



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE TELEINFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA

HITALO JOSEFERSON BATISTA NASCIMENTO

**NOVAS ESTRATÉGIAS PARA O PROJETO DE SISTEMAS DE POSICIONAMENTO
3D EM AMBIENTES FECHADOS BASEADOS EM APRENDIZADO DE MÁQUINA.**

FORTALEZA

2018

HITALO JOSEFERSON BATISTA NASCIMENTO

NOVAS ESTRATÉGIAS PARA O PROJETO DE SISTEMAS DE POSICIONAMENTO 3D
EM AMBIENTES FECHADOS BASEADOS EM APRENDIZADO DE MÁQUINA.

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Doutor em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas.

Orientador: Prof. Dr. Francisco Rodrigo Porto Cavalcanti

FORTALEZA

2018

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

N195n Nascimento, Hitalo Joseferson Batista.

Novas estratégias para o projeto de sistemas de posicionamento 3D em ambientes fechados baseados em aprendizado de máquina / Hitalo Joseferson Batista Nascimento. – 2018.
115 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2018.

Orientação: Prof. Dr. Francisco Rodrigo Porto Cavalcanti.

1. Posicionamento indoor 3D. 2. Inferência Bayesiana. 3. Impressão digital. I. Título.

CDD 621.38

HITALO JOSEFERSON BATISTA NASCIMENTO

NOVAS ESTRATÉGIAS PARA O PROJETO DE SISTEMAS DE POSICIONAMENTO 3D
EM AMBIENTES FECHADOS BASEADOS EM APRENDIZADO DE MÁQUINA.

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Doutor em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas.

Aprovada em: 05 de Julho de 2018

BANCA EXAMINADORA

Prof. Dr. Francisco Rodrigo Porto
Cavalcanti (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Augusto José Venâncio Neto
Universidade Federal do Rio Grande do Norte
(UFRN)

Prof. Dr. Ajalmar Rego da Rocha Neto
Instituto Federal do Ceará (IFCE)

Prof. Walter da Cruz Freitas Junior
Universidade Federal do Ceará (UFC)

Prof. Dr. Yuri Carvalho Barbosa Silva
Universidade Federal do Ceará (UFC)

A Deus e à minha família.

AGRADECIMENTOS

Agradeço em primeiro lugar a Deus que iluminou o meu caminho durante esta caminhada, à minha esposa Edineuda por seu amor e companheirismo, aos meus pais Maria Batista da Silva e José Nascimento da Silva por me incentivarem nos momentos de dificuldade, aos meus irmãos Douglas e Handrezza pelo carinho dado e a todos meus amigos pelo apoio ao longo do doutorado. Ao meu orientador, Prof. Dr. Francisco Rodrigo Porto Cavalcanti, com quem tive a imensa honra de aprender bastante, dedico meu agradecimento especial por estar sempre presente, guiando-me na realização deste trabalho. Agradeço ao Prof. Dr. Emanuel Rodrigues por suas valiosas observações e aos colegas Regilane Lima e Mateus Mota pela ajuda neste projeto. Agradeço também a todos os professores do Programa de Pós-Graduação em Engenharia de Teleinformática da Universidade Federal do Ceará.

“A matemática é a rainha das ciências.”

(Carl Friedrich Gauss)

RESUMO

Sistemas de posicionamento *indoor* (IPS) têm atraído muita atenção nos últimos anos, e isso é motivado principalmente por um grande número de aplicações potenciais. No entanto, continua sendo um desafio maximizar a precisão desse tipo de sistema, especialmente para estimativas tridimensionais. Nesta tese, este problema é discutido de forma ampla. Além disso, três soluções baseadas em inferência Bayesiana são propostas. Entre essas soluções, destaca-se o sistema intitulado IPS-MAS, que foi desenvolvido a partir de um sistema multiagente composto por uma rede Bayesiana e uma rede neural profunda. Adicionalmente, esse sistema foi projetado de forma a combinar os métodos de multilateração e impressão digital, a fim de reduzir a região de aquisição dos vetores de intensidade de sinal recebido. Além disso, a relação entre a qualidade do sinal recebido e o nível de ruído, que é influenciada pelo incremento do número de pontos de acesso e do número de pessoas que se deslocam dentro do ambiente, é considerada pelo sistema. Os sistemas propostos apresentaram melhor desempenho quando comparado com os demais, resultando em erros de posicionamento médios de 0,90 m, 1,80 m, 1,82 m, para os algoritmos IPS-MAS, *kmeans*-NB e *kNN*-Bayes, respectivamente (cenário em que a combinação entre o método multilateração e impressão digital foi considerada somente para o algoritmo IPS-MAS) e 0,90 m, 1,12 m, 1,19 m, para os algoritmos IPS-MAS, *kmeans*-NB e *kNN*-Bayes, respectivamente (cenário em que a combinação entre o método multilateração e impressão digital foi considerada para as três soluções).

Palavras-chave: Posicionamento indoor 3D. Inferência Bayesiana. Impressão digital.

ABSTRACT

Indoor positioning systems (IPS) have attracted much attention in recent years, and this is motivated mainly by a large number of potential applications. However, it remains challenging to maximize the precision of this type of system, especially for three-dimensional (3D) estimates. In this research, this problem is discussed in a broad way. In addition, three solutions based on Bayesian inference are proposed. Among these solutions, we highlight the IPS-MAS system, which was developed from a multiagent system composed of a Bayesian network and a deep neural network. Additionally, this proposed system was designed to combine the multilateration and fingerprint methods in order to reduce the acquisition region of the received signal strength vectors. Additionally, the relationship between the quality of the received signal and the noise level, which is influenced by the increase in the number of access points and the number of people moving within the environment, is considered by the system. The proposed systems presented better performance when compared to the others, resulting in mean positioning errors of 0.90 *m*, 1.80 *m*, 1.82 *m*, for the IPS-MAS, *k* means-NB and *k* means-NB, respectively (scenario where the combination between the multilateration and fingerprint method was considered only for the IPS-MAS algorithm) and 0.90 *m*, 1.12 *m*, 1.19 *m* for the algorithms IPS-MAS, *k* means-NB and *k*NN-Bayes, respectively (scenario where the combination between the multilateration and fingerprint method was considered for the three solutions).

Keywords: 3D indoor positioning. indoor 3D. Bayesian Inference. Fingerprint.

LISTA DE FIGURAS

Figura 1 – Configuração original do GPS com três anéis de oito satélites cada	19
Figura 2 – Linha do tempo GPS	21
Figura 3 – Atenuação do sinal dos satélites devido à ausência de linha de visada direta com o usuário	22
Figura 4 – Linha do tempo - IPS	23
Figura 5 – Galeria subterrânea de uma antiga mina de ouro em Quebec, no Canadá . .	26
Figura 6 – IPS baseado em lateração circular	34
Figura 7 – IPS baseado em lateração para o cenário 3D	35
Figura 8 – IPS baseado em lateração hiperbólica	37
Figura 9 – IPS baseado no método de angulação	38
Figura 10 – Localização <i>indoor</i> baseada no método de impressão digital	39
Figura 11 – Ilustração do padrão de sinais temporais no sistema Walkie-Markie	41
Figura 12 – Localização <i>indoor</i> baseada no método de proximidade	42
Figura 13 – Modelo de lançamento de raios	50
Figura 14 – Princípio da imagem. Círculos em cinza: fontes virtuais correspondentes a um único reflexo. Círculos brancos: fontes virtuais correspondentes a reflexões duplas. Linhas pontilhadas: raios das fontes virtuais para o RX. Linhas tracejadas: reflexões reais. Linhas sólidas: linha de visada	51
Figura 15 – Exemplo do algoritmo k -NN para $k = 5$	52
Figura 16 – Arquitetura do modelo McCulloch-Pitts	55
Figura 17 – Diferentes Funções de ativação: (a) Limiar, (b) pseudo-linear, (c) sigmoide e (d) Gaussiana	56
Figura 18 – Modelo básico de neurônio não linear	56
Figura 19 – Arquitetura de uma ANN MLP com uma camada escondida	58
Figura 20 – Arquitetura de uma ANN recorrente com uma camada escondida	58
Figura 21 – Impressão digital obtida em diferentes alturas	63
Figura 22 – Alocação de 500 RPs em 20 <i>clusters</i> com o algoritmo k -means	64
Figura 23 – Histogramas do RSS em uma região específica para diferentes números de <i>bins</i> .	67
Figura 24 – Estimativa de $f_X(x)$ a partir do método <i>kernel</i>	68
Figura 25 – Arquitetura do IPS k means-NB	70
Figura 26 – Estimativa de $P(x)$ para $d = 2$ e $k = 5$	71

Figura 27 – Estimativa de $P(x)$ para $d = 3$ e $k = 4$	71
Figura 28 – Exemplo de aplicação do algoritmo k NN-Bayes em um ambiente com cinco setores para o caso 2D	73
Figura 29 – Exemplo de uma rede Bayesiana com variáveis aleatórias $V = \{A, B, V, D, E, F\}$	76
Figura 30 – Arquitetura de uma DNN	77
Figura 31 – Arquitetura básica de um sistema multiagente IPS	79
Figura 32 – TAN aplicada ao problema IPS	79
Figura 33 – Arquitetura de sistema multiagente IPS com agente moderador	84
Figura 34 – Arquitetura IPS-MAS baseado no algoritmo ACE	86
Figura 35 – Arquitetura geral - IPS-MAS	87
Figura 36 – Arquiterura básica - sistemas de posicionamento para ambientes fechados / <i>indoor positioning system</i> (IPS) baseado em Wi-Fi	91
Figura 37 – Bloco acadêmico 707 - Centro de tecnologia da Universidade federal do Ceará	92
Figura 38 – Planta do primeiro andar do bloco 707 utilizado nos experimentos	92
Figura 39 – Variações da intensidade do sinal em ponto fixo para os quatro APs	93
Figura 40 – CDF do erro de posicionamento com 4 APs	95
Figura 41 – Histograma da distribuição de probabilidade do erro para 16 estimativas para os algoritmos IPS-MAS e k means-BN.	97
Figura 42 – Comparação dos algoritmos IPS-MAS e k means-NB para 16 estimativas	97
Figura 43 – (a) Trajeto real, (b) trajeto estimado com IPS-MAS	98
Figura 44 – CDF do erro de posicionamento para o método ML com 7, 9, 11, 12, 15, 17, 19, 21 e 23 APs simulados a partir do modelo de propagação cost 231 MWM	99
Figura 45 – Precisão em função do número de APs para um erro fixado em 1,5m do posicionamento real para o método multilateração (ML) simulado a partir do modelo de propagação cost 231 MWM	99
Figura 46 – Relação entre precisão e nível de ruído / <i>noise level</i> (NL)	100
Figura 47 – CDF do erro de posicionamento considerando a combinação entre os métodos ML e impressão digital	101
Figura 48 – Comparação da distribuição de probabilidade do erro para 16 estimativas para os algoritmos IPS-MAS e k means-BN considerando a combinação entre os métodos ML e impressão digital	102
Figura 49 – Principais distribuições de probabilidade discretas e contínuas.	115

LISTA DE TABELAS

Tabela 1 – Principais características dos códigos utilizados pelo GPS	20
Tabela 2 – Comparação entre os métodos para posicionamento <i>indoor</i>	42
Tabela 3 – Tipos de paredes utilizadas no Cost 231 MWM	47
Tabela 4 – Valores para L_{w1} , L_{w2} , L_f e b em dB - Cost 231 MWM	48
Tabela 5 – Valores de N para o modelo ITU	48
Tabela 6 – Valores de $L_f(n_p)$ para o modelo ITU	49
Tabela 7 – Alguns valores de RPs e amostras s utilizados na literatura	90
Tabela 8 – Alguns Packages utilizados nas implementações em R.	91
Tabela 9 – Relação entre diferentes valores para os parâmetros de η e o Coeficiente de correlação (CC)	94
Tabela 10 – Valores referentes a recompensas em função do coeficiente de variação (C_v)	94
Tabela 11 – Intervalos de classe para as estimativas de posicionamento	96
Tabela 12 – Estatísticas das estimativas de posicionamento (Média, coeficiente de variação, Q1, Q2, e Q3 em metros)	96
Tabela 13 – Estatísticas das estimativas de posicionamento para o usuário em movimento (Média, coeficiente de variação, Q1, Q2 e Q3 quartis em metros	98
Tabela 14 – Estatísticas das estimativas de posicionamento (Média, coeficiente de variação, Q1, Q2, e Q3 em metros) - Combinação ML e impressão digital	101

LISTA DE ALGORITMOS

Algoritmo 1	– Aplicação do k -NN ao problema de localização <i>indoor</i>	54
Algoritmo 2	– REDES NEURAIS ARTIFICIAIS / <i>artificial neural networks</i> (ANN) perceptron de múltiplas camadas / <i>multilayer perceptron</i> (MLP) apli- cada ao problema de posicionamento <i>indoor</i>	59
Algoritmo 3	– Inferência Bayesiana aplicada ao problema de Posicionamento <i>indoor</i> .	61
Algoritmo 4	– Algoritmo k -means	65
Algoritmo 5	– Algoritmo $kmeans$ -NB para posicionamento <i>indoor</i> 3D	69
Algoritmo 6	– Algoritmo kNN -Bayes para posicionamento <i>indoor</i> 3D	72
Algoritmo 7	– Algoritmo de construção de rede da Pearl.	76
Algoritmo 8	– <i>Backpropagation</i>	77
Algoritmo 9	– Processo de aprendizado em uma rede TAN (FRIEDMAN <i>et al.</i> , 1997)	80
Algoritmo 10	– Obtenção de uma AGM genérica (PANDEY, 2008)	81
Algoritmo 11	– Algoritmo de Prim	81
Algoritmo 12	– Algoritmo de Kruskal	82
Algoritmo 13	– Estrutura básica de uma mensagem KQML. (PANDEY, 2008)	84
Algoritmo 14	– IPS-MAS para posicionamento 3D baseado na tecnologia IEEE 802.11 <i>indoor</i>	88

LISTA DE ABREVIATURAS E SIGLAS

C_v	coeficiente de variação
kNN	k-vizinhos mais próximos / <i>k – nearest neighbors</i>
1SM	<i>one-slope model</i>
2D	espaço bidimensional
3D	espaço tridimensional
ACE	algoritmo de estimativa de ação / <i>action estimation algorithm</i>
AID	ambiente <i>indoor</i> dinâmico
ANN	redes neurais artificiais / <i>artificial neural networks</i>
AOA	ângulo de chegada / <i>Angle of arrival</i>
AP	ponto de acesso / <i>access point</i>
API	interface de programação de aplicação / <i>application programming interface</i>
BLE	<i>Bluetooth</i> de baixa energia / <i>Bluetooth low energy</i>
BN	rede Bayesiana / <i>Bayesian network</i>
CC	Coeficiente de correlação
CDF	função de distribuição acumulada / <i>cumulative distribution function</i>
CFL	lâmpadas fluorescentes compactas / <i>compact fluorescent lamp</i>
CPT	tabela de probabilidade condicional
DAG	grafo direcionado acíclico / <i>directed acyclic graph</i>
DNN	rede neural profunda
FDP	função densidade de probabilidade
GPS	sistema de posicionamento global / <i>global positioning system</i>
IPS	sistemas de posicionamento para ambientes fechados / <i>indoor positioning system</i>
IPS-MAS	sistema de posicionamento baseado em sistemas multiagente
ITU	união internacional de telecomunicações / <i>International Telecommunication Union</i>
KQML	linguagem de consulta e manipulação de conhecimento / <i>knowledge query and manipulation language</i>
LED	diodo emissor de luz / <i>light emitting diode</i>
ML	multilateração
MLP	perceptron de múltiplas camadas / <i>multilayer perceptron</i>
MST	árvore geradora mínima / <i>minimum spanning tree</i>

MWM	modelo de Multi-Parede e Piso / <i>Cost 231 multi-wall model</i>
NB	Naive Bayes
NL	nível de ruído / <i>noise level</i>
OSS	método de secante em um passo / <i>one-step secant</i>
PDA	assistente pessoal digital / <i>personal digital assistant</i>
POO	programação orientada a objetos
RBF	função de base Radial / <i>radial basis function</i>
RF	rádio frequência / <i>radio frequency</i>
RFID	identificação por rádio frequência / <i>Radio – Frequency IDentification</i>
RP	pontos de referência / <i>reference points</i>
RSS	intensidade do sinal recebido / <i>received signal strength</i>
SSID	identificador do conjunto de serviço / <i>service set identification</i>
TAN	árvore aumentada naive Bayes / <i>tree augmented naive bayes</i>
TDOA	diferença do tempo da chegada / <i>time difference of Arrival</i>
TOA	tempo de chegada / <i>time of arrival</i>
VLC	comunicação por luz visível / <i>visible light communication</i>

LISTA DE SÍMBOLOS

η	Taxa de aprendizado;
k	Número de vizinhos mais próximos;
\mathcal{P}	Número de clusters / Partições;
\mathbf{s}	vetor de observações RSS;
\mathcal{P}	Número de clusters / Partições;
L_{LF}	Perda no espaço livre entre transmissor e receptor em dB;
L_c	Constante de perda em dB;
k_{wi}	Número de paredes penetradas do tipo i ;
k_f	Número de pisos penetrados;
L_{wi}	Fator de atenuação nas paredes do tipo i [dB];
L_f	Fator de atenuação entre pisos adjacentes [dB];
b	Parâmetro empírico;
I	Número de paredes distintas;
$L_f(n_p)$	Fator referente a perda de penetração do piso para o modelo ITU;
n_p	Número de pisos entre transmissor e o receptor para o modelo ITU;
γ	coeficiente de propagação;
N_p	Coeficiente de perda no espaço livre entre transmissor e receptor para o modelo ITU;
α_a	Coeficiente de atenuação para o modelo <i>Linear attenuation model</i> ;
n_f	número de pisos para o modelo <i>Wall and floor factor models</i> ;
n_w	número de paredes para o modelo <i>Wall and floor factor models</i> ;
l_f	Fator de atenuação referente aos pisos <i>Wall and floor factor models</i> ;
l_w	Fator de atenuação referente às paredes <i>Wall and floor factor models</i> ;
\mathbf{rp}	vetor de RPs;
C_j	Centróides;
\mathcal{P}_i	Coordenada de posicionamento do alvo;
n_f	Número de pisos entre o transmissor e o receptor;

n_w	Número de paredes entre o transmissor e o receptor;
l_f	Fator de atenuação referentes a pisos;
l_f	Fator de atenuação referentes a paredes;
$\perp\perp$	Independência;
θ	Parâmetro Populacional;
\mathcal{S}	representa o espaço de posicionamento;
V	Volume para uma hiperesfera em d dimensões;
N	Total de observações RSS no ambiente;
n	Total de observações RSS em setor específico;
k_i	Total de observações RSS em setor específico capturadas pela esfera;
\mathcal{E}	Conjunto de estados discretos;
\mathcal{A}	Conjunto de ações realizadas por um agente;
E	Ambiente;
EQM	Erro quadrático médio;
α	Fator de risco para uma ação executada pelo agente;
R_i^j	Parâmetro de relevância associado ao conjunto de ações que podem ser executadas por um agente;
$\hat{\mathbf{E}}$	Matriz de estimativas de posicionamento;
$\hat{\mathbf{p}}$	Posicionamento estimado do alvo;
ε	Erro de posicionamento;
ε_m	Erro médio de posicionamento;
r	Raio representando a distância de um ponto de acesso até o alvo;

SUMÁRIO


1	INTRODUÇÃO	19
1.1	Objetivos	27
1.1.1	<i>Objetivo da Pesquisa</i>	27
1.1.2	<i>Objetivos Específicos</i>	28
1.2	Justificativa e Motivação	28
1.3	Metodologia	28
1.4	Trabalhos Relacionados	29
1.5	Publicações	31
1.6	Organização da Tese	32
2	FUNDAMENTAÇÃO TEÓRICA	33
2.1	Métodos para posicionamento <i>indoor</i>	33
2.1.1	<i>Triangulação</i>	33
2.1.1.1	<i>Lateração circular</i>	33
2.1.1.2	<i>Lateração Hiperbólica</i>	35
2.1.1.3	<i>Angulação</i>	37
2.1.2	<i>Impressão digital</i>	39
2.1.3	<i>Proximidade</i>	41
2.2	Tecnologias de comunicação sem fio para posicionamento <i>indoor</i>	43
2.2.1	<i>WLAN (IEEE 802.11)</i>	43
2.2.2	<i>WPAN (IEEE 802.15)</i>	43
2.2.3	<i>Identificação por radiofrequência (RFID)</i>	44
2.2.4	<i>Dead Reckoning</i>	45
2.2.5	<i>Posicionamento Acústico</i>	45
2.2.6	<i>Luz visível</i>	45
2.3	Modelos de Propagação para Ambientes Fechados	46
2.3.1	<i>one-slope model (ISM)</i>	46
2.3.2	<i>Cost231 multi-wall model</i>	47
2.3.3	<i>ITU indoor Path Loss Model</i>	48
2.3.4	<i>Linear attenuation model</i>	49
2.3.5	<i>Wall and floor factor models</i>	49

2.3.6	<i>Ray launching model</i>	49
2.3.7	<i>Ray tracing model</i>	50
2.4	Algoritmos Baseados em Impressão digital	51
2.4.1	<i>k-nearest neighbors (k-NN)</i>	52
2.4.2	<i>Redes Neurais</i>	54
2.4.3	<i>Inferência Bayesiana</i>	59
3	SOLUÇÕES PROPOSTAS I E II (<i>kMEANS</i> -NB E <i>kNN</i> -BAYES)	62
3.1	Introdução	62
3.2	Método proposto I - <i>kmeans</i> -NB	63
3.3	Método II - <i>KNN</i> -Bayes proposto	70
3.4	Conclusão	74
4	MÉTODO PROPOSTO III - IPS-MAS	75
4.1	Introdução	75
4.2	IPS-MAS	77
4.3	Agente BN	79
4.4	Agente DNN	82
4.5	Comunicação e interação	83
4.6	Conclusão	89
5	RESULTADOS EXPERIMENTAIS	90
6	CONCLUSÕES E TRABALHOS FUTUROS	104
	REFERÊNCIAS	106
	ANEXOS	114
	ANEXO A – DISTRIBUIÇÕES DE PROBABILIDADE:	115

1 INTRODUÇÃO

A ideia de se implementar um sistema de navegação digital surgiu nos anos 1950, quando os primeiros satélites foram lançados. Desde então, sistemas de posicionamento têm atraído muita atenção, e isso é motivado principalmente pelo grande número de aplicações potenciais. Neste contexto, um dos sistemas mais utilizados, o sistema de posicionamento global / *global positioning system* (GPS), consiste de um sistema de rádio-navegação desenvolvido pelo departamento de defesa dos Estados Unidos na década de 1970. O GPS é composto por uma rede de 24 satélites em órbita a uma altura aproximada de 20.200 Km acima do nível do mar em seis diferentes rotas orbitais. Os satélites estão em constante movimento, fazendo duas órbitas completas ao redor da Terra em pouco menos de 24 horas. A figura 1, ilustra a configuração original do GPS com satélites distribuídos em três anéis.

Figura 1 – Configuração original do GPS com três anéis de oito satélites cada



Fonte: Parkinson e Spilker (1996).

Os satélites transmitem duas ondas portadoras $L1$ e $L2$ com frequências derivadas a partir de uma frequência fundamental ($f = 10,23 \text{ MHz}$), o que resulta nas seguintes frequências e comprimento de ondas (PARKINSON; SPILKER, 1996):

- $L1 = 154 : f = 1575,42 \text{ MHz}$, comprimento de onda $19,0 \text{ cm}$;
- $L2 = 120 : f = 1227,60 \text{ MHz}$, comprimento de onda $24,4 \text{ cm}$.
- Código C/A: O código C / A (*course acquisition*) é uma sequência de código que se repete a cada 1 ms . Trata-se de um código pseudo-aleatório transmitido a $1,023 \text{ Mbps}$ com comprimento de onda de $293,1 \text{ m}$;
- Código P (*Precision*) = $10,23 \text{ MHz}$, comprimento de onda de $29,31 \text{ m}$, período de 266 dias. Esse código é dividido em segmentos de sete dias.

As principais características destes códigos utilizados pelo GPS são apresentadas na tabela 1. O GPS utiliza o conceito de tempo de chegada / *time of arrival* (TOA) para determinar a posição do usuário. Esse conceito consiste em medir o tempo de propagação de sinais emitidos por uma constelação de emissores em posições conhecidas em relação ao receptor GPS. Este intervalo de tempo é, então, multiplicado pela velocidade de propagação do sinal, obtendo-se a distância emissor-receptor, estimando assim sua posição.

Tabela 1 – Principais características dos códigos utilizados pelo GPS


<i>Atomic Clock (G,Rb) fundamental frequency</i>	$10,23 \text{ MHz}$
<i>L1 Carrier Signal</i>	$154 \times 10,23 \text{ MHz}$
<i>L1 Frequency</i>	$1575,42 \text{ MHz}$
<i>L1 Wave length</i>	$19,05 \text{ cm}$
<i>L2 Carrier Signal</i>	$120 \times 10,23 \text{ MHz}$
<i>L2 Frequency</i>	$1227,60 \text{ MHz}$
<i>L2 Wave Length</i>	$24,45 \text{ cm}$
<i>P-Code Frequency (Chipping Rate)</i>	10.23 MHz (Mbps)
<i>P-Code Wave length</i>	$29,31 \text{ m}$
<i>P-Code Period</i>	267 dias : 7 Dias/Satélite
<i>C/A-Code Frequency (Chipping Rate)</i>	1.023 MHz (Mbps)
<i>C/A-Code Wave length</i>	$293,1 \text{ m}$
<i>C/A-Code Cycle Length</i>	1 ms
<i>Data Signal Frequency</i>	50 bps
<i>Data Signal Cycle Length</i>	30 s

Fonte: Fell (1994).

A tecnologia de navegação através do GPS, pode ser classificada em quatro gerações (veja a figura 2). A primeira geração, compreendida entre 1985 e 1995, era composta de funções básicas e um conjunto limitado de rotas. Na segunda geração, de 1995 a 2000, houve uma ampliação geográfica (área de cobertura). A terceira geração (2000 a 2005), incluiu recursos como (KARIMI, 2011): a possibilidade de navegação a partir de dispositivos tais como assistente pessoal digital / *personal digital assistant* (PDA), a disponibilidade de rotas

alternativas, o aprimoramento da inclusão de *feedbacks* de usuários ao sistema e a disponibilidade para a população em geral (as gerações anteriores estavam disponíveis apenas em dispositivos instalados em alguns automóveis de luxo). A geração atual é composta de recursos aprimorados das gerações anteriores.


Figura 2 – Linha do tempo GPS



Fonte: Karimi (2011).

Apesar do GPS ser considerado um dos sistemas de posicionamento mais bem sucedidos em ambientes *outdoor*, a baixa precisão em ambientes fechados, devido à atenuação do sinal dos satélites, bem como os diversos obstáculos e materiais que compõem esse tipo de ambiente, tais como: paredes, pisos, divisórias, o torna inadequado para o posicionamento *indoor* (veja a figura 3) (KHALAJMEHRABADI *et al.*, 2016).

Figura 3 – Atenuação do sinal dos satélites devido à ausência de linha de visada direta com o usuário



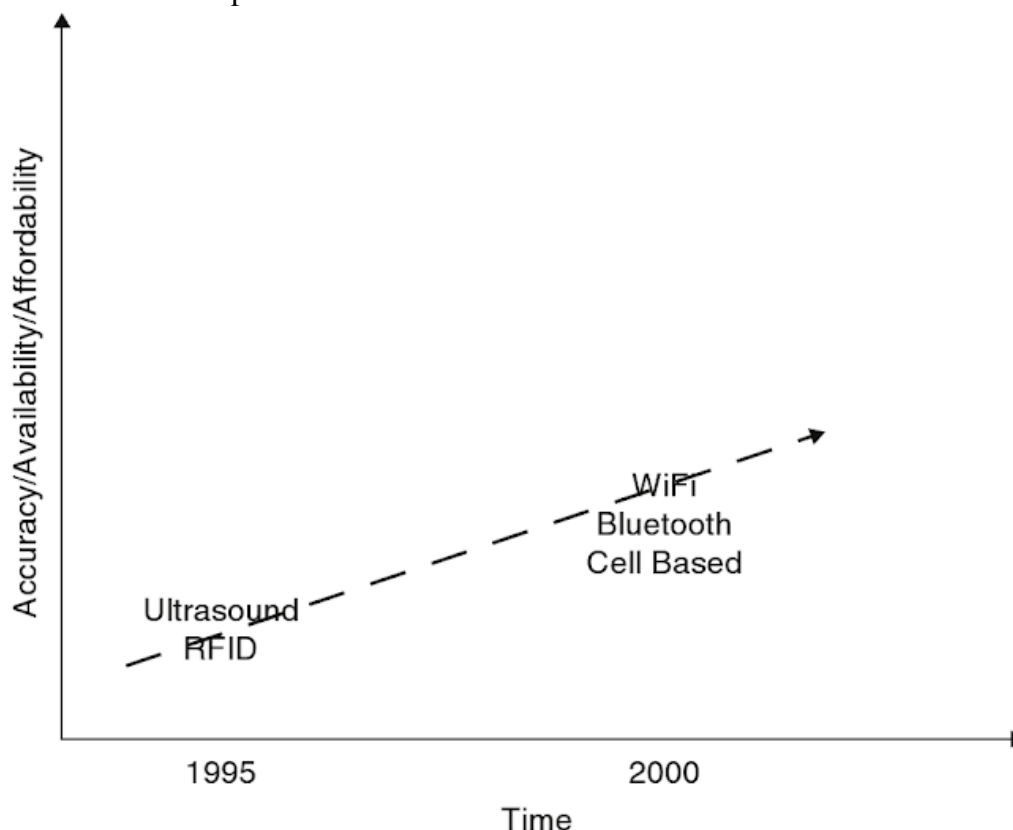
Fonte: Khalajmehrabadi *et al.* (2016).

