

UM ARCABOUÇO PROBABILÍSTICO PARA
LOCALIZAÇÃO DOS NÓS DE UMA REDE DE
SENSORES SEM FIO BASEADA EM RSSI

FABRICIO FEITOSA CARVALHO

UM ARCABOUÇO PROBABILÍSTICO PARA
LOCALIZAÇÃO DOS NÓS DE UMA REDE DE
SENSORES SEM FIO BASEADA EM RSSI

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação do Instituto de Ciências Exatas da Universidade Federal de Minas Gerais como requisito parcial para a obtenção do grau de Mestre em Ciência da Computação.

ORIENTADOR: MÁRIO FERNANDO MONTENEGRO CAMPOS

COORIENTADOR: ANDRÉA IABRUDI TAVARES

Belo Horizonte

Julho de 2013

© 2013, Fabricio Feitosa Carvalho.
Todos os direitos reservados.

C331a Carvalho, Fabricio Feitosa
Um arcabouço probabilístico para localização dos
nós de uma rede de sensores sem fio baseada em RSSI /
Fabricio Feitosa Carvalho. — Belo Horizonte, 2013
xxviii, 98 f. : il. ; 29cm

Dissertação (mestrado) — Universidade Federal de
Minas Gerais

Orientador: Mário Fernando Montenegro Campos
Coorientador: Andréa Iabrudi Tavares

1. Computação - Teses. 2. Robótica – Teses.
I. Orientador. II. Coorientadora. III. Título.

CDU 519.6*82.9(043)



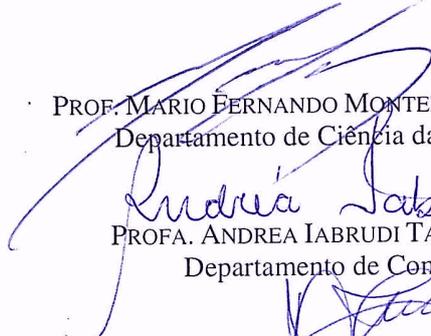
UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

FOLHA DE APROVAÇÃO

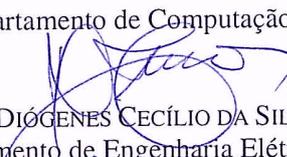
Um arcabouço probabilístico para localização dos nós de uma rede de sensores
sem fio baseada em RSSI

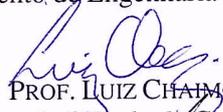
FABRICIO FEITOSA CARVALHO

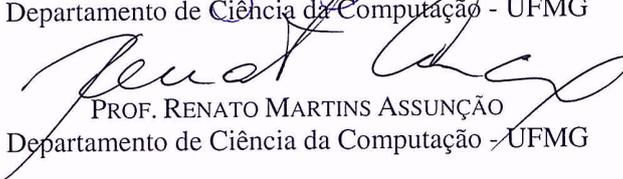
Dissertação defendida e aprovada pela banca examinadora constituída pelos Senhores:


PROF. MARIO FERNANDO MONTENEGRO CAMPOS - Orientador
Departamento de Ciência da Computação - UFMG


PROFA. ANDREA IABRUDI TAVARES - Coorientadora
Departamento de Computação - UFOP


PROF. DIÓGENES CECÍLIO DA SILVA JÚNIOR
Departamento de Engenharia Elétrica - UFMG


PROF. LUIZ CHAIMOWICZ
Departamento de Ciência da Computação - UFMG


PROF. RENATO MARTINS ASSUNÇÃO
Departamento de Ciência da Computação - UFMG

Belo Horizonte, 03 de julho de 2013.

Agradecimentos

Perceber o mundo ao redor é inerente a cada ser humano, no entanto, distinguir diferentes perspectivas de situações e discernir sobre elas é algo que vem com o tempo, aprendizado e experiência. A partir do período anterior, posso afirmar que os últimos dois anos e três meses ampliaram perceptivelmente a minha capacidade de ver um pouco mais do mundo que está ao meu redor, tanto profissionalmente quanto pessoalmente. Nesse processo, houveram diversas pessoas que participaram das diversas mudanças e sou muito grato a elas. Separando por âmbito, asserto que:

Profissionalmente, sou grato pela oportunidade de pertencer a essa fabulosa equipe chamada VeRLab que me acolheu durante esse tempo, cujos recursos mais valiosos são os profissionais de diversas áreas, que proporcionaram conversas e discussões fontes de criatividade, conhecimentos e conselhos, profissionais e pessoais. Nesse sentido, tenho que agradecer ao professor Mário Campos e a professora Andrea Iabrudi pela orientação, atenção e grandes conselhos. Aos colegas de laboratório pela sinergia desenvolvida, explicações e perguntas valiosas.

Pessoalmente, agradeço à dona Lúcia e ao seu João, meus pais, pela dedicação, preocupação, apoio e conversas que sempre me motivaram. A minha irmã Patrícia por sua atenção e preocupação e a meu irmão Fábio pelos conselhos. A minha amada namorada Priscila, por estar presente nos momentos difíceis e nos momentos de alegria, compartilhando conselhos pessoais e profissionais, e por seu carinho. Aos amigos que estão noutros estados, dentre esses Luiz Eduardo, Nathália Dobal e Marla Ibrahim. Às amizades cultivadas durante o mestrado.

Para finalizar, tenho que agradecer a Deus em todos os âmbitos, pois é a entidade que proporcionou todas as situações passadas e presentes, e peço que me guie da melhor forma as escolhas relacionadas às situações que estão por vir.

*“Na matemática você não entende coisas.
Você apenas se acostuma com elas.”*
(John Von Neumann)

Resumo

A localização de nós sensores numa rede de sensores sem fio (RSSF) é crucial, pois os dados produzidos na maioria das aplicações tem uma forte relação com a posição onde foram gerados. Embora existam diversas maneiras de localizar nós sensores, há situações onde o uso de *Received Signal Strength Indicator* (RSSI) é a melhor opção. No entanto, existem algumas dificuldades em utilizar o rádio na localização, tais como obstruções estáticas e dinâmicas presentes no ambiente. No presente estudo é proposto um arcabouço probabilístico que integra diferentes fontes de incerteza. A metodologia aqui desenvolvida aborda o problema de localização de nós sensores a partir do RSSI e um robô localizado com precisão. Foram propostos dois modelos probabilísticos que foram testados com diferentes mecanismos de inferência. Os modelos estabelecem uma relação do RSSI com a posição precisa de um robô móvel através de modelos de observação para criar um estado de crença sobre a localização dos nós.

A metodologia aqui apresentada foi avaliada através de simulações que permitiram controlar as possíveis variações de fatores que são encontrados em ambientes reais. O conjunto dessas variações é chamado de cenário e este é definido pela variação do nível do ruído no sinal de rádio, do intervalo entre as aquisições de amostras RSSI e da posição de nós sensores.

Uma contribuição dessa dissertação foi a análise da interação entre a variação de cenários com o resultado de localização dos nós sensores. Esta análise serve para mostrar quais dos fatores influenciaram no resultados de localização. Os experimentos mostraram que o arcabouço desenvolvido possui algumas contribuições, tais como: a avaliação do impacto das características dos cenários na localização dos nós sensores e os bons resultados na localização desses, cuja precisão chega a ser de centímetros num ambiente com $7000 m^2$.

Portanto, pode-se concluir que a localização de nós sensores baseada em RSSI proporciona uma maneira de localização quando tecnologias mais comuns não estão disponíveis e, simultaneamente, obter erros de localização aceitáveis para grande parte das aplicações. No entanto, esse erro de localização do nó sensor também aumenta

com o aumento das perturbações de sinal e a solução consiste em tentar equilibrar os parâmetros do modelo para abarcar as incertezas do processo.

Palavras-chave: Localização, RSSI, Nós Sensores, Robô, RSSF, Robótica.

Abstract

The localization of wireless sensors network (WSN) nodes is a crucial task because in most applications the data they produce needs to be grounded with the position where they were generated. Though there are many ways to locate sensor nodes, there are situations where the use of the received signal strength indicator (RSSI) is the single option. However, there are some difficulties in using the radio location, due to static and dynamic obstruction in the environment. In this work, a probabilistic framework that integrates the different sources of uncertainty is proposed. The methodology developed here addresses the problem of localization of sensor nodes based on RSSI and a precisely located robot. We propose two models that have been tested with different mechanisms of inference. These models establish a relationship with the RSSI and the precise position of a mobile robot through observation models to create a belief state about the location of the sensor nodes.

The methodology presented here was evaluated through simulations that allowed controlling the possible variations of factors may be found in real environments. All of these variations are called scenario and is defined by the variation of the noise level in the radio signal, the interval between acquisitions of RSSI samples and the position of sensor nodes.

One contribution of this dissertation is the analysis of the interaction between the scenario variation and the sensor nodes localization results, this analysis aims to show which factors affect the results. The experiments showed that the developed framework has other contributions, such as the impact on the evaluation of various scenarios characteristics in the localization process and the good results of locating the sensor nodes with location uncertainty of centimeters in an environment with $7000 m^2$. Therefore, it can be concluded that the localization of sensor nodes based on RSSI provides a way to locate when the most common technologies are not available, and is able to simultaneously obtain acceptable localization errors in most applications. However, the localization error also increases with increasing disturbance in the signal and the solution consists in the balance of the model parameters to reduce the uncertainty of

the process.

Keywords: Localization, Sensor Nodes, Robot, WSN, Robotics.

Lista de Figuras

1.1	Caixa reusável com etiquetas RFID	2
1.2	Meias com etiquetas RFID	2
1.3	Exemplo de como é importante a vinculação da localização dos dados com a localização dos nós sensores	4
1.4	O problema da localização de um nó sensor através do RSSI	5
2.1	Taxonomia para sistemas de localização de nós sensores	10
2.2	Algoritmo livre de distância baseado em número de saltos	11
2.3	Algoritmo livre de distância baseado em área - ALS	12
2.4	Algoritmo livre de distância baseado em área - APIT	12
2.5	Localização por infraestrutura	13
2.6	Localização distribuída	14
2.7	Localização por âncoras móveis	15
2.8	Resultado da abordagem proposta por Caballero et al. [2008]	18
2.9	Resultado da abordagem proposta por Djughash et al. [2008]	19
2.10	O resultado do algoritmo proposto por Menegatti et al. [2009]	21
2.11	O resultado do método proposto por Caballero et al. [2010]	22
3.1	O modelo gráfico probabilístico do problema de localização simultânea entre um elemento móvel e os nós sensores	26
3.2	Regiões de interseção formadas pelas distribuições de probabilidade na localização de nós sensores	28
3.3	Fluxo de informação das abordagens para localização de nós sensores	29
3.4	Anel formado por uma distribuição de probabilidade uniforme	30
3.5	Anel formado por uma distribuição de probabilidade baseada numa normal	31
3.6	Rede Bayesiana usada na inferência exata para o problema de localização de nós sensores	34

3.7	O HMM usado na inferência aproximada para o problema de localização de nós sensores	35
3.8	HMM usada na inferência da localização do robô	36
3.9	Seccionamento do ambiente em grade para inferência exata	37
4.1	Inferência da posição do nó sensor quando o robô percorre um caminho linear	43
4.2	Diferentes níveis de perturbação no sinal comparados com uma amostra de RSSI de um ambiente real	46
4.3	Cenário com 20 nós sensores e caminho percorrido pelo robô nos experimentos	48
4.4	Erro de localização utilizando uma inferência exata com distribuição uniforme	50
4.5	Erro de localização utilizando uma inferência exata com modelo de observação normal	51
4.6	Erro de localização utilizando um filtro de partículas com modelo de observação normal	52
4.7	Resultado da localização dos métodos de inferência testados para o nó sensor 2	53
4.8	Resultado da localização dos métodos de inferência testados para o nó sensor 1	54
4.9	Resultado da localização dos métodos de inferência testados para o nó sensor 3	55
4.10	Resultado da localização dos métodos de inferência testados para o nó sensor 7	56
4.11	Resultado da localização dos métodos de inferência testados para o nó sensor 14	57
4.12	Comparação do tempo de atualização do estado de crença de cada método de inferência	58
4.13	Resultado da análise estatística dos fatores (perturbação, estimador e intervalo) para cada método de inferência	60
4.14	Resultado da análise estatística dos fatores (perturbação e estimador) para cada método de inferência	61
4.15	Resultado da análise estatística dos fatores (perturbação, estimador e método) em relação ao erro de localização dos nós sensores	62
4.16	MAP \times MGP na inferência exata com modelo de observação normal . . .	64
4.17	MAP \times MGP na inferência exata com modelo de observação uniforme . .	65
4.18	MAP \times MGP no filtro de partículas com modelo de observação normal . .	66
B.1	Comparação dos modelos junto a valores reais de RSSI	87
C.1	Relação de Potência de sinal Recebida por transmitida analisada através dos aspectos de <i>Path-loss</i> , <i>Shadowing</i> e <i>Multi-path</i> VS distância	91

D.1	Hardware Setup: Um robô Pioneer da Activmedia TM equipado com um <i>laser Sick LMS 200</i> , um controle e um netbook.	94
D.2	Mapa do terceiro andar do departamento de computação e o resultado do sistema de localização do robô. Esta informação de localização foi utilizada para fazer a criação do estado de crença da posição do nó sensor.	95
D.3	Erro de localização em metros entre a posição estimada do nó sensor e a posição real versus o número de amostras de RSSI no experimento simulado. (Retirado de Carvalho et al. [2012])	96
D.4	Erro de localização em metros entre a posição estimada do nó sensor e a posição real versus o número de amostras de RSSI no experimento real. (Retirado de Carvalho et al. [2012])	96

Lista de Tabelas

2.1	Trabalhos dentro da taxonomia de localização de nós sensores de uma WSN	17
4.1	A distância média, mínima e máxima dos nós sensores	49
4.2	Média e erro padrão dos resultados da localização do Nó Sensor 2	51
4.3	Média e erro padrão dos resultados da localização do nó sensor 1	52
4.4	Média e erro padrão dos resultados da localização do nó sensor 3	54
4.5	Média e erro padrão dos resultados da localização do nó sensor 7	55
4.6	Média e erro padrão dos resultados da localização do nó sensor 14	56
4.7	Tempo gasto de atualização do estado de crença de cada método de inferência	58
A.1	Resultado do <i>n-way</i> ANOVA (perturbação x estimador x intervalo) para uma inferência exata uniforme	76
A.2	Resultado do two-way ANOVA (perturbação x estimador) para uma inferência exata uniforme	77
A.3	Resultado do n-way ANOVA (perturbação x estimador x intervalo) para uma inferência exata normal	79
A.4	Resultado do two-way ANOVA (perturbação x estimador) para uma inferência exata normal	80
A.5	Resultado do n-way ANOVA (perturbação x estimador x intervalo) para um filtro de partículas	81
A.6	Resultado do two-way ANOVA (perturbação x estimador) para um filtro de partícula	82
A.7	Resultado do n-way ANOVA (perturbação no <i>Received Signal Strenght Indicator</i> (RSSI) × estimador × método de inferência)	83
B.1	Tabela de valores de coeficiente de atenuação	86
C.1	Valores dos coeficiente de atenuação. Esses valores foram calculados com base nos dados fornecidos por 3Com [2006]	90

Lista de Siglas

AMCL	<i>Adaptative Monte Carlo Localization</i>
ANOVA	<i>Analisis Of Variance</i>
AoA	<i>Angle of Arrival</i>
EKF	<i>Extended Kalman Filter</i>
GMM	<i>Gaussian Mixture Model</i>
GPS	<i>Global Positioning System</i>
HMM	<i>Hidden Markov Model</i>
MAP	<i>Maximum a Posteriori</i>
MGP	Média geral Ponderada
PDF	<i>Probability Distribution Function</i>
RFID	<i>Radio-Frequency IDentification</i>
ROS	<i>Robot Operational System</i>
RSSI	<i>Received Signal Strenght Indicator</i>
RToF	<i>Roundtrip Time of Flight</i>
RSSF	Redes de Sensores Sem Fios
ToA	<i>Time of Arrival</i>
TDoA	<i>Time Difference of Arrival</i>
ToF	<i>Time of Flight</i>

Lista de Algoritmos

1	Algoritmo do modelo de verossimilhança com distribuição uniforme . . .	30
2	Algoritmo do modelo de verossimilhança com distribuição normal	32
3	Algoritmo de inferência exata uniforme para localização de nós sensores	38
4	Algoritmo do filtro de partículas para localização de nós sensores	40

Sumário

Agradecimentos	vii
Resumo	xi
Abstract	xiii
Lista de Figuras	xv
Lista de Tabelas	xix
Lista de Siglas	xxi
1 Introdução	1
1.1 Definição do problema	3
1.2 Objetivos	4
1.3 Contribuições	5
1.4 Organização da dissertação	6
2 Fundamentação e Trabalhos Relacionados	9
2.1 Taxonomia para localização de nós sensores	9
2.1.1 Localização livre de distância	10
2.1.2 Localização baseada em distância	13
2.2 Localização, probabilidade e sinal de rádio	16
3 Metodologia	25
3.1 Definição do modelo	25
3.1.1 Modelos de observação para RSSI	28
3.1.2 Estimadores	32
3.2 Localização de nós sensores	33
3.2.1 Estado de crença	33

3.2.2	Posição do robô conhecida	33
3.2.3	Posição do robô incerta	34
3.3	Processo de inferência	36
3.3.1	Inferência exata	36
3.3.2	Inferência aproximada	38
4	Resultados e discussão	41
4.1	Configuração do cenário	41
4.1.1	Ferramentas	42
4.1.2	O ambiente	42
4.1.3	Caminho percorrido pelo robô	43
4.1.4	Testes estatísticos utilizados	44
4.2	Parâmetros	44
4.2.1	Perturbação no RSSI	44
4.2.2	Intervalo de aquisição do RSSI	47
4.2.3	Caracterização dos nós sensores	47
4.3	Comparando os métodos de inferência	48
4.3.1	Resultado de cada método de inferência	48
4.3.2	Comparação dos métodos de inferência	49
4.4	Comparando o tempo de atualização do estado de crença	57
4.5	Análise dos métodos de inferência	59
4.5.1	Análise dos métodos de inferência separados	59
4.5.2	Método de inferência é significativo?	62
4.6	Considerações finais	62
5	Conclusões	67
	Referências Bibliográficas	71
	Apêndice A Análises dos métodos de inferência	75
A.1	Inferência exata uniforme	75
A.1.1	Perturbação no RSSI x estimador x intervalo	75
A.1.2	Perturbação no RSSI x estimador	76
A.2	Inferência exata normal	77
A.2.1	Perturbação no RSSI x estimador x intervalo	77
A.2.2	Perturbação no RSSI x estimador	78
A.3	Filtro de partículas com distribuição normal	79
A.3.1	Perturbação no RSSI x estimador x intervalo	79

A.3.2	Perturbação no RSSI x estimador	80
A.4	Perturbação no RSSI x estimador x métodos	81
Apêndice B Modelos de propagação de sinal		85
Apêndice C Atenuação do sinal relacionado à PathLoss, Shadowing e MultiPath		89
Apêndice D Prova de conceito		93
D.1	Especificações do hardware	93
D.2	Especificações de software	94
D.3	Aquisição do RSSI	94
D.4	Os resultados de localização de nós sensores	95
Apêndice E AMCL - Algoritmo de Localização Monte Carlo Adaptativo		97

Capítulo 1

Introdução

Esta dissertação trata do problema enfrentado por um robô autônomo móvel ao localizar nós sensores de uma rede sem fio utilizando somente a medida da potência do sinal de rádio recebida, RSSI, que é caracterizada pela localização do emissor (posição do nó sensor) e a localização do receptor (posição do robô) no ambiente. O presente trabalho é um passo inicial em direção a um modelo para o problema de localização sequencial probabilística utilizando RSSI, que pode ser estendido para acomodar, dentro de um mesmo *framework*, localização de nós sensores e de robôs.

As Redes de Sensores Sem Fios (RSSF) estão ganhando espaço devido à aplicabilidade imediata numa variedade de domínios. No âmbito militar, ambiental, civil e empresarial existem aplicações que precisam fazer o sensoriamento de grandes áreas, tornando impraticável a utilização de cabos para interligar os vários nós sensores, justificando o uso das tecnologia sem fio. Além disso, condições do ambiente, tal como a presença de árvores, podem interferir ou mesmo impedir a recepção do sinal do *Global Positioning System* (GPS). Outro motivo para a localização precisa dos nós sensores é o crescente uso de robôs móveis para a coleta dos dados que dependem da posição confiável do nó sensor para definir uma rota adequada de coleta. Outro exemplo de utilização da localização dos nós em RSSF é o uso das etiquetas de *Radio-Frequency Identification* (RFID) (Finkenzeller et al. [2010]) de baixo custo, entre 1 e 100 reais, que emitem um sinal de rádio para identificação. Num futuro próximo, etiquetas se tornarão ubíquas e presentes em locais como paradas de ônibus, caixas de correios e contêineres (Figura 1.1). Assim, se precisarmos chegar em algum desses locais, o sinal de rádio pode ser utilizado para localizá-lo. Essas etiquetas RFID também podem ser costuradas nas roupas (Figura 1.2). Assim, pessoas que ficaram sob escombros podem ser encontradas após terremotos, incêndios e outros desastres.

Liu et al. [2007] fornecem outros exemplos onde a localização baseada em RSSI

poderia ser aplicada, tais como, a localização de produtos em armazéns, localização de pessoal médico e equipamentos em hospitais, localização e detecção de bombeiros em estruturas em chamas, detecção e localização de cães policiais treinados para encontrar explosivos em instalações e localização de ferramentas e equipamentos ao longo de uma fábrica.



Figura 1.1. Caixa reusável com etiquetas RFID reprogramáveis produzida pela LogiData [2007]. A identificação do conteúdo e localização da caixa podem ser feitas através do sinal de rádio emitido pela etiqueta.



Figura 1.2. Meias com etiquetas RFID BlackSocks [2012]. O usuário distingue diferentes pares de meias e acha-as em seu quarto, guarda-roupa ou mala rapidamente.

Muitas destas aplicações necessitam associar corretamente a posição física do nó sensor à informação gerada, como por exemplo na coleta de informações ambientais por nós sensores de baixo custo sobre uma área. Mesmo que os nós sensores sejam

equipados com receptores GPS, sua estimativa de localização poderá ter uma incerteza da ordem de dezenas de metros. Apesar da localização por RSSI ser possível, há alguns desafios devidos à baixa qualidade da medida real do sinal. O ruído na medida do sinal é influenciado por campos eletromagnéticos produzidos por equipamentos elétricos, tais como computadores, lâmpadas fluorescentes e motores. A reverberação do sinal (multi-caminho) é também grande devido à reflexão e absorção do sinal causada por superfícies, como paredes e pessoas, presentes no ambiente. Além disso, a localização da posição da fonte do RSSI requer várias medidas de diferentes posições do robô.

É desafiador recuperar a localização exata de um nó sensor, pois o ambiente pode ser muito complexo para ser modelado com seus detalhes. Nesse sentido, um robô móvel que possui um sistema de localização preciso, baixo erro de localização, pode ser utilizado na localização aproximada desses nós sensores. Visto que, apesar dos sistemas de localização de robôs móveis terem evoluído com adição de novos sensores e técnicas de localização, as incertezas sobre os dados do conjunto de sensores internos do robô ainda persistem. Portanto, para mitigar a complexidade do ambiente e as incertezas dos sensores do robô, afim de localizar nós sensores, o uso de um modelo probabilístico sequencial pode ser uma solução viável.

A principal motivação de localizar nós sensores na maioria das aplicações é que os dados produzidos só fazem sentido se vinculados à localização do nó sensor. Na Figura 1.3 é mostrada a importância da vinculação da localização dos dados com a localização dos nós sensores, onde a correta associação de um recurso a um evento depende estritamente da posição dos nós sensores que registram a situação.

Quando o problema a ser resolvido é localização, a primeira ideia é utilizar um dispositivo largamente difundido chamado GPS. No entanto, seu uso está limitado a ambientes que possuam visadas entre a unidade que se deseja localizar e os satélites (Kurth et al. [2003]). Ou seja, construções subterrâneas, construções subaquáticas, estruturas no ambiente e até mesmo folhagens comprometem essa visibilidade.

Uma alternativa para o GPS é o uso de rádio frequência (Liu et al. [2007]). A utilização do RSSI calculado a partir do sinal de rádio é uma maneira de localizar nós sensores utilizando uma infraestrutura de baixo consumo e custo, e robusta a problemas de falta de visadas.

1.1 Definição do problema

O problema abordado nesta dissertação é a localização de nós sensores baseada em RSSI dado um ambiente estático, com um mapa conhecido *a priori*, supondo-se nenhum

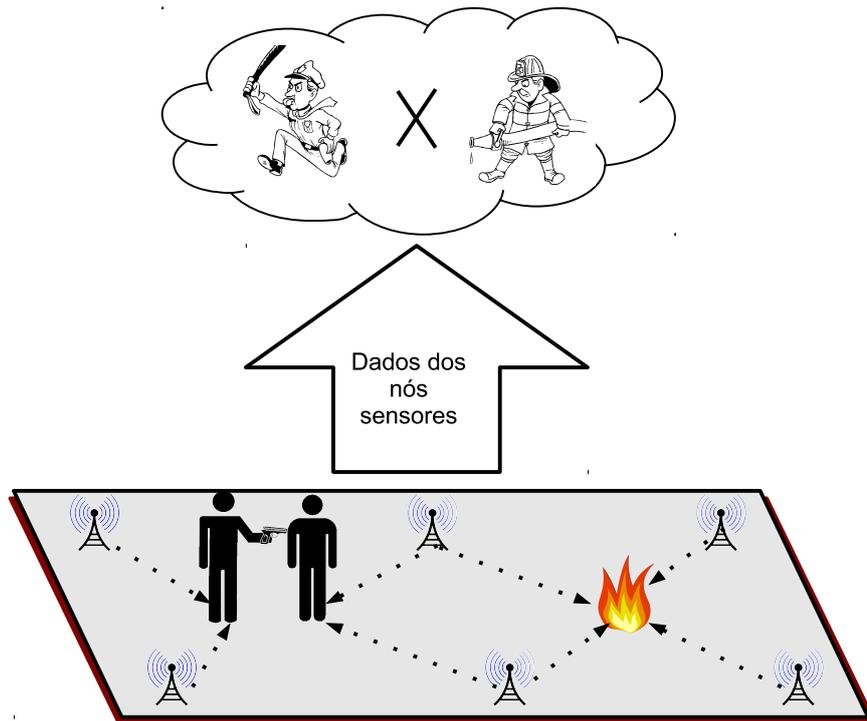


Figura 1.3. Acima, é possível identificar duas situações, incêndio e assalto, onde cada uma delas necessita uma ação específica. Das duas ações possíveis, chamar um bombeiro ou um policial, é preciso saber onde os nós sensores estão para determinar a melhor associação entre situação e ação. Se a associação do recurso necessário for errada, pode resultar em péssimos resultados e desperdício de recursos.

conhecimento inicial sobre a posição dos nós sensores, um robô com posição conhecida que percorre um caminho pré-definido, e o recebimento do sinal de rádio advindo de um emissor, cuja identificação está embutida no sinal, ao longo do caminho percorrido pelo robô.

1.2 Objetivos

Os objetivos deste trabalho são:

1. Propor um modelo probabilístico que integre as incertezas provenientes da utilização do RSSI na localização de nós sensores.
2. Resolver o modelo de forma eficiente.
3. Avaliar diferentes cenários:
 - a) Variação do intervalo de aquisição das amostras de RSSI.

- b) Variação na perturbação do sinal de rádio no erro de localização.
- c) Nós sensores localizados em diferentes posições do cenário.
- d) Utilização de métodos alternativos de inferência.
- e) Utilização de estimadores diferentes.

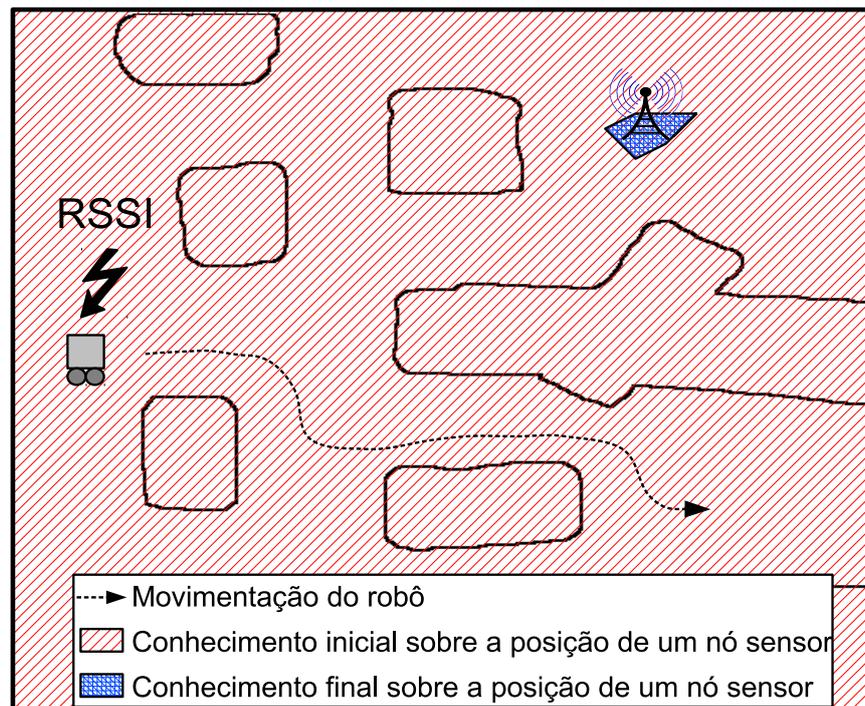


Figura 1.4. No problema da localização de um nó sensor através do RSSI assume-se que o nó pode estar em qualquer lugar do mapa, linhas vermelhas, e objetivo é obter uma crença final sobre a posição do nó sensor, hachurado azul, que nos permita estimar a posição do mesmo.

