

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
DE AUTOMAÇÃO E SISTEMAS**

Ezequiel Conte

**ALGORITMOS DE ANÁLISE DE CENA PARA
LOCALIZAÇÃO INDOOR VIA REDES IEEE 802.11**

Florianópolis

2015

Ezequiel Conte

**ALGORITMOS DE ANÁLISE DE CENA PARA
LOCALIZAÇÃO INDOOR VIA REDES IEEE 802.11**

Dissertação submetida ao Programa
de Pós-Graduação em Engenharia de
Automação e Sistemas para a obtenção
do Grau de Mestre em Engenharia de
Automação e Sistemas.

Orientador: Prof. Jean-Marie Farines

Florianópolis

2015

Catálogo na fonte elaborada pela biblioteca da
Universidade Federal de Santa Catarina

A ficha catalográfica é confeccionada pela Biblioteca Central.

Tamanho: 7cm x 12 cm

Fonte: Times New Roman 9,5

Maiores informações em:

<http://www.bu.ufsc.br/design/Catalogacao.html>

Ezequiel Conte

**ALGORITMOS DE ANÁLISE DE CENA PARA
LOCALIZAÇÃO INDOOR VIA REDES IEEE 802.11**

Esta Dissertação foi julgada aprovada para a obtenção do Título de “Mestre em Engenharia de Automação e Sistemas”, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Automação e Sistemas.

Florianópolis, 4 de março 2015.

Prof. Rômulo Silva de Oliveira
Coordenador

Prof. Jean-Marie Farines
Orientador

Banca Examinadora:

Prof. Jean-Marie Farines
Presidente

Prof. Leandro Buss Becker

Prof. Carlos Barros Montez

Prof. Gustavo Medeiros de Araújo

À minha família

AGRADECIMENTOS

Dedico este trabalho à minha esposa Catherine que sempre esteve ao meu lado, apoiando e até abdicando de momentos para me auxiliar.

Dedico ao meu filho Victor, que futuramente vai conhecer este trabalho e, espero, usar como incentivo para seus estudos e conquistas.

Ao meu pai, minha mãe, meu irmão e minha sogra, que sempre incentivaram e me deram a motivação para seguir em frente.

Ao meu amigo Eduardo Brito, que não mediu esforços, desde o início, para que eu prosseguisse com o trabalho.

Ao meu orientador, que com seu trabalho e conhecimento, me auxiliou ao longo dessa caminhada.

Aos professores, que desde os anos primários despertaram em mim o desejo de buscar conhecimento e superar desafios.

A todos os que contribuíram com sugestões, críticas ou dicas e que de alguma forma colaboraram com o trabalho.

*A educação é a ferramenta mais poderosa
que podemos usar para mudar o mundo.*

Nelson Mandela

RESUMO

Sistemas de localização global já fazem parte do cotidiano das pessoas. O GPS é usado diariamente para guiar condutores, localizar equipamentos e monitorar atividades externas. Porém, a localização indoor ainda se mostra como um problema. Tecnologias distintas possuem vantagens em determinadas situações, porém nenhuma sobressai como solução definitiva. As redes IEEE 802.11 são frequentemente utilizadas para desempenhar essa função sendo que o algoritmo de análise de cena, que mapeia previamente os níveis de sinais do ambiente, é o que vem fornecendo os melhores resultados. O presente estudo apresenta um sistema de posicionamento indoor utilizando um algoritmo de análise de cena, acrescido de estratégias para minimizar algumas de suas desvantagens. Modificações foram propostas e avaliadas, como a atribuição de fator de qualidade para os pontos coletados, o uso de filtro de Kalman e a utilização do histórico de movimentação na estimativa. Os resultados mostram as melhorias obtidas em termos de precisão na estimativa de posição, em particular para o algoritmo baseado no histórico de movimentação.

Palavras-chave: Localização Indoor. Posicionamento Indoor. Ambientes Fechados.

ABSTRACT

Global Positioning Systems are part of daily life. GPS is used everyday to guide drivers, find equipments and track outdoor activities. However Indoor Location is still an open topic. Distinct technologies are being analyzed and each one has its own advantages, although no one is considered the best solution. IEEE 802.11 networks are frequently chosen for this task and fingerprinting algorithm is providing the best results. This study describes a fingerprinting based indoor location system where modifications were introduced in order to mitigate some of its drawbacks. A quality factor was attributed to each collected point, Kalman filter was used and historical location was taken in consideration during estimation process. The results show a more accurate location estimation, especially when considering the historical location. **Keywords:** Indoor Location. Indoor Positioning. Wireless Location.

LISTA DE FIGURAS

Figura 1	Percentual de permanência em ambientes indoor vs outdoor.....	29
Figura 2	Componentes de um Sistema de Posicionamento Indoor.....	30
Figura 3	Cálculo através da trilateração.....	38
Figura 4	Mapa do sinal de um ponto de acesso (dBm).....	41
Figura 5	Variação da distância estimada devido à variação da potência de sinal.....	44
Figura 6	Centroide calculado com: (a) média simples; (b) média ponderada por D; (c) média ponderada por Q.....	54
Figura 7	Representação esquemática do filtro de Kalman (AIUBE, 2005).....	55
Figura 8	Raio de busca para Histórico de Movimentação.....	58
Figura 9	Fluxograma do algoritmo Histórico de Movimentação.....	60
Figura 10	Arquitetura do sistema para o aplicativo smartphone.....	63
Figura 11	Aplicativo realizando coleta de sinais.....	64
Figura 12	Aplicativo estimando posição em tempo real.....	65
Figura 13	Crachá WiFi.....	66
Figura 14	Hardware do Crachá WiFi.....	67
Figura 15	Arquitetura do módulo RN-171 - Microchip.....	67
Figura 16	Duração da bateria do Crachá WiFi.....	68
Figura 17	Arquitetura do sistema para o Crachá WiFi.....	69
Figura 18	Mapa em tempo real com a localização dos crachás.....	70
Figura 19	Mapa de calor das áreas com maior circulação.....	70
Figura 20	Piso térreo do cenário de testes A.....	71
Figura 21	Primeiro andar do cenário de testes A.....	72
Figura 22	Caminho realizado e estimativas para Percurso 1.....	78
Figura 23	Função distribuição acumulada do erro para o Percurso 1.....	80
Figura 24	Caminho realizado e estimativas para Percurso 2.....	81
Figura 25	Função distribuição acumulada do erro para o Percurso 2.....	82
Figura 26	Função distribuição acumulada do erro para o Percurso 2 com áreas de exclusão.....	83

Figura 27 Caminho realizado e estimativas para Percurso 3.....	84
Figura 28 Função distribuição acumulada do erro para o Percurso 3.....	85

LISTA DE TABELAS

Tabela 1	Comparativo entre tecnologias de posicionamento indoor	35
Tabela 2	Comparação de resultados entre os algoritmos.	73
Tabela 3	Resultados com variação no parâmetro Threshold.	74
Tabela 4	Resultados ao variar cálculo de centroide.	75
Tabela 5	Resultados da proposta Fator de Qualidade.	76
Tabela 6	Resultados dos algoritmos para o Percurso 1.	79
Tabela 7	Resultados dos algoritmos para o Percurso 2.	81
Tabela 8	Resultados para o Percurso 2 com áreas de exclusão.	82
Tabela 9	Resultados dos algoritmos para o Percurso 3.	85

LISTA DE ABREVIATURAS E SIGLAS

GPS	Global Positioning System	25
IEEE	Institute of Electrical and Electronics Engineers	26
RFID	Radio-Frequency Identification	26
UWB	Ultra Wide Band	26
UHF	Ultra High Frequency	26
UTM	Universal Transverse Mercator	31
DSSS	Direct Sequence Spread Spectrum	42
FHSS	Frequency Hopping Spread Spectrum	42
ISM	Industrial, Scientific and Medical	42
AP	Access Point	42
RSSI	Received Signal Strength Indicator	42
NN	Nearest Neighbour	43
kNN	k-Nearest Neighbours	43
wkNN	weighted k-Nearest Neighbours	43

SUMÁRIO

1 INTRODUÇÃO	25
1.1 OBJETIVOS	26
1.2 RESULTADOS ESPERADOS	27
1.3 ESTRUTURA DA DISSERTAÇÃO	27
1.4 CONTEXTUALIZAÇÃO	27
2 SISTEMAS DE POSICIONAMENTO INDOOR	29
2.1 ASPECTOS GERAIS DE UM SISTEMA DE POSICIONAMENTO INDOOR	30
2.1.1 Componentes	30
2.1.2 Tipos de Localização	31
2.1.3 Topologias	32
2.1.4 Tecnologias	32
2.1.4.1 GPS	32
2.1.4.2 GSM	33
2.1.4.3 Bluetooth	33
2.1.4.4 ZigBee	33
2.1.4.5 RFID	34
2.1.4.6 UWB	34
2.1.4.7 WiFi	34
2.1.4.8 Análise Comparativa	35
2.1.5 Segurança e Privacidade	36
2.2 ALGORITMOS DE POSICIONAMENTO	37
2.2.1 Proximidade	37
2.2.2 Trilateração	38
2.2.3 Análise de Cena	40
2.3 POSICIONAMENTO INDOOR VIA REDES IEEE 802.11 ..	42
2.4 CONCLUSÃO	45
3 PROPOSTAS DE ALGORITMOS DE ANÁLISE DE CENA	47
3.1 ALGORITMO DE ANÁLISE DE CENA COM WKNN	47
3.1.1 Fase Offline	48
3.1.2 Fase Online	49
3.2 PROPOSTAS PARA UM SISTEMA DE POSICIONAMENTO INDOOR	52
3.2.1 Proposta de um Algoritmo de Análise de Cena Baseado no Fator de Qualidade	52

3.2.2 Proposta de um Algoritmo de Análise de Cena Baseado no Filtro de Kalman	54
3.2.3 Proposta de um Algoritmo de Análise de Cena Baseado no Histórico de Movimentação	57
3.2.4 Conclusão	59
4 AVALIAÇÃO DAS PROPOSTAS	61
4.1 METODOLOGIA E AMBIENTE DE EXPERIMENTAÇÃO	61
4.1.1 Metodologia de Avaliação	61
4.1.2 Arquitetura do Sistema	62
4.1.2.1 Aplicativo para Smartphone	63
4.1.2.2 Crachá WiFi	65
4.1.2.3 Servidor Web	69
4.1.3 Cenários de Testes	71
4.2 AVALIAÇÃO DA INFLUÊNCIA DOS PARÂMETROS NO ALGORITMO WKNN	72
4.2.1 Algoritmos e valor de K	73
4.2.2 Threshold	74
4.2.3 Centroide	75
4.2.4 Conclusão	75
4.3 ANÁLISE DE CENA COM FATOR DE QUALIDADE	75
4.4 ANÁLISE DE CENA COM FILTRO DE KALMAN E HISTÓRICO DE MOVIMENTAÇÃO	77
4.4.1 Percurso 1	77
4.4.2 Percurso 2	80
4.4.3 Percurso 3	83
4.5 ANÁLISE DOS RESULTADOS	86
5 CONCLUSÃO	87
REFERÊNCIAS	91

1 INTRODUÇÃO

Recentemente há um crescente interesse em sistemas de posicionamento e localização. Além de utilizações tradicionais como militar, industrial e governamental, cada vez mais equipamentos pessoais apresentam esta capacidade. As aplicações são as mais variadas e permeiam distintas áreas, abrangendo desde agrimensura à navegação veicular.

O Sistema de Posicionamento Global (GPS - *Global Positioning System*) é a principal tecnologia usada para este fim, porém não provê geoposicionamento com precisão em ambientes indoor (PAHLAVAN; LI; MAKELA, 2002). Os sinais emitidos pelos satélites sofrem atenuação em ambientes fechados e subterrâneos. Além disso, há imprecisões próximo à árvores e “canyons” urbanos, devido ao bloqueio da linha de visão com o satélite e à propagação multi-caminho (OTSASON et al., 2005).

Por outro lado, as pessoas passam em média 90% de seu tempo em ambientes indoor (REPACE; LOWREY, 1980). E são nessas áreas onde a maioria das interações acontecem. Para atender a estes ambientes, faz-se necessário a utilização de um Sistema de Posicionamento Indoor.

Os Sistemas de Posicionamento Indoor possuem características únicas e aplicações em várias áreas, como comercial e de segurança pública. Sua utilização pode ser exemplificada no uso em hospitais e abrigos onde seria aplicado na localização de pessoas com necessidade de atenção especial, como idosos e crianças. Além disso, auxiliaria na localização de equipamentos médicos, que são transportados entre salas de atendimento além da localização de médicos especialistas em casos de emergência. Mais exemplos seriam o suporte à navegação em museus e shoppings centers, localização de pessoas em grandes eventos e a localização de objetos em armazéns, aumentando a eficiência e produtividade.

Também vale citar o valor desta tecnologia para o auxílio à navegação de robôs e a localização de dispositivos em uma rede de sensores. Apesar de serem nomeados indoor, estes sistemas não se restringem a ambientes fechados, abrangendo também áreas externas limitadas, como por exemplo, um campus universitário.

Várias tecnologias vêm sendo investigadas para resolver o problema de posicionamento indoor. As mais utilizadas são Identificação por Radiofrequência - RFID, Ultra Wide Band – UWB, Bluetooth e WiFi (IEEE 802.11) (LIU et al., 2007). Dentre elas, as redes IEEE 802.11 se destacam, principalmente devido o atual grau de adoção pelo

mercado, reduzindo custos de implantação e a disponibilidade em dispositivos pessoais.

O método mais utilizado para posicionamento indoor através de redes IEEE 802.11 é a utilização da indicação da potência do sinal (Received Signal Strength Indicators - RSSI) em conjunto com um algoritmo de localização como trilateração ou análise de cena, sendo que esta última tem apresentado os melhores resultados (MAUTZ, 2012).

1.1 OBJETIVOS

Objetivo Geral

O objetivo geral do presente trabalho é a proposição e avaliação de um sistema de posicionamento indoor via redes IEEE 802.11 baseado no algoritmo de análise de cena, que forneça uma maior precisão da posição estimada.

Objetivos Específicos

1. Elaborar um estudo qualitativo sobre a influência dos diversos parâmetros do algoritmo de Análise de Cena.
2. Propor um algoritmo de análise de cena com a atribuição de fatores de qualidades para os pontos coletados, que serão usados como pesos no cálculo da posição.
3. Propor um algoritmo de análise de cena que utiliza filtro de Kalman para reduzir a oscilação entre as posições estimadas.
4. Propor um algoritmo de análise de cena com base no histórico da movimentação para a estimativa de posição, que utiliza a posição anterior e velocidade de deslocamento no cálculo de cada posição.
5. Avaliar os resultados obtidos para estas três propostas: executar testes comparativos entre o algoritmo de análise de cena clássico (wkNN) e as propostas anteriores a fim de verificar as melhorias obtidas.

1.2 RESULTADOS ESPERADOS

Os resultados esperados deste trabalho se concentram principalmente na proposta e avaliação de um Sistema de Posicionamento Indoor funcional, com precisão de localização melhorada em relação aos algoritmos originais.

Como resultado, almeja-se propor uma arquitetura adaptada para um sistema de posicionamento indoor em redes IEEE 802.11.

Com base na arquitetura proposta, será desenvolvido um sistema de posicionamento indoor funcional, que utilizará dispositivos pessoais (*smartphones*) para a localização de seus usuários.