Neste sentido, muitos estudos têm se dedicado ao tema em questão. Um levantamento dos principais sistemas aplicados a esse problema mostra que eles podem ser divididos em duas principais categorias: os que exigem *hardware* especializado, tais como sistemas baseados em comunicação por luz visível, identificação por rádio frequência / *Radio – Frequency IDentification* (RFID) e sinais acústicos (WANT *et al.*, 1992), (WARD *et al.*, 1997), (PRIYANTHA *et al.*, 2000) e (HOSSAIN *et al.*, 2013). A outra categoria, consiste de sistemas que fazem uso da infra-estrutura existente no ambiente, por exemplo redes Wi-Fi, conforme: Bahl e Padmanabhan (2000), Castro *et al.* (2001), Gwon *et al.* (2004), Wang *et al.* (2012), Roos *et al.* (2002), Ladd *et al.* (2002), (LI, 2006), Battiti *et al.* (2002) e Elnahrawy *et al.* (2004). Com relação às técnicas de implementação, essas podem ser classificadas em três métodos: triangulação, análise de cena (técnica de impressão digital) e proximidade. Esses métodos são discutidos em LIU *et al.* (2007) e YASSIN *et al.* (2017), enquanto que em KRISHNAMURTHY (2015), uma visão geral das principais tecnologias para posicionamento *indoor* é apresentada.

Pesquisas experimentais relacionadas a ambientes *indoor* surgiram no início dos anos 1990. Seidel e Rappaport (1992), propuseram modelos de perda de percurso em função da distância, baseados em dados medidos a 914 MHz. Karimi (2011) classifica o desenvolvimento de sistemas de posicionamento para ambientes fechados / *indoor positioning system* (IPS) em

duas gerações. A figura 4 exibe uma linha do tempo com as principais tecnologias abordadas neste contexto.

Figura 4 – Linha do tempo - IPS



Fonte: Karimi (2011).

A tecnologia da primeira geração, era baseada principalmente no uso de RFID. Neste caso, o posicionamento é obtido através de nós transmissores e receptores anexados a objetos. Esta e outras tecnologias são discutidas no capítulo 2. Christ *et al.* (1993), foi um dos primeiros trabalhos a sugerir que o posicionamento de um alvo pode ser obtido a partir da intensidade do sinal recebido / *received signal strength* (RSS) como função da distância entre o receptor e o transmissor. Por volta do início dos anos 2000, novas abordagens e algoritmos foram propostos, resultando em IPS's com melhor desempenho. A avaliação do desempenho em questão pode ser mensurada através de vários critérios, conforme apresentado a seguir:

- Acurácia: é uma das métricas mais importantes em sistemas de posicionamento. É utilizada como sinônimo de erro de posicionamento. Geralmente, o erro médio da distância entre a posição estimada e a posição real é adotado como a métrica de desempenho. Matematicamente isso significa que (KUSHKI *et al.*, 2012):

$$\boldsymbol{\varepsilon} \triangleq \mathbf{p} - \hat{\mathbf{p}} \quad (1.1)$$

Em que $\hat{\mathbf{p}} = (\hat{p}_x, \hat{p}_y)$ e $\mathbf{p} = (p_x, p_y)$, representam o posicionamento estimado e o real, respectivamente para o espaço bidimensional (2D). A norma l_2 , é definida na equação 1.2, é frequentemente utilizada para estimar o erro de posicionamento.

$$\boldsymbol{\varepsilon} = \|\mathbf{p} - \hat{\mathbf{p}}\| = \sqrt{(\hat{p}_x - p_x)^2 + \hat{p}_y - p_y)^2} \quad (1.2)$$

O erro definido em 1.2, é geralmente calculado sobre várias instâncias de posicionamento, de forma a obter uma medida geral da acurácia do sistema (acurácia do IPS). Este procedimento é definido na equação 1.3.

$$\varepsilon_m = \frac{1}{N} \sum_{i=1}^N \boldsymbol{\varepsilon}(i) \quad (1.3)$$

Em que $\boldsymbol{\varepsilon}(i)$ representa o erro para o i -ésimo posicionamento e N é o número total de estimativas;

- **Precisão:** a acurácia fornece uma medida de desempenho somente em função da distância da posição real do alvo. A precisão, no entanto, fornece uma distribuição do erro da distância entre a posição estimada e a posição real (LIU *et al.*, 2007). Isso é obtido a partir da função de distribuição acumulada / *cumulative distribution function* (CDF), que é comumente descrita no formato de percentil, o que facilita a comparação entre os algoritmos. Como exemplo, considere os cenários a seguir:
 - Cenário I: IPS com precisão de 90% dentro de 2,3 m (90% das estimativas estão distantes no máximo 2,3 m do posicionamento real) e 95% dentro de 3,5 m.
 - Cenário II: IPS com precisão de 50% dentro de 2,3 m e 95% dentro de 3,0m.

Para os cenários acima, poderíamos selecionar o primeiro IPS, dada a maior precisão para o intervalo 0 – 2,3 m.

- **Complexidade:** A complexidade de um sistema de posicionamento pode ser atribuída a fatores como *hardware*, *software* e operação (LIU *et al.*, 2007). Geralmente utiliza-se o tempo de execução dos algoritmos como medida de complexidade. Uma característica a ser considerada é o modo como o IPS será executado. Se for executado em um servidor centralizado, o posicionamento do alvo pode ser estimado rapidamente devido à grande capacidade de processamento e à fonte de alimentação de energia. Se for realizado no lado da unidade móvel, os efeitos da complexidade podem ser evidentes. A maioria das unidades móveis não possuem grande capacidade de processamento e de duração de bateria;

- **Robustez:** Definimos robustez como a capacidade de um sistema tratar erros durante a execução. Um IPS robusto deve funcionar mesmo quando parte da informação necessária estiver indisponível em dado momento ou quando os valores relacionados à entrada apresentarem um padrão muito distinto do que usualmente é tratado pelo sistema. Em um cenário como este, é necessário que os algoritmos de posicionamento utilizem outras informações, como por exemplo, o RSS referentes a outras unidades transmissoras, de forma a maximizar a precisão neste tipo de situação;
- **Escalabilidade:** é um atributo que descreve a capacidade de um IPS se adaptar e funcionar corretamente diante da necessidade de mudanças na dinâmica dos ambientes, minimizando a exigência de modificações no sistema ou inclusão de infra-estrutura extra;
- **Custo:** o custo de um IPS relaciona-se a diversos fatores. Esses fatores incluem tempo, espaço, peso e energia e custos financeiros (LIU *et al.*, 2007). O fator tempo, por exemplo, está relacionado à instalação e manutenção do sistema. Energia é outra variável importante. *Tags* ativas em sistemas baseados em RFID (como discutido posteriormente), exigem fonte de energia própria.

Uma observação importante relacionada a esse tema consiste no fato de que a maioria das pesquisas e tecnologias foram desenvolvidas para uso em escritórios, shoppings, aeroportos, fábricas e ambientes similares. No entanto, existem outros espaços onde os sistemas de posicionamento, rastreamento e navegação desempenham um papel central em operações de segurança e resgate. Esses espaços incluem túneis subterrâneos, minas e até poços e cavernas submarinas. As características a seguir referentes a túneis possuem grande impacto em IPS's projetados para esta finalidade (PEREIRA *et al.*, 2015):

- Alta atenuação do sinal GPS, o que torna esta tecnologia não adequada para este tipo de ambiente;
- Condições difíceis para a propagação de sinais de rádio dentro dos túneis, como alta atenuação, reflexão, refração e desvanecimento por múltiplos caminhos;
- Alta temperatura, especialmente em minas e outros espaços onde grandes máquinas são usadas;
- Alta umidade, característica que afeta a propagação do sinal de rádio;
- Presença de gases inflamáveis, levando ao risco de explosões;
- Dificuldade de acesso a fontes de energia elétrica para alimentar a infraestrutura de posicionamento;

- Dificuldade ou impossibilidade de instalação ou manutenção de novos equipamentos.

Em Nerguizian *et al.* (2006) é proposto um IPS baseado em redes neurais artificiais / *artificial neural networks* (ANN). Os experimentos foram conduzidos em uma galeria subterrânea de uma antiga mina de ouro em Quebec, no Canadá (veja a figura 5). Para o cenário em questão, no melhor caso, o IPS proposto, possui como retorno uma precisão de 90% a uma distância máxima de 2,0m da posição real.

Figura 5 – Galeria subterrânea de uma antiga mina de ouro em Quebec, no Canadá



Fonte: Nerguizian *et al.* (2006).

Nesse sentido, a escolha do conjunto de métodos e tecnologias a serem utilizadas para a implementação de um IPS deve considerar o tipo de ambiente em que se deseja obter o posicionamento do alvo, bem como um conjunto particular de requisitos para o posicionamento e navegação em função do tipo de ambiente. Schneider (2010) identificou um conjunto de requisitos para o posicionamento e navegação nesse contexto, incluindo precisão, capacidades de posicionamento no espaço tridimensional (3D), facilidade de uso, disponibilidade de energia, custo, entre outros.

Dada a importância desse tema de pesquisa e suas inúmeras aplicações, que incluem a utilização em sistemas de emergência, posicionamento de robôs móveis e assistência de navegação em shoppings, escolas, universidades, aeroportos e hospitais, essa tese possui como objetivo propor novas soluções baseadas em inferência Bayesiana para o projeto e implementação de sistemas de posicionamento em ambientes fechados, com foco na maximização da precisão de

sistemas tridimensionais baseado na tecnologia IEEE 802.11. A primeira dessas soluções, consiste em uma combinação dos algoritmos *k – means* e *naive Bayes*, enquanto que o segundo possui como base, o algoritmo k-vizinhos mais próximos / *k – nearest neighbors (kNN)* e o teorema de Bayes. O terceiro algoritmo foi desenvolvido a partir de um sistema multiagente composto de uma rede Bayesiana e uma rede neural profunda. Esse sistema foi projetado de forma a combinar os métodos de multilateração e impressão digital, a fim de reduzir a região de aquisição dos vetores de intensidade de sinal recebido. Além disso, a relação entre a qualidade do sinal recebido e o nível de ruído, que é influenciada pelo incremento do número de pontos de acesso (APs) e do número de pessoas que se deslocam dentro do ambiente, é considerada pelo sistema.

Os experimentos foram conduzidos no primeiro, segundo e terceiro pisos do bloco acadêmico 707, localizado no campus do Pici, Centro de Tecnologia da Universidade Federal do Ceará, em Fortaleza, com área total de 3791,05 m^2 . Essa pesquisa possui as seguintes contribuições:

- Projeto e implementação de três sistemas de posicionamento para ambientes fechados, baseados em inferência Bayesiana, com foco na maximização da precisão para o cenário tridimensional baseado na tecnologia IEEE 802.11. Os resultados experimentais mostram que a terceira abordagem proposta apresenta um erro médio de posicionamento inferior a 0,9 m . Esse resultado é mais preciso do que outras abordagens similares (Wi-Fi / Impressão digital / RSS), que possuem erro médio que varia de 1 a 5 m (DARDARI *et al.*, 2015), com média de 3 a 4 m (BAHL; PADMANABHAN, 2000).
- Uso de simulações para verificar a relação entre a precisão do método multilateração e o incremento do número de pontos de acesso;
- Verificação de como o nível de ruído pode influenciar a precisão dos sistemas de posicionamento;
- Discussão e aplicação dos principais algoritmos abordados na literatura.

1.1 Objetivos

1.1.1 Objetivo da Pesquisa

Abordar de forma ampla os principais métodos, tecnologias e desafios para o posicionamento em ambientes fechados e com base nesses desafios, propor três soluções fundamentadas em inferência Bayesiana com o objetivo de maximizar a precisão para o cenário tridimensional

baseado na tecnologia IEEE 802.11, de forma a contribuir com um avanço na área de pesquisa.

1.1.2 Objetivos Específicos

- Verificar o efeito da combinação entre os métodos multilateração e impressão digital com relação à precisão dos sistemas;
- Verificar se o incremento de pontos de acesso (APs) e do número de pessoas no ambiente pode influenciar no desempenho de sistemas de posicionamento para ambientes fechados;
- Comparar as soluções propostas com as principais abordagens encontradas na literatura.

1.2 Justificativa e Motivação

Vários fatores justificam o desenvolvimento desse trabalho, esses fatores incluem as inúmeras aplicações potenciais, a imprecisão do GPS em ambientes fechados, devido à ausência de linha de visada entre o transmissor e o receptor, o fato de que as pessoas passam a maior parte do tempo em ambientes fechados, sejam em casa, no escritório ou em um ambiente similar. Além disso, o problema de posicionamento em ambientes fechados ainda continua sendo um problema em aberto, principalmente em relação a maximização da precisão que é fundamental para algumas situações específicas. Se para um IPS desenvolvido para localizar pacientes em um hospital, não é necessário uma precisão que possua como retorno poucos centímetros, bastando uma precisão da ordem de $1 - 2\text{ m}$, um sistema de navegação *indoor* desenvolvido para deficientes visuais é muito dependente da precisão. Nesse sentido, essa pesquisa é motivada pelo desafio da maximização da precisão de sistemas de posicionamento *indoor*, principalmente para o cenário 3D.

1.3 Metodologia

- Identificação dos pontos de referência (pontos de coleta de sinais);
- Identificação dos APs;
- Teste das flutuações do sinal a partir de um ponto fixo;
- Realização do levantamento da impressão digital do ambiente e armazenamento das amostras no banco de dados;
- Implementação dos algoritmos;
- Realização de leituras em diferentes pontos do ambiente e aplicação dos algoritmos;

- Comparação dos desempenhos dos algoritmos quando apenas o algoritmo baseado no conceito de multiagente, é implementado a partir da combinação entre multilateração e impressão digital;
- Comparação do desempenho dos algoritmos quando todos os algoritmos baseados em impressão digital são implementados a partir da combinação desse método com a multilateração;
- Verificação da relação entre o incremento do número de APs e a precisão do método de multilateração.

1.4 Trabalhos Relacionados

Existem vários trabalhos relacionados ao tema de pesquisa em questão. Muitos desses trabalhos são apresentados ao decorrer desse trabalho.

Na pesquisa conduzida por Liu *et al.* (2012), é proposta uma abordagem de localização assistida por pares para reduzir grandes erros. Este sistema obtém boas estimativas através do mapeamento conjunto entre dois dispositivos móveis em diferentes posições a partir de um mapa de assinatura *Wi-Fi* sujeito a restrições de alcance. Segundo os autores, os experimentos mostram que essa abordagem pode limitar o erro máximo em $2m$. No entanto, este sistema requer um servidor central para receber medições de sinal e determinar as localizações dos pares e as distâncias entre eles.

Em Li *et al.* (2016), uma abordagem chamada FS - kNN é proposta para considerar o fato de que as diferenças da intensidade de sinal recebido em níveis distintos de RSS não significam necessariamente diferenças semelhantes na distância geométrica. Os experimentos relatados mostram que 80% estimativas de posicionamento estão distantes no máximo $2,5 m$ da posição real.

No estudo realizado por Roos *et al.* (2002), sugere-se a aplicação de aprendizado de máquina para o problema de posicionamento *indoor*. O algoritmo kNN e dois métodos, chamados de *kernel* e histograma, baseados no teorema de Bayes, são propostos como solução do problema. Os resultados mostram que os métodos probabilísticos produziram resultados ligeiramente melhores que o algoritmo kNN .

Em Fang *et al.* (2017) é proposto um algoritmo de posicionamento para redes de sensores sem fio baseado em um modelo evolucionário multi-objetivo, de forma a minimizar os efeitos do ruído sobre o sistema posicionamento. A precisão média reportada para este sistema

foi de 1,02 *m* no melhor caso.

O estudo conduzido por Gan *et al.* (2017), é proposto um sistema de posicionamento baseado em aprendizagem profunda, intitulado DL-IMPS. Este sistema busca resolver o problema da baixa precisão em relação ao posicionamento em ambientes fechados em cenários com conjunto de treinamentos insuficientes. Este sistema de posicionamento 2D, segundo os autores possui um erro médio de 0,52 *m* e 93,3% das estimativas dentro de um 1 *m*.

Na pesquisa desenvolvida por Huang e Manh (2016), foi proposto um sistema de posicionamento baseado em uma função *Kernel* multidimensional, que foi aplicada de forma a tratar a dissimilaridade do RSS em regiões vizinhas ocorridas devido as flutuações de sinais em ambientes fechados, o que pode resultar em baixa precisão na estimativa de posicionamento do alvo. Segundo os autores, o sistema apresenta melhores resultados em relação a trabalhos anteriores em ambientes de teste com ruído, movimento dinâmico de objetos, e variação de RSS multimodal.

Em Bozkurt *et al.* (2015), diferentes algoritmos para aprendizado de máquina aplicados ao posicionamento *indoor*, são comparados em relação à precisão e tempo de processamento.

O sistema de posicionamento COMPASS proposto por King *et al.* (2006) utiliza conjuntamente a infra-estrutura IEEE 802.11 e bússolas digitais disponíveis em telefones celulares de forma a determinar o posicionamento e orientação do alvo. Segundo os autores este procedimento conjunto pode representar uma melhora significativa na precisão de sistemas de posicionamento. O erro médio relatado para essa abordagem é 1,65 *m* para um ambiente de 312 *m*².

Em Cota-Ruiz *et al.* (2013), os autores introduzem um algoritmo de posicionamento distribuído para uma rede de sensores sem fio, em que um conjunto de sensores determina a posição de forma iterativa e colaborativa através de estimativas de alcance e posição para os vizinhos dentro de sua faixa de comunicação. Os autores concluem que o desempenho da abordagem proposta é bastante competitiva quando comparado com abordagens similares. No entanto, a atenuação devido ao desvanecimento por multipercursos ou multicaminhos podem degradar o desempenho do sistema. Além disso, o método proposto possui grande custo computacional comparado com sistemas similares.

Um estudo conduzido por Shareef *et al.* (2007), discute sobre os efeitos do ruído em sistemas de posicionamento. Nessa pesquisa, compara-se qualitativamente o desempenho de três diferentes famílias de redes neurais e os resultados são comparados com duas variantes do filtro

de Kalman que são tradicionalmente usados em sistemas de posicionamento.

1.5 Publicações

- NASCIMENTO, HITALO JOSEFERSON BATISTA; CAVALCANTI, FRANCISCO RODRIGO P. ; RODRIGUES, EMANUEL B. ; PAIVA, ANTONIO R. . APPLICATION OF MULTIAGENT SYSTEMS TO THREE-DIMENSIONAL POSITIONING PROBLEM IN INDOOR ENVIRONMENTS BASED ON IEEE 802.11. PROGRESS IN ELECTROMAGNETICS RESEARCH LETTERS, v. 75, p. 53-59, 2018.
- NASCIMENTO, HITALO; CAVALCANTI, FRANCISCO R.P. ; RODRIGUES, EMANUEL B. ; PAIVA, ANTÔNIO R. . An algorithm for three-dimensional indoor positioning based on Bayesian inference, Fingerprinting method and Wi-Fi technology. INTERNATIONAL JOURNAL OF ADVANCED ENGINEERING RESEARCH AND SCIENCE, v. 4, p. 166-175, 2017.
- NASCIMENTO, H. J. B.; CAVALCANTI, F. R. P. ; RODRIGUES, E. B. ; PAIVA, A. R. . An Algorithm Based on Bayes Inference And K-nearest Neighbor For 3D WLAN Indoor Positioning. In: XXXIV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais, 2016, Santarém. Anais do XXXIV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT 2016), 2016. p. 1-5.
- PAIVA, A. R.; W. C. Freitas; I. M. Guerreiro; NASCIMENTO, H. J. B. Indoor Localization Algorithm based on Fingerprint Using a Single Fifth Generation Wi-Fi Access Point. IEEE Latin America Transactions. Fator de Impacto(2016 JCR): 0,6310, v.16, p.2021 - 2027, 2018.
- PAIVA, A. R. ; CAVALCANTI, F. R. P. ; NASCIMENTO, H. J. B. . Avaliação de Algoritmos de Localização Indoor baseados em Mapa de Assinatura de WLANs. In: XXXIV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais, 2016, Santarém. Anais do XXXIV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT 2016), 2016. p. 1-5.

1.6 Organização da Tese

O restante dessa tese está organizada na seguinte maneira: no capítulo II, apresenta-se os principais métodos para posicionamento para ambientes fechados, que incluem a triangulação, impressão digital e proximidade. Ao final seção 2.1, uma comparação entre os métodos é apresentada. Na seção 2.2 apresenta-se uma discussão das principais tecnologias relacionadas ao posicionamento *indoor*. Os modelos de propagação e algoritmos mais comuns utilizados nesse contexto, são discutidos nas seções 2.3 e 2.4 respectivamente.

No capítulo III, a seção 3.1 apresenta uma visão geral sobre o procedimento de aquisição de sinais e introduz os algoritmos *kmeans-NB* e *kNN-Bayes*. Esses algoritmos são discutidos em detalhes nas seções 3.2 e 3.3.

O capítulo IV, na seção 4.1 discute-se de forma geral sobre a terceira abordagem proposta (IPS-MAS). Uma apresentação detalhada desse IPS, incluindo, uma visão geral sobre sistemas multiagentes, redes Bayesianas, redes neurais e a arquitetura do sistema, é discutida nas seções 4.2 – 4.5.

No capítulo V apresenta-se o cenário de testes, a metodologia adotada nos experimentos e os resultados computacionais. Por fim, são apresentadas as conclusões e trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, apresenta-se uma visão geral sobre as principais abordagens relacionadas ao posicionamento *indoor*. A seção 2.1, introduz os principais métodos de posicionamento *indoor*. As tecnologias relacionadas ao problema em questão são abordadas na seção 2.2. Na seção 2.3 os principais modelos de propagação em ambientes *indoor* são apresentados, e por fim, os principais algoritmos de baseado em reconhecimento de padrões, são apresentados na seção 2.4.

2.1 Métodos para posicionamento *indoor*

Na literatura é comum classificar em três os métodos de estimativa de posicionamento em ambientes fechados: triangulação, impressão digital e proximidade. Esses métodos são discutidos a seguir:

2.1.1 Triangulação

O método de triangulação utiliza propriedades geométricas baseadas em triângulos para estimar a localização do usuário. Este método é classificado em duas categorias:

2.1.1.1 Lateração circular

Neste método, o posicionamento do alvo é obtido a partir da sua distância a múltiplos APs. Usualmente utiliza-se a técnica TOA para estimar essas distâncias. Para um posicionamento 2D é necessário pelo menos três APs como pontos de referência. A figura 6 ilustra este conceito. Matematicamente, este método pode ser definido da seguinte forma:

Definição 2.1.1. Sejam (x_1, y_1) , (x_2, y_2) e (x_3, y_3) as coordenadas cartesianas 2D referentes a três APs centrados em uma região circular e cujas distâncias (raios) até o alvo (x, y) , são dadas por r_i^2 , para $i = 1, 2, \dots, 3$, que resulta na equação 2.1.


$$r_i^2 = (x - x_i)^2 + (y - y_i)^2 \quad (2.1)$$

A posição do alvo é estimada a partir da interseção dos círculos (KUSHKI *et al.*, 2012). Isso é feito através da aplicação do método dos mínimos quadrados ao sistema de equações definido em 2.1, que resulta nas equações 2.2 e 2.3.

$$r_i^2 - r_1^2 = (x - x_i)^2 + (y - y_i)^2 - (x - x_1)^2 - (y - y_1)^2 \quad (2.2)$$

$$= x_i^2 + y_i^2 - x_1^2 - y_1^2 - 2x(x_i - x_1) - 2y(y_i - y_1) \quad (2.3)$$

Figura 6 – IPS baseado em lateração circular



Fonte: o autor.

Se considerarmos $i = 1, 2, \dots, N$, pode-se reescrever o sistema apresentado na equação 2.3 em forma matricial, resultando na equação 2.4.

$$\mathbf{H}\mathbf{X} = \mathbf{B} \quad (2.4)$$

em que $\mathbf{X} = [x, y]^T$, descreve as coordenadas que devem ser determinadas,

$$\mathbf{H} = \begin{pmatrix} x_2 - x_1 & y_2 - y_1 \\ \vdots & \vdots \\ x_n - x_1 & y_n - y_1 \end{pmatrix} \quad (2.5)$$


$$\mathbf{B} = \frac{1}{2} \begin{pmatrix} (r_1^2 + r_2^2) + (x_2^2 + y_2^2) - (x_1^2 + y_1^2) \\ \vdots \\ (r_1^2 + r_n^2) + (x_n^2 + y_n^2) - (x_1^2 + y_1^2) \end{pmatrix} \quad (2.6)$$

Assim o método dos mínimos quadrados pode ser aplicado de forma a estimar o posicionamento do alvo através da equação 2.7 (KUSHKI *et al.*, 2012).

$$\mathbf{X} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{B} \quad (2.7)$$

De modo análogo ao caso do 2D, o posicionamento para o espaço tridimensional (3D), denominado de multilateração (ML), é obtido a partir da estimativa da distância dos APs ao alvo. Neste caso, necessita-se de pelo menos quatro APs. Centrada em cada um dos APs, define-se uma esfera com raio r , sendo a localização do usuário definida pela intersecção de tais esferas. O sistema é análogo ao GPS. A figura 7 ilustra este conceito, enquanto que a equação 2.8 descreve matematicamente esta expansão.

Figura 7 – IPS baseado em lateração para o cenário 3D



Fonte: o autor.

$$r_i^2 = (x - x_i)^2 + (y - y_i)^2 + (z - z_i)^2 \quad (2.8)$$

2.1.1.2 Lateração Hiperbólica

O método de lateração hiperbólica utiliza a técnica conhecida como diferença do tempo de chegada / *time difference of Arrival* (TDOA), para obter a posição do alvo. Similar a lateração circular, um sistema de equações pode ser composto da diferença entre todos os pares de pontos d_{ij} , para $\forall i, j; i \neq j$, conforme a equação definida em 2.9 e 2.10.

$$d_{ij} = r_i - r_j \quad (2.9)$$

$$= \sqrt{(x-x_i)^2 + (y-y_i)^2} - \sqrt{(x-x_j)^2 + (y-y_j)^2} \quad (2.10)$$

A solução para este sistema de equações pode ser obtido de forma similar à lateração circular (KUSHKI *et al.*, 2012), observando que:

$$(r_1 + d_{i1})^2 = r_i^2 \quad (2.11)$$

$$x_i^2 + y_i^2 - x_1^2 - y_1^2 - 2x(x_i - x_1) - 2y(y_i - y_1) - d_{i1} - 2d_{i1}r_1 = 0 \quad (2.12)$$

O sistema de equações definido nas equações 2.11 e 2.12, pode ser escrito de forma matricial como:

$$\mathbf{H}\mathbf{X} = \mathbf{B} \quad (2.13)$$

Em que:

$$\mathbf{X} = [x, y, r_1]^T, \quad (2.14)$$


$$\mathbf{H} = \begin{pmatrix} x_2 - x_1 & y_2 - y_1 & r_{21} \\ \vdots & \vdots & \vdots \\ x_n - x_1 & y_n - y_1 & r_{n1} \end{pmatrix} \quad (2.15)$$

$$\mathbf{B} = \frac{1}{2} \begin{pmatrix} (x_2^2 + Y_2^2) - (x_1^2 + Y_1^2) - d_{21}^2 \\ \vdots \\ (x_n^2 + Y_n^2) - (x_1^2 + Y_1^2) - d_{n1}^2 \end{pmatrix} \quad (2.16)$$

Aplicando o método dos mínimos quadrados, obtêm-se a estimativa definida na equação 2.17. O conceito de lateração hiperbólica é ilustrado na figura 8.

$$\mathbf{X} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{B} \quad (2.17)$$

Figura 8 – IPS baseado em lateração hiperbólica




Fonte: Kushki *et al.* (2012).

2.1.1.3 Angulação

Angulação é um método que faz uso de uma técnica chamada ângulo de chegada / *Angle of arrival* (AOA), que no contexto de sistemas de posicionamento, estima o posicionamento do alvo através da interseção de vários pares de linhas em relação à direção dos ângulos, cada uma formada pelo raio circular a partir de um conjunto de APs. Nesta abordagem, o ângulo θ_i entre o receptor e transmissor, é obtido conforme a equação 2.18. A figura 9 ilustra este procedimento.

$$\tan \theta_i = \frac{y - y_i}{x - x_i} \quad i = 1, 2, \dots, k. \quad (2.18)$$

Figura 9 – IPS baseado no método de angulação



Fonte: Frattasi e Rosa (2017).

Baseado na equação 2.18, conforme discutido em Frattasi e Rosa (2017) é possível estimar o posicionamento do alvo através do seguinte procedimento:

$$(x_i - x) \sin(\theta_i) = (y_i - y) \cos(\theta_i) \quad (2.19)$$

A equação definida em 2.19, pode ser escrita de forma matricial como:

$$\mathbf{H}\mathbf{X} = \mathbf{B} \quad (2.20)$$

Em que:

$$\mathbf{X} = [x, y]^T, \quad (2.21)$$

$$\mathbf{H} = \begin{pmatrix} -\sin(\theta_1) & \cos(\theta_1) \\ \vdots & \vdots \\ -\sin(\theta_n) & \cos(\theta_n) \end{pmatrix} \quad (2.22)$$

$$\mathbf{B} = \frac{1}{2} \begin{pmatrix} y_1 \cos(\theta_1) & -x_1 \sin(\theta_1) \\ \vdots & \vdots \\ y_n \cos(\theta_n) & -x_n \sin(\theta_n) \end{pmatrix} \quad (2.23)$$

Aplicando o método dos mínimos quadrados, obtêm-se a estimativa definida na equação 2.24.

