

**Localização em dispositivos móveis  
utilizando sinais de redes *Wi-Fi***

Rodrigo Bernardo Pimentel

DISSERTAÇÃO APRESENTADA  
AO  
INSTITUTO DE MATEMÁTICA E ESTATÍSTICA  
DA  
UNIVERSIDADE DE SÃO PAULO  
PARA  
OBTENÇÃO DO TÍTULO  
DE  
MESTRE EM CIÊNCIAS

Programa: Ciência da Computação  
Orientador: Prof. Dr. Roberto Hirata Jr

Durante o desenvolvimento deste trabalho  
o autor recebeu auxílio financeiro da FAPESP e da FINEP

São Paulo, abril de 2011

# Localização em dispositivos móveis utilizando sinais de redes *Wi-Fi*

Esta dissertação trata-se da versão original  
do aluno Rodrigo Bernardo Pimentel.

# Agradecimentos

Este trabalho contou com financiamento da FAPESP e da FINEP. Gostaria então, primeiramente, de agradecer a estas instituições, cujo apoio viabilizou o projeto.

Agradeço imensamente à Universidade de São Paulo, minha *alma mater*, e ao Instituto de Matemática e Estatística, que me acolheu após uma conturbada mudança de área. É uma honra e um privilégio ser aluno aqui.

Durante o desenvolvimento desta pesquisa, convivi com membros do grupo de visão computacional e bioinformática do IME/USP. É estimulante estar em meio a pesquisadores tão competentes.

Aos membros da banca julgadora deste trabalho, professores Alfredo Goldman e Carlos Santos, muito obrigado por aceitarem esta incumbência. Espero que meus esforços estejam à altura.

Gostaria de agradecer também aos membros da banca do meu exame de qualificação, professores Ronaldo Fumio Hashimoto e Roberto Marcondes Cesar Jr. Suas considerações foram fundamentais à definição dos rumos desta pesquisa.

Em particular, agradeço ao professor Roberto Marcondes por seu papel como co-orientador da minha pesquisa. Seus comentários foram sempre relevantes e seu entusiasmo é fonte permanente de inspiração.

Devo muito ao meu orientador, professor Roberto Hirata. Ele foi um guia paciente e encorajador, mesmo quando eu não mereci. Sua orientação se estendeu para muito além dos aspectos técnicos, e fico feliz por poder contar com a sua amizade.

Aos novos amigos da *Hyves*, obrigado pela paciência e pela acolhida.

Aos velhos amigos que negligenciei nos últimos anos, com a desculpa de que “hoje não posso, preciso trabalhar no mestrado”, agradeço a compreensão. Ao longo de todo este processo, tive a sorte de poder contar com seu carinho, além de sua comida e seus martinis.

Aos meus gatos, Gandalf e Malu, agradeço a companhia nas noites que passei em claro.

Ao Daniduc e à Carla, nossas longas videoconferências me ajudaram a manter a sanidade. Mal posso esperar para encontrá-los novamente. E à Alice, no que imagino ser sua primeira menção em um trabalho acadêmico. Bem-vinda!

Finalmente, agradeço ao meu pai, Cesar, que me ensinou o Teorema de Pitágoras e deu início a tudo isto; à minha mãe, Maristela, que me ensinou a colocar o ponto final; e à minha esposa, Aline, com quem estou escrevendo o epílogo. Este trabalho é dedicado a eles.

# Resumo

Localização é um problema fundamental no estudo da computação móvel. Obter uma estimativa confiável de posição é essencial para navegação, realização de tarefas, apresentação de informações contextualmente relevantes etc.

Neste trabalho, apresentamos uma solução para localização utilizando sinais de redes *Wi-Fi*, baseada em classificadores Bayesianos ingênuos. A pesquisa se foca em localização de usuários portando dispositivos móveis como *notebooks*, *tablets* e telefones celulares. O número crescente de aparelhos deste tipo já equipados com antenas receptoras de sinais *Wi-Fi* estimula o uso destes sinais como base para localização.

A solução é descrita em detalhes, e são realizados experimentos com dados adquiridos para este propósito. Os resultados dos experimentos são justapostos aos de outras pesquisas na área. Mostramos que a estimativa de localização obtida com nossa solução tem qualidade comparável, e muitas vezes superior, à das obtidas por outros autores.

**Palavras-chave:** localização, *Wi-Fi*, *WLAN*, dispositivos móveis, classificadores Bayesianos, computação móvel.

# Abstract

Localisation is a fundamental problem in mobile computing. Obtaining trustworthy position estimates is essential for navigating, performing tasks, presenting relevant contextual information etc.

In this work, we present a solution to localisation using Wi-Fi network signals, based on naïve Bayesian classifiers. Our research focuses on locating users carrying mobile devices such as notebooks, tablets and mobile phones. The growing number of such devices already equipped with Wi-Fi antennas drives the use of these signals as a basis for localisation.

The solution is described in detail, and a number of experiments are carried out with data acquired for this purpose. The results of these experiments are set against those of other research in the area. We show that the location estimate obtained with our solution has quality comparable, and often superior, to that of those obtained by other authors.

**Keywords:** localisation, Wi-Fi, WLAN, mobile devices, Bayesian classifiers, mobile computing.

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
<b>2</b>	<b>Fundamentos teóricos e tecnológicos</b>	<b>4</b>
2.1	Reconhecimento de padrões . . . . .	4
2.1.1	$k$ vizinhos mais próximos . . . . .	6
2.1.2	Classificador ingênuo de Bayes . . . . .	7
2.2	O problema de localização . . . . .	9
2.3	$Wi-Fi$ . . . . .	17
<b>3</b>	<b>Localização baseada em redes <math>Wi-Fi</math></b>	<b>20</b>
3.1	Estado atual da área . . . . .	22
3.2	Descrição da solução . . . . .	24
3.3	Tratamento de dados . . . . .	25
3.4	Treinamento . . . . .	29
3.5	Classificação . . . . .	30
3.6	Pós-processamento . . . . .	31
<b>4</b>	<b>Experimentos</b>	<b>33</b>
4.1	Aquisição de dados . . . . .	33
4.2	Análise dos dados coletados . . . . .	40
4.2.1	Variabilidade temporal . . . . .	46
4.3	Resultados . . . . .	52
4.3.1	Protótipo de aplicativo móvel . . . . .	62
<b>5</b>	<b>Conclusões</b>	<b>64</b>
5.1	Considerações finais . . . . .	64
5.2	Sugestões para trabalhos futuros . . . . .	66

# Lista de Figuras

3.1	Comparação dos sinais de uma mesma rede, aplicado o filtro da média com $N = 13$ , obtidos por um <i>notebook</i> e um <i>smartphone</i> . . .	27
3.2	Comparação do comportamento relativo entre redes, observadas a partir de dois dispositivos diferentes. Às redes foi aplicado o filtro da média, com $N = 13$ . . . . .	28
4.1	Diagrama esquemático do método de aquisição de dados em 2010. .	34
4.2	Exemplos de imagens adquiridas em quatro instantes consecutivos. Para cada instante, aparecem aqui as três imagens adquiridas no trajeto inicial, e a quarta imagem adquirida no trajeto de volta. . .	36
4.3	Diagrama esquemático do método de aquisição de dados em 2011. .	38
4.4	Comparação de qualidade de sinais de diferentes redes. Sinais obtidos com o dispositivo <i>Mac</i> . . . . .	41
4.5	Distribuição de intensidades das redes <i>Wi-Fi</i> observadas. . . . .	42
4.6	Comparação dos sinais de uma mesma rede (00:05:9e:87:f3:ff) capturados pelos vários dispositivos. . . . .	43
4.7	Comparação dos sinais de uma mesma rede (00:1c:f0:58:35:1f) demonstrando mais claramente a potência relativa dos sinais do <i>Android</i> . . . . .	44
4.8	Comparação de qualidade de sinais de diferentes redes. Sinais obtidos com o dispositivo <i>N900</i> . . . . .	45
4.9	Sinais obtidos na aquisição de 50 horas, para redes que aparecem em pelo menos 95% das aquisições. . . . .	47
4.10	Sinais médio, máximo e mínimo de cada grupo de 10 sinais consecutivos. . . . .	49
4.11	<i>Boxplot</i> dos sinais das redes que aparecem em pelo menos 95% das aquisições. . . . .	50
4.12	<i>Boxplot</i> dos sinais de todo o período de aquisição, dos sinais de um período de movimentação no ambiente, e dos sinais de um período sem movimentação, para cada rede. . . . .	51



4.13	Comparação de valores de $N$ no filtro da média. $N = 1$ são os sinais originais. . . . .	53
4.14	Comparação dos erros obtidos na classificação com e sem probabilidades combinadas. . . . .	58
4.15	Capturas de tela do protótipo. . . . .	63

# Lista de Tabelas

3.1	Exemplo de sinais relativos. . . . .	28
3.2	Formato do conjunto de dados para treinamento do classificador. . . . .	29
4.1	Intensidades de redes $Wi-Fi$ , correspondentes aos locais onde se adquiriram as imagens da Figura 4.2. . . . .	35
4.2	Intensidades de redes $Wi-Fi$ na posição (8.4, 0.0), nos vários dispositivos de aquisição. . . . .	38
4.3	Testes com diversos valores de $N$ para o filtro da média. . . . .	54
4.4	Testes “70/30” com cada dispositivo. . . . .	55
4.5	Testes comparando treinamento com dados de um dispositivo e teste com dados de outro, sem utilização de sinais relativos. . . . .	55
4.6	Testes comparando treinamento com dados de um dispositivo e teste com dados de outro, com a utilização de sinais relativos. . . . .	56
4.7	Testes de combinação de probabilidades, para diferentes números de posições. . . . .	57
4.8	Resultados de classificação com configuração ótima. . . . .	58
4.9	Resultados de classificação com configuração ótima, somente com dados da aquisição de 2011. . . . .	59
4.10	Resultados de testes com dados do dispositivo $N900$ . . . . .	60
4.11	Comparação dos resultados desta pesquisa com os obtidos por outros autores. . . . .	61

# Capítulo 1

## Introdução

A busca por sistemas que permitam localizar confiavelmente um veículo ou indivíduo remonta a tecnologias desenvolvidas durante e imediatamente após a II Guerra Mundial. Baseadas inicialmente em sinais de rádio, evoluíram a partir de sistemas de auxílio a um navegador humano para mecanismos autônomos e sofisticados [Gro07].

De aplicações a princípio majoritariamente militares e, em segundo momento, mercantis, os sistemas de localização passaram a ser utilizados mais amplamente nas áreas de Engenharia e Ciência da Computação com o desenvolvimento da robótica. Para que veículos autônomos realizem tarefas de forma previsível, ou para que possam navegar por um determinado trajeto, é essencial que tenham alguma forma de se localizar confiavelmente no ambiente em que se encontram. Conforme os robôs foram expandindo sua capacidade de armazenamento, processamento e comunicação, e conforme sensores mais precisos, baratos e portáteis passaram a ser produzidos, as pesquisas se ramificaram para que os métodos de localização acompanhassem esta evolução.

Com o avanço da miniaturização de componentes, em particular, dispositivos móveis como *notebooks* e telefones celulares se tornaram plataformas atraentes para a aplicação de técnicas de localização. Atualmente, estão disponíveis comercialmente dispositivos móveis modernos, poderosos e acessíveis. Estes aparelhos são, cada vez mais, capazes de efetuar sensoriamento e processamento necessários a métodos eficazes de localização. Possuem, também, infra-estrutura de comunicação que lhes possibilita interagir rapidamente com servidores externos se necessário [HB08].

A utilização de métodos de localização para o auxílio a deficientes visuais, por exemplo, já era discutida em 1985 [LGK98]. Na época, os equipamentos então ditos “portáteis” eram caros e volumosos, mas hoje são plenamente adequados à tarefa de fornecer informações e orientação baseadas em localização ao usuário [LHKB08].

Área correlata, a pesquisa em realidade aumentada também é afetada por novos

desenvolvimentos de sistemas de localização. Aplicações que utilizem a posição do usuário para sobrepôr informações de diversos tipos a uma cena são comuns neste campo. Um sistema de realidade aumentada que possua um mecanismo confiável de localização pode apresentar ao usuário sugestões de navegação, dados sobre o deslocamento em si (como velocidade e tempo estimado até o destino), informações sobre um local ou marco, identificação de outros usuários próximos etc. [TP10]. Até alguns anos atrás, soluções de realidade aumentada tipicamente requeriam equipamentos dedicados ou, pelo menos, volumosos [DH07]. Aplicações recentes, entretanto, funcionam eficientemente em telefones celulares amplamente disponíveis, e podem ser utilizados gratuitamente por usuários não-especializados [Goo11, Lay11].

Qualquer que seja a aplicação, sistemas de estimação de localização, de forma geral, necessitam de algum sensor com o qual obter informações sobre o ambiente onde se encontram. São freqüentemente utilizados *lasers*, sonares, radares e câmeras fotográficas e de vídeo [FTBD01, SCMR04]. Há alguns anos, porém, começou a aumentar o interesse pela aplicação de sinais de redes *Wi-Fi* ao problema da localização [SSH03, HSS03].

Redes *Wi-Fi* se popularizaram por volta do ano 2000, com o aumento do uso de computadores portáteis. Atualmente, são cada vez mais incomuns os dispositivos móveis que não possuam interface *Wi-Fi* [LDBL07]. Ambientes internos, como prédios de escritórios, instituições educacionais, bares, restaurantes e mesmo moradias, freqüentemente possuem redes privadas próprias, e não raro mais de uma delas.

Em ambientes externos urbanos com alta densidade demográfica é possível também utilizar o conjunto de redes privadas como base para a localização [ACVS08]. Com a criação, em algumas cidades, de redes *Wi-Fi* públicas, abrangendo toda uma região metropolitana, a área coberta por sinais *Wi-Fi* aumenta consideravelmente [Kaw09, ACVS10].

Entretanto, redes *Wi-Fi* possuem características particulares, que as distinguem de outros sinais comumente utilizados em localização. Assim como ondas de rádio em geral, são bastante sensíveis a interferências, tanto de campos eletromagnéticos (incluindo outras redes *Wi-Fi*) quanto de características físicas do ambiente (paredes, janelas, móveis etc) [HAP02]. Os sinais podem ser deformados também pelo trânsito de pessoas nas proximidades, e mesmo a orientação da antena receptora influi no sinal obtido [ACVS08, HSS03, SCMR04, CLDR09].

É notável que sinais de redes *Wi-Fi* sofrem de variação temporal. Ainda que em ambientes estáticos e sem movimentação aparente, uma única antena receptora em repouso pode observar variações da ordem de 10% a 20% entre sinais obtidos em instantes consecutivos [HSS03, ZSS05]. Esta variação pode decorrer tanto do ambiente quanto dos próprios equipamentos utilizados [KGNM06].

Finalmente, diferentes antenas receptoras podem observar valores diferentes para sinais provenientes de uma mesma rede, já descontados os efeitos de interferências e de variabilidade temporal [YA05]. Um sistema desenvolvido para funcionar bem com um determinado dispositivo, não necessariamente apresentará bons resultados quando utilizado com outro [TCC09].

Apesar destas características, o estudo de localização utilizando redes *Wi-Fi* vem ganhando força. O grande número de dispositivos móveis já equipados com antenas receptoras de sinais *Wi-Fi* elimina a necessidade de sensores especializados. Ao mesmo tempo, fornecem plataformas com capacidade de processamento e armazenamento considerável. Além disso, equipamentos transmissores de redes *Wi-Fi* estão disponíveis com baixo custo, e ainda se podem utilizar redes pré-existentes, cada vez em maior quantidade.

Estes aspectos tornam a localização com *Wi-Fi* atraente também como método auxiliar a outras técnicas [CLDR09]. Soluções de localização utilizando visão computacional, por exemplo, tipicamente exigem bases de dados volumosas e processamento intenso para obterem bons resultados. A utilização de sinais de redes *Wi-Fi* pode rapidamente restringir o espaço de busca a uma pequena região, sobre a qual o algoritmo de visão computacional pode agir com eficiência para atingir resultados mais precisos [HB07]. Esta combinação de técnicas pode inclusive facilitar, ou até tornar viável, uma implementação completamente contida em dispositivos móveis com menor poder de processamento, sem a necessidade de delegação a um servidor externo [MHP<sup>+</sup>11].

Junte-se a estas considerações o fato de que algoritmos de localização utilizando redes *Wi-Fi* vêm obtendo resultados cada vez mais precisos [YA05, LDBL07]. Aumenta, então, a relevância de sua utilização, tanto isoladamente quanto em conjunto com outras técnicas.

O presente trabalho propõe uma solução para o problema de localização utilizando sinais de redes *Wi-Fi*, baseada em técnicas de reconhecimento de padrões. As características de variabilidade das redes são estudadas, e a solução apresenta formas de mitigar os efeitos de cada uma delas. O trabalho pressupõe uma situação de uso real, com ambientes potencialmente dinâmicos e dispositivos arbitrários.

Primeiramente, será apresentada a fundamentação teórica em que a pesquisa se baseou. Em seguida, descreveremos o problema que pretendemos abordar e uma proposta de solução. Detalharemos então os experimentos realizados, incluindo as aquisições dos dados, sua análise, e o resultado da aplicação da solução proposta a eles. Mostraremos que o classificador sugerido neste trabalho apresenta bons resultados quando comparado a outras soluções para o mesmo problema. Finalmente, apresentaremos nossas conclusões finais e indicaremos possíveis melhorias e extensões futuras.

# Capítulo 2

## Fundamentos teóricos e tecnológicos

### 2.1 Reconhecimento de padrões

O estudo de reconhecimento de padrões, em termos gerais, pesquisa formas de se atribuírem categorizações a amostras de um determinado universo. Essas categorizações podem ser escolhidas dentre um conjunto limitado pré-definido de valores discretos (como, por exemplo, letras do alfabeto latino), ou assumir valores arbitrários de um intervalo contínuo (como o conjunto dos números reais). Aplicam-se técnicas de reconhecimento de padrões à classificação de caracteres manuscritos, leitura labial, análise de formato de ondas eletromagnéticas etc.

Sistemas de reconhecimento de padrões, tipicamente, podem ser divididos em alguns componentes distintos [DHS01]:

**Sensoriamento.** O sistema precisa receber, ou coletar, dados do universo a que esteja sendo aplicado.

**Pré-processamento.** Os dados obtidos, em geral, precisam ser tratados de alguma forma. Aqui são realizadas segmentação de imagens, atenuação de ruído de sinais, normalização de valores em diferentes escalas etc. Após o pré-processamento, o sistema pode tratar de amostras (ou “exemplos”) individuais, e não mais de uma massa de dados.

**Extração de características.** Uma amostra é associada a um conjunto de características. Por exemplo, um sistema de reconhecimento de caracteres poderia dividir uma imagem em quadrantes e observar a quantidade de pixels escuros em cada um deles; neste caso, as características seriam “número de pixels escuros no quadrante 0”, “número de pixels escuros no quadrante

1” etc. Cada amostra apresenta uma valoração para o conjunto das características. Idealmente, uma valoração específica define a categorização da amostra. A escolha de quais características utilizar é uma parte crucial da definição de um sistema de reconhecimento de padrões.

**Classificação.** Dados os valores obtidos para as características de uma amostra, o sistema pode proceder à classificação. Em uma situação ideal, conforme mencionado acima, a extração de características em si implicaria imediatamente uma classificação. No entanto, em aplicações práticas a classificação é normalmente mais complexa. Uma amostra pode não apresentar valores para todas as características (por falhas no sensoriamento, por exemplo), os valores podem ser imprecisos (como medições freqüentemente são), as características podem ser inerentemente ambíguas etc. Na etapa de classificação, o sistema busca a melhor forma de explicar os valores das características, a partir de um modelo pré-definido. Este modelo está intrinsecamente ligado à escolha das características, e ambos dependem de conhecimento prévio do domínio do problema sendo estudado.

**Pós-processamento.** Um sistema de reconhecimento de padrões, tipicamente, tem uma ação, ou sugestão de ação, associada: apresentar um determinado texto ao usuário, acionar um alarme, mover um veículo etc. Uma vez que toda classificação está sujeita a erro e que cada ação tem um custo associado, cada sugestão de ação envolve um risco. Além disso, a classificação pode estar imersa em um contexto que a influencie; por exemplo, uma extração de características realizada à noite pode implicar maiores taxas de erros, ou a movimentação de um veículo nas proximidades de um penhasco incorre em maiores riscos. O pós-processamento deve levar estes fatores em consideração para, a partir da classificação, decidir qual ação deve ser sugerida em relação à amostra observada. O sistema pode ainda utilizar diversos classificadores diferentes, e cabe ao pós-processamento a combinação de seus resultados.

A construção de um classificador com estas características requer a definição do modelo de descrição das amostras, assim como a escolha das características. Para validar as decisões tomadas neste processo, é necessário adquirir dados; esta etapa de aquisição é freqüentemente lenta ou custosa, mas indispensável. Os dados são utilizados para treinar e avaliar o classificador, e, portanto, é importante que sejam representativos do universo em que o classificador vá atuar. O classificador pode então ser refinado e re-avaliado até que os resultados atinjam os níveis de acurácia e precisão desejados.

Ao discutir acurácia e precisão, estamos atribuindo certo grau de confiança, ou crença, em que uma amostra pertença a uma determinada classe. O conjunto destas atribuições de confiança relacionadas a uma mesma classe, para todas as

possíveis valorações das características, é representado por uma função densidade de probabilidade definida sobre o espaço de características (ou seja, um espaço cujas dimensões são as características). Para cada possível classe, é definida uma função densidade de probabilidade.

