 0,02 por padrão.

$$PSNR = 10 \times \log_{10} \left(\frac{R^2}{MSE} \right) \quad (21)$$

com

$$MSE = \frac{1}{M \times N} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} (x(i, j) - y(i, j))^2, \quad (22)$$

onde R representa o valor máximo de pixel; Mean Squared Error ([MSE](#)) é o erro quadrático médio entre a imagem original (x) e a imagem reconstruída (y); M e N representam, respectivamente, o número de linhas e colunas das imagens.

A otimização das métricas [SSIM](#) e [PSNR](#) consiste em aumentar seus valores. No caso do [SSIM](#), valores mais próximos de um (1) indicam maior similaridade estrutural entre as imagens. Para o [PSNR](#), valores mais altos indicam menor distorção e ruído, sugerindo uma reconstrução com menos perda de qualidade. Essas métricas permitem avaliar a precisão dos métodos de Super-Resolution ([SR](#)) comparando as imagens ampliadas com as originais.

5.3 RESULTADOS

A Figura 19 apresenta o fluxo do primeiro teste de [SR](#), mostrando os resultados para cada método.




Figura 19: Testes com uma amostra.

A primeira imagem na Figura 19 mostra a impressão digital completa. Essa imagem passa por um processo de amostragem ou redução de pontos, resultando na segunda imagem, que representa a impressão digital reduzida. O objetivo desse processo é selecionar apenas os pontos onde um usuário coletaria dados para modelagem. Após essa etapa, foram aplicados algoritmos e modelos de redimensionamento. Para avaliar o desempenho, uma impressão digital foi gerada com uma única amostra por ponto de referência, mostrada na imagem inferior à esquerda, e o índice **SSIM** foi calculado para comparação.

Os resultados apresentados na Figura 19 indicam que o algoritmo **EDSR**, com um índice **SSIM** de 0,726, mostra o melhor desempenho na representação dos pontos de referência que não foram incluídos na modelagem do ambiente de localização. O número de amostras para criar uma nova impressão digital foi aumentado para verificação do desempenho. A Figura 20 ilustra a variação no número de amostras de 1 a 30.




Figura 20: Testes do SSIM com incremento no número de amostras.

Os resultados indicam que o modelo EDSR é o mais adequado para ajustar as *fingerprints* no cenário experimental, apresentando os melhores valores de SSIM. O desempenho ideal é alcançado com 13 amostras, resultando em um SSIM em torno de 0,786. No entanto, um número maior de amostras aumenta o tempo de coleta durante a fase de localização. A Figura 21 apresenta os resultados dos testes de PSNR realizados para medir a qualidade das *fingerprints*. Quanto maior o valor de PSNR, melhor a qualidade da imagem reconstruída.




Figura 21: Testes do PSNR com incremento no número de amostras.

Os resultados de PSNR indicam que o modelo EDSR proporciona a melhor qualidade na representação dos dados de *fingerprint*. O valor mais alto, $PSNR(dB) = 30,21$, foi alcançado com 12 amostras. Este modelo destaca-se como um forte candidato para otimizar bases de dados em sistemas de posicionamento.

Com o objetivo de avaliar o desempenho das técnicas de SR em diferentes redes, os testes foram ampliados para incluir todos os 26 pontos de acesso Wi-Fi. A Figura 22 apresenta os resultados desses testes, evidenciando a variação do número de amostras (N) utilizadas para criar as *fingerprints* de teste, com valores entre 1, 5, 10, 15, 20, 25 e 30. Os valores de SSIM calculados para cada ponto de acesso foram utilizados para elaborar *boxplots* específicos para cada técnica de SR. Para facilitar a análise, os *boxplots* foram organizados de acordo com o desempenho das técnicas.




Figura 22: Testes do SSIM com incremento no número de amostras utilizando todas as redes Wi-Fi.

Os resultados apresentados na Figura 22 revelam que os melhores desempenhos foram alcançados com $N = 10$. Para $N = 15$ ou mais, os valores de SSIM tendem a ser mais baixos ou permanecem constantes. Como o número de amostras (N) influencia diretamente no tempo de localização, $N = 10$ é considerado um valor ideal para os testes. Observa-se ainda que o modelo EDSR se destaca significativamente em relação às demais técnicas.

A Figura 23 apresenta os resultados do PSNR nos testes com todos os 26 APs Wi-Fi.




Figura 23: Testes do PSNR com incremento no número de amostras utilizando todas as redes Wi-Fi.

Os resultados do PSNR também evidenciam a superioridade do modelo EDSR. Com $N = 10$, foram obtidos os melhores desempenhos entre as técnicas avaliadas.

5.4 CONCLUSÕES

Em conclusão, os testes realizados demonstraram que o modelo EDSR se destaca na representação dos dados de impressões digitais, apresentando os melhores resultados em métricas como SSIM e PSNR. O aumento do número de amostras por ponto de referência contribuiu para a melhoria da qualidade das imagens reconstruídas, tornando o EDSR um candidato promissor para a otimização de bancos de dados em sistemas de posicionamento. Esses resultados ressaltam a importância de técnicas avançadas de super-resolução na melhoria da precisão e confiabilidade em aplicações de localização. No próximo capítulo, essa abordagem será ampliada com fusão de dados, combinando múltiplas fontes, como Wi-Fi e FM, para aumentar a precisão e a robustez do sistema.

