

# Novo Método de Localização em Sistema Celular

Sergio Forcellini

Depto. de Engenharia de Telecomunicações e Controle  
Escola Politécnica da Universidade de São Paulo  
sergio@lcs.poli.usp.br; sergioforcellini@hotmail.com

Luiz Cezar Trintinalia

Depto. de Engenharia de Telecomunicações e Controle  
Escola Politécnica da Universidade de São Paulo  
trinti@lcs.poli.usp.br

**Resumo:** Este trabalho estabelece um novo método de estimação de localização usando a relação existente entre o atraso de excesso médio e o atraso de espalhamento em um canal de propagação de um sistema celular. Uma vez estimado o atraso de espalhamento, este valor é utilizado para corrigir as distâncias na equação de localização usando o método da máxima verossimilhança. Na simulação de trajetórias, a distância entre a  $i$ -ésima base e o móvel, assim como a localização final, são estimadas através da filtragem de Kalman. O erro de localização é minimizado se conhecermos a estatística dos erros introduzidos pela não-visada-direta (NLOS) e ruído de medida. Comparado com outros métodos, o algoritmo proposto apresenta excelente precisão.

**Palavras-chave:** Maximum likelihood estimation (ML), Non-Line- of-Sight (NLOS), time of arrival (TOA), time difference of arrival (TDOA).

**Abstract:** This paper establishes a new location estimation method using the relationship between mean excess delay and delay spread in a channel model for a wireless system. Once the delay spread is estimated, its value is used to correct the distance estimated in the maximum likelihood location equation. In trajectory simulation, the distance between  $i$ -th base and the mobile, besides the final location are estimated through Kalman filtering. The location error is minimized if we know the error statistics introduced by NLOS propagation and measured noise. Compared with other methods, the proposed algorithm shows big accuracy.

**Keywords:** Maximum likelihood estimation (ML), Non-Line- of-Sight (NLOS), time of arrival (TOA), time difference of arrival (TDOA).

## I. INTRODUÇÃO

Os regulamentos para localização móvel foram estabelecidos pelo FCC o qual determina que a precisão de localização para fase II é de 100m em 67% do tempo e 300m em 95% do tempo para sistemas de localização baseados na rede [1]. Os métodos principais de localização do terminal móvel são por intensidade de sinal, ângulo de chegada (AoA), tempo de chegada (ToA) e diferença de tempo de chegada (TDoA). Infelizmente, seja qual for o método utilizado, o ambiente adverso de propagação impõe grandes obstáculos para estimação precisa dos parâmetros envolvidos mesmo utilizando múltiplas estações bases. O problema de estimação não é tão complicado quando os receptores estão distribuídos ao longo de uma linha reta, onde muitos processos ótimos foram desenvolvidos para este caso [2] – [4]. Contudo, quando os receptores estão distribuídos arbitrariamente, a estimação é mais complexa. Em ambientes urbanos típicos e adversos podem, na maior parte das vezes, não haver visada direta entre o móvel e a estação base. Devido a reflexões e difrações do sinal, as ondas de propagação podem percorrer distâncias adicionais na ordem de centenas de metros devido aos multipercursos e a onda direta é bloqueada [5]. Este fenômeno, o qual refere-se ao erro de não-visada direta (NLOS) transforma-se em uma estimativa polarizada da

localização do móvel. Este problema é considerado o mais crítico no processo de localização [5], [6].

Chan e Ho [7] propuseram um algoritmo de localização baseado na diferença de tempo de Chegada (TdoA) de máxima verossimilhança em 2 passos, o qual é muito preciso quando o problema de não visada direta não é tão sério. Considerando o problema de não visada direta, Wang [8] propôs um algoritmo que utiliza programação matemática para se obter a estimativa de máxima verossimilhança da posição da fonte em domínio restrito definido pelas desigualdades induzidas pela propagação sem visada direta (NLOS). De modo a melhorar a estimativa na situação de não visada direta é necessário desenvolver um algoritmo robusto a este tipo de erro. Dados reais apresentados pela Motorola e Ericsson [9] mostraram que  $\tau_m$  (atraso em excesso) é essencialmente correlacionado com  $\tau_{RMS}$  (espalhamento do atraso) do canal de propagação. Foi confirmada esta correlação através de simulações realizadas com o modelo do COST-259 em ambientes típicos urbanos e este fator de correlação, entre  $\tau_{RMS}$  e  $\tau_m$ , é da ordem 1:1 na condição de NLOS e 2:1 em visada direta (figura 1). O algoritmo proposto neste trabalho usa esta correlação entre esses parâmetros de modo a corrigir as distâncias medidas na equação de localização [10].

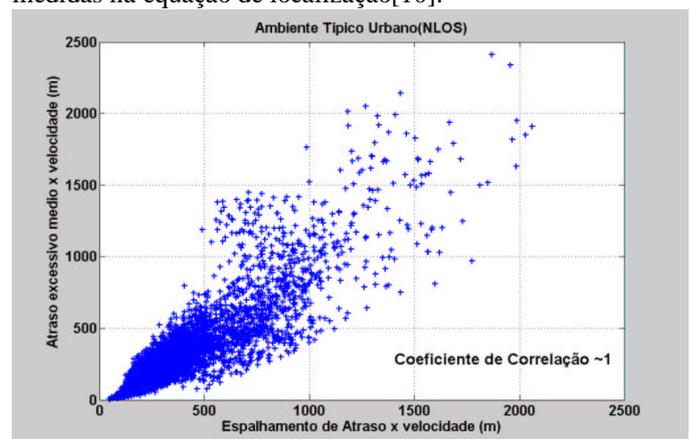


Fig. 1- Espalhamento de atraso x Atraso excessivo médio

## II. ALGORITMO PROPOSTO

Por simplicidade, consideraremos o problema de localização no espaço bi-dimensional. A formulação também poderá ser estendida ao espaço tri-dimensional. Sejam  $M$  estações bases arbitrariamente distribuídas num plano 2-D (fig.2). Admita-se também que  $(x,y)$  é a posição da estação móvel,  $(x_i,y_i)$  é a

