

5

Testes

Neste capítulo apresentaremos alguns testes e avaliações que realizamos com o LIS. Nosso objetivo foi medir a precisão da inferência e avaliar questões como desempenho e escalabilidade do serviço. Descreveremos ainda alguns protótipos de aplicações sensíveis à localização que foram desenvolvidas com o auxílio do LIS.

Iniciaremos o capítulo descrevendo os cenários onde foram realizados os testes de precisão (Seção 5.1). Em seguida, na Seção 5.2, apresentaremos os resultados obtidos com os testes de precisão que realizamos com o serviço. Testes para medir o desempenho e a escalabilidade do serviço são apresentados na Seção 5.3. Por fim, apresentaremos alguns protótipos de aplicações desenvolvidas com o auxílio do serviço, Seção 5.4.

5.1

Cenários de Teste

Os testes de precisão foram realizados em dois ambientes diferentes, um *interno* e outro *externo*.

O primeiro cenário de teste (ambiente interno) foi o 5^o andar do Departamento de Informática da PUC-Rio, uma área de aproximadamente 500m². O ambiente é composto por salas de professores, corredores, banheiros, salas de aula, etc.

No ambiente estão disponíveis 8 pontos de acesso IEEE 802.11 que cobrem, com sobreposição de sinais, toda a região. Dois pontos de acesso apresentam variação de sinal bem reduzida (5dB). Outros 5 pontos de acesso apresentam variação de sinal entre 30 e 50dB e o último ponto de acesso apresenta variação de 11dB. Cada ponto de referência é, em média, coberto

por 4 pontos de acesso.

Nesse ambiente utilizamos o mapeamento geométrico uma vez que estava disponível a planta baixa do ambiente.

O segundo cenário de teste escolhido foi o ambiente conhecido como *Espaço Aberto*. Esse é um ambiente externo disponibilizado para a comunidade da PUC-Rio onde os usuários da rede costumam se concentrar devido à existência de cadeiras e mesas. O espaço aberto é uma área de aproximadamente $200m^2$, sendo uma parte coberta e outra parte ao ar livre (onde as mesas são cobertas apenas por sombrinhas). Ao redor ainda existe um jardim com plantas e árvores e há um grande movimento de pessoas no local.

Nesse ambiente é possível identificar 8 pontos de acesso diferentes. Quatro destes apresentam variação do sinal inferior a $5dB$. Os outros 4 pontos de acesso apresentam variação entre 10 e $23dB$. Cada ponto de referência é, em média, coberto por 3 pontos de acesso.

Para esse ambiente utilizamos o mapeamento simbólico dado que não tínhamos disponível a planta baixa do ambiente.

Coletamos, para cada cenário, dois conjuntos de dados, o primeiro foi usado no mapeamento do serviço e o segundo como pontos de teste. Os pontos de teste e referência foram escolhidos o mais próximo possível um do outro. Foram realizadas 25 varreduras, em quatro direções diferentes, para cada ponto de referência e teste, com um tempo de 1s entre cada varredura. Para uma avaliação mais real, os pontos de referência e teste foram coletados em dias e horários diferentes. Foram coletados um total de 62 pontos de referência, sendo 53 no “5^o Andar” e 9 no “Espaço Aberto”. Foram criadas um conjunto de 62 regiões simbólicas (atômicas), uma para cada ponto de referência, com $12m^2$ de área em média. Cada ponto de referência foi coletado no centro da região.

5.2

Testes de Precisão

O objetivo dos testes apresentados nesta seção é medir a precisão dos algoritmos e também analisar a influência dos diversos parâmetros do serviço na precisão da inferência.

Para cada tipo de teste será apresentada a percentagem de acerto da inferência em relação à região. Ou seja, o teste mede a percentagem de

vezes em que o sistema infere corretamente a região atômica do dispositivo móvel. Será apresentado também o erro percentil (95%, 90%, 70% e 50%) à distância, em centímetros, da coordenada inferida em relação à coordenada real do dispositivo. O erro percentil será mostrado somente nos cenários onde realizamos o mapeamento geométrico.

Cada teste foi realizado 50 vezes e os dados apresentados correspondem a uma média simples desses dados.

Os testes apresentados nas seções seguintes foram todos realizados no primeiro cenário de testes (ambiente interno). Os testes no ambiente externo serão mostrados na Seção 5.2.5.

Os parâmetros que avaliaremos nos testes são o número de vizinhos, o número de varreduras utilizadas no mapeamento e na inferência e o número de pontos de acesso.

5.2.1

Variações Temporais na Intensidade do Sinal

A inferência da localização se baseia na variação espacial da intensidade do sinal de rádio-freqüência. No entanto, ocorre também uma variação temporal na intensidade do sinal, que dificulta a inferência. Por isso, é importante conhecer a amplitude da variação que ocorre na intensidade do sinal em relação ao tempo.

Para analisar tais variações foram coletados sinais de um ponto de acesso durante o período de uma hora, a cada 1 segundo. Os histogramas mostrados na Figura 5.1 mostram as probabilidades da variação da intensidade do sinal para 10, 100 e 1.000 varreduras.

Pode-se notar que o período de tempo das medições não influencia de forma decisiva na variação da intensidade do sinal. Quando comparamos os histogramas para 100 e 1.000 varreduras, por exemplo, eles apresentam praticamente as mesmas probabilidades. Entretanto, a amplitude da variação na intensidade do sinal sugere que o modelo construído para os dados coletados deve refletir tais variações, ou seja, podemos determinar que o sistema deve usar mais que uma varredura, tanto para o mapeamento como para a inferência, para capturar tais variações.

