

# Filtro de Kalman Estendido

Valéria de Carvalho Santos  
Prof. Roseli A. F. Romero

# Introdução

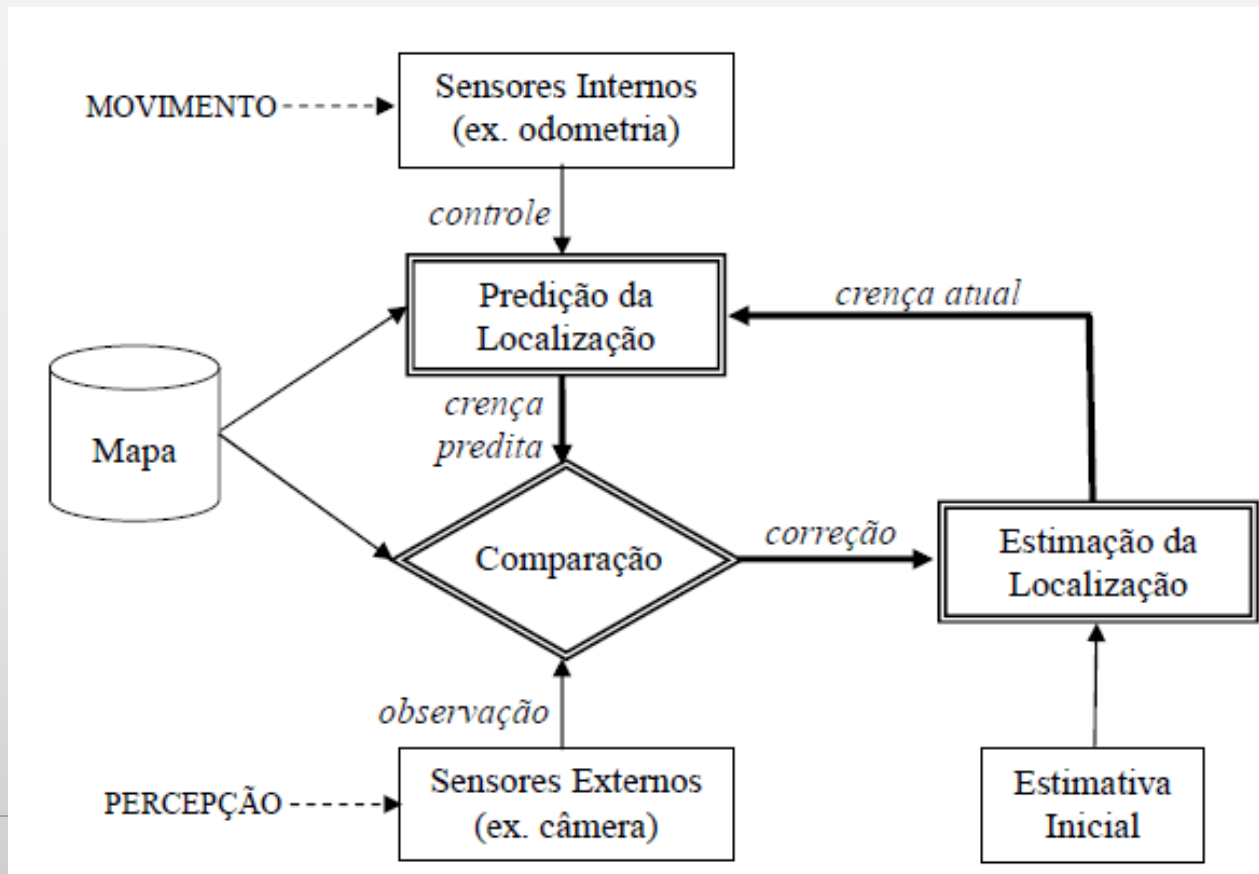
---

- ▶ Tarefa de navegação de um robô móvel
  - ▶ Competência fundamental de se movimentar por um ambiente
  - ▶ Evitar colisões
  - ▶ Atingir localidades específicas
  - ▶ Atuadores e sensores