posição da  $i$ -ésima estação base e  $d_i$  é a distância medida no receptor  $i$ . Em grandes cidades e em áreas montanhosas o problema principal em propagação é a não visada direta (NLoS). Nesta condição, a comunicação é mantida via multi-percursos. Entretanto, os multi-percursos possuem comprimentos diferentes em relação à visada direta o que causará erros na precisão da posição final. Estes erros são enormes e polarizados, tornando-os dominantes sobre os erros de medidas.

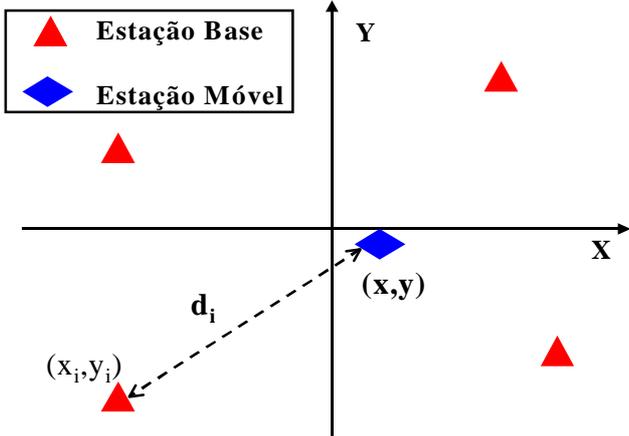


Fig. 2- Localização no plano 2-D

Incluindo-se as influências dos erros NLOS e de medidas em nossa formulação, temos:

$$d_i = \sqrt{(x-x_i)^2 + (y-y_i)^2} + n_i, \quad i=1,2,\dots,M \quad (1)$$

onde  $d_i = c\tau_i$  é a medida da distância entre a estação móvel e o receptor da estação base  $i$ ,  $c$  é a velocidade de propagação do sinal,  $\tau_i$  representa o atraso e  $n_i$  os erros devidos a não visada direta e ruído de medida o qual, normalmente, tem média nula. Tomando-se o valor médio de  $d_i$ , no tempo, através de  $L$  amostras temos:

$$\tilde{d}_i = \sqrt{(x-x_i)^2 + (y-y_i)^2} + \tilde{n}_i, \quad i=1,2,\dots,M \quad (2)$$

Re-arranjando os termos na equação e elevando-a ao quadrado temos:

$$x^2 - 2xx_i + x_i^2 + y^2 - 2yy_i + y_i^2 = (\tilde{d}_i - \tilde{n}_i)^2 \quad (3)$$

$$\text{Façamos } x^2 + y^2 = d \text{ e } x_i^2 + y_i^2 = K_i$$

Desta forma, temos:

$$-2xx_i - 2yy_i + d = (\tilde{d}_i - \tilde{n}_i)^2 - K_i \quad (4)$$

Admitamos que  $\mathbf{Z}_a = [x, y, d]^T$  seja o vetor de incógnitas e expressando (4) na forma matricial temos:

$$\mathbf{G}_a \mathbf{Z}_a = \tilde{\mathbf{h}}, \quad (5)$$

onde:

$$\mathbf{G}_a = \begin{bmatrix} -2x_1 & -2y_1 & 1 \\ -2x_2 & -2y_2 & 1 \\ \vdots & \vdots & \vdots \\ -2x_M & -2y_M & 1 \end{bmatrix}$$

$$\tilde{\mathbf{h}} = \begin{bmatrix} (\tilde{d}_1 - \tilde{n}_1)^2 - K_1 \\ (\tilde{d}_2 - \tilde{n}_2)^2 - K_2 \\ \vdots \\ (\tilde{d}_M - \tilde{n}_M)^2 - K_M \end{bmatrix} \quad (6)$$

O estimador de máxima verossimilhança que minimiza a soma do erro quadrático médio é dado por:

$$\mathbf{Z}_a = (\mathbf{G}_a^T \mathbf{G}_a)^{-1} \mathbf{G}_a^T \tilde{\mathbf{h}} \quad (7)$$

O valor esperado de  $\mathbf{Z}_a$  dado  $\tilde{\mathbf{d}}$  é fornecido pela seguinte expressão:

$$E(\mathbf{Z}_a / \tilde{\mathbf{d}}) = E\left\{[(\mathbf{G}_a^T \mathbf{G}_a)^{-1} \mathbf{G}_a^T \tilde{\mathbf{h}}] / \tilde{\mathbf{d}}\right\} = (\mathbf{G}_a^T \mathbf{G}_a)^{-1} \mathbf{G}_a^T E(\tilde{\mathbf{h}} / \tilde{\mathbf{d}}) \quad (8)$$

onde:

$$E(\tilde{h}_i / \tilde{d}_i) = \tilde{d}_i^2 - 2\tilde{d}_i E[\tilde{n}_i] + E[\tilde{n}_i^2] - K_i \quad (9)$$