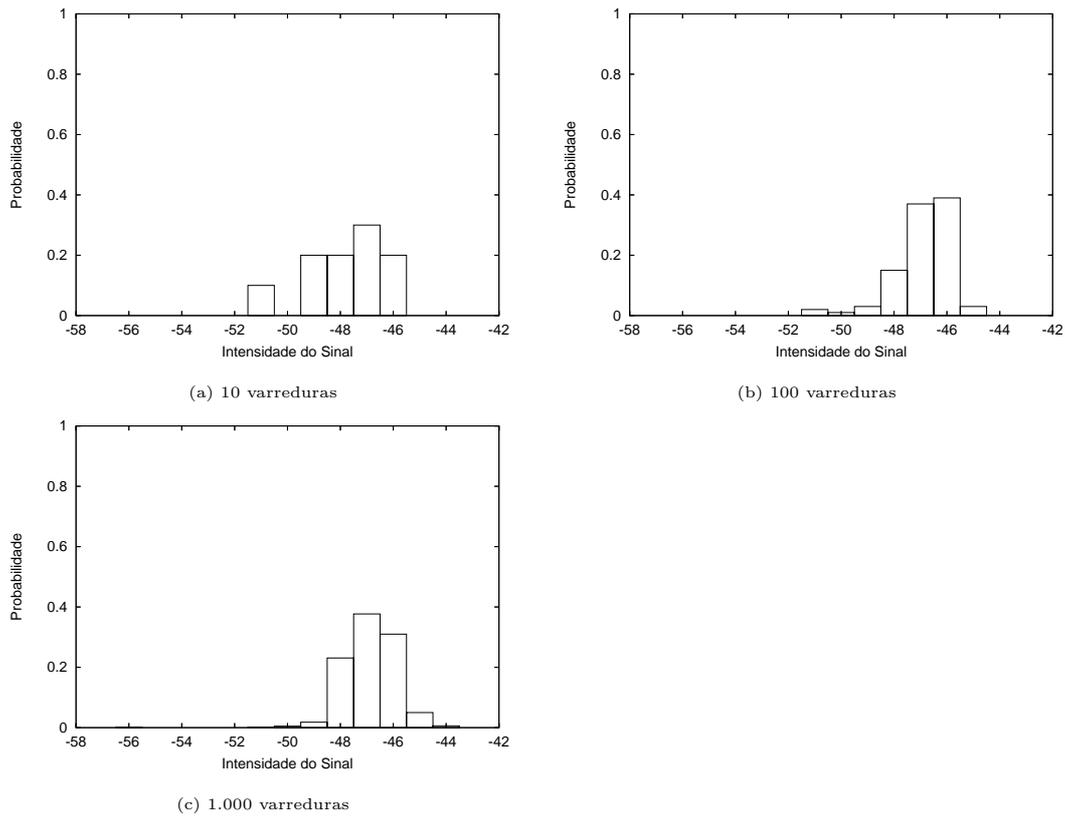


Figura 5.1: Probabilidades da intensidade de sinal para 10, 100 e 1.000 varreduras em um ponto de acesso.

5.2.2

Influência do Número de Vizinhos

O objetivo deste teste é medir a precisão em relação ao número de vizinhos usados no algoritmo.

A Figura 5.2 mostra a percentagem de acerto e a Tabela 5.1 o erro percentil, em centímetros, com relação ao número de vizinhos em cada um dos algoritmos. Para o teste foram utilizados 25 varreduras para o mapeamento e para a inferência.

Ao analisar os dados é fácil perceber que a precisão da inferência diminui com o aumento do número de vizinhos para ambos os algoritmos implementados. Esse fato pode ser explicado por dois motivos. Primeiro, os pontos de teste e referência foram mapeados o mais próximo possível um em relação ao outro. Dessa forma, caso o algoritmo de inferência selecione o ponto de referência fisicamente mais próximo ao ponto de teste a adição de vizinhos no cálculo da inferência apenas contribui para o ponto inferido se afastar do ponto de teste. Segundo, os pontos de referência foram escolhidos bastante

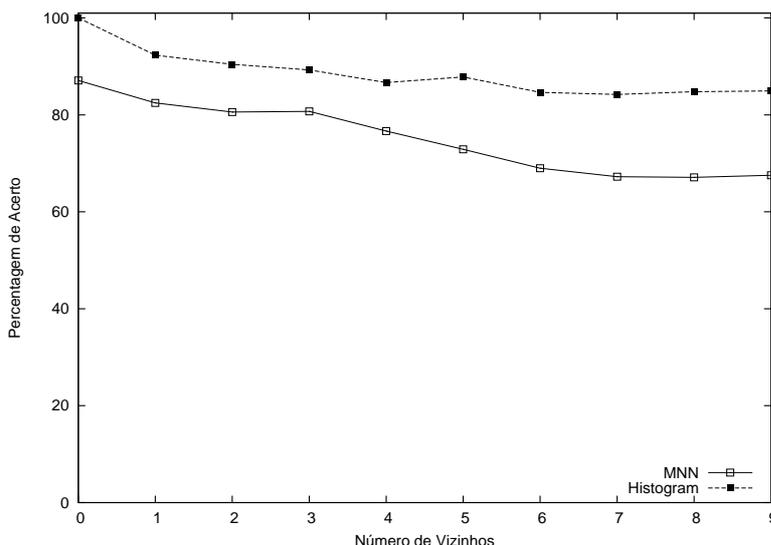


Figura 5.2: Influência do número de vizinhos na percentagem de acerto da região.

