

Estimación y Predicción en Series Temporales

Filtro de Kalman

Departamento de Procesamiento de Señales

Instituto de Ingeniería Eléctrica
Facultad de Ingeniería

2023

Biblio:

- Brown and Hwang, *Introduction to Random Signals and Applied Kalman Filtering*, 3ra edición, 1996.
- Anderson and Moore, *Optimal Filtering*, 1979 (re-edición Dover 2005).

Motivación

Recapitulación


Filtro de Wiener



Óptimo y elegante, pero no adaptivo.

Recapitulación

Filtro LMS (Widrow-Hopf)



Adaptivo y rápido, pero lento y ruidoso.

Recapitulación

Filtro RLS (vox populi)



Adaptivo, rápido y preciso, pero más costoso.

Recapitulación

Filtro de Kalman



Adaptivo, rápido, preciso, más general. Más complicado.

Filtros adaptivos clásicos (LMS, RLS)

Modelo: relación lineal entre entrada y salida:

$$\hat{\mathbf{x}}_n = \hat{\mathbf{w}}^\top \hat{\mathbf{u}}_n$$

Filtro de Kalman

El modelo es un sistema dinámico lineal

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

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

- $\mathbf{x}_n$ es el estado del sistema (no observable)
- $\mathbf{y}_n$ son sus salidas observables
- $\mathbf{w}_n, \mathbf{v}_n$ ruido en estado y observación

Filtro de Kalman

Idea principal

Dado el sistema dinámico lineal:

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

- Deseamos estimar $\mathbf{x}$
- Estimación *a priori* de $\mathbf{x}$: dinámica del sistema ($\mathbf{F}$)
- Refinamiento: incorpora información provista por $\mathbf{y}_n$.

Qué agrega el filtro de Kalman?

- Adaptivo y rápido, como RLS
- Muchísimo más general: no se limita a modelos AR/MA

Impacto Enorme

- No habría ni satélites, ni exploración espacial
- Tampoco misiles balísticos, pero bueh.
- Tracking de todo tipo (desde touchpads a GPS)

Planteo

Planteo formal

Sistema dinámico lineal

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

- $\mathbf{x}_n$ es un vector de estados del sistema
- $\mathbf{y}_n$ son observaciones del sistema
- $\mathbf{w}_n \in \mathcal{N}(0, \mathbf{Q}_n), \mathbf{v}_n \in \mathcal{N}(0, \mathbf{R}_n)$, independientes
- $\mathbf{w}_n$ y $\mathbf{v}_n$ mutuamente independientes (ortogonales)

Todo proceso ARMA puede ser modelado de esta manera

Planteo

Formulación recursiva

En el tiempo n se tiene

- Estimación a priori de $\mathbf{x}_n$, $\bar{\mathbf{x}}_n \approx \mathbb{E}[\mathbf{x}_n]$
- Covarianza de su error: $\bar{\mathbf{P}}_n \approx \mathbb{E}[\bar{\mathbf{e}}_n^T \bar{\mathbf{e}}_n]$, $\bar{\mathbf{e}}_n = \mathbf{x}_n - \bar{\mathbf{x}}_n$

Idea: refinar usando observación $\mathbf{y}_n$

$$\hat{\mathbf{x}}_n = \bar{\mathbf{x}}_n + \mathbf{K}_n(\mathbf{y}_n - \mathbf{C}_n \bar{\mathbf{x}}_n)$$

Objetivo: hallar $\mathbf{K}_n$ que minimice

$$\mathbb{E}[\|\mathbf{e}_n\|^2], \mathbf{e}_n = \mathbf{x}_n - \hat{\mathbf{x}}_n$$

La matrix $\mathbf{K}_n$ se llama **ganancia de Kalman**

Objetivo:

- Encontrar $\mathbf{K}_n$ que minimice $\mathbb{E} [\|\mathbf{e}_n\|^2]$
- Podemos reescribirlo de manera equivalente como:

$$\mathbf{K}_n = \arg \min_{\mathbf{K}} \text{Tr}(\mathbf{P}_n)$$

en donde $\mathbf{P}_n$ es la **matriz de covarianza del error efectivo**

$$\mathbf{P}_n = \mathbb{E}[\mathbf{e}_n \mathbf{e}_n^\top] = \mathbb{E}[(\mathbf{x}_n - \hat{\mathbf{x}}_n)(\mathbf{x}_n - \hat{\mathbf{x}}_n)^\top].$$

Notar que $(\mathbf{x}_n - \hat{\mathbf{x}}_n)^\top (\mathbf{x}_n - \hat{\mathbf{x}}_n) = \text{Tr}((\mathbf{x}_n - \hat{\mathbf{x}}_n)(\mathbf{x}_n - \hat{\mathbf{x}}_n)^\top)$

Objetivo: hallar $\mathbf{K}_n$ que minimice $\text{Tr}(\mathbf{P}_n)$:

$$\mathbf{P}_n = \mathbb{E}[\mathbf{e}_n \mathbf{e}_n^\top] = \mathbb{E}[(\mathbf{x}_n - \hat{\mathbf{x}}_n)(\mathbf{x}_n - \hat{\mathbf{x}}_n)^\top].$$

Tenemos:

$$\text{i) } \hat{\mathbf{x}}_n = \bar{\mathbf{x}}_n + \mathbf{K}_n(\mathbf{y}_n - \mathbf{C}_n \bar{\mathbf{x}}_n),$$

$$\text{ii) } \mathbf{y}_n = \mathbf{C}_n \mathbf{x}_n + \mathbf{v}_n.$$

Combinando i e ii:

$$\hat{\mathbf{x}}_n = \bar{\mathbf{x}}_n + \mathbf{K}_n(\mathbf{C}_n \mathbf{x}_n + \mathbf{v}_n - \mathbf{C}_n \bar{\mathbf{x}}_n)$$

Sustituyendo en el error efectivo:

$$\begin{aligned} \mathbf{e}_n &= \mathbf{x}_n - \bar{\mathbf{x}}_n - \mathbf{K}_n(\mathbf{C}_n \mathbf{x}_n + \mathbf{v}_n - \mathbf{C}_n \bar{\mathbf{x}}_n) \\ &= (\mathbf{I} - \mathbf{K}_n \mathbf{C}_n)(\mathbf{x}_n - \bar{\mathbf{x}}_n) - \mathbf{K}_n \mathbf{v}_n \\ &= (\mathbf{I} - \mathbf{K}_n \mathbf{C}_n) \bar{\mathbf{e}}_n - \mathbf{K}_n \mathbf{v}_n \end{aligned}$$

Objetivo: hallar $\mathbf{K}_n$ que minimice $\text{Tr}(\mathbf{P}_n)$:

$$\mathbf{P}_n = \mathbb{E}[\mathbf{e}_n \mathbf{e}_n^T]$$

donde

$$\mathbf{e}_n = (\mathbf{I} - \mathbf{K}_n \mathbf{C}_n) \bar{\mathbf{e}}_n - \mathbf{K}_n \mathbf{v}_n$$

Ahora: Si sustituimos la expresión de arriba y asumimos

$$(i) \mathbb{E}[\mathbf{e}^T \mathbf{v}_n^T] = 0, \quad (ii) \bar{\mathbf{P}}_n = \mathbb{E}[\bar{\mathbf{e}}_n \bar{\mathbf{e}}_n^T]$$

llegamos a:

