



## **TRABALHO DE GRADUAÇÃO**

# **LOCALIZAÇÃO DE USUÁRIOS EM AMBIENTES PREDIAIS ATRAVÉS DE SISTEMA RFID E CLASSIFICADORES SUPERVISIONADOS VISANDO ECONOMIA DE ENERGIA**

**Vitor Almeida Barbosa**

**Brasília, Abril de 2013**



**ENGENHARIA  
MECATRÔNICA**  
UNIVERSIDADE DE BRASÍLIA

UNIVERSIDADE DE BRASÍLIA

Faculdade de Tecnologia

Curso de Graduação em Engenharia de Controle e Automação

## TRABALHO DE GRADUAÇÃO

# LOCALIZAÇÃO DE USUÁRIOS EM AMBIENTES PREDIAIS ATRAVÉS DE SISTEMA RFID E CLASSIFICADORES SUPERVISIONADOS VISANDO ECONOMIA DE ENERGIA

**Vitor Almeida Barbosa**

Relatório submetido como requisito parcial para obtenção

do grau de Engenheiro de Controle e Automação.

### **Banca Examinadora**

Prof. Adolfo Bauchspiess, UnB/ ENE

Orientador

Prof. Geovany Araújo Borges, UnB/ ENE

Examinador interno

Prof. Renato Borges, UnB/ENE

Examinador interno

---

---

---

Brasília, Abril de 2013

## FICHA CATALOGRÁFICA

BARBOSA, V. A.

LOCALIZAÇÃO DE USUÁRIOS EM AMBIENTES PREDIAIS ATRAVÉS DE SISTEMA RFID E CLASSIFICADORES SUPERVISIONADOS VISANDO ECONOMIA DE ENERGIA

[Distrito Federal, 2013]

xiii, 130p., 297 mm (FT/UnB, Engenheiro, Controle e Automação, 2013). Trabalho de Graduação – Universidade de Brasília. Faculdade de Tecnologia.

1. Automação

2. Conforto térmico

I. Mecatrônica/FT/UnB

## REFERÊNCIA BIBLIOGRÁFICA

Barbosa, V. A., (2013). Localização de usuários em ambientes prediais através de sistema RFID e classificadores supervisionados visando economia de energia. Trabalho de Graduação em Engenharia de Controle e Automação, Publicação FT.TG-nº XX , Faculdade de Tecnologia, Universidade de Brasília, Brasília, DF, 130p.

## CESSÃO DE DIREITOS

AUTOR: Vitor Almeida Barbosa.

TÍTULO DO TRABALHO DE GRADUAÇÃO: Sistema de Identificação de Usuários Utilizando RFID para a Racionalização de Energia em Ambientes Inteligentes.

GRAU: Engenheiro de Controle e Automação

ANO: 2013

É concedida à Universidade de Brasília permissão para reproduzir cópias deste Trabalho de Graduação e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desse Trabalho de Graduação pode ser reproduzida sem autorização por escrito do autor.

## RESUMO

A aplicação de algoritmos de aprendizagem supervisionada que realizem classificação de padrões em ambientes prediais, se utilizando de dados advindos de sistema de RFID, permite controlar de forma racional o acionamento de aparelhos de ar-condicionado. Neste trabalho, os algoritmos classificadores utilizados foram o Multilayer Perceptron (MLP) e o Support Vector Machine (SVM), ambos treinados com valores de RSSI coletados por um sistema de controle de acesso via RFID (Radio Frequency Identification) instalado em um ambiente predial. Os resultados mostraram que a abordagem de classificação de padrões é viável para localização de usuários e possui boa taxa de acerto na classificação dos três ambientes propostos. Foi possível propor uma metodologia para o desenvolvimento de um sistema capaz de realizar o acionamento automático de aparelhos de ar-condicionado, proporcional ao grau de ocupação do laboratório, a fim de garantir conforto e economia de energia.

**Palavras-chave:** RFID, RSSI, localização de usuários, Redes Neurais Artificiais, Perceptron Multicamadas, racionalização de energia.

## ABSTRACT

Applying supervised learning algorithms that perform pattern classification in indoor environments, using data from RFID system, allows controlling rationally the air-conditioning system. In this work, the classification algorithms used were Multilayer Perceptron (MLP) and Support Vector Machine (SVM), both trained with RSSI values collected from a RFID (Radio Frequency Identification) access control system present in an indoor environment. The results showed that the pattern classification approach is feasible for locating users and has good accuracy rate in the classification of the three proposed environments. It was possible to propose a methodology for the development of a system capable of performing the automatic actuation of air-conditioning systems, proportional to the degree of occupation of the laboratory to ensure comfort and energy savings.

**Key-words:** RFID, RSSI, user localization, Artificial Neural Networks, Multilayer Perceptron, energy savings.

## Sumário

1	Introdução.....	8
1.1	Objetivos.....	8
1.2	Definição do Problema .....	8
1.3	Motivação: Consumo Energético .....	9
2	Sistemas RFID .....	12
2.1	Hardware utilizado .....	18
3	Desenvolvimento do sistema de localização.....	20
3.1	Trabalhos Anteriores .....	20
3.2	Machine Learning.....	20
3.3	Redes Neurais Artificiais .....	23
3.4	Sistema Proposto .....	26
3.5	Configuração do Ambiente .....	27
4	Análise dos Resultados .....	32
4.1	Melhorando o desempenho da rede .....	42
4.2	Análise dos resultados após as melhorias .....	45
4.3	Resumo do projeto do sistema de localização .....	49
5	Conclusão .....	51
5.1	Trabalhos Futuros .....	51
6	Bibliografia .....	53

## Lista de Figuras

<i>Figura 1. Participação de diversos equipamentos elétricos no consumo total do setor residencial. (Eletrobras 2007).</i>	11
<i>Figura 2. Distribuição de consumo no setor comercial. (Eletrobras 2007).</i>	11
<i>Figura 3. Distribuição de consumo no setor público. (Eletrobras 2007).</i>	11
<i>Figura 4. Funcionamento de um sistema RFID.</i>	13
<i>Figura 5. Pedágio utilizando sistema RFID.</i>	13
<i>Figura 6. Propagação do sinal eletromagnético em um meio qualquer. O sinal atenua à medida que a onda se propaga no espaço.</i>	14
<i>Figura 7. Variação do RSSI com a distância, em um ambiente aberto.</i>	15

<i>Figura 8. Variação do RSSI com a distância, em um ambiente fechado.</i>	15
<i>Figura 9. Processo de interferência entre duas ondas.</i>	16
<i>Figura 10. Caminhos múltiplos de reflexão de uma onda. Leitora em verde, tag em azul.</i>	17
<i>Figura 11. Regiões de fronteira (vermelho) são críticas em qualquer algoritmo de classificação por ambientes.</i>	17
<i>Figura 12. Leitora modelo L-RX900 com antena omnidirecional de modelo L-N200 Stub, frequência de operação 433MHz, e distância efetiva de leitura de 7m.</i>	18
<i>Figura 13. Tag ativa, modelo L-TG501.</i>	19
<i>Figura 14. Figura que mostra a leitora e a tag em cima da mesa da sala de reuniões do LARA. Foto mostra o cabo UTP que conecta a leitora à rede TCP/IP do LARA. A tag possui uma cavidade para que se utilize um fio a fim de portá-la como um crachá.</i>	19
<i>Figura 15. Abstração do conceito de neurônio.</i>	23
<i>Figura 16. Rede Neural e suas camadas.</i>	24
<i>Figura 17. Visão geral da proposta do sistema.</i>	26
<i>Figura 18. Região do LARA escolhida para o desenvolvimento dos experimentos.</i>	28
<i>Figura 19. Definição inicial dos ambientes. Retângulos azuis indicam as posições reais dos aparelhos de ar-condicionado do LARA.</i>	28
<i>Figura 20. A divisão do laboratório proposta nesse trabalho, que inclui o posicionamento das leitoras, representadas por círculos azuis.</i>	29
<i>Figura 21. Os 15 pontos de coleta definidos nesse trabalho.</i>	30
<i>Figura 22. Valores do RSSI para coletas com a tag parada(acima) e com a tag em movimento (abaixo). As coletas acima foram feitas na mesma posição dentro do laboratório e com a tag tendo a mesma orientação.</i>	32
<i>Figura 23. Região vermelha representa o pico de sinal ao redor da localização de uma determinada leitora.</i>	33
<i>Figura 24. Figura que mostra na parte superior o sinal de RSSI medido em cada uma das 5 leitoras durante 20 coletas. Abaixo a predição da rede neural para cada uma dessas coletas. A rede neural se "ancorou" na variação da leitora 12.</i>	34
<i>Figura 25. Novo layout proposto, de forma a distanciar as leitoras e permitir uma maior diferenciação na atenuação dos sinais. Linhas em vermelho definem as fronteiras dos ambientes.</i>	35
<i>Figura 26. Algoritmo heurístico, feito em uma estrutura condicional-relacional.</i>	35
<i>Figura 27. Os primeiros 500 dados representam o ambiente 3, os próximos 400 dados representam o ambiente 2 e os 400 últimos o ambiente 1.</i>	37
<i>Figura 28. Leitora isolada plotada junto com a média dos valores a cada um dos 13 grupos de 100 dados, a fim de permitir fácil visualização dos diferentes níveis de atenuação que ocorrem ponto a ponto.</i>	38
<i>Figura 29. Sinal de RSSI representando o mapa de atenuação do ambiente 3 para apenas uma leitora.</i>	38
<i>Figura 30. Comparação entre coletas feitas para um mesmo ponto, porém em momentos distintos do dia. Análise criteriosa mostra diferenças sensíveis entre os dados.</i>	40
<i>Figura 31. O instante em que ocorre mudança na classificação é devido ao usuário realizando a coleta que resolve "sair da frente" da tag, pois este bloqueava o caminho mais curto entre esta e a leitora 12 (em verde). O sinal rapidamente sobe e ativa o limiar do classificador (instante 13).</i>	41
<i>Figura 32. Pessoa passando muito próxima da tag durante os instantes de coleta 25 a 35. Há enorme variação do sinal nesse momento.</i>	41
<i>Figura 33. RSSI da leitora 10 sofre forte queda no instante de coleta 9. Não foi possível detectar o motivo dessa queda. A orientação da tag não mudou, e o laboratório estava vazio, exceto pelo usuário fazendo o experimento.</i>	42
<i>Figura 34. Gráfico ilustra a atenuação da variação do RSSI quando faz-se a média de duas coletas distintas.</i>	43
<i>Figura 35. Compara o desvio padrão das duas coletas, com o desvio padrão da média entre elas.</i>	43
<i>Figura 36. As saídas de 13 dos 15 neurônios da camada de saída da rede neural para 9 dados coletados.</i>	44

<i>Figura 37. Imagem de cima mostra o mapa de atenuação em um determinado ponto, que é ensinado para a rede. Imagem de baixo ilustra o que foi coletado no mesmo ponto durante o teste em tempo real. A rede ainda assim conseguiu acertar todos os pontos.</i>	45
<i>Figura 38. Rede neural mudando sua predição após o sinal das 5 leitoras mudar consideravelmente.</i>	46
<i>Figura 39. Figura que mostra claramente que quando o sinal do RSSI voltou a se parecer com o sinal ensinado à rede (figura na metade superior) esta passa a acertar todos as classificações.</i>	47
<i>Figura 40. Desempenho da rede neural na fase online para os métodos 1 e 2 e para o algoritmo heurístico.</i>	47
<i>Figura 41. Tela de supervisorio, para coletar os valores de RSSI ao longo do tempo e mostrar a posição dos usuários. O gráfico mostra a variação do RSSI para cada uma das 5 leitoras ao longo do tempo.</i>	50
<i>Figura 42. Histograma para 100 valores de RSSI provenientes de uma mesma leitora e coletados no mesmo ponto.</i>	52

---

# 1 Introdução

O presente trabalho buscou dar continuidade às pesquisas no Laboratório de Automação e Robótica (LARA) da UnB com foco em localização de usuários em ambientes prediais através de sistemas RFID. Aqui, buscou-se dar seguimento à abordagem adotada no último trabalho realizado [7] e investigou-se mais à fundo outras metodologias ainda não exploradas. Foi possível confirmar a exequibilidade de um sistema de localização de usuários por ambientes através de uma abordagem que enxergou a localização de usuários como um problema de classificação de padrões.

## 1.1 Objetivos

O objetivo desse trabalho não foi criar o sistema de localização propriamente dito, mas investigar a exequibilidade de tal sistema e fornecer amparo técnico na forma de metodologias úteis para um futuro desenvolvedor do supracitado sistema. Conclusões foram tomadas acerca de estratégias de posicionamento de leitoras RFID, algoritmos heurísticos de classificação, métodos para aumentar a robustez de treinamentos de classificadores supervisionados, metodologias para melhorar o desempenho de redes neurais classificadoras de padrão. Investigou-se as características intrínsecas de repetibilidade do RSSI e sua possibilidade de uso em classificação de padrões.

## 1.2 Definição do Problema

Muitos sistemas RFID fornecem apenas o Received Signal Strength Indicator (RSSI) como possível parâmetro para cálculo de distâncias entre etiquetas ativas e leitoras RFID. O uso de tal parâmetro é dificultado pelo fato de não haver uniformidade nas leituras do seu valor. Diversos fatores contribuem para que o valor do RSSI varie muito ao longo tempo, mesmo quando avaliado em um mesmo ponto no espaço com condições praticamente idênticas. Buscou-se entender que tal comportamento de variabilidade, segue um determinado padrão no tempo, e, para um determinado local, mantidas as configurações dos móveis no ambiente, é possível capturar esse padrão e aguardar o momento em que ele se manifeste novamente.

Algoritmos de machine learning usam diferentes tipos de paradigmas de programação e abordagens para conseguir simular, em computadores, a capacidade de aprendizado do cérebro humano. Entre os diversos tipos existentes, estão os algoritmos de aprendizado supervisionado, cujo princípio será detalhado nas seções seguintes deste trabalho. É possível usar tais algoritmos para classificar padrões de dados, e dada a premissa do parágrafo anterior, estudou-se a possibilidade de sucesso na tentativa de viabilizar o uso do RSSI como estimador de distâncias entre etiquetas e leitoras.

Ao alimentar algum desses classificadores supervisionados com dados provenientes de um sistema de localização de usuários baseado em RFID, é possível permitir que o programa reconheça quais ambientes possuem ou não pessoas em seu interior, e assim, ligar ou desligar os aparelhos de ar-condicionado apropriados. O LARA adquiriu um sistema de controle de acesso via Identificação por Rádio Frequência (RFID) que, a princípio, pode ser usado como base para um sistema de localização de usuários em



ambientes prediais. Um sistema desse tipo, pode reduzir os custos de consumo energético predial, através do controle racional de aparelhos de ar-condicionado.

