

# Estimation of Mobile Point Distance based on the Signal Strength of Wireless Network Routers

R. de Lima, G. Bernardes, and A. de Miranda

**Abstract**—The necessity to obtain the localization on the terrestrial globe surface allowed the expansion and emergence of primordial technologies to contemporary engineering, especially in the context of Intelligent Transportation Systems. Several systems have been based on the information obtained by GNSS (Global Navigation Satellite System) for localization. However, these kind of systems demonstrate structural limitations, which prevent users from obtaining more accurate positions, especially in closed environments such as underground parking lots, environments where satellite signals are not possible or where interference occurs. In this sense, positioning systems based on rssi (received signal strength indication) function is a support for traditional localization. The strategy used in this work consists of using signals provided by wireless network routers, available in the infrastructure of domestic, corporate or public networks, to estimate the position based the of signal power received by wireless receivers of mobile devices. Moreover, different models were studied and evaluated that equate the distance relation as a function of the power of the rssi signal received. In order to evaluate the models from desired external scenarios, an optimization was applied using the Particle Swarm Optimization (PSO) algorithm to obtain the optimum parameters of each model, conducting to an accurate position estimation. Experiments in real environment were performed to evaluate these different models with reference to a GPS-RTK system.

**Index Terms**—Location, GPS, Rssi, Wi-fi, Trilateration, Particle Swarm Optimization.

## I. INTRODUÇÃO

**S**ISTEMAS de Transporte Inteligentes (ITS) vem sendo objeto de muitas pesquisas. Dentre as várias tarefas neste contexto, a localização é peça chave na geração de trajetórias.

Conforme ilustrado na Figura 1, um problema típico de oclusão em sistemas de Percepção pode ter sua solução com o auxílio da localização dos elementos participantes da cena. Uma vez que estejam localizados, as trajetórias podem ser comparadas e avisos enviados com o propósito de se evitar um acidente.

Estes e outros acidentes ocasionaram, somente no ano de 2014, cerca de 45% de vítimas fatais no estado de São Paulo [1].

Sistemas de localização normalmente utilizam sinais de satélites, como é o caso do GPS (Global Positioning System). No entanto, o sinal pode sofrer interferência devido a diferentes fatores, sobretudo em centros urbanos, como a proximidade a edifícios, árvores e outros obstáculos naturais

The authors are with Terrestrial Mobility Lab. at the Federal University of Lavras (UFLA) and with Lab. of Robotics, Intelligent and Complex Systems at the Federal University of Itajubá (UNIFEI), Brazil. A. Miranda Neto was projects coordinator of 88881.067959/2014-01 and 88881.068069/2014-01 from CAPES/Brazil. G. Vitor held a visiting researcher scholarship from CAPES/Brazil: 88887.091468/2014-00. Contact authors givanibernardes@unifei.edu.br / arthur.miranda@deg.ufla.br.



Fig. 1. Pedestre em um ponto cego.

e artificiais. Outro ponto a se destacar é que a utilização de GPS em ambientes fechados é inviabilizada, como no caso de estacionamentos verticais ou subterrâneos, ou ainda em um shopping center. [2].

Face a este contexto, o presente estudo busca obter uma estimativa satisfatória de pontos móveis utilizando os sinais *RSSI* emitidos por roteadores de rede sem fio (AP's), conforme demonstrado pela Figura 2. Os principais modelos encontrados na literatura para equacionamento da relação de distância ( $d_i$ 's) em função da potência do sinal *RSSI* foram implementados e avaliados em ambiente externo. Com o propósito de garantir o ajuste fino de cada modelo em relação aos cenários estudados, foi proposto um modelo de otimização que utiliza o algoritmo *Particle Swarm Optimization* (PSO) para se obter os parâmetros ótimos, os quais fornecem um erro de estimativa mínimo. Uma vez estimada as distâncias para o ponto móvel, seu posicionamento foi obtido pelo esquema de trilateração.

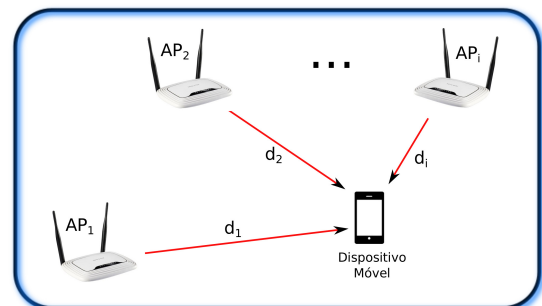


Fig. 2. Modelo estudado nesta proposta.

As principais contribuições do trabalho são (i) promover uma fundamentada análise comparativa entre os principais modelos de estimativa da distância propostos na literatura, a fim de avaliar o desempenho em ambiente urbano, estudo até então não realizado; (ii) formulação de um procedimento de

otimização usando PSO, que resulta nos parâmetros ótimos de cada modelo, minimizando assim o erro de estimação da distância e viabilizando uma comparação justa entre estes modelos. Ressalta-se que esta distância constitui elemento chave no processo de trilateração.

Desta forma, na seção II são destacados os três principais modelos de estimação da distância por *RSSI*. A seção III apresenta a metodologia proposta para obtenção do posicionamento, bem como a forma de análise realizada para os diferentes modelos e cenários selecionados. A seção IV apresenta o modelo que deu origem ao processo de otimização usando PSO. Por fim, a seção V faz as análises comparativas dos diferentes modelos em cada um dos cenários selecionados, seguido pelas conclusões e trabalhos futuros expostos na seção VI.

## II. TRABALHOS RELACIONADOS

Com foco na técnica de estimação do posicionamento apresentado, a distância relativa entre um transmissor e um receptor de rádio frequência determina o nível de precisão do sistema. A literatura [3], [4], [5], [6], [7], [8], [9], [10], [11], [12], [13], [14], [15], [16], [17], [18], [19], [20], [21], [22], [23], [24], [25], [26] apresenta algumas variações de modelos, tendo como entrada o valor de potência do sinal *RSSI* em diferentes meios, na sua maioria em ambientes internos.

Observa-se que, dentre os trabalhos consultados, foram encontrados diferentes parâmetros para caracterizar os diversos fatores de interferência e atenuação no sinal, como espelhamento, reflexão, difração e perda do sinal [27]. Assim, três principais modelos foram identificados como regularmente utilizados. Modelo 1 - COLA [22], Modelo 2 - Distância fixa para Calibração [26] e Modelo 3 - Distância variável para Calibração [17].

