

# LOCALIZAÇÃO DE UM ROBÔ MÓVEL BASEADA EM ODOMETRIA E MARCOS NATURAIS UTILIZANDO FILTRO DE KALMAN ESTENDIDO

ANDRÉ M. SANTANA\* , ADELARDO A.D. MEDEIROS\*

\**Departamento de Engenharia de Computação e Automação - DCA  
Universidade Federal do Rio Grande do Norte - UFRN  
Natal, RN, Brasil*

Email: [andremacedo,adelardo]@dca.ufrn.br

**Abstract**— This work proposes a localization system for mobile robots using the Extended Kalman Filter. The robot navigates in an known environment where the lines of the floor are used as natural landmarks and identified by using the Hough transform. The prediction phase of the Kalman filter is implemented using the odometry model of the robot. The update phase directly uses the parameters of the lines detected by the Hough algorithm to correct the robot's pose.

**Keywords**— Robot Localization , Kalman Filter, Sensor Fusion.

**Resumo**— Este trabalho propõe um sistema de localização para robôs móveis com acionamento diferencial utilizando Filtro de Kalman Estendido. O sistema em questão considera que o robô navega em um ambiente conhecido onde as arestas do piso podem ser identificadas como marcos naturais utilizando a transformada de Hough. A fase de predição do filtro é implementada usando o modelo de odometria do robô e a fase de atualização usa os parâmetros das linhas detectadas por Hough diretamente nas suas equações para corrigir a pose do robô.

**Keywords**— Localização de Robôs, Filtro de Kalman, Fusão Sensorial.

## 1 Introdução

Borenstein et al. (1997) classificam os métodos de localização em duas grandes categorias: métodos de localização relativa, que dão a pose do robô em relação a uma pose inicial e métodos de localização absoluta, que dão a pose global do robô e não necessitam das posições calculadas anteriormente.

No caso de robôs com rodas é comum o uso de *encoders* acoplado aos eixos de rotação das rodas, na técnica denominada odometria (Borenstein et al., 1997). Entretanto, a idéia básica da odometria é a integração da informação da movimentação em um dado período de tempo, o que leva ao acúmulo de erros (Park et al., 1998).

As técnicas de localização absoluta utilizam marcos para localizar o robô. Estes marcos podem ser artificiais, quando introduzidos no ambiente com a finalidade de auxiliar na localização do robô, ou naturais, quando já se encontram no ambiente. É importante ressaltar que mesmo as técnicas de localização absolutas são imprecisas devido aos ruídos oriundos dos sensores utilizados.

A literatura mostra trabalhos utilizando medidas de distância a marcos naturais (paredes por exemplo) para localizar o robô. A obtenção destas medidas geralmente é feita utilizando sonar, laser e visão computacional (Lizzaralde et al., 2003; Kim and Kim, 2004; Péres et al., 1999).

Bezerra (2004) utilizou no seu trabalho as retas do piso que compõem o ambiente como marcos naturais. Kiriy and Buehler (2002) utilizaram filtro de Kalman estendido para seguir diversos marcos artificiais dispostos de forma não estruturada. Launay et al. (2002) usaram as lâmpadas do teto de um corredor para localizar o robô.

O presente artigo propõe um sistema capaz de localizar um robô móvel em um ambiente onde as linhas do chão formam uma grade bidimensional. Para tal, as linhas são identificadas como marcos naturais e suas características, juntamente com o modelo de odometria do robô, são incorporados em um filtro de Kalman a fim de obter sua pose.

Além desta seção, este documento possui outras quatro. A Seção 2 descreve a teoria básica necessária para entender o funcionamento do filtro de Kalman. A Seção 3 que trata da modelagem do problema. Os resultados encontrados são ilustrados na Seção 4 e, por fim, a Seção 5 traz as conclusões e as perspectivas deste trabalho.

