



# Redes de Sensores

## Estimación

Manuel A. Vázquez  
Joaquín Míguez  
Jose Miguel Leiva

4 de febrero de 2024


# Índice

- 1 Contexto
- 2 Sistema dinámico
- 3 El filtro de Kalman
- 4 El filtro de Kalman con término de control

# Índice

- 1 Contexto
- 2 Sistema dinámico
- 3 El filtro de Kalman
- 4 El filtro de Kalman con término de control

# Red para estimación centralizada



Estructura de la red con  $N$  sensores ( $i = 1, \dots, N$ ):

- $S_i \equiv$  sensor  $i$ -ésimo
- $y_i \equiv$  observación en el sensor  $i$ -ésimo

El CF debe utilizar el conjunto de observaciones para estimar un vector  $\mathbf{x}$  de dimensiones  $M \times 1$ .

## Estimación clásica

La estimación de  $\mathbf{x}$  dada la colección de datos  $\mathbf{y} = \{y_1, \dots, y_N\}$  es equivalente a un problema de estimación *clásico*. Hay varios estimadores posibles:

- Máxima verosimilitud (ML  $\equiv$  maximum likelihood)

$$\hat{\mathbf{x}}^{ML} = \arg \underset{\mathbf{x}}{\text{máx}} p(\mathbf{y}|\mathbf{x}).$$

- Máximo a posteriori (MAP)

$$\hat{\mathbf{x}}^{MAP} = \arg \underset{\mathbf{x}}{\text{máx}} p(\mathbf{x}|\mathbf{y}).$$

- Mínimo error cuadrático medio (MMSE)

$$\begin{aligned} \hat{\mathbf{x}}^{MMSE} &= \arg \underset{\hat{\mathbf{x}}}{\text{mín}} \mathbb{E} [\|\mathbf{x} - \hat{\mathbf{x}}\|^2] \\ &= \mathbb{E} [\mathbf{x}|\mathbf{y}] = \int \mathbf{x} p(\mathbf{x}|\mathbf{y}) d\mathbf{x}. \end{aligned}$$

# Índice

- 1 Contexto
- 2 Sistema dinámico**
- 3 El filtro de Kalman
- 4 El filtro de Kalman con término de control

# Modelo dinámico

## Un problema más interesante...

¿Y si la variable de interés cambia con el tiempo?

$$\mathbf{x} \rightarrow \mathbf{x}_t$$

siendo  $t$  una variable temporal discreta. Si  $\mathbf{x}$  era una variable aleatoria, entonces  $\mathbf{x}_t$  es un *proceso estocástico*.

## Objetivo

Queremos hacer un **seguimiento** de la evolución de  $\mathbf{x}$  con el tiempo.

Entonces, necesitamos dos ecuaciones

- una **ecuación de estado** que modele la evolución de la variable de interés
- una **ecuación de observación** que modele la relación entre la variable de interés y lo observado

# Modelo lineal y gaussiano

- El proceso  $\mathbf{x}_t$  evoluciona de acuerdo a un modelo lineal y gaussiano

$$\mathbf{x}_t = \mathbf{F}\mathbf{x}_{t-1} + \mathbf{v}_t \quad (\text{ecuación de estado})$$

donde  $\mathbf{F}$  es una matriz  $M \times M$ , y  $\mathbf{v}_t$  es un vector aleatorio  $M \times 1$  gaussiano de media  $\mathbf{0}$  y covarianza  $\mathbf{Q}$ , siendo  $M$  el número de elementos en  $\mathbf{x}_t$ .

- La relación entre la variable de interés  $\mathbf{x}_t$  y las observaciones viene dada por

$$\mathbf{y}_t = \mathbf{H}\mathbf{x}_t + \mathbf{w}_t \quad (\text{ecuación de observación})$$

donde  $\mathbf{H}$  es una matriz  $N \times M$  y  $\mathbf{w}_t$  es un vector aleatorio  $N \times 1$  gaussiano de media  $\mathbf{0}$  y covarianza  $\mathbf{R}$ .