### 1.3 Motivação: Consumo Energético

Adquirir boa eficiência energética tem sido uma meta da maior relevância para empresas e governos ao longo dos últimos anos, por ser uma solução econômica, eficaz e rápida para mitigar o impacto do alto consumo de energia nas mudanças climáticas do planeta, um problema que cada vez mais preocupa a comunidade científica mundial. Não obstante, a melhoria da eficiência energética traz, ainda, outras vantagens. Poupa recursos naturais, como o petróleo e o gás, diminui custos de produção, possibilita a produção de bens cada vez mais baratos e competitivos, melhora o desempenho econômico das empresas, permite investimentos mais eficazes em infraestrutura e energia, pois é mais barato racionar do que gerar. Além disso, melhora o retorno do investimento realizado, já que o montante é recuperado ao longo da vida útil de equipamentos, por conta da economia de energia ocorrida [1]. Melhorar a eficiência energética significa, enfim, deixar recursos disponíveis para as gerações que estão por vir.

Mas o que significa ter alta eficiência energética? Equipamentos e sistemas, para funcionar, transformam uma forma de energia em outra. Uma parte dela sempre é perdida para o meio ambiente durante esse processo. Por exemplo: uma lâmpada transforma a eletricidade em luz e calor. Como o objetivo da lâmpada é iluminar, uma medida da sua eficiência é obtida dividindo a energia gasta na forma de luz pela energia elétrica usada pela lâmpada. Da mesma forma, pode-se avaliar a eficiência de um automóvel dividindo a quantidade de energia cinética que o veículo possui em seu deslocamento pela quantidade que estava contida na gasolina originalmente. Esse cálculo visa representar o quanto há de perdas inerentes durante os processos de transformação de energia. Entretanto, outra fonte de perdas deriva do uso inadequado dos aparelhos e sistemas, ou simplesmente do desperdício. Uma lâmpada acesa em uma sala vazia também configura um desperdício, já que a luz não está servindo ao seu propósito de iluminação [2]. Da mesma maneira, aparelhos de ar-condicionado funcionando durante a madrugada, em um laboratório sem pessoas, ocasionam um enorme consumo desnecessário de energia. Esse último exemplo é um problema que atualmente acomete o Laboratório de Automação e Robótica (LARA), do Departamento de Engenharia Elétrica da Universidade de Brasília.

Avaliando o cenário global, o Brasil desperdiça, por ano, cerca de 12,6 milhões de megawatts-hora, energia suficiente para abastecer a cidade do Rio de Janeiro por um ano. O desperdício representa R\$ 11,3 bilhões, de dinheiro gasto a mais, em energia, do que seria necessário. O setor público – municipal, estadual e federal – é o que, proporcionalmente, mais desperdiça energia: cerca de 40% dos gastos são para pagar a conta do desperdício [4]. O aumento no consumo de energia elétrica no Brasil está nas previsões do Governo Federal. O consumo de energia elétrica cresceu 3,8% em maio de 2012, em relação ao mesmo período do ano passado [5]. O relatório de 2012 para o Balanço Energético Anual Brasileiro [3] indica o consumo energético por setor, em toneladas equivalentes de petróleo (tep). Verificou-se que o consumo total dos setores de Serviços, Comercial e Público e Residencial somam 119.126 tep, o que representa 52% do total de 228.919 de consumo em todos os setores brasileiros, como pode-se verificar pela Tabela 1, que segue abaixo:

**Tabela 1. Consumo final energético brasileiro, por setores. Destaque para o consumo dos setores Comercial e Público, Serviços e Residencial. (Eletrobras 2007).**

Consumo Final Energético											10 <sup>3</sup> tep (toe)
	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	
CONSUMO FINAL ENERGÉTICO	165.543	169.622	178.221	182.687	188.574	201.338	211.717	206.224	224.252	228.919	FINAL ENERGY CONSUMPTION
SERVIÇOS	57.285	56.370	59.929	61.362	62.354	67.112	72.201	72.717	79.669	84.871	SERVICES
COMERCIAL E PÚBLICO <sup>1</sup>	8.122	8.210	8.461	8.903	9.083	9.491	9.757	10.031	10.238	10.881	COMMERCE AND OTHERS <sup>1</sup>
TRANSPORTES	49.163	48.160	51.469	52.459	53.270	57.621	62.444	62.687	69.430	73.989	TRANSPORTATION
AGROPECUÁRIO	7.812	8.152	8.276	8.358	8.550	9.062	9.905	9.453	9.904	9.882	AGRICULTURE AND LIVESTOCK
INDÚSTRIA	65.373	68.367	72.217	73.496	76.757	81.856	82.327	76.413	85.678	88.416	INDUSTRY
EXTRATIVA MINERAL <sup>2</sup>	2.356	2.495	2.642	2.905	3.013	3.342	3.349	2.395	3.113	3.289	MINING <sup>2</sup>
TRANSFORMAÇÃO	63.018	65.872	69.575	70.592	73.745	78.514	78.978	74.018	82.565	85.127	TRANSFORMATION INDUSTRY
NÃO METÁLICOS <sup>3</sup>	6.190	5.935	5.864	6.243	6.620	7.214	7.899	7.770	8.637	9.309	NON-METALS <sup>3</sup>
METALURGIA <sup>4</sup>	21.380	23.185	24.806	24.503	24.292	26.026	26.015	20.598	24.132	26.109	FERROUS AND NON-FERROUS <sup>4</sup>
QUÍMICA	6.595	6.547	7.115	7.168	7.364	7.657	7.209	6.774	7.443	7.464	CHEMICAL
ALIMENTOS E BEBIDAS	15.839	16.659	17.599	17.926	20.122	21.262	20.694	21.623	23.646	22.972	FOODS AND BEVERAGES
TÊXTIL	1.117	1.080	1.186	1.202	1.213	1.275	1.208	1.146	1.212	1.201	TEXTILES
PAPEL E CELULOSE	6.586	7.120	7.299	7.684	8.016	8.554	8.957	9.485	10.076	10.180	PAPER AND PULP
OUTRAS INDÚSTRIAS	5.311	5.346	5.707	5.866	6.118	6.525	6.997	6.622	7.419	7.891	OTHERS
ENERGÉTICO	14.391	15.832	16.442	17.643	18.823	21.036	24.546	24.414	25.332	22.376	ENERGY SECTOR
RESIDENCIAL	20.681	20.902	21.357	21.827	22.090	22.271	22.738	23.227	23.669	23.374	RESIDENTIAL

Abaixo encontram-se gráficos que mostram a distribuição de consumo entre diversos equipamentos eletrônicos, em cada setor destacado na Tabela 1 [9]. É evidente a grande contribuição dos aparelhos de ar-condicionado para a formação do consumo total.

Comprova-se, com os números acima, que reduzir o desperdício no uso dos equipamentos de ar-condicionado resultará em um grande impacto positivo na saúde financeira do país, fomentando um desenvolvimento robusto e palpável para os anos que se seguirão.

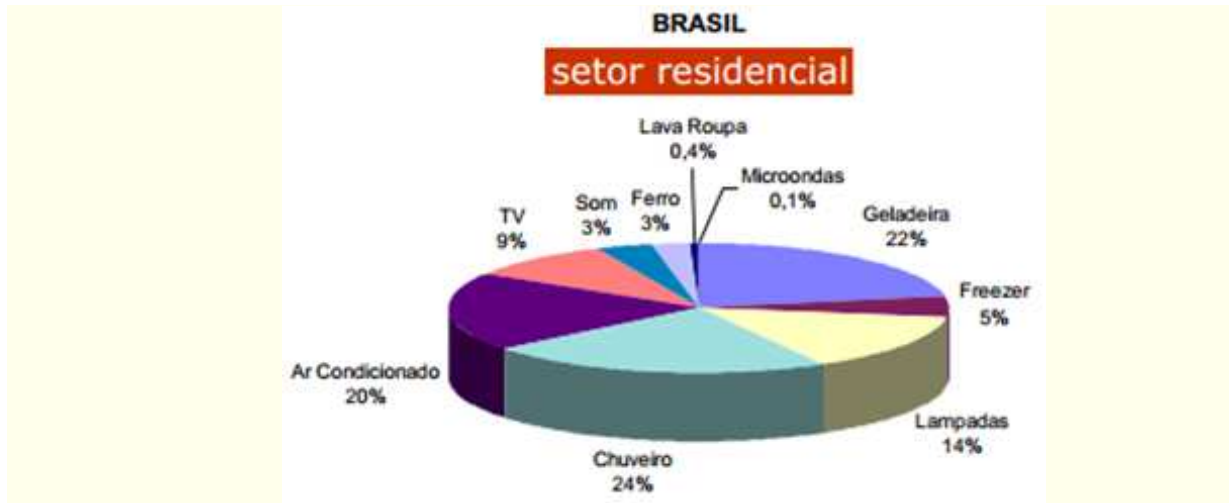


Figura 1. Participação de diversos equipamentos elétricos no consumo total do setor residencial. (Eletrobras 2007).



Figura 2. Distribuição de consumo no setor comercial. (Eletrobras 2007).



Figura 3. Distribuição de consumo no setor público. (Eletrobras 2007).

## 2 Sistemas RFID

O sistema de identificação por radiofrequência (RFID) se utiliza da propagação de ondas eletromagnéticas no ambiente para estabelecer comunicação sem fio entre dois dispositivos de interesse. Um deles chama-se tag e o outro, leitora. Esse tipo de sistema, em geral, possui muitas tags e algumas leitoras. Uma tag, é pequena e portátil, e cada uma delas possui internamente um identificador único, que a diferencia das demais. A leitora é maior que a tag, e geralmente fica estacionária, próxima a uma estação de trabalho (computador) com que possa se comunicar para transmitir os dados coletados das tags. Das muitas informações que podem ser trocadas entre tags e leitoras, está justamente esse identificador exclusivo, que permite caracterizar um determinado alvo que esteja portando essa tag. Um exemplo de aplicação desse sistema consiste no uso de tags RFID para identificar produtos em um caixa de supermercado, e cobrar do cliente o preço adequado. Um sistema RFID também pode ser utilizado como sistema de controle de acesso a ambientes restritos. Dessa forma, cada usuário com permissão de entrar no ambiente teria sua própria tag que o identificaria no momento do acesso.

Utilizando uma definição mais formal, proveniente de [10], define-se que um sistema RFID consiste basicamente de pelo menos uma leitora, uma tag e um meio entre eles. A leitora possui uma antena, um hardware para comunicação por radiofrequência (RF) e um hardware de comunicação para enviar dados para outros dispositivos, como um computador. Exemplos de protocolos usados pelos fabricantes de leitoras para que estas se comuniquem com outros dispositivos são: WiFi, Ethernet, RS-232, entre outros.

A tag, quando dita ser do tipo passiva, possui apenas um circuito RF. Quando dita ser do tipo ativa, possui adicionalmente um microcontrolador e uma bateria. A tag ativa possui alcance maior em relação à tag passiva, pois envia sinal a uma potência proporcionalmente maior, devido à alimentação da bateria. Esta também pode enviar dados em intervalos regulares, mesmo sem ser solicitada pela leitora. Uma desvantagem das tags ativas é o seu alto custo e, mais especificamente em relação ao problema de localização, a perda de potência do sinal ao longo do tempo à medida que a bateria se descarrega [6]. Neste trabalho usou-se tags ativas.

O meio entre a tag e a leitora é o meio de propagação da onda eletromagnética que estabelece a comunicação entre ambos os dispositivos. Embora o meio mais comum seja o ar, a onda eletromagnética atravessa diversos tipos de materiais, porém sofre atenuações diferentes, de acordo com o material. A atenuação do sinal eletromagnético, ou seja, a perda de potência da onda durante o trajeto tag-meio-leitora, é uma variável de interesse nesse trabalho e será explorada mais detalhadamente adiante.

Além dos três elementos citados acima, um sistema RFID consiste de outro elemento chamado middleware. Esse nada mais é que um software que faz a interface entre o firmware da leitora e o software do computador. O middleware é então, o responsável por extrair os dados que se encontram na leitora e enviar para o computador.

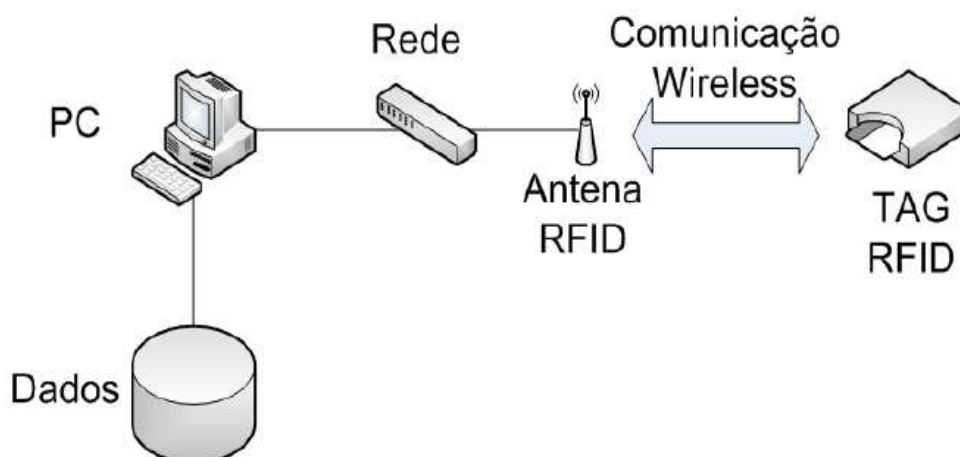


Figura 4. Funcionamento de um sistema RFID.

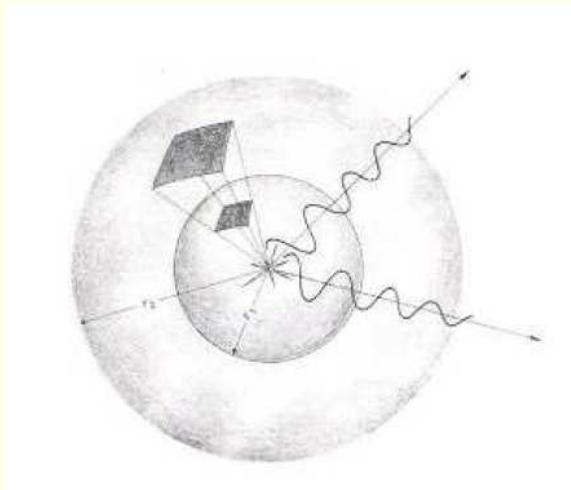
São inúmeras as aplicações de um sistema RFID, principalmente porque não há necessidade de contato visual entre a tag e a leitora para se estabelecer a comunicação. Assim sendo, a principal utilidade do sistema é utilizar a tag para reconhecer unicamente a presença de um alvo, ou identificar, entre vários alvos, qual é qual. Se o alvo sempre portar a tag, ele sempre será identificado por uma ou mais leitoras próximas. Dessa forma é possível rastrear produtos em uma linha de montagem ou animais em um grande celeiro ou pasto. A Figura 5 mostra um sistema de pedágio baseado em RFID, muito comum em diversos países.