## 2 Filtro de Kalman

A modelagem do Filtro de Kalman Discreto - FKD pressupõe que o sistema seja linear e descrito pelo modelo de equações do sistema (1):

$$\begin{cases} \mathbf{s}_t = \mathbf{A}_t \mathbf{s}_{t-1} + \mathbf{B}_t \mathbf{u}_{t-1} + \gamma_t \\ \mathbf{z}_t = \mathbf{C}_t \mathbf{s}_t + \delta_t \end{cases} \quad (1)$$

onde  $\mathbf{s} \in R^n$  é o vetor de estados;  $\mathbf{u} \in R^l$  é o vetor das entradas de controle;  $\mathbf{z} \in R^m$  é o vetor de medições; a matriz  $n \times n$ ,  $\mathbf{A}$ , é a matriz de transição de estados;  $\mathbf{B}$ ,  $n \times l$ , é a matriz de coeficientes de entrada; a matriz  $\mathbf{C}$ ,  $m \times n$ , é a matriz de observação;  $\gamma \in R^n$  representa o vetor de ruídos do processo e  $\delta \in R^m$  o vetor de erros de medição. Os índices  $t$  e  $t - 1$  representam os instantes de tempo atual e anterior respectivamente.

O filtro opera em modo de predição-atualização levando em consideração as propriedades estatísticas do ruído. Um modelo interno do sistema

é usado para atualização e um esquema de realimentação realiza as medições.

As etapas de predição e atualização para o FGD podem ser descritas pelos sistemas (2) e (3) respectivamente.

$$\begin{cases} \bar{\mu}_t = \mathbf{A}_t \mu_{t-1} + \mathbf{B}_t \mathbf{u}_{t-1} \\ \bar{\Sigma}_t = \mathbf{A}_t \Sigma_{t-1} \mathbf{A}_t^T + \mathbf{R}_t \end{cases} \quad (2)$$

$$\begin{cases} \mathbf{K}_t = \bar{\Sigma}_t \mathbf{C}_t^T (\mathbf{C}_t \bar{\Sigma}_t \mathbf{C}_t^T + \mathbf{Q}_t)^{-1} \\ \mu_t = \bar{\mu}_t + \mathbf{K}_t (\mathbf{z}_t - \mathbf{C}_t \bar{\mu}_t) \\ \Sigma_t = (\mathbf{I} - \mathbf{K}_t \mathbf{C}_t) \bar{\Sigma}_t \end{cases} \quad (3)$$

O filtro de Kalman representa o vetor de estados  $\mathbf{s}_t$  no tempo  $t$  por sua média  $\mu_t$  e covariância  $\Sigma_t$ . As matrizes  $\mathbf{R}$ ,  $n \times n$ , e  $\mathbf{Q}$ ,  $l \times l$ , são as matrizes de covariância dos ruídos de processo ( $\gamma$ ) e medição ( $\delta$ ) respectivamente e a matriz  $\mathbf{K}$ ,  $n \times m$ , representa o ganho do sistema.

Uma derivação do filtro de Kalman aplicado a sistemas não-lineares é o: Filtro de Kalman Estendido - FKE.

A idéia do FKE é linearizar as funções em torno da estimação corrente usando as derivadas parciais do processo e das funções de medição para calcular as estimações, mesmo em face a relações não-lineares.

O modelo do sistema para o FKE é dado pelo sistema (4):

$$\begin{cases} \mathbf{s}_t = g(\mathbf{u}_{t-1}, \mathbf{s}_{t-1}) + \gamma_t \\ \mathbf{z}_t = h(\mathbf{s}_t) + \delta_t \end{cases} \quad (4)$$

onde  $g(\mathbf{u}_{t-1}, \mathbf{s}_{t-1})$  é uma função não-linear que representa o modelo do sistema, e  $h(\mathbf{s}_t)$  é uma função não-linear que representa o modelo das medições.

Suas etapas de predição e atualização podem ser obtidas pelos sistemas de equações (5) e (6) respectivamente.

$$\begin{cases} \bar{\mu}_t = g(\mathbf{u}_{t-1}, \mu_{t-1}) \\ \bar{\Sigma}_t = \mathbf{G}_t \Sigma_{t-1} \mathbf{G}_t^T + \mathbf{R}_t \end{cases} \quad (5)$$

$$\begin{cases} \mathbf{K}_t = \bar{\Sigma}_t \mathbf{H}_t^T (\mathbf{H}_t \bar{\Sigma}_t \mathbf{H}_t^T + \mathbf{Q}_t)^{-1} \\ \mu_t = \bar{\mu}_t + \mathbf{K}_t (\mathbf{z}_t - h(\bar{\mu}_t)) \\ \Sigma_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \bar{\Sigma}_t \end{cases} \quad (6)$$

