

# Mínimos Cuadrados Recursivos con Olvido

Antonio Sala Piqueras

Dept. Ing. Sistemas y Automatica (DISA)  
**Universitat Politècnica de València (UPV)**

Presentación vídeo en:  
<http://personales.upv.es/asala/YT/V/mcr2.html>

# Introducción, Motivación, Objetivos

**Motivación:** Aplicaciones donde es necesario identificar unos parámetros cambiantes (detección de fallos, control adaptativo).

**Objetivos:** Comprender las situaciones prácticas donde los algoritmos recursivos con olvido son necesarias; entender la derivación de las fórmulas correspondientes.

**Contenidos:** Fórmulas con factor de olvido; Filtro de Kalman; motivación en aplicaciones.

# Mínimos cuadrados recursivos con olvido: Motivación

- Fórmulas sin olvido: refinar un estimado previo en media e intervalo de confianza (p. ej., modelo teórico + tolerancias) con datos.
  - Siempre se **reduce** el intervalo de confianza (aumenta precisión).
  - Inspirado en fórmula de Bayes (incorporando probabilidad *a priori*).
- La aplicación a sistemas *variantes en el tiempo* requiere un “olvido” de información antigua.
  - El intervalo de confianza no siempre se reduce, depende de cuánta información pasada se olvida y cómo de informativos son los nuevos datos.
  - **Nota:** Ello podría resultar problemático si los últimos datos son poco informativos.

# Revisión: Mínimos cuadrados recursivos sin olvido

Supongamos que de datos anteriores (o tolerancias de componentes) disponemos de un estimado previo (**media** y **varianza**):

$$\theta = \mathcal{N}(\hat{\theta}_0, \Sigma_{\theta,0})$$

**Objetivo:** conocida la distribución **a priori** de  $\theta$ , calcular la mejor predicción de  $\theta$  a partir de dicha información a priori y una nueva serie de datos  $(y, X)$ , supuesto modelo  $y = X\theta + v$ .

**Mejor predicción** incorporando nueva información:

\***media:** 
$$\hat{\theta}_1 = \hat{\theta}_0 + \Sigma_{\theta,0} X^T (X \Sigma_{\theta,0} X^T + V)^{-1} (y - X \hat{\theta}_0)$$

\***varianza:** 
$$\Sigma_{\theta,1} = \Sigma_{\theta,0} - \Sigma_{\theta,0} X^T (X \Sigma_{\theta,0} X^T + V)^{-1} X \Sigma_{\theta,0}$$

**Interpretación alternativa:** Filtro de Kalman para  $\theta_{k+1} = \theta_k$  (ec. estado) junto con  $y_k = X_k \theta_k + v$  (ec. salida).

# Mínimos cuadrados recursivos con olvido

En uso “en línea” (control adaptativo), conveniente olvidar datos pasados. Alternativas (entre otras):

- 1 Hacer mínimos cuadrados sin olvido, pero con una “**ventana**” fija de datos pasados.
- 2 Factor de olvido  $\lambda < 1$ , multiplicar  $\Sigma_{\theta,i}$  por  $\lambda^{-1}$  para la siguiente iteración (p.ej.,  $\lambda \approx 0.999$ ), **subiendo** la varianza a priori.
- 3 Suponer **dinámica** de los parámetros y hacer filtro de Kalman **completo**:

$$\theta_{k+1} = H\theta_k + w_k$$

$$y_k = X_k\theta_k + v_k$$

- Por ejemplo,  $H = I$  (paseo aleatorio),  $H = 0.998I$  parámetros tendiendo a un pto. funcionamiento.

Detalles en siguiente transparencia...

# Fórmula recursivas con “olvido”

Fórmula sin olvido original:

$$\begin{aligned}
 \text{*media:} \quad & \hat{\theta}_1 = \hat{\theta}_0 + \Sigma_{\theta,0} X^T (X \Sigma_{\theta,0} X^T + V)^{-1} (y - X \hat{\theta}_0) \\
 \text{*varianza:} \quad & \Sigma_{\theta,1} = \Sigma_{\theta,0} - \Sigma_{\theta,0} X^T (X \Sigma_{\theta,0} X^T + V)^{-1} X \Sigma_{\theta,0}
 \end{aligned}$$

[1] **Kalman:** Si suponemos que  $\theta$  en el siguiente instante verifica  $\theta_1 = H\theta_0 + w$ , con matriz de varianzas  $E(w w^T) = W$ , entonces debe sustituirse la “varianza antes de medir”  $\Sigma_{\theta,0}$  por  $\hat{S}_{\theta,1} := H \Sigma_{\theta,0} H^T + W$   
 $E[\theta_1 \theta_1^T] = E(H \theta_0 \theta_0^T H^T + H \theta_0 w^T + w \theta_0^T H^T + w^T w)$

Sin olvido, caso particular  $W = 0, H = I \Rightarrow \hat{S}_{\theta,1} = \Sigma_{\theta,0}$

[2] **Factor de olvido  $\lambda \leq 1$ :** Aumentar la incertidumbre del siguiente estado (conservar sólo parte de la información):  $\hat{S}_{\theta,1} = \lambda^{-1} \cdot \Sigma_{\theta,0} \geq \Sigma_{\theta,0}$ .

|                        | Kalman   | / | Olvido exponencial  |
|------------------------|--|---|---|
| *Variación parámetros: | $\hat{S}_{\theta,1} = H \Sigma_{\theta,0} H^T + W$   |   | $\hat{S}_{\theta,1} = \lambda^{-1} \Sigma_{\theta,0} \quad H = I$ |
| *media:                | $\hat{\theta}_1 = H \hat{\theta}_0 + \hat{S}_{\theta,1} X^T (X \hat{S}_{\theta,1} X^T + V)^{-1} (y - X H \hat{\theta}_0)$  |   |   |
| *varianza:             | $\Sigma_{\theta,1} = \hat{S}_{\theta,1} - \hat{S}_{\theta,1} X^T (X \hat{S}_{\theta,1} X^T + V)^{-1} X \hat{S}_{\theta,1}$ |   |   |

# Conclusiones

- Los algoritmos recursivos de mínimos cuadrados incorporan información de nuevos datos junto a a información “a priori”.
- Fórmulas con olvido /ruido de parámetros para uso “en línea” en sistemas variantes con el tiempo.
- Aplicaciones a monitorización, diagnóstico, control adaptativo.