Figura 5. Pedágio utilizando sistema RFID.

Como dito anteriormente, a tag envia diversas informações junto com seu identificador, no que consiste em o que se chama de pacote de dados. Este pacote é formado por um stream de bytes, que trafegam através do meio e chegam até a antena da leitora. Cada grupo desses bytes representa uma informação diferente. A informação de

interesse, no contexto desse trabalho, é uma variável chamada Received Signal Strength Indicator (RSSI), que representa a potência do sinal enviado por uma tag e recebido por uma leitora. Uma onda eletromagnética tem a potência de seu sinal atenuada de forma proporcional à distância trafegada. Quanto mais distante uma tag estiver, em relação à leitora, menor será a potência percebida pela leitora (maior atenuação do sinal) e, conseqüentemente, menor será o valor do RSSI.



**Figura 6.** Propagação do sinal eletromagnético em um meio qualquer. O sinal atenua à medida que a onda se propaga no espaço.

O RSSI é inversamente proporcional ao quadrado da distância entre emissor e receptor, e por isso é possível usá-lo como estimador da posição, em relação à leitora, de uma pessoa que esteja portando a tag. A Figura 7, retirada de [11], mostra a variação do RSSI com a distância, em um ambiente aberto (outdoor), como no caso do pedágio da Figura 5. É possível perceber, analisando-se a regressão explicitada pela curva mostrada em vermelho, que os valores condizem com o modelo de proporcionalidade inversa ao quadrado da distância, mesmo que haja uma pequena distorção.




Figura 7. Variação do RSSI com a distância, em um ambiente aberto.

Já a Figura 8, retirada de [6], mostra como o RSSI se comporta quando tag e leitora estão em um ambiente fechado. Percebe-se que a curva agora possui uma forma diferente da mostrada pela figura 7, e não mais se comporta de maneira inversamente proporcional ao quadrado da distância.

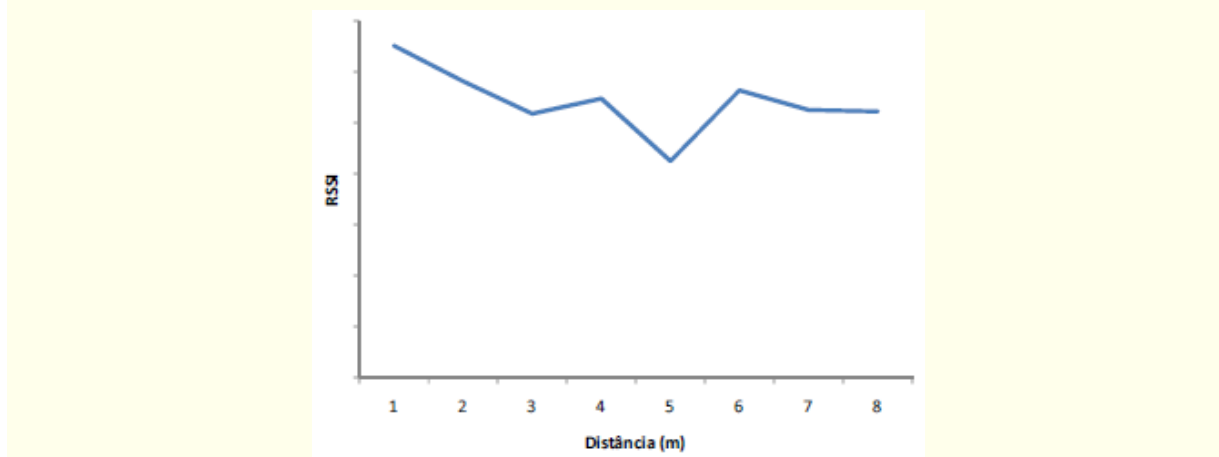


Figura 8. Variação do RSSI com a distância, em um ambiente fechado.

Existem diversas explicações para justificar o comportamento mostrado na figura 8. Primeiramente, deve-se entender que o RSSI é um valor que é calculado pela leitora, através de um circuito interno que mede a potência média das ondas portadoras recebidas pela antena da leitora dentro de uma janela de tempo. Dessa forma, equipamentos que estejam operando na mesma frequência que o sistema RFID, podem interferir no cálculo do RSSI. Ondas eletromagnéticas sofrem interferências umas das outras através de um processo que pode ser construtivo ou destrutivo. O primeiro acontece quando a onda

interferente contribui com o aumento da potência do sinal, pois há sobreposição dos vales de uma onda com os vales da outra. O segundo caso, ocorre quando há sobreposição entre o vale de uma onda com o pico de outra. A figura ilustra esse fenômeno.




Figura 9. Processo de interferência entre duas ondas.

Além do caso acima, ressalta-se a atenuação do sinal proveniente de sua travessia por um meio diferente do ar. Quando há algum obstáculo entre a tag e a leitora, a onda eletromagnética sofrerá uma atenuação mais acentuada, que depende da natureza (material) desse obstáculo. A título de exemplo, podemos citar a madeira como material de fraca atenuação, a água como um material de média atenuação, e o metal como um material de alta atenuação.

Cita-se ainda, no caso da tag ativa, que o valor do RSSI é, também, diretamente proporcional à carga da bateria portada pela tag. Quanto mais próxima do fim de sua vida útil, menor será a intensidade do RSSI. Tal fato dificulta o uso do RSSI como ferramenta de localização, pois duas tags diferentes, na mesma posição, mas com cargas diferentes em suas baterias, enviarão um valor distinto de RSSI.

Por fim, o principal fator interferente no valor do RSSI é o que se chama de caminhos múltiplos de propagação da onda. Como a onda possui a propriedade de se refletir quando encontra algum obstáculo em seu caminho, o mesmo sinal enviado por uma tag pode alcançar a leitora através de caminhos diferentes, o que implica, naturalmente, em atenuações diferentes, pois a distância percorrida não é a mesma.

A Figura 10, retirada de [6], ilustra uma leitora, em verde, representada pelo número 1, e uma tag, representada pelo círculo azul. As ondas eletromagnéticas se espalham em todas as direções ao redor da tag, no momento do envio do sinal para a leitora. Ela pode percorrer o caminho representado em preto, batendo na parede esquerda e refletindo de volta para a leitora, ou pode pegar um dos caminhos em azul claro, refletindo na parede superior ou inferior e posteriormente indo de encontro à leitora. Cada um dos três caminhos possuirá uma atenuação diferente. Dessa forma, os valores de RSSI irão variar dependendo de qual caminho é percorrido pela onda.






Figura 10. Caminhos múltiplos de reflexão de uma onda. Leitora em verde, tag em azul.

Os comportamentos descritos dificultam o uso do RSSI para a localização indoor (em ambientes fechados) de usuários, pois os erros na posição estimada são grandes demais para dar confiabilidade necessária na tomada de decisões, por exemplo, em regiões fronteiriças. Tais regiões são pequenos espaços imaginários (ou físicos, como paredes) que separam um ou mais ambientes de interesse em um prédio. Erros grandes nas fronteiras são fundamentais na decisão de viabilizar ou inviabilizar o uso de determinado algoritmo de localização, pois o sistema não deve ligar o ar-condicionado em uma determinada sala, quando o usuário encontrar-se na sala vizinha.




Figura 11. Regiões de fronteira (vermelho) são críticas em qualquer algoritmo de classificação por ambientes.

Na linha de trabalho apresentada aqui, buscou-se, sob a ótica da aprendizagem de máquina, formas de driblar as dificuldades de se trabalhar com o RSSI como variável principal na estimação da posição de um usuário em um ambiente.

## 2.1 Hardware utilizado

O hardware utilizado neste trabalho foi um conjunto de cinco leitoras de RFID modelo L-RX900 e uma tag ativa, dentro de um universo de 80 tags ativas do modelo L-TG501, todas do fabricante Wavetrend. As antenas das leitoras são omnidirecionais, do modelo L-N200 Stub. As antenas internas das tags também são omnidirecionais. A frequência de operação do sistema é de 433MHz e a distância efetiva de leitura, medida experimentalmente, é de 7 metros entre tag e leitora e difere do valor indicado pelo datasheet, que sugere uma distância maior e supõe condições ideais de operação. As tags ativas enviam um pacote de dados a cada 1,5 segundos, quando estão em movimento, e a cada 15 segundos quando estão em repouso. As tags possuem um sensor de movimento, e não precisam receber um pedido das leitoras para começar o envio de pacotes. Por isso não é possível estabelecer um controle rígido dos instantes de envio. As leitoras RFID possuem um buffer FIFO interno com tamanho máximo de 40 pacotes, que podem ser passados para o software de interesse via RS-232 ou Ethernet. Optou-se por conectar as leitoras via rede Ethernet, para que estas pudessem se comunicar diretamente com o Matlab, que pode ser instalado em qualquer computador do laboratório. As Figuras 12, 13 e 14 mostram a leitora e tag usadas, respectivamente. A leitora possui uma função de auto-polling, o que significa que assim que houver dados disponíveis no buffer (e a rede puder recebê-los), a leitora os enviará imediatamente. Nesse modo de operação, também não é possível ter controle rígido sobre os instantes de envio de pacotes da leitora para a rede TCP/IP.



**Figura 12.** Leitora modelo L-RX900 com antena omnidirecional de modelo L-N200 Stub, frequência de operação 433MHz, e distância efetiva de leitura de 7m.



**Figura 13.** Tag ativa, modelo L-TG501.



**Figura 14.** Figura que mostra a leitora e a tag em cima da mesa da sala de reuniões do LARA. Foto mostra o cabo UTP que conecta a leitora à rede TCP/IP do LARA. A tag possui uma cavidade para que se utilize um fio a fim de portá-la como um crachá.

## 3 Desenvolvimento do sistema de localização

### 3.1 Trabalhos Anteriores

Diferentes abordagens para viabilizar o uso do RSSI têm sido tentadas na literatura. No paradigma de redes de sensores sem fio, destaca-se o trabalho de [10] que buscou usar a metodologia k-Nearest-Neighbour em conjunto com técnicas de triangulação. As recorrentes tentativas de explorar o RSSI como estimador da distância podem ser justificadas pelo fato de que este é um componente inerente de muitos sistemas sem fio, e por isso seu uso não implica em custos adicionais, tanto do ponto de vista financeiro, quanto do ponto de vista computacional.

Trabalhos realizados no LARA também exploraram a viabilidade do RSSI como estimador de distância. Em [1] comparou-se técnicas de triangulação hiperbólica com aproximação da função de distância entre sensores através de redes neurais artificiais, em um cenário de rede de sensores sem fio. O trabalho de [6] introduziu pela primeira vez o sistema RFID no LARA e também se valeu da triangulação, em conjunto com redes neurais artificiais, para estimar a distância entre tag e leitora. Uma mudança de paradigma surgiu em [7] que enxergou a localização de usuários como um problema de classificação por ambientes. O presente trabalho dá continuidade a essa última abordagem, e lida com algoritmos de aprendizagem supervisionada, implementados via Matlab. Nas próximas seções essa discussão será aprofundada, iniciando-a pelo entendimento dos princípios por trás do machine learning.

### 3.2 Machine Learning

Um algoritmo de Inteligência Artificial é um programa de computador que executa determinadas funções no intuito de simular a capacidade de decisão do cérebro humano. Machine learning (aprendizagem de máquina) é a parte da Inteligência Artificial que estuda como desenvolver em um programa de computador algoritmos com processos de aprendizado similares aos processos cognitivos humanos.

Assim como o nome deixa inferir, um sistema com machine learning é capaz de melhorar seu desempenho ao longo do tempo, de forma que sua estrutura mude de alguma maneira a medida que este interaja com o ambiente [16]. Essa mudança sucessiva permite que o programa amplie sua capacidade de generalização das respostas, ou seja, o algoritmo não se limitará apenas ao que foi ensinado. Esse comportamento define a principal característica do algoritmo de machine learning, que é a capacidade de aprendizado. A importância do aprendizado para a solução de problemas ocorre em diversas aplicações, destacam-se aqui os seguintes casos:

- Tarefas que não podem ser descritas de maneira precisa ou analítica, exceto através de exemplos. Nesse caso é importante apresentar ao programa qual o resultado esperado, para que ele possa aprendê-lo. Diversas tarefas não possuem modelo matemático preciso e não é possível ensinar uma fórmula ao programa, restando apenas a alternativa de mostrar que a saída desejada é Y quando a entrada for X.

- Sistemas inseridos em ambientes que mudam ao longo do tempo requerem capacidade de aprendizado, sob pena de terem que ser redesenhados para se adequar à cada mudança.
- Encontrar relações implícitas entre variáveis ao longo de enormes quantidades de dados. Por exemplo, encontrar uma relação que permita inferir se um tumor no corpo humano é benigno ou maligno se baseando em diversas características deste tumor, como tamanho, cor, número de células presentes, entre outros, coletadas de diversos pacientes diferentes.

Quando já se tem o conhecimento do problema a ser resolvido, a primeira pergunta que deve ser respondida é: quais os requisitos para se usar aprendizagem de máquina? Em essência, machine learning é uma abordagem viável quando o problema em questão satisfaz os seguintes pré-requisitos:

1. Existem dados disponíveis.
2. Existe um padrão nesses dados.
3. Não é possível descrever esse padrão matematicamente, de forma precisa.

Aplicando estes pré-requisitos ao problema de localização de usuários por ambientes, obtemos as respostas:

1. O sistema RFID é capaz de fornecer a quantidade necessária de dados.
2. Acredita-se que os valores de RSSI para um determinado local do laboratório repetem-se e há um padrão latente que pode ser capturado e interpretado.
3. Não é possível descrever matematicamente a correlação exata entre RSSI e a distância entre tag e leitora, uma vez que muitos fatores influenciam no problema

Então é possível, a princípio, aplicar machine learning no problema de localização de usuários por ambientes. Investigando a literatura, uma possível abordagem reside na utilização de classificadores supervisionados.

Um classificador supervisionado é um paradigma de machine learning que representa um sistema capaz de receber como entrada um dado e fornecer como saída uma classificação para esse dado. É possível que um classificador receba como entrada as características de plantas como tamanho do caule, número de pétalas na flor, número de folhas, entre outros, e na saída determine qual a espécie dessa planta. Outra aplicação possível é determinar, dado o peso e o tamanho de uma moeda, qual o país de origem dessa moeda.