1.3 Contribuições

As principais contribuições do presente estudo são um modelo gráfico probabilístico para localização simultânea entre robô e nós sensores (também chamado de modelo geral) e dois modelos para localização de nós sensores, um que utiliza posição do robô conhecida e outro que utiliza posição do robô incerta. O modelo *Hidden Markov Model* (HMM) (Thrun et al. [2005]) para localização simultânea foi definido para integrar várias fontes de incerteza – sinal do nó sensor, sensores e atuadores do robô – com objetivo de definir uma função de densidade de probabilidade sobre a posição dos nós sensores e do robô usando inferência Bayesiana. No entanto, somente o problema

de localização de nós sensores foi abordado neste primeiro momento. Então, dois modelos HMMs com o objetivo de gerar um estado de crença para localização de nós sensores foram estabelecidos a partir do modelo geral: um que não integra as incertezas da posição do robô e é conhecido por modelo de localização que utiliza uma posição conhecida do robô, e outro que adiciona a incerteza da posição do robô ao processo de localização dos nós sensor, conhecido como modelo de localização de nós sensores com posição de robô incerta.

Secundariamente, outras contribuições foram surgindo durante o desenvolvimento do estudo, tais como: o modelo de observação com distribuição uniforme, parâmetros dos modelos, análise estatística de alguns fatores que afetam a localização e, futuramente, a disponibilização dos módulos do *Robot Operational System* (ROS) para efetuar localização de nós sensores.

Um modelo de observação utiliza um modelo de propagação de sinal que integra a amostra de RSSI e o ruído, difícil de especificar, presente para definir a distância entre o emissor e o receptor. Então, o modelo de observação com distribuição uniforme, descrito no artigo Carvalho et al. [2012], descreve a utilização de uma distribuição uniforme para estabelecer a relação dessa distância.

Informações importantes sobre as características do sinal, como decaimento da potência do sinal a uma certa distância do emissor, conseqüentemente são parâmetros do modelo de propagação e da distribuição e serão parte das contribuições. O resultado da análise estatística realizada com esses fatores aplicados aos experimentos mostra quais destes influenciam na localização de nós sensores, conseqüentemente isso é outra contribuição.

Um módulo de localização de nós sensores escrito em C++ para a plataforma ROS foi desenvolvido. Este utiliza os HMMs de localização propostos e o RSSI calculado em diferentes posições que o robô esteve durante um caminho pré-definido para realizar a localização dos nós. No entanto, apesar de estar em estágio inicial de desenvolvimento, este módulo pode vir a ser liberado para a comunidade da robótica e redes de nós sensores no intuito de fomentar pesquisas na mesma área por outros pesquisadores.

1.4 Organização da dissertação

Este trabalho está organizado da seguinte forma: O Capítulo 1 faz uma introdução sobre o problema de localização de nós sensores e descreve os objetivos do estudo. No Capítulo 2, uma revisão sobre localização utilizando nós sensores e localização a partir de redes de sensores sem fios é feita. Logo após, alguns trabalhos que utilizam alter-

nativas probabilísticas e RSSI para localização são descritos e discutidos. No Capítulo 3 é apresentada a metodologia desenvolvida para o nosso arcabouço. No Capítulo 4, são apresentados a análise estatística dos resultados obtidos nos experimentos e a comparação dos mesmos. Finalmente, no Capítulo 5, apresentamos as conclusões finais e direções para pesquisas futuras.

Capítulo 2

Fundamentação e Trabalhos Relacionados

O tema localização de nós sensores de uma RSSF já vem sendo estudado há algum tempo e, conseqüentemente, abordagens com diferentes características surgem. As características de cada abordagem determinam onde essa será encaixada dentro de alguma taxonomia existente na literatura. No presente trabalho, a taxonomia adotada é a proposta por Chandrasekhar et al. [2006] devido à sua abrangência e clareza. Nesse sentido, o atual capítulo começará descrevendo e exemplificando na Seção 2.1 os tipos de abordagens para localização de nós sensores de uma RSSF definidas na taxonomia adotada, cujos critérios de classificação são descritos e discutidos. Logo após, na Seção 2.2, alguns trabalhos relacionados à localização de nós sensores são descritos. Dando ênfase à explicação e discussão dos trabalhos que relacionam probabilidade, sinal de rádio e localização, que são os principais enfoques do presente trabalho.

2.1 Taxonomia para localização de nós sensores

A taxonomia divide os algoritmos de localização livres de distância (*Range-Free*) e baseados em distância (*Range-Based*). Quando o algoritmo de localização é livre de distância, este utiliza normalmente a informação sobre área ou número de saltos entre sensores. Os algoritmos de localização baseados em distância utilizam a informação de distância ou variação de posição. Em prol da localização, alguns algoritmos utilizam âncoras para se localizar. Estas âncoras, também chamadas de nós de referência, são nós cuja localização é conhecida e fornecem ao sistema de localização uma referência para a localização de outros nós. Na Figura 2.1 é mostrada a taxonomia proposta por *Chandrasekhar* dos algoritmos de localização de nós sensores numa RSSF.

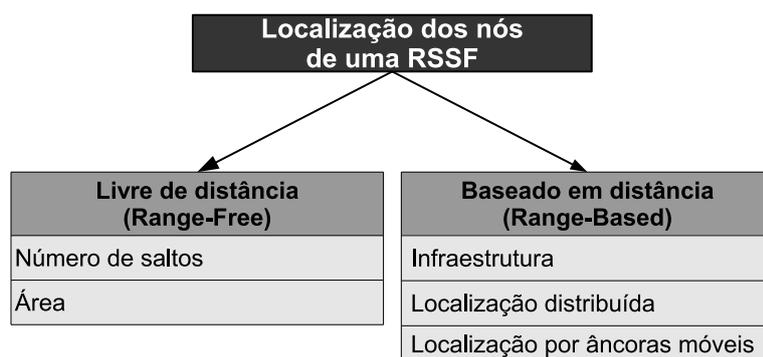


Figura 2.1. A taxonomia para sistemas de localização de nós sensores de uma RSSF proposta por Chandrasekhar et al. [2006].

2.1.1 Localização livre de distância

Os algoritmos de localização livres de distância podem ser classificados em baseados em número de saltos e área. São geralmente usados quando a aplicação não necessita de uma grande precisão na localização dos nós sensores.

2.1.1.1 Número de saltos

Nos algoritmos baseados em número de saltos entre nós, os nós âncoras são colocados nos cantos ou ao longo dos limites de uma grade quadrada. Com os nós âncoras em suas devidas posições, é realizada uma troca de vetores de distância de modo que todos os nós na rede obtenham as distâncias, em número de saltos, para os nós âncoras. Cada nó mantém uma tabela e troca atualizações apenas com os nós vizinhos. Uma vez que um nó âncora recebe as distâncias para outros pontos de referência, ele estima uma distância média de um salto, que é propagada como uma correção para toda a rede. Ao receber a correção, um nó estima as distâncias entre ele e os pontos de referência (âncoras). Essas distâncias são utilizadas para localizar o nó sensor. Um dos métodos que representa este tipo de localização é o DV-Hop, mostrado por Niculescu & Nath [2003], e um exemplo da utilização dessa abordagem que utiliza saltos entre nós é ilustrado na Figura 2.2.

2.1.1.2 Área

Em redes de sensores sem fios muito grandes e densas, pode não ser viável ter com precisão a localização exata de cada nó sensor. Uma estimativa grosseira da localização dos nós sensores pode ser suficiente para uma aplicação que não requeira de grande precisão. O *Area Localization Schema* (ALS) utilizado em Yao et al. [2005] e Chandrasekhar & Seah [2007], e o *Approximate Point in Triangle* (APIT) He et al. [2003], são

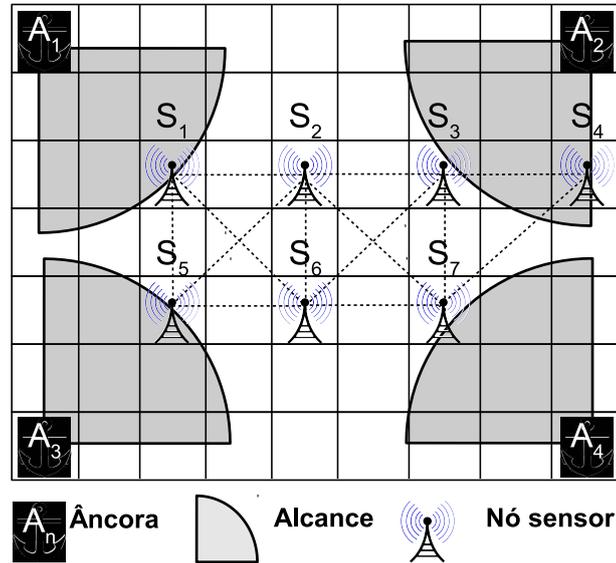


Figura 2.2. Um exemplo da utilização do DV-hop (Niculescu & Nath [2003]). Os nós âncoras são $\{A_1, A_2, A_3, A_4\}$. A troca de vetores de distância, em número de saltos, ocorre entre os nós sensores $\{S_1, S_2, S_3, S_4, S_5, S_6, S_7\}$ para os nós âncoras. O alcance de comunicação, área sombreada, define as tuplas de comunicação, $\{A_1, (S_1)\}$, onde a âncora A_1 vai comunicar com S_1 , $\{A_2, (S_3, S_4)\}$, $\{A_3, (S_5)\}$ e $\{A_4, (S_7)\}$. Uma vez que uma âncora recebe as localizações e distâncias para outras âncoras, ela estima uma distância média de um salto que é propagada para os nós sensores como uma correção para toda a rede. Essa distância média é utilizada para realizar a localização dos nós sensores.

exemplos de algoritmos baseados em área que representam bem esse tipo de algoritmo de localização.

O ALS é um algoritmo centralizado que fornece uma estimativa da localização de um nó sensor dentro de uma certa área em vez das coordenadas exatas no ambiente. Na Figura 2.3 é representada a geração de áreas menores pela interseção dos sinais de cada âncora.

No processo de localização de um nó sensor baseado em ponto aproximado em triângulo, três âncoras são escolhidas, dentre todas as âncoras que tem seus sinais recebidos por um nó sensor, e é feito um teste para verificar se o nó sensor está dentro da região do triângulo formada por estas três âncoras. O APIT usa a informação RSSI dos sinais para determinar se um ponto está dentro ou fora de um dado triângulo. A

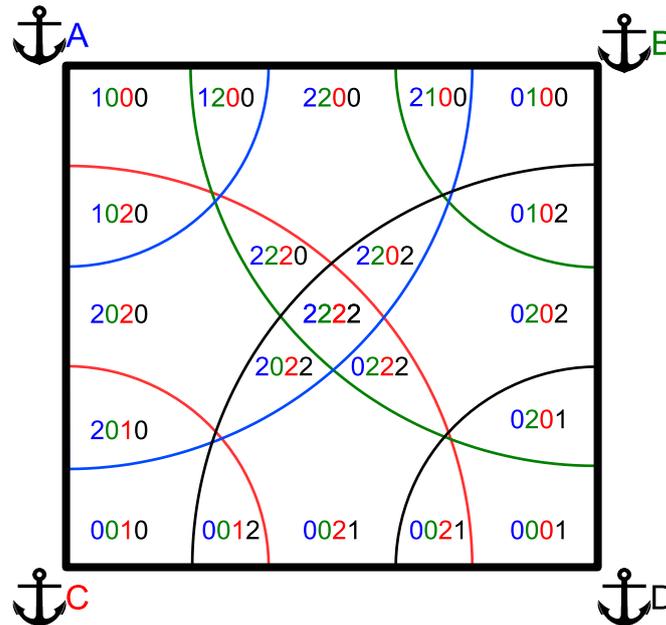


Figura 2.3. No ALS, o ambiente é dividido em áreas menores pela interseção dos sinais de cada âncora. A interseção é representada pelo nível de potência mais baixo a partir de n nós âncoras, formando uma coordenada n -dimensional.

informação é então processada por um servidor central para reduzir a possível área em que um nó de destino reside. No servidor central, diferentes combinações de âncoras com sinais percebíveis pelo nó sensor são testadas até que todas as combinações estejam esgotadas. Resultando na localização do nó sensor, como pode ser visto na Figura 2.4.

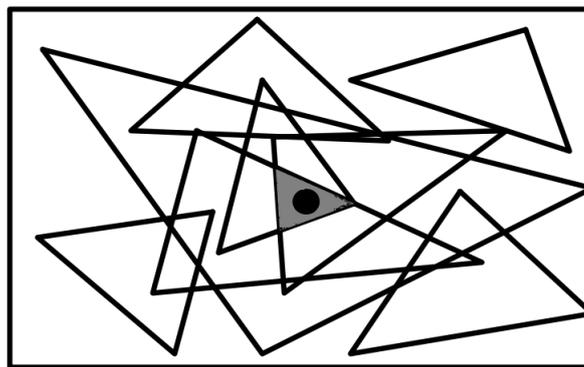


Figura 2.4. No APIT, diferentes combinações de âncoras com sinais percebíveis pelo nó sensor são testadas até que todas as combinações estejam esgotadas e assim resultando na localização do nó sensor. He et al. [2003]

2.1.1.3 Pontos Fracos

A principal desvantagem dos algoritmos livres de distância é fornecer uma estimativa grosseira do local do nó sensor. Além disso, os algoritmos baseados em saltos só funcionam bem quando a RSSF possui uma distribuição de nós sensores uniforme e densa. Se estas condições não forem atendidas, a estipulação da distância do salto acumula erro, resultando numa baixa eficiência do algoritmo. Outra desvantagem comum é a utilização de processamento centralizado para determinar a localização.

2.1.2 Localização baseada em distância

Os algoritmos de localização baseados em distância dependem de medidas precisas de distância ou dos ângulos da linha de visada do sinal para estimar a localização de um nó sensor numa RSSF. Existem várias abordagens para calcular essas medidas, as mais comuns utilizam *Time of Arrival* (ToA), *Time Difference of Arrival* (TDoA), *Angle of Arrival* (AoA) ou RSSI. Uma abordagem baseada em distância pode ser, segundo a taxonomia de *Chandrasekhar*, baseada em infra-estrutura, localização distribuída e localização por âncoras móveis.

2.1.2.1 Infraestrutura

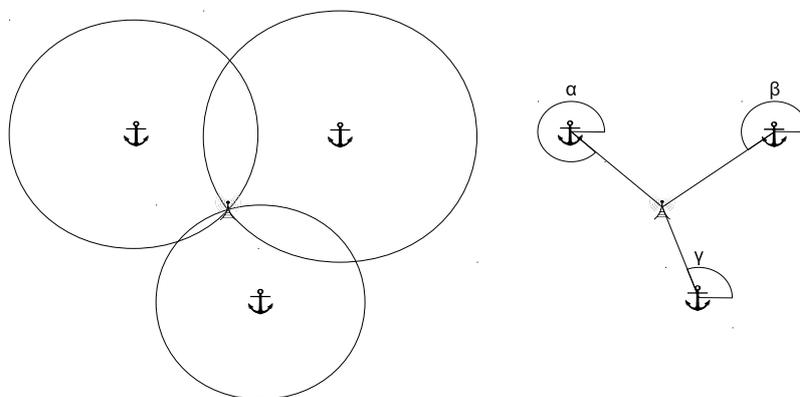


Figura 2.5. O processo de localização de nós sensores por infraestrutura utiliza as âncoras que foram posicionadas em posições conhecidas no ambiente para fazer a localização. Para localizar algum nó sensor basta realizar, por exemplo, uma triangulação ou angulação com as âncoras. No lado esquerdo é mostrado o esquema de localização por triangulação, que utiliza distância, baseado em infraestrutura. No lado direito está o esquema de localização por angulação, que utiliza ângulos, baseado em infraestrutura.

Sistemas de localização baseados em infraestrutura funcionam de forma similar ao GPS. Ou seja, uma infraestrutura prévia é disponibilizada no ambiente na forma

de um conjunto de âncoras com posições conhecidas e dada essa infraestrutura, em conjunto com outra informação como a distância ou ângulo de chegada do sinal, a localização dos nós sensores é realizada.

2.1.2.2 Localização distribuída

Na localização distribuída (Figura 2.6) os nós são capazes de se comunicar com outros nós que estão a um salto deles e computar suas distâncias entre si, e com as múltiplas distâncias, ou ângulos, de nós conhecidos, então a localização do nó com posição desconhecida é realizada.

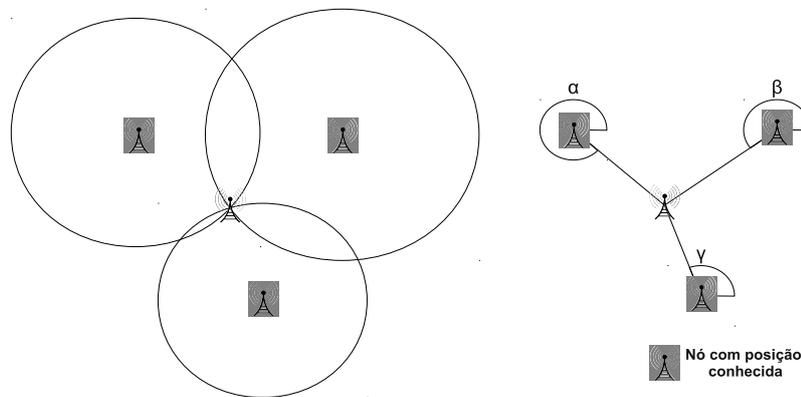


Figura 2.6. O processo de localização de nós sensores por localização distribuída utiliza outros nós sensores que tem posições conhecidas no ambiente. Para localizar algum nó sensor basta realizar, por exemplo, uma triangulação ou angulação com os nós com posição conhecida. No lado esquerdo é mostrado o esquema de localização por triangulação, que utiliza distância e usa a localização de outros nós como referência. No lado direito está o esquema de localização por angulação, que utiliza ângulos relativos entre os nós de referência.

Algoritmos de localização distribuída geralmente são aplicados no caso de não existir a possibilidade de criar uma infraestrutura para que seja feita a localização. Este tipo de algoritmo é chamado na literatura por *anchor-free*. Algoritmos de localização distribuída geralmente possuem três fases: a fase de estimativa da distância, onde os nós estimam as distâncias para os seus vizinhos mais próximos utilizando RSSI ou medições ToA, a fase de estimação de posição, em que um sistema de equações lineares é geralmente resolvido utilizando uma abordagem de mínimos quadrados para calcular a posição do nó, e uma fase de refinamento onde a precisão do algoritmo é melhorada através da utilização de um algoritmo iterativo.

2.1.2.3 Localização por âncoras móveis

No posicionamento que utiliza âncoras móveis (Figura 2.7) uma âncora móvel percorre um caminho dentro da região onde há uma rede de nós sensores e ao longo do caminho a âncora móvel faz um *broadcast* de pacotes que contêm suas coordenadas.

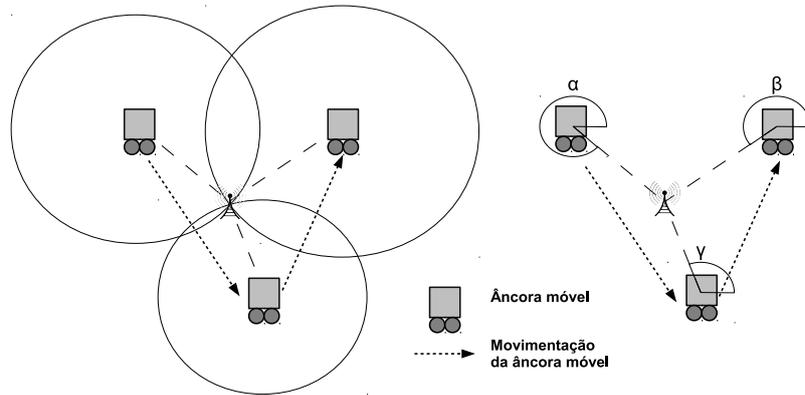


Figura 2.7. O processo de localização de nós sensores por âncoras móveis. No lado esquerdo é mostrado o esquema de localização por triangulação, que utiliza distância e usa a localização das âncoras móveis como referência. No lado direito está o esquema de localização por angulação, que utiliza ângulos relativos entre as âncoras móveis. Na figura, o robô, âncora móvel, e o tracejado representa a mensagem do *broadcast* da posição e os dados necessários da âncora móvel, por exemplo: distância ou ângulo, para que o nó sensor seja localizado ou se localize.

Qualquer nó sensor que receber o pacote será capaz de inferir que ele deve estar em algum lugar próximo da âncora móvel com uma determinada probabilidade. Também há a possibilidade dos nós sensores emitirem um sinal e a âncora móvel inferir a distância desse sinal através do RSSI, e com essa informação a âncora móvel determinar a posição do nó sensor. O RSSI dos pacotes do nós sensores é utilizado para determinar a distância entre o emissor e receptor. Após um certo número de pacotes recebidos, a unidade responsável pelo processamento utiliza algum método de inferência para determinar a localização do nó sensor.

2.1.2.4 Pontos Fracos

É importante notar que essas abordagens também possuem desvantagens. Sistemas que usam ToA sofrem problemas da falta de visadas, o que restringe o funcionamento do algoritmo. Isso acontece geralmente em ambientes internos ou ambientes que contém objetos (pessoas, animais e portas) que atrapalham a propagação de sinal. No entanto, sistemas baseados em RSSI têm a desvantagem de fornecer uma precisão de poucos metros. Porém, em relação as outras formas de determinar a distância, o RSSI traz a

vantagem de sofrer menos com a falta de visadas, pois é possível determinar a distância se não houver problemas severos de propagação do sinal de rádio.

Outro problema nos sistemas baseados em ToA ou TDoA é a necessidade de sincronização de tempo entre os relógios dos dispositivos envolvidos no sistema de localização. A latência do sinal é um fator importante a ser considerado, pois algoritmos de sincronização de tempo em RSSF e a exatidão de algoritmos de localização são imprescindíveis para essas abordagens. A latência é uma medida aproximada que estabelece o intervalo de tempo que o sinal sai do emissor e chega ao receptor. Uma das causas da variação da latência do sinal, geralmente aumentando, é a presença de objetos no ambiente. Em algoritmos baseados em ToA ou TDoA, os relógios das unidades envolvidas precisam estar sincronizados, mas a sincronização torna-se imperfeita com a variação da latência, conseqüentemente, resultando em erros de localização.

Algoritmos baseados em AoA necessitam de um equipamento especial, pois os nós sensores e os nós referência precisam estar equipados com uma antena receptora direcional, que deixa o custo do sistema alto.

2.2 Localização, probabilidade e sinal de rádio

Esta seção apresenta alguns trabalhos que estão relacionados à localização utilizando sinal de rádio e modelos probabilísticos. Na implementação de sistemas de localização baseados em RSSF é importante ter uma consideração especial com a variação de sinal e as demais incertezas, fatores como sombreamento de sinal, multi-caminho, custo, topologia e hardware, possuem efeitos que podem ser modelados na localização. Alguns trabalhos que descrevem as incertezas do processo e que foram encontrados na literatura são descritos e enumerados na Tabela 2.1.

Kurth et al. [2003] trata o problema de localização de robôs e nós sensores a partir de uma informação *a priori* conhecida e com ruído sobre a localização de ambas as plataformas. O cenário utilizado neste trabalho foi uma área sem obstáculos onde foram dispostos alguns nós sensores e um robô que percorre um caminho pré-definido entre os nós sensores.

A localização do robô é realizada utilizando um filtro de Kalman que usa *Dead Reckoning*¹ no modelo de predição, que é afetado pelos erros de hodiometria, e um modelo de observação baseado na distância entre o robô e os nós sensores para estimar

¹Em navegação, vem da palavra *Deduced Reckoning*. É o processo de calcular a posição atual pela posição anterior utilizando a velocidade estimada, direção, sentido e o tempo da ação. Em robôs, a posição é estimada com base nas medidas das distâncias percorridas e orientações realizadas por *encoders* de roda e giroscópios.

Tabela 2.1. Alguns trabalhos dentro da taxonomia para localização de nós sensores em uma WSN, proposta em Chandrasekhar et al. [2006]

Tipo de Localização	Característica	Trabalho	Princípio
Livre de distância	Área	Baggio & Langendoen [2008]	Monte Carlo Localization Boxed
Baseado em distância	Infraestrutura e pos. dado âncoras móveis	Kurth et al. [2003]	Kalman
	Pos. distribuído e pos. dado âncoras móveis	Djugash et al. [2008]	Protocolo de mensagens e EKF
	Pos. dado âncoras móveis	Caballero et al. [2008]	Filtro de partículas
		Menegatti et al. [2009]	EKF
		Caballero et al. [2010]	GMM
		Fink & Kumar [2010]	Processos Gaussianos

a posição atual do robô. A atualização da localização de um nó sensor é feita quando o robô recebe uma resposta de um nó sensor, cuja inquirição foi originada do robô. Essa resposta estabelece uma estimativa de distância entre o robô e o nó sensor, onde o erro que foi considerado na medida é gaussiano. Cada estimativa de distância é integrada para uma atualização da localização inicial, que é incerta, de cada nó sensor. Sucessivamente, essa nova informação do nó sensor é integrada no filtro de Kalman para atualização da localização do robô.

Essa abordagem apresenta alguns pontos que serão discutidos. O primeiro ponto é o fato de assumir uma posição inicial conhecida, com alguma incerteza, para os nós sensores. Em problemas reais, isso geralmente não acontece, ou no mínimo, a incerteza é muito maior que a assumida. Outro ponto percebido: o método é avaliado com a utilização de nós sensores que ficam muito próximos ao caminho percorrido pelo robô. Não demonstrando como o método reagiria dado a falta de possibilidade de um caminho perto do sensor. Outro ponto é não haver uma discussão sobre os problemas que afetam o RSSI ou parâmetros do sistema, por exemplo: intensidade do ruído do sinal, intervalo de atualização, etc.

Caballero et al. [2008] propõem um método de localização dos nós sensores numa rede de sensores sem fio utilizando um filtro de partículas. O modelo considera a localização precisa de um robô aéreo, auxiliado por GPS, e a potência de sinal recebido, que é emitido pelos nós sensores da rede, para fazer inferência da posição do nó sensor.

Para obter a localização do robô, este é equipado com um GPS diferencial que fornece sua localização. A potência do sinal recebido é transformada na distância entre o emissor e o receptor através de uma relação pré-calibrada entre a potência do sinal recebido e distância, em outras palavras, um modelo de propagação de sinal. Inicialmente as partículas são distribuídas uniformemente em uma área e a re-amostragem é realizada através de inferência Bayesiana com distribuição normal com média igual a distância proveniente do RSSI e variância definida pela relação RSSI e distância pré-calibrada. O resultado do método pode ser visualizado na Figura 2.8.

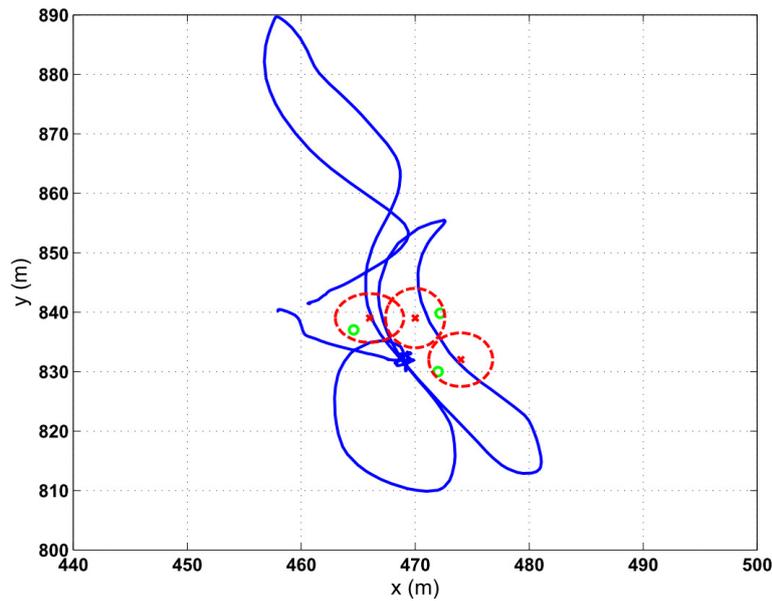


Figura 2.8. O resultado da estimação da posição utilizando o método proposto, onde os pontos verdes são a posição real dos nós sensores, a linha azul é o caminho percorrido pelo robô e as cruces vermelhas são a posição estimada dos nós sensores (Caballero et al. [2008]).

O autor cogita sobre a localização do nó em três dimensões, porém é descrito que é computacionalmente caro, pois representaria um alto custo de memória, impossibilitando a execução do método em tempo real. Outra restrição vem do uso do GPS, ou seja, naturalmente esta abordagem somente funciona em ambientes externos que possuem cobertura de GPS.

Essa abordagem apresenta alguns pontos que serão discutidos. O primeiro ponto é se o caminho executado pelo robô não passasse muito perto da posição real do nó sensor. O segundo ponto aparece quando é descrito o local de estudo, que é um deserto. Neste tipo de ambiente há poucos objetos e conseqüentemente a variação do RSSI é baixa, resultando em variações mais comportadas. Portanto, não foram feitos testes em ambientes com maior perturbação de sinal.