Espera-se obter um algoritmo baseado em análise de cena, cuja precisão seja melhorada em relação ao clássico (wkNN) utilizado como base.

Outro resultado, será uma análise da influência de cada parâmetro do algoritmo de análise de cena, a partir dos experimentos realizados.

1.3 ESTRUTURA DA DISSERTAÇÃO

Os próximos capítulos estão organizados da seguinte forma. O Capítulo 2 apresenta os conceitos sobre sistemas de posicionamento indoor, revisão da literatura e trabalhos relacionados. O Capítulo 3 descreve as modificações propostas. No Capítulo 4, as propostas são avaliadas e os resultados discutidos. O Capítulo 5 apresenta as conclusões e perspectivas do trabalho desenvolvido, bem como sugestões para trabalhos futuros.

1.4 CONTEXTUALIZAÇÃO

Esta pesquisa está inserida no contexto de projeto contemplado pelo prêmio Sinapse da Inovação, um programa da Fundação de Amparo a Pesquisa e Inovação do Estado de Santa Catarina - FAPESC, que oferece recursos para pesquisa e desenvolvimento de idéias inovadoras.

O projeto contemplado é de autoria deste pesquisador e é intitulado “Sistemas de localização em tempo real para smartphones e redes WiFi”. O projeto envolveu parcerias com o Departamento de Automação e Sistemas da Universidade Federal de Santa Catarina (DAS-UFSC), a Fundação de Amparo à Pesquisa e Extensão Universitária

(FAPEU) e o Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (SEBRAE), onde foram alocadas uma bolsa de graduação e uma de pós graduação. Desta parceria resultou o desenvolvimento de um novo produto para a empresa Ubiacom Sistemas Ltda, localizada no Sapiens Parque em Florianópolis.

2 SISTEMAS DE POSICIONAMENTO INDOOR

Sistemas de Posicionamento são sistemas cuja função é determinar a localização de um objeto automaticamente (LIU et al., 2007).

Para ambientes externos, o sistema GPS desempenha essa função de maneira satisfatória, cobrindo todo o globo terrestre. Porém, o sistema sofre com atenuações e interferências em ambientes indoor, impedindo seu correto funcionamento.

Porém, segundo Repace e Lowrey (1980), as pessoas passam em média 90% de seu tempo em ambientes indoor. E são nesses ambientes onde a maioria das interações acontecem.

Percentual de Permanência Indoor vs Outdoor




Figura 1: Percentual de permanência em ambientes indoor vs outdoor.

Segundo levantamento do serviço de emergências americano (911), mais de 60% das chamadas de emergências ocorrem em ambientes indoor (BUTLER; AHIMOVIC, 2012). Para um atendimento mais eficaz, a localização precisa é de suma importância.

Sistemas de Posicionamento Indoor são usados para localizar objetos ou pessoas em ambientes fechados, através da implantação de uma

infraestrutura específica ou reutilizando uma infraestrutura existente (PAHLAVAN; LI; MAKELA, 2002).

2.1 ASPECTOS GERAIS DE UM SISTEMA DE POSICIONAMENTO INDOOR

Nesta seção são apresentadas algumas características de sistemas de posicionamento indoor, como os principais componentes do sistema, topologia, algoritmos utilizados, entre outros.

São levados em consideração sistemas de posicionamento indoor através de redes sem fio. Outras abordagens, como por exemplo, as que são baseadas na utilização de câmeras e visão computacional não são tratadas.

2.1.1 Componentes

A Figura 2 mostra a estrutura de um sistema de posicionamento indoor com os seus componentes básicos (PAHLAVAN; LI; MAKELA, 2002). O sistema é constituído de sensores de localização, algoritmo de posicionamento e interface com usuário.

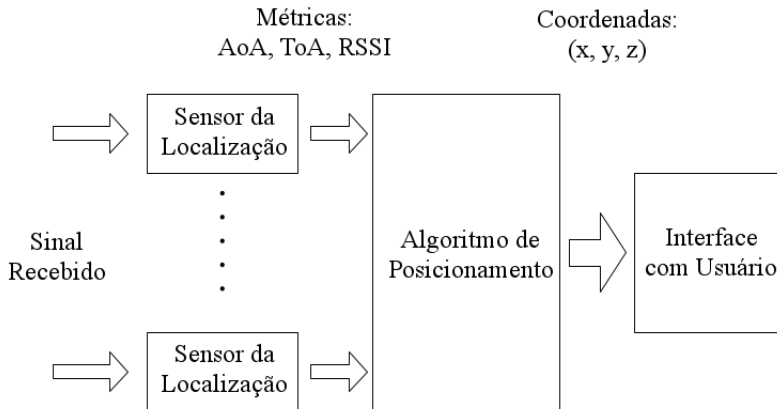


Figura 2: Componentes de um Sistema de Posicionamento Indoor.

O elemento básico para a localização é o sinal de radiofrequência. Este sinal pode ser emitido por um ponto de referência conhecido ou mesmo pela unidade móvel, conforme a topologia adotada.

Os dispositivos sensores de localização captam o sinal de radiofrequência e calculam métricas referentes à posição relativa da unidade móvel em relação a um ponto de referência. Estes dispositivos podem estar fisicamente acoplados à uma unidade móvel, ao ponto de referência ou à um elemento externo.

Com estes dados, as métricas obtidas pelos sensores são utilizadas pelo algoritmo de posicionamento para estimar as coordenadas de posição da unidade móvel.

Finalmente, um sistema com interface para o usuário pode ser utilizado para mostrar a posição aos usuários finais. Este sistema pode ser restrito à própria unidade móvel, como um aplicativo em um *smartphone*, ou até mesmo um sistema universalmente acessível através da Internet.

Alguns exemplos de métricas são a potência do sinal recebido (RSSI), ângulo de chegada (angle of arrival - AOA) e tempo de chegada (time of arrival - TOA). Elas são analisadas por algoritmos como trilateração, algoritmos probabilísticos, redes neurais entre outros, que serão analisados mais adiante.

2.1.2 Tipos de Localização

Dependendo da aplicação-alvo, diferentes tipos de informação de localização são utilizadas, algumas mais detalhadas e outras até mesmo em linguagem natural. Os principais tipos são localização física, localização simbólica, localização absoluta e localização relativa (LIU et al., 2007).

Localização Física: através de coordenadas que identificam um ponto em mapa 2D ou 3D. Normalmente usa sistemas de coordenadas em graus, minutos e segundos e também Universal Transverse Mercator – UTM.

Localização Simbólica: utiliza linguagem natural, usada principalmente para comunicar ao usuário final. Exemplos: na sala de estar, no escritório, no térreo.

Localização Absoluta: usa um grid de referência compartilhado por todos os objetos localizados.

Localização Relativa: normalmente baseada na proximidade de um ponto de referência conhecido ou uma estação base. Ex.: 3 metros da estação base A.

2.1.3 Topologias

Os sistemas de posicionamento indoor podem ser organizados nas seguintes topologias (PRATA, 2008):

Posicionamento Remoto: a medição é feita pelas estações bases. Consiste de transmissor de sinal móvel e varias unidades fixas de medição que captam o sinal. O resultado é coletado de todas as unidades de medição e a localização é computada em uma estação principal.

Auto-Posicionamento: a medição é realizada pela unidade móvel. Recebe sinal de vários transmissores em posições conhecidas e computa a localização baseada nos sinais medidos.

Posicionamento Remoto Indireto: o cálculo da posição é realizada pela unidade móvel e o resultado é enviado para a estação base.

Auto-Posicionamento Indireto: o cálculo da posição é realizado nas estações bases e enviado à unidade móvel.

2.1.4 Tecnologias

2.1.4.1 GPS

Conforme mencionado anteriormente, a tecnologia GPS utiliza satélites em órbita geostacionária como emissor de sinal, usando o princípio da triangulação para determinar a posição de um objeto.

Porém, devido a baixa cobertura do sinal em ambientes fechados, sua informação fica muito imprecisa, tornando-o inviável para estimar posições em ambiente fechado.

Várias empresas trabalham em sistemas para melhorar essa situação. Um exemplo é a SnapTrack (MOEGLEIN; KRASNER, 1998), que utiliza um receptor GPS de referência e um servidor remoto de localização para auxiliar no cálculo da posição de um dispositivo remoto (seu foco é a telefonia móvel).

2.1.4.2 GSM

Vários sistemas usam redes GSM/CDMA para posicionamento. Porém, sua precisão é baixa, estimando posições com erros em torno de 50 a 200 metros, tornando-os ineficientes para aplicações indoor.

Alguns estudos foram desenvolvidos focando a utilização de rede de telefonia celular para sistemas de posicionamento indoor. Um trabalho (OTSASON et al., 2005) desenvolveu um sistema utilizando *wide signal-strength fingerprinting*. O sistema utiliza a técnica de *fingerprinting*, utilizando inclusive canais com sinais impróprios para comunicação, mas que auxiliam na composição do resultado. Seus estudos mostraram uma precisão de até 2.5 metros de precisão.

2.1.4.3 Bluetooth

Bluetooth (IEEE 802.15) é uma tecnologia para transmissão de dados em curta distância, trabalhando normalmente com distâncias de 10 à 15 metros. Opera na frequência de 2,4 GHz e é encontrado em uma grande gama de aparelhos portáteis, como smartphones e PDAs.

Estudos (KOTANEN et al., 2003) conseguiram precisão de aproximadamente 3,7 metros usando técnicas de modelo de propagação e cálculos com filtro de Kalman estendido.

2.1.4.4 ZigBee

ZigBee (IEEE 802.15.4) é uma tecnologia para transmissão de dados sem fio para redes pessoais (Wireless Personal Area Network - WPAN) de baixa taxa de transmissão. Desenhada para aplicações que necessitam baixo consumo de energia e que não demandam tráfego de dados volumosos. O alcance é de até 100 metros em área livre, porém em ambientes fechados tipicamente atinge 20 à 30 metros.

A estimativa de distância entre *nodes* ZigBee é geralmente realizada pelo valor de RSSI. Como opera em bandas ISM não licenciadas, é vulnerável à interferências de outros sinais.

Larranaga et al. (2010) apresenta um sistema de posicionamento indoor baseado em análise de cena via redes ZigBee, com precisão média de 3 metros.

2.1.4.5 RFID

A Identificação por Rádio Frequência (*Radio Frequency Identification* - RFID) utiliza comunicação através de ondas de rádio para troca de dados entre um leitor e um receptor (*tag*) remoto. *Tags* podem ser classificadas em ativas ou passivas.

Tags passivas operam sem bateria e sua principal aplicação é substituir código de barras. São mais leves, menores e mais baratas que tags ativas. Elas refletem o sinal do leitor e adicionam informação de identificação modulando o sinal refletido. Normalmente a distância de leitura é curta (em torno de 1 à 2 metros) e os leitores são relativamente caros.

Tags ativas emitem ativamente seu Identificador (ID) e informações adicionais. Possuem a vantagem de comunicar a uma distância maior (dezenas de metros). Idealmente usado em produtos de alto valor, dado seu maior custo.

LANDMARC (NI et al., 2004) é um sistema de posicionamento indoor bastante citado na literatura que utiliza RFID. Baseia-se na utilização de alguns leitores e um grid de *tags* de referência, funcionando como um *fingerprinting* dinâmico. Usando uma *tag* de referência por metro quadrado, conseguiu uma precisão com erro máximo de 2 metros.

2.1.4.6 UWB

UWB (*Ultra Wide Band*) é uma tecnologia de rádio para transmissão de informação sobre uma banda larga (maior que 500 MHz), com pulsos de curta duração. Dentre suas vantagens está o baixo consumo e a baixa interferência de outros sinais de rádio. Seus pulsos curtos podem ser facilmente filtrados a fim de diferenciar sinais corretos de gerados por propagação multicaminho.

A precisão obtida com esta tecnologia é bastante alta, situando-se na faixa de 15 à 30 cm. Porém seu custo de implantação é bastante elevado (LIU et al., 2007).

2.1.4.7 WiFi

O padrão IEEE 802.11 é amplamente adotado pelo mercado para comunicações sem fio. Tem sido um forte candidato para sistemas de posicionamento indoor principalmente pelo baixo custo e pelo fato de

que, dada sua grande adoção, é muito provável que a rede já esteja instalada no ambiente em que se vai implantar o sistema de localização. A precisão varia de 3 a 30 metros usando algoritmos baseados em RSSI (LIU et al., 2007).

Através de algoritmos de classificação e análise de cena, consegue-se melhorar a precisão significativamente, como é o caso do sistema RADAR (BAHL; PADMANABHAN, 2000), que usando k-Nearest Neighbour conseguiu uma precisão de 2 a 3 metros.

2.1.4.8 Análise Comparativa

A Tabela 1 apresenta uma análise comparativa entre diferentes soluções e tecnologias. Estes dados foram compilados a partir de Liu et al. (2007).

Tabela 1: Comparativo entre tecnologias de posicionamento indoor

Sistema	Tecnologia	Algoritmo	Precisão	Custo
Microsoft Radar	WLAN, RSSI	kNN, Viterbite	3-5 m	Baixo
Ekahau	WLAN, RSSI	Métodos Probabilísticos	2 m	Baixo
SnapTrack	GPS assistido	-	5-50 m	Médio
Ubisense	UWB	Quadrados Mínimos	15 cm	Médio à Alto
SpotON	RFID ativo	Trilateração	N/D	Baixo
LANDMARC	RFID ativo	kNN	<2 m	Baixo
GSM fingerprinting	GSM	kNN	5-10 m	Médio
Topaz	Bluetooth + IR	-	2 m	Médio

Pela tabela nota-se que sistemas desenvolvidos com a tecnologia UWB apresentam a melhor precisão para localização indoor. Porém, os custos de implantação são altos, devido à utilização de infraestrutura e equipamentos dedicados. Em situações onde a precisão é fator extremamente crítico, como por exemplo localizar equipamentos médicos em prateleiras, e quando os custos envolvidos são justificados, UWB é a tecnologia sugerida.

Ao considerar o monitoramento de pessoas e navegação indoor, onde a precisão ideal seria de 1 metro (MAUTZ, 2012), o sistema GPS não apresenta uma precisão adequada. GSM também não atinge uma precisão adequada. Somado a isso, a infraestrutura é dependente de terceiros, com custos elevados e não pode ser modificada a fim de auxiliar o sistema de posicionamento indoor.

Bluetooth e RFID possuem uma precisão aceitável porém sua área de cobertura é baixa, o que implica em instalar vários receptores pelo ambiente, envolvendo custos com equipamento e intervenções no espaço. Se a área de posicionamento indoor for pequena (dezenas de metros quadrados), ou quando se deseja cobertura parcial do ambiente, a utilização destas tecnologias é justificável.

Sistemas baseados em redes IEEE 802.11 (WLAN) possuem uma precisão aceitável para muitas aplicações. Além disso, apresentam baixo custo e se encontram disponíveis em muitos ambientes e dispositivos pessoais, uma vez que é a rede com maior presença atualmente. Estes são os principais motivos da adoção desta infraestrutura no presente trabalho.

2.1.5 Segurança e Privacidade

A localização de uma pessoa é uma informação sensível e deve ser tratada com responsabilidade. O acesso não autorizado a essa informação pode afetar um usuário em diversas maneiras, desde constrangimentos ao comprometimento de sua integridade física.