### A. Modelo 1 - COLA

Este Modelo 1 (M1) [22], [23], [24], considera que a potência do sinal recebido *RSSI* (dBm) é definido pela potência do sinal de saída do transmissor  $P_0$ , a frequência  $f$  (MHz) do sinal e a propagação do sinal no ambiente, dado por uma constante de degradação do sinal  $c = 27.56$  [4], conforme apresentado pela Equação 1.

$$rssi = P_0 - 20 \log(f) - 20 \log(d) + c \quad (1)$$

A fim de generalizar a modelagem para ambientes internos e externos, foi então proposto uma modificação na Equação 1 de maneira a considerar o parâmetro  $n$ , que representa o coeficiente de perda do sinal para diferentes tipos de ambientes, além da alteração da constante  $c$  para  $c = 30 * n - 32.44$  [22], Equação 2.

$$rssi = P_0 - 10n \log(f) - 10n \log(d) + c \quad (2)$$

Realizando as devidas manipulações e ajustes, a distância  $d$  pode então ser estimada na Equação 3. Note que nesta equação,  $F_m$  (*FadeMargin*) define a diferença do sinal recebido e a intensidade mínima do sinal, determinada pelo fabricante, para operação confiável.

$$d = 10^{\frac{(P_0 - F_m - rssi - 10n \log(f) + c)}{10n}} \quad (3)$$

### B. Modelo 2 - Distância Fixa de Calibração

O equacionamento do modelo 2 (M2) leva em conta a distância de calibração para o receptor, sendo esta distância fixa [21]. Inicialmente, a Equação 4, a potência do sinal recebido  $P_{SR}$  (em Watt) é equacionado pela potência do sinal transmitido  $P_{ST}$  (em Watt) e ponderado pela expressão que leva em conta o ganho da antena do sensor transmissor  $G_{ST}$ , o ganho da antena do sensor receptor  $G_{SR}$ , o comprimento de onda do sinal  $\lambda$ , a distância do transmissor  $d$  (em metros) e o coeficiente de perda do sinal para diferentes tipos de ambientes.

$$P_{SR} = P_{ST} \frac{G_{ST} G_{SR} \lambda^2}{(4\pi)^2 d^n} \quad (4)$$

A Equação 5 [21] converte o sinal  $P_{SR}$  de Watt para dBm, podendo deste modo modelar o sinal *RSSI* conforme a Equação 6. Note que o processo de calibração considera o fator de potência  $P_c$  (em dBm) calibrado para uma distância de 1 metro entre o receptor e transmissor.

$$P_{[dBm]} = 10 \log(P_{[W]} 10^3) \quad (5)$$

$$RSSI = -(10n \log(d) + P_c) \quad (6)$$

Assim, respeitando-se esta restrição e a constante de propagação compatível com o ambiente (interno ou externo), a distância é obtida pela Equação 7.

$$d = 10^{-\frac{rssi + P_c}{10n}} \quad (7)$$

### C. Modelo 3 - Distância Variável de Calibração

O modelo 3 (M3) é semelhante ao M2, exceto pelo fato do processo de calibração não ser limitado para uma distância de referência de 1 metro. Tendo em vista o conjunto de fatores que podem afetar o sinal recebido, que decresce proporcionalmente a  $d^n$ , o equacionamento do sinal *RSSI* entre os sensores receptor e transmissor é dado pela Equação 8. Isolando o termo de interesse, a distância  $d$  é então estimada pela Equação 9 [5], [7], [9], [10], [16], [17].

$$rssi = P_{cr} - 10n \log\left(\frac{d}{d_{cr}}\right) \quad (8)$$

Na Equação 8,  $d_{cr}$  define a distância de referência e  $P_{cr}$  define a potência do sinal medido na distância  $d_{cr}$ .

$$d = d_{cr} 10^{\frac{P_{cr} - rssi}{10n}} \quad (9)$$

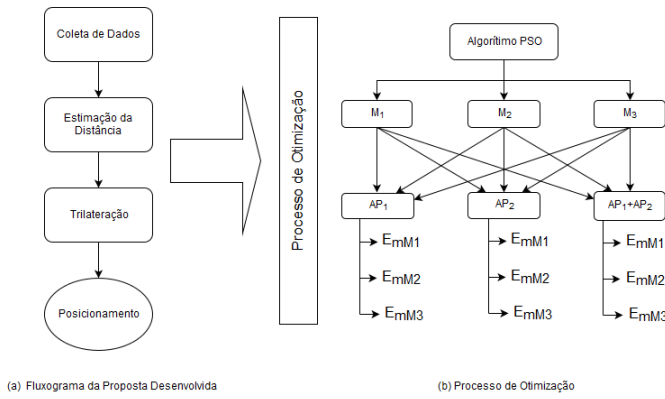


Fig. 3. Proposta do método de estimação do posicionamento baseado em informações de roteadores sem fio.

### III. METODOLOGIA PROPOSTA

O processo de estimação seguiu o fluxograma apresentado na Figura 3a.

Para a **coleta de dados**, foi desenvolvido um software para registro das informações de latitude, longitude e sinal RSSI do dispositivo móvel, além do *timestamp*, número *MAC* e *SSID* dos pontos de acesso observados. A obtenção e disposição dos pontos levou em conta dois diferentes cenários urbanos. O primeiro cenário, sem a interferência de outros sinais RSSI que não fossem provenientes dos equipamentos utilizados no experimento, duas configurações foram estudadas; (i) a obtenção dos pontos de forma aleatória ao redor de dois roteadores (AP1 e AP2) e (ii) a obtenção dos pontos seguindo um padrão linear, simulando a caminhada de um pedestre. O segundo cenário sem a restrição de fatores de interferência. A coleta dos pontos para estes dois cenários é apresentada na Figura 4. É importante ressaltar que este processo de coleta de dados pelo dispositivo móvel, foi considerada ao mesmo tempo a coleta de pontos usando um sistema GPS-RTK.

Conforme apresentado na Figura 3, o módulo de **Estimação da Distância** aplica o valor do sinal RSSI recebido pelo dispositivo móvel para inferir o valor de distância usando os três modelos apresentados. O módulo de **Trilateração** calcula a posição para a localização usando 3 ou mais pontos de referência e a medida de distância entre o objeto e cada ponto de referência, baseado no equacionamento proposto em [28]. Assim, a medida de distância foi determinada entre cada um dos pontos coletados e os dois roteadores (AP1 e AP2). A saída deste módulo é então a localização estimada para os pontos relacionados aos roteadores.

Visto que cada modelo apresentado possui parâmetros que contribuem ou não para a estimativa dos valores de distância, em função do sinal RSSI recebido dos diferentes ambientes, para não comprometer a forma de análise de desempenho desses modelos, foi então aplicado o processo de otimização observado na Figura 3b como forma de avaliar o comportamento de cada modelo, em seu estado ótimo, dentro da metodologia proposta para localização.

Uma vez conhecidas as coordenadas dos dois pontos referentes aos roteadores, obtidas pelo sistema GPS-RTK, o processo de otimização buscou obter os parâmetros ótimos

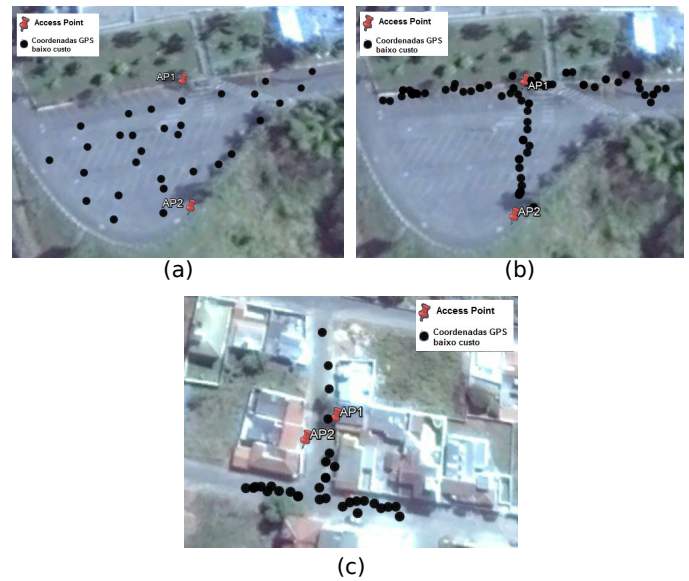


Fig. 4. Modelagem dos cenários urbanos para coleta e realização dos experimentos em ambiente externo. (a) Cenário 1 com disposição aleatória. (b) Cenário 1 com disposição linear e (c) cenário 2 com disposição linear.

de cada modelo considerando o erro obtido entre o ponto estimado pela trilateração e o ponto fornecido pelo GPS-RTK. Logo, têm-se os três erros  $E_m$  obtidos pelos diferentes modelos e com referência aos roteadores.