O classificador é simplesmente uma função matemática, que possui parâmetros, que são ajustados em sucessivas iterações numa fase chamada de fase de treinamento. Essa fase consiste em apresentar dados reais, junto com sua classificação correta, e implementar um algoritmo que atualize os parâmetros do classificador, de forma que após muitas iterações, os parâmetros estejam calibrados e possam receber dados reais novos, gerando uma classificação correta, parecida com a apresentada durante a fase de treinamento. Para

treinar um classificador no primeiro exemplo dado acima, seria preciso mostrar a ele informações do tipo:

<i>tamanho do caule</i>	15cm	
<i>numero petalas</i>	8	<i>orquídea</i>
<i>numero folhas</i>	12	
<i>tamanho do caule</i>	7cm	
<i>numero petalas</i>	5	<i>rosa</i>
<i>numero folhas</i>	2	

Dessa forma, o classificador tentará aprender as informações apresentadas, de forma a encontrar entre elas uma relação que permita fazer inferências. Ou seja, é possível afirmar que: em geral, rosas possuem poucas folhas? Que orquídeas são plantas compridas?

O objetivo de se utilizar um classificador é justamente poder apresentar, após o treinamento, uma informação como:

<i>tamanho do caule</i>	11cm	
<i>numero petalas</i>	6	?
<i>numero folhas</i>	2	

E esperar uma resposta deste classificador indicando a qual classe ele acha que essa planta pertence, dentre o total de classes possíveis.

Como pode-se inferir, a escolha das informações a serem apresentadas é crucial para o correto aprendizado de seu classificador. Se no exemplo acima também fosse apresentado ao classificador, além das três informações citadas, o número de manchas por folha, talvez essa informação pouco acrescentasse na determinação da classe e apenas desperdiçasse poder computacional, pois essa característica talvez esteja mais relacionada com a idade da planta, do que com sua espécie. Mais ainda, se eu apenas apresentar o número de manchas na folha, talvez o classificador não tenha sucesso na determinação de espécies de plantas. Por isso, o desafio do projetista reside em escolher um conjunto de informações (chamadas features) que sejam relevantes para a resolução do problema.

Acredita-se que o valor do RSSI contenha informações suficientes para que um classificador supervisionado possa inferir a posição de um usuário portando a tag, e essa suposição pautou todo o trabalho. Trabalhos futuros podem tentar incluir mais features, caso se conclua que isso pode melhorar o desempenho do classificador. Um exemplo de possível feature seria o nível da bateria, pois sabe-se que este também afeta o valor do RSSI.

O grande benefício de utilizar o paradigma do machine learning supervisionado está na sua capacidade de generalização, ou seja, aprender com os exemplos, mas não se limitar a eles, de forma que inferências sobre os dados possam ser feitas e as predições extrapolem os casos mais triviais[17]. Machine learning se baseia no aprendizado indutivo, de forma que, com pouca informação, se produza muito conteúdo. Não obstante, um dos grandes desafios do uso do machine learning está em fornecer uma quantidade adequada de dados. Mesmo que sejam de qualidade, poucos dados não serão suficientes para treinar uma rede adequadamente. Entretanto, não é possível determinar com precisão o que são “muitos

dados” ou “poucos dados” e a quantidade mínima depende do problema em questão, e sua determinação se baseia mais na experiência do projetista do sistema do que em uma relação matemática.

Neste trabalho, utilizou-se os classificadores Perceptron Multicamadas, da sigla em inglês MLP e as Support Vector Machine (SVM). O MLP é uma rede neural bastante utilizada em problemas de classificação e é bastante robusta. É um dos principais algoritmos para classificação usados atualmente. O SVM é um algoritmo com capacidade de classificação equivalente ao MLP, porém se baseia em um paradigma diferenciado e apresenta vantagens em relação ao MLP, dependendo do tipo de problema em questão. Na próxima seção explorou-se o conceito de redes neurais artificiais e omitiu-se a explicação do funcionamento da SVM, pois como será mostrado mais adiante, ela teve pouco destaque nos resultados obtidos no trabalho.

### 3.3 Redes Neurais Artificiais

Uma rede neural é uma função matemática implementada em computador que se baseia no funcionamento do cérebro humano com o intuito de realizar tarefas específicas, principalmente regressão de funções e classificação de padrões de dados. A rede pode ser abstraída como sendo uma estrutura que consiste em um grande conjunto de pequenas unidades de processamento ligadas entre si chamadas nós (ou neurônios), o que permite que essa rede atue com computação paralela das informações. Esses nós podem ser lineares ou não-lineares, o que confere flexibilidade à rede. Uma abstração do conceito matemático de nó pode ser visto na figura 15.




Figura 15. Abstração do conceito de neurônio.

As entradas são multiplicadas por pesos sinápticos, e somadas entre si e a um valor constante chamado bias, o que gera um número real como resultado. Esse resultado é

avaliado por uma função, denominada função de ativação, que gera a resposta na saída do nó. O tipo da função de ativação influencia no resultado da rede, e existem diversas opções de uso.

Uma rede neural nada mais é que um conjunto grande desses nós. Eles são agrupados em camadas, que são um conjunto de nós que estão no mesmo 'nível', ou seja, têm a mesma finalidade. A figura 16 ilustra uma rede com 3 camadas: a camada de entrada, a camada escondida com quatro neurônios (ou nós) e a camada de saída com dois neurônios (detalhes da nomenclatura não serão discutidos aqui). As informações se propagam desde a entrada da rede, até à saída, passando sucessivamente por todas as camadas e todos os nós.

Em um problema de classificação, foco deste trabalho, a topologia mais adequada consiste em uma camada de entrada, com um número de nós igual ao número de features, uma camada escondida com um número arbitrário de nós, e uma camada de saída, com um número de nós igual ao número de classes. Uma abordagem usada nesse trabalho usou 5 neurônios de entrada, cada um correspondendo ao valor de RSSI de cada uma das 5 leitoras, 3 neurônios de saída, cada um correspondendo a um dos 3 possíveis ambientes de classificação, e um número arbitrário de nós na camada escondida, visto que esse é um parâmetro que não pode ser determinado facilmente, e apenas testes podem confirmar qual o número adequado de nós nessa camada. De uma maneira geral, precisa-se de mais nós na camada escondida a medida que a complexidade do problema aumenta, principalmente em relação à dimensão dos dados,  $R^3$ ,  $R^4$ ,  $R^n$ .




Figura 16. Rede Neural e suas camadas.



A rede neural compartilha das características citadas na explicação dada no tópico anterior sobre algoritmos de machine learning, e por isso, precisa ser treinada para poder generalizar os resultados quando for apresentada a novos dados.

Uma rede neural pode ser desenvolvida seguindo um total de 5 passos, descritos abaixo:

- **Coleta de dados:** O projetista da rede deve coletar os dados que serão apresentados para a rede (camada de entrada), de forma que esta possa ser treinada e gerar saídas satisfatórias. Os dados coletados nesse trabalho, por exemplo, foram um conjunto de valores de RSSI provenientes de 5 leitoras em um sistema RFID.
- **Criar a rede:** Escolher um software que possa implementar a rede neural, ou desenvolver código próprio, em uma linguagem de programação conveniente. No caso deste trabalho optou-se por utilizar a Neural Network Toolbox do Matlab.
- **Configurar a rede:** Nessa etapa deve-se escolher o layout da rede, bem como seus parâmetros. Se a opção for por uma rede como descrita na figura 16, embora existam várias configurações possíveis, deve-se escolher quantos nós estarão na camada escondida e quantas classes terá o problema. É possível, em um estágio mais avançado de entendimento do processo, escolher a função de ativação, a taxa de treinamento, o número de camadas escondidas, entre outros parâmetros.
- **Treinar a rede:** A rede deve passar por uma etapa onde dados são apresentados a ela, e estes servem como ponto de partida para mudanças internas em sua estrutura, principalmente a atualização dos pesos sinápticos, que devem idealmente ir se aproximando cada vez mais dos valores necessários para que a saída da rede possa dar resultados satisfatórios. O treinamento da rede é uma etapa crucial no seu desempenho final, e diversos fatores como número de iterações (épocas), coeficiente de aprendizagem, função de ativação, influenciam nesse momento. Existem também diversos paradigmas disponíveis, como aprendizado supervisionado (caso deste trabalho), não-supervisionado, e reforçado.
- **Validar a rede:** Consiste em usar uma parte dos dados coletados na primeira etapa para confirmar se a rede está sendo capaz de generalizar na saída. É o teste propriamente dito do desempenho da rede, após o seu treinamento.

### 3.4 Sistema Proposto

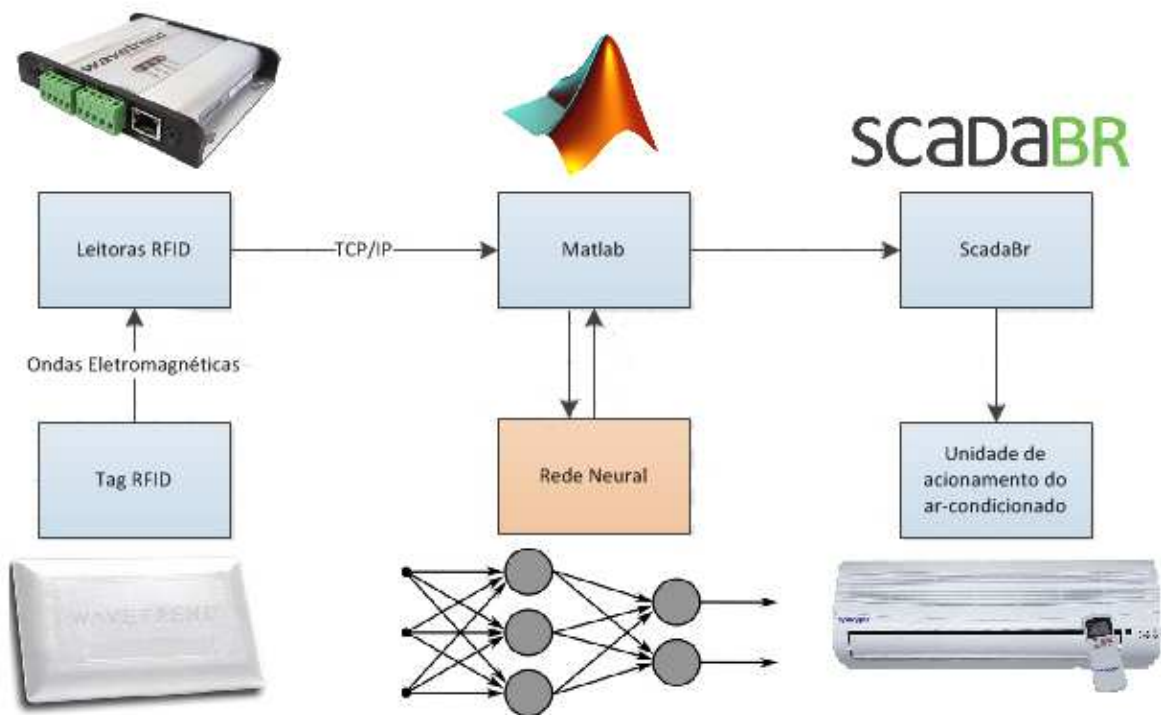


Figura 17. Visão geral da proposta do sistema.

A figura 17 mostra uma visão geral da proposta para o sistema de localização. As leitoras coletam os dados enviados pelas tags, armazenam em um buffer FIFO com tamanho para 40 pacotes e disponibilizam para a rede local via TCP/IP, quando puderem fazê-lo. O Matlab acessa a rede local e busca nas informações dos pacotes os valores de RSSI para cada uma das 5 leitoras. Faz-se uma coleta dos dados numa fase chamada de fase 'offline' onde os classificadores serão treinados. Na fase posterior, chamada de fase 'online' o sistema estará coletando dados das leitoras continuamente e apresentando esse valores para que os classificadores possam inferir o ambiente do usuário. As informações pertinentes são passadas para um sistema supervisorio, que armazena os dados ao longo do tempo e potencialmente poderá atuar sobre os aparelhos de ar-condicionado. Essa última parte relacionada ao acionamento dos aparelhos, embora tenha nortado muitas decisões, não fez parte desse trabalho. Outro ponto a ser ressaltado é que todas as coletas neste trabalho usaram apenas uma tag, sendo que teve-se o cuidado de sempre usar a mesma. Uma extrapolação possível em um trabalho futuro é investigar os impactos no RSSI quando mais de uma tag estiver presente e atuante no laboratório.

Um dos desafios em projetar um algoritmo de coleta no Matlab, reside no fato de que este não possui controle direto sobre as leitoras. Para tanto, deveria-se ter baixado o Software Development Kit (SDK) do fabricante e desenvolvido código que pudesse acessar

as funcionalidades das leitoras. Dada essa limitação, ocorria um grave problema de falta de sincronização na hora de coletar os dados. As leitoras enviam automaticamente quaisquer pacotes armazenados em seu buffer, pois elas têm uma função de auto-polling. Dessa forma, o Matlab não pode ter controle do momento dos envios, e o que acontece é que os dados das 5 leitoras, chegam muitas vezes fora de ordem, e por isso valores de RSSI de pacotes de instantes de tempo diferentes podem ser montados juntos. Mais especificamente, se uma leitora receber um pacote de determinada tag com atraso, sendo que as outras quatro leitoras receberam esse dado corretamente, então o Matlab, ao pegar os valores de RSSI em um instante posterior, poderá montar um vetor com 4 valores de RSSI provenientes do pacote de mesmo instante de tempo, porém com o último valor proveniente de um pacote correspondente a um instante de tempo posterior ao desses 4.

Esse é um problema que precisou ser corrigido a fim de melhorar a qualidade dos dados de coleta. Para efetuar tal correção, simplesmente avaliou-se o valor do Age Counter, uma informação que acompanha cada pacote enviado pela tag, e que é um contador interno que se incrementa em uma unidade cada vez que um pacote é enviado para as leitoras. Dessa forma, é possível saber quantos pacotes foram enviados ao longo da vida útil da tag e estimar a carga restante na bateria. Porém o interessante é que os 5 valores de RSSI devem corresponder a um mesmo número de Age, pois isso significa que eles são de pacotes provenientes do mesmo instante de tempo. O que o sistema faz para garantir a sincronia dos dados é comparar os valores do age para a cada um dos 5 pacotes (um de cada leitora). Se forem diferentes, o sistema descarta esses dados completamente, esvazia o buffer das leitoras e reinicia a coleta, de forma a pegar dados novos e em sincronia. Isso deixa o sistema um pouco mais lento, porém garante a integridade dos dados. Em média, 30% dos pacotes são descartados em um processo de coleta devido a essa metodologia.