6 Localização em ambientes semiabertos utilizando fusão de dados

Com o advento da internet das coisas ou Internet of Things (**IoT**), diversas aplicações são ofertadas para dar praticidade nas demandas do dia-a-dia. Muitas destas aplicações exigem o posicionamento do usuário a partir de um dispositivo móvel. Tecnologias de comunicação sem fio, como Wireless Fidelity (**Wi-Fi**), Frequency Modulation (**FM**), Ultra-Wide Band (**UWB**), Long Range (**LoRa**) e outras, são amplamente utilizadas para disponibilizar sistemas de localização. Algoritmos de aprendizado de máquina, tais como o k-Nearest Neighbors (**kNN**), Neural Network (**NN**) ou Convolutional Neural Network (**CNN**) podem ser empregados para reconhecer padrões de características dos sinais em locais de um ambiente sem fio, a fim de disponibilizar a localização. Neste Capítulo, a fim de melhorar a acurácia de localização, propõe-se investigar a utilização conjunta de redes **Wi-Fi** e sinais de rádio **FM**.

6.1 INTRODUÇÃO

Diversos autores buscam categorizar ou classificar os sistemas baseados em localização ou Location-Based Service (**LBS**) considerando as características e funcionalidades em comum, além dos requisitos para funcionamento. O trabalho de Ali et al. 2017 [1] apresenta as seguintes categorias:

- Serviços e aplicações de emergência,
- Serviços e aplicações de rastreamento/gerenciamento,
- Serviços e aplicações de mapa/navegação,
- Serviços e aplicações sociais,
- Serviços e aplicações de informação,
- Serviços e aplicações de jogos/entretenimento, e
- Serviços de publicidade/promoção.

Dado que os **LBSs** aplicam-se em diversos contextos, uma das características que podem diferenciá-los é a precisão. Com isso, cada método proposto na literatura pode ser adequado para certo serviço ou aplicação. Por exemplo, na categoria de serviços e aplicações de rastreamento/gerenciamento, o rastreamento de veículos com dimensões de 4,590 m $\times$ 1,770 m pode ser implementado com erros de até um (1) metro, não inviabilizando a localização do ativo. No entanto, na categoria de serviços e aplicações de informação, a localização de estoques é prejudicada com erros de um (1) metro na busca por caixas medindo 50 cm $\times$ 50 cm $\times$ 50 cm.

As soluções para os problemas de localização são apresentadas com tecnologias emergentes. No entanto, os métodos propostos podem ser implementados com tecnologias precedentes, como redes sem fio 802.11n (Wi-Fi 4), rádio **FM** e Long Term Evolution (**LTE**) [6]. Estas tecnologias ainda são amplamente implantadas e estão acessíveis nos dispositivos móveis atuais.

No trabalho realizado por [56], os autores buscaram uma solução baseada em aprendizado de máquina para uma melhor precisão da localização em áreas urbanas, que é prejudicada pela degradação do desempenho dos sistemas globais de navegação por satélite ou Global Navigation Satellite System (GNSS) em áreas densamente povoadas. A proposta consiste na fusão de dados [57] entre informações do GNSS e impressões digitais (*fingerprints*) do indicador de intensidade do sinal recebido ou Received Signal Strength Indicator (RSSI) dos feixes formados pelo beamforming das redes Fifth Generation (5G).

Foram propostos dois modelos de redes neurais (NN), o primeiro é utilizado para a localização utilizando apenas dados das redes 5G e obteve um erro médio de localização de 3,4 m. O segundo modelo tem por objetivo combinar adequadamente os dados das redes 5G com as informações providas do GNSS. Após a fusão dos dados, obteve-se uma redução de 49% no erro médio de localização, ficando em 1,75 m. Os autores apontam que a utilização de redes neurais convolucionais (CNN) para o reconhecimento de novos padrões é uma abordagem que pode melhorar ainda mais a localização, pois são capazes de ler os padrões nos dados e oferecer desempenho acima do nível humano em visão computacional e reconhecimento de padrões.

As atuais tecnologias de comunicação que aplicam a técnica de *beamforming*, como redes sem fio 802.11ac (Wi-Fi 5) e redes móveis de quinta geração (5G), podem ser utilizadas na localização de dispositivos móveis e obter resultados de localização com maior acurácia. No entanto, a propagação sem linha de visada ou Non-line of sight (NLOS) e multipercurso (*multipath*) ainda degrada a precisão de um sistema de localização baseado no RSSI.

No trabalho realizado por [58], os autores propõem um sistema de localização para ambientes internos utilizando redes Wi-Fi. Os autores empregam impressões digitais multivariáveis ou Multivariable Fingerprints (MVF) que consistem das medidas associadas ao sinal de sincronização secundário ou Secondary Synchronization Signal (SSS): Reference Signal Received Power (RSRP), Reference Signal Received Quality (RSRQ), RSSI e Signal-to-noise and Interference Ratio (SINR).

Os dados coletados são pré-processados usando o filtro de Kalman para suavizar os ruídos e, em seguida, são combinados com as coordenadas dos respectivos pontos de referências ou Access Points (APs) para a geração de uma base de imagens para treinamento de um modelo CNN. Com intuito de aperfeiçoar a precisão, os Reference Points (RPs) que apresentam medições de RSRP pouco afetadas pelo efeito do multipercurso são empregados para estimar um modelo de propagação Log-normal. As medições são selecionadas de acordo com as normas 3GPP TS 38.215.

Na etapa de localização, caso haja um alto nível de ruído nos dados, o posicionamento é calculado diretamente pelo centróide ponderado de todos os RPs. O peso de cada RP é proporcional às probabilidades preditas no modelo CNN. Caso haja baixo nível de ruído, utiliza-se o modelo Log-normal para estimar as distâncias entre a posição a ser localizada e os k RPs mais prováveis. Assim, os pesos dos k RPs são atualizados no cálculo do centróide.

