



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE CIÊNCIAS EXATAS E NATURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Leomário Silva Machado

**AVALIAÇÃO DE DESEMPENHO DE TÉCNICAS DE LOCALIZAÇÃO
EM AMBIENTES REAIS APLICADAS A REDES DE SENSORES SEM
FIO.**

Belém
2014

Leomário Silva Machado

**AVALIAÇÃO DE DESEMPENHO DE TÉCNICAS DE LOCALIZAÇÃO
EM AMBIENTES REAIS APLICADAS A REDES DE SENSORES SEM
FIO.**

Dissertação de Mestrado apresentada para
obtenção do grau de Mestre em Ciência
da Computação.

Programa de Pós-Graduação em Ciência
da Computação.

Instituto de Ciências Exatas e Naturais.
Universidade Federal do Pará.

Área de concentração em Sistemas de
Computação

Linha de pesquisa: Redes de Sensores Sem
Fio.

Orientador Prof. Dr. Josivaldo Araújo

Belém

2014

Leomário Silva Machado

**AVALIAÇÃO DE DESEMPENHO DE TÉCNICAS DE LOCALIZAÇÃO
EM AMBIENTES REAIS APLICADAS A REDES DE SENSORES SEM
FIO.**

Dissertação de Mestrado apresentada para
obtenção do grau de Mestre em Ciência
da Computação. Programa de Pós-
Graduação em Ciência da
Computação. Instituto de Ciências Exatas
e Naturais. Universidade Federal do Pará

Data da defesa: 26/05/2014 Belém-PA.

Banca Examinadora

Prof. Dr. Josivaldo de Souza Araújo

Faculdade de Computação – UFPA - Orientador

Prof. Dr. Dionne Cavalcante Monteiro

Faculdade de Computação – UFPA – Membro

Prof. Dr. Ailton Santa Barbara

Centro de Pesquisas Renato Archer – CTI – Membro

Belém

2014

Dedico ao criador do universo.

Agradecimentos

Ao meu orientador, aos amigos do Gercom, a equipe WSN/Gercom, à minha família, namorada, flash, aos amigos, aos falecidos amigos que ainda moram no coração, ao Deus que criou os céus e a terra.

RESUMO

A localização em redes de sensores sem fio é um desafio que vai além do uso do popular GPS, com trabalhos diversos que visam aprimorá-lo ou mesmo substituí-lo. A localização pode ser realizada utilizando múltiplas antenas e seus respectivos ângulos, tempo e sincronização, diferencial de tempo entre envio de dois rádios diferentes ou mesmo com a potência do sinal. A partir destes padrões de estimativa, várias técnicas foram postuladas com objetivo de se utilizar dos recursos disponíveis para mensurar distâncias e estimar as coordenadas de um nó. Dentre estas técnicas pode-se citar como as mais importantes a Lateração, *Nearest Neighbor*, *K-Nearest Neighbor*, *Min-Max*, *Non-Linear Regression*, *Iterative Non-Linear Regression*, *Sum-Dist*, *Dv-hop*, Rede Neural Artificial, filtro de *Kalman*.

Este trabalho conduz um conjunto de testes realizados em dois ambientes, sendo o primeiro *indoor*, e o segundo *outdoor* utilizando como *hardware* os módulos IRIS da MEMSIC para realização do experimento. Nestes testes são comparadas as técnicas Lateração, KNN e uma Rede Neural Artificial é proposta para o objetivo de estimar a localização de um nó da RSSF. São apresentadas as formulações matemáticas da Lateração e KNN, assim como a configuração da Rede Neural utilizada nos testes conduzidos neste trabalho. Os resultados são exibidos tomando o *benchmark* entre as técnicas para análise comparativa percentual entre as mesmas e para melhor análise quantitativa, os dados são Tabelados para visualização da precisão.

PALAVRAS-CHAVE: Redes de Sensores Sem Fio, RSSI, Redes Neurais Artificiais, Algoritmos de Localização, Lateração, KNN.

ABSTRACT

The location of wireless sensor networks is a challenge that goes beyond the use of popular GPS through several studies that aim to improve it or even replace it . The location can be performed using multiple antennas and their respective angles , and time synchronization, time differential between transmission of two different or same power with a radio signal . From these patterns estimated , various techniques have been postulated in order to use the resources available to measure distances and estimate the coordinates of a node. Among these techniques may be cited as the most important Lateração , Nearest Neighbor , K -Nearest Neighbor , Min- Max , Non - Linear Regression , Linear Regression Non- Iterative , Sum - Dist , Dv - hop , Artificial Neural Network , filter Kalman .

This paper conducts a series of tests conducted in two environments , the first indoor , outdoor and the second using the hardware as the MEMSIC IRIS modules to perform the experiment . These tests are compared Lateração , KNN and an Artificial Neural Network techniques is proposed for the purpose of estimating the location of a WSN node . Lateração mathematical formulations KNN and are presented as well as the configuration of the neural network used in the tests conducted in this work. The results are shown taking the benchmark for comparative analysis techniques to the percentage there between and better quantitative analysis, the data are tabulated for display accuracy.

KEYWORDS: Wireless Sensors Network; RSSI; Artificial Neural Network; localization algorithms; Lateration; KNN.

LISTA DE FIGURAS

FIGURA 1 - ESTRUTURA DE UM NÓ DA RSSF E A COMUNICAÇÃO SERIAL	16
FIGURA 2 - PILHA DE PROTOCOLOS DE RSSF	16
FIGURA 3- NÓS DA RSSF EM DIFERENTES TOPOLOGIAS	18
FIGURA 4 - CONFIGURAÇÕES <i>FULL</i> E <i>REDUCED</i> EM RSSF	19
FIGURA 5 - PRINCÍPIO DE AOA. FONTE: (SHI, MUELLER, & MARX, 2005).....	28
FIGURA 6 - LOCALIZAÇÃO POR AOA	29
FIGURA 7 - AOA APLICADO EM AMBIENTE DE TESTE. FONTE: (BOUKERCHE, OLIVEIRA, NAKAMURA, & LOUREIRO, 2007).....	30
FIGURA 8 - ESQUEMA DE TRANSMISSÃO EM TOA FONTE: (BOUKERCHE, OLIVEIRA, NAKAMURA, & LOUREIRO, 2007).....	31
FIGURA 9 - TDOA UTILIZANDO SINAL DE RÁDIO E PULSO ULTRASSOM. FONTE: (BOUKERCHE, OLIVEIRA, NAKAMURA, & LOUREIRO, 2007).....	32
FIGURA 10 - PODER DE ALCANCE DO RSSI. FONTE: (BOUKERCHE, OLIVEIRA, NAKAMURA, & LOUREIRO, 2007) .	33
FIGURA 11 - DIAGRAMA DE BLOCOS DA ESTIMATIVA DO RSSI (XUEWEN, YONG, & YANMENG, 2011).....	33
FIGURA 12 - ILUSTRAÇÃO DA CARACTERÍSTICA DO SINAL CONFORME A DISTÂNCIA	34
FIGURA 13 - ESPALHAMENTO DO SINAL NO RAIO DE ALCANCE.....	34
FIGURA 14 - COMUNICAÇÃO ENTRE ÂNCORAS E O ALVO CONJUNTAMENTE A INTERFACE DESKTOP.....	36
FIGURA 15–ESTIMATIVA DA DISTÂNCIA NA LATERAÇÃO.....	38
FIGURA 16 - EXEMPLO DE ESTIMATIVA DO KNN	42
FIGURA 17 - EXEMPLOS DE NEURÔNIOS BIOLÓGICOS	43
FIGURA 18 - ESTRUTURA BÁSICA DE UM NEURÔNIO	44
FIGURA 19 - ARQUITETURA DE UMA RNA <i>MULTILAYER PERCEPTRON</i>	45
FIGURA 20 - ILUSTRAÇÃO DA TÉCNICA MIN-MAX	47
FIGURA 21 - IDENTIFICAÇÃO DAS DISTÂNCIAS NO MÉTODO <i>SUM-DIST</i>	50
FIGURA 22 - IDENTIFICAÇÃO DAS DISTÂNCIAS NO MÉTODO <i>DV-HOP</i>	51
FIGURA 23 - LOCALIZAÇÃO DOS PONTOS EM ESCALA DE 200M.	53
FIGURA 24 - PONTOS DE COLETA DO RSSI DO AMBIENTE <i>INDOOR</i>	61
FIGURA 25 - PONTOS DE COLETA DO RSSI DO AMBIENTE <i>OUTDOOR</i>	61
FIGURA 26 - DIAGRAMA REFERENTE A COLETA DE DADOS	62
FIGURA 27 - FLUXO DE TRABALHO DA RNA	65
FIGURA 28 - CONFIGURAÇÃO DA RNA.....	66
FIGURA 29 - ARQUITETURA DO TINYOS	68
FIGURA 30 - MOTE IRIS.....	69
FIGURA 31 - MIB520	70
FIGURA 32– COMPARAÇÃO PERCENTUAL ENTRE A RNA E A LATERAÇÃO EM AMBIENTE <i>INDOOR</i>	73
FIGURA 33 - COMPARAÇÃO PERCENTUAL ENTRE A RNA E O KNN EM AMBIENTE <i>INDOOR</i>	73
FIGURA 34 - POSIÇÕES REAIS E ESTIMADAS POR TÉCNICA EM PONTOS PERIFÉRICO SEM AMBIENTE <i>INDOOR</i>	77
FIGURA 35 - POSIÇÕES REAIS E ESTIMADAS POR TÉCNICA EM PONTOS INTERNOS EM AMBIENTE <i>INDOOR</i>	77

FIGURA 36–ERRO ACUMULADO EM AMBIENTE <i>INDOOR</i>	78
FIGURA 37 - COMPARAÇÃO PERCENTUAL ENTRE A RNA E A LATERAÇÃO EM AMBIENTE <i>OUTDOOR</i>	79
FIGURA 38 - COMPARAÇÃO PERCENTUAL ENTRE A RNA E O KNN EM AMBIENTE <i>OUTDOOR</i>	79
FIGURA 39 - POSIÇÕES REAIS E ESTIMADAS POR TÉCNICA EM PONTOS PERIFÉRICOS EM AMBIENTE <i>OUTDOOR</i>	81
FIGURA 40 - POSIÇÕES REAIS E ESTIMADAS POR TÉCNICA EM PONTOS INTERNOS EM AMBIENTE <i>OUTDOOR</i>	82
FIGURA 41–ERRO ACUMULADO EM AMBIENTE <i>OUTDOOR</i>	83
FIGURA 42 - FLUXOGRAMA - NÓ ÂNCORA	96
FIGURA 43 - FLUXOGRAMA NÓ ALVO	98
FIGURA 44 - FLUXOGRAMA DO AGENTE DESKTOP	101
FIGURA 45 - GINÁSIO DA UFPA (VISTA EXTERNA). FONTE: HTTP://WWW.PORTAL.UFPA.BR	103
FIGURA 46 - GINÁSIO DA UFPA (VISTA INTERNA). FONTE: HTTP://WWW.PORTAL.UFPA.BR	103
FIGURA 47 - NÓS DA RSSF NO AMBIENTE DE TESTES	104
FIGURA 48 - NÓ LOCALIZADO NA ORIGEM.....	104
FIGURA 49 - VISTA AÉREA DO LOCAL DE TESTES <i>OUTDOOR</i>	105
FIGURA 50 - VISTA AÉREA COM VISUALIZAÇÃO DA ÁREA ADJACENTE	105

LISTA DE TABELAS

TABELA 1- PERFORMANCE: RNA VERSUS LAT E RNA VERSUS KNN EM AMBIENTE <i>INDOOR</i>	74
TABELA 2- PERCENTUAL DE ACERTOS POR TÉCNICA EM AMBIENTE <i>INDOOR</i>	74
TABELA 3 - MÉDIA E VARIÂNCIA DO ERRO EM METROS EM AMBIENTE <i>INDOOR</i>	75
TABELA 4 - ANÁLISE QUANTITATIVA DO ERRO A CADA METRO EM AMBIENTE <i>INDOOR</i>	76
TABELA 5 - PERFORMANCE: RNA VERSUS LAT E RNA VERSUS KNN EM AMBIENTE <i>OUTDOOR</i>	80
TABELA 6 - MÉDIA E VARIÂNCIA DO ERRO EM METROS EM AMBIENTE <i>OUTDOOR</i>	80
TABELA 7- PERCENTUAL DE ACERTO POR TÉCNICA EM AMBIENTE <i>OUTDOOR</i>	81

LISTA DE QUADROS

QUADRO 1 - CLASSIFICAÇÃO DOS NÓS DA RSSF.....	18
QUADRO 2 -CARACTERÍSTICAS POR TÉCNICA.....	35
QUADRO 3 - EXEMPLOS DE FUNÇÕES DE ATIVAÇÃO	44
QUADRO 4 - COMPARATIVO ENTRE TRABALHOS RELACIONADOS.....	58
QUADRO 5 - CONFIGURAÇÃO DA RNA.....	66

LISTA DE SIGLAS

AOA	<i>Angle Of Arrival</i>
APs	<i>Access Points</i>
BS	<i>Base Station</i>
FFD	<i>Full Function Device</i>
GDOP	<i>Geometric Dilution of Precision</i>
GPS	<i>Sistema de Posicionamento Global</i>
INLR	<i>Iterative Non- Linear Regression</i>
KNN	<i>K-Nearest Neighbor</i>
LNNE	<i>Location Neural Network Ensembles</i>
LS	<i>Least Squares</i>
LSNN	<i>Localization Signal Neural Network</i>
MLP	<i>Multi-Layer Perceptron</i>
MLPNN	<i>Multi-Layered Perceptron Neural Network</i>
NN	<i>Nearest Neighbor</i>
NLR	<i>Non-Linear Regression</i>
OML	<i>Optimal Multi-Lateration</i>
PV	<i>Position Velocity</i>
PVA	<i>Position Velocity Acceleration</i>
RANSAC	<i>Random Sample Consensus</i>
RBF	<i>Radial Basis Function</i>
RFD	<i>Reduced FunctionDevice</i>
RMSE	<i>Root Mean Square Error</i>
RNA	<i>Rede Neural Artificial</i>
RNN	<i>Recurrent Neural Networks</i>
RRBF	<i>Reduced Radial Basis Function</i>
RSSF	<i>Redes de Sensores Sem Fio</i>
RSSI	<i>Received Signal Strenght Indicator</i>
SBT	<i>Sub-optimal Blind Trilateration</i>
TDOA	<i>Time Difference Of Arrival</i>
TFDA	<i>Time Frequency Difference of Arrival</i>
TOA	<i>Time Of Arrival</i>
Tom	<i>Trilaterate on Minima</i>
UWB	<i>Ultra-Wide Band</i>

SUMÁRIO

1. Introdução	15
1.1. <i>Visão Geral</i> -----	15
1.2. <i>Os desafios em RSSF</i> -----	21
1.3. <i>Objetivos</i> -----	23
1.4. <i>Justificativa</i> -----	23
1.5. <i>Metodologia</i> -----	24
1.6. <i>Motivação</i> -----	25
1.7. <i>Estrutura da Dissertação</i> -----	25
2. Localização em RSSF.....	27
2.1. <i>Técnicas para utilização de Localização sem GPS</i> -----	27
2.1.1. <i>Angle of Arrival</i> -----	27
2.1.2. <i>Time of Arrival</i> -----	30
2.1.3. <i>Time Difference of Arrival</i> -----	31
2.1.4. <i>Received Signal Strength Indicator</i> -----	32
2.1.5. <i>Comparação entre os métodos</i> -----	35
2.2. <i>Técnicas de localização</i> -----	36
2.2.1. <i>Lateralização</i> -----	37
2.2.2. <i>KNN</i> -----	40
2.2.3. <i>RNA</i> -----	42
2.2.3.1. <i>RNAs em localização</i> -----	44
2.2.3.1.1. <i>MultiLayer Perceptron</i> -----	45
2.2.3.1.2. <i>RBF</i> -----	46
2.2.4. <i>Min-Max</i> -----	46
2.2.5. <i>Técnicas de Regressão não Linear</i> -----	47
2.2.5.1. <i>Non-linear Regression (NLR)</i> -----	47
2.2.5.2. <i>Iterative Non-linear Regression (INLR)</i> -----	48
2.2.5.3. <i>Least Squares (LS)</i> -----	48
2.2.5.4. <i>Random Sample Consensus (RANSAC)</i> -----	49
2.2.5.5. <i>Trilaterate on Minima (ToM)</i> -----	49
2.2.6. <i>Sum-dist</i> -----	49
2.2.7. <i>DV-hop</i> -----	50
3. Trabalhos Correlatos.....	52
3.1. <i>Comparação dos trabalhos relacionados</i> -----	57
4. Configurações dos Testes	59

4.1. Metodologia	62
4.1.1. Lateração	63
4.1.2. KNN	63
4.1.3. RNA	64
4.2. Arquitetura de Hardware e Software	67
4.2.1. Sistema operacional TinyOS	67
4.2.2. Sistema operacional Ubuntu/Linux	69
4.2.3. Motes IRIS	69
4.2.4. Gateway Mib520	69
4.2.5. FannTool	70
4.2.6. Softwares Diversos	71
5. Análise Comparativa	72
5.1. Estudo de Caso 1: Indoor	72
5.2. Estudo de Caso 2: Outdoor	78
6. Considerações Finais	84
6.1. Trabalhos Futuros	86
Bibliografia	88
Apêndice	95
Apêndice A. Comunicação Serial.	96
Apêndice B. Ambientes de teste.	103

1. Introdução

Este capítulo introduz conceitos iniciais de Redes de Sensores sem Fio (RSSF) abrangendo seus componentes de *hardware*, camadas de protocolos de rede, configurações e topologias dos nós da RSSF. Apresenta também o objetivo principal e objetivos secundários, a justificativa do trabalho, a motivação e a metodologia utilizada para a realização deste trabalho.

1.1. Visão Geral

RSSF são redes compostas por um conjunto de nós sensores com objetivo de coletar e monitorar grandezas ambientais ou industriais adquirindo dados do tipo: acústico, sísmico, temperatura, pressão, luminosidade, multimídia, dentre outros. Os nós de uma RSSF normalmente utilizam uma bateria como fonte de energia onde, em sua maioria, a comunicação é realizada através de ondas eletromagnéticas utilizando o padrão IEEE 802.15.4 (Lee, Lee, Yeo, Park, & Barolli, 2011) que dita diretrizes de comunicação de baixo custo, permitindo que a bateria destes aparelhos disponha de durabilidade e resistência de meses ou anos (Kinney, Jamieson, Gutierrez, & Naeve, 2014). A bateria é dispensável em casos excepcionais, onde há disponibilidade de ligação direta a uma fonte abundante de energia.

O *hardware* de um nó da RSSF é composto por um microcontrolador, memória interna, memória flash para persistência de dados, rádio para comunicação e sensores diversos dependendo do hardware utilizado. Um nó da RSSF se comunica com outros nós ou com um nó *gateway* da rede. Este gateway é ligado a uma interface de comunicação (USB, paralela, serial ou ethernet) repassando os dados obtidos dos nós sensores e repassando para um aplicativo que realiza o tratamento destes dados. A estrutura é ilustrada na Figura 1.

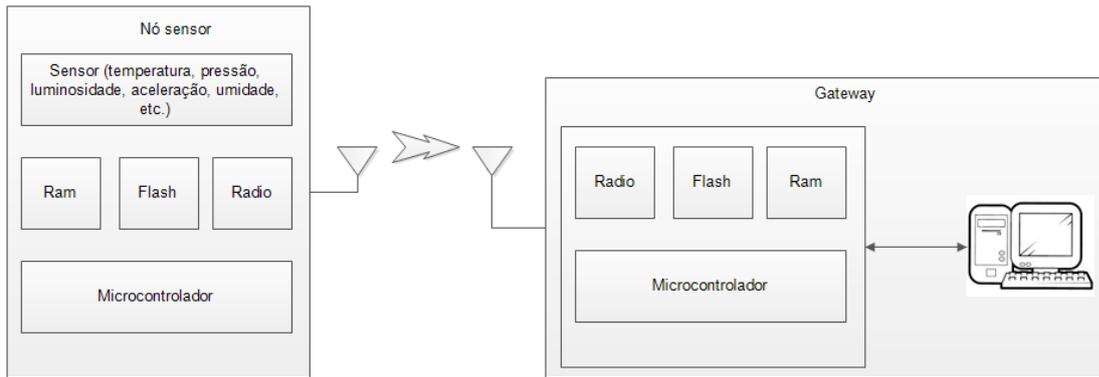


Figura 1 - Estrutura de um nó da RSSF e a comunicação serial

A comunicação entre os nós da rede é realizada conforme a descrição do padrão IEEE 802.15.4, ou com o padrão alternativo ZigBee (Zarrabi, Al-Khalili, & Savaria, 2011), compostos por um conjunto simplificado de camadas nas pilhas de protocolos se comparando ao modelo OSI. Estes padrões são compostos pelas camadas:

- Física: A camada física realiza o tratamento dos dados em forma de bits.
- MAC/Enlace: A camada MAC atua sobre o controle do enlace de rádio.
- Rede: A camada de rede é responsável pelo roteamento de dados, esta camada é inexistente no padrão 802.15.4, implementada apenas no padrão ZigBee.
- Aplicação: A camada de aplicação atua conforme a proposta da aplicação para comunicação de dados.

A pilha de protocolos é ilustrada na Figura 2.

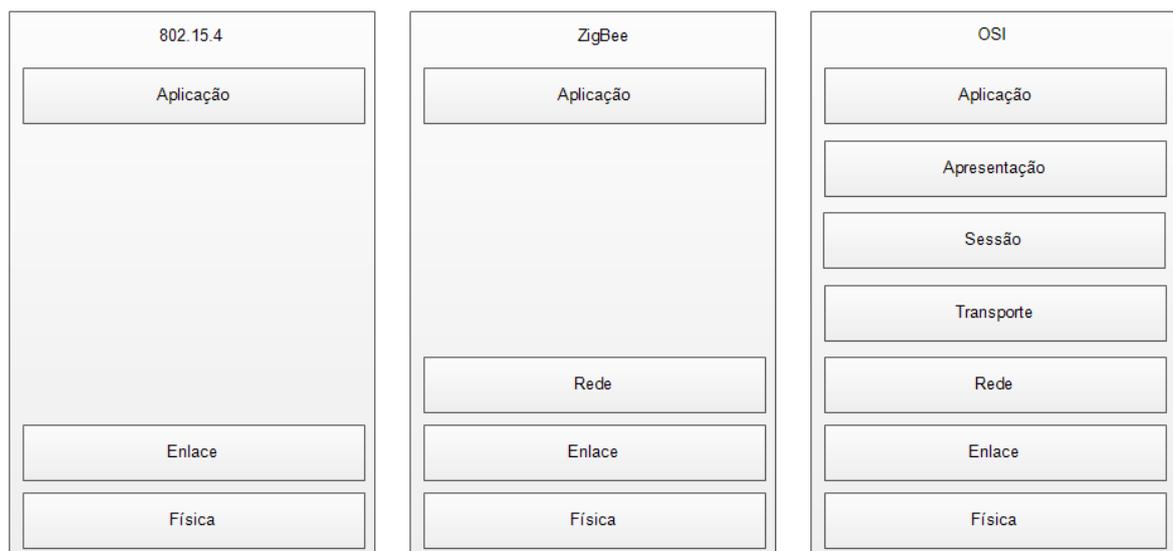


Figura 2 - Pilha de protocolos de RSSF

Conforme a natureza da implementação de uma RSSF, os nós podem se comportar de forma homogênea ou diferenciada. Em cenários onde todos os nós alcançam o *gateway*, o uso de roteamento é dispensável focando apenas na coleta de dados, entretanto quando o mesmo se encontra a uma distância maior que o alcance dos rádios, o roteamento é um requisito para o bom funcionamento. As características referentes à coleta, roteamento e centralização de dados repercute na configuração dos nós que podem ser classificados como:

- Nó coletor: Responsável apenas pela coleta e encaminhamento de dados para nós roteadores ou para o coordenador.
- Nó roteador: Responsável pelo encaminhamento dos dados adquiridos na rede, sendo opcionalmente também coletores de dados, quando são dispostos na área de coleta. O roteamento é realizado tendo em vista o cuidado com o consumo energético, uma vez que a transmissão de dados exige um consumo maior que o processamento. O uso de nós roteadores permite expandir o limite de alcance geográfico da RSSF, uma vez que, um roteador, ou conjunto de roteadores, podem ser inseridos entre um coletor e o coordenador realizando o encaminhamento de dados.
- Nó coordenador: Responsável pela aquisição de dados da rede, possui comunicação direta com a *Base Station* (BS) através da comunicação serial, paralela, ethernet ou USB. Este nó também dispõe de alimentação contínua, dispensando em geral, o uso da bateria e utilizando uma fonte alternativa como tomada elétrica ou mesmo pela conexão direta com a BS.

As RSSFs apresentam-se como um proveitoso componente em aplicações integradas a sistemas de coleta, monitoramento, rastreamento e comunicação de sistemas tomando em vista sua capacidade de coleta de dados e alta relação custo-benefício (Li, Xiaoguang, Ke, & Ketai, 2011). RSSF suportam sinergia com tecnologias diversas, as quais podem ser citadas a robótica (Dunbabin & Marques, 2012), Dispositivos RFID (Mirshahi, Uysal, & Akbari, 2013), Smart Grid (Li, Xiaoguang, Ke, & Ketai, 2011), redes IP (Teubler, Hail, & Hellbruck, 2012), redes de telefonia celular (Feng, Zheng, & Liu, 2013) além de outras. Esta sinergia permite a integridade da coleta de dados automatizando a tarefa, mensurando valores de forma mais rápida em comparação ao trabalho manual realizado por um humano. Também em comparação ao ser humano, uma RSSF obtém um volume maior de amostras em um mesmo intervalo de tempo (Yick, 2008).

A Figura 3 mostra a relação entre os nós roteadores, coletores e o coordenador da rede, dispostos em topologias Estrela, *Árvore* e *Mesh*, nas quais, exceto na topologia estrela, os nós roteadores auxiliam no repasse de dados dos nós coletores ao nó coordenador.

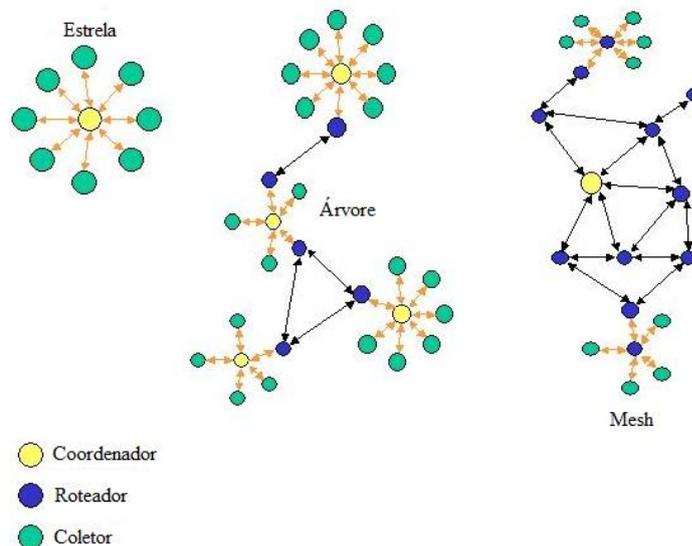


Figura 3- Nós da RSSF em diferentes topologias

Os nós da RSSF podem ser classificados em dispositivos *Reduced Function Device* (RFD) e *Full Function Device* (FFD). Neave (2003) descreve no documento de especificação da camada MAC do padrão IEEE 802.15.4 que dispositivos FFD e RFD possuem as seguintes características apresentadas no Quadro 1:

Quadro 1 - Classificação dos nós da RSSF

FFD	RFD
Pode ser usado em qualquer topologia	Limita-se a topologia estrela ou a redes ponto-a-ponto
Pode ser configurado como nó Coordenador da rede	Não pode se tornar um Coordenador da rede
Realiza comunicação com qualquer outro dispositivo	Implementação simples
Implementa completamente todo o conjunto de protocolos disponíveis	Possui um conjunto de protocolos simplificado

Sistemas embarcados alimentados por baterias portáteis exigem maior zelo no consumo de transmissão e processamento na qual a eficiência na utilização desta bateria precisará ser aplicada as camadas de projeto de hardware e software (Zarrabi, Al-Khalili, & Savaria, 2011). O tempo de vida da RSSF depende do número de nós ativos e do grau de conectividade da rede. Quanto mais eficiente o uso dos recursos, dentro dos requisitos da

aplicação, o consumo energético tende a ser menor e conseguinte o tempo de vida é prolongado (Conti, Willemsen, & Crispo, 2013).