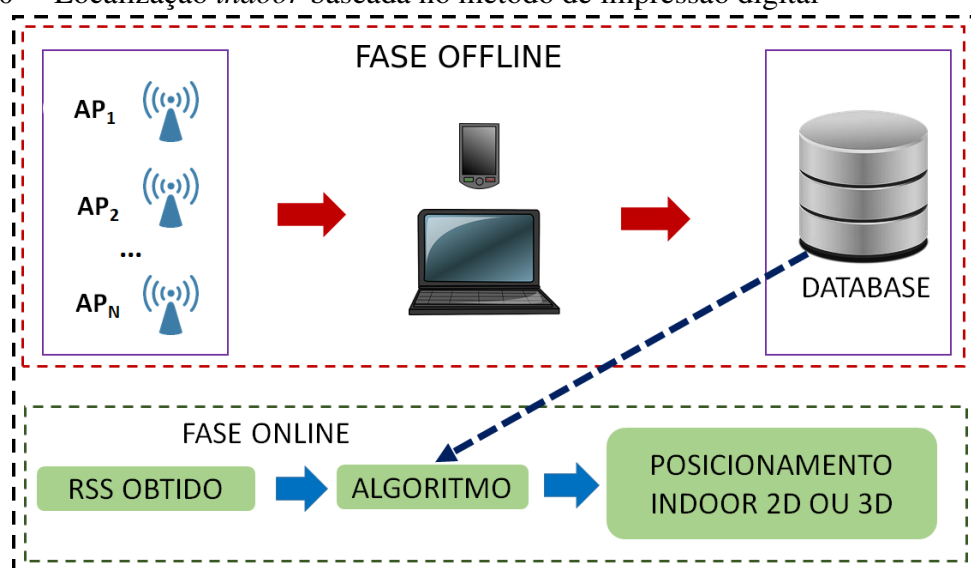
$$\mathbf{X} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{B} \quad (2.24)$$

Mais detalhes sobre a implementação deste método podem ser obtidos em Werner (2014), Kushki *et al.* (2012) e Frattasi e Rosa (2017).

2.1.2 Impressão digital

É uma técnica baseada em reconhecimento de padrões que envolve a divisão do sistema de posicionamento em duas fases, *off-line* e *on-line*. Na fase *off-line*, os vetores RSS são coletados com relação a todos os APs detectados. Esta coleta ocorre em várias posições pré-estabelecidas chamadas de pontos de referência / *reference points* (RP). Assim, cada RP é representado por sua impressão digital e todos os vetores RSS formam as impressões digitais do ambiente e são armazenados em um banco de dados para consulta *on-line*, chamado de *radio map* (HE; CHAN, 2016). A fase *on-line* consiste em ler um vetor RSS e por meio de um algoritmo de classificação, comparar este vetor com o armazenado no banco de dados durante a fase *off-line*, estimando assim o posicionamento do usuário. A figura 10 exibe o modelo de um IPS baseado na técnica em questão.

Figura 10 – Localização *indoor* baseada no método de impressão digital



Fonte: o autor.

Definição 2.1.2. Formalmente, o conceito de impressão digital, discutido em Morales *et al.* (2015), Khalajmehrabadi *et al.* (2016) e Au *et al.* (2013), consiste em dividir o espaço *indoor* em

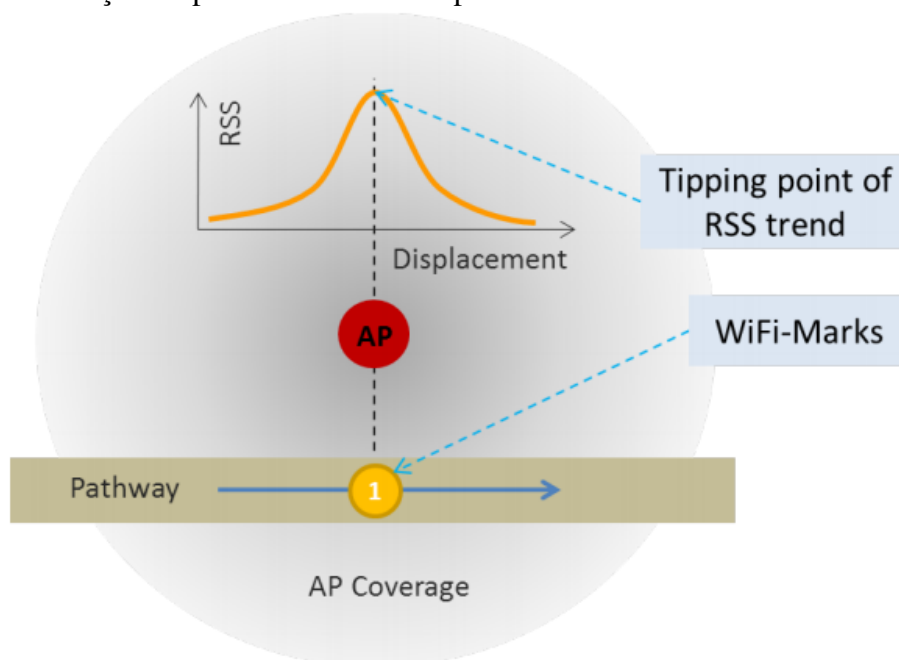
um conjunto de RPs, em que cada RP é identificado por uma coordenada cartesiana $p_j = (x, y)$, ou $p_j = (x, y, z)$, $\forall j$, $1 \leq j \leq N$, para sistemas em 2D e 3D, respectivamente. Posicionado em cada uma destas coordenadas, são coletados amostras de RSS de tamanhos iguais em instantes de tempo t_m , for $m = 1, 2, \dots, N$, com intensidades RSS dadas por $(s_j^i(t_1), s_j^i(t_2), \dots, s_j^i(t_M))$ para cada RP, em que i indica o ponto de acesso / *access point* (AP) selecionado a partir de um conjunto $L = \{AP^1, AP^2, \dots, AP^L\}$. As amostras RSS coletadas em relação a todos os APs considerando o tempo t_m em p_j são armazenadas em um vetor de sinal dado por $\mathbf{s} = [s_j^i(t_1), s_j^i(t_2), \dots, s_j^i(t_N)]^T$. O *radio map* para este experimento pode ser representado pela matriz de sinais definida em 2.25.

$$\mathbf{S}(t_m) = s_1(t_m), s_2(t_m), \dots, s_N(t_m) = \begin{pmatrix} s_1^1(t_m) & s_2^1(t_m) & \dots & s_N^1(t_m) \\ s_1^2(t_m) & s_2^2(t_m) & \dots & s_N^2(t_m) \\ \vdots & \vdots & \ddots & \vdots \\ s_1^L(t_m) & s_2^L(t_m) & \dots & s_N^L(t_m) \end{pmatrix} \quad (2.25)$$

Na fase *on-line*, é obtido o vetor de sinais $\mathbf{s} = \{o_1, o_2, \dots, o_N\}$, em que o_i , $i = 1, 2, \dots, N$, representa o conjunto de observações RSS. O objetivo é determinar o posicionamento p_j , com base em um algoritmo que compare as leituras realizadas na fase *on-line* e os valores armazenados no *radio map*. Uma desvantagem deste método implementado a partir de *Wi-Fi* (um conjunto de especificações para redes locais sem fio baseada no padrão IEEE 802.11), consiste na possibilidade de um alvo ser mapeado para uma posição diferente do real, devido a variações do sinal no ambiente. Este problema foi observado em Liu *et al.* (2012), Sun *et al.* (2013), Tsuda *et al.* (2013), He e Chan (2016), Wang *et al.* (2012) e Shen *et al.* (2013). Uma maior precisão pode ser obtida considerando-se conjuntamente observações temporais ou espaciais (HE; CHAN, 2016). Padrões temporais refere-se a uma sequência do sinal RSS observada durante uma trajetória percorrida pelo alvo, enquanto que observações espaciais estão relacionados à distribuição geográfica de sinais. Essas observações são úteis para corrigir e restringir o posicionamento do alvo, tomando como base o RSS, a localização dos APs e a cobertura do sinal em ambientes com altas flutuações. Neste sentido, o IPS Walkie-markie proposto em Shen *et al.* (2013), registra valores de RSS em diferentes regiões com o usuário em movimento. Como ilustrado na figura 11, percebe-se que o RSS tende a aumentar à medida que o usuário se movimenta da esquerda para a direita ao longo de um caminho coberto por um AP. Quando o usuário se distancia do AP, a tendência de RSS inverte. Esta sequência de dados RSS relacionadas a vários trajetos são usados por *Walkie-Markie* com o objetivo de construir um

padrão e assim identificar o posicionamento do alvo de forma estática ou em movimento.

Figura 11 – Ilustração do padrão de sinais temporais no sistema Walkie-Markie




Fonte: Shen *et al.* (2013).

2.1.3 Proximidade

Dentre os três métodos para posicionamento *indoor*, o método de proximidade é considerado o mais simples. Trata-se de um método que se baseia puramente na proximidade do dispositivo móvel a locais previamente conhecidos. Assim, a detecção de proximidade não fornece uma coordenada como estimativa de posicionamento do alvo. Neste caso, a localização é dada setorialmente, isto é, o sistema retorna o cômodo ou uma região em que o alvo pode estar em um determinado momento. A implementação de um IPS a partir deste conceito, consiste em um ambiente com um grid de antenas com posições conhecidas. Quando um dispositivo móvel é detectado em movimento, a antena mais próxima é usada para estimar a localização do alvo (KAVEHRAD *et al.*, 2015). Quando sinais de múltiplas fontes são detectados, a antena com o sinal mais forte é usada para indicar sua localização. Este procedimento é ilustrado na figura 12.

Figura 12 – Localização *indoor* baseada no método de proximidade



Fonte: Kavehrad *et al.* (2015).

A tabela 2, apresenta as principais vantagens e limitações para os métodos discutidos.

Tabela 2 – Comparação entre os métodos para posicionamento *indoor*

Triangulação	<p>Vantagens:</p> <ol style="list-style-type: none"> 1. Não é necessário um conhecimento prévio do comportamento do sinal no ambiente; 2. Fácil implementação; <p>Limitações:</p> <ol style="list-style-type: none"> 1. Baixa precisão devido à alta variação em ambientes fechados; 2. O sistema de posicionamento é altamente dependente do número de APs. Para um posicionamento 3D, necessita-se de pelo menos quatro APs; 3. É necessário ter conhecimento prévio sobre a localização dos APs.
Impressão digital	<p>Vantagens:</p> <ol style="list-style-type: none"> 1. Alta precisão; 2. Boa integração com os algoritmos clássicos de classificação; 3. O método lida bem com a variação do sinal em ambientes fechados. <p>Limitações:</p> <ol style="list-style-type: none"> 1. É necessário um conhecimento prévio do comportamento do sinal no ambiente; 2. Necessita-se de uma base de dados robusta.
Proximidade	<p>Vantagens:</p> <ol style="list-style-type: none"> 1. Método de fácil implementação; 2. Pode ser implementado a partir de uma grande variedade de tecnologias para posicionamento <i>indoor</i>; <p>Limitações:</p> <ol style="list-style-type: none"> 1. Baixa precisão. A estimativa da localização do usuário é dada por uma região aproximada e não através de uma coordenada; 2. São necessárias várias antenas para uma localização aceitável; 3. É necessário ter conhecimento prévio sobre a localização dos APs.

Fonte: o autor.

2.2 Tecnologias de comunicação sem fio para posicionamento *indoor*

2.2.1 WLAN (IEEE 802.11)

A tecnologia *Wi-Fi* é considerada a mais popular em IPS. Isso se dá porque está presente em inúmeros ambientes, tais como, residências, escritórios, shoppings e universidades, além de ser compatível com muitos dispositivos que incluem telefones, *laptops* e *tablets*, motivo pelo qual, o custo com a infraestrutura para implementação de um IPS com esta tecnologia é minimizada. Contudo, uma desvantagem dessa tecnologia consiste na variabilidade do sinal relacionado a inúmeras variáveis, tais como a movimentação de pessoas no ambiente, interferência entre APs entre outros fatores. Neste sentido, métodos como TOA e TDOA, tornam-se ineficientes quando deseja-se obter a distância de um determinado ponto aos APs baseado em uma observação RSS (KRISHNAMURTHY, 2015). Por essa razão, métodos baseados em impressão digital têm sido amplamente discutidos nesse contexto. Bahl e Padmanabhan (2000), foi um dos primeiros trabalhos a aplicar o conceito de impressão digital baseado em sinal *Wi-Fi*. Entre os experimentos realizados pelos autores destacam-se: a relação entre orientação do usuário e a precisão do sistema; e a obtenção de um parâmetro chamado de fator de atenuação, que foi estimada a partir da média das diferenças entre os RSS's com linha de visada entre os transmissor e receptor e com a obstrução de paredes.

Outro trabalho bastante citado na literatura foi proposto por Wang *et al.* (2012). Neste trabalho, os autores propõem um IPS baseado em *Wi-Fi* chamado de Horus que funciona da seguinte maneira: dada uma sequência de observações obtidas em cada AP, ordena-se estes AP em ordem decrescente de acordo com o RSS. Em seguida, seleciona-se o AP com sinal médio mais forte e então, a partir desse AP, calcula-se a probabilidade de cada posição. Battiti *et al.* (2002) propõem o uso de uma ANN perceptron de múltiplas camadas / *multilayer perceptron* (MLP) de forma a implementar um mapeamento entre as medições do sinal bruto e a posição do alvo. Essa rede neural foi implementada com uma camada escondida e treinada com o algoritmo método de secante em um passo / *one-step secant* (OSS). A precisão média alcançada foi de aproximadamente 2,3 m.

2.2.2 WPAN (IEEE 802.15)

Bluetooth é frequentemente classificado como uma tecnologia de rede pessoal sem fio, sendo a potência de transmissão e alcance muito menor do que uma rede *Wi-Fi*, ocupando um

espaço limitado em torno do usuário (geralmente 10 m) (KRISHNAMURTHY, 2015). Sua versão mais recente, *Bluetooth* de baixa energia / *Bluetooth low energy* (BLE), também conhecido como *Bluetooth Smart*, pode fornecer dados aprimorados a uma taxa de 24 Mbps com alcance de cobertura de 70 – 100m com maior eficiência energética, em comparação com versões mais antigas (ZAFARI *et al.*, 2016).

Uma das vantagens da utilização do Bluetooth na implementação de um IPS, consiste no fato dessa tecnologia possuir baixo consumo de energia. Especificamente, este consumo representa algo em torno de 81-120 mW em comparação com o Wi-Fi, que usa 890-1600 mW (FROST *et al.*, 2012). Contudo, pelo fato de ter sido projetado de forma a abranger uma pequena região, sua aplicação IPS destina-se a cenários de pequena escala (FROST *et al.*, 2012).

O *Bluetooth* têm sido abordado como tecnologia para posicionamento *indoor* em muitos trabalhos. Frost *et al.* (2012), propõem a aplicação da técnica de impressão digital com *Bluetooth* resultando em uma precisão média de 2 m. TOPAZ (TADLYS, 2004) é uma IPS baseado em *Bluetooth* composto de três tipos de elementos: servidor de posicionamento, pontos de acesso sem fio e *tags* sem fio. O desempenho do sistema o torna adequado para rastrear pessoas e objetos, com uma precisão 95% dentro de 2 m.

2.2.3 Identificação por radiofrequência (RFID)

Consiste em uma tecnologia que utiliza ondas de rádio que rastreia e determina o posicionamento e a orientação de um alvo. Isso é feito, através da leitura de informações armazenadas em uma *tag* anexada a um objeto. Essas *tags* são classificadas em passivas e ativas. *Tags* passivas refletem o sinal de rádio frequência / *radio frequency* (RF) emitido pelo leitor com a modulação específica da *tag*, sendo possível assim determinar seu posicionamento. Este tipo *tag* opera sem a necessidade de bateria, reduzindo o custo de implementação de um sistema com esta tecnologia. O alcance típico de leitura é de 1 – 2m e o custo dos leitores é relativamente alto (LIU *et al.*, 2007). *Tags* ativas possuem fonte própria de energia, isso permite ampliar a faixa de varredura do sinal que pode ser detectado pelos leitores.

A desvantagem do uso de RFID é que esta tecnologia não é tipicamente implementada em smartphones (KRISHNAMURTHY, 2015). *SpotOn* (HIGHTOWER; BORRIELLO, 2000) é um exemplo de IPS que utiliza essa tecnologia para posicionamento 3D. Outro IPS conhecido é LANDMARC (NI *et al.*, 2003) cuja a precisão relatada é de aproximadamente 1 m, considerando 50º percentil.

2.2.4 *Dead Reckoning*

Este método estima a posição e movimentação de um alvo em ambiente em termos de velocidade, distância e direção, tomando como base seu posicionamento no passado. Assim como outros métodos de posicionamento, está sujeito a erros de estimativa, principalmente erro cumulativo ao decorrer do tempo (BOWDITCH *et al.*, 2002). No entanto, sua precisão pode ser significativamente melhorada usando métodos híbridos para obter uma nova posição, como demonstrado em Sharp e Yu (2014). Este método foi considerado por Beauregard e Haas (2006). Neste trabalho, uma ANN foi aplicada utilizando variáveis como velocidade de deslocamento e o número de passos dados por usuários, obtidos através de um sensor. A precisão reportada é de 10 metros após 1 *Km* de movimentação.

2.2.5 *Posicionamento Acústico*

A implementação de um IPS a partir desta tecnologia, envolve uso de *hardware* de forma a instalar nós ultrassônicos em usuários e objetos. Esses nós representam transmissores e receptores que emitem sinais, obtendo a posição do alvo. Este procedimento é usualmente feito através de técnicas como TOA. Um trabalho clássico que utiliza esta abordagem é *active bat project* (WARD *et al.*, 1997). Neste sistema, utilizou-se a técnica TOA e a precisão reportada é de poucos centímetros. Este resultado representa uma precisão melhor que sistemas baseados em *Wi-Fi* ou *Bluetooth*, porém um sistema baseado em ultrassom necessita de linha de visada, uma vez que som ou ultrassom não podem penetrar paredes (KRISHNAMURTHY, 2015). Além disso, a maioria dos dispositivos móveis não possuem tecnologia ultrassom. Outras desvantagens, como a impossibilidade de localizar mais de um alvo ao mesmo tempo, são discutidas em Ward *et al.* (1997).

2.2.6 *Luz visível*

A comunicação por luz visível / *visible light communication* (VLC) é uma tecnologia de comunicação sem fio na qual a transmissão de dados é realizada através da luz a 380 – 780 *nm* de comprimento de onda. VLC usa lâmpadas fluorescentes compactas / *compact fluorescent lamp* (CFL) e diodo emissor de luz / *light emitting diode* (LED) para transmitir sinais a 10 *kb/s* e 500 *Mb/s* respectivamente (NDJIONGUE *et al.*, 2015). O IPS VL é uma tecnologia de posicionamento que utiliza a luz visível para determinar a posição de um alvo para fins de

rastreamento e navegação (SAKPERE *et al.*, 2017). Este sistema, consiste de uma fonte de luz ou estação base (transmissor), um terminal móvel ou sensor de imagem (receptor) e um canal de comunicação (ZHANG *et al.*, 2014).

Em Zheng *et al.* (2017), é proposto um IPS com alta precisão de posicionamento, baseado em comunicação por luz visível. O erro médio de posicionamento é de 1,72 *cm* para o cenário 2D e 3 *cm* para 3D. Porém a implementação de um IPS a partir desse conceito possui alto custo, uma vez que transmissores e receptores devem ser projetados baseado nessa tecnologia.

2.3 Modelos de Propagação para Ambientes Fechados

Como discutido no início desse capítulo, a estimativa de posicionamento de usuários e objetos em ambientes fechados, apresenta muitas dificuldades em relação ao contexto *outdoor*. Estas dificuldades estão relacionadas à atenuação do sinal devido aos diversos obstáculos presentes nesse tipo de ambiente. Na literatura existem muitos trabalhos, ambos teóricos e experimentais, que propuseram a aplicação de modelos de propagação *indoor* à estimativa do comportamento do sinal em ambientes fechados. Para maiores detalhes sobre estes modelos veja Damosso e Correia (1999). Nesta seção são apresentados os principais modelos de propagação utilizados no contexto *indoor*.

2.3.1 *one-slope model (ISM)*

O modelo *one-slope model* (ISM) (DAMOSSO; CORREIA, 1999), assume que há uma dependência linear entre a perda de percurso e o logaritmo da distância entre o transmissor e o receptor. Trata-se um modelo muito simples por não considerar os vários obstáculos característicos de ambientes fechados, tornando o modelo impreciso para esse tipo de ambiente. A equação para este modelo é dada por:

$$L = L_0 + 10 \cdot \gamma \cdot \log(d) \quad (2.26)$$

Onde L_0 representa a perda por percurso a um metro da antena irradiante para uma determinada frequência em *dB*; γ é o coeficiente de propagação e d é a distância entre transmissor e receptor em metros. Valores típicos de L_0 e n , para um ambiente similar a um escritório a uma frequência de 2.45 GHz, são de $L_0 = 40,2$ e $\gamma = 4,2$ (KWIECIEN *et al.*, 2009). Este modelo é de fácil implementação, uma vez que apenas a distância entre o transmissor e receptor é utilizado como parâmetro de entrada.

2.3.2 Cost231 multi-wall model

O modelo de Multi-Parede e Piso / Cost 231 multi-wall model (MWM) (DAMOSSO; CORREIA, 1999) considera a atenuação do sinal como a perda no espaço livre adicionada a perda resultante do número de paredes e pisos penetrados entre o transmissor e receptor. O modelo em questão é dado por:

$$L = L_{LF} + L_c + \sum_{i=1}^I k_{wi} L_{wi} + k_f^{\frac{k_f+2}{k_f+1}-b} L_f \quad (2.27)$$

em que:

- L_{LF} = Perda no espaço livre entre transmissor e receptor em dB;
- L_c = Constante de perda em dB;
- k_{wi} = Número de paredes penetradas do tipo i ;
- k_f = Número de pisos penetrados;
- L_{wi} = Fator de atenuação nas paredes do tipo i em dB;
- L_f = Fator de atenuação entre pisos adjacentes em dB;
- b = Parâmetro empírico;
- I = Número de paredes distintas.

Observou-se que a perda total de piso é uma função não linear do número de pavimentos penetrados (DAMOSSO; CORREIA, 1999). Esta característica é levada em consideração pela introdução de um fator empírico b . Por razões práticas, o número de paredes distintas deve ser mantido baixo, pois a diferença entre os vários tipos de paredes em relação a atenuação é pequena e seu significado no modelo não está claro (DAMOSSO; CORREIA, 1999). Os tipos de paredes em questão são exibidos na tabela 3, enquanto que os valores típicos de L_{w1} , L_{w2} , L_f e b , são exibidos na tabela 4.

Tabela 3 – Tipos de paredes utilizadas no Cost 231 MWM

Tipo de Parede	Descrição
L_{w1}	Parede com espessura $< 10\text{cm}$
L_{w2}	Parede com espessura $\geq 10\text{cm}$

Fonte: Damosso e Correia (1999).

Tabela 4 – Valores para L_{w1} , L_{w2} , L_f e b em dB - Cost 231 MWM

Multi-Wall (MWM)				
Ambiente	L_{w1} [dB]	L_{w2} [dB]	L_f [dB]	b
Denso	3,4	6,9	18,3	0,46
Um piso				
Dois Pisos				
Multi-pisos				
Aberto	3,4	6,9	18,3	0,46
Ampla	3,4	6,9	18,3	0,46
Corredor	3,4	6,9	18,3	0,46

Fonte: Damosso e Correia (1999).

2.3.3 ITU indoor Path Loss Model

O modelo de propagação *indoor* união internacional de telecomunicações / *International Telecommunication Union* (ITU) estima a perda por percurso dentro ambiente fechado. Este modelo é formalmente expresso como (PARKINSON; SPILKER, 2005):

$$L = 20\log(f) + N_p\log(d) + L_f(n_p) - 28dB \quad (2.28)$$

Em que $L_f(n_p)$, é o fator referente a perda de penetração do piso e n_p representa o número de pisos entre transmissor e o receptor. A Tabela 5 exibe os valores representativos para o coeficiente de perda no espaço livre entre transmissor e receptor, N_p , dado pela ITU, enquanto que a Tabela 6, fornece os valores referentes a $L_f(n)$.

Tabela 5 – Valores de N para o modelo ITU

Frequência	Residencial	Escritório	Comercial
900 MHZ	–	33	20
1.2 – 1.3 GHZ	–	32	22
1.8 – 2 GHZ	28	30	22
4 GHZ	–	28	22
5.2 GHZ	–	31	–
60 GHZ	–	22	17

Fonte: Parkinson e Spilker (1996).

Tabela 6 – Valores de $L_f(n_p)$ para o modelo ITU

Frequência	Residencial	Escritório	Comercial
900 MHZ	–	$9(n_p = 1)$ $19(n_p = 2)$ $24(n_p = 3)$	–
1.8–2GHZ	$4n_p$	$15+4(n_p - 1)$	$6+3(n_p - 1)$
5.2 GHZ	–	$16 (n_p = 1)$	–

Fonte: Parkinson e Spilker (1996).

2.3.4 Linear attenuation model

Este modelo assim como o 1SM, assume uma dependência linear entre a perda de percurso e o logaritmo da distância entre o transmissor e o receptor. A diferença fundamental como relação ao 1SM, consiste na inclusão de um coeficiente de atenuação α , de forma a tornar o modelo mais preciso. O modelo é dado pela equação 2.29 (DAMOSSO; CORREIA, 1999).

$$L = L_{LF} + \alpha_a d \quad (2.29)$$

Em alguns estudos, termos adicionais relacionados a perdas por paredes são adicionados ao modelo, de forma a melhorar a performance (KARLSSON; LUND, 2018).

2.3.5 Wall and floor factor models

Este modelo dado pela equação 2.30, assume que a perda de percurso para ambientes fechados é dado pela perda no espaço livre adicionado aos parâmetros n_f e n_w , que representam respectivamente, o número de pisos e paredes entre o transmissor e o receptor. Em que l_f e l_w , são os fatores de atenuação referentes a pisos e paredes respectivamente (DAMOSSO; CORREIA, 1999).


$$L = L_0 + 20.\gamma.\log(d) + n_f L_f + n_w L_w \quad (2.30)$$

2.3.6 Ray launching model

O modelo de lançamento de raios (*ray launching*), ilustrado na figura 13, é baseado na ótica geométrica que simula a propagação de ondas de rádio de acordo com os fenômenos físicos, tais como reflexão, refração e difração. Esta abordagem, verifica se há linha de visada entre o transmissor e o receptor e então os raios são lançados a partir de uma fonte transmissora em direções especificadas. Os raios são rastreados de forma a verificar se eles são interceptados

por um obstáculo. Se não forem interceptados, novos raios são lançados até que atinjam o receptor ou um número máximo de iterações seja atingido.

Figura 13 – Modelo de lançamento de raios




Fonte: o autor.

2.3.7 Ray tracing model

O traçado de raios (Ray tracing), determina todos os raios que podem atingir um receptor R_x a partir de um transmissor T_x . O modelo opera em duas etapas (MOLISCH, 2011):

- Todos os raios que podem transferir energia da localização de T_x para a localização de R_x são determinados. Isso geralmente é feito por meio do princípio da imagem. Os raios que chegam ao R_x por meio de uma reflexão mostram o mesmo comportamento que os raios de uma fonte virtual localizada onde uma imagem da fonte original (em relação à superfície refletora) seria localizada (veja a Figura 14);
- Em um segundo passo, as atenuações (devido à propagação do espaço livre e coeficientes de reflexão finita) são calculadas, fornecendo assim os parâmetros de todos os componente multipercurso (*multi-path components*).

Figura 14 – Princípio da imagem. Círculos em cinza: fontes virtuais correspondentes a um único reflexo. Círculos brancos: fontes virtuais correspondentes a reflexões duplas. Linhas pontilhadas: raios das fontes virtuais para o RX. Linhas tracejadas: reflexões reais. Linhas sólidas: linha de visada



Fonte: Molisch (2011).

Outros modelos de pequena escala bastante citados na literatura, incluem: *Rayleigh fading model*, *Rice fading model* e *Nakagami-m fading model*. Esses modelos são classificados como estocásticos e são discutidos em detalhes em Damosso e Correia (1999).


2.4 Algoritmos Baseados em Impressão digital

Algoritmos para posicionamento *indoor* baseados em impressão digital podem ser classificados em determinísticos e probabilísticos. Algoritmos clássicos determinísticos incluem *kNN* e redes neurais artificiais (HUI, 2017) e (ZHENG *et al.*, 2017). A principal vantagem dos métodos determinísticos é a facilidade de implementação. Esses métodos podem ser facilmente implementados com base em algoritmos como *kNN* e a complexidade computacional é frequentemente baixa (HE; CHAN, 2016). Algoritmos probabilísticos são baseados em inferência Bayesiana e buscam estimar a probabilidade do alvo pertencer a uma posição específica dada uma observação RSS (LIU *et al.*, 2007). As próximas seções discutem sobre a aplicação desses algoritmos ao problema posicionamento.

2.4.1 *k*-nearest neighbors (*k*-NN)

O Algoritmo *k*NN é um dos mais conhecidos e utilizados em reconhecimento de padrões. Trata-se de um algoritmo não paramétrico que classifica um novo objeto baseado na similaridade em relação às classes. O procedimento de classificação consiste em calcular a distância entre o objeto observado e as *k* classes mais próximas. Uma vez identificado as *k* classes mais próximas, classificar-se-á a observação à classe mais comum entre seus vizinhos. Este procedimento é ilustrado na figura 15. Perceba que ao ser obtida uma observação *X*, implementa-se um círculo ao redor dessa observação que capture os 5 vizinhos mais próximos. Baseado nesta regra o *k*-NN, então classificaria a observação como pertencente a classe dos pontos negros.

Figura 15 – Exemplo do algoritmo *k*-NN para *k* = 5



Fonte: Duda e Hart (1973).

