

Uma Abordagem de Fusão de Dados em Redes de Sensores para Reduzir o Impacto de Erros de Localização em Algoritmos de Rastreamento *

Éfren L. Souza¹, Eduardo F. Nakamura², Horácio A.B.F. de Oliveira¹

¹ Universidade Federal do Amazonas – UFAM

Departamento de Ciência da Computação – DCC

Av. Gen. Rodrigo Octávio Jordão Ramos, 3000, Coroado I – 69077-000 Manaus, AM.

²Fundação Centro de Análise, Pesquisa e Inovação Tecnológica – FUCAPI

Av. Danilo de Matos Areosa, 381, Distrito Industrial – 69075-351 Manaus, AM.

efren@dcc.ufam.edu.br, nakamura@pq.cnpq.br, horacio@dcc.ufam.edu.br

Abstract. *In wireless sensor networks (WSNs), target tracking algorithms usually depend on geographical information provided by a localization algorithm. However, the errors introduced by such algorithms may affect the performance of tasks that depend on information about node position. Information fusion techniques are natural choices to try reducing such errors. In this paper, we use the Kalman filter to reduce distance estimation errors used by localization algorithms: Recursive Position Estimation (RPE) and Directed Position Estimation (DPE). Then, we evaluate how two classical tracking algorithms (Kalman and Particle filters) are affected by localization errors, when we use various distance estimates. Results show that using multiple distance estimates in the localization algorithms improves the tracking, but this feature should be used with caution, mainly, due to the associated communication cost.*

Resumo. *Em Redes de Sensores Sem Fio (RSSF), algoritmos de rastreamento são frequentemente baseados em informações geográficas providas por algoritmos de localização. Entretanto, os erros introduzidos por tais algoritmos afetam o desempenho das tarefas que dependem dessa informação. Técnicas de fusão de dados podem ser utilizadas para reduzir esse erro. Neste artigo, utilizamos o filtro de Kalman clássico para filtrar múltiplas estimativas de distância no processo de localização de nós sensores. Em seguida, avaliamos como dois algoritmos de rastreamento clássicos (filtros de Kalman e Partículas) são afetados pelos erros de dois algoritmos de localização (RPE e DPE) que utilizam várias estimativas de distância. Os resultados mostram que usar várias estimativas de distância na localização melhora o rastreamento, mas esse recurso deve ser usado com cuidado devido ao custo associado.*

1. Introdução

Rede de Sensores Sem Fio (RSSF) [Akyildiz et al. 2002] é um tipo especial de rede *ad-hoc* composta por dispositivos com recursos limitados, chamados nós sensores. Esses nós

*Este trabalho estende significativamente a avaliação feita anteriormente pelos autores [Souza et al. 2009] ao introduzir o uso de fusão de dados para reduzir erros no processo de localização de nós sensores. Os resultados aqui apresentados mostram os benefícios e custos desta nova abordagem.

sensores são capazes de monitorar um ambiente, coletar dados, realizar processamento localmente e disseminar dados. Para muitas aplicações, a rede precisa definir a localização de cada nó, uma vez que um evento é geralmente associada com o local de sua ocorrência.

Para prover a localização dos nós em RSSF são usados sistemas de localização. Na maioria das atuais soluções de localização existe uma fração dos nós sensores que conhecem a priori sua localização (usando GPS ou posicionamento manual), chamados nós *beacons*. Então, esses algoritmos compartilham as informações dos *beacons* para estimar as posições dos nós, mas essa estimativa não é perfeita [Albowicz et al. 2001, Oliveira et al. 2009]. Muitas aplicações, como rastreamento de alvos, roteamento geográfico e controle de densidade, dependem da informação de localização. Entretanto, existem poucas pesquisas que integram localização com essas aplicações [He et al. 2003, Souza et al. 2009].

Rastreamento de alvos consiste em três partes: detecção do alvo (como animais, pessoas e veículos), cálculo de sua posição atual e estimativa de sua posição futura [Nakamura et al. 2007]. Essa aplicação é altamente dependente das posições dos nós. Dessa forma, os erros de localização afetam negativamente o rastreamento, já que os algoritmos de rastreamento não filtram com sucesso os erros introduzidos pela localização [Souza et al. 2009]. Por isso, técnicas de fusão de dados podem ser usadas para reduzir esses erros [Boukerche et al. 2008].

Neste artigo propomos e avaliamos uma técnica de fusão de dados que usa múltiplas estimativas de distância durante o processo de localização, que são processadas para obter uma única estimativa mais precisa. Para isso, avaliamos o impacto de dois algoritmos de localização em dois algoritmos de rastreamento. O primeiro algoritmo de localização é o RPE (*Recursive Position Estimation* – Estimativa de Localização Recursiva) [Albowicz et al. 2001] – a solução iterativa pioneira – enquanto o segundo é o DPE (*Directed Position Estimation* – Estimativa de Localização Direcionada) [Oliveira et al. 2009] – uma solução que evoluiu a partir do original RPE reduzindo erros e custos do seu antecessor. Os estimadores Bayesianos usados em rastreamento que avaliamos são os clássicos KF (*Kalman Filter* – Filtro de Kalman) e PF (*Particle Filter* – Filtro de Partículas) [Nakamura et al. 2007].

O restante deste artigo está organizado como segue. A Seção 2 apresenta os trabalhos relacionados. A Seção 3 apresenta os fundamentos teóricos de localização e rastreamento. Na Seção 4 apresentamos nossa abordagem que reduz o impacto dos erros de localização em rastreamento. Na Seção 5 apresentamos nossa metodologia experimental e as avaliações quantitativas. Por fim, na Seção 6 apresentamos nossas conclusões e trabalhos futuros.

2. Trabalhos Relacionados

Várias soluções de rastreamento são baseadas no KF [Nakamura et al. 2007]. Esse tem sido usado, por um longo tempo, em algoritmos de localização e rastreamento. Nas redes de sensores, esse tendência é mantida, visando a melhora da precisão. Para lidar com modelos não-lineares o KF sofreu adaptações [Julier and Uhlmann 1997]. O PF também é uma solução de rastreamento bastante popular. [Arulampalam et al. 2002] discute o uso do PF em aplicações de rastreamento.