Nestes termos, reconhecimento de padrões pode ser entendido como a tarefa de se encontrarem funções densidade de probabilidade sobre o espaço de características. Quando a forma das funções densidade de probabilidade é bem conhecida, ou pode ser aproximada, o trabalho do classificador é estimar parâmetros que definam cada uma delas (*estimação paramétrica*). Pode ocorrer também que as funções densidade de probabilidade assumam formas não estruturadas, e não possam ser definidas por um conjunto de parâmetros (*estimação não-paramétrica*). Em ambos os casos, o classificador pode “aprender” a realizar a estimação a partir de um conjunto de dados de treinamento [Fuk90].

Este aprendizado, tipicamente, se divide em “supervisionado” e “não supervisionado”. No caso do aprendizado supervisionado, o classificador recebe dados de treinamento previamente classificados, e busca adaptar sua classificação de forma a concordar com eles. Aprendizado não supervisionado é mais complexo, pois os dados de treinamento não estão classificados; o classificador precisa de alguma forma agrupar os dados a fim de lhes atribuir categorias. Há ainda variações como “aprendizado semi-supervisionado”, em que apenas uma pequena quantidade dos dados de treinamento é previamente classificada; e “aprendizado por reforço”, em que os dados não estão classificados, mas é fornecida uma função de avaliação para apontar quão boa é uma classificação (ou, em muitos casos, simplesmente se ela está correta ou não) [DHS01].

A área de reconhecimento de padrões é bastante extensa, e engloba uma ampla gama de ramificações e aplicações. Serão ressaltadas, aqui, duas técnicas relevantes a esta pesquisa:  $k$  vizinhos mais próximos (ou  $kNN$ , de “ $k$  nearest neighbours”) e classificadores Bayesianos ingênuos (ou “naïve”).

### 2.1.1 $k$ vizinhos mais próximos

$kNN$  é uma técnica não-paramétrica bastante utilizada em reconhecimento de padrões. O princípio empregado é simples: as amostras de “treinamento” são simplesmente armazenadas como pontos no espaço de características. Quando se deseja classificar um novo exemplo, ele é localizado neste espaço, e recebe a classificação prevalecente entre as dos  $k$  pontos mais próximos.

Naturalmente, um classificador  $kNN$  é bastante sensível ao conceito de “proximidade”. Uma simples mudança de escala nos valores de uma das dimensões do espaço pode alterar as relações de distância entre os pontos, e conseqüentemente alterar as classificações obtidas. Além das unidades adotadas, é também importante escolher uma métrica adequada para a distância. É comum



o uso de distância Euclidiana, especialmente quando o problema não implica, intrinsecamente, métricas diferentes (e às vezes, por simplicidade, até quando implica). No entanto, uma escolha cuidadosa da métrica utilizada pode resultar em ganhos significativos na acurácia do classificador.

Em particular, se o classificador precisa lidar com amostras sem valores para algumas das características, a função escolhida para distância deve definir algum critério de solução. Pode-se, por exemplo, calcular a distância baseada somente nas dimensões que apresentem valores; entretanto, isto pode tratar pontos bastante distantes como próximos. Outra alternativa é preencher valores ausentes com um valor padrão (como 0, ou uma média dos valores dos pontos já presentes no espaço). De qualquer modo, quanto maior for a taxa de valores ausentes, maior será o peso desta escolha na classificação.

Classificadores do tipo  $kNN$  são freqüentemente utilizados em função de sua facilidade de implementação. No entanto, é importante conhecer as limitações de uma implementação ingênua. Um classificador com  $n$  amostras armazenadas em um espaço de características com  $d$  dimensões, tem complexidade computacional  $O(d \times n)$  para encontrar os  $k$  pontos mais próximos de um novo exemplo. Em problemas com alta dimensionalidade ou grande número de amostras armazenadas, isto pode tornar o classificador lento, ou mesmo inviável. Por outro lado, há métodos para se reduzir esta complexidade, empregando algoritmos que aceitem comprometer a acurácia da solução em troca de maior velocidade de processamento [DHS01].

$kNN$  é uma técnica bastante estudada, e não raro são propostas variações na busca por melhores resultados. Por exemplo, uma delas propõe alterar o critério de escolha dos  $k$  pontos cujas classificações serão utilizadas. Assim, dado um exemplo a ser classificado, podem-se dividir os  $k$  pontos mais próximos em conglomerados de acordo com uma regra pré-definida. Seleciona-se então um dos grupos, e somente os pontos contidos nele são utilizados na classificação do exemplo [MLTL08]. Outra variação atribui pesos aos pontos, seguindo algum critério, e, no momento da classificação, a influência que cada ponto tem na decisão da classificação final é ponderada por estes pesos [LWL<sup>+</sup>05].

Apesar de sua aparente simplicidade, classificadores  $kNN$  funcionam bem em problemas com alto número de classes, e são bastante utilizados, com bons resultados práticos [Fuk90].

### 2.1.2 Classificador ingênuo de Bayes

Em um dado problema de classificação, seja  $P(c)$  a probabilidade *a priori* de uma amostra pertencer a uma classe  $c \in C$ , em que  $C = \{c_1, c_2, \dots, c_m\}$  é o conjunto de todas as  $m$  classes possíveis. Sem ter mais informações sobre o problema, um classificador poderia escolher a classe com maior probabilidade *a priori*, e atribuí-la

sempre a qualquer nova amostra.

Entretanto, em problemas de reconhecimento de padrões, tipicamente temos pelo menos mais uma fonte de informações: as características extraídas da amostra. Para efeitos de classificação, a amostra pode ser representada pelos valores de suas características. Seja, então, uma amostra  $\mathbf{a} = \{v_1, v_2, \dots, v_n\}$ , em que  $v_1, v_2$  etc. são, em geral, resultados de medidas, e assumem valores em  $\mathbb{R}$ . Gostaríamos de incorporar ao classificador o fato de que conhecemos os valores das características associados a esta amostra.

O Teorema de Bayes [DHS01] permite relacionar a probabilidade *a posteriori* à probabilidade *a priori*:

$$P(c|\mathbf{a}) = \frac{P(c) \times P(\mathbf{a}|c)}{P(\mathbf{a})} \quad (2.1)$$

Na Equação 2.1,  $P(c|\mathbf{a})$  é a probabilidade *a posteriori* da classe  $c$  dada a amostra.  $P(\mathbf{a}|c)$  é a *verossimilhança*, ou seja, a probabilidade desta amostra se se assume a classe  $c$ . O termo  $P(\mathbf{a})$  é chamado de “evidência”, e pode ser interpretado como um fator de escala, para que as probabilidades *a posteriori* somem um [DHS01].

Um classificador Bayesiano é um classificador probabilístico que se baseie no Teorema de Bayes para estimar a classe mais provável de uma determinada amostra. A partir da Equação 2.1, o classificador Bayesiano pode atribuir à amostra a classe  $c_i \in C$  que maximize  $P(c_i|\mathbf{a})$ . Para isto, é necessário determinar  $P(c_i)$  e  $P(\mathbf{a}|c_i)$ . O termo relativo à evidência é irrelevante à classificação, uma vez que é o mesmo para todas as probabilidades *a posteriori*.

Os valores das probabilidades *a priori*  $P(c_i)$  de cada classe  $c_i$  vêm de conhecimento do problema sendo estudado. Uma situação freqüente é a de que todas as classes são igualmente prováveis:

$$P(c_1) = P(c_2) = \dots = P(c_m) = \frac{1}{m}$$

Resta determinar a probabilidade condicional  $P(\mathbf{a}|c_i)$ . Este resultado é tipicamente difícil de se obter, uma vez que o número de possíveis valorações  $\{v_1, v_2, \dots, v_n\}$  pode ser muito grande. Se assumirmos, entretanto, que os valores das características são independentes entre si, podemos reescrever a probabilidade condicional acima como uma combinação das probabilidades de cada valor, dada a classificação  $c_i$  [Siv96]:

$$P(\mathbf{a}|c_i) = P(v_1, v_2, \dots, v_n|c_i) = \prod_{j=1}^n P(v_j|c_i)$$

Esta premissa de independência condicional é conhecida como “regra ingênua (ou *naïve*) de Bayes”. Sua utilização permite aproximar  $P(\mathbf{a}|c_i)$  a partir dos dados de treinamento do classificador (por exemplo, atribuindo valores a  $P(v_j|c_i)$  de acordo com as freqüências relativas). É uma premissa bastante forte, e freqüentemente não é verdadeira. Entretanto, quando a relação de dependência não é bem conhecida ou é muito complexa, assumir independência pode funcionar bem, em termos práticos [DHS01]. Um classificador Bayesiano que empregue a regra ingênua de Bayes é chamado de “classificador ingênuo de Bayes”.

Classificadores Bayesianos ingênuos permitem lidar de forma simples com valores ausentes, e se adaptam bem a características sujeitas a ruído. No caso de valores ausentes, as probabilidades *a posteriori* são calculadas em termos das verossimilhanças dos valores presentes. Quando há ruído nas medições dos valores das características, pode-se descrevê-lo por uma distribuição de probabilidades (um “modelo de ruído”) e incorporá-la ao cálculo das probabilidades *a posteriori*. No caso extremo em que o ruído é uniforme sobre todas as medidas de determinadas características (e elas, portanto, não fornecem informação relevante à categorização), pode-se aplicar a mesma solução adotada para valores ausentes [DHS01].

## 2.2 O problema de localização

Localização é um dos problemas fundamentais na área de robótica móvel e veículos autônomos [Cox91, TFBD01]. Entende-se, aqui, como “localização”, uma estimativa da posição de um robô (ou, mais genericamente, um indivíduo) em relação a um sistema de coordenadas. Sobre este sistema de coordenadas se define, também, o ambiente (previamente mapeado ou não) onde o robô deve se localizar. Em particular, tratamos do problema de localização a partir da utilização de sensores presentes no próprio indivíduo a ser localizado, e não de indivíduos localizados por sensores externos [YMA07]. Uma extensão freqüentemente abordada deste problema é a obtenção de “pose”, ou seja, estimativa também da orientação, além da posição do veículo. Estudos de obtenção de pose estão normalmente associados à utilização de sensores ou métodos inerentemente direcionais, como *lasers* ou visão computacional [TFBD01, JK01, KGMP05, HGL<sup>+</sup>09].

Thrun *et al.* [TFBD01, FBT99] identificam três variações do problema de localização de um robô móvel:

**Rastreamento de posição** é a mais simples e mais freqüentemente abordada. O ambiente e a posição inicial do robô são conhecidos. O problema consiste em se manter uma estimativa da posição do robô após sucessivas movimentações, levando-se em conta as incertezas associadas ao modelo de deslocamento e às medidas pelos sensores.

**Localização global** trata da situação em que a posição inicial do robô é desconhecida. Não se pode, portanto, assumir que o erro das estimativas de localização do robô seja pequeno. Um modelo do ambiente vai sendo construído a partir dos dados obtidos pelos sensores, e não se pode garantir que ele esteja completo ou que não vá mudar posteriormente [JK01]. Ou seja, o robô precisa, a cada instante, saber lidar com múltiplas hipóteses de descrição do ambiente e de sua localização nele.

**Robô seqüestrado** ocorre quando o robô é subitamente transportado para outra posição, sem ser informado. Para lidar com esta ocorrência, uma solução de localização precisa ser capaz de, em todo instante, rapidamente verificar que suas estimativas não descrevem mais as observações, e se adequar aos novos dados. Esta situação é freqüentemente utilizada para testar a habilidade de um robô de se recuperar de falhas graves de localização. É interessante notar que o problema do robô seqüestrado é, por vezes, tratado como parte (ou decorrência) do problema de localização global [JK01].

Destas, a variação mais simples é a que lida somente com o rastreamento de posição. Assume-se que o ambiente é (pelo menos parcialmente) conhecido e que as movimentações do indivíduo são incrementais, e então a posição estimada é revisada em termos de erros pequenos, a cada passo. Estas características favoreceram a utilização de filtros de Kalman, que, efetivamente, são largamente empregados em rastreamento de posição [SSC90, KHLH03].

Filtros de Kalman são uma abordagem probabilística da busca por uma estimativa *a posteriori* de localização (ou, mais genericamente, da classificação de alguma grandeza arbitrária). Considera-se que as distribuições de probabilidades da incerteza inicial e dos erros nas medições subseqüentes tenham forma gaussiana. Em cada momento, a estimativa é revisada em dois passos:

- Uma atualização temporal, levando em consideração o modelo de movimentação adotado para o indivíduo. Isto descreve o deslocamento esperado entre dois instantes, e define uma estimativa *a priori* para o próximo passo.
- Uma atualização das medições, ou seja, a incorporação da próxima observação do ambiente, por meio dos sensores utilizados. Esta atualização avalia a correção da estimativa *a priori* obtida no passo anterior, assumida uma certa distribuição (gaussiana) de probabilidades de ruído nas medições.

Ao longo do período de rastreamento, estes passos são aplicados, recursivamente, e a estimativa de localização é construída incrementalmente [Kal60, WB95].

Filtros de Kalman representam uma solução simples e eficiente para grande parte das problemas de rastreamento de posição, mas a premissa adotada de

erro gaussiano não consegue descrever problemas de localização global (ou de seqüestro), em que a crença no estado atual pode mudar radicalmente de um instante para outro [TFBD01].

Em resposta a esta limitação, foi proposta uma modificação da técnica, em que a crença em um determinado estado é representada pela combinação de uma série de gaussianas. Ou seja, em todo momento o sistema trabalha simultaneamente com diversas hipóteses. Soluções desta forma são conhecidas, apropriadamente, como “filtros de Kalman de hipóteses múltiplas” [JK01]. No entanto, ainda se assume que o ruído nas medições obtidas é gaussiano, o que limita as informações que podem ser aproveitadas dos dados dos sensores [TFBD01].

Uma alternativa relacionada, algoritmos de “Localização de Markov” discretizam o espaço em uma malha fina e descrevem a densidade de probabilidades de todas as possíveis localizações por histogramas [BFHS96]. Esta família de algoritmos também consegue descrever múltiplas hipóteses, e algumas implementações se adaptam a ambientes dinâmicos. A representação fina necessária para a construção da densidade de probabilidades, entretanto, significa uma quantidade maior de dados a tratar, o que aumenta a complexidade computacional envolvida [FBT99].

Algoritmos de “Localização de Monte Carlo” (“MCL”), por outro lado, representam as probabilidades nos diversos possíveis estados por um conjunto de “amostras” (ou “partículas”). Em cada instante, um conjunto de pontos (as partículas) é extraído aleatoriamente da distribuição de probabilidades naquele momento. A estes pontos se aplica o modelo de deslocamento adotado, o que gera um novo conjunto de partículas. A cada partícula deste novo conjunto são aplicados pesos (também chamados “fatores de importância”), de acordo com uma observação dos sensores. Com isto, obtém-se uma distribuição atualizada de probabilidades. Esta técnica de representação por amostras é chamada, genericamente, de “filtro de partículas” [FTBD01]. Ao contrário de filtros de Kalman e de localização de Markov, que tentam parametrizar as estimativas *a posteriori*, localização de Monte Carlo pode descrever uma gama extremamente ampla de distribuições de probabilidade. Além disso, a atribuição de pesos às partículas tende a focar o processamento em regiões de maior probabilidade, o que evita desperdício de recursos em se manter uma descrição completa de todo o espaço de probabilidades [FTBD01, TFBD01].

Mesmo implementações simples de filtros de partículas exibem excelentes resultados não só para o problema de rastreamento de posição, mas também para o problema de posição global. Extensões do algoritmo podem também ser aplicadas ao problema de seqüestro de robô [FTBD01].

O problema da localização global é mais complexo, pois, inicialmente, todas as possíveis localizações são igualmente prováveis. Em uma situação ainda mais extrema, o ambiente onde o indivíduo se encontra pode ser completamente

desconhecido de antemão. Ou seja, não só desconhecemos a posição inicial do indivíduo no ambiente, como nem mesmo sabemos quais as características e marcos relevantes neste ambiente. A solução envolve, portanto, construir um mapa ao mesmo tempo em que se determina a posição do indivíduo nele. Problemas deste tipo são conhecidos como *SLAM* (“Simultaneous Localisation And Mapping”, ou “Localização e Mapeamento Simultâneos”) [DwB06a].

Uma solução para *SLAM* deve, basicamente, definir uma distribuição de probabilidades tanto para os pontos de referência (ou seja, o mapa) quanto para a posição relativa do indivíduo (ou robô) que se está tentando localizar, em cada momento. As soluções utilizam os mesmos dois passos que soluções de rastreamento de posição: atualização temporal, em que se faz uma previsão sobre a nova posição do indivíduo em relação ao mapa parcial do ambiente após uma movimentação; e uma rodada de novas observações, em que se corrigem as previsões do passo anterior. Neste segundo passo, entretanto, são incorporadas também novas medições sobre o ambiente, cujo mapa vai sendo então aprimorado.

Podem ser utilizados, na atualização recursiva das distribuições de probabilidades de marcos do ambiente e de localização do indivíduo, os mesmos métodos de filtros de Kalman e filtros de partículas. De forma geral, soluções baseadas em filtros de partículas são mais adequadas a problemas de localização com ruído de sensoriamento e distribuição de probabilidades não triviais [SSH03]. No entanto, muitas vezes são adotadas soluções híbridas. Por exemplo, um filtro de Kalman, de implementação simples, pode ser adotado para a estimativa de posições de marcos no ambiente que, de forma geral, possam ser considerados estáticos, enquanto um filtro de partículas é utilizado para a localização do indivíduo [KGMP05].

Todas as soluções apresentadas acima são tipicamente aplicadas a problemas de localização em robótica. Implementações destes algoritmos são utilizadas em áreas como vôo autônomo, navegação submersa, serviços de manutenção em locais de difícil acesso etc [CSR07, KN07, DRMS07]. Seu estudo, portanto, forma a base da pesquisa em localização.

No entanto, elas impõem, ou pressupõem, algumas características e restrições que podem torná-las inadequadas a situações como a de um usuário portando um telefone celular.

Por exemplo, a natureza incremental dos métodos de localização, mesmo quando é conhecida a posição inicial do indivíduo, exige que o dispositivo de localização esteja constantemente em funcionamento e fazendo medições. Ou seja, o usuário não pode guardar o aparelho durante parte do deslocamento. Caso contrário, o sistema sempre se encontra no caso de “seqüestro” e tem de convergir novamente para estimativa atualizada de posição, desconexa da anterior.

No caso de posição inicial desconhecida, ou mesmo de seqüestro, as técnicas apresentadas até aqui levam em torno de 30 a 100 segundos para convergir para

uma estimativa de localização com erro de magnitude de 1 m, e durante este tempo assume-se que o indivíduo está se movimentando pelo ambiente [FTBD01, SCMR04, DNC<sup>+</sup>01]. Embora deslocamentos desta ordem sejam perfeitamente aceitáveis para uma aplicação de robótica, são naturalmente inconvenientes para o usuário, especialmente se ele deseja obter a localização de onde se encontra naquele instante e não tem intenção de se deslocar.

Muitas destas soluções, também, podem ser computacionalmente intensas, no contexto de dispositivos móveis. Em particular, soluções para o *SLAM* tipicamente requerem amplo poder de processamento [DwB06b], tornando inviável sua implementação em dispositivos móveis de menor porte, como *smartphones*, ou exigindo que o usuário transporte equipamento volumoso [SEP05]. Para mitigar estes efeitos, algumas soluções recorrem a fornecer parâmetros de calibração (como alguma indicação da posição inicial), e mesmo assim exigem processamento em um computador de mesa para operação em tempo real [DRMS07].

Finalmente, boa parte das implementações de localização em robótica se baseia em sensores de distância, como radares, sonares e *lasers*. Este tipo de sensor, no entanto, não está normalmente disponível em dispositivos móveis comerciais. Algumas implementações chegam a utilizar câmeras e técnicas de visão computacional. Em muitos casos, porém, as imagens são utilizadas para pouco mais do que uma medida de distância, como substituto direto dos sensores especializados. Por exemplo, Thrun *et al.* [TFBD01] utilizam, em um de seus testes, um robô com uma câmera apontada diretamente para cima, obtendo imagens do teto do museu onde está buscando se localizar. Estas imagens são analisadas, principalmente, pela distribuição regular de luzes no teto. Após os experimentos, a solução baseada somente em imagens não foi utilizada nas operações regulares do robô, cuja localização durante o expediente do museu se baseou primariamente no uso de sensores *laser*.

Por outro lado, localização de usuários humanos portando dispositivos móveis podem ter outras restrições relaxadas. Por exemplo, erros de localização da ordem de 1 metro podem ser inconseqüentes (ou mesmo imperceptíveis), uma vez que estão dentro do cone de visão do usuário, e ao alcance de um ou dois passos. Mesmo em casos em que erro desta ordem seja relevante, como aplicações de realidade aumentada, pode ser mais simples efetuar uma correção no ajuste da imagem superposta do que alcançar uma estimativa mais precisa de localização global [HB07].

Dadas estas considerações, freqüentemente se empregam soluções alternativas, ou complementares, para a localização de usuários humanos, levando em conta características diferentes das presentes em estudos de robótica.