### 3.5 Configuração do Ambiente

Definida a proposta do sistema, e de posse de um software de coleta robusto, foi preciso então, decidir como implementar a metodologia de classificação por ambientes, o que envolveu três etapas:

1. **Definição dos ambientes de interesse, dentro do laboratório.** Visa dividir o ambiente maior em regiões estratégicas, de acordo com a disposição de aparelhos de ar-condicionado, a fim de atender aos usuários, gerando conforto térmico para estes. Cada ambiente, só pode conter um aparelho de ar-condicionado, de forma que todas as pessoas desse ambiente, devem ser capazes de ser atendidas de forma satisfatória. Dentro de cada um desses ambientes, serão coletados valores de RSSI de uma tag portada por um usuário, para posteriormente alimentar os classificadores com os dados obtidos.
2. **Disposição das leitoras de RFID no ambiente.** A forma como as leitoras se encontram no ambiente influencia diretamente no mapa de atenuação do RSSI do LARA, afinal a potência a ser calculada depende da distância entre a tag e as leitoras. Como será mostrado mais adiante, concentrar muitas leitoras próximas entre si dificulta a diferenciação dos ambientes, por que em um círculo ao redor de cada leitora os

valores de RSSI são muito fortes, e, na região de sobreposição desses valores elevados, os classificadores perdem sensibilidade na classificação.

3. **Definição dos pontos de coleta.** Os pontos onde serão coletados os valores de RSSI devem ser representativos do ambiente em questão, e refletir o comportamento dos usuários. Ou seja, evita-se apresentar para a rede locais onde as pessoas não costumam ficar, como corredores, por exemplo. Essa medida visou simplificar o problema para o classificador. Além disso, um dos objetivos ao se discretizar o ambiente do LARA foi atingir uma baixa granularidade, escolhendo alguns pontos mais significativos que pudessem representar uma grande vizinhança ao seu redor.

As figuras 18, 19, 20 e 22 ilustram as três etapas descritas acima.




Figura 18. Região do LARA escolhida para o desenvolvimento dos experimentos.

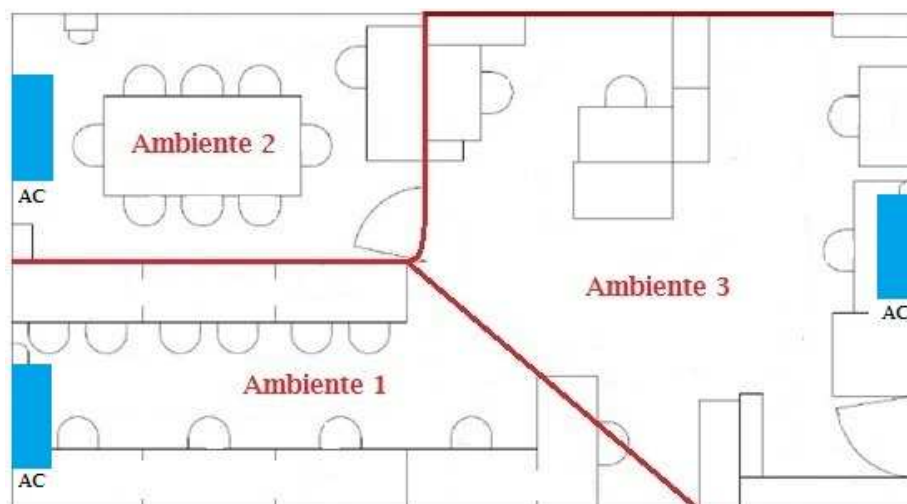


Figura 19. Definição inicial dos ambientes. Retângulos azuis indicam as posições reais dos aparelhos de ar-condicionado do LARA.

A região do LARA usada para desenvolver os experimentos possui tamanho aproximado de 6m x 11m, e é composta de uma sala de reunião e grandes corredores preenchidos com mesas, cadeiras e armários. Dentro dessa região, existem três aparelhos de ar-condicionado. A sala de reunião separa-se do restante do ambiente através de uma divisória, de forma que há uma fronteira real delimitando esse local. A figura 18 ilustra essa região.

Baseando-se na etapa 1 da metodologia, dividiu-se o laboratório em três ambientes distintos. A sala de reunião determinou o ambiente 2. A definição dos ambientes 1 e 3 não atendeu exatamente a etapa 1 da metodologia, pois tais ambientes possuem carga térmica compartilhada, uma vez que não há barreira física separando-os. Entretanto, buscou-se definir a fronteira de separação desses ambientes de forma a equilibrar o uso dos recursos de refrigeração, sem sacrificar o conforto térmico dos usuários. Chegou-se à linha diagonal imaginária mostrada na figura 18. Todas as fronteiras de definição dos ambientes foram representadas nas figuras por linhas vermelhas.

De acordo com a etapa 2, buscou-se distribuir as leitoras pelos ambientes para posteriormente investigar sua influência no desempenho dos classificadores. Foram utilizadas 5 leitoras dispostas segundo a Figura 20 e representadas pelos círculos azuis. A proposta era concentrar as leitoras nas regiões de fronteira de forma a reforçar o aprendizado nessas regiões críticas de classificação.




Figura 20. A divisão do laboratório proposta nesse trabalho, que inclui o posicionamento das leitoras, representadas por círculos azuis.

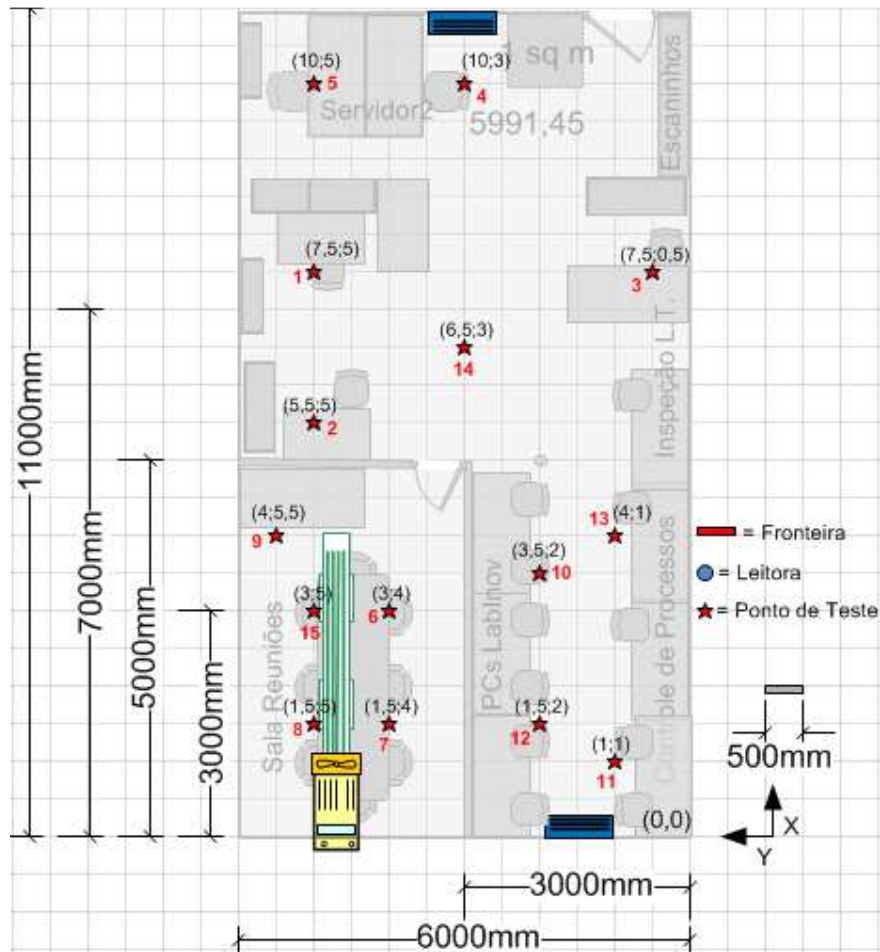


Figura 21. Os 15 pontos de coleta definidos nesse trabalho.

Seguindo a etapa três, definiu-se 15 pontos de coleta, sendo 6 no ambiente três, 4 no ambiente um e 5 no ambiente dois. Apenas regiões onde o usuário pudesse parar e sentar foram escolhidas, além do ponto 14 onde é comum usuários conversarem em pé. A figura 21 ilustra esses pontos, representados por uma estrela e um par coordenado, que representa sua posição no espaço do laboratório. Colocou-se a origem do eixo coordenado no canto inferior direito da figura. O eixo X é vertical e o eixo Y é horizontal.

Com a metodologia montada, foi possível passar para a fase de coleta de dados. Nessa fase, também denominada fase offline, um usuário portando uma tag, ficaria estacionário em cada um dos 15 pontos de coleta definidos, a fim de conseguir um determinado número de valores de RSSI, capazes de descrever o perfil de atenuação do sinal, um ponto de cada vez. Restou-se definir como efetuar essa coleta. Foi preciso arbitrar sobre as seguintes condições:

1. As coletas serão feitas com a tag parada ou com a tag em movimento?
2. Quantos valores serão coletados em cada ponto?
3. A tag pode mudar sua orientação?
4. Como o usuário portará a tag?

As respostas foram as seguintes:

- 1) É preciso realizar um experimento comparativo entre as duas situações para decidir qual a melhor.
- 2) Serão coletados 100 dados em cada ponto.
- 3) A tag não deve mudar orientação. Em [6], um estudo mostra que diferentes orientações geram diferentes níveis de sinal.
- 4) O usuário portará como um crachá, a qual é a forma esperada que se porte essa tag caso o sistema seja implementado, de fato, no LARA.

Após definida a metodologia de coleta, foi preciso definir como se utilizar dos dados que seriam coletados. Dividiu-se o experimento em duas fases:

- 1) Fase 1: Offline. Onde a rede neural será treinada, validada e testada com os 100 dados coletados de cada um dos 15 pontos de coleta definidos. Nessa fase, será possível escolher a melhor configuração possível para a rede neural.
- 2) Fase 2: Online. Onde a rede neural será testada apenas com dados novos, coletados continuamente em situações que simulem o sistema de localização em tempo real. Os valores de RSSI serão apresentados de forma instantânea para a rede, e esta irá classificar em qual ambiente o usuário se encontra. Será possível comparar diferentes layouts para disposição das leitoras, diferentes estratégias de localização e diferentes algoritmos e/ou classificadores.


A fase online é ainda dividida em duas metodologias:

- 1) Metodologia 1: Coletar dados novos apenas em um dos 15 pontos de coleta por vez, e observar qual o desempenho da rede classificando aquele ponto específico. Essa metodologia não é localização de usuários, propriamente dita.
- 2) Metodologia 2: Coletar dados novos em diversos locais de um mesmo ambiente, mesmo que estes locais não tenham sido apresentados à rede. O usuário deve movimentar-se a esmo dentro de um mesmo ambiente, e fazer algumas transições entre os três ambientes propostos. Essa metodologia visa testar a capacidade de localização de usuários dos algoritmos.

## 4 Análise dos Resultados

Primeiramente testou-se a possibilidade de haver mudanças no valor do RSSI se as coletas fossem feitas com a tag em movimento, relativamente a uma coleta com a tag estática. Entretanto, não foi possível chegar a alguma conclusão sobre isso. Os sinais são diferentes, como mostra a figura 23, porém não há um prejuízo evidente que determine que um método de coleta é melhor que o outro. O que importa é escolher sempre o mesmo método, ou seja, não permitir que uma coleta que começou com a tag em movimento tenha valores que a tag enviou estando parada, e vice-versa. Dessa forma eliminamos um possível fator de variação adicional para influenciar no valor do RSSI. Decidiu-se que todas as coletas seriam feitas em movimento, uma vez que estas seriam dez vezes mais rápidas em comparação com coletas feitas com a tag estática.

Além disso, o sistema sempre aplica um filtro de mediana, com janela de 5 unidades, em todos os valores de RSSI coletados a fim de minimizar os ruídos presentes no sistema. Esse filtro é aplicado tanto na fase offline (treinamento) quanto na fase online (teste contínuo do sistema) para a metodologia 1. Outro fator importante é apresentar os dados normalizados, a fim de não permitir que valores grandes se sobressaíssem em relação a valores pequenos, enviesando a amostra dos dados. Mais uma vez, preocupou-se em normalizar os dados tanto na fase offline, quanto na fase online. Os gráficos que aparecerão no trabalho a partir de agora, no entanto, mostram dados que foram filtrados porém não foram normalizados, de forma que os eixos pudessem ter valores mais compreensíveis e fáceis de analisar.



**Figura 22.** Valores do RSSI para coletas com a tag parada(acima) e com a tag em movimento (abaixo). As coletas acima foram feitas na mesma posição dentro do laboratório e com a tag tendo a mesma orientação.


Tendo definido o último ponto acerca da metodologia a ser empregada, iniciou-se a fase de coleta. A fase offline determinou uma rede neural com os seguintes parâmetros:



**Número de neurônios na camada de entrada:** 5.  
**Número de camadas escondidas:** 1.  
**Número de neurônios na camada escondida:** 10.  
**Número de neurônios na camada de saída:** 3.  
**Função de treinamento:** Scaled Conjugate Gradient ('trainscg').  
**Divisão dos dados (Treinamento/Validação/Teste):** 90%/5%/5%.  
**Função de transferência na camada de saída:** Linear ('purelin').  
**Pré-processamento nos dados:** Filtro de mediana e normalização (divisão por 255).

Tal rede obteve desempenho na classificação por ambientes de 55%-60% durante a fase offline. Na fase online, o desempenho médio foi de aproximadamente 25%-30% aplicando-se a metodologia 1.

Através da análise do conjunto de 1500 dados, descobriu-se que a disposição de leitoras mostrada na figura 20 dificulta a diferenciação dos ambientes. Como podemos ver pela figura abaixo, extraída de [6], próximo da leitora temos uma zona bastante forte de sinal de RSSI.




**Figura 23.** Região vermelha representa o pico de sinal ao redor da localização de uma determinada leitora.

Ao concentrarmos as leitoras na região de fronteira, que fica aproximadamente no centro do laboratório, todas as leitoras passam a ter um perfil de atenuação muito parecido, pois qualquer ponto do LARA está aproximadamente à mesma distância de qualquer uma das leitoras. Essa pouca diferenciação dificultou no desempenho da rede neural.

Pela figura 25, vemos claramente que a rede neural se ancorou na variação da leitora 12 para tomar suas decisões. Pôde-se confirmar esse comportamento também em outros testes. Tal fato ocorre por que essa leitora é a mais distante das demais, e por isso fornece mais informação para a rede neural uma vez que possui uma quantidade maior de valores possíveis de RSSI. Por isso, a rede neural ignorou a variação das outras leitoras na sua tomada de decisão. Observar novamente a figura 25, na região da quarta coleta. Nesse ponto, quando a leitora 12 passa a superar um determinado limiar (constatado nesse e em outros experimentos como sendo aproximadamente 89) a rede neural muda sua decisão e passa a classificar esse ponto como pertencente da região 3 e não mais da região 1.