O modelo CNN foi comparado com os algoritmos kNN e perceptron multicamadas ou Multilayer Perceptron (MLP) e apresentou o melhor resultado com erro médio de 1,62 m. A utilização do modelo Log-normal combinado com o modelo CNN resultou em uma melhoria de 9,26% na precisão, assim o erro médio de localização foi de 1,47 m. Para trabalhos futuros, os autores observaram a necessidade de um método mais adequado para combinar os dois modelos propostos.

Apesar de possuírem uma infraestrutura fixa em locais estratégicos nas cidades e alcançarem lugares onde não há presença de sinais Wi-Fi, os sinais das estações de rádio FM podem sofrer interferências externas até chegarem aos ambientes internos. Os trabalhos de [56], [58] promovem o uso de tecnologias heterogêneas como apoio à tecnologia base de um sistema de lo-

calização. Assim, utilizando redes Wi-Fi, pode-se analisar dados com diferentes comportamentos diante dos mesmos obstáculos. Além disso, os APs Wi-Fi são fontes mais próximas de um ponto a ser localizado por serem instalados dentro dos ambientes, e podem auxiliar nas regiões com baixa intensidade do sinal FM. Neste trabalho também será avaliado apenas o uso das redes Wi-Fi para prover a localização.

Neste Capítulo, é proposta uma arquitetura baseada em algoritmos de aprendizado de máquina para localização em ambientes internos e semiabertos. São abordadas estratégias análogas às demonstradas nos trabalhos de [56], [58] para tecnologias heterogêneas. Foram exploradas tecnologias preexistentes de comunicação móvel, como Wi-Fi e rádio FM, integradas à modelagem estatística por meio da distribuição de Nakagami-m. O objetivo é aplicar essas ferramentas para fusão de dados, aprimorando a precisão e eficiência da localização em ambientes internos e semiabertos.

Este trabalho visa contribuir para o aprimoramento das técnicas de localização em ambientes semiabertos, propondo uma abordagem híbrida que combina dados de redes Wi-Fi e sinais de rádio FM. A principal abordagem será a fusão dessas duas tecnologias de comunicação sem fio, com o objetivo de superar limitações causadas por falhas de sinal ou interferências. Espera-se que, ao aplicar o algoritmo de regressão kNN e realizar a adaptação dinâmica do conjunto de dados de *fingerprints*, seja possível manter a precisão e continuidade na estimativa de localização, mesmo em cenários em que os dados das redes Wi-Fi sejam parciais ou ausentes. Além disso, será utilizado o modelo de distribuição Nakagami-m para avaliar a aceitabilidade da rede Wi-Fi em termos de sua qualidade para a localização, considerando a propagação do sinal e sua adequação para ambientes internos e semiabertos. A expectativa é que essa combinação de tecnologias e modelos forneça uma solução robusta e eficiente, capaz de melhorar a precisão de sistemas de localização em cenários reais.

6.2 MATERIAL E MÉTODOS

O diagrama de fluxo da metodologia proposta neste Capítulo, apresentado na Figura 24, está estruturado em duas fases principais: *off-line* e *on-line*. Na fase *off-line*, realiza-se a coleta de dados, que serão pré-processados e utilizados posteriormente para a consulta do modelo de regressão kNN. Já a fase *on-line* refere-se ao processo de localização em tempo real, durante a execução do sistema.




Figura 24: Diagrama de fluxo da metodologia proposta.

O método de localização proposto utiliza o RSSI das redes Wi-Fi e das estações de rádio FM para estimar a posição de um dispositivo. O RSSI é utilizado na técnica de *fingerprinting*, que compara as intensidades do sinal recebido para identificar a localização do dispositivo com base em um banco de dados previamente coletado. O sistema coleta o RSSI de $M = 26$ redes Wi-Fi e utiliza esses valores para determinar a posição do dispositivo, comparando-os com os dados de fingerprints registrados em pontos específicos do ambiente.

Quando a coleta de RSSI de uma ou mais redes Wi-Fi falha, o sistema recorre ao RSSI das estações de rádio FM. Além disso, uma rede Wi-Fi é removida do processo de fusão de dados caso não possua medições suficientes ou se o parâmetro m da distribuição de Nakagami for inferior a três, indicando um ruído elevado nas medições devido à distorção no canal de comunicação.

A estação FM selecionada para compor a base de consulta é a que possui o maior RSSI no momento da coleta. O método proposto ajusta a base de dados (*fingerprints*) em tempo real para garantir que a estimativa de localização não seja comprometida. A coluna correspondente ao Wi-Fi com falha é removida, e os dados previamente coletados da estação FM com maior RSSI no momento da coleta são adicionados ao conjunto de treino. Não é necessário realizar iterações de treinamento no regressor kNN, uma característica intrínseca desse tipo de modelo.

O regressor kNN é utilizado para calcular a proximidade entre os RSSI coletados e os dados conhecidos de *fingerprints*, estimando a localização do dispositivo. A inclusão de dados das estações FM no conjunto de treino ajuda a compensar as falhas nas redes Wi-Fi, mantendo o sistema eficiente e preciso mesmo em cenários de perda de sinal. Dessa forma, o ajuste dinâmico assegura a continuidade da operação do sistema e a precisão das estimativas de localização.