A matriz  $\mathbf{G}$ ,  $n \times n$ , é o jacobiano que lineariza o modelo, e  $\mathbf{H}$ ,  $l \times n$ , o jacobiano que lineariza o vetor de medições. Tais matrizes são definidas pelas equações (7) e (8).

$$\mathbf{G}_t = \frac{\partial g(\mathbf{u}_{t-1}, \mathbf{s}_{t-1})}{\partial \mathbf{s}_{t-1}} \quad (7)$$

$$\mathbf{H}_t = \frac{\partial h(\mathbf{s}_t)}{\partial \mathbf{s}_t} \quad (8)$$

A seguir será descrita a modelagem do problema bem como definidas as matrizes que serão utilizadas no filtro de Kalman.

### 3 Modelagem

#### 3.1 Fase de Predição: Modelo de Odometria do Movimento do Robô

Um método clássico utilizado para calcular a pose de um robô é a odometria. Este método utiliza sensores, *encoders* óticos por exemplo, que medem as rotações das rodas do robô. Usando o modelo cinemático do robô sua pose é calculada através da integração dos seus movimentos a partir de um referencial fixo.

Como os *encoders* são sensores, normalmente suas leituras seriam utilizadas na fase de atualização do filtro de Kalman, e não na fase de predição. Thrun et al. (2005) propõem que as informações odométricas não funcionem como medidas sensoriais, mas sim, que elas sejam incorporadas ao modelo do robô.

Para que esta proposta seja utilizada, deve-se utilizar um modelo cinemático do robô, considerando os deslocamentos angulares das rodas como sinais de entrada do sistema na fase de predição do filtro de Kalman.

Considere um robô com acionamento diferencial em que os sinais de controle aplicados a seus atuadores não sejam tensão mas sim, deslocamentos angulares, conforme a Figura 1.




Figura 1: Variáveis do modelo geométrico.

Com esta idéia, e supondo que as velocidades são constantes no período de amostragem, pode-se determinar o modelo geométrico do movimento do robô (sistema 9).

$$\begin{cases} x_t = x_{t-1} + \frac{\Delta L}{\Delta \theta} [\sin(\theta_{t-1} + \Delta \theta) - \sin(\theta_{t-1})] \\ y_t = y_{t-1} - \frac{\Delta L}{\Delta \theta} [\cos(\theta_{t-1} + \Delta \theta) - \cos(\theta_{t-1})] \\ \theta_t = \theta_{t-1} + \Delta \theta \end{cases} \quad (9)$$

Para facilitar a legibilidade do sistema (9), que representa o modelo de odometria do robô, foram utilizadas duas variáveis auxiliares  $\Delta L$  e  $\Delta\theta$

$$\begin{cases} \Delta L = (\Delta\theta_d r_d + \Delta\theta_e r_e)/2 \\ \Delta\theta = (\Delta\theta_d r_d - \Delta\theta_e r_e)/b \end{cases} \quad (10)$$

onde  $\Delta\theta_d$  é a leitura do *encoder* direito e funciona para o robô como o deslocamento angular aplicado à roda direita;  $\Delta\theta_e$  é a leitura do *encoder* esquerdo e funciona como o deslocamento aplicado à roda esquerda;  $b$  representa a distância de roda a roda do robô, e  $r_d$  e  $r_e$  são os raios de suas rodas direita e esquerda respectivamente.

É importante ressaltar que em aplicações reais o deslocamento angular efetivamente realizado pela roda difere do medido pelo *encoder*. Além disso, a suposição de que as velocidades são constantes no período de amostragem, que foi utilizada para obter o modelo 9, nem sempre é verdade. Daí, existem diferenças entre os deslocamentos angulares “reais” das rodas ( $\Delta\hat{\theta}_d$  e  $\Delta\hat{\theta}_e$ ) e os medidos pelos *encoders* ( $\Delta\theta_d$  e  $\Delta\theta_e$ ). Esta diferença será modelada por um ruído gaussiano aditivo, conforme o sistema (11).

$$\begin{cases} \Delta\hat{\theta}_d = \Delta\theta_d + \varepsilon_d \\ \Delta\hat{\theta}_e = \Delta\theta_e + \varepsilon_e \end{cases} \quad (11)$$

Sabe-se que a odometria possui erro acumulativo. Portanto, os ruídos  $\varepsilon_d$  e  $\varepsilon_e$  não possuem variância constante. Assume-se que estes ruídos têm desvio padrão proporcional ao módulo do deslocamento medido.