Por exemplo, é possível utilizar sinais de telefonia celular para localizar um determinado aparelho. Na pior das hipóteses, pode-se estimar a posição do

aparelho como a área de cobertura da célula que ele esteja usando. Se o aparelho estiver em um local onde haja presença de diversas células, é possível aplicar métodos de reconhecimento de padrões para obter localização mais confiável, com acurácia da ordem de até 2.5 m [LDBL07].

Atualmente, é muito difundido (mesmo em robótica) o uso do GPS (“*Global Positioning System*”, ou “Sistema de Posicionamento Global”), que, a partir de dados transmitidos por satélites, fornece informação de posicionamento a receptores apropriados. O acesso sem custo aos dados dos satélites, a ampla disponibilidade de receptores e a razoável qualidade da localização obtida contribuem fortemente para a larga adoção do sistema. Um número crescente de aplicações que desejam obter localização em ambientes externos utiliza GPS [Goo11, Lay11]. Suas limitações, entretanto, notavelmente incluem a dificuldade de recepção em ambientes fechados ou parcialmente encobertos, e a possibilidade de interferência nas proximidades de determinados campos eletromagnéticos (naturais ou artificiais). Seu uso depende, também, de hardware específico (ainda que receptores GPS estejam cada vez mais acessíveis, miniaturizados e incorporados a telefones celulares). Finalmente, a precisão do posicionamento via GPS, para receptores típicos, não é confiável, podendo atingir variações entre 1 e 20 metros [WEK05]. Ainda assim, uma estimativa de posição obtida por GPS pode ser utilizada como método auxiliar a outras técnicas [CLDR09, TP10].

Outra tecnologia que pode ser utilizada para localização é RFID (“Radio-Frequency Identification”, ou “Identificação por Rádio-Frequência”). O equipamento, baseado em ondas de rádio de curto alcance, é amplamente utilizado em sistemas de segurança, controle de rebanhos, mecanismos de pagamento (de transporte público, por exemplo) e, mais recentemente, passaportes. Seu uso exige etiquetas (ou *tags*) contendo informações relevantes, e um leitor que as detecte [LDBL07]. Além da necessidade, trabalhosa e intrusiva, de se posicionarem etiquetas em todos os ambientes onde se deseje obter localização, os sinais não são regulares e exigem tratamento considerável para fornecer estimativa confiável de posição [LCL06].

Há uma série de outros métodos que também utilizam etiquetas. Por exemplo, *Ubisense* [SG05] é um sistema de posicionamento baseado em sensores pré-ajustados ao ambiente e etiquetas que o usuário deve carregar consigo. Assim como a RFID, o *Ubisense* exige configuração antecipada (e potencialmente complexa) do ambiente. Sua acurácia pode chegar a 15 cm. Por outro lado, mesmo em ambientes preparados o *Ubisense* nem sempre é preciso, ou mesmo funcional, a depender das características físicas do local onde se encontra. Além disso, o *Ubisense* não prevê ambientes dinâmicos. Finalmente, é um equipamento especializado, de custo relativamente alto, e não amplamente disponível.

Métodos de visão computacional são utilizados por grande parte da pesquisa em localização com dispositivos móveis [RSF<sup>+</sup>06, RJ03, TP10, WRMT08]. Talvez



mais do que qualquer outro sensor, um número cada vez maior de dispositivos móveis conta com câmeras fotográficas e de vídeo. A disponibilidade deste tipo de equipamento, a baixo custo, incentiva sua utilização para localização. Além disso, técnicas de visão vêm sendo utilizadas com sucesso há décadas na área de localização em robótica [DwB06b, TFBD01, CSR07, KGMP05, KBO<sup>+</sup>05].

Alguns dos algoritmos de visão computacional propostos utilizam marcadores especiais, desenhados especificamente para armazenar informações facilmente recuperáveis a partir de fotografias, e que precisam ser posicionados previamente em locais adequados [CTCW07, MWBS09].

Mas as técnicas mais comuns, e mais robustas, se baseiam em extração e casamento de características das imagens adquiridas. Estes métodos tipicamente utilizam algoritmos SIFT [HB07, HB08, SLL02] ou SURF [BETG08, TP10]. Alguns até recorrem, com razoável sucesso, a soluções com menor complexidade computacional, como histogramas de cores [RSF<sup>+</sup>06].

Algumas aplicações, voltadas mais fortemente para uso interativo, utilizam ainda extração de características para obter reconhecimento de referenciais conceitualmente familiares ao usuário (como “casa”, “igreja” ou “árvore”). Estes sistemas utilizam bases de dados de referenciais previamente localizados e provêm navegação com o auxílio de pontos de fácil identificação que se sobressaiam ao local [HGL<sup>+</sup>09, HVC<sup>+</sup>08].

De modo geral, soluções de visão computacional tendem a ser robustas, mesmo em aplicações sensíveis, como auxílio a deficientes visuais. São razoavelmente resistentes a oclusão, variações de iluminação, movimentação de indivíduos e mutação do ambiente em relação a seu estado no momento de treinamento [SEP05, CM09, LGK98].

À sofisticação destas técnicas, alia-se a considerável capacidade de processamento de dispositivos móveis modernos, e a abundância dos que, dentre eles, portam câmeras digitais. A qualidade de imagem e resolução obtidas por estas câmeras, é claro, tem grande variabilidade. Mesmo câmeras de aparelhos simples, porém, já fornecem imagens adequadas para uso em diversas aplicações de visão computacional [TCG<sup>+</sup>08].

Por outro lado, mesmo com o avanço expressivo dos últimos anos, aparelhos celulares ainda não são adequados para computação intensiva, especialmente em tempo real (como se espera de um sistema de localização). Sua memória é tipicamente limitada e lenta, e boa parte dos aparelhos não possui suporte nativo a operações de ponto flutuante. Um algoritmo ingênuo de casamento de características de imagens, que tentasse buscar em toda a base de dados disponível, certamente não seria prático. Destas limitações computacionais, surgem algoritmos para tentar reduzir o processamento necessário, mas ainda mantendo a solução contida no dispositivo móvel [TP10, MHP<sup>+</sup>11].

A utilização de sinais de redes *Wi-Fi* em métodos de localização começou a ser objeto de pesquisa nos últimos anos. Estes estudos são estimulados pela ampla disponibilidade de redes *Wi-Fi* e o número crescente de dispositivos móveis (em particular, telefones celulares) capazes de receber seus sinais.

Na área de robótica, há, por exemplo, implementações de algoritmos de localização de Monte Carlo aplicadas a sinais de redes *Wi-Fi* [SSH03], obtendo erros da ordem de 0.5 metro. Outras soluções parametrizam as redes a partir de um modelo teórico de propagação dos sinais [SCMR04]. Foram inclusive propostas soluções para o problema de *SLAM* utilizando-se sinais de redes *Wi-Fi* [FFL07].

No entanto, estas abordagens estão sujeitas às mesmas considerações feitas anteriormente sobre o uso por um indivíduo portando um dispositivo móvel.

Uma forma comumente utilizada em localização de usuários humanos por redes *Wi-Fi* consiste em se caracterizarem posições a partir da distribuição de sinais de redes *Wi-Fi*, o que se denomina *fingerprinting* (pois tenta-se atribuir uma característica única, ou “impressão digital”, a cada ponto).

Há diversas técnicas de *fingerprinting* aplicadas à localização com *Wi-Fi*. Algoritmos de “k vizinhos mais próximos” são freqüentemente utilizados, tanto em implementações simples [LSDR06, LWL<sup>+</sup>05] quanto em variações mais sofisticadas, como por exemplo utilizando pesos [ZSS05] ou conglomerados (“clusters”) [MLTL08]. Estas implementações podem alcançar precisão menor ou igual a 2 metros.

Outros algoritmos se baseiam na modelagem da propagação dos sinais das redes para localizar o indivíduo [YA05]. Este tipo de abordagem, no entanto, tem de lidar com a grande variabilidade de redes *Wi-Fi* [HSS03], e com sua sensibilidade a interferências [HAP02].

Alguns algoritmos optam por uma abordagem mista, criando um modelo de propagação das redes e corrigindo-o com amostras coletadas [YA05]. E há ainda pesquisas sobre localização de indivíduos passivos, isto é, que não portem dispositivo algum (e que podem nem mesmo estar a par de que sua posição está sendo obtida), pela análise da variação dos sinais de rede no ambiente [YMA07].

Finalmente, existem ainda experimentos de localização utilizando dispositivos móveis que buscam utilizar somente sensores “auto-contidos” de *smartphones*, como acelerômetros e magnetômetros (ao contrário de GPS e *Wi-Fi*, que necessitam de fontes externas de sinais) [SCM10]. Embora a eficiência destes métodos ainda não possa ser bem aferida, são técnicas passíveis de serem empregadas como auxílio a outras mais precisas, porém computacionalmente mais caras.

## 2.3 *Wi-Fi*

Redes locais sem fio (“Wireless Local Area Networks”, ou *WLANs*) baseadas no padrão IEEE 802.11<sup>1</sup> ganharam proeminência a partir do início do século XXI, com o aumento da produção e consumo de computadores pessoais portáteis [LDBL07].

O desenvolvimento de padrões para comunicação sem fio fomentou a adoção das tecnologias relacionadas, cujo conjunto é popularmente conhecido como “*Wi-Fi*”. O termo *Wi-Fi* é marca registrada da “Wi-Fi Alliance”<sup>2</sup>, e seu uso comercial, assim como dos logotipos relacionados, está restrito a produtos certificados. No entanto, é comum referir-se genericamente a redes locais sem fio como *Wi-Fi*.

As tecnologias englobadas pelo termo *Wi-Fi* têm origem no padrão original IEEE 802.11 (de 1997, ocasionalmente chamado de “802.11 *legacy*”, ou “legado”). A faixa de transmissão de *WLANs*, assim como outras tecnologias de transmissão de rádio como telefonia celular, é regulamentada pela frequência de transmissão, e o padrão 802.11 opera na banda de 2.4 GHz (que não requer licenciamento), com taxa de transferência de dados de até 2 Mbps.

O padrão IEEE 802.11a (publicado em 1999) tem taxa de transmissão de até 54 Mbps, e opera na banda de 5 GHz. Esta banda, em boa parte do mundo, possui quantidade de canais superior à de 2.4 GHz, e está menos sujeita a interferências [ZSS05]. No entanto, o padrão 802.11a não é interoperável com os padrões 802.11b, 802.11g e 802.11n subsequentes.

Os padrões IEEE 802.11b (publicado em 1999) e IEEE 802.11g (publicado em 2003) são, atualmente, os mais amplamente utilizados em redes locais sem fio. Ambos operam na banda de 2.4 GHz, e alcançam taxas de transmissão de até, respectivamente, 11 Mbps e 54 Mbps. Estes padrões são interoperáveis entre si, o que favoreceu a adoção do padrão IEEE 802.11g em detrimento do IEEE 802.11a, que atinge as mesmas taxas de transmissão [ACVS10].

O padrão IEEE 802.11n opera tanto na banda de 2.4 GHz quanto na de 5 GHz, e pode alcançar taxas de transmissão de até 600 Mbps. O padrão foi publicado somente em 2009, mas, graças à demanda por redes de maior velocidade, diversos fabricantes passaram a lançar, anos antes, equipamentos baseados na especificação ainda não aprovada, denominada “*draft-n*”. Tanto o padrão IEEE 802.11n quanto o *draft-n* são compatíveis com os padrões IEEE 802.11b e IEEE 802.11g.

Para os efeitos desta pesquisa, trataremos indistintamente como “*Wi-Fi*” redes seguindo os padrões IEEE 802.11b, IEEE 802.11g, IEEE 802.11n e IEEE 802.11 *draft-n*, uma vez que as características de propagação de sinais que nos são relevantes são as mesmas.

Os padrões IEEE 802.11 determinam que o valor do sinal seja dado como um

---

<sup>1</sup><http://standards.ieee.org/about/get/802/802.11.html>

<sup>2</sup><http://www.wi-fi.org>

número inteiro entre 0 e 255, sem unidade associada, como uma medida relativa chamada RSSI (“*Received Signal Strength Index*”). Cada fabricante de dispositivos compatíveis pode utilizar sua própria interpretação desta escala. Os sinais são freqüentemente reportados em decibéis (dB), que também é uma unidade relativa. Normalmente, o valor de referência é o miliwatt (e a unidade é, portanto, dBm), mas nem todos os dispositivos adotam esta convenção. Mesmo quando o fazem, não há padronização quanto ao mapeamento entre o índice RSSI e os valores em dBm, o que pode causar incoerências na comparação de sinais obtidos por dispositivos diferentes [HAP02, KM08].

Em ambientes externos desimpedidos, sinais de redes *Wi-Fi* decaem exponencialmente com a distância da antena transmissora [HSS03]. Em ambientes internos, entretanto, o comportamento dos sinais está sujeito a atenuação, reflexões, refrações, efeitos de propagação multi-caminho etc., e é bastante mais complexo e difícil de se parametrizar [HSS03]. Abordagens de modelagem estão atreladas à geometria do espaço e à disposição de paredes e vãos, assim como aos materiais de que são constituídos estes elementos [HAP02].

Ambientes dinâmicos implicam comportamentos ainda mais complexos. O sinal *Wi-Fi* pode ser deformado pelo abrir e fechar de janelas e portas, por reposicionamento de móveis etc. Fontes de energia eletromagnética como micro-ondas e mesmo outras redes sem fio são também causa de interferência de difícil parametrização [MET08].

Variações substanciais dos sinais podem ainda ocorrer pela presença e trânsito de pessoas no ambiente. A interferência de transeuntes em redes *Wi-Fi* é tão relevante que há algoritmos de localização que se baseiam inteiramente nestes efeitos, sem que o usuário precise tomar qualquer atitude ou portar qualquer dispositivo [YMA07].

Além de interferências de elementos estáticos e dinâmicos no ambiente, redes *Wi-Fi* notoriamente apresentam considerável variação temporal, mesmo na ausência aparente de outras fontes de ruído [KGNM06]. A literatura comumente representa esta variação temporal como distribuída de forma aproximadamente regular em torno de uma média, com amplitude típica de  $\pm 5$  dB e picos de  $\pm 10$  dB [HSS03, ZSS05].

Dispositivos diferentes, ainda, podem observar potências diferentes para sinais de uma mesma rede. Mesmo que se levem em consideração os efeitos de distância, variabilidade temporal e interferências diversas, os sinais obtidos por diferentes antenas receptoras podem apresentar variações sistemáticas entre si [YA05]. A composição e qualidade da antena em si afeta a potência percebida do sinal [TCC09]. Além disso, a própria falta de padronização na unidade adotada para medidas de sinais de rede *Wi-Fi* contribui para este efeito [KM08].

Até mesmo a orientação das antenas transmissoras e receptoras influencia na

potência do sinal recebido [KH04, ZSS05, IK07, CLDR09]. Isto é particularmente relevante em aplicações com dispositivos móveis, especialmente portados por um usuário humano, uma vez que a orientação exata do receptor é difícil de prever, e inconveniente de controlar.

# Capítulo 3

## Localização baseada em redes

### *Wi-Fi*

Nesta pesquisa, abordamos o problema de localização de um indivíduo utilizando um dispositivo móvel, a partir da potência de sinais de redes *Wi-Fi*. Chamamos de “dispositivos móveis” computadores pessoais portáteis, de uso comum e disponíveis para o consumidor geral, que possuam antenas receptoras de sinais *Wi-Fi*. Incluem-se nesta definição *notebooks*, *tablets* e *smartphones*. Excluem-se dela robôs e outros veículos autônomos que, embora tecnicamente se enquadrem na descrição de “dispositivos móveis”, se prestam a outro tipo de utilização. Isto não significa que a pesquisa seja incompatível com veículos autônomos, mas somente que eles não são o foco principal do nosso trabalho. O conjunto de um usuário portando um dispositivo móvel é, por vezes, chamado de “unidade móvel”.

Tratamos da situação em que um indivíduo execute um aplicativo em seu dispositivo móvel, a fim de saber sua localização. Ao receber a requisição, o aplicativo efetua uma ou mais capturas dos sinais de rede *Wi-Fi* do ambiente onde se encontra. Em, no máximo, poucos segundos, o aplicativo deve responder ao usuário, identificando sua localização.

O aplicativo pode realizar tarefas adicionais, como indicar o caminho até um determinado destino. Não é, entretanto, objetivo deste trabalho apontar aplicações específicas, embora uma lista delas seja potencialmente extensa. Por exemplo, soluções para localização em dispositivos móveis são essenciais às áreas de realidade aumentada [TP10], auxílio a deficientes visuais [CM09], navegação de sistemas robóticos autônomos [FTBD01] etc. Uma solução baseada em redes *Wi-Fi* pode ser utilizada em museus, escritórios, ou, genericamente, em muitos dos ambientes urbanos que, atualmente, contam com ampla cobertura de redes, públicas e privadas [Kaw09, ACVS10].

Entretanto, optamos por não desenvolver soluções cuja utilização precise ser limitada à robótica. Como discutido na Seção 2.2, muitos dos algoritmos

de localização aplicados à robótica exigem deslocamentos consideráveis até a estimativa de localização convergir para um erro aceitável. Também é freqüente, na robótica, a utilização de sensores especializados, como *lasers*, radares e sonares, que normalmente não estão presentes em dispositivos móveis. Alguns algoritmos também exigem processamento muito intenso, ainda inviável mesmo em dispositivos móveis modernos.

Esta decisão pode implicar menor acurácia das estimativas obtidas. Soluções de localização utilizando redes *Wi-Fi* para aplicação em robótica tipicamente convergem para erros da ordem de 0.5 metro [SSH03, SCMR04]. Soluções aplicadas a usuários portando telefones celulares, porém, geralmente apresentam erros da ordem de alguns metros [YA05, LDBL07, CLDR09], como consequência direta dos objetivos propostos.

Outro objetivo da pesquisa é que a técnica obtida preveja a utilização de combinação arbitrárias de dispositivos diferentes, tanto no treinamento quanto nas classificações. Grande parte das pesquisas de localização com *Wi-Fi* baseia seus testes em uma seleção bastante uniforme de dispositivos. Alguns autores utilizam dispositivos diferentes, mas de mesmas especificações e fabricação (ou seja, unidades diferentes de uma mesma linha de equipamentos), para coletar dados e posteriormente efetuar testes de localização [HSS03, MLTL08]. Mas a maioria utiliza os mesmos dispositivos (uma única unidade) em todo o arranjo experimental [CLDR09, SCMR04, ZSS05, FFL07, SSH03].

Embora esta prática, por si só, não invalide o experimento, ela não permite inferir o comportamento dos algoritmos testados quando confrontados com situações menos homogêneas. O problema é particularmente grave no estudo de redes *Wi-Fi*, que são naturalmente irregulares: é fácil verificar que um mesmo sinal, capturado por antenas receptoras de diferentes fabricantes e em diferentes dispositivos, sofre variação considerável [YA05, TCC09], conforme comprovado por nossa própria coleta de dados (analisada na Seção 4.2).

Desta forma, qualquer solução de localização proposta deve ser submetida à validação por diferentes combinações de dispositivos.

Nossa intenção é estudar localização em situações realistas. Uma solução deve lidar com ambientes internos complexos. Não se deve assumir, *a priori*, a ausência de obstáculos ou uma geometria específica do ambiente.

Além disso, antenas transmissoras de redes *Wi-Fi* estão tipicamente sujeitas a variações fora do controle do projetista de um sistema de localização. Equipamentos transmissores podem ser desativados ou movidos, seu hardware pode ser substituído, antenas de potencialização de sinal podem alterar as medidas entre o treinamento do sistema e sua utilização etc. Esta dinamicidade deve ser levada em consideração e o método de localização deve assumir que a confiabilidade da disposição das redes *Wi-Fi* é variável (ou mais baixa do que em um ambiente controlado, projetado

exclusivamente para os testes).

Ainda sobre dinamicidade do ambiente, gostaríamos de evitar a premissa de que os testes sejam feitos em situações de pouco ou nenhum movimento, adotada em diversas pesquisas com redes *Wi-Fi* [SSH03, CCLK05]. A variabilidade de sinal decorrente de interferências de transeuntes deve ser entendida como parte do problema proposto.

Muitos testes de localização com *Wi-Fi* pressupõem que, durante o mapeamento das redes existentes, seja feita simultaneamente uma estimativa da posição das antenas transmissoras de cada rede [KH04, Kaw09, IK07]. Outros não utilizam redes previamente disponíveis no ambiente, mas posicionam suas próprias antenas transmissoras, em posições conhecidas e arranjos espaciais convenientes [HSS03, MLTL08, SSH03, ZSS05]. Nosso objetivo é utilizar redes pré-existentes, cujos transmissores se encontrem em localizações desconhecidas (e potencialmente inacessíveis fisicamente, como em salas privadas).

Finalmente, assumimos que o ambiente em que se queira obter localização possa ser previamente mapeado, ou percorrido em uma fase de tomada de dados.

Existem algoritmos que não requerem este conhecimento prévio, a exemplo de *SLAM*, discutido na Seção 2.2. Em particular, há soluções de *SLAM* utilizando sinais de redes *Wi-Fi* [FFL07]. Como convém à formulação do *SLAM*, estas redes não precisam ser catalogadas *a priori*, a localização e o mapeamento do ambiente são obtidos a partir das potências dos sinais em cada momento e de um modelo de propagação de redes *Wi-Fi*.