Por exemplo, um profissional pode desejar compartilhar sua posição apenas em seu posto de trabalho e omiti-la ao se ausentar do recinto ou fora do horário de trabalho. Outro cenário mais crítico seria o caso de um sequestrador obtendo acesso não autorizado à posição de um alvo e abordá-lo quando o mesmo estiver em um local pouco movimentado, como por exemplo uma garagem.

Levando esses cenários em consideração, ao se desenvolver um sistema de posicionamento é imprescindível o estudo e análise de possíveis problemas de segurança e aspectos de privacidade.

Também deve se levar em conta que diferentes aplicações requerem diferentes níveis de segurança e permissões. Por exemplo, quando os alvos monitorados são objetos, as questões de privacidade se mitigam, mas ao se tratar de pessoas, elas se tornam fundamentais.

Diferentes estratégias de posicionamento também terão seus problemas específicos. Por exemplo, quando a posição é calculada na uni-

dade móvel ou se a posição é estimada nas bases. Ao ser calculada na unidade móvel, o usuário tem mais poder sobre com quem ele deseja compartilhar esta informação. Posicionamento remoto, em que a posição é estimada remotamente, é mais crítico, uma vez que o usuário não possui o controle sobre o que será feito com os seus dados.

A tecnologia empregada no mecanismo de localização também deve ser estudada minuciosamente a fim de garantir a privacidade do usuário. Notadamente, conforme citado por Kolodziej e Hjelm (2006), apesar de não estar na especificação, muitos dispositivos IEEE 802.11 notificam sua existência para a infraestrutura regularmente. Outro caso de desvio da especificação são de dispositivos Bluetooths que enviam seu endereço MAC durante uma busca (*scan*) de dispositivos nas proximidades.

Existem também questões de privacidade diretamente envolvidas com a lógica da aplicação. Uma aplicação de mapas, por exemplo, para economizar espaço em disco e tráfego de dados faz a requisição de mapas sob demanda, obtendo apenas a região visível na tela do usuário móvel. Um administrador mal intencionado pode observar a região que foi requisitada e com esta informação saber a localização do usuário.

Apesar de não serem o foco do presente estudo e não serem analisados, segurança e privacidade são elementos críticos e devem ser partes fundamentais no desenvolvimento e implantação de um sistema de posicionamento indoor.

2.2 ALGORITMOS DE POSICIONAMENTO

Os algoritmos de posicionamento indoor podem ser classificados em três grandes grupos: proximidade, trilateração e análise de cena (LIU et al., 2007).

2.2.1 Proximidade

Provê informação simbólica e relativa da localização de um objeto. Normalmente consiste de um grid de estações bases, com posições conhecidas (LIU et al., 2007).

Quando o sinal é detectado por uma única estação base, a unidade móvel é considerada estar na posição daquela base. Quando mais de uma base detecta o sinal, a posição é estimada como sendo a da base que possui o sinal mais forte. Um exemplo de utilização é a localização

Cell-ID da rede de telefonia móvel.

Possui uma precisão de localização baixa, sendo que requer muitas estações bases para melhorar a estimativa da localização, sendo pouco viável para ambientes indoor.

2.2.2 Trilateração

Também citada como triangulação, utiliza-se das propriedades geométricas para estimar a localização. Sabendo-se a distância de três ou mais pontos de referências e o raio entre eles e um determinado ponto x , podemos calcular a posição de x através de manipulação matemática.




Figura 3: Cálculo através da trilateração.

Ao determinarmos cada ponto de referência como o centro de uma esfera no espaço, ou um círculo no plano a fim de evitar tornar o problema mais complexo do que o necessário, deve-se medir a distância da unidade móvel a cada uma das referências para que a posição absoluta do dispositivo possa ser calculada.

Algoritmos baseados em triangulação podem ser classificados baseados na métrica utilizada:

ToA: Time of Arrival

Calculada pelo tempo de viagem entre o transmissor e um receptor. Necessita sincronização entre emissor e receptor. A sincronia pode ser obtida através das seguintes estratégias:

- Através de relógios sincronizados;

- Usando dois sinais de diferentes frequências e portanto diferentes velocidades;
- Medição ou acionamento através de ponto de referência comum.

TDoA – Time Difference of Arrival

O emissor envia para 3 ou mais receptores, que comparam diferença no tempo de recebimento. Não necessita saber o exato momento em que foi transmitido, apenas a diferença. Com 4 receptores consegue-se estimar um ponto no espaço 3D. Adicionando mais receptores pode-se melhorar a precisão. Teoricamente hiperboloides se tocariam em um único ponto. Porém devido a imprecisões, isso não ocorre, então aborda-se como problema de otimização, resolvendo com filtro de Kalman ou método de quadrados mínimos, por exemplo.

RToF – Roundtrip Time of Flight

Mede o ToA do sinal enviado do transmissor para a unidade medida e o retorno. Remove a necessidade de sincronia de relógios. Porém, em distâncias curtas, o tempo de processamento e resposta do retorno do sinal pode interferir na medição.

RSSI-Based

As opções anteriores exigem campo de visão aberto entre emissor e receptor, algo raro em um ambiente fechado, criando efeitos de propagação multicaminho. Esta técnica consiste em medir a atenuação do sinal emitido, a fim de estimar a distância entre o emissor e receptor.

Tal distância pode ser calculada através da relação entre potência do sinal e sua taxa de atenuação em função da distância, que pode ser obtida através do cálculo da Perda no Espaço Livre (*Free Space Path Loss*):

$$L_{FS} = 20\log_{10}\left(\frac{4\pi d}{\lambda}\right) + G_{TX} + G_{RX} \quad (2.1)$$

onde d é a distância entre emissor e receptor, λ é o comprimento da onda e G_{TX} e G_{RX} representam os ganhos do emissor e receptor, respectivamente. Assumindo ganhos constantes e a frequência da onda do padrão IEEE 802.11 como 2,4 GHz, obtém-se:

$$L_{FS} = K_1 + 20\log_{10}(d) \quad (2.2)$$

Outras perdas L_O , devido a sombras, propagação multicaminho, etc., são comumente assumidas a aumentar linearmente em relação ao logaritmo da distância:

$$L_O = K_2 + n_1 \log_{10}(d) \quad (2.3)$$

onde K_2 e n_1 são constantes descrevendo o ambiente de propagação.

Uma forma de modelar é assumir R como a potência do sinal transmitido a 1 metro de distância menos as perdas citadas:

$$\begin{aligned} R &= P_{out} - LFS - L_O \\ &= P_{out} - K_1 - 20 \log_{10}(d) - K_2 - n_1 \log_{10}(d) \end{aligned} \quad (2.4)$$

Agrupando as constantes, obtém-se:

$$R = C - 10n \log_{10}(d) \quad (2.5)$$

sendo que C descreve a medição de RSSI à 1 metro do transmissor e n descreve a atenuação média do ambiente. Para a estimativa de distância, resolvendo a equação em d , obtém-se:

$$d = 10^{\frac{R-C}{-10n}} \quad (2.6)$$

No espaço livre, n é igual a 2. Mas para caminhos com obstruções, n tem um valor entre 4 e 5 (BOSE; FOH, 2007). Geralmente, um protótipo é desenvolvido para estimar o valor de n .

2.2.3 Análise de Cena

Este algoritmo consiste em realizar uma medição preliminar do ambiente para obter as características da cena (*fingerprint*) para depois estimar a posição que mais se aproxima desta medição. Geralmente utiliza a potência do sinal para caracterizar o ambiente e é também conhecida como *location fingerprinting*.

Apresenta duas fases bem distintas, chamadas de *fase offline* e *fase online*.

Na fase *offline*, o nível do sinal é coletado em todo o ambiente de maneira manual. O projetista percorre todo o ambiente, efetuando medições de sinal, marcando a posição em um mapa do ambiente.




Figura 4: Mapa do sinal de um ponto de acesso (dBm).

Um exemplo de mapa de medições de sinal é exibido pela Figura 4. Por motivo de visualização, a figura exibe o mapa para apenas um ponto de acesso. Todos os pontos de acesso do ambiente são coletados e seus mapas gerados.

Durante a fase *online*, é realizada uma nova leitura de sinal que é comparada com os sinais coletados anteriormente. A posição então é estimada como sendo a do sinal com maior similaridade.

O cálculo da similaridade pode ser realizado utilizando-se diversos métodos, como métodos probabilísticos, redes neurais e técnicas de reconhecimento de padrões (LIU et al., 2007).

O principal desafio é que o sinal é bastante afetado pelo ambiente indoor, causando variações em leituras para um mesmo ponto. Pessoas se movimentando, utilização da rede e móveis reposicionados influenciam nos valores coletados.

A seção seguinte aborda as redes IEEE 802.11 como infraestrutura para um sistema de posicionamento indoor e justifica a adoção do

algoritmo de análise de cena como base do presente trabalho.

2.3 POSICIONAMENTO INDOOR VIA REDES IEEE 802.11

O padrão *de facto* para conectividade local sem fio é o IEEE 802.11. Empresas, fábricas, universidades, hospitais, centros comerciais e residências se beneficiam do mesmo para fornecer acesso à rede local com mobilidade.

Sua ampla presença no mercado e cobertura em ambientes com movimentação de pessoas, como ambientes de trabalho, lazer e residencial, torna o padrão um forte candidato para desenvolvimento de sistemas de posicionamento indoor. Como grande vantagem cita-se a redução de custos de implantação, uma vez que é reutilizada a infraestrutura de rede existente e o sistema implementado se beneficia de uma grande base instalada, abrangendo diversos locais.

O padrão IEEE 802.11 foi aprovado em 1997 pelo IEEE, após 7 anos de pesquisa e desenvolvimento, com taxas de transmissão atingindo 1 e 2 Mbps. O padrão e suas emendas prevêm técnicas de modulação half-duplex, como DSSS (Direct Sequence Spread Spectrum) e FHSS (Frequency Hopping Spread Spectrum), trabalhando na banda de rádio não licenciada ISM (Industrial, Scientific and Medical) de 2.4 GHz.

As redes IEEE 802.11 apresentam duas topologias: ad hoc e modo infraestruturado. No modo ad hoc, cada estação móvel pode se comunicar diretamente com outra estação móvel em seu alcance de transmissão. No modo infraestruturado, uma estação central (AP – Access Point) é responsável pelo repasse de mensagens entre estações e outras redes.

O sinal recebido pode ser medido pelo hardware das interfaces sem fio. Esse valor é chamado de RSSI – Received Signal Strength Indicator, sendo normalmente expresso em dBm. Esse sinal sofre com alguns fenômenos como atenuação em espaço livre, que é a atenuação ao propagar-se pelo meio e propagação multi-caminho, quando um mesmo sinal pode chegar ao receptor através de diferentes caminhos, com diferentes fases e amplitudes. A mudança de temperatura, umidade, disposição da mobília e principalmente o trânsito de pessoas também afetam a qualidade do sinal recebido (NUNES, 2006). Esta variação é o principal desafio no projeto de um sistema de posicionamento indoor para redes IEEE 802.11.

Na literatura foram encontrados exemplos de utilização de vari-

ados algoritmos, sendo que algoritmos de análise de cena vem apresentando os melhores resultados (LIU et al., 2007).

Dentre eles, destacam se RADAR (BAHL; PADMANABHAN, 2000), Horus (YOUSSEF; AGRAWALA, 2005) e Compass (KING et al., 2006). Esses algoritmos trabalham em duas etapas. Primeiramente, a fase *offline* é usada para coletar medições de força de sinal (fingerprints) dos pontos de acesso ao longo do ambiente, em posições determinadas. Na segunda fase, a fase *online*, a informação de potência de sinal é obtida e comparada com a base de dados coletados na fase *offline*. Algoritmos são usados então para calcular a posição como sendo a de sinal mais parecido com a medição atual (Nearest Neighbour – NN). Alternativamente são usados k vizinhos mais próximos (k-Nearest Neighbour - kNN), podendo ou não usar a distância no espaço de sinal como um fator de ponderação (weighted KNN – wkNN) ou métodos probabilísticos.

Um ensaio preliminar demonstrou a principal dificuldade de se utilizar o algoritmo de trilateração em redes IEEE 802.11: a variação dos níveis de RSSI. No ensaio, um dispositivo foi mantido em uma posição fixa onde realizou medições periódicas de RSSI para um determinado ponto de acesso. O valor medido foi aplicado à formula da Perda no Espaço Livre (ou Free Space Loss) anteriormente apresentada, a fim de estimar a distância entre o dispositivo e o ponto de acesso.




Figura 5: Variação da distância estimada devido à variação da potência de sinal.

Como observado no gráfico da Figura 5, uma distância que deveria ser estimada em 12 metros, tem valores estimados variando entre 10 e 24 metros.

Essa variação dificulta a aplicação do algoritmo de trilateração. E apesar de exigir uma coleta de dados trabalhosa, o algoritmo de análise de cena se mostra como melhor opção para posicionamento em redes IEEE 802.11.

Um dos primeiros sistemas para localização indoor a utilizar redes IEEE 802.11 com análise de cena foi RADAR (BAHL; PADMA-NABHAN, 2000). RADAR é um sistema determinístico que utiliza kNN para estimar a posição e apresenta um modelo opcional de propagação de sinal para automatizar a criação da base de dados de amostras de sinais. Os autores perceberam o impacto da orientação do usuário, devido a atenuação causada pelo corpo e propuseram coletas em múltiplas direções.

Recentemente, um estudo aprofundado das propriedades do RSSI foi realizado por Kaemarungsi e Krishnamurthy (2012), onde foram analisados resultados práticos de medições de RSSI sob diversos cenários. Suas conclusões indicam que os erros em estimativas de posições são proporcionais ao aumento do desvio-padrão do RSSI, sendo este o

parâmetro mais influente em um sistema de posicionamento indoor. Os resultados mostram que a presença do corpo humano pode reduzir em até 9dBm a força do sinal recebido.

O método de análise de cena que apresenta os melhores resultados é o algoritmo wkNN (ALI-LOYTTY et al., 2009). Porém, quando tem-se poucas medições as estimativas não são precisas. Para estes casos uma solução seria a utilização de filtros, como Kalman, que consideram medições anteriores para o cálculo de uma nova estimativa.

Muitas propostas atuais consideram a combinação de WLAN com tecnologias adicionais e sensores, como acelerômetros e giroscópios, como em SMARTPOS (KESSEL; WERNER, 2011) e Hansson e Tufvesson (2011).

Mais próximos da proposta apresentada, outros trabalhos recentes também focam em modificações no algoritmo de análise de cena. Shin et al. (2012) propõe a utilização de um número de vizinhos k variável ao invés de um k fixo, melhorando a estimativa em até 25%. Yu e Liu (2013) propõe um novo algoritmo wkNN, onde o peso é calculado através de conjuntos fuzzy, sendo que os resultados apresentam ganhos marginais.

Seguindo outro caminho, Miao et al. (2014), utiliza o conceito de seleção de pontos de acesso para filtrar os pontos de acesso usados na estimativa, visando diminuir a complexidade computacional e aumentar a precisão da estimativa.

2.4 CONCLUSÃO

Pelo estudo apresentado, há indicativos de que o padrão IEEE 802.11 é um forte candidato para a infraestrutura de um sistema de posicionamento indoor, principalmente dado sua grande adoção pelo mercado e baixo custo.

