

Estimación y Predicción en Series Temporales

Kalman optimalidad, extensiones

Departamento de Procesamiento de Señales

Instituto de Ingeniería Eléctrica
Facultad de Ingeniería

2023

Optimalidad MMSE del filtro de Kalman

- Por definición, Kalman es óptimo en sentido MSE
- Veremos que es óptimo cuando el ruido es Gaussiano

Esperanza condicional

- Sean $\mathcal{Y}_n = \{\mathbf{y}_0, \mathbf{y}_1, \dots, \mathbf{y}_{n-1}\}$ las obs. hasta el tiempo n
- Consideremos el MSE condicionado a \mathbf{y}_n ,

$$\mathbb{E}[\mathbf{e}_n^H \mathbf{e}_n | \mathcal{Y}_n], \quad \mathbf{e}_n = \mathbf{x}_n - \hat{\mathbf{x}}_n$$

- La idea es encontrar el estimador $\hat{\mathbf{x}}_n$ que la minimice

Minimización de la esperanza condicional

$$\begin{aligned}\mathbb{E}[\mathbf{e}_n^H \mathbf{e}_n | \mathcal{Y}_n] &= \mathbb{E}[(\mathbf{x}_n - \hat{\mathbf{x}}_n)^H (\mathbf{x}_n - \hat{\mathbf{x}}_n) | \mathcal{Y}_n] \\ &= \mathbb{E}[\mathbf{x}_n^H \mathbf{x}_n - \mathbf{x}_n^H \hat{\mathbf{x}}_n - \hat{\mathbf{x}}_n^H \mathbf{x}_n + \hat{\mathbf{x}}_n^H \hat{\mathbf{x}}_n | \mathcal{Y}_n].\end{aligned}$$

Ahora aplicamos la linealidad de $\mathbb{E}[\cdot]$.

Como $\hat{\mathbf{x}}_n$ queda determinado por \mathcal{Y}_n , $\mathbb{E}[\hat{\mathbf{x}}_n | \mathcal{Y}_n] = \hat{\mathbf{x}}_n$ y tenemos:

$$\mathbb{E}[\mathbf{e}_n^H \mathbf{e}_n | \mathcal{Y}_n] = \mathbb{E}[\mathbf{x}_n^H \mathbf{x}_n | \mathcal{Y}_n] - \mathbb{E}[\mathbf{x}_n^H | \mathcal{Y}_n] \hat{\mathbf{x}}_n - \hat{\mathbf{x}}_n^H \mathbb{E}[\mathbf{x}_n | \mathcal{Y}_n] + \hat{\mathbf{x}}_n^H \hat{\mathbf{x}}_n$$

Para minimizarla, derivamos en $\hat{\mathbf{x}}_n$ e igualamos a 0:

$$0 = -2\mathbb{E}[\mathbf{x}_n^H | \mathcal{Y}_n] + 2\hat{\mathbf{x}}_n \Rightarrow \hat{\mathbf{x}}_n = \mathbb{E}[\mathbf{x}_n | \mathcal{Y}_n]$$

Esta fórmula es general para cualquier estimador MMSE, indep. del modelo y las densidades de los ruidos.

Supongamos

- $\bar{\mathbf{x}}_n$ es cond. óptimo en sentido MSE dado \mathcal{Y}_n
- Su matriz de covarianza es $\bar{\mathbf{P}}_n$

Entonces, por def. del MMSE:

$$f_{\mathbf{x}_n|\mathcal{Y}_n}(\mathbf{x}_n) = \mathcal{N}(\hat{\mathbf{x}}_n, \bar{\mathbf{P}}_n)$$

Al medir tenemos:

$$\mathbf{y}_n = \mathbf{C}_n \mathbf{x}_n + \mathbf{v}_n \Rightarrow f_{\mathbf{y}_n|\mathbf{x}_n}(\mathbf{y}_n) = \mathcal{N}(\mathbf{C}_n \mathbf{x}_n, \mathbf{R}_n)$$

Si, en lugar de \mathbf{x}_n , condicionamos respecto a $\bar{\mathbf{x}}_n$:

$$f_{\mathbf{y}_n|\bar{\mathbf{x}}_n}(\mathbf{y}_n) = \mathcal{N}(\mathbf{C}_n \bar{\mathbf{x}}_n, \mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^H + \mathbf{R}_n)$$

que refleja el ruido adicional debido a usar $\bar{\mathbf{x}}_n$ en lugar de \mathbf{x}_n .