Com essas novas considerações o sistema (9) passa a ser representado pelo sistema (12):

$$\begin{cases} x_t = x_{t-1} + \\ \quad \frac{\Delta\hat{L}}{\Delta\hat{\theta}} [\sin(\theta_{t-1} + \Delta\hat{\theta}) - \sin(\theta_{t-1})] \\ y_t = y_{t-1} - \\ \quad \frac{\Delta\hat{L}}{\Delta\hat{\theta}} [\cos(\theta_{t-1} + \Delta\hat{\theta}) - \cos(\theta_{t-1})] \\ \theta_t = \theta_{t-1} + \Delta\hat{\theta} \end{cases} \quad (12)$$

onde

$$\begin{cases} \Delta\hat{L} = (\Delta\hat{\theta}_d r_d + \Delta\hat{\theta}_e r_e)/2 \\ \Delta\hat{\theta} = (\Delta\hat{\theta}_d r_d - \Delta\hat{\theta}_e r_e)/b \end{cases} \quad (13)$$

Observa-se que este modelo não pode ser utilizado quando  $\Delta\hat{\theta} = 0$ . Ocorrendo isto, utiliza-se um modelo odométrico mais simples do robô (sistema 14), obtido a partir do limite do sistema 12 quando  $\Delta\hat{\theta} \rightarrow 0$ .

$$\begin{cases} x_t = x_{t-1} + \Delta\hat{L} \cos(\theta_{t-1}) \\ y_t = y_{t-1} + \Delta\hat{L} \sin(\theta_{t-1}) \\ \theta_t = \theta_{t-1} \end{cases} \quad (14)$$

Utilizar a idéia de Thrun implica uma diferença em relação ao sistema (4), pois o ruído não é aditivo e sim incorporado à função que descreve o modelo, como mostra o sistema (15):

$$\begin{cases} \mathbf{s}_t = p(\mathbf{u}_{t-1}, \mathbf{s}_{t-1}, \varepsilon_t) \\ \mathbf{z}_t = h(\mathbf{s}_t) + \delta_t \end{cases} \quad (15)$$

onde  $\varepsilon_t = [\varepsilon_d \ \varepsilon_e]^T$  é o vetor de ruído associado à odometria.

É necessário, portanto, fazer uma modificação na fase de predição do sistema (6) resultado nas equações do sistema (16):

$$\begin{cases} \bar{\mu}_t = \mu_{t-1} + p(\mathbf{u}_{t-1}, \mu_{t-1}, 0) \\ \bar{\Sigma}_t = \mathbf{G}_t \Sigma_{t-1} \mathbf{G}_t^T + \mathbf{V}_t \mathbf{M}_t \mathbf{V}_t^T \end{cases} \quad (16)$$

onde a matriz  $\mathbf{M}$ ,  $l \times l$ , é a matriz de covariância dos ruídos dos sensores ( $\varepsilon$ ) e  $\mathbf{V}$ ,  $n \times m$ , é o jacobiano que mapeia o ruído dos sensores para o espaço de estado. A matriz  $\mathbf{V}$  é definida pela equação (17).

$$\mathbf{V}_t = \frac{\partial p(\mathbf{u}_{t-1}, \mathbf{s}_{t-1}, 0)}{\partial \mathbf{u}_{t-1}} \quad (17)$$

Utilizando o modelo de odometria do robô descrito nesta seção e as definições das matrizes utilizadas pelo filtro de Kalman, tem-se:

$$\mathbf{G} = \begin{pmatrix} 1 & 0 & g_{13} \\ 0 & 1 & g_{23} \\ 0 & 0 & 1 \end{pmatrix}, \quad \text{onde} \quad (18)$$

$$(19)$$

$$g_{13} = \frac{\Delta\hat{L}}{\Delta\hat{\theta}} [\cos(\theta_{t-1} + \Delta\hat{\theta}) - \cos(\theta_{t-1})]$$

$$g_{23} = \frac{\Delta\hat{L}}{\Delta\hat{\theta}} [\sin(\theta_{t-1} + \Delta\hat{\theta}) - \sin(\theta_{t-1})]$$