Rastreamento de alvos são altamente dependentes da informação de localização

dos nós sensores da rede. Estratégias iterativas para o problema de localização são populares em RSSF. [Niculescu and Nath 2001] propõem o APS (*Ad Hoc Positioning System*). Esse algoritmo pode funcionar com apenas três nós *beacons*, pois cada nó calcula sua distância aos *beacons* por meio de múltiplos saltos. Outros dois importantes algoritmos de localização são o RPE proposto por [Albowicz et al. 2001] e o DPE proposto por [Oliveira et al. 2009]. Esses algoritmos são utilizados diretamente neste artigo, por isso são tratados de forma mais detalhada na próxima seção.

Algumas pesquisas avaliam o impacto que os erros de localização têm em aplicações dependentes de informações geográficas. Nesse sentido, [Shah et al. 2005] e [Seada et al. 2004] mostram experimentos de roteamento geográfico com erros de localização. [Souza et al. 2009] avaliam o impacto do erro de algoritmos de localização reais em rastreamento. [He et al. 2003] também analisa o rastreamento na presença de erros de localização, mas apenas simula esse erro perturbando a posição real do nó com uma fração da distância, que não é um cenário de localização realístico em RSSF. Fusão de dados é amplamente utilizada para reduzir erros de localização e rastreamento [Nakamura et al. 2007, Boukerche et al. 2008].

3. Fundamentos Teóricos

Nesta seção, apresentaremos uma descrição dos algoritmos de localização e rastreamento avaliados neste artigo.

3.1. Rastreamento de Alvos

Os algoritmos de rastreamento visam calcular a atual localização de um alvo e prever a sua próxima posição. Entretanto, esses algoritmos são expostos a diferentes fontes de ruídos, devido ao processo de medição e aos erros na informação de localização usadas para localizar o alvo. Portanto, fusão de dados [Nakamura et al. 2007] é comumente usada para filtrar essas fontes de ruído. Dois populares algoritmos para este problema são os filtros de Kalman e Partículas.

3.1.1. Filtro de Kalman

O KF é o método de fusão de dados mais popular usado para fundir um baixo nível de dados redundantes [Nakamura et al. 2007]. Se um modelo linear pode ser descrito como um sistema e o erro pode ser modelado como um ruído com distribuição de probabilidade Gaussiana, o KF gera recursivamente estimativas estatisticamente ótimas.

O KF estima o estado x de um tempo discreto k baseado no modelo de espaço de estados governado pela equação do processo

$$x_{k+1} = Ax_k + Bu_k + w_k, \quad (1)$$

com medições y representadas por

$$y_k = Cx_k + v_k, \quad (2)$$

em que A é a matriz de transição de estados, B é a matriz de controle de entrada que é aplicada ao vetor de controle u , C é a matriz de medições; w é o ruído do processo e v é

o ruído da medição, modelados por variáveis aleatórias que obedecem as leis Gaussianas de média zero com matrizes de covariância Q e R respectivamente.

Baseado nas medições y e nos parâmetros do sistema, a estimativa de x , representada por \hat{x} é obtida por

$$\hat{x}_{k+1} = (A\hat{x}_k + Bu_k) + K_k(y_k - C\hat{x}_k), \quad (3)$$

em que K é o ganho de Kalman determinado por

$$K_k = P_k C^T (C P_k C^T + R)^{-1}, \quad (4)$$

enquanto P é a matriz de covariância da previsão que é determinado por

$$P_{k+1} = A(I - K_k C)P_k A^T + Q. \quad (5)$$

O KF possui duas fases: previsão e correção. A fase de previsão é responsável por projetar o estado atual, obtendo o estado no próximo tempo, sendo formado pelas Equações 1 e 2. A fase de correção é responsável por incorporar a nova medição ao estado atual para obter uma estimativa mais precisa considerando todo o histórico das medições. Essa fase é formada pelas Equações 3, 4 e 5 [Nakamura et al. 2007].

3.1.2. Filtro de Partículas

Os filtros de Partículas são recursivas implementações dos métodos sequenciais de Monte Carlo (SMCs). Apesar do KF ser a abordagem clássica para estimativa de estados, PF representa uma alternativa para problemas não-lineares com ruídos não-Gaussianos [Nakamura et al. 2007].

Esse método cria uma pdf (*probability density function*) baseado em um grande número de amostras aleatórias denominadas partículas. Essas partículas são propagadas ao longo do tempo, combinando sequencialmente os passos de amostragem e reamostragem. A cada passo no tempo, a reamostragem é usada para descartar algumas partículas, aumentando a relevância das regiões de maior probabilidade. Cada partícula tem um peso associado que indica a sua qualidade. A estimativa é o resultado da soma dos pesos de todas as partículas.

O PF pode ser dividido em duas fases: previsão e correção. Durante a previsão, cada partícula é modificada de acordo com o modelo existente, incluindo a adição de ruído aleatório, a fim de simular o efeito do ruído. Na correção, os pesos de cada partícula são reavaliados baseados na última informação disponível, sendo que as partículas com menores pesos são eliminadas no processo de reamostragem.

3.2. Localização

Localização consiste em determinar a localização física (e.g., latitude, longitude e altitude) dos nós sensores da rede, sendo essencial que este processo seja desempenhado pelos próprios nós (auto-localização). Este trabalho usa os algoritmos RPE e o DPE para calcular a posição dos nós. Então, as localizações estimadas são usadas pelos algoritmos de rastreamento.

3.2.1. Estimativa de Localização Recursiva

O RPE [Albowicz et al. 2001] é um algoritmo de localização que requer, usualmente, que 5% dos nós sejam *beacons*. Nesse algoritmo, um nó livre precisa de pelo menos três referências para estimar sua posição, sendo que as posições estimadas também são transmitidas para ajudar os outros nós. Dessa forma, o número de referências aumenta iterativamente, fazendo com que a maioria dos nós tenham suas posições estimadas.

Esse algoritmo pode ser dividido em quatro fases, como mostra a Figura 1. Na primeira fase, os nós *beacons* divulgam suas posições para serem usadas como referências pelos nós livres. Na segunda fase, os nós estimam suas distâncias para suas referências. Na terceira fase, os nós calculam suas posições usando trilateração ou multilateração, tornando-se nós estabelecidos. Na última fase, os nós estabelecidos informam suas posições para auxiliar seus vizinhos a serem localizados.