### IV. APLICAÇÃO DO MÉTODO DE OTIMIZAÇÃO PSO

Conforme apresentado na Figura 3, o posicionamento é estimado aplicando a técnica de trilateração que, por sua vez, possui um conjunto de pontos formados pela sua coordenada e distância em relação ao ponto de interesse, definindo as  $N$ -tuplas  $(x_i, y_i, d_i)$ . Logo, a distância é obtida em função dos modelos paramétricos relacionados ao sinal RSSI. Neste sentido, o processo de otimização busca encontrar os parâmetros ótimos para cada modelo apresentado na seção II, com o objetivo de embasar a avaliação de desempenho dos referidos modelos em seu “estado ótimo”.

No algoritmo PSO, a função objetivo avalia os indivíduos da população, retornando um valor de *fitness* para cada um deles. No caso em questão, o valor de *fitness* é obtido por meio da diferença do ponto estimado com o ponto assumido como sendo correto (GPS-RTK). Portanto, as subseções seguintes procuram explicar em detalhes esse processo.

#### A. Modelagem da Função Objetivo

A modelagem da função objetivo busca minimizar a seguinte função de erro  $J(\cdot)$  apresentada pela Equação 10.

$$\alpha^* = \arg \min_{\alpha} J(\alpha) \quad (10)$$

Onde  $\alpha$  é dado pelo vetor que contém os parâmetros a serem otimizados em cada modelo, que constituem os diferentes indivíduos da população. Os parâmetros em  $\alpha^*$  são os valores ótimos encontrados para o modelo em questão. A função  $J(\alpha)$  foi definida na Equação 11.

$$J(\alpha) = \sqrt{\sum_i E_i(\alpha)^2} \quad \forall i \in \{APs\} \quad (11)$$

A Equação 11 considera o somatório dos erros para o conjunto de *Access Points* (*APs*) dados. O índice  $i$  caracteriza cada elemento dentro deste conjunto  $\{APs\}$ . Cada  $E_i(\cdot)$  é assumido ser a distância entre o ponto do GPS-RTK,  $P_{RTK}$ , e o ponto estimado,  $P_{est}$ , com relação a Equação de Haversine [29]. Considerando esta equação como sendo a função  $D_{Haversine}$ , o erro é caracterizado pela Equação 12.

$$E(\alpha) = D_{Haversine}(P_{RTK}, P_{est}) \quad (12)$$

$P_{est}$  é de fato a estimação obtida pela técnica de trilateração modelada [28]. Assumindo que essa trilateração é dada pela função  $Trilateracao(\cdot)$ , têm-se então a Equação 13.

$$P_{est} = [\phi^e, \psi^e] = Trilateracao(V) \quad (13)$$

Onde  $V$  é definido como sendo o conjunto de pontos utilizados para se determinar a trilateração, caracterizado por  $\mathbf{V} = \{\mathbf{v}_j | \forall j \in \mathbf{C}_p\}$ , na qual cada tupla  $v_j$  está dentro do conjunto de N-tuplas  $C_p$ . A tupla  $\mathbf{v}_j$  é definida na Equação 14. Logo, a tupla é modelada passando a latitude,  $\phi^e$ , e a longitude,  $\psi^e$ , dos pontos que foram medidos pelo GPS do *smartphone* e também a distância  $d^{rssi}$  que cada ponto se encontra do roteador (*AP*).

$$v_j = [\phi_j^e, \psi_j^e, d_j^{rssi}] \quad (14)$$

Por fim, o valor de  $d^{rssi}$  é relacionado com cada um dos três modelos detalhados, referenciados aqui como *Modelo<sub>k</sub>*. Cada índice  $k$  defini umas das Equações 3, 7 e 9, tendo respectivamente como entrada a intensidade do sinal *RSSI* obtida pelo aplicativo desenvolvido para este trabalho e que estava embarcado no *smartphone* e o vetor de parâmetros  $\alpha_k^*$ .

$$d_j^{rssi} = Modelo_k(rssi, \alpha_k^*) \quad (15)$$

Como mencionado, a função objetivo foi definida para ser aplicada dentro do processo de otimização. Vale ressaltar que existem neste caso, uma função objetivo para encontrar o erro de estimação para o roteador 1, e outra para o roteador 2 e uma terceira unindo os dois roteadores. Estes caracterizam o conjunto  $\{APs\}$ . Para cada configuração, foram obtidos os parâmetros otimizados dos três modelos paramétricos.

## V. RESULTADOS EXPERIMENTAIS

Nos experimentos buscou-se evidenciar os diferentes aspectos da estimação de posicionamento, considerando os cenários apresentados. Tais aspectos incluem os resultados do processo de otimização, as análises de desempenho dos três modelos e também a influência do número de pontos necessários para se obter uma estimação satisfatória de posicionamento em função da trilateração. No processo de otimização do PSO avaliou-se a resposta do sinal *RSSI* recebido do **AP1**, do **AP2** e então sua união (**AP1 + AP2**). Para todos os processos de otimização, a configuração do PSO seguiu o seguinte padrão apresentado na Tabela I.

TABELA I  
CONFIGURAÇÃO DO PSO PARA TODOS OS PROCESSOS DE OTIMIZAÇÃO.

		Lim. Inferior	Lim. Superior	Pop. Inicial
<b>Modelo 1</b>	$P_0$	-50	-10	
	$n$	0,5	10	100
<b>Modelo 2</b>	$F_m$	0,0	100,0	
	$P_c$	-30,0	-20,0	100
	$n$	2,0	5,0	
<b>Modelo 3</b>	$d_{cr}$	0,5	2,0	
	$P_{cr}$	-50,0	-10,0	100
	$n$	0,5	10,0	

### A. Análise de Estimação da Localização para o Cenário 1: Captura de Dados de Forma Aleatória

Conforme observado na Figura 5, os gráficos apresentam a minimização do erro para cada modelo, baseado na informação de posicionamento extraída do sistema GPS-RTK. Ao comparar os valores iniciais dos erros em metros, nota-se que o gráfico responsável pelo **AP1** apresenta valores de erros menores que os valores apresentados no gráfico do **AP2**, da mesma forma quando se obtém os valores simultâneos para os dois pontos de acesso como se observa no gráfico **AP1+AP2**. Os valores iniciais são representados pela população informada ao algoritmo PSO com valores aleatórios, e mesmo que os valores tenham sido os mesmos para ambos os modelos, a divergência nos resultados pode ser correlacionada aos valores de dBm capturados pelo *smartphone* ao armazenar cada ponto.

Analisando o gráfico do **AP1**, o algoritmo PSO conseguiu otimizar os valores com menos de 10 iterações. Também é possível perceber que os três modelos obtiveram resultados muito próximos ao final do processo de otimização, diferente do que é apresentado no gráfico do **AP2**. Para este, foi necessário mais de 20 iterações para se obter a otimização dos valores mais próximos para os modelos 2 e 3. Já o modelo 1 não conseguiu aproximar dos valores encontrados pelos demais modelos, assim descartando a sua utilização para este caso.