No caso mais simples deste algoritmo, quando $k = 1$, chamado de 1 *Nearest Neighbor* (1-NN), simplesmente classifica-se o objeto à classe mais próxima. Formalmente o *k*NN é definido da seguinte forma:

Definição 2.4.1. Sejam $((x_1^{(1)}, x_2^{(1)}, \dots, x_N^{(1)}), \omega_1), \dots, ((x_1^{(N)}, x_2^{(N)}, \dots, x_N^{(N)}), \omega_N)$, um conjunto de N pares representando um conjunto de treinamento, em que $\omega_i, i = 1, 2, \dots, N$, é defi-

nido como um conjunto de classes ao qual $x_i^{(j)} \in \mathbb{R}^d, i, j = 1, 2, \dots, N$ pertence. Considere $\mathbf{y} = (y_1, y_2, \dots, y_N)$, uma observação não classificada pertencente ao mesmo espaço de $x_i^{(j)}$, o objetivo é classificar essa nova observação ao par $((x_i^{(j)}), \omega_i)$ mais similar. Este procedimento é realizado calculando-se a distância entre os \mathbf{y} e todos os vetores \mathbf{x} pertencentes ao conjunto de treinamento. Existem várias métricas de distância, as mais comuns são (KELLEHER *et al.*, 2015):

- Distância euclidiana:

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^N (\mathbf{x}_i - \mathbf{y}_i)^2} \quad (2.31)$$

- Distância Manhattan:

$$d(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^N |\mathbf{x}_i - \mathbf{y}_i| \quad (2.32)$$

- Distância Minkowski:

$$d(\mathbf{x}, \mathbf{y}) = \left(\sum_{i=1}^N |\mathbf{x}_i - \mathbf{y}_i|^p \right)^{\frac{1}{p}} \quad (2.33)$$

Matematicamente a distância entre duas instâncias deve satisfazer as seguintes condições (DUDA; HART, 1973):

- Não-negatividade: $d(\mathbf{x}, \mathbf{y}) \geq 0$;
- Reflexividade / identidade: $d(\mathbf{x}, \mathbf{y}) = 0 \iff \mathbf{x} = \mathbf{y}$;
- Simetria: $d(\mathbf{x}, \mathbf{y}) = d(\mathbf{y}, \mathbf{x})$;
- Desigualdade triangular: $d(\mathbf{x}, \mathbf{y}) + d(\mathbf{y}, \mathbf{z}) \geq d(\mathbf{x}, \mathbf{z})$;

O k -NN foi proposto por Fix e Hodges (1951) como uma alternativa aos métodos de classificação tradicionais, nos casos em que se encontra dificuldade em estimar os parâmetros das densidades de probalidades. Este algoritmo tornou-se popular, após algumas de suas propriedades formais serem discutidas por Cover e Hart (1967), que provaram que quando a quantidade de dados se aproxima do infinito, a classificação de um vizinho mais próximo é limitada pelo dobro do erro assintótico como a regra de Bayes, independente da métrica de distância aplicada. Isso é formalmente apresentado no teorema 2.4.1.

Teorema 2.4.1. *Seja X um espaço métrico separável. Sejam x, f_1 e f_2 , tal que com probabilidade um x é (i), um ponto de continuidade de f_1 e f_2 , ou (ii) um ponto de medida de probabilidade maior que zero. Então, o risco NN assintótico R (probabilidade de erro) tem os limites*

$$R^* \leq R^{NN}(\infty) \leq 2R^*(1 - R^*)$$

O teorema 2.4.1 implica que a probabilidade de erro do classificador 1-NN é menor que o dobro da probabilidade de erro da regra de Bayes, para um conjunto de treinamento suficientemente grande.

Esse algoritmo quando aplicado ao problema de posicionamento *indoor*, inicialmente recebe um vetor RSS e busca as k impressões digitais mais próximas ao vetor de entrada. Na sequência, o algoritmo aloca o alvo na posição que possui uma distribuição de sinal mais similar ao vetor de entrada, conforme a definição 2.4.1. O algoritmo 1 resume este procedimento.

Algoritmo 1: Aplicação do k -NN ao problema de localização *indoor*

Input: $\mathbf{rp} = \{rp_1, rp_2, \dots, rp_N\} \in \mathbb{R}^n$ representando um conjunto de pontos de referência.

Um inteiro k , representando o número de vizinhos mais próximos.

Um vetor de sinal $\mathbf{s} = \{RSS_1, RSS_2, \dots, RSS_N\}$.


Output: Um posicionamento 2D ou 3D tomando como base o ponto de referência mais similar.

- 1: Obtenha os k pontos de referência mais próximos;
 - 2: **for** $i = 1$ **to** N **do**
 - 3: Calcule a distância entre \mathbf{s} e todos RSS's com relação aos pontos de referência mais próximos;
 - 4: **end for**
 - 5: Aloque a observação \mathbf{s} no ponto de referência mais próximo e retorne a posição deste ponto de referência como estimativa de posicionamento do usuário.
-

2.4.2 Redes Neurais

As redes neurais artificiais foram introduzidas por McCulloch e Pitts (1943). A rede proposta possuía as seguintes características: as entradas e saídas dos nós binárias; a ativação de um neurônio é binária; rede conectada por caminhos direcionados e ponderados; cada neurônio possui um limite u . Se a entrada no neurônio for maior que o limite, o neurônio é ativado; uma função de ativação e um único neurônio de saída, y . A figura 16 ilustra a arquitetura básica dessa rede.

Figura 16 – Arquitetura do modelo McCulloch-Pitts




Fonte: O autor.

Nos anos 1950, Rosenblatt (1958), a partir do modelo desenvolvido por McCulloch e Pitts (1943), apresentou o conceito de *perceptron*, um modelo particular de aprendizado supervisionado, que se tornou fundamental na formação posterior de redes neurais. Durante a década de 1980, o interesse renovado na rede neural foi alimentado por muitos pesquisadores que contribuíram para o desenvolvimento de diversas aplicações (MALOBERTI; DAVIES, 2016). Alguns trabalhos importantes nesse sentido, incluem: Kohonen (1988) e Hopfield (1988).

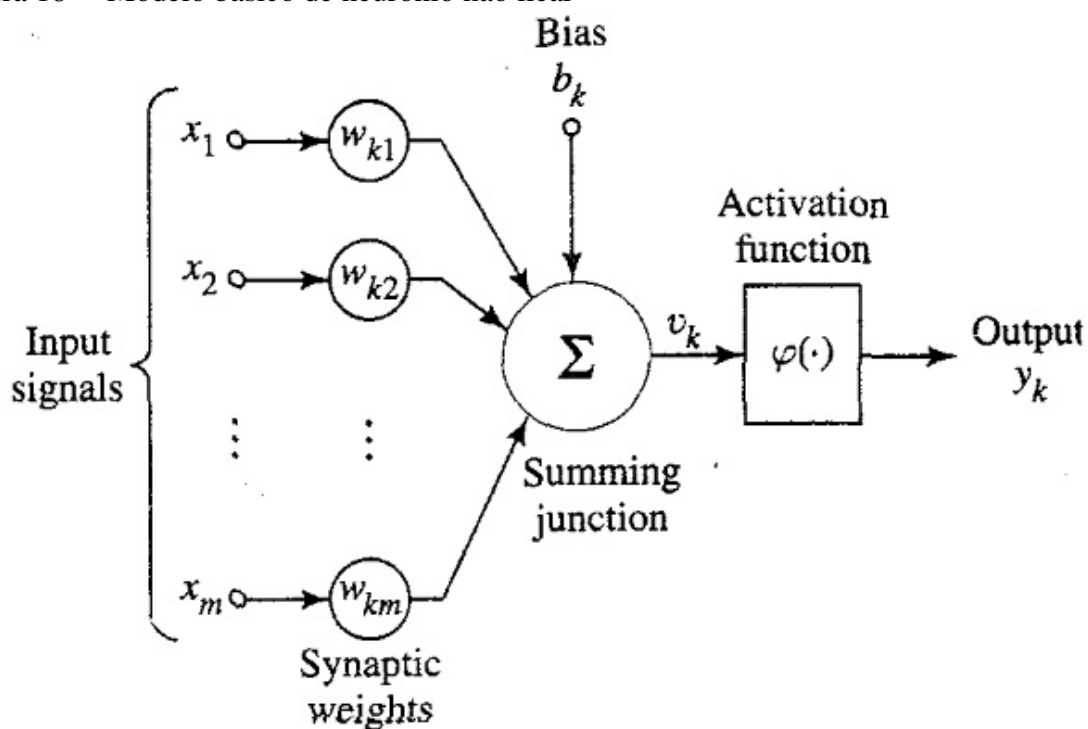
Uma ANN pode ser definida como um modelo matemático para processamento de informação que simula o comportamento do cérebro humano. A estrutura básica de uma ANN é composta por um conjunto de neurônios artificiais que recebem como entrada um vetor de sinal $\mathbf{x} = (x_1, x_2, \dots, x_n)$. Para cada entrada, atribui-se um peso sináptico, a partir do vetor $\mathbf{w} = (w_{k1}, w_{k2}, \dots, w_{kn})$ e, em seguida, é obtida a soma referentes às entradas ponderadas. Na etapa seguinte é aplicada uma função de ativação e um valor de limite que irá gerar o resultado de saída (KRIESEL, 2007). Existem várias funções de ativação. Algumas dessas funções são ilustradas na figura 17. A figura 18 ilustra o modelo de rede neural em questão.

Figura 17 – Diferentes Funções de ativação: (a) Limiar, (b) pseudo-linear, (c) sigmoide e (d) Gaussiana



Fonte: Jain *et al.* (1996).

Figura 18 – Modelo básico de neurônio não linear



Fonte: Haykin (1998).

O modelo apresentado na figura 18, possui uma entrada especial chamada de bias denotada por b_k , com o objetivo ajustar o efeito da entrada da função de ativação ϕ . Assim, a saída dessa rede é definida matematicamente pela equação 2.34 (HAYKIN, 1998).

$$y_k = \phi(u_k + b_k) \quad (2.34)$$

Em que:

$$u_k = \sum_{j=1}^m w_j x_j \quad (2.35)$$

De um modo geral, as ANN podem ser classificadas em duas categorias (KUMAR, 2004): *feed-forward*, representada por um grafo acíclico, em que a propagação do sinal ocorre apenas no sentido da entrada para a saída. A estrutura básica inclui:

- Camada ou nó de entrada: Os nós da camada de entrada são passivos, isso significa que não há modificação dos dados nesses nós. O objetivo é apenas transmitir os sinais de entrada para a próxima camada;
- Camadas escondidas ou nós escondidos: realiza todo processamento da informação e transferem às informações às camadas de saída;
- Camada ou nó de saída: responsável por transmitir o resultado gerado ao mundo externo.

Formalmente uma rede neural *feed-forward*, pode ser definida como:


Definição 2.4.2. Uma ANN *feed-forward* consiste em uma tupla $T = (G \rightarrow W, \theta, f, y_k)$, em que G, \rightarrow , é um grafo acíclico $N \times N$. Considere $i \rightarrow j$, representando a conexão de um neurônio i a um neurônio j , com um peso $w_i \in \mathbb{R}$. Os neurônios sem predecessores são chamados de neurônios de entrada, enquanto os neurônios intermediários são chamados de camadas escondidas. Assim uma ANN *feed-forward* com n nós de entrada e m nós de saída pode ser representada matematicamente através da equação 2.36.

$$f : \mathbb{R}^n \rightarrow \mathbb{R}^m, f(x_1, x_2, \dots, x_m) = (y_1, y_2, \dots, y_n) \quad (2.36)$$

A figura 19, ilustra a arquitetura da rede *feed-forward* simples, conhecida como MLP com uma camada escondida.


Uma segunda categoria de ANN é chamada de redes recorrentes (KUMAR, 2004) que, contrariamente ao modelo *feed-forward*, apresenta pelo menos um laço de realimentação de neurônios. Este modelo é ilustrado na figura 20.

Figura 19 – Arquitetura de uma ANN MLP com uma camada escondida



Fonte: Haykin (1998).

Figura 20 – Arquitetura de uma ANN recorrente com uma camada escondida



Fonte: Haykin (1998).

Uma ANN aplicada ao problema de posicionamento *indoor* consiste em receber

como entrada um vetor RSS e as coordenadas relacionadas ao mesmo. A saída é um vetor com dois ou três elementos para o espaço 2D e 3D, respectivamente. O algoritmo 2 resume o procedimento da aplicação de uma ANN ao problema de posicionamento *indoor* a partir do algoritmo *backpropagation* (discutido no capítulo 4).

Algoritmo 2: ANN MLP aplicada ao problema de posicionamento *indoor*

Input: $s = \{RSS_1, RSS_2, \dots, RSS_N\}$.

Output: Posicionamento 2D ou 3D.

- 1: **for** $i = 1$ **to** t **do**
 - 2: Inicializar os valores dos pesos e neurônios aleatoriamente
 - 3: Apresentar um padrão a camada de entrada da rede
 - 4: Encontrar os valores para as camadas escondidas e a camada de saída
 - 5: Determinar o erro de cálculo (Estimativa de posicionamento - Posicionamento real) na camada de saída.
 - 6: Ajustar os pesos através da retropropagação dos erros (reduzir o erro a cada iteração)
 - 7: Encontrar o erro na camada escondida
 - 8: Ajustar os pesos e retornar ao passo 2.
 - 9: **end for**
 - 10: **return** Posicionamento 2D ou 3D do alvo.
-

2.4.3 Inferência Bayesiana

A inferência Bayesiana consiste no uso de probabilidades condicionais para obter conhecimento sobre quantidades desconhecidas, baseado em informações a priori. Este tipo de inferência é baseada no teorema de Bayes, que foi desenvolvido pelo matemático Thomas Bayes (BAYES, 1763), como uma consequência de seu interesse em probabilidades inversas. O teorema 2.4.2, apresenta formalmente este conceito (IVERSEN, 1984).

Teorema 2.4.2. *Sejam $P(H)$ a probabilidade a priori de H , isto é, a probabilidade de H ocorrer antes de D ser observado, $P(H | D)$ a probabilidade a posteriori, em outras palavras, a probabilidade de H ocorrer dado que D ocorreu e $P(D | H)$, uma função chamada de verossimilhança, que representa a inversa da probabilidade condicional $P(H | D)$, então o teorema de Bayes é dado pela equação definida em 2.37:*

$$P(H | D) = \frac{P(D | H) P(H)}{P(D)} \quad (2.37)$$

Considere o problema de se encontrar um estimador pontual para o parâmetro θ para a população com distribuição $f(x | \theta)$. Seja $\pi(\theta)$ a distribuição a priori sobre θ . Suponha que uma amostra aleatória de tamanho n , denotada por $x = (x_1, x_2, \dots, x_N)$, é observada. A distribuição de $\theta | x$, é dada pela equação 2.38 (WALPOLE; MYERS, 2009).

$$\pi(\theta | x) = \frac{f(\mathbf{x}|\theta)\pi(\theta)}{g(\mathbf{x})} \quad (2.38)$$

Em que $g(x)$ é a distribuição marginal de \mathbf{x} , dada por:

$$g(\mathbf{x}) = \begin{cases} \sum_{\theta} f(\mathbf{x}|\theta)\pi(\theta) & \text{Para } \theta \text{ discreto} \\ \int_{\mathbb{R}} f(\mathbf{x}|\theta)\pi(\theta)d(\theta) & \text{Para } \theta \text{ Contínuo} \end{cases} \quad (2.39)$$

e $\int_{\mathbb{R}} f(\mathbf{x}|\theta)\pi(\theta)d(\theta)$ é uma generalização da integral de de Riemann, chamada de integral de Riemann–Stieltjes.

Note que $g(\mathbf{x})$ é constante com relação a θ , o que significa que podemos reescrever a equação 2.38, como (PUZA, 2015):

$$\pi(\theta|\mathbf{x}) = \frac{f(\mathbf{x}|\theta)\pi(\theta)}{\zeta} \quad (2.40)$$

ou da seguinte forma:

$$\pi(\theta|\mathbf{x}) = c f(\mathbf{x}|\theta)\pi(\theta) \quad (2.41)$$

em que $k = f(y)$ e $c = 1/\zeta$.

Também podemos escrever que (DUDA; HART, 1973):

$$\pi(\theta|\mathbf{x}) \propto f(\mathbf{x}|\theta)\pi(\theta) \quad (2.42)$$

Em que \propto representa o símbolo de proporcionalidade. Para enfatizar que a proporcionalidade é dada especificamente com relação a θ . tem-se que:

$$\pi(\theta|\mathbf{x}) \stackrel{\theta}{\propto} f(\mathbf{x}|\theta)\pi(\theta) \quad (2.43)$$

A equação 2.43, pode ser reescrita resultando na equação 2.44:

$$\pi(\theta|\mathbf{x}) \stackrel{\theta}{\propto} L(\mathbf{x}|\theta)\pi(\theta) \quad (2.44)$$

Em que $L(\mathbf{x}|\theta)$, é chamada de função de verossimilhança. Assim podemos resumir a equação 2.44, como: probabilidade a posteriori = verossimilhança \times probabilidade a priori.

O problema de posicionamento *indoor* a partir desse conceito é definido da seguinte forma:

Definição 2.4.3. Seja $\mathbf{s} = \{o_1, o_2, \dots, o_N\}$ o vetor RSS observado na fase *on-line* e $\mathcal{P}_i(x, y, z)$, para $i = 1, 2, \dots, N$, um conjunto de posições armazenadas no *radio map* na fase *off-line*, em que cada posição é candidata a posição do alvo, tal que $\bigcup_{i=1}^N \mathcal{P}_i = \mathcal{S}$ representa o espaço de posicionamento. Selecione \mathcal{P}_i se $P(\mathcal{P}_i | \mathbf{s}) > P(\mathcal{P}_j | \mathbf{s})$, for $i, j = 1, 2, \dots, N$ and $i \neq j$. Esta classificação formalmente é obtida aplicando a equação 2.45, o que resulta em:

$$P(\mathcal{P}_i | \mathbf{s}) = \frac{P(\mathbf{s} | \mathcal{P}_i)P(\mathcal{P}_i)}{P(\mathbf{s})} = \frac{P(o_1, o_2, \dots, o_N | \mathcal{P}_i)P(\mathcal{P}_i)}{P(\mathbf{s})} \quad (2.45)$$

Algoritmo 3: Inferência Bayesiana aplicada ao problema de Posicionamento *indoor*

Input: $\mathbf{s} = \{o_1, o_2, \dots, o_N\}$

Output: Posicionamento *indoor* 2D ou 3D.

- 1: **for** $i=1$ **to** N **do**
 - 2: Calcule $P(\mathcal{P}_i | \mathbf{s})$ baseado na equação 2.45.
 - 3: **end for**
 - 4: Aloque o usuário em $\mathcal{P}_i(x, y, z)$, para $i = 1, 2, \dots, N$, em que

$$\mathcal{P}_i(x, y, z) = \arg \max P(\mathcal{P}_i | \mathbf{s})$$
-

Neste capítulo, foram discutidos os fundamentos matemáticos dos métodos de triangulação, impressão digital e de proximidade. Uma comparação Qualitativa entre esses métodos foi apresentada ao final da seção 2.1.

Sistemas de posicionamento para ambientes fechados baseados nas tecnologias *Wi-Fi*, *Bluetooth*, *RFID*, *Dead Reckoning*, *Posicionamento Acústico* e *Posicionamento por Luz visível* foram discutidos na seção 2.2. Os modelos de propagação e os algoritmos para posicionamento *indoor*, foram abordados nas seções 2.3 e 2.4 respectivamente. No capítulo seguinte, discute-se em detalhes os dois primeiros IPS's propostos, *kmeans-NB* e *kNN-Bayes*.

3 SOLUÇÕES PROPOSTAS I E II (*kMEANS*-NB E *kNN*-BAYES)

3.1 Introdução

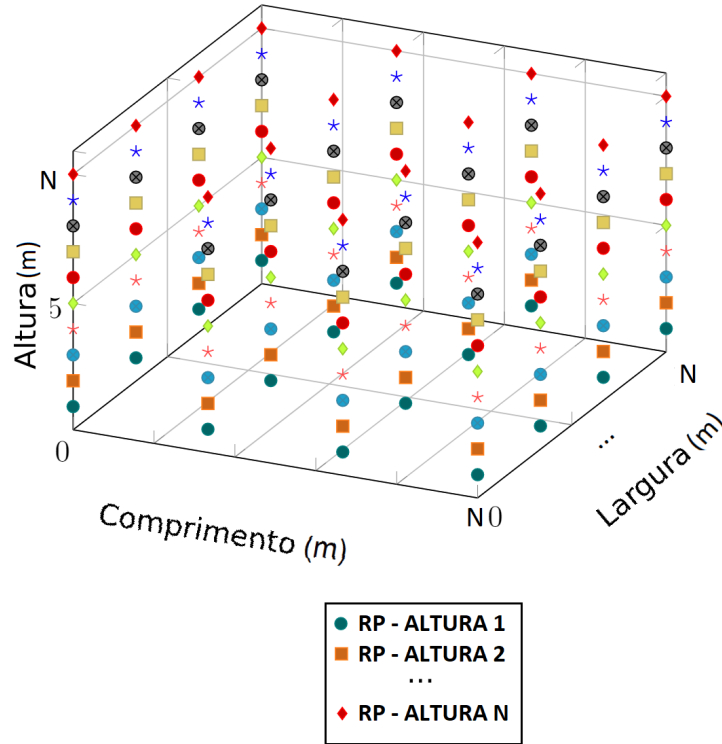
Neste capítulo são propostos dois algoritmos aqui chamados de *kmeans*-NB e *kNN*-Bayes, como soluções ao problema de posicionamento em ambientes fechados. O primeiro algoritmo proposto consiste em combinar um algoritmo de análise de agrupamentos chamado de *k-means* proposto em Lloyd (1982) e uma versão simplificada do teorema de Bayes definido na equação 2.45, chamada de *Naive Bayes (NB)* (DUDA; HART, 1973). O segundo algoritmo, composto por uma combinação entre o *kNN* e o teorema definido em 2.45, determina o posicionamento do alvo, a partir da construção de um estimador que implementa uma região em torno do RSS médio observado, de forma a capturar um total de k observações mais próximas.

As soluções propostas estão fundamentadas nos conceitos de estatística Bayesiana e utilizam a técnica de impressão digital discutida no capítulo 2 como estrutura básica para estimativa de posicionamento. Como discutido no capítulo 2, nesta técnica, os vetores RSS são obtidos em N RPs com posições 3D predeterminadas. Em cada RP, as medições são obtidas em relação a todos os APs. Estendendo esse conceito, essas medições são realizadas em diferentes alturas $\mathbf{z} = \{z_1, z_2, \dots, z_N\}$ e com o dispositivo móvel direcionado para o norte, sul, leste e oeste. Este procedimento visa tornar o *radio map* mais robusto, maximizando assim a precisão do posicionamento. A matriz definida em 3.1 e a figura 21, exibem este conceito.

$$\mathbf{RP}_s = \begin{pmatrix} rp1_{z_1}^{\mathcal{O}} & rp2_{z_1}^{\mathcal{O}} & \cdots & rpN_{z_1}^{\mathcal{O}} \\ rp1_{z_2}^{\mathcal{O}} & rp2_{z_2}^{\mathcal{O}} & \cdots & rpN_{z_2}^{\mathcal{O}} \\ \vdots & \vdots & \ddots & \vdots \\ rp1_{z_N}^{\mathcal{O}} & rp2_{z_N}^{\mathcal{O}} & \cdots & rpN_{z_N}^{\mathcal{O}} \end{pmatrix} \quad (3.1)$$

em que $\mathcal{O} = \{0^\circ, 90^\circ, 180^\circ, 270^\circ\}$, representa as direções norte, sul, leste e oeste.

Figura 21 – Impressão digital obtida em diferentes alturas



Fonte: o autor.

As seções 3.2 e 3.3, discutem em detalhes os algoritmos

3.2 Método proposto I - *kmeans*-NB

Na seção anterior, foi definida uma matriz (equação 3.1) de RPs com RSS obtidos em diferentes alturas e posições. Este procedimento corresponde a primeira etapa da fase *off-line*. A partir das observações armazenadas no *radio map*, a segunda etapa da fase *off-line*, consiste em particionar o espaço *indoor* em subconjuntos disjuntos chamados de *clusters*. Quando este procedimento é finalizado, o algoritmo NB é aplicado e o alvo é alocado em um desses *clusters*, obtendo-se seu posicionamento a partir do centroide do *cluster*. Formalmente este procedimento é definido como:


Definição 3.2.1. Considere o problema de particionamento do espaço *indoor* (matriz de RPs definida na equação 3.1) em \mathcal{P} *clusters* que representam os setores ou regiões nos quais os RPs serão alocados. Para cada um desses *clusters* define-se um conjunto de centróides c com coordenadas cartesianas escolhidas aleatoriamente na primeira iteração e com base na coordenada média dos RPs, a partir da segunda iteração. O particionamento é obtido, calculando-se a distância entre cada RP e os centróides, atribuindo-se cada RP ao *cluster* que possui o

centroide mais próximo. Este procedimento é repetido até que não haja mudança de RPs entre os *clusters*. O algoritmo *k-means*, realiza tal particionamento minimizando uma função objetivo, chamada função erro quadrático, definida pela equação 3.2 (HAN *et al.*, 2006).

$$E = \sum_{j=1}^K \sum_{rp \in \mathcal{P}_i} \|\mathbf{rp} - \mathbf{c}_j\|^2 \quad (3.2)$$

em que $\|\mathbf{rp} - \mathbf{c}_j\|$, representa a distância 3D entre cada RP e os centroides \mathbf{c}_j . O algoritmo 4 resume o problema de particionamento a partir do algoritmo *k-means*, enquanto que a figura 22, ilustra um exemplo de particionamento *indoor* composto por 500 RPs em 20 *clusters* para o caso 2D.

Figura 22 – Alocação de 500 RPs em 20 *clusters* com o algoritmo *k-means*



Fonte: o autor - (exemplo implementado na Linguagem R).

Algoritmo 4: Algoritmo *k-means*

Input: Um vetor $\mathbf{x} = \{x_1, x_2, \dots, x_N\} \in \mathbb{R}^n$

Número de *clusters*

Output: Um conjunto de clusters \mathcal{P} .

- 1: Defina aleatoriamente um conjunto centroide c_1, c_1, \dots, c_k .
 - 2: **for** $i=1$ **to** K **do**
 - 3: $c_i = \{x \in X \mid i = \operatorname{argmin}_{1 \leq j \leq k} \|r_i - \mathbf{c}_j\|^2\}$
 - 4: **end for**
 - 5: **for** $i=1$ **to** K **do**
 - 6: $c_i = \operatorname{argmin}_{Z \in \mathbb{R}^n} \sum_{x \in C_i} \|Z - X\|^2$
 - 7: **end for**
 - 8: **repeat**
 - 9: Retorne ao passo 1
 - 10: **until** que não haja movimento de dados entre os *clusters*.
-

Quando o processo de particionamento é finalizado, têm-se a seguinte configuração:

- Cada RP, possui uma coordenada 3D definitiva $\mathcal{P}_i(x, y, z)$, para $i = 1, 2, \dots, N$ e um vetor \mathbf{s} associado a esta coordenada;
- São atribuídas probabilidades para cada um dos *clusters*, conforme o conhecimento da frequência de usuários em cada uma desses clusters ou uniformemente, isto é, considerando que $P(\mathcal{P}_i), i = 1, \dots, N$ sejam equiprováveis.

Após este procedimento, a fase *off-line* estará finalizada. Na fase *online* a partir da leitura do vetor \mathbf{s} , o posicionamento do alvo é obtido com base na equação 2.45, resultando na equação 3.3.

$$P(\mathcal{P}_i|\mathbf{s}) = \frac{P(\mathbf{s}|\mathcal{P}_i)P(\mathcal{P}_i)}{P(\mathbf{s})} = \frac{P(o_1, o_2, \dots, o_N|\mathcal{P}_i)P(\mathcal{P}_i)}{P(o_1, o_2, \dots, o_N)} \quad (3.3)$$

Pela regra do produto (SCHUM, 1994), têm-se que:

$$P(o_1, o_2, \dots, o_N|\mathcal{P}_i) = P(o_1|o_2, \dots, o_N, \mathcal{P}_i) \times \dots \times P(o_{N-1}|o_N, \mathcal{P}_i)P(o_N|\mathcal{P}_i) \quad (3.4)$$

De forma a reduzir o custo computacional do sistema com o cálculo da equação 3.3, quando se faz necessário a aquisição de um grande volume de dados, iremos considerar que $o_i \perp\!\!\!\perp o_j|\mathcal{P}_i, \forall i, j, 1 \leq i, j \leq N$. Isso significa que $P(o_1, o_2, \dots, o_N|\mathcal{P}_i)$ é dado pela equação 3.5.

$$P(o_i | o_{i+1}, \dots, o_N, \mathcal{P}_i) = P(o_i | \mathcal{P}_i) = \prod_{i=1}^N P(\mathbf{s} | \mathcal{P}_i) \quad (3.5)$$

Assim, a probabilidade de alocação do alvo na partição \mathcal{P} dado \mathbf{s} é simplificado para:

$$P(\mathcal{P} | \mathbf{s}) \propto P(\mathcal{P}_i, o_1, \dots, o_N) \quad (3.6)$$

$$\propto P(\mathcal{P}_i) \times P(o_1, \dots, o_N | \mathcal{P}_i) \quad (3.7)$$

$$\propto P(\mathcal{P}_i) \times P(o_1 | P(\mathcal{P}_i)) \times \dots \times P(o_N | P(\mathcal{P}_i)) \quad (3.8)$$

$$\propto P(\mathcal{P}) \prod_{i=1}^N P(\mathbf{s} | \mathcal{P}_i) \quad (3.9)$$

A equação 3.9 é uma versão simplificada do teorema de Bayes, conhecido como *naive Bayes*. Trata-se de um modelo de rede Bayesiana (discutido no capítulo 4) em que os atributos estão associados apenas a classe, representada como o nó raiz da rede. Para mais detalhes sobre este classificador veja: Friedman *et al.* (1997) e Duda e Hart (1973).

Após a identificação da partição que resulta em máxima probabilidade, estima-se a posição do usuário a partir da coordenada do centroide dos RPs.