O conjunto de treinamento utilizado nos experimentos é composto pelos dados gerados pela técnica de Super-Resolution (SR) Enhanced Deep Residual Network for Single Image Super-Resolution (EDSR) [23], conforme apresentado no Capítulo 5. Por sua vez, as amostras coletadas que não foram empregadas no conjunto de treinamento foram destinadas à composição do con-

junto de testes. Nos testes realizados, foram comparados três métodos de localização, que se diferem na fonte de dados de RSSI:

1. Utilizando apenas Wi-Fi;
2. Utilizando apenas FM;
3. Utilizando a combinação de Wi-Fi e FM.

6.3 RESULTADOS

Os testes de localização foram realizados em 716 pontos de referência no cenário experimental. Vale ressaltar que, dos 720 pontos definidos, quatro foram desconsiderados devido à presença de obstáculos. Inicialmente, foi analisado o erro médio de localização, em metros, para os três métodos. Nesta análise, para o cálculo do erro médio, os erros dos testes de localização foram agrupados conforme o número de AP Wi-Fi disponíveis no local de teste, conforme ilustrado na Figura 25.




Figura 25: Distribuição dos testes conforme o número de APs Wi-Fi disponíveis.

A distribuição percentual do número de testes conforme a quantidade de redes Wi-Fi disponíveis, apresentada na Figura 25, mostra o quão variável é o número de redes Wi-Fi, o que afetaria um sistema de localização que depende de um número fixo de redes e fixa as redes utilizadas para a estimativa de posição. Essa variação pode impactar a precisão e a confiabilidade do sistema, pois a disponibilidade e a qualidade das redes podem variar conforme a localização e as condições ambientais.

O erro médio de localização em função da quantidade de pontos de acesso Wi-Fi disponíveis é apresentado na Figura 26. Embora o método 2 não utilize APs Wi-Fi, seus erros médios foram

incluídos no gráfico para fins comparativos, considerando os mesmos pontos de teste utilizados nos cenários com diferentes quantidades de APs Wi-Fi disponíveis.




Figura 26: Erro médio de localização em função da quantidade de pontos de acesso Wi-Fi disponíveis.

Na Figura 26, os círculos azuis representam os erros médios dos testes de localização utilizando exclusivamente APs Wi-Fi. Os quadrados vermelhos indicam os erros médios dos testes de localização com o uso exclusivo de estações de rádio FM. Já os triângulos verdes representam os erros médios dos testes de localização combinando APs Wi-Fi e estações de rádio FM.

Utilizando entre 1 e 7 APs Wi-Fi, o método 1 apresentou os maiores erros, sendo superado pelo método 2, que utilizou exclusivamente estações FM. Entre 8 e 12 APs Wi-Fi, os métodos 1 e 2 apresentaram erros semelhantes. A partir de 13 APs Wi-Fi, o método 1 superou o método 2, demonstrando-se superior até 26 APs Wi-Fi.

Ainda na Figura 26, observa-se que o método 3, que combina os dados de Wi-Fi e FM, mostrou superioridade em 100% dos testes quando comparado ao método 1. Ressalta-se que, com 26 APs Wi-Fi, nenhuma estação FM é utilizada nas predições do método 3. Os erros do método 3 só foram piores que os do método 2 quando se utilizou 2 APs Wi-Fi.

Entre 1 e 7 APs Wi-Fi, a maior diminuição do erro foi de 69,90%, obtida quando se encontrou apenas 1 AP Wi-Fi. Nesse caso, o método 1 obteve um erro médio de 18,21 m, enquanto o método 3 obteve 5,48 m. Entre 8 e 12 APs Wi-Fi, a maior diminuição do erro foi de 77,69%, obtida quando se encontraram 12 APs Wi-Fi. Nesse caso, o método 1 obteve um erro médio de 5,86 m, enquanto o método 3 obteve 1,31 m.

A fusão de dados foi eficiente na redução do erro médio de localização, apresentando ganhos de desempenho superiores a 50% nos testes que utilizaram até 12 AP Wi-Fi. Nos testes com 13 ou mais APs Wi-Fi, os erros do método 1 foram menores, resultando em um ganho de desempenho mais modesto para o método 3.

Para avaliar o desempenho dos três métodos em todos os testes realizados, independentemente do número de APs Wi-Fi disponíveis, foi construído o gráfico da função de distribuição

acumulada ou Cumulative Distribution Function (CDF) dos erros de localização, conforme apresentado na Figura 27.




Figura 27: Função de distribuição acumulada dos erros de localização.

O gráfico apresentado na Figura 27 compara os erros brutos de localização obtidos pelos três métodos avaliados. O eixo horizontal representa os valores dos erros em metros, enquanto o eixo vertical exibe a probabilidade acumulada de ocorrência desses erros. Observa-se que o método 3 (Wi-Fi + FM) apresenta a melhor curva na função de distribuição acumulada, indicando maior precisão e menores erros acumulados em comparação aos métodos 1 e 2, que utilizam apenas uma única fonte de dados.

Também foi analisado o tempo necessário para a coleta de dados de cada tecnologia. A Figura 28 apresenta o tempo, em segundos, para a aquisição das medições de RSSI das redes Wi-Fi e das estações de rádio FM.




Figura 28: Tempo para aquisição das amostras de RSSI.

Os dados apresentados na Figura 28 correspondem às médias obtidas a partir de 20 repetições dos testes para cada número de amostras, garantindo maior precisão e representatividade dos resultados. Os experimentos revelaram que o tempo de coleta dos sinais das estações de rádio FM é aproximadamente duas vezes menor que o necessário para coletar os sinais das redes Wi-Fi. Assim, o método 1, que utiliza exclusivamente redes Wi-Fi, apresenta o maior tempo de coleta, enquanto o método 2, que emprega apenas rádio FM, é mais rápido. Já o método 3, que combina Wi-Fi e FM, tem um tempo total de aquisição superior aos métodos anteriores, pois envolve ambas as fontes de dados.