A partir das referências bibliográficas e do ensaio realizado, verificou-se que o algoritmo de trilateração não apresenta bons resultados, sendo análise de cena o algoritmo com maior precisão para sistemas de posicionamento indoor em redes IEEE 802.11.

Conforme apresentado, o algoritmo estimador mais eficaz para análise de cena é o algoritmo wkNN. Porém, a precisão alcançada pode não ser o suficiente para muitas aplicações.

Dado estas condições, no capítulo seguinte são apresentadas propostas para melhorar a precisão da localização estimada por um sistema de posicionamento indoor baseado em análise de cena e wkNN.

3 PROPOSTAS DE ALGORITMOS DE ANÁLISE DE CENA

O presente trabalho se baseia em um sistema de posicionamento indoor em redes IEEE 802.11 utilizando o algoritmo de análise de cena. As propostas são variações do algoritmo inicial a fim de minimizar algumas desvantagens:

1. a atribuição de fatores de qualidade para os pontos coletados, os quais serão usados como pesos no cálculo da centroide;
2. a utilização de filtro de Kalman para melhorar a estimativa;
3. a utilização do histórico de movimentação a fim de reduzir o conjunto de pontos a serem processados e diminuir erros;

A motivação da adoção da rede IEEE 802.11 como infraestrutura no presente trabalho se deve ao fato de ser atualmente a rede sem fio com maior presença, tanto em ambientes comerciais, como industriais e residências, conforme abordado no Capítulo 2. Isso permite que o sistema possa ser implantado sem grandes custos de infraestrutura, reaproveitando a rede presente e aumentando o número de ambientes e usuários potenciais. Além disso, apresenta uma precisão suficiente para inúmeras aplicações, como a localização pessoal, e uma boa relação custo/benefício.

Com base nos trabalhos relacionados, percebe-se que o algoritmo de análise de cena é o que vem apresentando os melhores resultados para redes IEEE 802.11. Desta forma, justifica-se a escolha do mesmo como base para o trabalho.

Como a precisão do sistema é o fator principal a ser melhorado, as propostas tomam como base o algoritmo estimador wkNN, uma vez que dado os estudos levantados, este obtém as estimativas mais precisas.

3.1 ALGORITMO DE ANÁLISE DE CENA COM WKNN

Conforme citado anteriormente, o algoritmo de análise de cena consiste na elaboração de uma "mapa" de leituras de sinais do ambiente (fase *offline*) e sua comparação com uma leitura onde se deseja estimar a posição (fase *online*).

Nesta seção, são apresentados detalhes destas duas etapas, bem como seus desafios.

Ao tratar da fase *online*, também será descrito o funcionamento do algoritmo estimador wkNN e seu algoritmo predecessor kNN.

3.1.1 Fase Offline

Na fase *offline*, é realizado um mapeamento da potência de sinal dos pontos de acesso abrangendo toda a área do ambiente, associando essas potências com a localização de leitura. Quanto mais próximos os pontos de leitura, melhor serão os dados de entrada para o algoritmo.

Por exigir o deslocamento pelo ambiente, com intervalos para leitura de valores, esta etapa é bastante dispendiosa. Novas formas de coleta estão sendo estudadas como *crowdsourcing* para geração e manutenção dos mapas e a utilização de robôs.

A qualidade da posição estimada está diretamente relacionada a qualidade da coleta da fase offline. Alguns fatores foram identificados na literatura como influentes na qualidade da coleta.

A maior dificuldade para um sistema de posicionamento indoor consiste na variação do RSSI. Em uma mesma posição, ao se obter a leitura em tempos distintos, os níveis de RSSI para um determinado ponto de acesso podem ser ligeiramente diferentes. Isso implica que na fase online, os valores observados podem não ser exatamente os mesmos que na fase offline, dificultando a comparação (*matching*) das leituras para se obter a posição.

Outro aspecto importante da fase *offline* está relacionado ao total de posições de coleta e o número de amostras em cada uma. A maioria dos estudos sugere dividir o ambiente em grid de 1 a 2 metros, e fazer coletas em cada ponto deste grid. Porém, nem todas as aplicações necessitam uma grande precisão, sugere-se então dividir o ambiente em células (i.e., sala/escritório) e estimar a posição por célula ao invés de coordenadas (HAEBERLEN et al., 2004).

Muitos estudos foram realizados levantando-se as características dos níveis RSSI, revelando seu comportamento.

Haeberlen et al. (2004) identificaram que os níveis de RSSI variam ao longo do tempo, devido a propriedades do ambiente, como a movimentação de pessoas e o abrir e fechar de portas. Também observaram que interferência pode ser causada por outros dispositivos eletrônicos como fornos microondas, telefones sem fio e dispositivos Bluetooth.

Bahl e Padmanabhan (2000) no estudo seminal RADAR afirmaram que a orientação do usuário tem um grande impacto na medição

registrada, recomendando que a medição seja feita em múltiplas orientações. Em uma orientação, a antena pode ter linha de visão (*line-of-sight*), enquanto na orientação oposta, o corpo do usuário se torna uma obstrução. A variação observada foi de até 5 dBm.

Um estudo aprofundado das propriedades do RSSI foi realizado (KAEMARUNGI; KRISHNAMURTHY, 2012), onde foram analisados resultados práticos de medições de RSSI sob diversos cenários. As conclusões indicam que os erros em estimativas de posições são proporcionais ao aumento do desvio-padrão do RSSI, sendo este o parâmetro mais influente em um sistema de posicionamento indoor. As flutuações do RSSI são propriedades intrínsecas das interfaces de rede e do ambiente e que para melhorar a performance do sistema, o projetista deve tentar reduzir os efeitos do desvio-padrão.

O número de pontos de acesso cobrindo a área é também bastante relevante na precisão de um sistema de posicionamento indoor. T. King, T. Haenselmann e W. Effelsberg mostram em (KING et al., 2006) que a precisão melhora 33% ao aumentar de um para dois o número de pontos de acesso no ambiente. Ao aumentar de dois para três, ganha-se mais 20%. A partir disso os ganhos são marginais, seguindo uma tendência logarítmica.

Outro aspecto importante da fase offline está relacionado ao total de posições de coleta e o número de amostras em cada uma. A maioria dos estudos sugere dividir o ambiente em grid de 1 a 2 metros, e fazer coletas em cada ponto deste grid. Porém (HAEBERLEN et al., 2004) sugere que nem todas as aplicações necessitam uma grande precisão, sugerindo dividir o ambiente em células (cada célula uma sala/escritório, por exemplo) e estimar a posição por célula ao invés de coordenadas. Isso reduz significativamente a custosa etapa de coleta de dados da fase offline.

Como resultado final desta etapa, obtém-se um mapa do ambiente com a localização das coletas de sinal e seus respectivos valores de RSSI.

3.1.2 Fase Online

Na fase *online* é realizada a estimativa da posição de um dispositivo móvel. O equipamento executa uma coleta de níveis de potência de sinal (RSSI), que é comparada com as coletas levantadas na fase *offline* a fim de encontrar a posição que mais se assemelha aos níveis dessa coleta *online*. Esta operação pode ser realizada utilizando-se diversos

algoritmos, como métodos probabilísticos, redes neurais e reconhecimento de padrões.

Os algoritmos mais comumente utilizado para este fim são o Nearest Neighbour (NN), e seus derivados k-Nearest Neighbour (kNN) e weighted k-Nearest Neighbour (wkNN).

Nearest Neighbour - NN

O algoritmo NN calcula o grau de dissimilaridade entre a leitura atual com cada um dos pontos do conjunto de treino da fase *offline*. Assume-se então a posição como sendo a mesma da leitura com o menor grau de dissimilaridade. A métrica de dissimilaridade mais utilizada é a distância euclidiana dos valores de RSSI de cada ponto.

Suponhamos um ambiente n pontos de acesso. Definimos um vetor de RSSIs para cada posição de leitura p coletada na fase *offline* sendo $S_p = (S_1, S_2, \dots, S_n)$, onde S_i denota o valor de RSSI do ponto de acesso i , onde $i \in (1, n)$. Definimos um vetor de RSSIs para uma posição a ser estimada como $P_i = (P_1, P_2, \dots, P_n)$, onde P_i denota o valor de RSSI do ponto de acesso i . Para cada posição de leitura da fase *offline* p , calculamos D_p , pela distância Euclidiana:

$$D_p(S_p, P) = \sqrt{\sum_{i=1}^n (S_i - P_i)^2} \quad (3.1)$$

A posição com menor valor de D_p é assumida como posição estimada.

k-Nearest Neighbour - kNN

De maneira análoga ao algoritmo NN, o algoritmo kNN calcula o grau de dissimilaridade entre a leitura atual com cada um dos pontos do conjunto de treino. Ordena-se então pelo valor da dissimilaridade e escolhe-se os k primeiros pontos (i.e., os mais similares). A posição é então estimada como sendo o centroide destes k pontos.

$$x = \frac{\sum_{i=1}^k x_i}{k} \quad (3.2)$$

$$y = \frac{\sum_{i=1}^k y_i}{k} \quad (3.3)$$

O valor de k é atribuído pelo projetista, sendo geralmente utilizado o valor 4 ou 5 (SHIN et al., 2012).

Weighted k-Nearest Neighbour - wkNN

Uma modificação do algoritmo kNN que tem apresentado bons resultados é o algoritmo weighted k-Nearest Neighbour (wkNN), cuja proposta é ponderar o centroide pelo valor da distância calculada:

$$x = \frac{\sum_{i=1}^k \frac{X_i}{D_i}}{\sum_{i=1}^k \frac{1}{D_i}} \quad (3.4)$$

$$y = \frac{\sum_{i=1}^k \frac{Y_i}{D_i}}{\sum_{i=1}^k \frac{1}{D_i}} \quad (3.5)$$

Estes valores x e y são então tomados como a estimativa da posição para P .

Os cálculos de dissimilaridade exigem a leitura de sinal de todos os pontos de acesso, a fim de tornar seus valores comparativos. Porém, ao implantar o sistema em um ambiente real isso dificilmente ocorre devido a atenuações e a área do ambiente muitas vezes ser maior que a abrangência do ponto de acesso. Para esses casos, deve-se fixar um valor arbitrário para representar uma leitura faltante. Idealmente, esse valor deveria ter pouca influência no cálculo do valor da dissimilaridade.

Como a dissimilaridade é calculada com uma subtração, esse valor deve ser diferente de um sinal de boa qualidade, porém parecido com um sinal de baixa potência. Esse valor deve indicar o valor mínimo de sinal a ser considerado no cálculo e qualquer leitura com valor inferior, será substituída por esse valor, denominado de *threshold*. Nos experimentos foram analisados diferentes valores de *threshold*, a fim de encontrar o valor ideal.

A variação do RSSI em relação ao valor obtido durante a fase *offline* é o principal limitante para se obter uma boa estimativa.

Outro fator limitante da fase *online* está no desempenho do algoritmo. A posição de um objeto deve ser calculada rapidamente para corresponder à sua posição atual. Um cálculo muito demorado, torna-se irrelevante, uma vez que o objeto pode ter se movimentando, não estando mais presente no local estimado.

Nos métodos apresentados, as estimativas de posição são calculadas de maneira independente (ponto a ponto), sem levar em conside-

ração posições anteriores. Esta característica pode ser vista como uma limitação e será abordada nas propostas deste trabalho.

O algoritmo wkNN se baseia em atribuir pesos às k-posições a fim de aproximar o centroide das posições mais similares. Esse peso é proporcional ao valor de D_p . Porém, outros métodos para atribuição de pesos poderiam ser utilizados. Uma das propostas apresenta um novo método para atribuição de pesos e será apresentada a seguir.

3.2 PROPOSTAS PARA UM SISTEMA DE POSICIONAMENTO IN-DOOR

As propostas apresentadas a seguir são variações do algoritmo de análise de cena com wkNN. A proposta baseada no Fator de Qualidade apresenta uma nova maneira de calcular o centroide.

Já as propostas seguintes, baseada em Filtro de Kalman e Histórico de Movimentação, representam um passo adicional ao algoritmo de análise de cena, tomando como base o valor estimado pelo wkNN, e compondo com valores anteriormente observados.

Após apresentadas as propostas, serão realizadas avaliações, a fim de verificar possíveis ganhos das propostas.

3.2.1 Proposta de um Algoritmo de Análise de Cena Baseado no Fator de Qualidade

O algoritmo wkNN é uma alternativa ao algoritmo kNN através da modificação do cálculo da centroide utilizando a média aritmética ponderada pelo valor de D para aferir a posição, conforme fórmulas anteriormente expostas.

A modificação proposta consiste em atribuir os pesos do algoritmo wkNN por um fator de qualidade Q do ponto coletado. Assim, pontos com maior “qualidade” são considerados mais relevantes para a estimativa e tendem a levar a posição estimada para mais próximo da posição de coleta da fase *offline*.

Essa proposta assume o fato de que alguns pontos do conjunto de calibração sofrem oscilações/ruídos no sinal recebido, e por consequência devem ter papel menos importante na estimativa de posição.

Esse fator de qualidade Q pode ser obtido através do cálculo da dissimilaridade de cada ponto coletado em relação aos seus vizinhos. Pontos de calibração que possuem grande semelhança com seus vizi-

nhos próximos podem ser considerados pontos com boa qualidade. Já pontos que não se assemelham a seus vizinhos, podem ser indicativos de sinais ruidosos e sua importância deve ser menor. Essa dissimilaridade também pode ser calculada pela distância Euclidiana. No algoritmo wkNN, substitui-se então o valor de D_i pelo valor de Q_i obtido.

O Algoritmo 1 apresenta um esboço do algoritmo de atribuição de fator de qualidade aos pontos do conjunto de calibração. Esta é uma operação $O(n^2)$, bastante custosa, principalmente em conjuntos com muitos pontos de calibração, porém ela é executada apenas uma vez, após finalizado o processo de coleta da fase offline.

Algoritmo 1 Atribuição do Fator de Qualidade

Entrada: P = vetor de pontos de calibração de tamanho N , j = número de vizinhos a considerar para o fator de qualidade

Saída: Q = vetor com valor de fatores de qualidades de cada ponto do conjunto

- 1: $Q \leftarrow$ vetor Vazio Com Tamanho N
 - 2: **para** $i = 1$ a N **faça**
 - 3: $dVizinhos \leftarrow$ vetor Vazio Com Tamanho $N-1$
 - 4: **para todo** p em $P - \{P[i]\}$ **faça**
 - 5: $dVizinhos[p] \leftarrow$ calcularDissimilaridade($P[i], p$)
 - 6: **fim para**
 - 7: ordenar($dVizinhos$)
 - 8: $Q[i] \leftarrow$ média($dVizinhos[1..j]$)
 - 9: **fim para**
 - 10: retorna Q
-

Para ilustrar o comportamento da modificação, na Figura 6 são exemplificadas as estimativas de posição nos diferentes cálculos de centroide. Os números representam a ordenação dos k -vizinhos pelo valor de dissimilaridade e (x) representa a posição estimada.




Figura 6: Centroide calculado com: (a) média simples; (b) média ponderada por D ; (c) média ponderada por Q .

Como pode-se visualizar, o centroide pode variar significativamente entre os métodos listados. Fatores do ambiente alvo podem influenciar qual alternativa terá melhor desempenho, portanto este é mais um parâmetro a ser considerado pelo projetista do sistema.