Djugash et al. [2008] apresentam um algoritmo para mapeamento de nós sensores em uma rede de sensores conectados esparsamente usando a potência do sinal e o movimento de um robô móvel. Para isso é utilizado um *Extended Kalman Filter* (EKF) no espaço polar e um protocolo de passagem de mensagens entre os nós sensores. O processo de localização dos nós sensores é realizado em duas partes. Na primeira parte, o robô move-se no ambiente recebendo a informação de potência do sinal e é calculada a distância entre ele e os nós sensores através de um modelo de propagação. Então a distância calculada é usada para inferir a posição dos nós através de um EKF. Na segunda parte, cada nó da rede recebe a estimativa de sua localização e passa uma mensagem, através do protocolo de propagação de mensagem, para os nós vizinhos, de forma que cada nó propague a crença da sua própria posição, atualizando a posição de outros nós sensores. Essa abordagem pode ser classificada como um misto entre localização de sensores através de localizações distribuída e localizações por âncoras móveis. Na Figura 2.9 é mostrado o resultado da abordagem.

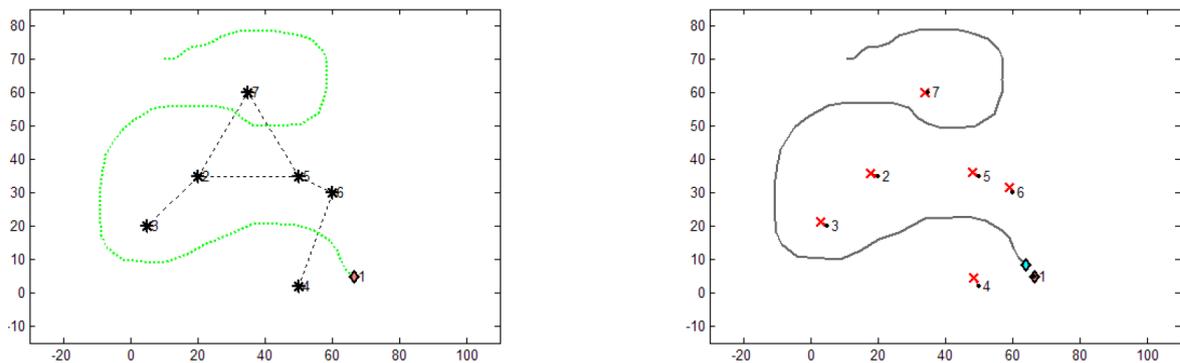


Figura 2.9. A imagem da esquerda mostra as verdadeiras localizações dos nós sensores, representadas por *. Todas as medidas de distância entre os nós (linha preta tracejada) e o caminho que o robô percorreu (linha pontilhada verde). A imagem da direita mostra o erro do resultado do EKF, o caminho estimado do robô (linha cinza e sólida). As cruces vermelhas são as posições estimadas e os pontos pretos as localizações reais dos nós sensores. Extraído de Djugash et al. [2008].

Essa abordagem apresenta alguns pontos que serão discutidos a seguir. O primeiro ponto trata-se do resultado da localização ser obtido a partir de um robô em movimento que executa um caminho que passa próximo aos nós sensores, não mostrando nenhum resultado quando o nó sensor está longe do caminho. Outro ponto notado é não realizar análises de resultados a partir da variação controlada da perturbação no sinal e intervalo de aquisição de amostras de RSSI.

Baggio & Langendoen [2008] propõem um método livre de distância para localização de nós sensores em uma rede de nós sensores baseado em âncoras chamado

Monte Carlo Localization Boxed (MCB). Âncoras são elementos estáticos que sabem com precisão a própria localização. A localização precisa de uma âncora é dada por uma tecnologia de localização, como GPS ou GPS diferencial, que provê a posição de cada âncora posicionada no mesmo ambiente onde os nós sensores estão. O alcance do sinal das âncoras numa determinada posição cria uma zona em formato de caixa, que é construída sobre as regiões onde os sinais de rádio das âncoras se sobrepõem, cujos os vértices são definidos pelas posições das âncoras cujos sinais se sobrepõem, assim delimitando a possível área da localização de um nó sensor. A caixa representa a região onde está localizado o nó sensor e onde as novas estimativas de posição do nó sensor são geradas e filtradas através de um modelo baseado em *Monte Carlo*. O resultado do MCB é a estimação da posição do nó sensor dada pela uma média aritmética das possíveis localizações geradas e filtradas.

Essa abordagem possui dois pontos que chamam atenção, o primeiro é a necessidade de âncoras bem localizadas e bem distribuídas no mapa. Esse requerimento deixa o processo de localização mais caro, pois para obter uma melhor precisão na localização dos nós numa área esparsa é necessário posicionar uma quantidade maior de âncoras com posições conhecidas, conseqüentemente, distribuir essas âncoras de forma otimizada deixa todo o processo mais complexo. O segundo ponto advém da característica do tipo da abordagem, pois como esse método é baseado em área, o resultado apresenta uma incerteza maior de acordo com Chandrasekhar et al. [2006].

Menegatti et al. [2009] apresentam uma abordagem para localizar nós sensores de uma RSSF através de um EKF através do RSSI. A diferença desta abordagem é a integração da posição dos nós sensores no ambiente com a localização do robô móvel que está executando a localização de nós sensores. Inicialmente, o EKF necessita ser inicializado com um primeiro palpite da localização e este é realizado através da trilateração da posição do nó sensor e um método de mínimos quadrados aplicado à interseção das circunferência formadas pela relação RSSI e distância. A localização do robô é feita através da integração dos dados da hodometria no EKF. Após algum tempo, o filtro passa a utilizar a informação da localização estimada dos nós sensores e RSSIs calculados para melhorar a estimação da localização. Também é utilizado um filtro de pré-processamento simples para o RSSI que reduz variações criadas por sombreamento e multi-caminhos de sinal de radio. O resultado desse algoritmo pode ser visto na Figura 2.10.

Essa abordagem apresenta alguns pontos que serão discutidos a seguir. O primeiro ponto é a localização ser feita a partir de um robô que executa um caminho que passa próximo aos nós sensores. Não mostrando nenhum resultado quando o robô não se aproxima do nó sensor. Outro ponto está relacionado ao filtro de pré-processamento

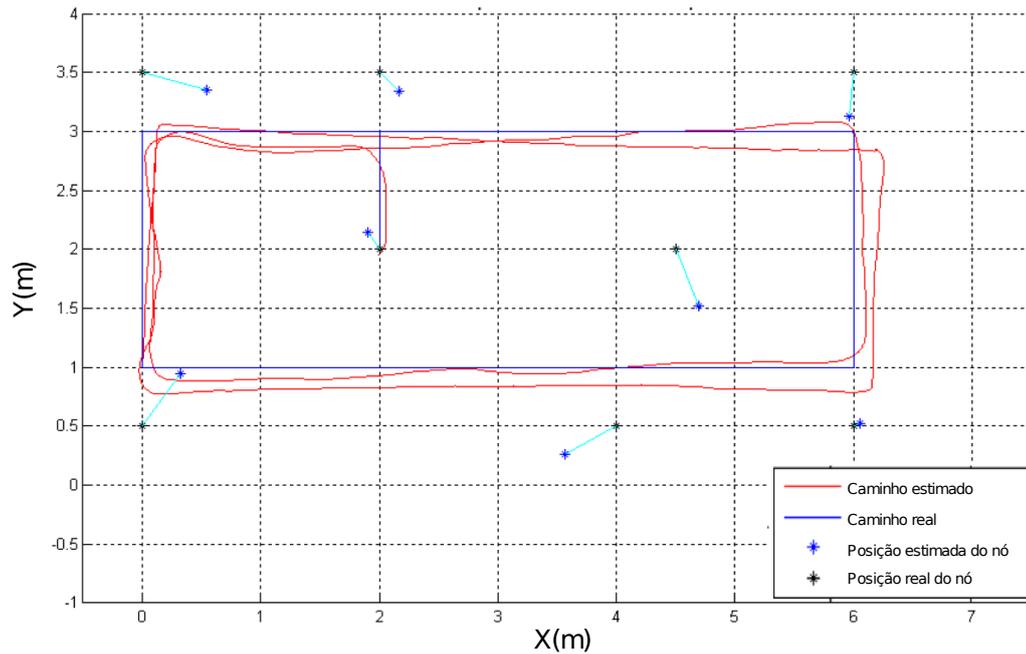


Figura 2.10. A localização do robô foi feita por intermédio da integração dos dados da hodometria do robô num EKF e a informação da localização estimada dos nós sensores e dos RSSIs para melhorar a estimação da localização do robô. Modificado de Menegatti et al. [2009]

simples do RSSI. Esse é baseado no ruído sofrido por um tipo de sinal e ambiente específico, tornando-o condicionado para a situação onde os resultados foram gerados.

Caballero et al. [2010] propôs um método de localização de nós sensores através de uma *Gaussian Mixture Model* (GMM) que usa como observações o RSSI calculado e a localização de um robô móvel. O sistema recebe a posição do robô móvel, que é considerada como precisa, e a distância referente à potência do sinal recebido na posição do robô. Então são definidos k ângulos que vão dividir igualmente o espaço polar de 0 a 2π . É gerado um conjunto de k gaussianas com média no ponto formado na relação $angulo_k vs. distancia_{RSSI}$ com variância inicialmente fixa. Um GMM é criado a partir da k gaussianas e serve para inicializar a *priori* da posição dos nós sensores.

Novas medidas de RSSI serão adquiridas com a movimentação do robô e consequentemente novas gaussianas serão acrescentadas ao GMM. Essas novas gaussianas terão seus pesos alterados de acordo com a equação de verossimilhança que o autor utilizou. Esses novos pesos farão que as hipóteses, representadas por cada k , com menor peso sejam descartadas e as hipóteses com maior peso permanecendo no GMM.

Após algumas observações de RSSI, sobrarão menos hipóteses e estas representam a provável posição onde o nó sensor pode estar. Assim, a GMM é utilizada num filtro de *Kalman* para estimar a localização do nó sensor.

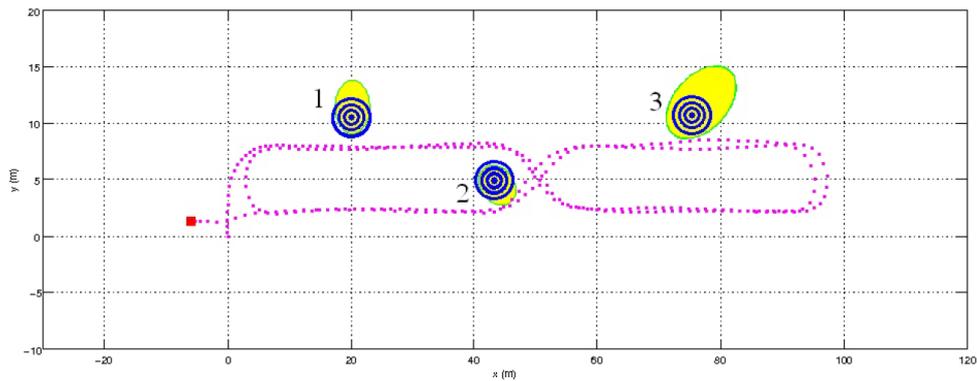


Figura 2.11. O resultado experimental na localização de três nós sensores (pontos azuis) usando um robô móvel (quadrado vermelho)(Caballero et al. [2010]).

Essa abordagem apresenta alguns pontos que serão discutidos. O primeiro ponto, a abordagem não mostra resultados quando o robô executa um caminho que o mantém longe do nó sensor, isso pode ser observado na Figura 2.11. Outro ponto é a não avaliação da influência do ambiente no resultado de localização, pois diferentes ambientes possuem diferentes níveis de perturbação de sinal.

O trabalho proposto em Fink & Kumar [2010] explora um método de mapeamento *online* do RSSI utilizando robôs móveis. O mapeamento é feito através de processos gaussianos que permitem criar uma predição sobre a potência do sinal recebido em regiões que ainda não foram exploradas, resultando num mapa de potência do sinal no ambiente. Conseqüentemente este mapa pode ser usado para determinar a localização da fonte, os nós sensores, através da máxima verossimilhança. As amostras de sinal são integradas ao processo gaussiano atuando na função de verossimilhança e localização da fonte de sinal. Um gradiente é aplicado na função de verossimilhança para mostrar a estimativa de sinal no mapa, mesmo que o lugar não tenha sido visitado.

Essa abordagem apresenta alguns pontos que serão discutidos. O primeiro ponto: não são apresentados resultados quantitativos, tais como, o erro médio de localização dos nós sensores ou variância do mesmo. Outro ponto é não comparar o mapa gerado pelo método, como também o resultado de localização do nó sensor, com algum resultado de outro método ou até mesmo de um valor esperado que é o resultado de uma simulação.

A partir da análise dessa pequena parte da literatura é possível perceber que há algumas possíveis extensões que poderiam ser abordadas. Dentre essas extensões, podem ser citadas: 1) a não suposição de informação inicial sobre as posições dos nós sensores. Geralmente essa informação não é disponível em boa parte das aplicações. 2) A maioria dos trabalhos que realizam a localização de nós sensores pré definem uma

rota para o robô que faz com que esse se aproxime da posição real dos nós sensores, porém, ao se aproximar do nó sensor, uma tendência de maior acerto da posição é criada, pois há uma menor perturbação do sinal devido à redução de objetos e estruturas que deterioram o sinal de rádio. Como nem sempre é possível criar uma rota com essa característica, geralmente por obstruções no ambiente, a opção seria mostrar os resultados de localização de nós que permaneceram em diferentes distâncias da rota do robô, seja por distância mínima, média e máxima que o robô permaneceu do nó sensor. 3) Outra possível extensão é realizar uma análise dos resultados com diferentes taxas de amostragem de RSSI. Nesse sentido, seria possível verificar se o método de inferência de posição de nó sensor tem melhor resultado com taxas mais altas de amostragem de RSSI, demonstrando se compensa o uso de maior processamento. 4) Outra contribuição seria a aplicação dos diferentes métodos de localização em ambientes, cuja perturbação no RSSI fosse controlada. Isso poderia ser feito através de ambientes simulados e demonstraria a resiliência da abordagem de localização em diferentes situações. 5) Os resultados mostrados nas Figuras 2.10(Menegatti et al. [2009]) e 2.11(Caballero et al. [2010]) foram criados em ambientes muito menores que os outros trabalhos. É interessante verificar se o resultado de qualquer abordagem de localização é eficiente em ambientes maiores, cujos nós sensores estão em posições mais esparsas e, conseqüentemente, avaliar quando há maiores perturbações no RSSI.

Certamente, essas são algumas extensões que tornariam a avaliação de abordagens para localização de nós sensores mais interessantes.

Capítulo 3

Metodologia

Neste capítulo descrevemos a metodologia para integrar as incertezas do problema de localização dos nós sensores. Para isso, o modelo probabilístico de localização estabelece as relações entre as diversas observações e variáveis aleatórias envolvidas no problema. Na solução, foram consideradas diferentes modelagens para a verossimilhança do sinal, principal foco deste trabalho, e diferentes técnicas de inferência.

Este capítulo é organizado da seguinte forma: Na Seção 3.1 é apresentado o modelo geral do problema, as alternativas para o cálculo da verossimilhança e a arquitetura probabilística da solução. Na Seção 3.2 são apresentadas as formulações dos dois modelos gráficos probabilísticos utilizados na localização de nós sensores. Na Seção 3.3 são descritos os métodos de inferência utilizados na atualização do estado de crença da localização do nós sensores.

3.1 Definição do modelo

Os modelos gráficos probabilísticos são uma ferramenta que serve para modelar situações complexas que envolvam aleatoriedade ou incerteza utilizando uma estrutura matemática que une grafos e probabilidade. Os nós do grafo representam variáveis aleatórias do problema que se tenta modelar e as arestas entre os nós definem a dependência condicional entre as variáveis.

O modelo proposto para resolver a localização simultânea de um robô e nós sensores é um modelo gráfico probabilístico chamado *Hidden Markov Model* (HMM), que permite modelar, fazer inferências e aprender em domínios estocásticos. No HMM, a medida de uma variável aleatória depende estocasticamente do estado não observável do sistema no tempo t (Thrun et al. [2005]).

O HMM é definido por um conjunto de estados não diretamente observáveis, um conjunto de medidas, e duas funções probabilísticas: o modelo de observação, também chamado modelo de verossimilhança, e o modelo de transição. O modelo de observação captura os aspectos importantes do problema de localização baseada em RSSI, já que relaciona o nível do sinal, as posições do nó sensor e do robô móvel. O modelo de transição captura as características sequenciais do problema relacionando o estado do tempo $t - 1$ para o t . A vantagem de utilizar modelos gráficos probabilísticos no problema de localização é a possibilidade de manter várias hipóteses alternativas para o estado atual desconhecido que são sintetizadas pela distribuição de probabilidade resultante.

No modelo geral, ilustrado na Figura 3.1, o estado do sistema no tempo t , X^t , é composto por $\{X_R^t, X_{1\dots m}\}$ que é a posição do robô no tempo t , X_R^t , e as posições fixas dos m nós sensores, $X_{1\dots m}$. As observações, também chamadas de evidências, são as leituras dos dados dos sensores de localização do robô O^t e as amostras de RSSIs $S_{1\dots m}^t$ dos m nós sensores.

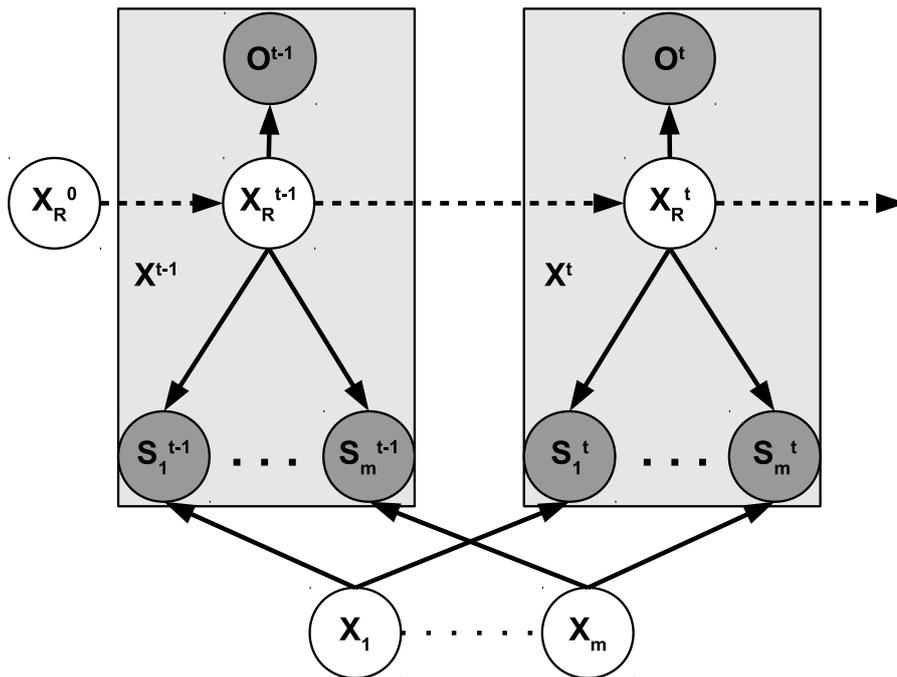


Figura 3.1. O modelo gráfico probabilístico para localização simultânea entre um elemento móvel e os nós sensores. Onde X_R^t é a posição do elemento móvel – um robô – no tempo t , O^t são as observações dos sensores do robô, X_m e S_m^t são, respectivamente, a posição do nó sensor e o RSSI recebido pelo robô de um nó sensor m .

O objetivo inicial deste arcabouço era determinar a posição X_R^t do robô móvel R e, simultaneamente, as posições $X_{1\dots m}$ dos nós sensores $1\dots m$. Porém, ao invés

de inicialmente abordar o problema mais complicado de localização simultânea, foi escolhido quebrá-lo e somente abordar o problema de localização de nós. A partir deste modelo do objetivo original, dois modelos, que serão descritos nas Subseções 3.2.2 e 3.2.3, foram criados. O primeiro utiliza uma rede Bayesiana muito simples, pois a posição X_R^t do robô R é considerada observável, logo, independente do estado anterior. No segundo modelo, a posição X_R^t de um robô móvel R não é observável diretamente e a localização do robô no ambiente tem um modelo gráfico probabilístico constituído por uma rede Bayesiana que relaciona a posição dos nós sensores $X_{1\dots m}$, os RSSIs $S_{1\dots m}^t$ e as observações \mathbf{O}^t , que são os dados obtidos com os sensores de localização internos do elemento móvel.

O processo evolui em ciclos indexados por t . A cada ciclo, R atualiza sua posição X_R^t por algum sistema de localização que usa os sensores internos. Calcula o RSSI S_m^t a partir do sinal recebido emitido por um sensor m . R realiza uma inferência da posição não observável do nó sensor X_m partir dessas informações, utilizando um modelo probabilístico, sintetizando um estado de crença definido em $b^t(X_m)$.

Este processo é ilustrado na Figura 3.2, onde é apresentada uma evolução em três ciclos. O robô R move-se no ambiente para adquirir outras observações do RSSI em diferentes localizações. Consequentemente, o estado de crença $b^t(X_m)$ sobre a posição X_m do nó sensor m começa a se formar a partir das interseções dos estados de crenças prévios $b^{t-1}(X_m)$ derivados das amostras anteriores de RSSI.

As composições das distribuições de probabilidade formam estas áreas de interseção e resultam em algo similar à forma mostrada na Figura 3.2. A posição inferida do nó sensor X_m é definida como a posição esperada dado o estado de crença atual.

O RSSI S_m^t de um nó sensor de índice m é modelado por uma função de propagação de sinal de rádio (Equação 3.1) chamada *Path-loss governing the radio propagation*¹. Esta função, primeiramente descrita na literatura em Rappaport [1996] e adaptada em outros trabalhos, é definida como:

$$S_m^t = L_0 - 10\psi \log \left(\frac{\mu}{D_0} \right) - f(X_m, X_R^t) - \epsilon(X_m, X_R^t) \quad (3.1)$$

onde X_m é a posição do nó sensor m , S_m^t é a potência do sinal calculada no tempo t , X_R^t é a posição do receptor de rádio do robô móvel, L_0 é a potência medida a D_0 metros da fonte do sinal, ψ é o coeficiente de atenuação do sinal ao longo da distância, μ é distância entre o emissor e o receptor do sinal, definida por $\|X_m - X_R^t\|$. As incertezas no RSSI são representadas no modelo por ϵ , a incerteza causada pela perda

¹Maiores detalhes sobre funções de propagação de sinal de rádio, consultar o Apêndice B.

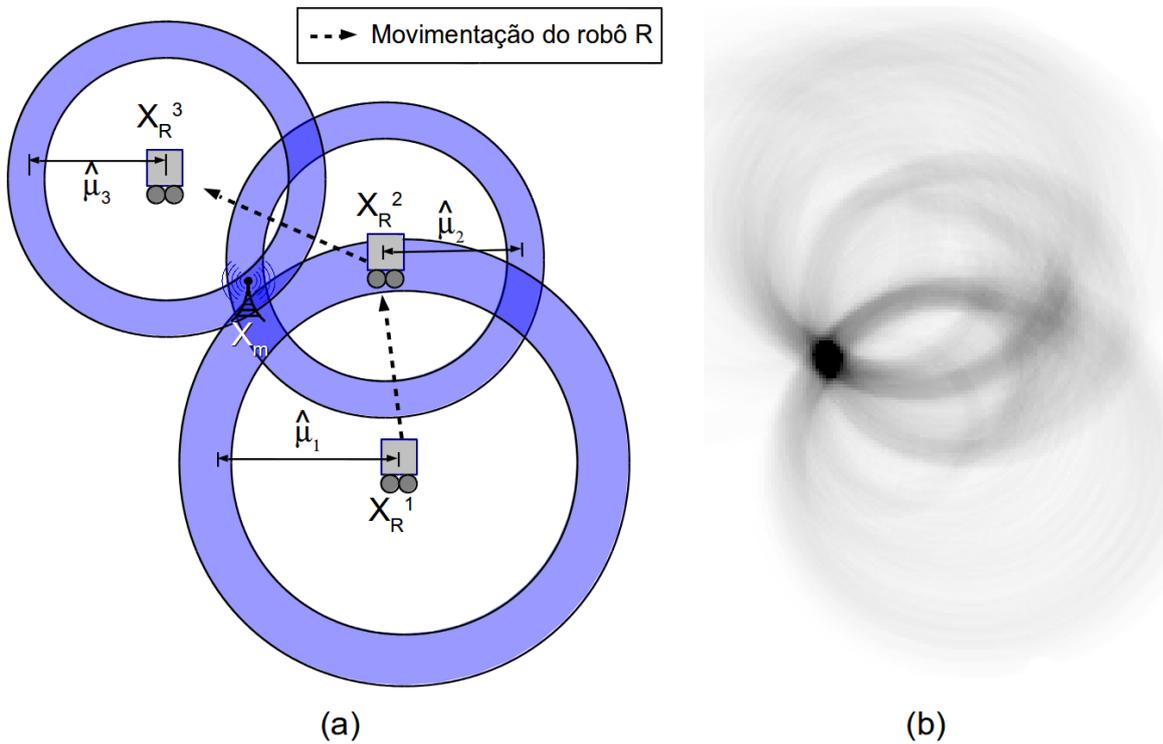


Figura 3.2. Na Figura (a) é ilustrado a interseção de regiões formadas pela movimentação do robô e aquisição de novas amostras de RSSI. Estas amostras criam distribuições de probabilidade da posição do nó sensor, Figura (b). As composições de várias distribuições de probabilidade formam regiões probabilisticamente densas, resultando no estado de crença da posição do nó sensor.

de potência do sinal devido à reverberação (multi-caminho) do sinal, e f , que modela a perda de potência do sinal devido ao sombreamento causado por estruturas e objetos no ambiente.

Dentro dos HMMs do arcabouço existe um fluxo de informação, exibido na Figura 3.3, que define o seu funcionamento diante de cada problema abordado.

3.1.1 Modelos de observação para RSSI

A dificuldade da localização de nós sensores utilizando RSSI está na modelagem da forma de observar esta medida e ao mesmo tempo tratar os possíveis problemas de propagação de sinal. É necessário incorporar estas incertezas numa função de medida de sinal com o objetivo de minimizar o impacto causado por esses problemas. No presente trabalho são utilizados dois modelos: um modelo de observação com distribuição uniforme, descrito em nosso trabalho anterior Carvalho et al. [2012], e um modelo de observação com distribuição normal. O modelo de observação, ou modelo de verossi-

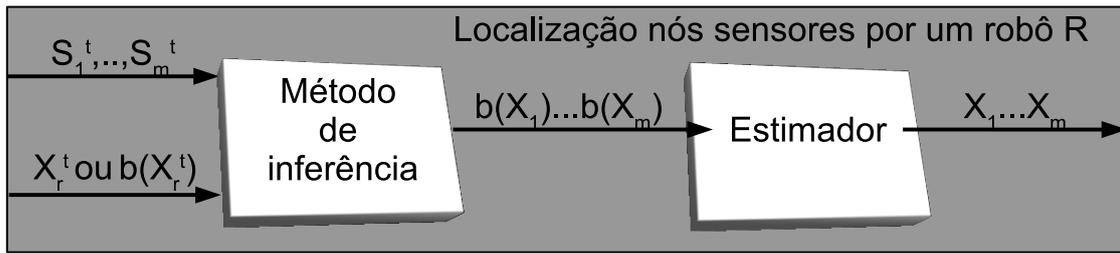


Figura 3.3. O fluxo de informação das abordagens para localização de nós sensores. Os métodos de inferência são utilizados no processo de inferência para criar o estado de crença da posição uma variável, a caixa "Estimador" representa um método gerar uma estimativa a partir de um estado de crença $b(X_1) \dots b(X_m)$ da posição $X_1 \dots X_m$ dos m nós sensores. O RSSI S_m^t e a posição X_R^t do robô, ou o estado de crença dela $b(X_R^t)$ são os dados de entrada do método de inferência para gerar o estado de crença sobre a posição do nó sensor $b(X_m)$.

milhança, fornece uma distribuição de probabilidade sobre a posição do nó sensor a partir das amostras de RSSI obtidas pelo robô e sua posição.

3.1.1.1 Distribuição uniforme

Manipulando a Equação 3.1, pode se afirmar que a distância μ , entre o robô e o nó sensor, se relaciona com o sinal, quando a potência S_m^t é recebida, da seguinte forma:

$$\log(\mu) = \frac{L_0 - S_m^t - f(X_m, X_R^t) - \epsilon(X_m, X_R^t)}{10\psi} + \log(D_0). \quad (3.2)$$

Como não se sabe a influência das perturbações na potência do sinal, simplificamos o modelo de propagação para que este retorne uma distância nominal que será utilizada no modelo de observação:

$$\log(\hat{\mu}) = \frac{L_0 - S_m^t}{10\psi} + \log(D_0). \quad (3.3)$$

As perturbações do sinal, f e ϵ de rádio não são facilmente modeladas e o modelo de verossimilhança do RSSI tenta englobar esses problemas de propagação através da distribuição de probabilidades igualmente numa região no mapa definida por uma área formada entre duas circunferências com raios dK_1 e dK_2 , concêntricas na posição do robô R , onde K_1 e K_2 são constantes que tentam capturar os limites de ϵ e f .