No algoritmo proposto,  $\sigma_{n_i}^2$  é estimado através das  $L$  amostras tomadas no tempo através da relação:

$$\sigma_{n_i}^2 = E[d_i^2] - E[d_i]^2 = E[n_i^2] - E[n_i]^2 \quad (10)$$

O valor de  $E[n_i]$  é obtido através da correlação entre o espalhamento de atraso e o atraso de excesso médio[9]. O

valor  $E[n_i^2]$  é obtido através da relação estatística :

$$E[n_i^2] = \frac{\sigma_{n_i}^2}{L} + E[\tilde{n}_i]^2 \quad (11)$$

Aplicando-se os valores obtidos em (9) e resolvendo (7) obtemos uma primeira estimativa de  $\mathbf{Z}_a$

Nesta primeira estimativa de  $\mathbf{Z}_a$  utilizamos a independência das variáveis  $x$ ,  $y$  e  $d$ , embora a variável  $d$  seja dependente das variáveis  $x$  e  $y$ . Para melhorar a precisão da estimativa de localização devemos usar esta dependência como é feito em [8]. Sejam os erros de estimação de  $x$ ,  $y$  e  $d$  como sendo  $e_1$ ,  $e_2$  e  $e_3$ . Daqui em diante, indicaremos a  $i$ -ésima entrada de uma matriz  $\mathbf{Z}_a$  como sendo  $[\mathbf{Z}_a]_i$ , então as entradas no vetor  $\mathbf{Z}_a$ , tornam-se:

$$[\mathbf{Z}_a]_1 = x^0 + e_1, [\mathbf{Z}_a]_2 = y^0 + e_2, [\mathbf{Z}_a]_3 = d^0 + e_3, \quad (12)$$

onde  $x^0$ ,  $y^0$  e  $d^0$  representam os valores verdadeiros de  $x$ ,  $y$  e  $d$ . Definindo um outro vetor de erro como sendo:

$$\boldsymbol{\Psi}' = \mathbf{h}' - \mathbf{G}_a' \mathbf{Z}_p \quad (13)$$

onde:

$$\mathbf{h}' = \begin{bmatrix} [\mathbf{Z}_a]_1^2 \\ [\mathbf{Z}_a]_2^2 \\ [\mathbf{Z}_a]_3 \end{bmatrix}, \quad \mathbf{G}_a' = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 1 & 1 \end{bmatrix} \quad (14)$$

e  $\mathbf{Z}_p = \begin{bmatrix} x^2 \\ y^2 \end{bmatrix}$ , substituindo (12) em (13), nós temos:

$$\begin{aligned} \begin{bmatrix} \psi' \\ \psi' \end{bmatrix} &= 2x^0 e_1 + e_1^2 \approx 2x^0 e_1 \\ \begin{bmatrix} \psi' \\ \psi' \end{bmatrix} &= 2y^0 e_2 + e_2^2 \approx 2y^0 e_2 \\ \begin{bmatrix} \psi' \\ \psi' \end{bmatrix} &= e_3 \end{aligned} \quad (15)$$

Obviamente, as aproximações acima são válidas somente quando os erros  $e_1$ ,  $e_2$  e  $e_3$  são muito pequenos. A matriz de covariância  $\Psi'$  é dada por:

$$\Psi' = E[\Psi' \Psi'^T] = 4\mathbf{B}' \text{cov}(\mathbf{Z}_a) \mathbf{B}' \quad (16)$$

$$\mathbf{B}' = \text{diag}\{x^0, y^0, 0,5\}$$

A matriz de covariância de  $\mathbf{Z}_a$  é calculada conforme mostrado em [7]:

$$\text{cov}(\mathbf{Z}_a) = (\mathbf{G}_a^T \Psi^{-1} \mathbf{G}_a)^{-1}, \quad (17)$$

onde:

$$\Psi = 4\mathbf{B}\mathbf{Q}\mathbf{B} \quad \text{e} \quad \mathbf{B} = \text{diag}\{d_1^0, \dots, d_M^0\} \quad (18)$$

e  $\mathbf{Q}$  representa a matriz de covariância do ruído medido e  $d_1^0, \dots, d_M^0$  indica as distâncias verdadeiras entre a fonte e os receptores.

Como se trata de uma aproximação, os elementos  $x^0$  e  $y^0$  na matriz  $\mathbf{B}'$  podem ser substituídos pelos dois primeiros elementos  $x$  e  $y$  de  $\mathbf{Z}_a$ . Analogamente, a estimativa de máxima verossimilhança de  $\mathbf{Z}_p$  é dada por:

$$\begin{aligned} \mathbf{Z}_p &= (\mathbf{G}_a^T \Psi'^{-1} \mathbf{G}_a')^{-1} \mathbf{G}_a^T \Psi'^{-1} \mathbf{h}' \approx \\ &= (\mathbf{G}_a^T \mathbf{B}'^{-1} (\text{cov}(\mathbf{Z}_a))^{-1} \mathbf{B}'^{-1} \mathbf{G}_a')^{-1} \mathbf{G}_a^T \mathbf{B}'^{-1} (\text{cov}(\mathbf{Z}_a))^{-1} \mathbf{B}'^{-1} \mathbf{h}' \end{aligned} \quad (19)$$

Desta forma, a estimativa da posição final  $\mathbf{Z} = [x \quad y]^T$  é dada por:

$$\mathbf{Z} = \sqrt{\mathbf{Z}_p} \quad \text{ou} \quad \mathbf{Z} = -\sqrt{\mathbf{Z}_p} \quad (20)$$

Aqui, o sinal de  $x$  deverá coincidir com o sinal de  $[\mathbf{Z}_a]_1$  calculado pela solução de (7) e o sinal de  $y$  coincide com o sinal de  $[\mathbf{Z}_a]_2$ .