Uma das formas de prolongamento do tempo de vida é a utilização do estado de *sleep* de um nó. Neste mecanismo um nó pode permutar entre três estados: *sleep*, *active*, e *listen* no qual o primeiro estado consiste em um período inativo do nó durante um determinado tempo. O estado *active* corresponde ao período no qual um nó realiza as coletas e envia suas mensagens, enquanto o modo *listen* consiste em um período no qual o nó ativa apenas o mecanismo de escuta, sem transmitir mensagens (Gaur, Toshniwal, Prakash, & Agrawal, 2010).

A Figura 4 apresenta exemplos de dispositivos FFD e RFD atuando nas mesmas topologias citadas na Figura 3.

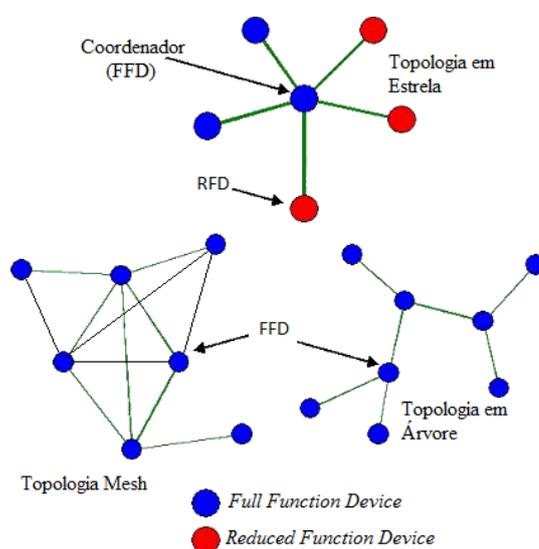


Figura 4 - Configurações Full e Reduced em RSSF

Os tipos de RSSF disponíveis são terrestres (Shareef, Zhu, & Musavi, 2008), subterrânea (Rong, 2011), sub-aquáticas (Yan, Wang, Shen, & Fu, 2012), multimídia (Pande, Elmannai, & Elleithy, 2013) e redes móveis (Jinghua, Tingting, Huan, & Yuanyua, 2009). As mais utilizadas são redes de sensores terrestres, que tipicamente consiste em dezenas ou centenas de nós sensores espalhados por uma determinada área de forma planejada ou *ad hoc*.

As aplicações das RSSFs abrangem diversos segmentos da sociedade, incluindo áreas como a vigilância militar, o monitoramento agrícola e industrial, assim como, automação residencial (Chunxia, Chen, Zhan, & Wang, 2010). Loureiro (Loureiro, Ruiz, Mini,

Nakamura, & Figueiredo, 2004) descreve que redes de sensores sem fio têm potencial em diversas áreas e setores, tais como:

- Controle, para ambientes industriais, agropecuários, domésticos e outros, como por exemplo, sensores sem fio podem ser embutidos em peças numa linha de montagem para fazer testes no processo de manufatura;
- Ambiente, para monitorar variáveis ambientais em locais internos como prédios e residências, e locais externos como florestas, desertos, oceanos, vulcões, etc;
- Tráfego, para monitoramento do fluxo de veículos em rodovias, estradas, malhas viárias urbanas, etc;
- Segurança, promovendo e melhorando sistemas de segurança em centros comerciais, estacionamentos, espaços públicos e privados, entre outros;
- Medicina/Biologia, para monitorar o funcionamento de órgãos como o coração, detectar a presença de substâncias que indicam a presença ou surgimento de um problema biológico, seja no corpo humano ou animal;
- Militar, incluindo detecção de movimentos inimigos, explosões, a presença de material perigoso como gases venenosos ou radiação, etc;
- Produção industrial através do monitoramento em indústrias petroquímicas, fábricas, refinarias e siderúrgicas realizando o sensoriamento de parâmetros como fluxo, pressão, temperatura, e nível, identificando problemas como vazamento e aquecimento;
- Áreas industriais, cujo monitoramento de dados em determinadas áreas é de difícil acesso ou perigosas;
- Extração de petróleo e gás em plataformas de alto-mar, os quais podem resultar em monitoramento crítico;
- Indústria de aviação, na qual sua utilização na tecnologia *fly-by-wire* que faz largo uso de transdutores (sensores e atuadores);
- Monitoramento de linhas de distribuição de energia e sistemas de distribuição de gás e água, realizando coleta de dados como fluxo, pressão, temperatura, e nível;

Dos fatores listados para área industrial, a substituição da atividade humana para o uso de uma RSSF em uso industrial é evidenciado principalmente em cenários insalubres, perigosos ou nocivos ao ser humano como a realização do monitoramento em casos de acidente nuclear,

análise de atividade vulcânica, exploração subterrânea ou mesmo exploração subaquática nas quais o fator humano presencial tende a ser uma limitação no monitoramento.

Uma RSSF na área ambiental aplicada para o monitoramento de incêndios florestais permite que em tempo real se tome conhecimento do fato, permitindo a tomada de decisão imediata para solucionar o problema crítico.

1.2.Os desafios em RSSF

Hadim e Mohamed (Hadim & Mohamed, 2006) descrevem os seguintes desafios apresentados na área de RSSF:

- Limitações de *Hardware*: Com o advento da microeletrônica é possível projetar dispositivos com poucos centímetros cúbicos gerando a necessidade de criar mecanismos para o uso eficiente do processador e memória ao mesmo tempo que estabelece a comunicação de baixo custo;
- Topologia de rede: A topologia da rede é sujeita a frequentes mudanças, pelos mais diversos fatores, tais como: falha no dispositivo, acréscimo de obstáculos, mobilidade e interferências.
- Escalabilidade: Em grandes áreas pode haver a necessidade de adição de novos nós a qualquer momento sem afetar o desempenho da rede.
- Tolerância a falhas: O sistema deve estar devidamente preparado para auto configuração e auto manutenção para coleta, organização topológica e interferências;
- Heterogeneidade: Suportar a interação entre diferentes dispositivos de *hardware* realizando a interface de comunicação simples e abstraída trocando mensagens de dados primitivos.
- Gerenciamento de energia: Otimizar o consumo de bateria em protocolos de roteamento, localização, agregação, etc.
- Integração com o mundo real: Aplicações em tempo real integradas a outros sistemas, reduzindo a necessidade de controle manual, e permitindo a comunicação entre sistemas, também conhecido como *internet of things*.
- Organização da Rede: Em algumas redes, há necessidade de auto localização dos nós da rede de sensores, nas quais o uso do Sistema de Posicionamento Global (GPS) destaca-se para tal finalidade. Entretanto o GPS não é a única forma de localização.

Existem vários protocolos, algoritmos e técnicas cujo objetivo é estender a vida útil da rede, nos quais podem citar como mais importantes: os sistemas de roteamento (Pires, Silva, Cerqueira, Monteiro, & Viegas, 2011), fusão de dados (Lichuan & Manli, 2010), agregação de dados (Jun, Yatskiv, Sachenko, & Yatskiv, 2012). A localização em RSSF pode ser usada como auxiliar na redução do consumo de energia, considerando cenários nos quais as menores distâncias estejam diretamente relacionadas ao menor custo energético de envio.

O desafio de localização tem recebido atenção considerável, visto que muitas aplicações necessitam localizar ou rastrear objetos e/ou pessoas, desta forma vários serviços de localização foram criados. OGPS é o serviço de localização mais conhecido (Langendoen & Reijers, 2003). Porém, apresenta algumas desvantagens, tais como a utilização de até quatro sinais de satélite para conseguir uma localização satisfatória, a necessidade de um consumo significativo de energia devido à recepção de sinais de comunicação via satélite e ao custo adicional de utilização de um GPS em cada *hardware* (Lichuan & Manli, 2010). Paralelamente a este método, outras técnicas alternativas são capazes de compor um sistema de localização em RSSF (Priwgharm & Chemtanomwong, 2011). Dentre elas, destacam-se:

- Lateração (Maheshwari & Kemp, 2009);
- *Nearest Neighbor* (NN – ou vizinho mais próximo) (Priwgharm & Chemtanomwong, 2011);
- *K-Nearest Neighbor* (KNN – ou K vizinhos mais próximos) (Min, Stanley, Yuan, Bonner, & Zhang, 2009);
- *Min –Max* (Will, Hillebrandt, Yuan, & Yubin, 2012);
- RNA (Redes Neurais Artificiais) (Rajae, AlModarresi, Sadeghi, & Aghab, 2008);
- Filtro de *Kalman* (Jieyang & Liang, 2011);
- *Least-Square Support Vector Regression* (LSSVR – ou mínimos quadrados de Apoio regressão vetorial) (Xuewen, Yong, & Yanmeng, 2011).

A Lateração, *Min-Max*, LSSVR, NN, KNN e RNA entre outras compõem um conjunto de técnicas que usam o *Received Signal Strength Indicator* (RSSI – ou indicador de intensidade do sinal recebido) para estimar a localização do nó em uma RSSF. É uma medida da potência do sinal no enlace do rádio quando uma mensagem é recebida, cuja potência aumenta conforme a proximidade do emissor ao receptor. Com o RSSI, é possível:

- Calcular a matriz de localização para cada ponto (Lateração),
- Calcular as coordenadas como pesos na média aritmética dos seus vizinhos mais próximos (KNN),

- Inserir as entradas em uma RNA ou,
- Obter a localização geográfica de um nó de rede usando outras técnicas e filtros.

Este trabalho apresenta uma avaliação experimental real que compara as técnicas de Lateração (Neto, Neto, Yang, & Glover, 2010), KNN (Chun-Chieh, Yi-Jing, Seng-Yong, & Chia-H, 2011) e RNA (Shareef, Zhu, & Musavi, 2008) projetadas para a localização. Todas as experiências foram realizadas com base em um conjunto de RSSI's coletados e aplicados a técnicas de localização em ambiente real.

O erro de localização de um nó sensor na RSSF e o *benchmark* comparando técnicas distintas são métricas eficazes para tomar conhecimento da eficiência no processo de localização, assim como reduzir o consumo de energia, uma vez que a distância é diretamente proporcional ao consumo energético (Lei Fang & Ning, 2007).

1.3.Objetivos

Este trabalho tem como seu principal objetivo a análise comparativa entre as técnicas de localização Lateração, KNN e RNA em ambientes reais *indoor* e *outdoor*, estabelecendo o *benchmark* do erro de localização como métrica para comparar as técnicas.

Os objetivos específicos desta dissertação são:

- Desenvolver um *software* capaz de coletar o RSSI entre dois nós.
- Coletar os valores do RSSI em um nó alvo tomando quatro nós âncoras.
- Aplicar os algoritmos de Lateração, KNN e RNA para estimativa da localização.
- Realizar a análise do erro por técnica.
- Estabelecer uma comparação (*benchmark*) entre as técnicas.

1.4.Justificativa

Este trabalho visa contribuir com a pesquisa no campo da localização de redes de sensores sem fio em ambientes reais, visto que muitos trabalhos relacionados apresentam ambientes simulados, e trabalhos práticos são encontrados em menor escala.

Outra contribuição desejada é estabelecer um estudo comparativo entre as técnicas Lateração, KNN e RNA. O motivo da escolha da primeira é a presença em grande parte dos trabalhos correlatos, sendo uma técnica muito explorada desde trabalhos mais antigos aos mais recentes. A escolha da segunda técnica se deu pelo estudo realizado em (Priwgharm & Chemtanomwong, 2011) onde comparou quatro técnicas, a Lateração apresentou o menor erro

e a técnica KNN obteve segundo lugar, porém com resultados muito próximos a Lateração. A escala do ambiente de testes e o *hardware* disponível para este experimento são diferentes em relação ao trabalho citado, gerando a curiosidade de tomar conhecimento se em ambientes maiores e utilizando *hardwares* diferentes o resultado seria semelhante, ou a técnica KNN em algum momento apresentaria melhores resultados.

A pesquisa bibliográfica apresentou trabalhos de localização com utilização de RNAs, comparando as diversas formas e configurações para estabelecer as configurações mais indicada para o problema da localização (Rice & Harle, 2005) (Shareef, Zhu, & Musavi, 2008) (Tian & Xu, 2012) (Rahman, Youngil, & Ki-Doo, 2009).

Trabalhos comparativos se dividiam em técnicas clássicas e técnicas inteligentes, não conflitando a diferente natureza de cada uma. Devido a isto, a utilização de Redes Neurais Artificiais em comparação com a Lateração e o KNN se dá para o enriquecimento do estudo científico para as técnicas de diferentes naturezas.

1.5. Metodologia

Este trabalho visa realizar experimentos em ambientes reais para estimativa da localização em ambientes *indoor* e *outdoor*. Para isto é necessário realizar as seguintes etapas:

- Demarcação territorial, definindo os valores das coordenadas dos nós âncoras;
- Coleta e armazenamento dos RSSIs dos nós âncoras;
- Divisão dos dados coletados em amostras para treino e amostra para testes;
- Treinamento da RNA;
- Teste da RNA;
- Aplicar a Lateração às amostras do arquivo de teste usado na RNA;
- Aplicar o KNN às amostras do arquivo de teste usado na RNA;
- Calcular o *benchmark* entre as técnicas;
- Tabelar os resultados;
- Exibir graficamente os pontos reais e suas respectivas estimativas para cada técnica;

As análises comparativas têm como objetivo principal estabelecer uma relação entre as técnicas Lateração, KNN e RNA para utilização de um protocolo de localização, onde as informações de escala, topologia da rede e tipo de ambiente permitisse a melhor escolha da técnica utilizada.

1.6.Motivação

Postulações matemáticas são amplamente utilizadas para modelagem do mundo real em ambientes virtuais, conhecidas como simulações, nas quais tomam um conjunto de variáveis que influem diretamente no desenvolvimento do modelo. Entretanto a confiabilidade da simulação pode ser perdida completamente em caso de erro na modelagem de uma ou mais variáveis, ou mesmo se apresentar resultados divergentes se comparados ao ambiente real na qual se propõe a replicar virtualmente. Desta forma a maior motivação deste trabalho se dá pela realização de testes em cenários do mundo real. Embora o ambiente de simulação forneça comodidades e facilidades da obtenção de dados, a experimentação demonstra maior veracidade e confiabilidade, devido a sua própria natureza dos testes.

1.7.Estrutura da Dissertação

Este trabalho é composto por sete capítulos e um apêndice, além deste capítulo introdutório, esta dissertação esta dividida em:

Capítulo 2: Aborda as formas de localização em RSSF sem uso de GPS, classificadas pela natureza da comunicação. Das quais cita-se: o ângulo das antenas como referência para estimativa, o tempo sincronizado entre dois rádios, a diferença de tempo no envio de duas mensagens e a potência do sinal recebido. Este capítulo aborda também técnicas e algoritmos matemáticos, inteligentes e estatísticos utilizados no levantamento bibliográfico para a localização de nós sensores em RSSF.

Capítulo 3: Apresenta os principais conceitos sobre o estado da arte e trabalhos correlatos de localização em RSSF utilizando abordagens matemáticas, inteligentes, estatísticas, filtros, etc. Apresenta a perspectiva dos autores quanto a organização do experimento, abordando implementações reais e simulações, assim como um levantamento prévio referente aos trabalhos correlatos.

Capítulo 4: Apresenta os ambientes de testes, sendo um ambiente *indoor* e outro ambiente *outdoor*. Apresenta também a metodologia dos testes realizada neste trabalho e a arquitetura necessária para reproduzir o experimento apresentando o conjunto de *hardware* e *software* necessários.

Capítulo 5: Apresenta a análise comparativa entre as técnicas em estudo, vislumbrando os resultados através de Tabelas, gráficos e discorrendo a respeito dos dados percentuais, quantitativos, qualitativos e acumulados.

Capítulo 6: Estabelece as considerações finais a respeito do trabalho realizado.

Apêndice A: Apresenta a comunicação entre nós da RSSF e o encaminhamento de dados via comunicação serial.

Apêndice B: Apresenta as imagens referentes ao ambiente de teste *indoor* e *outdoor*.

2. Localização em RSSF

Para localização em RSSF, uma alternativa popular é o Sistema de Posicionamento Global (GPS). Para sua utilização com precisão satisfatória, são necessários que pelo menos o sinal de quatro satélites sejam observados para estimativa de posicionamento, além do fato que a comunicação com satélites exige um consumo demasiado de energia (Lichuan & Manli, 2010). Em ambientes florestais amazônicos, por exemplo, as copas das árvores dificultam a transmissão do sinal, gerando assim uma forte barreira para comunicação com os satélites. O consumo de energia elevado pode fazer com que os nós de uma RSSF usem parte de sua energia residual para localização e não para a coleta e transmissão de dados.

Devido ao problema do consumo de energia por parte do GPS, alternativas são utilizadas para a estimativa da localização que são baseadas em outros tipos de medidas, tais como:

- *Time Of Arrival* (TOA) (Hyochang & Sang-Burm, 2010);
- *Time Difference Of Arrival* (TDOA) (Hsi-Chou, Jyh-Horng, Chia-Hsin, & Yi-Shi, 2011);
- *Angle Of Arrival* (AOA) (Chan & Wen, 2011);
- *Received Signal Strength Indicator* (RSSI) (Zhou, Zhao, & Tan, 2013).

2.1. Técnicas para utilização de Localização sem GPS

Nesta sessão serão apresentadas as técnicas AOA, TOA, TDOA e RSSI como alternativas ao GPS, podendo também utilizá-las em conjunto para melhoria da precisão da localização.

2.1.1. *Angle of Arrival*

As medições AOA, também conhecidas como direção de chegada, são obtidas a partir da amplitude ou da fase da antena do receptor. Além do direcionamento da antena, a precisão da AOA nas medições é afetada por outros fatores ambientais, como sombreamento e *multipath* (caminhos múltiplos), podendo resultar na transmissão para uma direção diferente de onde se encontra o receptor.

A primeira categoria de medidas AOA é conhecida como formação de feixe e é baseada na anisotropia do padrão de recepção de uma antena. A anisotropia é uma característica de objetos cuja propriedade física varia com a direção. Quando o feixe da antena

do receptor transmite na direção correspondente a força máxima de sinal, considera-se a mesma como a direção do transmissor. A precisão das medições é determinada pela sensibilidade do receptor e da largura de feixe.

A utilização de um feixe de rotação tem um problema potencial de que o receptor não pode diferenciar a variação de intensidade do sinal causado pela variação da amplitude do sinal transmitido e a variação da intensidade do sinal causado pela anisotropia do padrão de recepção. Este problema pode ser tratado por meio de um segundo feixe não rotativo e a antena omnidirecional no receptor. O impacto da variação de intensidade do sinal pode ser, em grande parte removido normalizando a intensidade do sinal recebido pela antena rotativa anisotrópica referente à potência do sinal recebido pela antena omnidirecional não rotativa. A Figura 5 apresenta a esquematização do AOA.

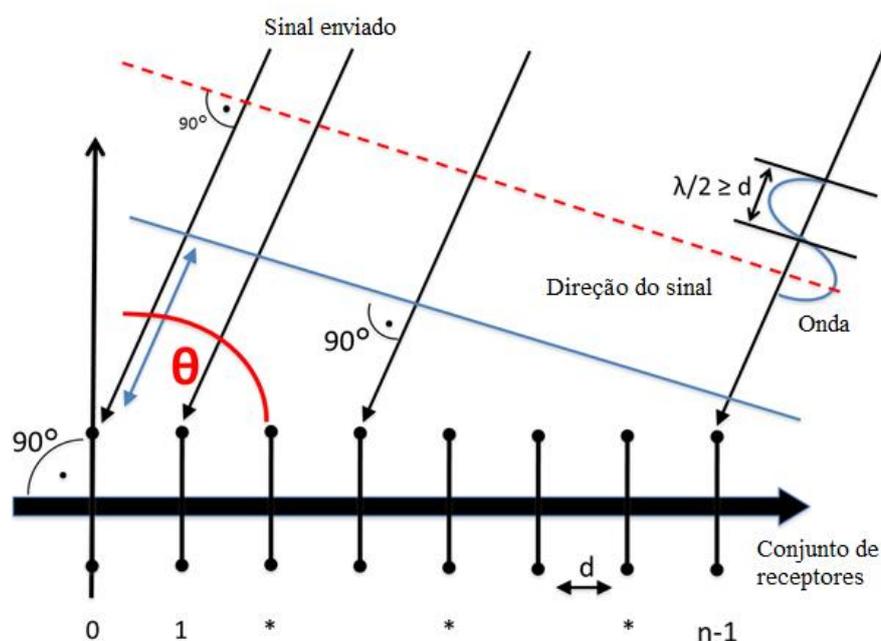


Figura 5 - Princípio de AOA. Fonte: (Shi, Mueller, & Marx, 2005)

Alternativamente, pode-se também usar várias antenas fixas comunicáveis entre si conjuntamente com antenas anisotrópicas. Comparando a intensidade do sinal recebido a partir de cada antena, é possível estimar a direção do transmissor, mesmo quando a intensidade do sinal muda (Boukerche, Oliveira, Nakamura, & Loureiro, 2007). A Figura 6 apresenta medição a partir de um ângulo β que é gerado pela recepção da mensagem da

origem (*source*), a Figura 7 apresenta de forma simplificada a interação entre o emissor e os receptores no processo de estimativa por AOA.

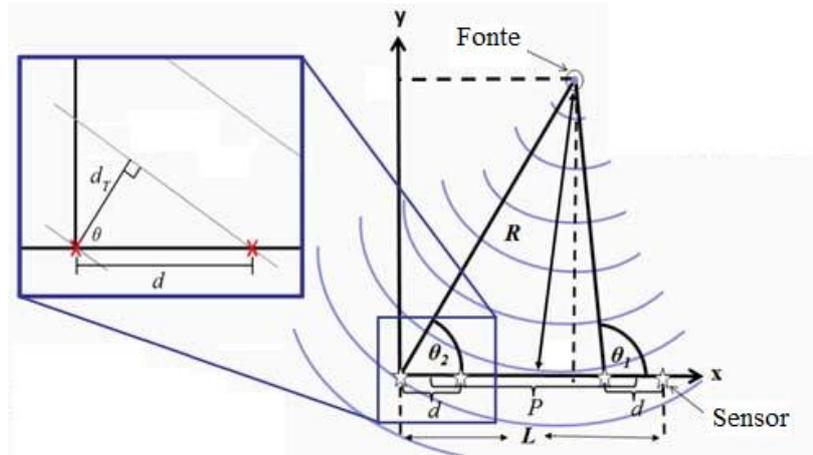


Figura 6 - Localização por AOA

A representação gráfica apresentada na Figura 6 mostra a geometria associada à técnica. As coordenadas x e y são estimadas a partir das equações (1) e (2), e o ângulo θ na equação (3).

$$x = \frac{-P}{2} \frac{[\tan(\theta_2) + \tan(\theta_1)]}{\tan(\theta_2) - \tan(\theta_1)} \quad (1)$$

$$y = \frac{-P[\tan(\theta_2) \tan(\theta_1)]}{\tan(\theta_2) - \tan(\theta_1)} \quad (2)$$

$$\cos \theta = \frac{v_s n}{d f_s} \quad (3)$$

Onde,

θ é o ângulo de chegada do sinal.

v_s é a velocidade do som

n é o atraso nas amostras

f_s é a frequência das amostras (*samples*)

d é a distância entre dois nós.

A equação (3) é resultante da decomposição trigonométrica pelas equações (4), (5) e (6)

$$d_T = d * \cos \theta \quad (4)$$

$$d_T = v_s * T \quad (5)$$

$$T = \frac{n}{f_s} \quad (6)$$

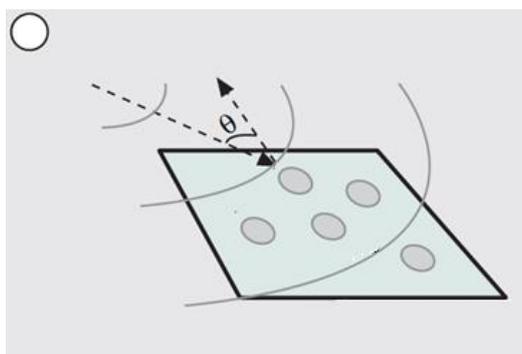


Figura 7 - AOA aplicado em ambiente de teste. Fonte: (Boukerche, Oliveira, Nakamura, & Loureiro, 2007).

A outra categoria de técnicas de medição utilizando AOA é conhecida como fase de interferometria, caracterizada pela sobreposição de duas ou mais entrada de dados, e que deriva a partir das medições AOA das diferenças de fase da chegada de uma onda eletromagnética. Uma grande antena no receptor (em relação ao comprimento de onda do sinal do transmissor) ou um conjunto de antenas é geralmente necessário quando se utiliza esta técnica.

A precisão das medições de AOA é limitada pelo direcionamento da antena e as medições são ainda mais difíceis com a presença de sombreamento e de trajetória múltipla no ambiente de medição. Um grande desafio nas medições AOA é, por conseguinte, a estimativa exata de AOA na presença de trajetórias múltiplas e sombreamento. Métricas AOA dependem de um caminho direto entre o transmissor e o receptor. Um componente de trajetória múltipla a partir do sinal do transmissor pode aparecer como um sinal vindo de uma direção completamente diferente e, conseqüentemente, provoca um grande erro na medição AOA (Boukerche, Oliveira, Nakamura, & Loureiro, 2007).

2.1.2. Time of Arrival

Time Of Arrival (TOA), também conhecido como "*time off light*", explora a relação entre a distância e o tempo de transmissão quando a velocidade de propagação é conhecida. Assumindo que o remetente e o receptor conhecem o momento em que a transmissão de uma mensagem será iniciada, o tempo de chegada desta transmissão para o receptor pode ser usado para calcular o tempo de propagação e a distância. Para isentar o receptor desta tarefa, ele pode retornar uma mensagem "pulso mensurado" em um tempo determinístico, o remetente

original então só medirá o tempo de ida e volta assumindo caminhos simétricos (Hsi-Chou, Jyh-Horng, Chia-Hsin, & Yi-Shi, 2011). A Figura 8 ilustra a funcionalidade de TOA.

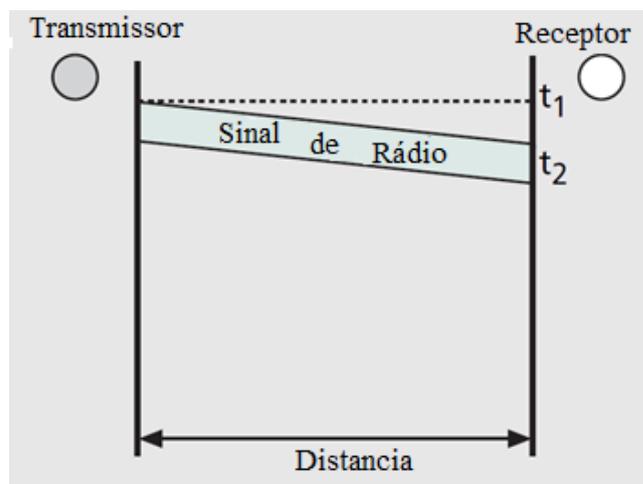


Figura 8 - Esquema de transmissão em TOA Fonte: (Boukerche, Oliveira, Nakamura, & Loureiro, 2007)

Dependendo do meio de transmissão que é usado, o tempo de chegada requer relógios de alta resolução para produzir resultados de uma precisão aceitável. Para ondas sonoras, estes requisitos de resolução são modestos, visto que o meio pode influir sobre a transmissão da propagação de ondas de rádio ou de ultrassom. Uma desvantagem do som é que sua velocidade de propagação depende de fatores externos, tais como temperatura ou umidade na qual é necessária uma calibração cuidadosa (Catovic & Sahinoglu, 2004). A estimativa da distância é realizada a partir da equação (7).

$$d = v * t \quad (7)$$

Onde,

d é a distância entre o emissor e o receptor,

v é a velocidade de transmissão,

t é o tempo de transmissão.