Fórmula de de Bayes

Nos interesa el estimador óptimo luego (a posteriori) de observar y_n :

$$f_{\mathbf{x}_k | \mathcal{Y}_n, y_n} = \frac{f_{y_n | \mathbf{x}_n, \mathcal{Y}_n} \cdot f_{\mathbf{x}_n | \mathcal{Y}_n}}{f_{y_n | \mathcal{Y}_n}} = \frac{f_{y_n | \mathbf{x}_n} \cdot f_{\mathbf{x}_n | \mathcal{Y}_n}}{f_{y_n | \bar{\mathbf{x}}_n}}$$

Lo anterior surge de:

- y_n es cond. indep. de \mathcal{Y}_n dado \mathbf{x}_n
- y_n es cond. indep. de \mathcal{Y}_n dado $\bar{\mathbf{x}}_n$

Tenemos

$$f_{\mathbf{x}_n|\mathcal{Y}_n, \mathbf{y}_n} = \frac{f_{\mathbf{y}_n|\mathbf{x}_n} \cdot f_{\mathbf{x}_n|\mathcal{Y}_n}}{f_{\mathbf{y}_n|\bar{\mathbf{x}}_n}}$$

$$f_{\mathbf{x}_n}(\mathbf{x}_n|\mathcal{Y}_n) = \mathcal{N}(\hat{\mathbf{x}}_n, \bar{\mathbf{P}}_n)$$

$$f_{\mathbf{y}_n|\mathbf{x}_n}(\mathbf{y}_n) = \mathcal{N}(\mathbf{C}_n \mathbf{x}_n, \mathbf{R}_n)$$

$$f_{\mathbf{y}_n|\bar{\mathbf{x}}_n}(\mathbf{y}_n) = \mathcal{N}(\mathbf{C}_n \bar{\mathbf{x}}_n, \mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^H + \mathbf{R}_n)$$

Sustituyendo y haciendo cuentas, se llega a:

$$\hat{\mathbf{x}}_n = \mathbb{E}[\mathbf{x}_n|\mathcal{Y}_n] = \bar{\mathbf{x}}_n + \bar{\mathbf{P}}_n \mathbf{C}_n^H (\mathbf{C}_n \bar{\mathbf{P}}_n \mathbf{C}_n^H + \mathbf{R}_n)^{-1} (\mathbf{y}_n - \mathbf{C}_n \bar{\mathbf{x}}_n)$$

$$\mathbf{P}_n = \text{Cov}[\mathbf{x}_n|\mathcal{Y}_n] = (\bar{\mathbf{P}}_n^{-1} + \mathbf{C}_n^H \mathbf{R}_n^{-1} \mathbf{C}_n)^{-1}$$

- La expresión de \hat{x}_n es idéntica a la de Kalman.
- Se puede demostrar que la covarianza del error también es equivalente a la de Kalman.
- **No se impuso que el filtro fuese lineal!**
- Eso surgió naturalmente de suponer:
 - ruidos Gaussianos
 - que el estimado sea la esperanza condicional

Conclusión:

En el caso Gaussiano, los filtros de Kalman/Wiener son óptimos aún incluyendo los filtros no-lineales

Kalman para sistemas dinámicos no lineales

Modelo lineal

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

En este caso:

- Ruido arbitrario: Kalman es el filtro lineal óptimo en sentido MMSE
- Ruido Gaussiano: Kalman es **universalmente óptimo** en sentido MMSE
- El modelo lineal incluye a los ARMA

Consideremos el modelo dinámico no lineal:

$$\begin{aligned}\mathbf{x}_{n+1} &= \mathbf{f}_n(\mathbf{x}_n, \mathbf{v}_n) \\ \mathbf{y}_n &= \mathbf{h}_n(\mathbf{x}_n, \mathbf{w}_n)\end{aligned}$$

Qué se puede hacer en este caso?

- Extended Kalman Filter (EKF):
 - 1 linearizar modelo en tiempo n
 - 2 aplicar Kalman al modelo resultante
- Unscented Kalman Filter (UKF):
 - 1 mapeo no lineal de medias y matrices de covarianza
 - 2 Estimaciones: ponderación de muchos puntos
- El EKF es trivial; el UKF es más complicado

Extended Kalman Filter

El filtro de Kalman Extendido (EKF)

La linealización

Modelo no lineal:

$$\begin{aligned}\mathbf{x}_{n+1} &= \mathbf{f}_n(\mathbf{x}_n, \mathbf{v}_n) \\ \mathbf{y}_n &= \mathbf{h}_n(\mathbf{x}_n, \mathbf{w}_n)\end{aligned}$$