6.4 CONCLUSÕES

A análise dos métodos de localização revelou diferenças significativas no desempenho e nos tempos de coleta de dados entre as abordagens testadas. O método 1, baseado exclusivamente em redes Wi-Fi, apresentou tempos de coleta maiores que o método 2, mas obteve resultados satisfatórios em cenários com maior disponibilidade de pontos de acesso. No entanto, em ambientes com poucos APs Wi-Fi, o desempenho foi comprometido, destacando as limitações da dependência exclusiva de uma única fonte de dados. O método 2, que utiliza apenas sinais de estações FM, mostrou-se vantajoso em cenários com baixa disponibilidade de redes Wi-Fi, mas seu desempenho geral foi inferior ao método 3.

Por sua vez, o método 3, que combina dados de RSSI das redes Wi-Fi e estações FM, demonstrou ser a abordagem mais robusta, apresentando os menores erros de localização em praticamente todos os cenários testados. Apesar de apresentar aumento no tempo de coleta devido à fusão com as medições de RSSI das estações de rádio FM, a fusão de dados resultou em um desempenho consistentemente superior, com ganhos de precisão que superaram 50% em cenários com até 12 APs Wi-Fi e atingiram reduções de erro de até 77,69% em outras situações.

Esses resultados destacam a eficácia da fusão de dados para melhorar a precisão de sistemas de localização, especialmente em ambientes semiabertos com variabilidade na disponibilidade de redes Wi-Fi. A metodologia proposta é promissora para cenários semiabertos onde a disponibilidade de redes Wi-Fi pode variar, garantindo um bom compromisso entre precisão e eficiência temporal.

7 Considerações finais

A presente tese abordou a problemática central de melhorar a precisão e a eficiência de sistemas de localização em tempo real ou Real Time Location System ([RTLS](#)) em ambientes semiabertos, onde obstáculos e limitações das tecnologias de comunicação sem fio frequentemente comprometem a qualidade da localização. A principal contribuição deste trabalho foi a proposta e avaliação de uma metodologia que integra múltiplas tecnologias de comunicação, como sinais de rádio [FM](#) e [Wi-Fi](#), e técnicas de aprendizado de máquina e pré-processamento de dados.

Os resultados obtidos demonstraram que a combinação de sinais [FM](#) e [Wi-Fi](#), aliada ao uso de técnicas de super-resolução para otimização de fingerprints e a fusão dinâmica de dados, levou a um aumento significativo na precisão da localização, especialmente em ambientes semiabertos e em cenários de alta variabilidade do sinal. A integração desses sinais foi fundamental para contornar as limitações das tecnologias isoladas e melhorar a robustez do sistema. Além disso, a aplicação de métodos de aprendizado de máquina, como o regressor [kNN](#), ajudou a reduzir o esforço necessário para o treinamento, oferecendo um sistema mais adaptável e eficiente.

A metodologia proposta neste trabalho, ao viabilizar a redução na coleta de dados e simplificar o processo de configuração e treinamento, mostrou-se promissora para a implementação de sistemas de [RTLS](#) em ambientes variados, com diferentes desafios e exigências. A combinação de múltiplas fontes de dados permite que o sistema se ajuste dinamicamente a diferentes cenários, oferecendo uma solução flexível e escalável para aplicações práticas de localização.

Apesar dos avanços alcançados neste trabalho, ainda existem diversos caminhos a serem explorados para aprimorar os [RTLSs](#). Algumas das direções para trabalhos futuros incluem:

- A super-resolução mostrou-se eficaz na melhoria da localização, permitindo reduzir a coleta de dados. Como trabalho futuro, propõe-se avaliar a escalabilidade do sistema com menos pontos de medição, analisando o impacto na localização e a viabilidade de substituir parcialmente a coleta manual, tornando o sistema mais eficiente para aplicações reais.
- A fusão de dados proposta neste trabalho mostrou bons resultados utilizando a distribuição Nakagami-m, mas há espaço para otimização. O desenvolvimento de novos algoritmos de fusão, mais eficientes em termos computacionais, pode melhorar a adaptabilidade e a precisão do sistema em tempo real. A aplicação de técnicas de aprendizado profundo para combinar diferentes fontes de dados pode ser uma área promissora.
- Finalmente, a realização de testes em larga escala, envolvendo outros ambientes reais, é essencial para validar as soluções propostas em cenários do dia a dia. A implementação de sistemas de [RTLS](#) em ambientes industriais ou em hospitais, por exemplo, proporcionaria dados valiosos para a melhoria contínua do sistema e para a avaliação de sua viabilidade em cenários diversos.

Essas direções futuras não apenas melhorariam a precisão e eficiência dos sistemas de localização, mas também ampliariam sua aplicabilidade a diferentes contextos e necessidades, criando soluções cada vez mais robustas e adaptáveis.

