

## Localização II

Filtro de Kalman  
Monte Carlo

1

## Filtro de Kalman

- Uma das primeiras implementações práticas do filtro de Bayes (1960).
- Hipóteses para utilização do filtro:
  - Erro médio de cada variável igual a zero;
  - Erro de cada variável independente;
  - Modelo linear de evolução do sistema;
  - Relacionamento linear entre variáveis de estado e variáveis medidas.
- Se as hipóteses acima não forem cumpridas, a optimalidade não é assegurada.

2

## Filtro de Kalman

- Estima o estado  $x$  de um processo controlado em tempo discreto que é governado por uma equação estocástica

$$x_t = A_t x_{t-1} + B_t u_t + \varepsilon_t$$

- Com medição

$$z_t = C_t x_t + \delta_t$$

3

## Componentes do filtro de Kalman

- $A_t$  Matriz (nxn) que descreve a evolução do estado de  $t$  a  $t-1$  sem ações de controle ou ruído.
- $B_t$  Matriz (nxl) que descreve como as ações de controle  $u_t$  mudam o estado de  $t-1$  para  $t$ .
- $C_t$  Matriz (kxn) que mapeia o estado  $x_t$  em uma observação  $z_t$ .
- $\varepsilon_t$  Variáveis aleatórias que representam os ruídos de processo e de medição, assumidos independentes e com distribuição normal com covariância  $R_t$  e  $Q_t$  respectivamente.
- $\delta_t$

4

## Filtro de Kalman: dinâmica

- A dinâmica do sistema é uma função linear do estado e das ações de controle, mais o ruído do sistema:

$$x_t = A_t x_{t-1} + B_t u_t + \varepsilon_t$$

$$p(x_t | u_t, x_{t-1}) = N(x_t; A_t x_{t-1} + B_t u_t, R_t)$$

$$\overline{bel}(x_t) = \int p(x_t | u_t, x_{t-1}) \overline{bel}(x_{t-1}) dx_{t-1}$$

$$\Downarrow \qquad \qquad \qquad \Downarrow$$

$$\sim N(x_t; A_t x_{t-1} + B_t u_t, R_t) \quad \sim N(x_{t-1}; \mu_{t-1}, \Sigma_{t-1})^\delta$$

## Filtro de Kalman: observações

- As observações são funções lineares do estado, mais o ruído associado:

$$z_t = C_t x_t + \delta_t$$

$$p(z_t | x_t) = N(z_t; C_t x_t, Q_t)$$

$$\overline{bel}(x_t) = \eta \int p(z_t | x_t) \overline{bel}(x_t) dx_t$$


$$\Downarrow \qquad \qquad \qquad \Downarrow$$

$$\sim N(z_t; C_t x_t, Q_t) \quad \sim N(x_t; \bar{\mu}_t, \bar{\Sigma}_t)^\delta$$

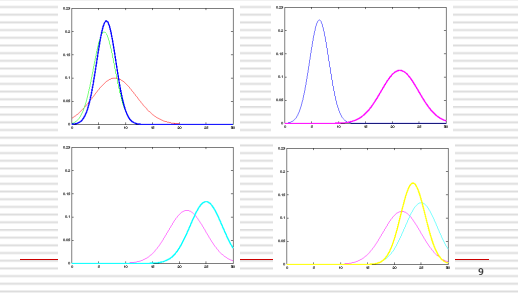
## Filtro de Kalman

1. Algoritmo **Kalman\_filter**(  $\mu_{t-1}, \Sigma_{t-1}, u_t, z_t$ ):
2. **Predição:**
3.  $\bar{\mu}_t = A_t \mu_{t-1} + B_t u_t$
4.  $\bar{\Sigma}_t = A_t \Sigma_{t-1} A_t^T + R_t$
5. **Correção:**
6.  $K_t = \bar{\Sigma}_t C_t^T (C_t \bar{\Sigma}_t C_t^T + Q_t)^{-1}$
7.  $\mu_t = \bar{\mu}_t + K_t (z_t - C_t \bar{\mu}_t)$
8.  $\Sigma_t = (I - K_t C_t) \bar{\Sigma}_t$
9. **Return**  $\mu_t, \Sigma_t$

