

Localização em ambientes internos baseada em regressão k NN utilizando *beamforming*

David Ferreira e Celso Carvalho

Resumo—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 artigo é proposto um método de localização utilizando um único transmissor com múltiplas antenas. Neste trabalho, realizou-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 destacou-se ao utilizar somente 2 características dos sinais, provendo a localização com erro médio de 0,7979 m, desvio padrão de 0,9703 m, e acurácia de aproximadamente 89% para erros abaixo da distância de 2 metros.

Palavras-Chave—localização, regressão k NN, quartis, PCA.

Abstract—To locate mobile devices on wireless networks, you can install three or more fixed devices, whose transmitted signals are used as location parameters. The problem with this approach is the increase in energy and monetary costs. Thus, in this article a location method using a single transmitter with multiple antennas is proposed. In this work, static tests were performed in a simulated environment of 100 m^2 with 361 reference points for signal power measurements. As test results, the proposed method stood out for using only 2 characteristics of signals, providing the location with an average error of 0.7979 m, standard deviation of 0.9703 m and accuracy of approximately 89% for errors below the distance of 2 meters.

Keywords—localization. k NN regression, quartiles, PCA.

I. INTRODUÇÃO

A localização de objetos móveis é um tema de grande relevância no campo de desenvolvimento da Internet das Coisas (*internet of things* – IoT) [1], uma vez que tal informação pode contribuir para a funcionalidade de aplicações cientes de contexto nos mais diversos setores [2], tais como, indústrias, residências, comércios e hospitais.

Embora o Sistema de Posicionamento Global (*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 [3].

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 (ou *wireless fidelity* – Wi-Fi), devido à ampla presença dessas redes em locais públicos e privados, e utilizam o RSSI (*Received Signal Strength Indicator*) como parâmetro para determinar a

localização [4]. Estas propostas concentram-se em minimizar os erros de localização e a complexidade computacional [4]–[9].

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*).

Aliado ao avanço das técnicas de *beamforming*, o advento do padrão IEEE 802.11ac (e versões superiores) traz maior velocidade na transmissão de dados. O *beamforming* é empregado a múltiplas antenas disponíveis em um ponto de acesso (*Access Point* – AP) que identificam a posição relativa dos dispositivos móveis conectados, para então efetuar transmissões direcionadas [10], permitindo que os sinais sejam mais fortes em direções específicas.

Assim, muitos autores [11], [13], [15] têm procurado utilizar a técnica de *beamforming* nos sistemas de localização, visando reduzir as interferências nos sinais transmitidos e o número de APs necessários.

Em [11] 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 elevado custo econômico 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 [12]. 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 [13] 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 tempo de chegada (*time of arrival* – ToA) e ângulo de chegada (*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 (*line of sight* – LOS) entre o AP e o dispositivo móvel a todo o momento. Por

David Ferreira, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Amazonas, Manaus-AM, e-mail: ferreirad08@gmail.com; Celso Carvalho, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Amazonas, Manaus-AM, e-mail: ccarvalho@ufam.edu.br.

tanto, 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 [8], [14].

Os autores de [15] propõem um sistema de localização interna usando um único AP 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 NN 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 trabalho, busca-se aprimorar os conceitos propostos em [15] utilizando métodos estatísticos para reduzir a quantidade de características (feixes para a *beamforming*) aplicadas como preditores para localização. Este artigo está organizado nas seguintes seções: Na Seção II apresenta-se a fundamentação teórica. Na Seção III, são apresentados os métodos e a proposta deste artigo. Na Seção IV são expostos os resultados obtidos e na Seção V apresenta-se as conclusões do trabalho.

II. FUNDAMENTAÇÃO TEÓRICA

A. Análise de Quartis

A análise de quartis (*Quartile Analysis - QA*) é um método estatístico utilizado para avaliar a tendência central e a dispersão dos dados. Os quartis particionam um conjunto parcialmente ordenado (poset) em quatro partes iguais. O primeiro quartil ($Q_{\frac{1}{4}}$) ou quartil inferior delimita as 25% menores observações, o segundo quartil ($Q_{\frac{2}{4}}$) ou mediana separa as 50% menores das 50% maiores observações, e o terceiro quartil ($Q_{\frac{3}{4}}$) ou quartil superior delimita as 25% maiores observações [16].

São encontradas na literatura diversas definições para o cálculo dos quartis [17]. Dessa forma, uma equação generalizada para o cálculo computacional/estatístico dos quartis é definida neste artigo. A partir de um poset (S, \leq) com n elementos, 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 respectiva porcentagem p , conforme a Equação 1.

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

com $i = (n - 1)p + 1$

onde $[i]$ é a parte inteira de i .