Existem vários métodos para estimativa de $P(\mathbf{s} | \mathcal{P})$. Dois métodos amplamente utilizados, são o método histograma e *kernel* (WASSERMAN, 2006) e (SILVERMAN, 1986). Estes métodos são discutidos a seguir:

Definição 3.2.2. Considere $P(\mathbf{s} | \mathcal{P})$ como uma função densidade de probabilidade (FDP) denotada por $f_X(x)$ que deve ser estimada com o mínimo de suposições possíveis através de um estimador $\hat{f}_X(x)$, em que a qualidade da estimativa é obtida através da equação 3.10 (WASSERMAN, 2006).

$$R = E(L) \quad (3.10)$$

em que:

$$L = \int (\hat{f}_X(x) - f_X(x))^2 dx \quad (3.11)$$

$$L(h) = \int (\hat{f}_X(x) - f_X(x))^2 dx = \int \hat{f}_x^2(x) dx - 2 \int \hat{f}_X(x) f_X(x) dx + \int f^2(x) dx \quad (3.12)$$

Em que h é um parâmetro de suavização dos dados não negativo chamado de *bandwidth* (largura de banda). O último termo da equação 3.12, não depende de h , assim, obtêm-se (WASSERMAN, 2006):

$$J(h) = \int (\hat{f}_X(x) - f_X(x))^2 dx = \int \hat{f}_X^2(x) dx - 2 \int \hat{f}_X(x) f_X(x) dx \quad (3.13)$$

em que:

$$E(J(h)) = R(h) + c \quad (3.14)$$

Definição 3.2.3. Seja $\hat{f}_{(-1)}(x)$ o estimador de densidade após ter removido a i -ésima observação. Definimos $\hat{f}(h)$ como um *score* chamado de validação cruzada do risco dado pela equação 3.15.

$$\hat{f}(h) = \int (\hat{f}_X(x))^2 dx - \frac{2}{N} \sum_{i=1}^N \hat{f}_{(-1)}(x_i) \quad (3.15)$$

O método mais simples e antigo para estimativa de probabilidade é conhecido como histograma. Este método subdivide o espaço de $f_X(x)$ com suporte $[0,1]$ em M bins de tamanhos iguais, dados pela equação 3.16.

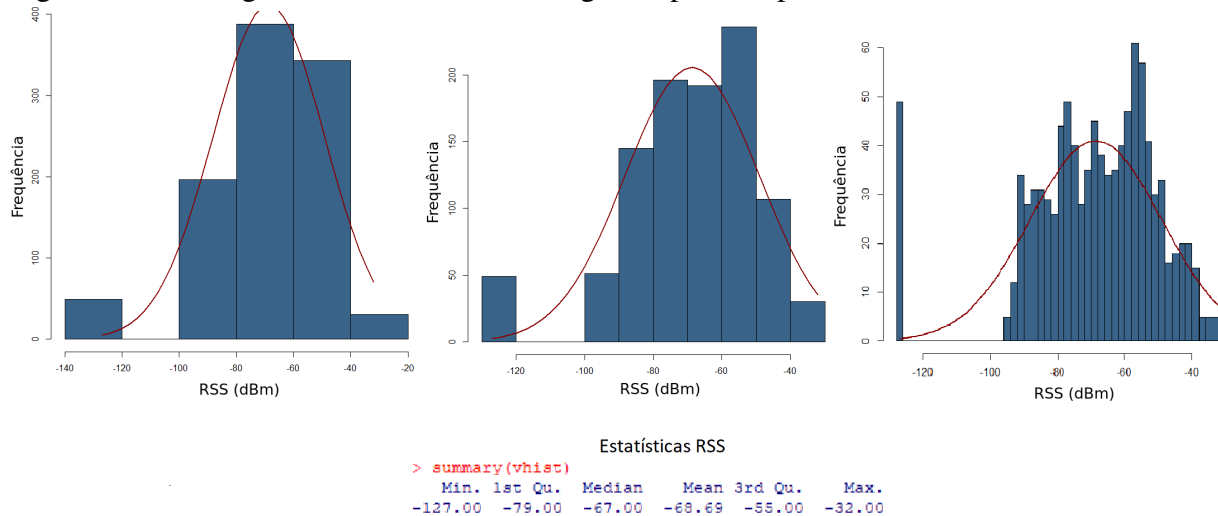
$$B_1 = \left[0, \frac{1}{M}\right), B_2 = \left[\frac{1}{M}, \frac{2}{M}\right), \dots, B_M = \left[\frac{M-1}{M}, 1\right] \quad (3.16)$$

Definição 3.2.4. Seja $h = \frac{1}{M}$, $p_j = \int_{B_j} f_X(x) dx$ e $Y = \sum_{i=1}^N I(x_i \in B_j)$, a estimativa de $f_X(x)$ a partir do método histograma é dado pela equação 3.17 (WANG *et al.*, 2012).

$$\hat{f}_X(x) = \sum_{j=1}^M \frac{\hat{p}_j}{h} I(x_i \in B_j) \quad (3.17)$$

A figura 23 ilustra a distribuição do RSS em uma região específica para diferentes números de *bins*.

Figura 23 – Histogramas do RSS em uma região específica para diferentes números de *bins*



Fonte: o autor - (exemplo implementado na Linguagem R).

Para estimar a $P(\mathbf{s}|\mathcal{P})$, a partir deste conceito, obtém-se a distribuição de frequência dos sinais no ambiente. O objetivo é verificar a frequência de cada intervalo RSS em relação a todas as partições \mathcal{P} .

Outro método bastante conhecido, é a estimativa de densidade *kernel* (WASSERMAN, 2006). Esse método estima $f_X(x)$ determinando o número de observações RSS dentro de uma região fixa com comprimento igual a b centrada na média de \mathbf{s} , representada como $\bar{\mathbf{s}}$. Este conceito é ilustrado na figura 24, com uma região centrada em x com $b = 0,5$.

Definição 3.2.5. Seja $X_i, i = 1, 2, \dots, N$ com $N \in \mathbb{N}$, denotando uma amostra de N observações, $K : \mathbb{R} \rightarrow \mathbb{R}$, a estimativa de densidade *kernel* é dada pela equação 3.18 (WASSERMAN, 2006):

$$f_X(x) = \frac{1}{n} \sum_{i=1}^N \frac{1}{h} K\left(\frac{x - X_i}{h}\right) \quad (3.18)$$


em que: n representa o tamanho da amostra e $K(\bullet)$ é a função *Kernel* que deve satisfazer as seguintes condições:

- (i) K não negativo;
- (ii) $\int_{\mathbb{R}} K_X(x) dx = 1$;
- (iii) $h > 0$.

Uma função amplamente utilizada neste caso, é o *Kernel* gaussiana. Assim, a estimativa $P(\mathbf{s}|\mathcal{P})$ pode ser modelada através de uma distribuição normal (essa e outras distribuições são apresentadas no anexo A) dada pela equação 3.19 (ROOS *et al.*, 2002):

$$f_x(x) = \frac{1}{N} \sum_{i=1}^N \frac{1}{h\sqrt{2\pi}} \exp\left[-\frac{1}{2} \left(\frac{o - o_i}{h}\right)^2\right] \quad (3.19)$$

Figura 24 – Estimativa de $f_X(x)$ a partir do método *kernel*



Fonte: Theodoridis e Koutroumbas (2008).

Uma função geral para $K(\bullet)$, é dada pela equação 3.20 (FUKUNAGA, 1990).

$$K(X) = \frac{m\Gamma\left(\frac{n}{2}\right)\left(\frac{n+2}{2m}\right)}{(n\pi)^{n/2}\Gamma^{n/2+1}\left(\frac{n}{2m}\right)} \cdot \frac{1}{r^n |\mathbf{A}|^{1/2}} \exp \left[- \left\{ \frac{\Gamma\left(\frac{n+2}{2m}\right)}{n\Gamma\left(\frac{n}{2m}\right)} X^T (r^2 \mathbf{A})^{-1} X \right\}^m \right] \quad (3.20)$$

em que m é o parâmetro que determina a forma da função *kernel*. Para $m = 1$, a equação 3.20, se reduz a *kernel* gaussiana. Quando $m \rightarrow \infty$, a equação 3.20 se reduz a uma *kernel* uniforme (hiperelíptica). A matriz \mathbf{A} determinada a forma do hiper-elipsóide, r , controla o tamanho ou volume do *kernel* e $\Gamma(\alpha)$ é a função gama dada pela equação 3.21.

$$\Gamma(\alpha) = \int_0^\infty x^{\alpha-1} e^{-\beta x} dx \quad (3.21)$$

A implementação do IPS em questão é resumida no algoritmo 5 e na figura 25.

Algoritmo 5: Algoritmo *kmeans*-NB para posicionamento *indoor* 3D

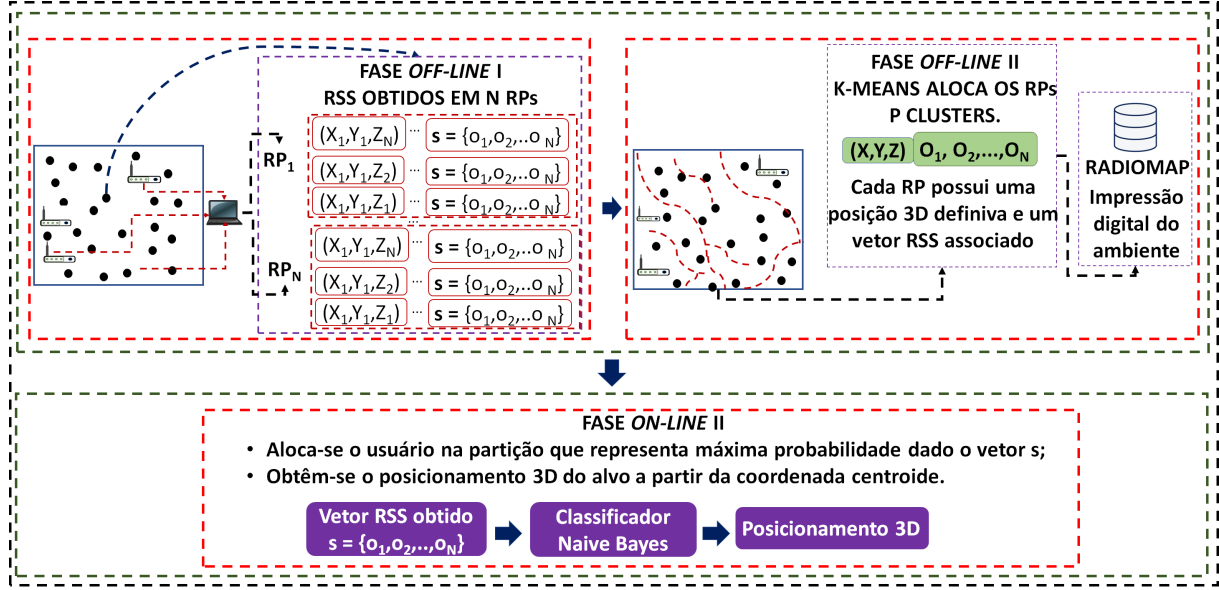
Input: $\mathbf{rp} = \{rp_1, rp_2, \dots, rp_N\} \in \mathbb{R}^n$ que representa o vetor de pontos de referência.

Número de *clusters* \mathcal{P} representando o número de *clusters*.

Um vetor de sinal $\mathbf{s} = \{o_1, o_2, \dots, o_N\}$.

Output: Posicionamento 3D a partir do centroide das coordenadas dos RPs

- 1: Defina um conjunto de centroides $c_1, c_2, \dots, c_{\mathcal{P}}$ com coordenadas aleatórias para cada *cluster*.
 - 2: **repeat**
 - 3: Calcule as distâncias entre os RPs e os centroides usando a equação 3.2 e atribua cada ponto ao *cluster* com centroide mais próximo.
 - 4: Recalcule os centroides de cada *cluster* com base nas coordenadas dos RPs.
 - 5: **until** que não haja movimento de dados entre os *clusters*.
 - 6: **for** $i=1$ **to** N **do**
 - 7: Calcule $P(\mathcal{P}|\mathbf{s})$ baseado na equação 3.9.
 - 8: **end for**
 - 9: Aloque o usuário ao *cluster* que resulta em máxima probabilidade.
 - 10: Obtenha o centroide dos RPs.
 - 11: Retorne o posicionamento 3D baseado na coordenada obtidas no passo 10.
-

Figura 25 – Arquitetura do IPS *kmeans*-NB

3.3 Método II - KNN-Bayes proposto

A implementação do IPS com base neste método, consiste na estimativa da probabilidade a posteriori na equação 2.45 através do algoritmo *kNN*.

Na fase online, após a leitura do vetor s , define-se uma região (aqui discutida como uma hipersfera com volume V) centrada em \bar{s} e que capture k vizinhos mais próximos de \bar{s} . Usualmente o valor de k deve ser pequeno comparado ao número total de observações RSS no ambiente, denotado por N (FUKUNAGA, 1990). Em Gramacki (2017), é sugerido $k \approx \sqrt{N}$.

Após o procedimento de captura dos pontos mais similares, verifica-se a frequência de cada observação com relação a todos os setores (regiões de alocação do usuário). Assim, um setor é selecionado para se estimar o posicionamento do alvo, se possui a maior frequência de observações entre todos os setores. Este procedimento de estimativa de densidade para $N = 25$ e $k = 5 / N = 16$ e $k = 4$, é apresentado nas figuras 26 e 27, para os casos 2D e 3D, respectivamente.

Formalmente esse procedimento de estimativa de densidade aplicado ao problema de posicionamento *indoor* para o espaço \mathbb{R}^d , é definido como:

Definição 3.3.1. Sejam o_1, o_2, \dots, o_N , o total de observações RSS no setor i , para $i = 1, 2, \dots, N$, diremos que $\bigcup_{i=1}^N o_i = n$, $\mathcal{R}_k^d(x)$ é a distância da estimativa entre \bar{s} e os k vizinhos mais próximos e c_d é o espaço ocupado (V) para uma hipersfera em d dimensões, dada pela equação 3.22 (FUKUNAGA, 1990).


$$c_d = \int_{R_{\bar{s}}} dY = \frac{\pi^{d/2}}{(d/2)!} = \frac{\pi^{d/2}}{\Gamma(d/2 + 1)} \quad (3.22)$$

Dessa forma, a probabilidade do setor i , para $i = 1, 2, \dots, N$, é dado pela equação 3.23 (DUDA; HART, 1973) e a probabilidade de \bar{s} é estimada como a razão entre as observações capturadas pela hipersfera e o produto entre \mathcal{N} e V . Dessa forma a estimativa de densidade é dada pela equação 3.24 (THEODORIDIS; KOUTROUMBAS, 2008).

$$P(S) = \frac{n}{\mathcal{N}} \quad (3.23)$$


$$P(\bar{s}) = \frac{k}{\mathcal{N} c_d \mathcal{R}_k^d(x)} = \frac{k}{\mathcal{N} V} \quad (3.24)$$

Figura 26 – Estimativa de $P(x)$ para $d = 2$ e $k = 5$



Fonte: o autor.

Figura 27 – Estimativa de $P(x)$ para $d = 3$ e $k = 4$



Fonte: o autor.

A função de verossimilhança é estimada a partir da razão entre o total de observações de um setor específico capturadas pela esfera, definido por k_i e o produto entre n e V , o que resulta na equação 3.25.

$$P(\bar{s} | S) \cong \frac{k_i}{nV} \quad (3.25)$$

Assim, a probabilidade do setor ser selecionado para estimar posicionamento do alvo é dado pela razão entre k_i e k , conforme a equação 3.26.

$$P(S|\bar{s}) = \frac{P(\bar{s}|S)P(S)}{P(\bar{s})} = \frac{\frac{k_i}{nV} \frac{n}{N}}{\frac{k_i}{nV}} = \frac{k_i}{k} \quad (3.26)$$

Esse procedimento de estimativa da probabilidade a posteriori através do algoritmo k NN é discutido em detalhes em Fukunaga (1990), Duda e Hart (1973), Gramacki (2017) e Theodoridis e Koutroumbas (2008). A implementação do IPS em questão é resumido através do algoritmo 6 e da figura 28 (O procedimento de posicionamento 3D é o mesmo, com a diferença que uma esfera deve ser implementada).

Algoritmo 6: Algoritmo k NN-Bayes para posicionamento *indoor* 3D

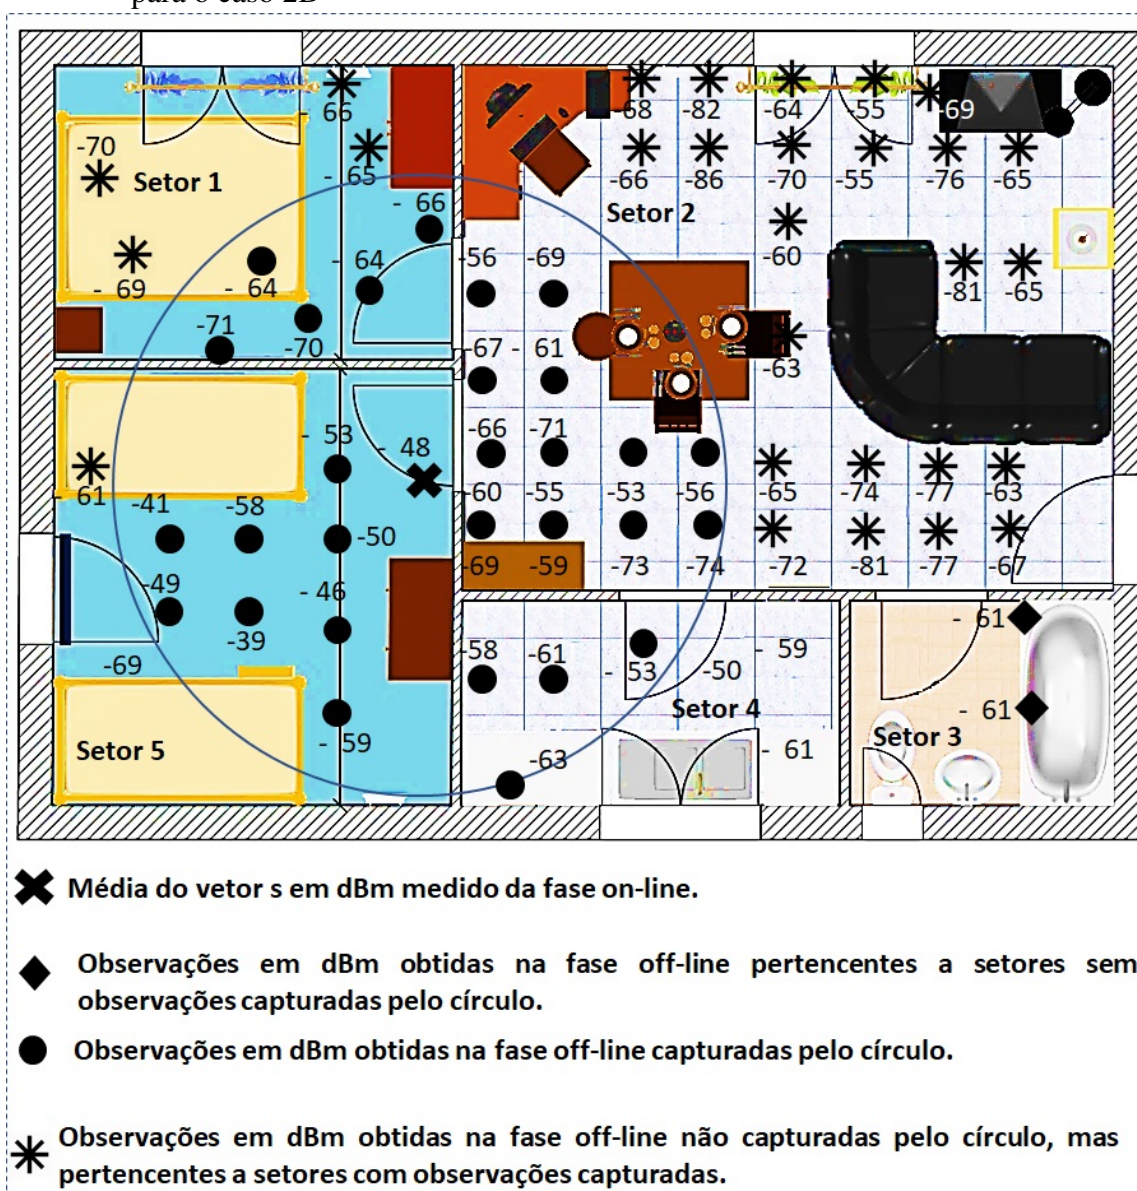
Input: $\mathbf{rp} = \{rp_1, rp_2, \dots, rp_N\} \in \mathbb{R}^n$ que representa o vetor de pontos de referência.

Um vetor de sinal $\mathbf{s} = \{o_1, o_2, \dots, o_N\}$.

Output: Posicionamento 3D a partir do centroide das coordenadas dos RP's do setor que apresenta o maior número de observações capturadas pela esfera.

- 1: obtenha $k = \sqrt{N}$
 - 2: Implemente uma esfera de volume V que capture os k vizinhos mais próximos de \bar{s} .
 - 3: **for** $i=1$ **to** N **do**
 - 4: Selecione o setor com o maior quantidade de observações capturadas pela esfera.
 - 5: **end for**
 - 6: Obtenha o centroide dos RPs do setor selecionado.
 - 7: Retorne a posicionamento 3D baseado nas coordenadas obtidas no passo 6.
-

Figura 28 – Exemplo de aplicação do algoritmo k NN-Bayes em um ambiente com cinco setores para o caso 2D



Fonte: o autor - exemplo implementado através do software *Sweet Home 3D* (ETEKS, 2006).

Note que na figura 28, têm-se quatro possíveis setores para se estimar a localização do alvo (setores 1, 2, 4 e 5). O setor 3 neste caso não foi selecionado, pois seus pontos não foram capturados pela esfera). Dentre esses setores, o 5 apresenta maior frequência de observações similares a \bar{s} (-48dBm) que os demais. Assim esse setor é selecionado e o posicionamento 3D do alvo é obtido através do centroide das observações.

3.4 Conclusão

Nessa seção, foram propostos dois algoritmos baseados em estatística Bayesiana para ao problema de posicionamento *indoor* 3D. A primeira solução proposta consiste em combinar os algoritmos *k-means* e *naive* Bayes, uma versão simplificada do teorema de Bayes, em que os atributos do vetor s são independentes um dos outros dado os setores. A segunda solução, estima a probabilidade a priori da equação em definida em 2.45 através do algoritmo *kNN*. No próximo capítulo apresentaremos uma solução para o problema de posicionamento baseado em sistemas multiagente, utilizando uma rede neural profunda e uma rede Bayesiana que está fundamentada nos conceitos relacionados ao algoritmo *naive* Bayes.

4 MÉTODO PROPOSTO III - IPS-MAS

4.1 Introdução

Aqui, a solução proposta chamada de sistema de posicionamento baseado em sistemas multiagente (IPS-MAS), foi desenvolvida a partir de duas hibridizações. Primeiro o método ML foi combinado com o método de impressão digital com o objetivo de reduzir a região de aquisição dos vetores de sinais. Depois, uma hibridização entre uma rede Bayesiana / *Bayesian network* (BN) e uma rede neural profunda (DNN), foi implementada, de modo que esses algoritmos possam funcionar de forma integrada com o objetivo de maximizar a precisão do sistema de posicionamento.

Definição 4.1.1.


Uma BN, denotada por $\mathcal{B} = \langle G, \theta \rangle$, é um grafo direcionado acíclico / *directed acyclic graph* (DAG), com $G = (V, A)$ definido por um par composto de vértices (V) que representam um conjunto de variáveis aleatórias, $\{\mathcal{V}_1, \mathcal{V}_2, \dots, \mathcal{V}_N\}$ e arestas ou arcos (A) representando a dependência entre essas variáveis aleatórias. θ representa o conjunto de probabilidades condicionais relacionadas a cada variável aleatória. Se existe um arco no sentido de \mathcal{V}_1 para \mathcal{V}_2 , diremos que \mathcal{V}_1 é pai de \mathcal{V}_2 . Assim a probabilidade conjunta $P(\mathcal{V}_1, \mathcal{V}_2, \dots, \mathcal{V}_N)$, é dada pela equação 4.1.

$$\prod_i P(\mathcal{V}_i | \mathcal{V}_1, \mathcal{V}_2, \dots, \mathcal{V}_{i-1}) = \prod_i P(\mathcal{V}_i | \text{pais}(\mathcal{V}_i)) \quad (4.1)$$

Na figura 29, a probabilidade conjunta $P(A, B, C, D, E, F)$, considerando:

$V = \{A, B, C, D, E, F\}$ e $A = \{(A, B), (A, C), (A, D), (B, E), (C, E), (D, E), (E, F)\}$, é expressa como $P(A)P(B | A)P(C | A)P(D | A)P(E | B, C, D)P(F | E)$.

Figura 29 – Exemplo de uma rede Bayesiana com variáveis aleatórias $V = \{A, B, V, D, E, F\}$



Fonte: o autor.

O algoritmo 7 Pearl (1988) resume o procedimento de construção de uma rede bayesiana.

Algoritmo 7: Algoritmo de construção de rede da Pearl.


- 1: Defina um conjunto de variáveis aleatórias \mathcal{V}_i relevantes que descrevem o domínio.
 - 2: Defina uma ordem para as variáveis \mathcal{V}_i
 - 3: **while** houver variáveis restantes **do**
 - 4: Adicione a próxima variável \mathcal{V}_i à rede.
 - 5: Relacione os vértices \mathcal{V}_i , de forma a satisfazer a equação definida em 4.1.
 - 6: Defina uma tabela de probabilidade condicional (CPT) para \mathcal{V}_i .
 - 7: **end while**
-

Definição 4.1.2.

Uma DNN pode ser entendida intuitivamente como uma rede MLP convencional com várias camadas ocultas (frequentemente mais do que duas). Este modelo de ANN utilizado

por Yu *et al.* (2012) para modelagem de problemas relacionados ao reconhecimento de voz. Outros trabalhos que discutem sobre esse tipo de rede, incluem: Yu e Deng (2014), Ali e Senan (2018) e Bengio (2009). A figura 30 ilustra a arquitetura de uma típica DNN com três camadas escondidas enquanto que o algoritmo 8 resume o processo de aprendizado dessa rede através do algoritmo *backpropagation* Rumelhart *et al.* (1986).

Figura 30 – Arquitetura de uma DNN



Fonte: o autor.

Algoritmo 8: *Backpropagation.*

- 1: **for** d in data **do**
 - 2: Forwards Pass
 - 3: Apresente um padrão à camada de entrada da rede que será propagado ao longo das conexões entre os neurônios das várias camadas até ser gerado um padrão nas unidades de saída.
 - 4: Backwards Pass
 - 5: **for** layer in layers **do**
 - 6: Compare o padrão de saída com o padrão desejado. A diferença ou erro é propagada para trás através da rede, modificando-se os pesos.
 - 7: **end for**
 - 8: **end for**
 - 9: Retorne estimativa.
-

4.2 IPS-MAS

Para implementação desse IPS, inicialmente aplicou-se o método ML de forma a estimar $\mathcal{T}(x,y,z)$ como a coordenada representando a posição do alvo. Esta estimativa é formalmente obtida pela interseção de quatro esferas centradas em pelo menos quatro APs com

coordenadas dadas por $(x_1, y_1, z_1), (x_2, y_2, z_2), \dots, (x_N, y_N, z_N)$, cujas distâncias para o alvo são dadas por r_i^2 , para $i = 1, 2, \dots, N$ e obtidas conforme a equação 2.8. Quando esse processo é concluído, a região de aplicação do método de impressão digital é reduzida a uma esfera com raio $r = \max(r_i)$, for $i = 1, 2, \dots, N$, e os vetores s em N RPs com posições são obtidos conforme a matriz definida em 3.1. Na fase online do IPS, sinais são apresentados a uma BN e uma DNN (aqui tratadas como agentes inteligentes) que de forma integrada estimam o posicionamento do alvo.

Um agente inteligente quando relacionado ao problema abordado nessa tese, pode ser definido como um algoritmo que situado em um ambiente *indoor* dinâmico (AID), aqui definido como um conjunto de estados discretos $\mathcal{E} = \{e_0, e_1, \dots, e_N\}$, é capaz tomar ações autônomas $\mathcal{A} = \{a_0, a_1, \dots, a_N\}$ de forma a maximizar a precisão do posicionamento do alvo.

Observação. O termo AID, refere-se ao conjunto de estados que o ambiente pode apresentar em um dado momento. Para cada um dos estados o agente retorna uma ação. Assim a resposta r de um agente pode ser visto como uma sequência dada por (WOOLDRIDGE, 2009):

$$r : e_0 \xrightarrow{a_0} e_1 \xrightarrow{a_1} e_2, \dots, \xrightarrow{a^{N-1}} e_N \quad (4.2)$$

Definição 4.2.1. Seja \mathcal{R} o conjunto de todas as sequências finitas possíveis definidas na equação 4.2, em que \mathcal{R}^A representa o subconjunto dessa sequência que termina com uma ação e \mathcal{R}^E o subconjunto dessa sequência que termina com um estado. Para representar o efeito que as ações de um agente têm em um ambiente, considere uma função de transformação, conforme Wooldridge (2009), dada pela equação:

$$\mathcal{T} = \mathcal{R}^A \rightarrow \mathcal{P}_o(\mathcal{E}) \quad (4.3)$$

que mapeia uma ação do agente a um conjunto de possíveis estados. Neste sentido, de uma forma mais geral, um ambiente pode ser definido como uma 3-tupla dado pela equação 4.4 e um agente como uma função dado pela equação 4.5 (RUSSELL; SUBRAMANIAN, 1995):

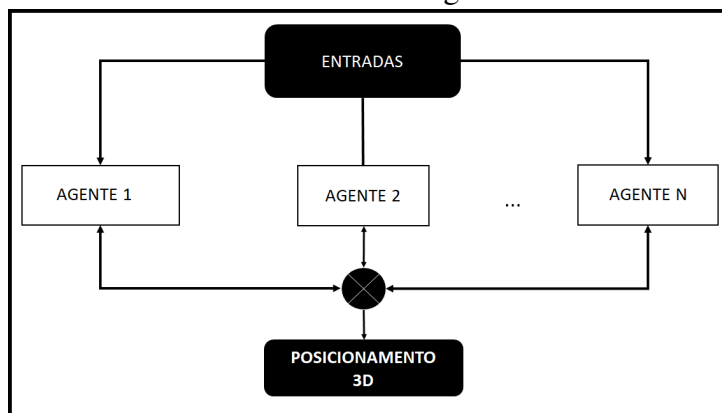
$$E = \langle \mathcal{E}, e_0, \mathcal{T} \rangle \quad (4.4)$$

$$\mathcal{AG} = \mathcal{R}^E \rightarrow \mathcal{A} \quad (4.5)$$

Fundamentado nas definições acima, a ideia geral deste método proposto é a implementação de um sistema composto de múltiplos agentes em um ambiente E denotado pelo par $((\mathcal{AG}_1, \mathcal{AG}_2, \dots, \mathcal{AG}_N), E)$. Esses agentes trabalham de forma integrada e colaborativa com

o objetivo de obter maior precisão para estimativa de posicionamento. A figura 31 ilustra a arquitetura básica desse IPS.