$$\mathbf{V} = \begin{pmatrix} v_{11} & v_{12} \\ v_{21} & v_{22} \\ r_d/b & -r_e/b \end{pmatrix}, \quad \text{onde} \quad (20)$$

$$(21)$$

$$v_{11} = k1 \cos(k2) - k3[\sin(k2) - \sin(\theta_{t-1})]$$

$$v_{12} = -k1 \cos(k2) + k3[\sin(k2) - \sin(\theta_{t-1})]$$

$$v_{21} = k1 \sin(k2) - k3[-\cos(k2) + \cos(\theta_{t-1})]$$

$$v_{22} = -k1 \sin(k2) + k3[-\cos(k2) + \cos(\theta_{t-1})]$$

$$\mathbf{M} = \begin{pmatrix} (\alpha_1 |\Delta\hat{\theta}_d|)^2 & 0 \\ 0 & (\alpha_2 |\Delta\hat{\theta}_e|)^2 \end{pmatrix} \quad (22)$$

Os elementos  $m_{11}$  e  $m_{22}$  na equação (22) representam o fato dos desvios padrões de  $\varepsilon_d$  e  $\varepsilon_e$  serem proporcionais ao módulo do deslocamento angular. As variáveis  $k1$ ,  $k2$  e  $k3$  são dadas pelo

sistema (23), considerando  $r_d = r_e = r$ .

$$\begin{cases} k1 = \frac{r(\Delta\hat{\theta}_d + \Delta\hat{\theta}_e)}{b(\Delta\hat{\theta}_d - \Delta\hat{\theta}_e)} \\ k2 = \theta_{t-1} + \frac{r(\Delta\hat{\theta}_d - \Delta\hat{\theta}_e)}{b} \\ k3 = \frac{b\Delta\hat{\theta}_e}{2(r(\Delta\hat{\theta}_d - \Delta\hat{\theta}_e)/b)^2} \end{cases} \quad (23)$$

### 3.2 Fase de Atualização: Modelo do Sensor para a Detecção dos Marcos Naturais

Neste trabalho, utilizaremos como marcos naturais um conjunto de linhas retas formadas pelas arestas do piso do ambiente onde o robô irá navegar, pois além de já existirem, esta característica do ambiente é muito comum no mundo real.

Devido à escolha das retas como marcos, a técnica adotada para identificá-los é a transformada de Hough. Esta transformada é um método para detectar em uma imagem digital, uma classe de formas geométricas que pode ser representada por uma curva paramétrica (Gonzales, 2000). No caso das retas, é feito um mapeamento entre o espaço cartesiano  $(X, Y)$  e o espaço de parâmetros  $(\rho, \alpha)$  em que a reta é definida.

Hough define uma reta utilizando sua representação normal como mostra a equação (24), onde o parâmetro  $\rho$  representa o comprimento do vetor que passa pela origem e é perpendicular à reta e  $\alpha$  o ângulo que esse vetor forma com o eixo X. A Figura 2 mostra a representação geométrica desses parâmetros.

$$\rho = x \cos(\alpha) + y \sin(\alpha) \quad (24)$$

O sistema tratado neste trabalho é baseado em um robô com acionamento diferencial que possui uma câmera fixa e imóvel acoplada a sua estrutura, como mostra a Figura 3. A idéia é utilizar as informações diretamente obtidas do processamento de imagem  $(\rho, \alpha)$  na fase de atualização de um filtro de Kalman estendido para calcular




Figura 2: Parâmetros de Hough.




Figura 3: Visão geral do sistema.

a pose do robô. Para tal, deve-se deduzir o modelo do sensor (ou seja, o processador de imagens) em função das variáveis de estado.

O robô navega em um ambiente onde a posição das retas no mundo  $(\alpha^F, \rho^F)$  é conhecida e a cada passo identifica os descritores das retas contidas na imagem  $(\alpha^M, \rho^M)$  utilizando processamento de imagem e os parâmetros de calibração da câmera.

A Figura 4 ilustra os sistemas de coordenadas fixo  $\{F\}$  e móvel  $\{M\}$  utilizados na dedução matemática do modelo do sensor. O ponto  $(x_M^F, y_M^F)$  é a coordenada da origem do sistema móvel mapeado no sistema de coordenadas fixo e a variável  $\theta_M^F$  representa o ângulo de rotação do sistema de coordenadas móvel.