Linearización

- Ecuación de estado: entorno a $(\mathbf{x}, \mathbf{v}) = (\hat{\mathbf{x}}_n, 0)$.
- Ecuación de medida: entorno a $(\mathbf{x}, \mathbf{w}) = (\bar{\mathbf{x}}_n, 0)$.

$$\begin{aligned}\mathbf{x}_{n+1} &= \mathbf{f}_n(\hat{\mathbf{x}}_n, 0) + \mathbf{F}_n(\mathbf{x}_n - \hat{\mathbf{x}}_n) + \mathbf{G}_n \mathbf{v}_n \\ \mathbf{y}_n &= \mathbf{h}_n(\bar{\mathbf{x}}_n, 0) + \mathbf{H}_n(\mathbf{x}_n - \bar{\mathbf{x}}_n) + \mathbf{U}_n \mathbf{w}_n,\end{aligned}$$

donde

$$\begin{aligned}\mathbf{F}_n &= \frac{\partial \mathbf{f}_n}{\partial \mathbf{x}}(\hat{\mathbf{x}}_n, 0), & \mathbf{G}_n &= \frac{\partial \mathbf{f}_n}{\partial \mathbf{v}}(\hat{\mathbf{x}}_n, 0), \\ \mathbf{H}_n &= \frac{\partial \mathbf{h}_n}{\partial \mathbf{x}}(\bar{\mathbf{x}}_n, 0), & \mathbf{U}_n &= \frac{\partial \mathbf{h}_n}{\partial \mathbf{w}}(\bar{\mathbf{x}}_n, 0).\end{aligned}$$

El filtro de Kalman Extendido (EKF)

Algoritmo

- Inicialización: $\mathbf{x}_0, \mathbf{P}_0$.
- Para $n = 0, 1, 2, \dots$, calcular:

$$\bar{\mathbf{x}}_n = \mathbf{f}_n(\hat{\mathbf{x}}_{n-1}, 0)$$

$$\bar{\mathbf{P}}_n = \mathbf{F}_n \hat{\mathbf{P}}_{n-1} \mathbf{F}_n^T + \mathbf{G}_n \mathbf{Q}_n \mathbf{G}_n^T$$

$$\mathbf{K}_n = \bar{\mathbf{P}}_n \mathbf{H}_n^T (\mathbf{H}_n \bar{\mathbf{P}}_n \mathbf{H}_n^T + \mathbf{U}_n \mathbf{R}_n \mathbf{U}_n^T)^{-1}$$

$$\hat{\mathbf{x}}_n = \bar{\mathbf{x}}_n + \mathbf{K}_n (\mathbf{y}_n - \mathbf{h}_n(\bar{\mathbf{x}}_n, 0))$$

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

Observaciones

- Problema (i): linealización introduce un sesgo en $\hat{\mathbf{x}}_{n|k}$
- Problema (ii): linealización produce covarianza errónea
- Cuanto menor sean $\|\mathbf{x} - \hat{\mathbf{x}}_n\|^2$ y $\|\mathbf{x} - \bar{\mathbf{x}}_n\|^2$, mejor
- Es de esperar que el EKF sea mejor si SNR es alto
- Ver [Anderson & Moore] para más detalles

Unscented Kalman Filter

Julier & Uhlmann 1996

Unscented Kalman Filter (UKF)

Premisa

- Evitar linearización (y sus sesgos)
- Aproximar $\hat{\mathbf{y}}$ y \mathbf{P}_y de manera *insesgada*
- Capturar geometría de $\mathbf{h}(\cdot)$, $\mathbf{f}(\cdot)$ mediante muestreo
- El muestreo es *determinístico*
- Se elige de manera de preservar estadísticas relevantes

Unscented Kalman Filter (UKF)

Estrategia

- Se asume $\mathbf{x} \sim \mathcal{N}(\bar{\mathbf{x}}, \mathbf{P}_{\mathbf{x}})$
- Se eligen $2n + 1$ puntos $\mathcal{X}_0, \mathcal{X}_1, \dots, \mathcal{X}_{2n+1}$ tales que su covarianza empírica igual a la covarianza de \mathbf{x}
 - estos son llamados σ -puntos
 - Cada punto tiene un peso W_i
- Se obtienen $2n + 1$ puntos $\mathcal{Y}_i = \mathbf{h}(\mathcal{X}_i)$
- Se calculan media y covarianza empíricas:

$$\bar{\mathbf{y}} = \sum_i W_i \mathcal{Y}_i$$

$$\mathbf{P}_{\mathbf{y}} = \sum_i W_i (\mathcal{Y}_i - \bar{\mathbf{y}})(\mathcal{Y}_i - \bar{\mathbf{y}})^T$$

- Éstas se insertan en las ecuaciones de Kalman

Unscented Kalman Filter (UKF)

Estrategia (cont.)