## Ciclo correção-predição




## Ciclo correção-predição




## Ciclo correção-predição


Estimação do estado inicial




Predição: associação à ação de controle



Atualização: incorporação da medição



Predição: associação à ação de controle



## Filtro de Kalman na robótica

- Altamente Eficiente: complexidade polinomial com as dimensões de medição  $k$  e de estado  $n$ :  $O(k^{2.376} + n^2)$
- Ótimo para sistemas lineares Gaussianos
- Maioria dos sistemas robóticos é não-linear!


## Não linearidade

- A maioria dos problemas de robótica envolve funções não-lineares!

$$x_t = g(u_t, x_{t-1})$$


$$z_t = h(x_t)$$

## Não linearidade




13

## Não linearidade



14

## Não linearidade



15

## Linearização do KF: Série de Taylor – primeira ordem

### □ Predição:

$$g(u_t, x_{t-1}) \approx g(u_t, \mu_{t-1}) + \frac{\partial g(u_t, \mu_{t-1})}{\partial x_{t-1}} (x_{t-1} - \mu_{t-1})$$

$$g(u_t, x_{t-1}) \approx g(u_t, \mu_{t-1}) + G_t (x_{t-1} - \mu_{t-1})$$

### □ Correção:

$$h(x_t) \approx h(\bar{\mu}_t) + \frac{\partial h(\bar{\mu}_t)}{\partial x_t} (x_t - \bar{\mu}_t)$$

$$h(x_t) \approx h(\bar{\mu}_t) + H_t (x_t - \bar{\mu}_t)$$

16

## Algoritmo: filtro de Kalman estendido

### 1. Extended\_Kalman\_filter( $\mu_{t-1}, \Sigma_{t-1}, u_t, z_t$ ):

#### 2. Prediction:

$$\bar{\mu}_t = g(u_t, \mu_{t-1})$$

$$\bar{\Sigma}_t = G_t \Sigma_{t-1} G_t^T + R_t$$

#### 3. Correction:

#### 4. Return $\mu_t, \Sigma_t$

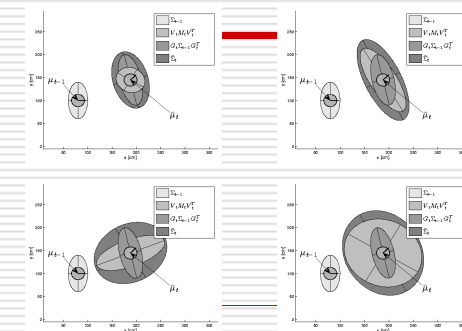
$$K_t = \bar{\Sigma}_t H_t^T (H_t \bar{\Sigma}_t H_t^T + Q_t)^{-1} \leftarrow K_t = \bar{\Sigma}_t C_t^T (C_t \bar{\Sigma}_t C_t^T + Q_t)^{-1}$$

$$\mu_t = \bar{\mu}_t + K_t (z_t - h(\bar{\mu}_t)) \leftarrow \mu_t = \bar{\mu}_t + K_t (z_t - C_t \bar{\mu}_t)$$