Para dados altamente assimétricos e/ou afetados por *outliers*, o $Q_{\frac{2}{4}}$ é mais eficiente que a média, e não necessita, previamente, de uma análise exploratória. Além disso, o intervalo interquartil ($IQR = Q_{\frac{3}{4}} - Q_{\frac{1}{4}}$) é uma medida estatística relativamente robusta frente ao desvio padrão [18].

B. Análise de Componentes Principais

A análise de componentes principais (*Principal Component Analysis - PCA*) foi introduzida por Karl Pearson em 1901 e, atualmente, é um método estatístico amplamente utilizado para analisar dados multivariados [19]. 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 [20].

De uma forma geral, a PCA transforma um conjunto de variáveis correlacionadas/redundantes em um novo conjunto de variáveis não-correlacionadas. 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 e, 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 2.

$$s_{xy}^2 = \frac{1}{n} \sum_{i=1}^n [(x_i - \bar{x})(y_i - \bar{y})] \quad (2)$$

Posteriormente, calcula-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:

$$P = DV \quad (3)$$

C. Regressor k -Nearest Neighbors

O algoritmo k -Nearest Neighbors (k NN) é geralmente utilizado em problemas de classificação, como em [21], entretanto, ele também pode ser utilizado em problemas de regressão. O k NN realiza a predição de novos valores a partir de medidas de similaridade entre as variáveis predictoras (x_i). Diferentemente do classificador que utiliza o valor modal, a saída \hat{y} do regressor é calculada como o valor médio dos valores da variável dependente (y_i) dos vizinhos mais similares [22]. 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 (*Test Point - TP*) e cada um dos pontos de referência (*Reference Point - RP*), conforme a Equação 4.

$$D(TP, RP) = \sqrt{\sum_{i=1}^m (x_{TPi} - x_{RPi})^2} \quad (4)$$

onde m é o número de variáveis predictoras, x_{TPi} é o valor da variável i para o TP, e x_{RPi} 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 5.

$$\hat{y} = \frac{1}{k} \sum_{i=1}^k y_i \quad (5)$$

III. MATERIAL E MÉTODOS

A. Cenário experimental e banco de dados

Para o desenvolvimento deste trabalho, foi utilizado o software de código aberto *QUAsi Deterministic Radio channel GenerAtor* (QuaDRiGa) para a modelagem de canais de rádio MIMO (*Multiple-Input Multiple-Output*) [23]. Além dos parâmetros das antenas de transmissão e de recepção, o QuaDRiGa permite a simulação de ambientes rurais, urbanos, industriais e internos.

A Figura 1 ilustra o ambiente interno simulado com dimensões de 10 m \times 10 m, contendo 361 RPs para o posicionamento dos receptores durante o experimento. Neste cenário foi simulada a existência de 01 ou mais receptores, dispositivos a serem localizados, posicionados no RPs e equipados com uma antena omnidirecional e, ainda a existência de 01 transmissor equipado com múltiplas antenas. No transmissor, as múltiplas antenas são utilizadas para a geração de 128 feixes, gerados na banda de 60GHz.




Fig. 1. Posicionamento dos receptores e do transmissor.

No cenário da Figura 1, 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_loss_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.

B. 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 TPs, conforme a Equação 6.

$$X = \left[\overbrace{Q_{\frac{1}{4}}, Q_{\frac{2}{4}}, Q_{\frac{3}{4}}}^{B_1}, \overbrace{Q_{\frac{1}{4}}, Q_{\frac{2}{4}}, Q_{\frac{3}{4}}}^{B_2}, \dots, \overbrace{Q_{\frac{1}{4}}, Q_{\frac{2}{4}}, Q_{\frac{3}{4}}}^{B_{128}} \right] \quad (6)$$

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 análise de componentes principais para selecionar as 128 melhores características.

C. Métrica de desempenho

Para avaliar o modelo de regressão k NN com abordagens estatísticas na extração de características, foi considerado o Erro Médio (EM) como medida de desempenho. O EM, dado pela Equação 7, 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.

$$EM = \frac{1}{N} \sum_{i=1}^N D(P, \hat{P}) \quad (7)$$

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 reduzem o erro quadrático das medições, mas não necessariamente extraem características discriminantes.

A implementação dos métodos pode ser observada no fluxograma da Figura 2.

IV. 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 3.

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




Fig. 2. Fluxograma da metodologia desenvolvida.