Figura 31 – Arquitetura básica de um sistema multiagente IPS




Fonte: o autor.

4.3 Agente BN

A implementação do agente proposto a partir do conceito de rede bayesiana, consiste em uma variação da equação definida em 3.9 chamada de árvore aumentada *naive Bayes* / *tree augmented naive bayes* (TAN), proposta em Friedman *et al.* (1997). Essa variação foi utilizada de forma a considerar a dependência do RSS com relação ao nível de ruído / *noise level* (NL) no ambiente, estimado a partir da verificação do quanto o sinal é atenuado em função da movimentação de pessoas no prédio, além da atenuação quando se incrementa o número de APs.

TAN é uma rede Bayesiana em que $\Pi_{\mathcal{P}} = \emptyset$ e cada atributo possui como pai \mathcal{P} e no máximo mais algum outro atributo. Perceba que este algoritmo é similar ao NB, permitindo, no entanto, dependências entre os atributos. A figura 32 ilustra essa estrutura para o problema em questão.



Fonte: o autor.

O processo de aprendizado deste agente consiste no conjunto de dados \mathcal{D} , que em um dado momento, está melhor relacionado aos atributos da rede. Onde \mathcal{D} é composto das informações armazenadas no *radio-map*, assim como a relação entre s , o NL e as informações recebidas por um agente responsável pela comunicação e mediação entre os agentes, chamado de moderador. O algoritmo 9, resume este procedimento.

Algoritmo 9: Processo de aprendizado em uma rede TAN (FRIEDMAN *et al.*, 1997)

- 1: Forneça um conjunto de treinamento \mathcal{D} (i.i.d).
 - 2: Aplique a versão modificada do algoritmo definido por Chow e Liu (1968).
 - 3: Adicione \mathcal{P} como pai de $\{NL, o_1, o_2, \dots, o_N\}$
 - 4: Obtenha uma árvore geradora mínima / *minimum spanning tree* (MST).
 - 5: Transforme a árvore não direcionada resultante em uma direcionada, escolhendo uma variável raiz e definindo a direção de todas as arestas.
-

O passo 2 do algoritmo 9 consiste em calcular $I_{\hat{P}_D}(A_i; A_j | \mathcal{P})$ entre cada par de atributos, $i \neq j$, em que $I_{\hat{P}_D}(A_i; A_j | \mathcal{P})$ é a informação mútua condicional com relação à distribuição empírica \hat{P}_D em \mathcal{D} entre A_i, A_j dado \mathcal{P} . A versão modificada do algoritmo proposto por Chow e Liu (1968) é apresentado na equação 4.6.

$$I(A_i; A_j | C) = \sum_{a_i; a_j; c} \hat{P}_D(a_i; a_j; c) \log \frac{\hat{P}_D(a_i; a_j | c)}{\hat{P}_D(a_i | c) \hat{P}_D(a_j | c)} \quad (4.6)$$

O passo 3 do algoritmo 9, pode ser obtido a partir de dois algoritmos clássicos em teoria dos grafos. O algoritmo de Prim desenvolvido por Jarník (1930) e mais tarde republicado por Prim (1957) e o algoritmo de Kruskal (KRUSKAL, 1956). Uma MST é formalmente definida como:

Definição 4.3.1. Dado um grafo não direcionado $G = (V, A)$, em que cada aresta (u, v) possui um peso $p(u, v)$. Encontre um conjunto $T \subseteq$ conectando todos os vértices V com pesos mínimos. Em que $p(T) = \sum_{(u,v) \in T} p(u, v)$. Um conjunto acíclico conectando todos os vértices em que o somatório dos pesos representa o mínimo entre todas possibilidades, é chamado de MST. O algoritmo 10 resume o procedimento para obtenção de uma MST genérica.

Algoritmo 10: Obtenção de uma AGM genérica (PANDEY, 2008)

```

1:  $C \leftarrow \{\}$ 
2: while um conjunto  $C$  não formar uma AGM do
3:   encontrar uma aresta segura para  $A$ .
4: end while
5:  $C \leftarrow C \cup \{(u, v)\}$ .
6: Retorne  $C$ 

```

- Algoritmo de Prim: Este algoritmo inicia selecionando aleatoriamente um vértice v em um grafo $G = (V, A)$. Em seguida, seleciona-se outro vértice u que se conecta a v tal que a aresta (u, v) possua o menor peso entre todas arestas incidentes em v . A cada iteração escolhe-se um vértice que satisfaça esta condição. Este processo é repetido até que se gere uma AGM. O algoritmo 11 resume esse procedimento.

Algoritmo 11: Algoritmo de Prim

```

1:  $Q \leftarrow V[G]$ 
2: for cada  $u$  em  $Q$  do
3:    $chave[u] \leftarrow \infty$ 
4:    $chave[r] \leftarrow o$ 
5:    $\pi[r] \leftarrow NIL$ 
6: end for
7: while A fila  $Q$  não estiver vazia do
8:    $u \leftarrow DeleteMin(Q)$ 
9: end while
10: for cada  $v$  adj em  $[u]$  do
11:   if  $v$  em  $Q$  e  $\omega(u, v) < chave([u])$  then
12:      $\pi[r] \leftarrow \omega(u, v)$ 
13:      $chave([v]) \leftarrow \omega(u, v)$ 
14:   end if
15: end for

```

- Algoritmo de Kruskal: Implementa uma floresta em que cada vértice é considerado uma árvore separada. Duas árvores se conectam se e somente se a aresta que as conecta possuir

o menor peso entre todas as opções disponíveis e não formar um ciclo.

Algoritmo 12: Algoritmo de Kruskal

```

1:  $C \leftarrow \{\}$ 
2: for cada vértice  $v \in V[G]$  do
3:   Ordene as aresta de  $A$  em ordem crescente por peso.
4:   Make-Set ( $v$ ): Cria um novo conjunto  $\{v\}$ 
5: end for
6: for cada  $a = (u, v) \in A$  do
7:   if Find-Set ( $u$ )  $\neq$  Find-Set ( $v$ ): Retorna um ponteiro para o representante
      do (único) conjunto que contém  $x$ . then
8:      $C \leftarrow C \cup \{(u, v)\}$ 
9:     UNION ( $u, v$ )
10:  end if
11: end for
12: The system returns the 3D positioning based on the centroid of the estimates.

```

4.4 Agente DNN

Formalmente, o agente implementado a partir desse conceito é definido como:

Definição 4.4.1. Seja uma DNN com a camada de entrada denotada por camada \mathcal{C}_0 e a camada de saída como \mathcal{C} para uma DNN com uma $\mathcal{C} + 1$ camadas, então a \mathcal{C} -ésima camada pode ser representada pela equação 4.7.

$$\mathbf{v}^c = f(\mathbf{a}^c), 0 < c < \mathcal{C} \quad (4.7)$$

em que $\{\mathbf{a}^c = (\mathbf{W}^c \mathbf{v}^{c-1} + b^c), \mathbf{v}^c, b^c\} \in \mathbb{R}^{N_c \times 1}$, $\mathbf{W}^c \in \mathbb{R}^{N_c \times N_{c-1} \times 1}$ e $N_c \in \mathbb{R}$, representando respectivamente, o vetor de excitação, o vetor de ativação, a matriz de peso, um neurônio especial chamado de *bias* e o número de neurônios na camada c . Considere ainda $\mathbf{v}^0 = \mathbf{o} \in \mathbb{R}^{N_0 \times 1}$ uma observação do vetor, $N_0 = D$ é a dimensão dessa observação e $f(\bullet)$ é uma função de ativação (geralmente uma sigmóide ou a tangente hiperbólica dadas pelas equações 4.8 e 4.9 respectivamente (YU; DENG, 2014)) aplicada a v , então define-se um o erro quadrático médio com o objetivo de otimizar os pesos e *bias* de forma a minimizar o erro dado pela equação 4.10.

$$f(\mathbf{a}) = \frac{1}{1 + e^{-a}} \quad (4.8)$$

$$f(\mathbf{a}) = \frac{e^a - e^{-a}}{e^a + e^{-a}} \quad (4.9)$$

$$EQM = \frac{1}{2} \sum (\mathcal{C} - o(\mathbf{v}^0, \mathbf{W}))^2 \quad (4.10)$$

em que $o(\mathbf{v}^0, \mathbf{W})$ representa a saída real.

De forma ajustar cada peso na rede proporcionalmente a contribuição com relação ao erro geral, aplica-se o algoritmo *backpropagation* de forma calcular o gradiente (Δ) da equação definida em 4.10, aplicando sistematicamente a regra da cadeia a partir do cálculo de múltiplas variáveis. A ideia é que em cada iteração seja dado pequenos passos na direção que minimiza o erro. Assim os pesos e *bias* a cada iteração podem ser ajustados conforme as equações 4.11 e 4.12 (ALI; SENAN, 2018).

$$\Delta w_{i,j}^c = -\eta \frac{\partial E}{\partial w_{i,j}^c} \quad (4.11)$$

$$\Delta b_i^c = -\eta \frac{\partial E}{\partial b_i^c} \quad (4.12)$$

em que η é o parâmetro de taxa de aprendizado. Este parâmetro está relacionado com o tempo de convergência do algoritmo. Se η for muito pequeno, a descida de gradiente também irá progredir lentamente. Se for muito grande, a descida em gradiente ultrapassará os mínimos e possivelmente não convirja. Não há um método sistemático para obtenção do η . No capítulo 5 discutimos sobre alguns valores abordados na literatura.

4.5 Comunicação e interação

A implementação da comunicação em um sistema multiagente é crucial para garantir seu bom desempenho. Um agente especial chamado de moderador é responsável pela a comunicação e tomada de decisão entre os agentes da *BN* e da *DNN*, evitando a implementação de um módulo de mediação em cada um deles. Existem várias abordagens para a implementação dessa comunicação. Uma bastante conhecida é a linguagem de consulta e manipulação de conhecimento / *knowledge query and manipulation language* (KQML). Essa linguagem foi desenvolvida no início de 1990 sendo parte do projeto *American Knowledge Sharing Efforts* (CASTAÑO, 2018). KQML define um formato comum para mensagens, que no contexto de

programação orientada a objetos (POO), pode ser entendida como um objeto (WOOLDRIDGE, 2009). Cada mensagem possui uma estrutura (que pode ser pensada como a classe da mensagem) e um conjunto de parâmetros de performativos representando variáveis de instância. O algoritmo 13, apresenta a estrutura básica de uma mensagem em KQML.

Algoritmo 13: Estrutura básica de uma mensagem KQML. (PAN-DEY, 2008)

```

1: (KQML - performative
2:   :Sender <Agent 1>
3:   :Receiver <Agent 2>
4:   :language <C>
5:   :Ontology <Estimativa de posicionamento>
6:   :content <(2.5,0.75,12)>
7:   ...
8: )

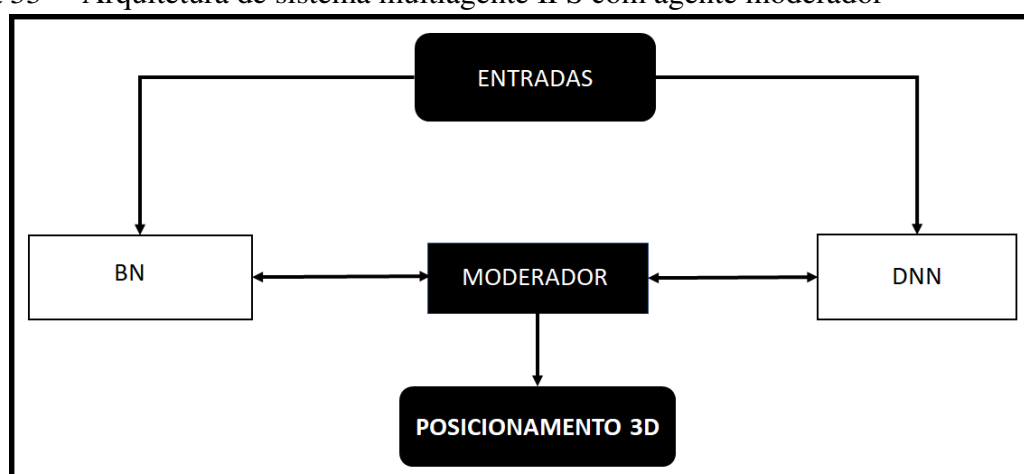
```

Observação. Uma ontologia representa uma descrição explícita de um domínio (conceitos, propriedades, restrições e assim por diante) (CASTAÑO, 2018).

Outras abordagens aplicadas à comunicação entre agentes são discutidas em Jones (2008), Leondes (2002), Hadzic *et al.* (2009), Castaño (2018) e Wooldridge (2009).

A figura 33, estende o conceito de MAS ilustrado na figura 31.

Figura 33 – Arquitetura de sistema multiagente IPS com agente moderador



Fonte: o autor.

A interação dos agentes BN e DNN, foi implementada a partir de um algoritmo chamado de *algoritmo de estimativa de ação / action estimation algorithm (ACE)* proposto por Weib (1993), que consiste em variação do algoritmo de atribuição de crédito *bucket brigade* proposto por Holland (1985). No algoritmo ACE, inicialmente cada agente \mathcal{AG}_i , para $i = 1, 2, \dots, N$, ao observar e_i , para $i = 1, 2, \dots, N$, determina um conjunto de possíveis ações (possíveis retornos de posicionamento) que podem ser executadas, denotada por a_i^j , em que $a_i^j \subseteq \mathcal{A}$. Para cada a_i^j , os agentes executam um lance (*bid*) conforme a equação 4.13.

$$B_i^j(E) = \begin{cases} (\alpha + \beta)R_i^j & : R_i^j \geq \theta_e \\ 0 & : \text{Caso contrário} \end{cases} \quad (4.13)$$

em que R_i^j é um parâmetro de relevância associado à cada a_i^j , α representa uma constante chamada de fator de risco para uma ação executada pelos agentes. Representa uma fração de R_i^j que os agentes estão dispostos arriscar para executarem suas ações. β é chamado de termo de ruído escolhido, cuja o objetivo é evitar que o aprendizado de um agente convirja para um mínimo local. No próximo capítulo é discutido uma regra para obtenção desse termo. θ_e é uma constante chamada de *estimate minimum*. Finalizado esse processo, os valores de $B_i^j(E)$ são compartilhados com os demais agentes e as ações a_i^j são armazenadas em um conjunto denotado por $CP(E)$, em que $CP(E) = \bigcup_{i=1}^N \mathcal{A}$. Em seguida os agentes selecionam as ações que resultaram em maiores valores para equação 4.13 e armazenam tais ações em um novo conjunto chamado de contexto de atividades, denotado por $C(E)$, que representa o conjunto das ações que serão executadas. Este procedimento é formalmente descrito nos seguintes passos (DOWELL; STEPHENS, 1994):

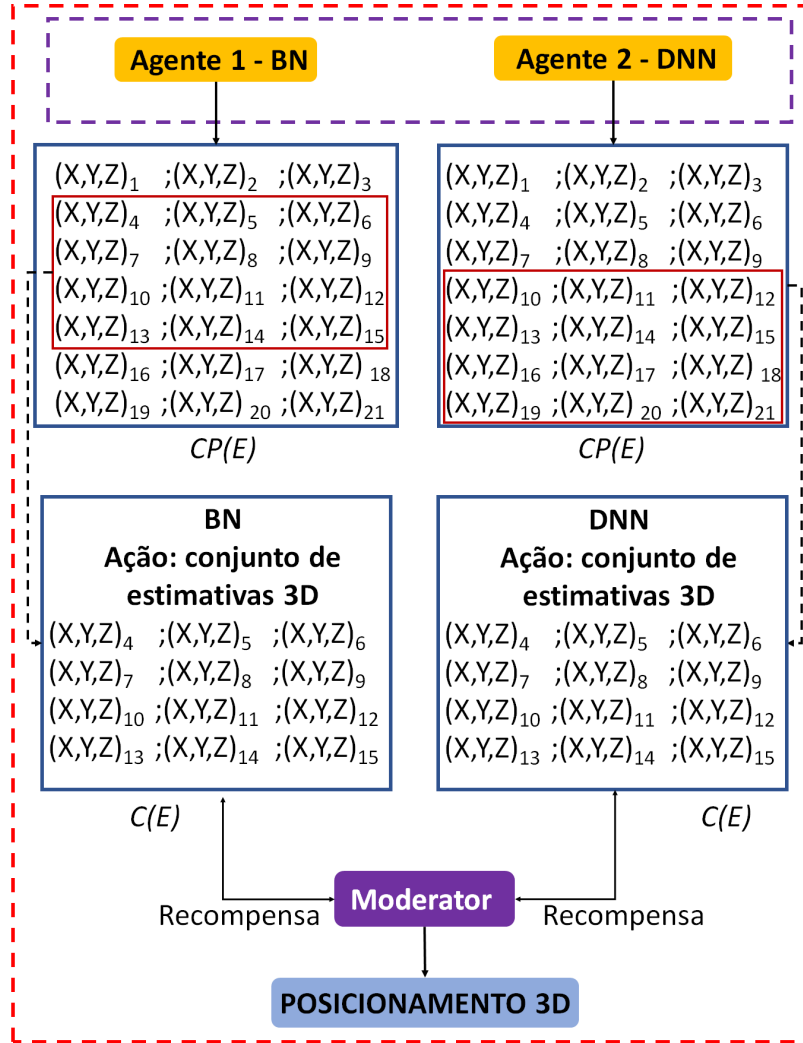
- $CP(E) = \bigcup_{i=1}^N \mathcal{A}$ e $C(E) = \emptyset$;
- Até que $CP(E) = \emptyset$ faça
 - selecione $a_i^j \in CP(E)$, em que $B_i^j(E) \geq B_k^l(E) \forall a_k^l \in CP(E)$;
 - $C(E) = C(E) \cup a_i^j$;
 - $CP(E) = CP(E) - \left(\left\{ a_i^j \right\} \cup \left\{ a_k^l \in CP(E) : a_k^l; a_i^j \text{ são incompatíveis} \right\} \right)$

A etapa final desse algoritmo permite que cada agente possa aprender ajustando suas estimativas R_i^j para cada ação selecionada a_i^j em $C(E)$. Formalmente, este procedimento é definido conforme a equação 4.14.

$$R_i^j = R_i^j - B_i^j(E) + \frac{R_e}{|C(E)|} + \frac{\sum_{a_i \in C} B_i^j(E)}{|C(E)|} \quad (4.14)$$

em que R_e representa uma recompensa fornecida por um agente moderador. Essa recompensa será fornecida em função do quão distante os pontos de posicionamento estão do centroide dessas estimativas. Isso significa que quanto mais homogêneo $C(E)$, maior a recompensa. O objetivo é que os agentes possam iterativamente reduzir os *outliers*. O critério de R_e relacionado a dispersão, é discutido no próximo capítulo. A figura 34 resume a arquitetura geral do algoritmo ACE.

Figura 34 – Arquitetura IPS-MAS baseado no algoritmo ACE

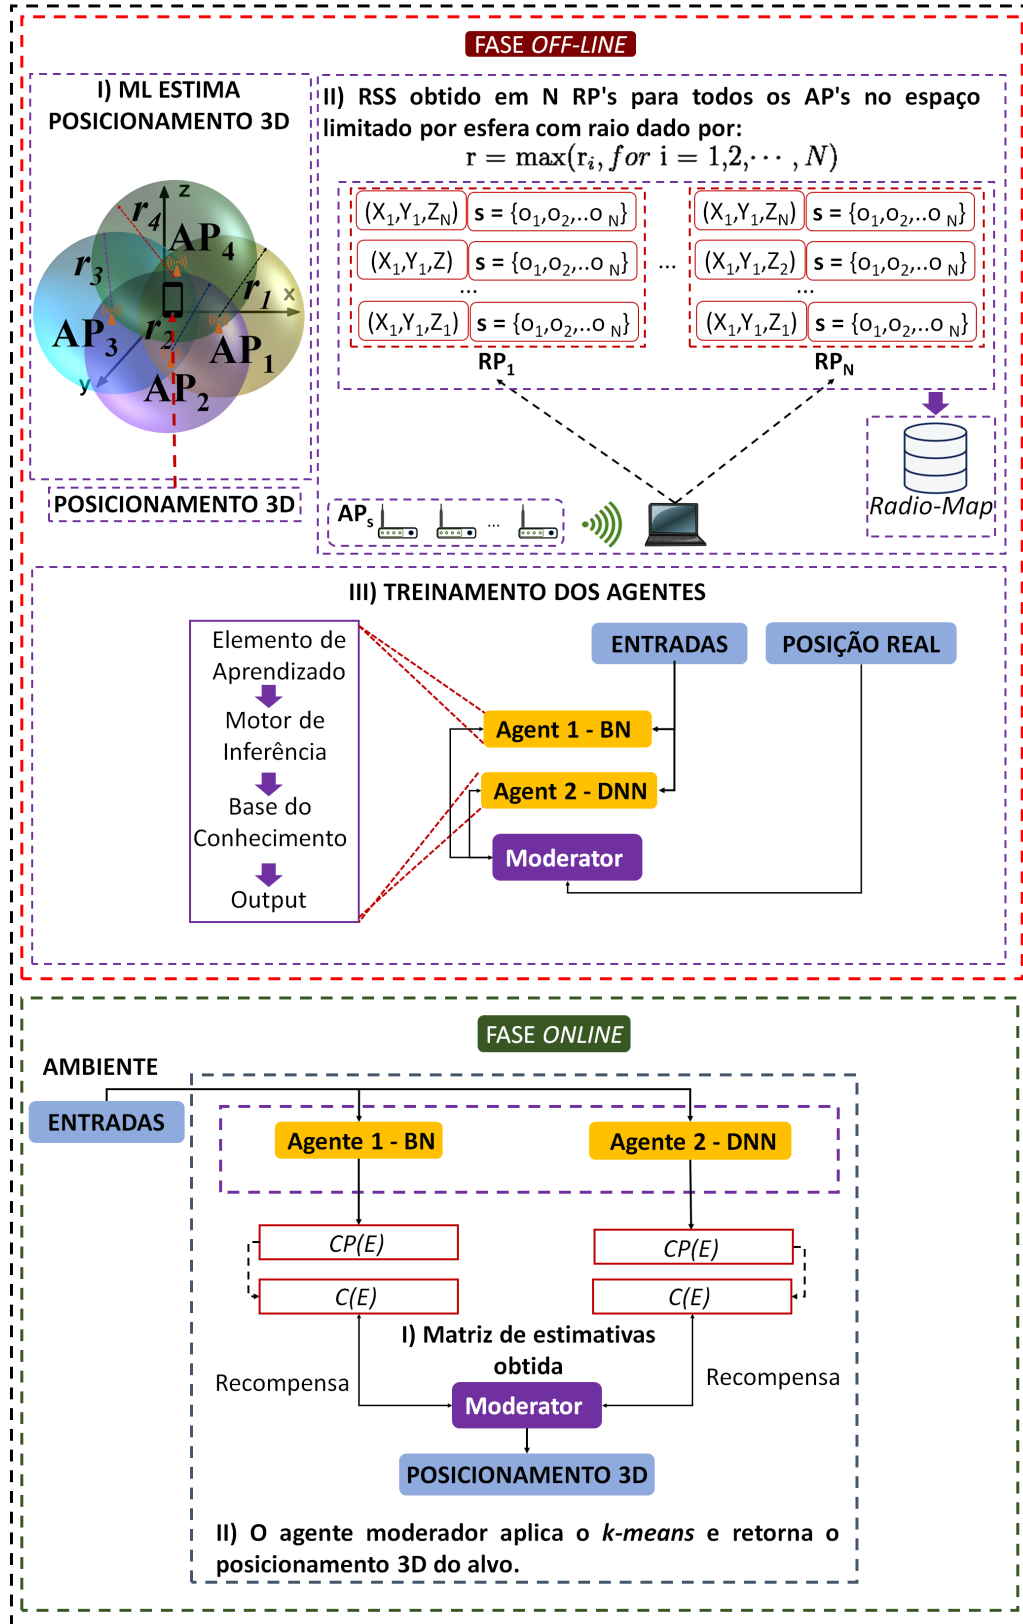


Fonte: o autor.

Após N iterações, as estimativas de $C(E)$ para os agentes BN e DNN, são armazenadas uma matriz de estimativa denotada por $\hat{\mathbf{E}} := (\mathbf{o}_{i,j})$, para $1 \leq i \leq N$ e $1 \leq j \leq M$, então o agente moderador verificará a ocorrência de *outliers* e os eliminará caso necessário. Às estimativas restantes, é aplicado o algoritmo k -means de forma particionar a matriz $\hat{\mathbf{E}}$. Finalizado esse processo, o agente moderador seleciona \mathcal{P} que possui o maior número de pontos estimados e

define o posicionamento 3D final do alvo a partir da coordenada do centroide dessa partição. O IPS proposto é resumido na figura 35 e no algoritmo 14.

Figura 35 – Arquitetura geral - IPS-MAS



Fonte: o autor.

Algoritmo 14: IPS-MAS para posicionamento 3D baseado na tecnologia

 IEEE 802.11 *indoor*

Input: Um vetor de sinal $\mathbf{s} = \{o_1, o_2, \dots, o_N\}$.

Output: Posicionamento 3D baseado no centroide das estimativas.

- 1: **for** $i=1$ **to** N **do**
 - 2: Recebe as coordenadas (x, y, z) dos APs.
 - 3: **for** $i=1$ **to** N **do**
 - 4: Recebe um vetor de sinal $\mathbf{s} = \{o_1, o_2, \dots, o_N\}$.
 - 5: **end for**
 - 6: Estima a distância ao alvo r_i^2 com $i = 1, 2, \dots, N \geq 4$ usando algum modelo de propagação.
 - 6: **end for**
 - 7: Centrado em cada um dos APs, implemente uma esfera com raio r .
 - 8: Estimar uma posicionamento 3D a partir da interseção das esferas.
 - 9: Implemente uma esfera de raio r em torno do ponto 3D estimado, em que $r = \max(r_i, \text{para } i = 1, 2, \dots, N)$.
 - 10: **for** $i=1$ **to** N **do**
 - 11: Leia \mathbf{s} em N RPs a partir da região definida no passo 9, conforme discutido no capítulo 3, equação 3.1.
 - 12: **end for**
 - 13: Implemente três funções que representam os agentes moderador, BN e DNN, em que cada um desses agentes possui uma base de conhecimento, um motor de inferência e um elemento de aprendizado.
 - 14: Aplique o algoritmo ACE, conforme discutido em Weib (1993).
 - 15: **while** $i \leq \text{maxIter}$ **do**
 - 16: BN e DNN recebem um conjunto de parâmetros chamado vetor ou matriz de percepção e retorna $\hat{\mathbf{E}}_1$ e $\hat{\mathbf{E}}_2$.
 - 17: **end while**
 - 18: O agente moderador aplica o algoritmo *k-means* de forma a particionar $\hat{\mathbf{E}}_1$ e $\hat{\mathbf{E}}_2$, e alocar o alvo na partição \mathcal{P} que possui maior quantidade de pontos estimados.
 - 19: Retorne o posicionamento 3D com base no centroide de \mathcal{P}
-

4.6 Conclusão

Neste capítulo, foi proposto um **IPS** baseado no desenvolvimento de um MAS que foi implementado a partir de uma combinação dos métodos ML e impressão digital. O sistema proposto considera a relação entre o RSS e o NL, que é influenciado pelo aumento do número de APs e do número de pessoas que se deslocam pelo ambiente. No próximo capítulo, apresentaremos os resultados experimentais, comparando os três algoritmos propostos com os métodos mais abordados na literatura.

5 RESULTADOS EXPERIMENTAIS

Este capítulo tem como objetivo resumir os resultados relacionados aos desempenhos dos algoritmos propostos em um cenário real. Esses algoritmos foram comparados com outras sete abordagens amplamente utilizado na literatura (LIU *et al.*, 2007). De forma a realizar tais comparações, várias métricas foram utilizadas, tais como: média, coeficiente de variação, medidas separatrizes e função de distribuição acumulada. Além disso, esses experimentos foram aplicados a fim de mensurar a influência da combinação entre os métodos ML e impressão digital na precisão dos algoritmos.

Os experimentos foram conduzidos no primeiro, segundo e terceiro pisos do bloco acadêmico 707, localizado no Centro de Tecnologia da Universidade Federal do Ceará, em Fortaleza, com área total de 3791,05m². Os seguintes setores foram selecionados:

- Térreo: toda região (espaço de convivência);
- Primeiro andar: *Hall*, corredor, sala de aula 11 e 12;
- Segundo andar: *Hall* e corredor.

As figuras 37 e 38, ilustram respectivamente o bloco e planta baixa referentes ao primeiro andar. Os vetores *s* foram obtidos em 180 RPs distribuídos nos três andares utilizados. Para cada RP, 25 amostras RSS foram coletadas em quatro direções e em três alturas diferentes com relação a quatro APs selecionados, resultando em 300 valores RSS para cada RP. A tabela 7 apresenta alguns valores adotados na literatura.