### 11.1. FILTRAGEM DE KALMAN

Num terminal móvel, além do ruído gerado pelas condições de propagação do sinal no meio, temos o ruído gerado pelo movimento. Para compensarmos este tipo de ruído propõe-se a utilização do filtro de Kalman como elemento estimador das distâncias entre o móvel e as estações bases. Desta forma, o filtro de Kalman é usado na determinação dos valores de distância média  $E(d_i(t))$  da equação (9), em tempo real, entre

o terminal móvel em movimento e a  $i$ -ésima estação base. Este valor de  $E(d_i(t))$  é utilizado então para calcular  $\sigma_{n_i}^2$  através de:

$$\sigma_{n_i}^2 = \frac{1}{L-1} \sum_{i=1}^L (d_i(t) - E[d_i(t)])^2 \quad (21)$$

O valor de  $E[\tilde{n}_i]$  é obtido através da correlação entre o espalhamento de atraso e o atraso de excesso médio [9] e o valor  $E[n_i^2]$  é obtido através de (11):

Os valores encontrados são aplicados no equacionamento proposto incluindo a dependência das variáveis  $x$ ,  $y$  e  $d$ , e após a determinação da posição do móvel através da equação (20) utiliza-se novamente a filtragem de Kalman para rastrear o terminal móvel, diminuindo-se, com isto, a variância final do erro de localização

#### • Equacionamento

As seguintes equações (22-29) são adaptadas de [11]. O vetor de dados de estados satisfaz (22)

$$\mathbf{x}_{k+1} = \Phi \mathbf{x}_k + \Gamma \mathbf{w}_k \quad (22)$$

onde  $\mathbf{x}_k = \begin{bmatrix} x_k & \dot{x}_k \end{bmatrix}$  é o vetor de estados no instante  $t_k$ ,

$\dot{x}_k$  indica a primeira derivada de  $x_k$ ,  $\mathbf{w}_k$  é o vetor de ruído com matriz de covariância  $\mathbf{Q} = \sigma_w^2 \mathbf{I}$

$$\Phi = \begin{bmatrix} \mathbf{I} & \Delta \mathbf{I} \\ 0 & \mathbf{I} \end{bmatrix}, \quad \Gamma = \begin{bmatrix} 0 \\ \Delta \mathbf{I} \end{bmatrix} \quad (23)$$

O processo de medida é descrito por:

$$\mathbf{y}_k = \mathbf{H} \mathbf{x}_k + \mathbf{v}_k \quad (24)$$

onde  $\mathbf{y}_k$  é o vetor de dados medidos,  $\mathbf{H} = [\mathbf{I} \quad 0]$  e  $\mathbf{v}_k$  possui matriz de covariância  $\mathbf{R} = \sigma_v^2 \mathbf{I}$ .

As equações (25-29) apresentam a operação iterativa do filtro

$$\mathbf{x}_{k+1,k} = \Phi \mathbf{x}_{k,k} \quad (25)$$

$$\mathbf{P}_{k+1,k} = \Phi \mathbf{P}_{k,k} \Phi^T + \Gamma \mathbf{Q} \Gamma^T \quad (26)$$

$$\mathbf{K} = \mathbf{P}_{k+1,k} \mathbf{H}^T (\mathbf{H} \mathbf{P}_{k+1,k} \mathbf{H}^T + \mathbf{R})^{-1} \quad (27)$$

$$\mathbf{P}_{k+1,k+1} = (\mathbf{I} - \mathbf{K} \mathbf{H}) \mathbf{P}_{k+1,k} \quad (28)$$

$$\mathbf{x}_{k+1,k+1} = \mathbf{x}_{k+1,k} + \mathbf{K} (\mathbf{y}_{k+1} - \mathbf{H} \Phi \mathbf{x}_{k,k}) \quad (29)$$

onde  $\mathbf{K}$  representa o ganho de Kalman e  $\mathbf{P}_{k,k}$  é a matriz de covariância de  $\mathbf{x}_{k,k}$ .

Portanto, no caso da estimativa da distância, o vetor de estados

é dado por  $\mathbf{x}_k = \begin{bmatrix} d_k(t) & \dot{d}_k(t) \end{bmatrix}^T$  onde  $d_k(t)$  representa a

distância em função do tempo e  $\dot{d}_k(t)$  a velocidade radial.

No caso da estimativa final o vetor de estados é dado por  $\mathbf{x}_k = [x_k \quad y_k \quad v_{xk} \quad v_{yk}]^T$ , onde  $(x_k, y_k)$  representa a

coordenada do móvel e  $(v_{xk}, v_{yk})$  as velocidades do móvel nas direções  $x$  e  $y$  respectivamente.

### III. RESULTADOS DE SIMULAÇÃO E COMPARAÇÃO

Neste item serão apresentadas as simulações realizadas com os algoritmos propostos e seus resultados, comparando-os com os principais algoritmos conhecidos.

1. Num primeiro cenário, 1000 posições do móvel são sorteadas aleatoriamente e para cada posição somam-se o ruído de medida e o ruído de não visada direta (Rayleigh e com distribuição constante) e são extraídas as distâncias médias. É aplicado o algoritmo proposto conforme item II.