# Técnicas de localização

- ▶ Como o robô sabe onde se encontra à medida que se movimenta em um determinado ambiente?
  - ▶ Executa ciclos que intercalam movimento com percepção



# Técnicas de localização

---

- ▶ Técnicas probabilísticas permitem explicitar as probabilidades de cada possível localização
- ▶ Estimação Bayesiana, Filtro de Kalman e Localização de Monte Carlo
- ▶ O Filtro de Kalman e sua versão estendida estimam o estado de uma variável aleatória dinâmica, cuja densidade de probabilidade é gaussiana, a partir da sequência de observações ruidosas
- ▶ No caso da localização de um robô, o intuito é estimar a sua localização a cada instante,  $X_t$ , que por sua vez influencia diretamente na observação dos sensores naquele momento,  $Z_t$

# Filtro de Kalman

---

## ► Problema de filtragem

- Dado um modelo dinâmico estocástico  $x_k$ , a sequência de observações ruidosas  $Z_k$  e as condições iniciais, encontrar  $\hat{X}_k$ , o valor estimado  $x_k$

- Considere o seguinte sistema não-linear, descrito pela equação de diferenças e o modelo de observação com ruído:

$$\begin{aligned}\mathbf{x}_k &= \mathbf{M}(\mathbf{x}_{k-1}) + \mathbf{w}_k \\ \mathbf{z}_k &= \mathbf{h}(\mathbf{x}_k) + \mathbf{v}_k\end{aligned}$$

- O estado inicial  $x_0$  é um vetor aleatório com média  $m_0 = E[x_0]$  e covariância  $E[(x_0 - m_0)(x_0 - m_0)^T]$

# Filtro de Kalman

---

- ▶  $w_k$  captura incertezas no modelo e  $v_k$  denota o ruído da medida
- ▶  $w_k$  e  $v_k$  não são correlacionados:

$$\begin{array}{llll} E[\mathbf{w}_k] = 0 & E[\mathbf{w}_k \mathbf{w}_k^T] = \mathbf{Q}_k & E[\mathbf{w}_k \mathbf{w}_j^T] = 0 \text{ for } k \neq j & E[\mathbf{w}_k \mathbf{x}_0^T] = 0 \text{ for all } k \\ E[\mathbf{v}_k] = 0 & E[\mathbf{v}_k \mathbf{v}_k^T] = \mathbf{R}_k & E[\mathbf{v}_k \mathbf{v}_j^T] = 0 \text{ for } k \neq j & E[\mathbf{v}_k \mathbf{x}_0^T] = 0 \text{ for all } k \end{array}$$

- ▶ Também os vetores aleatórios  $w_k$  e  $v_j^T$  não são correlacionados:

$$E[\mathbf{w}_k \mathbf{v}_j^T] = 0 \text{ for all } k \text{ and } j$$

# Filtro de Kalman

---

## ► Dimensão e descrição das variáveis:

$x_k$	$n \times 1$	Vetor de estados
$w_k$	$n \times 1$	Vetor de ruído do processo
$z_k$	$m \times 1$	Vetor de observação
$v_k$	$m \times 1$	Vetor de ruído da medida
$M(.)$	$n \times 1$	Função vetorial do processo não-linear
$H(.)$	$m \times 1$	Função vetorial da observação não-linear
$Q_k$	$n \times n$	Matriz de covariância de ruído do processo
$R_k$	$m \times m$	Matriz de covariância de medida do processo

