



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

**Eduardo Costa de Carvalho**

**Investigação em Arquiteturas de Redes sem Fio  
para Localização em Ambientes Internos  
Usando Aprendizado de Máquina**

Belém-Pará

2016



Eduardo Costa de Carvalho

**Investigação em Arquiteturas de Redes sem Fio para  
Localização em Ambientes Internos Usando Aprendizado  
de Máquina**

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. Orientador Prof. Dr. Gustavo Pessin.

Universidade Federal do Pará – UFPA

Faculdade de Computação

Programa de Pós-Graduação em Ciência da Computação

Orientador: Dr. Gustavo Pessin

Belém-Pará

2016

Dados Internacionais de Catalogação-na-Publicação (CIP)  
Sistema de Bibliotecas da UFPA

---

Carvalho, Eduardo, 1989-

Investigação em arquiteturas de redes sem fio para localização em ambientes internos usando aprendizado de máquina / Eduardo Carvalho. - 2016.

Orientador: Gustavo Pessin.

Dissertação (Mestrado) - Universidade Federal do Pará, Instituto de Ciências Exatas e Naturais, Programa de Pós-Graduação em Ciência da Computação, Belém, 2016.

1. Arquitetura e tecnologia. 2. Inovações tecnológicas-Localização. 3. Sistemas de comunicação sem fio. 4. Tecnologia ambiental. 5. Aprendizagem de máquinas-Métodos inteligentes-Ambientes internos. I. Título.

CDD 22. ed. 004.65

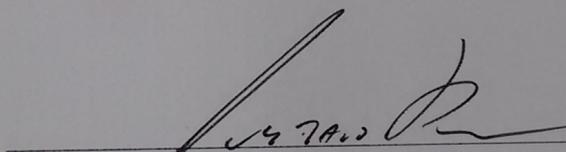
---

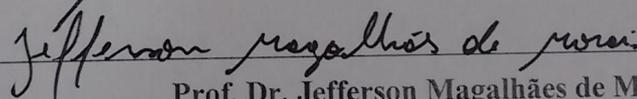
UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE CIÊNCIAS EXATAS E NATURAIS  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

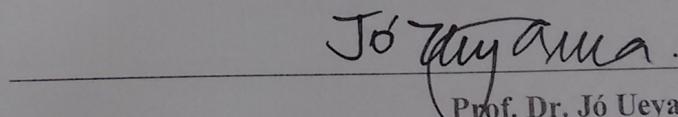
**EDUARDO COSTA DE CARVALHO**

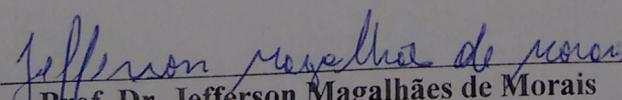
**INVESTIGAÇÃO EM ARQUITETURAS DE REDES SEM FIO PARA  
LOCALIZAÇÃO EM AMBIENTES INTERNOS USANDO  
APRENDIZADO DE MÁQUINA**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal do Pará como requisito para obtenção do título de Mestre em Ciência da Computação, defendida e aprovada em 29/04/2016, pela banca examinadora constituída pelos seguintes membros:

  
Prof. Dr. Gustavo Pessim  
Orientador – PPGCC/UFPA

  
Prof. Dr. Jefferson Magalhães de Moraes  
Membro Interno – PPGCC/UFPA

  
Prof. Dr. Jó Ueyama  
Membro Externo – USP

Visto:   
Prof. Dr. Jefferson Magalhães de Moraes  
Coordenador do PPGCC/UFPA

Prof. Dr. Jefferson Magalhães de Moraes  
Coordenador do PPGCC  
Mat.: SIAPE: 2378314

*Este trabalho é dedicado aos membros da minha família, que sempre acreditaram no potencial que os seres humanos têm de alcançar grandes objetivos.*

# Agradecimentos

Os agradecimentos principais são direcionados à minha família, em especial ao pai Luiz Carlos Vieira de Carvalho, *in memoriam*, a pessoa na qual sempre me espelhei para todos os objetivos que procuro chegar em minha vida. Agradeço muito a minha mãe Narcleide Socorro Costa de Carvalho que me apoia em todas as tarefas e decisões que tomo para meu futuro, bem como minhas duas irmãs e sobrinho, a quem quero mostrar como podemos chegar longe. Agradeço também a Thais de Mendonça Petta, companheira para todas as ocasiões. Ao meu orientador Gustavo Pessin, por todas as ideias no decorrer do projeto. Aos colegas de laboratório: Bruno Ferreira (UFPA), Marcelo Silva (UFPA), Leon Cardoso (ITV), Gerson Serejo (ITV), Helder Arruda (ITV) e Andres H. Gutierrez (ITV), por suas ajudas e ideias, além dos parceiros de outra universidade: Diego Damasceno (ICMC-USP), Geraldo Pereira (ICMC-USP), Bruno Faiçal (ICMC-USP) e Jó Ueyama (ICMC-USP). Além do agradecimento a fundação CAPES, por seu apoio financeiro no andar do curso.



*“ Não há nada nobre em  
sermos superiores ao próximo.  
A verdadeira nobreza consiste  
em sermos superiores ao que  
eramos antes.”*

*Esopo.*



# Resumo

Localização em ambientes *indoor* tem sido uma área de pesquisa muito ativa nas últimas décadas. Grande parte das pesquisas foram direcionadas ao contexto de atividades robóticas. Embora as tecnologias de sensores e as técnicas propostas para a localização de robôs em ambientes internos tenham apresentado soluções cada vez mais confiáveis, estas apresentam dificuldades se adotadas como solução para localização de pessoas em ambientes internos, particularmente, devido ao seu alto custo computacional, uso de energia e peso dos sensores. Para mitigar esses problemas, uma solução tecnológica de detecção com baixo consumo de energia, com base em sinais de potência do WiFi, é estudada nesse trabalho. No entanto, há uma preocupação quando se trabalha com estes sinais, que é a sua vulnerabilidade a interferências. Assim, a dissertação explora o uso de aprendizagem de máquina em duas arquiteturas diferentes para a localização e apresenta como uma técnica de filtragem de dados pode atenuar as interferências. Ainda, um passo para uma abordagem de tolerância a falhas é estudada para uma das estratégias, apresentando que o sistema utilizado pode manter uma determinada confiabilidade, mesmo perdendo alguns de seus nós.

**Palavras-chave:** Localização. Localização em Ambientes Internos. Estratégias Inteligentes.



# Abstract

Indoor localization has been a very active research area in recent decades. Much of the researches were directed to the context of robotic activities. Although the sensor technologies and technical proposals for the localization of robots in indoor environments have presented increasingly reliability, they cannot be adopted as a solution to locate people indoors, particularly due to its high computational cost, energy needs, and weight of the sensors. In order to mitigate these problems, a method with low computational needs and low energy consumption, based on Wi-Fi signals strength, is proposed in this dissertation. Nevertheless, a concern when working with these signals is their vulnerability to interferences. This dissertation exploits the use of machine learning in two different architectures for localization and presents how a data filtering technique can alleviate interferences. A step into a fault tolerance approach is also given, presenting that the system can maintain certain reliability even losing some of its parts.

**Keywords:** Localization. Indoor Localization. Smart Strategies.



# Lista de ilustrações

Figura 1 – Exemplo de AOA em duas fontes de sinais para dois dispositivos presos aos ouvidos de uma pessoa (BRICE, 2001). . . . .	28
Figura 2 – Esquema de transmissão com TOA (FARID; NORDIN; ISMAIL, 2013). . . . .	29
Figura 3 – Exemplos de Limites mínimos e máximos com RSSI (BOUKERCHE et al., 2007). . . . .	30
Figura 4 – Exemplo de comportamento de filtro de mediana móveis. A linha azul mostra o valor bruto de um dos pontos de aceso. A linha preta mostra como o filtro remove alguns ruídos (PESSIN et al., 2013). . . . .	31
Figura 5 – Exemplo de esquema com KNN (THIRUMURUGANATHAN, 2010). . . . .	34
Figura 6 – Esquema de uma rede neural com quatro camadas, sendo as camadas de 1 a 4 sendo ocultas e as três setas representadas indicam as saídas da rede (KHATCHATOURIAN; PADILHA, 2008). . . . .	35
Figura 7 – Conjuntos em SVM com: (a) Hiperplanos: em que a separação de dois conjuntos é ótima e linearmente separáveis; (b) Vetores de suporte: em que são dados pertencentes a um conjunto à uma distância conhecida (BELTRAMI, 2009) (ALES, 2008). . . . .	36
Figura 8 – Mapa de cores da <i>International Space Station</i> ISS, em que (a) Coletas de RSSI para o primeiro <i>dataset</i> , (b) Coletas de potência em RSSI para o segundo <i>dataset</i> , e (c) Junção das duas coletas em um mapa de cor (YOO et al., 2014). . . . .	37
Figura 9 – Experimento apresentado em Schneider, Andreão e Nunes (2011), conta com o mapeamento prévio com <i>Fingerprint</i> e mapas de potências, juntamente com o resultado do experimento realizado com 2 e 3 estações base indicam que um erro menor que 2 metros para cerca de 80% para todos os testes com 2 estações base e de 92% para todos os testes com 3 estações base. . . . .	39
Figura 10 – Comparação de performace do método de localização de âncoras livres em Pei et al. (2009). . . . .	40
Figura 11 – Planta-baixa do ambiente testado. No próprio estão identificadas as posições dos roteadores (R1, R2, R3) e as posições de coletas (C1, C2, C3, C4, C5). . . . .	44

Figura 12 – Duas Arquiteturas avaliadas. (a) Localização <i>indoor</i> pessoal: pessoa deve ter um dispositivo que recebe RSSI de roteadores e emprega aprendizagem de máquina para obter a sua localização. (b) Localização <i>indoor</i> assistida: A pessoa deve ter um dispositivo emissor e roteadores comunicam-se entre eles para compartilhar percepções RSSI, em seguida, um nó coordenador emprega aprendizagem de máquina para obter a localização pessoa. . . . .	45
Figura 13 – Esquema de entrada e saída do sistema de localização utilizado nas duas arquiteturas. . . . .	46
Figura 14 – Diagrama de coleta de dados. . . . .	47
Figura 15 – Diagrama do processo de tolerância a falhas. . . . .	50
Figura 16 – Gráfico com a intensidade de sinal (RSSI) nas 5 coletas para a estratégia de localização <i>indoor</i> pessoal. Percebe-se a dispersão das leituras entre os roteadores dispostos na rede para a localização da pessoa em forma de sinal em decibéis. . . . .	51
Figura 17 – Comparações das taxas de acerto nos algoritmos de aprendizado de máquinas para os métodos com três diferentes kernels, para cada um dos métodos na arquitetura 1 de localização <i>indoor</i> pessoal. . . . .	52
Figura 18 – Mapa em árvore ( <i>treemap</i> ) para a arquitetura 1 apresentando tamanho das caixas e cores em relação a taxa de acerto. O gráfico ajuda a perceber que o filtro tem mais impacto que o método de aprendizado utilizado. Acumulados em verde escuro na parte superior esquerda estão todos os métodos com filtro de 10 medidas. Acumulados no canto inferior direito estão todos os métodos sem filtro. Sendo que o melhor método foi o KNN (1-D). . . . .	53
Figura 19 – Gráfico com a intensidade de sinal (RSSI) nas 5 coletas para a estratégia de localização <i>indoor</i> assistida. Percebe-se a dispersão das leituras entre os roteadores dispostos na rede para a localização da pessoa em forma de sinal em decibéis. . . . .	55
Figura 20 – Comparações das taxas de acerto nos algoritmos de aprendizado de máquinas para os métodos com três diferentes kernels, para cada um dos métodos na arquitetura 2 de localização <i>indoor</i> assistida. . . . .	56
Figura 21 – Mapa em árvore ( <i>treemap</i> ) para a arquitetura 2 apresentando tamanho das caixas e cores em relação a taxa de acerto. O gráfico ajuda a perceber que o filtro tem mais impacto que o método de aprendizado utilizado. Acumulados em verde escuro na parte superior esquerda estão todos os métodos com filtro de 10 medidas. Acumulados no canto inferior direito estão todos os métodos sem filtro. Sendo que o melhor método continuou sendo o KNN. . . . .	57

Figura 22 – Indicação de taxas de acerto com janelas de médias móveis de 10 posições para tolerância a falhas nos Roteadores do experimento. Retirada de um dos roteadores para o caso do KNN com médias de dez posições. . 58



# Lista de tabelas

Tabela 1 – Comparativo entre trabalhos relacionados . . . . .	41
Tabela 2 – Variações dos métodos de aprendizado de máquinas realizados no WEKA	48
Tabela 3 – Matriz de confusão de um dos melhores casos do método inteligente KNN (NW) (Figura 17), com janela de média móvel de dez posições, no esquema de localização <i>indoor</i> pessoal . . . . .	54
Tabela 4 – Matriz de confusão do melhor caso do método inteligente KNN (NW) (Figura 20), com janela de média móvel de 10 posições, no esquema de localização <i>indoor</i> assistida . . . . .	58



# Lista de abreviaturas e siglas

AOA	<i>Angle of Arrival</i>
EUA	Estados Unidos da América
FM	Frequência Modulada
GPS	<i>Global Positioning System</i>
IEEE	Instituto de Engenheiros Eletricistas e Eletrônicos
IMU	<i>Inertial Measurement Unit</i>
KNN	<i>k-Nearest Neighbors</i>
LAN	<i>Local Area Network</i>
LLC	<i>Logical Link Control</i>
MAC	<i>Media Access Control</i>
ML	<i>Machine Learning</i>
MLP	<i>Multilayer Perceptron</i>
OSI	<i>Open Systems Interconnection</i>
RBF	<i>Radial Base Function</i>
RNA	Redes Neurais Artificiais
RSSF	Redes de Sensores sem Fio
RSSI	<i>Received Signal Strength Indication</i>
SVM	<i>Support Vector Machines</i>
TOA	<i>Time of Arrival</i>
TDOA	<i>Time Difference of Arrival</i>
UWB	<i>Ultra-WideBand</i>
WLAN	<i>Wireless Local Area Network</i>
WLS	<i>Wireless LAN Services</i>



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>23</b>
1.1	Contextualização e justificativa	23
1.2	Objetivos	25
1.3	Estrutura da Dissertação	26
<b>2</b>	<b>LOCALIZAÇÃO EM REDES DE SENSORES SEM FIO</b>	<b>27</b>
2.1	Técnicas de localização sem GPS	27
2.1.1	<i>Angle of Arrival</i>	27
2.1.2	<i>Time of Arrival</i>	28
2.1.3	<i>Time Difference of Arrival</i>	29
2.1.4	<i>Received signal strength indication</i>	30
2.2	Diminuição de Ruídos	31
2.3	Tolerância a Falhas em RSSF	32
2.4	Técnicas Inteligentes	33
2.4.1	<i>K-Nearest Neighbors</i>	33
2.4.2	Redes Neurais Artificiais	34
2.4.3	<i>Support vector machine</i>	35
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>37</b>
3.1	Discussão dos Trabalhos Relacionados	40
<b>4</b>	<b>CONFIGURAÇÕES DE ARQUITETURAS DE TESTE</b>	<b>43</b>
4.1	As arquiteturas propostas: Localização <i>indoor</i> pessoal e Localização <i>indoor</i> assistida	45
4.2	Fase de coleta	46
4.2.1	WEKA	47
4.3	Filtro de médias móveis	48
4.4	Tolerância a Falhas	49
<b>5</b>	<b>ANÁLISES COMPARATIVAS</b>	<b>51</b>
5.1	Arquitetura 1: Localização <i>indoor</i> pessoal	51
5.2	Arquitetura 2: Localização <i>indoor</i> assistida	55
5.2.1	Tolerância a Falhas	58
<b>6</b>	<b>CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS</b>	<b>61</b>
6.1	Trabalhos Futuros	62

**REFERÊNCIAS** ..... 63

# 1 Introdução

## 1.1 Contextualização e justificativa

Ambientes fechados como minas subterrâneas, cavernas, casas ou prédios são caracterizados como ambientes que possuem limitações de acesso. Esta limitação de acesso é um grande problema em caso de acidentes como: deslizamentos de terra em uma mina subterrânea ou um incêndio em um prédio. Buscando aumentar a segurança e capacidade de resgate, é imprescindível uma tecnologia de localização (JUNIOR; MADEIRA, 2005). De acordo com o departamento dos Bombeiros dos EUA (DEPARTMENT, 2012), no período entre 2003-2012, o número de incêndios em residências foi de mais de 3,5 milhões. Nesses casos 24.720 pessoas vieram a óbito, 132.450 pessoas foram feridas e U\$ 74,8 bilhões de dólares perdidos. Enquanto que incêndios em prédios não residenciais chegaram a 957.300 casos, com 875 óbitos, 13.300 pessoas feridas e U\$ 28 bilhões de dólares perdidos. Assim, a criação de uma tecnologia de baixo custo e fácil manuseio, para localização de pessoas em ambientes internos se torna essencial. Por esses e diversos outros motivos, trabalhos com aplicações reais vem ganhando mais espaço em ambientes internos, pois a segurança de pessoas tem extrema relevância para qualquer empresa ou órgão.