2.1.3. Time Difference of Arrival

Para superar a necessidade de sincronização explícita, o método *Time Difference of Arrival* (TDOA) utiliza sincronização implícita. TDOA utiliza dois meios de transmissão de diferentes velocidades de propagação, Figura 9 por exemplo, as ondas de rádio propagam à velocidade da luz e ultrasons, com uma diferença de velocidade de cerca de seis ordens de magnitude (Hsi-Chou, Jyh-Horng, Chia-Hsin, & Yi-Shi, 2011).

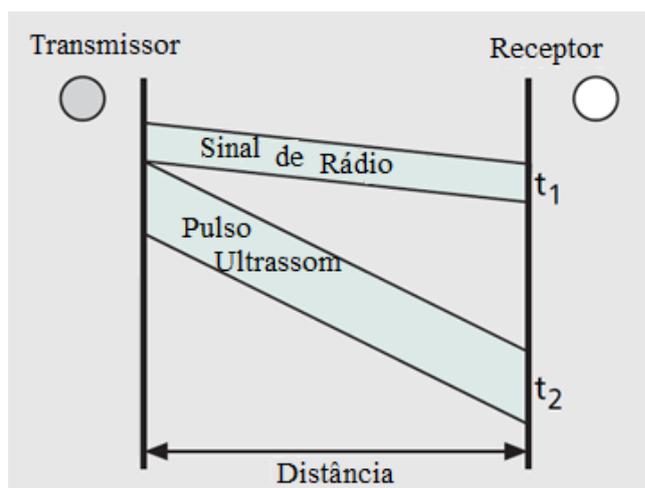


Figura 9 - TDOA utilizando sinal de rádio e pulso ultrassom. Fonte: (Boukerche, Oliveira, Nakamura, & Loureiro, 2007)

Quando um remetente começa o envio de ultrasons e uma transmissão de rádio ao mesmo tempo, o receptor pode utilizar a chegada da transmissão de rádio para iniciar a medição do tempo até à chegada da transmissão de ultrasons, ignorando seguramente o tempo de propagação da comunicação. A desvantagem nítida deste método é a necessidade de dois tipos de emissores e receptores em cada nó limitando hardwares que não possuem duas antenas de diferentes rádios. A vantagem, por outro lado, é uma precisão consideravelmente maior em comparação com as abordagens baseadas em RSSI (Catovic & Sahinoglu, 2004). O cálculo da distância é semelhante à técnica TOA, estimando a distância para cada mensagem recebida e subtraindo os valores da segunda pela primeira.

2.1.4. Received Signal Strength Indicator

Received Signal Strength Indicator (RSSI) permite estimar a distância entre dois nós sensores vizinhos a partir das medições da potência do sinal recebido. A maioria dos dispositivos sem fio tem capacidade de medir a potência do sinal. A intensidade do sinal entre sensores é uma função decrescente em função da distância, desta forma, quanto maior a potência do sinal recebido, mais próximo o emissor e receptor se encontram. A Figura 10 apresenta a área de cobertura na qual se pode estimar a distância a partir do RSSI.

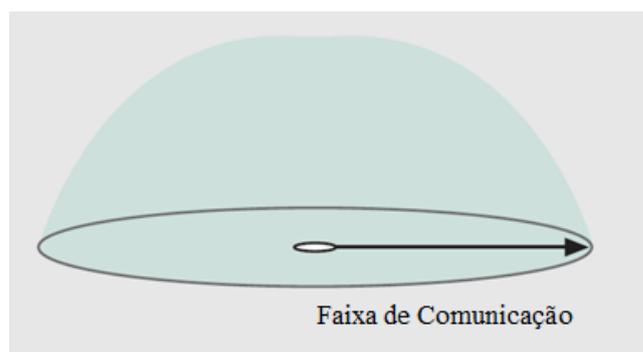


Figura 10 - Poder de alcance do RSSI. Fonte: (Boukerche, Oliveira, Nakamura, & Loureiro, 2007)

Localização com base em RSSI requer a configuração do transmissor e receptor para que seja possível extrair a perda de propagação (*path loss*) para obtenção do RSSI, e posteriormente atuar como entrada para algoritmos de localização. A estimativa de perda de propagação exige como parâmetro o RSSI e a distância do transmissor. A Figura 11 apresenta um diagrama em blocos da obtenção da estimativa de localização partindo do RSSI.



Figura 11 - Diagrama de blocos da estimativa do RSSI (Xuewen, Yong, & Yanmeng, 2011)

Quando os rádios estão lado a lado, com as antenas muito próximas, é possível obter o valor máximo da potência do sinal, visto que a distância entre ambos é zero. A distância mínima varia conforme o hardware utilizado, podendo em alguns ser limitado a zero dbm ou mensurar valores negativos dependendo da implementação do fabricante. A relação distância x qualidade é ilustrada pela Figura 12, na qual mostra a potência recebida conforme a intensidade da cor dos círculos monocromáticos da imagem.

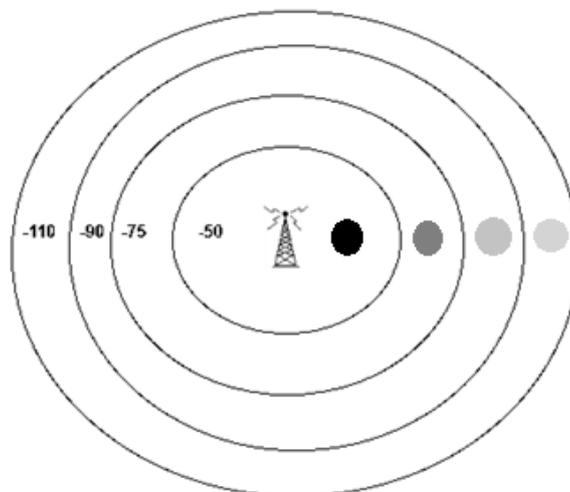


Figura 12 - Ilustração da característica do sinal conforme a distância

Desta forma, para se testar a distância máxima, assim como o valor mínimo de RSSI permitido entre dois módulos, é necessário afastá-lo até o limite de alcance do sinal (Boukerche, Oliveira, Nakamura, & Loureiro, 2007). Entretanto o espalhamento do sinal não é uniforme, conforme a Figura 13.

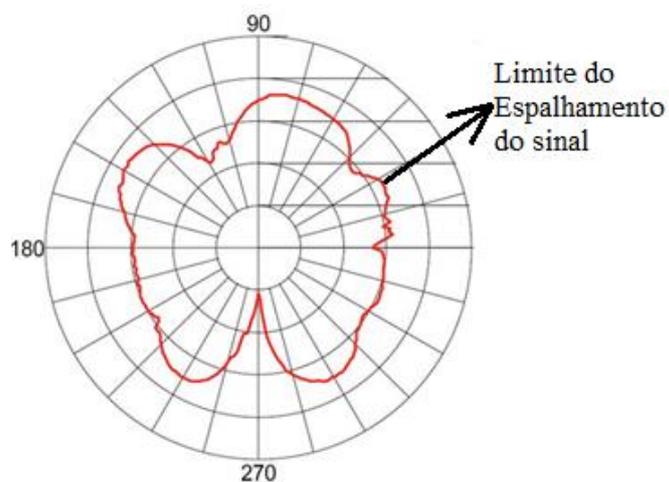


Figura 13 - Espalhamento do sinal no raio de alcance

Dada a natureza dos ambientes reais, o espalhamento do sinal sofre variação ao redor do ponto de transmissão. Isto ocorre a partir de um conjunto finito de raios em diferentes direções. O alcance máximo não será igual para todas as direções, sofrendo maiores perdas para alguns dos pontos e melhor cobertura para outros raios de direção. Isto se agrava com a presença de obstáculos, refletores, e até o próprio chão é um agente limitador do raio de

transmissão (Priwgharm & Chemtanomwong, 2011) (Tsai, Lau, & Huang, 2012) (Rice & Harle, 2005).

2.1.5. Comparação entre os métodos

O Quadro 2 estabelece a comparação entre as técnicas de localização cujo objetivo é substituir ou auxiliar o GPS na localização. O Quadro destaca as desvantagens como a necessidade de hardware adicional e passível a interferência. A sincronização, por sua vez, recai em um desafio existente de relógios em sistemas distribuídos.

Quadro 2 -Características por técnica

Técnica	Hardware adicional	sincronização	sujeito a interferência
AOA	x		x
TOA		X	
TDOA	x	X	
RSSI			x

As técnicas AOA e TDOA tendem a ser mais eficientes que a técnica RSSI na precisão da estimativa da localização (Chan & Wen, 2011). Porém, as técnicas AOA e TDOA necessitam de *hardware* adicional para executar suas estimativas, o que recai na mesma situação do GPS que também necessita de recursos físicos para incorporar à sua solução (Chan & Wen, 2011) (Catovic & Sahinoglu, 2004).

A técnica TOA por sua vez utiliza a sincronização como parte do controle do protocolo de localização para estimar a distância entre dois pontos. Em sistemas distribuídos, a sincronização é um dos desafios existentes, visto que, os relógios nunca ficam perfeitamente ajustados, ocasionando uma pequena diferença de tempo entre dois nós da RSSF. Outro fator é a sincronização dos relógios, na qual a adição de novos nós cujo relógio não esteja ajustado em relação aos primeiros nós da rede podem comprometer a escalabilidade (Domenech & Wehr, 2011) (Hsi-Chou, Jyh-Horng, Chia-Hsin, & Yi-Shi, 2011).

A maioria das rádios permitem estimar o RSSI a partir de uma mensagem recebida sem a necessidade de *hardware* adicional, motivo que causa a popularidade da técnica (Priwgharm & Chemtanomwong, 2011). Devido a existência do problema de radiofrequência, técnicas de utilização da potência do sinal repercutem em alguns desafios, e muitos sistemas de localização baseados na potência do sinal têm sido propostos e implementados com diferentes graus de sucesso transformando estimativas de alcance em estimativas de localização precisas (Xuewen, Yong, & Yanmeng, 2011).

2.2. Técnicas de localização

Inicialmente, define-se como nó âncora todo nó cuja localização é conhecida, e possui o objetivo de auxiliar nós que ainda desconhecem sua posição atual. Os nós com localização desconhecida são definidos como nós alvo. Estes nós recebem uma mensagem de cada nó âncora, e através da mensagem recebida é possível estimar o valor do RSSI entre o nó âncora (origem da mensagem) e o nó alvo (destino da mensagem).

Nesta sessão, serão apresentados alguns algoritmos para estimativa da localização dos nós da RSSF utilizando o RSSI. Estes algoritmos também são considerados técnicas de localização, porém sua natureza é diferente das técnicas citadas anteriormente. As técnicas AOA, TOA, TDOA e RSSI substituem fisicamente o uso do GPS, enquanto as técnicas Lateração, KNN, RNA, entre outras, utilizam das distâncias adquiridas para estimar os valores das coordenadas planares. Para todas as técnicas utilizadas, haverá um conjunto de nós âncoras, que enviarão mensagens ao nó alvo para extrair o RSSI de cada mensagem. Este nó alvo está diretamente ligado a um computador para que seja possível coletar os dados, conforme mostrado na Figura 14.



Figura 14 - Comunicação entre âncoras e o alvo conjuntamente a interface desktop.

A Figura 14 ilustra quatro nós de referência, ou nós âncoras, que se comunicam com o nó alvo enviando mensagens para que o nó alvo extraia o RSSI a partir destas mensagens. Em

seguida, os valores coletados são encaminhados para o aplicativo desktop permitindo o armazenamento de dados e a estimativa da localização.

2.2.1. Lateração

A técnica de Lateração consiste inicialmente na estimativa da localização que utiliza a distância euclidiana entre um nó alvo e cada nó âncora. O conjunto de equações das distâncias permite montar a matriz distâncias, que posteriormente é utilizada para encontrar as coordenadas referentes à localização do nó alvo da RSSF. A técnica de Lateração inicia a partir de quando um nó alvo obtém um conjunto de sinais (RSSI). A equação (8) é referente ao RSSI obtido por cada nó âncora. A equação (9) estima a distância entre o nó alvo e cada nó âncora.

$$RSSI[dbm] = -10 * pathloss * \log(d_i)_{10} + A \quad (8)$$

$$d_i = 10^{\frac{Rssi-A}{-10*pathloss}} \quad (9)$$

Onde,

RSSI é o valor da potência do sinal da mensagem

Path loss é a variável de perda de propagação do ambiente

d_i é a distância do nó âncora *i* ao nó alvo

A é o valor do RSSI a 1 metro de distância entre o nó alvo e nó âncora

O *path loss* é a medida de atenuação introduzida pelo ambiente onde o sinal se propaga. O ambiente fornece um efeito de filtragem do sinal entre o transmissor e o receptor ocorrendo a perda de energia. O *path loss* é expresso pela equação (10).

$$pathloss = \frac{Rssi-A}{-10 \cdot \log_{10}(d_i)} \quad (10)$$

Os valores de *A* e do *path loss* são obtidos antes do início dos testes de localização. Para *A* o RSSI é extraído de forma experimental a partir da separação de dois nós tomando a distância de 1 metro entre os mesmos. Para o *path loss*, toma-se alguns pontos com diferentes distâncias e o valor de *A*, a partir destes parâmetros, o valor do *path loss* é estimado conforme a distância entre o emissor e o receptor. Para cada mensagem recebida por um nó

ancora a distância d_i é determinada a partir da equação (11). Estas distâncias são exemplificadas na Figura 15.

$$d_i^2 = (x - x_i)^2 + (y - y_i)^2 \quad (11)$$

Onde:

d_i é a distância do nó âncora i ao nó alvo

x é a coordenada x do nó alvo

y é a coordenada y do nó alvo

x_i é a coordenada x do nó âncora

y_i é a coordenada y do nó âncora

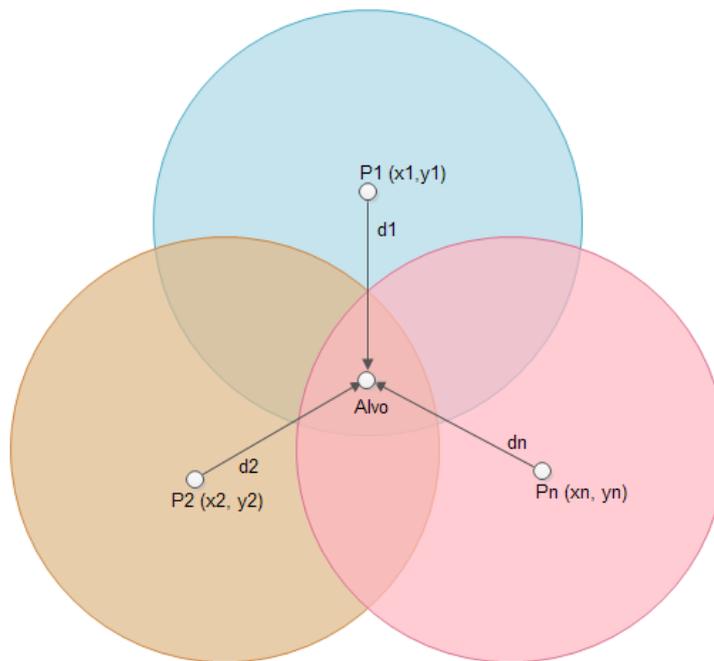


Figura 15–Estimativa da distância na Lateração

Considerando n nós âncoras, a partir da equação (11) obtém-se um conjunto de n equações exibidas na equação (12).

$$\begin{cases} d_1^2 = (x - x_1)^2 + (y - y_1)^2 \\ d_2^2 = (x - x_2)^2 + (y - y_2)^2 \\ \dots \\ d_n^2 = (x - x_n)^2 + (y - y_n)^2 \end{cases} \quad (12)$$

O conjunto de equações (13) mostra a expansão das equações (12), que por sua vez resultam em um sistema quadrático, portanto não linear. Dado que d_i , x_i e y_i são valores conhecidos, portanto constantes, subtraindo a última equação do sistema de equações em (13) pelas demais são obtidos os cálculos mostrados na equação (14). Em (14) ocorre a eliminação algébrica do fator quadrático montando um sistema linear conforme visto na equação (15).

$$\begin{cases} d_1^2 = x^2 - 2 * x * x_1 + x_1^2 + y^2 - 2 * y * y_1 + y_1^2 \\ d_2^2 = x^2 - 2 * x * x_2 + x_2^2 + y^2 - 2 * y * y_2 + y_2^2 \\ \dots \\ d_n^2 = x^2 - 2 * x * x_n + x_n^2 + y^2 - 2 * y * y_n + y_n^2 \end{cases} \quad (13)$$

$$\begin{cases} d_n^2 - d_1^2 = -x^2 + x^2 + 2 * x * x_1 - 2 * x * x_n - x_1^2 + x_n^2 \\ \quad - y^2 + y^2 + 2 * y * y_1 - 2 * y * y_n - y_1^2 + y_n^2 \\ d_n^2 - d_2^2 = -x^2 + x^2 + 2 * x * x_2 - 2 * x * x_n - x_2^2 + x_n^2 \\ \quad - y^2 + y^2 + 2 * y * y_2 - 2 * y * y_n - y_2^2 + y_n^2 \\ \dots \\ d_n^2 - d_{n-1}^2 = -x^2 + x^2 + 2 * x * x_{n-1} - 2 * x * x_n - x_{n-1}^2 + x_n^2 \\ \quad - y^2 + y^2 + 2 * y * y_{n-1} - 2 * y * y_n - y_{n-1}^2 + y_n^2 \end{cases} \quad (14)$$

$$\begin{cases} 2(x_1 - x_n)x + 2(y_1 - y_n)y = x_1^2 - x_n^2 + y_1^2 - y_n^2 - d_1^2 + d_n^2 \\ 2(x_2 - x_n)x + 2(y_2 - y_n)y = x_2^2 - x_n^2 + y_2^2 - y_n^2 - d_2^2 + d_n^2 \\ \dots \\ 2(x_{n-1} - x_n)x + 2(y_{n-1} - y_n)y = x_{n-1}^2 - x_n^2 + y_{n-1}^2 - y_n^2 - d_{n-1}^2 + d_n^2 \end{cases} \quad (15)$$

O sistema linear (15) pode ser representado na forma matricial conforme equação (16) e para determinar as coordenadas desconhecidas, basta isolar a matriz referente ao ponto (x,y) conforme a equação (17).

$$BX = C \quad (16)$$

$$X = (B^T B)^{-1} B^T C \quad (17)$$

Onde,

$$X = \begin{bmatrix} x \\ y \end{bmatrix} \quad (18)$$

$$C = \begin{bmatrix} x_1^2 - x_n^2 + y_1^2 - y_n^2 - d_1^2 + d_n^2 \\ x_2^2 - x_n^2 + y_2^2 - y_n^2 - d_2^2 + d_n^2 \\ \vdots \\ x_{n-1}^2 - x_n^2 + y_{n-1}^2 - y_n^2 - d_{n-1}^2 + d_n^2 \end{bmatrix} \quad (19)$$

E,

$$B = \begin{bmatrix} 2(x_1 - x_n) & 2(y_1 - y_n) \\ 2(x_2 - x_n) & 2(y_2 - y_n) \\ \vdots & \vdots \\ 2(x_{n-1} - x_n) & 2(y_{n-1} - y_n) \end{bmatrix} \quad (20)$$

2.2.2. KNN

O KNN é uma técnica de classificação de dados que mede a diferença ou similaridade entre duas instâncias a partir da proximidade das características do objeto. As instâncias são definidas utilizando um conjunto de amostras para tomar conhecimento inicial do problema. A métrica utilizada para realizar as estimativas da distância de um ponto aos seus vizinhos pode ser calculada de diversas formas, entre elas as distâncias:

- Euclidiana (Julazadeh, Marsousi, & Alirezaie, 2012): distância entre dois pontos que pode ser mensurada através do teorema de Pitágoras conforme apresentado na equação(21).

$$a^2 = b^2 + c^2 \quad (21)$$

Onde:

- a é a hipotenusa,
- b é o cateto oposto, e
- c é o cateto adjacente.

- Mahalanobis (Washizawa & Hotta, 2012): é uma medida de distância estatística entre um grupo de valores utilizando vetores das coordenadas e a matriz de covariância (medida do grau de interdependência numérica entre duas variáveis aleatórias) conforme equação (22).

$$d(\vec{x}, \vec{y}) = \sqrt{(\vec{x} - \vec{y})^T S^{-1} (\vec{x} - \vec{y})} \quad (22)$$

Onde:

- d é a distância de Mahalanobis,
- \vec{x} e \vec{y} são os vetores de coordenadas,
- S é a matriz de covariância.

- Minkowsky (Cavalcanti, 2005): é uma métrica generalizada cujas medidas permitem estimar distâncias que tendem ao infinito. A distância de Minkowsky é apresentada na equação (23).

$$d = (\sum_{i=1}^n |x_i - y_i|^p)^{\frac{1}{p}} \quad (23)$$

Onde:

d é a distância de Minkowsky,

x_i e y_i são as coordenadas das amostras,

n é o número de amostras,

p é a ordem da métrica de Minkowsky.

- Hamming (Zhang, Zhang, Tang, Lu, & Qi, 2013): a distância de Hamming é aplicada sobre cadeias de caracteres que possuem o mesmo tamanho na qual mede o número mínimo de substituições para alterar de uma cadeia de caracteres para a outra.

A definição do valor de K é realizada conforme a necessidade da aplicação, para valores de K muito pequenos, a classificação fica sujeita a pontos inconsistentes ou mesmo aos ruídos provenientes da classificação, enquanto valores de K muito grandes podem incluir elementos de outras classes.

Um exemplo destas classes pode ser a relação peso x altura de uma população conforme mostrado na Figura 16, na qual o valor de $K = 3$, os pontos verdes são as pessoas mais leves, os pontos azuis se referem às pessoas mais pesadas e os pontos amarelos são pessoas que desconhecem seu peso, tentando estimar seu peso a partir da altura dos seus vizinhos.

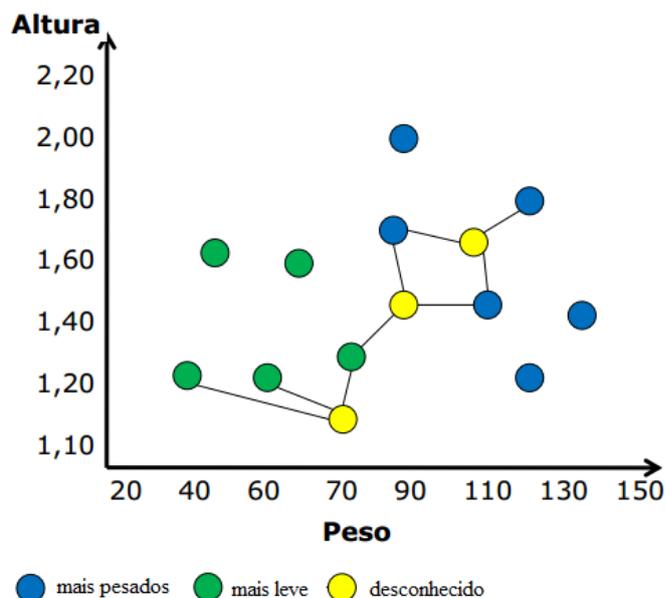


Figura 16 - Exemplo de estimativa do KNN

Ainda no mesmo exemplo, para valores muito baixos de K , a estimativa pode ser realizada erroneamente dependendo do modelo no qual o problema se propõe a estimar. Ou também pode agregar valores desconexos para valores de K muito grandes, tais como o salário do indivíduo.

2.2.3. RNA

Redes Neurais Artificiais são modelos baseados no cérebro biológico realizando o aprendizado em estruturas que simulam o comportamento dos neurônios incluindo suas sinapses e interconexões. O cérebro é altamente complexo, não linear, e possui computação paralela (sistema de processamento de informações), composto por um conjunto de neurônios que por sua vez são compostos por dendritos, axônios e o corpo celular (Yi, Gies, Teles, & Ginoux, 2013) (Monteiro & Takita, 1996). A Figura 17 apresenta diferentes tipos de neurônios biológicos.

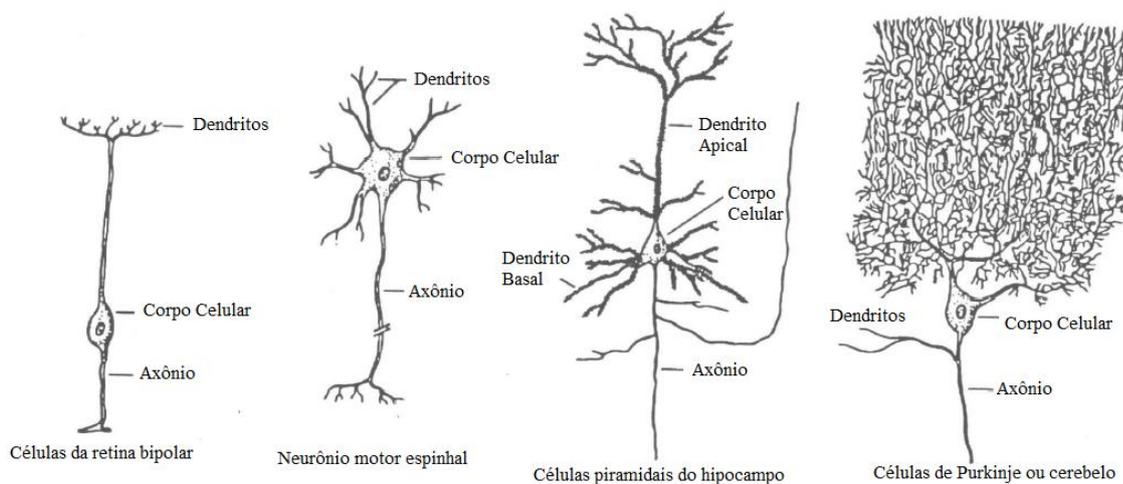


Figura 17 - Exemplos de neurônios biológicos

Uma rede neural é um processador distribuído massivamente paralelo, que possui uma propensão natural para armazenar conhecimentos experimentais e fazê-los disponíveis para uso. A rede se assemelha ao cérebro humano em dois aspectos:

- 1) O Conhecimento é adquirido pela rede através de um processo de aprendizagem.
- 2) A energia de conexão entre neurônios, conhecida como peso sináptico, é usada para armazenar conhecimento.

O procedimento usado para executar o processo de aprendizagem é conhecido como algoritmo de aprendizagem. Ele é o responsável pela alteração dos pesos sinápticos fazendo com que a rede neural se adapte às condições do meio em que está envolvida (Haykin, 2008).

Em um neurônio, o fluxo da informação é direcionado dos dendritos para o corpo celular, e posteriormente para os axônios, que por sua vez são ligados a dendritos de outros neurônios compondo uma sinapse. A informação biológica é proveniente de impulsos elétricos. No corpo celular ocorre uma soma e processamento das cargas elétricas, que por sua vez resultam no impulso de saída.

O neurônio artificial segue o mesmo princípio do neurônio biológico, no qual a entrada, seus respectivos pesos e um bias, fator de ajuste de entrada, compõem a estrutura análoga aos dendritos, a saída igualmente aos axônios, e o corpo celular é responsável pelo processamento da informação (Haykin, 2008). A estrutura básica de um neurônio é apresentada na Figura 18.