Formalmente, o modelo de verossimilhança para o RSSI é:

$$P(S_m^t | X_m, X_R^t) = \begin{cases} \delta + \gamma & \text{quando } \hat{\mu}K_1 \leq \|X_m - X_R^t\| \leq \hat{\mu}K_2 \\ \delta & \text{caso contrário} \end{cases} \quad (3.4)$$

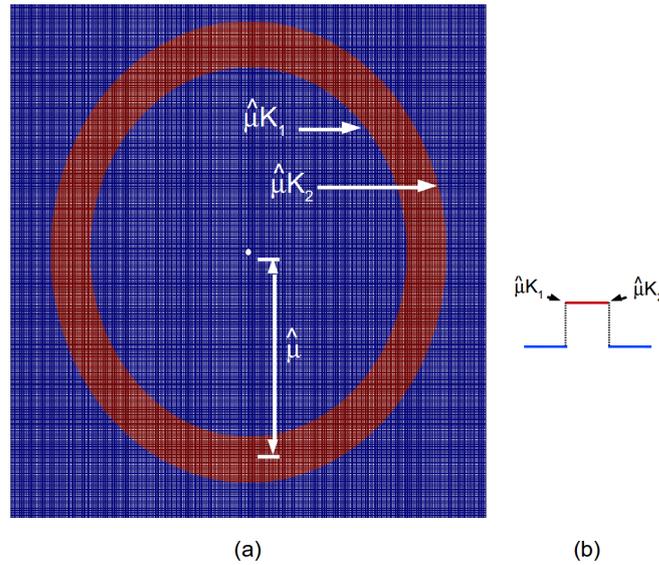


Figura 3.4. Utilizando o modelo de observação uniforme, o anel formado por uma distribuição de probabilidade uniforme é ilustrado na Figura (a). A distribuição uniforme está centrada na posição do robô, ponto branco, e o mapa de calor da imagem (Tom azul = menor probabilidade, Tom vermelho = maior a probabilidade) representa como é distribuída a probabilidade de haver um nó sensor. Na Figura (b), a vista lateral da distribuição de probabilidade do modelo de verossimilhança.

onde δ é um valor muito pequeno com intuito de não zerar a probabilidade de um determinado local do mapa, γ é o valor da probabilidade dado pela distribuição uniforme, $\delta \ll \gamma$, $0 \leq K_1 < 1$ e $1 < K_2$.

O algoritmo para o modelo de verossimilhança através da inferência exata uniforme é mostrado no Algoritmo 1.

Algoritmo 1: Algoritmo do modelo de verossimilhança com distribuição uniforme.

```

begin - Função modeloVerossimilhança
  Entrada:  $X_R^t, X_m, \hat{\mu}, \lambda$ 
  //  $\lambda$  contém os parâmetros  $\{K_1, K_2\}$ 
   $\{K_1, K_2\} = \lambda$ ;
  if  $\hat{\mu}K_1 \leq \text{distânciaEntre}(X_R^t, X_m) \leq \hat{\mu}K_2$  then
  | return  $\delta + \text{Uniforme}(\hat{\mu}K_1, \hat{\mu}K_2)$ ; // Retorna  $P(S_m^t | X_m, X_R^t)$ 
  else
  | return  $\delta$ ;

```

O gráfico de densidade de probabilidade desse modelo de observação é ilustrado na Figura 3.4.

3.1.1.2 Distribuição normal

Nesse modelo de verossimilhança, uma distribuição normal é aplicada para representar o conhecimento obtido com as amostras do RSSI. A distribuição de probabilidade resultante forma um anel concêntrico na posição do robô e raio $\hat{\mu}$ (Equação 3.3) onde uma variância constante captura os limites de ϵ e f . Formalmente, o modelo de verossimilhança de RSSI:

$$P(S_m^t | X_m, X_R^t) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-\hat{\mu})^2}{2\sigma^2}\right) \quad (\text{Igual à } Normal(x, \hat{\mu}, \sigma^2)) \quad (3.5)$$

onde σ é a variância da perturbação no RSSI e x é a distância entre o robô e a posição que deseja-se calcular a probabilidade de ter o nó sensor. Como é um modelo inicial, o valor de σ foi definido como um valor fixo que não varia com a distância $\hat{\mu}$. Essa suposição veio da falta de experiência necessária ou uma solução elegante eficiente para solucioná-la.

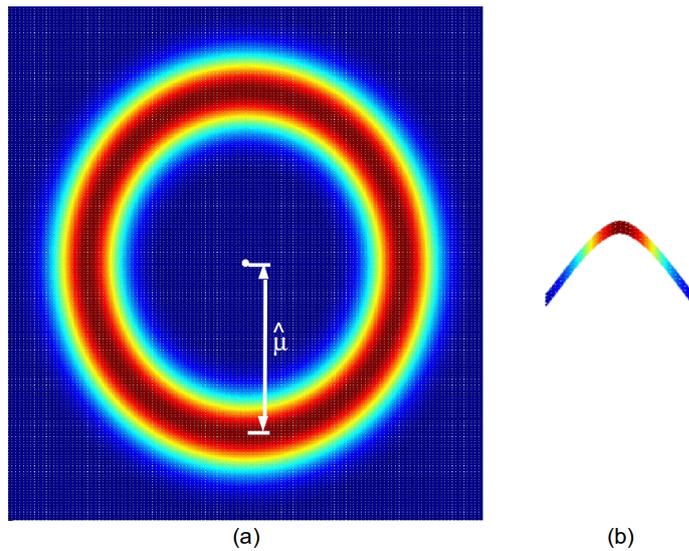


Figura 3.5. Utilizando o modelo de observação normal, o anel formado por uma distribuição de probabilidade normal é ilustrado na Figura (a). A distribuição normal está centrada na posição do robô, ponto branco, e o mapa de calor da imagem (Tom azul = menor probabilidade, Tom vermelho = maior a probabilidade) representa como é distribuída a probabilidade de haver um nó sensor. Na Figura (b), a vista lateral da distribuição de probabilidade do modelo de verossimilhança.

A partir do modelo formal, podemos estabelecer um algoritmo para o modelo de verossimilhança através da inferência exata normal. Este é mostrado no Algoritmo 2.

Algoritmo 2: Algoritmo do modelo de verossimilhança com distribuição normal.

```

begin - Função modeloVerossimilhança
  Entrada:  $X_R^t, X_m, \hat{\mu}, \lambda$ 
  //  $\lambda$  contém o parâmetro  $\sigma$ 
   $\{\sigma\} = \lambda$ ;
   $x = \text{distânciaEntre}(X_R^t, X_m)$ ;
  return  $Normal(x, \mu, \sigma^2)$ ; // Representa  $P(S_m^t | X_m, X_R^t)$ 

```

A Figura 3.5 mostra a formação da distribuição de probabilidade em formato de anel devido ao modelo de verossimilhança.

3.1.2 Estimadores

Neste trabalho, foram utilizados os estimadores, *Maximum a Posteriori* (MAP) e a Média geral Ponderada (MGP), para obter estimativas das posições dos nós sensores de acordo com o estado de crença. Um estimador é uma combinação dos elementos da amostra com finalidade de representar, ou estimar, um parâmetro de interesse na população. A estimativa da posição é um valor numérico atribuído pelo estimador, dado o conjunto de probabilidades (estado de crença) da posição do nó sensor.

Existem outros métodos para obter estimativas do parâmetro de interesse, porém os utilizados nesse trabalho foram escolhidos devido à simplicidade que apresentam em seus conceitos. O método MGP (Equação 3.6) estima a posição do nó sensor através de uma média ponderada da probabilidade de cada posição na grade, caso seja uma inferência exata, ou cada partícula existente, caso seja na inferência aproximada.

$$(\hat{x}, \hat{y}) = (\Sigma x \times b^t(X_m), \Sigma y \times b^t(X_m)) \quad (3.6)$$

onde (\hat{x}, \hat{y}) é o par ordenado que define a estimativa da posição do objeto de interesse e w é o peso de uma amostra (x, y) da população.

O método MAP (Equação 3.7) estima um valor de uma distribuição de probabilidade com a escolha da posição, ou partícula, como a maior probabilidade dentro do conjunto de possibilidades.

$$(\hat{x}, \hat{y}) = \text{argmax}(b^t(X_m)) \quad (3.7)$$

onde (\hat{x}, \hat{y}) é a estimativa da posição do objeto de interesse e $\text{argmax}_{x,y}(P(x, y))$ é uma função que retorna uma estimativa de acordo com o peso da amostra (x, y) máximo da população.

3.2 Localização de nós sensores

O problema probabilístico de localização de nós sensores por robôs móveis pode ser especificado como a determinação da distribuição de probabilidade sobre a posição do nó sensor, que é a variável escondida do sistema, dada as informações disponíveis, como a posição do robô e o RSSI.

Nesta seção, primeiramente descreveremos como o estado de crença da posição do nós sensores é determinado. A seguir, explicaremos os dois modelos gráficos probabilísticos, gerados a partir do modelo geral de localização simultânea, para o problema de localização de nós sensores por um robô móvel. Sendo que o primeiro modelo utiliza a posição do robô conhecida, e o segundo, a posição do robô incerta.

3.2.1 Estado de crença

Um estado de crença reflete o conhecimento interno de um robô sobre o estado do ambiente que não pode ser diretamente medido (Thrun et al. [2005]). O robô infere a localização do nó sensor a partir de dados indiretos, vindos das observações de sinais de rádio em diferentes posições do robô. Estes dados são agregados na sua base de conhecimento sobre o estado do sistema. Portanto, o verdadeiro estado, a posição real do sensor, e o estado de crença $b^t(X_m)$ (crença da posição do nó sensor dado o conhecimento do robô) no tempo t são distintos. A partir do estado de crença pode-se estimar a posição X_m do nó sensor m .

A atualização do $b^t(X_m)$ no tempo t utiliza um modelo de observação que depende do RSSI S_m^t calculado pelo robô R , da distância $\hat{\mu}$ dado o modelo de propagação, e o estado de crença anterior $b^{t-1}(X_m)$. No processo de localização de nós sensores, quando uma amostra de RSSI S_m^t é adquirida pelo robô R , a possível posição do nó sensor é determinada por aquela que está a uma distância $\hat{\mu}$ (Equação 3.3) partindo da posição X_R^t do robô R . Expressando geometricamente, o nó sensor pode estar localizado dentro de uma circunferência concêntrica de X_R^t e de raio $\hat{\mu}$.

O modelo de probabilidade *a priori* $b^0(X_m)$ representa o estado de crença inicial sobre a posição do nó sensor. No presente estudo, $b^0(X_m)$ foi representado por um conjunto de probabilidades muito pequenas distribuídas uniformemente no mapa.

3.2.2 Posição do robô conhecida

Nesse modelo, o estado do sistema $\mathbf{X}^t = (X_R^t, S_m^t)$ é parcialmente observável. X_R^t é observado diretamente, entretanto a observação de X_m é uma variável aleatória não observável que descreve a posição estática de um nó sensor m . O robô recebe o valor

de RSSI S_m^t e deve inferir a posição do nó sensor X_m . O modelo para um único X_m é apresentado na Figura 3.6, onde o *template* (parte cinza da figura) é repetido para cada ciclo.

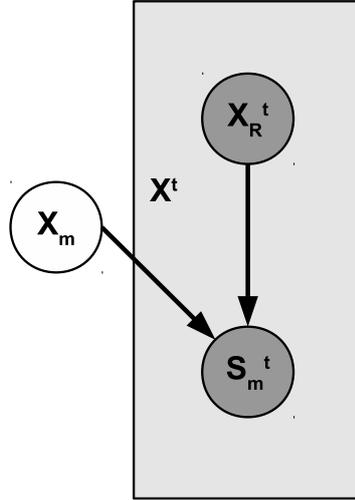


Figura 3.6. Rede Bayesiana usada na inferência exata para o problema de localização de nós sensores baseada em distância, quando a posição do robô é conhecida. A variável aleatória e as setas representam a dependência condicional. Nós brancos são não observáveis diretamente.

Utilizando as independências do modelo, a atualização do estado de crença $b^t(X_m)$ sobre a posição do nó sensor no ciclo t é:

$$\begin{aligned}
 b^t(X_m) &= P(X_m | S_m^t, X_R^t) && \text{(definido pelo HMM da Figura 3.6)} \\
 &= \frac{P(S_m^t | X_R^t, X_m) P(X_R^t, X_m)}{P(S_m^t)} && \text{(Aplicando o teorema de Bayes)} \\
 &= \frac{P(S_m^t | X_R^t, X_m) P(X_m)}{P(S_m^t)} && \text{(Independência } \rightarrow P(X_R^t, X_m) = P(X_m)) \\
 &= \alpha P(S_m^t | X_R^t, X_m) P(X_m) && \text{(A posteriori é proporcional ao numerador)} \\
 &= \alpha P(S_m^t | X_R^t, X_m) b^{t-1}(X_m) && \text{(Cálculo da distribuição a posteriori).}
 \end{aligned} \tag{3.8}$$

onde α é a constante de normalização e $P(S_m^t | X_R^t, X_m)$ é o modelo de verossimilhança que um dado valor de RSSI S_m^t seja observado pelo robô se sua posição atual for X_R^t e a posição do nó sensor, que é desconhecida, for X_m .

3.2.3 Posição do robô incerta

Neste modelo, a posição do robô X_R^t é uma variável aleatória sobre a qual se tem um estado de crença $b(X_R^t)$ obtido externamente, e a única observação direta de R é o RSSI S_m^t . É importante ressaltar que esse modelo resolve um problema mais difícil,

pois, além de integrar a incerteza do sinal, ele também integra a incerteza do estado de crença da posição do robô $b(X_R^t)$.

A atualização de $b^t(X_m)$ é realizada como descrito na Equação 3.9, onde $P(S_m^t|X_R^t, X_m)$ é o modelo de observação descrito anteriormente e $b^{t-1}(X_m)$ é o estado de crença anterior da posição do nó sensor.

$$\begin{aligned}
 b^t(X_m) &= P(X_m|S_m^t, X_R^t) && \text{(definido pelo HMM da Figura 3.7)} \\
 &= \frac{P(S_m^t|X_R^t, X_m)P(X_R^t, X_m)}{P(S_m^t)} && \text{(Aplicando o teorema de Bayes)} \\
 &= \frac{P(S_m^t|X_R^t, X_m)P(X_R^t)P(X_m)}{P(S_m^t)} && \text{(Independência } \rightarrow P(X_R^t, X_m) = P(X_m)P(X_R^t)) \\
 &= \alpha P(S_m^t|X_R^t, X_m)P(X_R^t)P(X_m) && \text{(A posteriori é proporcional ao numerador)} \\
 &= \alpha P(S_m^t|X_R^t, X_m)b(X_R^t)b^{t-1}(X_m) && \text{(Cálculo da distribuição a posteriori).} \\
 & && (3.9)
 \end{aligned}$$

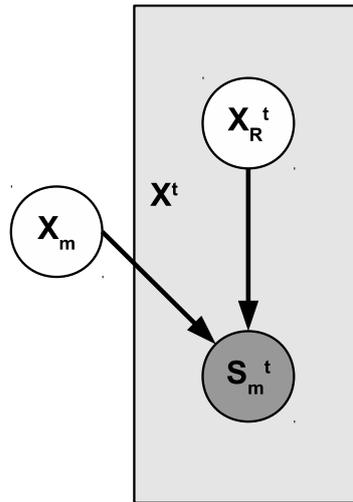


Figura 3.7. O HMM usado na inferência aproximada da localização de nós sensores baseado em distância não considera X_R^t e X_m diretamente observáveis (círculos preenchidos pela cor branca), já S_m^t é considerado observável (círculos preenchidos pela cor cinza).

O estado de crença $b(X_R^t)$ da posição X_R^t do robô R no tempo t pode ser obtido por um modelo externo de localização clássica, ilustrado na Figura 3.8 e discutido por Thrun et al. [2005], onde há evidências sensoriais \mathbf{O}^t são obtidas através dos sensores internos do robô e são utilizadas no processo de atualização de $b(X_R^t)$.

A distribuição *a posteriori* da posição do robô $b(X_R^t)$ é realizada a partir do estado de crença anterior da posição do robô $b(X_R^{t-1})$ e as novas observações dos sensores do robô \mathbf{O}^t que fornecem informação sobre sua posição no tempo t . Uma vez que estabelecido $b(X_R^t)$, o processo de integração dos novos valores é realizado no intuito

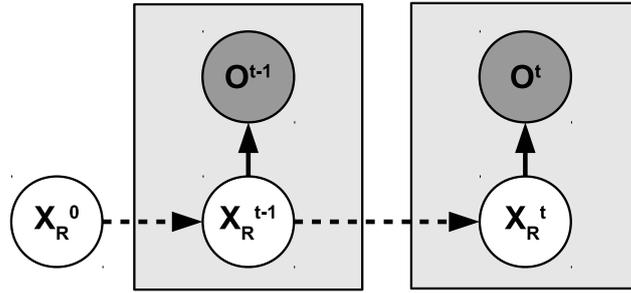


Figura 3.8. HMM usada na inferência da localização do robô baseada nas observações dos sensores internos do robô.

de atualizar o estado de crença da posição do nó sensor.

$$\begin{aligned}
 b(X_R^t) &= P(X_R^t | \mathbf{O}^t, X_R^{t-1}) && \text{(definido pelo HMM da Figura 3.8)} \\
 &= \frac{P(\mathbf{O}^t | X_R^t, X_R^{t-1}) P(X_R^t, X_R^{t-1})}{P(\mathbf{O}^t)} && \text{(Aplicando o teorema de Bayes)} \\
 &= \alpha P(\mathbf{O}^t | X_R^t, X_R^{t-1}) P(X_R^t, X_R^{t-1}) && \text{(A posteriori é proporcional ao numerador)} \\
 &= \alpha P(\mathbf{O}^t | X_R^t, X_R^{t-1}) P(X_R^t | X_R^{t-1}) b(X_R^{t-1}) && \text{(Cálculo da distribuição a posteriori).} \\
 & && (3.10)
 \end{aligned}$$

3.3 Processo de inferência

Nessa seção são descritos os processos de inferência que resolvem o arcabouço proposto para a localização de nós sensores. Inicialmente será explicado o método de inferência exata, onde foram utilizados os dois modelos de verossimilhança. Logo após, será explicado o método de inferência aproximada utilizado, conhecido na literatura como filtro de partículas (Thrun [2002]).

3.3.1 Inferência exata

Na localização de nós sensores através de inferência exata foi utilizado o modelo de localização de nós sensores mais simples como na Figura 3.6. O ambiente é dividido em células de tamanho definido por especificação do usuário formando uma grade, mostrada na Figura 3.9, onde cada célula representa uma área no ambiente. O tamanho da célula pode ser tão pequeno quanto necessário, esse limite depende da precisão especificada para a aplicação. Na utilização da grade, quanto menor for a célula melhor será a representação do ambiente, em compensação será necessário processar um maior número de células para atualizar o estado de crença. A célula é um quadrado de lado L

que define a resolução necessária na aplicação, ou seja, $L = \text{resolução}$. Dessa forma a grade possui uma dimensão de $\text{linhas} \times \text{colunas}$ que representa o ambiente com largura X e a altura Y unidades, cujos números de linhas (células na vertical) e colunas (células na horizontal) são definidos na Equação 3.11.

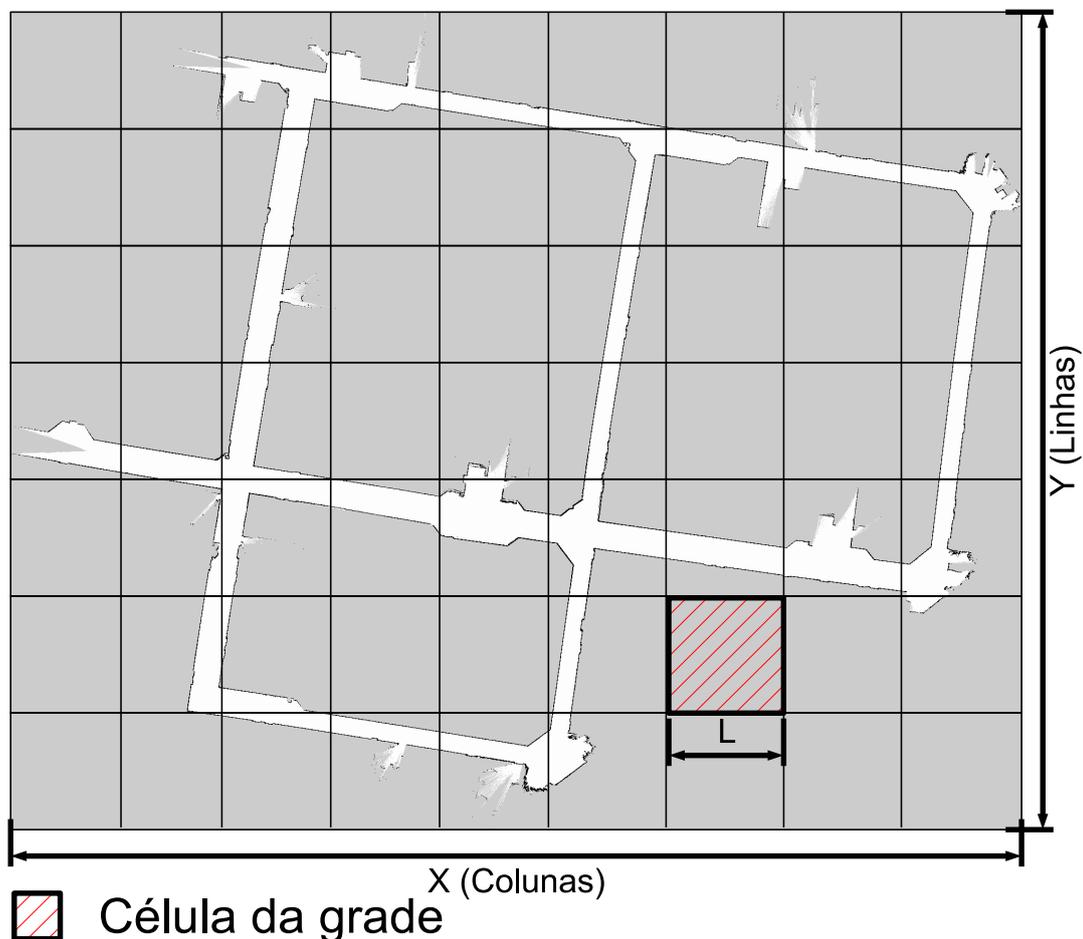


Figura 3.9. O ambiente é seccionado em várias células de tamanho fixo formando uma grade. Uma célula, área hachurada de vermelho, vai representar a probabilidade da presença do nó sensor na área do ambiente que a célula cobre. O tamanho da célula é um recurso da inferência exata que funciona como regulador entre precisão de localização e desempenho.

$$\begin{cases} \text{linhas} &= \frac{Y}{L} \\ \text{colunas} &= \frac{X}{L} \end{cases} \quad (3.11)$$

O algoritmo para localização de nós sensores usando inferência exata é descrito no Algoritmo 3. No algoritmo, a atualização de crença da posição de um nó sensor é efetuada a cada iteração, onde há o percorrimto de todas as células da grade, calculando-se a probabilidade de cada célula possuir o nó sensor de acordo com as

evidências. A cada iteração, as evidências são lidas através do método **lerDadosRobô**, em seguida, a função **transformarRSSIemDistância** faz a conversão do valor do RSSI em distância a partir da Equação 3.3, a função **modeloVerossimilhança** calcula o valor da probabilidade de cada célula de acordo com o modelo probabilístico, e a função **normalizaGrade** normaliza a probabilidade de todas as células de forma que a soma das probabilidades destas seja igual a 1.

Algoritmo 3: Algoritmo de inferência exata uniforme para localização de nós sensores.

```

Entrada: Parâmetros da distribuição  $\lambda$ , Dimensão do Ambiente  $(x, y)$ 
            metros e Resolução do Grade Resolucao
Saída : Grade que representa a distribuição de probabilidade da
            localização do nó sensor  $\mathbf{X}_m$ 

// A grade vai ter  $\frac{x}{Resolucao}$  colunas e  $\frac{y}{Resolucao}$  linhas e cada célula
// vai ter um valor igual, ou seja, representando a ignorância
// sobre a posição do nó sensor  $b(X_m)$ 
grade = inicializaGrade( $x, y, Resolucao$ );
while true do
    // Posição do Robô  $X_R^t$ , RSSI  $S_m^t$ 
    [ $X_R^t, S_m^t$ ] = lerDadosRobô();
     $\hat{\mu} = \text{transformarRSSIemDistância}(S_m^t)$ ;
    foreach linha lin na grade do
        foreach coluna col na grade do
            // Atualização da crença através da posteriori:
             $P(S_m^t | X_m, X_R^t)P(X_R^t)$ 
            grade(lin, col) = modeloVerossimilhança( $X_R^t, [lin, col], \hat{\mu}, \lambda$ )
            * grade(lin, col);
        end
    end
    normalizaGrade(Grade);
end

```

3.3.2 Inferência aproximada

A ideia chave da inferência aproximada é representar o estado de crença por um conjunto de amostras aleatórias da distribuição posteriori (Thrun et al. [2005]). No contexto do presente trabalho, a posteriori é estado de crença sobre a posição do nó sensor $b^t(X_m)$. O HMM resolvido pelo filtro de partículas é o modelo gráfico probabilístico da Figura 3.7 e o modelo de verossimilhança da Equação 3.9. É importante ressaltar que a localização do robô foi realizada por outro HMM ilustrado na Figura 3.8, que é um módulo externo cujo retorno é um estado de crença da posição dos nós sensores.

Após a mudança de estado, o filtro de partículas gera uma amostra de partículas $b^t(X_m)$ que será utilizada na estimação da posição do nó sensor X_m .

O Algoritmo 4 realiza o processo da atualização do estado de crença da posição dos nós sensores através da geração de novas partículas a cada ciclo. Inicialmente, cria-se um estado de crença sobre a posição do nó sensor na forma de partículas de maneira uniforme através da função **InicializaPartículas**. Na iteração principal (**while true do**), $b(X_R^t)$ e o S_m^t são adquiridos do robô pela função **lerDadosRobô**. Sendo que $b(X_R^t)$ é representado por um conjunto de partículas criadas de um módulo de localização externo sendo executado no robô. Para cada partícula existente é feito um sorteio de uma partícula que vai representar a posição do robô. Para cada partícula que representa uma amostra de $b(X_m)$, sorteamos uma nova partícula que vai substituir a primeira. Para não copiar a partícula que foi selecionada, é inserido uma pequena variação da posição desta partícula e calculado o seu novo peso com o modelo de verossimilhança de RSSI. No final da iteração todas as partículas iniciais são renovadas e começa-se um novo ciclo quando uma nova amostra de RSSI são recebidos.

Algoritmo 4: Algoritmo do filtro de partículas para localização de nós sensores.

Entrada: Parâmetros da distribuição λ , número de partículas
NmrParticulas

Saída : Conjunto de partículas que representam o estado de crença da localização do nó sensor $b(X_m)$

```
// Inicializa as partículas com uma distribuição uniforme sobre
o mapa
S = inicializaParticulas(NmrParticulas);
while true do
    [b(XRt) , Smt] = lerDadosRobô();
    μ = transformarRSSIemDistância(Smt) ;
    for Np = 1 : NmrParticulas do
        // Sorteando um valor entre 0 e 1 uniformemente
        sorteioxr = uniformeAleatório(0,1);
        soma = 0;
        // Adquirindo as partículas do estado de crença da
        localização do robô
        R = amostrarPosiçãoRobô(b(XRt));
        // Sorteio da posição do robô
        xr = sorteiaPosição (R);
        sorteioxm = uniformeAleatório (0, 1);
        soma = 0;
        // Atualização de cada partícula
        for j = 1 : NmrParticulas do
            soma = soma + S(j).peso;
            if soma >= sorteioxm then
                // Inserindo uma pequena variação na partícula
                Snew(Np) = multivariadoAleatório(S(j), λ);
                d = distânciaEntre(xr, Snew(Np));
                Snew(Np).peso = modeloVerossimilhança(xr , Snew(Np) , μ
                , λ);
                interrompeLoop;
            end
        end
    end
    S = Snew;
end
```

Capítulo 4

Resultados e discussão

Neste capítulo são apresentados os experimentos realizados para avaliar o arcabouço probabilístico de localização de nós sensores. Para realizar os experimentos, foi desenvolvido no ROS/Stage (Quigley et al. [2009]; Gerkey et al. [2003]) um módulo que estima a localização dos nós sensores utilizando o RSSI e a posição estimada de um robô, calculada através dos dados dos sensores internos deste. Através dos experimentos simulados, o erro de localização dos nós sensores é avaliado em diferentes cenários que incluem diferentes configurações. A variação do cenário consiste em diferentes localizações dos nós, níveis de perturbação no RSSI e intervalos de tempo de aquisição do valor do RSSI.

Os resultados e discussões estão divididos em seis seções. A descrição da construção dos cenários envolvidos está na Seção 4.1. Os parâmetros que caracterizam cada cenário estão descritos na Seção 4.2. A comparação dos resultados entre os diferentes métodos de inferência é apresentada na Seção 4.3. A comparação do tempo de atualização de crença dos processos de inferência se encontra na Seção 4.4. Na Seção 4.5 são apresentadas as análises estatísticas dos resultados obtidos nos cenários e a discussão desses. As considerações finais da análise dos resultados são demonstradas na Seção 4.6.