Uma vasta gama de tecnologias tem sido investigada para a localização de pessoas em ambientes internos nas últimas décadas, tais como (i) unidades de medição inercial (IMU), (ii) laser, (iii) sensores de visão, ou uma combinação destes. Entretanto ainda é um campo de pesquisa em aberto, haja vista que IMU apresenta erros incrementais (RUIZ et al., 2012), câmeras apresentam restrições de campos de acesso limitado e dificuldades relacionadas a iluminação, como em Kim e Jun (2008), bem como trabalhos de localização com laser, como o de Zhou, Liu e Huang (2007) possuem limitações de tamanhos de equipamentos e orçamento, por se tratarem de equipamentos de alto custo. Por outro lado, técnicas de localização de robôs obtiveram bons resultados em ambientes internos, como na utilização de laser para localização de robôs no experimento de Zhou, Liu e Huang (2007), que propôs que uma combinação de sistemas com laser com RFID e visão pudessem se localizar em ambientes internos com triangulação, como em um *Global Positioning System* (GPS) para ambientes internos, embora o uso destas tecnologias não seja viável para a localização de pessoas em virtude do peso dos equipamentos e elevado custo computacional de processamento dos dados recolhidos pelos sensores que são utilizados. Assim, um tipo diferente de metodologia tem sido investigada, que faz uso de *Received Signal Strength Indication* (RSSI), impulsionado pelo grande número de dispositivos que fazem uso dele como *notebooks*, telefones celulares e *tablets*, assim formando uma fonte alternativa ao GPS, para ser utilizada em ambientes internos (STOJANOVIC; STOJANOVIC, 2014).

Segurança de pessoas ou equipamentos importantes em ambientes internos pode ser melhorada com um sistema de localização. Isto considerado, alguns estudos têm sido realizados para propor soluções para esta situação. Existem duas abordagens mais comuns, (i) uma abordagem pessoal, no qual um sensor acoplado na pessoa estima a sua própria posição, em relação a uma rede de sensores sem fio e (ii) uma abordagem de rede, em que a rede calcula a posição das pessoas dentro do ambiente e informa a localização a pessoa ou a um sistema. Com dados de posições, ou de potências (RSSI) coletados em um ambiente real, técnicas de classificação são amplamente utilizadas para a estimativa de posições, como o uso de algoritmos de aprendizado de máquina, tais como K vizinhos mais próximos (KNN), Redes Neurais Artificiais (RNA) e *Support Vector Machines* (SVM). O uso desses algoritmos de aprendizagem combinados com técnicas de filtragem de dados, tais como o uso de janelas de médias móveis, são alternativas para a redução do ruído na coleta de dados (RSSI) e, portanto, pode eventualmente diminuir o número de erros na classificação das posições a serem previstas. Além disso, técnicas de tolerância de falhas devem ser almejadas para manter o sistema funcionando em caso de um incêndio que pode destruir algum nó que forma a rede, seja na primeira abordagem mencionada, ou na segunda, podendo gerar problemas de localização, entretanto, ainda assim o sistema deve ser capaz de estimar a posição das pessoas dentro de certo grau de precisão.

Com base nesse contexto esse trabalho busca contribuir com o campo da rede de computadores, por meio das redes de sensores sem fio, aplicadas em ambientes reais. Outra contribuição é a comparação entre dois tipos de arquiteturas, divididas em dois cenários de teste. O primeiro cenário a pessoa emite um sinal *broadcast* a um grupo de sensores que estão esperando ouvir esse comando, então uma posição é estimada. A segunda arquitetura é o inverso, um dispositivo acoplado a uma pessoa recebe o sinal de outros sensores e também estima uma posição por meio de classificação, com a utilização de métodos de aprendizado de máquinas (KNN, RNA e SVM), comparando os métodos entre si, utilizando técnicas de filtros de janelas móveis, e para o melhor caso dessa segunda arquitetura, a utilização de uma técnica de tolerância a falhas no *hardware* utilizado.

Com posse de duas diferentes arquiteturas, o trabalho espera comparar as coletas dos dispositivos e testar três tipos de métodos inteligentes, que são: KNN, RNA e o SVM. Nesse sentido a intenção é avaliar as classificações de taxas de acerto das posições da respectiva pessoa para três diferentes *kernel* dos algoritmos e avaliar os respectivos cenários, além de apresentar o melhor algoritmo a ser levado em conta no experimento conduzido. A utilização desses algoritmos de aprendizado, combinado com técnicas de filtragem de dados, como utilização de Janelas de Medianas Móveis, ou Janelas de Médias Móveis, é alternativa para diminuição do ruído nas coletas de sinais RSSI, e assim possivelmente diminuir erros de classificações de posições (PESSIN et al., 2013). A pesquisa bibliográfica indica que os trabalhos comparam os métodos de aprendizado de máquina com alguma alteração do próprio método, como em Jekabsons, Kairish e Zuravlyov (2011), em que os

autores comparam o KNN com uma variação do mesmo, o WKNN. A comparação com mais de uma técnica de aprendizado de máquina geralmente utiliza o MLP e outro método, como o KNN, por exemplo, além de que a natureza desses trabalhos é a de estudar apenas uma arquitetura, dessa forma a comparação de métodos em diferentes arquiteturas é uma contribuição desse trabalho. Outra contribuição do trabalho é a questão de tolerância à falha, que também não é muito vista nos trabalhos da bibliografia pesquisada, e como em ambientes internos, como em uma caverna ou mina subterrânea situações de quebra de equipamento podem ocorrer. A posição ainda deveria ser classificada e estimada, nesse sentido a retirada de um nó na coleta simularia essa adversidade e indicaria uma nova posição da pessoa no ambiente.

Pontualmente, neste documento serão feitas referências aos trabalhos publicados pelo autor durante o período do mestrado, as mesmas estão listadas a seguir:

- Carvalho, E. C., Pereira, G., Façal, B. S., Gutierrez, A. H., Ueyama, J., Pessin, G. Avaliação de Métodos de Aprendizado de Máquina para Localização de Pessoas em Ambientes Internos. In: III Workshop of Communication in Critical Embedded Systems, 2015, Vitória (ES). Anais do WoCCES 2015, 33o Simpósio Brasileiro de redes de computadores e sistemas distribuídos, 2015. p. 21-30.
- Carvalho, E. C., Façal, B. S., Pereira, G., Vargas, P. A., Ueyama, J., Pessin, G. Exploiting the use of Machine Learning in two Different Sensor Network Architectures for Indoor Localization. In: 2016 IEEE International Conference on Industrial Technology (ICIT2016), p. 652-657.

É importante ressaltar que a área na qual essa dissertação se insere tem relação com projetos em colaboração entre a Universidade Federal do Pará, a Universidade de São Paulo (ICMC-USP), onde o aluno realizou visita técnica, o Instituto Tecnológico Vale e a Heriot-Watt Universty (Reino Unido).

## 1.2 **Objetivos**

O trabalho busca, principalmente, por um método de localização alternativo ao GPS (para emprego em ambientes internos) que seja fácil, prático e barato de implementar, capaz de localizar pessoas e objetos, com auxílio de métodos inteligentes para classificação.

Para chegar a esse fim, objetivos específicos devem ser realizados, esses são:

- Investigação, desenvolvimento e avaliação de arquiteturas para localização de pessoas/objetos usando sinal de potência de redes sem fio (IEEE 802.11) e aprendizado de máquina;

- Desenvolvimento e avaliação de dois cenários para localização de pessoas e objetos, um identificando uma pessoa/objeto através de uma rede de sensores sem fio, e o segundo em que uma pessoa/objeto informa a rede de sensores sem fio a sua localização;
- Avaliação de diferentes algoritmos de aprendizado de máquina buscando verificar qual deles permitam o aprendizado com maior acurácia;
- Proposta e investigação de filtros de médias móveis, a serem aplicados sobre o sinal lido dos roteadores, a fim de avaliar o comportamento geral dos modelos, bem como do aprendizado dos algoritmos de aprendizado de máquina;
- Avaliação dos algoritmos de aprendizado de máquina considerando diferentes quantidades de roteadores, a fim de avaliar como o aprendizado se comporta com mais ou menos pontos de acesso disponíveis. Essa diminuição nos pontos de acesso é relacionada a tolerância a falhas.

### 1.3 Estrutura da Dissertação

A presente dissertação está disposta em seis Capítulos, além do Capítulo introdutório, tem-se:

- Capítulo 2: Apresenta uma introdução sobre localização em redes de sensores sem fio, indicando e conceituando as bases da mesma com os conceitos de *angle of arrival*, *time of arrival*, e *time difference of arrival*, até a localização com a utilização de potências com RSSI e o tratamento das informações com métodos inteligentes.
- Capítulo 3: Apresenta os trabalhos relacionados que vêm sendo realizados ao longo dos anos mais recentes, indicando as fraquezas e os pontos fortes de cada um.
- Capítulo 4: Apresenta as configurações de arquiteturas dos testes realizados, indica a metodologia utilizada para cada coleta em cada arquitetura, como a filtragem dos dados foi realizada, e os itens de software utilizados para a predição com aprendizado de máquina, bem como o processo de tolerância a falhas utilizadas.
- Capítulo 5: Apresenta as análises comparativas, que concentram os resultados coletados nos cenários de teste e indicam quais foram os algoritmos mais indicados para cada um dos mesmos, bem como análises por meio de gráficos de verificações de ruídos e tolerância a falhas.
- Capítulo 6: Apresenta as considerações finais e trabalhos futuros, mostra a conclusão do trabalho e os próximos passos do referido trabalho.

## 2 Localização em redes de sensores sem fio

Este Capítulo apresenta os conceitos de *angle of arrival*, *time of arrival*, e *time difference of arrival*, a utilização de potências com RSSI e o tratamento de informações com métodos inteligentes, apresentados com o *K-Nearest Neighbors*, Redes Neurais Artificiais e *Support vector machine*. Assim algumas técnicas de localização alternativas ao GPS foram se aperfeiçoando, como: (i) *Angle of Arrival*; (ii) *Time of Arrival*; (iii) *Time Difference of Arrival*; (iv) RSSI. Além das técnicas alternativas ao GPS, alguns tratamentos aos dados podem ser realizados com aplicações de filtros e tratamentos de tolerância a falhas, juntamente com técnicas de aprendizado de máquinas, como as mencionadas anteriormente.

### 2.1 Técnicas de localização sem GPS

#### 2.1.1 *Angle of Arrival*

*Angle of Arrival*, ou AOA, são medidas por meio de amplitudes de antenas de um receptor, ou através da fase do receptor. Interferências acontecem com frequência nessa forma de localização, pois, o direcionamento da antena interfere nas análises; além de fatores ambientais, como presença de objetos dinâmicos: árvores ou paredes por exemplo; além do conceito de sombreamento e caminhos múltiplos (*multipath*), em que os caminhos múltiplos ocasionam diversas induções de erros a fim de encontrar o receptor (BOUKERCHE et al., 2007). As medições em AOA possuem duas categorias principais: formação de feixe, interferometria .

Anisotropia é a base da medição por meio de formação de feixe, e esta significa uma característica de objetos físicos que variam de acordo com a direção. Sendo que o cálculo da direção de onde se encontra o transmissor segue de acordo com o recebimento da força máxima do sinal e na sensibilidade e largura de feixe do receptor. A formação de feixe pode possuir antenas fixas que se comunicam entre si, em conjunto de antenas anisotrópicas, ou com a utilização de um feixe não rotativo juntamente com feixes rotativos, assim a variação de intensidade do sinal pode ser removida em grande parte, normalizando a intensidade do sinal recebido pela antena rotativa anisotrópica referente à potência do sinal recebido pela antena omnidirecional não rotativa. Esses tipos de formação servem para minimizar erros em feixes de rotação, a Figura 1 indica AOA em um ambiente de teste com ouvidos humanos. A interferometria é caracterizada pela sobreposição de duas ou mais entradas de dados, e que a partir das medições AOA perceber diferenças entre uma onda eletromagnética e as fases de chegada. A utilização de uma antena maior no receptor ou um conjunto de antenas é primordial quando se utiliza esta técnica.

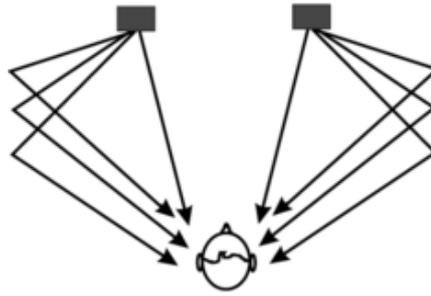


Figura 1: Exemplo de AOA em duas fontes de sinais para dois dispositivos presos aos ouvidos de uma pessoa (BRICE, 2001).

A localização com AOA é determinada pela posição do terminal e é calculada pela intercepção de duas linhas efetuadas por sinais piloto, cada uma formando um ângulo entre a estação base e o terminal. A precisão em AOA é limitada pelo posicionamento das antenas e pelos problemas ambientais já mencionados, assim, métricas AOA são melhores em ambientes em que receptor e transmissor estão alinhados, pois um componente de trajetória múltipla pode surgir em uma vibração ou por algum equipamento e variar as leituras e gerar erros consideráveis na percepção de uma pessoa ou equipamento (BOUKERCHE et al., 2007). Em Sakagami et al. (1992) um trabalho de localização é feito com AOA com um erro aproximado de 300 m quando utilizada duas antenas de rádio, e quando aumentada para três antenas de rádio o erro diminui para 200 m. O trabalho consiste em localização em ambientes externos, pois, segundo o autor, o AOA é um método muito interessante para áreas rurais e suburbanas, em que a precisão é melhor atingível.

### 2.1.2 *Time of Arrival*

*Time of Arrival* (TOA), explora a relação entre a distância e o tempo de transmissão quando a velocidade de propagação é conhecida. Assim, se emissor e receptor estiverem sincronizados e tiverem conhecimento da transmissão e recebimento de uma mensagem, pode-se calcular então o tempo de propagação e a distância entre dois nós de rede. A Figura 2 indica um esquema de transmissão com TOA. A forma de localizar corretamente com TOA requisita haver pelo menos três sensores, sendo que o terminal observa as medições dos tempos que chegam das estações vizinhas. A posição desconhecida do terminal é calculada processando as medições entre o terminal e, no mínimo, três estações base de posições conhecidas, assim quando as distâncias de três sensores diferentes são conhecidas, a localização pode ser encontrada na interseção dos três círculos criado em redor de cada sensor com o raio, sendo esse raio, a distância calculada. Medições imperfeitas criam uma região de incerteza entre cada um dos sensores, em que o transmissor pode estar contido.

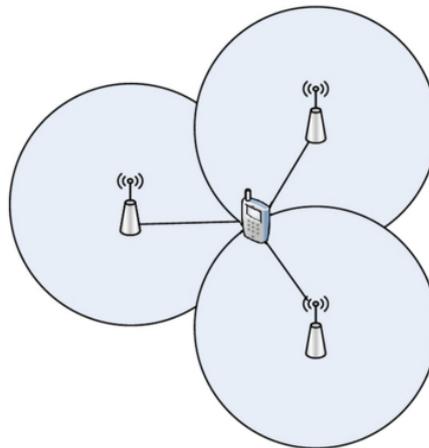


Figura 2: Esquema de transmissão com TOA (FARID; NORDIN; ISMAIL, 2013).

O problema principal para um sistema baseado em tempo é a sincronização dos relógios dos dispositivos, conseqüentemente o mesmo acontece com sistemas baseados com TOA, especialmente considerando a alta velocidade com que os sinais são transmitidos. Pelo fato dos sistemas serem sensíveis ao tempo, há também a possibilidade de atrasos nas leituras realizadas pelo *hardware*, pois muito se gasta para sincronização dos relógios, e assim que devem ser contabilizados para o cálculo das distâncias corretas (DOBBINS, 2011). Trabalhos como o de Ravindra e Jagadeesha (2014) utilizam simulações de um ambiente interno para estimar localização de pessoas, ou objetos. O trabalho em si, utiliza TOA com métodos de aproximações lineares para localização em ambientes simulados, e mostra que o método *two step WLS* é superior ao resto dos outros métodos testados.

### 2.1.3 Time Difference of Arrival

*Time Difference of Arrival* (TDOA), usa multilateração, ou posicionamento hiperbólico, para localizar um dispositivo ou pessoa. É muito semelhante a TOA na medida em que utiliza o tempo de percurso do transmissor para o receptor, a fim de medir distâncias. Entretanto, em vez de usar o tempo de viagem a partir de cada receptor para encontrar a distância entre transmissor e receptor, a diferença dos tempos de viagem de cada um dos sensores é utilizada para encontrar a distância entre cada sensor. Os resultados dessa técnica mostram várias hipérbolas sem que a interseção das mesmas seja a localização do transmissor (EXEL; LOSCHMIDT, 2009).