3.2.2 Proposta de um Algoritmo de Análise de Cena Baseado no Filtro de Kalman

Como visto anteriormente, o algoritmo de análise de cena é suscetível a ruídos do sinal recebido, contribuindo significativamente para os erros na posição estimada. Uma forma de lidar com essas variações é através do uso de filtros. Inspirado na aplicação do filtro de Kalman em processamento de imagem e visão computacional (CUEVAS, 2005) (BLACKRNAN; HOUSE, 1999), onde vem sendo utilizado para o rastreamento (*tracking*) de objetos em movimento, a presente proposta aplica o filtro de Kalman na estimativa da posição da localização indoor.

Kalman (1960) apresenta uma solução recursiva para o problema de filtragem de dados discretos em um sistema linear. Dados alguns valores iniciais, pode-se prever e ajustar os parâmetros do modelo através de cada nova medição, obtendo a estimativa do erro em cada atualização. Sua capacidade de incorporar os efeitos de erros e sua estrutura computacional fez com que o filtro de Kalman tivesse um amplo campo de aplicações.

Nesta seção será explanada a utilização do filtro de Kalman e a definição do modelo e seus parâmetros aplicados ao problema proposto. Uma explicação detalhada sobre o filtro de Kalman é apresentada nas referências (WELCH; BISHOP, 1995) (AIUBE, 2005) e uma representação esquemática é listada na Figura 7.

O filtro de Kalman é composto de duas etapas: a previsão do estado através de uma função com base no estado anterior e a atualização desses valores em virtude das medições realizadas.

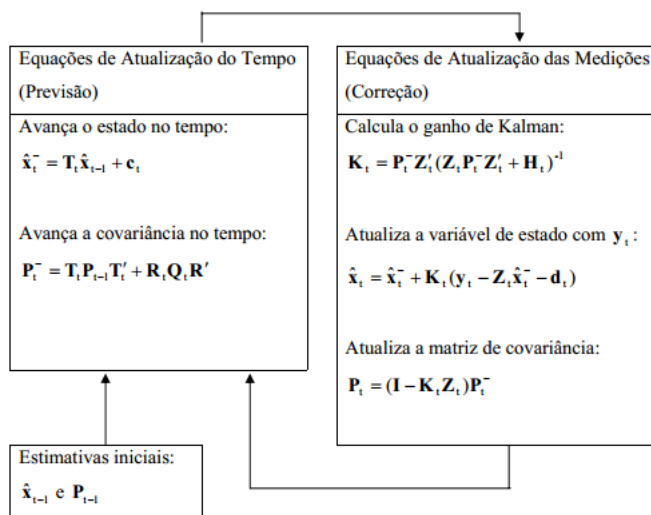


Figura 7: Representação esquemática do filtro de Kalman (AIUBE, 2005).

Através da observação da variável denominada “variável de observação” pode-se estimar de maneira eficiente uma variável não observável, denominada “variável de estado”. Para tanto, o comportamento esperado do sistema deve ser modelado sob a forma espaço-estado.

Para o objetivo proposto, definiu-se o estado do sistema \hat{x}_t no tempo t como as posições x e y da localização e as velocidades nos respectivos eixos para cada intervalo de tempo, V_x e V_y . Para a etapa de atualização do filtro de Kalman, considerou-se como medições de entrada as coordenadas x e y estimadas pelo algoritmo wkNN.

$$\hat{x}_t = \begin{bmatrix} x_t \\ y_t \\ V_{x_t} \\ V_{y_t} \end{bmatrix} \quad (3.6)$$

As equações para transição de estado que descrevem o comportamento esperado são baseadas na posição, velocidade e aceleração a dos eixos x e y :

$$\begin{aligned} x_{t+1} &= x_t + V_{x_t} + \frac{1}{2}a_x t^2 \\ y_{t+1} &= y_t + V_{y_t} + \frac{1}{2}a_y t^2 \\ V_{x_{t+1}} &= V_{x_t} + a_x t \\ V_{y_{t+1}} &= V_{y_t} + a_y t \end{aligned} \quad (3.7)$$

A partir destas equações a matriz de transição de estado T pode ser obtida:

$$T = \begin{bmatrix} 1 & 0 & t & 0 \\ 0 & 1 & 0 & t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (3.8)$$

Apesar de utilizar a velocidade e aceleração em modelo, a posição é a única informação fornecida pelo algoritmo estimador. As variáveis observadas Y_t são as posições x e y .

$$Y_t = \begin{bmatrix} \tilde{x}_t \\ \tilde{y}_t \end{bmatrix} \quad (3.9)$$

$$\begin{aligned} \tilde{x}_t &= x_t \\ \tilde{y}_t &= y_t \end{aligned} \quad (3.10)$$

Portanto a matriz de observação Z_t considera apenas estes valores:

$$Z_t = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (3.11)$$

A matriz da covariância do erro da medição H_t considera que as observações das posições x e y são independentes.

$$H_t = \begin{bmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{bmatrix} \quad (3.12)$$

E a matriz de covariância do erro do processo P_t está relacionado ao termo da aceleração a , que resulta em:

$$P_t = \begin{bmatrix} \frac{t^4}{4} & 0 & \frac{t^3}{2} & 0 \\ 0 & \frac{t^4}{4} & 0 & \frac{t^3}{2} \\ \frac{t^3}{2} & 0 & t^2 & 0 \\ 0 & \frac{t^3}{2} & 0 & t^2 \end{bmatrix} \quad (3.13)$$

De posse destas variáveis, podemos aplicar o filtro de Kalman na posição estimada pelo algoritmo wkNN. Para tanto, as estimativas devem ser geradas periodicamente e aplicadas no filtro. Espera-se que as posições com erros grandes sejam reduzidas após o filtro, fazendo com que as estimativas estejam mais próximas do caminho percorrido.

3.2.3 Proposta de um Algoritmo de Análise de Cena Baseado no Histórico de Movimentação

O algoritmo Nearest Neighbour é lento (WU et al., 2008). Cada estimativa consiste em calcular a dissimilaridade em cada ponto do conjunto de calibração. Uma forma de melhorar o desempenho, é reduzir o número de comparações em cada estimativa, através da redução de pontos a serem analisados.

Em uma aplicação real, um sistema deve informar em intervalos regulares a localização de seu objeto, como é o caso de uma pessoa usando um sistema de navegação em um edifício, onde sua posição deve ser calculada a cada segundo, para informar onde ela está e onde deve ir.

Levando isso em conta, o algoritmo pode se beneficiar do histórico de posições, principalmente da localização anterior, ao calcular uma nova posição. Através da fórmula da velocidade e sabendo a velocidade do caminhar, pode-se calcular a distância máxima percorrida por uma pessoa no intervalo entre duas estimativas de posições. Essa

heurística nos fornece um raio de busca (distância máxima) entre a posição anterior e a nova posição, eliminando a necessidade de comparação dos pontos que estiverem fora deste raio. Quanto maior o cenário, mais significativa é essa redução.

Exemplificado na Figura 8, uma pessoa caminhando a 2 m/s, com uma estimativa de posição a cada segundo, reduz a área de busca ao círculo com raio R de 2 metros em destaque.




Figura 8: Raio de busca para Histórico de Movimentação.

Essa heurística apresenta benefícios múltiplos. Além da redução do espaço de busca, outro benefício está na redução de efeitos de ruídos, como posições estimadas com erros grandes (i.e., mais de 10 metros). Com essa redução do espaço de busca, a posição se manterá dentro do círculo, fornecendo uma estimativa mais conservadora.

Uma limitação da proposta é que se considera que as posições serão estimadas periodicamente. O raio de busca R é diretamente proporcional a esse período. Quanto mais curto o período, mais próxima uma posição será em relação à anterior. Em contrapartida, períodos longos aumentarão o raio de busca, reduzindo os benefícios da proposta, podendo anular por completamente caso a área de busca seja igual ou maior que a área do ambiente.

A Figura 9 apresenta um fluxograma do procedimento para a estimativa de posição para o algoritmo Histórico de Movimentação. O critério de seleção em questão é o ponto estar contido no raio do movimentação permitida.

3.2.4 Conclusão

Neste capítulo foram apresentadas três modificações para um algoritmo de análise de cena com wkNN.

A primeira proposta apresenta um método alternativo para atribuição dos pesos no cálculo do centroide do algoritmo wkNN através de fatores de qualidade dos pontos coletados.

As outras duas propostas abordam a utilização de estimativas anteriores ao se calcular uma nova estimativa. Uma delas utiliza filtro de Kalman sobre os pontos estimados em um percurso, enquanto a outra se baseia na distância em relação à posição anterior.

No capítulo seguinte cada proposta será avaliada e comparada com os resultados do algoritmo original. Para tanto, serão realizados experimentos em cenários reais e os mesmos dados serão processados pelos distintos algoritmos.

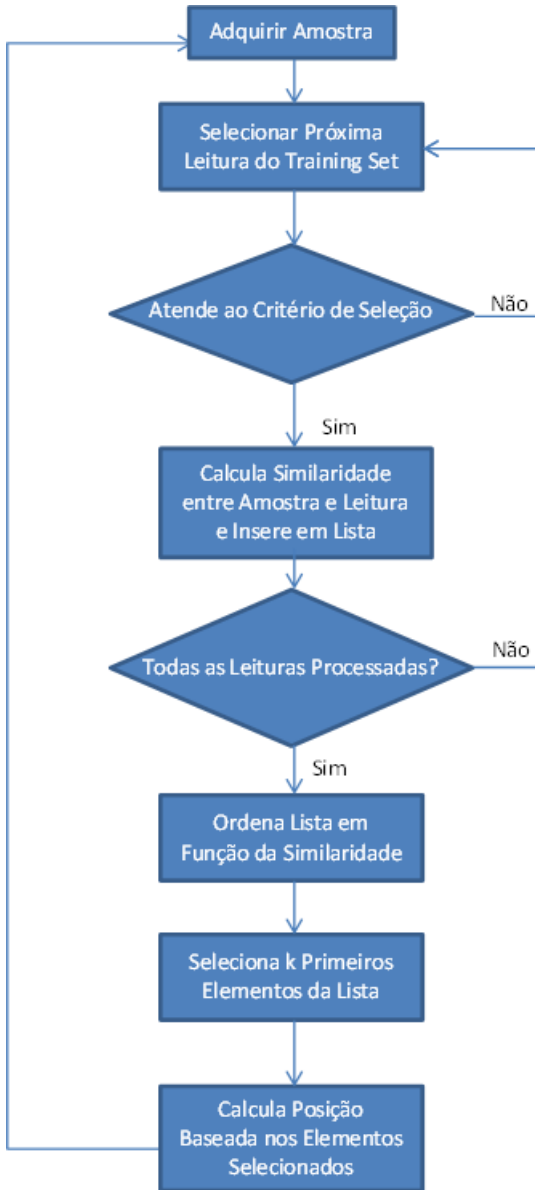


Figura 9: Fluxograma do algoritmo Histórico de Movimentação.

4 AVALIAÇÃO DAS PROPOSTAS

Como forma de avaliação da precisão do sistema proposto, foram realizados alguns experimentos em cenário real.

Dada as características do problema, que consiste em estimar uma posição, a principal métrica a ser avaliada é a precisão da posição estimada. Para isso, será definido o erro da posição estimada como sendo a distância euclidiana entre a posição estimada pelo algoritmo e a posição real de leitura do sinal.

Inicialmente, avaliou-se o algoritmo de análise de cena sem as modificações propostas. Nesta avaliação, buscou-se encontrar os parâmetros ótimos do algoritmo, e um entendimento da influência de cada parâmetro no resultado final.

Em sequência, comparou-se o desempenho do algoritmo wkNN adicionado de fatores de qualidade Q como forma de ponderar os k vizinhos. Como os resultados foram muito similares aos observados pelo wkNN original, nos experimentos seguintes estes valores foram omitidos para efeito de redução de espaço.

Posteriormente se comparam o desempenho do algoritmo wkNN em relação às modificações que utilizam, respectivamente, filtro de Kalman e histórico de movimentação em suas estimativas.

4.1 METODOLOGIA E AMBIENTE DE EXPERIMENTAÇÃO

Nesta seção são descritos a metodologia, ferramentas e os cenários de testes utilizados nos testes.

Os testes foram realizados através da experimentação em ambientes reais, pelos motivos expostos na seção seguinte. As ferramentas desenvolvidas para coleta e execução dos algoritmos e os cenários escolhidos são apresentados e justificados posteriormente.

4.1.1 Metodologia de Avaliação

A abordagem comumente utilizada para a avaliação de sistemas de posicionamento indoor em redes IEEE 802.11 consiste na experimentação em ambiente físico. O algoritmo é executado conforme uma operação real e a posição estimada é comparada com a posição verdadeira, de onde os sinais foram coletados.

Outra maneira de se avaliar um sistema de posicionamento indoor é através da simulação, onde o algoritmo de posicionamento indoor recebe dados criados artificialmente e os utiliza para suas estimativas. Essa abordagem é altamente dependente da qualidade dos dados de entrada. Se os dados refletem o ambiente real, os resultados do sistema serão compatíveis com os observados no ambiente. Caso os dados não representem fielmente o ambiente, os resultados do algoritmo de posicionamento também não representarão os resultados do ambiente real.

Apesar da dificuldade de se modelar com exatidão o comportamento de redes IEEE 802.11 em ambientes indoor (HENDRIK, 2012), o uso de simulações é justificado em um estudo mais exaustivo, onde se relaxa a restrição sobre a qualidade dos dados, porém se possibilita uma maior variação de ambientes e parâmetros. Idealmente, tomaria-se a simulação como um complemento da experimentação.

Como um primeiro estudo, nas avaliações apresentadas neste capítulo optou-se pelo método de experimentação, a fim de validar o desempenho do sistema com dados de cenários reais. Contudo, ao invés de executar os algoritmos no local, as medições de sinais e posições reais foram coletadas e armazenadas para execuções posteriores do algoritmo. Desta maneira, os dados coletados podem ser utilizados múltiplas vezes, possibilitando a análise de variações de parâmetros e comparações entre vários algoritmos sobre um mesmo conjunto de dados.

4.1.2 Arquitetura do Sistema

Conforme exposto anteriormente, as redes IEEE 802.11 são padrão de mercado. Muitos ambientes já possuem a rede implantada e a maioria dos dispositivos móveis, como *smartphones*, possuem essa forma de conectividade.

Dado este contexto, o sistema de posicionamento indoor proposto se baseia em utilizar a infraestrutura de rede existente e em *smartphones* como unidades móveis, através do desenvolvimento um aplicativo para localização do usuário.

Com a evolução do sistema, foi desenvolvido um dispositivo eletrônico em formato de crachá, com a função específica de fornecer a localização de seu portador. Essa fato demandou a modificação da arquitetura para atender ao requisito de estimativa de posição remota.

Ambas arquitetura são apresentadas ao longo das seções seguintes.

4.1.2.1 Aplicativo para Smartphone

Na arquitetura original do sistema de posicionamento indoor proposto, um *smartphone* realiza as coletas da fase *offline*, e repassa essas informações para um servidor central. Estas informações, juntamente com o mapa e demais dados do ambiente se tornam acessíveis a outros *smartphones*, que podem então realizar suas estimativas de posição e exibi-las ao usuário em um mapa interativo (fase *online*), no próprio dispositivo.

Esta arquitetura se baseia na topologia **Auto-Posicionamento**. A Figura 10 apresenta um diagrama desta arquitetura.