Número de Vizinhos	50%	70%	90%	95%
0	0.00	0.00	272.02	400.40
1	37.90	65.83	228.68	403.42
2	48.42	81.73	212.45	393.62
3	59.70	104.65	238.32	364.41
4	69.55	118.07	271.30	426.21
5	72.41	127.44	337.21	430.89
6	86.35	151.67	359.48	501.08
7	88.21	175.51	385.66	506.89
8	100.42	199.16	418.79	648.82
9	101.22	190.08	446.28	623.08

(a) MNN

Número de Vizinhos	50%	70%	90%	95%
0	0.00	0.00	2.27	4.54
1	31.45	47.94	118.87	203.79
2	38.71	60.36	137.27	202.53
3	39.89	68.23	138.55	218.70
4	46.92	73.94	153.79	230.03
5	47.93	75.21	164.24	272.29
6	47.65	81.13	171.87	267.52
7	50.30	80.41	178.21	268.64
8	47.40	79.13	163.75	273.15
9	48.36	80.22	174.30	258.36

(b) Histogram

Tabela 5.1: Influência do número de vizinhos no erro percentil.

distantes um do outro (em média 4 metros). Portanto, quanto mais vizinhos forem selecionados, maior será a probabilidade de o ponto inferido se distanciar do ponto real.

Analisando a Tabela 5.1, percebe-se que quando o número de vizinhos é igual a 0 o erro na inferência para vários valores de percentil é de 0.0cm. Isso acontece porque a inferência foi correta e o ponto de referência tem a mesma coordenada do ponto de teste. Como não são considerados pontos de referências vizinhos o erro é igual a zero.

A menos que seja especificado de outra forma, nos testes seguintes usaremos o valor de 1 para o número de vizinhos dos dois algoritmos. Nosso objetivo é garantir que o ponto inferido seja a média entre os dois pontos de referência mais próximos, semelhante ao caso em que tivéssemos coletados os pontos de testes o mais afastado possível dos pontos de referência, ou seja, o

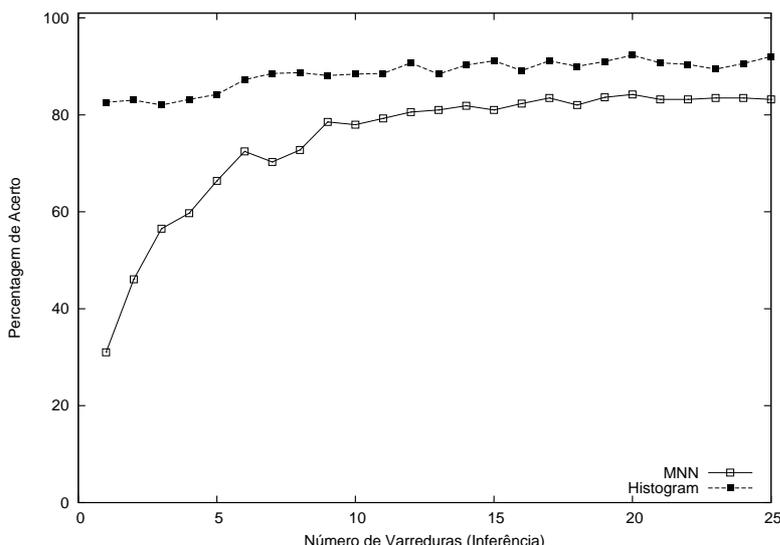


Figura 5.3: Influência do número de varreduras na inferência na percentagem de acerto da região.

pior caso para a inferência. Com isso, é eliminada a “vantagem” de utilizar pontos de referência e de testes muito próximos.

Os resultados de precisão obtidos deste teste são bastante satisfatórios. Quando utilizando o número de vizinhos igual a 1 foram obtidos erros em torno de 4m e 2m em 95% dos casos e em torno de 66cm e 48cm em 70% dos casos para os algoritmos *MNN* e *Histogram*, respectivamente.

5.2.3

Influência do Número de Varreduras

O objetivo deste teste é avaliar a precisão da inferência em relação ao número de varreduras utilizadas tanto para o mapeamento quanto para a inferência. Ou seja, queremos determinar o número de varreduras suficientes para o mapeamento e o tamanho do cache de varreduras que deve ser mantido para cada dispositivo na inferência.

A Figura 5.3 e a Tabela 5.2 mostram a percentagem de acerto e o erro percentil, em centímetros, como efeito da variação do número de varreduras na inferência para cada um dos algoritmos. Para este teste foram utilizados os seguintes parâmetros: número de vizinhos = 1 e número de varreduras no mapeamento = 25.

Analisando os gráficos da Figura 5.3 pode-se perceber que para o algo-

Número de Varreduras na Inferência	50%	70%	90%	95%	Número de Varreduras na Inferência	50%	70%	90%	95%
1	293.56	411.29	736.92	992.38	1	2.41	18.95	302.98	572.99
2	150.54	299.62	566.67	668.25	2	8.99	66.09	242.33	382.74
3	110.36	199.89	406.83	549.87	3	18.04	80.16	229.61	333.41
4	93.75	179.86	404.07	562.40	4	28.71	80.04	198.23	312.30
5	75.75	147.90	337.64	456.05	5	33.81	78.91	181.27	297.01
6	64.39	115.59	323.00	414.49	6	38.48	70.96	148.67	248.85
7	62.63	128.53	295.43	460.44	7	38.00	69.78	159.10	240.20
8	59.37	114.91	290.84	411.98	8	39.02	63.13	145.49	254.97
9	50.09	84.77	252.37	341.39	9	39.74	64.95	150.70	233.44
10	52.43	89.59	262.33	396.72	10	38.03	60.45	148.98	239.55
15	43.86	75.82	256.38	395.74	15	34.29	54.77	119.85	191.92
20	39.67	68.52	226.33	332.76	20	32.42	50.77	120.18	192.60
25	39.43	67.93	227.37	405.30	25	30.64	47.48	121.82	202.54