No entanto, soluções para o *SLAM*, tipicamente, exigem processamento intenso, e ainda são de difícil implementação em dispositivos móveis de menor porte, como *smartphones* [DwB06b]. Além disso, pela natureza incremental e recursiva das soluções de *SLAM*, o sensor precisa se deslocar consideravelmente até obter informação confiável de localização [DNC<sup>+</sup>01]. Estas características dificultam a obtenção de uma solução adequada à situação que descrevemos nesta seção, que permita utilização por um usuário humano portando um dispositivo móvel de uso comum.

Soluções do tipo *SLAM* são bastante úteis quando o ambiente é efetivamente desconhecido. Entretanto, quando é possível se obter de antemão um mapeamento, o uso de *SLAM* não se justifica [TP10]. Desta forma, abordamos a situação em que o local de aplicação da solução é previamente conhecido.

### 3.1 Estado atual da área

Diversas soluções vêm sendo apresentadas, nos últimos anos, para o problema da localização utilizando sinais de redes *Wi-Fi*. Dentre elas, muitas aplicam técnicas de reconhecimento de padrões, e tipicamente se adequam às restrições



que impusemos, na definição do problema.

Grande parte dos autores estudados utiliza variações do método de “k vizinhos mais próximos” ( $kNN$ , descrito na Seção 2.1). Implementações diretas do  $kNN$  tipicamente fornecem classificação de localização com erro médio em torno de 2 a 5 metros e precisão de 3 a 10 metros [CLDR09, LWL<sup>+</sup>05, PKC02, LDBL07, LSDR06]. Variações da técnica, como incorporação de pesos ou conglomerados, permitem atingir erros com média em torno de 1.5 m e precisão de 2 a 7 metros [MLTL08, LWL<sup>+</sup>05, ZSS05]. É importante notar, entretanto, que estas variações tendem a aumentar a complexidade de implementação e processamento da solução.

Chen *et al.* [CLL08] utilizam as relações entre os sinais das diversas redes para obterem uma combinação de regras, criadas tanto estática quanto dinamicamente, que definam a localização. O desempenho da técnica não é avaliado em relação à diferença entre coordenadas esperadas e obtidas, mas em relação à classificação correta da sala em que o indivíduo se encontra, o que torna difícil a comparação com outros métodos. No entanto, os autores comparam sua técnica favoravelmente a diversas outras, adaptadas para o mesmo método de avaliação.

São particularmente interessantes as inferências que Chen *et al.* utilizam posteriormente à resposta de localização obtida pelas regras. Quando os dados de *Wi-Fi* não são imediatamente classificados por regra alguma (ou quando há divergência entre regras quanto à classificação), o sistema:

1. elimina posições em que o usuário esteja impossibilitado de se encontrar, dada uma planta do ambiente onde ele se encontre (por exemplo, paredes, vãos etc.);
2. e recorre a classificações de momentos anteriores, assumindo que o usuário esteja constantemente utilizando o sistema de localização, enquanto se desloca.

Li *et al.* [LSDR06] empregam um classificador Bayesiano e o comparam à utilização de  $kNN$ . Em sua abordagem, a solução Bayesiana parametriza a potência do sinal da rede *Wi-Fi* em relação à distância da antena transmissora como uma curva Gaussiana. Os próprios autores admitem que esta parametrização não é perfeita, mas argumentam que é boa o bastante. E, com efeito, o erro médio obtido utilizando o classificador Bayesiano é de 1.46 m (95% dos erros são de até 3.4 m), enquanto o obtido com  $kNN$  é de 2.2 m (95% até 5.1 m).

De encontro ao nosso problema proposto, a solução de Li *et al.* requer que as localizações de todas as antenas transmissoras utilizadas sejam previamente conhecidas. Ainda assim, apresenta resultados encorajadores da aplicação de classificadores Bayesianos à localização por sinais de *Wi-Fi*.

## 3.2 Descrição da solução

Baseando-se na literatura disponível, na análise de soluções apresentadas por estudos correlatos e na realização de testes preliminares, esta pesquisa aborda o problema da localização usando classificadores Bayesianos ingênuos.

Classificadores Bayesianos ingênuos, discutidos na Seção 2.1, constituem uma solução robusta para se obter classificação probabilística a partir de observações. Em particular, classificadores Bayesianos podem ser adaptados para lidar com dados esparsos e ruidosos, o que é particularmente desejável para os objetivos deste trabalho.

Inicialmente, utilizamos os sinais das redes *Wi-Fi* como as “características” com que lida o classificador. Mais especificamente, cada uma das diferentes antenas transmissoras de rede observadas, identificada por seu BSSID (o endereço MAC da interface de rede sem fio), equivale a uma característica distinta. Entretanto, os dados passam por algumas transformações antes de se aplicar o classificador, como será apresentado a seguir, e uma delas altera o significado das características.

Os valores possíveis para cada característica, conseqüentemente, são os valores possíveis de serem obtidos por uma antena receptora de *Wi-Fi*. Estes valores são, tipicamente, números inteiros negativos, na faixa de  $-10$  a  $-100$  [CLDR09]. Estes valores também serão afetados pela supracitada transformação das características.

As classificações possíveis, naturalmente, são as diversas posições em que podemos localizar o indivíduo. Assim como grande parte das soluções de localização [BFHS96, GF98, GBFK98, HSS03, LWL<sup>+</sup>05, PKC02, SCMR04], consideramos que o ambiente pode ser discretizado em uma grade com um número finito de posições.

Em princípio, o classificador não assume qualquer relação entre duas classificações. Ou seja, ele é indiferente ao fato de que as classificações representam posições. No entanto, apresentaremos um método de combinação de classificações para tirar proveito desta informação.

É importante notar que a regra ingênua de Bayes pressupõe que as características utilizadas na classificação são condicionalmente independentes entre si. No nosso problema, isto não necessariamente se observa. Em primeiro lugar, nossas “características” são as redes *Wi-Fi*, cujos sinais podem sofrer interferência uns dos outros [MET08]. Além disso, como utilizamos redes previamente existentes no ambiente, fora do controle do experimento, elas podem ter relações de dependência desconhecidas.

Assumimos, no entanto, que a pressuposição de independência condicional é boa o bastante para efeitos da nossa pesquisa, e que as vantagens da simplicidade desta suposição superam as de uma modelagem de dependências. Dadas as características no problema, uma modelagem pode até mesmo não ser atingível. Apoiamo-nos no fato de que, de forma geral, a premissa de independência apresenta

bons resultados práticos [DHS01].

Nossa solução é aplicada em quatro fases: tratamento de dados, treinamento, classificação e pós-processamento dos resultados.

### 3.3 Tratamento de dados

Antes de serem submetidos ao classificador, os dados de entrada sofrem algumas transformações:

1. Filtro da média.

Sinais de redes *Wi-Fi* tipicamente apresentam alta variabilidade, mesmo quando obtidos a partir de uma única posição (vide o experimento descrito na Seção 4.2). No entanto, os dados individuais tendem a se espalhar de forma aproximadamente regular em torno de uma média. Algumas pesquisas lidam com este problema realizando diversas medições em uma mesma posição, e utilizando a média das aquisições no lugar de cada valor individual [HSS03, ZSS05, YA05, CLDR09]. No entanto, isto acarreta processos de capturas de dados significativamente mais longos (em nossas aquisições, cada captura de sinais levou aproximadamente 5 segundos, independentemente do dispositivo utilizado).

Propomos, alternativamente, que cada valor de potência de rede seja substituído pela média dos valores adquiridos nas posições mais próximas, para a mesma rede (incluindo o valor original). A fim de manter as características da distribuição do sinal no ambiente, a média de um sinal em uma posição  $p_k$  utiliza os sinais de posições distribuídas igualmente em torno de  $p_k$ . Ou seja, assumindo  $N$  posições ao longo de uma única dimensão, o sinal  $s_k$  na posição  $p_k$  será substituído por

$$\frac{s_{k-\frac{N-1}{2}} + s_{k-\frac{N-1}{2}+1} + \dots + s_{k-1} + s_k + s_{k+1} + \dots + s_{k+\frac{N-1}{2}-1} + s_{k+\frac{N-1}{2}}}{N}$$

Mais genericamente, se houver captura de sinais em  $d$  sentidos ao redor de  $p_k$ , a média é feita entre sinais nas  $\frac{N-1}{d}$  posições mais próxima a  $p_k$ . Nas situações limite em que não haja  $\frac{N-1}{d}$  posições em algum dos sentidos, ou se não houver sinal da rede em questão em alguma das posições, a média é feita com sinais de quantas posições houver, ignorando-se os ausentes.

O filtro da média pode ser aplicado a todo o conjunto de dados de treinamento. No entanto, em uma situação de uso real do classificador, o exemplo a ser classificado normalmente não vem acompanhado de dados

relativos a posições próximas. O filtro, portanto, não pode ser indiscriminadamente aplicado ao conjunto de dados de testes. A média somente pode ser aplicada aos dados de testes caso se deseje uma implementação da solução de localização que preveja o deslocamento de alguns passos do usuário. Neste caso, o filtro da média pode ser aplicado a um número de posições igual ao de passos, que tipicamente deve ser pequeno.

O número de posições utilizadas na média dos dados de treinamento deve ser definido experimentalmente, e é discutido na Seção 4.3.

## 2. Sinais relativos.

A variação do sinal de redes *Wi-Fi* observado por dispositivos distintos foi discutida na Seção 2.3. Este efeito geralmente decorre de diferenças entre antenas e da falta de padronização da unidade utilizada na medida dos sinais [TCC09]. A variação, no entanto, é tipicamente sistemática, entre dois dispositivos quaisquer. Ou seja, os mesmos sinais obtidos por dispositivos diferentes descrevem um comportamento semelhante, mas com uma diferença de magnitude.

Esta situação é ilustrada na Figura 3.1, que compara os sinais de uma mesma rede, obtidos por dois dispositivos diferentes (um *notebook* e um *smartphone*). A ambos os conjuntos de sinais foi previamente aplicado o filtro da média (com  $N = 13$ ), com o objetivo de se atenuarem outros efeitos de variabilidade. Assim, fica mais evidente a relação entre os sinais capturados pelos dois dispositivos.

O gráfico mostra claramente a diferença entre os sinais observados pelos dispositivos. No entanto, as relações de potência entre as redes, em cada ponto, tendem a se manter [CLL08]. Isto significa que, em tese, se um dispositivo observa que o sinal da rede A é 1.5 vezes maior que o sinal da rede B, em uma certa localização, então espera-se que quaisquer outros dispositivos enxerguem a mesma relação de 1.5 vezes entre os sinais das redes A e B, naquele local, ainda que dispositivos diferentes observem valores absolutos diferentes para os sinais. A Figura 3.2 mostra os sinais de três redes, já submetidos ao filtro da média, obtidos por dois dispositivos diferentes. Os formatos das curvas e as relações de potências entre elas são semelhantes, apesar de os sinais no gráfico 3.2a serem em torno de 15 dB mais fortes que os do gráfico 3.2b.

Esta constatação levou à proposição de uma normalização dos dados, para que se avaliem não mais os sinais absolutos das redes em cada posição, mas as relações entre eles. Isto facilita a aplicabilidade da solução proposta a dispositivos arbitrários, em ambientes heterogêneos, o que é um dos objetivos que esta pesquisa busca alcançar.




Figura 3.1: Comparação dos sinais de uma mesma rede, aplicado o filtro da média com  $N = 13$ , obtidos por um *notebook* e um *smartphone*.

Realizamos, então, uma transformação dos dados, de modo que cada “característica” observada pelo classificador passe a ser um par ordenado de redes, e os valores correspondentes sejam a proporção que o valor do sinal de uma representa em relação ao valor do sinal da outra. Por exemplo, se os valores obtidos para os sinais de duas redes A e B em um determinado ponto são, respectivamente,  $s_A$  e  $s_B$ , então, após a transformação, a nova característica será  $(A, B)$  e o novo valor,  $\frac{s_A}{s_B}$ .

A Tabela 3.1 ilustra esta transformação. Para manter a clareza, utilizamos nomes fictícios para as redes, ao invés de utilizar o formato de um BSSID. Quando há somente uma rede com sinal visível em uma determinada posição (como na posição  $p_3$ ), a posição equivalente nos dados transformados não apresenta valor algum.




Figura 3.2: Comparação do comportamento relativo entre redes, observadas a partir de dois dispositivos diferentes. Às redes foi aplicado o filtro da média, com  $N = 13$ .

Posição	$p_1$	$p_2$	$p_3$	$p_4$	$p_5$
Sinais originais (dB)					
bssid1	-70	-90			
bssid2	-80		-85	-85	-85
bssid3	-80	-55	-85		-50
bssid4	-80	-80			-60
Sinais modificados (valores relativos)					
(bssid1, bssid2)	0.875				
(bssid1, bssid3)	0.875	1.640			
(bssid1, bssid4)	0.875	1.125			
(bssid2, bssid3)	1.000		1.000		1.700
(bssid2, bssid4)	1.000				1.420
(bssid3, bssid4)	1.000	0.688			0.830

Tabela 3.1: Exemplo de sinais relativos.

É importante notar que a escolha do critério de ordenação entre as redes é irrelevante, desde ele seja coerente em todo o processo (tanto de treinamento, quanto de classificações subseqüentes). Como as características originais são os BSSIDs de cada rede (ou seja, cadeias únicas de caracteres contendo letras, números e o sinal de dois-pontos), escolhemos simplesmente a ordenação lexicográfica crescente entre eles.

Estes tratamentos são aplicados a todos os dados antes de sua utilização no classificador, tanto para treinamento quanto para classificações.

### 3.4 Treinamento

O classificador passa por aprendizado supervisionado, em que recebe uma série de amostras já classificadas. Um exemplo submetido para treinamento é composto de pares  $(bssid^j: s^j)$ , em que cada  $bssid^j$  representa uma rede observada e  $s^j$  é o valor do sinal obtido para aquela rede, um número inteiro (tipicamente negativo). Ao exemplo é associada a posição  $p_k$  a que se referem estes valores. A posição é dada em duas dimensões, por um par de números reais  $(x_k, y_k)$ . Portanto, se há  $n$  exemplos de treinamento, em que são observados  $b$  *bssids*, o conjunto de treinamento tem a forma da Tabela 3.2.

$bssid^1$	$bssid^2$	...	$bssid^b$	posição
$s_1^1$	$s_1^2$	...	$s_1^b$	$(x_1, y_1)$
$s_2^1$	$s_2^2$	...	$s_2^b$	$(x_2, y_2)$
		⋮		
$s_n^1$	$s_n^2$	...	$s_n^b$	$(x_n, y_n)$

Tabela 3.2: Formato do conjunto de dados para treinamento do classificador.

A partir do conjunto de treinamento, são obtidas as probabilidades condicionais  $P(s^j|p_k)$ . Ou seja, a cada valor de sinal  $s^j$  de uma rede  $bssid^j$  é associada uma probabilidade condicional dada cada possível posição  $p_k$ .

As probabilidades condicionais são estimadas pela frequência relativa de cada valor nos dados de treinamento. Assim, por exemplo, se o classificador é treinado com os dados

$bssid^1$	$bssid^2$	posição
$s1$	$s2$	$p_1$
$s1$	$s3$	$p_2$

então as probabilidades condicionais obtidas serão

$$P(s1^1|p_1) = P(s1^1|p_2) = 0.5$$

$$P(s2^2|p_1) = 1$$

$$P(s3^2|p_2) = 1$$

É importante notar que estas probabilidades condicionais são inferidas diretamente do conjunto de dados, sem interpolações. Isto significa que somente são calculadas probabilidades relativas a posições que constem do conjunto de dados de treinamento. Estas posições, portanto, definem o conjunto de todas as posições possíveis, para o classificador. Ou seja, um exemplo de teste obtido em uma posição fora deste conjunto nunca poderá ser localizado com erro zero. O Capítulo 5 comenta possíveis soluções para esta restrição.

### 3.5 Classificação

Uma vez treinado o classificador, podem-se submeter exemplos para classificação. Um exemplo  $E$  consiste de pares  $(bssid^j : s^j)$  para todas as redes observadas. Ou seja, tem a forma

$$\begin{aligned} E &= \{bssid^1 : s^1, bssid^2 : s^2, \dots, bssid^b : s^b\} \\ &= \{bssid^j : s^j \mid 1 \leq j \leq b\} \end{aligned}$$

Ao classificador cabe determinar a posição com maior probabilidade *a posteriori*, dado este exemplo. A probabilidade *a posteriori* de uma posição  $p_k$ , dado o exemplo  $E$ , é dada por

$$P(p_k|E) = \frac{P(p_k) \times P(E|p_k)}{P(E)} \quad (3.1)$$

O termo  $P(E)$  só depende do exemplo e é igual para todas as probabilidades *a posteriori*. Portanto, é irrelevante à busca pela maior delas. A classificação do exemplo  $E$  é dada, então, por

$$\begin{aligned} C(E) &= \operatorname{argmax}_{p_k} (P(p_k|E)) \\ &= \operatorname{argmax}_{p_k} (P(p_k) \times P(E|p_k)) \end{aligned} \quad (3.2)$$

Como assumimos que o sistema não tem informações prévias sobre a localização, as probabilidades *a priori*  $P(p_k)$  de todas as localizações possíveis são consideradas iguais entre si. Com isto, e expandindo o termo de verossimilhança  $P(E|p_k)$  de acordo com a regra ingênua de Bayes apresentada na Seção 2.1, a classificação do exemplo  $E$  se reduz a

$$C(E) = \operatorname{argmax}_{p_k} \left( \prod_{j=1}^b P(s^j|p_k) \right) \quad (3.3)$$



Lembrando que as probabilidades condicionais  $P(s^j|p_k)$  foram estimadas na fase de treinamento, o classificador pode então determinar a localização mais provável a que se refere o exemplo  $E$ . Se o exemplo não contiver sinais relativos a alguma das redes  $bssid^j$ , o classificador considera suas probabilidades condicionais equiprováveis entre todas as posições, e realiza a classificação a partir dos sinais presentes [DHS01].

### 3.6 Pós-processamento

A solução proposta conta ainda com uma fase de pós-processamento, aplicado sobre o resultado da classificação descrita na Seção 3.5.

O classificador Bayesiano considera as possíveis posições como “classes” independentes, sem relação entre si. O objetivo deste pós-processamento é atribuir relação de proximidade a classificações realizadas em momentos consecutivos. Conceitualmente, se o sistema classifica o usuário como estando em uma determinada posição, gostaríamos que, quando o usuário se deslocar por um metro, o sistema o classificasse, coerentemente, como estando um metro à frente.

Mais genericamente, assumamos que, em um instante  $t_1$  e dado um exemplo  $E_1$ , o classificador localize o usuário na posição  $p_1$ . Imaginemos agora que, no instante seguinte  $t_2$ , o usuário se deslocou  $\Delta p$ . Se o classificador estava correto na classificação em  $t_1$ , a hipótese é que, em  $t_2$ , o classificador deveria classificar um exemplo  $E_2$  como correspondente à posição  $p_1 + \Delta p$ .

É importante lembrar que, do classificador, obtemos os valores das verossimilhanças para todas as posições. Da verossimilhança, pode-se facilmente obter a probabilidade *a posteriori* para cada posição, lembrando-se que consideramos as probabilidades *a priori* iguais para todas as posições, e que o termo da evidência é utilizado para que todas as probabilidades *a posteriori* somem um.

O pós-processamento consiste em se combinarem as probabilidades *a posteriori* obtidas em  $t_1$  e  $t_2$ . Assumindo independência condicional entre elas, a “probabilidade combinada”  $P^c$  de que, no instante  $t_1$ , o usuário estivesse na posição  $p_1$  é dada por

$$P^c(p_1, t_1|E_1, E_2) = P(p_1, t_1|E_1) \times P(p_1 + \Delta p, t_2|E_2) \quad (3.4)$$

Naturalmente, o classificador calcula as probabilidades de todas as posições possíveis, para um dado exemplo  $E$ . A Equação 3.4 pode então ser generalizada, para definir a probabilidade combinada de uma posição arbitrária  $p_k$ , dados dois exemplos  $E_1$  e  $E_2$ , como

$$P^c(p_k, t_1|E_1, E_2) = P(p_k, t_1|E_1) \times P(p_k + \Delta p, t_2|E_2) \quad (3.5)$$

Em um deslocamento arbitrário, em que o usuário percorra  $n$  posições (a original, mais  $n - 1$  passos de tamanho  $\Delta p$ ), pode-se extrapolar a Equação 3.5 para

$$\begin{aligned}
 P^c(p_k, t_1 | E_1, E_2, \dots, E_n) = & P(p_k, t_1 | E_1) \times \\
 & P(p_k + \Delta p, t_2 | E_2) \times \\
 & P(p_k + 2\Delta p, t_3 | E_3) \times \dots \times \\
 & P(p_k + (n - 1)\Delta p, t_n | E_n)
 \end{aligned} \tag{3.6}$$

Com isso, podemos definir a localização em  $t_1$ , obtida pela combinação de probabilidades após  $n$  posições, como

$$\begin{aligned}
 C(\mathbf{E}) = \operatorname{argmax}_{p_k} (P^c(p_k, t_1 | \mathbf{E})) \quad \text{em que} \\
 \mathbf{E} = \{E_1, E_2, \dots, E_n\}
 \end{aligned} \tag{3.7}$$

Este pós-processamento das classificações implica um modelo implícito de deslocamento, em que o usuário tem velocidade  $\frac{\Delta p}{t_{i+1} - t_i}$ . Implica, inclusive, que o usuário deverá se deslocar, o que, em princípio, tentávamos evitar, na descrição do problema (Capítulo 3).