4.1 Configuração do cenário

Os experimentos executados para avaliar o arcabouço utilizaram cenários que foram elaborados com combinações de diferentes fatores e o que utilizado para montá-los será descrito na presente seção. Inicialmente são apresentadas as ferramentas utilizadas para o desenvolvimento dos cenários. Logo após, o ambiente utilizado nos experimentos é descrito e alguns valores, como a dimensão, são descritos. Será descrito como as

características do caminho executado pelo robô durante a localização dos nós sensores. Finalmente, será explicado como a análise estatística dos resultados foi realizada.

4.1.1 Ferramentas

Os experimentos para avaliar o arcabouço foram feitos a partir da união do ROS (Quigley et al. [2009]) com um simulador, bastante conhecido na comunidade da robótica, chamado *Stage* (Gerkey et al. [2003]). A escolha do ROS é devida à ampla disponibilidade de módulos para criação de aplicações para robótica. A escolha do *Stage* foi por ser um simulador que tem grande suporte da comunidade e por ter recursos que são compatíveis com o que é necessário no presente trabalho: diferentes modelos de robôs e nós sensores.

O modelo do robô utilizado na simulação tem as mesmas características de um *Pioneer 3AT*, produzido pela *Activmedia*, equipado com um sensor laser e um receptor de rádio para aquisição do sinal dos nós sensores no ambiente. O modelo de nó sensor utilizado nos experimentos utiliza o padrão *802.11g* que opera a 2.4 Gigahertz (GHz) e possui um alcance de sinal em torno de 50 a 100 metros (Muthukrishnan et al. [2005]).

A posição do robô no ambiente é estimada por um módulo disponível no ROS chamado *Adaptive Monte Carlo Localization* (AMCL)¹. O módulo faz a correspondência do mapa fornecido com as leituras de distâncias do laser para gerar uma distribuição de probabilidades da posição do robô que é integrada com a distribuição de probabilidade da hometria. O resultado é utilizado como uma distribuição *a posteriori* para um filtro de partículas que corresponde ao estado de crença sobre a localização do robô.

4.1.2 O ambiente

O ambiente da simulação foi um mapa parcial do terceiro andar do ICEx da UFMG contendo uma área de $95,1 \times 77,1 \text{ m}^2$. Nos métodos que utilizam inferência exata, a resolução utilizada para criar a grade foi de $0,15 \text{ m}$, ou seja, a grade possui um tamanho de 634×514 células, onde cada célula representa um retângulo de $0,0225 \text{ m}^2$. O valor da resolução é escolhido de acordo com os requisitos da aplicação. Neste trabalho, o desenvolvimento do módulo de localização de nós sensores considerou um erro máximo $0,15 \text{ m}$.

¹Maiores informações sobre o AMCL podem ser encontradas no apêndice E.

4.1.3 Caminho percorrido pelo robô

Nos experimentos para localização de nós sensores, o robô percorre um caminho pré-definido no ambiente. Esse caminho, mostrado na Figura 4.3, é resultado de um módulo de navegação presente no ROS chamado *move_base* que utiliza o mapa do ambiente, as leituras do laser e a localização do robô para traçar uma trajetória dado alguns pontos de interesse definidos pelo usuário. O caminho não deve ser linear para diminuir o número de hipóteses sobre a posição do nó sensor. Múltiplas hipóteses são causadas pelo processo de inferência da posição do nó sensor, pois este utiliza uma informação que não tem o ângulo de recepção do sinal, decorrente da antena do receptor ser omnidirecional. A maior vantagem das antenas omnidirecionais é o custo baixo, porém o maior problema é não indicar a direção do recebimento do sinal. Para resolver isso, seria necessário utilizar um conjunto de antenas ou uma antena de recepção mais complexa que aumentaria os custos e a complexidade do projeto. O resultado das múltiplas hipóteses são áreas de altas probabilidades em lugares distintos no ambiente, como mostrado na Figura 4.1, que representam o estado de crença da posição do nó sensor.

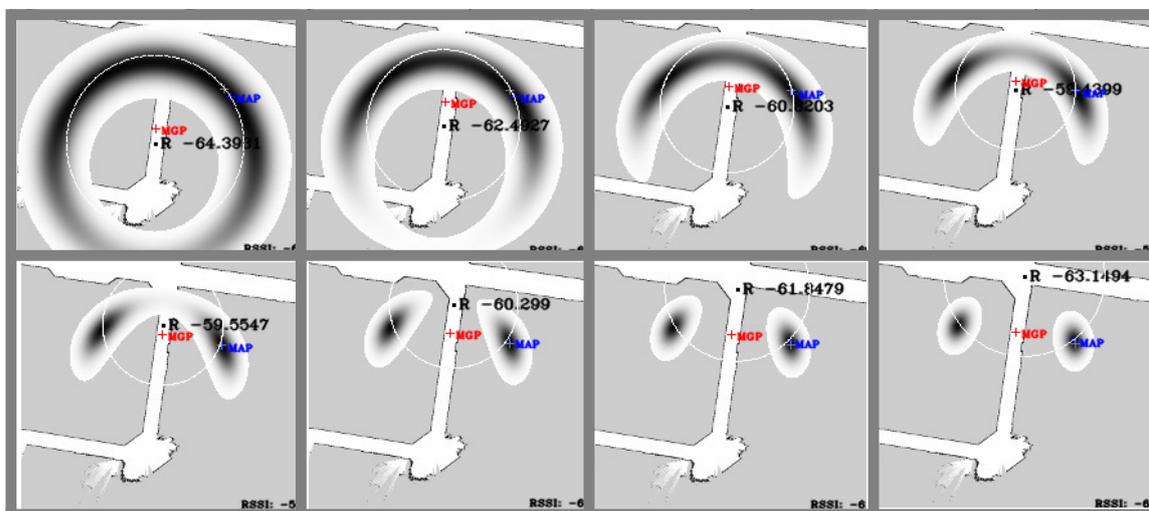


Figura 4.1. A inferência da posição do nó sensor quando o robô percorre um caminho linear não determina qual das hipóteses alternativas é a verdadeira, causando uma dúvida da posição do nó sensor. Isto pode observado na sequência que vai da esquerda para a direita e de cima para baixo: o robô – ponto preto identificado com um R – percorre um corredor inferindo a posição de um nó sensor, resultando num estado de crença não conclusivo.

4.1.4 Testes estatísticos utilizados

O método *Analysis Of Variance* (ANOVA) (Fisher [1925]) foi escolhido para avaliar se os parâmetros dos cenários e métodos de inferência são significativos em relação aos erros de localização dos nós sensores obtidos nos experimentos. Dentro da família do ANOVA, os testes utilizados foram o *two-way* ANOVA, para dois fatores, e o *n-way* ANOVA, quando há mais de dois fatores. Nos teste ANOVA é necessário definir um valor α que indica se há uma diferença estatisticamente significativa entre os dados. Se o resultado do teste for menor que este valor, pode ser dito que os experimentos com diferentes fatores possuem pelo menos uma média de erro de localização que é significativamente diferente de outra média de erro de localização em outro experimento. A escolha do valor α é definida por cada pesquisador e no presente trabalho $\alpha = 0,05$. As análises foram realizadas no *software* MATLAB [2011].

4.2 Parâmetros

Vários cenários foram definidos para avaliar os métodos de inferência da posição do nó sensor. Cada cenário é composto por uma variação de parâmetros que mudam as características do ambiente. A perturbação aplicada ao RSSI, intervalo de tempo de aquisição e localização do nó sensor em relação ao caminho do robô são características definidas em cada cenário.

4.2.1 Perturbação no RSSI

Nesse trabalho, o RSSI é um elemento fundamental para a localização dos nós sensores. O modelo de nó sensor utiliza as características do padrão de rádio 802.11g e possui um alcance em torno de 50 a 100 metros. Apesar de experimentos simulados terem sido realizados, resultados num cenário eram imprescindíveis pois permitiram a avaliação dos parâmetros controladamente, que é o caso da perturbação do sinal. Outras tecnologias poderiam ser utilizadas: infravermelho (5 m e restrito por visadas), ultrassom (3–10 m), DC eletromagnético (1–3 m), ótico (5 m e restrito por visadas), etc. (Muthukrishnan et al. [2005]). Porém, como pode ser percebido, todos possuem um alcance muito pequeno e problemas de propagação que não são contornáveis dado um ambiente com maiores proporções.

A propagação do sinal de rádio é modelada pela Equação 4.1 e é uma aproximação da propagação de um sinal de rádio num ambiente real². Seguindo proposta da

²Maiores detalhes podem ser vistos no Apêndice C.

literatura, o valor escolhido para definir o decaimento do sinal ψ é 2.9, este foi escolhido de acordo com a Tabela B.1, definida no Apêndice B. Na Figura 4.2 é ilustrado uma linha azul que mostra como se comporta a função de propagação de sinal com o valor de decaimento de sinal escolhido. Percebe-se que a linha azul é um pouco acima dos dados reais (cruzes vermelhas) pois o efeito do multi-caminho é reduzido de forma drástica em maiores distâncias. Outros pontos a serem observados são os fatos que a amostra foi realizada num trajeto específico no ambiente, ou seja, não foram adquiridas medidas de RSSI de outros lugares com a mesma distância, e a amostra não contém a mesma quantidade de medidas em todas as distâncias onde o RSSI foi amostrado. O valor de L_0 (-35 dBm) foi definido a partir da média da 20 medições quando o receptor estava a uma distância igual a D_0 , no presente trabalho esta distância é igual a 1 metro.

A modelagem do sinal de rádio é uma tarefa complexa devido às características estáticas e dinâmicas de cada ambiente, que acarretam problemas de propagação³. Nos experimentos desse trabalho, a simulação do sinal foi quebrada em duas partes: a propagação do sinal e a perturbação aplicada aos RSSI.

A Equação 4.1 modela a propagação do sinal para definir sua potência quando o receptor (um robô) está a uma distância específica do emissor (nó sensor).

$$S_m^t = L_0 - 10\psi \times \log\left(\frac{\|X_m - X_R^t\|}{D_0}\right). \quad (4.1)$$

A Equação 4.2 modela a perturbação aplicada ao RSSI e representa a nossa ignorância sobre os problemas de propagação causados pela complexidade do ambiente.

$$f(X_m, X_R^t) + \epsilon(X_m, X_R^t) = \text{Normal}(0, \sigma^2). \quad (4.2)$$

Os termos f e ϵ representam, respectivamente, a perda de potência por sombreamento e a variação do RSSI por multi-caminho. Estes termos são adicionados ao resultado da função de propagação de sinal que justifica o uso dos modelos de observação do RSSI, definidos na Subseção 3.1.1, desde que estes tentam modelar a incerteza da potência do sinal de rádio. Como a perturbação não assume distribuição bem definida, tentamos englobar toda a falta de conhecimento sobre ela num ambiente real com uma distribuição normal com média zero. Onde a variância σ é um parâmetro da distribuição que serve para modelar a intensidade da perturbação no RSSI causada por diversos problemas de propagação.

³Breves e melhores explicações sobre propagação de sinal e problemas de propagação podem ser encontradas nos apêndices B e C respectivamente.

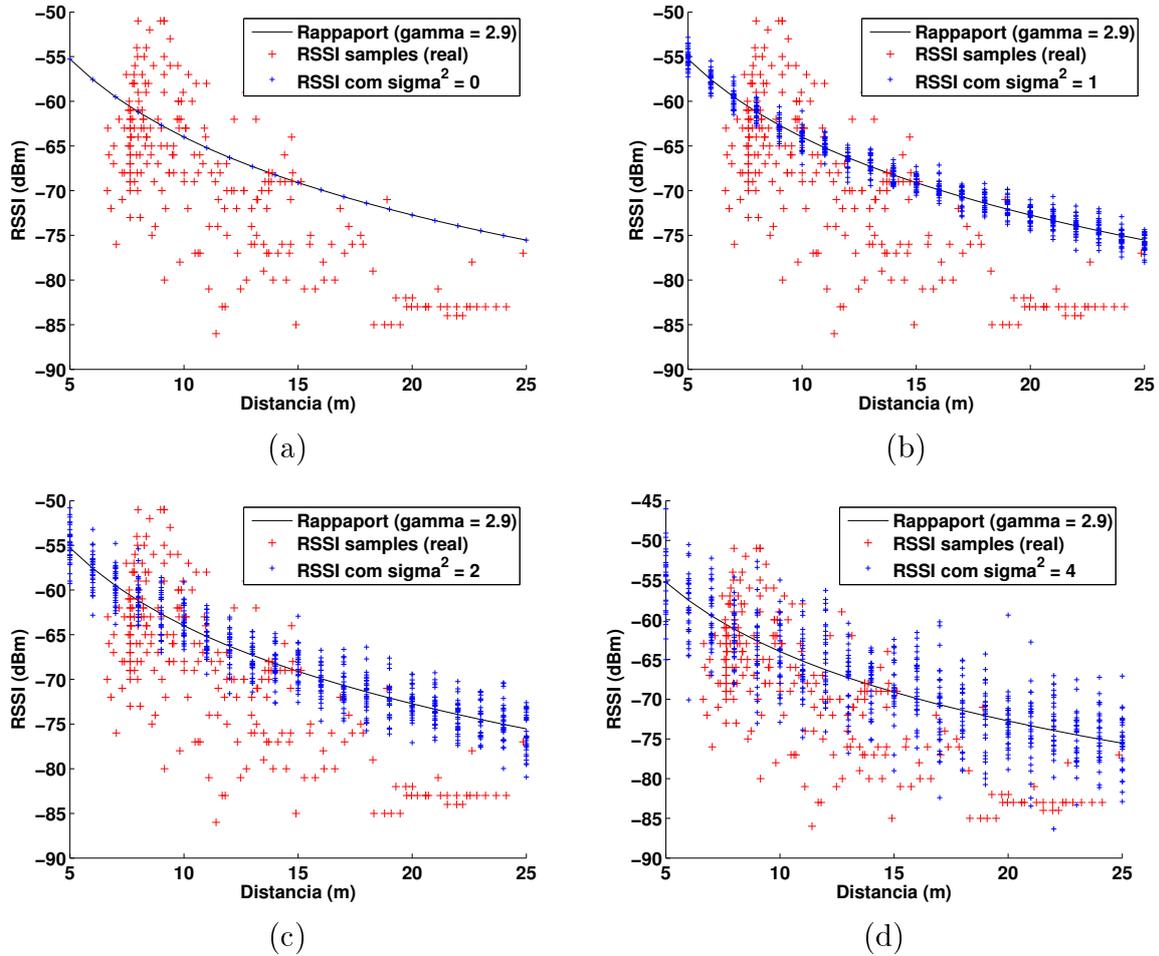


Figura 4.2. Diferentes níveis de perturbação no sinal comparados com uma amostra de RSSI de um ambiente real. A linha azul corresponde ao valor nominal definido pelo modelo de propagação definido por Rappaport [1996] com um valor de decaimento ψ igual a 2.9. As amostras reais de RSSI (cruzes vermelhas) foram tomadas num ambiente real que possui muitas estruturas, superfícies e objetos que modificam a característica do sinal, resultando em grande variações de sinal. Em (a) é mostrado a perturbação do sinal quando $\sigma^2 = 0$, (b) quando a $\sigma^2 = 1$, (c) quando a $\sigma^2 = 2$ e (d) quando a $\sigma^2 = 4$.

Quatro valores $\{0, 1, 2, 4\}$ foram definidos na intensidade da perturbação de sinal σ^2 para uma avaliação qualitativa da adequação do modelo de geração de sinal (Figura 4.2). Os valores foram definidos com base na amplitude da perturbação; quanto maior for a amplitude, maior será a variação da potência calculada do sinal de rádio. Portanto, o sinal de rádio não sofre perturbação quando $\sigma^2 = 0$ e terá maior perturbação quando $\sigma^2 = 4$.

4.2.2 Intervalo de aquisição do RSSI

O intervalo de aquisição é o tempo que o sistema deve esperar entre aquisições de RSSI. O aumento do intervalo de tempo entre amostras durante a movimentação do robô causa uma redução no número de amostras de RSSI utilizadas para a localização dos nós sensores, conseqüentemente o robô trafega distâncias maiores sem aquisição de RSSI e a unidade de processamento (CPU) fica mais ociosa entre as atualizações do estado de crença. Foi avaliada a influência do intervalo de amostragem de RSSI no erro de localização de nós sensores. Os intervalos usados foram $\{0, 2, 4\}$ segundos. O intervalo de 0 segundos faz a coleta dos valores de RSSI no limite do *hardware*, ou seja, quanto mais rápido for o *hardware* do dispositivo mais rápida será a coleta dos RSSIs. O sistema utilizado no experimentos era capaz de coletar os valores do RSSI no intervalo de 1,5 segundos. Como os outros intervalos são maiores que a capacidade do sistema, o intervalo de medidas diminui a necessidade de processamento das amostras de RSSI.

4.2.3 Caracterização dos nós sensores

A característica principal utilizada para descrever os nós sensores é a distância que esses estão do robô. Uma vez que o robô percorre um caminho pré-definido no ambiente, esta distância varia ao longo desse caminho. Nesse sentido, os critérios de distância mínima, média e máxima entre um sensor específico e o caminho do robô foram escolhidos para caracterizar cada nó sensor.

Na Tabela 4.1, os identificadores dos nós sensores são mostrados e suas respectivas características em relação ao caminho que o robô percorreu. O identificador de cada nó sensor e sua posição no ambiente podem ser vistos na Figura 4.3.

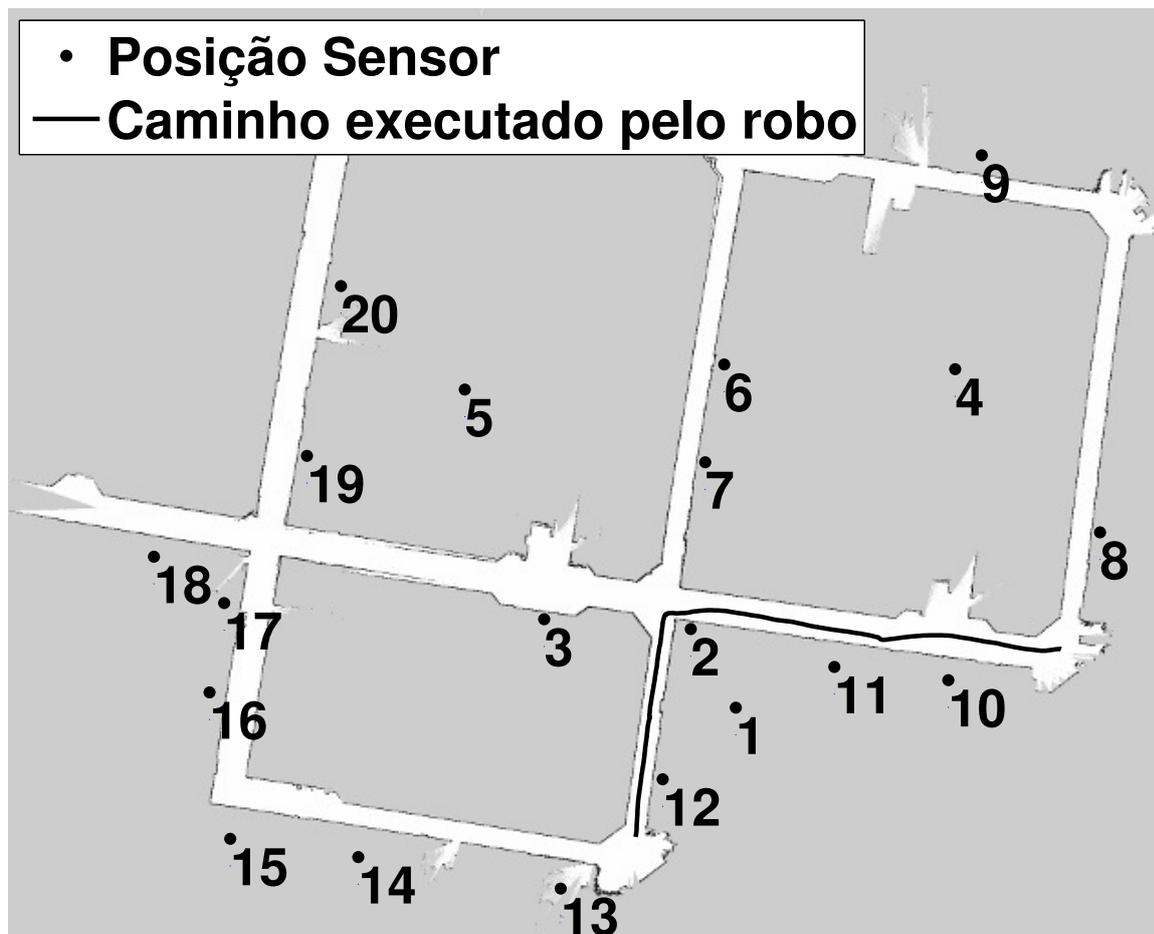


Figura 4.3. Cenário com 20 nós sensores e caminho percorrido pelo robô nos experimentos.

4.3 Comparando os métodos de inferência

O intuito desta seção é mostrar e avaliar o erro de localização dos nós sensores entre os métodos de inferências. Para isso, inicialmente, serão mostrados os resultados qualitativos de cada um dos métodos de inferência. No final, os resultados de localização serão comparados quantitativamente.

4.3.1 Resultado de cada método de inferência

Primeiramente, serão exibidos alguns resultados, obtidos através dos processos de inferência (métodos de inferências e modelos de observação), que mostram qualitativamente os erros de localização de todos os nós sensores no ambiente. Na Figura 4.4 é ilustrado o resultado do uso do método de inferência exata (Algoritmo 3) com modelo de observação uniforme (Algoritmo 1) quando ausente a perturbação do sinal ($\sigma^2 = 0$). Na Figura

Tabela 4.1. Os nós sensores e a característica de distância em metros de cada um deles em relação ao caminho que o robô percorreu. O número do nó sensor e sua posição no ambiente podem ser vistos na Figura 4.3

Sensor	média (m)	mínima (m)	máxima (m)
1	12,6	7,0	27,2
2	12,6	1,4	30,5
3	21,5	9,6	42,5
4	29,9	22,1	46,8
5	36,1	25,0	53,5
6	27,8	20,4	39,8
7	21,0	12,3	33,1
8	28,7	10,2	45,8
9	46,5	40,0	63,3
10	16,3	3,6	28,8
11	12,2	3,0	21,6
12	16,2	1,8	34,4
13	27,2	7,5	45,7
14	39,0	22,9	60,3
15	48,3	33,5	70,2
16	47,8	36,1	70,1
17	47,0	35,9	69,0
18	53,1	42,1	74,9
19	43,7	32,1	64,0
20	49,3	38,1	66,4

4.5 é mostrado o resultado da inferência exata (Algoritmo 3) com modelo de observação normal (Algoritmo 2). Finalmente, na Figura 4.6, é ilustrado o resultado do método de inferência aproximada (Algoritmo 4), filtro de partículas, com modelo de observação normal (Algoritmo 2). Esses resultados qualitativos são mostrados para o leitor se familiarizar com o que é chamado erro de localização dos nós sensores. Percebe-se com essas figura que diferentes métodos de inferência, modelos de observação e estimadores produzem resultados diferentes que serão analisados posteriormente.

4.3.2 Comparação dos métodos de inferência

Nossa metodologia de comparação dos resultados dos métodos consiste em escolher alguns nós sensores, que representam melhor características de um grupo de sensores contidos no conjunto de todos nós sensores que foram localizados, e comparar o resultado final de localização de cada método, obtido no fim do caminho executado pelo robô. O critério escolhido na seleção dos nós sensores que terão seus resultados avaliados é a distância mínima entre o nó e o robô. Os nós sensores que tiveram uma distância

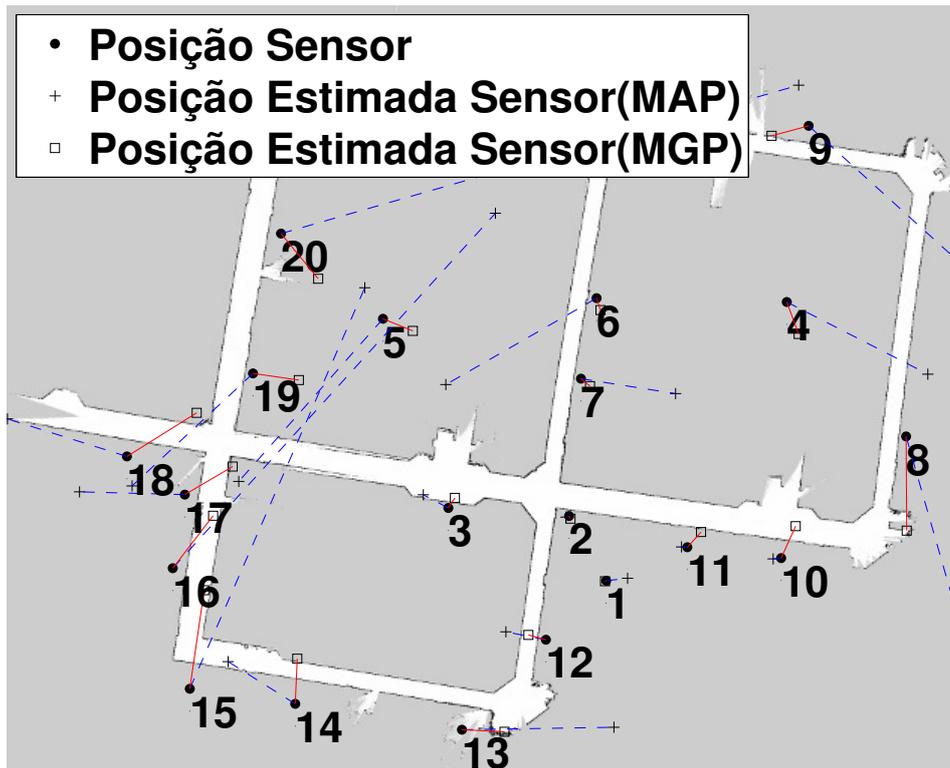


Figura 4.4. Erro de localização utilizando uma inferência exata com distribuição uniforme quando o valor da intensidade da perturbação é $\sigma^2 = 0$.

mínima pequena em torno de 1,4 m, enumerados pelos nós sensores {2, 10, 11 e 12}, serão representados pelo sensor 2. Os nós sensores que possuem uma distância maior que a mínima em torno de 6,9 m, enumerados pelos nós sensores {1 e 13}, um pouco maior que o sensor 2, estão representados pelo nó sensor 1. Os nós sensores que possuem uma distância mínima em torno de 9,7 m, enumerados pelos nós sensores {3 e 8}, serão representados pelo nó sensor 3. Para a distância mínima de 12,3 m, o nó sensor 7 o representará. Os nós sensores que possuem uma distância mínima em torno de 22,9 m, enumerados pelos nós sensores {4, 5, 6 e 14}, serão representados pelo nó sensor 14.

Para os nós sensores que possuem uma distância mínima de 1,4 m, Figura 4.7, o resultado da localização do nó sensor pelo método de inferência exata com modelo de observação uniforme mostrou proporcionar resultados com menores erros de localização com todos os estimadores. No entanto, o método de inferência exata com modelo de observação normal também mostrou bons resultados em ambos estimadores e as diversas perturbações de sinal. O método do filtro de partículas obteve resultados de erros maiores em todos os experimentos quando utilizava o estimador MAP.

Para os nós sensores que possuem uma distância mínima de 6,9 m, Figura 4.8, pode-se dizer que os métodos de inferência exata, uniforme e normal, obtiveram os me-

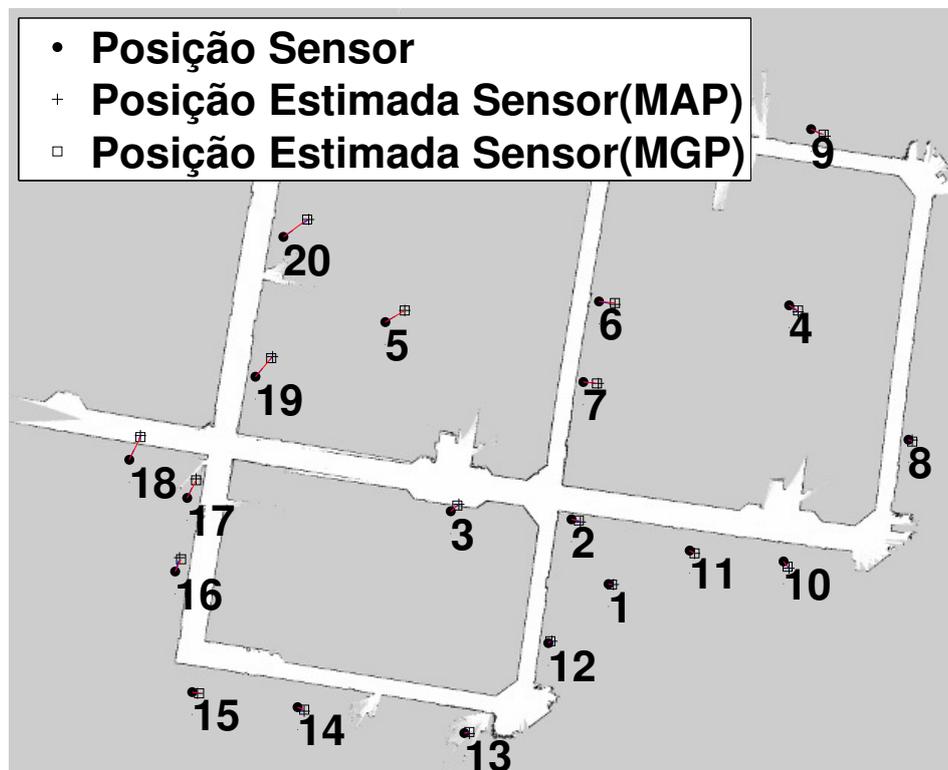


Figura 4.5. Erro de localização utilizando uma inferência exata com modelo de observação normal.