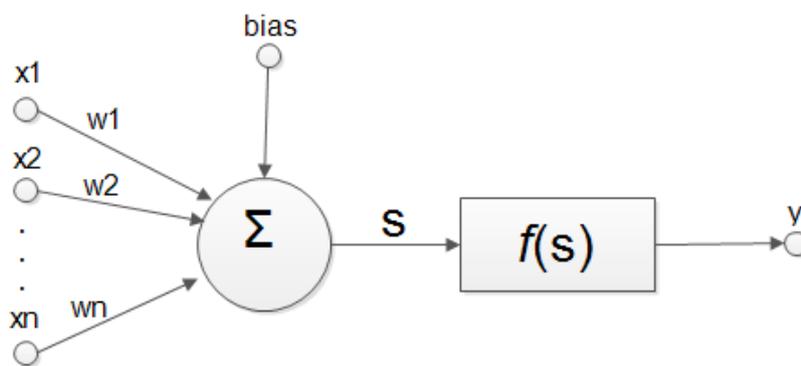


Figura 18 - Estrutura básica de um neurônio

A Figura 18 apresenta o modelo artificial de neurônio, no qual existe um conjunto de entradas representadas pelo conjunto $x = \{x_1, x_2, \dots, x_n\}$, um conjunto de pesos $w = \{w_1, w_2, \dots, w_n\}$, e um bias (b). No corpo celular do neurônio artificial ocorre a soma ponderada das entradas com seus respectivos pesos. A saída é estimada a partir de uma função que faz uso da soma como parâmetro (Haykin, 2008). O Quadro 3 apresenta algumas das funções cujo parâmetro s é a soma das entradas no neurônio.

Quadro 3 - Exemplos de funções de ativação

Linear	$f(s) = s$
Sinal	$f(s) = \begin{cases} +1, & \text{se } s \geq 0 \\ -1, & \text{se } s < 0 \end{cases}$
Degrau	$f(s) = \begin{cases} +1, & \text{se } s > 0 \\ 0, & \text{se } s \leq 0 \end{cases}$
Seno	$f(s) = \text{sen}(s)$
Cosseno	$f(s) = \text{cos}(s)$
Gaussiana	$f(s) = e^{-s^2}$
Sigmoide	$f(s) = \frac{1}{1 + e^{-s}}$
Tangente hiperbólica	$f(s) = \frac{1 - e^{-2s}}{1 + e^{-2s}}$

2.2.3.1. RNAs em localização

Diversas configurações de RNAs permitem estimar a localização utilizando parâmetros como: localização dos nós âncoras, potência do sinal obtida (Rahman, Youngil, & Ki-Doo, 2009) (Shareef, Zhu, & Musavi, 2008), ângulo de chegada (Van Sickle & Abdel-Aty-Zohdy, 2011), tempo de sincronização (Domenech & Wehr, 2011). Dentre as RNAs utilizadas para localização podem ser citadas:

2.2.3.1.1. *MultiLayer Perceptron*

Uma RNA *MultiLayer Perceptron* possui três características singulares:

- O modelo de cada neurônio na rede inclui uma não-linearidade de saídas nas funções de ativação, estas funções simulam o comportamento biológico do neurônio.
- A rede deve conter uma ou mais camadas de neurônios ocultas, ou intermediárias, que não participam da entrada ou saída da rede. Estes neurônios habilitam o aprendizado da rede em tarefas complexas extraindo progressivamente mais recursos significativos dos padrões de entrada.
- A rede expõe um alto grau de conectividade, determinado por sinapses da rede. A mudança na conectividade da rede requer a mudança na população das conexões sinápticas dos pesos.

A Figura 19 apresenta a arquitetura de uma RNA *MultiLayer Perceptron*.

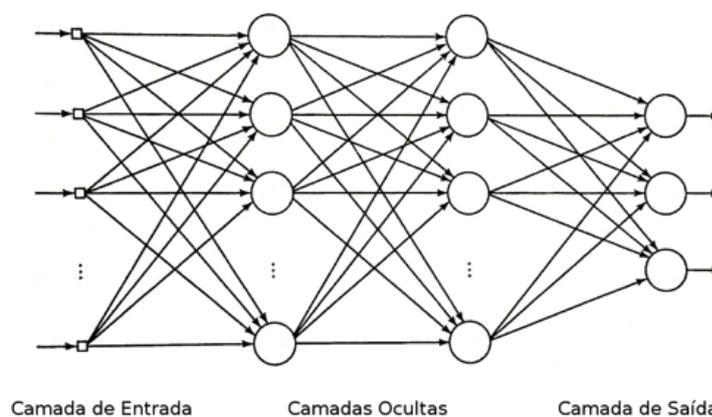


Figura 19 - Arquitetura de uma RNA *MultiLayer Perceptron*

A rede *MultiLayer Perceptron* pode ser treinada pelo padrão de aprendizagem por *back-propagation* cujo processo de aprendizado utiliza duas fases de propagação: *forward* e *backward* (Haykin, 2008). Este processo é resumido em cinco etapas:

- **Inicialização:** Inicia com uma configuração de rede preliminar definindo todos os pesos sinápticos e limiares da rede para números aleatórios que são distribuídos uniformemente.
- **Apresentação de exemplos para treinamento:** Apresenta uma época (iteração na qual se executa todo o conjunto de entradas para o treinamento) da rede para que cada exemplo no conjunto ordenado execute a sequência de cálculos de *forward* e *backward*, respectivamente.
- **Forward Computation:** Partindo de um vetor aplicado à camada de entrada da rede e um vetor de saídas desejáveis para ser comparado aos neurônios da camada de saída.

O cálculo do potencial de ativação e dos sinais de função da rede é realizado em cada camada da rede com fluxo no sentido da camada de entrada para a camada de saída. Nesta etapa, cada neurônio realiza a soma ponderada das sinapses, na qual cada estímulo é multiplicado pelo peso correspondente a entrada. O processo seguinte consiste em normalizar os dados a partir de uma função de saída de cada neurônio. O erro é calculado a partir do conjunto de saídas comparado ao vetor de saídas desejáveis logo, o erro é a diferença entre o valor desejado subtraído do valor de saída para cada neurônio da camada de saída.

- *Backward Computation*: Nesta fase, calcula-se o gradiente local da rede desta vez no caminho inverso iniciando a partir da camada de saída na qual o gradiente por sua vez atua como fator de ajuste dos pesos sinápticos da rede neural.
- *Iteração*: A iteração do cálculo apresenta a cada época um conjunto de parâmetros para estabilizar a rede através do erro quadrático médio (RMSE) sobre todo o conjunto de treinamento, este erro deve possuir um valor baixo para que a taxa de erro seja dada como aceitável.

2.2.3.1.2. *RBF*

Uma RNA *Radial Basis Function* (RBF) é caracterizada pelos seguintes aspectos:

- Utilização de modelos de regressão lineares e não-lineares com função de ativação de qualquer tipo de rede multicamada.
- Sempre apresenta uma única camada intermediária
- Os neurônios de saída são sempre lineares
- Os neurônios das camadas intermediárias utilizam apenas funções de base radial como função de ativação.

2.2.4. *Min-Max*

A técnica *Min-Max* tem como objetivo estimar a localização através da construção de áreas delimitadoras (conhecidas como *bounding box*) para cada nó âncora utilizando suas coordenadas e a distância entre o nó alvo e o nó âncora (Priwgharm & Chemtanomwong, 2011). Cada área delimitadora é criada a partir da estimativa da distância, somando e subtraindo às coordenadas para gerar os quatro pontos de um retângulo (Summers & Goulart,

2013). A localização do nó alvo é calculado a partir do centro de gravidade da área de interseção ou *intersected box*, conforme ilustrado na Figura 20.

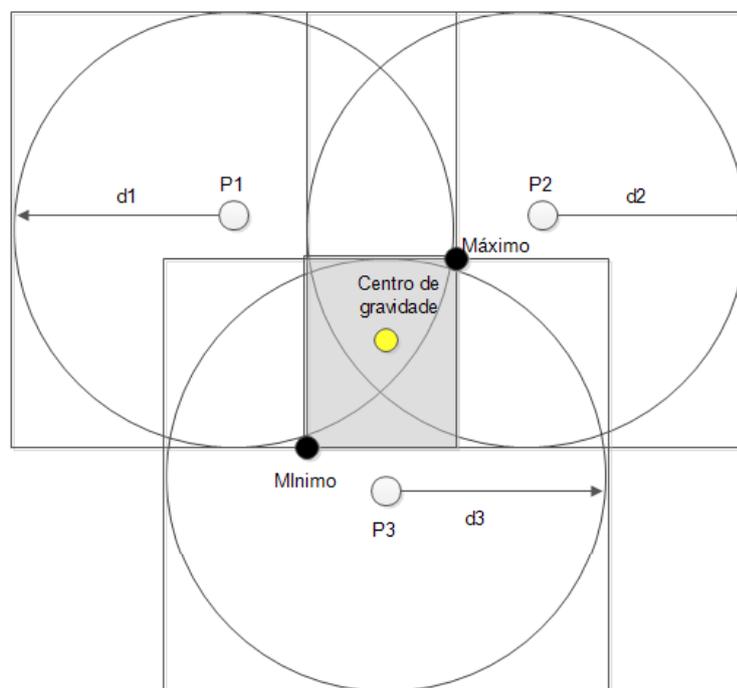


Figura 20 - Ilustração da técnica Min-Max

2.2.5. Técnicas de Regressão não Linear

Regressão não linear é um método estatístico que realiza uma análise observacional em que os dados são modelados por uma função de combinação não-linear de parâmetros em função de uma ou mais variáveis independentes (Cao, Zhu, Zhou, & Gao, 2008). A regressão não linear apresenta algumas vertentes, incluindo sua versão iterativa e os mínimos quadrados. As técnicas NLR, INLR, LS, RANSAC e ToM apresentadas a seguir são baseadas na técnica de Lateração. (Rice & Harle, 2005)

2.2.5.1. *Non-linear Regression* (NLR)

Modelos de regressão são modelos matemáticos que relacionam o comportamento de uma variável Y com outra X. Quando a função f que relaciona duas variáveis é do tipo $f(X) = a + bX$ temos o modelo de regressão simples (Pasolli, Notarnicola, & Bruzzone, 2010). A variável X é a variável independente da equação enquanto $Y = f(X)$ é a variável dependente das variações de X. O modelo de regressão é chamado de simples quando envolve uma relação causal entre duas variáveis. O modelo de regressão é não-linear quando envolve uma relação quadrática,

polinomial, algóritmica, exponencial ou qualquer outra forma não linear entre as variáveis X e Y (Cao, Zhu, Zhou, & Gao, 2008). Em se tratando de localização, a modelagem da distância entre os nós âncora e alvo utilizando a regressão não linear pode ser resultante do ajuste de um conjunto de medidas de entradas conforme equação (24).

$$d_i = \sqrt{(s_x - p_x)^2 + (s_y - p_y)^2 + (s_z - p_z)^2} \quad (24)$$

Onde:

s é o conjunto solução contendo os valores das posições geográficas

p é o parâmetro de ajuste para as respectivas coordenadas

s_x é a coordenada x desconhecida

s_y é a coordenada y desconhecida

s_z é a coordenada z desconhecida

p_x é o parâmetro de ajuste aplicado ao valor de s_x

p_y é o parâmetro de ajuste aplicado ao valor de s_y

p_z é o parâmetro de ajuste aplicado ao valor de s_z

2.2.5.2. Iterative Non-linear Regression (INLR)

Uma extensão do NLR é a sua forma iterativa de modelos para reduzir o tamanho dos dados de entrada com cada iteração. Após a formação de um modelo, a medição determina a divergência da estimativa, ou seja, a medida associada com o maior erro residual é descartada e o processo de modelagem começa novamente (Rice & Harle, 2005). A cada rejeição de um valor dentro da faixa, um novo modelo não-linear é calculado usando apenas os dados restantes. Esse processo se repete até que existam medidas suficientes para restringir totalmente o modelo (a falha) ou o valor do modelo se apresente abaixo de um limite nominal (um sucesso). Essencialmente, este algoritmo procura a maior quantidade de valores consistentes dentro do conjunto de medição, adotando a posição correspondente entre a estimativa de posição e o nível de concordância dentro do intervalo do erro esperado.

2.2.5.3. Least Squares (LS)

Linearizando o modelo de Regressão não linear, a fim de utilizar a regressão linear mais tradicional (ou mínimos quadrados), apresenta-se a solução por representação matricial que pode ser mais rápida do que calculado utilizando a análise de NLR semelhante ao realizado nas equações (4)-(12). Enquanto NLR considera efetivamente a intersecção das esferas

centradas em cada receptor, a linearização considera a intersecção de infinitos planos (Salgueiro, Sanguino, Rodrigues, & Hernandez, 2012). Cada par de esferas que se cruzam realizam inteiramente dentro de um plano para identificação de todas as possibilidades de linearização (Rice & Harle, 2005). O ponto que melhor representa a intersecção de todos estes planos é então encontrado pelo algoritmo de mínimos quadrados, o erro esperado pode ser derivado a partir de cálculo do erro residual de distância utilizando as medições iniciais (não linearizadas), e a posição estimada, ou com base na magnitude do máximo residual.

2.2.5.4. *Random Sample Consensus (RANSAC)*

A técnica RANSAC utiliza a triangulação para obter uma posição de um conjunto de trios selecionados aleatoriamente dentro da base de amostras dos dados. O restante do conjunto de dados é, então, dividido em dados de suporte e sem suporte com base no erro esperado de cada leitura (Xu & Lu, 2012).

Se o erro apresentado for baixo de forma que seja considerado adequado, então o algoritmo retorna a posição estimada. Caso contrário, outro trio é selecionado aleatoriamente e o processo é repetido até que um número pré-determinado de iterações tenha decorrido. O erro máximo esperado é atribuído a partir de uma leitura da precisão do algoritmo (Kang, Gao, & Tang, 2011).

2.2.5.5. *Trilaterate on Minima (ToM)*

Sistemas de localização de poucos recursos podem exigir algoritmos muito mais simples para a estimativa da posição do que os mencionados acima. O algoritmo ToM produz uma posição escolhendo as três leituras mais recentes a partir do conjunto de amostras. Esta heurística espera eliminar sinais refletidos, assumindo que eles tomam um caminho mais longo para a direção correta do sinal (Van Kleef, Bergmans, Kester, & Groen, 2006). Desta forma, os dados ruins não podem ser distinguidos dos dados bons, o algoritmo usa uma heurística que elimina os sinais refletidos para selecionar um conjunto de pontos de dados a partir dos dados disponíveis (Rice & Harle, 2005).

2.2.6. *Sum-dist*

A técnica *Sum-dist* inicia a partir do envio de mensagens cujo conteúdo inclui a sua identidade do transmissor, posição, e um comprimento de caminho inicializado com 0. Ao receber uma

mensagem, o nó alvo adiciona o intervalo de medição para o comprimento do caminho e encaminha (transmite) a mensagem conforme Figura 21, se o limite de envios permitir fazê-lo (Brito, Liu, & Garcia, 2011). Outra limitação é que, quando o nó recebe a informação sobre algum nó âncora em particular, só é permitido encaminhar a mensagem, se o comprimento do percurso da mensagem corrente é menor do que a anterior. Ao final todos os nós armazenarão a posição e comprimento mínimo do caminho para alcançar os nós âncoras (Langendoen & Reijers, 2003).

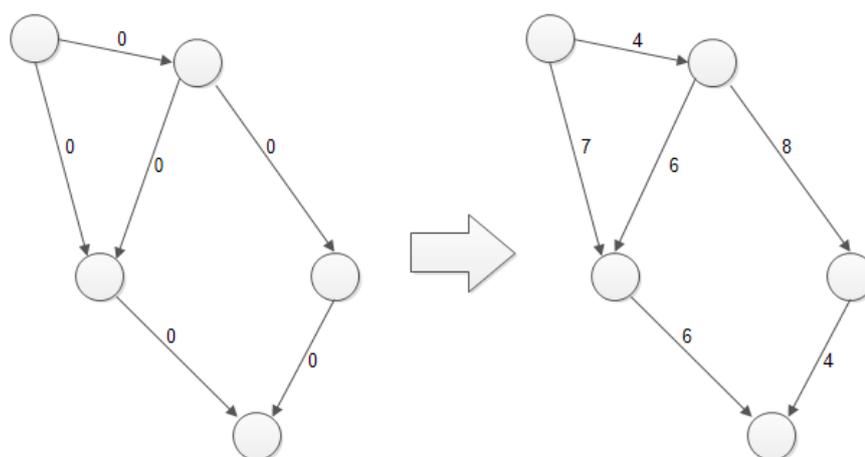


Figura 21 - Identificação das distâncias no método *Sum-dist*

2.2.7. *DV-hop*

DV-hop consiste em uma simplificação da técnica *Sum-dist*, que trabalha com a quantidade de saltos, e não com o peso do mesmo, sendo um algoritmo dividido em fases, a primeira fase, permite a visualização da posição e número mínimo de saltos para os nós âncoras dentro do limite de alcance (Langendoen & Reijers, 2003). Posteriormente, a calibração necessária para converter contagens de saltos em distâncias configuradas com valores médios, considerando que os sensores estão dispostos igualmente uns dos outros conforme Figura 22. A técnica *DV-hop* deve ser usada somente em casos de topologia em grade com distâncias equivalentes entre nós adjacentes (YingJie, Kai, Shenfang, & Hao, 2012).

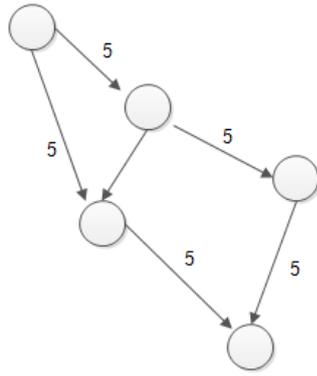


Figura 22 - Identificação das distâncias no método DV-hop

3. Trabalhos Correlatos

Esta seção apresenta algumas pesquisas sobre avaliações de desempenho de técnicas de localização em RSSF, com destaque para as comparações entre as técnicas de localização.

Conti, Willemsene Crispo (2013) realizam o levantamento do estado da arte de criptografia e localização aplicada à localização em redes de sensores sem fio para prover segurança aos nós alvo, tratando-se de objetos que necessitam de proteção. No artigo, é citado o exemplo da necessidade de proteger pandas (espécie ameaçada de extinção) em parques nacionais, tomando conhecimento da sua localização geográfica. Entretanto, para que caçadores não detenham conhecimento sobre a posição onde se encontra algum urso panda, utilizam criptografia dificultando o trabalho de suas ameaças potenciais. Desta forma, o monitoramento e rastreamento dos ursos pandas são realizados apenas pela equipe de proteção. O artigo descreve o uso da técnica AOA em substituição ao RSSI sem estabelecer um algoritmo de localização, também não realiza testes em ambiente real ou simulado focando apenas no aspecto teórico da localização.

Tian e Xu (2012) apresentam um modelo de *Multi-Layered Perceptron Neural Network* (MLPNN) para estimativa da localização. A RNA proposta é simulada em um ambiente de 3x3 m², marcados no espaçamento da grade de 0,3 metros, com quatro nós âncoras localizados nos vértices de um quadrado. Neste trabalho, os autores utilizaram o rádio CC2431 como referência de hardware para possibilitar a simulação.

Os resultados da simulação mostram que o algoritmo pode reduzir o erro causado sob a propagação de trajetória múltipla, sendo que a precisão da localização permite reaplicação em escalas de diferentes tamanhos. Os autores consideram que o algoritmo apresenta rápida convergência, podendo também ser concebido para auto-aprendizagem da RNA. Entretanto, existe um alto custo de retreinamento ou reestruturação da rede em caso da necessidade da mudança de parâmetros da MLPNN. O trabalho não apresenta comparação com outras técnicas ou outras RNAs, além de utilizar apenas simulações nos testes.

Rahman, Youngil e Ki-Doo (2009) propõem um algoritmo de RNA para estimativa da localização de RSSFs utilizando *Multi-Layer Perceptron* (MLP). No algoritmo proposto, a rede é formada por meio de nós de referência estacionários instalados em grade, cuja localização é conhecida. Os valores do RSSI são coletados a partir de todos os pontos de acesso da RSSF e suas respectivas localizações, sendo estas utilizadas para treinar a rede. Os

resultados das simulações mostram que a precisão da localização depende muito da densidade de alvo de rede e da quantidade de nós âncoras. O cenário é apresentado na Figura 23.

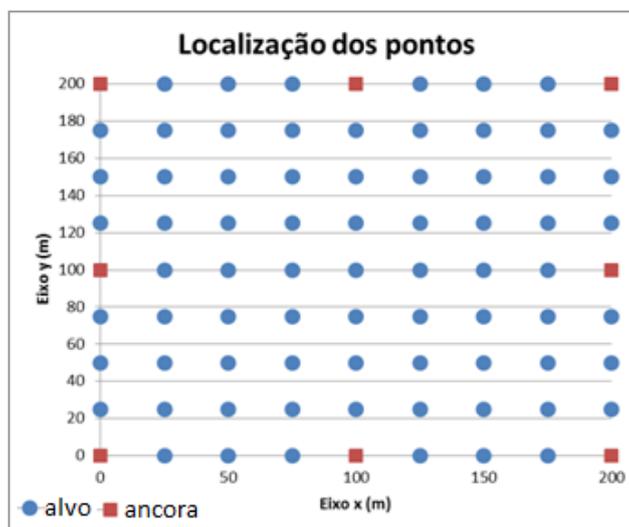


Figura 23 - Localização dos pontos em escala de 200m.

A rede consiste em oito nós âncoras e um conjunto de nós alvo para estimativa da localização em uma área quadrada de $200 \times 200 \text{ m}^2$. A simulação tomou como princípio que todos os nós sensores estão dentro do intervalo de leitura de todos os nós âncoras. A frequência de operação de rede utiliza a banda de 2,4 GHz utilizando o protocolo 802.15.4.

Simulações mostram que o *Root Mean Square Error* (RMSE) da distância é aumentado com a diminuição da densidade dos sensores. A partir desta experiência, os autores presumiram que a precisão da localização pode ser aumentada através do aumento escalar da área na qual estarão dispostos os nós alvos. O trabalho é restrito a simulação e também não compara a rede neural com outras modalidades de redes neurais nem com técnicas clássicas como a Lateração, KNN, Min-Max ou Filtro de *Kalman*.

Langendoen e Reijers (2003) apresentam o problema de determinar os locais dos nós em redes de sensores *ad-hoc* comparando três algoritmos de localização distribuídos: *Sum-dist*, *N-hop* e *DV-hop*.

Os autores destacam a principal desvantagem do *Sum-dist* é que os erros se acumulam conforme a propagação de múltiplos saltos. Este erro acumulado se torna significativo para grandes redes com poucos nós âncoras (em caminhos longos) e/ou utilizando *hardwares* com menor poder computacional. Uma desvantagem do *DV-hop* apontada pelos autores é a sua propensão a falhas para topologias de rede altamente irregulares, onde a variância em

distâncias reais de saltos seja muito grande. O método *DV-hop*, demonstrou estabilidade e previsibilidade, uma vez que não usa medidas de alcance, apresentando um erro relativo de 5% no experimento realizado pelos autores no cenário simulado.

Os autores utilizam também a distância euclidiana, cuja simulação descreve a capacidade de determinar as distâncias exatas dos nós âncoras, mas somente na ausência de erros de intervalo e em redes altamente conectadas. Na ausência destas condições, o desempenho do algoritmo decai rapidamente.

A conclusão dos autores é que entre os algoritmos testados, não há algum de melhor desempenho, cada algoritmo é cabível conforme as condições estabelecidas na simulação: erros alcance, conectividade, quantidade de nós âncoras, entre outros. O trabalho foi realizado apenas com simulações, não havendo implementação em ambientes reais.

Zheng e Dehghani (2012) apresentam um algoritmo de localização *free-range* baseado em Rede Neural conhecido como *Location Neural Network Ensembles* (LNNE). A localização de um nó sensor é estimada pelo algoritmo LNNE exclusivamente com base nas informações de conectividade da RSSF. Através de simulação, o desempenho do LNNE é comparado com três outros algoritmos distribuídos de localização: *Centroid*, *DV-Hop* e *LSNN* (*Localization on Signal Neural Network*).

Segundo os autores, os erros de localização dos quatro algoritmos são reduzidos com o aumento quantitativo de nós âncoras. O LNNE utilizado supera outros três algoritmos em todos os casos apresentando melhor precisão de localização em até 20,7%. O trabalho restringe-se a um cenário simples controlado por simulação, mas não executa a validação dos aspectos teóricos em ambientes reais.

Maheshwari e Kemp (2009) compararam três métodos de localização: *Optimal Multilateration* (OML), *Sub-optimal Blind Trilateration* (SBT) e *Geometric Dilution of Precision* (GDOP). O trabalho fornece a comparação (*benchmark*) da precisão com base no erro da localização. No referido trabalho, são comparadas apenas técnicas variantes da Lateração e não utilizam de técnicas de outra natureza, além disso, a abordagem do trabalho usa apenas simulação sem a realização de qualquer experiência real.

Villas, Guidoni e Ueyama (2013) abordam o problema de localização 3D em RSSF utilizando um Veículo Aéreo Não Tripulado (VANT). O VANT é equipado com GPS e voa sobre a área de monitoramento para transmitir a sua posição geográfica. Assim, os nós sensores são capazes de calcular a sua posição geográfica mesmo que não estejam equipados com um receptor GPS. O trabalho mostra resultados obtidos em que o uso de um VANT

apresenta um erro de aproximadamente 15% no cálculo da localização geográfica utilizando o algoritmo RPE (*Recursive Position Estimation*) (Albowicz, Chen, & Zhang, 2001). O trabalho restringiu-se a simulação sem apresentar resultados práticos em nível de testes em ambientes reais.

Tsai, Lau e Huang (2012) implantaram em um ambiente real *indoor* um sistema de localização utilizando o KNN na implementação do sistema de localização no *Taipei World Trade Center* (TWTC), tomando como pontos fundamentais: o modelo de comunicação, transmissão de dados, tempo de vida da rede, backup e clusterização. O ambiente de teste consiste em um andar completo, envolvendo todas as salas, desta forma, o modelo levou em consideração os obstáculos decorrentes deste local, tais como: paredes, mesas, computadores, armários, portas, pessoas, entre outros. O estudo focava na dinâmica no ambiente físico (movimento das pessoas, abrir e fechar de portas, movimentação de cadeiras, etc.) e no impacto resultante na transmissão via rádio nas estimativas da localização, ou seja, a influência da rotina dos funcionários e sua interação com os objetos no local de análise. Embora o trabalho apresente a implementação em ambiente real *indoor* e com obstáculos como paredes e móveis, o mesmo não deixa claro o motivo da seleção do KNN como método de localização.

Priwgharm e Chemtanomwong (2011) realizaram um estudo sobre técnicas de localização em RSSF para um ambiente *indoor* comparando duas categorias de técnicas de localização: técnicas *range based* (Lateração e *Min-Max*) e técnicas baseadas em *fingerprinting* (NN e KNN) em um único ambiente experimental real. Este estudo utiliza o RSSI adquirido pela mensagem de outros nós para testar os algoritmos de localização, para isto, fizeram uso de módulos sensoriais ZigBee.

Inicialmente os autores comparam as técnicas *Min-Max* e Lateração, utilizando vinte pontos de amostras na qual em apenas duas amostras o método *Min-Max* apresentou menor erro de localização, um caso de igualdade e dezessete amostras indicando a Lateração como técnica com menor erro entre as duas.

Posteriormente os autores comparam a influência da quantidade de nós na técnica KNN, considerando a técnica NN como um de seus casos particulares, agindo como 1-NN, variando o valor de K em 1, 3, 4, e 5 nós de referência.

Nesta comparação é visto que o erro tende a diminuir conforme a adição de nós âncoras. Entretanto, o erro de localização para 4 e 5 nós âncoras apresentou quase os mesmos resultados, inferindo desta forma que quatro nós é uma quantidade satisfatória para

estimativa. Por fim, todas as técnicas são confrontadas e a Lateração se apresenta como a técnica com menor erro seguida do KNN (para 5, 4 e 3 nós respectivamente), em seguida a técnica *Min-Max* e por ultimo a técnica NN (ou KNN com $K=1$).