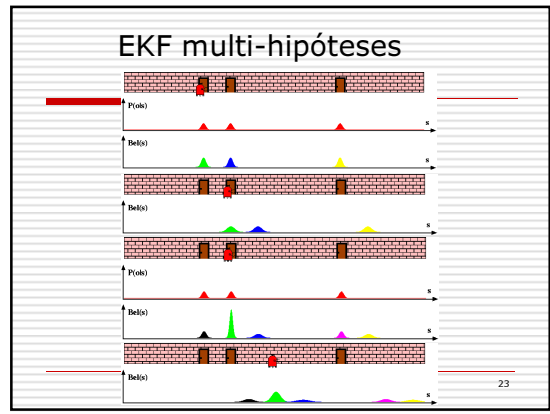
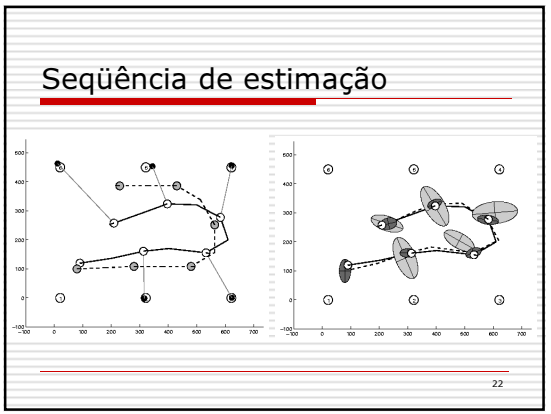
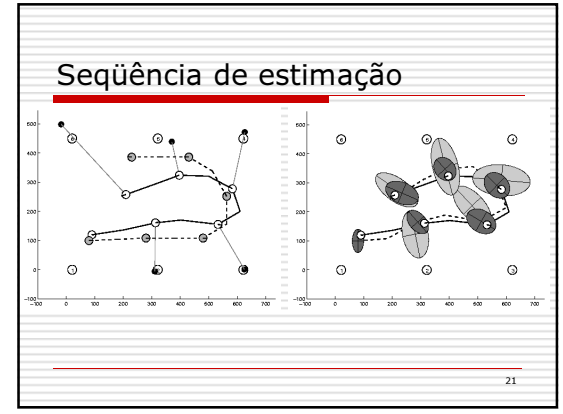
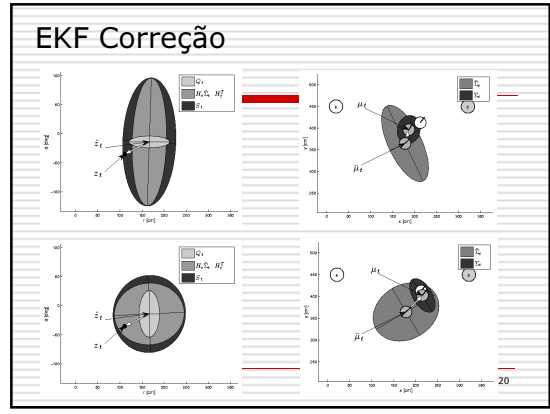

$$\Sigma_t = (I - K_t H_t) \bar{\Sigma}_t \leftarrow \Sigma_t = (I - K_t C_t) \bar{\Sigma}_t$$

$$H_t = \frac{\partial h(\bar{\mu}_t)}{\partial x_t} \quad G_t = \frac{\partial g(u_t, \mu_{t-1})}{\partial x_{t-1}}$$

## EKF Predição



18



### Filtro de Kalman estendido na robótica

- **Altamente Eficiente:** complexidade polinomial com as dimensões de medição  $k$  e de estado  $n$ :  $O(k^{2.376} + n^2)$
- **Não é ótimo.**
- Pode divergir se a não-linearidade **for forte!**
- Funciona **surpreendentemente bem**, mesmo quando as **suposições básicas são violadas!**

24

## Localização – resumo

	EKF	MHT	Coarse (topological) grid	fine (metric) grid	MCL
Measurements	landmarks	landmarks	landmarks	raw measurements	raw measurements
Measurement noise	Gaussian	Gaussian	any	any	any
Posterior	Gaussian	mixture of Gaussians	histogram	histogram	particles
Efficiency (memory)	++	++	+	-	+
Efficiency (time)	++	+	+	-	+
Ease of implementation	+	-	+	-	++
Resolution	++	++	-	+	+
Robustness	-	+	+	++	++
Global localization	no	no	yes	yes	yes