Figura 4: Sistema de coordenadas.

Parte-se de uma transformação simples que mapeia um ponto no sistema de coordenadas móvel  $\{M\}$  para o sistema de coordenadas fixo  $\{F\}$  como mostra o sistema (25).

$$\begin{cases} x^F = \cos(\theta_M^F)x^M - \sin(\theta_M^F)y^M + x_M^F \\ y^F = \sin(\theta_M^F)x^M + \cos(\theta_M^F)y^M + y_M^F \end{cases} \quad (25)$$

Utilizando a equação (24) e considerando o sistema de coordenadas fixo  $\{F\}$  tem-se:

$$\rho^F = x^F \cos(\alpha^F) + y^F \sin(\alpha^F) \quad (26)$$

Também utilizando a definição do sistema (24) porém agora considerando o sistema de coordenadas móvel  $\{M\}$  tem-se:

$$\rho^M = x^M \cos(\alpha^M) + y^M \sin(\alpha^M) \quad (27)$$

Substituindo (25) em (26) e fazendo as devidas equivalências com o sistema (27) obtém-se o sistema (28) que representa o modelo do sensor a ser utilizado no filtro.

$$\begin{cases} \alpha^M = \alpha^F - \theta_M^F \\ \rho^M = \rho^F - x_M^F \cos(\alpha^F) - y_M^F \sin(\alpha^F) \end{cases} \quad (28)$$

Neste sistema,  $\alpha^F$  e  $\rho^F$  são dados, pois representam a descrição do marco no mapa, que é suposto conhecido. As equações expressam a relação entre a informação retornada pelo sensor ( $\alpha^F, \rho^F$ ) e as grandezas que se quer estimar ( $x_F^M, y_F^M, \theta_F^M$ ).

Note-se que há uma relação direta entre estas variáveis ( $x_F^M, y_F^M, \theta_F^M$ ) e a pose do robô ( $x_R, y_R, \theta_R$ ) que é dada pelo sistema 29

$$\begin{cases} x_R = x_F^M \\ y_R = y_F^M \\ \theta_R = \theta_F^M + \frac{\pi}{2} \end{cases} \quad (29)$$

O modelo do sistema 28 é incorporado ao filtro de Kalman através da matriz H (equação 8) que é dada pela equação 30.

$$H = \begin{pmatrix} -\cos(\theta_M^F) & -\sin(\theta_M^F) & 0 \\ 0 & 0 & -1 \end{pmatrix} \quad (30)$$

#### 4 Resultados

As situações que serão apresentadas nesta seção foram obtidas por simulação. Procurou-se utilizar a medida dos ruídos dos sensores condizentes com a realidade. Para tal, nos *encoders* foi implementado um ruído com desvio padrão proporcional à quantidade de pulsos lidos, e para a identificação dos parâmetros das retas  $\rho$  e  $\alpha$  o desvio padrão do ruído também obedece uma proporção que é regida pelo tamanho que a reta aparece na imagem.

Nas figuras o retângulo tracejado representa a posição real do robô e o retângulo contínuo a posição calculada.

A Figura 5 apresenta o resultado do sistema de localização utilizando apenas a odometria.

Outro sistema de localização bastante utilizado também foi implementado: sistema de localização utilizando correção geométrica. Neste sistema, a cada passo as linhas são identificadas e usadas para calcular a pose do robô utilizando trigonometria. Quando não há retas identificadas a correção é feita por odometria (Figura 6).




Figura 5: Localização por Odometria.




Figura 6: Localização por Correção Geométrica.




Figura 7: Localização utilizando Filtro de Kalman, fundindo odometria e detecção de marcos.

Finalmente, na Figura 7, mostra-se o resultado do cálculo da pose utilizando a fusão dos dados da odometria e da detecção de marcos pelo FKE.

Uma situação em particular foi implementada para testar a robustez dos sistemas de localização. Para tal, uma perturbação foi adicionada ao sistema quando o robô se aproxima da posição (6.5,4.5). Os resultados encontrados utilizando geometria e Kalman são exibidos nas figuras 8 e 9.




Figura 8: Efeito da perturbação na Localização por Geometria.