Concomitante ao processo de teste do desempenho da rede, desenvolveu-se um algoritmo heurístico para classificação de ambientes que serviria como benchmark (referência de desempenho) para a rede neural. Esse algoritmo foi montado em uma estrutura puramente condicional relacional. De posse dos dados de RSSI em diversos pontos e situações distintas, um usuário humano, pode, apenas através da visualização do mapa de atenuação de um conjunto de pontos, determinar qual o padrão de incidência dos valores de RSSI para cada uma das leitoras nesses determinados pontos. Ou seja, é possível dizer que, de uma maneira geral, quando a tag estiver no ponto 5 ou no 4, o sinal da leitora 12 será mais forte. Quando estiver no ponto 12 a leitora 14 será a mais evidente. Dessa forma estabeleceu-se certos limiares e, através de estruturas do tipo se-então, construiu-se tal algoritmo heurístico.



**Figura 24.** Figura que mostra na parte superior o sinal de RSSI medido em cada uma das 5 leitoras durante 20 coletas. Abaixo a predição da rede neural para cada uma dessas coletas. A rede neural se "ancorou" na variação da leitora 12.

Essa experiência confirmou que é necessário haver uma diferenciação grande entre as leitoras, de forma a poder permitir maior acerto desse algoritmo heurístico, o que vai ao encontro do que se concluiu acerca do desempenho da rede neural.

Assim sendo, um novo layout para disposição das leitoras foi proposto, tentando posicioná-las de forma a garantir que certas regiões teriam leitoras cuja influência fosse evidente e dominante para facilitar a tomada de decisão no processo de classificação, tanto da rede neural, quando do algoritmo heurístico.

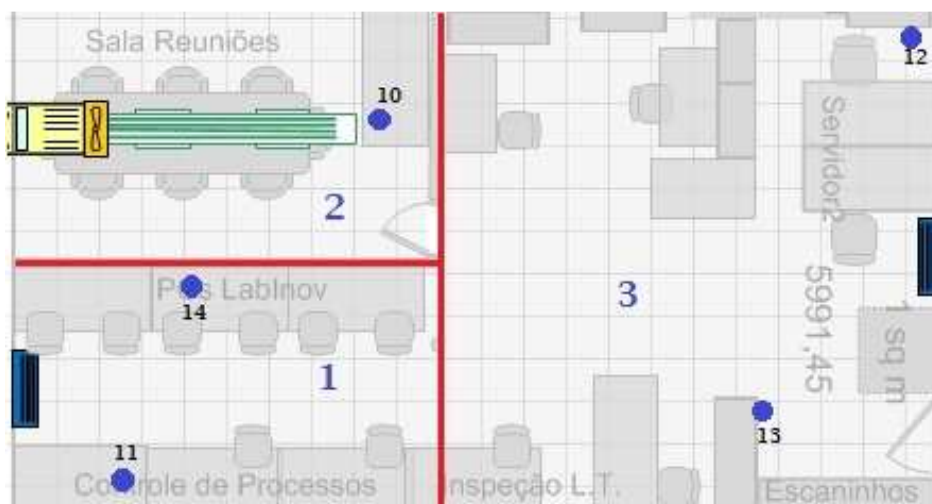


Figura 25. Novo layout proposto, de forma a distanciar as leitoras e permitir uma maior diferenciação na atenuação dos sinais. Linhas em vermelho definem as fronteiras dos ambientes.

O layout mostrado na figura 26 permitiu a construção de um bom algoritmo heurístico, por que os limiares para a tomada de decisão puderam ser bem definidos.

```

for n=1:numeroColetas
if ((RSSI_Leitora10F(n)>95 && RSSI_Leitora12F(n)<100 && RSSI_Leitora14F(n)<115) || (RSSI_Leitora10F(n)>113
&& (RSSI_Leitora14F(n)<110 || RSSI_Leitora11F(n)<100)))
ambHC(n)=2;
elseif ((RSSI_Leitora12F(n)>99 || RSSI_Leitora13F(n)>99) && RSSI_Leitora11F(n)<99 && RSSI_Leitora14F(n)<110)
|| (RSSI_Leitora12F(n)>115 || RSSI_Leitora13F(n)>115))
ambHC(n)=3;
else
ambHC(n)=1;
end
end
end

```

Figura 26. Algoritmo heurístico, feito em uma estrutura condicional-relacional.

Embora possua uma eficácia boa, o algoritmo mostrado na figura 27 carece de poder de generalização, ou seja, sua capacidade de classificação é bastante limitada a um comportamento bem rígido da atenuação do ambiente, e mesmo ruído temporário pode enfraquecer bastante o desempenho do algoritmo. É nesse contexto que se volta novamente para a análise do impacto que uma rede neural pode ter. Espera-se que um classificador mais poderoso como o MLP possa generalizar melhor e ainda consumir menos tempo para configurar, uma vez que definir os limiares do algoritmo heurístico é trabalhoso e estes variam muito fortemente a medida que o ambiente do laboratório ou as condições de operação mudam. Para explicar melhor esse último caso, pode-se citar que durante a definição dos limiares do algoritmo observou-se os valores de atenuação em coletas onde o laboratório encontrava-se praticamente vazio. Entretanto, em datas onde ocorram reunião no LARA, por exemplo, haverá mais pessoas e os limiares mudarão

bastante. Investiga-se a rede neural na expectativa de que ela tenha robustez maior (tolerância a condições adversas) em relação ao algoritmo heurístico.

Na prática o que se observou foi que não houve uma melhora significativa quando se usou a rede neural para esse novo layout. Algumas vezes ela acertou quando a heurística errou e vice-versa.

Entretanto, essa pouca melhora deu margem para o surgimento de uma nova proposta de treinamento da rede. Durante a análise do mapa de atenuação percebeu-se que o que estava sendo ensinado para a rede neural não condizia com o que era apresentado para ela durante os testes em tempo real no laboratório. A figura 28 representa o mapa de atenuação das 5 leitoras do LARA para os três ambientes. São 1300 dados, sendo que em cada um dos 13 pontos foram coletados 100 amostras (dos 15 pontos de coleta definidos no trabalho, pegou-se dados apenas dos 13 primeiros, nessa figura particular). Logo as 100 primeiras amostras do gráfico correspondem ao ponto de coleta 1, as 100 próximas correspondem ao ponto de coleta 2, as próximas 100 ao ponto 3, e assim sucessivamente até cobrir os 13 pontos definidos na figura 13 e chegar aos 1300 dados da figura.


O paradigma de classificação de padrões se vale justamente da necessidade de se existir um padrão por trás dos dados que são apresentados para o classificador. Dessa forma, percebemos que os padrões de interesse são mais bem representados não pela divisão em 3 classes, mas sim em 15 classes, uma para cada ponto de coleta. É visualmente perceptível que a cada grupo de 100 dados temos níveis de RSSI bem distintos para cada uma das leitoras. Analisando a figura 29, essa distinção por níveis fica ainda mais evidente. Partiu-se da suposição que se os dados são possíveis de serem separados visualmente pelo olho humano, a rede neural também conseguirá encontrar uma relação explícita para classificar os dados.

A figura 30 mostra a atenuação no ambiente 3 para apenas uma leitora. Na metodologia de treinamento anterior, esse mapa era apresentado à rede neural como sendo a classe 3. Percebe-se que dentro dessa classe há uma distinção de valores muito grande. Mesmo que haja, sim, uma distinção entre esse mapa e o mapa completo do ambiente 2, por exemplo, entende-se que ele cobre uma gama de possibilidades muito grande, e induz uma atribuição de similaridade a valores muito distintos entre si.

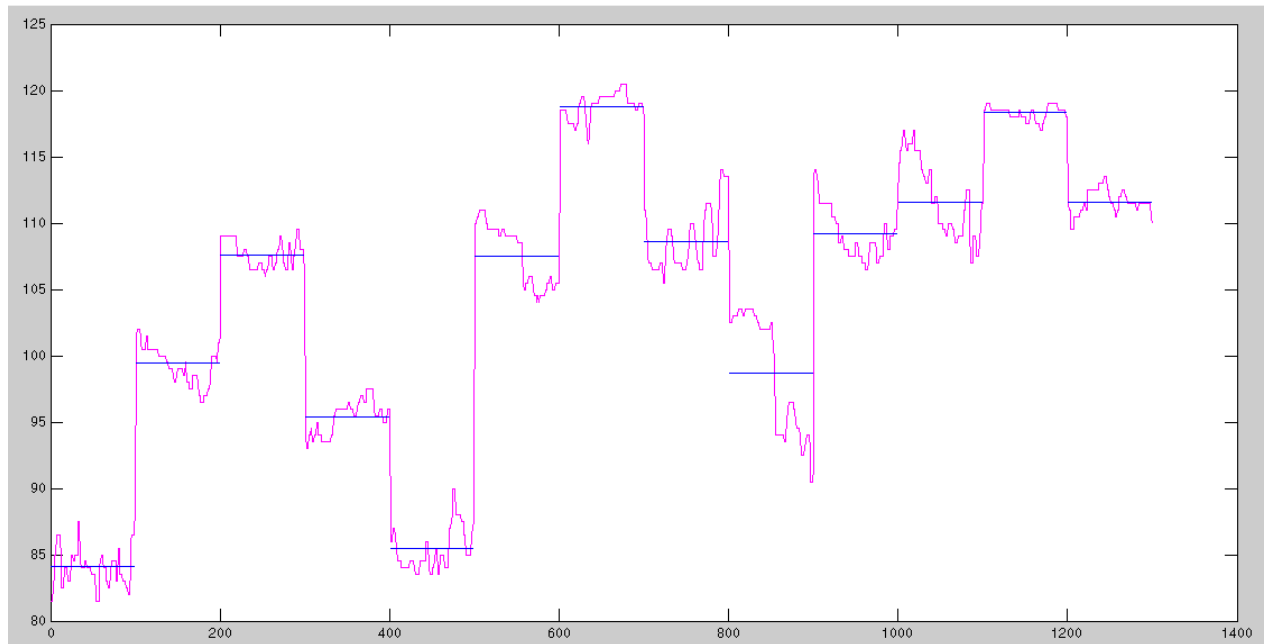
O que é mostrado à rede neural durante uma coleta do sistema funcionando em tempo real é apenas uma pequena parcela do ambiente 3, entretanto, essa metodologia de treinamento faz com que a rede neural tente aproximar esses dados pela curva mostrada na figura 29. Dessa forma, essa metodologia dificulta o trabalho da rede, pois ela tenta aproximar uma pequena parte do mapa através da totalidade do mapa.

Surgiu então a ideia de tentar comparar os dados coletados em tempo real com as pequenas regiões representadas pelos pontos de coleta, e não com o ambiente todo. Isso visa simplificar o trabalho da rede, pois maximiza as similaridades entre os dados. Dessa forma, dividiu-se os pontos de treinamento em 15 classes, que seriam as saídas da rede neural. Um algoritmo viria depois para decidir, baseado na saída da rede, qual ambiente seria predito. Tentou-se algumas abordagens, e nesse momento do trabalho, optou-se em classificar o usuário como estando no mesmo ambiente que a classe apontada pela rede neural. No entanto, em seções mais à frente discute-se outro método de classificação que gerou melhores resultados.


Para a metodologia apresentada, o desempenho offline teve melhora considerável e a rede classifica corretamente quase 100% dos casos. Isso confirma a suposição inicial de que os dados seriam facilmente separáveis pela rede neural ou outro classificador de desempenho equivalente.



**Figura 27.** Os primeiros 500 dados representam o ambiente 3, os próximos 400 dados representam o ambiente 2 e os 400 últimos o ambiente 1.



**Figura 28.** Leitora isolada plotada junto com a média dos valores a cada um dos 13 grupos de 100 dados, a fim de permitir fácil visualização dos diferentes níveis de atenuação que ocorrem ponto a ponto.



**Figura 29.** Sinal de RSSI representando o mapa de atenuação do ambiente 3 para apenas uma leitora.

As condições de treinamento para o experimento citado foram as seguintes:

- Número de neurônios na camada de entrada: 5.**
- Número de camadas escondidas: 1.**
- Número de neurônios na camada escondida: 20.**

**Número de neurônios na camada de saída:** 15.

**Função de treinamento:** Scaled Conjugate Gradient ('trainscg').

**Divisão dos dados (Treinamento/Validação/Teste):** 90%/5%/5%.

**Função de transferência na camada de saída:** Linear ('purelin').

**Pré-processamento nos dados:** Filtro de mediana e normalização (divisão por 255).

**Índice de acerto na fase offline (desempenho):** ~100%

O que se observa na prática (fase online do sistema), entretanto é que o algoritmo não é capaz de atingir tais números da fase offline, mesmo possuindo um bom desempenho. Aplicando-se a metodologia 1 conseguiu-se um desempenho médio de aproximadamente 50%-60%.

Investigou-se o motivo dessa discrepância entre a fase de testes offline e a fase de teste em tempo real. O motivo encontrado que justifica esse fato é bastante simples, e está bem representado na figura 31. Como pode-se observar, os valores de RSSI para o mesmo ponto, porém em momentos diferentes do dia, não é o mesmo. A rede neural erra, por que o padrão apresentado a ela durante a fase de treinamento não necessariamente se repete durante o momento desejado para que se realize a classificação em tempo real. Observou-se, entretanto, que esse padrão tende a se repetir novamente, principalmente se não houver mudanças significativas na posição das leitoras ou nos móveis do laboratório. Porém não é possível precisar em qual instante de tempo isso irá ocorrer. Dessa forma, um sistema de localização em tempo real que descarte sucessivamente medidas discrepantes do mapa de atenuação em relação ao que foi usado para treinar a rede conseguiria sempre acertar a posição do usuário da tag, uma vez que o padrão eventualmente irá se repetir. Porém, seria necessário que a aplicação dispusesse de uma restrição de tempo arbitrária, visto que o padrão pode se repetir em poucos segundos, mas também em vários minutos. Além disso, o usuário teria que permanecer parado em determinado local por algum tempo. De qualquer forma, tal sistema teria pouco valor prático.