Para o **AP1+AP2**, nota-se que o modelo 3 se destaca logo no início, atingindo o menor valor inicial. Possivelmente devido à população inicial do PSO ter sido inicializada com valores próximos ao ideal. Observando os modelos 1 e 2, os valores iniciais foram superiores quando comparados ao gráfico do **AP1** e **AP2**. O algoritmo do PSO necessitou de pouco mais de 10 iterações para se estabilizar. Após a estabilização do PSO, é possível perceber os mesmos resultados encontrados no gráfico do **AP2**, onde os modelos 2 e 3 obtiveram valores muito próximos no final do processo de otimização, enquanto para o modelo 1, a otimização não foi satisfatória.

A Tabela II apresenta os valores ótimos obtidos por meio do algoritmo PSO, em função da Figura 5. Esta tabela apresenta também o **Best Fitness**, que representa o menor erro de distância em metros ao executar cada modelo com os seus respectivos parâmetros ótimos.

Ao se analisar os dados do modelo 1 fica evidente a diferença quando comparados aos resultados dos modelos 2 e 3, que obtiveram valores próximos tanto para o **Best Fitness** quanto para os parâmetros ótimos. Isso se deve ao fato das equações dos modelos 2 e 3 serem semelhantes. Conforme

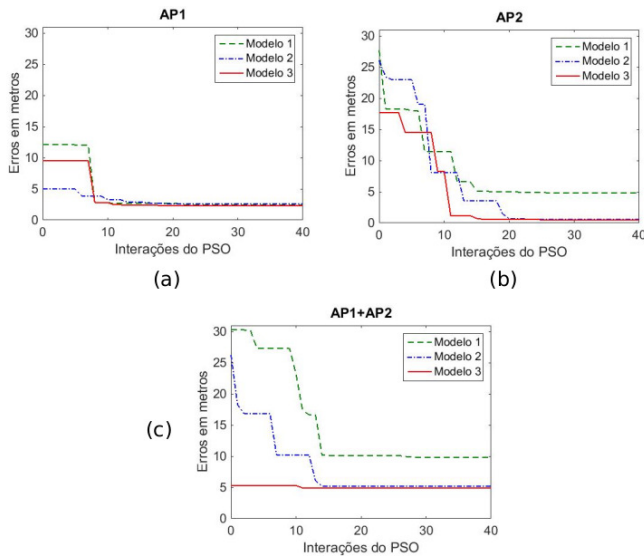


Fig. 5. Otimização por Enxame de Partículas (PSO) para o Cenário 1: captura de dados de forma aleatória.

TABELA II  
VALORES ÓTIMOS OBTIDOS PELO PSO NO CENÁRIO 1: CAPTURA DE DADOS DE FORMA ALEATÓRIA

	AP1	AP2	AP1+AP2	Média
Modelo 1	p0	-35,623	-20,000	-10,000
	n	0,5000	1,4557	1,7615
	fm	0,5875	0,1	3,2659
	<i>Best Fitness</i>	<b>2,39</b>	4,16	9,79
Modelo 2	p0	-20,000	-20,244	-10,003
	n	3,3002	3,5598	4,105
	<i>Best Fitness</i>	2,55	<b>0,61</b>	5,18
Modelo 3	d0	2,0	0,8297	1,3253
	p0	-20,0160	-20,0000	-11,0884
	n	3,9819	3,4204	4,333
<i>Best Fitness</i>	2,26	<b>0,48</b>	4,91	2,55

apresentado na Tabela II, e melhor evidenciado na Figura 6, pode-se notar que, pela média encontrada, o modelo 3 se destaca como o modelo mais apto, capaz de estimar a distância para os experimentos adquiridos para este cenário.

A Figura 7 apresenta a projeção para um dos três modelos aplicados nos cenários selecionados, considerando a trilateração sendo executada ponto a ponto, e utilizando os dados seguindo a ordem que foram capturados. Observa-se alguns picos que não estão contribuindo para a otimização. Possivelmente esse distúrbio é decorrente de pontos que não contribuem para a minimização do erro. Como forma de verificar este erro de uma maneira mais confiável, sorteou-se os pontos aleatoriamente, na Figura 8 é possível perceber os resultados deste processo.

Analisando a Figura 8, é notável o mesmo comportamento. Mesmo com o processo aleatório de trilateração entre os pontos, onde foram executadas 10 repetições aleatórias e obtida a média, ainda é visível a ocorrência do distúrbio encontrado na Figura 7. Isto confirma que existem pontos que não contribuem para a minimização do erro. Percebe-se também que não é necessário um conjunto mínimo de 28 pontos, conforme ilustrado na Figura 8, a fim de se obter uma




Fig. 6. Resultados dos modelos aplicados ao Cenário 1: captura de dados de forma aleatória.

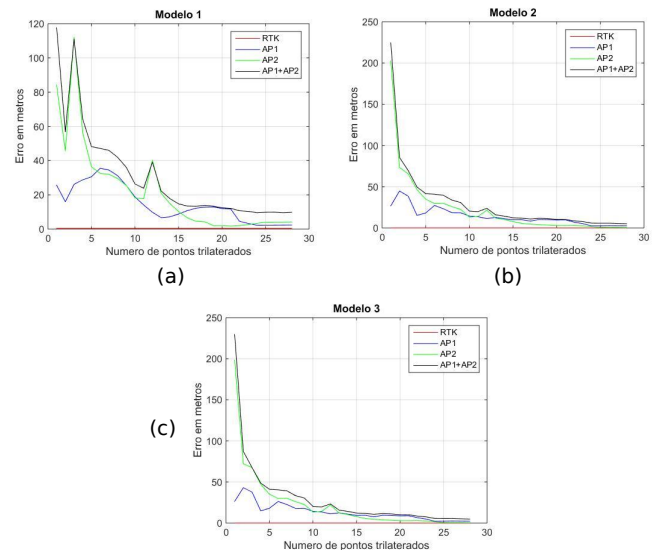


Fig. 7. Projeção da trilateração de 3 a 28 pontos.

estimacão de posicionamento satisfatória, levando em conta os parâmetros ótimos.

### B. Análise de Estimacão da Localizacão para o Cenário 1: Captura de Dados Seguindo Padrão Linear

Por meio da Figura 9 é observado o resultado de minimização do erro para cada modelo, baseado na informacão de posicionamento extraída do sistema GPS-RTK, em um cenário com disposicão linear dos pontos. Na Figura 9, a diferenaça de resultados entre os modelos é evidenciada. Se comparados aos resultados apresentados na Seção V-A, desta vez o modelo 1 se destacou como o modelo que obteve o menor erro. No entanto, também é possível identificar que o PSO não otimizou os resultados apresentados para este modelo inicialmente. Nota-se também que para os modelos 2 e 3, o algoritmo PSO executou menos de 5 iteraçoes para encontrar o menor erro. Ainda no gráfico do AP1 têm-se que o PSO não conseguiu otimizacão



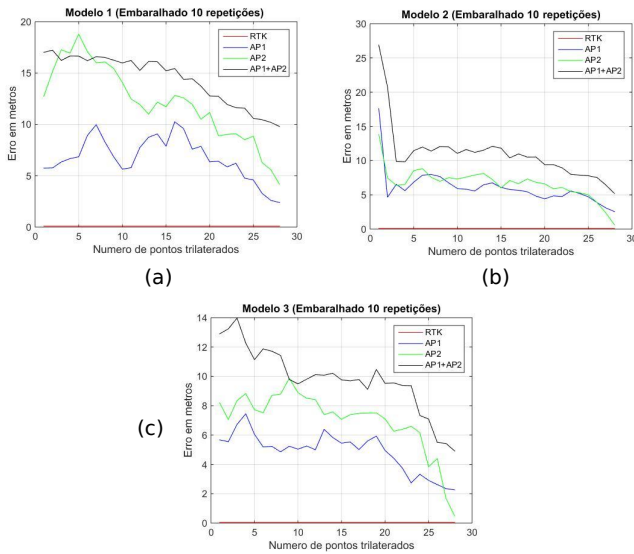


Fig. 8. Projeção da trilateração de 3 a 28 pontos com dados embaralhados em um ciclo de 10 repetições.

satisfatória para nenhum dos modelos, uma vez que a diferença entre os valores iniciais e o menor erro encontrado não passou de uma pequena variação.