## Las observaciones...

...dadas por el vector  $\mathbf{y}_t$ , recogen las medidas tomadas por todos los sensores



# Ejemplo I

## Objetivo

Localización y seguimiento de un objeto con velocidad constante y conocida  $\mathbf{c}$ .

- La posición del objetivo,  $\mathbf{x}_t$  (que aquí representa el estado del sistema), evoluciona de acuerdo a

$$\mathbf{x}_t = \mathbf{x}_{t-1} + \mathbf{c}T + \mathbf{v}_t,$$

donde  $T$  es el período de muestreo, i.e., el tiempo transcurrido entre dos observaciones consecutivas.

- Observamos directamente la posición:

$$\mathbf{y}_t = \mathbf{x}_t + \mathbf{w}_t$$

# Ejemplo II

## Objetivo

Localización y seguimiento de un objeto con velocidad constante *desconocida*.

Para estimar la velocidad, la incluimos en el estado del sistema

$$\mathbf{x}'_t = \begin{bmatrix} \mathbf{x}_t \\ \mathbf{c} \end{bmatrix}$$

- La **ecuación de estado** es ahora

$$\mathbf{x}'_t = \mathbf{F}\mathbf{x}'_{t-1} + \begin{bmatrix} \mathbf{v}_t \\ \mathbf{0} \end{bmatrix}, \text{ with } \mathbf{F} = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix},$$

- ...y la **ecuación de observación**

$$\mathbf{y}_t = \mathbf{H}\mathbf{x}'_t + \mathbf{w}_t, \text{ with } \mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$$

# Índice

- 1 Contexto
- 2 Sistema dinámico
- 3 El filtro de Kalman**
- 4 El filtro de Kalman con término de control

# ¿Qué es el filtro de Kalman?

Es un método **recursivo** para el **cálculo de distribuciones de probabilidad** a posteriori **en sistemas dinámicos lineales** y **gaussianos**.

- **recursivo**: nos da una estimación en un determinado instante de tiempo utilizando la estimación del instante anterior (igual que hacen los algoritmos adaptativos).
- **calcula distribuciones de probabilidad**: no nos va a dar una estimación del parámetro de interés sino su distribución (determinada por la media y la matriz de covarianza).
- **...en sistemas dinámicos**: en sistemas que cambian con el tiempo
- **lineales**: las ecuaciones que modelan el sistema son lineales con respecto a la variable de interés.
- **gaussianos**: el ruido que afecta a esas mismas ecuaciones es gaussiano.

# Sistema dinámico en formato de espacio de estados

$$\begin{array}{l} \mathbf{x}_t = \mathbf{F}_{t-1}\mathbf{x}_{t-1} + \mathbf{v}_t \quad \leftarrow \text{ecuación de estado} \\ \mathbf{y}_t = \mathbf{H}_t\mathbf{x}_t + \mathbf{w}_t \quad \leftarrow \text{ecuación de observación} \end{array} \left. \vphantom{\begin{array}{l} \mathbf{x}_t = \mathbf{F}_{t-1}\mathbf{x}_{t-1} + \mathbf{v}_t \\ \mathbf{y}_t = \mathbf{H}_t\mathbf{x}_t + \mathbf{w}_t \end{array}} \right\} \begin{array}{l} \text{sistema dinámico} \\ \text{en formato de es-} \\ \text{pacio de estados} \end{array}$$

## Objetivo

Estimar (recursivamente) el estado del sistema  $\mathbf{x}_t$  dadas las observaciones,  $\mathbf{y}_t$