# Derivação EKF

---

- ▶ Assumindo que as não-linearidades na dinâmica e no modelo de observação são suaves,  $M(x_k)$  e  $h(x_k)$  serão expandidas em Séries de Taylor e, assim, aproximadas a previsão e a próxima estimativa de  $x_k$
- ▶ Modelo do passo de previsão
  - ▶ Informação disponível inicialmente:

$$\begin{aligned}\hat{\mathbf{x}}_0 &= \mathbf{m}_0 = E[\mathbf{x}_0] \\ \mathbf{P}_0 &= E[(\mathbf{x}_0 - \hat{\mathbf{x}}_0)(\mathbf{x}_0 - \hat{\mathbf{x}}_0)^T]\end{aligned}$$



# Modelo do passo de previsão

- ▶ Assumindo que a estimativa ótima  $\hat{\mathbf{x}}_{k-1} \equiv E[\mathbf{x}_{k-1}|\mathbf{Z}_{k-1}]$  com covariância  $P_{k-1}$ , no tempo  $k-1$ . A parte previsível de  $x_k$  é dada por:

$$\begin{aligned}\mathbf{x}_k^f &\equiv E[\mathbf{x}_k|\mathbf{Z}_{k-1}] \\ &= E[\mathbf{M}(\mathbf{x}_{k-1}) + \mathbf{w}_k|\mathbf{Z}_{k-1}] \\ &= E[\mathbf{M}(\mathbf{x}_{k-1})|\mathbf{Z}_{k-1}]\end{aligned}$$

- ▶ Expandindo  $\mathbf{M}(\cdot)$  em Séries de Taylor sobre  $\hat{\mathbf{x}}_{k-1}$ :

$$\mathbf{M}(\mathbf{x}_{k-1}) \equiv \mathbf{M}(\hat{\mathbf{x}}_{k-1}) + \mathbf{J}_M(\hat{\mathbf{x}}_{k-1})(\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1}) + \mathbf{H.O.T.}$$

- ▶  $\mathbf{J}_M$  é o Jacobiano de  $\mathbf{M}(\cdot)$
- ▶ Os termos de ordem mais alta são desprezados

# Modelo do passo de previsão

---

- ▶ O Jacobiano é definido por:

$$\mathbf{J}_{\mathbf{M}} \equiv \begin{bmatrix} \frac{\partial \mathbf{M}_1}{\partial x_1} & \frac{\partial \mathbf{M}_1}{\partial x_2} & \dots & \frac{\partial \mathbf{M}_1}{\partial x_n} \\ \vdots & & \ddots & \vdots \\ \frac{\partial \mathbf{M}_n}{\partial x_1} & \frac{\partial \mathbf{M}_n}{\partial x_2} & \dots & \frac{\partial \mathbf{M}_n}{\partial x_n} \end{bmatrix}$$

$$\mathbf{M}(\mathbf{x}) = (\mathbf{M}_1(\mathbf{x}), \mathbf{M}_2(\mathbf{x}), \dots, \mathbf{M}_n(\mathbf{x}))^T$$

$$\mathbf{x} = (x_1, x_2, \dots, x_n)^T$$

$$\mathbf{M}(\mathbf{x}_{k-1}) \approx \mathbf{M}(\hat{\mathbf{x}}_{k-1}) + \mathbf{J}_{\mathbf{M}}(\hat{\mathbf{x}}_{k-1})\mathbf{e}_{k-1}$$

# Modelo do passo de previsão

---

- ▶ Tomando a esperança em ambos os lados, condicionada por  $\mathbf{Z}_{k-1}$ :

$$E[\mathbf{M}(\mathbf{x}_{k-1})|\mathbf{Z}_{k-1}] \approx \mathbf{M}(\hat{\mathbf{x}}_{k-1}) + \mathbf{J}_{\mathbf{M}}(\hat{\mathbf{x}}_{k-1})E[\mathbf{e}_{k-1}|\mathbf{Z}_{k-1}]$$

em que  $E[\mathbf{e}_{k-1}|\mathbf{Z}_{k-1}] = 0$

- ▶ Assim, o valor previsto de  $x_k$  é:

$$\mathbf{x}_k^f \approx \mathbf{M}(\hat{\mathbf{x}}_{k-1})$$

- ▶ E o erro predito fica:

$$\begin{aligned} \mathbf{e}_k^f &\equiv \mathbf{x}_k - \mathbf{x}_k^f \\ &= \mathbf{M}(\mathbf{x}_{k-1}) + \mathbf{w}_k - \mathbf{M}(\hat{\mathbf{x}}_{k-1}) \\ &\approx \mathbf{J}_{\mathbf{M}}(\hat{\mathbf{x}}_{k-1})\mathbf{e}_{k-1} + \mathbf{w}_k \end{aligned}$$