Tabela 7 – Alguns valores de RPs e amostras *s* utilizados na literatura

Referência	Algoritmo	Precisão Reportada	Parâmetros
<i>Cosine similarity</i> (HAN <i>et al.</i> , 2015)	WkNN	61,2% das estimativas dentro de 2,0m.	213 RPs (100 amostras - RP)
RADAR (BAHL; PADMANABHAN, 2000)	kNN	50% das estimativas dentro de 2,75m	70 RPs (>20 amostras- RP)
GS (KHALAJMEHRABADI <i>et al.</i> , 2017)	<i>GS sparse recovery</i>	50% das estimativas dentro de 1.24 m	192 RPs (>100 amostras - RP)
FS-kNN (LI <i>et al.</i> , 2016)	kNN	80% das estimativas dentro de 2,5m	133 RPs (>50 amostras - RP)
MDKDE (HUANG; MANH, 2016)	Multidimensional <i>kernel</i>	90% das estimativas dentro de 1,5m	370 RPs (>30 amostras - RP)

Fonte: o autor.

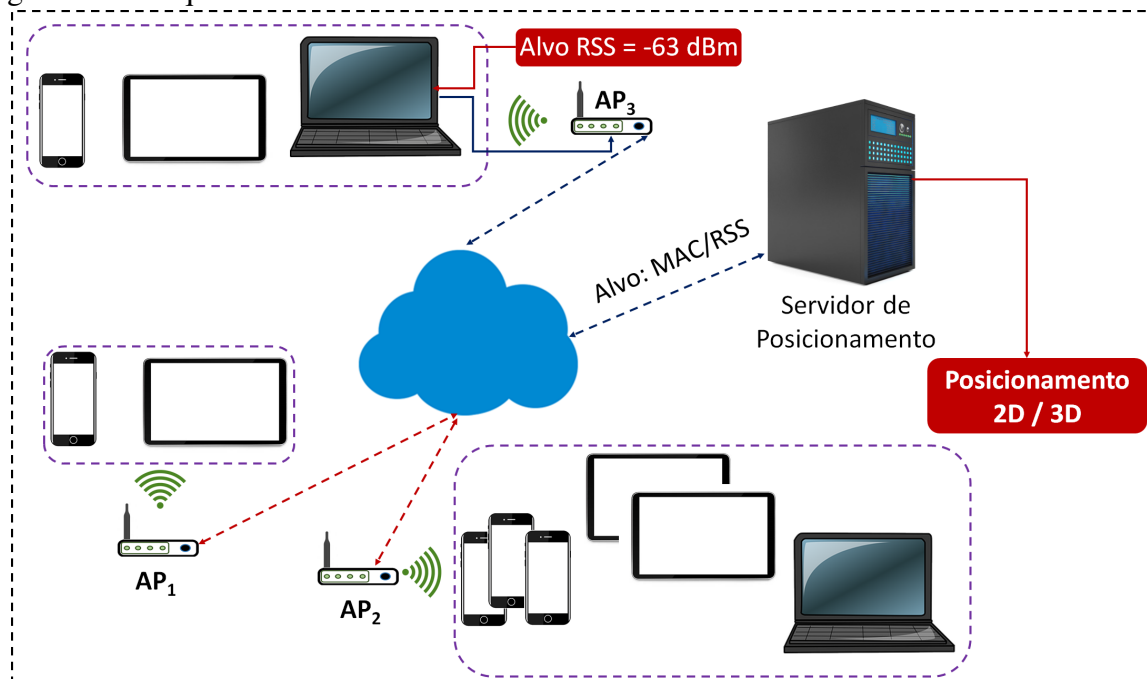
Para aquisição de s foi desenvolvido um *software* em C++ para o sistema operacional *Windows*, utilizando a interface de programação de aplicação / *application programming interface* (API) *Native WiFi da Microsoft*. O *software* realiza leituras passivas em modo monitor à procura dos APs com identificador do conjunto de serviço / *service set identification* (SSID) registrados, e então aquisições RSS são feitas para cada AP e os valores coletados são salvos em um arquivo de texto e lidos pela linguagem R, na qual foram implementados todos os algoritmos. A tabela 8, apresenta algumas bibliotecas utilizadas nos experimentos e simulações, enquanto que a figura 36, apresenta a arquitetura básica de posicionamento.

Tabela 8 – Alguns Packages utilizados nas implementações em R.

package	Versão
neuralnet	1.33
triangulation	0.5.0
knnDE	1.6.2
kde	1.10.7
Stats	3.6.0
mxnet	1.3.0
bnclassify	0.4.0
bnlearn	4.4-20180620

Fonte: o autor.

Figura 36 – Arquitetura básica - IPS baseado em Wi-Fi




Fonte: o autor.

Figura 37 – Bloco acadêmico 707 - Centro de tecnologia da Universidade federal do Ceará




Figura 38 – Planta do primeiro andar do bloco 707 utilizado nos experimentos



Fonte: Superintendencia de Infraestrutura e Meio Ambiente da UFC.

As máquinas utilizadas nos experimentos possuem a seguinte configuração: *Dell, Intel Core i5, 1.8 GHZ, 6 GB RAM, Adapter Dell Wireless 1703 802.11b/g/n* (para aquisição de dados) e *AMD FX-8120 desktop 8GB RAM* (implementação dos algoritmos). Após a etapa de aquisição do sinal, foi realizado um experimento com o objetivo de verificar a variação do sinal no ambiente. Em um ponto fixo (15,2; 0,7 e 7.72 m), durante 300 s foi verificada a intensidade do sinal com relação aos quatro APs utilizados nos experimentos. Os resultados são ilustrados na figura 39. Note que mesmo em uma posição fixa, as flutuações do sinal atingem 10 dB, o que representa uma variabilidade esperada para um ambiente indoor.

Figura 39 – Variações da intensidade do sinal em ponto fixo para os quatro APs



Fonte: o autor.

Com relação aos parâmetros dos algoritmos, para o algoritmo *kmeans* – *NB*, testou-se diferentes valores de \mathcal{P} . O melhor resultado foi obtido quando $\mathcal{P} = 50$. Para estimativa do termo $P(s|\mathcal{P})$, aplicou-se o método *kernel*. Com relação ao algoritmo *kNN*-Bayes, como discutido na seção 3.3, o valor de k é obtido a partir da \sqrt{N} , o que resulta em ≈ 232 . O algoritmo IPS-MAS foi implementado com uma ANN com quatro camadas ocultas. Números diferentes de neurônios foram testados para as camadas ocultas. O melhor resultado observado foi de 350 neurônios. Para essa rede neural, o algoritmo de *backpropagation* foi utilizado como método de aprendizagem. Existem diferentes regras na literatura para escolher a taxa de aprendizagem η para implementação desse algoritmo. Schulz *et al.* (2013) sugere $0,001 \leq \eta \leq 0,1$, enquanto

Kriesel (2007) sugere $0 \leq \eta \leq 1$. Nesse sentido, foram testados diferentes valores de η através do coeficiente de correlação (CC) entre a posição real do alvo e a posição estimada, conforme sugerido por Schulz *et al.* (2013). A tabela 9 apresenta os resultados obtidos:

Tabela 9 – Relação entre diferentes valores para os parâmetros de η e o CC

DNN	η	CC
DNN 1	0,01	0,82
DNN 2	0,02	0,817
DNN 3	0,03	0,813
DNN 4	0,04	0,834
DNN 5	0,05	0,794
DNN 6	0,1	0,72
DNN 7	0,2	0,734
DNN 8	0,3	0,709
DNN 9	0,4	0,705
DNN 9	0,5	0,698

Fonte: o autor.

Como discutido no capítulo 4, valores muito altos de η podem implicar em não convergência do algoritmo. Esse fenômeno pode ser observado tabela 10, em que maiores valores de η tentem a resultar em CC menor. Uma exceção porém, são $\eta = 0,04$ e $\eta = 0,2$. Nesse sentido, escolhemos $\eta = 0,04$ que resulta em maior CC. Para a BN, aplicamos um TAN com vértices representados por s , nível de ruído e informações recebidas pelo moderador. Além disso, usamos a suavização a priori de Dirichlet conforme discutido em Friedman *et al.* (1997). O algoritmo ACE, foi implementado segundo discutido em Weib (1993), com $\alpha = 0,1$, $\beta \in \left[-\frac{\alpha}{5}, \frac{\alpha}{5}\right]$ e $\theta = R_e$. A tabela 10 (dispersão classificada segundo Rangarajan *et al.* (1992)), apresenta os valores relacionados às recompensas fornecidas aos agentes em função do C_v .

Tabela 10 – Valores referentes a recompensas em função do C_v

C_v	Dispersão	Recompensa
$C_v \leq 10\%$	Baixa	+10
$10\% < C_v \leq 20\%$	Média	+5
$20\% < C_v \leq 30\%$	Alta	-5
$C_v > 30\%$	Muito Alta	-10

Como algoritmos para comparação, as principais soluções abordadas na literatura foram escolhidas. Em Bahl e Padmanabhan (2000), foi provado que o melhor desempenho para o algoritmo kNN é alcançado para $k \in (2,4)$. assim, utilizamos valores de $k = 2$ e 3 com a distância euclidiana. O teorema de Bayes definido na equação 2.45, foi aplicado utilizando os

métodos *kernel* e histograma como abordagens para estimativa da verossimilhança conforme discutido na seção 3.2 e sugerido por Roos *et al.* (2002). As redes neurais MLP e função de base Radial / *radial basis function* (RBF), também foram aplicadas ao problema de forma individual. Para a MLP, o melhor resultado foi alcançado a partir de 290 e 170 neurônios para a primeira e segunda camadas ocultas, respectivamente. Para RBF, esse valor foi de 400 neurônios.

Com relação ao desempenho dos algoritmos, o algoritmo IPS-MAS, apresentou melhores resultados que os demais. Este algoritmo teve como retorno um erro médio (ε_m) inferior a 0,9 m com uma precisão (\mathcal{P}_r) de 97,7% e 100% das estimativas dentro de 1,5 m e 2,0 m, respectivamente. Este resultado representa uma diferença no valor de ε_m de mais de 22 cm em relação ao algoritmo mais similar, e mais de 1,55 m em relação ao método ML. O melhor resultado desse algoritmo está relacionado a dois fatores importantes, a implementação de agentes inteligentes funcionado de forma integrada e colaborativa e da combinação dos métodos ML e impressão digital. Este último fator foi observado por Liu *et al.* (2007), que discute sobre a precisão em função da hibridização de algoritmos.

Uma comparação entre todos os algoritmos baseados em impressão digital, incluindo o erro absoluto ε_a , ε_m , C_v , o primeiro, segundo e terceiro quartis (Q1, Q2 e Q3) e \mathcal{P}_r é apresentada na figura 40 e nas tabelas 11 e 12.

Figura 40 – CDF do erro de posicionamento com 4 APs




Tabela 11 – Intervalos de classe para as estimativas de posicionamento

Algoritmo	\mathcal{P}_r (%) $\leq 1,5m$	\mathcal{P}_r (%) $\leq 3,5m$	\mathcal{P}_r (%) $\leq 5,5m$	\mathcal{P}_r (%) $\leq 7,5m$
ML	68,2	80,1	87,8	95,1
kNN $k = 2$	75,8	88	94,8	98,9
kNN $k = 3$	76,1	88,7	95,3	99,1
ANN MLP	76,2	89	95,8	99,3
ANN RBF	76,65	89,6	96,5	99,4
Histograma	76,9	90,8	98	100
<i>Kernel</i>	77,2	91,2	98,6	100
kNN -Bayes	74,4	92	98,7	100
$kmeans$ -NB	77,9	93,1	98,9	100
IPS-MAS	97,7	100	100	100

Tabela 12 – Estatísticas das estimativas de posicionamento (Média, coeficiente de variação, Q1, Q2, e Q3 em metros)

Algoritmo	ϵ_m	C_v	Q1	Q2	Q3
ML	2,235	59,70%	1,36	1,73	2,57
$kNN = 2$	1,919	45,22%	1,33	1,66	1,93
$kNN = 3$	1,916	44,16%	1,33	1,66	1,91
ANN (MLP)	1,905	43,15%	1,33	1,66	1,90
ANN (RBF)	1,883	41,89%	1,33	1,65	1,88
Histograma	1,843	37,97%	1,32	1,65	1,86
Kernel	1,832	36,80%	1,32	1,65	1,84
kNN -Bayes	1,819	36,19%	1,32	1,64	1,83
$kmeans$ -NB	1,803	35,06%	1,32	1,64	1,81
IPS-MAS	0,90	38,70%	0,64	0,84	1,19

O algoritmo $kmeans - NB$, resultou em \mathcal{P}_r de 77,9%, 93,1%, 98,9% para os intervalos 1,5; 3,5; 4,5 m e ϵ_m igual a 1,80 m. Esses resultados foram superiores ao algoritmo kNN -Bayes, que apresentou precisões de 77,4%, 92%, 98,7% para os mesmos intervalos e ϵ_m igual a 1,82 m.

Os sistemas implementados a partir do kNN e ANN obtiveram desempenhos próximos, com uma diferença do ϵ_m de $\approx 0,04$ m entre o algoritmo com melhor desempenho (ANN com RBF) e pior desempenho (kNN com $k = 2$).

Os algoritmos probabilísticos (histograma e *kernel*, implementados diretamente através da equação 2.45) apresentaram $\epsilon_m = 1,84$ e 1,832 m, respectivamente. As figuras 41

e 42, ilustram, respectivamente, uma comparação entre os algoritmos IPS-MAS e k means-NB em relação à distribuição de probabilidade do erro para 16 estimativas em comparação ao posicionamento real.

Figura 41 – Histograma da distribuição de probabilidade do erro para 16 estimativas para os algoritmos IPS-MAS e k means-BN.





Figura 42 – Comparação dos algoritmos IPS-MAS e k means-NB para 16 estimativas




O algoritmo IPS-MAS também foi testado com o usuário em movimento (posicionamento por trajetória). O experimento foi repetido 10 vezes nos períodos da manhã, tarde e noite. Os resultados indicam que houve um pequeno decremento na precisão desse algoritmo em função do deslocamento do usuário. Os resultados desse experimento estão apresentados na tabela 13 e na figura 43.

Tabela 13 – Estatísticas das estimativas de posicionamento para o usuário em movimento (Média, coeficiente de variação, Q1, Q2 e Q3 quartis em metros)

Distância	0,64 $\approx 30m$
Repetições	30
Total de observações RSS coletados	157
Velocidade	0,65m/s
Coordenadas de Origem	(0; 1,0; 3,20 m)
Coordenadas de destino	(10; 1,0; 6,40 m)
ε_m	0,93
C_v	40,34%
Q1	0,64
Q2	0,88
Q3	1,23

Figura 43 – (a) Trajeto real, (b) trajeto estimado com IPS-MAS



O método ML, amplamente utilizado no contexto de posicionamento *outdoor*, apresentou piores resultados comparado com outros algoritmos. Como discutido, isso ocorre devido à alta variabilidade do sinal, característica de ambientes fechados. Com o objetivo de verificar se o incremento de APs está relacionado a uma melhor precisão para este método, uma simulação utilizando o modelo de propagação MWM definido na equação 2.27, foi implementada de

forma a obter a precisão para 7, 9, 11, 12, 15, 17, 19, 21 e 23 APs. Os resultados da simulação indicam que à medida que o número de APs aumenta, há uma melhora na precisão do sistema considerando apenas o NL, que resulta do movimento de pessoas em torno do ambiente. A figura 44 ilustra o incremento da precisão em função do número de APs para o intervalo $0 - 4m$, enquanto que a figura 45 ilustra esse mesmo comportamento para o intervalo $0 - 2m$.

Figura 44 – CDF do erro de posicionamento para o método ML com 7, 9, 11, 12, 15, 17, 19, 21 e 23 APs simulados a partir do modelo de propagação cost 231 MWM



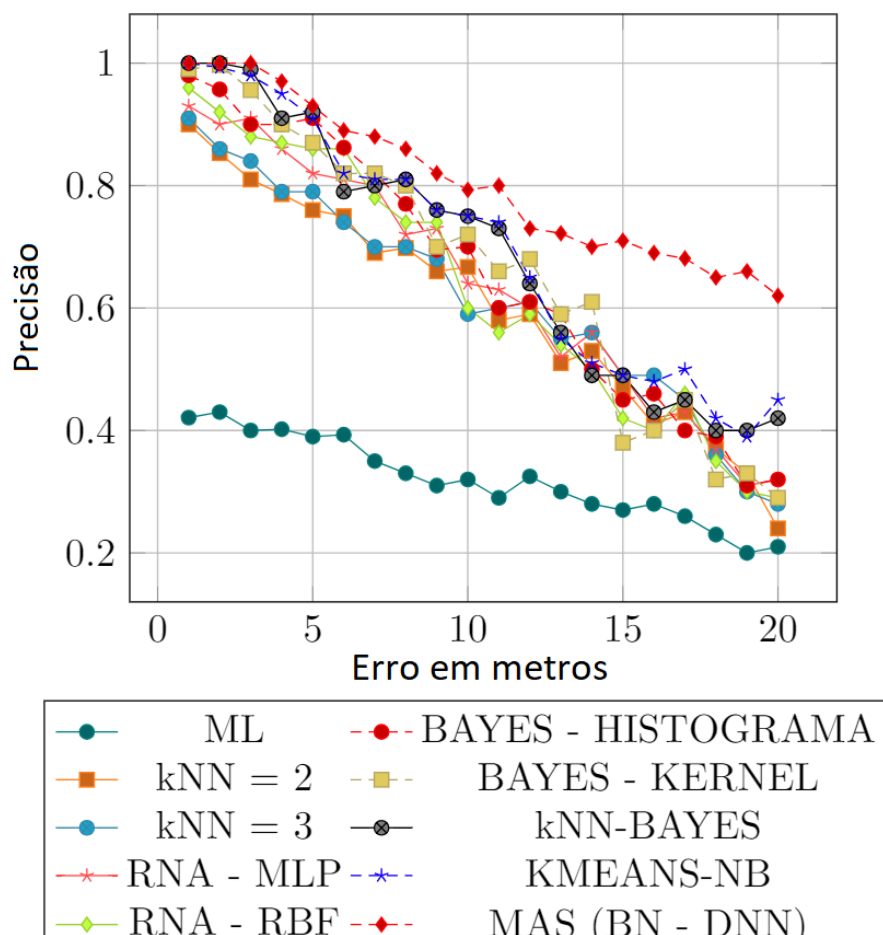


Figura 45 – Precisão em função do número de APs para um erro fixado em $1,5m$ do posicionamento real para o método ML simulado a partir do modelo de propagação cost 231 MWM



Quando consideramos também o NL causado pelo aumento do número de APs, a precisão de todos os algoritmos tende a piorar. Nesse cenário, o algoritmo IPS-MAS também apresentou melhor desempenho. Isso pode ser explicado pelo fato desse algoritmo ter sido projetado para considerar os efeitos NL sobre as estimativas. O resultado dessa simulação é mostrado na figura 46.

Figura 46 – Relação entre precisão e NL



De forma a mensurar o efeito da combinação da ML e impressão digital sobre o IPS (com exceção é claro do método ML), todos os algoritmos foram implementados considerando essa combinação. Os resultados indicam que houve um melhora significativa na precisão desses algoritmos. Para o Algoritmo *kmeans-NB*, por exemplo, esse incremento na precisão foi superior a 68 *cm*. A tabela 14 e as figuras 47 e 48, resumem as principais estatísticas relacionadas ao posicionamento.

Tabela 14 – Estatísticas das estimativas de posicionamento (Média, coeficiente de variação, Q1, Q2, e Q3 em metros) - Combinação ML e impressão digital

Algoritmo	ε_m	C_v	Q1	Q2	Q3
ML	2,45	55,78%	1,42	2,36	3,36
$kNN = 2$	1,41	46,22%	0,92	1,42	1,86
$kNN = 3$	1,35	45,85%	0,89	1,34	1,79
ANN (MLP)	1,28	44,88%	0,86	1,28	1,71
ANN (RBF)	1,26	45,33%	0,83	1,26	1,68
Histograma	1,23	44,55%	0,81	1,23	1,64
<i>kernel</i>	1,19	45,68%	0,77	1,19	1,59
kNN -Bayes	1,15	45,27%	0,7561	1,15	1,49
$kmeans$ -NB	1,12	44,43%	0,74	1,13	1,45
IP-MAS	0,90	38,70%	0,64	0,84	1,19

Figura 47 – CDF do erro de posicionamento considerando a combinação entre os métodos ML e impressão digital





Figura 48 – Comparação da distribuição de probabilidade do erro para 16 estimativas para os algoritmos IPS-MAS e *kmeans*-BN considerando a combinação entre os métodos ML e impressão digital



Nesse capítulo apresentou-se os principais resultados relacionados aos algoritmos propostos. Adicionalmente, uma comparação entre esses algoritmos e as principais abordagens baseadas em impressão digital foi apresentada. Os experimentos foram realizados no bloco didático 707 no centro de tecnologia da Universidade Federal do Ceará. Por se tratar de um espaço bastante movimentado, torna-se ideal para o teste dos algoritmos propostos. Os experimentos e simulações realizadas podem ser resumidos em da seguinte forma:

- Inicialmente todos os algoritmos foram comparados (com apenas o algoritmo IPS-MAS utilizando a combinação do método de multilateração ML e impressão digital);
- Em um segundo cenário, testou-se todos os algoritmos baseados em impressão digital, combinando este método com ML. O objetivo é verificar o efeito dessa combinação na precisão dos algoritmos;
- Uma simulação computacional foi implementada a fim de verificar os efeitos do incremento de pontos de acesso (APs) e do número de pessoas se movimentando pelo ambiente com relação à precisão dos algoritmos.

Verificou-se que uma combinação entre o método de impressão digital e o método clássico de posicionamento ML pode incrementar significativamente a precisão de um sistema de posicionamento *indoor*. Tomando o algoritmo *kmeans*-NB como exemplo, o erro médio ϵ_m

foi reduzido em mais 68 *cm*. Um outro fator relevante consiste no incremento da precisão do método ML, quando se aumenta o número de APs. Porém esse método se mostrou mais afetado pelo ruído causado pelo incremento de pessoas no ambiente. Por fim, o algoritmo proposto baseado no conceito de sistemas multiagentes, apresentou os melhores resultados em todos os cenários. Este melhor desempenho não está somente relacionado à combinação dos métodos ML e impressão digital. A integração entre os agentes baseados em redes neurais e Bayesianas tiveram grande contribuição nesse sentido.

6 CONCLUSÕES E TRABALHOS FUTUROS

Nessa pesquisa, as principais abordagens e desafios relacionados ao posicionamento *indoor* foram discutidos. Além disso, três soluções baseadas em inferência Bayesiana para posicionamento tridimensional foram propostas e comparadas com os principais algoritmos abordados na literatura, inclusive com método de multilateração, um dos mais utilizados no contexto outdoor.

Os experimentos foram conduzidos no primeiro, segundo e terceiro pisos do bloco acadêmico 707, localizado no Centro de Tecnologia da Universidade Federal do Ceará, em Fortaleza, com área total de $3791,05 \text{ m}^2$. O primeiro algoritmo proposto, consiste na combinação dos algoritmos *k*-means e *naive* Bayes, enquanto que o segundo tem como base o *k*-nearest neighbors e o teorema de Bayes. O terceiro algoritmo foi desenvolvido a partir de um sistema multiagente composto de uma rede Bayesiana e uma rede neural profunda. Com o objetivo de maximizar a precisão do sistema, esse algoritmo considerou além dos vetores RSS, outras variáveis como parâmetros de entrada, incluindo o nível de ruído provocado pelo aumento do número de pontos de acesso e pelo número de pessoas em movimento dentro do ambiente. Outro fator que contribuiu para o bom desempenho do sistema foi a redução da região de aplicação do método de impressão digital, através de uma combinação com o método de multilateração.

Os algoritmos propostos apresentaram melhor desempenho quando comparados com os demais, resultando $\epsilon_m = 0,90 \text{ m}$, $1,80 \text{ m}$, $1,82 \text{ m}$ para os algoritmos IPS-MAS, *k*means-NB e *k*NN-Bayes, respectivamente (cenário em que a combinação entre o método de multilateração e impressão digital foi considerada somente para o algoritmo IPS-MAS) e $\epsilon_m = 0,90 \text{ m}$, $1,12 \text{ m}$, $1,19 \text{ m}$, para os algoritmos IPS-MAS, *k*means-NB e *k*NN-Bayes, respectivamente (cenário em que a combinação entre o método de multilateração e impressão digital foi considerada para os três algoritmos). Por serem baseadas em inferência Bayesiana, as soluções propostas são bastante eficientes quando integradas com a técnica de impressão digital, pois relacionam as informações atuais e passadas de forma eficiente, o que resulta em bons resultados em relação à classificação. Contudo, uma das limitações das técnicas em questão está relacionada com a qualidade das informações, isto é, uma base de dados robusta é necessária para que um IPS baseado nestes algoritmos apresentem bons resultados.

Como relação aos trabalhos futuros, pretende-se maximizar a precisão do sistema, de forma a obter um $\epsilon_m \leq 0.5 \text{ m}$. Para atingir tal objetivo, certamente será necessário o desenvolvimento de vários métodos e algoritmos híbridos. Trabalhos futuros incluem:

- O desenvolvimento de IPSs híbridos baseados em angulação, multilateração e impressão digital;
- O desenvolvimento de IPS's baseados em análise de discriminante múltipla;
- A automatização do processo de aquisição da impressão digital.

REFERÊNCIAS

- ALI, A.; SENAN, N. Violence video classification performance using deep neural networks. In: GHAZALI, R.; DERIS, M. M.; NAWI, N. M.; ABAWAJY, J. H. (Ed.). **Recent Advances on Soft Computing and Data Mining**. Cham: Springer International Publishing, 2018. p. 225–233. ISBN 978-3-319-72550-5.
- AU, A. W. S.; FENG, C.; VALAEE, S.; REYES, S.; SOROUR, S.; MARKOWITZ, S. N.; GOLD, D.; GORDON, K.; EIZENMAN, M. Indoor tracking and navigation using received signal strength and compressive sensing on a mobile device. **IEEE Transactions on Mobile Computing**, v. 12, n. 10, p. 2050–2062, Oct 2013. ISSN 1536-1233.
- BAHL, P.; PADMANABHAN, V. N. Radar: an in-building rf-based user location and tracking system. In: **Proceedings IEEE INFOCOM 2000. Conference on Computer Communications. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies (Cat. No.00CH37064)**. [S.l.: s.n.], 2000. v. 2, p. 775–784 vol.2. ISSN 0743-166X.
- BATTITI, R.; NHAT, T. L.; VILLANI, A. **Location-Aware Computing: A Neural Network Model For Determining Location In Wireless LANs**. [S.l.], 2002.
- BAYES, T. An essay towards solving a problem in the doctrine of chances. **Phil. Trans.**, **53**, **370–418**, 1763.
- BEAUREGARD, S.; HAAS, H. Pedestrian dead reckoning: A basis for personal positioning. In: **Proceedings of the 3rd Workshop on Positioning, Navigation and Communication**. [S.l.: s.n.], 2006. p. 27–35.
- BENGIO, Y. **Learning Deep Architectures for AI**. Now Publishers, 2009. (Essence of knowledge, The). ISBN 9781601982940. Disponível em: <<https://books.google.com.br/books?id=cq5ewg7FniMC>>.
- BOWDITCH, N.; IMAGERY, U. S. N.; AGENCY, M. Book; Book/Illustrated. **The American practical navigator : an epitome of navigation**. 2002 bicentennial ed. ed. Bethesda, MD : National Imagery and Mapping Agency ; Washington, DC : For sale by the Supt. of Docs., U.S. G.P.O., 2002. Originally published under title: The new American practical navigator. ISBN 0160511259. Disponível em: <<http://purl.access.gpo.gov/GPO/LPS22411>>.
- BOZKURT, S.; GÜNAL, S.; YAYAN, U.; BAYAR, V. Classifier selection for rf based indoor positioning. In: **2015 23rd Signal Processing and Communications Applications Conference (SIU)**. [S.l.: s.n.], 2015. p. 791–794. ISSN 2165-0608.
- CASTAÑO, A. **Practical Artificial Intelligence: Machine Learning, Bots, and Agent Solutions Using C#**. [S.l.]: Apress, 2018. ISBN 9781484233573.
- CASTRO, P.; CHIU, P.; KREMENEK, T.; MUNTZ, R. R. A probabilistic room location service for wireless networked environments. In: **Proceedings of the 3rd International Conference on Ubiquitous Computing**. Berlin, Heidelberg: Springer-Verlag, 2001. (UbiComp '01), p. 18–34. ISBN 3-540-42614-0. Disponível em: <<http://dl.acm.org/citation.cfm?id=647987.741335>>.
- CHOW, C.; LIU, C. Approximating discrete probability distributions with dependence trees. **IEEE Transactions on Information Theory**, v. 14, n. 3, p. 462–467, May 1968. ISSN 0018-9448.

CHRIST, T. W.; GODWIN, P. A.; LAVIGNE, R. E. A prison guard duress alarm location system. In: **1993 Proceedings of IEEE International Carnahan Conference on Security Technology**. [S.l.: s.n.], 1993. p. 106–116.

COTA-RUIZ, J.; ROSILES, J. G.; RIVAS-PEREA, P.; SIFUENTES, E. A distributed localization algorithm for wireless sensor networks based on the solutions of spatially-constrained local problems. **IEEE Sensors Journal**, v. 13, n. 6, p. 2181–2191, June 2013. ISSN 1530-437X.

COVER, T.; HART, P. Nearest neighbor pattern classification. **IEEE Trans. Inf. Theor.**, IEEE Press, Piscataway, NJ, USA, v. 13, n. 1, p. 21–27, set. 1967. ISSN 0018-9448. Disponível em: <<http://dx.doi.org/10.1109/TIT.1967.1053964>>.

DAMOSSO, E.; CORREIA, L. M. **COST Action 231 : digital mobile radio towards future generation systems : final report**. [S.l.]: European Commission, 1999. ISBN 92-828-5416-7.

DARDARI, D.; CLOSAS, P.; DJURIĆ, P. M. Indoor tracking: Theory, methods, and technologies. **IEEE Transactions on Vehicular Technology**, v. 64, n. 4, p. 1263–1278, April 2015. ISSN 0018-9545.

DOWELL, M. L.; STEPHENS, L. M. Mage: Additions to the age algorithm for learning in multi-agent systems. In: CITESEER. **Proceedings of the Second International Working Conference on Cooperating Knowledge Based Systems (CKBS94)**. [S.l.], 1994.