Rice e Harle (2005) realizaram um experimento em ambiente real *indoor* em uma área de 550 m², utilizando rádios *Ultra-Wide Band* (UWB) (IEEE 802.15.4a) em sua camada física para transmitir e receber sinais. Para este experimento, os autores fizeram uso de cinco algoritmos baseados na técnica Lateração para estimativa da localização: algoritmo de Regressão Não-Linear (NLR – *Non-Linear Regression*) (Pasolli, Notarnicola, & Bruzzone, 2010), Regressão Iterativa Não-Linear (INLR – *Iterative Non-Linear Regression*) (Jianxiao, Hongli, Yarong, & Zhiwen, 2009), Mínimos Quadrados (LS – *LeastSquares*) (Rhode & Gauterin, 2013), *RandomSample Consensus* (RANSAC) (Xu & Lu, 2012) e *Trilaterate on Minima* (Tom) (Rice & Harle, 2005).

O algoritmo INLR reduziu o risco de erro do conjunto de amostras, já que cada redução produz um novo conjunto de medidas que são mais consistentes. O algoritmo NLR produz uma posição degradada e erro previsto comparado ao INLR. Conforme os autores, para o posicionamento preciso entre as técnicas, o elemento repetitivo mostrou-se necessário e desejável, visto que apresenta melhores resultados na avaliação de ajuste a partir de todos os dados disponíveis.

Shareef e Musavi (2008) realizam um estudo comparativo em um ambiente real confrontando várias configurações de RNAs para estimativa da localização: *Radial Basis Function* (RBF) (Liu, 2009), *Multi-Layer Perceptron* (MLP) (Zabidi, Mansor, Lee, & Fadzal, 2012), *Recurrent Neural Networks* (RNN) (Wang, Zhang, Xu, & Peng, 2009), *Position-Velocity* (PV) (Manor & Rimon, 2012), *Position Velocity Acceleration* (PVA) (Shareef, Zhu, & Musavi, 2008) e *Reduced Radial Basis Function* (RRBF) (Kuo, Lain, & Huang, 2006). Estes métodos avaliaram os erros de localização em centímetros no interior de um ambiente de 3x3 metros.

No experimento, a rede neural RBF tem o melhor desempenho de localização de acordo com o erro médio de distância por estimativa se comparado às demais configurações realizadas para teste. Posterior ao RBF, encontram-se respectivamente MLP, RNN, PV e PVA aplicados sob o modelo do Filtro de *Kalman*, e em seguida, a rede neural RRBF. Os filtros mostram relativamente erros maiores do que as redes neurais nos limites do experimento, devido ao fato de que o filtro de *Kalman* atua iterativamente trabalhando sobre a posição localizada. Nas áreas periféricas, onde o objeto pode movimentar-se bruscamente, o filtro de

Kalman realiza várias iterações antes de obter a localização do objeto, resultando em estimativas insatisfatórias.

Outra contribuição dos autores revela que as redes neurais com a exceção de RRBFF possuem maior percentual de erros inferiores a 10 cm. O filtro de *Kalman* estendido apresentou menor percentual de erros. Comparando o RBF com a rede neural MLP, a rede MLP tem uma menor percentagem de erros, mas estes erros apresentam maior magnitude. Outro dado importante é que a rede RRBFF também é o único método que tem um erro maior do que 40 cm por amostra, com um pico de cerca de 90 cm (Shareef, Zhu, & Musavi, 2008).

O trabalho não compara o desempenho de RNAs com os métodos comuns de localização aplicados em ambientes reais. Os resultados não mostram uma referência entre as soluções inteligentes e os métodos clássicos.

3.1.Comparação dos trabalhos relacionados

De acordo com a análise dos trabalhos relacionados, muitos dos estudos envolvem a utilização de Lateração ou alguma das suas variantes, (Priwgharm & Chemtanomwong, 2011) (Rice & Harle, 2005) (Langendoen & Reijers, 2003) (Maheshwari & Kemp, 2009), enquanto que outros estudos (Shareef, Zhu, & Musavi, 2008) (Tian & Xu, 2012) (Rahman, Youngil, & Ki-Doo, 2009) (Zheng & Dehghani, 2012) comparam diferentes topologias de RNAs. Uma abordagem experimental é apresentada em (Priwgharm & Chemtanomwong, 2011), na qual a Lateração mostra o melhor resultado em comparação com três outras técnicas (KNN, NN - Min e Max). Com base nos resultados apresentados nas referências anteriores, o presente trabalho realiza uma avaliação de desempenho utilizando os dois melhores métodos apresentados em (Priwgharm & Chemtanomwong, 2011) - Lateração e KNN - para comparar com uma RNA.

A maioria dos trabalhos atuais, mesmo fora deste levantamento bibliográfico, se restringe ao uso de simulação, e trabalhos experimentais são mais escassos, a principal contribuição deste trabalho consiste em estabelecer uma comparação prática entre algumas técnicas utilizadas para localização de redes de sensores em ambientes reais. O Quadro 4 realiza a compilação entre os trabalhos, classificando-os em simulados ou implementados em ambientes reais.

Quadro 4 - Comparativo entre trabalhos relacionados

Autores	Tipo de Trabalho	Teste Indoor	Teste Outdoor	hardware	Tamanho do ambiente	Comparações
Conti, Willemsen e Crispo	Teórico	-	-	-	-	-
Rahman e Ki-Doo	Simulado	-	-	Não informado	200 x 200 m ²	-
Langendoen e Reijers	Simulado	-	-	Não informado	6 x 6 x 5 m ³	Sum-dist, DV-hop, N-hop
Zheng e Dehghani	Simulado	-	-	Não informado	50 x 50 m ²	LNNE, Centroid, DV-hop, LSNN
Maheshwari e Kemp	Simulado	-	-	Não informado	200 x 200 m ² e 400 x 400 m ²	OML, SBT, GDOP
Tian e Xu	Simulado	-	-	CC2431	3 x 3 m ²	-
Villas, Guidoni e Ueyama	Simulado	-	-	Não informado	50 x 50 x 50 m ³	ZigBee/IEEE 802.15.4
Priwgharm e Chemtanomwong	implementado	x	-	ZigBee	3 x 3 m ²	Lateração, Min-Max, KNN, NN
Rice e Harle	implementado	x	-	UWB	550 m ²	NLR, INLR, LS, RANSAC, ToM
Shareef e Musavi	implementado	x	-	Não informado	3 x 3 m ²	RBF, MLP, RNN, PV, PVA, RRBF
Tsai, Lau e Huang	implementado	x	-	CC2420	1390 m ²	2.4 GHZ RF Transceiver

4. Configurações dos Testes

Conforme levantado nos trabalhos relacionados, 63% dos trabalhos de localização de redes de sensores sem fio restringem-se a simulação ou teoria, e 36% apresentam resultados práticos. Embora seja um recurso limitado, simular é interessante para estudar previamente o comportamento esperado em um ambiente real. A modelagem do problema e do meio pode, ou não, refletir fielmente as características de um ambiente real. A experiência prática obtida neste trabalho revelou um conjunto de problemas que em geral não são encontrados em simulações, como:

- Consumo da bateria: O funcionamento de cada nó se manterá o mesmo independente do consumo da bateria, utilizando sua carga até o fim e, não suportando mais, o nó será dado como perdido. Para os testes realizados, os módulos utilizavam duas pilhas comuns alcalinas como fonte de energia.
- Perda de um nó: Sem o imediato reconhecimento da perda de um nó, o teste pode ser completamente ou parcialmente comprometido, os primeiros testes realizados resultaram em alguns descartes de material por conta da falta de gerenciamento de perda de nós.
- Falhas e Reteste: Quando se trabalha em ambientes reais, pode haver situações nas quais o trabalho de um dia inteiro possa ser descartado, fator este que pode estar associado a erros de programação não detectados em ambiente de desenvolvimento, ou fatores ambientais.
- Imprecisão na medida: É plenamente possível ocorrer pequenos erros na demarcação do local, principalmente quando não é um local já demarcado tal como lajotas e azulejos que possuem um tamanho padrão, blocos ou espaços simétricos, desta forma, tomando uso de uma fita métrica é possível ocorrer leves erros de precisão na medida até mesmo pelo fator humano.
- Eventos internos ao experimento: A presença dos responsáveis pelos testes durante a aquisição de dados pode resultar na interferência do sinal. Além disto, nos ambientes reais tomados para teste pode ocorrer tráfego de pessoas e animais passando pelo centro do evento.

- Desnível no solo: Nem toda superfície é perfeita, principalmente em ambientes *outdoor*, por este fato, é necessário haver cuidado para manter os nós devidamente nivelados com pequenos itens que gerem altura suficiente para o nivelamento.
- Limitação física dos cabos e aparelhos: O aplicativo do nó alvo atua dentro do software do coordenador da rede. Para economizar o consumo de energia e controlar melhor o teste, este nó é ligado a um computador (notebook devido a sua mobilidade) com uso de um cabo USB. Para uma escala de $10 \times 10\text{m}^2$, o centro do evento fica a 5 metros da borda dos limites do teste, portanto, seriam necessários 5 extensões USB interconectadas para que o computador não fosse colocado no centro do evento, porém o uso de duas ou mais extensões interconectadas resulta no mau funcionamento ou funcionamento duvidoso do repasse dos dados, desta forma, seria mais confiável manter o computador no centro do evento quando necessário e todas as coletas seriam realizadas utilizando uma única extensão.

Limite de aquisição de dados: Quanto mais amostras por pontos, maior o tempo gasto no mesmo local, logo é necessário planejar a quantidade máxima de amostras por ponto de forma que haja tempo para coletar em todos os pontos desejados.

Neste trabalho, todos os itens acima descritos foram levados em consideração para que a coleta de dados fosse o mais confiável possível, havendo cuidados com a precisão, descarte de amostras com influências externas e internas, além de boas condições climáticas para realização dos testes em ambientes *outdoor*, já que este não é um problema considerável em ambientes *indoor*. Embora outros testes tenham sido realizados, são apresentados aqui os dois que contemplaram os requisitos de completude (coletando amostras em vários pontos) e continuidade (não houve fatores que impedissem o andamento dos testes tais como chuva, imprevistos, etc). São apresentados dois ambientes, o primeiro foi realizado em um ambiente *indoor* em um ginásio, e o segundo em um ambiente *outdoor* em um espaço aberto de um condomínio.

O primeiro ambiente foi conduzido no ambiente interno de $12 \times 12\text{m}^2$, conforme Figura 24, enquanto o segundo teste foi realizado em uma área de $20 \times 22\text{m}^2$ conforme Figura 25. Os nós âncora (pontos vermelhos) são posicionados nas bordas do cenário, localizados em (0, 0), (0, 12), (12, 0) e (12, 12), e os nós alvo (pontos azuis) são posicionados na área interna da grade.

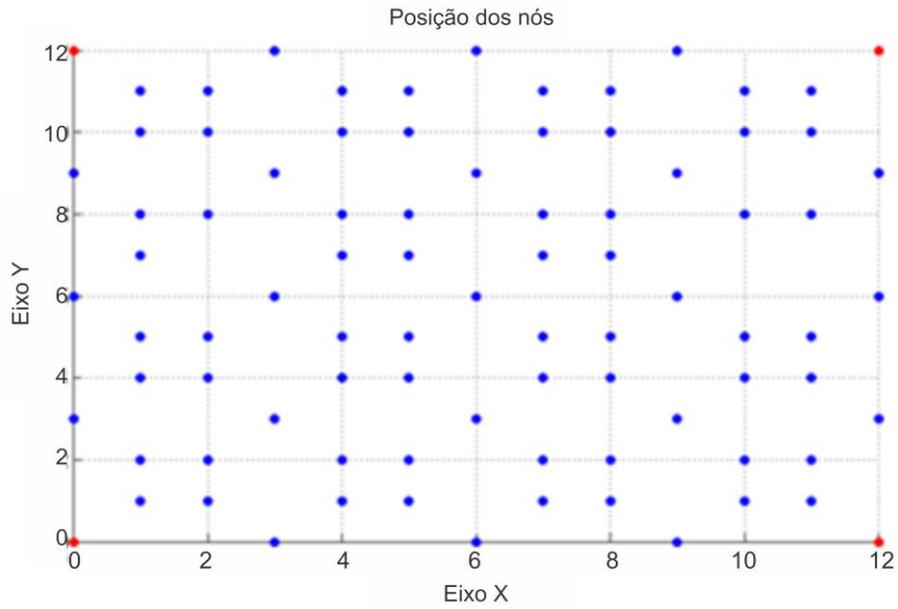


Figura 24 - Pontos de coleta do RSSI do ambiente *indoor*

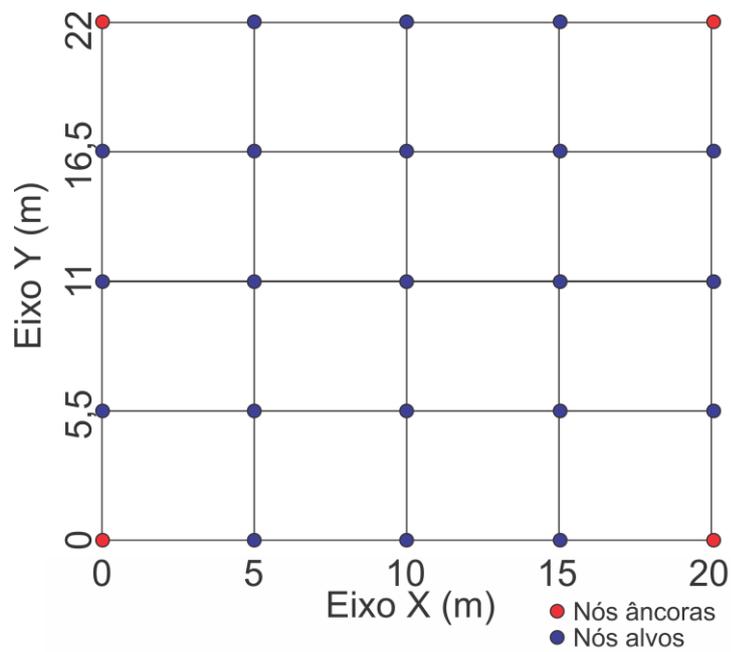


Figura 25 - Pontos de coleta do RSSI do ambiente *outdoor*

Semelhante a Figura 25, os nós âncora (pontos vermelhos) são posicionados nas bordas do cenário, localizados em $(0, 0)$, $(0, 22)$, $(20, 0)$ e $(20, 22)$, e os nós alvo (pontos azuis) são posicionados na área interna da grade. O anexo B apresenta imagens dos locais de teste.

4.1. Metodologia

O trabalho constitui nas etapas de aquisição de dados e estimativa da localização para as técnicas Lateração, KNN e RNA. Inicialmente os nós âncoras são posicionados na área de teste para enviar ao nó alvo uma mensagem a cada ciclo de 25 milissegundos. A cada ciclo, o nó alvo recolherá quatro amostras de RSSI extraídas referente a cada mensagem dos nós âncoras registrando a 4-tupla no arquivo de registros de coleta. O diagrama de aquisição de dados é apresentado na Figura 26.

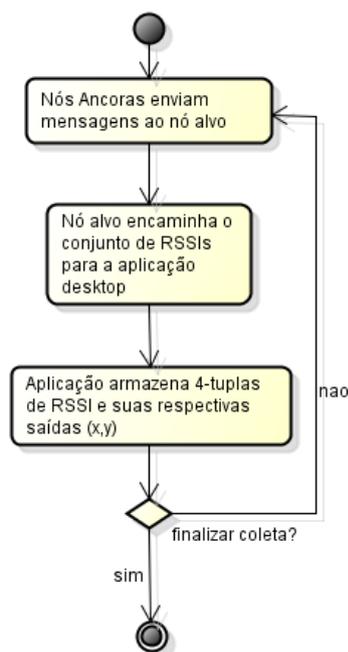


Figura 26 - Diagrama referente a coleta de dados

O tempo de coleta para cada ponto da área de testes é de aproximadamente 60 segundos, de forma que, se um nó âncora deixa de se comunicar, o teste é renovado e os dados antigos descartados para a localização na qual a falha ocorreu. Os dados foram registrados em arquivo texto seguindo padrões para tratar os dados com uso de programas satélites, que desempenharam o papel de filtrar e tratar os dados.

Após o tratamento realizado, os dados foram submetidos aos algoritmos de localização de Lateração e KNN que apresentaram suas respectivas estimativas. A RNA utilizou deste mesmo conjunto de dados coletados em ambiente *indoor* para realizar as etapas de treinamento e teste permutando métodos de treino, funções de ativação, quantidade de neurônios e de camadas ocultas. Para o experimento em ambiente *outdoor*, a mesma RNA foi

utilizada sem repetir as fases de treinamento e teste para que a mesma rede utilizada em ambientes *indoor* pudesse ser comparada para os dois tipos de ambientes.

Para ambos ambientes, os arquivos de teste utilizados na RNA foram os mesmos arquivos utilizados na estimativa por Lateração e KNN para estabelecer a comparação entre as técnicas.

4.1.1. Lateração

Para realizar a estimativa por Lateração foi necessário inicialmente estimar os valores do *path loss* do ambiente conforme descrito na equação (10) da sessão 2.2.1. Posteriormente foram utilizados um nó âncora e um nó alvo distantes a um metro para coletar os valores de RSSI correspondentes a variável A da equação (9) da sessão 2.2.1. A partir do *path loss*, a variável A e o RSSI obtido no momento da coleta, foram calculadas as distâncias entre cada nó âncora e o nó alvo. A partir do conjunto de distâncias o cálculo matricial apresentado na sessão 2.2.1 foi implementado conforme descrito no Algoritmo 1.

Algoritmo 1 – Algoritmo de Lateração

```

1   Lateracao(x: conjunto de coordenadas x dos nós âncoras,
2           y: conjunto de coordenadas y dos nós âncoras
3           d: conjunto de distâncias entre os nós âncoras e o nó alvo)
4   Variaveis: X, B e C matrizes
5   Inicio
6   Para i de 1 ate n-1 passo 1
7        $B_i = [2*(x_i-x_n) \quad 2*(y_i-y_n)]$ ;
8        $C_i = [x_i^2-x_n^2+y_i^2-y_n^2-d_i^2+d_n^2]$ 
9   Fim para
10   $X = (B^T \cdot B)^{-1} \cdot B^T \cdot C$ 
11  Fim
```

Os valores de x e y serão armazenados na matriz X da estimativa da Lateração.

4.1.2. KNN

A técnica KNN citada na sessão 2.2.2 define métricas para estimar a distância entre dois pontos, sendo a distância euclidiana a mais popular entre elas. Conforme as equações (8) e (9) da sessão 2.2.1, o RSSI é inversamente proporcional a distância, sendo assim, quanto maior o valor da potência do sinal, mais próximo o emissor (nó âncora) e receptor (nó alvo) se encontram. Desta forma, o cálculo das distâncias euclidiana, *Mahalanobis*, *Minkowsky* ou *Hamming* é desnecessário, utilizando diretamente os maiores valores de RSSI como vizinhos mais próximos.

A estimativa das coordenadas (x,y) é realizada a partir do calculo da média ponderada do RSSI com as coordenadas do nó de destino conforme (25).

$$\begin{cases} x = \frac{\sum_{i=1}^{i \leq k} (RSSI_i * x_i)}{\sum_{i=1}^{i \leq k} RSSI_i} \\ y = \frac{\sum_{i=1}^{i \leq k} (RSSI_i * y_i)}{\sum_{i=1}^{i \leq k} RSSI_i} \end{cases} \quad (25)$$

Onde:

x é o valor da coordenada x do nó alvo

y é o valor da coordenada y do nó alvo

$RSSI$ é a potencia do sinal adquirido

k é a quantidade de nós vizinhos mais próximos

x_i é o valor da coordenada x do nó âncora i

y_i é o valor da coordenada y do nó âncora i

4.1.3. RNA

A aplicação de RNA em relação ao processo de localização RSSF é realizada através da aquisição de dados de rede, treinamento da rede e avaliação de resultados. As entradas da rede correspondem aos RSSIs capturados. O nó de alvo calcula o RSSI de cada mensagem e passa os dados para o aplicativo de desktop que, por sua vez, armazena-os para utilização no treinamento da rede. Este treino é precedido pela escolha do método de treinamento, funções de ativação, número de camadas escondidas e a quantidade de neurônios por camadas. O fluxo de trabalho é mostrado na Figura 27.

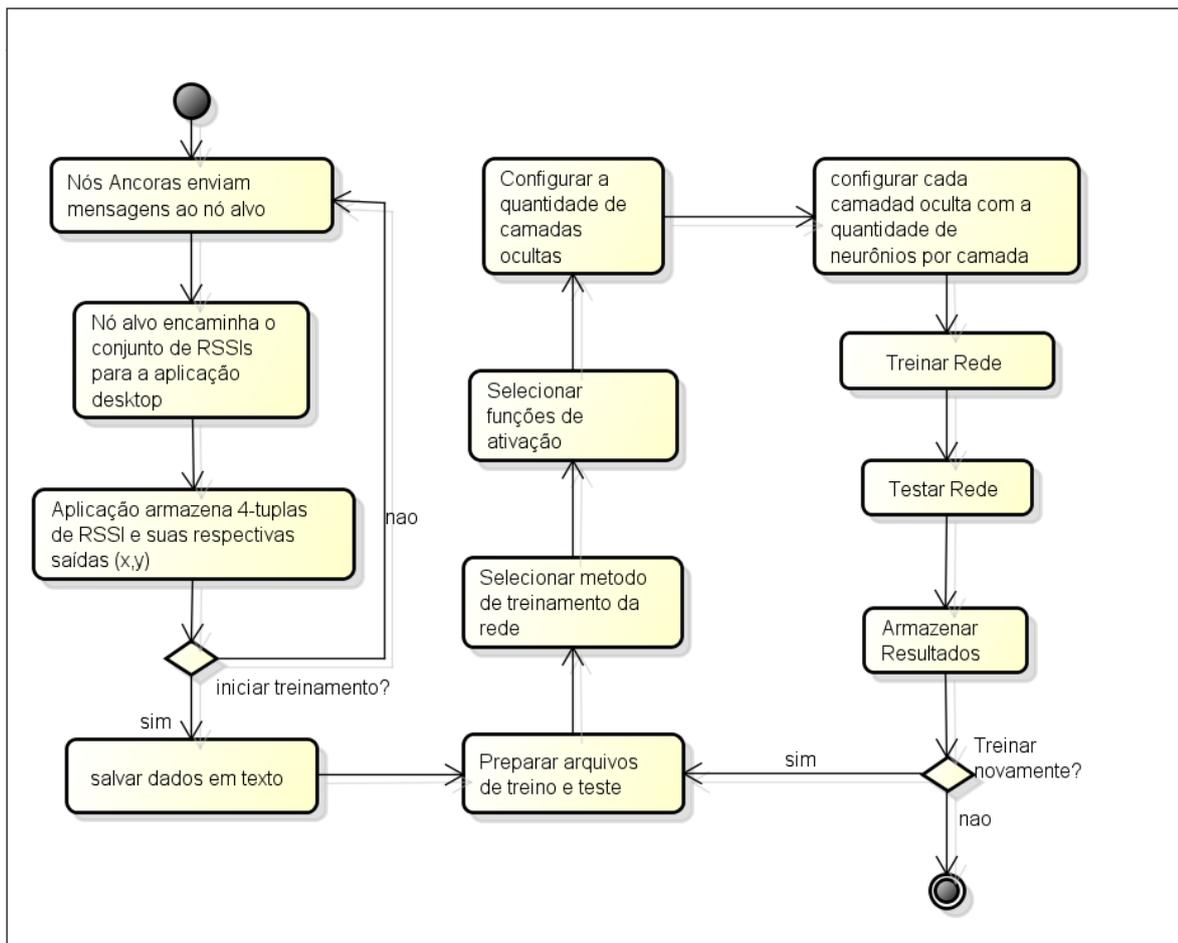


Figura 27 - Fluxo de trabalho da RNA

A aplicação da rede neural utilizada para a localização de um nó na RSSF é realizada através da aquisição dos RSSI's obtida das mensagens enviadas a partir de cada nó. Posteriormente, esses dados são usados como entrada para treinar e validar a rede.

Para cada ponto de localização, a média e o desvio padrão são calculados para identificar 10% das piores amostras. Com isso, as amostras são filtradas para melhor precisão no treino da RNA. Para treinar a RNA, os pontos coletados (x, y) são normalizados para manter esses valores de saída entre 0 e 1.

A configuração da RNA foi definida após uma série de sucessivos treinamentos e testes permutando o número de camadas ocultas, número de neurônios em cada camada, função de ativação para cada camada ou neurônio e algoritmo de treino. A arquitetura usada na RNA é uma rede *feed-forward* ilustrada na Figura 28 com cinco camadas: a camada de entrada com quatro neurônios (valores RSSI de cada nó âncora), três camadas escondidas com

10 neurônios em cada e a camada de saída com dois neurônios (x e y). A taxa melhor de aprendizado utilizado é de 0,7. Os parâmetros de RNA encontram-se resumidos no Quadro 5.

Quadro 5 - Configuração da RNA

Treinamento	<i>SARPROP</i>
Função de ativação da camada de saída	<i>Symmetric Gaussian</i>
Função de ativação das camadas ocultas	<i>Symmetric Cosine</i>
Função do erro de treinamento	<i>Linear</i>
Função de parada de treinamento	<i>MSE</i>
Camada de entrada	4neurônios + 1 bias
Camadas Ocultas	3 camadas com 10 neurônios + 1 bias para cada
Camada de saída	2 neurônios
Total de neurônios	40

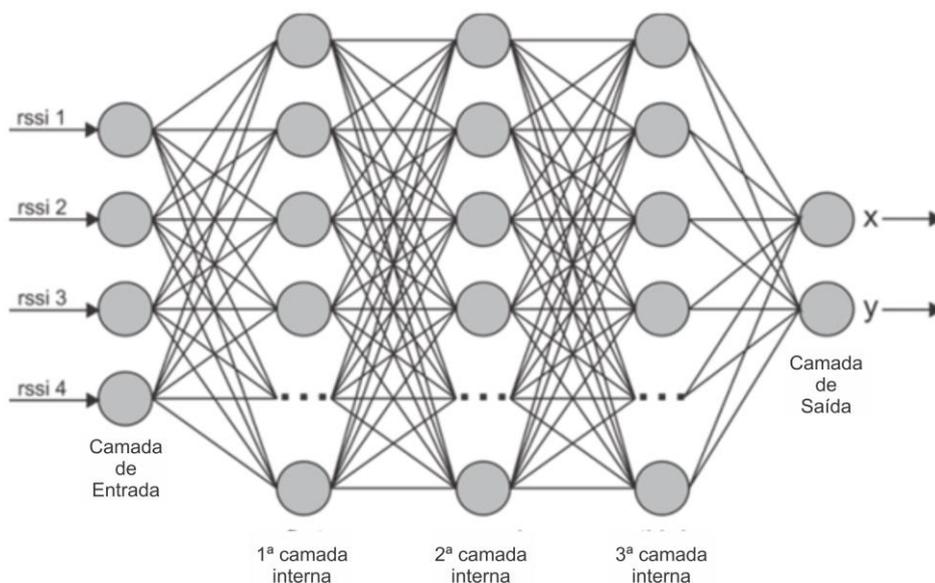


Figura 28 - Configuração da RNA

A Figura 28 apresenta a RNA utilizada como técnica de localização na qual o conjunto de entradas são os RSSIs obtidos pelos nós âncoras, três camadas internas, ou ocultas, e a camada de saída contendo dois neurônios referentes às coordenadas (x,y) . A configuração apresentada no Quadro 5 apresentou melhor precisão na estimativa da localização durante o processo de sucessivos treinos da RNA.

4.2.Arquitetura de Hardware e Software

Para realizar os experimentos, houve um conjunto de requisitos para o bom funcionamento da arquitetura. Utilizando recursos distribuídos de comunicação via rádio 802.15.4, comunicação USB e o tratamento dos dados. Esta sessão mostrará a configuração utilizada para que este trabalho fosse realizado.

4.2.1. Sistema operacional TinyOS

TinyOS é um sistema de código aberto, projetado para dispositivos *wireless* de baixa consumo, como redes de sensores, computação ubíqua, redes de área pessoal, edifícios inteligentes e contadores inteligentes (TinyOS, 2013). A arquitetura do TinyOs é dividida em duas camadas básicas: camada de *software* e camada de *hardware* conforme mostrado na Figura 29.