Tabela 4.2. Média e erro padrão dos resultados da localização do Nó Sensor 2. Referente à Figura 4.7. Valores em negrito representam o menor erro de localização dado o processo de inferência e a perturbação no RSSI.

Erro em metros para o nó sensor 2				
	$\sigma^2 = 0$		$\sigma^2 = 1$	
	MAP	MGP	MAP	MGP
Uniforme	0,57 ± 0,06	0,43 ± 0,00	0,35 ± 0,04	0,38 ± 0,02
Normal	0,95 ± 0,00	0,92 ± 0,00	0,87 ± 0,03	0,88 ± 0,03
FP	4,19 ± 0,83	1,35 ± 0,18	4,53 ± 0,80	1,32 ± 0,20
	$\sigma^2 = 2$		$\sigma^2 = 4$	
	MAP	MGP	MAP	MGP
Uniforme	0,53 ± 0,06	0,53 ± 0,05	0,51 ± 0,06	0,53 ± 0,06
Normal	0,79 ± 0,05	0,8 ± 0,04	0,83 ± 0,13	0,82 ± 0,11
FP	5,65 ± 0,58	1,84 ± 0,21	6,08 ± 0,62	2,21 ± 0,25

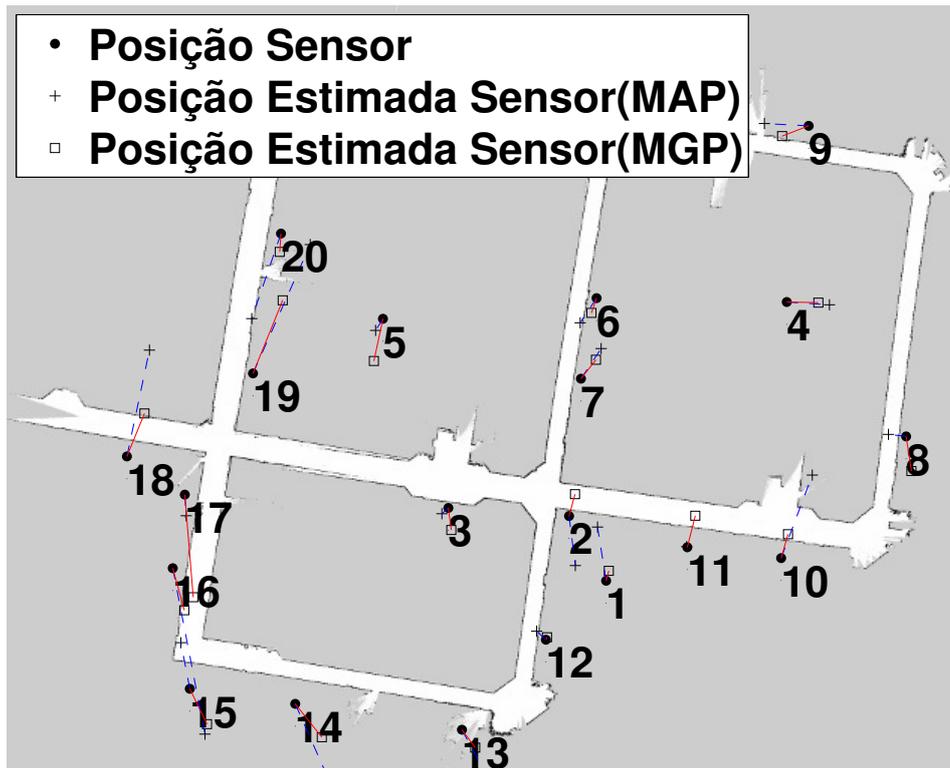


Figura 4.6. Erro de localização utilizando uma inferência através de um filtro de partículas com modelo de observação normal.

lhores resultados de localização. Porém, já é perceptível que o método exato com modelo de observação mantém bons resultados tanto com estimador MAP quanto MGP, diferentemente dos outros métodos. O filtro de partículas com modelo de observação normal mostrou-se ser pior em todos os experimentos.

Tabela 4.3. Média e erro padrão dos resultados da localização do nó sensor 1. Referente à Figura 4.8. Valores em negrito representam o menor erro de localização dado o processo de inferência e a perturbação no RSSI.

Erro em metros para o nó sensor 1				
	$\sigma^2 = 0$		$\sigma^2 = 1$	
	MAP	MGP	MAP	MGP
Uniforme	2,13 ± 0,00	0,13 ± 0,00	1,05 ± 0,06	0,35 ± 0,04
Normal	0,45 ± 0,00	0,43 ± 0,00	0,5 ± 0,02	0,49 ± 0,02
FP	4,37 ± 0,79	1,07 ± 0,17	4,52 ± 0,51	1,2 ± 0,18
	$\sigma^2 = 2$		$\sigma^2 = 4$	
	MAP	MGP	MAP	MGP
Uniforme	0,48 ± 0,05	0,41 ± 0,05	0,92 ± 0,11	0,84 ± 0,09
Normal	0,51 ± 0,06	0,49 ± 0,05	0,85 ± 0,08	0,84 ± 0,08
FP	4,61 ± 0,71	1,09 ± 0,20	5,05 ± 0,72	2,25 ± 0,27

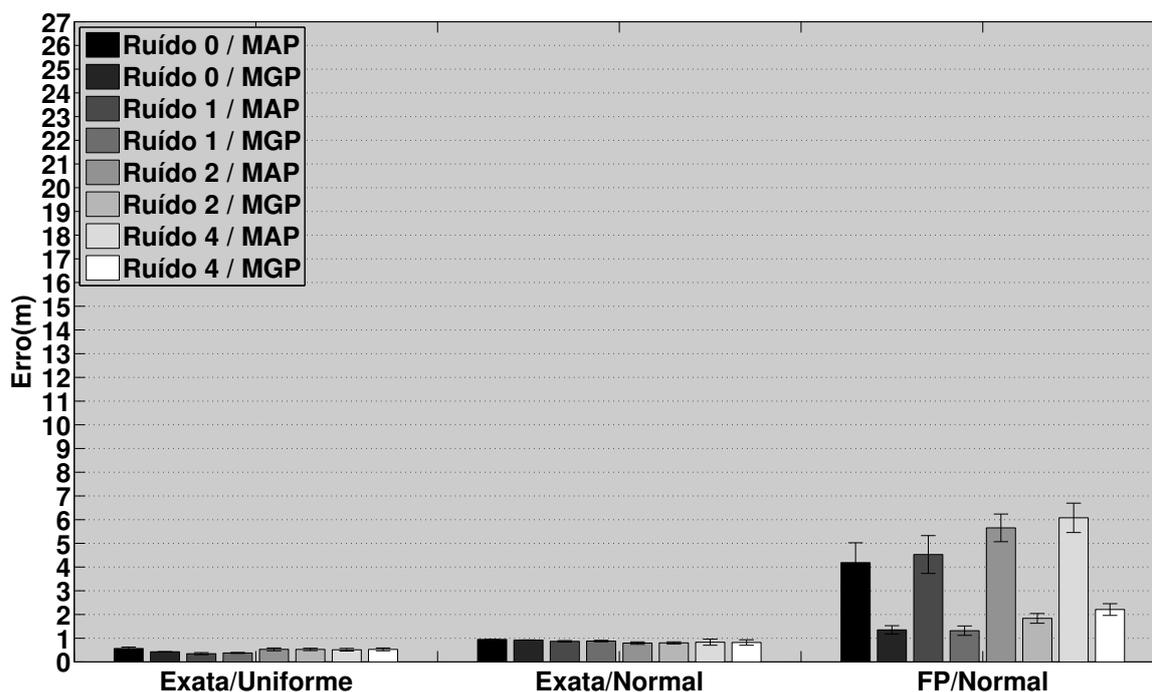


Figura 4.7. Resultados dos diferentes métodos na inferência da localização do nó sensor 2, levando em consideração os níveis de perturbação no sinal e o estimador. Os resultados aqui mostrados podem ser vistos na Tabela 4.2.

Para os nós sensores que possuem uma distância mínima de 9,72 m e 12,27 m, Figuras 4.9 e 4.10, os melhores resultados de localização dos nós sensores foram obtidos com o método de inferência exata normal e quando este foi pior que outro método, a média do erro não ficou tão baixa. O filtro de partículas obteve alguns resultados melhores que o método de inferência exata uniforme. Porém, ambos com maiores erros de localização comparados ao método de inferência exata normal.

Para os nós sensores que possuem uma distância mínima de 22,87, Figura 4.11, o método de inferência exata com modelo de observação normal mostrou novamente os melhores resultados para os níveis de perturbação $\{0, 1, 2\}$, porém quando o nível da perturbação no RSSI é muito grande e isto também pode ser verificado através dos resultados do filtro de partículas com modelo de observação normal. Apesar do modelo de observação normal se ajustar melhor em todos os métodos, a condensação da probabilidade num determinado ponto prejudica a localização quando o RSSI ruidoso faz o estado de crença, calculado pela triangulação da posição do nó sensor, tender para uma posição errada. Para melhor exemplificar esta situação, podemos pensar que em dado momento o RSSI sofre múltiplos erro de multi-caminho aumentando a potência do sinal continuamente, a distância calculada e utilizada para a triangulação vai ser menor que o real, afastando o estado de crença da posição correta.

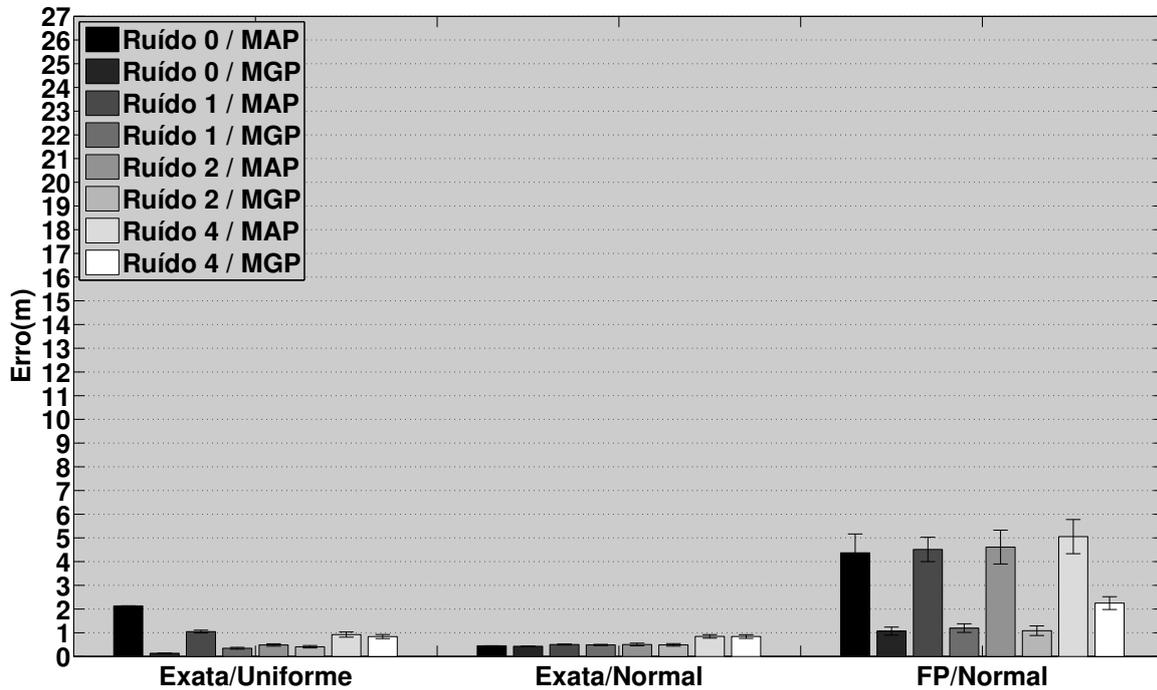


Figura 4.8. Resultados dos diferentes métodos na inferência da localização do nó sensor 1, levando em consideração os níveis de perturbação no sinal e o estimador. Os resultados aqui mostrados podem ser vistos na Tabela 4.3.

Tabela 4.4. Média e erro padrão dos resultados da localização do nó sensor 3. Referente à Figura 4.9. Valores em negrito representam o menor erro de localização dado o processo de inferência e a perturbação no RSSI.

Erro em metros para o nó sensor 3				
	$\sigma^2 = 0$		$\sigma^2 = 1$	
	MAP	MGP	MAP	MGP
Uniforme	5,86 ± 0,77	1,14 ± 0,01	2,17 ± 0,34	0,85 ± 0,08
Normal	0,98 ± 0,02	0,91 ± 0,00	0,9 ± 0,08	0,92 ± 0,08
FP	4,57 ± 0,89	1,92 ± 0,30	6,32 ± 1,21	2,58 ± 0,44
	$\sigma^2 = 2$		$\sigma^2 = 4$	
	MAP	MGP	MAP	MGP
Uniforme	1,27 ± 0,15	1,1 ± 0,13	2,28 ± 0,43	2,02 ± 0,41
Normal	0,85 ± 0,10	0,85 ± 0,10	1,28 ± 0,16	1,24 ± 0,15
FP	6,75 ± 0,85	2,38 ± 0,38	7,09 ± 0,97	4,15 ± 0,66

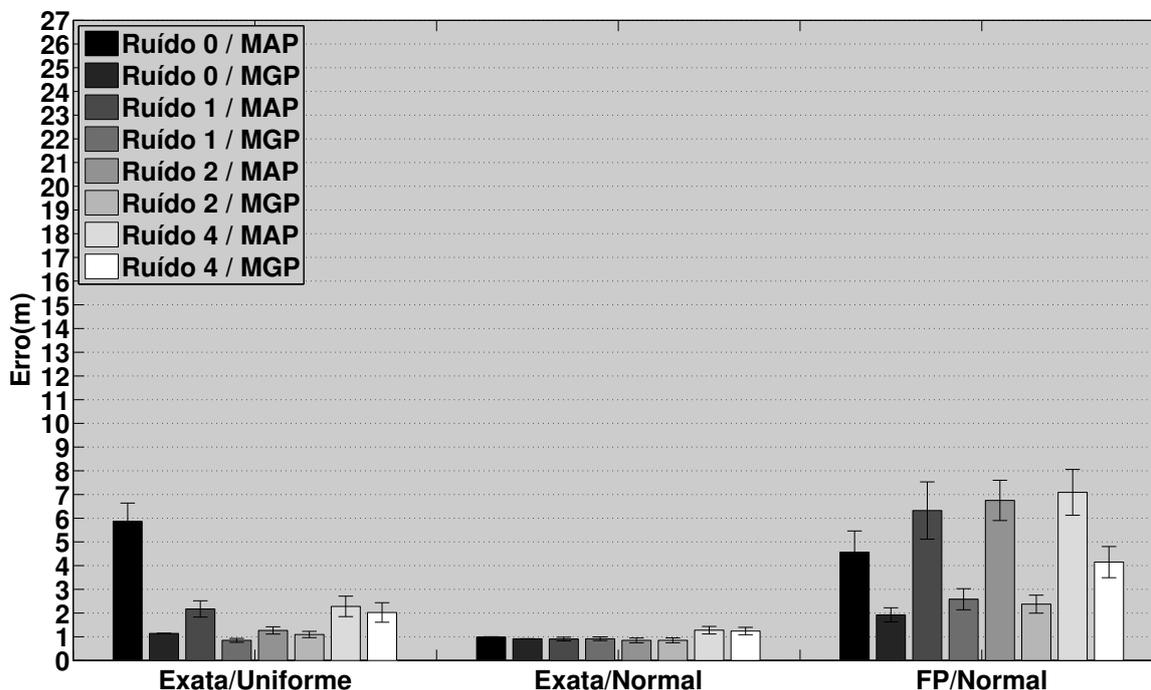


Figura 4.9. Resultados dos diferentes métodos na inferência da localização do nó sensor 3, levando em consideração os níveis de perturbação no sinal e o estimador. Os resultados aqui mostrados podem ser vistos na Tabela 4.4.

Tabela 4.5. Média e erro padrão dos resultados da localização do nó sensor 7. Referente à Figura 4.10. Valores em negrito representam o menor erro de localização dado o processo de inferência e a perturbação no RSSI.

Erro em metros para o nó sensor 7				
	$\sigma^2 = 0$		$\sigma^2 = 1$	
	MAP	MGP	MAP	MGP
Uniforme	9,2 ± 0,10	1,28 ± 0,00	4,25 ± 0,39	2,18 ± 0,09
Normal	1,51 ± 0,00	1,47 ± 0,00	1,38 ± 0,05	1,38 ± 0,04
FP	3,55 ± 0,51	2,04 ± 0,27	5,51 ± 0,90	1,45 ± 0,26
	$\sigma^2 = 2$		$\sigma^2 = 4$	
	MAP	MGP	MAP	MGP
Uniforme	2,55 ± 0,17	2,48 ± 0,15	2,22 ± 0,27	2,19 ± 0,25
Normal	1,26 ± 0,09	1,26 ± 0,10	1,34 ± 0,13	1,33 ± 0,13
FP	4,89 ± 0,67	1,77 ± 0,22	10,61 ± 1,68	7,85 ± 1,70

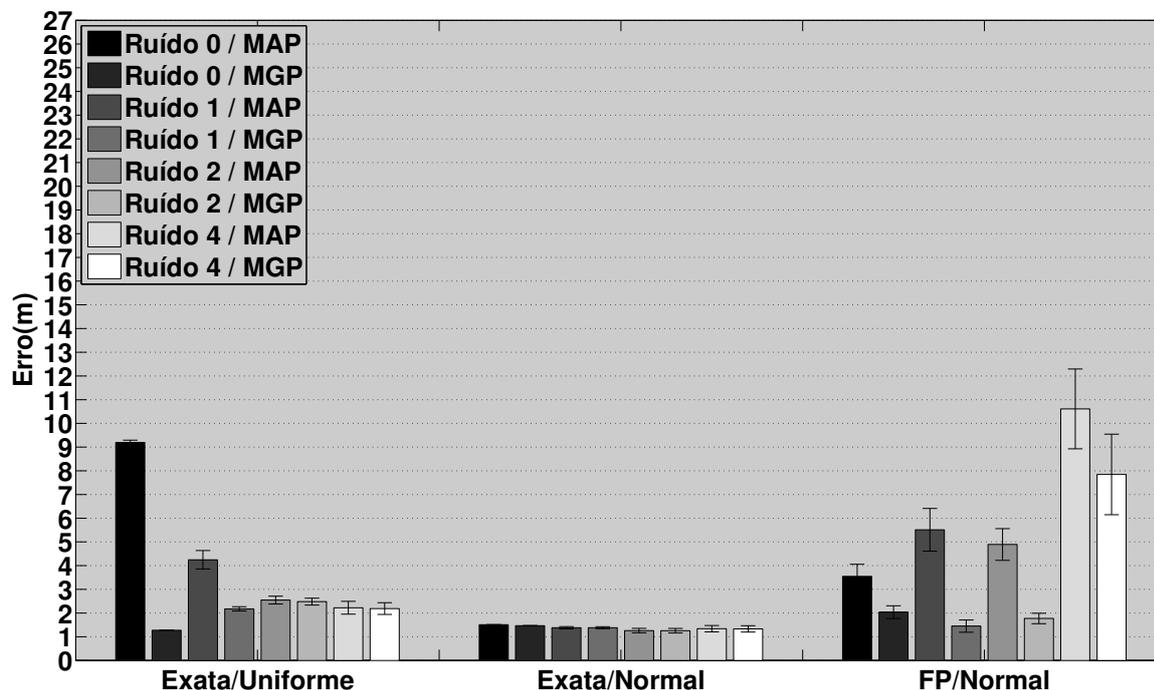


Figura 4.10. Resultados dos diferentes métodos na inferência da localização do nó sensor 7, levando em consideração os níveis de perturbação no sinal e o estimador. Os resultados aqui mostrados podem ser vistos na Tabela 4.5.

Tabela 4.6. Média e erro padrão dos resultados da localização do nó sensor 14. Referente à Figura 4.11. Valores em negrito representam o menor erro de localização dado o processo de inferência e a perturbação no RSSI.

Erro em metros para o nó sensor 14				
	$\sigma^2 = 0$		$\sigma^2 = 1$	
	MAP	MGP	MAP	MGP
Uniforme	10,12 ± 0,51	4,41 ± 0,00	9,47 ± 0,47	2,61 ± 0,22
Normal	0,75 ± 0,00	0,8 ± 0,00	1,24 ± 0,20	1,24 ± 0,18
FP	8,84 ± 1,81	3,65 ± 0,50	8,63 ± 1,32	3,94 ± 0,68
	$\sigma^2 = 3$		$\sigma^2 = 4$	
	MAP	MGP	MAP	MGP
Uniforme	5,05 ± 0,73	3,51 ± 0,33	8,37 ± 1,21	6,05 ± 1,08
Normal	2,13 ± 0,38	1,99 ± 0,34	18,06 ± 6,93	18,06 ± 6,93
FP	9,84 ± 1,30	4,54 ± 0,81	21,95 ± 4,61	19,71 ± 4,72

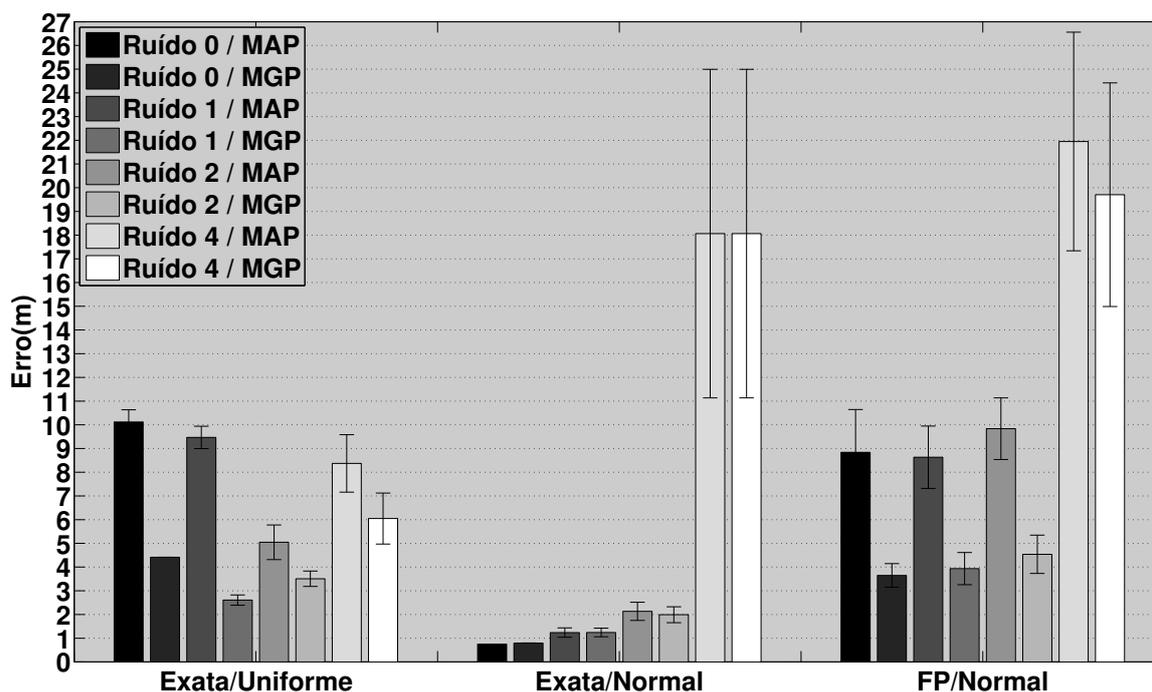


Figura 4.11. Resultados dos diferentes métodos na inferência da localização do nó sensor 14, levando em consideração os níveis de perturbação no sinal e o estimador. Os resultados aqui mostrados podem ser vistos na Tabela 4.6.

4.4 Comparando o tempo de atualização do estado de crença

Nesta seção, será apresentada uma análise do tempo utilizado na atualização do estado de crença da posição do nó sensor em cada processo de inferência.

A partir dos resultados, Figura 4.12 e Tabela 4.7, pode-se afirmar que o método de inferência exata com observação uniforme é o mais rápido, pois o cálculo da probabilidade é feito somente uma vez e atribuído as células do *grid*. Os outros métodos, que utilizam o modelo de observação normal, gastam mais tempo, pois precisam recalcular a probabilidade de acordo com a distância, tanto das células no caso do método exato quanto das partículas no método aproximado, tornando o processo de atualização de crença mais lento. Naturalmente, o método de inferência aproximada (filtro de partículas) é mais lento quando há mais partículas, pois a atualização de mais partículas acarreta num acréscimo do número de sorteios que dependem de uma escolha aleatória. Também é importante lembrar que este último utiliza um modelo probabilístico mais complexo que leva em consideração o estado de crença da posição do robô. Então, mesmo agregando mais informação na atualização do estado de crença,

o método aproximado manteve um tempo competitivo em relação aos outros métodos de inferência.

Tabela 4.7. Tempo gasto de atualização do estado de crença de cada método de inferência.

Método	Tempo(ms)
Inferência exata uniforme	12,7055 \pm 5,4449
Inferência exata normal	46,7730 \pm 13,7204
Filtro de partículas 1000 partículas	48,1992 \pm 21,8349
Filtro de partículas 2000 partículas	67,8300 \pm 10,4079
Filtro de partículas 4000 partículas	159,2545 \pm 46,2467

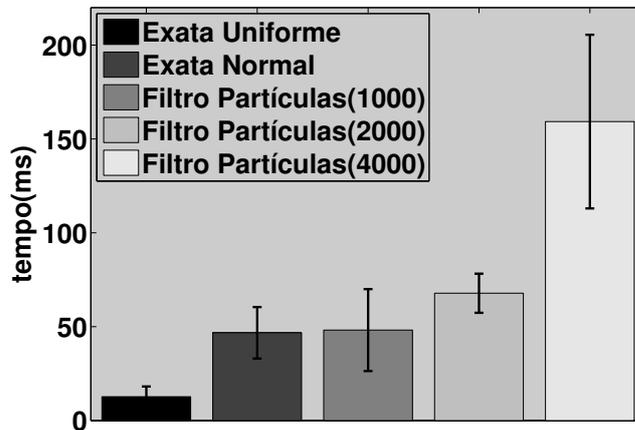


Figura 4.12. Comparação do tempo de atualização do estado de crença de cada método de inferência

Para verificar se os resultados de tempo possuem uma diferença estatística entre eles, um teste *one-way* ANOVA foi realizado inicialmente. No teste, para um $\alpha < 0,05$, foi obtido um valor $p < \alpha$. Isto implica que os tempos são estatisticamente diferentes. Porém, ao visualizar a Figura 4.12, pode-se perceber que o tempo obtido com o método de inferência exata com modelo de observação normal e o método de inferência aproximada com 1000 partículas são parecidos, pois possuem médias e variâncias semelhantes. Para melhor esclarecer essa situação, um teste *t-student* foi realizado com esses dois resultados. Mesmo assim, o resultado p obtido foi inferior a α , cujo significado foi mostrar que são estatisticamente diferentes. Portanto, todos os processo de inferência da posição da localização de nós sensores obtiveram um tempo de atualização de crença estatisticamente diferente.

4.5 Análise dos métodos de inferência

Esta seção contém a análise estatística dos resultados de cada método de inferência descrito no Capítulo 3. Inicialmente, foi analisado se a variação dos fatores nos cenários influenciam no resultado desses métodos. Os métodos que serão analisados independentemente são: inferência exata com modelo de observação uniforme, inferência exata com modelo de observação normal e filtro de partículas com modelo de observação normal. O filtro de partículas com modelo de observação uniforme não foi testado porque os resultados do modelo de observação uniforme não se mostraram tão bons quando aplicado ao método de inferência exata. Consequentemente, uma aplicação desse modelo de observação num método aproximado não irá trazer resultados melhores.

Os fatores analisados são a perturbação do RSSI, intervalo de tempo, a distância do nó sensor e o estimador. Essa combinação de fatores resulta em 480 cenários. Foram 21 execuções de cada cenário, sem critério pré-definido para a escolha do número de repetições dos experimentos, onde foi verificado o quanto que a perturbação no RSSI, o intervalo de tempo de aquisição e estimador são relevantes na localização de um nó sensor. Como vários nós sensores com características diferentes serão analisados, é esperado que a análise estatística mostre se há correlação entre o erro de localização e a distância entre o nó sensor e o robô.

4.5.1 Análise dos métodos de inferência separados

Na presente subseção, serão apresentados os resultados das análises estatísticas advindos dos erros de localização dos métodos de inferências separadamente. Esses resultados baseiam-se nos dados descritos no Apêndice A, nas Seções A.1, A.2 e A.3. Nestas seções, estão as tabelas com os valores de p , que é valor utilizado para afirmar se um determinado fator, ou interação de fatores, foi significativo na localização de um nó sensor. Para isso, é verificado se $p < \alpha | \alpha = 0,5$.

4.5.1.1 Perturbação no RSSI \times estimador \times intervalo

Uma análise estatística a partir de um teste *n-way* ANOVA foi realizada com intuito de verificar se os fatores e a interação entre eles afetam o erro de localização. Os fatores verificados nesse teste são: a variação do nível de perturbação no RSSI, o estimador e o intervalo de amostra. E o resultado pode ser acompanhado na Figura 4.13.