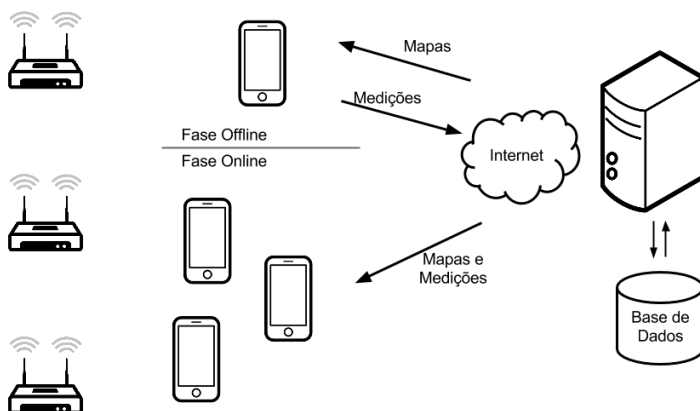


Figura 10: Arquitetura do sistema para o aplicativo smartphone.

As coletas de sinais devem ser realizadas em locais determinados, sendo necessário um bom grau de mobilidade para o desempenho desta função.

Como esta é uma tarefa trabalhosa, exigindo o deslocamento por todo o ambiente, foi desenvolvido um aplicativo para *smartphone* para auxiliar nesta tarefa chamado Urbiii e ilustrado na Figura 11.



Figura 11: Aplicativo realizando coleta de sinais.

O aplicativo apresenta um mapa do ambiente, onde o projetista deve marcar sua posição. No momento em que a posição é marcada, o aplicativo inicia uma coleta de sinal, armazena as informações em sua base de dados local e marca o local na tela, para notificar o projetista.

Uma segunda função, para agilizar o processo de coleta consiste em leituras periódicas consecutivas. Escolhendo essa função, o projetista marca sua posição inicial no aplicativo, desloca-se em velocidade constante e em linha reta, e assim que parar, marca seu ponto de destino no aplicativo. Internamente, o aplicativo realiza coletas consecutivas e associa com pontos ao longo do trajeto demarcado.

Após o processo de coleta, os dados podem ser exportados e usados na estimativas de posição da fase online.

O aplicativo também possui a função de estimar a posição em tempo real, conforme a Figura 12.

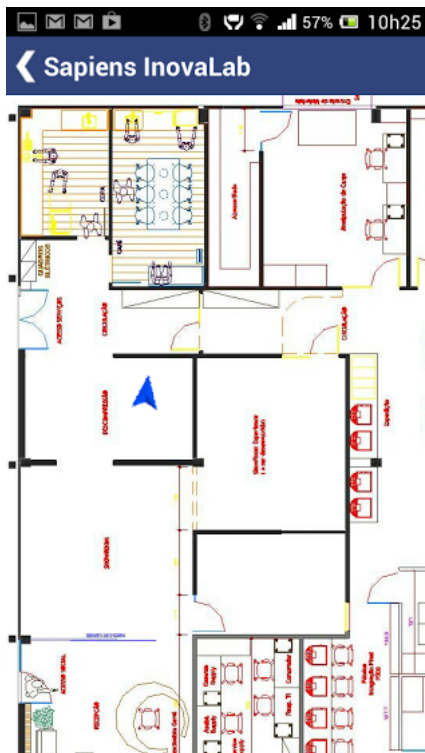


Figura 12: Aplicativo estimando posição em tempo real.

A utilização do sistema implicou no surgimento de novas demandas e melhorias. Dentre elas, a necessidade de um equipamento mais robusto, dedicado exclusivamente à localização e com maior duração de bateria. Para tanto, foi desenvolvido um dispositivo (crachá) eletrônico, cuja função é substituir o *smartphone* nesta aplicação e que será apresentado na seção seguinte.

4.1.2.2 Crachá WiFi

Para muitas aplicações práticas, a utilização de um *smartphone* para a localização é inconveniente, principalmente porque um profissional deve idealmente ter as mãos livres e não interromper seu trabalho enquanto sua posição é determinada.

Outro empecilho relacionado ao uso do *smartphone*, é a baixa duração da carga da bateria, que exige uma interrupção para recarga aproximadamente uma vez ao dia. Para uso cotidiano do sistema, como em um hospital, utilizar *smartphones* para localizar profissionais e efetuar a recarga diariamente exige um complexo trabalho, praticamente inviabilizando a aplicação.

Dada estas restrições, optou-se pelo desenvolvido um dispositivo eletrônico em formato de crachá, cuja função é substituir o *smartphone* no sistema de posicionamento indoor. Este crachá eletrônico (*wearable technology*) é um dispositivo WiFi que apresenta baixo consumo, suprindo as necessidades levantadas. As Figuras 13 e 14 apresentam imagens do Crachá WiFi.



Figura 13: Crachá WiFi.



Figura 14: Hardware do Crachá WiFi.

O crachá WiFi utiliza o módulo de rádio RN-171 do fabricante Microchip. Sua arquitetura é apresentada na Figura 15.

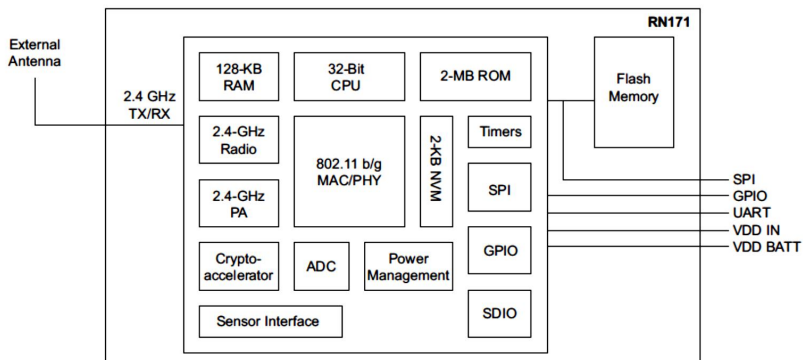


Figura 15: Arquitetura do módulo RN-171 - Microchip.

Uma avaliação da duração da bateria do crachá WiFi é apresen-

tada na Figura 16. No gráfico, o eixo horizontal apresenta as datas ao longo das quais a avaliação foi realizada e o eixo vertical apresenta a medição da voltagem da bateria, sendo que o crachá se mantém operacional entre 3 e 4 volts.

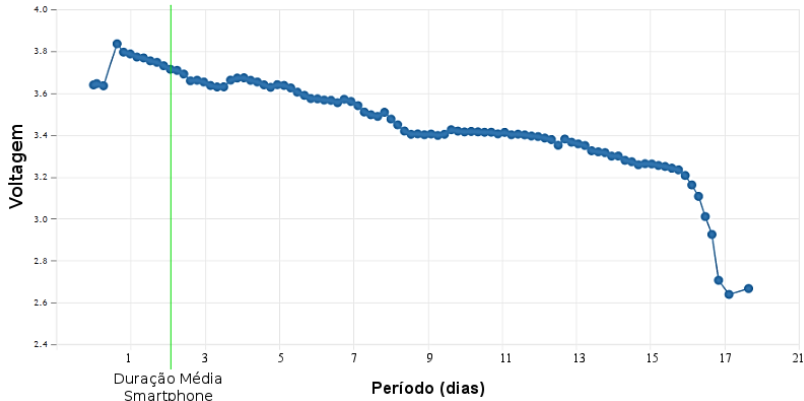


Figura 16: Duração da bateria do Crachá WiFi.

Neste teste, o crachá realizou medições de RSSIs para estimativas de posição a cada 10 segundos, entrando em modo de baixo consumo (*sleep mode*) em seguida. A bateria recarregável utilizada no teste é uma bateria de lítio-polímero com capacidade de 1000 mAh. Como pode se observar, foram efetuados 15 dias de posicionamento com uma única recarga da bateria.

A arquitetura do sistema é diferente da utilizada no aplicativo *smartphone*. Devido à reduzida capacidade computacional e a fim de minimizar o consumo de energia do crachá, os cálculos de estimativa de posição são realizados em um servidor remoto. O crachá periodicamente coleta os RSSIs e envia ao servidor, que estima a posição e a fornece através de uma interface *Web*. Essa arquitetura é um exemplo da topologia **Posicionamento Remoto Indireto** e é representada pelo diagrama da Figura 17.

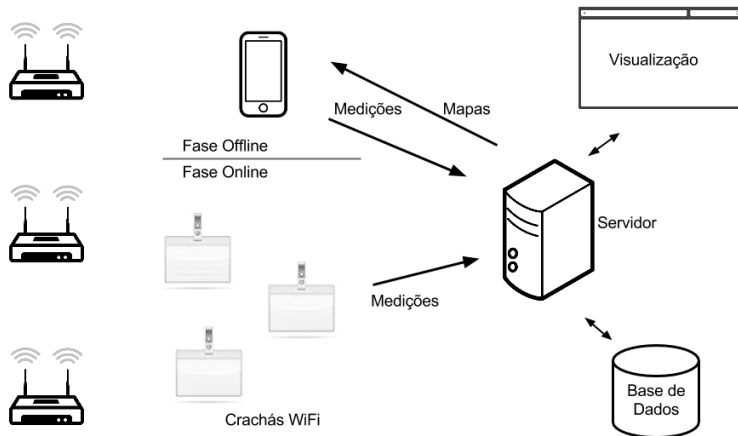


Figura 17: Arquitetura do sistema para o Crachá WiFi.

A utilização do crachá apresenta benefícios múltiplos no uso diário do sistema. Primeiramente, é um dispositivo dedicado, evitando interações indevidas. Além disso, não requer manuseio, bastando apenas ser portado pelo usuário. Outra vantagem é a bateria com longa duração, reduzindo procedimentos de recarga.

Uma desvantagem em relação ao *smartphone* é o fato da posição ser calculada remotamente, impossibilitando o usuário de ter total controle sobre a informação da sua localização.

Sugestões para desenvolvimentos futuros do crachá incluem um visor para troca de mensagens e botões para interações básicas, como confirmar e cancelar mensagens.

4.1.2.3 Servidor Web

A fim de manter um repositório de mapas e dos dados de coletas de sinais, foi desenvolvido um servidor web para o sistema. Além de centralizar os dados, o servidor possui a função de manter as informações sobre as posições dos dispositivos.

Para ambas topologias, as informações de localização em tempo real são disponibilizadas em uma interface *Web*, através de um mapa interativo do ambiente, conforme a Figura 18.



Figura 18: Mapa em tempo real com a localização dos crachás.

Além da posição mais recente de cada dispositivo, o sistema também armazena o histórico de posições a fim de apresentar relatórios aos usuários. Um exemplo de relatório gerado pelo sistema está na Figura19, que representa uma mapa de calor das áreas com maior circulação em um hemocentro.

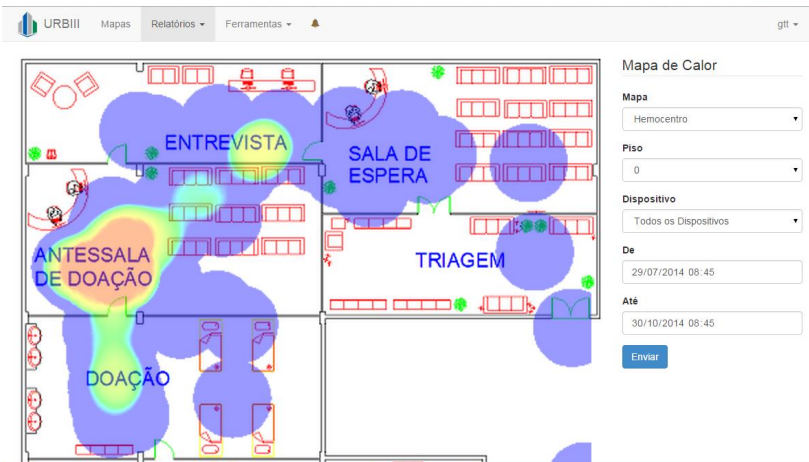


Figura 19: Mapa de calor das áreas com maior circulação.

As áreas de cores mais quentes (vermelho, laranja e amarelo) representam as áreas com maior movimentação de pessoas. No exemplo da figura, a antessala de doação é onde se concentrou a maior movimentação para o período. De porte destas informações, podem ser tomadas medidas para melhorar o atendimento, como por exemplo disponibilizar mais atendentes nesta área.

O sistema também permite a criação de alertas, como a delimitação de zonas onde a circulação é restrita. Qualquer dispositivo se deslocando em uma zona restrita, gera notificações para os administradores do sistema. Outros alertas incluem tempo de permanência e entrada e saída de áreas.

4.1.3 Cenários de Testes

Para fornecer dados para os experimentos, foram selecionados dois ambientes distintos.

O **Cenário A** é um prédio empresarial, localizado no Sapiens Parque em Florianópolis-SC. A construção conta com 2 pisos, sendo 450m^2 por andar, totalizando uma área de 900m^2 . O ambiente possui disposição variada, contendo desde salas pequenas ($4\text{m} \times 2,5\text{m}$) a ambientes amplos (mais de 200m^2). No ambiente são mensurados 11 APs, sendo alguns com cobertura parcial do ambiente. As plantas baixas estão ilustradas nas Figuras 20 e 21.



Figura 20: Piso térreo do cenário de testes A.




Figura 21: Primeiro andar do cenário de testes A.

O **Cenário B** para os experimentos é o shopping center Floripa Shopping em Florianópolis-SC. Devido ao seu vasto espaço, a área de coleta se limitou ao segundo piso. Esta área foi escolhida por apresentar espaços distintos, com áreas fechadas, como banheiros, corredores e ambientes amplos, como um hall, além da particularidade de apresentar um vão entre andares, a qual se mostrou uma área crítica para os algoritmos.

A escolha de dois cenários se deu apenas por motivos operacionais. As coletas de dados do cenário A foram feitas de modo independente, sem levar em consideração o percurso envolvido. O objetivo era atender as necessidades dos experimentos para a proposta do algoritmo wkNN com fator de qualidade e a influência dos parâmetros.

Posteriormente, foram elaboradas as propostas com filtro de Kalman e histórico de movimentação, as quais demandaram coletas de dados com informações de sequência de posições. Nesta etapa, o cenário A estava inacessível, implicando no uso do cenário B.

4.2 AVALIAÇÃO DA INFLUÊNCIA DOS PARÂMETROS NO ALGORITMO WKNN

Os testes apresentados nesta seção tem como objetivo avaliar como a estimativa gerada pelo algoritmo de análise de cena é influenciada por cada parâmetro individualmente.

Para esta análise, foram realizadas duas coletas de dados. A primeira coleta foi usada para a calibração do sistema (fase *offline*). A

segunda coleta foi utilizada como conjunto de prova, para comparação dos resultados estimados.

Utilizando o mesmo conjunto de dados, foram realizadas várias execuções do algoritmo com variações nos parâmetros, a fim de analisar a influência de cada um no algoritmo de análise de cena, como o valor de k , *threshold*, entre outros.

Os experimentos foram executados através da coleta de dados de sinais no Cenário A. Em cada simulação, cada um dos pontos do conjunto de prova foi avaliado e a posição estimada pelo algoritmo foi comparada com a posição real de coleta através da distância euclidiana entre as posições.

4.2.1 Algoritmos e valor de K

Nesta análise, executou-se sobre o mesmo conjunto de dados as variações do algoritmo kNN mais frequentemente encontradas na literatura.

