

LOCALIZAÇÃO INDOOR POR CORRELAÇÃO DE ASSINATURAS DE RÁDIO-FREQUÊNCIA EM REDES WIFI

Rafael Campos (CEFET/RJ) E-mail: rafael.campos@cefet-rj.br

Resumo: Este artigo apresenta uma breve revisão da literatura sobre posicionamento de dispositivos móveis em redes WiFi, com uma análise comparativa de várias técnicas de localização para ambientes *indoor* de único pavimento. O foco deste trabalho está nos métodos de correlação de banco de dados (DCM), também conhecidos como métodos de correlação de assinaturas de rádio-frequência devido à sua adequação para o posicionamento em tais redes.

Palavras-chave: posicionamento, dispositivos móveis, redes WiFi, ambientes *indoor*

WIFI INDOOR POSITIONING USING RADIOFREQUENCY FINGERPRINTING

Abstract: This paper presents a brief literature review on mobile device positioning in WiFi networks, with a comparative analysis of various localization techniques for single-floor indoor environments. The focus of this work is on database correlation methods (DCM), also known as radio frequency fingerprinting, due to their suitability for positioning in such networks.

Keywords: positioning, mobile stations, WiFi networks, indoor environments

1. Introdução

Desde o surgimento das primeiras redes WiFi IEEE 802.11 em 1997, Redes Locais Sem Fio (WLANs – *Wireless Local Area Networks*) baseadas nesse padrão se espalharam enormemente. Hoje, as redes WiFi são onipresentes em ambientes domésticos, corporativos e públicos. Esse fato, aliado à disponibilidade de *smartphones* habilitados para WiFi, torna o posicionamento de estações móveis (MSs – *Mobile Stations*) em WLANs uma questão crucial.

O posicionamento em WLANs WiFi não se restringe a ambientes internos, i.e., *indoor*. No entanto, é em tais cenários que o posicionamento WiFi se torna mais relevante, principalmente devido à (a) indisponibilidade de sinais do Sistema Global de Navegação por Satélite (GNSS – *Global Navigation Satellite System*) na maioria dos ambientes internos; (b) menor disponibilidade de sinais de rede de telefonia móvel celular em ambientes internos, salvo nos casos em que há micro e pico-células dedicadas implantadas especificamente para fornecer cobertura interna; e (c) alta densidade de pontos de acesso WiFi (APs – *Access Points*) em ambientes internos típicos.

Praticamente todas as soluções de posicionamento de radiofrequência (RF) utilizam uma das seguintes técnicas básicas: (i) **identidade de célula** (CID – *Cell Identity*): assume que o MS está localizado nas coordenadas da estação de serviço; (ii) **centróide**: a posição do MS alvo é dada pelo centróide do polígono cujos vértices são as estações de referência; (iii) **multi-lateração**: fornece o posicionamento do MS com base em estimativas de distância entre o MS e as estações de referência; essas estimativas são obtidas usando medições de tempo ou de força de sinal recebido (RSS – *Received Signal Strength*); a multi-lateração pode ser circular ou hiperbólica; (iv) **multi-angulação**: usa medições de ângulo de chegada (AOA – *Angle-of-Arrival*) entre o MS e as estações de referência para fornecer uma estimativa de posição; (v) **métodos de**

correlação de banco de dados (DCM – *Database Correlation Method*): também referidos como métodos de análise de cena, correspondência de padrões ou impressões digitais de RF.

A Fig. 2.1 mostra a representação geométrica básica do método do centróide e das técnicas de triangulação (multi-angulação e multi-lateração). Na Fig. 2.1a, o centróide do polígono cujos vértices são as estações de referência fornece a estimativa de posição (M). Na Fig. 2.1b, três estações de referência fornecem três linhas de posição circular (LOPs – *Lines of Position*) para uma estimativa de posição não-ambígua. Na Fig. 2.1c, quatro estações de referência fornecem três LOPs hiperbólicas para uma estimativa de posição não-ambígua. Na Fig. 2.1d, duas estações de referência não colineares fornecem duas LOPs lineares para uma estimativa de posição não-ambígua. Em todos os casos, é necessário conhecer as coordenadas das estações de referência com a maior precisão possível.