Uma forma encontrada de implementar uma metodologia de descarte de coletas diferentes daquelas que foram usadas para treinamento, baseou-se no cálculo e comparação das médias do sinal leitora a leitora. O programa guarda os valores das médias de RSSI apresentadas à rede neural durante a fase offline para todos os 15 pontos de coleta. Durante a fase online, faz-se uma nova coleta, apresenta-a ao classificador, e este faz a predição. Nesse momento, compara-se as médias de RSSI da nova coleta com as médias de RSSI do local predito pela rede. Havendo uma diferença em pelo menos duas leitoras que seja maior que 11, o sistema descarta a decisão da rede e faz uma nova coleta. Exemplo: Se a predição da rede neural for o ponto 5, então o sistema fará:

$$\text{MediaLeitora10ponto5treinamento} - \text{MediaLeitora10ponto5novaColeta} = x0$$


$$\text{MediaLeitora11ponto5treinamento} - \text{MediaLeitora11ponto5novaColeta} = x1$$

$$\text{MediaLeitora12ponto5treinamento} - \text{MediaLeitora12ponto5novaColeta} = x2$$

$$\text{MediaLeitora13ponto5treinamento} - \text{MediaLeitora13ponto5novaColeta} = x3$$

$$\text{MediaLeitora14ponto5treinamento} - \text{MediaLeitora14ponto5novaColeta} = x4$$


Caso mais de dois valores do vetor X seja superior a 11, o sistema descarta a decisão da rede e faz uma nova coleta. Pode-se fazer isso quantas vezes for necessário, porém o sistema não garante um tempo mínimo de resposta. Testando a rede neural na fase online para a metodologia 1, eventualmente conseguiu-se desempenho entre 90%-100% para as condições citadas acima, o que comprova que é possível achar um limiar de descarte que melhore o desempenho da rede neural.




**Figura 30.** Comparação entre coletas feitas para um mesmo ponto, porém em momentos distintos do dia. Análise criteriosa mostra diferenças sensíveis entre os dados.

Retornando à discussão da variação do RSSI, percebeu-se que, embora alguns dos fatores externos que exercem influência sejam bem conhecidos, muitas vezes é difícil precisar o que está perturbando determinada leitora. Algumas figuras abaixo ilustram bem esse ponto. As respectivas legendas contêm as explicações.






**Figura 31.** O instante em que ocorre mudança na classificação é devido ao usuário realizando a coleta que resolve “sair da frente” da tag, pois este bloqueava o caminho mais curto entre esta e a leitora 12 (em verde). O sinal rapidamente sobe e ativa o limiar do classificador (instante 13).



**Figura 32.** Pessoa passando muito próxima da tag durante os instantes de coleta 25 a 35. Há enorme variação do sinal nesse momento.



**Figura 33.** RSSI da leitora 10 sofre forte queda no instante de coleta 9. Não foi possível detectar o motivo dessa queda. A orientação da tag não mudou, e o laboratório estava vazio, exceto pelo usuário fazendo o experimento.

## 4.1 Melhorando o desempenho da rede

A fim de garantir maior robustez na classificação da rede neural, buscou-se também melhorar a qualidade do treinamento. A intuição dizia que a rede generaliza melhor, se é apresentado para ela características relevantes do problema a ser analisado. Apesar de à primeira vista parecer ser bom apresentar o sinal do RSSI com muita variação, pois é assim que ele é naturalmente, buscou-se provar que é mais interessante buscar formas de atenuar essas variações, para que as disintições na atenuação do sinal, de ponto para ponto, sejam mais evidentes para a rede. Dessa forma ela aprende o essencial, o âmago do problema, e pode generalizar a partir disso.

Uma forma encontrada de reduzir a variação do sinal foi realizar uma nova coleta de 1500 dados, pegando novamente 100 dados de cada ponto. Dessa vez, porém, a rede neural seria treinada com a média dos valores da coleta antiga e a coleta nova. Ou seja, para o ponto 1, havia-se coletado 100 dados de cada umas das 5 leitoras, formando uma matriz 5x100. Fez-se uma nova coleta que gerou outra matriz 5x100. Então fez-se a média dessas duas matrizes elemento a elemento, gerando uma nova matriz 5x100 que foi usada para treinar a rede neural. Essa nova matriz possuía um desvio padrão menor que pelo menos o de alguma das duas matrizes originais (às vezes melhor que as duas), e mostrou-se uma forma de enriquecer os dados sem ocasionar grandes variações que poderiam descaracterizar os aspectos essenciais dos dados. Fato esse observado por que percebeu-se que a medida que o número de amostras por coleta aumentava, o desvio padrão aumentava proporcionalmente e utilizar-se dessa metodologia baseada na média contribui para amenizar essa variação.

A figura 35, que contém os gráficos, mostra de maneira clara que quando há uma variação muito grande em uma leitura em alguma das duas coletas, essa variação será atenuada se na mesma posição a outra coleta não apresentar essa variação.




Figura 34. Gráfico ilustra a atenuação da variação do RSSi quando faz-se a média de duas coletas distintas.

```

Dev1 =

DesvioPadraoLeitora10: 2.2629
DesvioPadraoLeitora11: 2.8990
DesvioPadraoLeitora12: 2.5147
DesvioPadraoLeitora13: 6.3163
DesvioPadraoLeitora14: 2.2820

Dev2 =

DesvioPadraoLeitora10: 1.0076
DesvioPadraoLeitora11: 2.6025
DesvioPadraoLeitora12: 1.3676
DesvioPadraoLeitora13: 1.1598
DesvioPadraoLeitora14: 1.5537

DevMedia = Desvio padrão após feita a média
            entre as duas coletas acima

DesvioPadraoLeitora10: 1.2937
DesvioPadraoLeitora11: 2.0800
DesvioPadraoLeitora12: 1.3753
DesvioPadraoLeitora13: 3.2381
DesvioPadraoLeitora14: 1.0752
  
```

Figura 35. Compara o desvio padrão das duas coletas, com o desvio padrão da média entre elas.

Uma outra medida para aumentar a robustez da rede foi utilizar como método de decisão de ambientes a soma dos pesos dos nós das classes da rede neural pertencentes ao respectivo ambiente. A rede neural, possui um número de nós em sua camada de saída igual ao número de classes possíveis para classificação. Cada nó é especializado em detectar a chance de que o dado de entrada pertença à classe que ele representa. Em geral, quando a aplicação da rede requer classificação de dados, usa-se a metodologia Winner-takes-all, ou seja, o neurônio que se apontou como tendo a maior chance de ter o dado novo pertencente à sua classe é escolhido o “vencedor” e a classificação da rede neural será a representada por aquele neurônio. Exemplo: Ao apresentar para a rede um dado de RSSI (vetor 5x1) proveniente do ponto de coleta 6, cada um dos 15 neurônios de saída apresentará um valor, que será tão maior quanto a “confiança” que o nó tem de que esse dado pertença à sua classe. Naturalmente, queremos que o neurônio 6 apresente o maior valor, uma vez que este representa o ponto 6. Na prática, diferentes neurônios apresentarão confiança alta. A expectativa é que os neurônios que pertençam a um mesmo ambiente, em geral, também tenham uma confiança alta. Por isso foi proposto usar o somatório dos neurônios do mesmo ambiente como fator decisivo para a rede neural apontar ambiente em que o dado foi coletado. O desempenho em comparação com a metodologia winner-takes-all foi superior, porém, mais uma vez, valores muito discrepantes entre o RSSI coletado e aquele usado para treino não puderam ser corretamente classificados.

Maior valor da coluna: significa que a rede neural irá classificar esse ponto como pertencente à classe 1


A proposta é tomar a decisão somando os pesos dos nós de classes que pertençam a um mesmo ambiente

	1	2	3	4	5	6	7	8	9
1	0.9620	1.0097	0.9730	0.9357	0.8914	0.8900	0.8243	0.7896	0.8091
2	0.0275	0.0157	0.0173	0.0190	0.0334	0.0279	0.0359	0.0406	0.0402
3	0.0201	0.0063	-3.6055e-04	-0.0074	0.0068	-0.0061	-0.0115	-0.0142	-0.0179
4	-0.1285	-0.0640	-0.0311	0.0016	-0.0664	-0.0047	0.0236	0.0374	0.0548
5	0.1460	0.0746	0.0662	0.0630	0.1034	0.0690	0.0795	0.0771	0.0760
6	-0.0479	-0.0224	-0.0202	-0.0322	-0.0533	-0.0479	-0.0677	-0.0755	-0.0841
7	0.0119	0.0316	0.0172	0.0028	-0.0191	-0.0208	-0.0445	-0.0583	-0.0512
8	-0.0504	-0.0458	-0.0392	0.0012	-0.0089	0.0292	0.0497	0.0674	0.0886
9	0.0143	0.0216	0.0167	0.0198	0.0095	0.0168	0.0125	0.0110	0.0186
10	0.0560	0.0435	0.0354	0.0055	0.0197	-0.0133	-0.0256	-0.0382	-0.0498
11	-0.0068	-0.0045	-0.0062	0.0258	0.0221	0.0524	0.0681	0.0842	0.0990
12	-0.0031	0.0027	0.0034	0.0046	-0.0024	0.0029	0.0016	0.0011	0.0037
13	-0.0501	-0.0419	-0.0378	-0.0346	-0.0101	-0.0182	-0.0155	-0.0067	-0.0304

Figura 36. As saídas de 13 dos 15 neurônios da camada de saída da rede neural para 9 dados coletados.

Após aplicar essas pequenas mudanças, percebeu-se que o classificador passou a possuir maior poder de generalização. A figura abaixo ilustra uma situação onde apenas as leitoras 10 e 14 não apresentaram mudanças significativas no sinal, com as leitoras 11 e 12 mudando até consideravelmente. A rede neural entretanto, acertou todos os 20 pontos de teste em tempo real.

Dessa forma, a rede teve aumento real em seu desempenho comparado com a primeira de todas as metodologias de classificação, onde haviam apenas 3 classes e as leitoras estavam muito próximas, o que fez aquela rede recorrer à leitora 12, mais distante, para definir seus limiares de decisão. Além disso, a rede neural também mostrou-se mais robusta que o algoritmo heurístico desenvolvido neste trabalho, comprovando as expectativas iniciais.



**Figura 37.** Imagem de cima mostra o mapa de atenuação em um determinado ponto, que é ensinado para a rede. Imagem de baixo ilustra o que foi coletado no mesmo ponto durante o teste em tempo real. A rede ainda assim conseguiu acertar todos os pontos.

## 4.2 Análise dos resultados após as melhorias

O desempenho da rede neural na fase offline é surpreendente. Para várias configurações de rede e várias inicializações, a rede sempre acertou 100% dos casos. Isso atesta que se for possível garantir que os padrões mostrados durante a fase de treinamento se repitam durante a coleta em tempo real, a rede neural irá acertar a localização do usuário sempre, não apenas no ambiente, mas também em qual dos 15 pontos o usuário está. As figuras 39 e 40 são mais um exemplo que confirmam essa tese. Analisando as duas, nota-se na figura 39 um momento de transição dos valores de RSSI que impactam

diretamente na decisão da rede neural. Observando a figura 40, vemos que essa transição leva os sinais a uma configuração muito parecida com aquela que foi apresentada à rede neural no momento de treinamento. A partir daí a rede só acerta, pois a similaridade é enorme.

Além da rede neural, treinou-se também um classificador chamado Support Vector Machine. Ele demonstrou desempenho parecido com a rede neural na fase offline acertando 100% dos casos de teste. Isso comprova que no estágio atual do trabalho, a escolha dos classificadores não é um fator que contribuirá para um aumento no desempenho do sistema. Tanto a Support Vector Machine, quando o MLP são capazes de resolver o problema de maneira robusta e satisfatória e acredita-se que outros algoritmos disponíveis na literatura terão desempenho semelhante.






Figura 38. Rede neural mudando sua predição após o sinal das 5 leitoras mudar consideravelmente.

Talvez um supervisor que fique 24 horas por dia ligado no LARA coletando o RSSI de cada uma das 5 leitoras, possa usar os valores passados como ajuda para estimar qual a posição atual do usuário. Em uma situação onde um usuário caminhasse às 12h00min de uma segunda-feira, o sistema poderia, por exemplo, comparar os dados novos coletados instantaneamente com as coletas realizadas em 4 segundas-feiras anteriores, no mesmo horário. Se houver discrepância muito grande, o sistema pode tentar descartar a predição da rede ou aceitar a predição do segundo nó mais confiável. A comparação efetuada pode ser subtrair a média de valores passados com a média de valores atuais, e se esta ficar dentro de uma faixa está aceitável, aceita-se o valor predito, senão descarta-se. É possível chegar a um conjunto grande de possibilidades de melhora no desempenho, e apenas um estudo mais minucioso pode determinar qual seria o mais adequado em determinada situação e porquê.



**Figura 39.** Figura que mostra claramente que quando o sinal do RSSI voltou a se parecer com o sinal ensinado à rede (figura na metade superior) esta passa a acertar todos as classificações.



**Figura 40.** Desempenho da rede neural na fase online para os métodos 1 e 2 e para o algoritmo heurístico.

O último conjunto de testes consistiu em aplicar a rede neural com as melhores técnicas de treinamento descobertas no trabalho para realizar a localização do sistema usando a metodologia 2 da fase online, coletando-se 30 dados de cada ambiente (total de 90 dados). Definiu-se dois métodos que teriam seus desempenhos comparados ao desempenho do algoritmo heurístico:

- 1) **Método 1:** Winner-takes-all. A classificação será decidida baseada em qual ambiente está o neurônio que obteve o maior valor em sua saída, ou seja, se o neurônio de maior valor for o de número 2, então o ambiente predito será o ambiente 3, pois o ponto de coleta 2 está no ambiente 3.
- 2) **Método 2:** Soma dos Neurônios. A classificação será decidida comparando-se o somatório dos valores dos neurônios em cada ambiente e vendo qual o maior. Exemplo: o ambiente 1 possui os neurônios de número 10 a 13, então será feita a soma de todos esse neurônios e esse valor será comparado com a soma dos neurônios que estão no ambiente 2 (6,7,8,9,15) e no ambiente 1 (1, 2, 3, 4, 5, 14). Além disso, mesclou-se algumas das condições utilizadas para montar o algoritmo heurístico, de forma que efetivamente o método 2 é híbrido de rede neural e condicional-relacional.

A figura 41 mostra o desempenho dos métodos e do algoritmo heurístico em detalhes. O método 1 teve taxa média de acerto de 55%, o método 2 de 60% e o algoritmo heurístico de 40%. Analisando o desempenho apenas do método 2, ambiente a ambiente, chegou-se às seguintes taxas médias de acerto: 70% para o ambiente 1, 40% para o ambiente 2 e 70% para o ambiente 3. As tabelas 1 e 2 resumem os resultados do experimento. É possível inferir que o ambiente 2 foi o mais problemático e puxou o desempenho para baixo. O método 1 também teve suas menores taxas de acerto no ambiente 2. Uma investigação criteriosa dos momentos de erro pode levar a um aumento significativo do desempenho geral do método.