$$\begin{aligned} \mathbb{E}[\mathbf{e}_n \mathbf{e}_n^T] &= (\mathbf{I} - \mathbf{K}_n \mathbf{C}_n) \mathbb{E}[\bar{\mathbf{e}}_n \bar{\mathbf{e}}_n^T] (\mathbf{I} - \mathbf{K}_n \mathbf{C}_n)^T + \mathbf{K}_n \mathbb{E}[\mathbf{v}_n \mathbf{v}_n^T] \mathbf{K}_n^T \\ &= (\mathbf{I} - \mathbf{K}_n \mathbf{C}_n) \bar{\mathbf{P}}_n (\mathbf{I} - \mathbf{K}_n \mathbf{C}_n)^T + \mathbf{K}_n \mathbf{R}_n \mathbf{K}_n^T \\ &= \bar{\mathbf{P}}_n - \mathbf{K}_n \mathbf{C}_n \bar{\mathbf{P}}_n - \bar{\mathbf{P}}_n^T \mathbf{C}_n^T \mathbf{K}_n^T + \mathbf{K}_n (\mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^T + \mathbf{R}_n) \mathbf{K}_n^T. \end{aligned}$$

Derivación (iv)

Queremos minimizar:

$$\text{Tr}(\mathbf{P}_n) = \text{Tr} [\bar{\mathbf{P}}_n - \mathbf{K}_n \mathbf{C}_n \bar{\mathbf{P}}_n - \bar{\mathbf{P}}_n^\top \mathbf{C}_n^\top \mathbf{K}_n^\top + \mathbf{K}_n (\mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^\top + \mathbf{R}_n) \mathbf{K}_n^\top.]$$

Como la traza es *lineal*:

$$\text{Tr}(\mathbf{P}_n) = \text{Tr} [\bar{\mathbf{P}}_n] - \text{Tr} [\mathbf{K}_n \mathbf{C}_n \bar{\mathbf{P}}_n] - \text{Tr} [\bar{\mathbf{P}}_n^\top \mathbf{C}_n^\top \mathbf{K}_n^\top] + \text{Tr} [\mathbf{K}_n (\mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^\top + \mathbf{R}_n) \mathbf{K}_n^\top.]$$

Ahora usando $\text{Tr}(\mathbf{A}^\top) = \text{Tr}(\mathbf{A})$,

$$\text{Tr}[\bar{\mathbf{P}}_n^\top \mathbf{C}_n^\top \mathbf{K}_n^\top] = \text{Tr}[\mathbf{K}_n \mathbf{C}_n \bar{\mathbf{P}}_n] :$$

$$\text{Tr}(\mathbf{P}_n) = \text{Tr} [\bar{\mathbf{P}}_n] - 2\text{Tr} [\mathbf{K}_n \mathbf{C}_n \bar{\mathbf{P}}_n] + \text{Tr} [\mathbf{K}_n (\mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^\top + \mathbf{R}_n) \mathbf{K}_n^\top.]$$

Para hallar el $\mathbf{K}_n$ óptimo, basta derivar e igualar a cero:

$$\frac{\partial \text{Tr}(\mathbf{P}_n)}{\partial \mathbf{K}_n} = 0$$

Derivación (v)

Tenemos que hallar $\mathbf{P}_n$ tal que:

$$\begin{aligned} \frac{\partial \text{Tr}(\mathbf{P}_n)}{\partial \mathbf{K}_n} &= \frac{\partial \text{Tr}[\bar{\mathbf{P}}_n]}{\partial \mathbf{K}_n} - 2 \frac{\partial \text{Tr}[\mathbf{K}_n \mathbf{C}_n \bar{\mathbf{P}}_n]}{\partial \mathbf{K}_n} \\ &\quad + \frac{\partial \text{Tr}[\mathbf{K}_n (\mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^\top + \mathbf{R}_n) \mathbf{K}_n^\top]}{\partial \mathbf{K}_n} = 0 \end{aligned}$$

Ahora usamos las siguientes propiedades:

$$\frac{\partial}{\partial \mathbf{A}} \text{Tr}[\mathbf{AB}] = \mathbf{B}^\top \quad \frac{\partial}{\partial \mathbf{A}} \text{Tr}[\mathbf{ACA}^\top] = 2\mathbf{AC}$$

con $\mathbf{A}, \mathbf{B}$ cuadradas y $\mathbf{C}$ simétrica. Llegamos a:

$$\frac{\partial \text{Tr}(\mathbf{P}_n)}{\partial \mathbf{K}_n} = -2\bar{\mathbf{P}}_n^\top \mathbf{C}_n^\top + 2\mathbf{K}_n (\mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^\top + \mathbf{R}_n) = 0$$