El índice temporal es discreto, i.e.,  $t = 0, 1, \dots$

# Notación

$$\mathbf{x}_t = \mathbf{F}_{t-1}\mathbf{x}_{t-1} + \mathbf{v}_t$$

- $\mathbf{x}_t$  es el vector de estado (del sistema) en el instante  $t$
  - $\mathbf{F}_t$  es la **matriz de transición de estado**: determina la evolución del estado del sistema
  - $\mathbf{v}_t \sim \mathcal{N}(\mathbf{v}_t | \mathbf{0}, \mathbf{Q}_t)$  es el ruido estado (o de proceso)
    - $\mathbf{Q}_t$  es la matriz de covarianza del ruido de estado (puede ser variante con el tiempo)
- 

$$\mathbf{y}_t = \mathbf{H}_t\mathbf{x}_t + \mathbf{w}_t$$

- $\mathbf{y}_t$  es el el vector de observaciones
- $\mathbf{H}_t$  es la **matriz de observaciones**: relaciona las observaciones con el estado (desconocido)
- $\mathbf{w}_t \sim \mathcal{N}(\mathbf{w}_t | \mathbf{0}, \mathbf{R}_t)$  es el ruido de observación
  - $\mathbf{R}_t$  es la matriz de covarianza del ruido de observación (puede ser variante con el tiempo)

## Filtrado: hipótesis de partida

La distribución *a priori* (inicial) del estado es Gaussiana, i.e.,

$$p(\mathbf{x}_0) \sim \mathcal{N}(\mathbf{x}_0 | \hat{\mathbf{x}}_{0|0}, \mathbf{P}_{0|0})$$

siendo **conocidas**

- $\hat{\mathbf{x}}_{0|0}$ : la media de la distribución del estado en el instante 0
- $\mathbf{P}_{0|0}$ : matriz de cov. de la distr. del estado en el instante 0



### Notación

- $\hat{\mathbf{x}}_{a|b} \equiv$  media estimada en el instante  $a$  utilizando las observaciones hasta el instante  $b$
- $\mathbf{P}_{a|b} \equiv$  matriz de covarianza estimada en el instante  $a$  utilizando las observaciones hasta el instante  $b$



### Al principio

En el instante 0 no hay ninguna observación disponible...pero la notación sigue siendo conveniente.

# Filtrado: recursión

Si se cumple la hipótesis de partida, entonces para  $t = 1, 2, \dots$

$$p(\mathbf{x}_t \mid \mathbf{y}_{1:t-1}) \sim \mathcal{N}(\mathbf{x}_t \mid \hat{\mathbf{x}}_{t|t-1}, \mathbf{P}_{t|t-1}) \quad \leftarrow \begin{array}{l} \text{fdp} \\ \text{predictiva} \end{array}$$

$$p(\mathbf{x}_t \mid \mathbf{y}_{1:t}) \sim \mathcal{N}(\mathbf{x}_t \mid \hat{\mathbf{x}}_{t|t}, \mathbf{P}_{t|t}) \quad \leftarrow \text{fdp filtrada}$$

...esto es, ambas fdp's son Gaussianas si la distribución inicial es Gaussiana, y el **filtro de Kalman** nos da sus medias y covarianzas en un proceso que involucra dos etapas...



## Notación

$$y_{i:j} \equiv \{y_i, y_{i+1}, \dots, y_j\}$$



# Solución

## Etapa predictiva

$$\hat{\mathbf{x}}_{t|t-1} = \mathbf{F}_{t-1} \hat{\mathbf{x}}_{t-1|t-1} \quad \leftarrow \text{media predictiva}$$

$$\mathbf{P}_{t|t-1} = \mathbf{Q}_{t-1} + \mathbf{F}_{t-1} \mathbf{P}_{t-1|t-1} \mathbf{F}_{t-1}^H \quad \leftarrow \text{covarianza predictiva}$$

} asociadas a la fdp predictiva

## Etapa de actualización

$$\mathbf{K}_t = \mathbf{P}_{t|t-1} \mathbf{H}_t^H (\mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^H + \mathbf{R}_t)^{-1} \quad \leftarrow \text{ganancia de Kalman}$$

$$\hat{\mathbf{x}}_{t|t} = \hat{\mathbf{x}}_{t|t-1} + \mathbf{K}_t (\mathbf{y}_t - \mathbf{H}_t \hat{\mathbf{x}}_{t|t-1}) \quad \leftarrow \text{media filtrada}$$

$$\mathbf{P}_{t|t} = (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \mathbf{P}_{t|t-1} \quad \leftarrow \text{covarianza filtrada}$$