(a) MNN

(b) Histogram

Tabela 5.2: Influência do número de varreduras na inferência no erro percentil.

ritmo *MNN* a percentagem de acerto da região começa a estabilizar em 17 varreduras na inferência enquanto que no algoritmo *Histogram* a estabilização inicia em 12 varreduras na inferência. Isso nos leva a acreditar que o aumento no número de varreduras na inferência acima desses valores não deve acarretar em um aumento significativo na percentagem de acerto da região. Essa estabilização ocorre para o algoritmo *MNN* com percentagem de acerto por volta de 83% enquanto que para o algoritmo *Histogram* por volta de 90%.

Podemos perceber ainda na Tabela 5.2, que após 9 varreduras no algoritmo *MNN* o erro percentil de 95% não ultrapassa 4m enquanto no algoritmo *Histogram* esse erro fica abaixo de 2.5m.

Outro fator interessante a ser destacado, com base nesse gráfico, é que a percentagem de acerto da região para o algoritmo *Histogram* é pouco sensível ao número de varreduras na inferência, apresentando variação inferior a 11 pontos percentuais. Ao contrário, a percentagem de acerto da região do algoritmo *MNN* é bastante sensível ao número de varreduras na inferência, com uma variação maior que 50 pontos percentuais. Entretanto, ao analisar os dados da Tabela 5.2 percebemos que a pouca variação para o algoritmo *Histogram* na percentagem de acerto da região não se repete no erro percentil. Ou seja, para o algoritmo *Histogram* temos uma pequena variação na percentagem de acerto e uma alta variação no erro percentil. Tal fato pode ser explicado da seguinte maneira: apesar do erro percentil da inferência ser sensível a variações no número de varreduras na inferência o erro não é grande o suficiente para determinar que a inferência seja em outra região. Sendo assim, podemos deduzir que o número de varreduras na inferência e o tamanho das regiões é um importante fator na precisão da inferência.

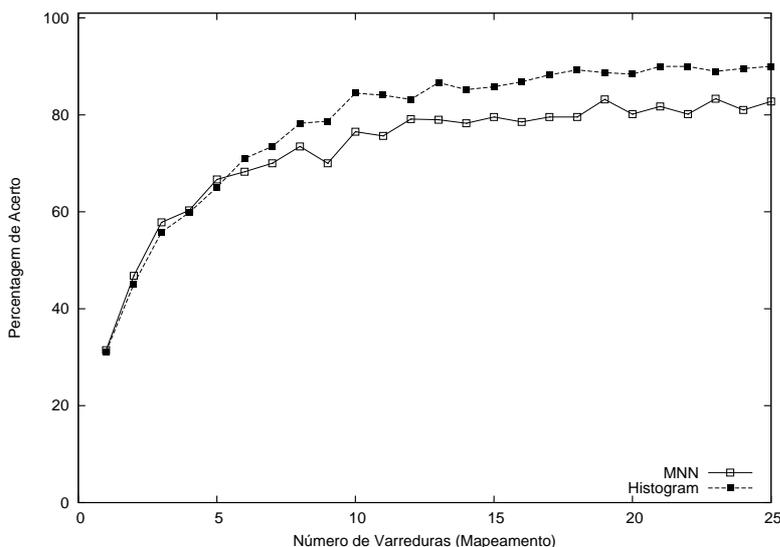


Figura 5.4: Influência do número de varreduras no mapeamento na percentagem de acerto da região.

A Figura 5.4 e a Tabela 5.3 mostram a percentagem de acerto e o erro percentil, em centímetros, como efeito da variação do número de varreduras no mapeamento para cada um dos algoritmos. Para este teste foram usados os seguintes parâmetros: número de vizinhos = 1 e número de varreduras na inferência = 15.

Analisando os dados nota-se que para ambos os algoritmos ocorre um crescente aumento na precisão da inferência com o aumento do número de varreduras no mapeamento. Nota-se ainda que após 15 varreduras a taxa de aumento diminui de forma considerável, entretanto, a taxa de aumento continua sendo representativa.

Pode-se concluir que o número de varreduras no mapeamento é um fator decisivo para a qualidade da inferência e que o número de varreduras no mapeamento é mais determinante da qualidade da inferência do que o número de varreduras na inferência.

Para uma melhor comparação da variação do número de varreduras no mapeamento e na inferência a Figura 5.5 e a Tabela 5.4 apresentam a percentagem de acerto e o erro percentil em 95% em relação ao número de varreduras no mapeamento para valores distintos (10, 15 e 25) no número de varreduras na inferência. Para este teste o número de vizinhos também é igual a 1.