Foram analisados os algoritmos NN, kNN e wkNN. Também foram analisados variações do valor de K em cada algoritmo aplicável.

Tabela 2: Comparação de resultados entre os algoritmos.

Algoritmo	Valor de k	Erro Médio (m)	Mediano (m)	Erro Máximo (m)
NN	1	3,15	2,89	14,30
kNN	3	2,79	2,43	17,35
wkNN	3	2,78	2,43	17,34
kNN	5	2,67	2,21	18,17
wkNN	5	2,66	2,21	18,15
kNN	7	2,71	2,34	15,54
wkNN	7	2,69	2,33	15,59

Pelos resultados expostos na Tabela 2, pode-se notar que os algoritmos kNN e wkNN apresentaram melhores resultados que o NN. Entretanto, os resultados entre ambos se mostraram muito próximos, não havendo melhorias significativas.

Os valores de k apresentam pouca melhoria entre si, porém apresentam ganhos em relação ao k igual a 1. De maneira similar ao encontrado na literatura, o valor de k igual a 5 apresentou os melhores

resultados.

4.2.2 Threshold

O valor que limita se um valor de leitura de um ponto de acesso será utilizado ou não no cálculo é o *threshold*. Esse valor também é utilizado como padrão no caso de pontos de acesso que não foram encontrados na leitura. A Tabela 3 mostra a variação na precisão das estimativas, conforme variou-se o *threshold* no algoritmo wkNN, com valor de k igual a 5.

Tabela 3: Resultados com variação no parâmetro Threshold.

Threshold (dBm)	Erro Médio (m)	Mediano (m)	Erro Máximo (m)
-70	2,84	2,40	19,46
-75	2,79	2,28	19,45
-80	2,66	2,21	18,15
-85	2,78	2,51	14,35
-90	2,81	2,59	13,66
-110	2,93	2,61	15,23

Pode-se notar que a influência é significativa, como por exemplo ao variar de -110 dBm a -80 dBm tem-se um ganho no erro médio de 27 cm, equivalendo a 10% da precisão.

Como mencionado anteriormente, o valor ideal do *threshold* deve ter pouca influência no cálculo da dissimilaridade ao representar pontos de acessos não encontrados. Valores mais próximos a sinais de boa qualidade, como -70 dBm na Tabela 3, acabam por ter um peso significativo ao se comparar com um sinal existente porém mais fracos. Isso faz com que posições corretas sejam consideradas menos similares, aumentando o erro da estimativa da posição.

No outro extremo da tabela, valores como -90 e -110 dBm, trabalham com valores próximos ao limite da captação de sinal pelo dispositivo, fazendo com que um ponto de acesso esteja presente em algumas leituras e ausente em outras, para um mesmo local. Quando isso ocorre, posições que deveriam ser similares são tidas como distintas, afetando a precisão da estimativa.

Portanto, o *threshold* é um parâmetro importante a ser analisado por projetistas de sistemas de posicionamento indoor.

4.2.3 Centroide

Para a análise da influência do centroide, foram testados os cálculos por Média Simples (MP) e Média Ponderada (MP). Foram usados os melhores valores dos parâmetros dos testes anteriores (algoritmo wkNN, *threshold* de -80dBm e k variados, conforme a tabela).

Tabela 4: Resultados ao variar cálculo de centroide.

Valor de k	Centroide	Erro Médio (m)	Mediano (m)	Erro Máximo (m)
3	MS	2,79	2,43	17,35
3	MP	2,78	2,43	17,34
5	MS	2,67	2,21	18,17
5	MP	2,66	2,21	18,15
7	MS	2,70	2,34	15,54
7	MP	2,68	2,33	15,59

Pelos resultados obtidos, observa-se que diferentes estratégias para cálculo da centroide pouco influenciam no resultado final. A diferença no erro fica em média de 1 a 2 cm, o que para o objetivo proposto pode ser considerado desprezível.

4.2.4 Conclusão

De maneira geral, podemos afirmar que o valor de k tem o papel mais influente. Comparando os algoritmos com valores de k igual a 1 (NN) e k igual à 5 (wkNN), nota-se que o erro médio cai de 3,15 m para 2,66 m, uma melhoria de 18%. Outro parâmetro que muda a qualidade consideravelmente é o *threshold*, alterando em até 10% o resultado.

Vale destacar que estes valores foram obtidos para o cenário em questão. Sendo necessário um estudo mais aprofundado para verificar se os mesmos se mantêm em outros cenários.

4.3 ANÁLISE DE CENA COM FATOR DE QUALIDADE

O objetivo deste experimento foi verificar se houve melhorias com a proposta de atribuição do fator de qualidade Q para os pontos

de calibração. Os testes foram realizados no **Cenário A**.

Para esta análise, foram realizadas duas coletas de dados. A primeira coleta foi usada para a calibração do sistema e a outra como conjunto de prova, para comparação dos resultados estimados com as posições reais de medição. Além dos distintos algoritmos, também foram analisadas variações dos valores de k , a fim de verificar se eventuais melhorias se manteriam nas diferentes variantes.

Nos testes foram observados erros médios de 2,66 metros para o algoritmo wkNN enquanto com a utilização do fator de qualidade Q o erro médio ficou em 2,62 metros, para k igual a 5. Com k igual a 3, o erro médio de wkNN foi 2,78 metros e 2,83 metros ao usar o fator de qualidade, conforme listados na Tabela 5.

Tabela 5: Resultados da proposta Fator de Qualidade.

Algoritmo	Valor de k	Erro Médio (m)	Mediano (m)	Erro Máximo (m)
wkNN	3	2,78	2,43	17,34
wkNN + Q	3	2,83	2,50	17,91
wkNN	5	2,66	2,21	18,15
wkNN + Q	5	2,62	2,26	18,08
wkNN	7	2,68	2,33	15,59
wkNN + Q	7	2,78	2,49	17,64

Esta modificação propõe uma maneira alternativa de calcular o centroide, sem que haja modificações em outros parâmetros do algoritmo. Conforme observado nos experimentos da seção anterior, os diferentes cálculos de centroide pouco influenciaram no resultado final. Espelhando esses resultados, a proposta também não apresentou melhorias significativas na precisão do sistema.

Como a modificação proposta não apresenta ganhos significativos em relação ao algoritmo wkNN original, as comparações das seções seguintes serão acompanhadas somente dos resultados do algoritmo wkNN, por motivo de brevidade.

4.4 ANÁLISE DE CENA COM FILTRO DE KALMAN E HISTÓRICO DE MOVIMENTAÇÃO

Como ambas modificações levam em conta uma sequência de estimativas, para avaliar o desempenho das modificações wkNN com Filtro de Kalman e wkNN com Histórico de Movimentação, os experimentos seguintes envolvem estimativas de posição ao longo de percursos, e não apenas posições independentes, como no experimento anterior, uma vez que há influência de posição anterior no cálculo de uma nova estimativa.

A fim de caracterizar diferentes condições do ambiente e verificar o comportamento das modificações de forma mais abrangente, foram realizados distintos percursos. Ao longo dos percursos, uma coleta de sinais era realizada a cada segundo.

Os parâmetros utilizados nos algoritmos foram os valores ótimos estipulados após a realização de vários estudos e simulações, sendo que para os experimentos, utilizou-se o valor de k sendo 5 e para o histórico de movimentação usou-se a velocidade de deslocamento como 1,5 m/s. Essa é a velocidade média preferida de deslocamento de uma pessoa (LEVINE; NORENZAYAN, 1999).

A seguir são apresentados três percursos realizados. Os diferentes trajetos foram percorridos no **Cenário B**.

4.4.1 Percurso 1

O primeiro percurso compreendeu uma movimentação ilustrada pela linha contínua na Figura 22. O objetivo deste percurso foi caracterizar uma movimentação usual realizada por uma pessoa no ambiente, abrangendo áreas com disposições distintas.

O trajeto teve início em frente aos banheiros, percorreu um corredor entre lojas, contornou o Vão 1 e finalizou pelo corredor de serviços. O início e fim do trajeto foram em espaços mais reduzidos, enquanto o meio passou por um espaço mais amplo, em torno do Vão 1.




Figura 22: Caminho realizado e estimativas para Percurso 1.

Neste primeiro percurso, podemos notar que o algoritmo wkNN por vezes obtém estimativas que se distanciam significativamente do caminho real percorrido, principalmente em áreas amplas. A utilização do filtro de Kalman minimiza essas ocorrências, por filtrar esses valores. Porém percebe-se que ao modificar a direção do percurso, como virar à esquerda após um corredor, a estimativa do filtro de Kalman demora a convergir.

Essa particularidade é reduzida significativamente no algoritmo com histórico de movimentação, onde nota-se uma maior proximidade com o caminho real. Podemos observar que este algoritmo se assemelha ao resultado do filtro de Kalman durante grande parte do trajeto, porém com a vantagem de um alinhamento maior com o caminho real durante uma mudança de direção. Essa maior aproximação se reflete em uma estimativa mais precisa.

A Tabela 6 sumariza os resultados obtidos no percurso. Ao longo do percurso, medições de sinais foram realizadas uma vez a cada segundo e as posições foram estimadas. Para cada posição estimada, foi calculada o erro, como sendo a distância euclidiana em relação à posição real de coleta. A partir de todos os pontos, foram calculados o erro

médio, desvio padrão e erro máximo para cada algoritmo analisado.

Tabela 6: Resultados dos algoritmos para o Percurso 1.

Algoritmo	Erro Médio (m)	Desvio Padrão (m)	Erro Máximo (m)
wkNN	5,98	2,86	12,41
wkNN + Kalman	3,20	1,11	6,83
wkNN + Histórico	2,35	1,07	5,17

Conforme se observa na Tabela 6, o erro é reduzido significativamente, partindo de um erro médio de 5,98 m com o wkNN e 3,20 m pelo filtro de Kalman para 2,35 m através do histórico de movimentação, uma melhoria de 60% e 26%, respectivamente, para o percurso realizado.

Uma maneira de visualizar comparativamente o desempenho de cada algoritmo é através do gráfico da função de distribuição acumulada (FDA) do erro. Esta função F representa a probabilidade P de que o erro de uma estimativa X seja igual ou inferior que um determinado erro x :

$$F(x) = P(X \leq x) \quad (4.1)$$

Este gráfico pode ser gerado a partir dos valores observados no experimento.

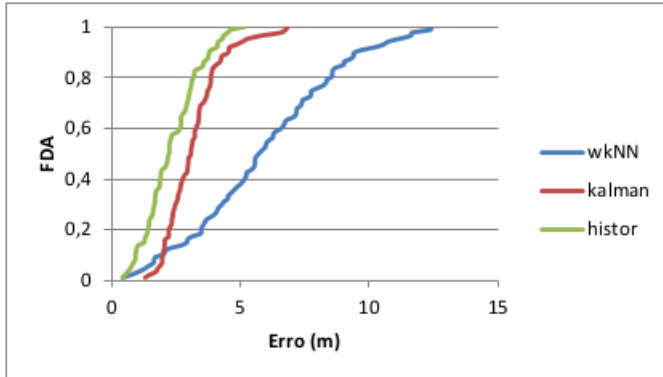


Figura 23: Função distribuição acumulada do erro para o Percurso 1.

Visualizando a função de distribuição acumulada do erro na Figura 23, podemos observar que 90% das estimativas realizadas pelo wkNN situam-se na faixa de 0 m à 9,67 m; pelo filtro de Kalman, a faixa vai de 0 m à 4,57 m; enquanto no histórico de movimentação, 90% das estimativas possuem um erro inferior à 3,85 m.

Neste tipo de cenário, pode-se verificar que os algoritmos propostos superam de maneira significativa a precisão alcançada pelo algoritmo wkNN original. Destaca-se o desempenho da modificação wkNN com histórico de movimentação, que obteve os melhores resultados, inclusive em relação ao filtro de Kalman, principalmente por se aproximar do trajeto real onde houve mudanças na direção do percurso.

4.4.2 Percurso 2

Observando-se que o vão entre os pisos se mostrou uma área sensível para os algoritmos, no Percurso 2 objetivou-se verificar o comportamento das modificações especificamente nesta área crítica. O caminho percorrido se restringiu a contornar esse vão.




Figura 24: Caminho realizado e estimativas para Percurso 2.

Como pode-se ver na Figura 24, os resultados das modificações foram bastante afetados nessa região. Por ser um trajeto curto e com alternâncias acentuadas nas posições estimada pelo wkNN, os algoritmos com Filtro de Kalman e Histórico de Movimentação não conseguiram alcançar bons resultados, conforme Tabela 7.

Tabela 7: Resultados dos algoritmos para o Percurso 2.

Algoritmo	Erro Médio (m)	Desvio Padrão (m)	Erro Máximo (m)
wkNN	4,49	2,90	12,50
wkNN + Kalman	7,74	3,03	13,38
wkNN + Histórico	7,26	2,83	12,48

O gráfico da função de distribuição acumulada do erro na Figura 25, auxilia na visualização do pior desempenho das propostas. Pode-se ver que a grande maioria das estimativas têm erros entre 7 e 10 metros.

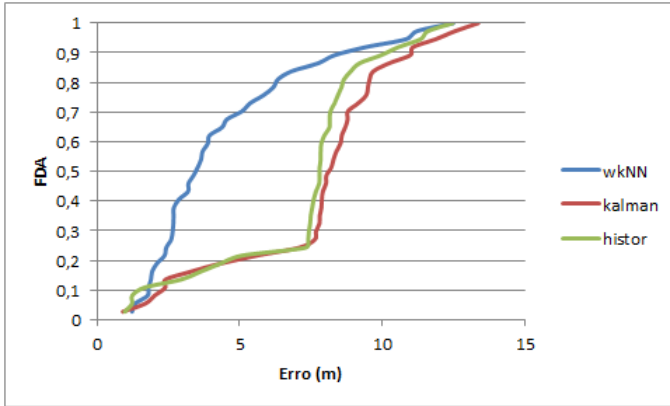


Figura 25: Função distribuição acumulada do erro para o Percurso 2.

Por este experimento, percebe-se que a área se coloca como um desafio para as modificações propostas. O fato da posição estimada oscilar, faz com que as modificações não consigam chegar em um valor próximo do real.

Uma maneira de lidar seria através da demarcação de áreas de exclusão, ou seja, áreas em que é fisicamente impossível uma movimentação, como por exemplo, a posição ser estimada no vão entre os andares. No caso de uma posição ser estimada dentro desta área de exclusão, deve-se alocar a posição para seu exterior ou borda.

Com essa abordagem, o mesmo percurso foi reavaliado e os resultados são apresentados na Tabela 8.

Tabela 8: Resultados para o Percurso 2 com áreas de exclusão.

Algoritmo	Erro Médio (m)
wkNN	4,49
wkNN + Kalman	4,63
wkNN + Histórico	4,54




Figura 26: Função distribuição acumulada do erro para o Percurso 2 com áreas de exclusão.

Através do auxílio de áreas de exclusão, as modificações propostas conseguem se aproximar do trajeto real, conforme FDA da Figura 26, diminuindo o erro médio e alcançando desempenho similar ao algoritmo original neste tipo de área. Entretanto, isso implica em um trabalho adicional na elaboração do mapa do ambiente.