No gráfico do **AP2** é possível notar uma diferença maior se comparado ao gráfico do **AP2** da seção V-A, uma vez que os valores iniciais para cada modelo foram superiores. Analisando o comportamento do algoritmo PSO, nota-se que o modelo 1 mais uma vez se destacou negativamente ao minimizar os erros. Mesmo com quase 20 iterações o seu menor erro encontrado ficou muito superior aos erros encontrados nos modelos 2 e 3. Agora para o modelo 2, o PSO necessitou de menos de 10 iterações para se estabilizar. Para o modelo 3, mesmo utilizando mais iterações, foi possível garantir, mesmo que por uma pequena diferença, que o modelo 3 se destacasse como sendo o modelo que apresentou o menor erro.

Analisando o gráfico do **AP1+AP2**, observa-se que os valores iniciais foram semelhantes aos apresentados no gráfico do **AP2**. A otimização por parte do algoritmo PSO para o modelo 1 se estabilizou com 15 iterações. Porém, mais uma vez este modelo não foi o que melhor se destacou ao encontrar o menor erro. O modelo 2 teve um pico na otimização próximo da 3ª iteração, se mantendo constante até a 13ª iteração, quando se estabilizou. O modelo 3, semelhante ao modelo 2, se estabilizou com 11 iterações e por uma pequena diferença mais uma vez foi o modelo que se destacou como o mais estável entre os três modelos, levando em conta este cenário.

A Tabela III apresenta os valores ótimos obtidos por meio do algoritmo PSO, em função da Figura 9. São apresentados as informações dos parâmetros ótimos para cada modelo, bem como o **Best Fitness** que representa o menor erro de distância em metros ao executar cada modelo com os seus respectivos parâmetros ótimos.

Conforme apresentado na Tabela III, e melhor evidenciado na Figura 10, é possível observar que os resultados, assim como no cenário 1, apontam que os modelos 1 e 2 foram os que obtiveram uma melhor eficiência ao estimar a localização

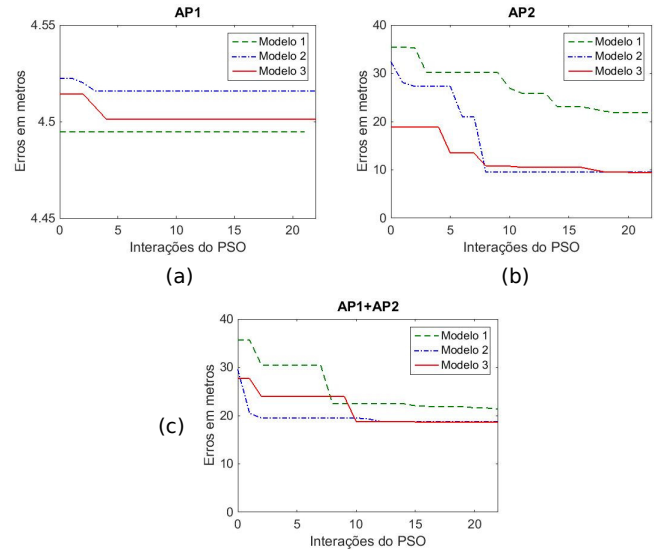


Fig. 9. Otimização por Enxame de Partículas (PSO) para o Cenário 1: captura de dados seguindo padrão linear.

TABELA III  
VALORES ÓTIMOS OBTIDOS PELO PSO NO CENÁRIO 1: CAPTURA DE DADOS SEGUINDO PADRÃO LINEAR

		AP1	AP2	AP1+AP2	Média
Modelo 1	p0	-25,558	-20,000	-10,0	
	n	1,9973	1,5722	2,0478	
	fm	65,6085	0,1	0,0	
	<b>Best Fitness</b>	<b>4,49</b>	21,50	21,36	15,78
Modelo 2	p0	-50,000	-20,000	-10,000	
	n	9,7294	3,7277	4,4031	
	d0	0,5	1,2519	2,000	
	<b>Best Fitness</b>	<b>4,52</b>	9,51	18,73	10,92
Modelo 3	p0	-43,3606	-22,0702	-13,089	
	n	10,0	3,8165	5,129	
	<b>Best Fitness</b>	<b>4,50</b>	9,27	18,69	10,82

para este cenário, e que o modelo 1 não se destacou assim como os demais.

A Figura 11 apresenta a projeção para cada modelo, considerando a trilateração sendo executada ponto a ponto, utilizando os dados seguindo a ordem que foram capturados. Semelhante com a análise do cenário 1, pode-se observar na Figura 11 a existência de picos no sinal, que da mesma forma também não estão contribuindo para a otimização. Foram tomados então o processamento de pontos sorteados aleatoriamente, a fim de se verificar a confiabilidade do erro. Na Figura 12 é possível perceber uma melhora significativa nos picos.

Analisando a Figura 12, nota-se que ao processar as amostras de sinal de forma embaralhada, em um ciclo de 10 repetições, isso foi capaz de suavizar os picos presentes na Figura 11. Contudo ainda é possível perceber a presença, mesmo que de forma suavizada, de pontos que não estão contribuindo para a minimização do erro.

Semelhante com a análise do cenário anterior, e apoiado nos resultados presentes na Figura 12, é seguro apontar que não é necessário um número relativamente maior de pontos para estimação. Neste caso, o procedimento foi realizado com 79




Fig. 10. Resultados dos modelos aplicados ao cenário.

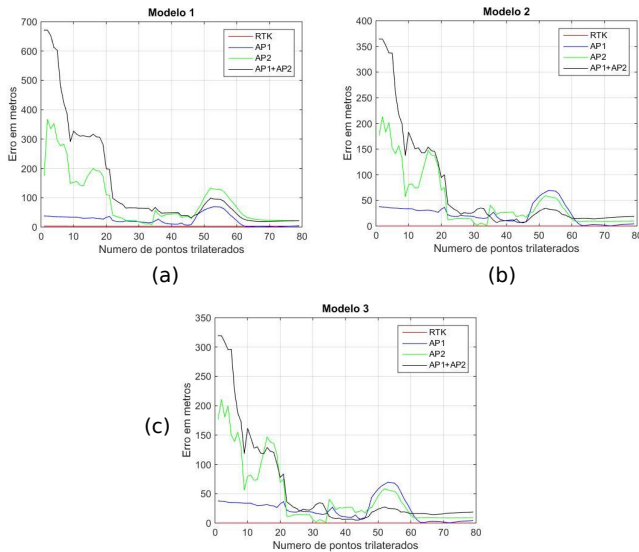


Fig. 11. Projeção da trilateração de 3 a 79 pontos.

pontos para se obter os parâmetros ótimos com o erro mínimo.