Similar à TOA ou quaisquer outros métodos baseados tempo, em que a sincronia entre os dispositivos deve existir para diferentes medições de tempo. No entanto, uma vez que TDOA não usa a distância entre o transmissor e o receptor, o transmissor não é obrigado a estar em sincronismo com o sensor. A sincronia só é necessária entre todos os sensores da rede, menos o nó sensor que não necessita de estar sincronizado com os demais, já que o cálculo é baseado em sua diferença de tempo por distância. O trabalho de

Yamasaki et al. (2005) apresentou a TDOA com dispositivos Wi-Fi IEEE 802.11b em um sistema de localização que incluía desde o procedimento de sincronização de roteadores, através de temporização e medições de várias fontes até a recepção de sinais para obtenção de uma boa acurácia e localizar com essa tecnologia. O trabalho alcançou um erro de 2,4 metros em um armazém, com a utilização de dez roteadores.

#### 2.1.4 Received signal strength indication

*Received signal strength indication* (RSSI) parte de um transmissor que pode ser utilizado para estimar a distância utilizando potências de sinal. Usando o RSSI a partir do transmissor, a distância entre ele e o receptor pode ser estimada utilizando os dados existentes de mais de um RSS encontrados em diferentes áreas. Embora este método possa ser adequado a ambientes internos, ainda há muito espaço para crescimento, como o estudo de diversos fatores que afetam o RSSI. A modelagem de perda de sinal pode ser utilizada com base na área estudada, mas ainda há uma grande margem de erro e imprevisibilidade com a presença de fatores externos, ou corpos estranhos dentro do ambiente, haja vista que a simples presença de uma barreira altera a intensidade que o sinal chega a seu destino Parameswaran et al. (2009). A distância mínima de dispositivos com RSSI varia de acordo com o fabricante do *hardware*, nesse sentido, para a descoberta dessa medida bastam deixar as antenas lado a lado para verificação, a partir dessa marca os valores irão aumentando de acordo com que a distância aumenta, como na Figura 3a. Da mesma forma para descoberta do limite do alcance do sinal, basta realizar o teste das antenas no limite máximo fornecido pelo fabricante, entretanto devido às interferências de ambiente, esse valor não é sempre o mesmo, de acordo com a Figura 3b (BOUKERCHE et al., 2007).

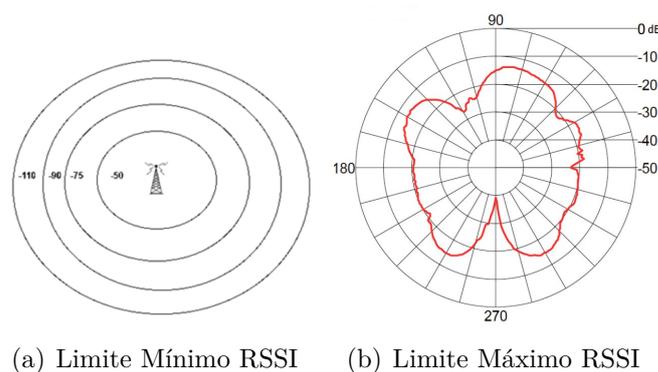


Figura 3: Exemplos de Limites mínimos e máximos com RSSI (BOUKERCHE et al., 2007).

Localização com RSSI pode ser realizada com *multipath fingerprint* sendo que a localização do terminal é descoberta fazendo coincidir a marca provocada pelo múltiplos caminhos produzidos pelo sinal recebido por uma ou mais estações com uma base de dados de localizações, como em uma impressão digital, o que é amplamente visto na bibliografia

estudada, como no trabalho de [Schneider, Andreão e Nunes \(2011\)](#), ou o de [Yoo et al. \(2014\)](#) que serão apresentados na Seção 2.5 deste trabalho. Este alcance máximo não é o mesmo devido um conjunto finito de raios em diferentes direções. O alcance máximo não será igual para todas as direções, pois em alguns dos pontos a cobertura é melhor que para outros. Isto se agrava com a presença de interferências como: refletores, movimentação de pessoas, paredes, entre outros.

## 2.2 Diminuição de Ruídos

A diminuição de ruídos ocorre na manipulação dos dados gerados pela rede de sensores sem fio. Nesse sentido, essa suavização pode ser obtida por diversos meios, como o filtro de médias móveis. A necessidade dessa diminuição consta na melhora das disposições dos dados, indicando que cada vez mais eles se tornem mais coerentes com a verdade que está sendo coletada, pois ruídos são anomalias que acontecem na coleta de um dado, fazendo com que oscilações sejam geradas ([OZSOY; BOZKURT; TEKIN, 2013](#)). E essa oscilação pode gerar uma falha em um sistema de localização, o que pode afetar na predição do local em que o objeto ou pessoa se encontra. Um dispositivo acoplado a uma pessoa que se desloca em um ambiente pode coletar informações de sinal, nesse sentido as amostras envolvendo a localização dessa pessoa pode gerar erros na referida coleta, pois quando há deslocamento, a variação do local que a pessoa se encontra, altera juntamente com o dispositivo, indicando que o sistema altere rapidamente a indicação da posição. Caso a localização não seja em tempo real, como na maioria das aplicações encontradas na literatura, o filtro de médias móveis acaba se tornando uma medida para suavizar ruídos.

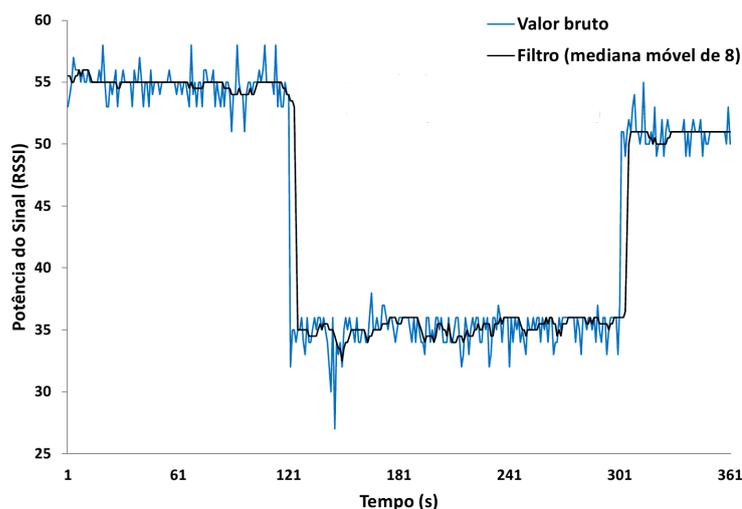


Figura 4: Exemplo de comportamento de filtro de mediana móveis. A linha azul mostra o valor bruto de um dos pontos de acesso. A linha preta mostra como o filtro remove alguns ruídos ([PESSIN et al., 2013](#)).

O filtro de médias móveis apresenta simplicidade teórica, bem como a presença em

diversos softwares comerciais, é o motivo da grande utilização dos filtros de médias móveis para suavizar sinais analíticos. A ideia básica consiste em dividir o sinal analítico em uma série de intervalos com a mesma largura, sequencialmente e ponto a ponto, e substituir o valor do ponto central do intervalo pelo valor médio do intervalo. A Figura 4 indica a criação de um filtro de mediana móvel, que se comporta similarmente ao filtro de médias móveis, na Figura 4 o sinal é dividido em oito posições e retira o valor central dessas oito posições para suavização do sinal.

O trabalho de (OZSOY; BOZKURT; TEKIN, 2013) apresenta um protótipo de sistema para localização interna construído com GPS e um módulo de amplificador de baixo ruído, em que consta em um filtro de sinal, nesse sentido o autor afirma um ganho em cerca de 30 decibéis do que com a utilização do sinal sem o referido filtro. Assim, a utilização de filtros são relevantes a fim de obter um sinal mais limpo e conseqüentemente um resultado melhor.

## 2.3 Tolerância a Falhas em RSSF

Confiabilidade e disponibilidade são conceitos que cada vez mais estão presentes na computação, nesse sentido módulos de tolerância a falhas são cada vez mais necessários. Confiabilidade em sistemas indica o nível de confiança que o *hardware* ou *software* não irá apresentar falhas, já disponibilidade indica o quanto o sistema permanece disponível para uso, segundo Weber (2003), assim para localização, a tolerância a falhas indica por quanto tempo a pessoa ou objeto está sendo localizada na rede, ou o quanto de precisão o sistema possui, no caso desse trabalho uma outra vertente de tolerância a falhas é indicada, em que a mesma se refere a capacidade de obter posições mesmo com perda de alguns roteadores.

Sistemas que são construídos com técnicas de tolerância a falhas são sistemas que exigem uma alta confiabilidade ou alta disponibilidade, pois casos contrários poderiam ser considerados somente prevenção de falhas, ou até mesmo remoção de falhas, entretanto quando se tratar de localização, essas características são importantes. Essas técnicas garantem funcionamento correto do sistema mesmo na ocorrência de falhas e são todas baseadas em redundância, e mesmo com redundância, sistemas tolerantes a falhas tem que possuir níveis de prevenção das mesmas.

Vários autores apresentaram suas próprias classificações para as técnicas de tolerância a falhas. A mais comum é a classificação em quatro fases de aplicação (LEE; ANDERSON, 2012): (i) detecção, que é o primeiro passo, em que a falha é manifestada como um erro; (ii) o confinamento que estabelece limites para a propagação que o dano ocorrido da falha pode acontecer; (iii) a recuperação que ocorre depois da detecção e pode ser com técnicas de recuperação por retorno (*backward error recovery*) e técnicas de recuperação por avanço (*forward error recovery*); (iv) e tratamento, cujo nome é explicativo.

Essas fases excluem mascaramento de falhas, que é uma técnica a parte, não usada em complemento às demais.

Outra situação em que a tolerância a falhas é pertinente em um sistema de localização, é quanto ao *hardware* utilizado. Um sistema que localize uma pessoa com quatro sensores não possui a mesma capacidade de um sistema que a calcule com três sensores, quanto menor o número de sensores sistemas tendem a errar mais (POPLETEEV; OSMANI; MAYORA, 2012). O trabalho do autor mencionado indica que quanto mais estações localizando uma pessoa em um ambiente controlado o erro tende a diminuir, até certo limiar, pois com o excessivo aumento de estações base o erro da localização tende a linearizar. Assim, a investigação de tolerância a falhas em estações base se tornam importante para verificar se o modelo estudado mantém resultados similares com um sistema completo.

## 2.4 Técnicas Inteligentes

A presente Seção indica os tipos de técnicas inteligentes que serão utilizados no trabalho. São explicados seus conceitos e características, como em redes neurais com *multilayer perceptron*, ou *k-nearest neighbors* ou *support vector machine*, estes estão cada vez mais sendo utilizadas nos cenários acadêmicos e industriais.

### 2.4.1 K-Nearest Neighbors

O KNN é um tipo de classificador em que o aprendizado se baseia na analogia (HALL et al., 2009). Um conjunto de treinamento que tem diversos vetores n-dimensionais e cada elemento deste conjunto representa um ponto nesse espaço. O classificador KNN procura K elementos em um conjunto de treinamento que tenham menor distância do elemento desconhecido, a fim de determinar a classe de um elemento que não pertença ao conjunto treinado. Ao elemento desconhecido será atribuída a classe mais frequente dentre os k-vizinhos mais próximos. Em seguida listam-se as métricas mais comuns no cálculo de distância entre dois pontos, sendo que a mais utilizada, é a distância Euclidiana.

- Distância Euclidiana: distância entre dois pontos, geralmente mensurada pelo teorema de Pitágoras;
- Distância Manhattan: soma das diferenças das distâncias entre duas dimensões;
- Distância Minkowsk: generalização das duas anteriores, em que podem calcular distâncias que tendem ao infinito.

A variável K no KNN é o controle do usuário para se obter uma classificação mais precisa, e segundo Silva (2005), quando se tem uma base de dados muito grande

essa técnica fica inviável. Em um universo com duas classes de conjuntos, representado na Figura 5 pelas circunferências pretas e brancas, quando aplicado um  $K=3$ , ou um  $K=7$ , tem-se o elemento “estrela” como mais provavelmente pertencendo ao conjunto de circunferências pretas.

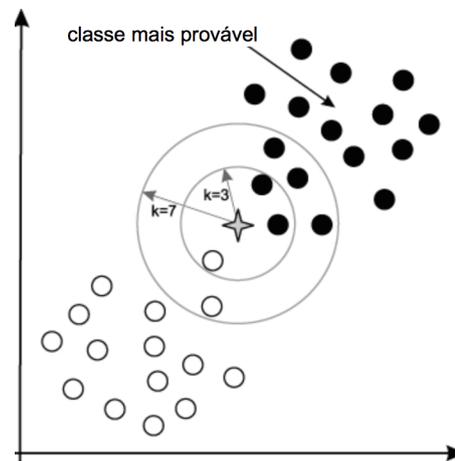


Figura 5: Exemplo de esquema com KNN (THIRUMURUGANATHAN, 2010).

## 2.4.2 Redes Neurais Artificiais

Redes neurais artificiais (RNA) são sistemas de processamento de informações distribuídas, podendo ser compostas por vários elementos computacionais simples que interagem por meio de conexões com pesos distintos. Com inspiração no cérebro humano, as redes neurais exibem características como a habilidade de aprender padrões complexos de dados e generalizar informações aprendidas (ZHANG G.; HU, 1998). Redes neurais com múltiplas camadas são formadas de três partes: os nós de entrada; uma ou mais camadas ocultas de neurônios; e por uma camada de saída. O sinal se propaga da entrada para a saída. Nesse tipo de rede cada camada possui seu próprio conjunto de pesos, um vetor polarizador, um vetor de entrada e um vetor de saída. A Figura 6 mostra uma rede neural, com quatro camadas ocultas e três saídas representadas na figura, em resumo, a rede possui quatro camadas.

Haykin (2001) afirma que os processos de aprendizagem de uma rede neural artificial são determinados pelo modo de como a modificação dos parâmetros ocorrem. Assim, o processo de aprendizagem de uma RNA está dividido em três partes: a estimulação por um ambiente através de exemplos extraídos do mesmo, a modificação de seus pesos através de processos iterativos, e por fim, a rede responde de uma nova forma ao ambiente em decorrência das mudanças ocorridas, ou seja, tudo ocorre novamente desde o primeiro passo, de acordo com as mudanças do segundo passo, atingindo assim uma solução generalizada para uma classe de problemas.

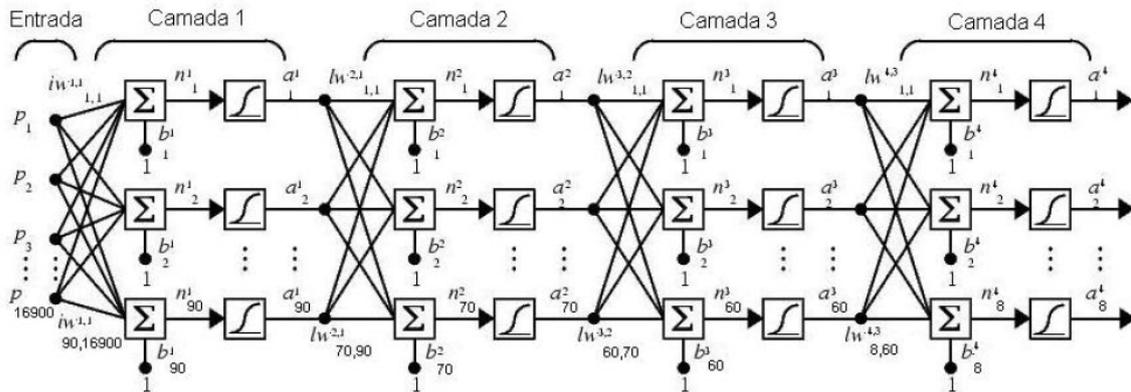


Figura 6: Esquema de uma rede neural com quatro camadas, sendo as camadas de 1 a 4 sendo ocultas e as três setas representadas indicam as saídas da rede (KHATCHATOURIAN; PADILHA, 2008).

O aprendizado do problema de uma RNA está na fase de treinamento em que é escolhido o algoritmo de aprendizado com os parâmetros para esse aprendizado, como: taxa de aprendizado (*learning rate*), taxa de momento (*momentum*), critérios de parada e forma de treinamento da rede. A aprendizagem por *backpropagation* consiste em dois passos: um passo para frente, que é a propagação do erro, e um passo para trás, a retropropagação. No passo para frente, um vetor é apresentado aos nós de entrada da rede e seu efeito se propaga através desta, da esquerda para a direita e de camada em camada. Um conjunto de saídas é produzido como resposta da rede. Durante este processo, os pesos sinápticos da rede são todos fixos. A resposta da rede é subtraída da resposta desejada e, então, determina-se o sinal de erro. Este sinal de erro é propagado para trás através da rede, contra a direção das conexões sinápticas. Os pesos são então ajustados de modo a se minimizar o sinal de erro.