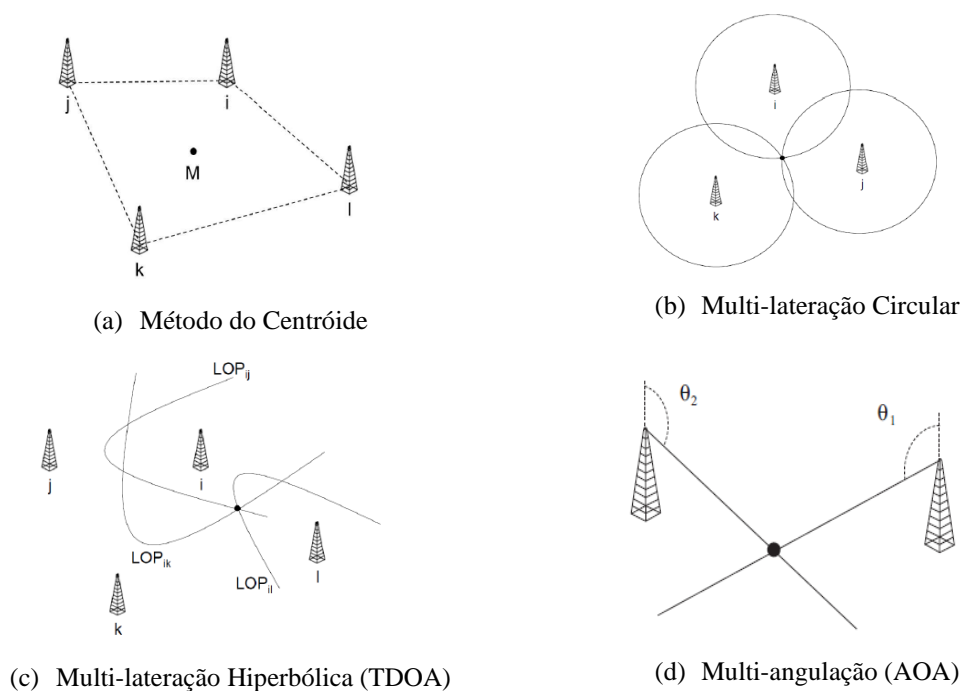


Figura 1 – Métodos de posicionamento por centróide e triangulação (multi-lateração e multi-angulação).

Inicialmente, todas essas técnicas se aplicariam às redes WiFi. No entanto, mesmo que haja algumas exceções, como em Bahillo (2011) e Bell (2010), a maioria das publicações sobre o tema não utiliza os métodos (i) a (iv). Isso se deve principalmente às seguintes questões: (a) ao contrário das redes celulares, os valores de atraso de ida e volta (RTD – *Round Trip Delay*) não estão disponíveis em redes WiFi; portanto, a multi-lateração baseada em tempo exigiria o uso de *hardware* adicional; (b) as antenas dos APs são tipicamente omnidirecionais; portanto, o posicionamento AOA também exigiria *hardware* adicional, ou seja, a instalação de *arrays* de antenas direcionais; (c) o posicionamento WiFi é mais relevante em ambientes internos; no entanto, em tais cenários, existem obstruções severas (como paredes, colunas e móveis) entre os APs e os MSs; portanto, a propagação fora do campo de visão (NLOS – *Non Line-of-Sight*) é prevalente, e essa condição prejudica severamente a precisão da multi-lateração e multi-angulação; (d) o posicionamento CID e centróide requerem que as localizações dos APs sejam conhecidas; no entanto, dificilmente essa informação estará disponível de forma confiável, já que os APs são implantados de maneira caótica, sem um esforço coordenado centralizado como em redes de telefonia móvel celular.

Como resultado, o DCM torna-se a técnica principal no posicionamento WiFi, tanto em ambientes internos quanto externos. Essa conclusão decorre do vasto número de artigos publicados sobre o assunto se comparado a outras técnicas. No entanto, implementar tais sistemas de posicionamento em ambientes internos não é uma tarefa sem desafios, pois tipicamente são necessárias fases extensivas e demoradas de treinamento *off-line* para coletar impressões digitais de referência a serem armazenadas no banco de dados de correlação (CDB – *Correlation Database*). Ademais, o ambiente RF não é estável ao longo do tempo: novos APs são implantados, outros são desligados ou movidos para outra localização, a frequência do canal WLAN pode mudar, móveis podem ser movidos ou adicionados ao piso. Conseqüentemente, o mapa de impressões digitais deve ser periodicamente atualizado para evitar a degradação da precisão. Além disso, diferenças de implementação entre fabricantes podem resultar em dispositivos diferentes relatando valores de RSS distintos no mesmo local (efeito *cross-device*). Por fim, as redes WiFi utilizam uma banda não licenciada, logo estão sujeitas a sofrer interferência de fontes externas.

O restante deste trabalho está organizado da seguinte forma: a Seção 2 apresenta os elementos básicos do DCM; e a Seção 3 analisa as técnicas DCM para localização de MS em cenários *indoor* com um único andar; seguida de uma conclusão.

2. Especificidades dos Métodos DCM

DCM, também conhecido como identificação de impressão digital ou assinatura de RF, é uma classe de métodos de posicionamento que podem ser aplicados a qualquer rede sem fio. Apesar de sua variabilidade e amplo escopo de aplicação, conceitualmente, todos os sistemas de localização DCM compartilham os mesmos elementos fundamentais: impressão digital de RF, banco de dados de correlação, correlação de assinaturas de RF, servidor de localização e técnica de redução do espaço de busca.

2.1. Impressão Digital ou Assinatura de RF

Uma impressão digital ou assinatura (os dois termos serão usados como sinônimos neste trabalho) de RF é um conjunto de parâmetros de sinal de RF dependentes de localização, coletados por um MS em uma posição específica. Esses parâmetros podem ser medidos tanto pelo MS a ser localizado quanto por suas estações âncora. Assim como uma impressão digital humana, que se presume identificar de forma única uma pessoa, espera-se que uma impressão digital de RF identifique de forma inequívoca uma posição geográfica. Uma impressão digital de RF pode ser classificada como sendo uma impressão digital alvo (TFING – *Target Fingerprint*) ou de referência (RFING – *Reference Fingerprint*). Uma TFING é a impressão digital de RF associada ao MS que está sendo localizado, ou seja, contém parâmetros de sinal medidos pelo MS ou por suas células âncora. As RFINGS são as impressões digitais de RF coletadas ou geradas durante a fase de treinamento e armazenadas no banco de dados de correlação.