# Modelo do passo de previsão

---

- ▶ A covariância do erro prevista:

$$\begin{aligned}\mathbf{P}_k^f &\equiv E[\mathbf{e}_k^f (\mathbf{e}_k^f)^T] \\ &= \mathbf{J}_M(\hat{\mathbf{x}}_{k-1}) E[\mathbf{e}_{k-1} \mathbf{e}_{k-1}^T] \mathbf{J}_M^T(\hat{\mathbf{x}}_{k-1}) + E[\mathbf{w}_k \mathbf{w}_k^T] \\ &= \mathbf{J}_M(\hat{\mathbf{x}}_{k-1}) \mathbf{P}_{k-1} \mathbf{J}_M^T(\hat{\mathbf{x}}_{k-1}) + \mathbf{Q}_k\end{aligned}$$

# Passo de assimilação de dados

---

- ▶ No tempo  $k$ , temos duas partes de informação:
  - ▶ O valor previsto  $\mathbf{x}_k^f$  com covariância  $\mathbf{P}_k^f$
  - ▶ Medida  $z_k$  com covariância  $R_k$
- ▶ O objetivo é encontrar a melhor estimativa não tendenciosa, no sentido dos mínimos quadrados  $\hat{\mathbf{x}}_k$  de  $\mathbf{x}_k$
- ▶ Uma maneira é assumir que a estimativa é uma combinação linear de  $\mathbf{x}_k^f$  e  $\mathbf{z}_k$

# Passo de assimilação de dados

---

- ▶ Seja:

$$\hat{\mathbf{x}}_k = \mathbf{a} + \mathbf{K}_k \mathbf{z}_k$$

- ▶ Considerando que a estimativa não é tendenciosa:

$$\begin{aligned} 0 &= E[\mathbf{x}_k - \hat{\mathbf{x}}_k | \mathbf{Z}_k] \\ &= E[(\mathbf{x}_k^f + \mathbf{e}_k^f) - (\mathbf{a} + \mathbf{K}_k \mathbf{h}(\mathbf{x}_k) + \mathbf{K}_k \mathbf{v}_k) | \mathbf{Z}_k] \\ &= \mathbf{x}_k^f - \mathbf{a} - \mathbf{K}_k E[\mathbf{h}(\mathbf{x}_k) | \mathbf{Z}_k] \\ \mathbf{a} &= \mathbf{x}_k^f - \mathbf{K}_k E[\mathbf{h}(\mathbf{x}_k) | \mathbf{Z}_k] \end{aligned}$$

- ▶ Substituindo o valor de a:

$$\hat{\mathbf{x}}_k = \mathbf{x}_k^f + \mathbf{K}_k (\mathbf{z}_k - E[\mathbf{h}(\mathbf{x}_k) | \mathbf{Z}_k])$$

# Passo de assimilação de dados

---

- ▶ Expandindo  $h(\cdot)$  em Séries de Taylor sobre  $\mathbf{x}_k^f$

$$\mathbf{h}(\mathbf{x}_k) \equiv \mathbf{h}(\mathbf{x}_k^f) + \mathbf{J}_h(\mathbf{x}_k^f)(\mathbf{x}_k - \mathbf{x}_k^f) + \text{H.O.T.}$$