### C. Análise de Estimação da Localização para o Cenário 2: Captura de Dados com Interferências Externas

Seguindo as mesmas orientações aplicadas aos dois cenários anteriores, a Figura 13 apresenta o resultado do processo de minimização. Ao analisar o gráfico responsável pelo **AP1**, não se nota nenhuma surpresa se comparados aos demais gráficos analisados. O modelo 1 mais uma vez se destacou negativamente e os modelos 2 e 3 obtiveram resultados muito próximos. Como pode se observar, o modelo 2 se estabilizou com 5 iterações e o modelo 3 se estabilizou com pouco mais de 10 iterações. Seguindo, o modelo 1 precisou de mais de 40 iterações para se estabilizar, e mesmo assim obteve erro mínimo superior aos modelos 2 e 3.

Avaliando o gráfico do **AP2**, semelhante ao que ocorreu no gráfico **AP1** da seção V-B, o modelo 1 se destacou como sendo o modelo capaz de obter o menor erro mínimo. Analisando o

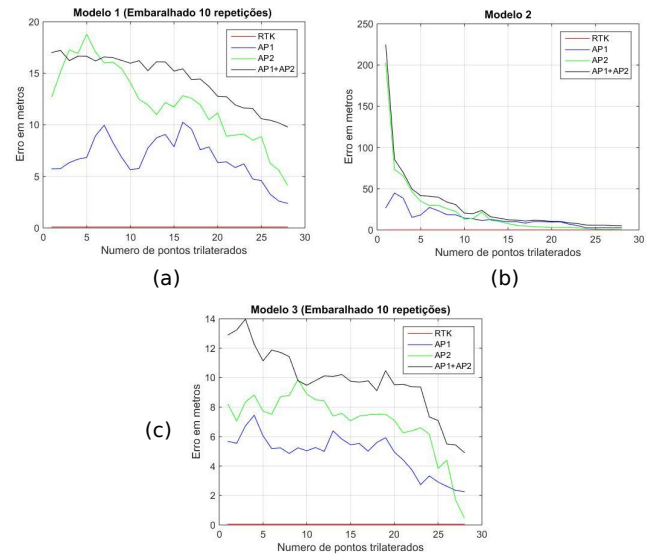


Fig. 12. Projeção da trilateração de 3 a 79 pontos com dados embaralhados em um ciclo de 10 repetições.

comportamento do algoritmo PSO, nota-se que a população inicial do mesmo se manteve com os valores ótimos não sofrendo alterações ao longo das iterações do modelo 1, o que se limitou a menos de 20 iterações para o término do processo. Os modelos 2 e 3 iniciaram na mesma faixa de erro que o modelo 1, diferenciando na escala por poucos centímetros. Ambos tiveram um pico na otimização no mesmo ponto, ou seja, na 3ª iteração e se mantiveram estáveis até o final do processo. Destaca-se o modelo 1 como o modelo que obteve o menor erro nesta condição.

O gráfico do **AP1+AP2** apresenta um resultado semelhante ao obtido pelo gráfico **AP2**, e ambos os modelos iniciaram com valores próximos, tendo apenas 2 centímetros de diferença do menor para o maior valor. Porém, o que chama a atenção é o fato de mais uma vez o modelo 1 ter se destacado como o modelo que obteve a melhor marca. Ao analisar os efeitos do PSO, nota-se que para o modelo 1, a otimização convergiu nas primeiras iterações e então se manteve estável até o término. No modelo 2, o PSO se estabilizou com 4 iterações e o modelo 3 se estabilizou com 5 iterações.

Conforme evidenciado pela Figura 13, fica claro que o modelo que obteve maior destaque ao conseguir estimar o erro mínimo para este cenário foi o modelo 1.

A Tabela IV apresenta os valores ótimos obtidos por meio do algoritmo PSO, em função da Figura 13. São apresentadas as informações dos parâmetros ótimos para cada modelo, bem como o **Best Fitness** que representa o menor erro de distância em metros ao executar cada modelo com os seus respectivos parâmetros ótimos.

Conforme apresentado na Tabela IV, e melhor evidenciado na Figura 14, é possível observar que aos resultados apresentados foram diferentes dos encontrados nos cenários anteriores. Neste momento fica claro que os três modelos obtiveram resultados muito semelhantes.

Desta forma, para cenários urbanos, em que há incidência de pontos causadores de interferência as análises apresentadas

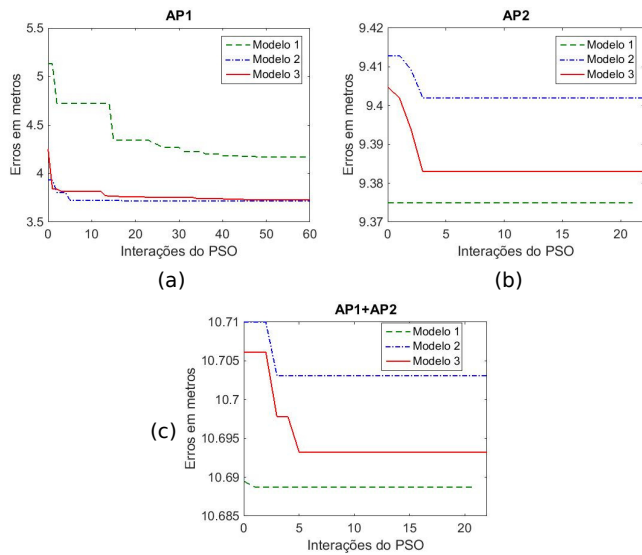


Fig. 13. Otimização por Enxame de Partículas (PSO) para o Cenário 2: captura de dados com interferências externas.

TABELA IV

VALORES ÓTIMOS OBTIDOS PELO PSO NO CENÁRIO 2: CAPTURA DE DADOS COM INTERFERÊNCIAS EXTERNAS

		AP1	AP2	AP1+AP2	Média
Modelo 1	p0	-20,000	-25,558	-46,9581	
	n	2,1490	1,9973	10,0000	
	fm	0,100	65,6085	0,0	
	<b>Best Fitness</b>	<b>4,17</b>	9,37	10,69	8,07
Modelo 2	p0	-20,000	-50,000	-50,000	
	n	4,9529	10,000	10,000	
	d0	1,999	0,509	0,500	
	<b>Best Fitness</b>	<b>3,72</b>	9,40	10,70	7,94
Modelo 3	p0	-36,2191	-44,8078	-46,3922	
	n	4,8218	10,000	9,4028	
	<b>Best Fitness</b>	<b>3,73</b>	9,38	10,69	7,93

apoiam a utilização dos três modelos, uma vez que ambos os resultados mostram que os três modelos testados podem ser utilizados.

A Figura 15, assim como os resultados dos cenários anteriores, apresenta a projeção para cada modelo estudado e aplicado também para o cenário que está sendo avaliado. Analogamente, este considera a trilateração sendo executada ponto a ponto e utilizando os dados seguindo a ordem que foram capturados.

Diferente de como ocorre nas análises dos cenários anteriores, pode-se observar que na Figura 15, mesmo com a existência de picos no sinal, estes já não ficam visíveis diretamente.