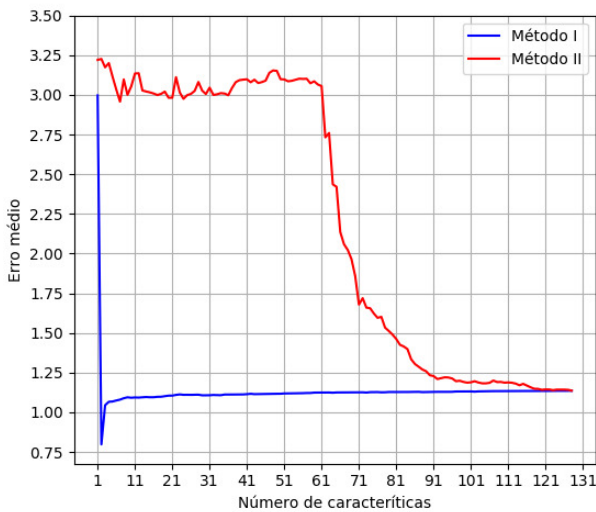


Fig. 3. Influência do número de características no erro médio.

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 das estimativas. A Tabela I apresenta as estatísticas das estimativas de localização utilizando 2 e 128 características, respectivamente para os métodos I e II.

TABELA I

INDICADORES DE DESEMPENHO PARA 3 CARACTERÍSTICAS.

Método	NC	EM	DP	Mín.	Máx.
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 nos quartis (QA) e nas componentes principais (PCA) expressa o menor desvio padrão, sendo este igual a 0,9703. O desvio padrão apresentado pelo método II, em seu melhor desempenho com 128 características, foi de 1,0051. O desvio padrão em torno de 1 metro, é considerado satisfatório, dado que tem-se um cenário com 100 m^2 .

Em fim, buscou-se a proporção de estimativas de localização com erros abaixo de 2 metros. As Figura 4 apresenta a CDF (*Cumulative Distribution Function*) dos erros com 2 características para o método I e com 128 características para o método II.

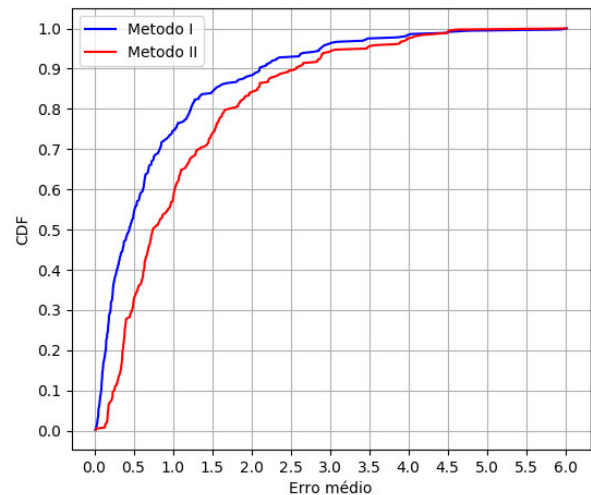


Fig. 4. Acurácias obtidas em cada iteração, acurácia média e desvio padrão.

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 2 metros, enquanto o método II estimou em torno de 84% das posições, conforme ilustrado na Figura 4. A baixa dimensão dos vetores com 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.

V. CONCLUSÕES

Neste trabalho 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: Análise de Quartis (QA) e Análise de Componentes Principais (PCA) e, o regressor k -Nearest Neighbors (k NN) 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 k NN, uma vez que destacou-se ao utilizar somente 2 características. Além de apresentar um erro médio de localização satisfatório de 0,7979 metros com desvio padrão de 0,9703 para a base de dados gerada com o *software* QuaDRiGa.

AGRADECIMENTOS

Esta pesquisa, conforme previsto no Art. 48 do decreto no 6.008/2006, foi financiada pela Samsung Eletrônica da Amazônia Ltda, nos termos da Lei Federal no 8.387/1991, através de convênio no 004, firmado com o CETELI/ UFAM; pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e pela Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM/ProgramaPPP); iv) fundo setorial de infraestrutura (CT-INFRA); v) MCT/CNPQ; vi) Governo do estado do Amazonas.