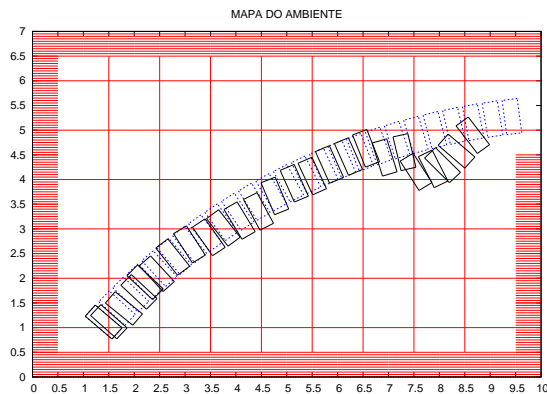


Figura 9: Efeito da perturbação na Localização utilizando Filtro de Kalman.

## 5 Conclusões e Perspectivas

Este trabalho propôs um sistema de localização para robôs móveis utilizando Filtro de Kalman Extendido. A principal contribuição é a modelagem do sensor óptico feita de tal forma a proporcionar a utilização dos parâmetros obtidos no processamento de imagem diretamente nas equações do filtro de Kalman, sem passar por nenhuma etapa intermediária de cálculo de pose ou de distância a partir das informações usuais.

Analisando as Figuras 5, 6 e 7 percebe-se que o comportamento do sistema de localização utilizando o filtro de Kalman mostrou-se mais satisfatório que os utilizando odometria e correções geométricas. No tocante a rejeições de perturbações (Figuras 8 e 9), o sistema baseado no filtro também mostrou-se eficiente pois tende a retornar à pose real, enquanto que o sistema baseado em correção geométrica não conseguiu o mesmo resultado.

Como trabalhos futuros pretende-se:

- implementar outras formulações do Filtro de Kalman, por exemplo, o Filtro de Kalman com Observações Parciais;
- substituir o filtro de Kalman por um Filtro

de Partículas, pois este incorpora mais facilmente as não-linearidades do problema além de tratar com ruídos não gaussianos;

- evoluir esta estratégia de localização para uma proposta de SLAM (*Simultaneous Localization and Mapping*), de forma que o robô seja capaz de fazer sua localização sem um conhecimento prévio do mapa e simultaneamente mapear o ambiente onde navega.

## Referências

- Bezerra, C. G. (2004). *Localização de um robô móvel usando odometria e marcos naturais*, Master's thesis, Universidade Federal do Rio Grande do Norte, UFRN, Natal, RN.
- Borenstein, J., Everett, H., Feng, L. and Wehe, D. (1997). Mobile robot positioning: Sensors and techniques, *Journal of Robotic Systems*, 14(4):231–249.
- Gonzales, R. C. (2000). *Processamento de Imagens Digitais*, Edgard Blucher.
- Kim, S. and Kim, Y. (2004). Robot localization using ultrasonic sensors, *Proceedings of the 2004 IEEE/RSJ International Conference on Intelligent Robots and Systems*, Sendai, Japan.
- Kiriy, E. and Buehler, M. (2002). Three-state extended kalman filter for mobile robot localization, *Report Centre for Intelligent Machines - CIM, McGill University*.
- Launay, F., Ohya, A. and Yuta, S. (2002). A corridors lights based navigation system including path definition using a topologically corrected map for indoor mobile robots, *Proceedings IEEE International Conference on Robotics and Automation*, pp.3918-3923.
- Lizzaralde, F., Nunes, E., Hsu, L. and J.T., W. (2003). Mobile robot navigation using sensor fusion, *Proceedings of the 2003 IEEE International Conference on Robotics and Automation*, Taipei, Taiwan.
- Park, K. C., Chung, D., Chung, H. and Lee, J. G. (1998). Dead reckoning navigation mobile robot using an indirect kalman filter, *Conference on Multi-sensor fusion and Integration for Intelligent Systems*, 9(3):107-118.
- Péres, J., Catellanos, J., Montiel, J., Neira, J. and Tardós, J. (1999). Continuous mobile robot localization: Vision vs. laser, *Proceedings of the 1999 IEEE International Conference on Robotic and Automation*.
- Thrun, S., Burgard, W. and Fox, D. (2005). *Probabilistic Robotics*, 01 edn, MIT Press.