Típica Arquitetura de Aplicação

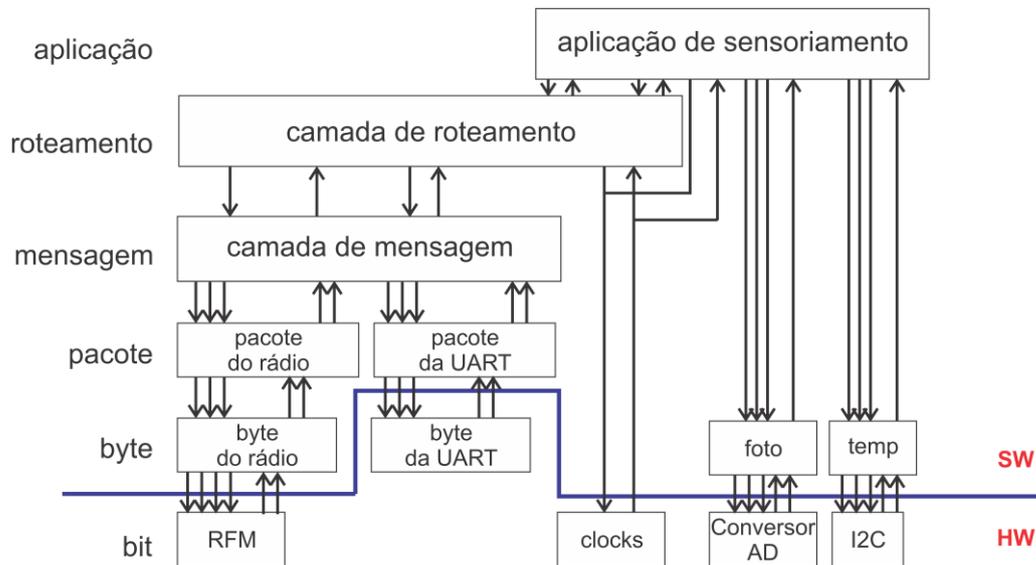


Figura 29 - Arquitetura do TinyOS

Os hardwares compatíveis com a plataforma TinyOS conforme documentação do mesmo aponta sua compatibilidade com os seguintes motes:

- EPIC
- Imote2
- Shimmer
- IRIS (utilizado neste experimento)
- Kmote, a.k.a. TelosRevB
- MicaZ
- Mica2
- Mica2dot
- NXTMOTE - TinyOS on LEGO MINDSTORMS NXT
- Mulle
- TMote Sky
- TelosRev B
- TinyNode
- Zolertia Z1
- UCMote Mini

Rádios compatíveis:

- CC1000
- CC1100/CC2500
- CC2420
- AT86RF212
- AT86RF230

4.2.2. Sistema operacional Ubuntu/Linux

Para desenvolvimento de aplicativos para redes de sensores utilizando TinyOS utilizou-se a plataforma Linux, com a distribuição Ubuntu 11.04 na máquina de desenvolvimento e Ubuntu 12.04 no computador de testes não apresentando problemas de compatibilidade.

4.2.3. Motes IRIS

Os módulos sensoriais IRIS fazem parte de uma geração de motes da Memsic. O XM2110 (2.400 MHz a 2.483,5 MHz) usa o Atmel RF230, compatível com IEEE 802.15.4 que é um transceptor de rádio frequência integrado com um micro controlador ATMEGA1281. Conforme o fabricante, fornece até três vezes melhor alcance do rádio e duas vezes a memória em relação à geração anterior de motes MICA. Faz parte da mesma família MICA, com conector de E/S de 51 pinos, e memória flash de série; todas as placas e sensores são compatíveis com o XM2110. O mote IRIS é ilustrado pela Figura 30.



Figura 30 - Mote IRIS

4.2.4. Gateway Mib520

O MIB520 fornece conectividade USB para a família IRIS e MICA de Motes para a comunicação e programação no sistema. Ele fornece energia para o dispositivo (gateway)

através de barramento USB. O MIB520 tem um processador on-board *in-system processor* (ISP), um ATMEGA16L localizado na sua placa para programação dos motes. O Código é transferido através da comunicação USB. AMIB520 é apresentada na Figura 31.

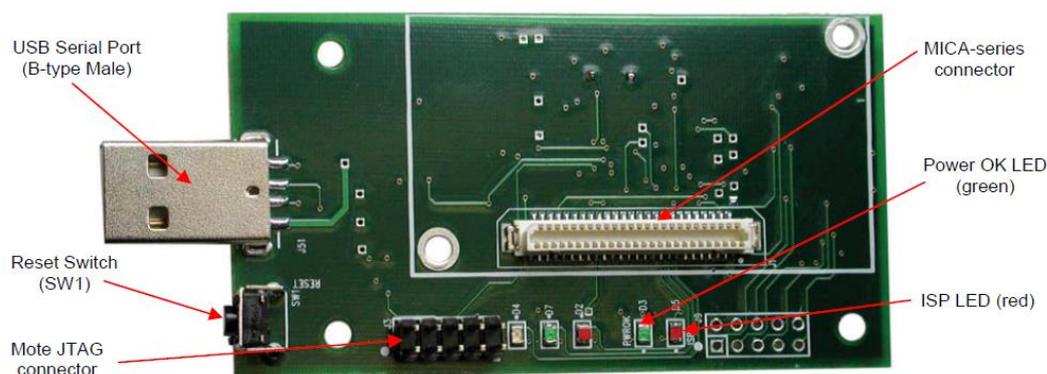


Figura 31 - MIB520

4.2.5. FannTool

A rede neural foi treinada e testada na ferramenta *FannTool* (Fantool, 2013), que por sua vez é uma implementação gráfica de uma biblioteca Fann (*Fast Artificial Neural Network*). *Fast Artificial Neural Network* é uma biblioteca de código aberto para treinar/testar redes neurais multicamadas com suporte para redes totalmente conectadas e pouco conectadas (Fann, 2013).

A aplicação *FannTool* tem como recurso um conjunto de operações para detectar as melhores funções de treino e de ativação, bem como a taxa percentual de acerto da rede (Fantool, 2013). A seguir, algumas características da ferramenta *FannTool*:

- **Diversidade:** Treinamentos para o algoritmo *back-propagation* (RPROP, Quickprop, Batch, Incremental) e funções de ativação diversas permitindo a permutação com outros parâmetros obtendo grande variedade de configurações de rede possíveis;
- **Persistência:** Os dados podem ser salvos e restaurados em arquivos;
- **Usabilidade:** A ferramenta apresenta passos para fácil criação, treino e execução de uma RNA;
- **Versatilidade:** Os parâmetros da rede podem ser facilmente ajustados;
- **Liberdade:** Software livre com permissão para fins comerciais, acadêmicos ou pessoais desde que, respeitadas as regras de licença.

4.2.6. Softwares Diversos

Para o tratamento dos dados, outros softwares foram criados para evitar tarefas manuais repetitivas e demoradas, dos quais cita-se:

- Calculo da variável A (Priwgharm & Chemtanomwong, 2011): apenas captura o RSSI, para que o valor saia exato, o emissor e o receptor devem ficar a 1 metro de distância contando suas antenas como pontos de referência conforme equação (8).
- Calculo do *path loss*: a partir da distância e do RSSI obtido, o programa calcula a variável da perda de propagação do ambiente para fazer uso nas técnicas de localização.
- Tratamento dos logs para RNA: Após a coleta de dados, é necessário formatar os dados para que o software FannTool compreenda a quantidade de amostras, quantidade de entradas e saídas respectivas.
- Tratamento dos logs para a Lateração e KNN em lote: Semelhante ao tratamento para a RNA, os dados devem ser formatados para que seja possível realizar o calculo da Lateração e do KNN para todas as amostras.
- Tabelamento de resultados: para que não haja o esforço de colocar cada amostra em uma Tabela, foi desenvolvido um sistema para agrupar todos os dados em Tabelas em formato html, que pode ser copiado e colado normalmente em editores de planilhas e até mesmo usado no MatLab para plotar gráficos.

5. Análise Comparativa

Este capítulo tem como objetivo apresentar os resultados obtidos no experimento em ambiente *indoor* e *outdoor*, assim como os resultados referentes ao comparativo entre técnicas avaliando quantitativamente o desempenho em função da precisão.

Os valores absolutos dos erros de posicionamento nas coordenadas x (x_{error}), y (y_{error}) e o erro de localização (l_e) são usados como uma métrica para comparação das técnicas. O erro de localização é a distância entre o ponto real e o valor estimado como mostrado nas equações (26), (27) e (28), respectivamente.

$$x_{error} = |x_{real} - x_{estimated}| \quad (26)$$

$$y_{error} = |y_{real} - y_{estimated}| \quad (27)$$

$$l_e = \sqrt{(x_{error})^2 + (y_{error})^2} \quad (28)$$

Para comparar os resultados entre a Lateração, KNN e a RNA, foi estabelecido o *benchmark* entre as técnicas utilizando as equações (29) e (30). O *benchmark* permitirá visualizar percentualmente o comparativo entre as técnicas RNA versus Lateração e RNA versus KNN.

$$bm_{RNA \times LAT} = 100 * \frac{l_{eLAT} - l_{eRNA}}{l_{eLAT}} \quad (29)$$

$$bm_{RNA \times KNN} = 100 * \frac{l_{eKNN} - l_{eRNA}}{l_{eKNN}} \quad (30)$$

Onde,

$bm_{RNA \times LAT}$: Benchmark entre a RNA e a Lateração

$bm_{RNA \times KNN}$: Benchmark entre a RNA e o KNN

l_{eRNA} : Erro de Localização obtido na RNA em metros

l_{eLAT} : Erro de Localização obtido na Lateração em metros

l_{eKNN} : Erro de Localização obtido no KNN em metros

5.1. Estudo de Caso 1: *Indoor*

O primeiro experimento consiste em realizar testes de localização em um ambiente *indoor* para verificar a eficácia da estimativa da localização por cada técnica. Na Figura 32, observa-

se o *benchmark* entre a RNA e a Lateração percentualmente, onde valores positivos indicam que a RNA tem melhores resultados do que Lateração. Do mesmo modo, a Figura 33 mostra o *benchmark* entre a RNA e o KNN. Para ilustrar estes gráficos com maior clareza e melhor visualização, 50 pontos foram selecionados tomando sempre a primeira amostra a cada cinco de um total de 255 utilizados para estimar a localização. Os valores negativos ocorrem sempre que a técnica RNA não produz melhores resultados na comparação.

Erro (%) RNA x LAT

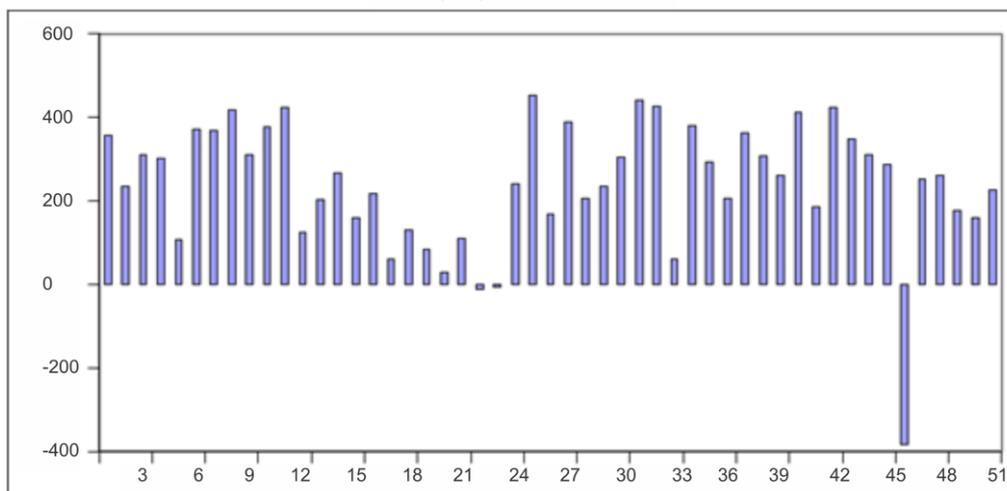


Figura 32– Comparação percentual entre a RNA e a Lateração em ambiente *indoor*

Erro (%) RNA x KNN

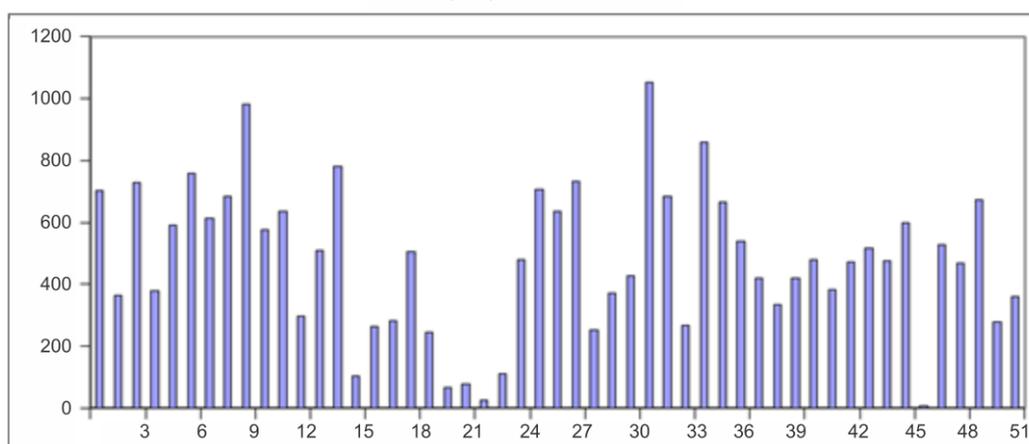


Figura 33 - Comparação percentual entre a RNA e o KNN em ambiente *indoor*

A RNA obteve melhores resultados na localização com média 232,43% melhor do que a Lateração e 470,45 % melhor do que KNN. Entretanto, esta comparação não é comutativa,

de forma que, o benchmark da RNA x Lateração não produz o mesmo gráfico que o benchmark entre a Lateração e a RNA. A RNA foi escolhida como ponto de partida devido à grande quantidade de acertos se comparada às outras duas técnicas.

A Tabela 1 mostra o percentual de casos em que cada técnica tem o melhor desempenho para as métricas acima mencionadas. Os valores x e y foram estimados para aplicar filtros em trabalhos futuros que permitam reduzir o erro estimado por coordenada, possibilitando a redução do erro de distância. Os dados da Tabela 1 mostram que a RNA obteve 76,0784% e 79,6078% dos melhores resultados nas estimativas quando comparado com a Lateração. No *benchmark* do KNN e a RNA, a Tabela 1 mostra que 85,8824 % e 88,6275 % das amostras têm melhores resultados para as coordenadas x e y respectivamente. Portanto, a RNA apresenta melhores resultados quando comparado com a Lateração e o KNN para ambientes *indoor*.

Tabela 1- Performance: RNA versus LAT e RNA versus KNN em ambiente *indoor*

Comparação	RNA x LAT		RNA x KNN	
	%RNA	%LAT	%RNA	%KNN
<i>Métrica</i>				
X	76,0784	23,9216	85,8824	14,1176
Y	79,6078	20,3922	88,6275	11,3725
<i>Menor Erro de Localização</i>	94,902	5,098	98,0392	1,9608

O erro de localização considera a distância entre o ponto real e o ponto estimado no plano. Quando se considera a distância da localização estimada e localização real, a RNA também tem melhores resultados do que a Lateração e o KNN, ou seja, a estimativa da localização da RNA confrontada à localização real sobrepõe-se com 94,902% e 98,0392% a Lateração e ao KNN respectivamente. A Tabela 2 exibe o percentual de acertos por técnica para as coordenadas x , y e para a localização do ponto confrontando o KNN, Lateração e Rede Neural.

Tabela 2-Percentual de Acertos por técnica em ambiente *indoor*

%	KNN	LAT	RNA
X	8,203125	21,09375	70,3125
Y	6,640625	16,40625	75,78125
Localização	0,78125	12,5	86,32813

Conforme previsto, dado que a RNA possui melhores resultados nas comparações com a Lateração e com o KNN, o nível percentual de melhores amostras entre as três técnicas

confrontadas quantitativamente em uma única Tabela resultaria na RNA como detentora dos maiores percentuais de acerto. Dada a taxa de aproximadamente 86% de acertos na localização dos pontos, a RNA é plenamente indicada para realizar experimentos em ambientes *indoor* livre de obstáculos, o qual não se restringe apenas a salas, galpões ou ambientes domésticos.

Um comportamento desejável para estimativa da localização é a estabilidade, visto que o erro é algo esperado nas estimativas. Entretanto, minimizar este erro é plenamente factível, a partir da obtenção média de erros considerada satisfatória (dependendo dos requisitos da aplicação) e variância baixa, ocasionando na estabilidade do erro. O erro médio tendendo a zero indicaria o quanto a técnica se aproxima dos valores reais, e a variância tendendo a zero indica o quanto o erro médio pode ser deslocado para diminuir o erro estimado. A Tabela 3 mostra a média (μ) e variância (σ) de erro de posicionamento de cada técnica. A média e a variância do erro de posicionamento na RNA são menores do que os calculados para Lateração e KNN.

Tabela 3 - Média e variância do erro em metros em ambiente *indoor*

Erro	LAT		KNN		RNA	
	μ	σ	μ	σ	μ	σ
x	1,76	1,27	2,68	3,55	0,80	0,51
y	2,02	1,34	3,77	4,68	0,88	0,88
l_e	2,94	1,18	5,01	4,49	1,30	1,12

Além de conhecer o erro médio e sua variância, é interessante tomar conhecimento a respeito do erro em camadas, que podem ser classificadas em raios de 1 metro. Desta forma considera-se a posição real do nó alvo da amostra, e a partir desta, classifica-se os erros conforme a faixa da distância da estimativa. Tomando todas as amostras, a Tabela 4 considera erros menores que 1 metro, e erros no intervalo a cada 1 metro da posição onde a amostra é encontrada.

Tabela 4 - Análise quantitativa do erro a cada metro em ambiente *indoor*

Erro de Localização	%LAT	%KNN	%RNA
$0 \leq l_e < 1$	5,09	1,96	48,62
$1 \leq l_e < 2$	19,21	6,27	29,80
$2 \leq l_e < 3$	22,74	8,23	15,29
$3 \leq l_e < 4$	35,29	14,50	3,52
$4 \leq l_e < 5$	17,64	21,17	2,74
$l_e \geq 5$	0	47,84	0

Para erros menores que 1 metro, a RNA apresenta os melhores resultados com uma grande vantagem, pois 48,62% dos locais das posições estimadas encontram-se na zona de erro inferior a 1 metro ($l_e < 1$).

As Figuras 34 e 35 mostram algumas amostras dos pontos estimados. Cada ponto real é ilustrado por um quadrado ligado às suas três estimativas (RNA, Lateração e KNN). A Figura 34 exibe as amostras localizadas na periferia do cenário, demonstrando o comportamento de cada técnica próximo às fronteiras do evento. A Figura 35 mostra os pontos situados na região mais interna do experimento.

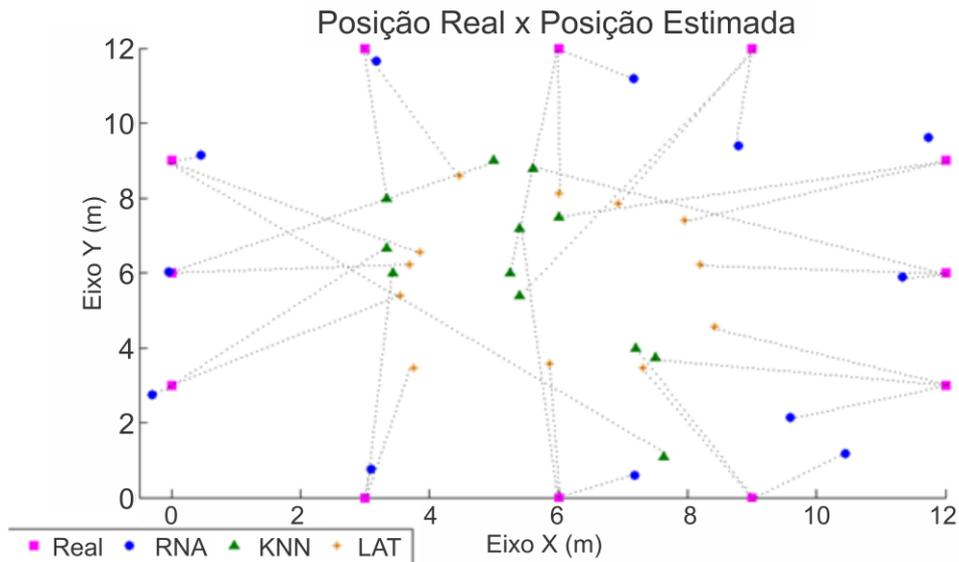


Figura 34 - Posições reais e estimadas por técnica em pontos periférico sem ambiente *indoor*

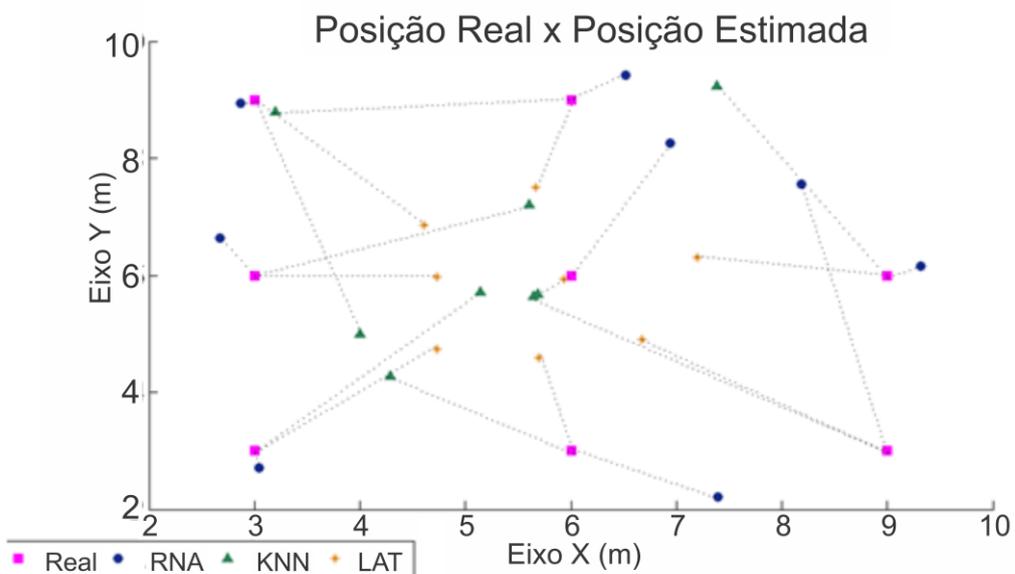


Figura 35 - Posições reais e estimadas por técnica em pontos internos em ambiente *indoor*

Para comparar as técnicas de localização aqui apresentadas, também estimou-se o tamanho do erro acumulado, indicando o modo como cada técnica desvia do valor real a cada acréscimo de um registro, tal como ilustrado na Figura. 36.

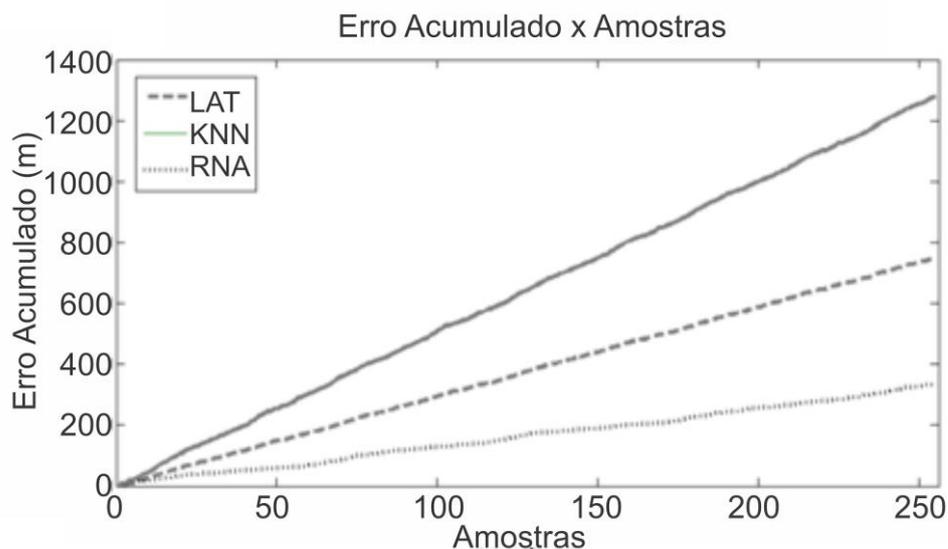


Figura 36–Erro acumulado em ambiente *indoor*

A Figura36 mostra o comportamento quase linear resultante da acumulação de erro nas amostras. O erro final acumulado da Lateração e KNN é 225,05% e 383,61% maior do que o erro final acumulado quando comparado à RNA, respectivamente.

5.2. Estudo de Caso 2: *Outdoor*

Para complementar o experimento realizado em ambiente *indoor*, foi realizado um segundo experimento utilizando as mesmas técnicas para analisar o comportamento em ambiente *outdoor*. A finalidade do novo experimento consiste em confirmar se os resultados serão semelhantes ao experimento anterior, ou se o comportamento será diferente aplicando os mesmos parâmetros da RNA.

Semelhante ao teste realizado em ambiente *indoor*, neste experimento também é realizado o *benchmark* entre as técnicas Lateração e KNN com a mesma RNA proposta. A Figura 37 apresenta a comparação entre a RNA e a Lateração, enquanto a Figura 38 apresenta o comparativo entre as técnicas RNA e KNN.

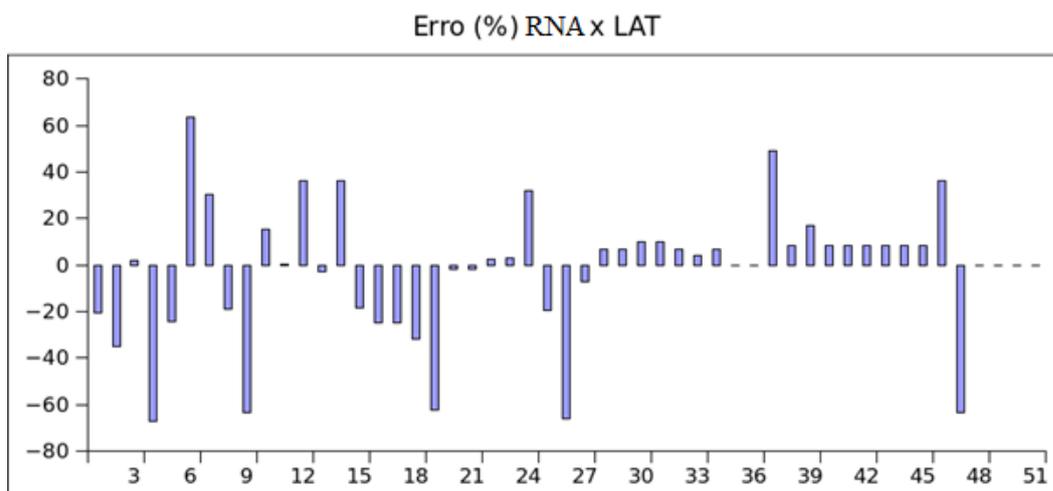


Figura 37 - Comparação percentual entre a RNA e a Lateração em ambiente *outdoor*

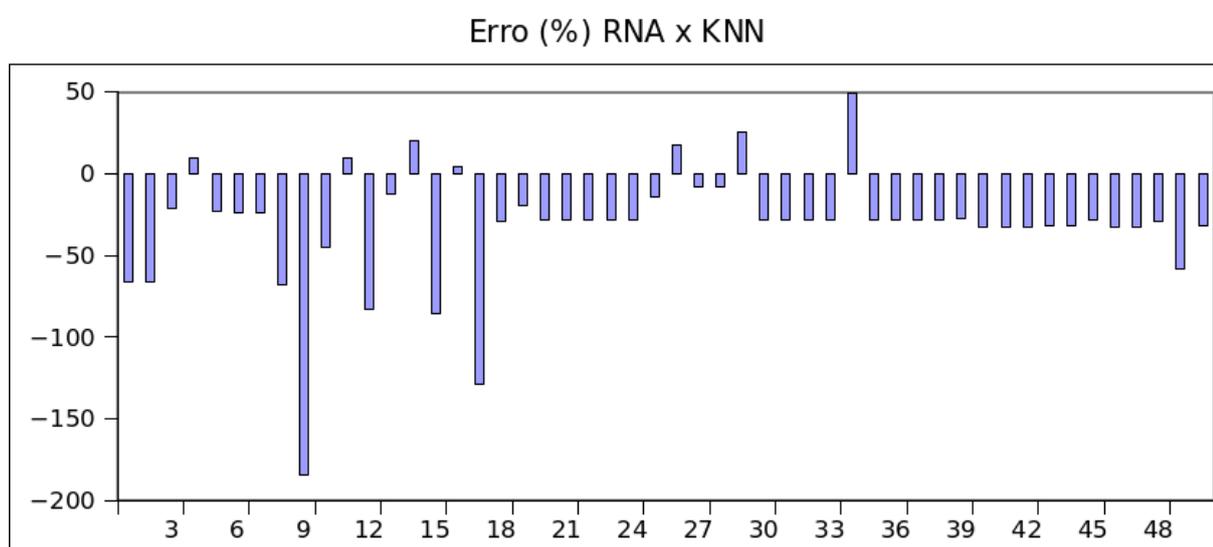


Figura 38 - Comparação percentual entre a RNA e o KNN em ambiente *outdoor*

A RNA chega a ser 17,9% superior à Lateração conforme os testes realizados em ambiente *outdoor*, e 55,1% inferior ao KNN, conforme Figura 38. Na Tabela 5 é possível analisar o percentual de sucesso nas amostras comparadas, tomando o KNN como técnica com maior proximidade do valor real com 94,43% de superioridade em relação a RNA. Destaca-se que a RNA continua apresentando resultados melhores que a Lateração, entretanto a diferença já não é tão grande como ocorria em ambientes *indoor*.