4.4.3 Percurso 3

No terceiro percurso almejou-se verificar se a posição estimada sofreria com a alternância da direção da movimentação. Para isso, percorreu-se um caminho similar ao realizado pelo Percurso 1, porém em direção contrária. O percurso teve início no corredor de serviços e contornou os Vãos 1 e 2, antes de finalizar, em frente aos banheiros.




Figura 27: Caminho realizado e estimativas para Percorso 3.

Novamente pode-se constatar pela Figura 27 que as áreas com vãos apresentam resultados com maior discrepância, tanto para o algoritmo wkNN como para as modificações. Porém, nota-se que nas demais regiões, as propostas conseguiram se aproximar do percurso real.

Pode-se, mais uma vez, observar que o Histórico de Movimentação consegue lidar melhor com mudanças no trajeto, como visto nas etapas finais do percurso. Enquanto o Filtro de Kalman suaviza as quinas, o Histórico de Movimentação encosta no caminho real em muitos pontos.




Figura 28: Função distribuição acumulada do erro para o Percurso 3

Pela FDA na Figura 28, podemos verificar que ambas modificações, no geral, se comportam melhor que o algoritmo wkNN. A título de comparação, tomando-se novamente o percentil do erro, temos que 90% das posições são estimadas com erro inferior a 8,81 m para wkNN; com Filtro de Kalman: 7,06 m; enquanto para o Histórico de Movimentação esse valor cai para 6,58 m.

Tabela 9: Resultados dos algoritmos para o Percurso 3.

Algoritmo	Erro Médio (m)	Desvio Padrão (m)	Erro Máximo (m)
wkNN	4,70	2,75	10,91
wkNN + Kalman	4,48	1,83	8,93
wkNN + Histórico	3,24	2,08	9,29

Na Tabela 9, podemos verificar que o erro médio para o wkNN e Filtro de Kalman estão próximos, enquanto para o Histórico de Movimentação melhorou-se o erro médio em 1,46 m, um ganho de 31% em relação ao wkNN.

Em conclusão, podemos constatar os seguintes resultados a partir dos experimento apresentados.

O filtro de Kalman elimina posições distantes do trajeto, como por exemplo no lado oposto do Vão 1, porém demora a convergir quando

há mudanças na direção do trajeto, reduzindo assim seus ganhos.

Já a proposta do algoritmo wkNN com histórico de movimentação consegue filtrar posições distantes e manter-se próximo do caminho real durante mudanças de direção no trajeto, potencializando seus resultados.

4.5 ANÁLISE DOS RESULTADOS

Pelos resultados dos experimentos, podemos perceber que a modificação proposta pela inclusão do histórico de movimentação no cálculo da estimativa de posição se mostrou significativamente superior aos demais resultados. Para o Percurso 1, nota-se que o Histórico de Movimentação se apresenta mais próximo que os demais do caminho realizado pela maior parte do trajeto. Isso se reflete no menor erro médio apresentado na tabela e além de um menor desvio padrão.

No Percurso 2, foi apresentado um caso crítico, em que a performance de ambas as modificações ao algoritmo wkNN apresentaram resultados inferiores. As particularidades do cenário, como o vão e ambiente amplo, além do percurso mais curto, foram fatores que influenciaram no resultado. A limitação das estimativas através da demarcação de áreas de exclusão, conseguiu com que as propostas tivessem desempenhos similares ao wkNN original, apesar do esforço adicional.

Finalmente, pelos resultados do Percurso 3, nota-se que novamente a região com vãos foi crítica e influenciou negativamente o resultado das estimativas, porém a inversão da direção de movimentação não afetou significativamente as estimativas, como pode ser observado no restante do trajeto.

Estes resultados preliminares são promissores, entretanto deve-se observar os limites do estudo. Foram concentrados esforços para que as avaliações abrangessem distintas configurações do ambiente, como por exemplo espaços com corredores, vãos, salas de diversos tamanhos, entre outros. Porém, nota-se que consiste de um ambiente específico. Para afirmações mais precisas quanto às propostas, mais avaliações devem ser conduzidas. Idealmente, avaliações deveriam ser realizadas em um número maior de ambientes. Outra abordagem seria a utilização de simulações, a fim de avaliar variações de ambientes e parâmetros.

5 CONCLUSÃO

A localização indoor se faz importante em muitas aplicações, principalmente dado o fato de que as pessoas passam a maior parte de seu tempo em ambientes fechados.

Este trabalho apresentou um estudo sobre um sistema de posicionamento indoor baseado no algoritmo de análise de cena via redes IEEE 802.11.

O padrão IEEE 802.11 foi escolhido como infraestrutura de rede por estar prontamente disponível em muitos ambientes, e por dispositivos móveis pessoais poderem ser usados para determinar a localização, reduzindo complexidades e custos de implantação.

Através de ensaios e da revisão de trabalhos relacionados, observou-se que o algoritmo de trilateração não apresenta bons resultados em redes IEEE 802.11, principalmente devido à variação do RSSI observado.

Desta forma, optou-se por utilizar o algoritmo de análise de cena no processo de estimativa de posição, que juntamente com wkNN, apresenta os melhores resultados em sistema de posicionamento indoor.

Estes algoritmos serviram como base para as três modificações propostas e avaliadas no presente trabalho.

A primeira proposta consiste na atribuição de um fator de qualidade para os pontos coletados na fase *offline*. Este fator é utilizado para ponderar os valores no cálculo de centroide no algoritmo wkNN. Esta proposta se mostrou ineficaz, adicionando etapas ao processo e apresentando resultados praticamente idênticos ao algoritmo original.

A segunda proposta foi a utilização do filtro de Kalman na sequência de posições estimadas. O objetivo seria filtrar posições discrepantes, levando-se em conta que as posições são calculadas através de uma movimentação contínua de um indivíduo ou objeto. Os resultados mostraram melhorias em relação ao algoritmo original na maioria dos testes.

A terceira proposta consiste na utilização do histórico de movimentação ao se estimar uma posição. A proposta consiste em verificar a distância máxima que se pode percorrer entre estimativas e limitar uma estimativa a esta distância em relação à estimativa de posição anterior.

Como um primeiro estudo das propostas, foram feitas avaliações destas em alguns cenários e experimentos. Pode-se observar pelas avaliações realizadas que a modificação proposta através da utilização do histórico de movimentação obteve os melhores resultados, apresentando melhorias em relação à posição estimada pelo algoritmo wkNN original

e em relação ao algoritmo acrescido do filtro de Kalman. A proposta também se mostra viável por não adicionar uma complexidade computacional significativa.

Um vão entre andares se mostrou uma área crítica e mais estudos devem ser conduzidos a fim de identificar outras possíveis áreas onde a proposta apresenta resultado inferior ao algoritmo original. Paralelamente, foi realizada uma avaliação dos parâmetros do sistema, onde foram levantados individualmente o grau de influência de cada parâmetro na precisão da posição estimada.

De modo geral, os objetivos iniciais do trabalho foram atingidos, porém muitos pontos ainda podem ser investigados e são sugeridos como trabalhos futuros.

Uma primeira sugestão para trabalhos futuros consiste na realização de mais testes exaustivos. O trabalho considerou cenários variados, porém especificidades de outros ambientes podem refletir em resultados significativamente diferentes dos obtidos pelo trabalho. A realização de mais testes pode ajudar a identificar estes possíveis pontos.

Uma dificuldade encontrada durante o trabalho foi a falta de um conjunto de dados ou um ambiente padrão para a avaliação dos algoritmos. Cada trabalho relacionado efetua experimentos em um cenário físico distinto, com características próprias, inviabilizando uma comparação justa entre os sistemas propostos, principalmente com relação à precisão obtida. A definição de um conjunto de dados padrão melhoraria a avaliação.

A fase *offline* do algoritmo de análise de cena exige a coleta de sinais por toda a área do ambiente. Além disso, a precisão do sistema está diretamente relacionada à qualidade da coleta realizada. Novas abordagens devem ser estudadas para reduzir o tempo e o trabalho envolvido nesta etapa.

Para melhorias específicas ao histórico de movimentação, uma sugestão seria flexibilizar o raio de movimentação considerado, através de um cálculo de velocidade de movimentação dinâmico, a partir das movimentações observadas. Além do raio de movimentação, outras heurísticas poderiam ser levadas em consideração, como por exemplo a direção da movimentação e a aceleração.

A integração com outras redes e sensores não foi abordada neste trabalho, porém estudos relacionados apresentam ganhos ao utilizar a combinação de tecnologias, e é outro ponto a ser levado em conta para novos trabalhos em sistemas de posicionamento indoor.

O presente trabalho resultou na submissão do artigo "Um Al-

goritmo de Análise de Cena Modificado para Localização Indoor via Redes IEEE 802.11"(CONTE, E.; FARINES, J. M.) para o XXXIII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos - SBRC 2015, o qual ainda se encontra em fase de avaliação.

A pesquisa realizada serviu como base para o desenvolvimento de um novo produto para a empresa Ubicom Sistemas Ltda, o sistema de posicionamento indoor Urbiii.

REFERÊNCIAS

- AIUBE, F. A. Modelagem dos preços futuros de commodities: abordagem pelo filtro de partículas. *Modelagem dos preços futuros de commodities: abordagem pelo filtro de partículas*, 2005.
- ALI-LOYTTY, S. et al. Fingerprint kalman filter in indoor positioning applications. In: IEEE. *Control Applications, (CCA) & Intelligent Control, (ISIC), 2009 IEEE*. [S.l.], 2009. p. 1678–1683.
- BAHL, P.; PADMANABHAN, V. N. Radar: An in-building rf-based user location and tracking system. In: IEEE. *INFOCOM 2000. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies. Proceedings. IEEE*. [S.l.], 2000. v. 2, p. 775–784.
- BLACKRNAN, S.; HOUSE, A. Design and analysis of modern tracking systems. *Boston, MA: Artech House*, 1999.
- BOSE, A.; FOH, C. H. A practical path loss model for indoor wifi positioning enhancement. In: IEEE. *Information, Communications & Signal Processing, 2007 6th International Conference on*. [S.l.], 2007. p. 1–5.
- BUTLER, B.; AHIMOVIC, S. *Testing E911 - EETimes*. 2012. [acesso 7 fevereiro 2015]. <http://www.eetimes.com/document.asp?doc_id=1279574>.
- CUEVAS, E. V. Kalman filter for vision tracking. 2005.
- HAEBERLEN, A. et al. Practical robust localization over large-scale 802.11 wireless networks. In: ACM. *Proceedings of the 10th annual international conference on Mobile computing and networking*. [S.l.], 2004. p. 70–84.
- HANSSON, A.; TUFVESSON, L. Using sensor equipped smartphones to localize wifi access points. *Department of Automatic Control May, Lund University*, 2011.
- HENDRIK, L. *Improved Tracking with IEEE 802.11 and Location Fingerprinting*. Dissertação (Mestrado) — Universität Mannheim, 2012.

KAEMARUNGSU, K.; KRISHNAMURTHY, P. Analysis of wlan's received signal strength indication for indoor location fingerprinting. *Pervasive and mobile computing*, Elsevier, v. 8, n. 2, p. 292–316, 2012.

KALMAN, R. E. A new approach to linear filtering and prediction problems. *Journal of Fluids Engineering*, American Society of Mechanical Engineers, v. 82, n. 1, p. 35–45, 1960.

KESSEL, M.; WERNER, M. Smartpos: Accurate and precise indoor positioning on mobile phones. In: *MOBILITY 2011, The First International Conference on Mobile Services, Resources, and Users*. [S.l.: s.n.], 2011. p. 158–163.

KING, T. et al. Compass: A probabilistic indoor positioning system based on 802.11 and digital compasses. In: *ACM. Proceedings of the 1st international workshop on Wireless network testbeds, experimental evaluation & characterization*. [S.l.], 2006. p. 34–40.

KOŁODZIEJ, K. W.; HJELM, J. *Local positioning systems: LBS applications and services*. [S.l.]: CRC press, 2006.

KOTANEN, A. et al. Experiments on local positioning with bluetooth. In: *IEEE. Information Technology: Coding and Computing [Computers and Communications], 2003. Proceedings. ITCC 2003. International Conference on*. [S.l.], 2003. p. 297–303.

LARRANAGA, J. et al. An environment adaptive zigbee-based indoor positioning algorithm. In: *IEEE. Indoor Positioning and Indoor Navigation (IPIN), 2010 International Conference on*. [S.l.], 2010. p. 1–8.

LEVINE, R. V.; NORENZAYAN, A. The pace of life in 31 countries. *Journal of cross-cultural psychology*, Sage Publications, v. 30, n. 2, p. 178–205, 1999.

LIU, H. et al. Survey of wireless indoor positioning techniques and systems. *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, IEEE, v. 37, n. 6, p. 1067–1080, 2007.

MAUTZ, R. *Indoor positioning technologies*. Tese (Doutorado) — Habilitationsschrift ETH Zürich, 2012, 2012.

MIAO, H. et al. A novel access point selection strategy for indoor location with wi-fi. In: *IEEE. Control and Decision Conference (2014 CCDC), The 26th Chinese*. [S.l.], 2014. p. 5260–5265.

- MOEGLEIN, M.; KRASNER, N. An introduction to snaptrack server-aided gps technology. In: *Proceedings of the 11th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GPS 1998)*. [S.l.: s.n.], 1998. p. 333–342.
- NI, L. M. et al. Landmarc: indoor location sensing using active rfid. *Wireless networks*, Springer, v. 10, n. 6, p. 701–710, 2004.
- NUNES, B. A. A. *Um Sistema de localização para redes Wi-Fi baseado em níveis de sinal e modelo referenciado de propagação*. Tese (Doutorado) — UNIVERSIDADE FEDERAL DO RIO DE JANEIRO, 2006.
- OTSASON, V. et al. Accurate gsm indoor localization. In: *UbiComp 2005: Ubiquitous Computing*. [S.l.]: Springer, 2005. p. 141–158.
- PAHLAVAN, K.; LI, X.; MAKELA, J.-P. Indoor geolocation science and technology. *Communications Magazine, IEEE*, IEEE, v. 40, n. 2, p. 112–118, 2002.
- PRATA, P. I. *Sistemas de localização para ambientes interiores baseados em rfid*. Universidade de Aveiro, 2008.
- REPACE, J. L.; LOWREY, A. H. Indoor air pollution, tobacco smoke, and public health. *Science*, American Association for the Advancement of Science, v. 208, n. 4443, p. 464–472, 1980.
- SHIN, B. et al. Enhanced weighted k-nearest neighbor algorithm for indoor wi-fi positioning systems. In: *IEEE. Computing Technology and Information Management (ICCM), 2012 8th International Conference on*. [S.l.], 2012. v. 2, p. 574–577.
- WELCH, G.; BISHOP, G. *An introduction to the Kalman filter*. 1995.
- WU, X. et al. Top 10 algorithms in data mining. *Knowledge and Information Systems*, Springer, v. 14, n. 1, p. 1–37, 2008.
- YOUSSEF, M.; AGRAWALA, A. The horus wlan location determination system. In: *ACM. Proceedings of the 3rd international conference on Mobile systems, applications, and services*. [S.l.], 2005. p. 205–218.
- YU, J.; LIU, J. A knn indoor positioning algorithm that is weighted by the membership of fuzzy set. In: *IEEE. Green Computing and Communications (GreenCom), 2013 IEEE and Internet of Things*

(iThings/CPSCom), IEEE International Conference on and IEEE Cyber, Physical and Social Computing. [S.l.], 2013. p. 1899–1903.