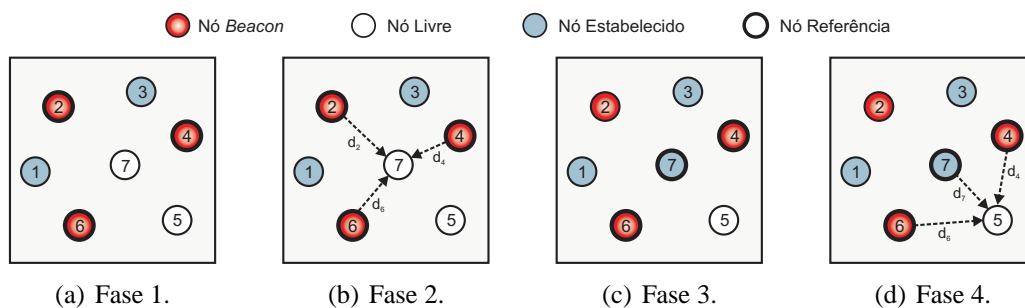


Figura 1. Fases da localização recursiva.

Os nós estabelecidos ajudam outros nós a estimarem suas posições, por isso o número de referências cresce rapidamente. Essa é a principal vantagem desse algoritmo, mas o uso de nós estabelecidos como referências acumulam erros que são propagados. Por fim, o RPE é um algoritmo que trabalha de forma distribuída usando múltiplos saltos. Ele não necessita de infra-estrutura, por isso é adequado para ambientes externos.

3.2.2. Estimativa de Localização Direcionada

O DPE [Oliveira et al. 2009] é um algoritmo similar ao RPE. A idéia do DPE é fazer a recursão do sistema iniciar de um único ponto, fazendo ela seguir uma direção conhecida. Isso possibilita que um nó estime sua posição usando somente duas referências e trabalhar em redes de densidade baixa. Além disso, o caminho controlado da recursão, leva a estimativas de localização com erros menores.

Para garantir que a recursão seja iniciada de um único ponto, o algoritmo faz uso de uma estrutura de beacons como mostra da Figure 2(a). Essa estrutura possui, geralmente, quatro *beacons* que ficam a uma distância conhecida da origem da recursão. Esses beacons iniciam a recursão divulgando suas posições aos seus vizinhos.

Com o uso de somente duas referências, a posição dos nós são calculadas fazendo a interseção de dois círculos obtidos pela posição e distância das referências. Logo um par de possíveis soluções resultam do sistema: a posição correta e a incorreta (ver Figura 2(b)). Uma vez que a direção da recursão é mantida, a posição correta do nó livre

é o ponto mais distante da origem da recursão. Quando o nó livre possui mais de duas referências, ele escolhe as que estão mais distantes entre si e mais próximas da origem da recursão, para garantir estimativas de distância mais consistentes.

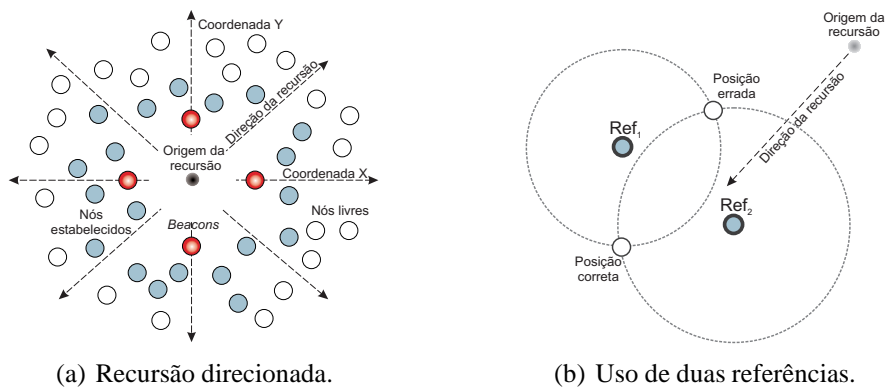


Figura 2. Localização direcionada.

Da mesma forma que o RPE, o DPE também propaga os erros de localização. Então os nós mais distantes da estrutura de *beacons* tem maior probabilidade de terem erros de localização maiores. Para evitar a propagação de erros exagerada é possível acrescentar mais estruturas de beacons ao sistema de localização, isso reduz o número de recursões e, conseqüentemente, melhora o desempenho final do algoritmo.

4. Abordagem Proposta

Os erros introduzidos pelo sistema de localização não são filtrados com sucesso pelos algoritmos de rastreamento [Souza et al. 2009]. Sendo assim, uma das alternativas para reduzir o erro do rastreamento é reduzir o erro de localização. Quanto menor for o erro de localização, mais próximos das condições ideais operam os algoritmos de rastreamento.

Dessa forma, propomos uma abordagem que busca reduzir o erro das estimativas de distância para melhorar a localização. Durante a localização são feitas múltiplas estimativas de distância, ou seja, cada nó referência informa sua posição k vezes. Os nós que recebem esses pacotes criam uma instância de KF para cada fonte distinta assim que o primeiro pacote é recebido. Todas as estimativas de distância seguintes são passadas como medição ao KF correspondente. Por sua vez, o filtro obtém uma única estimativa de distância mais precisa. Essa abordagem é representada pela Figura 3.

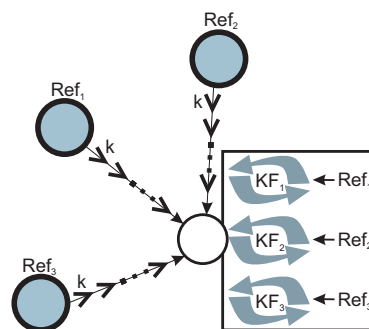


Figura 3. Abordagem de fusão de dados.

Usar KF para calcular a média das distâncias estimadas é uma boa opção, pois permite que o cálculo seja realizado iterativamente, evitando armazenar no nó todas as informações de distância e refazer o cálculo sempre que uma mensagem nova for recebida.