Pode-se notar que o número de varreduras na inferência, 10, 15 ou 25,

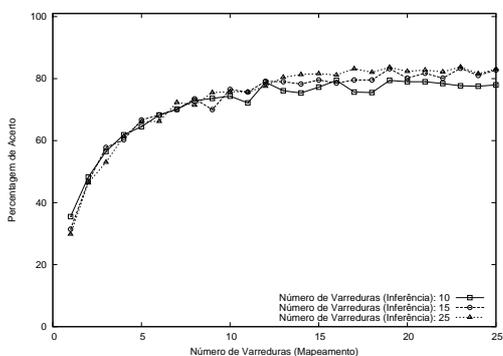
Número de Varreduras no Mapeamento	50%	70%	90%	95%
1	291.16	453.64	773.72	931.27
2	141.53	354.90	684.82	819.31
3	91.25	235.50	606.12	691.47
4	79.87	155.12	447.81	648.35
5	63.33	135.08	429.58	632.79
6	62.63	128.21	429.81	631.30
7	54.44	103.96	394.88	557.03
8	50.77	100.10	425.11	608.40
9	54.68	108.16	372.83	610.53
10	50.10	88.96	275.85	416.82
15	46.74	80.55	251.13	411.50
20	43.86	75.71	261.85	440.55
25	47.94	75.97	209.87	288.75

(a) MNN

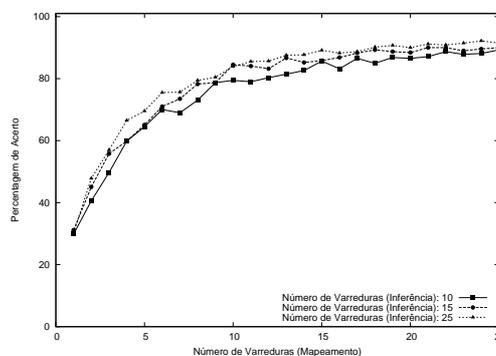
Número de Varreduras no Mapeamento	50%	70%	90%	95%
1	267.69	427.08	898.05	1153.46
2	164.09	279.94	537.81	728.46
3	129.32	209.45	442.59	589.31
4	105.34	180.20	351.68	466.05
5	96.82	154.55	293.43	396.84
6	81.34	125.09	267.52	348.75
7	72.42	117.90	241.80	333.55
8	66.79	108.66	213.63	330.59
9	63.20	104.17	209.20	294.86
10	57.78	88.17	183.08	278.43
15	47.03	74.53	170.54	228.28
20	41.66	60.72	149.70	232.73
25	36.30	55.11	128.48	212.76

(b) Histogram

Tabela 5.3: Influência do número de varreduras no mapeamento no erro percentil.



(a) MNN



(b) Histogram

Figura 5.5: Influência do número de varreduras no mapeamento com 10, 15 e 25 varreduras na inferência na percentagem de acerto da região.

pouco influencia na percentagem de acerto da região dos algoritmos. Mais uma vez nota-se a diferença de precisão entre o erro percentil e a percentagem de acerto da região.

Outro fator interessante a comentar é que a pouca variação existente na porcentagem de acerto no gráfico da Figura 5.3 no algoritmo *Histogram* não ocorre no gráfico da Figura 5.5(b). Isto é um indício de que a inferência é bastante sensível ao número de varreduras no mapeamento e pouco sensível ao número de varreduras na inferência. Tal fato pode ser explicado porque quanto maior o número de varreduras no mapeamento maior será a possibilidade de modelar a intensidade do sinal da forma mais correta possível. Ao contrário, quando o número de varreduras no mapeamento é pequeno, a modelagem da intensidade do sinal pode ser falha. Desta forma, não importa o número de varreduras na inferência, já que esses dados estarão sendo comparados a um

Número de Varreduras no Mapeamento / Inferência	10	15	25
1	917.94	931.27	954.26
2	755.96	819.31	815.68
3	754.91	691.47	794.16
4	643.60	648.35	663.05
5	593.72	632.79	655.32
6	620.87	631.30	647.55
7	533.57	557.03	619.89
8	494.14	608.40	619.18
9	441.79	610.53	618.92
10	470.67	416.82	427.08
15	406.62	411.50	481.10
20	413.82	440.55	419.91
25	411.14	288.75	395.47

(a) MNN

Número de Varreduras no Mapeamento / Inferência	10	15	25
1	1090.21	1153.46	1054.71
2	764.33	728.46	701.56
3	594.25	589.31	527.73
4	525.50	466.05	443.50
5	453.86	396.84	335.99
6	396.30	348.75	332.22
7	376.43	333.55	289.37
8	309.52	330.59	307.30
9	319.60	294.86	269.58
10	287.92	278.43	255.57
15	287.73	228.28	222.23
20	216.76	232.73	194.23
25	214.83	212.76	194.17

(b) Histogram

Tabela 5.4: Influência do número de varreduras no mapeamento com 10, 15 e 25 varreduras na inferência no erro percentil em 95%.

modelo pouco preciso.

5.2.4

Influência do Número de Pontos de Acesso

O objetivo deste teste é avaliar a precisão da inferência em relação ao número de pontos de acesso utilizados.

Para realizarmos esse teste variamos o número de pontos de acesso de 1 até 8, o número máximo de pontos de acesso disponíveis. Dado que cada ponto de acesso apresenta um padrão diferente de variação na intensidade do sinal, é evidente que a escolha dos pontos de acesso a serem considerados influencia de forma decisiva a precisão do resultado. Portanto, uma questão importante a considerar para os testes seria a escolha do conjunto de pontos de acesso.

Sendo assim, resolvemos inicialmente classificar os pontos de acesso em relação à precisão da inferência. Para isto, executamos testes de inferência considerando cada um dos pontos de acesso individualmente. Ou seja, executamos um conjunto de testes onde foi considerado somente um ponto de acesso por vez. Com os resultados, os pontos de acesso foram classificados em relação à percentagem de acerto na inferência, conforme mostrado na Figura 5.6.