2. Num segundo cenário o móvel percorre uma trajetória definida e para cada posição desta trajetória somam-se o ruído de medida e o ruído de não-visada direta (Rayleigh). As distâncias médias são estimadas pelo filtro de Kalman. É aplicado o algoritmo proposto e após obtida a posição, é aplicado a filtragem de Kalman novamente para melhorar esta estimativa (item II.1).

1. **Primeiro cenário** - As simulações foram realizadas admitindo-se a existência de 4 receptores ( $M=4$ ), os quais estão localizados um longe do outro. Suas posições são:

$(x_1=0$  km,  $y_1=0$  km),  $(x_2=-5$  km,  $y_2=8$  km),  $(x_3=4$  km,  $y_3=6$  km),  $(x_4=-2$  km,  $y_4=4$  km) e a fonte move-se aleatoriamente num espaço quadrado entre  $-5\text{km} \leq x_0, y_0 \leq 5$  km, com os valores dados pela seguinte expressão:

$$\begin{aligned} x_0 &= 5 \cdot (1 - 2 \cdot \text{rand}(1)) \text{ km} \\ y_0 &= 5 \cdot (1 - 2 \cdot \text{rand}(1)) \text{ km} \end{aligned} \quad (30)$$

onde  $\text{rand}(1)$  gera um número aleatório de zero até um com distribuição uniforme.

Utilizamos a distribuição gaussiana para simular o ruído de medida e a distribuição Rayleigh ou distribuição Uniforme para simular o erro de não visada direta (NLoS). Portanto, as distâncias medidas são obtidas através das seguintes expressões:

$$d_i = d_i^0 + \sigma_{LOS} \cdot \text{randn}(1) + \text{rayleigh}(\sigma_{Rayl}) \quad (31)$$

$$d_i = d_i^0 + \sigma_{LOS} \cdot \text{randn}(1) + N_{Unif} \cdot \text{rand}(1), \quad (32)$$

onde  $d_i^0$  é a distância exata da estação móvel até  $i$ -ésima estação base,  $\sigma_{LOS}$  representa o desvio padrão do erro de medida gaussiano,  $N_{Unif}$  é o erro máximo numa distribuição de erro uniforme,  $\sigma_{Rayl}$  é o desvio-padrão numa distribuição Rayleigh, ambos, devido a propagação NLoS. As funções  $\text{randn}(\cdot)$  /  $\text{rayleigh}(\cdot)$  geram as distribuições gaussianas e de Rayleigh respectivamente. Utilizamos as distribuições Rayleigh e Uniforme pois, para estas distribuições, as relações entre média e desvio-padrão são fixas e conhecidas:

$$\mu_{Rayl} = \sqrt{\pi/2} \sigma_{Rayl} \quad (33)$$

$$\mu_{Unif} = \sqrt{3} \sigma_{Unif} \quad (34)$$

Estimamos o erro de localização médio tomando-se uma média de 1000 posições aleatoriamente escolhidas  $(x, y)$ . Para cada posição, estimamos uma distância média  $E[d_i]$ , e a sua variância dada por  $\sigma_{n_i}^2 = E[d_i^2] - E[d_i]^2$  tomando-se a média

de  $L$  medidas de distâncias independentes  $(d_i)$ . O erro médio

$$E[n_i] \text{ é obtido das relações dadas por (33) e (34) e } E\left[\frac{\sim}{n_i^2}\right] \text{ é}$$

obtido através de (11).

Nós avaliamos o desempenho do algoritmo proposto comparando-o ao algoritmo de Wang [8] e ao algoritmo de Chan [7] com uma correção para não-visada direta (NLOS). No algoritmo de Wang, para cada posição  $(x, y)$  obtemos  $L$  estimativas  $(x_n, y_n)$  e tomamos a média delas para se obter a estimativa final, isto é:

$$\bar{x} = \frac{1}{L} \sum_{n=1}^L x_n \quad \text{e} \quad \bar{y} = \frac{1}{L} \sum_{n=1}^L y_n \quad (35)$$

Uma correção para distância sem visada direta é aplicada ao método de Chan, como proposto Y. Jeong [9]. Esta correção é dada por:

$$d_{i,1} \text{ corrigido} = (d_i - E[n_i]) - (d_1 - E[n_1]) \quad (36)$$

onde  $d_{i,1} = d_i - d_1$  representa a diferença de distância medidas entre os receptores  $i$  e um. Utilizou-se esta correção para compensar o erro de visada direta (NLoS) antes de se aplicar a equação de estimação de localização de Chan [7].

O erro de localização médio (ELM) é dado por:

$$ELM = E\left[\sqrt{(\hat{x} - x_0)^2 + (\hat{y} - y_0)^2}\right] \quad (37)$$

onde  $(x_0, y_0)$  é a posição exata e  $(\hat{x}, \hat{y})$  é a posição estimada.

e este valor é calculado tomando-se a média de 1000 simulações independentes (posições diferentes), com  $L=30$  amostras cada (exceto item 4, detalhado a seguir).

Nas simulações, quatro situações são analisadas:

- 1) A probabilidade do erro de localização é calculada para o erro NLoS de distribuição Rayleigh, para os três métodos. Para cada localização e cada estação base (com  $L$  amostras cada) um valor diferente de  $\sigma_{Rail}$  é usado, aleatoriamente distribuído entre 0 e 300 m, para gerar os dados. O ruído de medida foi gerado como uma variável gaussiana com  $\sigma_{LOS} = 10$  m (Fig. 3).
- 2) O erro de localização médio (ELM) é calculado para todos os métodos como uma função do desvio padrão do erro sem-visada direta (NLoS) (para ambos, erro de distribuição uniforme e Rayleigh), com a variância do ruído de medida fixo (Figs. 4, 5).
- 3) O erro de localização médio é calculado para todos os métodos como uma função do desvio-padrão do erro de medida,  $\sigma_{LOS}$ , com um erro de não-visada direta (NLoS) como uma distribuição uniforme entre 0 e 300 m (Fig. 6).
- 4) O erro de localização médio é calculado para todos os métodos como uma função do número de amostras,  $L$ , tomadas para cada posição. O ruído de medida foi gerado como uma variável gaussiana com  $\sigma_{LOS} = 10$  m e o erro de não visada direta (NLoS) como uma distribuição uniforme entre 0 e 300 m (Fig. 7).