REFERÊNCIAS

- [1] Carvalho, C., Mota, E., Ferraz, E., Seixas, P., Souza, P., Tavares, V., Lucena Filho, W., Ferreira, D., Manzoni, P., and Calafate, C. (2019). Entropy based routing for mobile, low power and lossy wireless sensors networks. *International Journal of Distributed Sensor Networks*. <https://doi.org/10.1177/1550147719866134>.
- [2] A. Al-fuqaha, M. Guizani, M. Mohammadi, M. Aledhari and M. Ayyash, "Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications," in *IEEE Communications Surveys & Tutorials*, vol. 17, no. 4, pp. 2347-2376, Fourthquarter 2015.
- [3] F. Salim et al., "Visualization of wireless sensor networks using ZigBee's Received Signal Strength Indicator (RSSI) for indoor localization and tracking," 2014 IEEE International Conference on Pervasive Computing and Communication Workshops, Budapest, 2014, pp. 575-580.
- [4] W. Le, Z. Wang, J. Wang, G. Zhao and H. Miao, "A novel WIFI indoor positioning method based on Genetic Algorithm and Twin Support Vector Regression," The 26th Chinese Control and Decision Conference (2014 CCDC), Changsha, 2014, pp. 4859-4862.
- [5] P. Bahl and V. N. Padmanabhan, "RADAR: An in-building RF-based user location and tracking system," in *INFOCOM*. IEEE, March 2000, tel Aviv, Israel.
- [6] K. Kaemarungsi and P. Krishnamurthy, "Properties of indoor received signal strength for WLAN location fingerprinting," The First Annual International Conference on Mobile and Ubiquitous Systems: Networking and Services, 2004. *MOBIQUITOUS 2004.*, Boston, MA, USA, 2004, pp. 14-23.
- [7] N. Ghourchian, M. Allegue-martinez, and D. Precup, "Real-time indoor localization in smart homes using semi-supervised learning," in *Proc. 31st. AAAI Conf. Art. Intel.*, (San Francisco, CA), pp. 4670–4677, 2017.
- [8] Wu, Z., Jedari, E., Liu, B., Rahidzadeh, R. and Ahmadi. M. "Particle Filter and Extreme Learning Machine Based Indoor Localization System". *IPSN*, Seattle, WA, 2015.
- [9] Labinghisa, B. and Lee, D. M. "Indoor Localization Algorithm based on Predictive Path Learning in Wi-Fi Environment". *Proceedings of Symposium of the Korean Institute of communications and Information Sciences*. 2018.
- [10] T. S. RAPPAPORT, "Wireless Communications: Principles and Practice", Prentice Hall, 1996.
- [11] C. TAO AND B. ZHOU, "Indoor Localization with Smart Antenna System: Multipath Mitigation with MIMO Beamforming Scheme," 2017 IEEE 14th International Conference on Mobile Ad Hoc and Sensor Systems (MASS), Orlando, FL, 2017, pp. 303-307.
- [12] A. KHALAJMEHRABADI, N. GATSIS AND D. AKOPIAN, "Modern WLAN Fingerprinting Indoor Positioning Methods and Deployment Challenges," in *IEEE Communications Surveys & Tutorials*, vol. 19, no. 3, pp. 1974-2002, thirdquarter 2017.
- [13] F. WEN AND C. LIANG, "Fine-Grained Indoor Localization Using Single Access Point With Multiple Antennas," in *IEEE Sensors Journal*, vol. 15, no. 3, pp. 1538-1544, March 2015.
- [14] LABINGHISA, B. E LEE, D. M. "Indoor Localization Algorithm based on Predictive Path Learning in Wi-Fi Environment". *Proceedings of Symposium of the Korean Institute of communications and Information Sciences*. 2018.
- [15] A. R. L. Paiva, W. C. Freitas, I. M. Guerreiro and H. J. B. Nascimento, "Indoor Localization Algorithm based on Fingerprint Using a Single Fifth Generation Wi-Fi Access Point," in *IEEE Latin America Transactions*, vol. 16, no. 7, pp. 2020-2026, July 2018, doi: 10.1109/TLA.2018.8447371.
- [16] Joarder, A. H. e Firozzaman, M. *Quartiles for Discrete Data*. *Teaching Statistics*. vol. 23, no 3, 2001.
- [17] Langford, E. *Quartiles in Elementary Statistics*. *Journal of Statistics Education*, vol. 14, no. 3, 2006, DOI: 10.1080/10691898.2006.11910589.
- [18] Mosteller, F. e Tukey, J. W. *Data analysis and regression: a second course in statistics*. Addison-Wesley Series in Behavioral Science: Quantitative Methods, 1977.
- [19] Karl Pearson F.R.S. (1901) 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*, 2:11, 559-572, DOI: 10.1080/14786440109462720.
- [20] Fang, H.S. e Lin, T. *Principal component localization in indoor WLAN environments*. *IEEE Trans. Mobile Comput.*, vol. 11, no. 1, pp. 100-110, 2012, DOI: 10.1109/TMC.2011.30.
- [21] Ferreira, D., Souza, R., and Carvalho, C. (2020). QA-kNN: Indoor localization based on quartile analysis and the knn classifier for wireless networks. *Sensors*, 20(17):4714.
- [22] Ortiz-Bejar, J.; Graff, M.; Tellez, E.; Ortiz-Bejar, J. *k-Nearest Neighbor Regressors Optimized by using Random Search*. *International Autumn Meeting on Power, Electronics e Computing*, 2018.
- [23] S. Jaekel, L. Raschkowski, K. Borner, and 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, no. 6, pp. 3242–3256, 2014.