

Estimación y Predicción en Series Temporales

Ejemplos de Kalman

Departamento de Procesamiento de Señales

Instituto de Ingeniería Eléctrica
Facultad de Ingeniería


2023

Motivación:

- Filtros de Kalman: muy generales
- Pueden ser intimidantes
- Cómo llevarlo a la práctica?
- Intentaremos ganar un poco de intuición

Agenda:


- Medición de una constante
- Modelado de procesos ARMA
- Aplicación completa: KalmanPaint



Medición de una constante

Modelo de constante

Modelando




- N medidas secuenciales de una constante a + ruido
- Cómo podemos diseñar un filtro de Kalman para esto?

(si estás leyendo los slides, tomate un rato para pensarlo)

Modelo de constante

Modelando



Modelo general

$$\mathbf{x}_{n+1} = \mathbf{F}\mathbf{x}_n + \mathbf{w}_n, \quad \mathbf{x}, \mathbf{w} \sim \mathcal{N}(0, \mathbf{Q}), \quad \mathbf{F} \in \mathbb{R}^{M \times M}, \quad \mathbf{Q} \in \mathbb{R}^{M \times M}$$
$$\mathbf{y}_n = \mathbf{C}\mathbf{x}_n + \mathbf{v}_n, \quad \mathbf{y}, \mathbf{v} \sim \mathcal{N}(0, \mathbf{R}), \quad \mathbf{C} \in \mathbb{R}^{N \times M}, \quad \mathbf{R} \in \mathbb{R}^{N \times N}$$

Este caso

$$x_{n+1} = 1 \cdot x_n = a \in \mathbb{R}$$
$$y_n = 1 \cdot x_n + 1 \cdot v_n \quad v_n \sim \mathcal{N}(0, \sigma^2)$$

Identificando

- $\mathbf{F} = 1, \mathbf{Q} = 0, \mathbf{C} = 1, \mathbf{R} = \sigma^2$

Recursión genérica

- 1 Ganancia de Kalman: $\mathbf{K}_n = \bar{\mathbf{P}}_n \mathbf{C}_n^\top (\mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^\top + \mathbf{R}_n)^{-1}$
- 2 Corrección del estimador: $\hat{\mathbf{x}}_n = \bar{\mathbf{x}}_n + \mathbf{K}_n (\mathbf{y}_n - \mathbf{C}_n \bar{\mathbf{x}}_n)$
- 3 Corrección de covarianza: $\mathbf{P}_n = (\mathbf{I} - \mathbf{K}_n \mathbf{C}_n) \bar{\mathbf{P}}_n$
- 4 Proyección a $n + 1$:

$$\bar{\mathbf{x}}_{n+1} = \mathbf{F}_n \hat{\mathbf{x}}_n, \quad \bar{\mathbf{P}}_{n+1} = \mathbf{F}_n \mathbf{P}_n \mathbf{F}_n^\top + \mathbf{Q}_n$$

Recursión en este caso

- 1 Ganancia de Kalman: $K_n = \bar{P}_n \cdot 1 \cdot (1 \cdot \bar{P}_n \cdot 1 + \sigma^2)^{-1}$
- 2 Corrección del estimador: $\hat{x}_n = \bar{x}_n + K_n (y_n - 1 \cdot \bar{x}_n)$
- 3 Corrección de covarianza: $\hat{P}_n = (1 - K_n \cdot 1) \cdot \bar{P}_n$
- 4 Proyección a $n + 1$:

$$\bar{x}_{n+1} = 1 \hat{x}_n, \quad \bar{P}_{n+1} = 1 \cdot \bar{P}_n \cdot 1$$

Recursión en este caso


- 1 Ganancia de Kalman: $K_n = \bar{P}_n / (\bar{P}_n + \sigma^2)$
- 2 Corrección del estimador: $\hat{x}_n = \bar{x}_n + K_n(y_n - \bar{x}_n)$
- 3 Corrección de covarianza: $\hat{P}_n = (1 - K_n)\bar{P}_n$
- 4 Proyección a $n + 1$:

$$\bar{x}_{n+1} = \hat{x}_n, \quad \bar{P}_{n+1} = \hat{P}_n$$

- 5 Valores iniciales: $\bar{x}_0 = 0, \bar{P}_0 = 1$

Modelo de constante

Resultado






Modelos ARMA

Modelos ARMA

Esquema de síntesis modelo ARMA



- $v[n]$ es ruido blanco
- Filtro transpuesto tipo II
- **Representación no es única**

Modelo general


$$\mathbf{x}_{n+1} = \mathbf{F}\mathbf{x}_n + \mathbf{w}_n, \mathbf{x}, \mathbf{w} \sim \mathcal{N}(0, \mathbf{Q}), \mathbf{F} \in \mathbb{R}^{M \times M}, \mathbf{Q} \in \mathbb{R}^{M \times M}$$
$$\mathbf{y}_n = \mathbf{C}\mathbf{x}_n + \mathbf{v}_n, \mathbf{y}, \mathbf{v} \sim \mathcal{N}(0, \mathbf{R}), \mathbf{C} \in \mathbb{R}^{N \times M}, \mathbf{R} \in \mathbb{R}^{N \times N}$$

Este caso

- Que es qué?
- No es tan fácil hacer la correspondencia
- Infinitas formas distintas: elegimos una

Modelos ARMA




Conceptos clave



- Qué es lo que **observamos**? Eso debería ser $y[n]$
- Cuál es el **estado** del sistema? Eso debería ser $x[n]$
- **Estado = memoria del sistema**
- Y dónde está la memoria?