Tabela 5 - Performance: RNA versus LAT e RNA versus KNN em ambiente *outdoor*

Comparação	RNA x LAT		RNA x KNN	
	%RNA	%LAT	%RNA	%KNN
<i>Metrica</i>				
X	93,45%	6,34%	7,93%	92,06%
Y	96,03%	3,76%	49,80%	50,20%
Localização	64,41%	35,58%	5,56%	94,43%

A partir desta comparação, nota-se que o comportamento das técnicas sofre diferenciação dada a mudança da escala e do local para testes. Na análise das coordenadas de forma independente, é visível que no eixo y na comparação entre a RNA e o KNN mantiveram uma taxa aproximada da quantidade de amostras com mais acertos, enquanto que para a coordenada x da mesma comparação, a rede neural foi bastante inferior ao KNN. A média e variância das técnicas neste experimento são apresentadas na Tabela 6, na qual a Lateração obteve menor média, enquanto o KNN apresentou menor desvio, portanto maior estabilidade. A rede neural por sua vez, ficou no meio termo entre a média e o desvio padrão. A Tabela 6 mostra as médias e variâncias para cada técnica em cada coordenada e no erro final de localização.

Tabela 6 - Média e variância do erro em metros em ambiente *outdoor*

erro	LAT		KNN		RNA	
	μ	σ	μ	σ	μ	σ
x	4,871377	0,38995	0,7184	6,91002	0,67807	6,34486
y	12,471	13,5003	9,9131	3,71332	9,87061	7,48594
l_e	6,50334	7,011449	10,809	4,61228	9,06192	5,11094

Posterior à análise da média e variância, a Tabela 7 exhibe a quantidade de acertos nas amostras para todas as técnicas em efeito quantitativo, visto que a Tabela 6 mostrou o quanto uma técnica foi melhor que a outra tomando o erro como parâmetro, na Tabela 7 é exibida a quantidade de amostras com melhor desempenho por técnica.

Tabela 7–Percentual de Acerto por técnica em ambiente *outdoor*

%	KNN	LAT	RNA
X	92,04771	1,590457	6,361829
Y	47,51491	3,578529	48,90656
localização	49,10537	4,572565	46,32207

Em se tratando de quantidade de acertos, houve um balanceamento entre a RNA e o KNN, de forma que o KNN possui quantitativamente um erro menor que 3% na localização em relação à rede neural. Nesta característica, a RNA ainda se manteve próxima do KNN. O KNN se comportou como a técnica com maior precisão para este experimento, uma das possíveis razões para isto pode ser o fato da característica do ambiente *outdoor* contribuir com a aplicação da técnica. As Figuras 39 e 40 apresentam o posicionamento das estimativas comparadas ao ponto real.

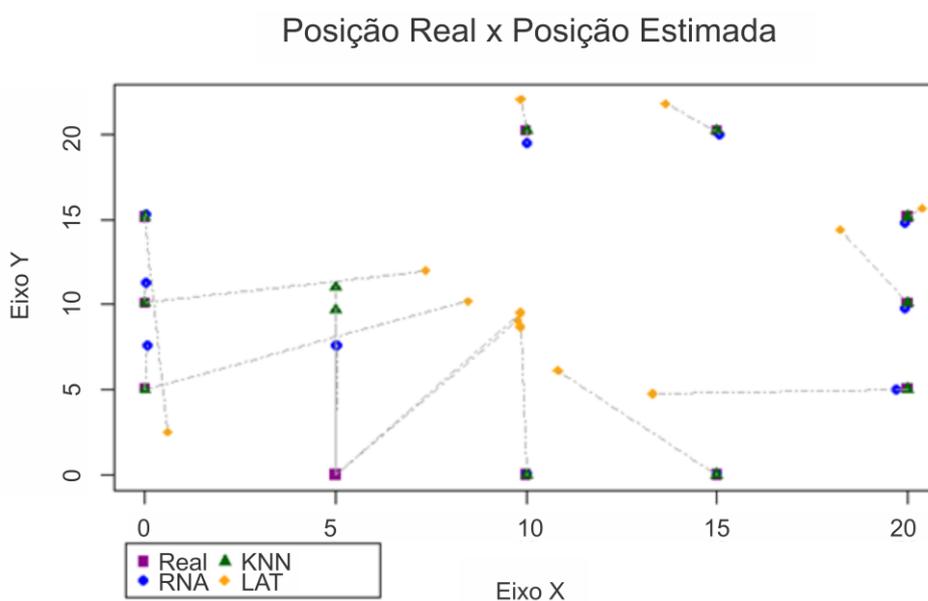


Figura 39 - Posições reais e estimadas por técnica em pontos periféricos em ambiente *outdoor*

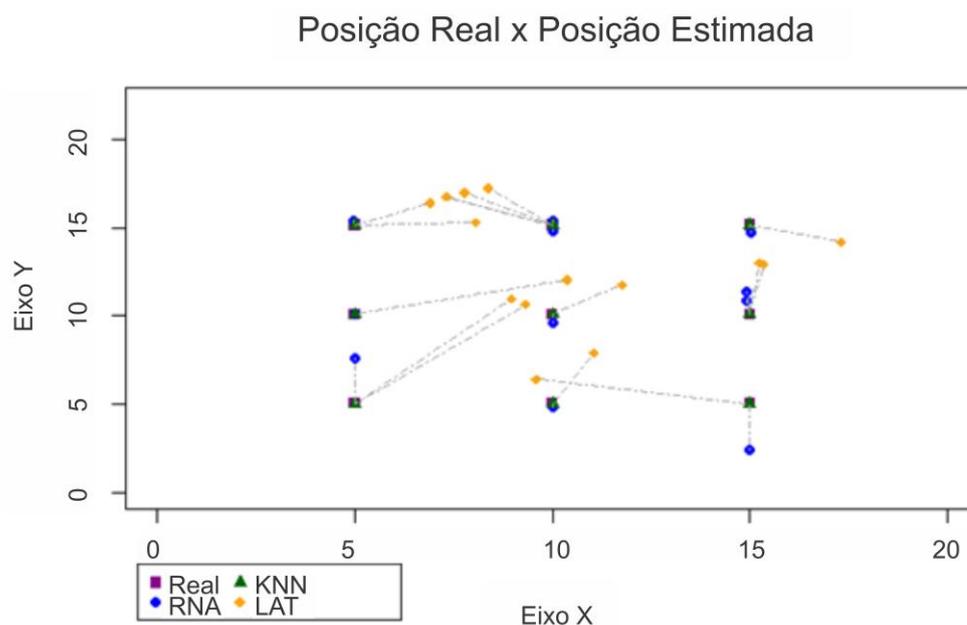


Figura 40 - Posições reais e estimadas por técnica em pontos internos em ambiente *outdoor*

As Figuras 39 e 40 mostram graficamente as posições reais e as respectivas estimativas da Lateração, KNN e RNA para pontos periféricos e internos da área do experimento. E por final a Figura 41 mostra o tamanho do erro acumulado para cada técnica. No qual o acúmulo do erro da RNA tendeu ao erro do KNN, visto que suas curvas são muito próximas. Desta forma, avalia-se que o KNN possuiu o maior conjunto de amostras com melhores resultados para ambientes *outdoor*, entretanto obteve a curva de erro acumulado muito próximo se comparado a RNA.

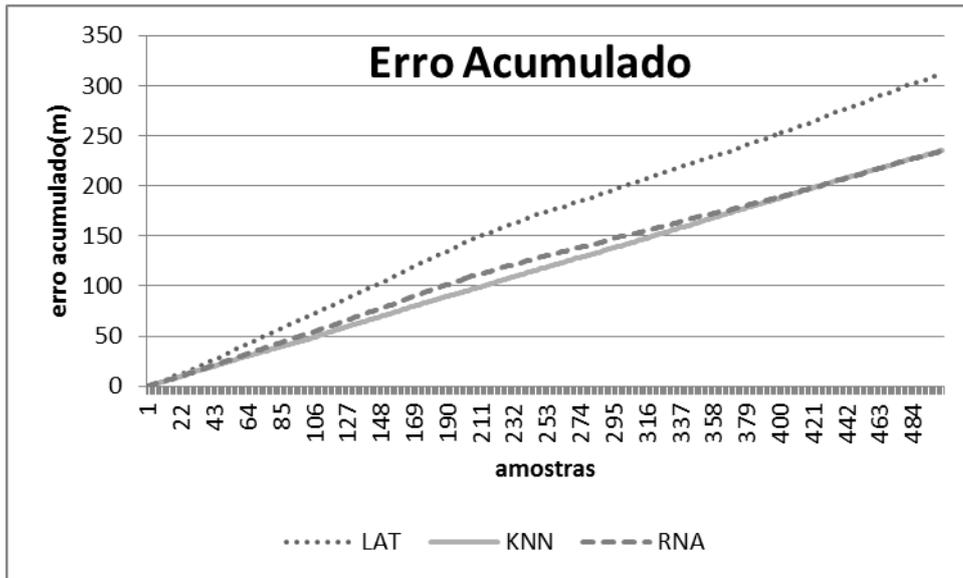


Figura 41–Erro Acumulado em ambiente *outdoor*

Desta forma, o algoritmo KNN e a RNA se destacam pelo menor erro acumulado nas estimativas, tomando a soma do erro como parâmetro para estabelecer o distanciamento do valor ideal ao ponto estimado real nos ambientes de teste.

6. Considerações Finais

O uso destas técnicas de localização pode ser aplicado em locais e situações nas quais o uso do aparelho GPS não é favorável por fatores de consumo de energia, limitação de hardware ou mesmo quando não há cobertura na área desejada. Entretanto, as técnicas descritas, podem ser utilizadas como complemento para melhorar a precisão da estimativa por GPS. Trabalhando em pequenas granularidades dentro do campo de uso do sistema de GPS, a precisão pode ser aprimorada, compreendendo intervalos que o mesmo não permite dada a escala de nível global.

O estudo de técnicas de localização aponta características desfavoráveis do GPS, uma vez que as mesmas visam sanar problemas referentes ao uso do mesmo em cenários, locais e situações em que não é possível utilizá-lo, ou quando o GPS não resulta em valores satisfatórios. Sua comunicação é realizada por satélite e possui limitações de transmissão por motivos físicos decorridos da distância do satélite ao solo na qual os satélites comumente são dispostos em posições geoestacionárias.

Para as demais técnicas, a substituição do satélite é realizada por pontos de transmissão atuando como nós âncoras, que agem de forma semelhante, visto que sua posição é conhecida e estática, assim como os satélites se mantêm estáticos em relação a um ponto no solo. O nó alvo por sua vez é o mesmo agente que ao notar a necessidade de conhecer sua localização, utiliza do seu protocolo, ou conjunto de protocolos que determinem a sua posição estimada. O processamento pode ser centralizado ou distribuído, dependendo da necessidade, da autonomia e do tempo que se deseja ao projetar uma rede.

As diversas técnicas cujo objetivo é prover a localização utilizando os artifícios do ângulo da antena (AOA), tempo e sincronização (TOA), diferença temporal entre emissão de rádio e ultrassom (TDOA) ou pela potência do sinal (RSSI) apresentam particularidades, contrabalanceando em dispender de mais recursos de hardware, consumo energético, precisão no sinal e conversão para unidades de fácil manipulação para encontrar os valores das coordenadas.

Técnicas clássicas como a Lateração assim como suas variantes e especializações permitem que manipulações matemáticas alcancem valores próximos do real, através de uma modelagem de fácil reprodução para os mais diversos ambientes dada a sua completude em se tratando de abrangência da escala e parâmetros do cenário dos testes. A Lateração é uma

técnica de fácil ajuste. Esta técnica requer uma precisão no *path loss* do meio e o valor da variável de RSSI a um metro A , conforme equação (8), de outro modo, o erro pode ser aumentado de forma a ultrapassar os limites das fronteiras.

Métodos classificativos e estatísticos tais como KNN ou NLR apresentam uma modelagem que faz uso dos dados para montar seus parâmetros estimando valores dos seus parâmetros para melhor precisão. O KNN utiliza os dados dos seus vizinhos mais próximos para realizar o cálculo de sua localização. Neste experimento, a técnica KNN foi realizada através da soma ponderada de cada coordenada dividindo pela soma dos seus pesos. Na técnica KNN, a localização estimada tende a estar dentro dos limites do cenário, devido à soma ponderada de RSSI's dos seus vizinhos. Os resultados apresentam valores com menor precisão para ambientes *indoor*. Entretanto, em ambiente *outdoor* a estimativa superou as técnicas Lateração e RNA possivelmente ocasionado pela influência do meio, entretanto isto só pode ser confirmado realizando futuros testes em outros ambientes com escalas diferentes das realizadas no experimento.

Inteligência artificial por sua vez é uma área de abrangente aplicação, apresentando as mais diversas formas de utilização, seja por redes neurais artificiais, algoritmos genéticos, lógica nebulosa, enxame de partículas ou lógica simbólica. A modelagem da RNA se demonstrou adequada visto que os valores de RSSI como entrada de dados dispensaria a necessidade de conhecimento da posição fixa do nó âncora, uma vez que o RSSI está diretamente relacionado à distância, e a distância está em função das coordenadas, além disto, os valores do *path loss* e a variável A de 1 metro já são inferidos nas camadas intermediárias da RNA.

A aplicação da rede neural, para resolver o problema de localização, mostra bons resultados para ambiente *indoor* e resultados aceitáveis para ambiente *outdoor* na estimativa de um nó dentro dos limites dos nós âncoras. Este método obteve em ambientes *indoor*, menor média e variância do erro quando comparada com as técnicas de Lateração e KNN, conseqüentemente, tendo uma maior estabilidade. Apresentando-se também como método intermediário para o segundo experimento, visto que a diferença para o KNN em termos de erro acumulado não foi grande, e na análise quantitativa, chegou próximo ao pareamento com o mesmo, perdendo consideravelmente no benchmark. Seu número de entradas é fixo e diretamente relacionado ao número de nós âncora, resultando na necessidade de um novo treinamento da rede para diferentes quantidades de nós âncoras cujo comportamento esperado é que o aumento de dados coletados gere maior precisão na estimativa.

Em (Priwgharm & Chemtanomwong, 2011), a avaliação do desempenho indicou que a técnica Lateração tem uma melhor precisão seguida pelo KNN em testes realizados em ambientes fechados, semelhante ao primeiro teste apresentado neste trabalho. Logo, é esperado o mesmo comportamento que no trabalho dos referidos autores, cuja precedência entre as técnicas se manteve a mesma. Neste estudo, ambas as técnicas foram comparadas com a RNA para localização, na qual observou que a RNA apresentou menor erro e consequentemente, melhor precisão na localização do nó de destino para ambientes fechados, e a técnica KNN de igual forma para ambientes abertos.

6.1. Trabalhos Futuros

Para testes em ambientes reais, o uso de um computador desktop é inviável, por questões de perda de mobilidade, desta forma, todos os testes foram realizados utilizando notebooks. Porém, referente à mobilidade do agente coletor de dados (agente desktop ou aplicativo desktop), inclui-se nos trabalhos futuros a substituição do notebook por Tablets, preferencialmente utilizando a tecnologia Android, visto que esta permite a reutilização de grande parte do trabalho já realizado sem necessidade de reescrita completa dos aplicativos. Além de permitir a compatibilidade com a biblioteca do TinyOS, o gargalo desta solução se dá na inexistência de drivers de comunicação serial para operar em sistemas operacionais embarcados, o que exigiria um esforço maior para estabelecer a comunicação serial entre o Tablet e a MIB520. Também será necessário desenvolver protocolos que permitam a comunicação segura de falhas, isto se mostra como fator de grande interesse visto que a autonomia da bateria destes aparelhos pode chegar ao máximo 8 horas, mantendo o peso do aparelho em aproximadamente 600 gramas. O formato retangular de um tablet, quase plano (dado que a profundidade é a menor das medidas do aparelho) permitiria a participação no centro do evento causando menos interferência que o método utilizado até o momento.

Atentando para ambientes florestais, no qual em parte deste as copas das grandes árvores cobrem a área de forma semelhante ao funcionamento de um telhado, pode-se caracterizar tal ambiente como *indoor*, e portanto estes resultados servem como base de interesse para estes tipos de ambientes.

O trabalho concentra-se em testes em ambientes reais, portanto os algoritmos de localização são o núcleo de toda a solução proposta, desde a coleta ao processo final, muitos outros algoritmos são utilizados para auxiliar na estruturação de dados, organização,

catalogação, apresentação, geração de gráficos e Tabelas, entre outros. Uma das formas de catalogação realizada foi a criação de um algoritmo que extraia os dados dos logs do sistema, organizava, catalogava e salvava em arquivo html, que por sua vez era plenamente compatível com os editores de planilhas. Para trabalhos futuros planeja-se criar um conjunto de aplicativos, assim como um passo a passo para cada etapa e suas respectivas ferramentas para minimizar o trabalho realizado no pós-teste.

Conforme descrito anteriormente, os trabalhos futuros compreendem:

- Repetir o experimento em escalas maiores e menores
- Realizar experimentos com *Angle of Arrival*.
- Realizar experimentos com *Time of Arrival*.
- Realizar experimentos com *Time Difference of Arrival*.
- Aplicação de outras técnicas de inteligência artificial
- Repetir o experimento *outdoor* retreinando a rede
- Aplicar outras técnicas para comparações (Min-Max, NLR, INLR, ToM, *Dv-hop*, etc)
- Realizar testes em ambientes diferentes: *indoor*, *outdoor*, *floresta*, *indústria*, etc.
- Realizar o rastreamento (*tracking*) em tempo real utilizando nós moveis
- Realizar testes com 3, 4, 5, 6, 7 e 8 nós âncoras
- Testar o funcionamento em outro Hardware
- Aplicar filtros para minimizar o erro da localização
- Integração com android para coleta de dados
- Ferramentas de integração de análise de dados
- Estudar o comportamento de *Multipath*
- Estudar outras geometrias para teste no ambiente.

Bibliografia

Albowicz, J., Chen, A., & Zhang, L. (2001). Recursive position estimation in sensor networks. *Network Protocols, 2001. Ninth International Conference on* , 35,41.

Boukerche, A., Oliveira, H., Nakamura, E., & Loureiro, A. (2007). Localization systems for wireless sensor networks. *Wireless Communications, IEEE* , 6-12.

Brito, L., Liu, Y., & Garcia, Y. (2011). An optimal Sum-Dist localization scheme for wireless sensors networks. *Communication Software and Networks (ICCSN), 2011 IEEE 3rd International Conference on* , 172,176.

Cao, A., Zhu, X., Zhou, J., & Gao, T. (2008). Theory of continued fraction interpolation and its application in non-linear regression. *Intelligent Control and Automation, 2008. WCICA 2008* , 8078,8081.

Catovic, A., & Sahinoglu, Z. (2004). The Cramer-Rao bounds of hybrid TOA/RSS and TDOA/RSS location estimation schemes. *Communications Letters, IEEE* , 626- 628.

Cavalcanti, N. (2005). A Fuzzy c-means Algorithm Based on an Adaptive L2 Minkowsky Distance. *Hybrid Intelligent Systems, 2005. HIS '05. Fifth International Conference on* , 104,109.

Chan, F., & Wen, C. (2011). Adaptive AOA/TOA Localization Using Fuzzy Particle Filter for Mobile WSNs. *Vehicular Technology Conference (VTC Spring)* , 1,5.

Chen, Y., Chung, T., Yang, J., Yang, J., & Chen, P. (2005). QMNF: QoS-aware multicasting routing protocol using N-hop dominating flooding approach on active network. *Advanced Communication Technology* , 1331,1336.

Chun-Chieh, H., Yi-Jing, S., Seng-Yong, L., & Chia-H, C. (2011). Towards long-term mobility tracking in NTU hospital's elder care center. *IEEE International Conference on Pervasive Computing and Communications Workshops (PERCOM 11)* , 649–654.

Chunxia, L., Chen, F., Zhan, Y., & Wang, L. (2010). Security verification of localization estimate in wireless sensor networks. *6th International Conference on Wireless Communications Networking and Mobile Computing (WiCOM 10), IEEE Press* , 1-4.

Conti, M., Willemsen, J., & Crispo, B. (2013). Providing Source Location Privacy in Wireless Sensor Networks: A Survey. *Communications Surveys & Tutorials, IEEE* , 1238,1280.

Domenech, C., & Wehr, T. (2011). Use of Artificial Neural Networks to Retrieve TOA SW Radiative Fluxes for the EarthCARE Mission. *Geoscience and Remote Sensing, IEEE Transactions on* , 1839,1849.

Dunbabin, M., & Marques, L. (2012). Robotics for Environmental Monitoring. *IEEE ROBOTICS & AUTOMATION MAGAZINE* , 24-39.

Fann. (Acessado em Jul. 2013.). Fast artificial neural network library [Online]. *Disponível em* <<http://leenissen.dk/fann/wp/>> .

Fantool. (Acesso em Julho de 2013). Fanntool.Tool for the fast artificial neural network library. *Disponível em* < <https://code.google.com/p/fanntool/>> .

Feng, J., Zheng, L., & Liu, Z. (2013). An optimum gateway discovery and selection mechanism in WSN and mobile cellular network integration. *Communications and Networking in China (CHINACOM)* , 483,487.

Gaur, A., Toshniwal, S., Prakash, A., & Agrawal, D. (2010). Enhanced localization based key pre-distribution scheme for secure communication in wireless sensor network (WSN). *7th International Conference on Mobile Adhoc and Sensor Systems (MASS 10), IEEE Press* , 8–12.

Hadim, S., & Mohamed, N. (2006). Middleware for Wireless Sensor Networks: A Survey. *Communication System Software and Middleware, 2006. Comsware 2006. First International Conference on* , 1,7.

(2008). In: S. Haykin, *Neural Networks: A Comprehensive Foundation 3. ed* (pp. 1-41). New York: Macmillan College Publishing Company.

Hongyu, Z., Wu, H., Su, X., Miao, J., & Ning, D. (2011). A distributed triangulation algorithm for wireless sensor networks on 2D and 3D surface. *INFOCOM Proceedings IEEE* , 1053-1061.

Hsi-Chou, H., Jyh-Horng, W., Chia-Hsin, C., & Yi-Shi, E. (2011). TOA estimation with DLC receivers for IEEE 802.15.4a UWB systems. *Fifth International Conference on Innovative Mobile and Internet Services in Ubiquitous Computing (IMIS 11)* , 424–428.

Hyochang, A., & Sang-Burm, R. (2010). Simulation of a RSSI-Based Indoor Localization System Using Wireless Sensor Network. *Ubiquitous Information Technologies and Applications (CUTE), 2010 Proceedings of the 5th International Conference on* , 16-18.

Jamel, M., Khammas, T., & Zibar, M. K. (2012). FPGA Based Neural Wireless Sensor Network. *The 13th International Arab Conference on Information Technology* .

Jianxiao, G., Hongli, W., Yarong, G., & Zhiwen, Z. (2009). A New Data Mining Method of Iterative Dimensionality Reduction Derived from Partial Least-Squares Regression. *Intelligent Information Technology Application, 2009. IITA 2009. Third International Symposium on* , 471,474.

Jieyang, Y., & Liang, Z. (2011). Enhanced localization algorithm with received signal strength using fading Kalman filter in wireless sensor networks. *International Conference on Computational Problem-Solving* , 458–461.

Jinghua, W., Tingting, G., Huan, H., & Yuanyua, C. (2009). Research of Improved GA in WSN Mobile Agent Routing Algorithm. *Computational Intelligence and Software Engineering, 2009. CiSE 2009. International Conference on* , 1,4.

Julazadeh, A., Marsousi, M., & Alirezaie, J. (2012). Classification based on sparse representation and Euclidian distance,. *Visual Communications and Image Processing (VCIP)* , 1,5.

Jun, S., Yatskiv, V., Sachenko, A., & Yatskiv, N. (2012). Data transmission optimal routing in WSN using ant colony algorithm. *Modern Problems of Radio Engineering Telecommunications and Computer Science (TCSET), 2012 International Conference on* , 342,343.

Kang, M., Gao, J., & Tang, L. (2011). Nonlinear RANSAC Optimization for Parameter Estimation with Applications to Phagocyte Transmigration. *Machine Learning and Applications and Workshops (ICMLA), 2011 10th International Conference on* , 501,504.

Kinney, P., Jamieson, P., Gutierrez, J., & Naeve, M. (2014). IEEE 802.15 WPAN™ Task Group 4 (TG4). *ieee802.org* , 1,2.

Kuo, K., Lain, J., & Huang, C. (2006). Reduced-Complexity Radial Basis Function-Assisted Turbo Equalization for Dispersive Rayleigh-Fading Channels. *Systems, Man and Cybernetics, 2006. SMC '06. IEEE International Conference on* , 3691,3696.

Langendoen, K., & Reijers, N. (2003). Distributed localization in wireless sensor networks: a quantitative comparison. *Computer Networks: The International Journal of Computer and Telecommunications Networking - Special issue: Wireless sensor networks* , 499 - 518.

Lee, Y., Lee, J., Yeo, S., Park, J., & Barolli, L. (2011). A Study on the Performance of Wireless Localization System Based on AoA in WSN Environment. *Intelligent Networking and Collaborative Systems (INCoS)* , 184,187.

Lei Fang, W. D., & Ning, P. (2007). A Beacon-Less Location Discovery Scheme for Wireless Sensor Networks. *Secure Localization and Time Synchronization for Wireless Sensor and Ad Hoc Networks* , pp. 33-55.

Li, L., Xiaoguang, H., Ke, C., & Ketai, H. (2011). The applications of WiFi-based Wireless Sensor Network in Internet of Things and Smart Grid. *Industrial Electronics and Applications (ICIEA)* , 789,793.

Lichuan, L., & Manli, E. (2010). Improve the positioning accuracy for wireless sensor nodes based on TFDA and TFOA using data fusion. *International Conference on Networking Sensing and Control (ICNSC 10), IEEE Press* , 32–37.

Liu, F. (2009). An Improved RBF Network for Predicting Location in Mobile Network. *Natural Computation, 2009. ICNC '09. Fifth International Conference on* , 345,348.

Loureiro, A., Ruiz, J., Mini, R., Nakamura, E., & Figueiredo, R. (2004). Introdução a Computação Móvel.