- ▶ O Jacobiano de  $h(\cdot)$  é definido como:

$$\mathbf{J}_h \equiv \begin{bmatrix} \frac{\partial \mathbf{h}_1}{\partial x_1} & \frac{\partial \mathbf{h}_1}{\partial x_2} & \cdots & \frac{\partial \mathbf{h}_1}{\partial x_n} \\ \vdots & & \ddots & \vdots \\ \frac{\partial \mathbf{h}_m}{\partial x_1} & \frac{\partial \mathbf{h}_m}{\partial x_2} & \cdots & \frac{\partial \mathbf{h}_m}{\partial x_n} \end{bmatrix}$$

$$\mathbf{h}(\mathbf{x}) = (\mathbf{h}_1(\mathbf{x}), \mathbf{h}_2(\mathbf{x}), \dots, \mathbf{h}_m(\mathbf{x}))^T$$

$$\mathbf{x} = (x_1, x_2, \dots, x_n)^T$$

# Passo de assimilação de dados

---

- ▶ Tomando a esperança dos dois lados da equação de  $\mathbf{h}(\mathbf{x}_k)$  condicionada por  $\mathbf{Z}_k$ :

$$E[\mathbf{h}(\mathbf{x}_k)|\mathbf{Z}_k] \approx \mathbf{h}(\mathbf{x}_k^f) + \mathbf{J}_h(\mathbf{x}_k^f)E[\mathbf{e}_k^f|\mathbf{Z}_k]$$

- ▶ em que  $E[\mathbf{e}_k^f|\mathbf{Z}_k] = 0$ .
- ▶ Substituindo em  $\hat{\mathbf{x}}_k = \mathbf{x}_k^f + \mathbf{K}_k(\mathbf{z}_k - E[\mathbf{h}(\mathbf{x}_k)|\mathbf{Z}_k])$ , o estado estimado é:

$$\hat{\mathbf{x}}_k \approx \mathbf{x}_k^f + \mathbf{K}_k(\mathbf{z}_k - \mathbf{h}(\mathbf{x}_k^f))$$



# Passo de assimilação de dados

---

- ▶ O erro no valor estimado de  $\hat{\mathbf{x}}_k$  é:

$$\begin{aligned} \mathbf{e}_k &\equiv \mathbf{x}_k - \hat{\mathbf{x}}_k \\ &= \mathbf{M}(\mathbf{x}_{k-1}) + \mathbf{w}_k - \mathbf{x}_k^f - \mathbf{K}_k(\mathbf{z}_k - \mathbf{h}(\mathbf{x}_k^f)) \\ &\approx \mathbf{M}(\mathbf{x}_{k-1}) - \mathbf{M}(\hat{\mathbf{x}}_{k-1}) + \mathbf{w}_k - \mathbf{K}_k(\mathbf{h}(\mathbf{x}_k) - \mathbf{h}(\mathbf{x}_k^f) + \mathbf{v}_k) \\ &\approx \mathbf{J}_M(\hat{\mathbf{x}}_{k-1})\mathbf{e}_{k-1} + \mathbf{w}_k - \mathbf{K}_k(\mathbf{J}_h(\mathbf{x}_k^f)\mathbf{e}_k^f + \mathbf{v}_k) \\ &\approx \mathbf{J}_M(\hat{\mathbf{x}}_{k-1})\mathbf{e}_{k-1} + \mathbf{w}_k - \mathbf{K}_k\mathbf{J}_h(\mathbf{x}_k^f)(\mathbf{J}_M(\hat{\mathbf{x}}_{k-1})\mathbf{e}_{k-1} + \mathbf{w}_k) - \mathbf{K}_k\mathbf{v}_k \\ &\approx (\mathbf{I} - \mathbf{K}_k\mathbf{J}_h(\mathbf{x}_k^f))\mathbf{J}_M(\hat{\mathbf{x}}_{k-1})\mathbf{e}_{k-1} + (\mathbf{I} - \mathbf{K}_k\mathbf{J}_h(\mathbf{x}_k^f))\mathbf{w}_k - \mathbf{K}_k\mathbf{v}_k \end{aligned}$$