Vários sistemas de localização por assinatura de RF empregam parâmetros que já estão disponíveis na rede de acesso por rádio (RAN – *Radio Access Network*). Esses parâmetros são dependentes da localização e, portanto, cada assinatura de RF pode ser associada a uma posição específica. Se apenas os parâmetros inerentes da RAN forem incluídos na assinatura de RF, então a técnica DCM pode ser totalmente baseada na rede. Nesse caso, a implantação do sistema de localização não requer nenhuma modificação nos MSs existentes.

Os métodos de posicionamento de multi-angulação e multi-lateração utilizam parâmetros de sinal dependentes da posição relativa entre o MS alvo e um conjunto de

estações de referência. Essas técnicas calculam a estimativa de posição a partir de princípios básicos de geometria, eletromagnetismo e processamento de sinais, diferindo do DCM na forma como empregam os parâmetros para estimar a posição do MS. A localização DCM, ao contrário da multi-angulação e multi-lateração, não se baseia na existência de linha de visada (LOS – *Line-of-Sight*) entre o MSs e as estações de referência, também denominadas estações âncora. Uma estação de referência ou âncora é uma estação fixa ou móvel que pode conter um transmissor, receptor e/ou um transponder, e cujos sinais são utilizados pelo MS alvo para estimar sua posição, ou que utiliza as transmissões do MS alvo para calcular a posição do alvo. As coordenadas das estações de referência devem ser conhecidas o tempo todo e com o mais alto grau possível de confiança (CAMPOS, 2015).

2.2. Banco de Dados de Correlação

O Banco de Dados de Correlação (CDB) é construído durante a fase de treinamento do DCM, utilizando modelagem de propagação de rádio, medições de campo ou uma combinação de ambos. Cada entrada do CDB é descrita por (f, x, y, z) , onde f é a RFING associada ao ponto definido pelas coordenadas (x, y, z) . A estrutura de f pode variar dependendo da tecnologia da RAN, mas alguns parâmetros comuns são RSS, tempo de ida e volta (RTD) e perfis de atraso. As entradas do CDB devem ser comparadas à TFING para fornecer uma estimativa de posição para o MS. Assume-se que o MS está localizado no ponto cuja RFING tem a maior correlação ou similaridade com a TFING. Alternativamente, é possível selecionar os K melhores resultados, sendo a localização do MS dada por uma média ponderada das coordenadas dos K melhores resultados (ou seja, das K RFINGs mais semelhantes à TFING associada ao MS a ser localizado) (AL KHANBASHI, 2013; CAMPOS, 2011; GEZICI, 2008; SEIDL, 1998; ZHU, 2005).

2.3. Correlação de Assinaturas de RF

O motor principal dos métodos DCM é o algoritmo de correspondência de padrões ou análise de cena. Ele é usado para comparar a TFING com as RFINGs previamente armazenadas no CDB. A partir dessas comparações, encontram-se candidatos (as posições associadas às RFINGs) para a localização onde a impressão digital de RF alvo foi coletada.

2.4. Servidor de Localização

O Servidor de Localização (LCS – *Location Server*) é um termo geralmente usado para se referir a elementos de rede (*hardware* e *software*) responsáveis por calcular a estimativa de posição. Ele recebe solicitações de localização de diferentes aplicativos ou dispositivos, consulta os CDBs e estima a localização do MS alvo a partir de sua assinatura de RF. No servidor de localização, a estimativa de posição pode ser calculada usando qualquer técnica de posicionamento suportada. No caso de métodos DCM, o servidor de localização deve ter acesso ao CDB.

2.5. Técnica de Redução do Espaço de Busca

O CDB pode ser bastante extenso e analisar todas as impressões digitais de RF nele armazenadas pode ser muito demorado. Para adquirir uma estimativa de posição dentro de um tempo aceitável, alguma redução no espaço de busca (inicialmente, todas as entradas no banco de dados) é bem-vinda. Portanto, a maioria das técnicas de localização por impressão digital emprega estratégias para reduzir o espaço de busca dentro do CDB. Como consequência, o tempo necessário para produzir uma estimativa de posição também é reduzido. Algumas das técnicas usadas na literatura são filtragem

determinística e pesquisa otimizada usando algoritmos genéticos, ambos aplicados em mapas de RSS construídos com modelos de propagação empíricos (CAMPOS, 2009; HATA, 1980; MAGRO, 2007).

2.6. Diagrama de Solicitação de Estimativa de Posição DCM originada pelo MS

A Figura 2 traz o diagrama simplificado de uma solicitação de posição DCM originada pelo MS. Primeiro (passo 1), o MS envia uma solicitação de posição contendo o TFING para o LCS via RAN. Em seguida (passo 2), a RAN comunica-se com o LCS, que recebe a TFING e então consulta o CDB (passo 3) para obter as impressões digitais de RF de referência (RFINGs), que são retornadas no passo 4. O LCS então compara a TFING com as RFINGs para obter a estimativa de posição do MS (passo 5), que é enviada de volta para a RAN (passo 6) e posteriormente para o MS (passo 7).