O tamanho do deslocamento necessário para que esta combinação de probabilidades atinja bons resultados, e se este deslocamento se justifica, devem ser determinados experimentalmente, e são discutidos na Seção 4.3.

# Capítulo 4

## Experimentos

### 4.1 Aquisição de dados

Para treinamento, calibração e testes dos métodos de localização, foram realizadas aquisições de dados no bloco A do Instituto de Matemática e Estatística da Universidade de São Paulo (IME/USP). Os dados utilizados nos testes de localização foram coletados em duas ocasiões distintas: Janeiro de 2010 e Fevereiro de 2011.

#### Janeiro de 2010

Esta foi a aquisição inicial, a partir da qual se desenvolveu a fase preliminar do trabalho aqui apresentado. Além de sinais de redes *Wi-Fi*, foram obtidas também imagens nas imediações do equipamento. Utilizou-se um *notebook* Apple Macbook Pro 13", rodando o sistema operacional Mac OS X 10.5. As capturas de sinais *Wi-Fi* foram efetuadas com o comando `airport`.

A Figura 4.1 mostra um visão esquemática do processo de aquisição, descrito a seguir.

Foi utilizado um *notebook* posicionado à altura de aproximadamente 1.6 m sobre um apoio móvel, que foi deslocado em linha reta por toda a extensão de um dos corredores do prédio. Ao *notebook* estavam conectadas duas câmeras, além de uma embutida. Uma das câmeras apontava para o sentido da movimentação do *notebook* (a “frente”), enquanto as outras duas foram posicionadas ortogonalmente à primeira, apontando cada uma para uma lateral. Uma destas, adicionalmente, foi posicionada inclinada para cima em relação ao solo, para simular a situação em que o usuário captura imagens sem que seu equipamento móvel esteja nivelado horizontalmente.

Em cada passo da aquisição, o apoio era deslocado de uma distância fixa (0.6 m) para a frente, estacionado, e cada câmera registrava uma imagem. Em seguida,




Figura 4.1: Diagrama esquemático do método de aquisição de dados em 2010.

era capturada a intensidade dos sinais das redes *Wi-Fi* disponíveis naquele local. Finalmente, o apoio era deslocado novamente, e o procedimento se repetia.

As medidas, portanto, foram feitas com o *notebook* sempre em repouso. Esta decisão foi tomada para evitar distorções na propagação do sinal das redes *Wi-Fi* e, conseqüentemente, facilitar seu uso para a estimação de localização [KH04].

Ao final do procedimento, o sistema percorreu o mesmo trajeto em sentido contrário, ou seja, com a câmera frontal apontada para o sentido inverso. As câmeras laterais foram desativadas e não houve captura de sinal de *Wi-Fi*. As aquisições foram realizadas nos mesmos pontos em que foram as do trajeto inicial. Esta fase foi executada unicamente para que a base de dados simulasse uma captura com quatro câmeras.

Nesta ocasião, a aquisição foi feita somente em linha reta (deslocamento em uma dimensão), ao longo de um único corredor.

Seguindo este procedimento, foram adquiridas imagens e sinais de redes *Wi-Fi* equivalentes a 134 posições (para cada uma, 4 imagens e o conjunto das redes *Wi-Fi* visíveis e suas respectivas potências naquele ponto). As Figuras 4.2a, 4.2b, 4.2c

e 4.2d mostram um exemplo de seqüência de imagens consecutivas adquiridas pelas quatro câmeras (já incluindo a captura correspondente no trajeto de volta).

As respectivas intensidades de sinais *Wi-Fi* nos instantes da aquisição de cada grupo de imagens 4.2a, 4.2b, 4.2c e 4.2d são apresentadas na Tabela 4.1. Cada rede é representada por seu BSSID (identificado, por questão de espaço, apenas pelo último par de dígitos hexadecimais). É apresentado também o SSID (o nome público) de cada uma.

SSID:	Rede	Rede	Rede	Rede	labmap	USP	USP	USP	vision
BSSID:	IME	IME	IME	IME		net	net	net	wl3
	...:15	...:3b	...:ff	...:fd	...:89	...:68	...:50	...:d8	...:1f
$t = 1$	-85	-58	-64	-88	-46	-49	-81	-77	-53
$t = 2$		-54	-64	-88	-40	-51	-82	-76	-51
$t = 3$		-51	-66	-88	-40	-57	-84	-75	-53
$t = 4$		-54	-67		-47	-56	-78	-77	-55

Tabela 4.1: Intensidades de redes *Wi-Fi*, correspondentes aos locais onde se adquiriram as imagens da Figura 4.2.

Nesta aquisição de dados, foram observadas 15 redes distintas. Destas, 10 foram observadas em pelo menos 50% das capturas.

Os sinais *Wi-Fi* adquiridos estão disponíveis em <http://vision.ime.usp.br/~rbp/datasets/wifi>.

O banco de dados de imagens foi utilizado em um trabalho relacionado. Nele, Morimitsu *et al.* desenvolvem um algoritmo de detecção de placas a partir de imagens de telefones celulares [MHP<sup>+</sup>11]. Os autores sugerem uma extensão da pesquisa para obtenção de localização a partir das imagens, utilizando classificação dos sinais de redes *Wi-Fi* associados para validar os resultados obtidos.

As imagens foram também utilizadas no protótipo descrito na Seção 4.3.

As imagens adquiridas, com os sinais *Wi-Fi* correspondentes codificados no formato EXIF [CIP11], no campo Photo.UserComment, estão disponíveis, sem qualquer tratamento posterior, em

<http://www.vision.ime.usp.br/VisionDataset/AlbumDetail?albumId=36>.

## Fevereiro de 2011

Nesta ocasião, foram adquiridos somente dados de *Wi-Fi*, não houve captura de imagens. Foi utilizado o mesmo apoio que na captura anterior, e os dados foram adquiridos seguindo o mesmo intervalo de 0.6 m. Porém, as posições das aquisições foram deslocadas em 0.3 m, em relação à captura de 2010. Ou seja, se as aquisições de 2010 foram realizadas em  $x_1$ ,  $x_1 + 0.6$  m,  $x_1 + 1.2$  m etc (lembrando que, em




(a)  $t = 1$ (b)  $t = 2$ (c)  $t = 3$ (d)  $t = 4$ 

Figura 4.2: Exemplos de imagens adquiridas em quatro instantes consecutivos. Para cada instante, aparecem aqui as três imagens adquiridas no trajeto inicial, e a quarta imagem adquirida no trajeto de volta.

2010, o deslocamento foi só em uma direção), as de 2011 foram realizadas em  $x_1 + 0.3$  m,  $x_1 + 0.9$  m,  $x_1 + 1.5$  m etc.

A captura de 2011, no entanto, foi realizada em todo o andar, e não apenas em um corredor. Ou seja, as posições relativas às aquisições passaram a ser tratadas em duas dimensões (x, y), e convencionou-se que o corredor em que ocorreu a captura de 2010 corresponderia às posições de coordenada  $y = 0$ .

Foram utilizados quatro dispositivos diferentes, simultaneamente:

**Mac** - *notebook* Apple Macbook Pro 15", rodando o sistema operacional Mac OS X 10.6. As capturas de sinais *Wi-Fi* foram efetuadas com o comando `airport`.

**Ubuntu** - *notebook* HP Pavilion dv2670br, rodando o sistema operacional Ubuntu Linux 9.10. As capturas de sinais *Wi-Fi* foram efetuadas com o comando `iwlist`.

**Android** - *smartphone* HTC G1/Dream, rodando o sistema operacional Android 2.2 (via CyanogenMOD 6.1.0). As capturas de sinais *Wi-Fi* foram efetuadas por um script Python rodando sobre a plataforma Scripting Layer for Android<sup>1</sup>, utilizando diretamente as APIs do sistema Android.

**N900** - *smartphone* Nokia N900, rodando o sistema operacional Maemo 5. As capturas de sinais *Wi-Fi* foram efetuadas com o comando `iwlist`. No entanto, ainda no primeiro corredor, após a posição (58.2, 0.0), o sistema operacional desabilitou a interface de rede sem fio, e a captura com este dispositivo não abrangeu todo o percurso.

Assim como na captura de 2010, as aquisições foram feitas com o sistema em repouso. Como não houve aquisição de imagens, não houve necessidade de percorrer o trajeto em sentido contrário, como na ocasião anterior. A Figura 4.3 mostra um visão esquemática deste processo de aquisição.

Nesta captura, foram adquiridos sinais de redes *Wi-Fi* correspondentes a 346 posições para cada dispositivo utilizado (exceto para o *N900*, que, conforme descrito, somente adquiriu sinais correspondentes a 98 posições). Foram observadas 21 redes distintas. 9 delas não haviam sido observadas na aquisição de 2010. Este número não é surpreendente por si só, dado que o trajeto percorrido naquela ocasião foi bem menor. Entretanto, considerando somente o trajeto percorrido na aquisição de 2010, foram observadas 3 redes em 2011 que não o haviam sido em 2010. 3 redes também haviam sido observadas em 2010 e não foram em 2011. Das 21 redes observadas, 7 constam de pelo menos 50% das aquisições.

A Tabela 4.2 mostra um exemplo de intensidades de sinais *Wi-Fi*, para cada dispositivo, em um mesmo instante de captura.

<sup>1</sup><http://code.google.com/p/android-scripting/>




Figura 4.3: Diagrama esquemático do método de aquisição de dados em 2011.

SSID:	Rede	Rede	Rede	Rede	labmap	USP	USP	USP	vision	vision
	IME	IME	IME	IME		net	net	net	wl1	wl3
BSSID:	...:15	...:3b	...:ff	...:fd	...:72	...:68	...:50	...:d8	...:68	...:1f
Mac	-72	-49	-63	-84	-27	-48	-76	-69		-59
Ubuntu	-75	-46	-68		-29	-51	-83	-66	-90	-49
Android		-65			-49	-63		-78		-68
N900		-89			-90	-88	-93	-90		-91

Tabela 4.2: Intensidades de redes *Wi-Fi* na posição (8.4,0.0), nos vários dispositivos de aquisição.

Os sinais *Wi-Fi* adquiridos estão disponíveis em <http://vision.ime.usp.br/~rbp/datasets/wifi>.

Tanto os sinais obtidos em 2010 quanto os obtidos em 2011 foram armazenados em uma estrutura de dados adequada aos testes realizados nesta pesquisa. As principais formas de utilização destes dados foram iteração por todas as capturas e acesso aos sinais capturados em uma posição específica.

Assim, as capturas realizadas por um mesmo dispositivo foram armazenadas



em uma tabela (“*hash table*”), em que cada chave representa uma posição visitada, e o valor correspondente é uma segunda tabela, associando o BSSID de cada rede ao sinal obtido dela naquela posição. No caso de haver mais de uma captura na mesma posição, as tabelas de sinais poderiam, por exemplo, ser armazenadas em uma lista. No entanto, esta situação não ocorreu nas nossas aquisições de dados.

À tabela de posições foi associada uma lista ligada de referências a cada chave, na ordem em que foram realizadas as capturas. Isto facilitou a iteração por todas as capturas, em uma ordem coerente: a mesma em que o ambiente foi percorrido no momento da aquisição.

Finalmente, foi criada uma tabela associando os BSSIDs das redes observadas a seus SSIDs. Os BSSIDs poderiam ser obtidos a partir da tabela de posições, porém a utilização desta informação se mostrou freqüente, justificando a tabela adicional. Além disso, este arranjo permitiu armazenar os nomes públicos das redes sem redundância.

Uma estrutura de dados neste formato foi criada para cada dispositivo utilizado nas aquisições de dados.

### **Captura por 50 horas em uma única posição**

Além das duas tomadas de dados ao longo de um percurso, foi realizada uma terceira coleta, a partir de uma posição fixa, com o propósito de se analisar a variação de redes *Wi-Fi* ao longo do tempo.

Esta aquisição utilizou o dispositivo *Mac*, e durou aproximadamente 50 horas (50 horas, 22 minutos e 30 segundos). Ao longo deste período, era realizada uma rodada de 10 capturas consecutivas de sinais de redes *Wi-Fi*, sem intervalos, e em seguida uma pausa de 30 segundos. Após a pausa, iniciava-se uma nova rodada de capturas. A aquisição de dados foi realizada seguindo este procedimento, ininterruptamente, por todo o período.

O dispositivo permaneceu posicionado sobre uma mesa, em uma sala ao longo do corredor onde foi realizada a aquisição de dados de 2010. O experimento foi realizado durante dias com movimentação normal. Durante o dia, houve trânsito limitado na sala (do professor que a ocupa, e eventualmente de alunos), e regular nos corredores. Durante a noite, praticamente não se observou trânsito nas imediações da sala em questão. O experimento foi iniciado em uma quarta-feira, às 15:31h, e interrompido na sexta-feira seguinte, às 17:54.

Ao longo desta aquisição de dados, foram realizadas 2.790 rodadas de capturas, todas com 10 capturas consecutivas. No total, portanto, foram realizadas 27.900 aquisições de dados.

Os sinais *Wi-Fi* adquiridos estão disponíveis em <http://vision.ime.usp.br/~rbp/datasets/wifi>.

## 4.2 Análise dos dados coletados

Conforme discutido na Seção 2.3, sinais de rádio em ambientes fechados apresentam comportamento complexo, fortemente dependente do posicionamento dos transmissores, da geometria do local e até mesmo dos materiais utilizados em sua construção.

Desta forma, é importante entender o comportamento real das redes *Wi-Fi* utilizadas como base para este trabalho, e o quanto ele se desvia da previsão teórica.

Esta pesquisa se propõe a utilizar redes *Wi-Fi* de uso comum, presentes no ambiente, e não especificamente configuradas para a finalidade de localização. Isto significa que encontramos toda qualidade de sinal, desde aqueles mais próximos à curva exponencial esperada, até distribuições disformes e extremamente ruidosas. A Figura 4.4 mostra sinais de algumas destas redes, para efeito de comparação. Todos os sinais foram obtidos com o dispositivo *Mac*.

As redes “Rede IME” de BSSID com finais :ff e :3f (círculos vermelhos e pretos, respectivamente, no gráfico) têm formato aproximadamente exponencial (ainda que só capturemos uma parte da segunda). É possível identificar a forma exponencial nas redes “Rede IME” de BSSID com final :3d e “USPnet” (círculos verdes e quadrados azuis, respectivamente), mas elas são claramente mais irregulares. As redes “Rede IME” de BSSID com final :15 e “localnet44” (triângulos amarelos e roxos, respectivamente) são pouco mais que ruído disforme.

É interessante observar que, mesmo em redes com comportamento mais próximo do teórico, os sinais individuais são razoavelmente espalhados. Por outro lado, como esta variação de sinal tipicamente se distribui aproximadamente uniforme em torno de um valor médio [CLDR09], espera-se que, em redes bem comportadas, uma interpolação sobre estes valores se aproxime da curva teórica esperada.

De forma geral, no entanto, as redes freqüentemente não apresentam comportamento regular, conforme já exemplificado na Figura 4.4. Um modo de visualizar esta irregularidade é observar a distribuição de intensidades dos sinais das redes *Wi-Fi*. A Figura 4.5 representa a intensidade de cada uma das redes, ao longo de parte do percurso da aquisição, utilizando-se o dispositivo *Mac*. Cada linha corresponde a uma rede (identificada pelos últimos dois dígitos do BSSID do equipamento transmissor). Os valores estão normalizados para que a maior intensidade observada no conjunto total de todas as redes, neste percurso, corresponda à tonalidade mais forte de cor (completamente opaca). Analogamente, a menor intensidade de sinal observada corresponde à cor mais clara.

Podemos observar que a intensidade do sinal de cada rede decai, como se poderia esperar, conforme nos afastamos de seu ponto de maior potência [KH04, HSS03]. No entanto, nota-se que há bastantes irregularidades e flutuações na distribuição do sinal. Este comportamento ilustra a variabilidade dos sinais.




Figura 4.4: Comparação de qualidade de sinais de diferentes redes. Sinais obtidos com o dispositivo *Mac*.




Figura 4.5: Distribuição de intensidades das redes *Wi-Fi* observadas.

E, apesar de nesta pesquisa tratarmos deslocamento sobre um plano, sem nos preocuparmos com variações de altura, todas estas influências ocorrem em três dimensões, o que torna a previsão do comportamento dos sinais ainda mais difícil.

É também importante observar a diferença entre os sinais capturados pelos diferentes dispositivos. A Figura 4.6 compara os sinais de uma mesma rede capturados pelos vários dispositivos ao longo do trajeto percorrido, incluindo a captura original de 2010.

O gráfico mostra como os sinais dos dispositivos *Ubuntu*, *Mac*, *Android* e os capturados em 2010 são razoavelmente correspondentes. Na Figura 4.6, entretanto, é possível notar uma tendência dos sinais capturados pelo dispositivo *Android* a serem relativamente mais fracos, embora sigam contorno semelhante aos sinais adquiridos pelos outros dispositivos. Esta tendência é reforçada ao se analisarem os sinais de outras redes, como exemplificado na Figura 4.7.

Outra tendência a ser levada em conta, e observável nos dois gráficos, é a dos dados obtidos pelo dispositivo *Ubuntu* serem mais espalhados, e apresentarem mais número de prováveis “*outliers*”.

Mais evidente é a disparidade entre os dados adquiridos pelo dispositivo *N900*, em relação aos outros. Os sinais capturados com este equipamento, de forma




Figura 4.6: Comparação dos sinais de uma mesma rede (00:05:9e:87:f3:ff) capturados pelos vários dispositivos.




Figura 4.7: Comparação dos sinais de uma mesma rede (00:1c:f0:58:35:1f) demonstrando mais claramente a potência relativa dos sinais do *Android*.

geral, são extremamente fracos e irregulares, a ponto de perderem a caracterização mesmo para redes cujos sinais são bem comportados (a julgar pelos dados das mesmas redes obtidos pelos outros dispositivos).

A Figura 4.8 mostra os sinais das mesmas redes apresentadas na Figura 4.4,

obtidos pelo *N900*. Conforme explicado na Seção 4.1, as capturas com o *N900* foram interrompidas na posição (58.2, 0.0). Mesmo assim, o gráfico se estende até a posição (90.0, 0.0), para permitir uma comparação mais direta com a Figura 4.4. A interrupção da captura implica que a rede “localnet44”, presente na Figura 4.4, não esteja presente na Figura 4.8, pois se encontrava fora do alcance nas posições abrangidas pelo *N900*.




Figura 4.8: Comparação de qualidade de sinais de diferentes redes. Sinais obtidos com o dispositivo *N900*.

Uma análise mais cuidadosa dos dados adquiridos com o *N900* reafirma a suspeita de problemas. Em primeiro lugar, há valores de sinais claramente inválidos: dos 741 sinais obtidos, 4 deles estão entre  $-180$  dB e  $-190$  dB, e 8 estão entre  $+35$  dB e  $+50$  dB. Estes valores não são, a rigor, inválidos, uma vez que o valor absoluto em que sinais de rede *Wi-Fi* são medidos é arbitrário, e o valor de referência pode variar com o fabricante do equipamento (ver Seção 2.3). No entanto, estes valores são, na prática, extremamente incomuns [CLDR09]. Dentro do próprio conjunto de dados do *N900*, eles também se sobressaem: excluindo estes 12 valores, o sinal mais fraco tem valor  $-104$  dB, e o mais forte,  $-54$  dB.

Excluindo-se estes valores como flagrantemente incorretos, restam 729 sinais observados, cuja média é  $-91$  dB, e cuja mediana é  $-92$  dB. Destes, 94% estão entre  $-80$  dB e  $-100$  dB. Ou seja, não só as potências registradas são baixas, como possuem pequena amplitude. Em situações típicas, a variabilidade temporal dos sinais oscila aproximadamente 10 dB [HSS03], e uma amplitude de 20 dB em 94% dos dados indica forte descaracterização das redes.

Como comparação, os dados obtidos com o dispositivo *Android* possuem média  $-75$  dB, mediana  $-77$  dB, e somente 37% dos sinais estão abaixo de  $-80$  dB. 94% dos sinais estão abaixo de  $-45$  dB, e este subconjunto exibe amplitude de 51 dB.

Isto não significa que tenhamos descartado ou ignorado completamente os dados obtidos com o *N900*. Entretanto, a má qualidade dos sinais, aliada ao problema da interrupção da captura, desestimulou uma nova rodada de aquisição de dados com o dispositivo e limitou sua aplicabilidade a esta pesquisa.

### 4.2.1 Variabilidade temporal

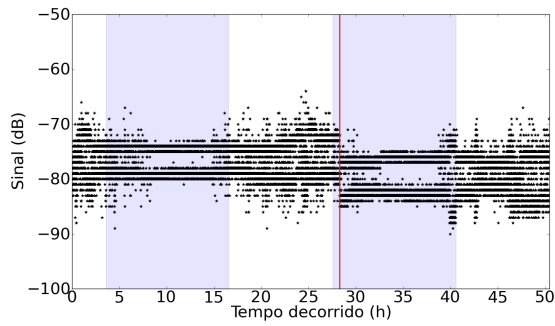
Além de interferências pontuais, redes *Wi-Fi* exibem também, notoriamente, variações com o tempo. Este comportamento ficou bastante claro com os dados obtidos por nossa aquisição de dados de 50 horas (descrita na Seção 4.1).