# Passo de assimilação de dados

- ▶ Então, a covariância posterior da nova estimativa é:

$$\begin{aligned}\mathbf{P}_k &\equiv E[\mathbf{e}_k \mathbf{e}_k^T] \\ &= (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f)) \mathbf{J}_M(\hat{\mathbf{x}}_{k-1}) \mathbf{P}_{k-1} \mathbf{J}_M^T(\hat{\mathbf{x}}_{k-1}) (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f))^T \\ &\quad + (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f)) \mathbf{Q}_k (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f))^T + \mathbf{K}_k \mathbf{R}_k \mathbf{K}_k^T \\ &= (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f)) \mathbf{P}_k^f (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f))^T + \mathbf{K}_k \mathbf{R}_k \mathbf{K}_k^T \\ &= \mathbf{P}_k^f - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f) \mathbf{P}_k^f - \mathbf{P}_k^f \mathbf{J}_h^T(\mathbf{x}_k^f) \mathbf{K}_k^T + \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f) \mathbf{P}_k^f \mathbf{J}_h^T(\mathbf{x}_k^f) \mathbf{K}_k^T + \mathbf{K}_k \mathbf{R}_k \mathbf{K}_k^T\end{aligned}$$

- ▶ Essa fórmula é válida para qualquer  $\mathbf{K}_k$
- ▶ Como no filtro de Kalman padrão,  $\mathbf{K}_k$  é descoberto por minimizar o  $tr(\mathbf{P}_k)$

$$\begin{aligned}0 &= \frac{\partial tr(\mathbf{P}_k)}{\partial \mathbf{K}_k} \\ &= -(\mathbf{J}_h(\mathbf{x}_k^f) \mathbf{P}_k^f)^T - \mathbf{P}_k^f \mathbf{J}_h^T(\mathbf{x}_k^f) + 2\mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f) \mathbf{P}_k^f \mathbf{J}_h^T(\mathbf{x}_k^f) + 2\mathbf{K}_k \mathbf{R}_k\end{aligned}$$

# Passo de assimilação de dados

---

- ▶ Substituindo novamente em  $\mathbf{P}_k$ , tem-se:

$$\begin{aligned}\mathbf{P}_k &= (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f)) \mathbf{P}_k^f - (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f)) \mathbf{P}_k^f \mathbf{J}_h^T(\mathbf{x}_k^f) \mathbf{K}_k^T + \mathbf{K}_k \mathbf{R}_k \mathbf{K}_k^T \\ &= (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f)) \mathbf{P}_k^f - \left( \mathbf{P}_k^f \mathbf{J}_h^T(\mathbf{x}_k^f) - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f) \mathbf{P}_k^f \mathbf{J}_h^T(\mathbf{x}_k^f) - \mathbf{K}_k \mathbf{R}_k \right) \mathbf{K}_k^T \\ &= (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f)) \mathbf{P}_k^f - \left[ \mathbf{P}_k^f \mathbf{J}_h^T(\mathbf{x}_k^f) - \mathbf{K}_k \left( \mathbf{J}_h(\mathbf{x}_k^f) \mathbf{P}_k^f \mathbf{J}_h^T(\mathbf{x}_k^f) + \mathbf{R}_k \right) \right] \mathbf{K}_k^T \\ &= (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f)) \mathbf{P}_k^f - \left[ \mathbf{P}_k^f \mathbf{J}_h^T(\mathbf{x}_k^f) - \mathbf{P}_k^f \mathbf{J}_h^T(\mathbf{x}_k^f) \right] \mathbf{K}_k^T \\ &= (\mathbf{I} - \mathbf{K}_k \mathbf{J}_h(\mathbf{x}_k^f)) \mathbf{P}_k^f\end{aligned}$$