Referências

- [1] A. A. M. Ali, N. A. Ahmad, S. Sahibuddin e M. S. M. Anuar, «Location-based Services: A study on applications and services», *Open International Journal of Informatics (OIJI)*, vol. 5, n.º 2, pp. 7–18, 2017.
- [2] S. R. Jondhale, A. S. Jondhale, P. S. Deshpande e J. Lloret, «Improved trilateration for indoor localization: Neural network and centroid-based approach», *International Journal of Distributed Sensor Networks*, vol. 17, n.º 11, p. 15 501 477 211 053 997, 2021. DOI: [10.1177/15501477211053997](https://doi.org/10.1177/15501477211053997).
- [3] Z. Wu, E. Jedari, B. Liu, R. Rahidzadeh e M. Ahmadi, «Particle Filter and Extreme Learning Machine Based Indoor Localization System», *Proceedings of the IPSN, Seattle, WA, USA*, pp. 14–16, 2015.
- [4] B. Labinghisa e D. M. Lee, «Indoor Localization Algorithm based on Predictive Path Learning in Wi-Fi Environment», *Proceedings of Symposium of the Korean Institute of communications and Information Sciences*, pp. 184–185, 2018.
- [5] P. Puricer e P. Kovar, «Technical limitations of GNSS receivers in indoor positioning», em *2007 17th International Conference Radioelektronika*, IEEE, 2007, pp. 1–5. DOI: [10.1109/RADIOELEK.2007.371487](https://doi.org/10.1109/RADIOELEK.2007.371487).
- [6] S. Urwan, D. R. Wysocka, A. Pietrzak e K. K. Cwalina, «Position estimation in mixed indoor-outdoor environment using signals of opportunity and deep learning approach», *International Journal of Electronics and Telecommunications*, pp. 594–607, 2022. DOI: [10.24425/ijet.2022.141279](https://doi.org/10.24425/ijet.2022.141279).
- [7] A. J. Silva, «As tecnologias de redes wireless», *RNP News Generation*, vol. 2, n.º 5, 1998. URL: <https://memoria.rnp.br/newsgen/9805/wireless.html>.
- [8] J. Deng, B. Liang e P. Varshney, «Tuning the carrier sensing range of IEEE 802.11 MAC», em *IEEE Global Telecommunications Conference, 2004. GLOBECOM '04.*, vol. 5, 2004, 2987–2991 Vol.5. DOI: [10.1109/GLOCOM.2004.1378900](https://doi.org/10.1109/GLOCOM.2004.1378900).
- [9] Q. Ni, «Performance analysis and enhancements for IEEE 802.11e wireless networks», *IEEE Network*, vol. 19, n.º 4, pp. 21–27, 2005. DOI: [10.1109/MNET.2005.1470679](https://doi.org/10.1109/MNET.2005.1470679).
- [10] IEEE Standards Association, *IEEE 802.11: Wireless LANs*, [Online; accessed 15-Feb-2025], 2025. URL: <https://standards.ieee.org/>.
- [11] T. S. Rappaport, *Wireless communications: principles and practice*. Prentice Hall communications engineering e emerging technologies series). Prentice Hall., 2002, vol. 2.
- [12] B. Lantz, «Machine Learning with R. Packt Publishing», *Birmingham Mumbai*, 2015.
- [13] E. Oti, M. Olusola, F. Eze e S. Enogwe, «Comprehensive Review of K-Means Clustering Algorithms», *International Journal of Advances in Scientific Research and Engineering (ijasre)*, vol. 7, n.º 8, 2021. DOI: [10.31695/IJASRE.2021.34050](https://doi.org/10.31695/IJASRE.2021.34050).
- [14] T. Cover e P. Hart, «Nearest neighbor pattern classification», *IEEE transactions on information theory*, vol. 13, n.º 1, pp. 21–27, 1967. DOI: [10.1109/TIT.1967.1053964](https://doi.org/10.1109/TIT.1967.1053964).

- [15] D. Ferreira, R. Souza e C. Carvalho, «Qa-knn: Indoor localization based on quartile analysis and the knn classifier for wireless networks», *Sensors*, vol. 20, n.º 17, p. 4714, 2020. DOI: [10.3390/s20174714](https://doi.org/10.3390/s20174714).
- [16] J. Ortiz-Bejar, M. Graff, E. S. Tellez, J. Ortiz-Bejar e J. C. Jacobo, «k-Nearest Neighbor Regressors Optimized by using Random Search», em *2018 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, 2018, pp. 1–5. DOI: [10.1109/ROPEC.2018.8661399](https://doi.org/10.1109/ROPEC.2018.8661399).
- [17] R. C. Gonzalez e R. E. Woods, «Processamento digital de imagem», *Pearson*, ISBN-10: 8576054019, vol. 10, pp. 11–27, 2010.
- [18] J. Brownlee, «Master Machine Learning Algorithms Discover How They Work and Implement Them From Scratch i Master Machine Learning Algorithms», Technical report, rel. téc., 2016.
- [19] C. Dong, C. C. Loy, K. He e X. Tang, «Image Super-Resolution Using Deep Convolutional Networks», *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, n.º 2, pp. 295–307, 2016. DOI: [10.1109/TPAMI.2015.2439281](https://doi.org/10.1109/TPAMI.2015.2439281).
- [20] W. Shi, J. Caballero, F. Huszar et al., «Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network», em *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [21] B. Lim, S. Son, H. Kim, S. Nah e K. Mu Lee, «Enhanced Deep Residual Networks for Single Image Super-Resolution», em *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, 2017.
- [22] C. Dong, C. C. Loy e X. Tang, «Accelerating the super-resolution convolutional neural network», em *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part II 14*, Springer, 2016, pp. 391–407. DOI: [10.1007/978-3-319-46475-6_25](https://doi.org/10.1007/978-3-319-46475-6_25).
- [23] B. Lim, S. Son, H. Kim, S. Nah e K. Mu Lee, «Enhanced deep residual networks for single image super-resolution», em *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, 2017, pp. 136–144. DOI: [10.1109/CVPRW.2017.151](https://doi.org/10.1109/CVPRW.2017.151).
- [24] W. Shi, J. Caballero, F. Huszár et al., «Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network», em *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 1874–1883. DOI: [10.1109/CVPR.2016.207](https://doi.org/10.1109/CVPR.2016.207).
- [25] A. Joarder e M. Firozzaman, «Quartiles for discrete data», *Teaching Statistics*, vol. 23, n.º 3, pp. 86–89, 2001. DOI: [10.1111/1467-9639.00063](https://doi.org/10.1111/1467-9639.00063).
- [26] E. Langford, «Quartiles in elementary statistics», *Journal of Statistics Education*, vol. 14, n.º 3, 2006. DOI: [10.1080/10691898.2006.11910589](https://doi.org/10.1080/10691898.2006.11910589).
- [27] F. Mosteller e J. W. Tukey, «Data analysis and regression. A second course in statistics», *Addison-Wesley series in behavioral science: quantitative methods*, 1977.
- [28] K. Pearson, «LIII. On lines and planes of closest fit to systems of points in space», *The London, Edinburgh, and Dublin philosophical magazine and journal of science*, vol. 2, n.º 11, pp. 559–572, 1901. DOI: [10.1080/14786440109462720](https://doi.org/10.1080/14786440109462720).
- [29] S.-H. Fang e T. Lin, «Principal component localization in indoor WLAN environments», *IEEE Transactions on Mobile Computing*, vol. 11, n.º 1, pp. 100–110, 2011. DOI: [10.1109/TMC.2011.30](https://doi.org/10.1109/TMC.2011.30).