De posse desses dados resolvemos realizar dois tipos de teste em relação ao número de pontos de acesso. O primeiro teste varia o número de pontos de acesso escolhendo primeiro os melhores, ou seja, para o teste com um ponto de acesso é escolhido o ponto de acesso com a melhor precisão, com dois pontos

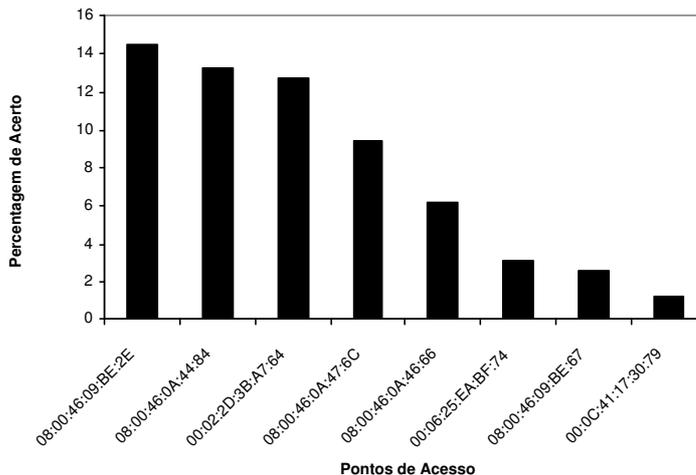


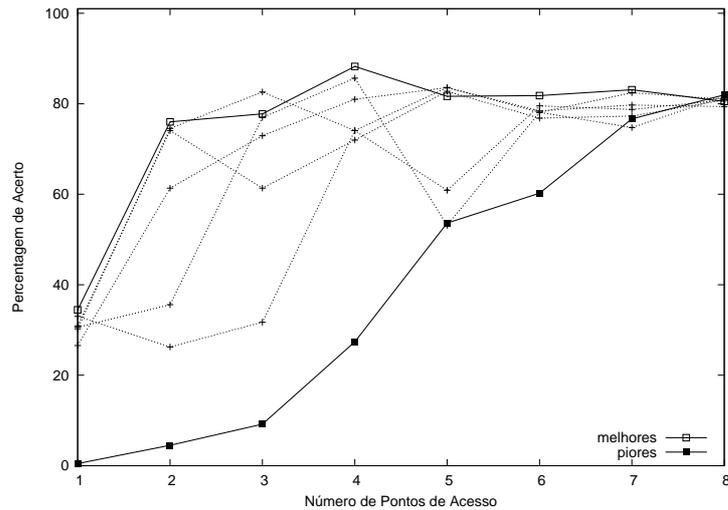
Figura 5.6: Classificação dos pontos de acesso em relação à precisão da inferência.

de acesso, os dois melhores, e assim por diante. Isso deve nos fornecer uma estimativa do melhor caso em relação ao número de pontos de acesso. Para obtermos o pior caso executamos novamente o mesmo teste, agora escolhendo os pontos de acesso de forma inversa, ou seja, primeiro o pior, depois o segundo pior e assim sucessivamente. Com esses dois testes esperamos obter os limites superior e inferior da precisão da inferência em relação número de pontos de acesso.

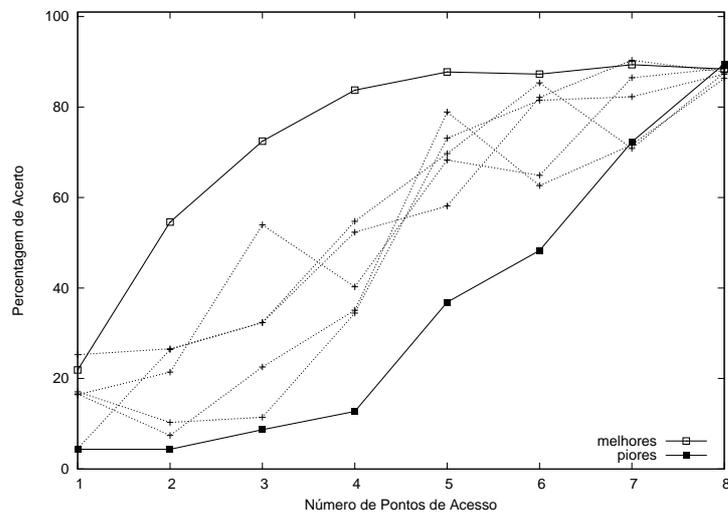
A Figura 5.7 mostra os resultados encontrados para esses dois testes. Além dos testes descritos acima ainda realizamos cinco execuções dos mesmos testes escolhendo os pontos de acesso de forma aleatória. Esses dados também são mostrados no gráfico e podemos visualizar que os mesmos situam-se dentro da região delimitada pelas duas curvas dos dois testes (seqüência de melhores e piores), como esperado. Isso ocorre já que as escolhas anteriores foram os melhores e piores pontos de acesso que representam os limites superior e inferior da precisão.

Podemos concluir dos testes que a fase de mapeamento é de extrema importância para a precisão dos algoritmos, e quanto maior o número de varreduras usadas nessa fase, melhor será a inferência.

Os testes demonstraram também que o algoritmo *Histograma* é definitivamente mais robusto que o *MNN*. Em todos os testes realizados o algoritmo do *Histograma* mostrou resultados bem superiores ao *MNN*.



(a) MNN



(b) Histogram

Figura 5.7: Influência do número de pontos de acesso na precisão.