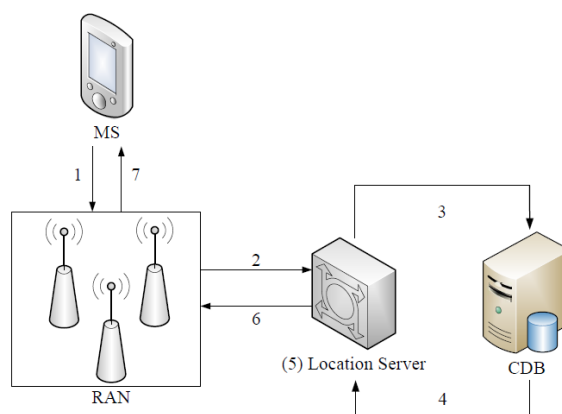


Figura 2 – Diagrama de Localização DCM

A partir desta breve descrição, nota-se que qualquer técnica de localização DCM tem duas etapas. A primeira é a fase de treinamento, quando o CDB é construído. A segunda é a fase de teste ou operacional, durante a qual as estimativas de posição do MS são produzidas a partir das impressões digitais de RF coletadas.

3. Posicionamento *Single-Floor* usando Assinatura de RF

3.1. Vizinho Mais Próximo no Espaço de Sinal

Um dos primeiros sistemas RF para localização e rastreamento de usuários em ambientes internos em redes WiFi foi o RADAR, testado em um único andar de 22×43 m² com 3 APs e 70 pontos de medição. Em cada ponto de medição, pelo menos 20 amostras (WiFi *scans*) foram coletadas em quatro direções diferentes (norte, sul, leste, oeste), pois os autores verificaram que, dependendo da direção para a qual o usuário estava virado, o RSS de um determinado AP poderia variar ± 5 dB. Para cada 3-tupla (x, y, ζ) , foram coletadas pelo menos 20 amostras, onde (x, y) são as coordenadas do ponto de medição e ζ é a direção para a qual o usuário estava virado. A média do RSS por AP em cada ponto/orientação foi então calculada, resultando em 70×4 impressões digitais de referência (BAHL, 2000).

Para comparar as impressões digitais alvo e de referência, foi introduzido o conceito de Vizinho Mais Próximo no Espaço de Sinal (NNSS – *Nearest Neighbour in Signal Space*), ou seja, a similaridade entre as impressões digitais foi medida pela distância euclidiana no espaço RSS N -dimensional. Nesse caso, $N = 3$, pois apenas 3 APs foram utilizados. Para testar o algoritmo, uma das quatro direções no ponto de medição i foi

selecionada para ser a assinatura alvo (TFING). As assinaturas de referência (RFINGs) do i -ésimo ponto foram então excluídas do mapa de impressões digitais (i.e., o CDB do RADAR), e a TFING foi comparada com as 69×4 RFINGs restantes. O processo foi repetido para $i = 1, \dots, 70$. Os autores relataram um erro de posicionamento bidimensional (2-D) mediano de 2,94 metros (BAHL, 2000).

Os autores conduziram outro experimento no mesmo local de teste, com um mapa de impressão digital (para os mesmos 70 pontos de medição) construído usando o modelo de propagação empírico dado por:

$$P(d) = P(d_0) - 10n \log\left(\frac{d}{d_0}\right) - mA_w \quad (1)$$

onde $P(d)$ é o RSS (em dBm) a d metros do AP, d_0 é uma distância de referência em metros, n é o expoente da perda de propagação, m é o número de paredes entre o AP e a posição atual, e A_w é o fator de atenuação da parede, ou seja, a perda adicional (em dB) introduzida por cada parede. Os parâmetros d_0 , n e A_w foram definidos empiricamente.

No segundo experimento, o erro de posicionamento bidimensional mediano aumentou para 4,3 metros. Os CDBs construídos a partir de modelos de propagação podem reduzir o tempo consumido na fase *offline*, seja na aquisição inicial do CDB ou em suas atualizações periódicas. No entanto, isso representa um compromisso entre o tempo de pré-processamento e a precisão. Além disso, modelar a propagação de RF em ambientes internos não é uma tarefa fácil.

Para esclarecimento, considere a Figura 3a, que mostra uma planta baixa com as localizações de 4 APs (quadrados brancos). A escala gráfica indica a perda adicional em dB por R metros, onde R é a resolução da matriz representando a planta baixa. As dimensões do piso são de 20×40 m². Há um grande hall de entrada (à esquerda), um longo corredor e 3 quartos, cada um com apenas uma entrada. A planta baixa é representada como uma matriz, onde cada elemento (*pixel*) corresponde a uma área de $R \times R$ m². Neste exemplo, $R = 0.1$ m e, portanto, a planta baixa é uma matriz 200×400 .

O nível de luminância dos *pixels* é proporcional à perda adicional (em dB) devido à presença da barreira na posição do *pixel*. Luminância zero indica a ausência de um obstáculo na posição do *pixel*. Esta simulação considera dois tipos de obstáculos: paredes de concreto com 30 cm de espessura, com uma perda de 20 dB por metro, e portas de madeira com 10 cm de espessura, com uma perda de 8 dB por metro. A Equação 1 define o modelo de propagação de RF. Os valores dos parâmetros são $n = 3.43$, $d_0 = 2.5$, $P(d_0) = -43$ dBm (LI, 2005).