### 2.4.3 Support vector machine

Algoritmos SVM são técnicas de aprendizado de máquina, fundamentadas em Minimização de Riscos Estruturais, e buscam minimizar o erro em relação ao conjunto de treinamento, bem como o conjunto de teste. Tendo como objetivo principal o balanceamento entre esses dois erros apresentados o SVM busca minimizar o excesso de treinamentos e aumentar a capacidade de generalização (VAPNIK, 1999). As limitações desse algoritmo ficam muitas a cargo da dificuldade de escolha dos parâmetros e da baixa velocidade de treinamento.

O método mais simples de cálculo do SVM trabalha com margens rígidas, que tem como principal objetivo em sua fase de treinamento, ajustar os parâmetros livres do sistema e assim determinar uma função que relacione os valores dos conjuntos. Devido esse acontecimento muitos erros de estimativas são penalizados para valorizar os acertos de forma

a melhorar o tempo de adquirir conhecimento. Devido apenas ter o conhecimento da entrada, a escolha dessa função é de extrema importância para que os conjuntos sejam separados por um hiperplano e o mesmo indicar o resultado esperado pelo algoritmo. (BELTRAMI, 2009). Outros dois conceitos importantes em hiperplanos do SVM são: os hiperplanos perfeitos, que possui equidistância entre os conjuntos a serem estimados, e os vetores de suporte, que são dados conhecidos que estão nessa distância perfeita, ou seja, o conjunto de elementos pertencente a cada conjunto que estão na mesma distância como ilustrado na Figura 7.

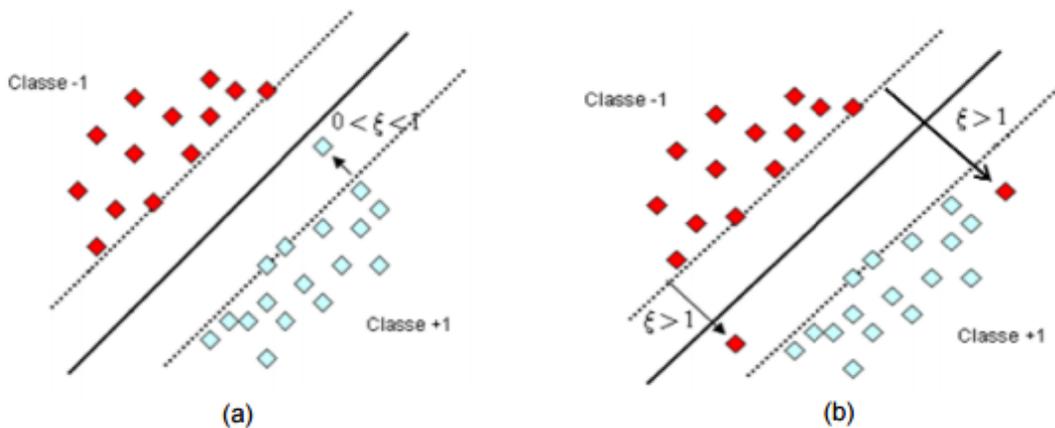


Figura 7: Conjuntos em SVM com: (a) Hiperplanos: em que a separação de dois conjuntos é ótima e linearmente separáveis; (b) Vetores de suporte: em que são dados pertencentes a um conjunto à uma distância conhecida (BELTRAMI, 2009) (ALES, 2008).

SVM de margens flexíveis tem aplicação mais correta quanto às aplicações nos conjuntos de treinamento, pois a maioria dos exemplos reais acontece dos elementos não serem linearmente separáveis, nesse caso tem-se o que se chama de constante de regulação, que estabelece o equilíbrio entre o erro de treinamento e a complexidade da situação, determinando como serão tratados os *outliers* dos conjuntos. Com o objetivo de se diminuir o custo computacional, o mapeamento irá ser realizado pelas funções *kernel*, que dependem somente de variáveis do espaço de entradas, resumindo, o que já se conhece. As funções *kernel* mais usadas são: linear, polinomial, função de base radial (RBF) e sigmoide (CHAVES, 2006); (LIMA, 2002).

## 3 Trabalhos Relacionados

Este Capítulo apresenta os Trabalhos Relacionados, destacando o estado da arte na aplicação de redes de sensores sem fio em ambientes internos nos últimos anos, demonstrando como os trabalhos estão sendo desenvolvidos, com testes internos, ou externos, tipos de hardware entre outras características levantadas nos mesmos.

O trabalho de [Yoo et al. \(2014\)](#) teve como objetivo calcular como robôs poderiam se locomover dentro da estação espacial para realizar operações dentro da mesma, com o menor erro possível. Nesse sentido, foram utilizados dispositivos *mobile* para realizar coletas de potências de sinal para criar um mapa Wi-Fi, como visto na Figura 8, utilizando *gaussian process* (GP) e propôs um método localizador baseado em filtros de partículas a fim de avaliar o desempenho.

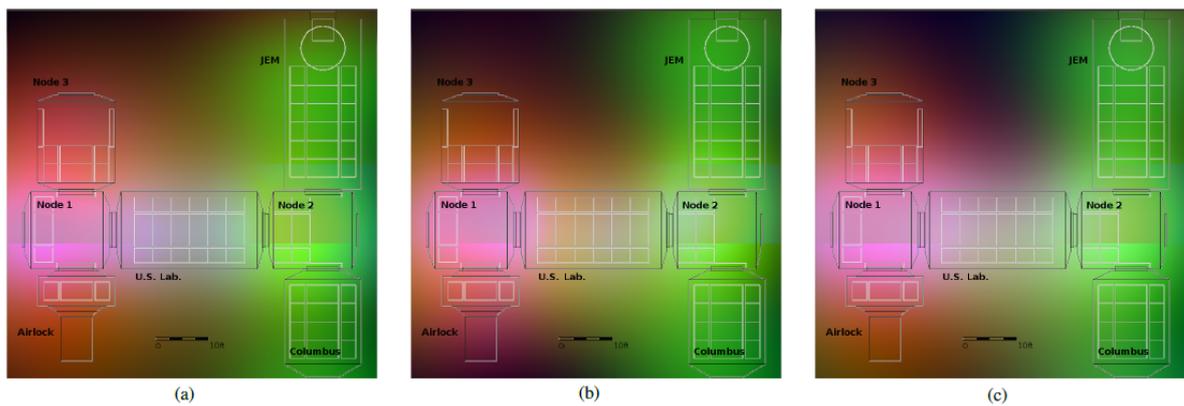


Figura 8: Mapa de cores da *International Space Station* ISS, em que (a) Coletas de RSSI para o primeiro *dataset*, (b) Coletas de potência em RSSI para o segundo *dataset*, e (c) Junção das duas coletas em um mapa de cor ([YOO et al., 2014](#)).

A Figura 8 está dividida em três partes, sendo a primeira indicando a coleta de sinais RSSI em um mês, a segunda parte indica a coleta em um mês diferente da primeira, e por fim a terceira parte tem um mapa das duas coletas no mapa da estação. Com posse do mapa o algoritmo baseado em filtros de partícula foi aplicado a fim de estimar as posições dos robôs na estação espacial, que chegaram a ter resultados com erros até 1.90 metros de indicação do local em que o robô se encontra.

[Liu et al. \(2007\)](#) realizaram um levantamento do estado da arte a fim de verificar o que foi realizado em trabalhos de localização em ambientes internos, ou seja, a pesquisa se centrou em informar quais foram os trabalhos mais relevantes da área, bem como a comparação dos trabalhos entre si. No artigo, foram abordadas as técnicas para localização que são utilizadas em RSSF, como: triangulação, análises de cenários e proximidades. Além disso, os autores citam algumas métricas para analisar a desempenho das redes,

como: acurácia, complexidade, grandeza, escalabilidade e custo, além de mostrar diversas tecnologias utilizadas para localização foram citados, como: RFID, *GPS-Based*, *Cellular-Based*, UWB, WLAN com IEEE 802.11 e *Bluetooth* com IEEE 802.15, entre outras. Com posse de todas as características que compõe uma RSSF os autores listaram diversos trabalhos da literatura e os classificaram de acordo com essas características, já citadas. Em seguida afirmaram que sempre o usuário terá que escolher entre as grandezas de performance o que será mais necessário para o seu problema, haja vista que nenhum dos trabalhos pesquisados pelos autores chegou a um sistema ideal que atendesse todos os requisitos de performance.

O artigo de [Popleteev, Osmani e Mayora \(2012\)](#) apresenta uma investigação e avaliação de emissões de sinais FM como uma alternativa para localização *indoor*. A utilização de ondas de rádio para localização com diferentes antenas e posições de antenas foram algumas das metodologias empregadas pelos autores, haja vista que dispositivos móveis possuem esse tipo de antenas em suas composições. Foi fornecida uma avaliação experimental de limitações de infraestruturas (tais como FM ou GSM) quando a área para localização é aumentada, ou seja, quanto maior a área maior é o erro da estimativa de posição. Por fim uma última análise é feita, onde a localização depende dos comprimentos de onda do sinal. Outra vertente do artigo buscou mostrar o consumo que esse tipo de abordagem consome (sinais FM), que é menor que outras, como Wi-Fi e GSM, que possibilita uma duração de bateria de 2,6 até 5,5 maiores em FM do que nas outras citadas.

Sistemas de posicionamento com Zigbee são presentes em trabalhos como o de [Schneider, Andreão e Nunes \(2011\)](#) (Figura 9). Este é um trabalho prático de leitura do ambiente e depois a coleta de dados para determinação do posicionamento dentro de um ambiente, nesse caso, foram-se distribuídos nós pelo ambiente para criação da rede e assim com assinaturas RSSI providas pelo Zigbee se determinar a posição de pessoas e objetos com auxílio de algoritmos como o KNN e redes neurais.

[Jung, Kang e Bae \(2013\)](#) identificam um experimento utilizando RSSI de *bluetooth* para localizar equipamentos dentro de ambientes internos, no seu trabalho eles afirmam que em uma distância pequena o dispositivo não conseguiu emular o ambiente, contando poucas variações dentro do ambiente estudado.

[Marti et al. \(2012\)](#) realizam testes reais em ambientes com pouca visibilidade, e para tal utilizam algoritmos como KNN e RNA, implantada com um *Multilayer Perceptron* (MLP), juntamente com uma solução proposta que os autores chamaram de ARIEL, que é baseada no algoritmo do KNN com base de cálculo na distância euclidiana, uma maneira de melhorar situações em que a visibilidade é baixa, como já dito. O método ARIEL teve um desempenho melhor que os outros métodos já citados (KNN, distância mínima e redes neurais), e mostrou resultados relativamente melhores. Como a intenção do trabalho era auxiliar robôs em ambientes com pouca visibilidade o mesmo conta com uma placa que

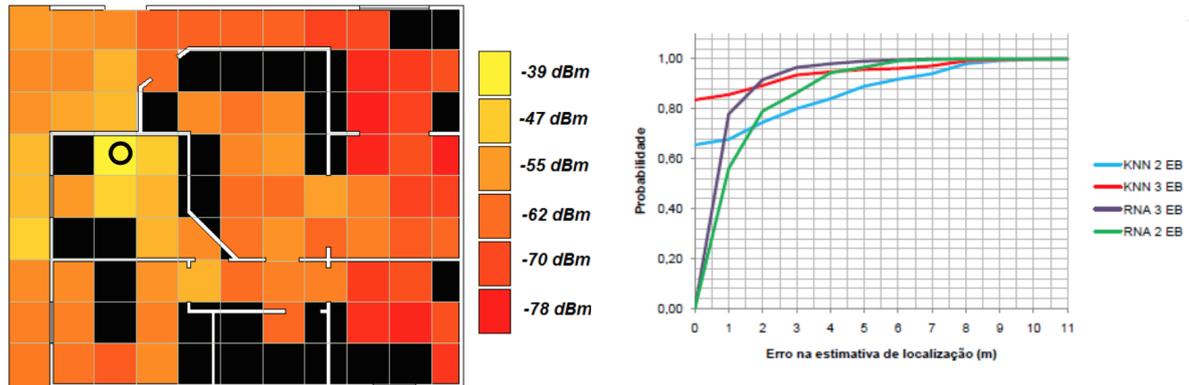


Figura 9: Experimento apresentado em [Schneider, Andreão e Nunes \(2011\)](#), conta com o mapeamento prévio com *Fingerprint* e mapas de potências, juntamente com o resultado do experimento realizado com 2 e 3 estações base indicam que um erro menor que 2 metros para cerca de 80% para todos os testes com 2 estações base e de 92% para todos os testes com 3 estações base.

emite luz para locomoção, entretanto apenas informações coletadas por nós de rede Zigbee foram considerados, em vez de unir os dados da rede e os de luminosidade, mesmo assim, o sistema pôde permitir que um robô navegasse em uma atmosfera com baixa visibilidade e chegar a pontos específicos de interesse para ajudar.

O trabalho apresentado em [Pei et al. \(2009\)](#) indica dois tipos de testes, o primeiro em ambientes externos e o segundo em ambientes internos. Nos testes uma técnica de extrapolação foi utilizada, que seria a *Multidimensional Scaling* (MDS), em que são geradas múltiplas escalas que são baseadas em um real, em resumo: coletas foram feitas, tanto externamente, quanto em uma mina subterrânea de gás, e em seguida foram levadas ao computador que simulou os outros 99 nós de uma rede, totalizando 100 nós de rede para o experimento simulado, resultando em uma base que seria complementada com dois algoritmos para inferir a localização de uma pessoa que estivesse na área dos 100 nós. Sendo assim, para o ambiente externo os algoritmos SBL e N-SBL foram aplicados para inferência dos nós, e o algoritmo N-SBL se saiu melhor, quanto ao ambiente interno, na mina subterrânea, o algoritmo de MDS foi utilizado para inferir tanto os nós da rede quanto o indivíduo que caminharia na mina, o que gerou um erro de menos que um metro para os dispositivos reais, como ilustrado na Figura 10.

Em [Jekabsons, Kairish e Zuravlyov \(2011\)](#) é utilizado o WiFi como técnica para localização em ambientes internos reais para determinar posições de pessoas. O trabalho indica que um aparelho móvel com Wi-Fi utiliza o sinal de diversas estações-base espalhadas em um ambiente interno, sem a necessidade de um servidor *back-end*, se locomove e com auxílio dos algoritmos classificadores (KNN e WKNN) o trabalho conclui de que com esses diferentes dispositivos com a tecnologia Wi-Fi o erro calculado com os algoritmos chegam a ficarem entre 2,5 e 4,0 metros no ambiente testado.

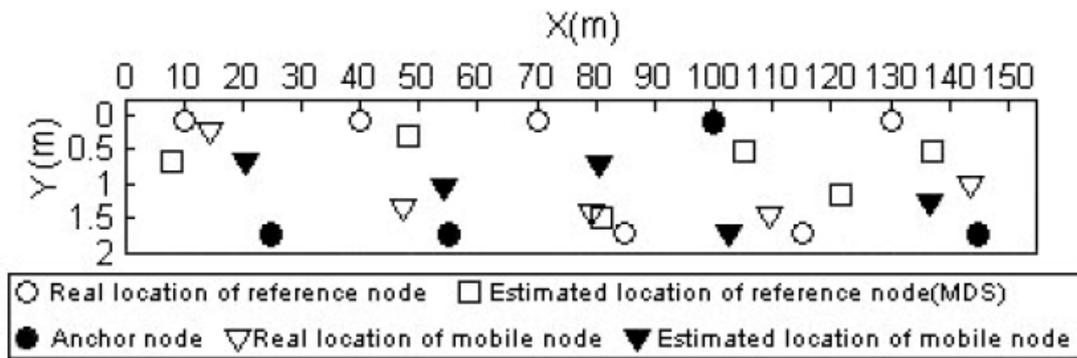


Figura 10: Comparação de performance do método de localização de âncoras livres em [Pei et al. \(2009\)](#).

[Neiva et al. \(2012\)](#) realiza um trabalho de simulação, que com o auxílio do computador, emula o andar de pessoas com problemas de visão por dentro de um ambiente interno. Nesse sistema o autor utiliza *tags* de Identificação por Radiofrequências (RFID) inteligentes que guiam a pessoa nesse ambiente. Assim, a intenção é que em cada pessoa, fique um dispositivo capaz de ler essas *tags* e enquanto a pessoa caminha nos corredores, por exemplo, o dispositivo informa tanto visualmente, para pessoas sem a deficiência, quanto auditivamente para o seu público final. Outro trabalho que utilizou simulação foi o de [Pereira \(2011\)](#), que utiliza AOA para inferir as posições de antenas simuladas em um programa de computador. No trabalho, o autor afirma que quando posicionadas em uma direção, antenas podem inferir a posição de uma fonte de radiofrequência, assim, com posse do ângulo de chegada dos sinais e com a diferença entre o emissor e o centro de sistemas de antenas, a localização do foco de sinal é inferido.