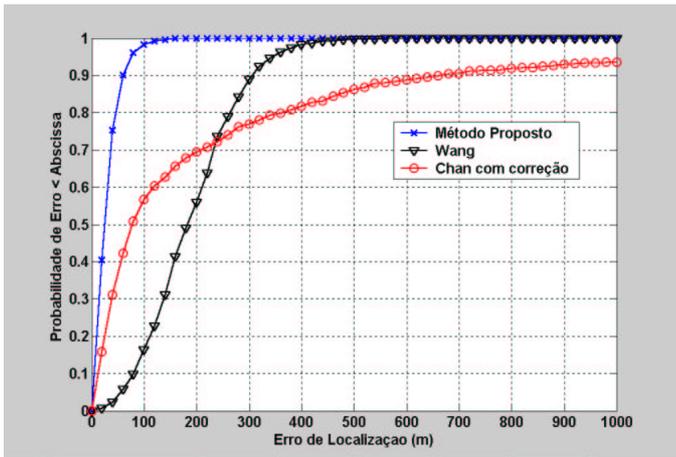


Fig. 3 – Probabilidade do Erro de localização médio para erro NLOS Rayleigh ( $\sigma_{Rayl}$  sorteado entre 0-300 m), com  $L=30$ ,  $M=4$  e ruído de medida gaussiano  $\sigma_{LOS} = 10$  m .

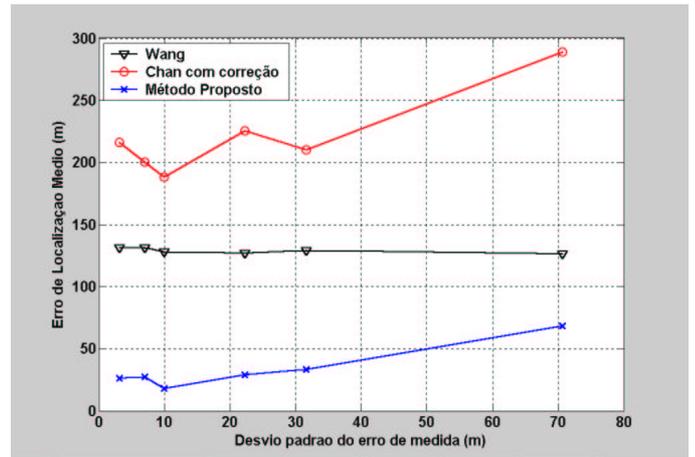


Fig. 6 – Erro de localização médio como uma função do desvio-padrão do erro de medida,  $\sigma_{LOS}$ , com erro NLOS com distribuição uniforme (0-300 m) e  $M=4$ .

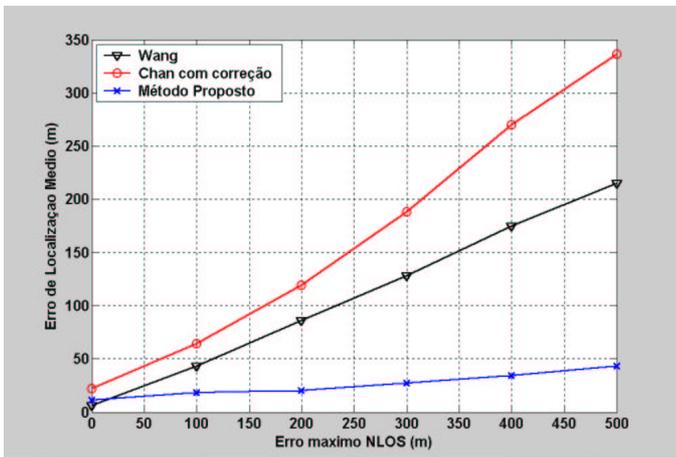


Fig. 4 – Erro de localização médio como uma função do erro máximo NLOS (distribuição uniforme), com ruído de medida gaussiano,  $\sigma_{LOS} = 10$  m , e  $M=4$ .

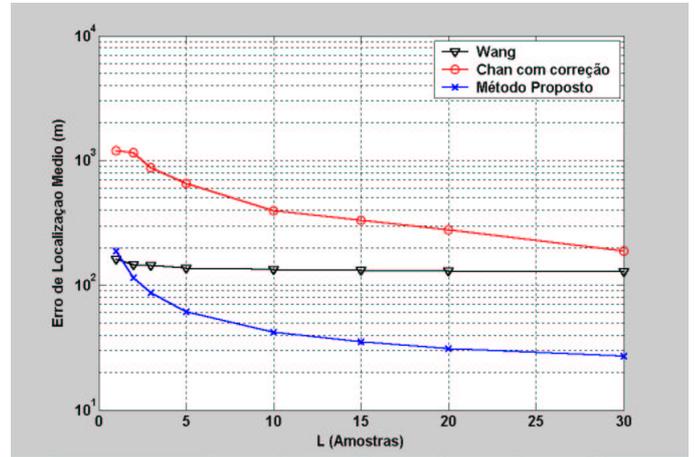


Fig. 7 – Erro de localização médio como uma função do número de amostras,  $L$ , para ruído de medida gaussiano,  $\sigma_{LOS} = 10$  m , erro NLOS de distribuição uniforme (0-300) e  $M=4$ .