} asociadas a la fdp filtrada

# Observaciones

- Para poder aplicar el KF
  - el **sistema** tiene que ser **lineal**
  - el **ruido** tiene que ser **gaussiano**
  - la **distribución inicial** del estado tiene que ser **gaussiana**
- El KF nos da (como salida) una distribución de probabilidad<sup>1</sup>, que contiene toda la información acerca del parámetro de interés



## En nuestro caso...

$p(\mathbf{x}_t \mid \mathbf{y}_{1:t})$  contiene toda la información disponible en el instante  $t$  acerca de  $\mathbf{x}_t$ , y a partir de ella podemos obtener la media, mediana, moda...

- $\hat{\mathbf{x}}_{t|t} \equiv$  estimador MMSE del estado en el instante  $t$
- $\text{Tr} \{ \mathbf{P}_{t|t} \} \equiv$  error mínimo (valor del error cuadrático en  $\hat{\mathbf{x}}_{t|t}$ )

<sup>1</sup>...porque una gaussiana está completamente determinada por su media y matriz de covarianza.

# Índice

- 1 Contexto
- 2 Sistema dinámico
- 3 El filtro de Kalman
- 4 El filtro de Kalman con término de control

# Ecuaciones de estado y observación

$$\mathbf{x}_t = \mathbf{F}_{t-1}\mathbf{x}_{t-1} + \mathbf{B}_t\mathbf{u}_t + \mathbf{v}_{t-1} \quad \leftarrow \begin{array}{l} \text{ecuación de} \\ \text{estado} \end{array}$$

$$\mathbf{y}_t = \mathbf{H}_t\mathbf{x}_t + \mathbf{w}_t \quad \leftarrow \begin{array}{l} \text{ecuación de} \\ \text{observación} \end{array}$$

El término de control,  $\mathbf{B}_t\mathbf{u}_t$ , con

- $\mathbf{B}_t$  es la matriz de control, y
- $\mathbf{u}_t$  el vector de control

es **conocido** (en todo instante de tiempo  $t$ ) y es un mecanismo para modificar el estado (desconocido).

## ¿Para qué sirve el término de control?

- ...a veces podemos ejercer un cierto *control* sobre aquello que queremos estimar



### example

Problema: estimar la trayectoria de un dron que nosotros mismos manejamos

- ...desde un punto de vista matemático, es útil para modelar funciones *afines*

El término de control es algo que afecta al estado<sup>2</sup>, pero que no es necesario estimar porque es conocido.

---

<sup>2</sup>...por lo que debe figurar en dicha ecuación!!

# Solución

## Etapa predictiva

$$\hat{\mathbf{x}}_{t|t-1} = \mathbf{F}_{t-1}\hat{\mathbf{x}}_{t-1|t-1} + \mathbf{B}_t\mathbf{u}_t \quad \leftarrow \text{media predictiva}$$

$$\mathbf{P}_{t|t-1} = \mathbf{Q}_{t-1} + \mathbf{F}_{t-1}\mathbf{P}_{t-1|t-1}\mathbf{F}_{t-1}^H \quad \leftarrow \text{covarianza predictiva}$$

} asociadas a la fdp predictiva

## Etapa de actualización

$$\mathbf{K}_t = \mathbf{P}_{t|t-1}\mathbf{H}_t^H (\mathbf{H}_t\mathbf{P}_{t|t-1}\mathbf{H}_t^H + \mathbf{R}_t)^{-1} \quad \leftarrow \text{ganancia de Kalman}$$

$$\hat{\mathbf{x}}_{t|t} = \hat{\mathbf{x}}_{t|t-1} + \mathbf{K}_t (\mathbf{y}_t - \mathbf{H}_t\hat{\mathbf{x}}_{t|t-1}) \quad \leftarrow \text{media filtrada}$$

$$\mathbf{P}_{t|t} = (\mathbf{I} - \mathbf{K}_t\mathbf{H}_t) \mathbf{P}_{t|t-1} \quad \leftarrow \text{covarianza filtrada}$$

} asociadas a la fdp filtrada