Tabela 2. Taxa média de acerto dos três algoritmos usados na localização de usuários por ambientes

	Método 1 (Winner-takes-all)	Método 2 (Sum of Neurons)	Heurístico
Taxa média de acerto	55%	60%	40%

Tabela 3. Taxa média de acerto detalhada, ambiente a ambiente, para o método 2.

	Ambiente 1	Ambiente 2	Ambiente 3
Taxa média de acerto	70%	40%	70%



### 4.3 Resumo do projeto do sistema de localização

Para projetar um sistema de localização de usuários por ambientes, utilizando classificadores supervisionados, definiu-se as seguintes etapas:

1. Construção do mapa de atenuação de sinal do ambiente predial desejado. Definir os ambientes, o posicionamento das leitoras, quais os pontos de coleta para treinamento e qual a metodologia para coleta dos dados. Tirar várias medidas, procurar por métodos que garantam pouca variação dos dados, para que o treinamento do classificador seja o mais robusto possível. Depois de concluída essa etapa, evitar mudar muito os móveis do prédio, principalmente os de metal.
2. Treinar a rede neural com os valores de RSSI coletados. Cada classe corresponderá a um ponto de coleta, e o classificador aprenderá a distinguir entre cada um desses pontos. Garantir o fornecimento de dados de qualidade.
3. Aplicar a rede neural, construindo um sistema de coleta de valores de RSSI em tempo real, que garanta que apenas versões parecidas com o mapa de atenuação apresentado para a rede durante a fase de treinamento seja apresentado durante o funcionamento do sistema. Buscar mesclar algoritmos heurísticos com os classificadores supervisionados, a fim de melhorar o desempenho de classificação geral.

Um sistema supervisorio deve ficar ativo, coletando os valores do RSSI e as decisões dos classificadores, a fim de montar um banco de dados bastante diversificado, que permita gerar flexibilidade e mais robustez ao sistema.

O software ScadaBR é um sistema supervisorio gratuito bastante simples de usar, e com diversas funcionalidades. Ele foi usado brevemente neste trabalho para desenvolver uma tela de supervisão durante as etapas de coleta e teste online do sistema, com o intuito de permitir um forte apelo visual na interpretação dos dados. A comunicação do ScadaBR com o sistema implementado via Matlab se deu através de simples arquivos de texto do Windows, no formato .txt. O Matlab simplesmente escrevia os valores desejados em um .txt e o ScadaBR acessava esses arquivos e buscava esses valores, mostrando-os posteriormente na tela de supervisão. Foi possível acompanhar em tempo real a evolução dos valores de RSSI a medida que o sistema completava um loop de execução.

Todos os dados coletados nesse processo são armazenados pelo ScadaBR e podem servir como base para a melhoria sugerida no final da seção anterior. Pode-se também integrar nessa tela uma gama ainda maior de variáveis de coleta, como a temperatura e humidade em cada um dos ambientes que compõem o LARA, o consumo instatâneo em cada um dos aparelhos de ar-condicionado e o seu estado de acionamento (ON/OFF). Pode-se até mesmo mostrar onde encontra-se cada usuário do laboratório em termos de sua posição relativa a algum dos 15 pontos de coleta propostos.

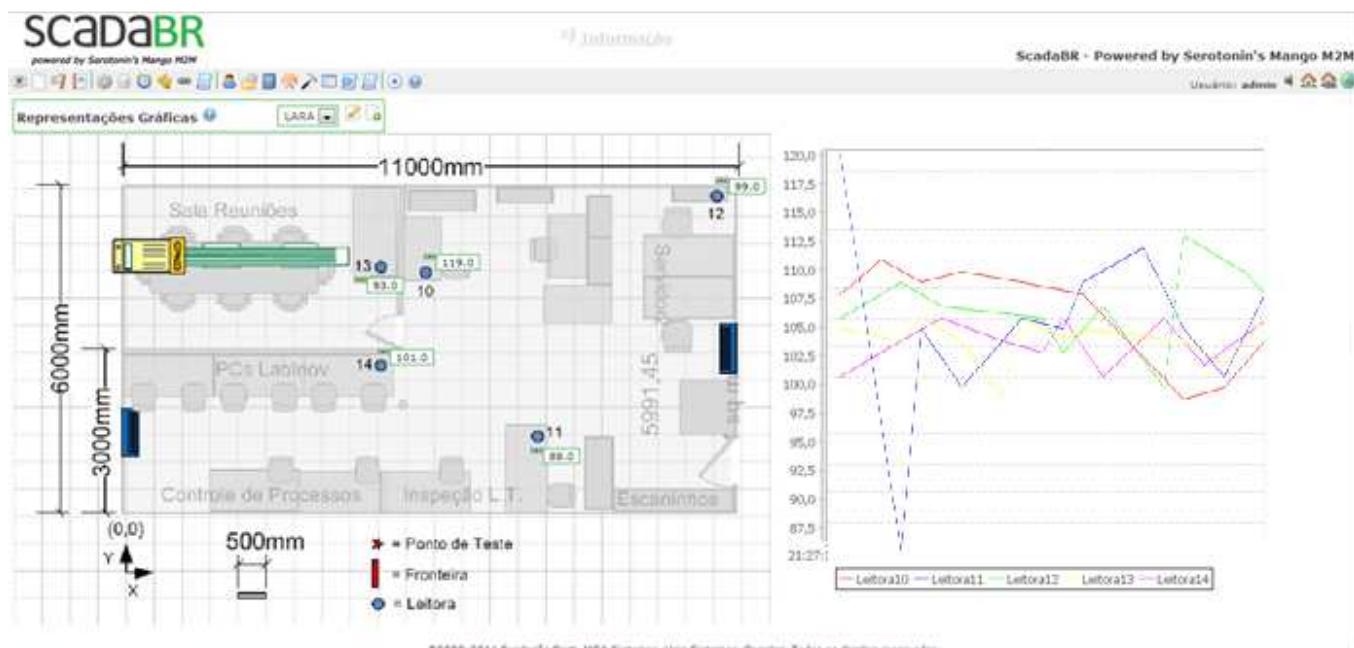


Figura 41. Tela de supervisor, para coletar os valores de RSSI ao longo do tempo e mostrar a posição dos usuários. O gráfico mostra a variação do RSSI para cada uma das 5 leitoras ao longo do tempo.

## 5 Conclusão

O RSSI de um determinado ponto no espaço possui um padrão latente, que se repete de forma imprevisível, porém que pode ser captada e aprendida por um algoritmo de machine learning.

No uso de classificadores supervisionados, a escolha dos features é importante, bem como a quantidade de dados que os representa. Na maioria das aplicações, o desafio reside mais na escolha, por parte do projetista do sistema, de features representativas do problema, e não na tentativa de conseguir os melhores parâmetros de uma rede neural. Se a quantidade e a qualidade dos dados for adequada, a rede neural certamente aprenderá bem o material apresentado. Se o padrão se desviar um pouco do original, a rede neural será capaz de se manter segura em sua classificação, entretanto, para grandes desvios nos valores do RSSI, a rede neural possui fraco desempenho de classificação.

O posicionamento das leitoras no ambiente deve permitir grande diferenciação entre os pontos de interesse do ambiente.

O trabalho mostrou que o foco deve ser garantir que o que for apresentado ao classificador durante a fase de treinamento seja consistente com o que será apresentado durante o funcionamento do sistema em tempo real. Ou seja, se houver uma classificação de padrões, deve-se garantir que o padrão volta novamente à tona dentro de uma determinada janela de tempo aceitável para a aplicação do sistema de localização. Pode-se buscar o uso de filtros de Kalman.

O classificador não poderia aprender corretamente como classificar os ambientes, se o que era apresentado era um conjunto grande de dados que não possuíam uma relação de padrão, e ele tentava aplicar em uma parte pequena (ponto) toda a identificação de um conjunto grande de dados. Então buscou-se a forma de implementação onde cada ponto seria uma classe, dessa forma seria mais fácil para o classificador identificar qual ponto é qual.

De qualquer maneira, é possível pelo menos localizar com boa eficácia o ambiente em que o usuário se encontra, o que justifica uma continuidade na investigação desse tipo de abordagem.

Então conclui-se que é possível desenvolver um algoritmo de localização utilizando sistema RFID, desde que o sistema lide com as oscilações no valor do RSSI e possa apresentar para a rede neural valores similares aos que foram usados para treinar a rede.

### 5.1 Trabalhos Futuros

Trabalhos futuros podem tentar desenvolver um sistema de localização propriamente dito e acionar os aparelhos de ar-condicionado para comparar a economia de energia em relação a um mesmo período com o sistema desligado. Uma das necessidades no desenvolvimento de tal sistema é a utilização da SDK do fabricante para ter acesso direto às leitoras, o que aumentará o ferramental e a gama de possibilidades. Dentre as funções das leitoras disponíveis para serem exploradas estão o cálculo do ruído branco a que cada leitora está submetida, a possibilidade de resetar as leitoras em conjunto, o que facilita a sincronização dos dados e agiliza o sistema, tornando-o mais viável em aplicações com janelas de tempo mais curtas. É possível citar também as funções para zerar o buffer

das leitoras para setar o ganho no cálculo do RSSI em HIGH ou LOW. Essa última implica em maior flexibilidade no sistema, pois possuirá uma faixa maior de valores disponíveis, uma vez que esse trabalho usou-se apenas o ganho no LOW, que é a configuração padrão de fábrica. Integrar o supervisor em um banco de dados, poderá aumentar a robustez do sistema, como sugerido na seção anterior. É possível também adaptar o sistema para incluir múltiplas tags (e conseqüentemente múltiplos usuários) e fazer a estimativa da carga térmica dos ambientes, dando continuidade aos estudos do LARA na área de conforto térmico de usuários em ambientes prediais.

Muito interessante, também, seria comparar a economia de energia gerada com o uso desse sistema de localização e fazer um estudo de viabilidade de projeto, mostrando que vale a pena investir nessa solução em comparação com outras ou até mesmo nenhuma.

Por fim, a principal recomendação que esse trabalho busca fornecer é que os trabalhos futuros devem focar os esforços em tentar diminuir a variação dos valores do RSSI durante a fase online do sistema, seja utilizando filtros no tempo ou outras técnicas em conjunto, pois acredita-se que esse é o principal empecilho para desenvolvimento de um sistema de localização confiável na maior parte do tempo. Uma figura interessante que ilustra a distribuição do RSSI ao longo do tempo está representada na figura 42 e mostra um histograma com 100 valores de RSSI para uma leitora, coletados em um mesmo ambiente. A distribuição parece ser gaussiana e o padrão se repete em todas os conjuntos de dados coletados em todo este trabalho.




Figura 42. Histograma para 100 valores de RSSI provenientes de uma mesma leitora e coletados no mesmo ponto.

## 6 Bibliografia

- [1] Figueredo, L., Do Couto, F. e Bauchspiess, A., 2011. **An evaluation of RSSI based indoor localization systems in wireless sensor networks**. Departamento de Engenharia Elétrica, Universidade de Brasília. Brasília-DF.
- [2] Petrobras Magazine, Edição 55, 2008. Disponível em:  
<http://www.hotsitespetrobras.com.br/petrobrasmagazine/edicoes/edicao55/pt/eficienciaenergetica/eficienciaenergetica.html>
- [3] Instituto Nacional de Eficiência Energética. Disponível em:  
[http://www.inee.org.br/eficiencia\\_o\\_que\\_eh.asp?Cat=eficiencia](http://www.inee.org.br/eficiencia_o_que_eh.asp?Cat=eficiencia)
- [4] Empresa de Pesquisa Energética, 2012. **Balço Energético Nacional**. Disponível em:  
[https://ben.epe.gov.br/downloads/Relatorio\\_Final\\_BEN\\_2012.pdf](https://ben.epe.gov.br/downloads/Relatorio_Final_BEN_2012.pdf)
- [5] Agência Brasil – Empresa Brasil de Comunicação  
<https://www.agenciabrasil.gov.br>
- [6] Fonseca, L., 2011. **Sistema de Localização RFID de Usuários Visando a Racionalização de Energia em Ambientes Inteligentes**. Trabalho de Graduação – Faculdade de Tecnologia. Universidade de Brasília. Brasília-DF.
- [7] Silva Júnior, C., 2012. **Classificação de Ambientes Prediais para Usuários Utilizando Tags RFID Ativas e Filtro de Kalman**. Dissertação de Mestrado em Engenharia Elétrica. Departamento de Engenharia Elétrica, Universidade de Brasília. Brasília-DF.
- [8] Norte Energia – Usina Hidrelétrica Belo Monte, 2012. **Consumo de energia elétrica cresce no Brasil e Belo Monte é garantia para essa demanda**. Disponível em:  
<http://www.blogbelomonte.com.br/2012/06/29/consumo-de-energia-eletrica-cresce-no-brasil-e-belo-monte-e-garantia-para-essa-demanda/>
- [9] Lamberts, R., 2007. **Eficiência Energética em Edificações**. Universidade Federal de Santa Catarina. Disponível em:  
[http://www.sindusconsp.com.br/downloads/eventos/2007/4sis\\_prediais/roberto\\_lamberts.pdf](http://www.sindusconsp.com.br/downloads/eventos/2007/4sis_prediais/roberto_lamberts.pdf)
- [10] Ni, L., Liu, Y., Lau, Y. e Patil, A., 2004. **LANDMARC: Indoor Location Sensing Using Active RFID**. *Wireless Networks*, 10, 701-710.
- [11] Souza, A., Oliveira, G., 2011. **Sistema de Localização para Robótica Móvel com RFID**. Trabalho de Graduação, Publicação FT.TG-x/11, Faculdade de Tecnologia, Universidade de Brasília, Brasília.
- [12] Matlab, MathWorks: <http://www.mathworks.com/products/matlab/>

- [13] OPC Foundation:  
[http://www.opcfoundation.org/Default.aspx/01\\_about/01\\_what\\_is.asp](http://www.opcfoundation.org/Default.aspx/01_about/01_what_is.asp)
- [14] Hsu, C., Chang, C. e Lin, C., 2003. **A Practical Guide to Support Vector Classification**. Department of Computer Science National Taiwan University, Taipei 106, Taiwan.
- [15] Crammer, K., Gilad-Bachrach, R. e Navot, A. **Margin Analysis of the LVQ Algorithm**.
- [16] Nilsson, N., 1998. **Introduction to Machine Learning**. Disponível em:  
<http://robotics.stanford.edu/~nilsson/MLBOOK.pdf>
- [17] Domingos, P. **A Few Useful Things to Know about Machine Learning**. Disponível em:  
<http://www.astro.caltech.edu/~george/ay122/cacm12.pdf>