5. Avaliação

Nesta seção apresentamos como a imprecisão dos algoritmos de localização afetam o rastreamento de alvos em redes de sensores, já que os algoritmos de rastreamento nessas redes são frequentemente baseados em informações geográficas geradas por algoritmos de localização. Sendo que durante o processo de localização são realizadas múltiplas estimativas de distância visando reduzir o erro resultante.

5.1. Metodologia

A metodologia adotada nas avaliações deste artigo é dividida em cinco fases, como mostra a Figura 4. Primeiramente, há uma rede de sensores com alguns nós *beacons*, onde a maioria dos nós desconhece sua localização. Na segunda fase, um algoritmo de localização é aplicado, sendo que durante essa etapa podem ser feitas múltiplas estimativas de distância aplicando a abordagem da Seção 4. Na terceira fase os nós conhecem sua posição, detectam o alvo e calculam sua posição. Na quarta fase, os nós enviam a posição do alvo para o nó *sink*. Na fase final o nó *sink* executa o algoritmo de rastreamento, enquanto houver medições, as estimativas continuam sendo realizadas (volta para a etapa 3).

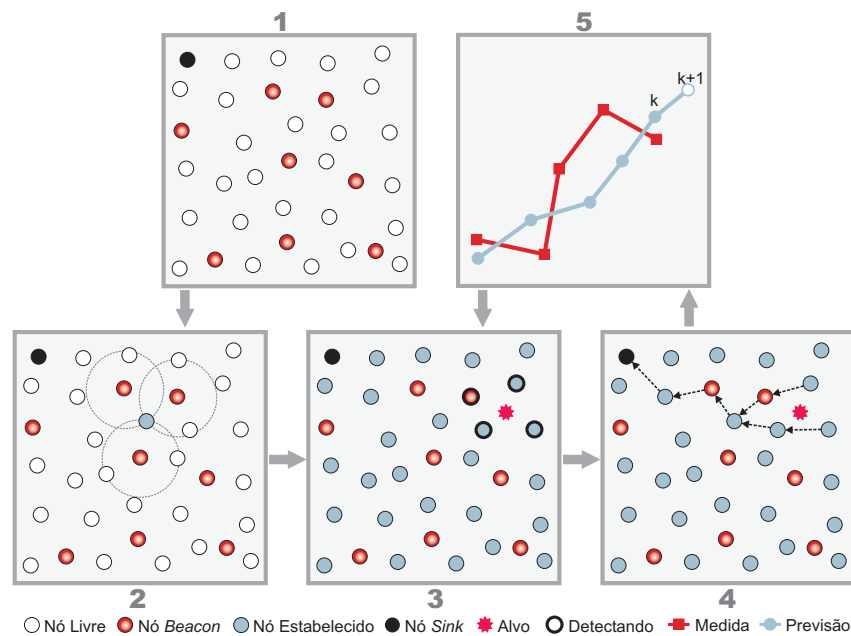


Figura 4. Fases da metodologia das avaliações.

As avaliações foram realizadas por meio de simulações com as implementações dos algoritmos em Java. Para isso, a rede foi gerada como um grafo, em que os nós da rede são vértices e a comunicação entre os nós são as arestas. Consideramos que a comunicação entre os nós é perfeita, portanto sempre há comunicação entre nós que estão dentro do raio de alcance.

As posições dos nós são estimadas com RPE e DPE. No RPE 5% dos nós são *beacons*, enquanto no DPE somente uma estrutura com quatro *beacons* é usada (posicionada no centro da rede). Para simular a imprecisão das estimativas de distância, geralmente feitas com RSSI (*Received Signal Strength Indicator*), ToA (*Time of Arrival*) e TDoA (*Time Difference of Arrival*) [Gibson 1999], cada amostra de distância é perturbada por uma variável Gaussiana de média zero e desvio padrão de 5% da distância. Durante a localização são realizadas 1, 10, 20, 50, 100 e 200 estimativas de distância entre cada nó livre e suas referências.

O rastreamento é feito com KF e PF. O PF foi fixado em 1000 partículas, valor obtido em avaliações anteriores que mostraram que mais de 1000 partículas não reduz significativamente o erro do rastreamento. Por uma questão de simplificação, foi considerado que a trajetória do alvo é um movimento uniforme, para que o movimento possa ser modelado como um sistema linear e ser usado com KF e PF. A trajetória do alvo é composta por 1000 pontos para considerar uma amostragem significativa. A distância entre esses pontos é de 0,1m (movimento uniforme) para manter o alvo dentro da área monitorada. As manobras do alvo são determinadas por um ângulo gerado aleatoriamente entre -25° e 25° a cada 25 passos.

A configuração padrão da rede é composta de 150 nós sensores distribuídos aleatoriamente no campo de sensores de $70 \times 70 \text{m}^2$. O raio de comunicação e detecção é de 15m para cada nó. Essa configuração define uma rede com densidade de $0,03 \text{ nós/m}^2$, suficiente para que a maioria dos nós estimem suas posições com RPE e DPE. Os resultados obtidos nos experimentos são obtidos da média de 100 execuções diferentes. As barras de erro representam um intervalo de confiança de 99% de confiança.

5.2. Resultados das Simulações

5.2.1. Custos e Benefícios de Múltiplas Estimativas de Distância

Realizar mais estimativas de distância na localização reduz os erros da própria localização e do rastreamento, mas é necessário enviar mais pacotes. Por isso, nesta seção avaliamos os custos e os benefícios da utilização dessa abordagem. Tal análise é importante, pois ajuda a definir o quanto se deve gastar para obter a precisão desejada no rastreamento.

O RPE e o DPE possuem complexidade de comunicação $O(n)$, em que n é a quantidade de nós. A Figura 5(a) mostra a quantidade de pacotes enviados quando as estimativas de distância aumentam. Utilizar k estimativas faz com a complexidade de comunicação mude para $O(kn)$. Ainda é possível notar nessa figura que o RPE envia menos pacotes que o DPE. Isso ocorre porque alguns nós não estimam suas posições com o RPE devido a baixa densidade da rede, reduzindo a quantidade de pacotes enviados.