- [30] H. Abdi e L. J. Williams, «Principal component analysis», *WIREs Computational Statistics*, vol. 2, n.º 4, pp. 433–459, 2010. DOI: [10.1002/wics.101](https://doi.org/10.1002/wics.101).
- [31] A. Goldsmith, *Wireless communications*. Cambridge university press, 2005.
- [32] A. Al-Fuqaha, M. Guizani, M. Mohammadi, M. Aledhari e M. Ayyash, «Internet of things: A survey on enabling technologies, protocols, and applications», *IEEE communications surveys & tutorials*, vol. 17, n.º 4, pp. 2347–2376, 2015. DOI: [10.1109/COMST.2015.2444095](https://doi.org/10.1109/COMST.2015.2444095).
- [33] F. Salim, M. Williams, N. Sony et al., «Visualization of wireless sensor networks using zig-bee's received signal strength indicator (rssi) for indoor localization and tracking», em *2014 IEEE International Conference on Pervasive Computing and Communication Workshops (PERCOM WORKSHOPS)*, IEEE, 2014, pp. 575–580. DOI: [10.1109/PerComW.2014.6815270](https://doi.org/10.1109/PerComW.2014.6815270).
- [34] X. Cai, X. Li, R. Yuan e Y. Hei, «Identification and mitigation of NLOS based on channel state information for indoor WiFi localization», em *2015 International Conference on Wireless Communications & Signal Processing (WCSP)*, IEEE, 2015, pp. 1–5. DOI: [10.1109/WCSP.2015.7341172](https://doi.org/10.1109/WCSP.2015.7341172).
- [35] R. Khullar e Z. Dong, «Indoor localization framework with WiFi fingerprinting», em *2017 26th Wireless and Optical Communication Conference (WOCC)*, IEEE, 2017, pp. 1–6. DOI: [10.1109/WOCC.2017.7928970](https://doi.org/10.1109/WOCC.2017.7928970).
- [36] K. S. Kim, R. Wang, Z. Zhong et al., «Large-scale location-aware services in access: Hierarchical building/floor classification and location estimation using Wi-Fi fingerprinting based on deep neural networks», *Fiber and Integrated Optics*, vol. 37, n.º 5, pp. 277–289, 2018. DOI: [10.1080/01468030.2018.1467515](https://doi.org/10.1080/01468030.2018.1467515).
- [37] W. Le, Z. Wang, J. Wang, G. Zhao e H. Miao, «A novel wifi indoor positioning method based on genetic algorithm and twin support vector regression», em *The 26th Chinese control and decision conference (2014 CCDC)*, IEEE, 2014, pp. 4859–4862. DOI: [10.1109/CCDC.2014.6853043](https://doi.org/10.1109/CCDC.2014.6853043).
- [38] H. Li, M. Syed, Y.-D. Yao e T. Kamakaris, «Spectrum sharing in an ISM band: Outage performance of a hybrid DS/FH spread spectrum system with beamforming», *EURASIP Journal on Advances in Signal Processing*, vol. 2009, pp. 1–11, 2009. DOI: [10.1155/2009/834527](https://doi.org/10.1155/2009/834527).
- [39] S. J. Danbatta e A. Varol, «Comparison of Zigbee, Z-Wave, Wi-Fi, and bluetooth wireless technologies used in home automation», em *2019 7th International Symposium on Digital Forensics and Security (ISDFS)*, IEEE, 2019, pp. 1–5. DOI: [10.1109/ISDFS.2019.8757472](https://doi.org/10.1109/ISDFS.2019.8757472).
- [40] A. Popleteev, V. Osmani e O. Mayora, «Investigation of indoor localization with ambient FM radio stations», em *2012 IEEE International Conference on Pervasive Computing and Communications*, IEEE, 2012, pp. 171–179. DOI: [10.1109/PerCom.2012.6199864](https://doi.org/10.1109/PerCom.2012.6199864).
- [41] A. H. Salamah, M. Tamazin, M. A. Sharkas e M. Khedr, «An enhanced WiFi indoor localization system based on machine learning», em *2016 International conference on indoor positioning and indoor navigation (IPIN)*, IEEE, 2016, pp. 1–8. DOI: [10.1109/IPIN.2016.7743586](https://doi.org/10.1109/IPIN.2016.7743586).
- [42] M. J. Azur, E. A. Stuart, C. Frangakis e P. J. Leaf, «Multiple imputation by chained equations: what is it and how does it work?», *International journal of methods in psychiatric research*, vol. 20, n.º 1, pp. 40–49, 2011. DOI: [/10.1002/mpr.329](https://doi.org/10.1002/mpr.329).