### 3.1 Discussão dos Trabalhos Relacionados

A Tabela 1 apresenta diversos trabalhos que mostram localização em ambientes internos, trabalhos teóricos, ou trabalhos simulados, entretanto houve um crescimento de aplicações práticas em ambientes reais com cenários de testes. Nesse sentido trabalhos como os de ([LIU et al., 2007](#)); ([NEIVA et al., 2012](#)) e ([PEREIRA, 2011](#)) cada vez mais vem perdendo espaço, pois as aplicações reais como os trabalhos restantes mencionados ([PEI et al., 2009](#)); ([YOO et al., 2014](#)); ([POPLETEEV; OSMANI; MAYORA, 2012](#)); ([SCHNEIDER; ANDREÃO; NUNES, 2011](#)); ([JUNG; KANG; BAE, 2013](#)); ([MARTI et al., 2012](#)); e ([JEKABSONS; KAIRISH; ZURAVLYOV, 2011](#)), tem muita visibilidade e procura para resolver problemas do cotidiano das pessoas. Quanto à utilização de Hardware o que mais se destaca ainda é o Wi-Fi. Entretanto nos trabalhos foi possível observar um forte apela tecnologia Zigbee, e surge uma tendência nessa vertente. No que diz respeito aos algoritmos, o KNN foi o algoritmo com maior destaque, e comparações entre ele e

RNA e SVM são relevantes. O que fica claro, como dito em [Liu et al. \(2007\)](#), a escolha entre desempenho e confiabilidade fica prejudicada, tendo em vista que a tolerância a falhas teve pouco destaque, assim como não se teve uma comparação entre estratégias de localização, ou a filtragem dos ruídos das coletas para a inferência das posições nos respectivos trabalhos.

Tabela 1: Comparativo entre trabalhos relacionados

Autores	Tipo de trabalho	Teste Indoor	Teste Outdoor	Hardware	Métodos	Tolerância a Falhas
Liu, et al., 2007	Teórico	-	-	-	-	-
Yoo, et al., 2014	Real	✓	-	Mobile/WiFi	<i>Gaussian Process</i>	-
Schneider, et al., 2011	Real	✓	-	Zigbee	KNN/RNA	✓
Pei et al., 2009	Real/Simulado	✓	✓	Zigbee	SBL/N-best SBL	
Marti,et al., 2012	Real	✓	✓	Zigbee	KNN/RNA/DM/ARIEL	-
Popleteev, et al., 2012	Real	✓	-	Mobile/FM	KNN/SVM/GP	-
Neiva, 2012	Simulado	-	-	RFID	AOA	-
Pereira, 2011	Simulado	-	-	RFID	AOA	-
Jekabsons, et al., 2011	Real	✓	-	Mobile/WiFi	Knn/WKNN	-

Com base na bibliografia consultada, percebe-se que a comparação de métodos de IA é comum e que as técnicas apresentam diferenças de acordo com ambientes e dispositivos diferentes. Isso encoraja uma nova comparação para nosso ambiente específico, considerando o hardware disponível. Além disso, é importante ressaltar que um dos principais diferenciais desse trabalho se concentra na comparação de arquiteturas de localização e na avaliação de tolerância a falhas.



## 4 Configurações de Arquiteturas de teste

No presente Capítulo é descrita o conjunto de passos empregado para realização do trabalho. É apresentada a metodologia de coleta, tratamento e análise dos resultados, bem como detalhamento do ambiente de teste escolhido. Este trabalho visa realizar experimentos em ambientes reais para estimar a taxa de acerto em localização de pessoas em ambientes internos. Nesse sentido algumas etapas necessitam serem cumpridas, estas são especificadas a seguir:

- Demarcação do ambiente e definição de regiões de um andar de prédio comercial;
- Preparação dos dispositivos e cenários de teste.
- Coleta e armazenamento dos RSSI para cada cenário de teste.
- Preparação dos dados coletados nos cenários de teste para o formato de entrada do programa WEKA.
- Treinamento e validação, usando a base de dados coletada e considerando *10-fold cross-validation*, em português, Validação Cruzada, considerando os algoritmos KNN, MLP e SVM e variações como número de neurônios e camadas na MLP, pesos do KNN e kernel no SVM.
- Análise dos resultados obtidos.

A utilização de diversos métodos de aprendizado de máquina se situa na forma de indicar qual técnica se comporta melhor com o ambiente testado e verificação de qual dos dois cenários de teste favorece uma melhor taxa de acerto. Alguns problemas acarretados pelo meio escolhidos podem refletir diretamente no resultado do experimento, nesse sentido alguns fatores foram observados no que diz respeito aos testes que foram realizados nesse trabalho, tais como:

- Consumo da bateria: apesar das baterias utilizadas serem de grande capacidade, o hardware utilizado também foi robusto. Para os testes foram utilizadas baterias de notebooks com seis células de Lítio;
- Perda de um nó: devido à alta disponibilidade dos dispositivos essa característica não influenciou tanto nas coletas, entretanto testes nas mesmas condições foram realizados com menos nós na rede para simular essa perda total do nó durante o teste;

- Coletas: devido à estrutura e disponibilidade do ambiente, os testes ocorreram mais de uma vez, pois fatores externos sempre interferem em situações reais;
- Objetos dinâmicos no experimento: A presença de terceiros em testes reais sempre acontece, entretanto como a intenção do experimento necessita dessas presenças, as alterações também não sofreram muita influência;
- Aquisição de dados: Devido ao teste ser real, o tempo é determinante para se obter uma média considerável de amostras, tendo em vista a quantidade de coletas e de estações base, o número de pontos a serem considerados cresce bastante.

Considerando todos os itens descritos, cuidando principalmente das coletas e presenças de objetos móveis nos testes, são apresentados nesse trabalho dois cenários que obedeceram a todos os itens, e assim, portanto, localizando uma pessoa em um ambiente interno. Os cenários de testes foram divididos em dois tipos de localização: as localizações *indoors* pessoal e assistida. A Figura 11 apresenta a área de testes das duas estratégias mencionadas e os roteadores (R1, R2 and R3), que são *notebooks*, com configurações semelhantes. Todos possuem processador Intel Core i5, bem como 4GB de memória RAM, e sistema operacional Linux Suse. Quanto as placas de redes utilizadas todos apresentam placas de redes iguais, a placa Atheros AR9285 *Wireless Network Adapter*. O ambiente mostra um andar de um prédio em que existe um corredor central e galerias adjacentes a esse corredor. O ambiente foi dividido de acordo com a posição em que as coletas foram realizadas: *Robotics Lab.* (C1), *Soft Engineering Lab.* (C2), *Corridor* (C3), *Food Court* (C4) e *Main Office* (C5).

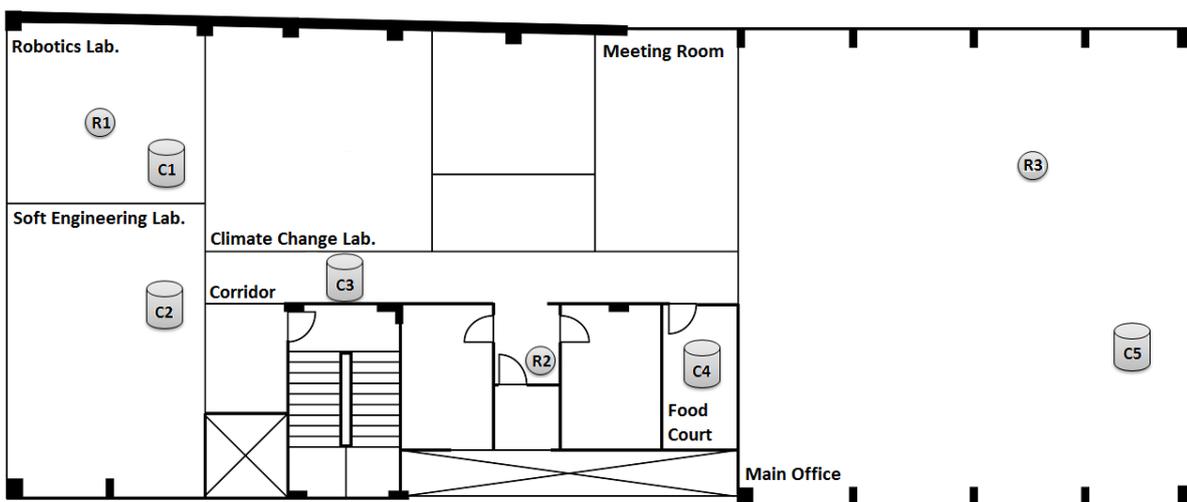


Figura 11: Planta-baixa do ambiente testado. No próprio estão identificadas as posições dos roteadores (R1, R2, R3) e as posições de coletas (C1, C2, C3, C4, C5).

Para realização dos testes foi respeitada para cada coleta (C1, C2, C3, C4 e C5) um tempo de 5 minutos permanecendo parados nos locais marcados, por escala, presentes

na Figura 11. Em seguida uma avaliação de algoritmos de aprendizado de máquina sobre os dados de RSSI, por meio do programa *Waikato Environment for Knowledge Analysis* (WEKA) (HALL et al., 2009).

#### 4.1 As arquiteturas propostas: Localização *indoor* pessoal e Localização *indoor* assistida

Duas arquiteturas são avaliadas: (i) localização *indoor* pessoal remete ao trabalho proposto por Neiva et al. (2012), em que uma pessoa informa a uma rede de sensores sem fio a sua posição, e após isso sua posição é informada novamente a pessoa, como visto no trabalho uma aplicação da mesma pode ajudar pessoas com problemas visuais; e (ii) com segunda arquitetura, tem-se localização *indoor* assistida que indica que a rede encontra uma pessoa em um ambiente, junto com um dispositivo que fica acoplado a essa pessoa, como no trabalho de Pei et al. (2009). A Figura 12 mostra os métodos de coleta de dados utilizados nos testes, onde, na arquitetura (a) em que a pessoa sabe sua posição e a informa em uma rede de sensores sem fio, que indica a localização *indoor* pessoal, e na arquitetura (b) uma rede de sensores sem fio localiza uma pessoa, semelhante em um sistema de *tracking*, indicando a localização *indoor* assistida.

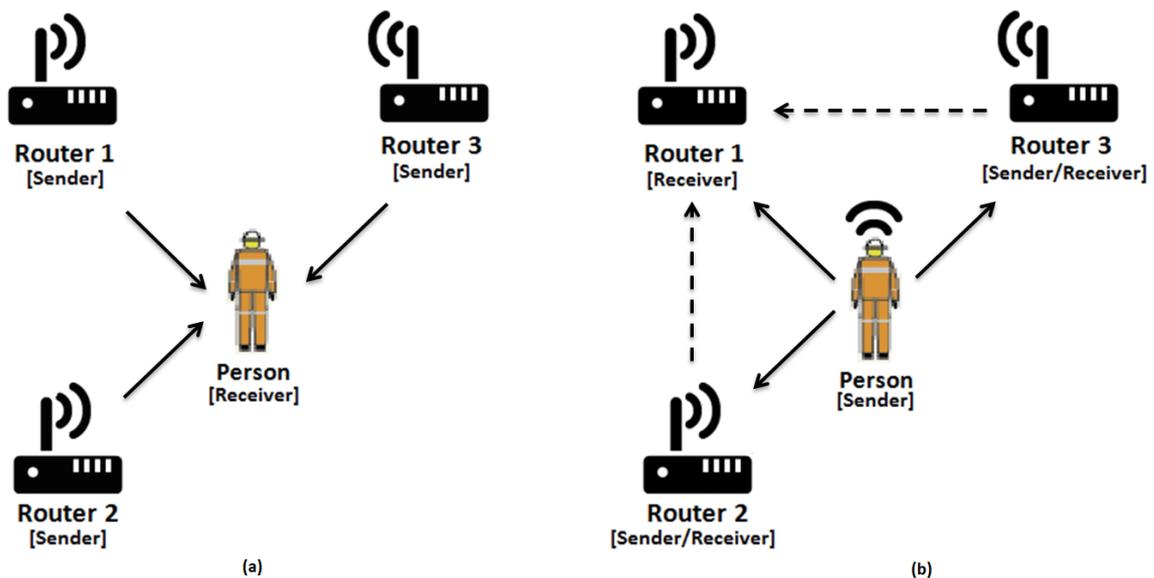


Figura 12: Duas Arquiteturas avaliadas. (a) Localização *indoor* pessoal: pessoa deve ter um dispositivo que recebe RSSI de roteadores e emprega aprendizagem de máquina para obter a sua localização. (b) Localização *indoor* assistida: A pessoa deve ter um dispositivo emissor e roteadores comunicam-se entre eles para compartilhar percepções RSSI, em seguida, um nó coordenador emprega aprendizagem de máquina para obter a localização pessoa.

Ainda na Figura 12 nota-se os três roteadores mencionados na Figura 11 e na

estratégia pessoal os roteadores não conversam entre si, apenas o usuário emite informações para os roteadores, e na estratégia assistida o sistema está mais completo para que as estações-base (roteadores), também conversem entre si, a fim de estabelecer uma confiança melhor dos dados, bem como o envio de informações para o usuário que está sendo assistido.

A Figura 12 mostra as duas estratégias de localização. No diagrama presente na Figura 12(a) a pessoa tem um sensor vestível para se localizar dentro da rede de sensores sem fio. No diagrama na Figura 12(b), a rede de sensores sem fio localiza a pessoa de uma maneira semelhante a um sistema de *tracking*, a pessoa tem de ter um dispositivo que transmite RSSI mas à estimativa de posição é efetuada por uma estação central. A principal vantagem da segunda abordagem é que ela torna mais fácil para enviar uma equipe de resgate, porque a estação central saberia a posição das pessoas, e também permite o reconhecimento da posição de veículos ou de outros objetos (que permite a construção de um sistema de prevenção de colisões, por exemplo). A principal vantagem da primeira abordagem ocorre quando não há equipes de salvamento disponível, o que poderia ocorrer no caso de cavernas, por exemplo. Neste caso, a pessoa sabe a sua posição e poderia empregar mecanismos de segurança para sair da caverna. De qualquer forma, empregando certa comunicação, as duas estratégias podem ocorrer, que são: tanto o dispositivo vestível se comunica com a RSSF, quanto o contrário. No entanto, neste trabalho, nós avaliamos se uma ou outra estratégia seria mais adequada para execução de métodos de aprendizado de máquina inclina-se para estimar posições.

## 4.2 Fase de coleta

Em resumo o sistema se comporta como na Figura 13, em que existem três entradas para o sistema, que são os três dados RSSI dos três roteadores presentes no ambiente, em seguida o programa WEKA realiza a execução dos algoritmos de aprendizado de máquina, que o mesmo nos revela a taxa de acerto do mesmo e assim estimar as posições da pessoa no ambiente interno.



Figura 13: Esquema de entrada e saída do sistema de localização utilizado nas duas arquiteturas.

Para a aquisição de dados, o processo de escolha dos pontos de coleta obedeceu

à estrutura mencionada na Figura 11, em que as estações-base, chamadas de R1 ao R3 na imagem, são inseridas no ambiente, e portanto, para a localização pessoal e para a localização assistida, as mensagens de envio e recebimento são armazenadas momentaneamente no próprio dispositivo, em seguida são enviadas a um dispositivo externo e assim criam-se arquivos em extensão .Arff para que o software WEKA realizasse a leitura e execução das estimativas com KNN, RNA e SVM, para cada uma das estratégias, como visto no diagrama da Figura 14.

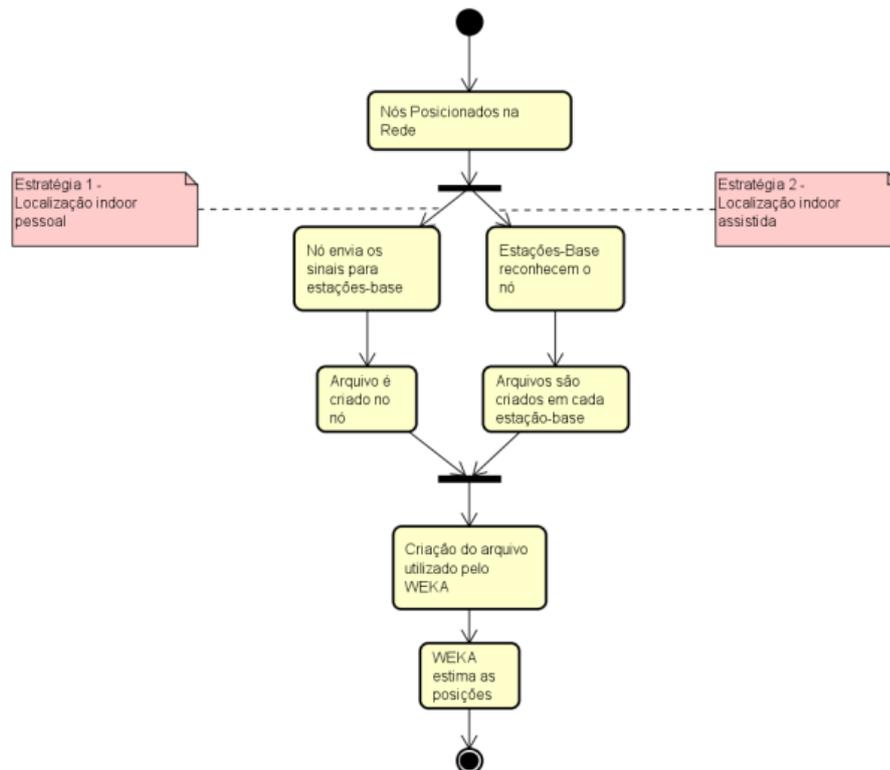


Figura 14: Diagrama de coleta de dados.