Contudo, ao se analisar a Figura 15, mais em específico o intervalo entre os pontos 10 e 15, é possível notar que o sinal sofre uma leve interferência. Conforme já detalhado nas análises anteriores, este pico possivelmente é causado por pontos que não estão contribuindo para a otimização, sendo assim, não necessários para o processo de trilateração.

Da mesma forma como fora feito nos cenários anteriores para verificar a confiabilidade do erro, foi realizado o processamento de pontos sorteados aleatoriamente. A Figura 16




Fig. 14. Resultados dos modelos aplicados ao cenário.

apresenta os resultados.

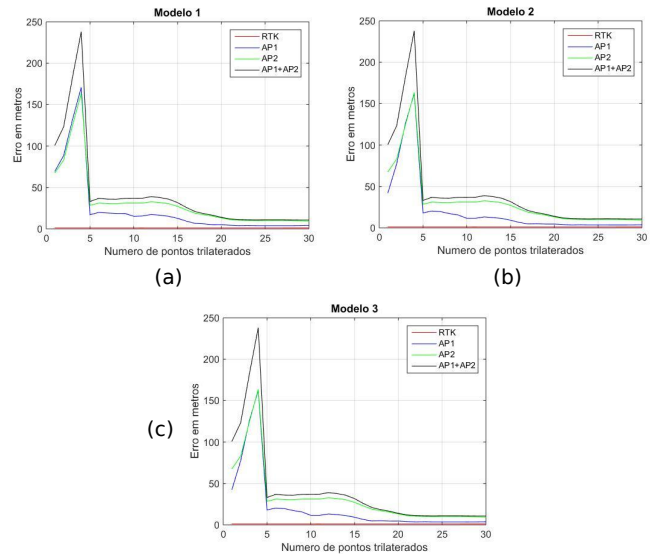


Fig. 15. Projeção da trilateração de 3 a 30 pontos.

Analisando a Figura 16, nota-se que mesmo com o processo de embaralhar os pontos 10 vezes e efetuar a trilateração, o processo só evidencia a suspeita de existência de pontos que não estão contribuindo para a estimativa da localização.

Realmente este processo vem apontar que existem pontos que não contribuem para minimização do erro. Significando dizer então que não são necessários um número considerável de 30 pontos, para se obter a estimativa de localização com certa precisão.

VI. CONCLUSÃO

O foco principal do trabalho foi analisar a eficiência de determinados modelos de estimação da distância em função do sinal *RSSI* recebido de roteadores, de maneira a obter uma melhor estimativa do dispositivo móvel em ambiente externo. Neste sentido, aplicou-se o processo de otimização usando o



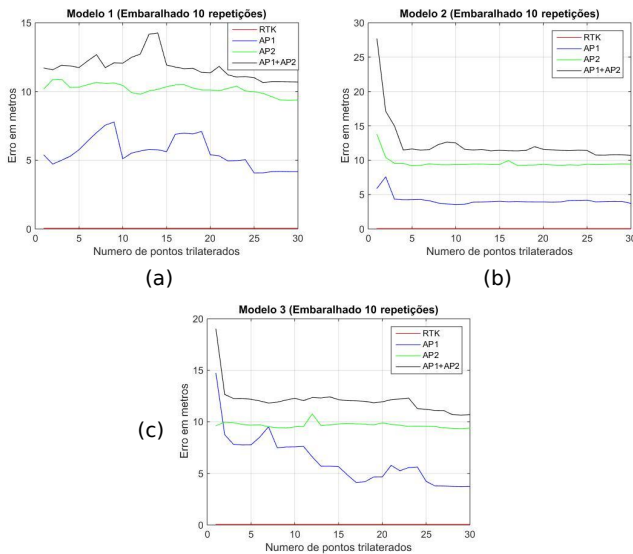


Fig. 16. Projeção da trilateração de 3 a 30 pontos com dados embaralhados em um ciclo de 10 repetições.

algoritmo PSO para garantir que cada modelo operasse em seu estado de parâmetros ótimo.

Diferentes experimentos foram realizados em diferentes configurações de cenário para avaliar o comportamento dos modelos, tomando como referência um sistema de posicionamento GPS-RTK. Observou-se a partir disso que o sinal *RSSI* apresenta instabilidades na propagação e recepção. Como exemplo, em um único ponto (em repouso), os valores podem variar entre 2 ou 3 unidades. Esta instabilidade conduz a erros expressivos uma vez que os cálculos dos modelos consideram fatores logarítmicos, dado que a variação do sinal *RSSI* é unitária. Contudo, os experimentos demonstraram que a partir de 25 pontos mapeados é possível estimar as coordenadas do dispositivo móvel de forma satisfatória. Como apresentado no cenário 1 com disposição aleatória, foi possível estimar a posição do roteador (AP2) com precisão de 0,48m. Logo, pode-se concluir que é viável a estimação de distâncias usando redes sem fio, desde que o modelo seja configurado com os parâmetros corretos para o tipo de ambiente no qual o sistema está sendo usado, informação que pode ser obtida em Mapas Digitais, por exemplo..

Os próximos passos serão voltados á elaboração de modelos mais robustos que consigam levar em conta não somente os ruídos externos mas também tais instabilidades do próprio sistema, usando para tal algoritmos inteligentes.

#### AGRADECIMENTOS

This work was carried out and funded in the framework of the Federal University of Lavras. It was equally supported by the CAPES in Brazil.