5.2.5

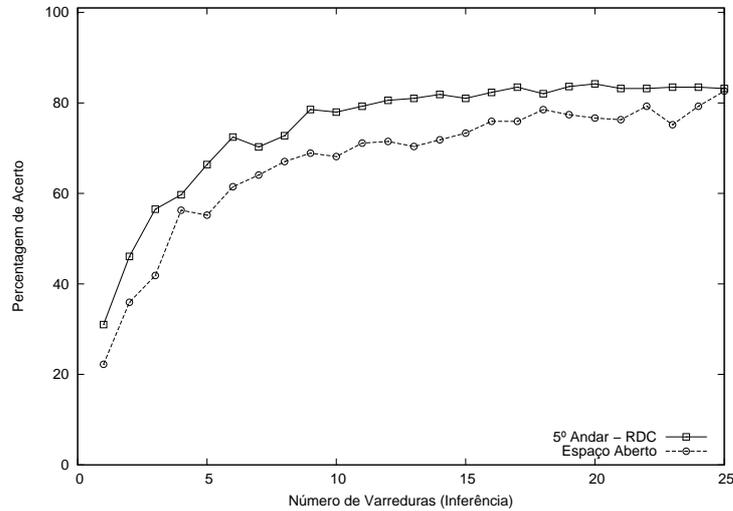
Testes em Ambiente Externo

Os mesmos testes de precisão foram realizados com os dados coletados no ambiente externo “Espaço Aberto”. Os resultados encontrados são bastante semelhantes. Entretanto, a precisão na inferência para o ambiente “Espaço Aberto” apresenta resultados um pouco piores.

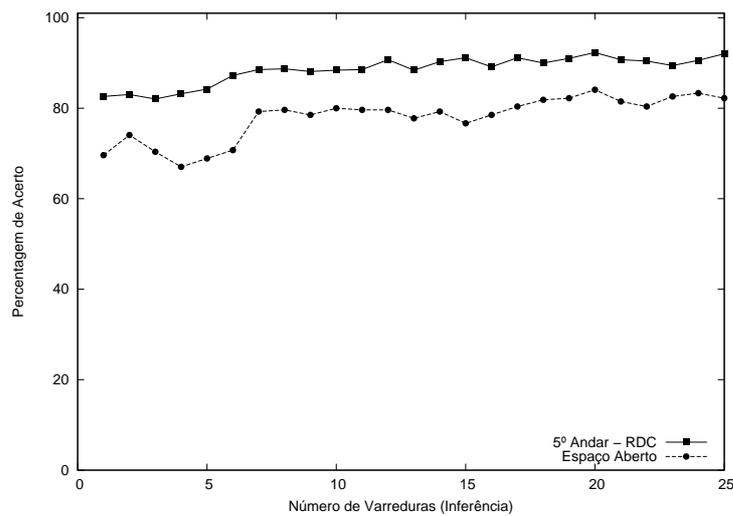
Essa diferença na precisão pode ser explicado pelo fato de que no “Espaço Aberto” o número de pontos de acesso audíveis em cada ponto de referência é menor (3) que no cenário interno (4).

A Figura 5.8 mostra a percentagem de acerto como efeito da variação do

número de varreduras na inferência para cada um dos algoritmos. Para uma comparação entre os dois cenários, são também apresentadas as curvas mostradas na Figura 5.3. Para este teste foram utilizados os seguintes parâmetros: número de vizinhos = 1 e número de varreduras no mapeamento = 25.



(a) MNN



(b) Histogram

Figura 5.8: Influência do número de varreduras na inferência na percentagem de acerto da região para o cenário “Espaço Aberto”.

5.3

Testes de Desempenho e Escalabilidade

Nesta seção descrevemos alguns testes que realizamos com o propósito de medir o desempenho e a escalabilidade do serviço. Nestes testes utilizamos duas

máquinas, uma para executar o servidor do LIS e outra para simular os clientes. A configuração das máquinas que utilizamos foram um computador Pentium IV 2.4Mhz, 512Mb de memória RAM com sistema operacional Windows XP.

Para facilitar a implementação dos nossos testes nós utilizamos a ferramenta AspectJ para instrumentar o código com instruções para anotar o tempo de processamento em diversas partes do código.

5.3.1 Em Relação ao Número de Clientes Simultâneos

O primeiro testes que realizamos foi para medir o tempo de uma requisição em função do número de clientes simultâneos acessando o serviço.

A Figura 5.9 mostra o tempo de resposta variando o número de requisições simultâneas de 1 até 150 atendidas pelo serviço. A requisição atendida pelo serviço é a `String[] getDevices(String regionId)`. Essa requisição é a que demanda maior processamento por parte do serviço.

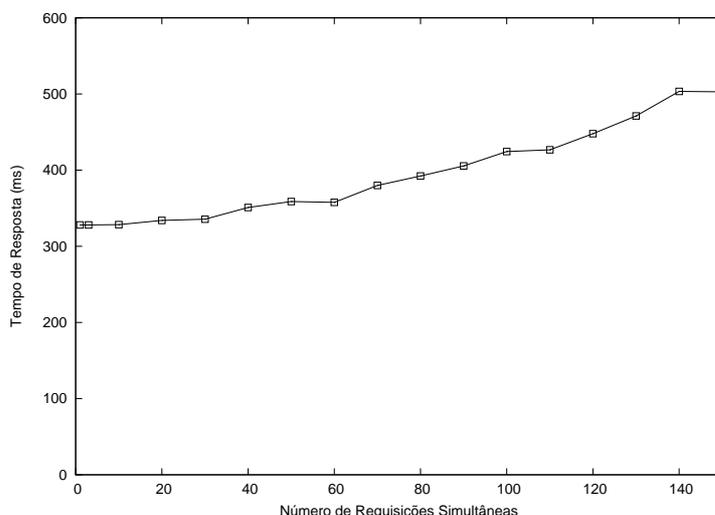


Figura 5.9: Efeito do número de requisições simultâneas no tempo de resposta.