Os APs têm antenas omnidirecionais, portanto, nenhum diagrama de radiação foi aplicado para gerar os mapas de cobertura RSS 2-D. A simulação não considera multipercurso devido a reflexões de superfícies e difração ao redor de obstáculos. A Figura 3b mostra o mapa do melhor servidor que representa, em cada *pixel*, o valor de RSS mais alto (dentro dos RSS de todos os APs). As Figuras 3c e 3d mostram os mapas de cobertura RSS (dBm) dos APs 3 e 4, respectivamente. O efeito dos obstáculos na propagação de RF é claramente distinguível em ambos os mapas. Os 4 mapas de RSS (um para cada AP) podem ser "empilhados", resultando em uma matriz $200 \times 400 \times 4$ que fornece um vetor de RSS de 4 elementos para cada *pixel*.

O nível de luminância dos *pixels* é proporcional à perda adicional (em dB) devido à presença da barreira na posição do *pixel*. Luminância zero indica a ausência de um obstáculo na posição do *pixel*. Esta simulação considera dois tipos de obstáculos:

paredes de concreto com 30 cm de espessura, com uma perda de 20 dB por metro, e portas de madeira com 10 cm de espessura, com uma perda de 8 dB por metro. A Equação 1 define o modelo de propagação de RF. Os valores dos parâmetros são $n = 3.43$, $d_0 = 2.5$, $P(d_0) = -43$ dBm (LI, 2005).




Figura 3: (a) Planta baixa com a localização dos APs; (b) Mapa de melhor servidor de RSS; (c) Mapa de RSS do AP 3; (d) Mapa de RSS do AP 4.

Os APs têm antenas omnidirecionais, portanto, nenhum diagrama de radiação foi aplicado para gerar os mapas de cobertura RSS 2-D. A simulação não considera multipercurso devido a reflexões de superfícies e difração ao redor de obstáculos. A Figura 3b mostra o mapa do melhor servidor que representa, em cada *pixel*, o valor de RSS mais alto (dentro dos RSS de todos os APs). As Figuras 3c e 3d mostram os mapas de cobertura RSS (dBm) dos APs 3 e 4, respectivamente. O efeito dos obstáculos na propagação de RF é claramente distinguível em ambos os mapas. Os 4 mapas de RSS (um para cada AP) podem ser "empilhados", resultando em uma matriz $200 \times 400 \times 4$ que fornece um vetor de RSS de 4 elementos para cada *pixel*.

3.2 Mapas de RSS Sensíveis ao Contexto

Fatores ambientais variáveis, como a umidade do ar, portas abertas ou fechadas e a presença de pessoas, podem interferir nas condições de propagação, alterando o RSS em cada ponto, em relação ao momento em que o mapa de impressões digitais foi construído.

Os autores em Chen (2005) tentaram avaliar o efeito quantitativo desses fatores ambientais (umidade do ar, portas e pessoas) na precisão da localização interna por WiFi. A presença de pessoas tem um efeito semelhante a obstáculos que bloqueiam a propagação de RF. Portas abertas e fechadas têm um efeito comparável a mudanças no layout do piso. É esperado que uma atmosfera com alta umidade absorva mais energia do sinal de RF em propagação do que uma atmosfera seca.

Eles construíram mapas de RSS sensíveis ao contexto, e que o MS alvo seleciona com base nas condições ambientais internas atuais. Como os autores assumiram dois possíveis estados para cada um dos três fatores ambientais (umidade - alta ou baixa; portas - todas fechadas ou todas abertas; pessoas - com ou sem pessoas), eles construíram seis mapas de impressões digitais de RF. Eles instalaram um AP em cada um dos 5 cômodos em um único andar e coletaram pelo menos 200 varreduras de WiFi ao longo de um corredor para cada conjunto de fatores ambientais. Durante a fase de

teste *online*, o MS alvo consultou sensores de umidade, *tags* de identificação por radiofrequência (RFID – *RF Identification*) e dispositivos *Bluetooth*, para que pudesse selecionar o melhor mapa de RSS sensível ao contexto. Este mapa é aquele que melhor corresponde às condições ambientais no momento do teste. As *tags* RFID detectaram se as portas estavam abertas ou fechadas. As mudanças na perda média de propagação entre transmissores *Bluetooth* fixos e o MS alvo identificaram a condição com ou sem bloqueio do caminho de propagação pela presença de pessoas.

As Tabelas 1 e 2 mostram degradações na precisão de localização de 1,1 metros quando um mapa de rádio de baixa umidade é aplicado em um ambiente de alta umidade, e 1,9 metros quando um mapa de rádio sem bloqueio de pessoas é empregado em um ambiente de teste com bloqueio de pessoas. No entanto, a Tabela 3 indica que o pior cenário ocorre quando há uma discrepância na condição de portas abertas/fechadas: o erro médio de localização aumenta de 2,1 metros para 7,2 metros quando um mapa de rádio com todas as portas fechadas é usado em um ambiente de teste com todas as portas abertas.

Tabela 1 - Impacto da Umidade Relativa (UR) na acurácia média do posicionamento DCM (em ambos os mapas: todas as portas fechadas e sem bloqueio de pessoas).

Acurácia média (m)	Ambiente com UR 40%	Ambiente com UR 70%
Ambiente com UR 40%	2,1	3,7
Ambiente com UR 70%	3,1	2,6

Tabela 2 - Impacto do bloqueio pela presença de pessoas na acurácia média do posicionamento DCM (em ambos os mapas: UR 40% e todas as portas fechadas).