Já a Figura 5(b) mostra a melhora na precisão do rastreamento à medida que a quantidade de estimativas de distância aumenta. A utilização de 10 estimativas já proporciona uma melhora significativa quando comparados aos resultados obtidos com apenas uma estimativa. No rastreamento utilizando o RPE, o PF consegue melhores resultados, pois esse algoritmo reduz uma pequena parte do ruído introduzido na localização. Já no rastreamento com DPE, o KF passa a gerar estimativas mais precisas a partir de 10 estimativas de distância, pois o erro de localização é baixo, de forma que o KF começa a operar próximo das suas condições ideais.

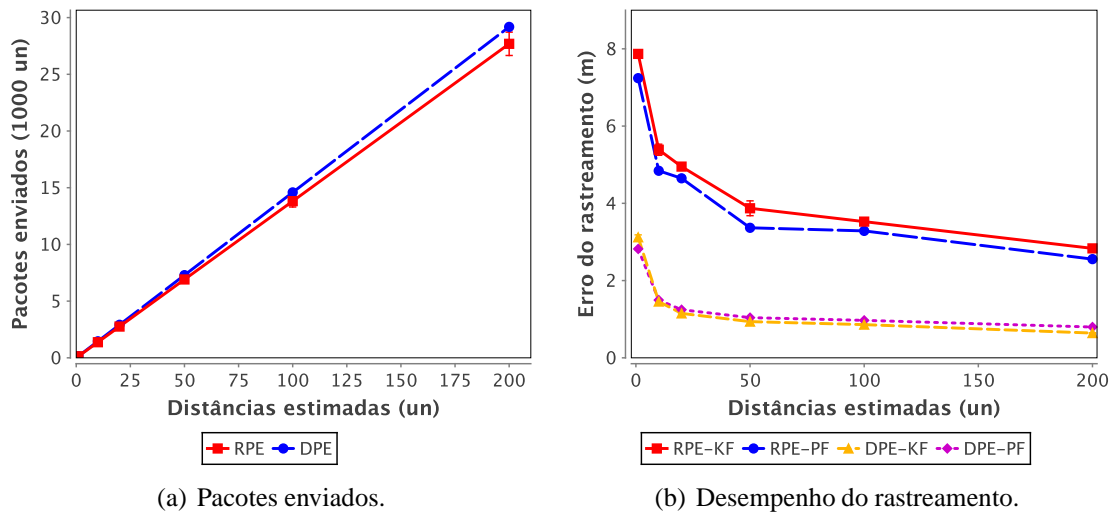


Figura 5. Custos e benefícios das múltiplas estimativas de distância.

Não é vantajoso utilizar uma quantidade muito elevada de estimativas de distância, pois o benefício atingido é baixo para o custo exigido. Usar 10 estimativas de distância é o suficiente para alcançar melhoras de aproximadamente 30% com o RPE e de 50% com o DPE. Já com 50 estimativas de distância a precisão do rastreamento com RPE e DPE melhoram, respectivamente, em aproximadamente 51% e 65%. Entretanto, mais estimativas, como 100 e 200, levam a uma melhora de apenas 5% se comparado com 50 estimativas, apesar de duplicar as estimativas de distância.

5.2.2. O Impacto da Imprecisão das Estimativas de Distância

A distância estimada pelos nós sensores não é perfeita. Dependendo da técnica utilizada e do ambiente monitorado, os erros associados são altos, afetando o desempenho do rastreamento. Em geral, esses erros dependem da distância e podem ser modelados como uma variável Gaussiana de média zero, em que o desvio padrão é um percentual da distância atual [Bachrach and Eames 2005]. Desse modo, para avaliarmos diferentes situações, variamos o desvio padrão de 5% a 30% da distância para RPE e DPE.

Os resultados são mostrados na Figura 6. Quando a imprecisão das estimativas de distância é baixa (entre 5% e 10% da distância), a melhora de precisão do rastreamento usando DPE é pouco significativa, independente do número de estimativas de distância utilizadas. Quando essa imprecisão é alta (entre 15% e 30%), a partir de 50 estimativas de distância, nota-se que o valor médio do erro converge para 1m (Figuras 6(b) e 6(d)). Entretanto, com o RPE, a melhora é perceptível mesmo quando a imprecisão das estimativas de distância é baixa (Figuras 6(a) e 6(c)).

Também é interessante notar nas Figuras 6(e) e 6(f) que o PF supera o KF, principalmente quando o RPE é o algoritmo de localização escolhido. Isto ocorre devido à natureza não-linear e não-Gaussiana do PF que reduz uma pequena fração do ruído não-Gaussiano introduzido pela localização.