Os resultados mostram um aumento praticamente linear do tempo de resposta com o aumento do número de requisições simultâneas. Considerando um número de 15000 clientes dos quais 1% fazem requisições simultâneas o LIS é capaz de responder requisições em $500ms$ em média.

5.3.2

Em Relação ao Número de Monitores

O objetivo deste teste é medir como o serviço se comporta em relação ao número de dispositivos móveis sendo monitorados.

A Figura 5.10 mostra o tempo de processamento da inferência da localização variando o número de monitores sendo atendidos pelo serviço. O número de monitores foi definido como sendo a quantidade de monitores que é atendida por segundo. Para os testes configuramos os monitores com a periodicidade de envio das informações em 1s.

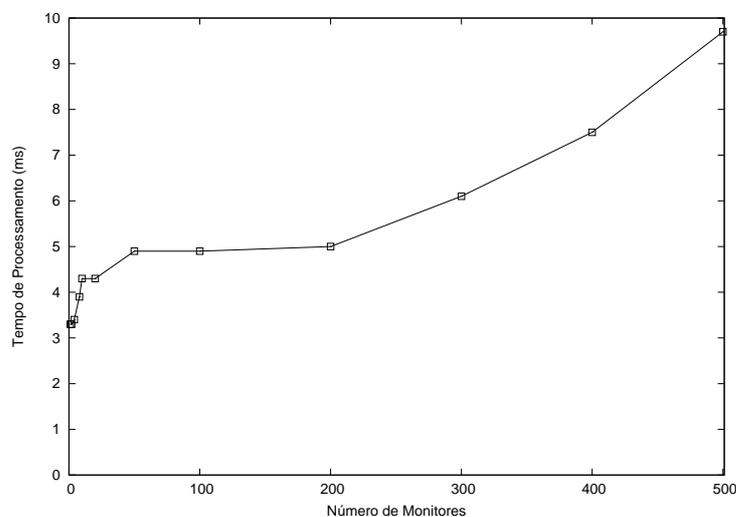


Figura 5.10: Efeito do número de monitores no tempo de processamento do cálculo da inferência.

Podemos ver na Figura 5.10 que o serviço é capaz de atender 500 monitores com um tempo de processamento abaixo de $10ms$ (desconsiderando a latência da rede). Com base nesses valores podemos prever o tempo de processamento em relação a diversas configurações de periodicidade do envio das informações. Por exemplo, aumentando a periodicidade de envio das informações para $5s$, aumentaríamos o número de monitores para 2500, mantendo o mesmo tempo de processamento.

Os testes de desempenho mostram que o LIS é possível de ser utilizado em um ambiente real de aplicações. Na próxima Seção mostraremos alguns protótipos de aplicações já desenvolvidas com o serviço.

5.4

Aplicações

O LIS está sendo utilizado por outros grupos para o desenvolvimento de protótipos de aplicações conscientes de localização. Os protótipos de aplicações desenvolvidos com o auxílio do LIS são as seguintes:

Notes in the Air (NITA) é uma aplicação para a postagem de mensagens de texto (e arquivos em geral) para uma região simbólica. A região simbólica faz o papel de um quadro de avisos virtual. Usuários que entram nesta região e estão devidamente autorizados, irão automaticamente receber as mensagens postadas à região. Uma segunda funcionalidade é a comunicação síncrona, que é uma sala de bate papo restrita a usuários presentes em uma mesma região simbólica.

BuddySpaceLive é uma extensão de uma aplicação de mensagens instantâneas que implementa “mapas vivos” (*live maps*). “Mapas vivos” são mapas que atualizam automaticamente a localização de pessoas presentes em sua lista de contatos.

Wireless Marketing Service (WMS) habilita lojas e companhias a enviarem cupons de descontos eletrônicos para uma região específica. Usuários móveis que visitarem esta região são capazes de receber tais cupons, que comprovam a presença do usuário na localização e não são forjáveis.

Mobile Matchmaking Service (MMS) permite a usuários descobrirem parceiros com perfis ou interesses similares em um dado local. O serviço auxilia o *matchmaking* de usuários baseados em sua localização e interesses comuns. A *matching* da localização é realizado com relação à região simbólica do usuário.

Virtual Lines é um sistema que controla filas virtuais em parques temáticos. O principal objetivo da aplicação é evitar que pessoas percam tempo em filas de atrações, permitindo visitar outros lugares ou atrações do parque. Com o auxílio do sistema usuários necessitam somente passar perto de uma atração que queiram participar para receber um bilhete virtual para a atração. O bilhete comporta-se como um lugar na fila virtual administrada pelo sistema. A interface do sistema no dispositivo móvel do usuário mostra todas as atrações do parque e informações sobre as filas virtuais nas quais o usuário está inscrito.

O sistema também é capaz de alertar o usuário quando a sua vez em uma determinada atração está próxima. Dessa forma, o usuário pode se encaminhar à atração a tempo de assumir seu lugar na fila real. Caso o usuário não retorne em tempo para uma atração, o sistema avisa-o que ele perdeu o lugar na fila.

Who Are You? (WAY) é uma aplicação *peer-to-peer* com a capacidade de permitir a usuários a percepção de outros usuários na sua vizinhança e a troca de cartões de visita eletrônicos entre os vizinhos.