Acurácia média (m)	Sem pessoas	Com pessoas
Sem pessoas	2,1	4,3
Com pessoas	4,0	2,5

Tabela 3 - Impacto das portas (abertas ou fechadas) na acurácia média do posicionamento DCM (em ambos os mapas: UR 40% e sem pessoas).

Acurácia média (m)	Portas fechadas	Portas abertas
Portas fechadas	2,1	4,6
Portas abertas	7,2	2,8

3.3 Mapas de Rádio Sob Demanda para Soluções Baseadas no MS

Soluções de posicionamento DCM *indoor* podem ser classificadas como assistidas pelo MS ou baseadas no MS. No caso assistido pelo MS, um servidor de localização calcula a posição do MS usando impressões digitais de RF enviadas pelo MS alvo e consultando um CDB baseado no servidor. No caso baseado no MS, o MS calcula sua posição consultando um CDB baseado no cliente, ou seja, um mapa de impressões digitais armazenado no próprio MS. No caso de um CDB baseado no servidor, o servidor de localização pode ter que lidar com várias solicitações de localização simultâneas, e uma técnica de redução de espaço de busca pode reduzir significativamente o atraso na obtenção de cada estimativa de posição. No caso de um CDB baseado no cliente, uma técnica de redução de espaço de busca, além de acelerar o tempo de aquisição, também reduz a carga da rede (pois o MS faz o *download* de mapas de impressões digitais menores) e o espaço de armazenamento necessário no MS. Em

King (2008), os autores propuseram duas técnicas para diminuir o espaço de busca em soluções baseadas em cliente: Interseção de Pontos de Acesso (IAP – *Intersection of APs*) e União de Pontos de Acesso (UAP – *Union of APs*). No IAP, o MS alvo faz o download apenas das RFINGs contendo pelo menos todos os APs detectados na varredura de WiFi. No UAP, o MS faz o *download* das RFINGs contendo pelo menos um dos APs detectados na varredura de WiFi. Os autores também definiram um critério chamado N-Grupo para disparar uma consulta de dados de impressão digital de RF (ou seja, a consulta e o *download* de um espaço de busca atualizado do servidor de localização para o CDB baseado no cliente) sempre que mais de N APs mudarem em duas varreduras consecutivas de WiFi. Quanto maior N, menor a frequência das consultas. O objetivo do N-Grupo era reduzir a frequência das consultas de dados, sem degradar a precisão do posicionamento. O CDB baseado no cliente é geralmente um subconjunto do CDB baseado no servidor.

O teste experimental da solução proposta em King (2008) compreendeu 25 APs e foi configurado no segundo andar de um prédio de escritórios com $57 \times 32 \text{ m}^2$ no campus da Universidade de Manheim. A fase de treinamento *offline* utilizou 130 pontos de medição dispostos em uma grade regular com espaçamento de 1,5 metros. Na fase de teste, 46 pontos foram escolhidos aleatoriamente. Tanto na fase de treinamento quanto na fase de teste, foram coletadas 110 varreduras de WiFi por ponto. A acurácia média da localização foi de 3 metros, sem redução de espaço de busca. Em seguida, o valor de N foi aumentado progressivamente ao usar IAP e UAP, e três parâmetros foram monitorados: acurácia do posicionamento, frequência de consulta do mapa de impressões digitais de RF e tamanho do espaço de busca (medido pelo número de pontos, ou seja, RFINGs). Os autores em King (2008) observaram que, ao usar UAP, a redução do espaço de busca era negligenciável: o tamanho médio do espaço de busca era 129. No entanto, ao usar IAP, o tamanho médio do espaço de busca diminuiu para 12. Porém, com IAP, ao aumentar N de 1 para 10, o erro de posicionamento aumentou quase 20% (de 3 metros para 3,5 metros).

3.4 Correspondência de Padrões Baseada em RNAs

Os autores em Stella (2007) utilizam uma rede neural artificial (RNA) para estabelecer uma relação entre vetores de RSS e locais. Em um ambiente interno, eles instalaram 3 APs em um piso de $28 \times 15 \text{ m}^2$ e selecionaram 125 pontos de medição, coletando 400 amostras por ponto. As amostras coletadas em 110 pontos foram usadas para treinar a RNA. Os pontos restantes foram usados para testá-la. A RNA tinha 3 entradas (os valores de RSS de cada AP), 18 neurônios na camada oculta e 2 saídas (coordenadas planares x e y). Assim como em Spirito (2009), a precisão experimental foi excelente: 61% dos padrões de teste tiveram erros inferiores a 1,8 metros, e 85% tiveram erros menores que 3 metros. No entanto, não há garantia de que algoritmos de correspondência de padrões baseados em RNA produzirão tal precisão em cenários mais complexos, como em prédios de vários andares, ou quando mapas de rádio construídos com modelos de propagação (ao invés de medidas) são usados no treinamento supervisionado de tais redes.