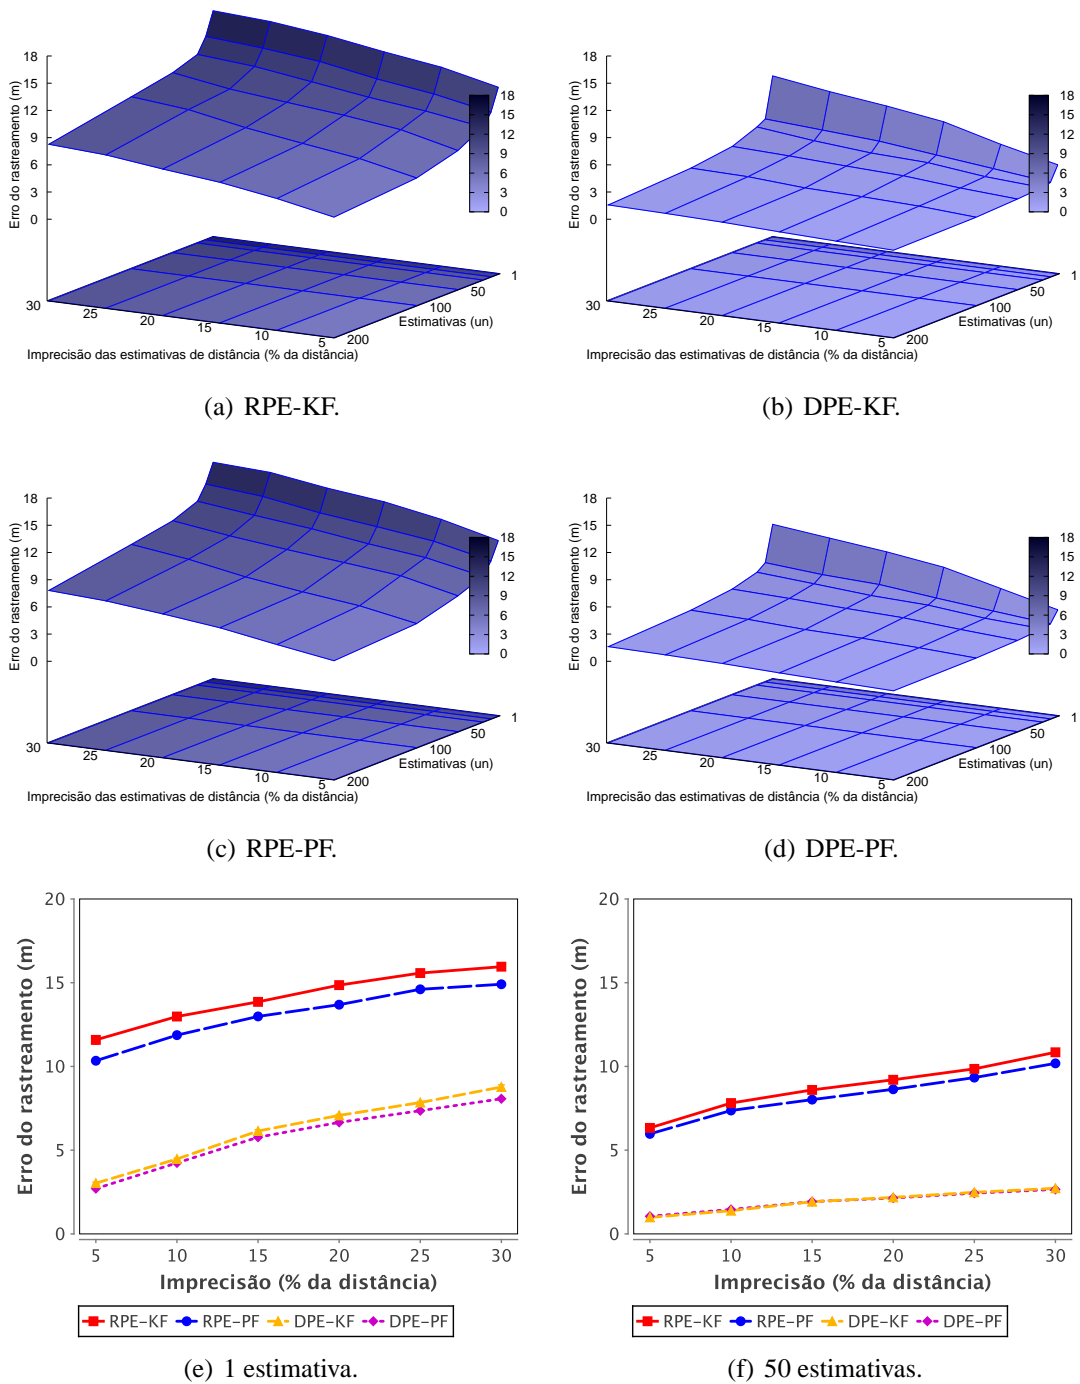


Figura 6. Impacto da imprecisão das estimativas de distância.

5.2.3. O Impacto da Densidade da Rede

Avaliamos o impacto da densidade da rede aumentando a quantidade de nós no mesmo campo de sensores, de modo que a densidade da rede varie de 0,03 a 0,07 nós/m². A menor densidade usada nesse experimento permite que tanto o RPE quanto o DPE estimem a localização da maioria dos nós sensores.