Em termos gerais, a perturbação no RSSI teve impacto em cada método de inferência testado. Os intervalos de tempo de amostragem do RSSI testados não trouxeram

Método	$p(x1)$	$p(x2)$	$p(x3)$	$p(x1x2)$	$p(x1x3)$	$p(x2x3)$	$p(x1x2x3)$
Exata uniforme	★	★	★	★	★	★	★
Exata normal	★	★	★	★	★	★	★
Filtro de partículas	★	★	★	★	★	★	★

Figura 4.13. Resultado da análise estatística dos fatores (perturbação ($x1$), estimador ($x2$) e intervalo de tempo ($x3$)) para cada método de inferência. Estrela verde caracteriza que o fator, ou interação entre fatores, foi significativo para os resultados de localização de todos os nós sensores, estrela azul caracteriza que o fator, ou interação entre fatores, foi significativo na maioria dos resultados, e estrela vermelha representam que o fator, ou interação entre fatores, não foi significativo no erro de localização da maioria, ou na totalidade, dos nós sensores.

um erro estatisticamente significativo no erro de localização dos nós sensores. A vantagem dessa conclusão é tornar possível a redução de processamento para a localização dos nós devido à diminuição da frequência de amostragem do RSSI, isto é, o número de amostras a serem processadas será menor e o processamento dessas amostras resultará num erro de localização estatisticamente igual ao erro que é obtido se estes forem adquiridos e processados com uma frequência maior. A análise conjunta entre perturbação e intervalo revelou que ambos fatores em conjunto não são estatisticamente significativos.

Também pode-se afirmar que a heterogeneidade dos resultados da análise estatística para nós sensores com diferentes características de distância afeta o erro de localização. Isso é melhor visualizado nas tabelas, citadas no começo da seção, onde o valor p dos fatores e interação de fatores destes nós sensores variam bastante, ou seja, a posição relativa do nó sensor em função da posição do robô é significativa nos métodos de localização.

Na inferência exata uniforme, quando o fator analisado é o estimador, nota-se que os sensores com um p estatisticamente não significativo foram os que tiveram tiveram uma a distância mínima baixa, isso demonstra que o estimador não faz diferença quando o nó sensor está muito perto do robô que está o localizando. Na inferência exata normal, em relação ao fator estimador, os nós sensores que são caracterizados por uma a distância média e mínima altas do robô mostraram que a estimativa da posição do nó sensor é afetada se o robô mantiver a uma distância grande do nó sensor.

4.5.1.2 Perturbação no RSSI \times estimador

Na análise anterior, o intervalo de tempo foi irrelevante para o erro de localização e este será desconsiderado para verificar se os outros fatores ainda continuam significativos dado este fator. Assim, será realizada a dos resultados obtidos a partir outros dois fatores, a perturbação no RSSI e estimador, para diferentes nós sensores. O resultado pode ser visto na Figura 4.14.

Método	p(x1)	p(x2)	p(x1x2)
Exata uniforme	★	★	★
Exata normal	★	★	★
Filtro de partículas	★	★	★

Figura 4.14. Resultado da análise estatística dos fatores (perturbação no RSSI (x1) e estimador (x2)) para cada método de inferência. Estrela verde caracteriza que o fator, ou interação entre fatores, foi significativo para os resultados de localização de todos os nós sensores, estrela azul caracteriza que o fator, ou interação entre fatores, foi significativo na maioria dos resultados, e estrela vermelha representam que o fator, ou interação entre fatores, não foi significativo no erro de localização da maioria, ou na totalidade, dos nós sensores.

A partir das análises do *two-way* ANOVA fixando o método de inferência, podemos afirmar que o resultado da avaliação mostrou que a perturbação do sinal faz diferença na localização de nós sensores, pois influencia no erro de localização. A alteração do estimador teve um forte impacto no erro de localização dos métodos de inferência exata uniforme e no filtro de partículas. Na inferência exata uniforme era esperado isso acontecer por causa da convergência do MAP em sensores que estão muito distante. Na análise dos fatores para o filtro de partículas, já era esperado que os fatores fossem significativos, porém a interação desses não se mostrou significativa porque a estimativa de posição dos nós sensores é realizada por amostras aleatórias de um estado de crença, ou seja, de um conjunto parcial de amostras. O que não acontece nos métodos exatos, pois nesses métodos o estado de crença, utilizado para gerar as estimativas da posição, ocupa todo o ambiente. A inferência exata normal é a que menos sofre com a alteração do estimador, isto é devido o fato de ser exata e possuir a distribuição que melhor se encaixa nesse modelo de localização de nós sensores, tornando o estimador quase irrelevante na maioria dos casos.

4.5.2 Método de inferência é significativo?

Para verificar se a utilização de diferentes métodos de inferência é significativa em relação ao erro de localização do nó sensor, foi realizada uma análise estatística considerando-os e os fatores que se mostraram significativos nas análises de cada método de inferência, descritas na Subseção 4.5.1. Assim, o teste conta com 480 cenários formados pela variação dos fatores: método de inferência, ruído no RSSI e estimador, e 63 repetições para cada cenário. O resultado da análise está ilustrada na Figura 4.15.

$p(x1)$	$p(x2)$	$p(x3)$	$p(x1x2)$	$p(x1x3)$	$p(x2x3)$	$p(x1x2x3)$
★	★	★	★	★	★	★

Figura 4.15. Resultado da análise estatística dos fatores (perturbação no RSSI ($x1$), estimador ($x2$) e método ($x3$)) em relação ao erro de localização dos nós sensores. Estrela verde caracteriza que o fator, ou interação entre fatores, foi significativo para os resultados de localização de todos os nós sensores, estrela azul caracteriza que o fator, ou interação entre fatores, foi significativo na maioria dos resultados, e estrela vermelha representam que o fator, ou interação entre fatores, não foi significativo no erro de localização da maioria, ou na totalidade, dos nós sensores.

Um teste *n-way* ANOVA com os fatores supracitados foi realizado e a partir dos resultados do teste (Figura 4.15 - que corresponde ao resultado apresentado na Tabela A.7 do Apêndice A) pode-se afirmar que os fatores influenciaram da seguinte forma: Existe um efeito estatisticamente significativo devido ao fator nível de ruído aplicado ao RSSI. A alteração do estimador mostrou-se estatisticamente significativo em relação ao erro de localização. A mudança do método de inferência tem influência no erro de localização. A interação do ruído e estimador tem influência na quantidade de erro de uma forma estatisticamente significativa, ou seja, o erro é estatisticamente significante. A interação ruído e método tem influência no erro de localização. A interação estimador e método afeta o erro de localização. A interação entre ruído, estimador e método influenciam no erro de localização significativamente.

4.6 Considerações finais

A inferência exata com distribuição uniforme, inferência exata com distribuição normal e filtro de partículas com distribuição normal são os três métodos de inferência testados no problema de localização de nós sensores e estão baseados nos HMMs do arcabouço probabilístico. Cada método probabilístico resulta num estado de crença da posição

do nó sensor e para comparar estes estados de crença é necessário fazer uma estimativa da posição do nó sensor utilizando um estimador.

Na Seção 4.5 foi descrita a análise de alguns fatores para verificar se estes influenciam na localização de nós sensores. Os fatores analisados foram: a perturbação no sinal, intervalo de tempo de aquisição do RSSI e as diferentes posições de dos sensores. A análise mostrou que a variação de intervalo de aquisição do RSSI não fez diferença em relação ao erro de localização da maioria dos nós sensores e, como já era esperado, a análise mostrou que a perturbação no sinal é significativa em todos os cenários. A variação dos intervalos de tempo não se mostrar significativa é um ponto positivo em termos de uso de CPU, pois o processamento necessário para a localização de nós sensores pode ser feito em intervalos maiores. Isto significa que será obtido a mesma precisão de localização com uma frequência menor da atualização do estado de crença da posição do nó sensor.

A análise também mostrou que os métodos de inferência, utilizando estimadores distintos, resultaram diferenças significativas no erro de localização dos nós sensores. Foi percebido que tanto o MGP quanto o MAP agiram diferentemente em cada método de inferência, com exceção do método de exato com modelo de observação normal. Na inferência exata com distribuição uniforme e no filtro de partículas o estimador MGP foi melhor que o MAP na maioria dos casos. Na inferência exata com modelo normal era esperado que tanto MAP quanto MGP resultasse em bons resultados devido à característica da distribuição melhor se ajustar ao problema. Este pode ser visto na Figura 4.16, onde os resultados de ambos os estimadores quase se sobrepõem.

No método exato uniforme, o estimador MAP não dá bons resultados devido à característica da distribuição uniforme e a causa disso pode ser vista na Figura 4.17, onde percebe-se que o estado de crença da posição do nó sensor, a área sobre o mapa que tem a maior probabilidade de ter o nó sensor, mantém uma probabilidade igual numa região muito grande. Como esse estimador seleciona a primeira ocorrência com o valor que tem probabilidade mais alta, este vai dar os piores resultados, pois todas as probabilidades nesta área são iguais.

O problema do filtro de partículas com o estimador MAP está na maneira como a estimativa escolhida, pois a atualização do estado de crença é feita para apenas um conjunto limitado de hipóteses (partículas) e apenas uma dessas será o representante para estimativa (a que tiver maior probabilidade). A vantagem de se usar o MGP neste caso é que o estimador faz a estimativa por meio do conjunto de todas partículas, levando em consideração toda a informação existente. A Figura 4.18 mostra um resultado dessa característica, onde a estimativa por MGP é melhor que a do MAP.

Dentre os métodos comparados, o modelo de inferência exata com modelo de



Figura 4.16. MAP \times MGP na inferência exata com distribuição normal. A cruz cinza é a posição verdadeira do nó sensor, a cruz vermelha é a estimativa por MGP e a azul por MAP, o ponto preto com um "R" é a posição do robô e o número ao lado é o RSSI na localização do robô.

observação normal obteve os melhores resultados de localização em quase todos os cenários. O bom resultado é devido ao bom ajuste da função normal na triangulação da posição de nós sensores, porém houve problemas de falsa localização quando houve uma alta intensidade de perturbação no RSSI, conseqüentemente houve um grande erro na localização do nó sensor nesta situação. Outro efeito desse método é que ambos os estimadores tiveram resultados semelhantes.

O método de inferência exata com modelo de observação uniforme mostrou-se melhor em alguns casos e na maioria desses quando o resultado da localização é obtida por MGP.

O filtro de partículas, que também utiliza modelo de observação normal, não se destacou diante dos outros, porém é importante lembrar que este competiu utilizando



Figura 4.17. MAP \times MGP na inferência exata com distribuição uniforme. A cruz cinza é a posição verdadeira do nó sensor, o ponto preto com um "R" é a posição do robô e o número ao lado é o RSSI na localização do robô.

um modelo probabilístico que *considera* as incertezas passadas pelo sistema de localização do robô, assim a probabilidade de acrescentar erros é considerada maior. No entanto, este método se mostrou bastante interessante em todos os cenários, pois manteve um erro de localização não tão alto e competitivo diante dos outros métodos. Vale lembrar que este também sofre do mesmo problema que o método de inferência exata com modelo de observação normal, pois compartilha o problema quando utilizado num cenário com a perturbação no RSSI muito alta e um nó sensor muito distante. Esse efeito pode ser visto novamente na Figura 4.11.

Outro ponto observado nos resultados é a relação entre caminho do robô e o erro de localização, pois se o robô realizar um caminho que o deixe mais próximo do nó sensor, melhor será a localização, ou seja, o caminho percorrido pelo robô influencia a localização de nós sensores em sistemas baseados em RSSI.



Figura 4.18. MAP \times MGP no filtro de partículas com modelo de observação normal. As cruzes vermelhas são as partículas (2000 no total), a cruz preta com a palavra "GT" é a posição verdadeira do nó sensor, a cruz verde é a estimativa por MGP e a azul por MAP, o ponto preto com um "R" é a posição do robô e o número ao lado é o RSSI na localização do robô.

Capítulo 5

Conclusões

Este capítulo apresenta um resumo dos esforços realizados considerando a proposta de um arcabouço probabilístico para localização de nós sensores de uma RSSF.

O objetivo da metodologia é a localização de nós sensores a partir do RSSI e um robô localizado com precisão. Nesta dissertação, uma metodologia para localização de nós sensores foi desenvolvida com fundamentação probabilística. Estabelecemos relações de interação entre os variáveis aleatórias que pertencem ao problema, em busca dos objetivos de cada metodologia.

A metodologia trouxe contribuições para a pesquisa em redes de sensores sem fios e robótica, especificamente no tópico de localização. Embora existam diversas maneiras de localizar nós sensores, existem situações nas quais é proibitivo o uso destas, assim o uso de RSSI pode ser uma saída. Consequentemente, expandir técnicas de localização passa ser uma tarefa imprescindível para os pesquisadores. Alguns empecilhos para desenvolver uma abordagem de localização probabilística com base no RSSI são intrínsecos a natureza do tema, por exemplo a multidisciplinaridade do tema e a dificuldade da modelagem do problema quando uma maior complexidade é adicionada.

O arcabouço probabilístico para localização de nós sensores proposto estabelece uma relação do RSSI com a posição (precisa) de um robô para realizar a localização dos nós sensores. Os cenários para localização foram variados em relação ao nível do ruído no sinal de rádio, ao método de inferência, estimador da posição do nó sensor e intervalo entre as aquisições de amostras RSSI. Uma das contribuições dessa dissertação foi a análise da interação entre a variação de cenários com o erro de localização dos nós sensores para mostrar quais dos fatores influenciaram no resultados de localização.

Uma outra contribuição é a construção de uma ferramenta de localização de nós sensores no ROS. Esta contribuição pode ser aprimorada no intuito da disponibilização de um módulo parametrizável que realize estas funções para a comunidade robótica,

onde outros pesquisadores poderão alterar e adicionar os recursos necessários para suas respectivas pesquisas.

Uma outra contribuição foi o artigo, Carvalho et al. [2012], que se trata da localização de nós sensores através de um modelo de observação baseado numa distribuição uniforme em ambientes internos.

No entanto, vários problemas foram enfrentados durante o processo de desenvolvimento do trabalho descrito nessa dissertação. Alguns deles persistem, tal como a determinação automática dos parâmetros dos modelos de observação. Nesses casos, onde não tínhamos a experiência necessária ou uma solução elegante eficiente para solucionar, tentamos sobrepor o problema assumindo soluções aceitáveis, porém não definidas, ou comprovadas, pela literatura. No entanto, decisões como a utilização de uma variância fixa acrescentou à evolução do trabalho, pois permitiu a evolução do desenvolvimento como um todo.

Os experimentos mostraram que o arcabouço desenvolvido produz bons resultados para a localização de nós sensores. Porém esses resultados dependem muito das características de cenário/ambiente que a abordagem é submetida. Por esse motivo, comparações entre as abordagens não são tão comuns na literatura, pois cada trabalho adota parâmetros de ambiente, sinal e movimentação do robô diferentes. Nessa condições, a comparação entre elas seria injusta.

Visto a evolução deste trabalho e problemas que não foram abordados, podemos enumerar algumas possíveis extensões: a) Assumindo que conheça alguma informação sobre os fatores que influenciam a localização dos nós sensores, o próximo passo é continuar o desenvolvimento do modelo geral que realiza localização dos nós e do nós sensores simultaneamente, assim como proposto neste trabalho. b) a criação de um módulo que realiza uma filtragem do RSSI para reduzir os efeitos do sombreamento do sinal. Nesta direção, o arcabouço poderá gerar melhores resultados em todos os cenários, ou pelo menos normalizar os resultado em erros de localização diante de cenários distintos; c) o desenvolvimento de um módulo que gere um mapa de propagação de sinal verossímil ao do ambiente real no simulador. Este módulo é bastante interessante para a comunidade, pois os testes em simuladores se tornarão mais verossímeis com a realidade; d) outra possível ampliação na primeira parte do arcabouço é relacionada a escolha autônoma do caminho, afim de realizar a melhor localização de um nó sensor. Neste sentido, a utilização de um *Partially Observable Markov Decision Process* (POMDP) para levar em consideração as variáveis aleatórias disponíveis decidindo qual o melhor caminho que o robô deve tomar para maximizar o resultado; e) um outro problema que surge é detecção de nós sensores defeituosos no processo da localização destes, isso agregaria mais uma funcionalidade no arcabouço e nas ferramentas dis-

poníveis para comunidade; f) existe a possibilidade de utilizar mais de um robô para realizar a localização de nós sensores, porém uma análise estatística deste fator não foi realizada, conseqüentemente não se sabe a influência deste fator nos demais fatores analisados neste trabalho; g) Comparar a metodologia apresentada no presente trabalho com outros trabalhos da literatura usando os mesmos parâmetros de ambiente, robô e sinal. Inclusive, comparando o resultado dessas abordagens quando o robô se mantém a determinadas distâncias do nó sensor;

Referências Bibliográficas

- 3Com (2006). 3com wireless antennas product guide.
- Baggio, A. & Langendoen, K. (2008). Monte Carlo localization for mobile wireless sensor networks. *Ad Hoc Networks*, 6(5):718--733.
- BlackSocks (2012). New: Smarter socks.
- Caballero, F.; Merino, L.; Maza, I. & Ollero, A. (2008). A particle filtering method for wireless sensor network localization with an aerial robot beacon. In *Robotics and Automation, 2008. ICRA 2008. IEEE International Conference on*, pp. 596--601. IEEE.
- Caballero, F.; Merino, L. & Ollero, A. (2010). A general gaussian-mixture approach for range-only mapping using multiple hypotheses. In *Robotics and Automation (ICRA), 2010 IEEE International Conference on*, pp. 4404--4409. IEEE.
- Carvalho, F.; Santos, E.; Iabrudi, A.; Chaimowicz, L. & Campos, M. F. M. (2012). Indoor wireless sensor localization using mobile robot and rssi. In *Annals of the Sixth International Workshop on Wireless Sensor, Actuator and Robot Networks*. Las Vegas.
- Chandrasekhar, V. & Seah, W. (2007). An area localization scheme for underwater sensor networks. In *OCEANS 2006-Asia Pacific*, pp. 1--8. IEEE.
- Chandrasekhar, V.; Seah, W.; Choo, Y. & Ee, H. (2006). Localization in underwater sensor networks: survey and challenges. In *International Conference on Mobile Computing and Networking: Proceedings of the 1st ACM international workshop on Underwater networks*, volume 25, pp. 33--40.
- Djugash, J.; Singh, S. & Grocholsky, B. (2008). Decentralized mapping of robot-aided sensor networks. In *Robotics and Automation, 2008. ICRA 2008. IEEE International Conference on*, pp. 583--589. IEEE.

- Fink, J. & Kumar, V. (2010). Online methods for radio signal mapping with mobile robots. In *Robotics and Automation (ICRA), 2010 IEEE International Conference on*, pp. 1940--1945. IEEE.
- Finkenzeller, K. et al. (2010). *RFID Handbook: Fundamentals and applications in contactless smart cards, radio frequency identification and near-field communication*. Wiley.
- Fisher, R. (1925). *Statistical methods for research workers*. Edinburgh Oliver & Boyd.
- Fox, D. (2001). Kld-sampling: Adaptive particle filters. In *Advances in Neural Information Processing Systems 14*. MIT Press.
- Gerkey, B.; Vaughan, R. & Howard, A. (2003). The player/stage project: Tools for multi-robot and distributed sensor systems. In *Proceedings of the 11th international conference on advanced robotics*, volume 1, pp. 317--323. Portugal.
- Goldsmith, A. (2005). *Wireless communications*. Cambridge Univ Pr.
- He, T.; Huang, C.; Blum, B.; Stankovic, J. & Abdelzaher, T. (2003). Range-free localization schemes for large scale sensor networks. In *Proceedings of the 9th annual international conference on Mobile computing and networking*, pp. 81--95. ACM.
- Kurth, D.; Kantor, G. & Singh, S. (2003). Experimental results in range-only localization with radio. In *Intelligent Robots and Systems, 2003.(IROS 2003). Proceedings. 2003 IEEE/RSJ International Conference on*, volume 1, pp. 974--979. IEEE.
- Lisboa Rodrigues, M. (2011). Localizacao em ambientes internos utilizando multiplas tecnologias sem fio. Dissertação de Mestrado, Universidade Federal de Minas Gerais.
- Liu, H.; Darabi, H.; Banerjee, P. & Liu, J. (2007). Survey of wireless indoor positioning techniques and systems. *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, 37(6):1067--1080.
- LogiData, S. (2007). Schreiner logidata integrates rfid labels into reusable shipping containers.
- MATLAB (2011). *version 7.12.0 (R2011a)*. The MathWorks Inc., Natick, Massachusetts.
- Menegatti, E.; Zanella, A.; Zilli, S.; Zorzi, F. & Pagello, E. (2009). Range-only slam with a mobile robot and a wireless sensor networks. In *Robotics and Automation, 2009. ICRA '09. IEEE International Conference on*, pp. 8--14. IEEE.

- Muthukrishnan, K.; Lijding, M. & Havinga, P. (2005). *Towards smart surroundings: Enabling techniques and technologies for localization*. Springer.
- Niculescu, D. & Nath, B. (2003). Dv based positioning in ad hoc networks. *Telecommunication Systems*, 22(1):267--280.
- Quigley, M.; Conley, K.; Gerkey, B. P.; Faust, J.; Foote, T.; Leibs, J.; Wheeler, R. & Ng, A. Y. (2009). Ros: an open-source robot operating system. In *ICRA Workshop on Open Source Software*.
- Rappaport, T. (1996). *Wireless communications: principles and practice*. IEEE press.
- Thrun, S. (2002). Particle filters in robotics. In *Proceedings of the 17th Annual Conference on Uncertainty in AI (UAI)*.
- Thrun, S.; Burgard, W. & Fox, D. (2005). *Probabilistic Robotics*. Intelligent Robotics and Autonomous Agents. Mit Press.
- Yao, Q.; Tan, S.; Ge, Y.; Yeo, B. & Yin, Q. (2005). An area localization scheme for large wireless sensor networks. In *Vehicular Technology Conference, 2005. VTC 2005-Spring. 2005 IEEE 61st*, volume 5, pp. 2835--2839. IEEE.
- Zagzebski, J. (1996). *Essentials of ultrasound physics*, volume 1. Mosby.

Apêndice A

Análises dos métodos de inferência

A.1 Inferência exata uniforme

A.1.1 Perturbação no RSSI x estimador x intervalo

Na Tabela A.1 cada linha mostra o resultado do teste aplicado aos resultados de localização dos nós sensores e cada coluna representa o valor p usado para avaliar a significância de um fator analisado no teste e as interações entre fatores. A partir dos resultados da análise podemos ter as seguintes conclusões:

- Em todos os casos avaliados existe um efeito estatisticamente significativo devido ao fator nível de perturbação aplicada ao RSSI.
- A alteração do estimador mostrou ser significativa na maior parte dos experimentos.
- A mudança do intervalo de tempo na amostragem do RSSI não causa um impacto significativo no erro de localização na maior parte dos nós sensores.
- A interação do nível de perturbação no sinal e do estimador afetam o erro de localização significativamente na maior parte dos sensores.
- A interação do nível de perturbação no sinal e do intervalo não afetam o erro de localização significativamente na maior parte dos sensores.
- A interação do estimador e do intervalo de tempo não afetam o erro de localização significativamente na maior parte dos sensores.

- A interação dos três fatores mostrou-se não significativa em todos nós sensores. Porém, como a interação dos dois primeiros fatores é significativa, há o indício que a consideração do intervalo de tempo na interação torna-a menos significativa.

Tabela A.1. Resultado do *n-way* ANOVA (perturbação x estimador x intervalo) para uma inferência exata uniforme

Inferência exata uniforme Perturbação no RSSI (x1) x Estimador (x2) x Intervalo (x3)							
Sensor	p(x1)	p(x2)	p(x3)	p(x1x2)	p(x1x3)	p(x2x3)	p(x1x2x3)
1	0,00	0,00	0,00	0,00	0,17	0,38	0,83
2	0,00	0,06	0,00	0,07	0,00	0,80	0,99
3	0,00	0,00	0,94	0,00	0,68	0,97	0,80
4	0,00	0,00	0,17	0,00	0,10	0,92	0,98
5	0,00	0,00	0,41	0,00	0,60	0,89	0,58
6	0,00	0,00	0,23	0,00	0,90	0,34	0,95
7	0,00	0,00	0,04	0,00	0,00	0,38	0,88
8	0,00	0,00	0,28	0,01	0,00	0,89	0,64
9	0,00	0,00	0,00	0,00	0,37	0,08	0,29
10	0,00	0,06	0,10	0,08	0,06	0,08	0,24
11	0,00	0,49	0,06	0,34	0,00	0,60	0,47
12	0,00	0,13	0,00	0,96	0,78	0,63	1,00
13	0,00	0,00	0,00	0,00	0,38	0,08	0,52
14	0,00	0,00	0,49	0,00	0,21	0,28	0,88
15	0,00	0,00	0,47	0,00	0,64	0,96	0,97
16	0,00	0,00	0,07	0,00	0,25	0,48	0,56
17	0,00	0,00	0,44	0,00	0,30	0,50	0,37
18	0,00	0,00	0,96	0,00	0,01	0,36	0,09
19	0,00	0,00	0,89	0,00	0,03	0,80	0,07
20	0,00	0,00	0,01	0,00	0,04	0,32	0,19

A.1.2 Perturbação no RSSI x estimador

Na análise anterior, o intervalo de tempo foi irrelevante para o erro de localização e este será desconsiderado para verificar se os outros fatores ainda continuam significativos desconsiderando este fator. Assim, a análise dos resultados, para diferentes nós sensores, obtidos na análise dos outros dois fatores – perturbação no RSSI e estimador da posição do nó sensor – da localização do nó sensor estão contidos na Tabela A.2.

A partir dos resultados apresentados das análises com o *two-way ANOVA*, podemos ter as seguintes conclusões:

- Existe um efeito estatisticamente significativo devido ao fator nível de perturbação aplicado ao RSSI.

- A alteração do estimador fez com que a média do erro de localização fosse significativamente diferente na maior parte dos sensores.
- A interação entre perturbação e estimador afeta a quantidade de erro de uma forma estatisticamente significativa na maior parte dos sensores.

Tabela A.2. Resultado do two-way ANOVA (perturbação x estimador) para uma inferência exata uniforme

Inferência exata uniforme			Perturbação no RSSI (x1) x Estimador (x2)
Sensor	p(x1)	p(x2)	p(x1x2)
1	0,00	0,00	0,00
2	0,00	0,07	0,08
3	0,00	0,00	0,00
4	0,00	0,00	0,00
5	0,00	0,00	0,00
6	0,00	0,00	0,00
7	0,00	0,00	0,00
8	0,00	0,00	0,01
9	0,00	0,00	0,00
10	0,00	0,06	0,09
11	0,00	0,51	0,37
12	0,00	0,13	0,96
13	0,00	0,00	0,00
14	0,00	0,00	0,00
15	0,00	0,00	0,00
16	0,00	0,00	0,00
17	0,00	0,00	0,00
18	0,00	0,00	0,00
19	0,00	0,00	0,00
20	0,00	0,00	0,00

A.2 Inferência exata normal

A.2.1 Perturbação no RSSI x estimador x intervalo

Uma análise estatística a partir de um teste *n-way* ANOVA foi realizada com o intuito verificar se os fatores e a interação entre eles afetam o erro de localização. Os fatores verificados no teste são: o nível de perturbação, o estimador e o intervalo de amostra. O resultado da análise é mostrado na Tabela A.3 e desses podemos ter as seguintes conclusões:

- Em todos os casos avaliados existe um efeito estatisticamente significativo devido ao fator nível de perturbação aplicado ao RSSI.
- A alteração do estimador não mostrou ser significativa na maior parte dos experimentos.
- Aproximadamente metade dos experimentos mostraram que o intervalo não mostrou ser significativo.
- A interação perturbação e estimador não afeta o erro de localização significativamente na maior parte dos sensores
- A interação do nível de perturbação no sinal e intervalo tempo não afeta o erro de localização significativamente na maior parte dos sensores.
- A interação estimador e intervalo de tempo não afeta o erro de localização significativamente em todos os nós sensores.
- A interação dos três fatores mostrou-se não significativa em todos nós sensores. Porém, como a interação dos dois primeiros fatores é significativa, há o indício que a consideração do intervalo de tempo na interação torna-a menos significativa.

A.2.2 Perturbação no RSSI x estimador

Na análise anterior, o intervalo de tempo é um fator que não apresentou uma representatividade afirmativa e nem negativa, porém quando verificada a interação dele com a intensidade da perturbação no sinal houve uma diminuição da representatividade desse. Isto é um indício que o intervalo de tempo também não é significativo no processo de localização. O estimador não ser significativo nessa abordagem era algo esperado, a distribuição normal estabelece as maiores densidades quando mais próximo da média e isto aproxima a estimativa criada por MGP e MAP. A partir dos resultados (Tabela A.4) apresentados podemos ter as seguintes conclusões:

- Existe um efeito estatisticamente significativo devido ao fator nível de perturbação aplicada ao RSSI.
- A alteração do estimador não se mostrou estatisticamente significativo em relação à média do erro de localização na maior parte dos nós sensores.
- A interação dos dois fatores não afeta a quantidade de erro de uma forma estatisticamente significativa na maior parte dos nós sensores.