Os tempos de aquisição em cada ponto de coleta, como já dito, são de cinco minutos, assim com posse desses dados, o *software* WEKA conta, além dos algoritmos citados (KNN, MLP e SVM), ainda com variações desses algoritmos, e assim diversas análises podem ser construídas a partir do programa com o mesmo conjunto de dados. Essas entradas de dados que foram indicadas na Figura 13 foram agrupadas em um único arquivo composto das cinco coletas com três roteadores. Esse arquivo de entrada do programa conta com cerca de duzentas leituras a cada 5 minutos de coleta, sendo que a cada 1,5 segundo se tem uma leitura.

#### 4.2.1 WEKA

O *Waikato Environment for Knowledge Analysis* (WEKA) foi a ferramenta computacional e estatística dos dados fornecidos recorrendo a técnicas de mineração de dados

tentando, indutivamente, a partir dos padrões encontrados gerarem hipóteses para soluções e inclusive teorias sobre os dados em questão (HALL et al., 2009). Nele é possível encontrar diversas soluções para se executar algoritmos relacionados à *Machine Learning* (ML), ou em português, aprendizado de máquina. A escolha dessa ferramenta foi realizada pelo fato dessa aglutinação de soluções em ML e suas grandes variações. O módulo de KNN no WEKA é conhecido pela sigla 'ibk', assim como o MLP está representado pela palavra *MultilayerPerceptron* e a biblioteca do SVM chama-se 'libSVM'.

Os arquivos de configuração para cada modelo rodado no WEKA seguiram os valores *default* do próprio programa, por exemplo, o K utilizado no método do KNN foi de 1 em 1, haja vista que o tempo de execução é menor para predição. Os algoritmos de aprendizado de máquinas descritos nas seções anteriores (KNN, SVM e RNA), como já dito, presentes no programa, sofreram algumas modificações em suas configurações *default* fornecidas pelo programa, a fim de avaliar as diferentes mudanças que os algoritmos proporcionam e assim indicar um método com maior taxa de acerto dentre os algoritmos testados. Para tais mudanças a Tabela 2:

Tabela 2: Variações dos métodos de aprendizado de máquinas realizados no WEKA

Método	Variação 1	Variação 2	Variação 3
KNN	KNN 1-D	KNN 1/D	KNN NW
MLP	MLP 3	MLP 3,3	MLP 6,6
SVM (C-SVC)	Linear	Radial	-
SVM (nu-SVC)	Linear	Radial	-

Como descrito na Tabela 2, o KNN sofreu três variações para verificar taxas de acerto, assim como a MLP (redes neurais artificiais), haja vista que o KNN possui diferenças no cálculo de pesos de suas ligações, e a MLP possui diferenças na quantidade de neurônios em suas camadas escondidas, e a diferença de uma camada escondida com três neurônios para as demais com duas camadas escondidas. As variações do SVM ficaram a cargo do *kernel* escolhido para cálculo da função, com função Radial ou função Linear, para dois diferentes modelos o SVM C-SVC e o SVM nu-SVC. Cada uma dessas variações descritas na Tabela 2 foram executadas dez vezes para verificação de mudanças em inicializações de pesos, principalmente com o método MLP, e os melhores resultados dessas execuções foram considerados para comparações.

### 4.3 Filtro de médias móveis

Nas coletas realizadas, a diminuição dos ruídos causados foi minimizada com a técnica de médias móveis, em que os dados coletados foram agrupados em outros arquivos e a média desse agrupamento foi calculada de forma a diminuir os ruídos. Na Figura 4 é visto como os ruídos são amenizados quando aplicada essa técnica de mediana móvel.

Como parâmetro foram criadas duas médias, com agrupamentos dos dados de cinco em cinco, e de dez em dez, dados únicos coletados, para as cinco coletas realizadas. Conforme a Figura 4, uma mediana de oito casas apresentada em (PESSIN et al., 2013) busca suavizar o erro das leituras. Uma alternativa similar foi levada em conta, que foi a aplicação de um filtro de médias móveis, uma vez que são calculadas médias em vez de medianas.

Nesse sentido o presente trabalho busca a comparação de três configurações de filtro. Uma configuração é sem filtro, utilizando o valor original da coleta (*raw value*). As demais duas configurações empregam filtro de média móvel de 5 unidades e 10 unidades.

A utilização dos filtros mencionados podem gerar um atraso na predição da posição da pessoa, haja vista que com somente a leitura do *raw value* se tem um tempo de 1,5 segundo para cada previsão, e quando aplicada as janelas de médias móveis, para a janela de cinco posições, a quantidade de tempo é multiplicada por cinco, e na janela de dez posições o tempo é multiplicado por dez, devido as quantidades unitárias das entradas de dados.

## 4.4 Tolerância a Falhas

A tolerância a falhas implementada nos testes foram realizadas de modo a identificar o quanto cada nó da rede pode ser mais importante na hora de uma coleta, ou seja, aquele que gera menos erros, que possui menos falhas, entre outros. Assim uma técnica foi utilizada, que é a de simular a quebra um nó da rede durante o processo inteiro de coleta, de acordo com o diagrama da Figura 15. De posse da coleta da localização *indoor* assistida, primeiramente, se leva em conta todos os nós ligados da rede, em seguida ocorre a simulação de quebra do primeiro nó e um novo arquivo de dados é criado apenas com os dados dos outros dois nós restantes, e assim o rodízio da simulação de quebras continua até o final das estações base.

Como mencionado nas seções desse Capítulo as coletas são realizadas no ambiente proposto, em seguida a análise do sinal é feita com os seus respectivos filtros no programa WEKA, e assim a análise de tolerância a falhas é realizada a fim de verificar o quanto a arquitetura de localização *indoor* assistida mantém o grau de acerto da localização da pessoa no ambiente.

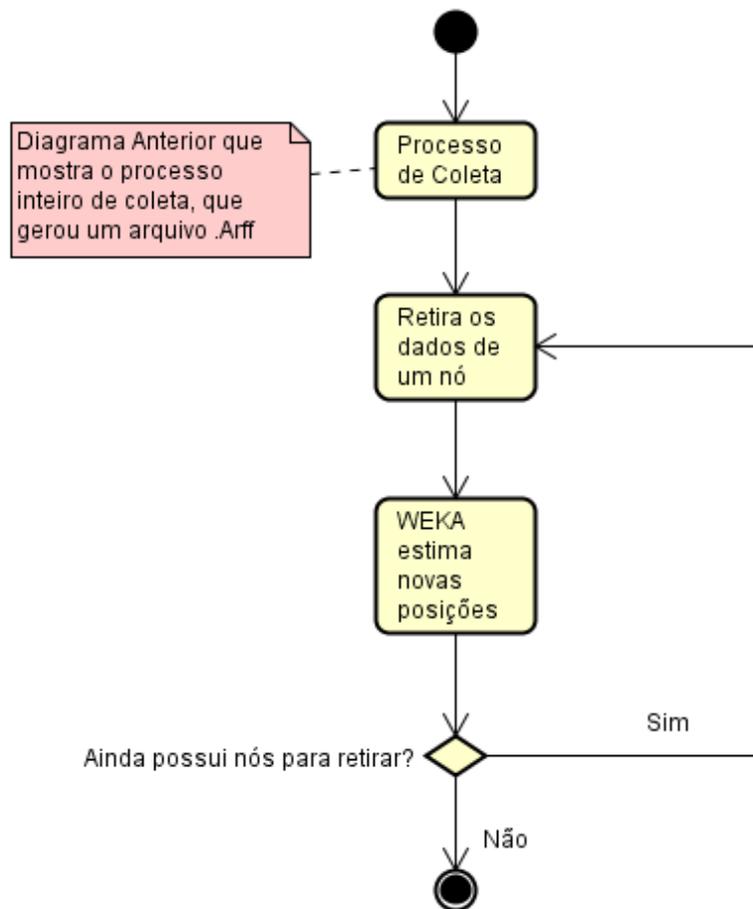


Figura 15: Diagrama do processo de tolerância a falhas.

## 5 Análises Comparativas

Nesse Capítulo são apresentadas as análises que foram consideradas para os dois tipos de estratégias para as arquiteturas avaliadas, notam-se gráficos de *boxplot*, de barras para as avaliações, os *maptrees* que ajudam a identificar os melhores métodos de aprendizado de máquina mais visualmente, bem como quadros para tabulação visível dos dados.

### 5.1 Arquitetura 1: Localização *indoor* pessoal

A chamada localização *indoor* pessoal remete, como já dita, a uma pessoa informando a rede sua posição e assim estimativas da mesma são inferidas pelo sistema. Com as coletas de dados realizadas a Figura 16 indica a natureza de como se comporta os dados das cinco coletas para essa primeira estratégia, ainda na Figura 16 a natureza dos dados representam intensidades de sinal (RSSI) que comparam a leitura dos dados originais nas cinco coletas realizadas. Nesse caso para a arquitetura de localização pessoal temos que as médias das cinco coletas nos três roteadores são similares. Com uma variação maior no R1, pode-se afirmar que as distâncias nesse roteador representam melhor a realidade.

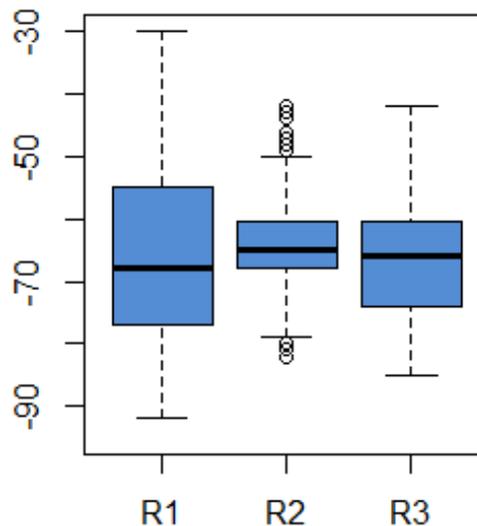


Figura 16: Gráfico com a intensidade de sinal (RSSI) nas 5 coletas para a estratégia de localização *indoor* pessoal. Percebe-se a dispersão das leituras entre os roteadores dispostos na rede para a localização da pessoa em forma de sinal em decibéis.

Após a coleta dos dados, que foram mostrados anteriormente na Figura 16, os mesmos foram transformados no formato ARFF do WEKA, e os métodos de aprendizado de máquinas foram executados, gerando assim as taxas de acerto como resultados, que são inseridos no gráfico da Figura 17. A Figura em questão indica que três tipos de filtros:

os dados executados sem filtros de médias móveis, um filtro de cinco posições e outro de dez posições, além de indicar entre três métodos de aprendizado de máquinas, para dez execuções de cada um, os melhores resultados em suas determinadas configurações. Configurações essas que são chamadas de modelos, em que para o método KNN, foram considerados o KNN sem alterações nos pesos de seus cálculos de distância (NW), além de sua distância sendo calculada com pesos, tendo essa distância sendo diminuída de um (1-D), e o peso calculado com a distância sendo divisível por um (1/D). O método de MLP, possuindo três variações em sua camada escondida, sendo essa camada sendo calculada com apenas 3 neurônios (MLP 3), com duas camadas de 3 neurônios (MLP 3,3) e com duas camadas de 6 neurônios (MLP 6,6). Por fim ainda na Figura 17 o método SVM em duas variações é levado em conta, o SVM com tipo de classificação C-SVC, e dois *kerneis* o com cálculo de função base radial, e com cálculo de função base linear, assim como o segundo tipo de classificação do SVM, o nu-SVC.

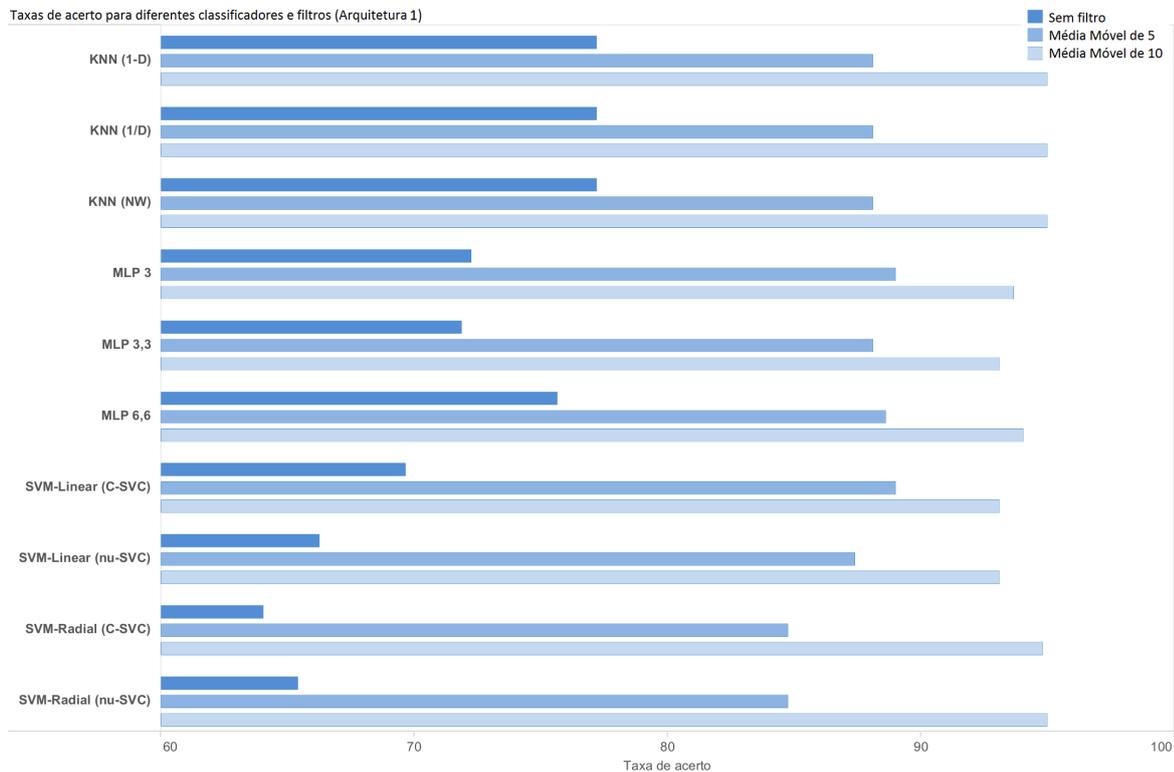


Figura 17: Comparações das taxas de acerto nos algoritmos de aprendizado de máquinas para os métodos com três diferentes *kerneis*, para cada uma dos métodos na arquitetura 1 de localização *indoor* pessoal.

Ainda no gráfico da Figura 17 nota-se que os três diferentes métodos apresentaram comportamento semelhante, com destaque positivo para o método KNN, que mostrou que independentemente do cálculo de seus pesos baseados nas distâncias, como explicado anteriormente, não houveram alterações, os três modelos apresentaram resultados iguais. Quanto ao SVM o comportamento dos *kerneis* foi semelhante quanto ao tipo de cálculo das predições das posições, em que no melhor caso, com média de dez posições, tanto SVM C-

SVC e SVM nu-SVC tiveram índices de acerto iguais para o cálculo radial e estatisticamente semelhante para o cálculo linear. E por fim o MLP teve um comportamento em que a utilização apenas de uma camada escondidas com 3 neurônios obteve melhor resultado que a utilização de duas camadas escondidas com 3 neurônios, entretanto o MLP com duas camadas de 6 neurônios obteve os melhores resultados.

Outra maneira de ilustrar as taxas de acerto é apresentada na Figura 18 que indica um mapa em árvore, ou *treemap*, em que a menor taxa de acerto inicia no canto inferior direito, indicando que o método SVM-Radial (C-SVC) teve o pior desempenho indicado com índice zero, ilustrando que não houve a aplicação de filtro, de acordo com que as taxas de acerto foram aumentando para a arquitetura 1, o mapa de cor cresce, passando pelos casos intermediários que são irradiados dos casos com menos taxa de acerto, sendo que estes foram os resultados dos métodos com médias móveis de cinco posições, por isso a indicação no mapa de índices “cinco”. Por fim, no canto superior esquerdo da Figura 18 tem-se o melhor caso das taxas de acerto, com o método KNN e o método SVM-Radial (nu-SVC) com as melhores taxas, indicadas com 94,99% de acerto de posições no ambiente estudado.