A Figura 7 mostra que, no DPE o erro do rastreamento permanece constante, pois

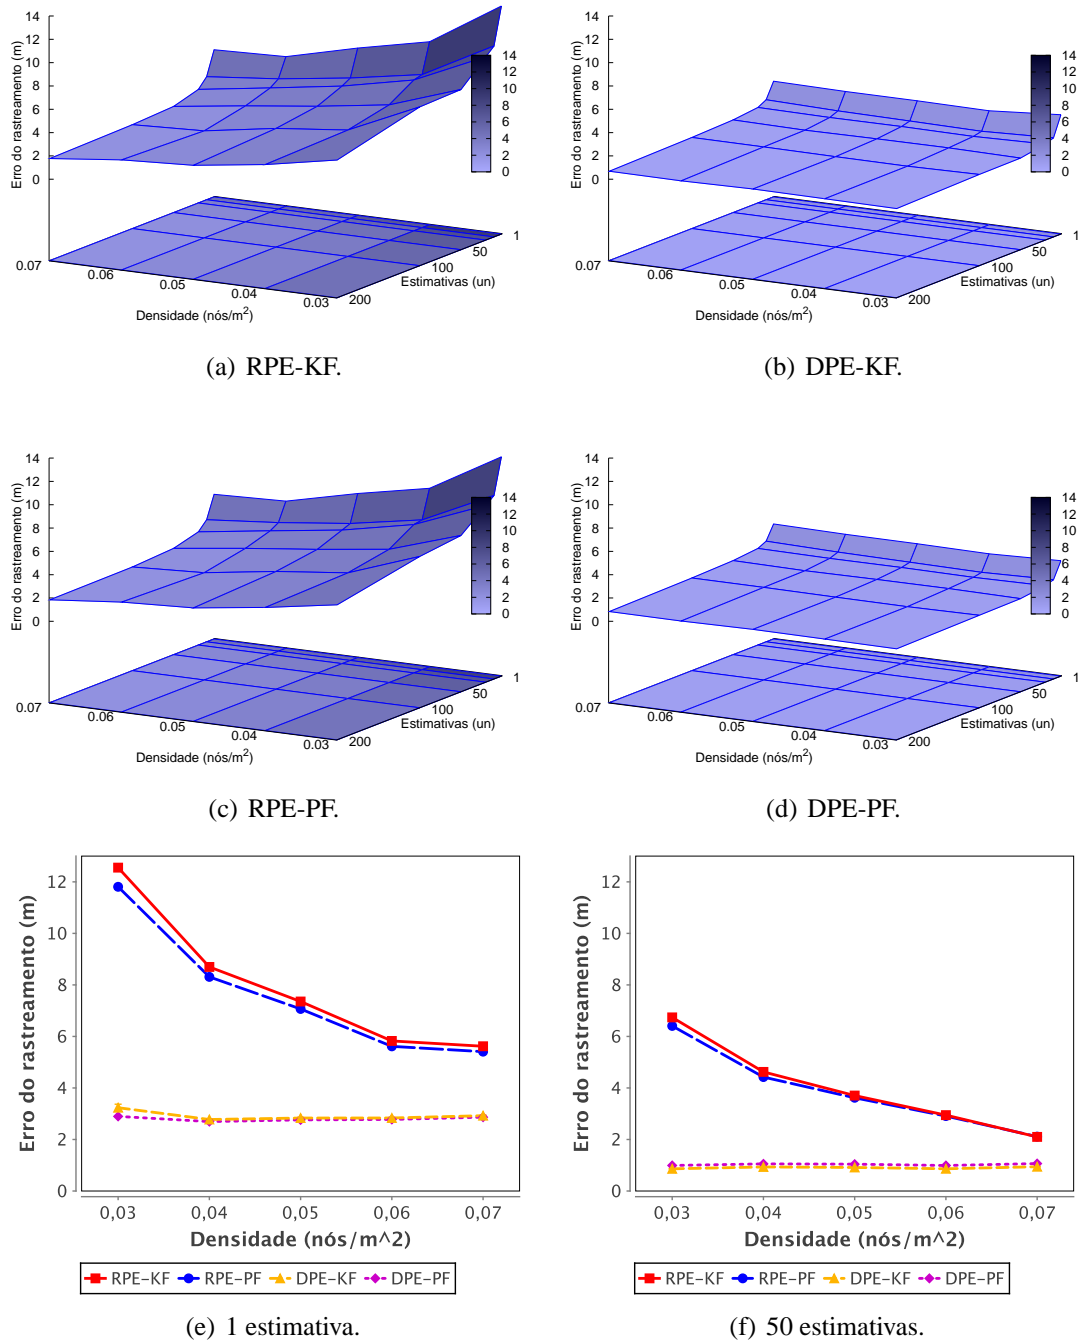


Figura 7. Impacto da densidade da rede.

somente uma estrutura de *beacons* é usada em todas as variações de densidade. Por outro lado, no RPE a quantidade de *beacons* aumenta com a densidade da rede, reduzindo o erro do rastreamento à medida que a quantidade de nós aumenta.

Usar múltiplas estimativas de distância é importante para melhorar a precisão do rastreamento com RPE, principalmente em redes esparsas, como mostram as Figuras 7(a) e 7(c). Já com o DPE, a densidade da rede não interfere no rastreamento. Portanto, a partir de 50 estimativas o valor médio do erro converge para 0,7m (Figuras 7(b) e 7(d)).

Com uma estimativa de distância, o rastreamento com PF é ligeiramente melhor, tanto no RPE quanto no DPE (Figura 7(e)), já que ele filtra uma pequena fração dos erros de localização não-Gaussianos. Quando são utilizadas 50 estimativas, o desempenho do KF chega a ser equivalente ao do PF no caso do RPE e superior no caso do DPE, pois com erros de localização baixos o KF opera próximo das condições ideais (Figura 7(f)).

5.2.4. O Impacto da Escala da Rede

Nesta seção, avaliamos como a escala da rede afeta a combinação de algoritmos localização-rastreamento. Essa análise é importante, pois as redes de sensores sem fio prevêm situações em que precisam ser implantadas em larga escala. Nesse contexto, variamos a quantidade de nós de 100 até 350, mantendo constante a densidade de 0,03 nós/m². Portanto, a área monitorada é redimensionada de acordo com a quantidade de nós sensores. Como o percentual de *beacons* usados no RPE é de 5%, o número de *beacons* aumenta de acordo com a quantidade de nós. O DPE mantém o uso de somente uma estrutura de *beacons* com quatro *beacons*.

A Figura 8 mostra que o aumento da escala da rede faz com que o erro do rastreamento utilizando DPE também aumente. Isso é causado pelo incremento na quantidade de nós que gera uma maior propagação dos erros, uma vez que a mesma quantidade de *beacons* é mantida independente da quantidade de nós. Entretanto, com o RPE o erro do rastreamento permanece quase constante, pois a quantidade de *beacons* aumenta na mesma proporção que os demais nós.


Com o DPE, usar múltiplas estimativas de distância melhora significativamente a precisão do rastreamento quando existem muitos nós na rede (entre 250 e 350), entretanto têm pouca influência quando existem poucos nós (Figuras 8(b) e 8(d)). Já com o RPE é importante para qualquer quantidade de nós usada (Figuras 8(a) e 8(c)).

6. Conclusões e Trabalhos Futuros


Este artigo avaliou o uso de fusão de dados para reduzir erros de localização e seus impactos em rastreamento. Para essa avaliação, escolhemos o RPE – solução pioneira – e o DPE – mais precisa e barata que o RPE – para calcular a posição dos nós. As técnicas de rastreamento de alvos escolhidas são o KF e o PF. Esses filtros são muito populares e podem ser considerados como soluções canônicas para os problemas de rastreamento.

Como conclusão geral, a redução do erro de localização favorece o desempenho do KF em relação ao PF, principalmente quando o DPE é utilizado, pois o erro de localização se torna pequeno o suficiente para que o KF comece a operar próximo de suas condições ideais. Usar 10 estimativas de distância é suficiente para alcançar melhoras superiores a 50%. Já com 50 estimativas de distância a precisão do rastreamento obtém uma melhora superior a 60%. Entretanto, a partir de 50 estimativas o valor médio do erro de rastreamento converge.

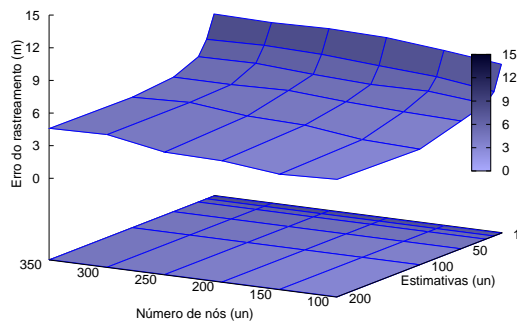
Indicação para o futuro incluem analisar a direção e sentido dos erros gerados pelos algoritmos de localização. O objetivo dessa análise é encontrar um padrão que possibilite a elaboração de um algoritmo de rastreamento que considere tal padrão para melhorar os resultados do rastreamento ou então melhorar o próprio sistema de localização.