Finalmente despejamos (usando $\mathbf{P}_n^\top = \mathbf{P}_n$):

$$\mathbf{K}_n = \bar{\mathbf{P}}_n \mathbf{C}_n^\top (\mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^\top + \mathbf{R}_n)^{-1}$$

Una vez hallado:

$$\mathbf{K}_n = \bar{\mathbf{P}}_n \mathbf{C}_n^\top (\mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^\top + \mathbf{R}_n)^{-1}$$

Podemos sustituirlo en la expresión de $\mathbf{P}_n$:

$$\mathbf{P}_n = (\mathbf{I} - \mathbf{K}_n \mathbf{C}_n) \bar{\mathbf{P}}_n (\mathbf{I} - \mathbf{K}_n \mathbf{C}_n)^\top + \mathbf{K}_n \mathbf{R}_n \mathbf{K}_n^\top$$

Luego de unas cuentas sencillas llegamos a:

$$\mathbf{P}_n = (\mathbf{I} - \mathbf{K}_n \mathbf{C}_n) \bar{\mathbf{P}}_n$$

Paso predictivo

- Asumimos conocidas las predicciones $\bar{\mathbf{x}}_n, \bar{\mathbf{P}}_n$
- Resta actualizarlas para usar en el paso $n + 1$, $\bar{\mathbf{x}}_{n+1}$
- Predecimos $\bar{\mathbf{x}}_n$ como su valor esperado dado $\hat{\mathbf{x}}_n$:

$$\bar{\mathbf{x}}_{n+1} = \mathbb{E}[\mathbf{x}_{n+1} \mid \hat{\mathbf{x}}_n] = \mathbf{F}_n \hat{\mathbf{x}}_n$$

porque $\mathbf{w}_n$ es blanco y de media nula.

- Ahora la covarianza del error de predicción:

$$\begin{aligned}\bar{\mathbf{e}}_{n+1} &= \mathbf{x}_{n+1} - \bar{\mathbf{x}}_{n+1} = (\mathbf{F}_n \mathbf{x}_n + \mathbf{w}_n) - \mathbf{F}_n \hat{\mathbf{x}}_n \\ &= \mathbf{F}_n \mathbf{e}_n + \mathbf{w}_n\end{aligned}$$

Luego,

$$\begin{aligned}\bar{\mathbf{P}}_{n+1} &= \mathbb{E}[\bar{\mathbf{e}}_{n+1} \bar{\mathbf{e}}_{n+1}^\top] \\ &= \mathbb{E}[(\mathbf{F}_n \mathbf{e}_n + \mathbf{w}_n)(\mathbf{F}_n \mathbf{e}_n + \mathbf{w}_n)^\top] \\ &= \mathbf{F}_n \mathbf{P}_n \mathbf{F}_n^\top + \mathbf{Q}_n\end{aligned}$$

Modelo

$$\begin{aligned}\mathbf{x}_{n+1} &= \mathbf{F}_n \mathbf{x}_n + \mathbf{R}_n \mathbf{w}_n \\ \mathbf{y}_n &= \mathbf{C}_n \mathbf{x}_n + \mathbf{Q}_n \mathbf{v}_n\end{aligned}$$

Inicialización

$$\bar{\mathbf{x}}_0, \quad \bar{\mathbf{P}}_0$$

Recursión

- 1 Ganancia de Kalman: $\mathbf{K}_n = \bar{\mathbf{P}}_n \mathbf{C}_n^T (\mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^T + \mathbf{R}_n)^{-1}$
- 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 $n + 1$:

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

Filtro de Kalman

Esquema recursivo