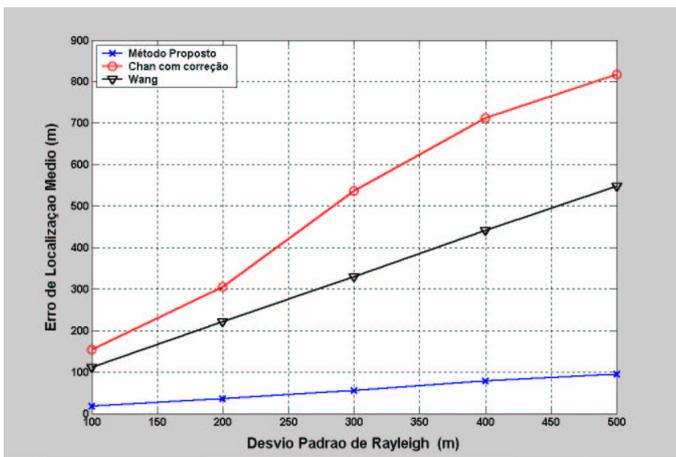


Fig. 5 – Erro de localização médio como uma função de  $\sigma_{Rayl}$  (Erro NLOS Rayleigh), com ruído de medida gaussiano,  $\sigma_{LOS} = 10$  m , e  $M=4$ .

Nós podemos verificar dessas figuras que o desempenho global do novo método é muito melhor que os métodos de Wang e Chan, para  $L \geq 2$ . Podemos ver também que quando aumentamos o ruído de medida o novo algoritmo não apresenta qualquer degradação perceptível na estimativa de localização.

2. **Segundo Cenário** – As simulações foram realizadas considerando-se duas situações:

Na primeira situação admitimos também a existência de 4 receptores ( $M=4$ ), os quais estão localizados um longe do outro. Suas posições são as mesmas do primeiro cenário.

E a fonte move-se segundo uma trajetória retilínea a partir de uma posição inicial sorteada dada por:

$$x_0 = 5000 \cdot (1 - 2 \cdot rand(1)) \text{ m}$$

$$y_0 = 5000 \cdot (1 - 2 \cdot rand(1)) \text{ m} \quad (38)$$

As velocidades nas direções  $x$  e  $y$  também são sorteadas para cada trajetória e é dada por:

$$v_x = 15 \cdot (1 - 2 \cdot rand(1)) \text{ m/s}$$

$$v_y = 15 \cdot (1 - 2 \cdot rand(1)) \text{ m/s} \quad (39)$$

Utilizamos a distribuição gaussiana para simular o ruído de medida e a distribuição Rayleigh para simular o erro de não

visada direta (NLoS). Portanto, a distância medida entre o móvel e a  $i$ -ésima estação base num tempo  $t$  é obtida através da seguinte expressão:

$$d_i(t) = d_i^0(t) + \sigma_{LOS} \cdot randn(1) + rayleigh(\sigma_{Rayl}) \quad (40)$$

onde  $d_i^0(t)$  é a distância exata no tempo  $t$  da estação móvel até  $i$ -ésima estação base. Utilizamos a distribuição Rayleigh pois, conforme visto pela expressão (33), a relação entre média e desvio-padrão é fixa e conhecida.

Para cada trajetória são sorteados os valores de  $\sigma_{Rail}$  (uniformemente distribuído entre 0 a 300m) para cada distância  $d_i$  e após o sorteio este se mantém fixo até o fim da trajetória.

Para cada posição medida do móvel, num passo de 0,1s, estimamos uma distância média  $E[d_i(t)]$  através do filtro de Kalman e a sua variância dada por (21) através de  $L$  medidas. O erro médio  $E[n_i]$  é obtida da relação dada por (33).

Nós avaliamos o desempenho do algoritmo proposto comparando-o ao algoritmo de Wang [8] e ao algoritmo de Chan [7] com uma correção para não-visada direta (NLOS). No algoritmo de Wang, para cada posição  $(x, y)$  obtemos  $L$  estimativas  $(x_n, y_n)$  e tomamos a média delas para se obter a estimativa final através da equação (35).

Uma correção para distância sem visada direta é aplicada ao método de Chan, como proposto Y. Jeong [9], de acordo com a equação (36).

Para os três algoritmos, após a obtenção das estimativas  $x$  e  $y$  da unidade móvel, é aplicado novamente a filtragem de Kalman para se diminuir a variância do erro de estimação final.

O erro de localização médio (ELM) é dado por (37) e ele é estimado neste trabalho tomando-se a média de 100 trajetórias independentes com 2000 pontos cada (Figura8).