Tabela A.3. Resultado do n -way ANOVA (perturbação x estimador x intervalo) para uma inferência exata normal

Inferência exata normal	Perturbação no RSSI (x1) x Estimador (x2) x Intervalo (x3)						
Sensor	p(x1)	p(x2)	p(x3)	p(x1x2)	p(x1x3)	p(x2x3)	p(x1x2x3)
1	0,00	0,63	0,21	0,99	0,72	1,00	1,00
2	0,00	0,89	0,00	0,94	0,00	1,00	1,00
3	0,00	0,34	0,00	0,49	0,31	0,49	0,65
4	0,00	0,31	0,11	0,40	0,24	0,38	0,45
5	0,00	0,37	0,03	0,67	0,58	0,60	0,71
6	0,00	0,92	0,04	1,00	0,04	1,00	1,00
7	0,00	0,88	0,00	1,00	0,00	0,98	1,00
8	0,00	0,64	0,00	0,64	0,04	0,99	0,98
9	0,00	0,95	0,01	1,00	0,26	1,00	1,00
10	0,00	0,13	0,02	0,94	0,01	0,81	0,98
11	0,00	0,32	0,11	0,98	0,14	0,87	0,99
12	0,00	0,87	0,04	1,00	0,75	0,96	1,00
13	0,00	0,70	0,00	0,98	0,01	0,92	1,00
14	0,00	0,03	0,86	0,00	0,96	0,83	0,96
15	0,00	0,00	0,66	0,00	0,84	0,24	0,13
16	0,00	0,02	0,13	0,00	0,12	0,87	0,99
17	0,00	0,00	0,15	0,00	0,19	0,20	0,15
18	0,00	0,01	0,09	0,00	0,86	0,98	1,00
19	0,00	0,01	0,02	0,00	0,19	0,16	0,08
20	0,00	0,07	0,02	0,04	0,07	0,20	0,13

A.3 Filtro de partículas com distribuição normal

A.3.1 Perturbação no RSSI x estimador x intervalo

Uma análise estatística a partir de um teste n -way ANOVA foi realizada com intuito de verificar se os fatores e a interação entre eles afetam o erro de localização. Os fatores verificados no teste são: o nível de perturbação no RSSI, o estimador e o intervalo de amostra. O resultado da análise é mostrado na Tabela A.5 e a partir desses resultados apresentados podemos ter as seguintes conclusões:

- Existe um efeito estatisticamente significativo devido ao fator nível de perturbação aplicada ao RSSI.
- A alteração do estimador mostrou ser significativa.
- O intervalo de tempo da amostragem do RSSI não causa um impacto significativo no erro de localização.

Tabela A.4. Resultado do two-way ANOVA (perturbação x estimador) para uma inferência exata normal

Inferência exata normal		Perturbação no RSSI (x1) x Estimador (x2)	
Sensor	p(x1)	p(x2)	p(x1x2)
1	0,00	0,62	0,99
2	0,00	0,89	0,95
3	0,00	0,34	0,49
4	0,00	0,32	0,41
5	0,00	0,37	0,67
6	0,00	0,92	1,00
7	0,00	0,89	1,00
8	0,00	0,65	0,65
9	0,00	0,95	1,00
10	0,00	0,14	0,94
11	0,00	0,32	0,98
12	0,00	0,87	1,00
13	0,00	0,71	0,98
14	0,00	0,02	0,00
15	0,00	0,00	0,00
16	0,00	0,02	0,00
17	0,00	0,00	0,00
18	0,00	0,01	0,00
19	0,00	0,01	0,00
20	0,00	0,07	0,04

- A interação do nível de perturbação no sinal e do estimador afetam o erro de localização significativamente na maior parte dos sensores.
- A interação do nível de perturbação no sinal e do intervalo não afetam o erro de localização significativamente na maior parte dos sensores.
- A interação do estimador e do intervalo de tempo não afetam o erro de localização significativamente na maior parte dos sensores.
- A interação dos três fatores mostrou-se não significativa em todos nós sensores.

A.3.2 Perturbação no RSSI x estimador

Como o intervalo de tempo da análise anterior mostrou-se irrelevante para o erro de localização, este será desconsiderado na análise posterior. A partir dos resultados (Tabela A.6) apresentados das análises com o *two-way* ANOVA, podemos ter as seguintes conclusões:

Tabela A.5. Resultado do n-way ANOVA (perturbação x estimador x intervalo) para um filtro de partículas

Filtro de partículas Perturbação no RSSI (x1) x Estimador (x2) x Intervalo (x3)							
Sensor	p(x1)	p(x2)	p(x3)	p(x1x2)	p(x1x3)	p(x2x3)	p(x1x2x3)
1	0,00	0,00	0,00	0,39	0,59	0,95	0,47
2	0,00	0,00	0,00	0,31	0,95	0,78	0,99
3	0,00	0,00	0,08	0,58	0,00	0,25	0,75
4	0,00	0,00	0,07	0,67	0,71	0,98	0,99
5	0,00	0,00	0,58	0,56	0,94	0,66	0,98
6	0,00	0,00	0,82	0,77	0,18	0,87	0,99
7	0,00	0,00	0,00	0,35	0,00	0,85	0,90
8	0,00	0,01	0,00	0,14	0,85	0,93	0,87
9	0,00	0,04	0,13	0,67	0,01	0,99	1,00
10	0,00	0,00	0,68	0,81	0,04	0,91	0,91
11	0,00	0,00	0,03	0,05	0,57	0,46	0,87
12	0,00	0,00	0,00	0,05	0,08	0,00	0,37
13	0,00	0,00	0,00	0,03	0,09	0,16	0,95
14	0,00	0,00	0,00	0,27	0,00	0,90	1,00
15	0,00	0,00	0,54	0,65	0,97	0,89	1,00
16	0,00	0,04	0,01	0,70	0,00	0,94	1,00
17	0,00	0,09	0,06	0,78	0,03	0,99	1,00
18	0,00	0,16	0,04	0,89	0,94	1,00	1,00
19	0,00	0,01	0,68	0,85	0,33	0,94	1,00
20	0,00	0,11	0,28	0,84	0,88	0,99	1,00

- Existe um efeito estatisticamente significativo devido ao fator nível de perturbação aplicada ao RSSI.
- A alteração do estimador fez com que a média do erro de localização fosse significativamente diferente.
- A interação dos fatores não afeta a quantidade de erro de uma forma estatisticamente significativa na maioria dos nós sensores.

A.4 Perturbação no RSSI x estimador x métodos

Tabela A.6. Resultado do two-way ANOVA (perturbação x estimador) para um filtro de partícula

Filtro de partículas Perturbação no RSSI (x1) x Estimador (x2)			
Sensor	p(x1)	p(x2)	p(x1x2)
1	0,00	0,00	0,39
2	0,00	0,00	0,31
3	0,00	0,00	0,60
4	0,00	0,00	0,66
5	0,00	0,00	0,55
6	0,00	0,00	0,77
7	0,00	0,00	0,38
8	0,00	0,01	0,14
9	0,00	0,04	0,67
10	0,00	0,00	0,81
11	0,00	0,00	0,05
12	0,00	0,00	0,06
13	0,00	0,00	0,04
14	0,00	0,00	0,30
15	0,00	0,00	0,64
16	0,00	0,04	0,71
17	0,00	0,09	0,79
18	0,00	0,15	0,89
19	0,00	0,01	0,84
20	0,00	0,11	0,84

Apêndice B

Modelos de propagação de sinal

Os modelos de propagação de sinal tentam caracterizar confiavelmente a propagação do sinal de rádio através de diversos tipos de ambientes, porém é difícil obter um único modelo dado à característica estocástica de cada ambiente.

Segundo Goldsmith [2005], modelos confiáveis de *Path-loss* podem ser obtidos de modelos analíticos complexos ou medidas empíricas quando os requisitos do sistema são bem estritos. Podendo ser citado como exemplo para sistemas bem estritos quando há necessidade de determinar as melhores localizações para estações bases de transmissão de informação ou onde os pontos de acesso de uma empresa precisam dispostos para um determinado fim. Entretanto, o projeto de sistemas que usam estes modelos é beneficiado, de forma geral, pelo uso de um modelo simples que captura a essência de propagação do sinal. Não havendo a necessidade de recorrer a modelos complexos que tentam fazer mais aproximações ao sinal real, deixando o modelo mais invariante para diversos tipos de ambientes. Então, utilizar um modelo mais simples é, normalmente, mais vantajoso.

A literatura traz modelos de propagação do sinal de rádio, o mais aceito está descrito em Rappaport [1996]. Outros, como os que foram descritos, ou utilizados, em Goldsmith [2005]; Fink & Kumar [2010] são derivações do modelo e suas diferenças são as aproximações realizadas.

No modelo descrito em Rappaport [1996], equação B.1, onde S é a potência recebida em dBm a uma distância μ , L_0 potência recebida a uma distância D_0 do emissor e ψ o coeficiente de decaimento do sinal de rádio.

$$S = L_0 - 10\psi \log\left(\frac{\mu}{D_0}\right). \quad (\text{B.1})$$

Em Goldsmith [2005] é descrito um modelo mais complexo, equação B.2, que

Tipo de ambiente	γ (intervalo)
Macro células urbanas	3,7 - 6,5
Micro células urbanas	2,7 - 3,5
Prédio de escritórios (mesmo andar)	1,6 - 3,5
Prédio de escritórios (múltiplos andares)	2 - 6
Uma loja	1,8 - 2,2
Uma fábrica	1,6 - 3,3
Uma casa	3

Tabela B.1. Tabela de valores de coeficiente de atenuação, γ , para vários tipos de ambientes. Retirada de Goldsmith [2005]

tenta incorporar características da antena e da atenuação do canal. Menegatti et al. [2009] também utiliza este modelo em seu trabalho.

$$S = L_0 + K(dB) - 10\psi \log\left(\frac{\mu}{D_0}\right). \quad (\text{B.2})$$

Na Equação B.2, $P_t(dBm)$ é potência de saída do sinal no emissor e os outros parâmetros foram padronizados e definidos anteriormente nesta seção. No entanto a equação B.2 utiliza $K(dB)$, definido na equação B.3, que é determinado pelo espaço livre do ganho do caminho (*path gain*) na distância D_0 , assumindo o uso de uma antena omnidirecional. λ é o valor de coeficiente de atenuação e ψ varia de acordo com o tipo de ambiente e objetos no ambiente. A tabela B.1 que aparece no livro texto de Goldsmith contém alguns coeficientes de atenuação com seus respectivos tipos de ambientes.

$$K(dB) = 20 \log \frac{\lambda}{4\pi D_0}. \quad (\text{B.3})$$

O modelo mostrado em Fink & Kumar [2010], equação B.4, é uma simplificação do modelo apresentado por Rappaport [1996],

$$S = L_0 - 10\psi \log(\mu) - f(X_{emissor}, X_{receptor}) - \epsilon. \quad (\text{B.4})$$

No trabalho Fink & Kumar [2010], $X_{emissor}$ e $X_{receptor}$ são, respectivamente, as posições do emissor do sinal e receptor, S é a potência recebida a distância μ e a simplificação do modelo é a omissão do termo D_0 e assunção que o parâmetro de potência, L_0 , está a 1 metro da fonte. Além da simplificação do termo L_0 , Fink acrescentou os termos de função de sombreado de sinal, $f(X_{emissor}, X_{receptor})$, e atenuação de sinal por *multi-path*, ϵ . Ambos os termos, $f(X_{emissor}, X_{receptor})$ e ϵ , são usados para modelar a incerteza do sinal em diversos locais do ambiente.

Outro modelo de propagação descrita na equação B.5 (Lisboa Rodrigues [2011])

é derivado da Equação B.1. Onde $Normal(0, \sigma)$ corresponde a uma variável aleatória gaussiana de média zero e variância desconhecida que descreve o efeito de sombreamento dos obstáculos.

$$S = 10 \log(L_0) + 10\psi \log\left(\frac{\mu}{D_0}\right) + Normal(0, \sigma). \quad (B.5)$$

Na Figura B.1, é mostrado, para alguns parâmetros pré-definidos, como se comporta o modelo junto a uma amostra de potência de sinais de rádio extraída de um ambiente real.

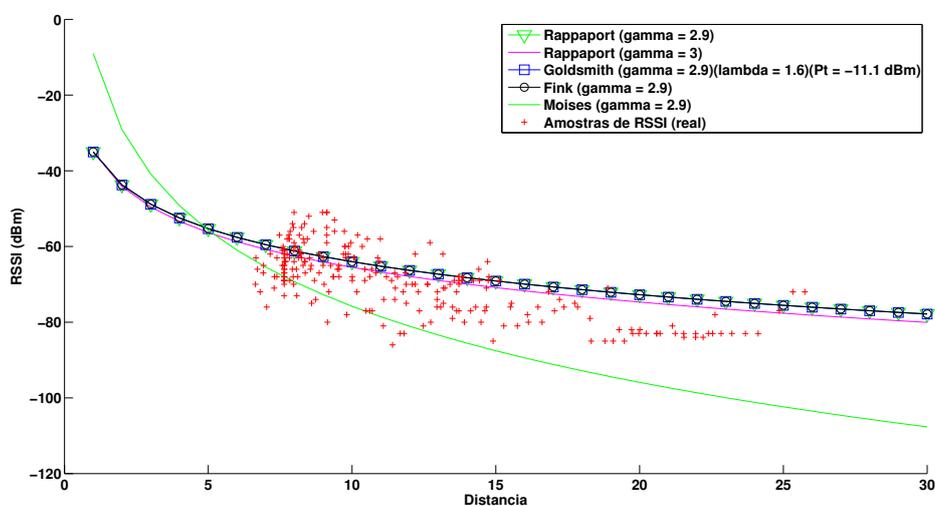


Figura B.1. Comparação dos modelos em relação aos valores reais de RSSI. O emissor foi um dispositivo 802.11g com uma antena omnidirecional de 6 dBi.

Apêndice C

Atenuação do sinal relacionado à PathLoss, Shadowing e MultiPath

O sinal de rádio frequência é suscetível ao ruído, interferência e outros impedimentos do canal de comunicação. Assim como raios-x são atenuados por chumbo, e luz e som pela água, as ondas eletromagnéticas do rádio também são atenuadas e diversos materiais tem influência em sua propagação. Na engenharia, a medida de atenuação é dada por dB/cm , dB/m , dB/km , etc, e é representada pelo coeficiente de propagação do meio em questão (ar, água, concreto, etc) Zagzebski [1996]. Esse coeficiente de atenuação $\varrho[dB]$ é definido na Equação C.1, onde P_R e P_T são, respectivamente, a potência recebida e a potência da transmissão em Watts:

$$\varrho[dB] = 10 \log_{10} \left(\frac{P_R}{P_T} \right). \quad (C.1)$$

Coefficientes de atenuação são usados para quantificar como a amplitude do sinal transmitido decresce em função da frequência. Cada material possui um coeficiente de atenuação diferente, visto na tabela C.1, e pode ser calculado através da equação C.2.

$$\varrho[dB] = \alpha \left[\frac{dB}{MHz.cm} \right] l[cm] f[MHz]. \quad (C.2)$$

Estes impedimentos variam de forma imprevisível devido à imprevisibilidade da movimentação do receptor e dos elementos, presentes no meio, que dificultam a passagem no sinal. *Path-loss* é causada pela dissipação da potência do sinal irradiado pelo transmissor como também pelos efeitos do canal de propagação. E modelos baseados em *Path-loss* assumem para a mesma distância entre transmissor e receptor haverá a mesma dissipação, não considerando os efeitos de *Shadowing*. *Shadowing* é a dissipação da potência do sinal causada por obstáculos entre o transmissor e o receptor, essa

Material	$\alpha[\frac{dB}{MHz.cm}]$
Porta de madeira sólida	0,0005624297
Porta de madeira oca	0,0003749531
Porta de escritório com janela	0,0003749531
Porta de incêncido	0,0012185977
Tijolo	0,0002812148
Parede concreto	0,000164042
Parede externa de concreto	0,0003220084
Divisória de vidro	0,0039370079
Mármore	0,000492126
Vidro a prova de bala	0,0016404199

Tabela C.1. Valores dos coeficiente de atenuação. Esses valores foram calculados com base nos dados fornecidos por 3Com [2006]

dissipação é causada pela atenuação da potência do sinal através da absorção, reflexão, espalhamento e difração. *Path-loss* e *Shadowing* são ocorrem geralmente em maiores distâncias e normalmente são chamados de efeitos de propagação em larga escala. Também existe os efeitos de propagação em pequena escala, na ordem de tamanho de onda, que é o caso do *Multi-path*. *Multi-path* é constituído pela adição destrutiva de sinais que tomaram diferentes caminhos, no percurso entre emissor e receptor e geralmente ocorre em distâncias pequenas. Vale observar que o *Multi-path* pode aumentar a potência do sinal recebido pelo receptor. Esse experimento é recriado num simulador de propagação de sinal

A imagem C.1 ilustra o efeito do *Path-loss*, *Shadowing* e *Multi-path* em relação à distância.

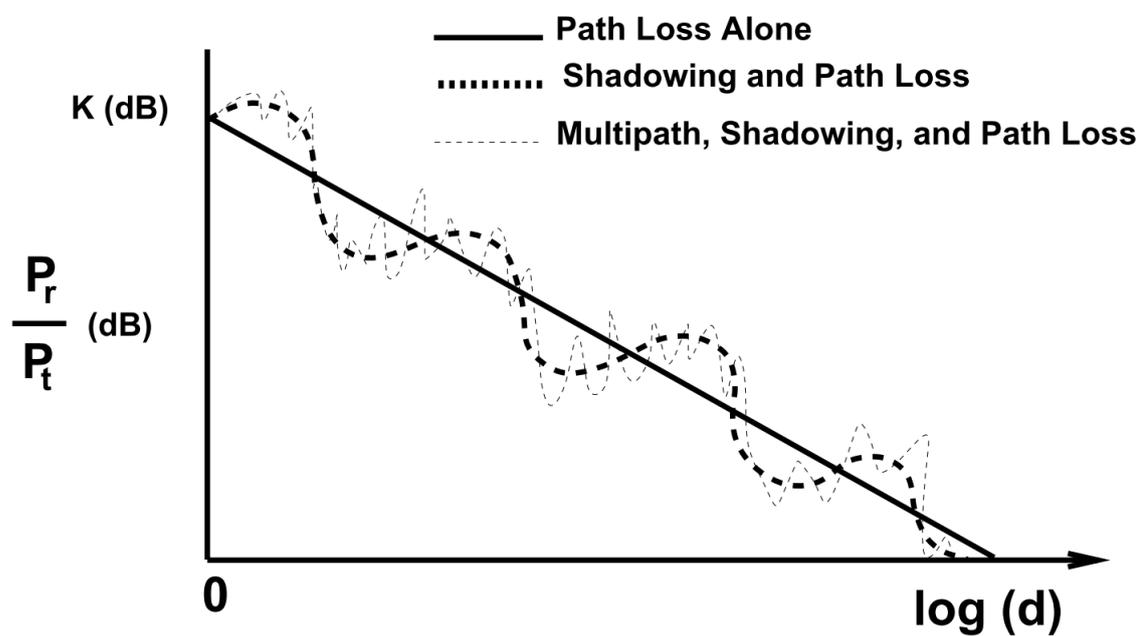


Figura C.1. Relação de Potência de sinal Recebida por transmitida analisada através dos aspectos de *Path-loss*, *Shadowing* e *Multi-path* VS distância (Goldsmith [2005]).

Apêndice D

Prova de conceito

O método de inferência exata com modelo de observação uniforme também foi validado com experimentos no mundo real, descritos em nosso trabalho anterior (Carvalho et al. [2012]).

Nesse teste de conceito, o ROS foi utilizado por também provê vários recursos e interfaces de controle do robô real. O ROS (Quigley et al. [2009]) foi utilizado nos experimentos do presente estudo, por ser uma plataforma mais nova, por possuir o maior conjunto de funcionalidades e, atualmente, ser a mais utilizada pela comunidade. Portanto, foram usados os mesmos algoritmos tanto nos testes simulados quanto nos reais.

O ambiente real do experimento foram os corredores do terceiro andar do Departamento de Computação da UFMG, onde há estruturas (paredes e colunas de sustentação), objetos (cadeiras, mesas, computadores, portas e pessoas), nós sensores e um robô. O robô possuía um sensor de distância baseado em *laser* que foi utilizado num módulo de localização de robô disponível no ROS, e um receptor de rádio que foi usado na aquisição do sinal de rádio dos nós sensores.

No experimento, o robô moveu-se ao longo de um caminho pré-definido no ambiente de modo que a coleta das amostras do RSSI fosse realizada em diferentes localizações no ambiente. Assim, com o acúmulo dessas amostras em diferentes posições no caminho do robô, era esperado que o erro de localização dos nós sensores diminuísse.

D.1 Especificações do hardware

A configuração usada para os experimentos era composta por um robô *Pioneer 3AT* da ActivmediaTM equipado com uma sensor *laser* de medida de distância (LMS) 200 e um controle usado para guiar o robô através do ambiente (Figure D.1).



Figura D.1. Hardware Setup: Um robô Pioneer da ActivmediaTM equipado com um *laser Sick LMS 200*, um controle e um netbook.

Para desempenhar o papel de nó sensor, foi escolhido um roteador *wireless* da *Linksys*TM que será localizado pela nossa abordagem. Na localização dos nós, são necessários parâmetros utilizados no modelo de observação uniforme idênticos aos descritos na Seção 4.2, cujos valores também foram iguais.

D.2 Especificações de software

A configuração de *software*, cuja execução é realizada num *netbook* acoplado ao robô, é composta pela plataforma robótica ROS que funciona como base para o AMCL (Adaptive Monte Carlo Localization), que é o módulo responsável pela localização do robô, e o módulo *Karto*.

O *Karto* foi utilizado previamente para construir um mapa parcial do terceiro andar do departamento de computação. O AMCL integra as leituras do *laser SICK*, a hodiometria e o mapa previamente gerado através de um filtro de partículas para gerar e atualizar um estado de crença sobre a posição do robô.

D.3 Aquisição do RSSI

Na Figura D.2 é ilustrado o mapa criado pelo *Karto* e a estimativa de localização do robô, pontos vermelhos, fornecida pelo AMCL. O robô foi guiado por alguns corredores do edifício enquanto coletava amostras de RSSI. No caminho percorrido com o robô, a velocidade permaneceu entre 0 e 0.5 m/s. Entretanto, o módulo AMCL poder retornar

uma posição com pouca precisão, esse comportamento é ilustrado no corredor da parte superior da Figura D.2, pois percebe-se que a localização estimada pelo AMCL não é precisa, indicando que o robô não estava no corredor. Portanto, o modelo probabilístico de localização de nó sensor precisa compensar, até um determinado limite, este erro de localização do robô, como também as incertezas advindas dos problemas de propagação de sinal que afetam o cálculo do RSSI.

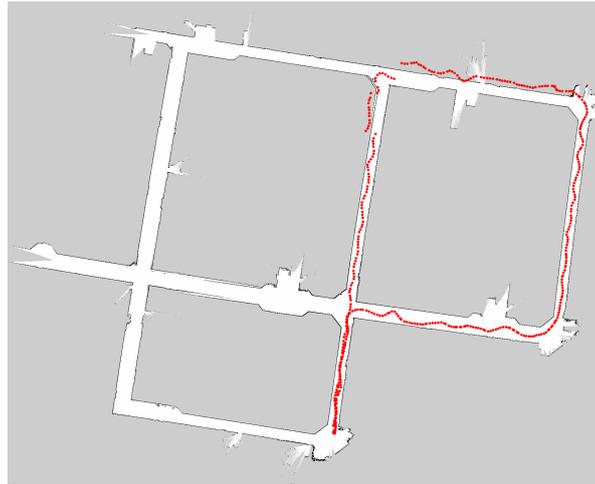


Figura D.2. Mapa do terceiro andar do departamento de computação e o resultado do sistema de localização do robô. Esta informação de localização foi utilizada para fazer a criação do estado de crença da posição do nó sensor.

D.4 Os resultados de localização de nós sensores

O resultado obtido com o nosso método aplicado a um ambiente real no final do caminho do robô é inferior a dois metros, como ilustrado na Figura D.4. A abscissa é o número de amostras de RSSI e a ordenada é o erro de localização de um dado nó sensor em relação a sua verdadeira localização. No mundo real, o erro de localização do nó sensor diminui com o processamento de novas amostras de RSSI, porém, a propriedade estocástica do ambiente (os problemas de sombreamento de sinal e multi-caminho) não permitem que a localização, através da inferência, seja perfeita.

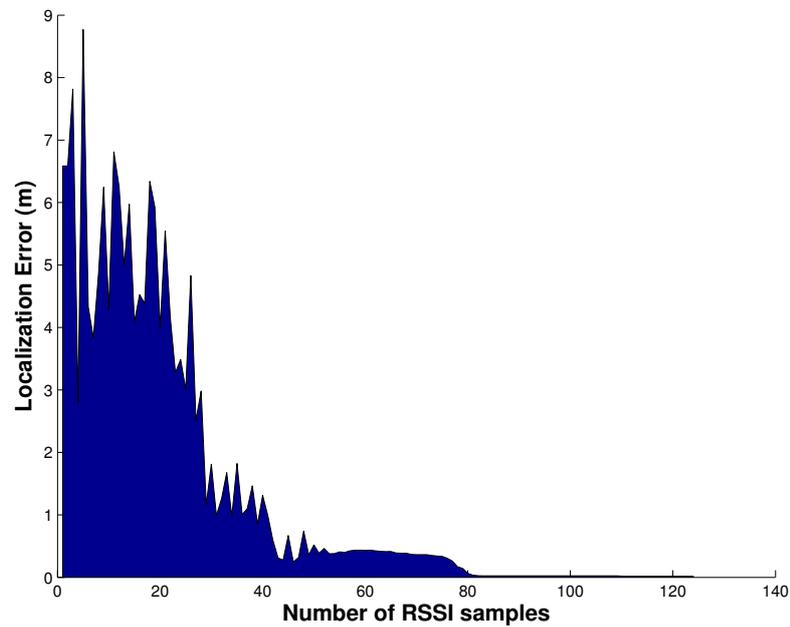


Figura D.3. Erro de localização em metros entre a posição estimada do nó sensor e a posição real versus o número de amostras de RSSI no experimento simulado. (Retirado de Carvalho et al. [2012])

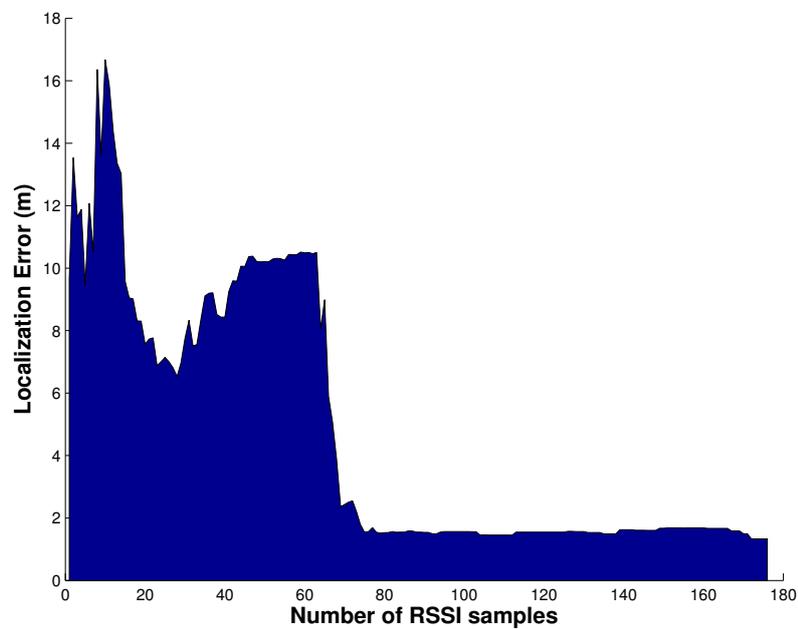


Figura D.4. Erro de localização em metros entre a posição estimada do nó sensor e a posição real versus o número de amostras de RSSI no experimento real. (Retirado de Carvalho et al. [2012])

Apêndice E

AMCL - Algoritmo de Localização Monte Carlo Adaptativo

O AMCL, Fox [2001]; Quigley et al. [2009], é um algoritmo utilizado para localização de um robô em um ambiente previamente mapeado. O robô utiliza a informação da hometria e das leituras de distância, obtidas através de um laser, para determinar a sua posição no mapa. O Algoritmo utiliza, para realizar a localização, uma abordagem estatística para melhorar a eficiência de um filtro de partículas através da adaptação do número de amostras durante a execução. Essa ideia foi chamada de amostragem por *Kullback-Leibler Distance* (KLD) e tem como ideia principal limitar o erro de aproximação introduzido pela representação baseada em amostra do filtro de partículas. Para medir o erro de aproximação de um conjunto de partículas é utilizado a distância de Kullback-Leibler, origem do nome KLD.

A distância de Kullback-Leibler é uma medida não simétrica entre duas distribuições de probabilidade de uma mesma variável aleatória discreta. Se o espaço de estados definido pelo KLD for grande, um grande número de amostras serão selecionadas indicando uma grande incerteza, porém o conjunto de amostras é menor se o espaço de estados for pequeno, indicando uma maior certeza da localização.

Um grande conjunto de amostras com distribuição uniforme é colocado em torno da posição inicial conhecida do robô. O robô movimenta adquirindo novas informações através de sua hometria e das leituras do sensor laser. Estas criam uma distribuição de probabilidade sobre a posição do robô e servem para calcular o número de amostras necessárias para a próxima iteração do algoritmo. Se a distância das distribuições de probabilidade, através de Kullback-Leibler, for grande, o número de amostras vai ser maior e assim serão mais espalhadas em uma posição do mapa, porém se a divergência entre as distribuições for pequena, o número de amostras será reduzido e menos

amostras serão necessárias, concentrando a crença na posição em uma área específica do mapa.