Foram observadas, ao longo das 50 horas, 14 redes diferentes, das quais apenas duas aparecem em todas as 27.900 aquisições. 6 aparecem em mais de 95% das aquisições (cada uma), e 8 aparecem em 50% ou mais. Uma está presente em 20% das aquisições, e as 5 redes restantes, em menos de 3% cada.


Focando somente nas redes presentes em pelo menos 95% das aquisições, a maior variação total (o sinal mais forte subtraído do mais fraco, do conjunto total de aquisições) foi 33 dB. Para todas as redes houve rodadas de 10 aquisições em que não houve variação alguma. Os sinais obtidos destas redes, ao longo das 50 horas de aquisições, estão representados na Figura 4.9

De imediato, podemos notar que todas as redes apresentam uma variação brusca por volta da 28<sup>a</sup> hora (apesar de menos evidente na Figura 4.9d). O evento está marcado nos gráficos com uma linha vertical vermelha. A simultaneidade sugere alguma interferência externa, e, com efeito, se refere ao reposicionamento






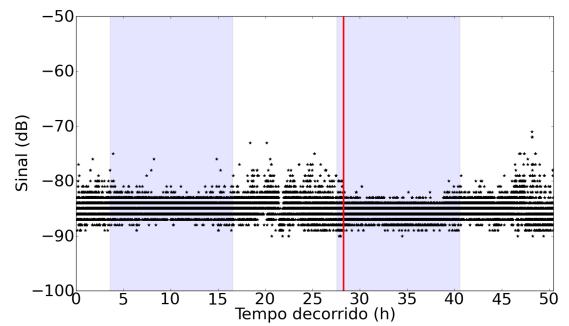
(a) USPnet (00:0c:db:8c:03:68)



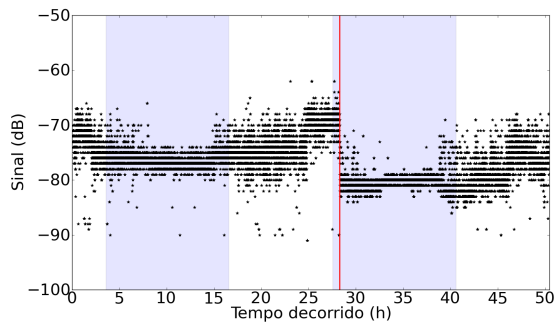
(b) Rede IME (00:05:9e:8c:70:3d)



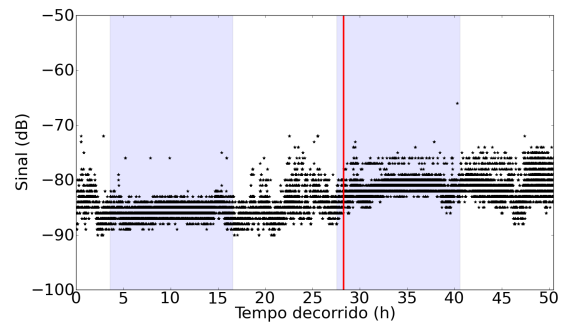
(c) visionw11 (00:c0:02:38:31:68)



(d) USPnet (00:0c:db:8b:f7:d8)



(e) Rede IME (00:05:9e:87:f3:ff)



(f) redelinux 2.0 (68:7f:74:af:c6:e0)

Figura 4.9: Sinais obtidos na aquisição de 50 horas, para redes que aparecem em pelo menos 95% das aquisições.

do dispositivo de captura, que foi rotacionado aproximadamente  $90^\circ$ . O efeito da orientação do dispositivo sobre o valor sinal obtido já havia sido discutido na Seção 2.3, e pode ser claramente observado nesta imagem.


Também é interessante notar que os períodos de maior variação coincidem. A aquisição foi iniciada às 15:30h de um dia de semana ( $t = 0$  h, nos gráficos). Portanto, espera-se que a movimentação nas vizinhanças do equipamento diminua em torno de  $t = 4$  h, às 19:00h, quando as atividades no prédio em questão cessam, e permaneça baixa até aproximadamente  $t = 17$  h, às 8:00h do dia seguinte. Seguindo esta conjectura, a movimentação deveria então permanecer alta até  $t = 30$  h, 19:00h do dia seguinte, e voltar a diminuir em  $t = 41$  h, 8:00h do último dia. Supomos então que ela permanecesse alta até o final de experimento, em  $t = 50$  h, às 17:30 da tarde. Os períodos alternados de aumento e diminuição da variação, aproximadamente síncronos entre as várias redes, corrobora esta pressuposição. Como referência, os horários anteriores a 8:00h e posteriores a 19:00h (teoricamente, períodos de menor movimentação no ambiente) aparecem escurecidos, na Figura 4.9.

De particular relevância para nossa pesquisa, esta análise aponta que variações de sinais de redes *Wi-Fi*, em ambientes sujeitos a trânsito moderado, podem extrapolar os  $\pm 5$  dB normalmente citados na literatura [HSS03, ZSS05, YA05, CLDR09], e freqüentemente o fazem. Em períodos em que o ambiente se encontra mais estático, as variações tipicamente se confinam a estes limites.


Por outro lado, um dos objetivos deste experimento, ao efetuar as aquisições de dados em rodadas de 10 capturas subseqüentes, era verificar como se comporta a média dos sinais, em relação à variação. A Figura 4.10 mostra, em vermelho, a média de cada grupo de 10 capturas, limitada pelos valores máximo e mínimo do grupo. Embora os dados não permitam afirmar que as variações se distribuem homogeneamente ao redor da média, fica claro que, de forma geral, as médias variam de forma bem mais controlada, aproximadamente na faixa de  $\pm 2$  dB. Mesmo nos períodos de maior interferência, a média se mantém relativamente estável.

Uma forma mais objetiva de se avaliar a variabilidade dos dados é utilizar “*boxplots*”. A Figura 4.11 representa *boxplots* das 6 redes que estamos analisando. As bordas inferior e superior dos retângulos limitam o primeiro e o terceiro quartis (25% e 75% dos valores), respectivamente, e a linha vermelha indica a mediana. Os *whiskers* se estendem até, no máximo, 1.5 vezes o intervalo entre o primeiro e o terceiro quartis. Valores fora destes limites estão indicados por “+”, e indicam prováveis *outliers*.


A Figura 4.11 permite avaliar o quão espalhados podem ser os sinais obtidos em uma mesma posição. É interessante notar que nem mesmo a variabilidade é garantida: os sinais de algumas redes são bem mais estáveis do que os de




(a) USPnet (00:0c:db:8c:03:68)




(b) Rede IME (00:05:9e:8c:70:3d)




(c) visionw11 (00:c0:02:38:31:68)



(d) USPnet (00:0c:db:8b:f7:d8)



(e) Rede IME (00:05:9e:87:f3:ff)



(f) redelinux 2.0 (68:7f:74:af:c6:e0)

Figura 4.10: Sinais médio, máximo e mínimo de cada grupo de 10 sinais consecutivos.




Figura 4.11: *Boxplot* dos sinais das redes que aparecem em pelo menos 95% das aquisições.

outras. Compare-se, por exemplo, “Rede IME” (com BSSID “00:05:9e:8c:70:3d”) a “USPnet” (com BSSID “00:0c:db:8b:f7:d8”).

A Figura 4.11 retrata todo o período de 50 horas de aquisição de dados. No entanto, conforme vimos acima, podemos distinguir situações em que o ambiente apresentava mais movimento, e situações em que ele se podia dizer mais estático. A Figura 4.12 apresenta, para cada uma das redes, três *boxplots*: um com todos os sinais (o mesmo da Figura 4.11), para referência; um de um período de movimentação mais intensa (das 8:00h às 19:00h do segundo dia do experimento, ou aproximadamente da 16.5<sup>a</sup> à 27.5<sup>a</sup> hora); e um de um período sem movimentação (das 19:00h do primeiro dia do experimento às 8:00h do segundo, ou aproximadamente da 3.5<sup>a</sup> à 16.5<sup>a</sup> hora).




Figura 4.12: *Boxplot* dos sinais de todo o período de aquisição, dos sinais de um período de movimentação no ambiente, e dos sinais de um período sem movimentação, para cada rede.

Observando a Figura 4.12, fica claro o aumento das variações em uma rede, durante períodos de interferências no ambiente. As exceções notáveis são as duas redes “USPnet”, cujos *boxplots* são semelhantes em ambos os períodos (a rede com BSSID “00:0c:db:8b:f7:d8”, em particular, é extremamente regular durante toda a aquisição, como se pode ver na Figura 4.9), e ainda assim a diferença de variação se manifesta na presença de *outliers*.

## 4.3 Resultados

Utilizando o algoritmo descrito na Seção 3.2 e os dados apresentados na Seção 4.2, foram realizados diversos experimentos, para validação e refinamento da solução. Os experimentos também foram utilizados na definição de parâmetros de configuração e de valores relacionados ao tratamento dos dados.

Em todos os testes, a qualidade do classificador foi medida em função do erro da classificação. O erro foi definido como a distância Euclidiana entre a posição real a que se referia a amostra e a obtida pelo classificador, em metros. A distância considera as posições em duas dimensões (x, y). Em geral, são apresentados o erro médio, como uma medida de acurácia, e o 95º percentil (o valor que limita 95% dos erros), como uma medida de precisão.

Embora tenham sido realizados experimentos em diversas configurações ao longo da pesquisa, os testes podem ser classificados em dois grupos:

**Dispositivo desconhecido** Nesta modalidade de testes, os dados são diferenciados de acordo com sua origem, ou seja, a data e o dispositivo de aquisição: *2010*, *Mac*, *Ubuntu* e *Android* (conforme descrito na Seção 4.1). Cada conjunto de sinais é então testado por um classificador treinado ou com dados de uma outra origem, ou com todos os outros conjuntos. O objetivo destes testes é avaliar como o classificador se comporta quando confrontado com dados obtidos por dispositivos previamente desconhecidos. Isto é uma premissa importante do problema com que esta pesquisa se propõe a lidar.

**70/30** Nestes testes, todos os dados em questão são agrupados, independentemente de origem de aquisição. Os dados são então divididos aleatoriamente em dois conjuntos, um de treinamento e um de teste. Durante o processo de divisão, cada dado tem probabilidade de 70% de ir para o conjunto de treinamento, e de 30% de ir para o de teste. O classificador é treinado com o conjunto de treinamento, e avalia-se a classificação de cada item do conjunto de testes. Este processo é tipicamente repetido algumas vezes, e para o resultado final são consideradas as classificações de todas as repetições. Nesta modalidade de testes, dados das diversas origens podem estar simultaneamente presentes no treinamento e nos testes. É importante notar que, como nossas aquisições de dados obtiveram somente uma captura por dispositivo, em cada posição, testes “70/30” com os dados de um único dispositivo nunca apresentação erro zero. Isto decorre de o classificador não ser ter sido treinado com dados na posição real de nenhum dos exemplos de teste (mais detalhes na Seção 3.5). O erro mínimo, neste caso, será o intervalo mínimo entre posições da aquisição de dados (ou seja, 0.6 m).

Definidos uma métrica de erro e o formato dos testes, o classificador pode

ser avaliado. De início, conforme descrito na Seção 3.3, os dados de treinamento sofrem uma transformação pela qual cada sinal é substituído pela média dos  $N$  sinais mais próximos. A escolha do parâmetro  $N$ , no entanto, deve ser feita com cuidado, pois valores muito baixos podem ser ineficazes, enquanto valores muito altos podem descaracterizar os sinais. A Figura 4.13 ilustra o efeito da aplicação do filtro da média, comparando os sinais originais de uma rede aos submetidos ao filtro, para alguns valores de  $N$  (note que  $N = 1$  significa os sinais originais, sem aplicação do filtro). Uma análise desta imagem sugeriria que  $N = 3$  não exerce muito efeito sobre os dados (embora afete prováveis *outliers*), e que  $N = 53$  atenua demasiadamente a curva.




Figura 4.13: Comparação de valores de  $N$  no filtro da média.  $N = 1$  são os sinais originais.

Para entender a influência do número de posições utilizadas no filtro da média sobre classificações, foram realizados testes de “dispositivo desconhecido” e

“70/30” com diversos valores de  $N$ . Os dados receberam o tratamento de sinais relativos, mas não o pós-processamento de combinação de probabilidades (descritos na Seção 3.3). Para manter a simetria do número de pontos utilizados na média em cada sentido de deslocamento (assumindo número par de sentidos), utilizamos somente  $N$  ímpares. A Tabela 4.3 apresenta os resultados destes testes. A média e o 95° percentil se referem aos resultados consolidados dos dois tipos de testes. Por concisão, nem todos os valores de  $N$  testados constam da tabela, sem que isto, no entanto, descaracterize a tendência dos erros de classificação de acordo com sua evolução.

$N$	Média do erro (m)	95° percentil (m)
1	7.0	43.2
5	4.4	15.6
9	5.4	28.1
13	5.1	27.2
15	3.8	15.7
17	4.3	15.6
21	4.5	16.4
25	4.6	20.1
29	5.0	18.9

Tabela 4.3: Testes com diversos valores de  $N$  para o filtro da média.

Os experimentos mostram que os melhores resultados se obtêm com filtro da média utilizando  $N = 15$ , e este foi o valor utilizado no restante dos testes.

A utilização de sinais relativos se mostrou de extrema importância para a obtenção de bons resultados, especialmente quando o treinamento e a classificação utilizam dispositivos distintos.

Para quantificar a relevância da utilização de sinais relativos, é preciso lembrar que sinais obtidos com um mesmo dispositivo tendem a ser relativamente regulares [TCC09], especialmente após a aplicação do filtro da média. Para ilustrar este comportamento, a Tabela 4.4 mostra o resultado de testes do tipo “70/30” para cada um dos dispositivos, individualmente. Os testes utilizam filtro da média com  $N = 15$ , e não são utilizados sinais relativos, nem é realizado pós-processamento nas classificações.

Entretanto, quando treinamos o classificador com dados de um dispositivo e o testamos com dados de um dispositivo diferente, o erro aumenta consideravelmente. A Tabela 4.5 mostra o resultado de experimentos neste formato, para diversos pares de dispositivos. Nestes testes, também, utilizou-se filtro da média com  $N = 15$ , e não se utilizaram sinais relativos ou pós-processamento.



Dispositivo	Média do erro (m)	95° percentil (m)
<i>Mac</i>	2.7	5.4
<i>Ubuntu</i>	3.8	11.2
<i>Android</i>	2.9	6.7
<i>2010</i>	3.0	7.1

Tabela 4.4: Testes “70/30” com cada dispositivo.

Treinamento	Teste	Média do erro (m)	95° percentil (m)
<i>Mac</i>	<i>Android</i>	16.4	42.54
<i>Ubuntu</i>	<i>Android</i>	13.6	37.44
<i>2010</i>	<i>Android</i>	14.1	43.14
<i>Mac</i>	<i>Ubuntu</i>	4.7	18.18
<i>Android</i>	<i>Ubuntu</i>	13.9	52.74
<i>2010</i>	<i>Ubuntu</i>	11.2	38.88
<i>Ubuntu</i>	<i>Mac</i>	3.1	8.94
<i>Android</i>	<i>Mac</i>	8.7	23.34
<i>2010</i>	<i>Mac</i>	4.3	9.3
<i>Mac</i>	<i>2010</i>	7.8	22.30
<i>Ubuntu</i>	<i>2010</i>	7.8	20.7
<i>Android</i>	<i>2010</i>	6.6	17.91

Tabela 4.5: Testes comparando treinamento com dados de um dispositivo e teste com dados de outro, sem utilização de sinais relativos.

De imediato, é possível notar que o resultado das classificações, de forma geral, é bastante inferior ao obtido quando se realizam treinamento e testes com dados de um mesmo dispositivo. Pode-se também perceber que os maiores erros envolvem o dispositivo *Android*. É importante notar que os outros dispositivos representados na Tabela 4.5 são todos *notebooks*, enquanto o *Android* é um telefone celular. Entre dispositivos de um mesmo “tipo” (dois *notebooks*), os erros tendem a diminuir. A Figura 4.7 já demonstrava a diferença de intensidade entre os dados do *Android* e os dos outros dispositivos.

A transformação de sinais relativos tem como objetivo normalizar estas diferenças de intensidade. A Tabela 4.6 mostra as mesmas combinação de conjuntos de dados de treinamento e testes, mas, desta vez, com a utilização de sinais relativos. A grande maioria das classificações é significativamente melhor com a utilização de sinais relativos.

Treinamento	Teste	Média do erro (m)	95° percentil (m)
<i>Mac</i>	<i>Android</i>	4.1	14.0
<i>Ubuntu</i>	<i>Android</i>	8.0	33.2
<i>2010</i>	<i>Android</i>	3.5	9.9
<i>Mac</i>	<i>Ubuntu</i>	2.7	9.5
<i>Android</i>	<i>Ubuntu</i>	9.3	35.3
<i>2010</i>	<i>Ubuntu</i>	3.6	9.8
<i>Ubuntu</i>	<i>Mac</i>	7.2	42.5
<i>Android</i>	<i>Mac</i>	11.2	40.1
<i>2010</i>	<i>Mac</i>	1.8	5.0
<i>Mac</i>	<i>2010</i>	2.0	4.7
<i>Ubuntu</i>	<i>2010</i>	4.6	17.6
<i>Android</i>	<i>2010</i>	3.9	13.2

Tabela 4.6: Testes comparando treinamento com dados de um dispositivo e teste com dados de outro, com a utilização de sinais relativos.

É interessante notar que esta transformação de dados não é comumente discutida nas pesquisas de localização com *Wi-Fi*, apesar de produzir resultados tão expressivos. Como a maioria dos autores utiliza um único dispositivo para tomada de dados de treinamento e de testes, ou ao menos dispositivos de mesma configuração (conforme discutido no Capítulo 3), o problema não se manifesta. Kjærsgaard e Munk [KM08] discutem uma transformação semelhante, em que incorporam ao cálculo dos sinais relativos a posição das antenas transmissoras de rede *Wi-Fi* e um modelo de propagação dos sinais. Chen *et al.* [CLL08] também utilizam uma solução com o mesmo princípio (apesar de no contexto de um tipo de classificador distinto do nosso), em que simplesmente sinalizam se uma rede tem sinal maior, menor ou igual ao de outra; no entanto, realizamos testes com este formato, e os resultados são bastante inferiores.

O pós-processamento de combinação de probabilidades tem origem na observação, durante a análise dos dados, de que algumas posições eram classificadas com erros altos, enquanto posições adjacentes eram classificadas corretamente, ou com erros pequenos.

O classificador foi testado, então, utilizando combinação de probabilidades, com alguns valores diferentes para o número de posições a serem consideradas. Como este número, em uma situação de uso real, implica um deslocamento do usuário, foram testados apenas valores pequenos, de 2 a 5. Foram realizados testes em diversas configurações. A Tabela 4.7 mostra o resultado de testes “70/30” com todo o conjunto de dados. Testes com apenas uma posição significam que não foi

utilizada combinação de probabilidades.

Número de posições	Média do erro (m)	95° percentil (m)
1 (sem combinação)	5.2	16.0
2	1.4	4.5
3	2.0	5.2
4	2.2	5.2
5	2.2	5.2

Tabela 4.7: Testes de combinação de probabilidades, para diferentes números de posições.

O resultado destes testes mostra que as classificações melhoram sensivelmente com a combinação de duas posições (ou seja, simulando a situação em que o usuário dá um único passo). O erro aumenta com mais uma e duas posições, e se mantém aproximadamente estável em seguida. Utilizamos, portanto, a combinação de probabilidades de apenas duas posições. Este resultado é bem-vindo, pois não exige grandes deslocamentos do usuário.

A Figura 4.14 ilustra a aplicação de probabilidades combinadas para duas posições consecutivas. Os erros representados são os de um teste do tipo “dispositivo desconhecido”, classificando os dados do dispositivo *Mac* com um classificador treinado com os dados de todos os outros dispositivos. 38% das classificações obtidas neste teste exibiram erro menor com combinação de probabilidades do que sem. O erro de 12% delas caiu a zero. Neste teste, nenhum erro aumentou com a aplicação de combinação de probabilidades.

Com o resultado dos testes, pode-se então definir a configuração ótima dos parâmetros a serem aplicados à solução proposta:

- Filtro da média com  $N = 15$ .
- Utilização de sinais relativos, no lugar dos valores absolutos dos sinais.
- Combinação de probabilidades de duas posições consecutivas.

A Tabela 4.8 apresenta os resultados obtidos nos testes com esta configuração. Estão descritos resultados de testes de classificação dos dados *2010*, *Mac*, *Ubuntu* e *Android*. Foram realizados tanto testes do tipo “dispositivo desconhecido” quanto “70/30”. A tabela apresenta a média dos erros obtido com as classificações, a mediana do erro, e o 95° percentil.