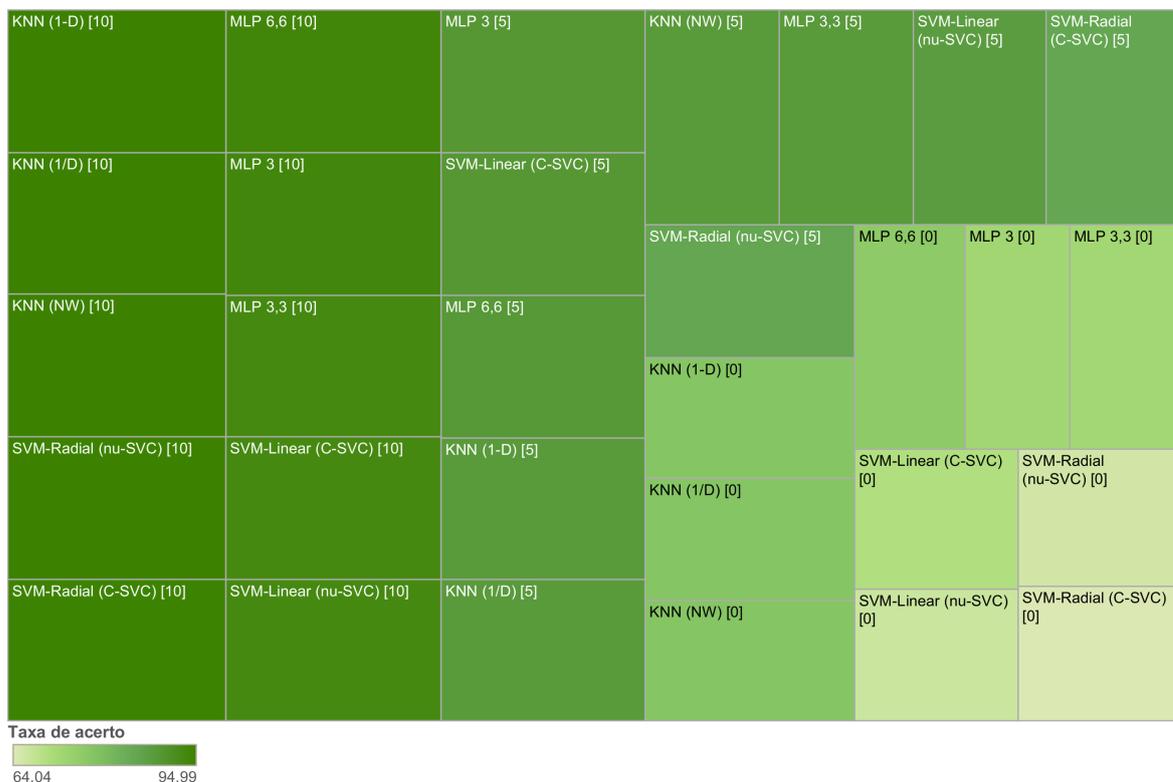


Figura 18: Mapa em árvore (*treemap*) para a arquitetura 1 apresentando tamanho das caixas e cores em relação a taxa de acerto. O gráfico ajuda a perceber que o filtro tem mais impacto que o método de aprendizado utilizado. Acumulados em verde escuro na parte superior esquerda estão todos os métodos com filtro de 10 medidas. Acumulados no canto inferior direito estão todos os métodos sem filtro. Sendo que o melhor método foi o KNN (1-D).

A fim de indicar numericamente os resultados apresentados nas figuras anteriores (Figura 17 e Figura 18), podemos verificar primeiramente o método do KNN, haja vista que foi método mais estável, pois, como não houve sensibilidade dentre as dez execuções do método, o melhor caso apresentado nas figuras mencionadas foi de 77% para o caso sem a aplicação de filtros, e de 94% para o melhor caso com média móvel de dez posições (KNN 1-D). No método do SVM o cálculo linear foi o que obteve melhor resultado, mesmo com dois diferentes tipos de classificação, com o cálculo linear o método atingiu 66% até 93% de taxa de acerto. Por fim, o MLP por ser sensível à inicialização, apenas o melhor caso foi considerado para criação dos gráficos, tendo taxas de acerto das posições da pessoa no ambiente entre 72% até 93% para o MLP 3; 71% até 93% para MLP 3,3; por fim de 75% até 94% para MLP 6,6.

Na Tabela 3 a matriz de confusão para um dos casos de maior sucesso com o método KNN sem a utilização de pesos (NW), este que obteve uma taxa de acerto em torno de 94%. Na Tabela 3 é vista algumas características importantes: a primeira é a caracterização de acerto os dados devem estar concentrados na diagonal principal da matriz, assim como vista na Tabela 3; outra característica é quanto aos erros, que são caracterizados pelos dados que não aparecem na diagonal principal, que são indicados nas coletas C1 e C2, que foram causadas devido à proximidade das duas coletas.

Tabela 3: Matriz de confusão de um dos melhores casos do método inteligente KNN (NW) (Figura 17), com janela de média móvel de dez posições, no esquema de localização *indoor* pessoal

KNN (NW)	C1	C2	C3	C4	C5
C1	100	14	0	0	0
C2	13	99	0	0	0
C3	0	0	116	0	0
C4	0	0	0	84	0
C5	0	0	0	0	113

Em resumo, quanto às mudanças de modelos, o método SVM, em suas duas formas (C-SVC e NU-SVC), a escolha de cálculo para corte do hiperplano para divisão dos conjuntos para as predições não sofreram muitas alterações, pois a diferença entre as taxas de acerto foram pequenas se comparadas aos kernels radial e linear. Os pesos do método KNN não chegaram a influenciar a predição das posições, fazendo com que ele sempre se mantivesse com as mesmas taxas de acerto. O MLP indicou que apesar das mudanças de camadas escondidas o método se manteve estável nas três variações diferentes.

A utilização de filtros de médias móveis também tem um marco interessante, pois todos os casos na Figura 17 a aplicação de filtros foi muito benéfica para o aumento das taxas de acerto, fazendo com que no melhor caso a taxa chegasse a 94% de acurácia.

## 5.2 Arquitetura 2: Localização *indoor* assistida

A chamada localização *indoor* assistida remete, como já dito, a uma pessoa sendo localizada por uma RSSF e assim estimativa das mesmas são inferidas pelo sistema. Com as coletas de dados realizadas a Figura 19 indica a natureza de como se comporta os dados das cinco coletas para essa segunda estratégia, da mesma forma como foi na primeira, ainda na Figura 19 a natureza dos dados, também, representam intensidades de sinal (RSSI) que comparam a leitura dos dados originais nas 5 coletas realizadas. Nesse caso para a estratégia pessoal temos que as médias das 5 coletas nos 3 roteadores indicam que os máximos e mínimos para cada um dos dados dos roteadores estão com boa variação, entretanto nota-se que os dados do roteado R2 são bastante similares ao do R3, fazendo com que os maiores erros possam ser interpretados nesses dois dispositivos.

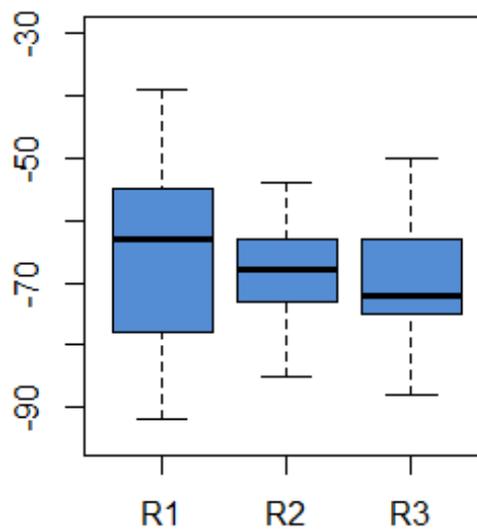


Figura 19: Gráfico com a intensidade de sinal (RSSI) nas 5 coletas para a estratégia de localização *indoor* assistida. Percebe-se a dispersão das leituras entre os roteadores dispostos na rede para a localização da pessoa em forma de sinal em decibéis.

Os dados da Figura 19, foram transformados no formato do programa (WEKA), como mesmo procedimento da primeira arquitetura, com uma leve diferença, nesse momento (localização assistida), cada estação-base irá mapear e gerar seu arquivo de coleta, que é repassado para uma estação que monta apenas um arquivo, com os três arquivos previamente gerados. De acordo com a primeira arquitetura, também foram levados em conta às variações de *kernel* para o método SVM (C-SVC e NU-SVC), as mudanças de camadas escondidas para MLP e as mudanças de peso para o KNN. Nesse sentido as taxas de acerto são inseridas no gráfico da Figura 20 .

Ainda no gráfico da Figura 20 nota-se que os três diferentes métodos apresentaram comportamento semelhante, assim como na primeira arquitetura, o método KNN ainda continua sendo o regular, sem alterações mesmo com as trocas de cálculo dos pesos das

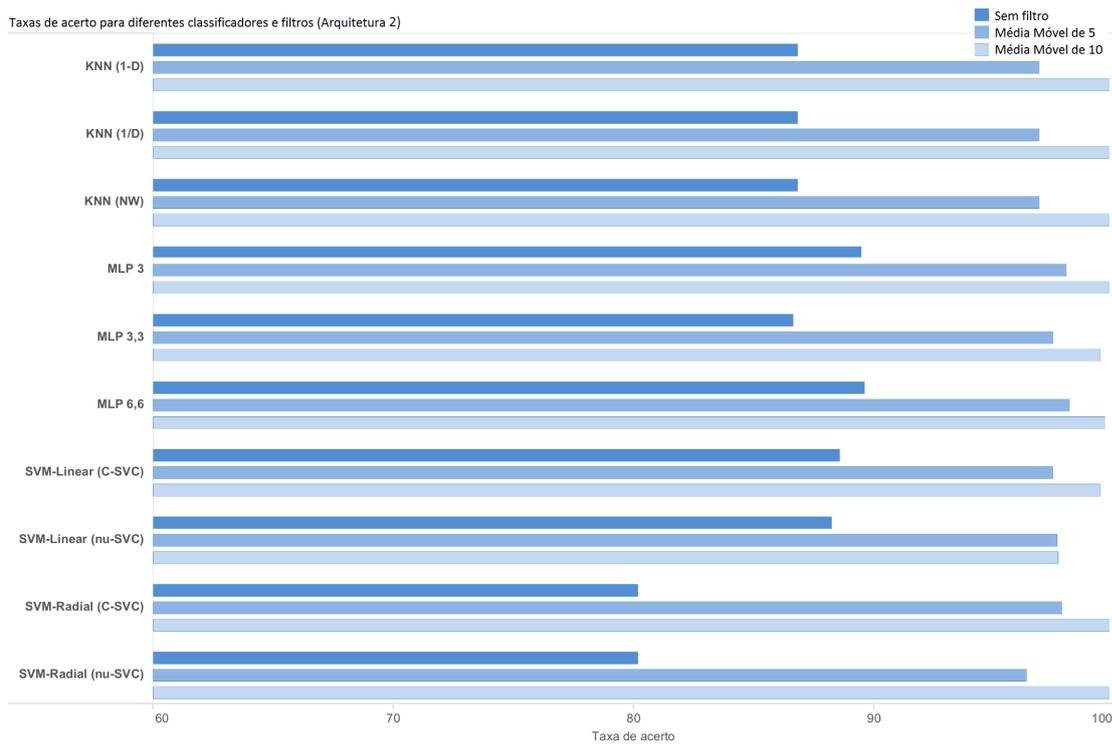


Figura 20: Comparações das taxas de acerto nos algoritmos de aprendizado de máquinas para os métodos com três diferentes kernels, para cada uma dos métodos na arquitetura 2 de localização *indoor* assistida.

distâncias. Quanto ao SVM o comportamento dos *kernels* também foi semelhante quanto ao tipo de cálculo das predições das posições, entretanto, quando se comparado os piores casos dos métodos, que é a não aplicação de filtro de médias móveis, o tipo de cálculo linear tem certa vantagem quanto ao tipo de cálculo radial. Por fim o MLP que sofre com a inicialização dos pesos do método, ainda foram considerados os melhores resultados dentre as dez execuções para cada teste com as camadas intermediárias do algoritmo.

Assim como na arquitetura 1, outra maneira de ilustrar as taxas de acerto é apresentada na Figura 21 que indica um mapa em árvore, ou *treemap*, agora para a arquitetura 2 de localização *indoor* assistida, em que a menor taxa de acerto inicia no canto inferior direito, indicando que o método SVM-Radial (C-SVC) também teve o pior desempenho indicado com índice “zero”, ilustrando que não houve a aplicação de filtro, de acordo com que as taxas de acerto foram aumentando para a arquitetura 2, o mapa de cor cresce, passando pelos casos intermediários que são irradiados dos casos com menos taxa de acerto, sendo que estes foram os resultados dos métodos com médias móveis de cinco posições, por isso a indicação no mapa de índices “cinco”. Por fim, no canto superior esquerdo da Figura 21 tem-se o melhor caso das taxas de acerto, com o método KNN e o método SVM-Radial (nu-SVC) com as melhores taxas. Entretanto, como visto nos dois *treemap* a arquitetura 2 teve vantagem nos piores e melhores casos, sendo que agora a diferença entre o pior e o melhor varia de 80,17% de taxa de acerto até 99,8%.

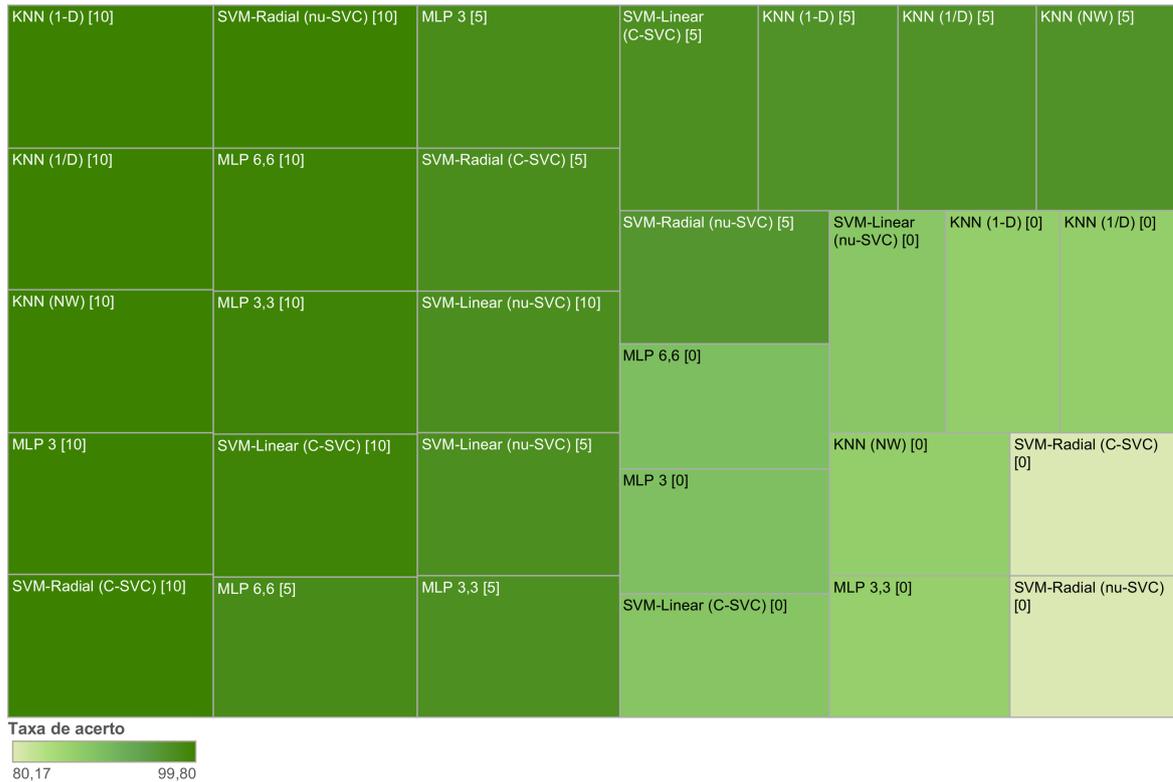


Figura 21: Mapa em árvore (*treemap*) para a arquitetura 2 apresentando tamanho das caixas e cores em relação a taxa de acerto. O gráfico ajuda a perceber que o filtro tem mais impacto que o método de aprendizado utilizado. Acumulados em verde escuro na parte superior esquerda estão todos os métodos com filtro de 10 medidas. Acumulados no canto inferior direito estão todos os métodos sem filtro. Sendo que o melhor método continuou sendo o KNN.

A fim de indicar numericamente os resultados apresentados nas figuras anteriores (Figura 20 e Figura 21), podemos verificar primeiramente o método KNN não sofre alterações quanto ao cálculo do peso quando a distância é levada em conta, contando com variações entre 86% e 99% de taxas de acerto das posições da pessoa no ambiente estudado. O método SVM teve resultados melhores que a arquitetura 1 assim como os outros métodos, entretanto a diferença de acerto quando considerada o pior caso entre os dois tipos de cálculo (linear e radial) para a arquitetura 2, é visto uma diferença de cerca de 8% melhor para o SVM com cálculo linear, tendo uma variação entre 88% até 99% com o SVM (linear) C-SVC. Quanto ao MLP, assim como na arquitetura 1, também, os resultados indicaram que o método MLP 3 teve melhor resultado que o MLP 3,3, mesmo assim a arquitetura 2, de localização *indoor* assistida, teve melhor taxa de acerto, e para o melhor caso da MLP (6,6) teve taxas entre 89% e 99%.