- [43] F. E. Harrell et al., *Regression modeling strategies: with applications to linear models, logistic regression, and survival analysis*. Springer, 2001, vol. 608.
- [44] V. Moghtadaiee e A. G. Dempster, «Indoor location fingerprinting using FM radio signals», *IEEE Transactions on Broadcasting*, vol. 60, n.º 2, pp. 336–346, 2014. DOI: [10.1109/TBC.2014.2322771](https://doi.org/10.1109/TBC.2014.2322771).
- [45] C. Carvalho, E. Mota, E. Ferraz et al., «Entropy based routing for mobile, low power and lossy wireless sensors networks», *International Journal of Distributed Sensor Networks*, vol. 15, n.º 7, p. 1 550 147 719 866 134, 2019. DOI: [10.1177/1550147719866134](https://doi.org/10.1177/1550147719866134).
- [46] P. Bahl e V. N. Padmanabhan, «RADAR: An in-building RF-based user location and tracking system», em *Proceedings IEEE INFOCOM 2000. Conference on computer communications. Nineteenth annual joint conference of the IEEE computer and communications societies (Cat. No. 00CH37064)*, Ieee, vol. 2, 2000, pp. 775–784. DOI: [10.1109/INFCOM.2000.832252](https://doi.org/10.1109/INFCOM.2000.832252).
- [47] K. Kaemarungsi e P. Krishnamurthy, «Properties of indoor received signal strength for WLAN location fingerprinting», em *The First Annual International Conference on Mobile and Ubiquitous Systems: Networking and Services, 2004. MOBIQUITOUS 2004.*, IEEE, 2004, pp. 14–23. DOI: [10.1109/MOBIQ.2004.1331706](https://doi.org/10.1109/MOBIQ.2004.1331706).
- [48] N. Ghourchian, M. Allegue-Martinez e D. Precup, «Real-time indoor localization in smart homes using semi-supervised learning», em *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 31, 2017, pp. 4670–4677. DOI: [10.1609/aaai.v31i2.19093](https://doi.org/10.1609/aaai.v31i2.19093).
- [49] C. Tao e B. Zhou, «Indoor localization with smart antenna system: multipath mitigation with MIMO beamforming scheme», em *2017 IEEE 14th International Conference on Mobile Ad Hoc and Sensor Systems (MASS)*, IEEE, 2017, pp. 303–307. DOI: [10.1109/MASS.2017.23](https://doi.org/10.1109/MASS.2017.23).
- [50] F. Wen e C. Liang, «Fine-grained indoor localization using single access point with multiple antennas», *IEEE Sensors Journal*, vol. 15, n.º 3, pp. 1538–1544, 2014. DOI: [10.1109/JSEN.2014.2364121](https://doi.org/10.1109/JSEN.2014.2364121).
- [51] A. L. Paiva, W. Freitas, I. M. Guerreiro e H. B. Nascimento, «Indoor localization algorithm based on fingerprint using a single fifth generation Wi-Fi access point», *IEEE Latin America Transactions*, vol. 16, n.º 7, pp. 2020–2026, 2018. DOI: [10.1109/TLA.2018.8447371](https://doi.org/10.1109/TLA.2018.8447371).
- [52] A. Khalajmehrabadi, N. Gatsis e D. Akopian, «Modern WLAN fingerprinting indoor positioning methods and deployment challenges», *IEEE Communications Surveys & Tutorials*, vol. 19, n.º 3, pp. 1974–2002, 2017. DOI: [10.1109/COMST.2017.2671454](https://doi.org/10.1109/COMST.2017.2671454).
- [53] S. Jaeckel, L. Raschkowski, K. Börner e L. Thiele, «QuaDRiGa: A 3-D multi-cell channel model with time evolution for enabling virtual field trials», *IEEE transactions on antennas and propagation*, vol. 62, n.º 6, pp. 3242–3256, 2014. DOI: [10.1109/TAP.2014.2310220](https://doi.org/10.1109/TAP.2014.2310220).
- [54] W. Liu, Y. Zhang, Z. Deng e H. Zhou, «Low-cost indoor wireless fingerprint location database construction methods: A review», *IEEE Access*, vol. 11, pp. 37 535–37 545, 2023. DOI: [10.1109/ACCESS.2023.3266874](https://doi.org/10.1109/ACCESS.2023.3266874).
- [55] die.net, *iwlist(8) - Linux man page*, Acesso em: 01 de jun. de 2024. URL: <https://linux.die.net/man/8/iwlist>.
- [56] R. Klus, J. Talvitie e M. Valkama, «Neural network fingerprinting and GNSS data fusion for improved localization in 5G», em *2021 International Conference on Localization and GNSS (ICL-GNSS)*, IEEE, 2021, pp. 1–6. DOI: [10.1109/ICL-GNSS51451.2021.9452245](https://doi.org/10.1109/ICL-GNSS51451.2021.9452245).

- [57] E. F. Nakamura, A. A. Loureiro e A. C. Frery, «Information fusion for wireless sensor networks: Methods, models, and classifications», *ACM Computing Surveys (CSUR)*, vol. 39, n.º 3, 9-es, 2007. DOI: [10.1145/1267070.1267073](https://doi.org/10.1145/1267070.1267073).
- [58] Y. Wang, K. Zhao, Z. Zheng, W. Ji, S. Huang e D. Ma, «Indoor positioning with cnn and path-loss model based on multivariable fingerprints in 5g mobile communication system», *Sensors*, vol. 22, n.º 9, p. 3179, 2022. DOI: [10.3390/s22093179](https://doi.org/10.3390/s22093179).