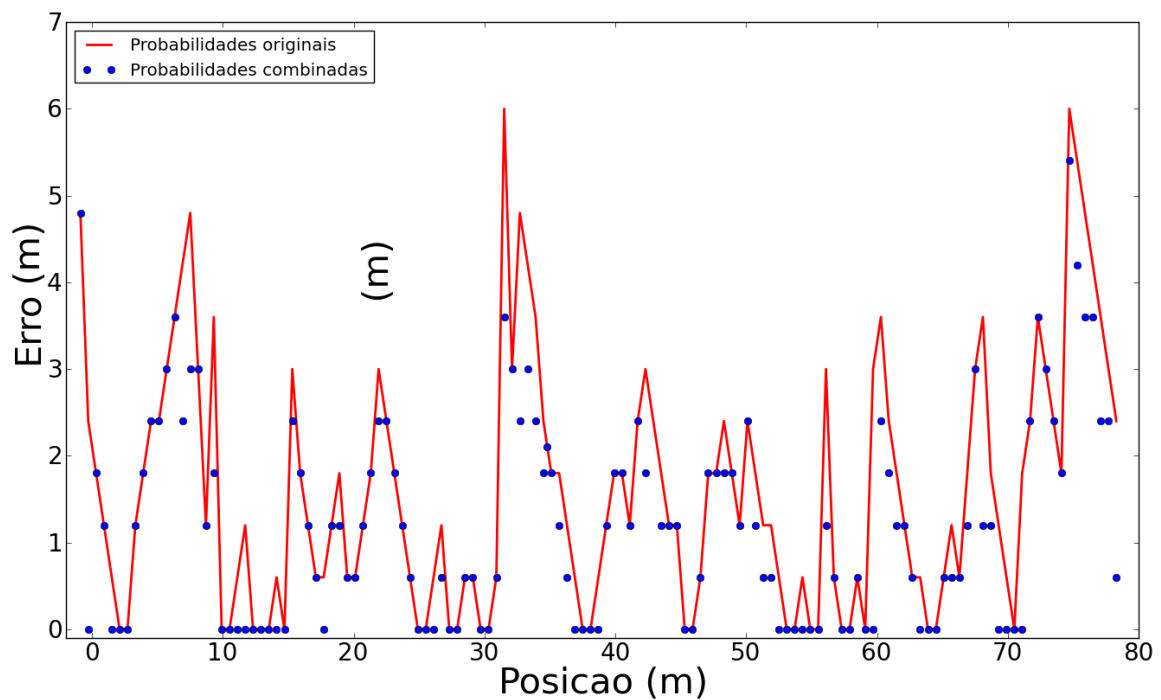


Figura 4.14: Comparação dos erros obtidos na classificação com e sem probabilidades combinadas.

Conjunto de treinamento	Conjunto de testes	Média do erro (m)	Mediana do erro (m)	95° percentil (m)
<i>Android + Mac + Ubuntu</i>	<i>2010</i>	1.4	0.9	3.5
<i>Android + Mac + 2010</i>	<i>Ubuntu</i>	2.4	2.1	5.7
<i>Android + Ubuntu + 2010</i>	<i>Mac</i>	2.2	0.9	8.9
<i>Mac + Ubuntu + 2010</i>	<i>Android</i>	3.3	2.1	11.0
70% de todos os dados	30% de todos os dados	1.4	0.9	4.5

Tabela 4.8: Resultados de classificação com configuração ótima.

Os testes “70/30” apresentam ótimos resultados. Mas os testes de “dispositivo desconhecido” são particularmente interessantes. Os maiores erros são obtidos ao se classificarem os dados do *Android*. Isto era esperado, uma vez que ele pertence a uma categoria diferente de dispositivo em relação aos outros. No entanto, ainda assim são bons resultados para um classificador que não havia sido treinado com dados de telefones celulares.

É também interessante notar que estes testes incluem os dados obtidos em

2010. No ano decorrido entre as tomadas de dados, muitas mudanças podem ter sido introduzidas no ambiente: deslocamento de antenas transmissoras, reposicionamento de móveis etc. Chama ainda a atenção o fato de que os testes de classificação dos dados de 2010 são significativamente melhores do que aqueles em que os dados de 2010 estão entre os utilizados pra classificar dados de outros dispositivos.

Com isto em mente, realizamos também testes somente com os dados obtidos na aquisição de 2011, apresentados na Tabela 4.9

Conjunto de treinamento	Conjunto de testes	Média do erro (m)	Mediana do erro (m)	95° percentil (m)
<i>Android + Mac</i>	<i>Ubuntu</i>	2.4	1.2	6.0
<i>Android + Ubuntu</i>	<i>Mac</i>	2.2	1.2	4.8
<i>Mac + Ubuntu</i>	<i>Android</i>	2.1	1.2	4.8
70% de todos os dados	30% de todos os dados	1.3	1.2	4.2

Tabela 4.9: Resultados de classificação com configuração ótima, somente com dados da aquisição de 2011.

Os resultados não são, em geral, extremamente diferentes dos obtidos com os dados de 2010, mas alguns efeitos são notáveis. A precisão das classificações tende a aumentar, quando se excluem os dados de 2010. O 95° percentil e a mediana diminuem consideravelmente ou ao menos se mantêm baixos. Ou seja, um número menor de classificações localiza o usuário em posições muito distantes da real. Por outro lado, a média os erros se mantém razoavelmente inalterada. Estes resultados sugerem que o treinamento com dados coletados em situações muito distintas possa gerar inconsistência nas distribuições de probabilidades do classificador.

É particularmente interessante notar a degradação da classificação dos dados do *Android*, quando o classificador é treinado com dados de 2010. Os testes do tipo “dispositivo desconhecido” já tendem (naturalmente) a fornecer resultados piores. O situação em que os dados do *Android* são classificados é ainda agravada pelo fato de o classificador não haver sido treinado com quaisquer dados obtidos por telefones celulares. Isto, aparentemente, torna sua classificação mais sensível à instabilidade introduzida pelos dados de 2010. Sem a presença dos dados de 2010, o resultado das classificações dos dados do *Android* é equivalente ao dos outros dispositivos.

Um caso mais extremo de dados inconsistentes é o do dispositivo *N900*. Na Seção 4.2, detalhamos os problemas encontrados em sua captura de dados. Devido a estes problemas, os dados foram considerados não confiáveis, e não foram utilizados para a obtenção dos valores expostos até aqui nesta seção.

No entanto, é interessante aplicar a solução proposta nesta pesquisa aos

dados obtidos pelo *N900*. A Tabela 4.10 expõe o resultados da classificação dos dados do *N900* por um classificador treinado com todos os outros dados. São também apresentados os resultados de teste “70/30”, com todos os dados coletados, inclusive os do *N900*.

Conjunto de treinamento	Conjunto de testes	Média do erro (m)	Mediana do erro (m)	95° percentil (m)
<i>Android + Mac + Ubuntu + 2010</i>	<i>N900</i>	10.92	8.10	28.08
70% de todos os dados (incluindo <i>N900</i> )	30% de todos os dados (incluindo <i>N900</i> )	2.06	0.90	8.10

Tabela 4.10: Resultados de testes com dados do dispositivo *N900*.

Como a Tabela 4.10 mostra claramente, o desempenho do classificador é bastante ruim, no teste de “dispositivo desconhecido”. Isto sugere que o classificador tem dificuldades em lidar com dados pouco estruturados. Ainda assim, é encorajador que o resultado seja significativamente melhor no teste “70/30”.

Finalmente, a Tabela 4.11 apresenta os resultados obtidos com a solução proposta nesta pesquisa, comparados a resultados de outros autores. Como diferentes estudos frequentemente utilizam critérios distintos de avaliação de seus métodos, nem sempre é possível fazer uma comparação imediata. Além disso, muitas pesquisas utilizam métodos que não se adequam às restrições que impusemos no Capítulo 3. Por este motivo, foram omitidas pesquisas fortemente ligadas à robótica, que exijam grandes deslocamentos ou equipamentos extremamente especializados. De qualquer modo, tentamos comparar os dados de forma relevante. Por concisão, estão na tabela somente o nome do primeiro autor e uma referência ao trabalho onde são apresentados os resultados. Quando a pesquisa apresenta diversos resultados (por exemplo, ao testar variações de uma solução), está representado aqui o que mais se adequa ao nosso problema. Se ainda assim houver vários resultados, apresentamos sempre o melhor deles. Os nossos resultados são apresentados para o conjunto de dados incluindo os de 2010, apresentados na Tabela 4.8.

Estão também incluídos na Tabela 4.11, como referência, os resultados obtidos com uma implementação simples de um classificador *kNN*, com  $k = 5$  vizinhos mais próximos. Os dados fornecidos a este classificador são submetidos ao filtro da média e à transformação de sinais relativos, e os resultados também são combinados em duas posições. A comparação com um classificador *kNN* utilizando os tratamentos de dados propostos neste trabalho é interessante, pois grande parte das soluções propostas a localização utilizando sinais de redes *Wi-Fi* se baseia em

$kNN$ .

Autor	Média do erro (m)	Mediana do erro (m)	90° percentil (m)	95° percentil (m)
Esta pesquisa	1.4	0.9	3.5	4.5
Youssef [YA05]	0.42		0.86	
Li [LWL <sup>+</sup> 05]	1.6			3.4
Li [LSDR06]		1.4	3.5	
Ma [MLTL08]	1.43			
Krumm [KH04]	1.53		≈5	
Cheong [CLDR09]		2.07	≈5	
Prasithsangaree [PKC02]	4.3			12.2
Zhou [ZSS05]				7
$kNN$ (referência)	2.3	1.5	5.6	7.6

Tabela 4.11: Comparação dos resultados desta pesquisa com os obtidos por outros autores.

De imediato, percebe-se que nossos resultados se encontram dentre os com maior acurácia e precisão. É importante notar que nenhum dos trabalhos com resultados comparáveis adota simultaneamente premissas de uso de dispositivos arbitrários, ambiente com movimentação e antenas transmissoras em localizações desconhecidas.

Youssef *et al.* [YA05] descrevem o sistema Horus, uma aplicação comercial de localização utilizando sinais *Wi-Fi*. Os resultados apresentados no artigo aparentam ser impressionantes, e as técnicas empregadas são bastante complexas. Seu algoritmo exige conhecimento das posições das antenas transmissoras. Os dados de treinamento e testes são obtidos com equipamentos semelhantes, e os autores discorrem sobre placas de rede *Wi-Fi* cujas leituras de sinal sejam compatíveis entre si. As coletas de dados foram realizadas ao longo de diversas ocasiões, com e sem movimentação no ambiente.

Li *et al.* [LWL<sup>+</sup>05] estudam uma nova forma de se criar uma base de dados para localização com *Wi-Fi*, e fazem vários experimentos diferentes. Os resultados apresentados na Tabela 4.11 utilizam  $kNN$  com pesos, e são os mais compatíveis com o nosso arranjo experimental. Eles conseguem melhores resultados (com média de erro da ordem de 1.19 m) utilizando uma base de dados alternativa, entretanto a construção desta base de dados necessita conhecimento preciso das posições e das relações espaciais entre as antenas transmissoras.

Em um trabalho posterior, também apresentado na tabela, Li *et al.* [LSDR06] descrevem a aplicação de um classificador Bayesiano, com resultados semelhantes ao nosso. O trabalho se refere à “mediana” do erro e nunca à média, o que

talvez seja um erro de grafia. É importante ressaltar, entretanto, que seu arranjo experimental é bastante controlado, e é utilizado um único equipamento na aquisição de dados de treinamento e de testes.

Ma *et al.* [MLTL08] empregam *kNN* com conglomerados. Suas medidas de sinais são sempre realizadas em 4 sentidos, para mitigar efeitos de orientação da antena.

A solução de Krumm *et al.* [KH04] é especificamente voltada para a robótica. Entretanto, o sistema desenvolvido (“LOCADIO”) é bastante conhecido na área e freqüentemente utilizado como base de comparação, e por este motivo foi incluído.

Cheong *et al.* [CLDR09] utilizam *Wi-Fi* em conjunto com GPS, em uma solução híbrida. O algoritmo utilizado é uma variante do *kNN*, com uma interpolação de dados em função da distância entre as antenas transmissoras, cujas posições precisam ser conhecidas. Suas aquisições são efetuadas com as antenas posicionadas em 4 sentidos, e foram efetuadas com o mesmo dispositivo para a base de treinamento e para os testes.

Prasithsangaree *et al.* [PKC02] fazem testes com uma série de variações de *fingerprinting*, a partir de valores médios dos sinais adquiridos e das posições das antenas transmissoras. Usam ainda uma heurística interessante após a aplicação do algoritmo, pela qual obtêm *K* posições mais prováveis, eliminam as mais distantes e devolvem como localização a média das posições que restaram.

Zhou [ZSS05] faz uma análise de uma série de variações de localização. Seus resultados não são apresentados de forma bem estruturada, mas, para comparação, é apresentada aqui uma medida da melhor precisão obtida, utilizando *kNN* com uso de pesos.

### 4.3.1 Protótipo de aplicativo móvel

De posse destes resultados, foi desenvolvida uma aplicação simples para *smartphone*, como prova de conceito. O programa foi escrito em Python para a plataforma Android.

O classificador deve ser treinado de antemão, sendo definidas as distribuições de probabilidades da forma descrita na Seção 3.4. Estas distribuições de probabilidades são então armazenadas no aparelho em que o aplicativo vai ser utilizado.

Ao ser iniciado, o programa instancia o classificador e carrega as distribuições de probabilidade calculadas no treinamento. Quando o usuário seleciona a opção de obter localização, o aplicativo inicia uma captura de sinais de redes *Wi-Fi*. Se a captura for realizada com sucesso, o aplicativo aplica a transformação de sinais relativos ao resultado, e o armazena.

Para a aplicação do pós-processamento de combinação de probabilidades, é necessário efetuar mais uma aquisição de sinais. Este protótipo, atualmente,



ainda não detecta a movimentação do usuário. A interface apresenta uma opção de realizar nova captura (assumindo que o usuário se deslocou), ou de obter a localização imediatamente, sem combinação de probabilidades.

Em qualquer uma destas situações, quando o usuário sinaliza o final das capturas o aplicativo realiza a classificação e apresenta imediatamente a localização estimada. Além disso, o programa também realiza uma busca na base de imagens obtidas na aquisição de 2010 (descrita na Seção 4.1). A base é indexada por localização, para que esta busca seja rápida. Finalmente, o programa apresenta ao usuário a imagem representando o local mais próximo da posição estimada.

A Figura 4.15a mostra a tela inicial do aplicativo (após o classificador ter sido carregado), e a Figura 4.15b mostra a localização obtida e a imagem associada. Toda a execução, do momento em que o usuário inicia o aplicativo até a obtenção de localização e apresentação da imagem correspondente, leva aproximadamente um minuto, no dispositivo *Android* descrito na Seção 4.1. A maior parte deste tempo é gasta no carregamento do classificador treinado. Do momento em que o usuário seleciona a opção de obter localização até o resultado ser mostrado na tela transcorrem menos de 5 segundos.




Figura 4.15: Capturas de tela do protótipo.

# Capítulo 5

## Conclusões

### 5.1 Considerações finais

Este trabalho apresentou pesquisa realizada sobre a utilização de sinais de redes *Wi-Fi* na solução do problema de localização, e sua aplicação em dispositivos móveis.

Localização é um problema chave para a computação móvel. Robôs, e veículos autônomos em geral, dependem fortemente de uma boa estimativa de sua posição para poderem se movimentar e realizar tarefas. Sistemas de auxílio a deficientes visuais e aplicações de realidade aumentada se baseiam em localização para apresentar informações relevantes ao usuário.

Sinais de redes *Wi-Fi*, no contexto de localização, diferem do emprego de outros sensores por sua grande variabilidade e extrema sensibilidade a interferências. Especialmente quando se lida com redes *Wi-Fi* previamente existentes no ambiente (ao invés de transmissores posicionados especificamente para localização), a propagação do sinal é de difícil modelagem. A utilização de dispositivos baratos, produzidos em massa, tanto para transmissão quanto para recepção de sinais, foram essenciais para a difusão do uso de redes *Wi-Fi*; e, ao mesmo tempo, afetam também a previsibilidade do seu comportamento. Movimentação de indivíduos no ambiente, campos eletromagnéticas (inclusive provenientes de outras redes *Wi-Fi*), reposicionamento de móveis, podem todos significar alteração considerável nos sinais.

Por outro lado, a presença massiva de redes *Wi-Fi* em ambientes urbanos, especialmente em ambientes internos, encoraja seu uso na busca por localização. Redes privadas e públicas provêm ampla cobertura de sinais, e a facilidade de implantação de novas redes, com equipamentos disponíveis a custos acessíveis, favorece uma cobertura cada vez mais densa.

Em particular, focamos na utilização de dispositivos móveis disponíveis ao

consumidor, como *notebooks*, *tablets* e *smartphones*. A adoção deste tipo de dispositivo vem crescendo constantemente nos últimos anos, e um número cada vez maior deles é equipado com antenas receptoras de sinais *Wi-Fi*. Dispositivos modernos possuem também capacidade de processamento compatível com tarefas de localização. Sendo aparelhos que o usuário normalmente leva consigo, uma solução de localização que os utilize se exime da necessidade de equipamentos dedicados.

Ao longo deste trabalho, foram realizadas aquisições de dados de redes *Wi-Fi*, para aplicação nesta pesquisa e em posteriores. As aquisições foram realizadas em ambientes dinâmicos, com presença de transeuntes, em dias de movimentação típica (a saber). As aquisições foram realizadas em mais de uma ocasião, e foram utilizados dispositivos distintos, a fim de que, nos testes, se pudessem simular situações menos homogêneas.

Há diversos cenários possíveis de se abordarem no estudo de localização. Nesta pesquisa, definimos o problema a ser tratado como o de obter estimativa da posição de um usuário portando um *smartphone*, em um ambiente previamente mapeado. A estimativa é realizada a partir de uma aquisição (ou uma pequena quantidade delas) dos sinais das redes *Wi-Fi* naquela posição. Não se assume que o ambiente seja estático, nem que o usuário utilize o mesmo dispositivo empregado no mapeamento original.

Após análise da literatura disponível e experimentos iniciais, foi proposta uma solução baseada em um classificador Bayesiano ingênuo. A solução envolve um tratamento prévio dos dados, tanto na fase de treinamento quanto nas classificações. A solução prevê ainda uma manipulação dos resultados do classificador Bayesiano, de modo a tirar proveito de que as possíveis classificações são posições, e possuem relação de distância entre si.

Foram realizadas séries de testes, envolvendo várias combinações dos dados. Foram especialmente considerados os testes em que o classificador era submetido a dados obtidos com dispositivos previamente desconhecidos a ele. Isto ressaltou um dos objetivos da pesquisa, de não limitar a solução à utilização de um determinado equipamento. Outro objetivo proposto, e refletido nos testes, foi o de que a solução deveria ser aplicável em ambientes com movimentação real, e não somente em situações controladas.

A partir dos testes, foram definidos os parâmetros de configuração ótimos da solução. Com estes parâmetros, foram obtidos resultados apresentando boa acurácia e precisão. Os resultados, de forma geral, são favoravelmente comparáveis aos de pesquisas com objetivos semelhantes.

Os resultados obtidos são particularmente notáveis por estimarem localização com erros baixos mesmo quando o usuário utiliza um aparelho não disponível na fase de treinamento do classificador. Esta restrição freqüentemente não é imposta,

ou não é considerada, em outras pesquisas na área.

Mesmo nos testes que apresentaram os piores resultados, o erro observado ainda é aceitável. Embora, nestes casos extremos, o classificador proposto possa ser inadequado a aplicações que exijam alta precisão, ele ainda pode ser utilizado como método auxiliar. A classificação obtida é entendida como estimativa prévia de localização, a ser refinada por técnicas que exijam processamento mais intenso ou grandes quantidades de dados. Estas técnicas podem partir dos resultados do nosso classificador, e não precisam mais buscar todo o espaço de possíveis localizações. Isto as torna mais eficientes, ou até mesmo viáveis em dispositivos com recursos computacionais escassos.

É relevante que um dos dispositivos utilizados na aquisição de dados gerou dados de má qualidade, e nem mesmo pode ser utilizado em todo o percurso da aquisição. O classificador, treinado com dados de todos os outros dispositivos, apresentou erro bastante alto quando aplicado aos dados deste. Os resultados, entretanto, foram melhores quando uma parte dos dados do dispositivo problemático foi utilizada no treinamento do classificador (e, naturalmente, retirada do conjunto de testes).

Esta situação explicitou uma fragilidade da nossa solução: dados com comportamento indefinido, geralmente com sinais muito fracos, são difíceis de se classificarem, especialmente quando dados semelhantes não fazem parte do conjunto de treinamento. O fato de que o dispositivo em questão é um *smartphone* sofisticado, de última geração (na época em que foram feitos os testes), sugere que este problema pode não ser incomum (embora não tenha se manifestado com os outros dispositivos utilizados nesta pesquisa).

## 5.2 Sugestões para trabalhos futuros

Nossa solução faz pouco uso da informação de que cada classificação obtida é uma posição. Uma alternativa a ser estudada é derivar a estimativa da localização a partir de uma interpolação das classificações com maior probabilidade. Ou seja, poderia se supôr que, se determinadas posições têm probabilidades semelhantes (e significativamente maiores que as outras), então o indivíduo deve estar localizado em algum ponto entre elas (e não necessariamente exatamente em uma delas). Prasithsangaree *et al.* [PKC02] sugere uma composição semelhante de resultados, em que, dadas as posições com maior probabilidade, são selecionadas as  $K$  mais próximas entre si, e a localização estimada pelo classificador é a média entre elas.

Alguns trabalhos na área realizam interpolações dos valores do conjunto de dados de treinamento [HSS03, LWL<sup>+</sup>05, LSDR06, CLDR09]. Isto dá ao classificador a possibilidade de maior acurácia, devido à malha mais fina de localizações possíveis, sem onerar a solução com uma etapa mais longa e complexa

de aquisição. Seria interessante incluir um método de interpolação ao tratamento de dados sugerido na nossa solução, e testar sua influência nos resultados.