3.5 DCM usando parâmetros que não o RSS

Todas as técnicas de DCM listadas até agora neste trabalho usaram impressões digitais de RF contendo apenas valores médios de RSS, que são relativamente simples de medir e estão prontamente disponíveis em redes WiFi. Essas características tornaram o uso de assinaturas de RF com RSS uma solução prática para sistemas de localização WiFi. A diferença central entre implementações distintas reside principalmente em como as

impressões digitais alvo e de referência são comparadas, ou seja, em qual técnica de correspondência de padrões (NNSS, correlação de vetores de RSS, baseada em RNA) é usada. No entanto, outros parâmetros podem ser empregados além do RSS. A possibilidade mencionada é explorada em Al Khanbashi (2013), onde os autores compararam a precisão das técnicas DCM aplicadas ao posicionamento WiFi indoor usando impressões digitais baseadas em RSS, Resposta do Canal ao Impulso (CIR – *Channel Impulse Response*), Função de Transferência do Canal (CTF – *Channel Transfer Function*) e Função de Coerência de Frequência (FCF – *Frequency Coherence Function*). A CIR para o impulso transmitido pelo j -ésimo AP é dado por:

$$\mathbf{h}_j(t) = \sum_{i=1}^M a_i e^{-j\phi_i} \delta(t - \tau_i) \quad (2)$$

onde a_i , ϕ_i e τ_i são a amplitude, fase e atraso do i -ésimo componente de multipercurso recebido; M é o número de componentes de multipercurso e $\delta(t)$ é a função impulso. A Equação 2 mostra que, em condições de propagação com multipercurso, o receptor detecta múltiplas cópias atrasadas e atenuadas do impulso transmitido. Ao tomar a CIR em relação a diferentes APs na mesma posição, é possível construir uma impressão digital de RF dada por $[\mathbf{h}_1(t), \dots, \mathbf{h}_N(t)]$, onde N é o número de APs. Note que cada elemento da impressão digital é um vetor de M elementos, então a impressão digital baseada em CIR é uma matriz $M \times N$. Espera-se que a CIR carregue as informações de multipercurso únicas para cada localização. No entanto, a acurácia é limitada pela largura de banda do sinal: larguras de banda mais altas são equivalentes a uma maior resolução no domínio do tempo, o que permite detectar (separar) mais componentes de multipercurso (ou seja, aumentar M). CTF é a Transformada Discreta de Fourier (DFT – *Discrete Fourier Transform*) da CIR. Uma impressão digital baseada em CTF pode então ser formada com as mesmas dimensões daquela baseada em CIR. O mesmo se aplica ao usar impressões digitais baseadas em FCF, onde a FCF para o j -ésimo AP em uma posição de medição dada é a autocorrelação complexa da CTF.

Os autores configuraram um banco de testes experimental em um único andar de 30×25 m² com 3 APs. Um total de 152 pontos de medição foram escolhidos com uma distância fixa de 1 metro entre pontos adjacentes. Dentre esses pontos, 51 foram selecionados aleatoriamente para o teste, e o restante compôs o CDB. A distância euclidiana no espaço de RSS foi usada para comparar as impressões digitais baseadas em RSS alvo e de referência (quanto maior a distância, menor a similaridade). Para as impressões digitais baseadas em CIR, CTF e FCF, a função de correlação foi o produto escalar. Então, o método dos K-vizinhos mais próximos ponderados (w-KNN) foi aplicado. No w-KNN, a estimativa de posição é dada por $(\hat{x}, \hat{y}) = \frac{\sum_{i=1}^K w_i (x_i, y_i)}{\sum_{i=1}^K w_i}$, onde K é o número de vizinhos, w_i e (x_i, y_i) são o peso e as coordenadas de referência do i -ésimo ponto vizinho, respectivamente. O peso w_i é diretamente proporcional à similaridade entre as impressões digitais alvo e de referência do i -ésimo ponto, logo, $\sum_{i=1}^K w_i = 1$.

As assinaturas de RF baseadas em FCF alcançaram os melhores resultados: um erro médio de 2,5 metros, com quase nenhuma variação à medida que o número de pontos vizinhos no algoritmo w-KNN aumentava de 1 para 10. A impressão digital baseada em RSS foi a técnica que mais se beneficiou com o uso do w-KNN: o erro médio caiu de 3,5 metros (para $K = 1$) para 2,8 metros (para $K = 9$). O desempenho do CTF foi um pouco pior que o FCF, e a CIR foi o pior de todos, com erros entre 3 e 4 metros para K variando de 2 a 10 (para $K = 1$, o erro na impressão digital baseada em CIR foi de 4,2

metros). Embora a impressão digital baseada em FCF tenha apresentado melhor desempenho no teste, se considerarmos implementações maiores na prática, é provável que o ganho de precisão não compense a complexidade adicional requerida para a obtenção dessas medições (o que envolveria a implantação de hardware adicional na infraestrutura de rede WiFi pré-existente), se comparado à relativa simplicidade de se medir o RSS.