Modelos ARMA

Pensemos




Modelos ARMA

Solución



Modelos ARMA

Ecuaciones



$$\phi_n = -\mathbf{a}^T(\phi_{n-1}, \dots, \phi_{n-M}) + v_n$$

$$\phi_{n-r} \leftarrow \phi_{n-r+1} \quad \text{al actualizar} \quad n \leftarrow n + 1$$

$$u_n = \mathbf{b}^T(\phi_{n-1}, \dots, \phi_{n-K})$$

Teníamos:

$$\begin{aligned}\phi_n &= -\mathbf{a}^\top(\phi_{n-1}, \dots, \phi_{n-M}) + v_n, & \phi_{n-r} &\leftarrow \phi_{n-r+1} \\ u_n &= \mathbf{b}^\top(\phi_{n-1}, \dots, \phi_{n-K})\end{aligned}$$

Definimos:

- Estado $\mathbf{x}_n = (\phi_{n-1}, \dots, \phi_{n-M})$
- Salida $y_n = u_n = \mathbf{b}^\top(\phi_{n-1}, \dots, \phi_{n-K}) = \mathbf{b}^\top \mathbf{x}_n$

Llegamos a la siguiente forma:

$$\begin{aligned} \overbrace{\begin{pmatrix} \mathbf{x}_{n+1} \\ \phi_n \\ \phi_{n-1} \\ \vdots \\ \phi_{n-M+1} \end{pmatrix}}^{\mathbf{x}_{n+1}} &= \overbrace{\begin{pmatrix} -a_1 & -a_2 & \cdots & -a_{M-1} & -a_M \\ 1 & 0 & \cdots & 0 & 0 \\ 0 & 1 & \ddots & 0 & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \cdots & 1 & 0 \end{pmatrix}}^{\mathbf{F}} \overbrace{\begin{pmatrix} \mathbf{x}_n \\ \phi_{n-1} \\ \phi_{n-2} \\ \vdots \\ \phi_{n-M} \end{pmatrix}}^{\mathbf{x}_n} + \overbrace{\begin{pmatrix} v_n \\ 0 \\ \vdots \\ 0 \end{pmatrix}}^{\mathbf{w}_n} \\ y_n &= \overbrace{(\mathbf{b}^\top, 0, 0, \dots, 0)}^{\mathbf{C}} \mathbf{x}_n \end{aligned}$$

- Recordar: hay muchas formas de hacer esto mismo, con otras definiciones de estado y otras matrices.



Suavizado de trayectorias

- Kalman aplicado a modelo físico
- Objetivo: seguir trayectoria
- Observación: posición
- Estado: posición + velocidad + aceleración
- Hipótesis (FALSA): aceleración constante + ruido

- Aceleración a , período de muestreo Δt
- Velocidad (horizontal): $\dot{x}_{n+1} = \dot{x}_n + \ddot{x}_n \Delta t$
- Posición (horizontal): $x_{n+1} = x_n + \dot{x}_n \Delta t + \ddot{x}_n (\Delta t)^2 / 2$
- Aceleración: $\ddot{x}_{n+1} = \ddot{x}_n + v_n$
- Idem con vel. y pos horizontal
- Ruido en la aceleración: σ_a^2
- Ruido en la posición: σ_x^2

$$\mathbf{x}_{n+1} = \mathbf{F}\mathbf{x}_n + \mathbf{w}_n, \mathbf{x}, \mathbf{w} \sim \mathcal{N}(0, \mathbf{Q}), \mathbf{F} \in \mathbb{R}^{M \times M}, \mathbf{Q} \in \mathbb{R}^{M \times M}$$
$$\mathbf{y}_n = \mathbf{C}\mathbf{x}_n + \mathbf{v}_n, \mathbf{y}, \mathbf{v} \sim \mathcal{N}(0, \mathbf{R}), \mathbf{C} \in \mathbb{R}^{N \times M}, \mathbf{R} \in \mathbb{R}^{N \times N}$$

- Estado = posición + velocidad + aceleración (natural!)
- Eso tanto vertical como horizontal $\Rightarrow$ (6 variables)
- Observación: posición (2 variables)
- Con esto, $\mathbf{F}$, $\mathbf{C}$ y $\mathbf{R}$ quedan muy sencillas

$$\mathbf{F} = \begin{pmatrix} 1 & \Delta t & (\Delta t)^2/2 & 0 & 0 & 0 \\ 0 & 1 & \Delta t & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & \Delta t & (\Delta t)^2/2 \\ 0 & 0 & 0 & 0 & 1 & \Delta t \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix}$$

$$\mathbf{C} = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{pmatrix}$$

$$\mathbf{R} = \begin{pmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_x^2 \end{pmatrix}$$

- Ya $\mathbf{Q}$ no es tan trivial
- El ruido en la aceleración afectan pos. y vel.!
- Hay que tomar valores esperados en cada casilla...
- La solución es:

$$\mathbf{F} = \sigma_a^2 \begin{pmatrix} \Delta t^2/4 & \Delta t^3/2 & \Delta t^2/2 & 0 & 0 & 0 \\ \Delta t^3 & \Delta t^2 & \Delta t & 0 & 0 & 0 \\ \Delta t^2/2 & \Delta t & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & \Delta t^2/4 & \Delta t^3/2 & \Delta t^2/2 \\ 0 & 0 & 0 & \Delta t^3 & \Delta t^2 & \Delta t \\ 0 & 0 & 0 & \Delta t^2/2 & \Delta t & 1 \end{pmatrix}$$

KalmanPaint

<https://eva.fing.edu.uy/mod/resource/view.php?id=173415>