Maheshwari, H. K., & Kemp, H. (2009). Comparative performance analysis of localization using optimal and sub-optimal lateration in WSNs. *Third International Conference on Next Generation Mobile Applications, Services and Technologies (NGMAST 09)* , 369–374.

Manor, G., & Rimon, E. (2012). High-speed navigation of a uniformly braking mobile robot using position-velocity configuration space. *Robotics and Automation (ICRA), 2012 IEEE International Conference on* , 14-18.

Min, R., Stanley, D. A., Yuan, Z., Bonner, A., & Zhang, Z. (2009). A deep non-linear feature mapping for large-margin KNN classification. *IEEE International Conference on Data (ICDM 09), ACM* , 357–366.

Mirshahi, S., Uysal, S., & Akbari, A. (2013). Integration of RFID and WSN for supply chain intelligence system. *Electronics, Computers and Artificial Intelligence (ECAI)* , 1,6.

Monteiro, D., & Takita, K. (1996). Position Control of XY Table Utilizing Artificial Neural. *The Third International Conference on Motion and Vibration Control* .

Naeve, M. (2003). IEEE 802.15.4 MAC Overview. *Project: IEEE P802.15 Working Group for Wireless Personal Area Networks (WPANs)* , 1-34.

Neto, J., Neto, J., Yang, Y., & Glover, I. (2010). Plausibility of practical low-cost localization using WSN path-loss law inversion. *Proceedings of IET International Conference on Wireless Sensor Network (IET-WSN 10)* , 15-17.

Pande, V., Elmannai, W., & Elleithy, K. (2013). Classification and detection of fire on WSN using IMB400 multimedia sensor board. *Systems, Applications and Technology Conference (LISAT), 2013 IEEE Long Island* , 1,6.

Pasolli, L., Notarnicola, C., & Bruzzone, L. (2010). Multiobjective model selection for non-linear regression techniques. *Geoscience and Remote Sensing Symposium (IGARSS), 2010 IEEE International* , 268,271.

Pires, A., Silva, C., Cerqueira, E., Monteiro, D., & Viegas, R. (2011). CHEATS: A cluster-head election algorithm for WSN using a Takagi-Sugeno fuzzy system. *Communications (LATINCOM), 2011 IEEE Latin-American Conference on* , 1,6.

Priwgharm, R., & Chemtanomwong, P. (2011). A comparative study on indoor localization based on RSSI measurement in wireless sensor network. *Eighth International Joint Conference on Computer Science and Software Engineering (JCSSE 11), IEEE Press* , 1–6.

Rahman, M., Youngil, P., & Ki-Doo, K. (2009). Localization of wireless sensor network using artificial neural network. *9th International Symposium on Communications and Information Technology (ISCIT 09)* , 639–642.

Rajaei, S., AlModarresi, S., Sadeghi, M., & Aghab, M. (2008). Energy efficient localization in wireless ad-hoc sensor networks using probabilistic neural network and independent component analysis. *International Symposium on Telecommunications (IST 08)* , 365–370.

Rhode, S., & Gauterin, F. (2013). Online estimation of vehicle driving resistance parameters with recursive least squares and recursive total least squares. *Intelligent Vehicles Symposium (IV), 2013 IEEE* , 269,276.

Rice, A., & Harle, R. (2005). Evaluating lateration-based positioning algorithms for fine-grained tracking. *Proceedings of the 2005 joint workshop on Foundations of mobile computing (DIALM-POMC 05), ACM* , 54–61.

Rong, L. (2011). A study of the security monitoring system in coal mine underground based on WSN. *Communication Software and Networks (ICCSN), 2011 IEEE 3rd International Conference on* , 91,93, 27-29.

Salgueiro, F., Sanguino, J., Rodrigues, A., & Hernandez, F. (2012). Weighted total least squares RAIM algorithm using carrier phase measurements. *Satellite Navigation Technologies and European Workshop on GNSS Signals and Signal Processing, (NAVITEC)* , 1,6.

Shareef, A., Zhu, Y., & Musavi, M. (2008). Localization using neural networks in wireless sensor networks. *Proceedings of the 1st international conference on MOBILE Wireless MiddleWARE, Operating Systems, and Applications (MOBILWARE 08)*, ACM , 1-7.

Shi, J., Mueller, C., & Marx, M. (2005). Pedestrian detection and localization using antenna array and sequential triangulation. *Intelligent Transportation Systems* , 126,130.

Summers, T., & Goulart, P. (2013). Performance bounds for constrained linear min-max control,. *Control Conference (ECC), 2013 European* , 185,190.

Teubler, T., Hail, M., & Hellbruck, H. (2012). Transparent Integration of Non-IP WSN into IP Based Networks. *Distributed Computing in Sensor Systems (DCOSS)* , 353,358.

Tian, J., & Xu, Z. (2012). RSSI localization algorithm based on RBF neural network. *3rd Int. Conf. on Software Engineering and Service Science (ICSESS 12)*, IEEE Press , 321–324.

TinyOS. (2013). TinyOS Home Page. *Disponível em <<http://www.tinyos.net/>> Acesso em Jul. 2013* .

Tsai, S., Lau, S., & Huang, P. (2012). WSN-based real-time indoor location system at the Taipei World Trade Center: Implementation, deployment, measurement, and experience. *Sensors, 2012 IEEE* , 1,4.

Van Kleef, J., Bergmans, J., Kester, L., & Groen, F. (2006). Multiple-Hypothesis Trilateration and Tracking with Distributed Radars. *Information Fusion, 2006 9th International Conference on* , 1,7.

Van Sickle, K., & Abdel-Aty-Zohdy, H. (2011). Improved supervision of NN's AOA determination with limited 1-D phased-array training data. *Aerospace and Electronics Conference (NAECON), Proceedings of the 2011 IEEE National* , 56,61.

Villas, L., Guidoni, D., & Ueyama, J. (2013). 3D Localization in Wireless Sensor Networks Using Unmanned Aerial Vehicle. *Symposium on Network Computing and Applications (NCA)* , 135,142.

Wang, L., Zhang, R., Xu, Z., & Peng, J. (2009). Some Characterizations of Global Exponential Stability of a Generic Class of Continuous-Time Recurrent Neural Networks. *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on* , 763,772.

Washizawa, Y., & Hotta, S. (2012). Mahalanobis distance on Grassmann manifold and its application to brain signal processing. *Machine Learning for Signal Processing (MLSP)* , 1,6.

Will, H., Hillebrandt, T., Yuan, Y., & Yubin, Z. (2012). The Membership Degree Min-Max localization algorithm. *Ubiquitous Positioning, Indoor Navigation, and Location Based Service (UPINLBS)* , 1,10.

Xu, M., & Lu, J. (2012). Distributed RANSAC for the robust estimation of three-dimensional reconstruction. *Computer Vision, IET* , 324,333.

Xu, H., Yong, X., & Yanmeng, W. (2011). A LSSVR three-dimensional WSN nodes localization algorithm based on RSSI. *International Conference on Electrical and Control Engineering (ICECE 11)* , 1889–1895.

Yan, Y., Wang, H., Shen, X., & Fu, Z. (2012). Efficient convex optimization method for underwater passive source localization based on RSS with WSN. *Signal Processing, Communication and Computing (ICSPCC), 2012 IEEE International Conference on* , 171,174, 12-15.

Yi, Z., Gies, V., Teles, A., & Ginoux, M. (2013). Multi-pattern cross training: An ANN model training method using WSN sensor data. *Neural Networks (IJCNN), The 2013 International Joint Conference on* , 1,6.

Yick, J. (2008). Wireless Sensor Network Survey. *Department of Computer Science, University of California* .

YingJie, Z., Kai, W., Shenfang, Y., & Hao, Y. (2012). Research of WSN Node localization algorithm based on Weighted DV-HOP. *Control and Decision Conference (CCDC), 2012 24th Chinese* , 3826,3829.

Zabidi, A., Mansor, W., Lee, K., & Fadzal, C. (2012). Classification of EEG signal from imagined writing using a combined Autoregressive model and multi-layer perceptron. *Biomedical Engineering and Sciences (IECBES), 2012 IEEE EMBS Conference on* , 964,968.

Zarrabi, H., Al-Khalili, A., & Savaria, Y. (2011). Activity management in battery-powered embedded systems: A case study of ZigBee® WSN. *Electronics, Circuits and Systems (ICECS)* , 727,731.

Zhang, L., Zhang, Y., Tang, J., Lu, K., & Qi, T. (2013). Binary Code Ranking with Weighted Hamming Distance. *Computer Vision and Pattern Recognition (CVPR)* , 23-28.

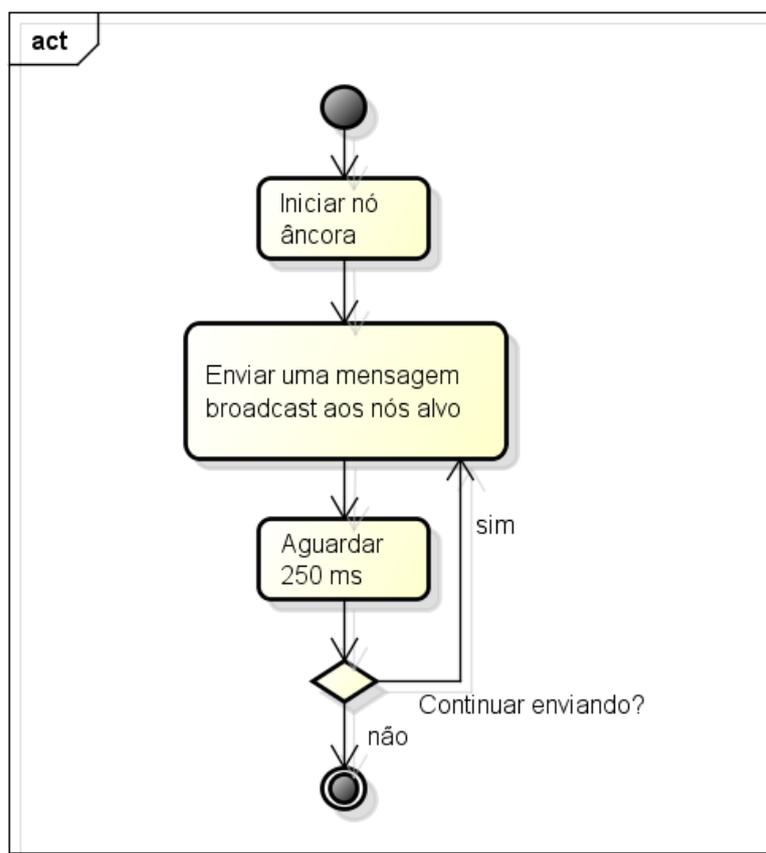
Zheng, J., & Dehghani, A. (2012). Range-free localization in wireless sensor networks with neural network ensembles. *Journal of Sensor and Actuator Networks* , 254–271.

Zhou, N., Zhao, X., & Tan, M. (2013). Deployment and Routing Method for Fast Localization Based on RSSI in Hierarchical Wireless Sensor Network. *Mobile Ad-Hoc and Sensor Systems (MASS)* , 614,619.

Apêndice

Apêndice A. Comunicação Serial.

Para desenvolvimento da leitura de dados da interface serial é necessário que a aplicação que executa no nó alvo repasse os dados da coleta para uma aplicação *desktop* afim de que o computador colete e processe os dados. Para isto, é necessário desenvolver inicialmente a comunicação entre o nó âncora e o nó alvo da rede. Na figura 42, o diagrama responsável pelo envio da mensagem por parte dos nós âncoras da rede de sensores e o respectivo algoritmo e código equivalente.



powered by Astah

Figura 42 - Fluxograma - nó âncora

Algoritmo2 – Âncoratinyos

- 1 Início
- 2 Iniciar nós âncoras
- 3 Enquanto(verdadeiro)
- 4 Enviar mensagem broadcast
- 5 Se(usarled)

6 Ligar led indicativo de envio de mensagem
 7 Aguardar 250 milissegundos
 8 Fim

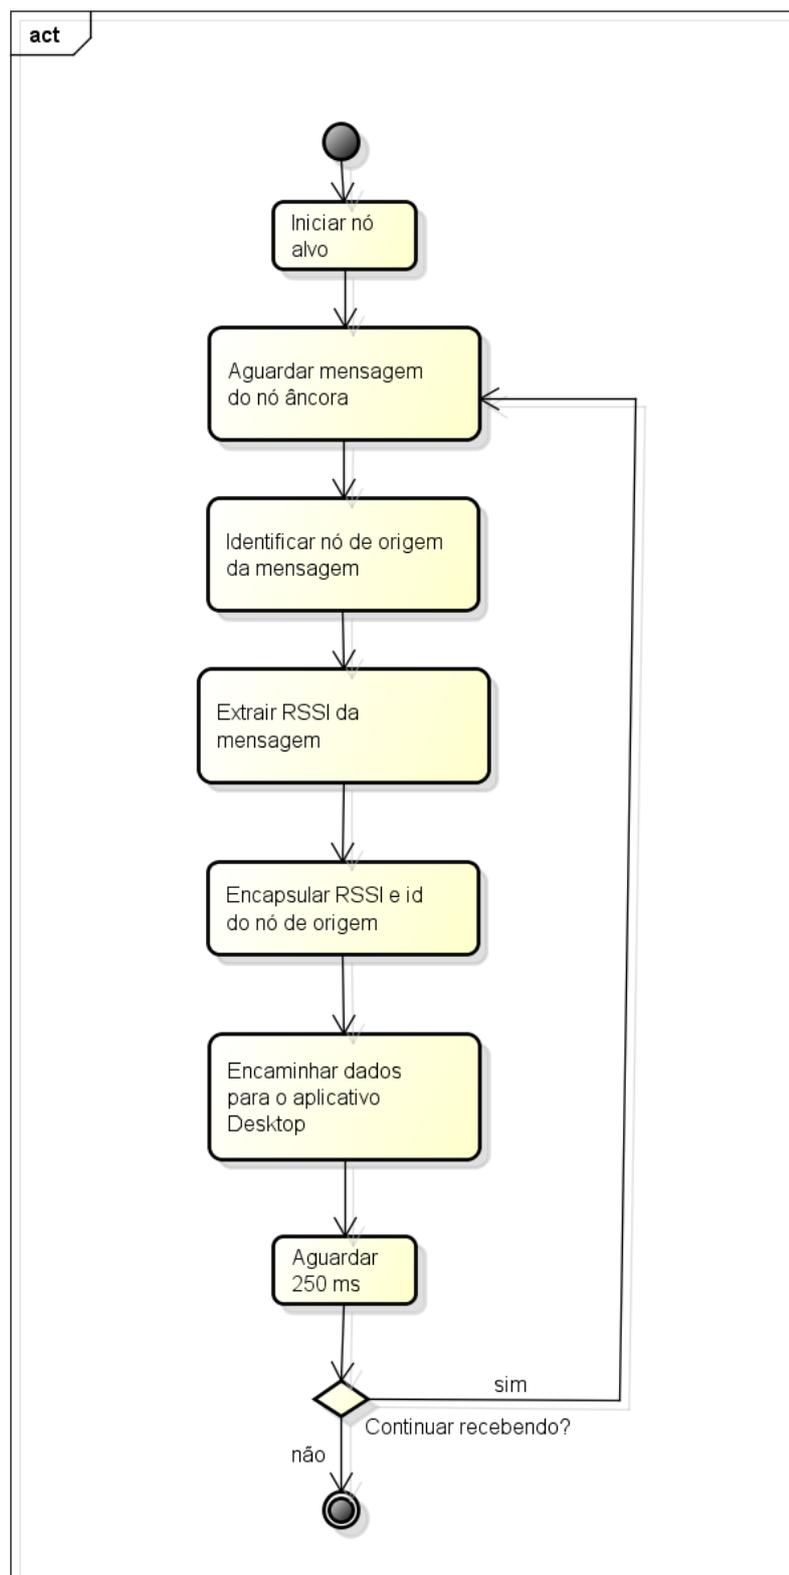
Código 1 – Âncoratinhos

```

1      #include "ApplicationDefinitions.h"
2      #include "RssiDemoMessages.h"
3
4      moduleSendingMoteC {
5      uses interface Boot;
6          uses interface Timer<TMilli> as SendTimer;
7
8          uses interface AMSend as RssiMsgSend;
9          uses interface SplitControl as RadioControl;
10      }implementation {
11      message_tmsg;
12
13      eventvoidBoot.booted(){
14      callRadioControl.start();
15      }
16
17      event void RadioControl.startDone(error_t result){
18          call SendTimer.startPeriodic(SEND_INTERVAL_MS);
19      }
20
21      event void RadioControl.stopDone(error_t result){ }
22
23      eventvoidSendTimer.fired(){
24          call RssiMsgSend.send(AM_BROADCAST_ADDR, &msg, sizeof(RssiMsg));
25      }
26
27      event void RssiMsgSend.sendDone(message_t *m, error_t error){ }
28      }

```

Os dados serão recebidos pelo nó alvo obtendo seu RSSI extraído como exemplificado por diagrama e codificação.



powered by Astah

Figura 43 - Fluxograma nó alvo

Algoritmo3 – Alvotinyos

```

1      Inicio
2      Iniciar nós âncoras
3      Enquanto(verdadeiro)
4          Receber mensagem
5          Identificar nó de origem
6          Extrair o RSSI da mensagem
7          Encapsular RSSI e id do nó de origem
8          Encaminhar dados para o aplicativo desktop
9      Se(usarled)
10     Ligar led indicativo de recepção de menságem
11     Aguardar 250 milissegundos
12     Fim

```

Código2 – Alvotinyos

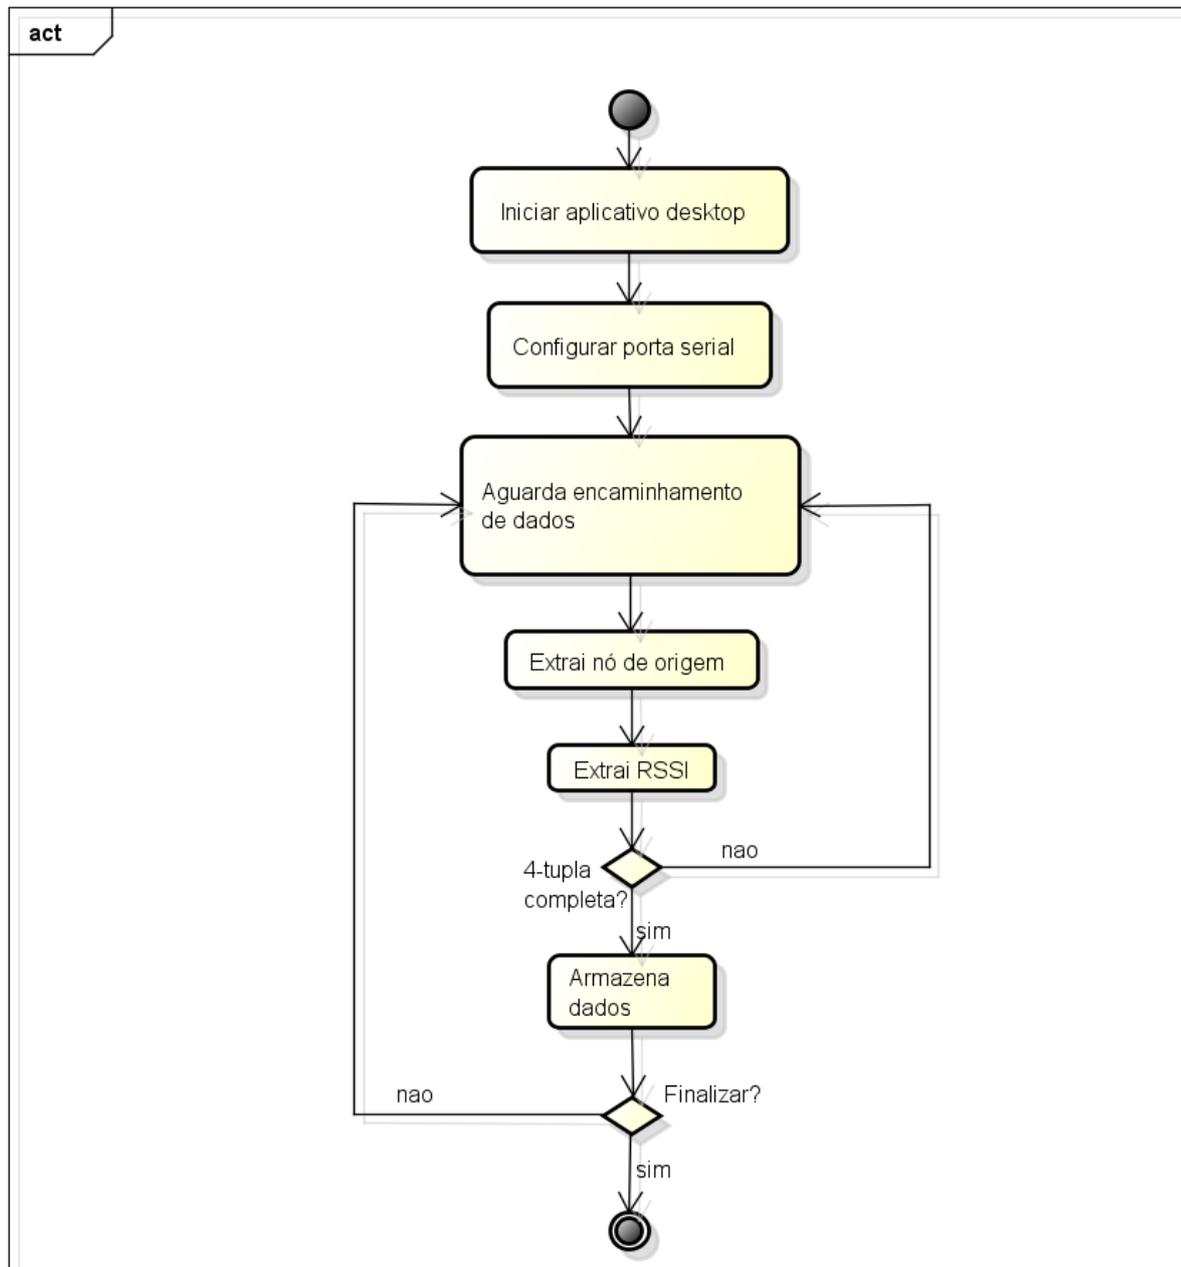
```

1      #include "ApplicationDefinitions.h"
2      #include "RssiDemoMessages.h"
3
4      moduleRssiBaseC {
5      uses interface Intercept as RssiMsgIntercept;
6
7      #ifdef __CC2420_H__
8      uses interface CC2420Packet;
9      #elif defined(TDA5250_MESSAGE_H)
10     uses interface Tda5250Packet;
11     #else
12     uses interface PacketField<uint8_t> as PacketRSSI;
13     #endif
14     }implementation {
15
16     uint16_t getRssi(message_t *msg);
17
18     event boolRssiMsgIntercept.forward(message_t *msg, void *payload, uint8_t len) {
19
20     RssiMsg *rssiMsg = (RssiMsg*) payload;
21     rssiMsg->rssi = getRssi(msg);
22
23     return TRUE;
24     }
25
26     #ifdef __CC2420_H__
27     uint16_t getRssi(message_t *msg){
28     return (uint16_t) call CC2420Packet.getRssi(msg);
29     }
30     #elif defined(CC1K_RADIO_MSG_H)
31     uint16_t getRssi(message_t *msg){
32     cc1000_metadata_t *md =(cc1000_metadata_t*) msg->metadata;
33     return md->strength_or_preamble;
34     }

```

```
35  #elif defined(PLATFORM_IRIS) || defined(PLATFORM_UCMINI)
36      uint16_t getRssi(message_t *msg){
37          if(call PacketRSSI.isSet(msg))
38              return (uint16_t) call PacketRSSI.get(msg);
39      Else
40          return 0xFFFF;
41      }
42  #elif defined(TDA5250_MESSAGE_H)
43      uint16_t getRssi(message_t *msg){
44          return call Tda5250Packet.getSnr(msg);
45      }
46  #else
47      #error Radio chip not supported! This demo currently works only \
48      for motes with CC1000, CC2420, RF230, RFA1 or TDA5250 radios.
49  #endif
50  }
```

Estes dados por sua vez são encaminhados para a porta serial da interface desktop, que recebe os dados com auxílio da biblioteca *tinynos.jar* que dispõe de toda a camada de comunicação necessária para esta tarefa, já atuando diretamente no protocolo de comunicação com o TinyOS para troca de mensagens via interface serial. A Figura 44 e Algoritmo 4 ilustram a implementação desktop da recepção dos dados do RSSI.



powered by Astah

Figura 44 - Fluxograma do agente Desktop

Algoritmo4 – Receptor Desktop

- 1 Iniciar
- 2 Configurar porta serial
- 3 Enquanto (verdadeiro)
- 4 Receber mensagem
- 5 Identificar nó de origem
- 6 Extrair RSSI
- 7 Se 4-tupla completa
- 8 Armazenar resultados

9 Fim

Código3 – Receptor Desktop

```

1    import java.io.IOException;
2
3    import net.tinyos.message.*;
4    import net.tinyos.packet.*;
5    import net.tinyos.util.*;
6
7    public class RssiDemo implements MessageListener {
8
9        private MoteIF moteIF;
10
11       public RssiDemo(MoteIF moteIF) {
12           this.moteIF = moteIF;
13           this.moteIF.registerListener(new RssiMsg(), this);
14       }
15
16       public void messageReceived(int to, Message message) {
17           RssiMsg msg = (RssiMsg) message;
18           int source = message.getSerialPacket().get_header_src();
19           System.out.println("Rssi Message received from node " + source + ": Rssi = " +
20               msg.get_rssi());
21       }
22
23       private static void usage() {
24           System.err.println("usage: RssiDemo [-comm<source>]");
25       }
26
27       public static void main(String[] args) throws Exception {
28           String source = "serial@/dev/ttyUSB1:iris";
29
30           PhoenixSource phoenix = BuildSource.makePhoenix(PrintStreamMessenger.err);
31           MoteIF mif = new MoteIF(phoenix);
32           RssiDemo serial = new RssiDemo(mif);
33
34       }
35   }

```

A partir deste código, é possível extrair o RSSI da mensagem, e aplicar a diversas técnicas de localização assim como para uso em QoS, nota-se que o caminho a partir da porta USB 1 é realizado pelo caminho do diretório de dispositivos do sistema, além de explicitar que o mote com o qual deseja se comunicar é a plataforma IRIS.

Apêndice B. Ambientes de teste.

Os locais para a realização de teste foram selecionados a partir da característica do ambiente. Para o ambiente *indoor*, os testes foram realizados no ginásio de educação física da Universidade Federal do Pará (UFPA) dada suas características de ambiente controlado *indoor*, com suas demarcações que auxiliaram e facilitaram a realização dos testes. A Figura 45 apresenta a vista externa do local, e a Figura 46 apresenta a vista interna



Figura 45 - Ginásio da UFPA (vista externa). Fonte: <http://www.portal.ufpa.br>



Figura 46 - Ginásio da UFPA (vista interna). Fonte: <http://www.portal.ufpa.br>

Dada as demarcações existentes na área poliesportiva, os testes foram conduzidos a partir destas marcas, auxiliando desta forma a demarcação dos pontos dos nós âncoras a partir dos vértices demarcados da área. As Figuras 47 e 48 apresenta um nó da RSSF no marco zero ou coordenada (0,0) do experimento.



Figura 47 - Nós da RSSF no ambiente de testes



Figura 48 - Nó localizado na origem

No ambiente *outdoor*, as demarcações foram realizadas manualmente utilizando pequenas superfícies para posicionar os nós evitando que os mesmos tivessem contato direto com o solo. As Figuras 49 e 50 apresentam o local de testes *outdoor* a partir da vista aérea.



Figura 49 - Vista aérea do local de testes *outdoor*



Figura 50 - Vista aérea com visualização da área adjacente

A Figura 49 apresenta a vista do local de testes com maior proximidade, enquanto a Figura 50 apresenta dentro do panorama das adjacências referentes ao local de teste. A área na qual os testes foram realizados são demarcadas em vermelho.