Conclusão

Este artigo apresentou uma pesquisa abrangente sobre técnicas de posicionamento DCM em redes WiFi em ambiente *indoor*, agrupando e analisando os aspectos chave de vários artigos sobre o assunto. A maioria das soluções DCM baseia-se na correlação de assinaturas de RF usando RSS, aplicando recursos como NNSS, mapas de rádio sensíveis ao contexto e correspondência de padrões baseada em ANN para melhorar a precisão. Alguns pesquisadores utilizam outros parâmetros para compor a assinatura de RF, como CIR, CTF e FCF, além de técnicas alternativas para reduzir o espaço de busca no CDB, como IAP e UAP. Pode-se acrescentar que uma precisão de localização arbitrária em redes WiFi pode certamente ser obtida em ambientes bem controlados com a instalação de um número suficientemente grande de APs. No entanto, o principal foco de pesquisa nesta área reside em buscar a melhor precisão em ambientes caóticos, onde na maioria das vezes nem mesmo a localização dos APs é conhecida. Isso permite o uso sistemas de localização de em uma ampla gama de situações, com custo e atraso mínimos. Outra conclusão é que, devido às características intrínsecas da propagação de RF em ambientes fechados, a correlação de assinaturas de RF parece ser a melhor alternativa para o posicionamento *indoor* WiFi.

Referências

- AL KHANBASHI, N. & AL SINDI, N. & AL-ARAJI, S.**; et al. “Real time evaluation of RF fingerprints in wireless LAN localization systems”. In: Positioning Navigation and Communication (WPNC), 2013 10th Workshop on, pp. 1–6, Dresden, Germany, March 2013.
- BAHILLO, A. & FERNANDEZ, P. & PRIETO, J.**; et al. “Distance Estimation based on 802.11 RTS/CTS Mechanism for Indoor Localization”. In: Miguel Almeida (Ed.), Advances in Vehicular Networking Technologies, InTech, cap. 12, Rijeka, Croatia, 2011.
- BAHL, P. & PADMANABHAN, V. N.** “RADAR: An in-building RF-based user location and tracking system”. In: INFOCOM 2000. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies. Proceedings. IEEE, v. 2, pp. 775–784, 2000.
- BELL, S. & JUNG, W. R. & KRISHNAKUMAR, V.** “WiFi-based Enhanced Positioning Systems: Accuracy Through Mapping, Calibration, and Classification”. In: Proceedings of the 2nd ACM SIGSPATIAL International Workshop on Indoor Spatial Awareness, pp. 3–9, San Jose, California, 2010.
- CAMPOS, R. S. & LOVISOLO, L.** “A Fast Database Correlation Algorithm for Localization of Wireless Network Mobile Nodes using Coverage Prediction and Round Trip Delay”. In: Proceedings of IEEE 69th Vehicular Technology Conference, Barcelona, Spain, April 2009.
- CAMPOS, R. S. & LOVISOLO, L.** “RF Fingerprinting Location Techniques”. In: John Wiley and Sons (Ed.), Handbook of Position Location: Theory, Practice, and Advances, 1 ed., S. A. Zekavat and R. M. Buehrer, cap. 15, pp. 487–520, Hoboken, NJ, USA, 2011.
- CAMPOS, R. S. & LOVISOLO, L.** RF Positioning: Fundamentals, Applications and Tools. 1st ed. Boston, USA, Artech House, 2015.
- CHEN, Y.-C. & CHIANG, J.-R. & CHU, H.-H.**; et al. “Sensor-assisted Wi-fi Indoor Location System for Adapting to Environmental Dynamics”. In: Proceedings of the 8th ACM International Symposium on Modelling, Analysis and Simulation of Wireless and Mobile Systems (MSWiM’05), pp. 118–125, Montreal, Canada, October 2005.

GEZICI, S. “A Survey on Wireless Position Estimation”, *Wireless Personal Communications: An International Journal*, v. 44, n. 3, pp. 263–282, February 2008.

HATA, M. “Empirical formula for propagation loss in land mobile radio services”, *Vehicular Technology, IEEE Transactions on*, v. 29, n. 3, pp. 317– 325, 1980.

KING, T. & HAENSELMANN, T. & EFFELSBERG, W. “On-demand fingerprint selection for 802.11-based positioning systems”. In: *International Symposium on a World of Wireless, Mobile and Multimedia Networks (WoWMoM 2008)*, pp. 1–8, Newport Beach, USA, June 2008.

LI, B. & DEMPSTER, A. & RIZOS, C. & BARNES, J. “Hybrid method for localization using WLAN”. In: *Proc. Spatial Sci. Conf.*, pp. 341–350, 2005.

MAGRO, M. J. & DEBONO, C. J. “A Genetic Algorithm Approach to User Location Estimation in UMTS Networks”. In: *EUROCON - The International Conference on Computer as a Tool*, pp. 1136–1139, Warsaw, Poland, September 2007.

SEIDL, T. & KRIEGEL, H.-P. “Optimal Multi-Step K-Nearest Neighbor Search”. In: *Proceedings of the 1998 ACM SIGMOD International Conference on Management of Data*, pp. 154–165, Seattle, USA, June 1998.

SPIRITO, M. A. & CACERES, M. & SOTTILE, F. “WLAN-Based Real Time Vehicle Locating System”, in *Proceedings of IEEE 69th Vehicular Technology Conference*, Barcelona, Spain, April 2009.

STELLA, M. & RUSSO, M. & BEGUSIC, D. “Location Determination in Indoor Environment based on RSS Fingerprinting and Artificial Neural Network”. In: *9th International Conference on Telecommunications (ConTel 2007)*, pp. 301–306, June 2007.

ZHU, J. & DURGIN, G. D. “Indoor/Outdoor Location of Cellular Handsets Based on Received Signal Strength”, *Electronic Letters*, v. 41, n. 1, pp. 24– 26, January 2005.