- A los efectos del muestreo, se considera la variable conjunta $\mathbf{x}^a = [\mathbf{x}, \mathbf{v}, \mathbf{w}]$, cuya varianza es:

$$\mathbf{P}^a = \begin{bmatrix} \hat{\mathbf{P}}_{n-1} & 0 & 0 \\ 0 & \mathbf{Q}_n & 0 \\ 0 & 0 & \mathbf{R}_n \end{bmatrix}$$

- Los puntos \mathcal{X}_i se toman en base a \mathbf{P}_n^a
- Luego se desarma $\mathcal{X}_i = [\mathcal{X}_i^x, \mathcal{X}_i^v, \mathcal{X}_i^w]$

Unscented Kalman Filter (UKF)

Algoritmo

- 1 Inicialización: $\hat{\mathbf{x}}_{n-1}, \hat{\mathbf{P}}_{n-1}$
- 2 Para $n = 1, 2, \dots$

$$\mathcal{X}_i = [\mathcal{X}_i^x, \mathcal{X}_i^v, \mathcal{X}_i^w] \quad i = 0, \dots, 2n \quad (\sigma - \text{puntos})$$

$$\bar{\mathcal{X}}_i^x = \mathbf{f}_n(\mathcal{X}_i^x, \mathcal{X}_i^v); \quad \bar{\mathbf{x}}_n = \sum_i W_i \bar{\mathcal{X}}_i^x$$

$$\bar{\mathbf{P}}_n^x = \sum_i W_i (\bar{\mathcal{X}}_i^x - \bar{\mathbf{x}}_n)(\bar{\mathcal{X}}_i^x - \bar{\mathbf{x}}_n)^T$$

$$\bar{\mathcal{Y}}_i = \mathbf{h}(\bar{\mathcal{X}}_i^x, \bar{\mathcal{X}}_i^w); \quad \bar{\mathbf{y}}_n = \sum_i W_i \bar{\mathcal{Y}}_i$$

$$\bar{\mathbf{P}}_n^y = \sum_i W_i (\bar{\mathcal{Y}}_i - \bar{\mathbf{y}}_n)(\bar{\mathcal{Y}}_i - \bar{\mathbf{y}}_n)^T$$

$$\bar{\mathbf{P}}_n^{xy} = \sum_i W_i (\bar{\mathcal{X}}_i^x - \bar{\mathbf{x}}_n)(\bar{\mathcal{Y}}_i - \bar{\mathbf{y}}_n)^T$$

$$\mathbf{K}_n = \bar{\mathbf{P}}_n^{xy} (\bar{\mathbf{P}}_n^y)^{-1}$$

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

$$\hat{\mathbf{P}}_n = \bar{\mathbf{P}}_n - \mathbf{K}_n \bar{\mathbf{P}}_n^y \mathbf{K}_n^T.$$

UKF: elección de los σ -puntos

- Sup. $\mathbf{x} \in \mathbb{R}^n$, $\mathbf{x} \sim \mathcal{N}(\bar{\mathbf{x}}, \mathbf{P}_x)$.
- Sea \mathbf{L} una factorización de \mathbf{P}_x : $\mathbf{P}_x = \mathbf{L}\mathbf{L}^\top$ (ej. Cholesky)
- Sea $\kappa > 0$ un escalar a elegir

Los σ -puntos y sus pesos se definen como:

$$\begin{aligned}\mathcal{X}_0 &= \bar{\mathbf{x}} & W_0 &= \frac{\kappa}{\kappa + n} \\ \mathcal{X}_{2i-1} &= \bar{\mathbf{x}} - \sqrt{\kappa + n} \cdot \mathbf{L}_i & W_{2i-1} &= W_{2i} = \frac{1}{2(\kappa + n)} \\ \mathcal{X}_{2i} &= \bar{\mathbf{x}} + \sqrt{\kappa + n} \cdot \mathbf{L}_i & i &= 1, \dots, n.\end{aligned}$$

donde \mathbf{L}_i es la i -ésima columna de \mathbf{L} .

Justificación:

Se puede ver que con esta elección la media y covarianza empíricas de $\bar{\mathcal{Y}}$ coinciden con las de $\bar{\mathbf{y}}$ hasta **tercer orden**.