#### REFERÊNCIAS

- [1] CETSP. (2014) Relatório anual de acidentes de transito. Disponível em: <<http://www.cetsp.com.br/media/395294/relatorioanualacidentesfatais2014.pdf>>. Acessado em: 24 novembro 2015.
- [2] A. Hofleitner, E. Come, L. Oukhellou, J.-P. Lebacque, and A. Bayen, "Automatic inference of map attributes from mobile data," pp. 1687–1692, 2012.
- [3] D. C. Cox, R. R. Murray, and A. Norris, "800-mhz attenuation measured in and around suburban houses," *AT&T Bell Laboratories technical journal*, vol. 63, no. 6, pp. 921–954, 1984.
- [4] S. Y. Seidel and T. S. Rappaport, "914 mhz path loss prediction models for indoor wireless communications in multifloored buildings," *IEEE transactions on Antennas and Propagation*, vol. 40, no. 2, pp. 207–217, 1992.
- [5] H.-L. Song, "Automatic vehicle location in cellular communications systems," *IEEE Transactions on Vehicular Technology*, vol. 43, no. 4, pp. 902–908, 1994.
- [6] P. Bahl and V. N. Padmanabhan, "Radar: An in-building rf-based user location and tracking system," vol. 2, pp. 775–784, 2000.
- [7] N. Patwari, R. J. O'Dea, and Y. Wang, "Relative location in wireless networks," in *Vehicular Technology Conference, 2001. VTC 2001 Spring. IEEE VTS 53rd*, vol. 2. Rhodes, Greece: IEEE, May 2001, pp. 1149–1153.
- [8] P. Prasithsangaree, P. Krishnamurthy, and P. Chrysanthis, "On indoor position location with wireless lans," in *Personal, Indoor and Mobile Radio Communications, 2002. The 13th IEEE International Symposium on*, vol. 2. Lisboa, Portugal: IEEE, Sep 2002, pp. 720–724.
- [9] N. Patwari, A. O. Hero, M. Perkins, N. S. Correal, and R. J. O'dea, "Relative location estimation in wireless sensor networks," *IEEE Transactions on signal processing*, vol. 51, no. 8, pp. 2137–2148, 2003.
- [10] N. Patwari, J. N. Ash, S. Kyperountas, A. O. Hero, R. L. Moses, and N. S. Correal, "Locating the nodes: cooperative localization in wireless sensor networks," *IEEE Signal processing magazine*, vol. 22, no. 4, pp. 54–69, 2005.
- [11] J. F. Kurose and K. W. Ross, *Computer networking: a top-down approach*, 6th ed. USA: Addison Wesley, 2007.
- [12] W.-Y. Chung *et al.*, "Enhanced rssi-based real-time user location tracking system for indoor and outdoor environments," in *Convergence Information Technology, 2007. International Conference on*. Korea: IEEE, Nov 2007, pp. 1213–1218.
- [13] T. Instruments, "Cc2431 system-on-chip for 2.4 ghz zigbee/ieee 802.15. 4 with location engine," *Datasheet*, <http://focus.ti.com/docs/prod/folders/print/cc2431.html>, 2007.
- [14] W. S. Choi, J. W. Nam, and S. G. Choi, "Hop state prediction method using distance differential of rssi in vanet," in *2008 Fourth International Conference on Intelligent Computing (ICIC 2008)*, vol. 1, Center for International Scientific Exchanges, Chinese Academy of Sciences, Shanghai, China: IEEE, Sep 2008, pp. 426–431.
- [15] D. Gislason, *ZigBee wireless networking*, 1st ed. USA: Newnes, 2008.
- [16] G. Zanca, F. Zorzi, A. Zanella, and M. Zorzi, "Experimental comparison of rssi-based localization algorithms for indoor wireless sensor networks," in *Proceedings of the workshop on Real-world wireless sensor networks*. Glasgow, Scotland: ACM, Apr 2008, pp. 1–5.
- [17] E. Menegatti, A. Zanella, S. Zilli, F. Zorzi, and E. Pagello, "Range-only slam with a mobile robot and a wireless sensor networks," in *IEEE International Conference on Robotics and Automation (ICRA)*. Kobe, Japan: IEEE, May 2009, pp. 8–14.
- [18] A. T. Parameswaran, M. I. Husain, S. Upadhyaya *et al.*, "Is rssi a reliable parameter in sensor localization algorithms: An experimental study," 2009.
- [19] J. Yang and Y. Chen, "Indoor localization using improved rssi-based lateration methods," in *Global Telecommunications Conference, 2009. GLOBECOM 2009. IEEE*. Hawaii USA: IEEE, Nov 2009, pp. 1–6.
- [20] J. Xu, W. Liu, F. Lang, Y. Zhang, and C. Wang, "Distance measurement model based on rssi in wsn," *Wireless Sensor Network*, vol. 2, no. 08, p. 606, 2010.
- [21] E. Goldoni, A. Savioli, M. Risi, and P. Gamba, "Experimental analysis of rssi-based indoor localization with ieee 802.15. 4," in *European Wireless Conference (EW)*. Lucca, Italy: IEEE, Apr 2010, pp. 71–77.
- [22] C.-Y. Shih and P. J. Marrón, "Cola: Complexity-reduced trilateration approach for 3d localization in wireless sensor networks," in *Sensor Technologies and Applications (SENSORCOMM), 2010 Fourth International Conference on*. Italy: IEEE, Jul 2010, pp. 24–32.
- [23] S. Farahani, *ZigBee wireless networks and transceivers*, 1st ed. USA: Newnes, 2008.
- [24] G. Gracioli, A. Fröhlich, R. Pires, and L. Wanner, "Evaluation of an rssi-based location algorithm for wireless sensor networks," *Latin America Transactions, IEEE (Revista IEEE America Latina)*, vol. 9, no. 1, pp. 830–835, 2011.

- [25] O. G. Adewumi, K. Djouani, and A. M. Kurien, "Rssi based indoor and outdoor distance estimation for localization in wsn," in *Industrial Technology (ICIT), 2013 IEEE International Conference on*, IEEE International Conference on Industrial Technology (ICIT). South Africa: IEEE, Fev 2013, pp. 1534–1539.
- [26] Y. Bellecieri, F. Jabour, and E. Jabour, "Localização indoor baseada na leitura bidirecional do rssi," *Seminários de Trabalho de Conclusão de Curso do Bacharelado em Sistemas de Informação*, vol. 1, no. 1, 2016.
- [27] T. S. Rappaport *et al.*, *Wireless communications: principles and practice*. New Jersey: Prentice Hall PTR New Jersey, 1996, vol. 2.
- [28] Y.-T. Chen, C.-L. Yang, Y.-K. Chang, and C.-P. Chu, "A rssi-based algorithm for indoor localization using zigbee in wireless sensor network," in *Proceedings of the 15th International Conference on Distributed Multimedia Systems (DMS'09)*, Knowledge Systems Institute. San Francisco, USA: Citeseer, Sep 2009, pp. 70–75.
- [29] N. R. Chopde and M. Nichat, "Landmark based shortest path detection by using a\* and haversine formula," *International Journal of Innovative Research in Computer and Communication Engineering*, vol. 1, no. 2, pp. 298–302, 2013.



**Rodrigo de Lima Cunha** was Born in Campo Belo, Minas Gerais, Brazil, in 1981. He holds a bachelor's degree in Information Systems from the Presidente Antônio Carlos University, Campo Belo, Brazil, in 2008. He received the M.S. degree in Systems Engineering and Atomation from Federal University of Lavras, Lavras, Brazil. **e-mail:** [rodrigolim@gmail.com](mailto:rodrigolim@gmail.com)



**Giovani Bernardes Vitor** was born in Varginha, Minas Gerais, Brazil, in 1985. He received his B.S. degree in Computer Science from the South of Minas University Center, Varginha, Brazil, in 2008, his M.S. degree in mechanical engineering from the State University of Campinas, Campinas, Brazil, in 2010, and his double PhD degree in Computer Science from the Heudiasyc/CNRS/UTC (Compigne, France) and Mechanical Engineering from the State University of Campinas, Campinas, Brazil, both in 2014 under a scientific cooperation agreement. In 2014, he worked as Research Engineering at the Heudiasyc Laboratory, Centre National de la Recherche Scientifique, Compigne, France. Since 2015, he has been an Visiting Researcher/Professor at the Engineering Department from the Federal University of Lavras (UFLA) and member of the Terrestrial Mobility Laboratory (LMT). His current research interests are Computational Vision, Machine Learning, Intelligent Mobile Robotics, Sensors Fusion, Sensor-based Control and Navigation of Autonomous Systems. **e-mail:** [giovani Bernardes@unifei.edu.br](mailto:giovani Bernardes@unifei.edu.br)



**Arthur de Miranda Neto** Received a Ph.D. degree in information and systems technologies (2011) from the University of Technology of Compiegne (UTC), Compiegne, France, and in mechanical engineering from the UNICAMP, Brazil. He was Officer (systems analyst) of the Brazilian Army between 1997 and 2005, Visiting Professor at the UNICAMP between 2012 and 2014 and at University of California, Berkeley in 2017. Since 2014, he is an Associate Professor in the Engineering Department at the Federal University of Lavras (UFLA) and Head of the Terrestrial Mobility Laboratory (LMT). His research interests are in the field of Intelligent Transportation Systems.