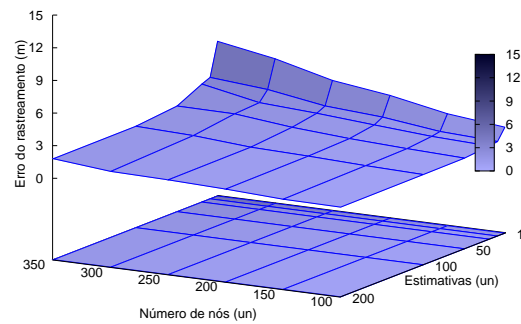
(a) RPE-KF.



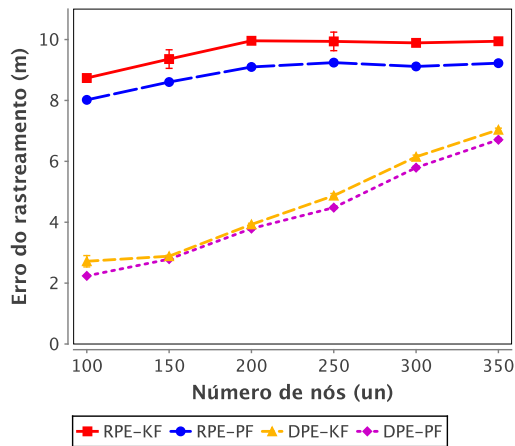
(b) DPE-KF.



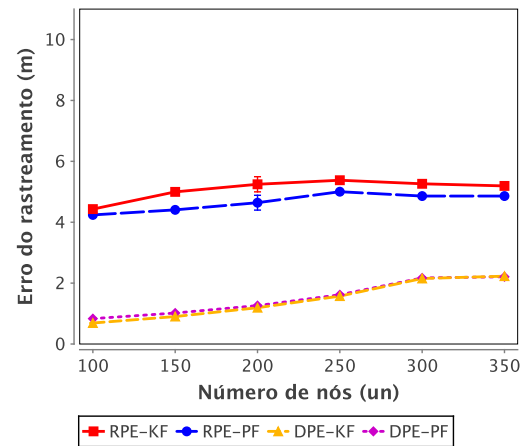
(c) RPE-PF.



(d) DPE-PF.



(e) 1 estimativa.



(f) 50 estimativas.

Figura 8. Escalabilidade do rastreamento.

7. Agradecimentos

Este trabalho foi parcialmente financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), sob os processos 47.4194/2007-8 (RastroAM), 55.4087/2006-5 (SAUIM) e 57.5808/2008-0 (Revelar).

Referências

- Akyildiz, I. F., Su, W., Sankarasubramaniam, Y., and Cayirci, E. (2002). Wireless sensor networks: A survey. *Computer Networks*, 38(4):393–422.
- Albowicz, J., Chen, A., and Zhang, L. (2001). Recursive position estimation in sensor networks. In *Proc. of the 9th Int'l Conf. on Network Protocols (ICNP'01)*, pages 35–41, Riverside, USA.
- Arulampalam, M. S., Maskell, S., Gordon, N., and Clapp, T. (2002). A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking. *IEEE Trans. on Signal Processing*, 50(2):174–188.
- Bachrach, J. and Eames, A. M. (2005). Localization in sensor networks. In Stojmenovic, I., editor, *Handbook of Sensor Networks: Algorithms and Architectures*, pages 277–310. John Wiley & Sons Inc.
- Boukerche, A., Oliveira, H. A., Nakamura, E. F., and Loureiro, A. A. (2008). Vehicular ad hoc networks: A new challenge for localization-based systems. *Computer Communications*, 31(12):2838 – 2849. Mobility Protocols for ITS/VANET.
- Gibson, J. D. (1999). *The Mobile Communication Handbook*. IEEE Press.
- He, T., Huang, C., Blum, B. M., Stankovic, J. A., and Abdelzaher, T. (2003). Range-free localization schemes for large scale sensor networks. In *Proc. of the 9th ACM Int'l Conf. on Mobile Computing and Networking (MobiCom '03)*, pages 81–95.
- Julier, S. J. and Uhlmann, J. K. (1997). A new extension of the Kalman filter to nonlinear systems. In *Proc. of the SPIE Signal Processing, Sensor Fusion, and Target Recognition VI Conference*, volume 3068, pages 182–193, Orlando, USA.
- Nakamura, E. F., Loureiro, A. A. F., and Frery, A. C. (2007). Information fusion for wireless sensor networks: Methods, models, and classifications. *ACM Computing Surveys*, 39(3):1–55 (A9).
- Niculescu, D. and Nath, B. (2001). Ad hoc positioning system (aps). In *Proc. of the IEEE Global Telecommunications Conference (GLOBECOM'01)*, pages 2926–2931.
- Oliveira, H. A. B. F., Boukerche, A., Nakamura, E. F., and Loureiro, A. A. F. (2009). Towards a directed localization recursion in wireless sensor networks. *IEEE Trans. on Computers*, 58(5):677–691.
- Seada, K., Helmy, A., and Govindan, R. (2004). On the effect of localization errors on geographic face routing in sensor networks. In *Proc. of the 3rd Int'l Symposium on Information Processing in Sensor Networks (IPSN'04)*, pages 71–80, Berkley, USA.
- Shah, R., Wolisz, A., and Rabaey, J. (2005). On the performance of geographical routing in the presence of localization errors [ad hoc network applications]. In *Proc. of the IEEE Int'l Conf. on Communication (ICC'05)*, pages 2979–2985.
- Souza, E. L., Nakamura, E. F., and de Oliveira, H. A. (2009). On the performance of target tracking algorithms using actual localization systems for wireless sensor networks. In *Proc. of the 12th ACM Int'l Conf. on Modeling, analysis and simulation of wireless and mobile systems (MSWiM'09)*, pages 418–423.