A seguir é apresentada na Tabela 4 a matriz de confusão para um dos casos de maior sucesso com o método KNN sem a utilização de pesos (NW), este que obteve uma taxa de acerto em torno de 99%, como é vista na Tabela 4 a quantidade de erros quando a janela de média móvel está com dez posições é minimizada a discrepância nas coletas 2

e 3, que foram as que causou um erro, devido uma leitura equivocada em que o roteador R2 foi bloqueado por um curioso ao experimento.

Tabela 4: Matriz de confusão do melhor caso do método inteligente KNN (NW) (Figura 20), com janela de média móvel de 10 posições, no esquema de localização *indoor* assistida

KNN (NW)	C1	C2	C3	C4	C5
C1	109	0	0	0	0
C2	0	111	1	0	0
C3	0	0	112	0	0
C4	0	0	0	84	0
C5	0	0	0	0	108

Tendo em vista as duas arquiteturas, a arquitetura de localização *indoor* assistida teve melhores resultados que a arquitetura 1. Isso pode ser indicado pela coleta realizada, haja vista que na arquitetura 2 o roteador coleta apenas a posição da pessoa, e na arquitetura 1 a pessoa busca três dispositivos diferentes para a localização, apesar disso as duas obtiveram excelentes resultados quanto a acurácia nas predições das posições.

### 5.2.1 Tolerância a Falhas

Uma maneira simples de emular falhas em uma rede de sensores sem fio, para esse ambiente de teste é simplesmente desligar um dos nós sensores da rede, assim para as coletas realizadas na estratégia de localização *indoor* assistida, os roteadores foram desligados, e em seguida análises foram realizadas. No modelo descrito na Figura 11 é visto que desligando apenas um roteador as predições de posições ficam a cargo dos outros dois que restaram, e assim por diante, para todos os casos, que são mostrados na Figura 22.

Para o gráfico da Figura 22 foi levado em conta apenas o melhor caso, que foi o método do KNN com médias móveis de dez posições, nesse sentido, se um sistema fosse instalado com essas configurações para predizer a posição de uma pessoa em um ambiente interno, erros maiores acontecem, pois, se tem uma menor quantidade de estações-base para cobrir uma área maior.

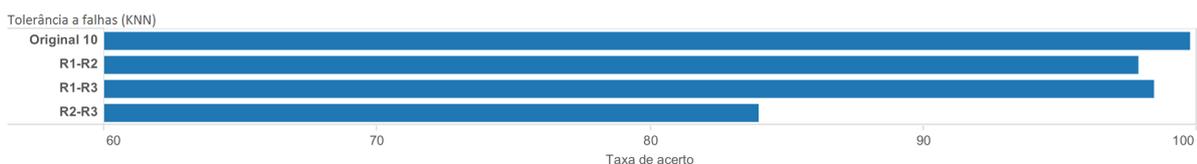


Figura 22: Indicação de taxas de acerto com janelas de médias móveis de 10 posições para tolerância a falhas nos Roteadores do experimento. Retirada de um dos roteadores para o caso do KNN com médias de dez posições.

A retirada de um roteador no caso apresentado acima mostra que o roteador que menos prejudica as leituras é o roteador um (R1), pois quando o roteador um está presente

no modelo às taxas de acerto conseguem se manter acima dos 97%, haja vista que quando o roteador 1 está fora da análise à taxa de acerto da posição de uma pessoa no ambiente interno pesquisado cai para 84%, indicando que apesar de hardwares semelhantes os corpos externos são importantes para melhores coletas.

Como os resultados apresentados no decorrer desse Capítulo mostram, a arquitetura 1, indica com clareza a localização de uma pessoa no ambiente do experimento, com grande precisão, em torno de 94% para o melhor caso, que foi com o algoritmo SVM C-SVC e filtro de dez posições. Além da apresentação da segunda arquitetura, com o melhor caso entre a primeira e a segunda arquitetura, que foi o algoritmo KNN, também com filtro de média móvel de dez posições, com 99% de taxa de acerto da posição da pessoa no ambiente estudado. Assim, pôde-se afirmar que a arquitetura 2 teve uma ligeira vantagem do que a arquitetura 1 e assim o algoritmo para teste dessa estratégia de tolerância a falhas foi selecionado o KNN, que indicou um nível de acerto de cerca de 87% quando o pior caso dessa tolerância foi visualizado.



## 6 Considerações finais e Trabalhos futuros

O trabalho mostra a localização de pessoas em ambientes internos por meio do Wi-Fi com o protocolo 802.11 e com métodos de aprendizado de máquina KNN, MLP e SVM. Além de testar em um ambiente real controlado dois tipos de arquiteturas para localização *indoor*, que foram chamadas de localização *indoor* pessoal, em que uma pessoa indica a rede a sua posição e a localização *indoor* assistida, em que a rede recupera o sinal da pessoa e tenta inferir sua localização através da classificação.

A intensa busca por soluções cada vez mais simples e robustas tem crescido ao longo dos anos, para mudar o panorama da localização *indoor*, e cada vez mais com a busca por soluções testadas em ambientes reais e com menos simulações. Em localização indoor ainda a utilização do RSSI é uma constatação que modelos simples podem gerar resultados satisfatórios para a academia, além da junção dessas técnicas com RSSI vinculadas a métodos de aprendizado de máquina, sendo a classificação uma maneira de gerar tais resultados. Assim diversas técnicas mais clássicas como ângulo da antena (AOA), tempo e sincronização (TOA), diferença temporal entre emissão de rádio e ultrassom (TDOA) apresentam diferenças entre si, sempre verificando qual é a que tem melhores resultados com as peculiaridades que as RSSF oferecem.

Assim métodos de classificação como KNN ou SVM, sendo que o KNN utiliza os dados dos seus vizinhos mais próximos para realizar o cálculo de sua localização. Além das redes neurais através da MLP que possuem em seu treinamento diversas camadas escondidas que podem alterar os valores de predição de posições. Nesse experimento, o método KNN conseguiu em certos pontos uma taxa de acerto de 99% para técnica de localização assistida, quando usada técnica de médias móveis para suavização do sinal. O SVM foi o que sofreu mais com as variações de *kernels*, pois suas taxas de acerto variaram para os a arquitetura de localização *indoor* pessoal, de 64% até 94% com o método SVM radial (C-SVC). O MLP indicou que a quantidade de camadas escondidas também deve ser levada em consideração, pois suas taxas de acerto variaram entre 80% e 99% para a segunda estratégia também. Quanto aos resultados da primeira estratégia, que foram levemente inferiores, a localização *indoor* pessoal, o método mais consistente também foi o KNN.

Essa consistência do KNN levou a considerá-lo para verificação de tolerância a falhas, caso um nó da rede simplesmente não funcionasse durante o período de testes o sistema deveria se manter de maneira coesa. Quando aplicada filtros de médias móveis de dez posições que foi o melhor caso, o KNN verificou que o roteador que fica *offline* possui relevância para o modelo, haja vista que houve variações entre 84% e 97% de taxa

de acerto.

Em comparação a diversos trabalhos, mais precisamente (SCHNEIDER; ANDREÃO; NUNES, 2011), que indicou que o KNN foi mais preciso em seu experimento em relação ao MLP, o que ficou claro no trabalho que foi similar o resultado, além de Popleteev, Osmani e Mayora (2012) que indicou que o KNN possui certa semelhança com o SVM, ainda levando pouca vantagem, o que ocorreu no experimento.

## 6.1 Trabalhos Futuros

Para testes em ambientes reais, a questão da mobilidade é de extrema importância, assim a utilização de desktops é inviável, e assim, todos os testes foram realizados utilizando notebooks. Porém referente à mobilidade do agente coletor de dados, inclui-se nos trabalhos futuros com a substituição do notebook por plataformas menores, como o *raspberry*, visto que esta permite a reutilização de grande parte do trabalho já realizado sem necessidade de reescrita completa dos aplicativos, além de a comparação com outros protocolos presentes na literatura, e a inserção de novos métodos para localização, como IMU ou *Deep Learning*, em uma base de dados para predição da posição de agentes em locais fechados.

Como descrito acima, em forma de itens, os trabalhos futuros compreendem:

- Realizar o experimento em áreas maiores;
- Realizar o experimento utilizando *hardwares* com limitações de memória e processamento, como *raspberrys*, *Edison*, ou *Arduínos*;
- Realizar o experimento utilizando de novos protocolos como o 802.15.4 (Zigbee), ou o protocolo *Bluetooth*;
- Realizar o experimento verificando com novos métodos como *Deep Learning* ou movimentos inerciais;
- Avaliar métodos de regressão ao contrário de métodos de classificação.

# Referências

- ALES, V. T. *O Algoritmo Sequential Minimal Optimisation para Resolução do Problema de Support Vector Machine: uma Técnica para Reconhecimento de Padrões*. Tese (Doutorado) — Dissertação de Mestrado, Universidade Federal do Paraná, 2008, 150, 2008.
- BELTRAMI, M. *Precificação de opções sobre ações por modelos de Support Vector Regression*. Tese (Doutorado) — Dissertação de Mestrado, Universidade Federal do Paraná, 2009, 125, 2009.
- BOUKERCHE, A. et al. Localization systems for wireless sensor networks. *wireless Communications, IEEE, IEEE*, v. 14, n. 6, p. 6–12, 2007.
- BRICE, R. *Music engineering*. [S.l.]: Newnes, 2001.
- CHAVES, A. d. C. F. *Extração de Regras Fuzzy para Máquinas de Vetores Suporte (SVM) para Classificação em Múltiplas Classes*. Tese (Doutorado) — PUC-Rio, 2006.
- DEPARTMENT, U. F. *U.S. fire statistics*. 2012. Disponível em: <<http://www.usfa.fema.gov/data/statistics/#tab-3>>.
- DOBBINS, R. *Software defined radio localization using 802.11-style communications*. Tese (Doutorado) — Naval Research Laboratory, 2011.
- EXEL, R.; LOSCHMIDT, P. High accurate timestamping by phase and frequency estimation. In: IEEE. *Precision Clock Synchronization for Measurement, Control and Communication, 2009. ISPCS 2009. International Symposium on*. [S.l.], 2009. p. 1–6.
- FARID, Z.; NORDIN, R.; ISMAIL, M. Recent advances in wireless indoor localization techniques and system. *Journal of Computer Networks and Communications*, Hindawi Publishing Corporation, v. 2013, 2013.
- HALL, M. et al. The weka data mining software: an update. *ACM SIGKDD explorations newsletter*, ACM, v. 11, n. 1, p. 10–18, 2009.
- HAYKIN, S. S. *Kalman filtering and neural networks*. [S.l.]: Wiley Online Library, 2001.
- JEKABSONS, G.; KAIRISH, V.; ZURAVLYOV, V. An analysis of wi-fi based indoor positioning accuracy. *Scientific Journal of Riga Technical University. Computer Sciences*, v. 44, n. 1, p. 131–137, 2011.
- JUNG, J.; KANG, D.; BAE, C. Distance estimation of smart device using bluetooth. In: *ICSNC 2013, The Eighth International Conference on Systems and Networks Communications*. [S.l.: s.n.], 2013. p. 13–18.
- JUNIOR, A. M.; MADEIRA, M. S. A segurança do trabalho em minas de carvão agindo na prevenção da pneumoconiose - região carbonífera de santa catarina. 2005.
- KHATCHATOURIAN, O.; PADILHA, F. R. Reconhecimento de variedades de soja por meio do processamento de imagens digitais usando redes neurais artificiais. *Eng Agric Jaboticabal*, v. 28, n. 4, p. 759–69, 2008.

- KIM, J.; JUN, H. Vision-based location positioning using augmented reality for indoor navigation. *Consumer Electronics, IEEE Transactions on*, IEEE, v. 54, n. 3, p. 954–962, 2008.
- LEE, P. A.; ANDERSON, T. *Fault tolerance: principles and practice*. [S.l.]: Springer Science & Business Media, 2012. v. 3.
- LIMA, A. R. G. Máquinas de vetores suporte na classificação de impressões digitais. *Universidade Federal do Ceará, Departamento de Computação, Fortaleza-Ceará*, 2002.
- LIU, H. et al. Survey of wireless indoor positioning techniques and systems. *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, IEEE, v. 37, n. 6, p. 1067–1080, 2007.
- MARTI, J. V. et al. Localization of mobile sensors and actuators for intervention in low-visibility conditions: the zigbee fingerprinting approach. *International Journal of Distributed Sensor Networks*, Hindawi Publishing Corporation, v. 2012, 2012.
- NEIVA, J. P. B. et al. Localização e orientação “indoor” com recurso à tecnologia rfid. *Master Thesis in Electrical and Computer Engineering. Faculty of Engineering of University of Porto*, 2012.
- OZSOY, K.; BOZKURT, A.; TEKIN, I. Indoor positioning based on global positioning system signals. *Microwave and Optical Technology Letters*, Wiley Online Library, v. 55, n. 5, p. 1091–1097, 2013.
- PARAMESWARAN, A. T. et al. Is rssi a reliable parameter in sensor localization algorithms: An experimental study. In: *Field Failure Data Analysis Workshop (F2DA09)*. [S.l.: s.n.], 2009.
- PEI, Z. et al. Anchor-free localization method for mobile targets in coal mine wireless sensor networks. *Sensors*, Molecular Diversity Preservation International, v. 9, n. 4, p. 2836–2850, 2009.
- PEREIRA, E. *Desenvolvimento de um sistema de localização de fontes Rádio Frequência para aplicações indoor*. Dissertação (Mestrado) — Universidade do Porto, 2011.
- PESSIN, G. et al. Investigation on the evolution of an indoor robotic localization system based on wireless networks. *Applied Artificial Intelligence*, Taylor & Francis, v. 27, n. 8, p. 743–758, 2013.
- POPLETEEV, A.; OSMANI, V.; MAYORA, O. Investigation of indoor localization with ambient fm radio stations. In: IEEE. *Pervasive Computing and Communications (PerCom), 2012 IEEE International Conference on*. [S.l.], 2012. p. 171–179.
- RAVINDRA, S.; JAGADEESHA, S. Time of arrival based localization in wireless sensor networks: A linear approach. *arXiv preprint arXiv:1403.6697*, 2014.
- RUIZ, A. R. J. et al. Accurate pedestrian indoor navigation by tightly coupling foot-mounted imu and rfid measurements. *Instrumentation and Measurement, IEEE Transactions on*, IEEE, v. 61, n. 1, p. 178–189, 2012.

- SAKAGAMI, S. et al. Vehicle position estimates by multibeam antennas in multipath environments. *Vehicular Technology, IEEE Transactions on*, IEEE, v. 41, n. 1, p. 63–68, 1992.
- SCHNEIDER, V.; ANDREÃO, R.; NUNES, R. Sistema de localização para ambientes fechados baseado na intensidade de sinal recebido em rede zigbee. In: *Simpósio Brasileiro de Automação Inteligente*. [S.l.: s.n.], 2011. p. 875–880.
- SILVA, L. M. O. da. *Uma aplicação de árvores de decisão, redes neurais e KNN para a identificação de modelos ARMA não-sazonais e sazonais*. Tese (Doutorado) — PUC-Rio, 2005.
- STOJANOVIC, D.; STOJANOVIC, N. Indoor localization and tracking: Methods, technologies and research challenges. *Facta Universitatis*, p. 57–72, 2014.
- THIRUMURUGANATHAN, S. A detailed introduction to k-nearest neighbor (knn) algorithm. *Tersedia: <http://saravananthirumuruganathan.wordpress.com/2010/05/17/a-detailedintroduction-to-k-nearest-neighbor-knn-algorithm/>*[26 Januari 2012], 2010.
- VAPNIK, V. The nature of statistical learning theory. Springer, 2nd edition, 1999.
- WEBER, T. S. Tolerância a falhas: conceitos e exemplos. *Apostila do Programa de Pós-Graduação–Instituto de Informática-UFRGS. Porto Alegre*, 2003.
- YAMASAKI, R. et al. Tdoa location system for ieee 802.11 b wlan. In: IEEE. *Wireless Communications and Networking Conference, 2005 IEEE*. [S.l.], 2005. v. 4, p. 2338–2343.
- YOO, J. et al. Wifi localization on the international space station. In: *Intelligent Embedded Systems (IES), 2014 IEEE Symposium on*. [S.l.: s.n.], 2014. p. 21–26.
- ZHANG G., P. B.; HU, M. Forecasting with artificial neural networks: the state of the art. v. 14, n. 1, p. 35–62, 1998.
- ZHOU, Y.; LIU, W.; HUANG, P. Laser-activated rfid-based indoor localization system for mobile robots. In: IEEE. *Robotics and Automation, 2007 IEEE International Conference on*. [S.l.], 2007. p. 4600–4605.