DUDA, R.; HART, P. **Pattern Classification and Scene Analysis**. Wiley, 1973. ISBN 9780471223610. Disponível em: <<https://books.google.com.br/books?id=POMGRAAAACAAJ>>.

ELNAHRAWY, E.; LI, X.; MARTIN, R. P. The limits of localization using signal strength: a comparative study. In: **2004 First Annual IEEE Communications Society Conference on Sensor and Ad Hoc Communications and Networks, 2004. IEEE SECON 2004**. [S.l.: s.n.], 2004. p. 406–414.

ETEKS. **Software Sweet Home 3D**. 2006. Disponível em: <<https://sourceforge.net/projects/sweethome3d/files/SweetHome3D/SweetHome3D-5.5/>>.

FANG, X.; NAN, L.; JIANG, Z.; CHEN, L. Noise-aware fingerprint localization algorithm for wireless sensor network based on adaptive fingerprint kalman filter. **Comput. Netw.**, Elsevier North-Holland, Inc., New York, NY, USA, v. 124, n. C, p. 97–107, set. 2017. ISSN 1389-1286. Disponível em: <<https://doi.org/10.1016/j.comnet.2017.06.016>>.

FELL, P. Satellite geodesy—foundations, methods, and applications. v. 75, p. 238–238, 01 1994.

FIX, E.; HODGES, J. Discriminatory analysis, nonparametric discrimination: Consistency properties. **Technical Report 4, USAF School of Aviation Medicine, Randolph Field**, 1951.

FRATTASI, S.; ROSA, F. **Mobile Positioning and Tracking: From Conventional to Cooperative Techniques**. [S.l.]: Wiley, 2017. (Wiley - IEEE). ISBN 9781119068822.

FRIEDMAN, N.; GEIGER, D.; GOLDSZMIDT, M. Bayesian network classifiers. **Mach. Learn.**, Kluwer Academic Publishers, Hingham, MA, USA, v. 29, n. 2-3, p. 131–163, nov. 1997. ISSN 0885-6125. Disponível em: <<https://doi.org/10.1023/A:1007465528199>>.

FROST, C.; JENSEN, C. S.; LUCKOW, K. S.; THOMSEN, B.; HANSEN, R. Bluetooth indoor positioning system using fingerprinting. In: SER, J. D.; JORSWIECK, E. A.; MIGUEZ, J.; MATINMIKKO, M.; PALOMAR, D. P.; SALCEDO-SANZ, S.; GIL-LOPEZ, S. (Ed.). **Mobile Lightweight Wireless Systems**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 136–150. ISBN 978-3-642-29479-2.

FUKUNAGA, K. **Introduction to Statistical Pattern Recognition (2Nd Ed.)**. San Diego, CA, USA: Academic Press Professional, Inc., 1990. ISBN 0-12-269851-7.

GAN, X.; YU, B.; HUANG, L.; LI, Y. Deep learning for weights training and indoor positioning using multi-sensor fingerprint. In: **2017 International Conference on Indoor Positioning and Indoor Navigation (IPIN)**. [S.l.: s.n.], 2017. p. 1–7.

GRAMACKI, A. **Nonparametric Kernel Density Estimation and Its Computational Aspects**. [S.l.]: Springer International Publishing, 2017. (Studies in Big Data). ISBN 9783319716886.

GWON, Y.; JAIN, R.; KAWAHARA, T. Robust indoor location estimation of stationary and mobile users. In: **IEEE INFOCOM 2004**. [S.l.: s.n.], 2004. v. 2, p. 1032–1043 vol.2. ISSN 0743-166X.

HADZIC, M.; CHANG, E.; WONGTHONGTHAM, P. **Ontology-Based Multi-Agent Systems**. [S.l.]: Springer Berlin Heidelberg, 2009. (Studies in Computational Intelligence). ISBN 9783642019036.

HAN, J.; PEI, J.; KAMBER, M. **Data Mining, Southeast Asia Edition**. [S.l.]: Elsevier Science, 2006. (The Morgan Kaufmann Series in Data Management Systems). ISBN 9780080475585.

HAN, S.; ZHAO, C.; MENG, W.; LI, C. Cosine similarity based fingerprinting algorithm in wlan indoor positioning against device diversity. In: **2015 IEEE International Conference on Communications (ICC)**. [S.l.: s.n.], 2015. p. 2710–2714. ISSN 1550-3607.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. 2nd. ed. Upper Saddle River, NJ, USA: Prentice Hall PTR, 1998. ISBN 0132733501.

HE, S.; CHAN, S. H. G. Wi-fi fingerprint-based indoor positioning: Recent advances and comparisons. **IEEE Communications Surveys Tutorials**, v. 18, n. 1, p. 466–490, Firstquarter 2016. ISSN 1553-877X.

HIGHTOWER, J.; BORRIELLO, G. Spoton: An indoor 3d location sensing technology based on rf signal strength. In: . [S.l.: s.n.], 2000.

HOLLAND, J. H. Properties of the bucket brigade. In: **Proceedings of the 1st International Conference on Genetic Algorithms**. Hillsdale, NJ, USA: L. Erlbaum Associates Inc., 1985. p. 1–7. ISBN 0-8058-0426-9. Disponível em: <[http://dl.acm.org/citation.cfm?id=645511.657087,acmid={65708}.>](http://dl.acm.org/citation.cfm?id=645511.657087,acmid={65708}.)

HOPFIELD, J. J. Neurocomputing: Foundations of research. In: ANDERSON, J. A.; ROSENFELD, E. (Ed.). Cambridge, MA, USA: MIT Press, 1988. cap. Neural Networks and Physical Systems with Emergent Collective Computational Abilities, p. 457–464. ISBN 0-262-01097-6. Disponível em: <<http://dl.acm.org/citation.cfm?id=65669.104422>>.

HOSSAIN, A. K. M. M.; JIN, Y.; SOH, W. S.; VAN, H. N. Ssd: A robust rf location fingerprint addressing mobile devices' heterogeneity. **IEEE Transactions on Mobile Computing**, v. 12, n. 1, p. 65–77, Jan 2013. ISSN 1536-1233.

HUANG, C. C.; MANH, H. N. Rss-based indoor positioning based on multi-dimensional kernel modeling and weighted average tracking. **IEEE Sensors Journal**, v. 16, n. 9, p. 3231–3245, May 2016. ISSN 1530-437X.

HUI, Y. **Artificial Intelligence Science And Technology - Proceedings Of The 2016 International Conference (Aist2016)**. World Scientific Publishing Company, 2017. ISBN 9789813206830. Disponível em: <<https://books.google.com.br/books?id=IlcvDwAAQBAJ>>.

IVERSEN, G. **Bayesian Statistical Inference**. SAGE Publications, 1984. (Bayesian Statistical Inference, N° 43). ISBN 9780803923287. Disponível em: <<https://books.google.com.br/books?id=rGaOmdmWIZMC>>.

JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. Artificial neural networks: a tutorial. **Computer**, v. 29, n. 3, p. 31–44, Mar 1996. ISSN 0018-9162.

JARNÍK, V. O jistém problému minimálním (about a certain minimal problem). p. 57–63, 1930.

JONES, T. **Artificial Intelligence: A Systems Approach with CD**. 1st. ed. USA: Jones and Bartlett Publishers, Inc., 2008. ISBN 0763773379, 9780763773373.

KARIMI, H. **Universal Navigation on Smartphones**. Springer US, 2011. ISBN 9781441977410. Disponível em: <<https://books.google.com.br/books?id=F5UFKNpemOkC>>.

KARLSSON, P.; LUND, T. högskolan i. Indoor radio propagation for personal communications services /. 04 2018.

KAVEHRAD, M.; CHOWDHURY, M. I. S.; ZHOU, Z. Indoor positioning methods using vlc leds. p. 225–262, 10 2015.

KELLEHER, J.; NAMEE, B.; D'ARCY, A. **Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies**. MIT Press, 2015. (Fundamentals of Machine Learning for Predictive Data Analytics). ISBN 9780262029445. Disponível em: <<https://books.google.com.br/books?id=uZxOCgAAQBAJ>>.

KHALAJMEHRABADI, A.; GATSIS, N.; AKOPIAN, D. Modern wlan fingerprinting indoor positioning methods and deployment challenges. PP, 10 2016.

KHALAJMEHRABADI, A.; GATSIS, N.; AKOPIAN, D. Structured group sparsity: A novel indoor wlan localization, outlier detection, and radio map interpolation scheme. **IEEE Transactions on Vehicular Technology**, v. 66, n. 7, p. 6498–6510, July 2017. ISSN 0018-9545.

KING, T.; KOPF, S.; HAENSELMANN, T.; LUBBERGER, C.; EFFELSBERG, W. Compass: A probabilistic indoor positioning system based on 802.11 and digital compasses. In: **Proceedings of the 1st International Workshop on Wireless Network Testbeds, Experimental Evaluation & Characterization**. New York, NY, USA: ACM, 2006. (WiNTECH '06), p. 34–40. ISBN 1-59593-539-8. Disponível em: <<http://doi.acm.org/10.1145/1160987.1160995>>.

KOHONEN, T. Neurocomputing: Foundations of research. In: ANDERSON, J. A.; ROSENFELD, E. (Ed.). Cambridge, MA, USA: MIT Press, 1988. cap. Self-organized Formation of Topologically Correct Feature Maps, p. 509–521. ISBN 0-262-01097-6. Disponível em: <<http://dl.acm.org/citation.cfm?id=65669.104428>>.

KRIESEL, D. **A Brief Introduction to Neural Networks**. [s.n.], 2007. Disponível em: <[Disponível em http://www.dkriesel.com](http://www.dkriesel.com)>.

KRISHNAMURTHY, P. Technologies for positioning in indoor areas. in: Indoor wayfinding and navigation. CRC Press, p. 35–51, 2015.

KRUSKAL, J. B. On the shortest spanning subtree of a graph and the traveling salesman problem. **Proceedings of the American Mathematical society**, v. 7, n. 1, p. 48–50, 1956.

KUMAR, S. **Neural Networks: A Classroom Approach**. McGraw-Hill, 2004. (Computer engineering series). ISBN 9780070482920. Disponível em: <<https://books.google.com.br/books?id=y67YnH4kEMsC>>.

KUSHKI, A.; PLATANIOTIS, K.; VENETSANOPOULOS, A. **WLAN Positioning Systems: Principles and Applications in Location-Based Services**. Cambridge University Press, 2012. ISBN 9781139503877. Disponível em: <<https://books.google.com.br/books?id=y4AKBYyT0lsC>>.

KWIECIEN, A.; GAJ, P.; STERA, P. **Computer Networks: 16th Conference, CN 2009, Wisla, Poland, June 16-20, 2009. Proceedings**. [S.l.]: Springer Berlin Heidelberg, 2009. (Communications in Computer and Information Science). ISBN 9783642026713.

LADD, A. M.; BEKRIS, K. E.; RUDYS, A.; MARCEAU, G.; KAVRAKI, L. E.; WALLACH, D. S. Robotics-based location sensing using wireless ethernet. In: **Proceedings of the 8th Annual International Conference on Mobile Computing and Networking**. New York, NY, USA: ACM, 2002. (MobiCom '02), p. 227–238. ISBN 1-58113-486-X. Disponível em: <<http://doi.acm.org/10.1145/570645.570674>>.

LEONDES, C. **Intelligent Systems: Technology and Applications, Six Volume Set**. [S.l.]: CRC Press, 2002. (Technology and Applications). ISBN 9781420040814.

LI, D.; ZHANG, B.; LI, C. A feature-scaling-based k -nearest neighbor algorithm for indoor positioning systems. **IEEE Internet of Things Journal**, v. 3, n. 4, p. 590–597, Aug 2016. ISSN 2327-4662.

LI, X. Rss-based location estimation with unknown pathloss model. **IEEE Transactions on Wireless Communications**, v. 5, n. 12, p. 3626–3633, December 2006. ISSN 1536-1276.

LIU, H.; DARABI, H.; BANERJEE, P.; LIU, J. Survey of wireless indoor positioning techniques and systems. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**, v. 37, n. 6, p. 1067–1080, Nov 2007. ISSN 1094-6977.

LIU, H.; GAN, Y.; YANG, J.; SIDHOM, S.; WANG, Y.; CHEN, Y.; YE, F. Push the limit of wifi based localization for smartphones. In: **Proceedings of the 18th Annual International Conference on Mobile Computing and Networking**. New York, NY, USA: ACM, 2012. (Mobicom '12), p. 305–316. ISBN 978-1-4503-1159-5. Disponível em: <<http://doi.acm.org/10.1145/2348543.2348581>>.

LLOYD, S. Least squares quantization in pcm. **IEEE Transactions on Information Theory**, v. 28, n. 2, p. 129–137, March 1982. ISSN 0018-9448.

MALOBERTI, F.; DAVIES, A. **A Short History of Circuits and Systems**. River Publishers, 2016. (River Publishers Series in Cir). ISBN 9788793379718. Disponível em: <<https://books.google.com.br/books?id=4uauDAAAQBAJ>>.

MCCULLOCH, W.; PITTS, W. A logical calculus of ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, 1943.

MOLISCH, A. F. **Wireless Communications**. 2nd. ed. [S.l.]: Wiley Publishing, 2011. ISBN 0470741864, 9780470741863.

MORALES, J. A.; AKOPIAN, D.; AGAIAN, S. Faulty measurements impact on wireless local area network positioning performance. **IET Radar, Sonar Navigation**, v. 9, n. 5, p. 501–508, 2015. ISSN 1751-8784.

NDJIONGUE, A. R.; FERREIRA, H.; NGATCHED, T. Visible light communications (vlc) technology. p. 1–15, 06 2015.

NERGUIZIAN, C.; DESPINS, C.; AFFÈS, S. Geolocation in mines with an impulse response fingerprinting technique and neural networks. **IEEE Transactions on Wireless Communications**, IEEE, v. 5, n. 3, p. 603–611, 2006.

NI, L. M.; LIU, Y.; LAU, Y. C.; PATIL, A. P. Landmarc: indoor location sensing using active rfid. In: **Proceedings of the First IEEE International Conference on Pervasive Computing and Communications, 2003. (PerCom 2003)**. [S.l.: s.n.], 2003. p. 407–415.

PANDEY, H. **Design Analysis and Algorithm**. [S.l.]: Laxmi Publications Pvt Limited, 2008. ISBN 9788131803349.

PARKINSON, B.; SPILKER, J. **Global Positioning System: Theory and Applications**. [S.l.]: American Institute of Aeronautics & Astronautics, 1996. (Ciencia militar y naval, v. 1). ISBN 9781600864193.

PARKINSON, B.; SPILKER, J. **Introduction to RF Propagation**. [S.l.]: Wiley Sons, 2005. (Ciencia militar y naval). ISBN 978-0-471-65596-1.

PEARL, J. **Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1988. ISBN 0-934613-73-7.

PEREIRA, F.; A., M.; C., T.; M., R. Localization in underground tunnels. in: Indoor wayfinding and navigation. CRC Press, p. 35–51, 2015.

PRIM, R. C. Shortest connection networks and some generalizations. **The Bell System Technical Journal**, v. 36, n. 6, p. 1389–1401, Nov 1957. ISSN 0005-8580.

PRIYANTHA, N. B.; CHAKRABORTY, A.; BALAKRISHNAN, H. The cricket location-support system. In: **Proceedings of the 6th Annual International Conference on Mobile Computing and Networking**. New York, NY, USA: ACM, 2000. (MobiCom '00), p. 32–43. ISBN 1-58113-197-6. Disponível em: <<http://doi.acm.org/10.1145/345910.345917>>.

PUZA, B. **Bayesian Methods for Statistical Analysis**. ANU Press, 2015. ISBN 9781921934254. Disponível em: <<http://www.jstor.org/stable/j.ctt1bgzbn2>>.

RANGARAJAN, G.; ARORA, B.; ARORA, B.; INDIA, G. S. of; SCIENCE, I. D. of; TECHNOLOGY; GEOMAGNETISM, I. I. of. **Geomagnetic Studies at Low Latitudes**. Geological Society of India, 1992. (Memoir (Geological Society of India)). ISBN 9788185867014. Disponível em: <<https://books.google.com.br/books?id=ZzUiAQAAMAAJ>>.

ROOS, T.; MYLLYMÄKI, P.; TIRRI, H. A statistical modeling approach to location estimation. **IEEE Transactions on Mobile Computing**, IEEE Educational Activities Department, Piscataway, NJ, USA, v. 1, n. 1, p. 59–69, jan. 2002. ISSN 1536-1233. Disponível em: <<http://dx.doi.org/10.1109/TMC.2002.1011059>>.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological**, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Parallel distributed processing: Explorations in the microstructure of cognition, vol. 1. In: RUMELHART, D. E.; MCCLELLAND, J. L.; GROUP, C. P. R. (Ed.). Cambridge, MA, USA: MIT Press, 1986. cap. Learning Internal Representations by Error Propagation, p. 318–362. ISBN 0-262-68053-X. Disponível em: <<http://dl.acm.org/citation.cfm?id=104279.104293>>.

RUSSELL, S. J.; SUBRAMANIAN, D. Provably bounded-optimal agents. **J. Artif. Int. Res.**, AI Access Foundation, USA, v. 2, n. 1, p. 575–609, jan. 1995. ISSN 1076-9757. Disponível em: <<http://dl.acm.org/citation.cfm?id=1622826.1622844>>.

SAKPERE, W.; OSHIN, M. A.; MLITWA, N. A state-of-the-art survey of indoor positioning and navigation systems and technologies. **South African Computer Journal**, v. 29, n. 3, 2017. ISSN 2313-7835. Disponível em: <<http://sacj.cs.uct.ac.za/index.php/sacj/article/view/452>>.

SCHNEIDER, O. Requeriments for positioning and navigation in underground constructions. In: **International conference on indoor positioning and indoor naviagation (IPIN)**. Nova Iorque: IEEE. [S.l.: s.n.], 2010.

SCHULZ, E.; BREITSPRECHER, T.; MUSAYEV, Y.; TREMMEL, S.; HOSENFELDT, T.; WARTZACK, S.; MEERKAMM, H. Interactions between amorphous carbon coatings and engine oil additives: Prediction of the friction behavior using optimized artificial neural networks. v. 33, p. 209–224, 01 2013.

SCHUM, D. **The Evidential Foundations of Probabilistic Reasoning**. [S.l.]: Northwestern University Press, 1994. ISBN 9780810118218.

SEIDEL, S. Y.; RAPPAPORT, T. S. 914 mhz path loss prediction models for indoor wireless communications in multifloored buildings. **IEEE Transactions on Antennas and Propagation**, v. 40, n. 2, p. 207–217, Feb 1992. ISSN 0018-926X.

SHAREEF, A.; ZHU, Y.; MUSAVI, M. Localization using neural networks in wireless sensor networks. In: **Proceedings of the 1st International Conference on MOBILE Wireless MiddleWARE, Operating Systems, and Applications**. ICST, Brussels, Belgium, Belgium: ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), 2007. (MOBILWARE '08), p. 4:1–4:7. ISBN 978-1-59593-984-5. Disponível em: <<http://dl.acm.org/citation.cfm?id=1361492.1361497>>.

- SHARP, I.; YU, K. Sensor-based dead-reckoning for indoor positioning. **Phys. Commun.**, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, The Netherlands, v. 13, n. PA, p. 4–16, dez. 2014. ISSN 1874-4907. Disponível em: <<http://dx.doi.org/10.1016/j.phycom.2013.11.013>>.
- SHEN, G.; CHEN, Z.; ZHANG, P.; MOSCIBRODA, T.; ZHANG, Y. Walkie-markie: indoor pathway mapping made easy. p. 85–98, 04 2013.
- SILVERMAN, B. **Density Estimation For Statistics And Data Analysis**. [S.l.: s.n.], 1986. Vol. 26.
- SUN, W.; LIU, J.; WU, C.; YANG, Z.; ZHANG, X.; LIU, Y. Moloc: On distinguishing fingerprint twins. In: **2013 IEEE 33rd International Conference on Distributed Computing Systems**. [S.l.: s.n.], 2013. p. 226–235. ISSN 1063-6927.
- TADLYS. **Topaz location system**. 2004. Disponível em: <http://www.tadlys.co.il/pages/Product_content.asp?iGlobalId=2>.
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. [S.l.]: Elsevier Science, 2008. ISBN 9780080949123.
- TSUDA, Y.; KONG, Q.; MAEKAWA, T. Detecting and correcting wifi positioning errors. In: **Proceedings of the 2013 ACM International Joint Conference on Pervasive and Ubiquitous Computing**. New York, NY, USA: ACM, 2013. (UbiComp '13), p. 777–786. ISBN 978-1-4503-1770-2. Disponível em: <<http://doi.acm.org/10.1145/2493432.2493460>>.
- WALPOLE, R.; MYERS, R. **Probability Statistics for Engineers Scientists, 8th Edition**. [S.l.]: Pearson Prentice Hall, 2009. ISBN 9788576051992.
- WANG, H.; SEN, S.; ELGOHARY, A.; FARID, M.; YOUSSEF, M.; CHOUDHURY, R. R. No need to war-drive: Unsupervised indoor localization. In: **Proceedings of the 10th International Conference on Mobile Systems, Applications, and Services**. New York, NY, USA: ACM, 2012. (MobiSys '12), p. 197–210. ISBN 978-1-4503-1301-8. Disponível em: <<http://doi.acm.org/10.1145/2307636.2307655>>.
- WANT, R.; HOPPER, A.; aO, V. F.; GIBBONS, J. The active badge location system. **ACM Trans. Inf. Syst.**, ACM, New York, NY, USA, v. 10, n. 1, p. 91–102, jan. 1992. ISSN 1046-8188. Disponível em: <<http://doi.acm.org/10.1145/128756.128759>>.
- WARD, A.; JONES, A.; HOPPER, A. A new location technique for the active office. **IEEE Personal Communications**, v. 4, n. 5, p. 42–47, Oct 1997. ISSN 1070-9916.
- WASSERMAN, L. **All of Nonparametric Statistics (Springer Texts in Statistics)**. Berlin, Heidelberg: Springer-Verlag, 2006. ISBN 0387251456.
- WEIB, G. Learning to coordinate actions in multi-agent systems. In: **in Proceedings of the 13th International Conference on Artificial Intelligence**. [S.l.]: Morgan Kaufmann, 1993. p. 311–316.
- WERNER, M. **Indoor Location-Based Services: Prerequisites and Foundations**. Springer International Publishing, 2014. ISBN 9783319106991. Disponível em: <<https://books.google.com.br/books?id=LGuhBQAAQBAJ>>.

WOOLDRIDGE, M. **An Introduction to MultiAgent Systems**. 2nd. ed. [S.l.]: Wiley Publishing, 2009. ISBN 0470519460, 9780470519462.

YASSIN, A.; NASSER, Y.; AWAD, M.; AL-DUBAI, A.; LIU, R.; YUEN, C.; RAULEFS, R.; ABOUTANIOS, E. Recent advances in indoor localization: A survey on theoretical approaches and applications. **IEEE Communications Surveys Tutorials**, v. 19, n. 2, p. 1327–1346, Secondquarter 2017.

YU, D.; DENG, L. **Automatic Speech Recognition: A Deep Learning Approach**. Springer London, 2014. (Signals and Communication Technology). ISBN 9781447157793. Disponível em: <<https://books.google.com.br/books?id=rUBTBQAAQBAJ>>.

YU, D.; SEIDE, F.; LI, G. Conversational speech transcription using context-dependent deep neural networks. In: **Proceedings of the 29th International Conference on International Conference on Machine Learning**. USA: Omnipress, 2012. (ICML'12), p. 1–2. ISBN 978-1-4503-1285-1. Disponível em: <<http://dl.acm.org/citation.cfm?id=3042573.3042574>>.

ZAFARI, F.; PAPAPANAGIOTOU, I.; CHRISTIDIS, K. Microlocation for internet-of-things-equipped smart buildings. **IEEE Internet of Things Journal**, v. 3, n. 1, p. 96–112, Feb 2016. ISSN 2327-4662.

ZHANG, W.; CHOWDHURY, M. I. S.; KAVEHRAD, M. Asynchronous indoor positioning system based on visible light communications. v. 53, p. 045105, 04 2014.

ZHENG, H.; XU, Z.; YU, C.; GURUSAMY, M. A 3-d high accuracy positioning system based on visible light communication with novel positioning algorithm. **Optics Communications**, v. 396, n. Complete, p. 160–168, 2017.

ANEXO A – DISTRIBUIÇÕES DE PROBABILIDADE:

Figura 49 – Principais distribuições de probabilidade discretas e contínuas.

Name	Distribution	Domain		s	$[g(\mathbf{s}, \boldsymbol{\theta})]^{1/n}$
Normal	$p(x \boldsymbol{\theta}) = \sqrt{\frac{\theta_2}{2\pi}} e^{-(1/2)\theta_2(x-\theta_1)^2}$	$\theta_2 > 0$		$\begin{bmatrix} \frac{1}{n} \sum_{k=1}^n x_k \\ \frac{1}{n} \sum_{k=1}^n x_k^2 \end{bmatrix}$	$\sqrt{\theta_2} e^{-\frac{1}{2}\theta_2(s_2 - 2\theta_1 s_1 + \theta_1^2)}$
Multi-variate Normal	$p(\mathbf{x} \boldsymbol{\theta}) = \frac{ \boldsymbol{\Theta}_2 ^{1/2}}{(2\pi)^{d/2}} e^{-(1/2)(\mathbf{x}-\boldsymbol{\theta}_1)^t \boldsymbol{\Theta}_2 (\mathbf{x}-\boldsymbol{\theta}_1)}$	$\boldsymbol{\Theta}_2$ positive definite		$\begin{bmatrix} \frac{1}{n} \sum_{k=1}^n \mathbf{x}_k \\ \frac{1}{n} \sum_{k=1}^n \mathbf{x}_k \mathbf{x}_k^t \end{bmatrix}$	$ \boldsymbol{\Theta}_2 ^{1/2} e^{-\frac{1}{2}[\text{tr} \boldsymbol{\Theta}_2 \mathbf{s}_2 - 2\boldsymbol{\theta}_1^t \boldsymbol{\Theta}_2 \mathbf{s}_1 + \boldsymbol{\theta}_1^t \boldsymbol{\Theta}_2 \boldsymbol{\theta}_1]}$
Exponential	$p(x \theta) = \begin{cases} \theta e^{-\theta x} & x \geq 0 \\ 0 & \text{otherwise} \end{cases}$	$\theta > 0$		$\frac{1}{n} \sum_{k=1}^n x_k$	$\theta e^{-\theta s}$
Rayleigh	$p(x \theta) = \begin{cases} 2\theta x e^{-\theta x^2} & x \geq 0 \\ 0 & \text{otherwise} \end{cases}$	$\theta > 0$		$\frac{1}{n} \sum_{k=1}^n x_k^2$	$\theta e^{-\theta s}$
Maxwell	$p(x \theta) = \begin{cases} \frac{4}{\sqrt{\pi}} \theta^{3/2} x^2 e^{-\theta x^2} & x \geq 0 \\ 0 & \text{otherwise} \end{cases}$	$\theta > 0$		$\frac{1}{n} \sum_{k=1}^n x_k^2$	$\theta^{3/2} e^{-\theta s}$
Gamma	$p(x \boldsymbol{\theta}) = \begin{cases} \frac{\theta^{\theta_1+1}}{\Gamma(\theta_1+1)} x^{\theta_1} e^{-\theta_2 x} & x \geq 0 \\ 0 & \text{otherwise} \end{cases}$	$\theta_1 > -1$ $\theta_2 > 0$		$\begin{bmatrix} \left(\prod_{k=1}^n x_k \right)^{1/n} \\ \frac{1}{n} \sum_{k=1}^n x_k \end{bmatrix}$	$\frac{\theta^{\theta_1+1}}{\Gamma(\theta_1+1)} s_1^{\theta_1} e^{-\theta_2 s_2}$
Beta	$p(x \boldsymbol{\theta}) = \begin{cases} \frac{\Gamma(\theta_1+\theta_2+2)}{\Gamma(\theta_1+1)\Gamma(\theta_2+1)} x^{\theta_1} (1-x)^{\theta_2} & 0 \leq x \leq 1 \\ 0 & \text{otherwise} \end{cases}$	$\theta_1 > -1$ $\theta_2 > -1$		$\begin{bmatrix} \left(\prod_{k=1}^n x_k \right)^{1/n} \\ \left(\prod_{k=1}^n (1-x_k) \right)^{1/n} \end{bmatrix}$	$\frac{\Gamma(\theta_1+\theta_2+2)}{\Gamma(\theta_1+1)\Gamma(\theta_2+1)} s_1^{\theta_1} s_2^{\theta_2}$
Poisson	$P(x \theta) = \frac{\theta^x}{x!} e^{-\theta} \quad x = 0, 1, 2, \dots$	$\theta > 0$		$\frac{1}{n} \sum_{k=1}^n x_k$	$\theta^s e^{-\theta}$
Bernoulli	$P(x \theta) = \theta^x (1-\theta)^{1-x} \quad x = 0, 1$	$0 < \theta < 1$		$\frac{1}{n} \sum_{k=1}^n x_k$	$\theta^s (1-\theta)^{1-s}$
Binomial	$P(x \theta) = \frac{m!}{x!(m-x)!} \theta^x (1-\theta)^{m-x} \quad x = 0, 1, \dots, m$	$0 < \theta < 1$		$\frac{1}{n} \sum_{k=1}^n x_k$	$\theta^s (1-\theta)^{m-s}$
Multinomial	$P(\mathbf{x} \boldsymbol{\theta}) = \frac{m! \prod_{i=1}^d \theta_i^{x_i}}{\sum_{i=1}^d x_i!} \quad \begin{matrix} x_i = 0, 1, \dots, m \\ \sum_{i=1}^d x_i = m \end{matrix}$	$0 < \theta_i < 1$ $\sum_{i=1}^d \theta_i = 1$		$\frac{1}{n} \sum_{k=1}^n \mathbf{x}_k$	$\prod_{i=1}^d \theta_i^{s_i}$

Duda e Hart (1973).