A variabilidade dos sinais é uma característica bastante marcante de redes *Wi-Fi*. A análise das aquisições de dados na Seção 4.2 mostra que a magnitude desta variabilidade pode ser associada a situações de maior movimento no ambiente. Associamos ainda a movimentação a períodos do dia, de acordo com a dinâmica esperada naquele ambiente. Consideradas estas relações, pode ser interessante analisar um classificador que leve em consideração o horário em que esteja sendo empregado para analisar um novo exemplo. Este classificador poderia utilizar somente, ou privilegiar, dados de treinamento obtidos em períodos de movimentação semelhante.

O pós-processamento da classificação Bayesiana, aplicando uma combinação de probabilidades, forneceu bons resultados nos experimentos realizados. Entretanto, ele implica deslocamento do usuário. É interessante notar que, se for imprescindível que o usuário não se desloque, este pós-processamento ainda pode ser utilizado. Basta que se altere a Equação 3.6 da probabilidade combinada para que todos os exemplos apresentados ao classificador representem a mesma posição. Entretanto, se vão ser realizadas diversas medidas em uma mesma posição, seria interessante comparar os resultados da combinação da probabilidades a simplesmente se utilizar uma média dos valores dos sinais de cada rede naquela posição, conforme implementado por diversos autores [HSS03, ZSS05, YA05, CLDR09].

Claramente, são necessários novos mecanismos para se classificarem dados muito disformes, como os do dispositivo problemático discutido na Seção 4.2. Talvez, ao se detectarem sinais consistentemente fracos, se devam obter diversas medidas em uma única posição, e utilizar a média delas. De qualquer modo, estes dados necessitam de análise mais aprofundada, inclusive para se determinar se é um problema recorrente nos *smartphones* daquele modelo, ou se é uma falha pontual da unidade utilizada.

Os resultados mostraram que o classificador perde precisão quando treinado com os dados obtidos em 2010. Um estudo do efeito de dados coletados em situações muito distintas exigiria diversas coletas de dados ao longo de um período extenso. Entretanto, é importante compreender este efeito, para aplicações reais.

Outro desenvolvimento interessante a partir desta pesquisa seria o estudo de estimação de orientação do indivíduo, a partir de sinais *Wi-Fi*. É conhecido que a potência do sinal obtido muda de acordo com a orientação da antena receptora, mas normalmente esta informação somente é utilizada para que se atenuem seus efeitos (por exemplo, capturando sinais com o dispositivo em várias orientações, e armazenando-se uma média) [HSS03, CLDR09]. Uma análise mais detalhada do comportamento do sinal poderia ser utilizada para que o sistema oferecesse estimativa de localização e orientação (ou seja, de pose) [IK07].

Apesar de ter sido desenvolvido um protótipo da solução para um *smartphone*, sua utilização é limitada e sua interface é bastante restrita. Os testes com as bases de dados completas foram realizados em *notebooks*, pois eram analisadas diversas variações da solução, com diversas combinações dos dados, o que exigiu processamento intenso. Uma continuação desta pesquisa deve incluir o desenvolvimento de um aplicativo completo, que possa ser utilizado em situações reais.

# Referências Bibliográficas

- [ACVS08] Mikhail Afanasyev, Tsuwei Chen, G.M. Voelker e A.C. Snoeren. Analysis of a mixed-use urban WiFi network: when metropolitan becomes neapolitan. Em *Proceedings of the 8th ACM SIGCOMM conference on Internet measurement*, páginas 85–98. ACM, 2008.
- [ACVS10] Mikhail Afanasyev, Tsuwei Chen, Geoffrey M. Voelker e Alex C. Snoeren. Usage Patterns in an Urban WiFi Network. *IEEE/ACM Transactions on Networking*, 18(5):1359–1372, Outubro 2010.
- [BETG08] Herbert Bay, Andreas Ess, Tinne Tuytelaars e Luc Van Gool. Speeded-Up Robust Features (SURF). *Computer Vision and Image Understanding (CVIU)*, 110(3):346–359, Junho 2008.
- [BFHS96] Wolfram Burgard, Dieter Fox, Daniel Hennig e Timo Schmidt. Estimating the absolute position of a mobile robot using position probability grids. Em *Proceedings of the national conference on artificial intelligence*, páginas 896–901. AAAI Press/MIT Press, 1996.
- [CCLK05] Yu-Chung Cheng, Yatin Chawathe, Anthony LaMarca e John Krumm. Accuracy characterization for metropolitan-scale Wi-Fi localization. Em *Proceedings of the 3rd international conference on Mobile systems, applications, and services*, páginas 233–245. ACM, 2005.
- [CIP11] CIPA. Exchangeable image file format for digital still cameras: Exif Unified Version 2.21. [http://www.jeita.or.jp/cgi-bin/standard\\_e/list.cgi?cateid=1&subcateid=4](http://www.jeita.or.jp/cgi-bin/standard_e/list.cgi?cateid=1&subcateid=4), Abril 2011.
- [CLDR09] Joon Wayn Cheong, Binghao Li, Andrew G. Dempster e Chris Rizos. GPS/WiFi real-time positioning device: An initial outcome. Em Georg Gartner e Karl Rehr, editors, *Location Based Services and TeleCartography II*, páginas 439–456. Springer, 2009.

- [CLL08] Qiuxia Chen, Dik-Lun Lee e Wang-Chien Lee. Rule-Based WiFi Localization Methods. Em *2008 IEEE/IFIP International Conference on Embedded and Ubiquitous Computing*, páginas 252–258, Dezembro 2008.
- [CM09] James Coughlan e Roberto Manduchi. Functional Assessment of a Camera Phone-Based Wayfinding System Operated by Blind and Visually Impaired Users. *International Journal on Artificial Intelligence Tools*, 18(Special Issue on Artificial Intelligence Based Assistive Technologies: Methods and Systems for People with Disabilities):379–397, 2009.
- [Cox91] Ingemar J. Cox. Blanche - an experiment in guidance and navigation of an autonomous robot vehicle. *IEEE Transactions on Robotics and Automation*, 7(2):193–204, Abril 1991.
- [CSR07] Zhenhe Chen, Jagath Samarabandu e Ranga Rodrigo. Recent advances in simultaneous localization and map-building using computer vision. *Advanced Robotics*, 21(3):233–265, Março 2007.
- [CTCW07] Yao-Jen Chang, Shih-Kai Tsai, Yao-sheng Chang e Tsen-Yung Wang. A novel wayfinding system based on geo-coded qr codes for individuals with cognitive impairments. Em *Proceedings of the 9th international ACM SIGACCESS Conference on Computers and Accessibility*, páginas 231–232. ACM, 2007.
- [DH07] Stephen DiVerdi e Tobias Hollerer. GroundCam: A Tracking Modality for Mobile Mixed Reality. Em *2007 IEEE Virtual Reality Conference*, páginas 75–82, Março 2007.
- [DHS01] Richard O. Duda, Peter E. Hart e David G. Stork. *Pattern classification*. Wiley-Interscience, second edição, 2001.
- [DNC<sup>+</sup>01] Gaminni M. W. M. Dissanayake, Paul Newman, Steven Clark, Hugh F. Durrant-Whyte e Michael Csorba. A solution to the simultaneous localization and map building (SLAM) problem. *IEEE Transactions on Robotics and Automation*, 17(3):229–241, 2001.
- [DRMS07] Andrew J. Davison, Ian D. Reid, Nicholas D. Molton e Olivier Stasse. MonoSLAM: real-time single camera SLAM. *IEEE transactions on pattern analysis and machine intelligence*, 29(6):1052–67, Junho 2007.



- [DwB06a] Hugh Durrant-whyte e Tim Bailey. Simultaneous localisation and mapping (SLAM): Part I the essential algorithms. *Robotics & Automation Magazine*, páginas 99–110, Junho 2006.
- [DwB06b] Hugh Durrant-whyte e Tim Bailey. Simultaneous localisation and mapping (SLAM): Part II state of the art. *Robotics & Automation Magazine*, páginas 108–117, 2006.
- [FBT99] Dieter Fox, Wolfram Burgard e Sebastian Thrun. Markov localization for mobile robots in dynamic environments. *Journal of Artificial Intelligence Research*, 11(3):391–427, 1999.
- [FFL07] Brian Ferris, Dieter Fox e Neil Lawrence. WiFi-SLAM Using Gaussian Process Latent Variable Models. Em *20th International Joint Conference on Artificial Intelligence*, páginas 2480–2485, 2007.
- [FTBD01] Dieter Fox, Sebastian Thrun, W. Burgard e Frank Dellaert. *Particle filters for mobile robot localization*, páginas 499–516. Springer-Verlag, 2001.
- [Fuk90] Keinosuke Fukunaga. *Introduction to statistical pattern recognition*. Academic Press, 1990.
- [GBFK98] Jens-Steffen Gutmann, Wolfram Burgard, Dieter Fox e Kurt Konolige. An experimental comparison of localization methods. Em *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 1998.
- [GF98] Jens-Steffen Gutmann e Dieter Fox. An experimental comparison of localization methods continued. Em *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 1998.
- [Goo11] Google Inc. Google Goggles. <http://www.google.com/mobile/goggles>, Abril 2011.
- [Gro07] Paul D. Groves. *Principles of GNSS, inertial, and multisensor integrated navigation systems*, volume 9. Artech House Publishers, 2007.
- [HAP02] Mudhafar Hassan-Ali e Kaveh Pahlavan. A new statistical model for site-specific indoor radio propagation prediction based on geometric optics and geometric probability. *IEEE Transactions on Wireless Communications*, 1(1):112–124, 2002.

- [HB07] Harlan Hile e Gaetano Borriello. Information overlay for camera phones in indoor environments. Em *Location-and context-awareness: third international symposium, LoCA 2007, Oberpfaffenhofen, Germany, September 20-21, 2007: proceedings*, páginas 68–84. Springer-Verlag New York Inc, 2007.
- [HB08] Harlan Hile e Gaetano Borriello. Positioning and Orientation in Indoor Environments Using Camera Phones. *IEEE Computer Graphics and Applications*, páginas 32–39, 2008.
- [HGL<sup>+</sup>09] Harlan Hile, Radek Grzeszczuk, Alan Liu, R. Vedantham, J. Košeccka e G. Borriello. Landmark-based pedestrian navigation with enhanced spatial reasoning. Em *Proceedings of the 7th International Conference on Pervasive Computing*, páginas 59–76. Springer, 2009.
- [HSS03] Andrew Howard, Sajid Siddiqi e Gaurav S Sukhatme. An Experimental Study of Localization Using Wireless Ethernet. Em *Proceedings of the 4th International Conference on Field and Service Robotics (FSR'03)*, páginas 1–6, 2003.
- [HVC<sup>+</sup>08] Harlan Hile, Ramakrishna Vedantham, Gregory Cuellar, Alan Liu, Natasha Gelfand, Radek Grzeszczuk e Gaetano Borriello. Landmark-based pedestrian navigation from collections of geotagged photos. *Proceedings of the 7th International Conference on Mobile and Ubiquitous Multimedia - MUM'08*, páginas 145–152, 2008.
- [IK07] Seigo Ito e Nobuo Kawaguchi. Wireless LAN based Vehicular Location Information Processing. *Biennial on DSP for in-Vehicle and Mobile Systems, M-10*, páginas 1–6, 2007.
- [JK01] Patric Jensfelt e Steen Kristensen. Active global localization for a mobile robot using multiple hypothesis tracking. *IEEE Transactions on Robotics and Automation*, 17(5):748–760, 2001.
- [Kal60] Rudolf E. Kalman. A new approach to linear filtering and prediction problems. *Journal of basic Engineering*, 82(1):35–45, 1960.
- [Kaw09] Nobuo Kawaguchi. WiFi Location Information System for Both Indoors and Outdoors. Em *Proceedings of the 10th International Work-Conference on Artificial Neural Networks: Part II: Distributed Computing, Artificial Intelligence, Bioinformatics, Soft Computing, and Ambient Assisted Living*, páginas 638–645. Springer, 2009.

- [KBO<sup>+</sup>05] Niklas Karlsson, Enrico D. Bernardo, Jim Ostrowski, Luis Goncalves, Paolo Pirjanian e Mario E. Munich. The vSLAM Algorithm for Robust Localization and Mapping. Em *Proc. IEEE Intl Conf. Robotics and Automation*, Barcelona, 2005.
- [KGMP05] Niklas Karlsson, Luis Goncalves, Mario E. Munich e Paolo Pirjanian. The vSLAM Algorithm for Navigation in Natural Environments. *Korean Robotics Society Review*, 2(1):51–67, 2005.
- [KGNM06] Gerold Kloos, Jose Guivant, Eduardo Nebot e Favio Masson. Range Based Localisation Using RF and the Application to Mining Safety. Em *2006 IEEE/RSJ International Conference on Intelligent Robots and Systems*, páginas 1304–1311, Outubro 2006.
- [KH04] John Krumm e Eric Horvitz. Locadio: Inferring motion and location from wi-fi signal strengths. Em *Proceedings of International Conference on Mobile and Ubiquitous Systems: Networking and Services (MobiQuitous' 04)*, páginas 4–13, 2004.
- [KHLH03] Antti. Kotanen, Marko Hannikainen, Helena Leppakoski e Timo D. Hamalainen. Experiments on local positioning with Bluetooth. *International Conference on Information Technology: Coding and Computing*, páginas 297–303, 2003.
- [KM08] Mikkel B. Kjærgaard e Carsten V. Munk. Hyperbolic Location Fingerprinting: A Calibration-Free Solution for Handling Differences in Signal Strength (concise contribution). Em *Pervasive Computing and Communications, 2008.*, páginas 110–116. IEEE, Março 2008.
- [KN07] Dennis Krys e Homayoun Najjaran. Development of Visual Simultaneous Localization and Mapping (VSLAM) for a Pipe Inspection Robot. *2007 International Symposium on Computational Intelligence in Robotics and Automation*, páginas 344–349, Junho 2007.
- [Lay11] Layar. Layar Reality Browser. <http://www.layar.com>, Abril 2011.
- [LCL06] Hyung S. Lim, Byoung S. Choi e Jang M. Lee. An Efficient Localization Algorithm for Mobile Robots based on RFID System. Em *SICE-ICASE, 2006. International Joint Conference*, páginas 5945–5950, 2006.
- [LDBL07] Hui Liu, Houshang Darabi, Pat Banerjee e Jing Liu. Survey of Wireless Indoor Positioning Techniques and Systems. *IEEE*

- Transactions on Systems, Man and Cybernetics, Part C (Applications and Reviews)*, 37(6):1067–1080, Novembro 2007.
- [LGK98] Jack M. Loomis, Reginald G. Golledge e Roberta L. Klatzky. Navigation system for the blind: Auditory display modes and guidance. *Presence: Teleoperators and Virtual Environments*, 7(2):193–203, 1998.
- [LHKB08] Alan L. Liu, Harlan Hile, Henry Kautz e Gaetano Borriello. Indoor wayfinding: Developing a functional interface for individuals with cognitive impairments. *Disability and Rehabilitation: Assistive Technology*, 3(1):69–81, Janeiro 2008.
- [LSDR06] Binghao Li, James Salter, Andrew G. Dempster e Chris Rizos. Indoor positioning techniques based on wireless LAN. Em *First IEEE International Conference On Wireless Broadband And Ultra Wideband Communications*, páginas 13–16, 2006.
- [LWL+05] Binghao Li, Yufei Wang, Hyung K. Lee, Andrew Dempster e Chris Rizos. Method for yielding a database of location fingerprints in WLAN. Em *IEE Proceedings: Communications*, páginas 580–586, 2005.
- [MET08] Răzvan Musăloiu-E e Andreas Terzis. Minimising the effect of wifi interference in 802.15. 4 wireless sensor networks. *International Journal of Sensor Networks*, 3(1):43–54, 2008.
- [MHP+11] Henrique Morimitsu, Marcelo Hashimoto, Rodrigo B. Pimentel, Roberto M. Cesar-Jr. e Roberto Hirata-jr. Keygraphs for Sign Detection in Indoor Environments by Mobile Phones. Em *Workshop on Graph-based Representations in Pattern Recognition*, 2011.
- [MLTL08] Jun Ma, Xuansong Li, Xianping Tao e Jian Lu. Cluster filtered KNN: A WLAN-based indoor positioning scheme. *2008 International Symposium on a World of Wireless, Mobile and Multimedia Networks*, páginas 1–8, Junho 2008.
- [MWBS09] Alessandro Mulloni, Daniel Wagner, Istvan Barakonyi e Dieter Schmalstieg. Indoor Positioning and Navigation with Camera Phones. *IEEE Pervasive Computing*, 8(2):22–31, Abril 2009.
- [PKC02] Phongsak Prasithsangaree, Prashant Krishnamurthy e Panos K. Chrysanthis. On Indoor Position Location with Wireless LANs.

- Proceedings of IEEE PIMRC 2002, volume 2, Lisbon, Portugal, September*, páginas 720–724, 2002.
- [RJ03] Thomas Röfer e Matthias Jüngel. Vision-based fast and reactive Monte-Carlo localization. Em *2003 IEEE International Conference on Robotics and Automation (Cat. No.03CH37422)*, páginas 856–861, 2003.
- [RSF<sup>+</sup>06] Nishkam Ravi, Pravin Shankar, Andrew Frankel, Ahmed Elgammal e Liviu Iftode. Indoor Localization Using Camera Phones. Em *Seventh IEEE Workshop on Mobile Computing Systems & Applications (WMCSA '06)*, páginas 19–34, 2006.
- [SCM10] Alberto Serra, Davide Carboni e Valentina Marotto. Indoor Pedestrian Navigation System Using a Modern Smartphone. Em *Mobile Human Computer Interaction 2010*, páginas 7–8, 2010.
- [SCMR04] Oscar Serrano, José M. Cañas, Vicente Matellán e Luis Rodero. Robot localization using WiFi signal without intensity map. Em *Workshop de Agentes Físicos 2004*, páginas 1–10, 2004.
- [SEP05] Juan M. Saez, Francisco Escolano e Antonio Peñalver. First steps towards stereo-based 6dof slam for the visually impaired. Em *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, páginas 23–30. IEEE Computer Society, 2005.
- [SG05] Pete Steggle e Stephan Gschwind. The Ubisense smart space platform. Em *Third International Conference on Pervasive Computing*, páginas 73–76, 2005.
- [Siv96] Devinderjit S. Sivia. *Data analysis: a Bayesian tutorial*. Oxford University Press, 1996.
- [SLL02] Stephen Se, David Lowe e Jim Little. Mobile robot localization and mapping with uncertainty using scale-invariant visual landmarks. *The International Journal of Robotics*, 21(8):735–758, 2002.
- [SSC90] Randall Smith, Matthew Self e Peter Cheeseman. *Estimating uncertain spatial relationships in robotics*, páginas 167–193. Springer-Verlag, 1990.
- [SSH03] Sajid M. Siddiqi, Gaurav S. Sukhatme e Andrew Howard. Experiments in Monte-Carlo Localization using WiFi Signal Strength. Em *Proceedings of the International Conference on Advanced Robotics*, pages, páginas 210–223, 2003.

- [TCC09] Arvin Wen Tsui, Yu-Hsiang Chuang e Hao-Hua Chu. Unsupervised Learning for Solving RSS Hardware Variance Problem in WiFi Localization. *Mobile Networks and Applications*, 14(5):677–691, Janeiro 2009.
- [TCG<sup>+</sup>08] Gabriel Takacs, Vijay Chandrasekhar, Natasha Gelfand, Yingen Xiong, Wei-Chao Chen, Thanos Bismpiagiannis, Radek Grzeszczuk, Kari Pulli e Bernd Girod. Outdoors augmented reality on mobile phone using loxel-based visual feature organization. *Proceeding of the 1st ACM international conference on Multimedia information retrieval - MIR '08*, páginas 427–434, 2008.
- [TFBD01] Sebastian Thrun, Dieter Fox, Wolfram Burgard e Frank Dellaert. Robust Monte Carlo localization for mobile robots. *Artificial Intelligence*, 128(1-2):99–141, Maio 2001.
- [TP10] Matthew Turk e Rémi Paucher. Location-based Augmented Reality on Mobile Phones. Em *IEEE International Workshop on Mobile Vision*, 2010.
- [WB95] Greg Welch e Gary Bishop. An introduction to the Kalman filter, 1995.
- [WEK05] Michael G. Wing, Aaron Eklund e Loren D. Kellogg. Consumer-grade global positioning system (GPS) accuracy and reliability. *Journal of Forestry*, 103(4):169–173, 2005.
- [WRMT08] Daniel Wagner, Gerhard Reitmayr, Alessandro Mulloni e T. Pose tracking from natural features on mobile phones. Em *Proceedings of IEEE/ACM International Symposium on Mixed and Augmented Reality*, páginas 125–134, Setembro 2008.
- [YA05] Moustafa Youssef e Ashok Agrawala. The Horus WLAN location determination system. Em *Proceedings of the 3rd international conference on Mobile systems, applications, and services*, páginas 205–218. ACM, 2005.
- [YMA07] Moustafa Youssef, Matthew Mah e Ashok Agrawala. Challenges: device-free passive localization for wireless environments. Em *Proceedings of the 13th annual ACM international conference on Mobile computing and networking*, páginas 222–229. ACM, 2007.

- [ZSS05] Rui Zhou, Gerhard Schneider e Dirk Von Suchodoletz. *Architecture And Implementation Of Indoor Wireless Positioning System*. M.sc., University of Freiburg, Germany, 2005.