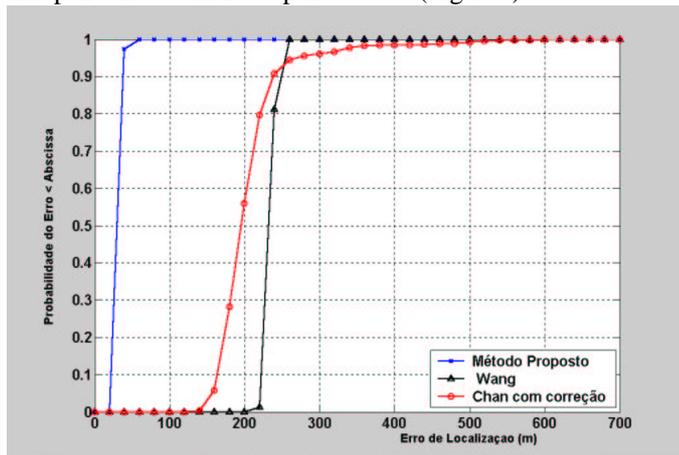


Fig. 8 – Probabilidade do Erro de localização médio para 100 trajetórias retilíneas com erro NLOS Rayleigh (com  $\sigma_{Rail}$  sorteado entre 0-300 m) e fixo para cada trajetória, com  $L=30$ ,  $M=4$  e ruído de medida gaussiano  $\sigma_{LOS} = 10$  m.

Numa segunda situação para cada trajetória são sorteados os valores de  $\sigma_{Rail}$  (uniformemente distribuído entre 0 a 300m) para cada distância  $d_i$ , só que desta vez o valor deste sorteio é feito a cada  $P$  pontos da trajetória, ou seja, o móvel pode

passar de uma situação de visada-direta para não visada-direta com relação à  $i$ -ésima base dependendo deste sorteio (Fig. 9).

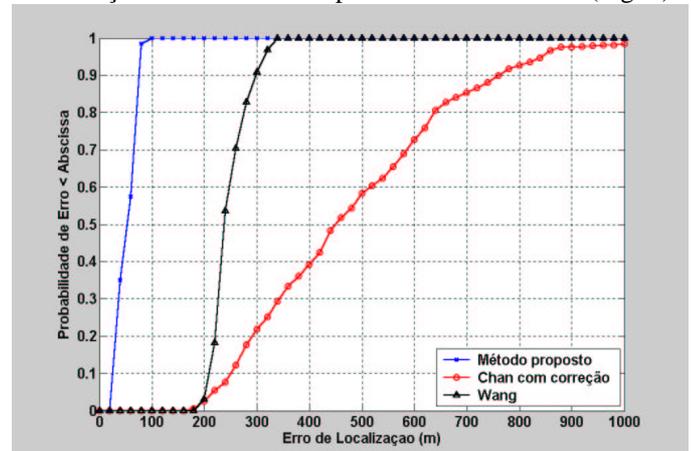


Fig. 9 – Probabilidade do Erro de localização médio para 100 trajetórias retilíneas com erro NLOS Rayleigh (com  $\sigma_{Rail}$  sorteado entre 0-300 m a cada  $P=200$  pontos) para cada trajetória, com  $L=30$ ,  $M=4$  e ruído de medida gaussiano  $\sigma_{LOS} = 10$  m.

#### IV. CONCLUSÃO

É proposto um novo método de localização, o qual explora a relação entre o espalhamento de atraso e o atraso médio excessivo na presença de erros NLoS. O algoritmo proposto é simples e tem maior precisão que o algoritmo de visada direta (LoS) com correção de distância, proposto por Jeong [9] e do que o algoritmo NLoS proposto por Wang [8], o qual usa programação matemática para encontrar a estimativa de máxima verossimilhança da posição de fonte num domínio restrito. Para melhorar a precisão de estimação com o terminal móvel em movimento é utilizada a filtragem de Kalman.

#### V. REFERÊNCIAS

- [1] FCC, *Enhanced Wireless 911 Services 1999*, [http://www.fcc.gov/Bureau/Wireless/News\\_Releases/1999/arv19040.html](http://www.fcc.gov/Bureau/Wireless/News_Releases/1999/arv19040.html).
- [2] G. Carter, "Time delay estimation for passive sonar signal processing," IEEE Trans. Acoustic., Speech, Signal Processing, vol. ASSP-29, no. 6, pp.463-470, 1981.
- [3] W. Hahn, "Optimum processing for passive sonar range and bearing estimation," J. Acoustic. Soc. Amer., vol.58, no. 7, pp.201-207, 1975.
- [4] W. Hahn and S. Tretter, "Optimum processing for delay-vector estimation in passive signal arrays," IEEE Trans. Inform. Theory, vol. IT 19, no. 5, pp. 608-614, 1973.
- [5] M.J. Silventoinen, T. Rantalainen, "Mobile Station Emergency Locating in GSM", IEEE International Conference on Personal Wireless Communications, India, February 1996
- [6] James L. Caffery and Gordon L. Stuber, "Radio Location in Urban CDMA Microcells", Proceedings of the Personal, Indoor and Mobile Radio Communications (PIMRC '95), vol.2, pp 858-862.
- [7] Y.Chan and K. Ho, "A Simple and Efficient Estimator for Hyperbolic Location" IEEE Trans. Signal Processing, vol.42, no.8, pp.1905-1915, August 1994.
- [8] X. Wang, Z. Wang and B. O'Dea, "A TOA- Based Location Algorithm Reducing the Errors due to Non-Line-of-Sight (NLOS) Propagation" IEEE Trans. on Vehicular Technology, vol.52, no.1, pp. 112-116, January 2003.
- [9] Y. Jeong, H. You and C. Lee, "Calibration of NLOS Error for Positioning Systems", VTC 2001, pp. 2605- 2608
- [10] S.Forcellini, L.C. Trintinália, "Location estimation using Relationship between Delay Spread and Mean Excess Delay", IEEE ICNSC 2005, pp. 638-643.
- [11] J. M. Mendel, "Lessons in Digital Estimation Theory", Englewood Cliffs, N. J: Prentice-Hall, 1987