

# Mínimos Cuadrados Recursivos: relación con fórmulas clásicas pseudoinversa

Antonio Sala Piqueras

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

Vídeo-presentación en:  
<http://personales.upv.es/asala/YT/V/mcmr.html>

# Introducción, Motivación, Objetivos

**Motivación:** Los mínimos cuadrados “clásicos” se basan en pseudoinversa. Los recursivos tienen una fórmula aparentemente diferente.

**Objetivos:** Comprender la relación con los mínimos cuadrados clásicos no recursivos: equivalentes si incertidumbre inicial tiende a infinito.

**Contenidos:** Relación mínimos cuadrados recursivos y no recursivos: lema de inversión de matrices.

# Revisión: Mínimos cuadrados recursivos sin olvido

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  $(y, X)$ :

\***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).

## Relación con mínimos cuadrados “clásicos”

Sin información previa, fórmula no recursiva  $\hat{\theta} = X^\dagger y = (X^T X)^{-1} X^T y$ .

Escalando a  $V = I$  (normalización), consideramos la ganancia del corrector  $K = \Sigma_{\theta,0} X^T (X \Sigma_{\theta,0} X^T + I)^{-1}$ . Aplicamos el lema de inversión de matrices:

<http://www.ee.ic.ac.uk/hp/staff/dmb/matrix/identity.html>:

$$K = \Sigma_{\theta,0} X^T (I + X \Sigma_{\theta,0} X^T)^{-1} = (\Sigma_{\theta,0}^{-1} + X^T X)^{-1} X^T$$

$$\begin{aligned} \text{*Demostración: } (\Sigma_{\theta,0}^{-1} + X^T X) \Sigma_{\theta,0} X^T &= X^T + X^T X \Sigma_{\theta,0} X^T = X^T (I + X \Sigma_{\theta,0} X^T) \\ \Sigma_{\theta,0} X^T &= (\Sigma_{\theta,0}^{-1} + X^T X)^{-1} X^T (I + X \Sigma_{\theta,0} X^T) \\ \Sigma_{\theta,0} X^T (I + X \Sigma_{\theta,0} X^T)^{-1} &= (\Sigma_{\theta,0}^{-1} + X^T X)^{-1} X^T \end{aligned}$$

► Si la varianza inicial  $\Sigma_{\theta,0}$  tiende a **infinito** (desconocimiento total a priori), entonces  $\Sigma_{\theta,0}^{-1} \rightarrow 0$ , y  $K \rightarrow (X^T X)^{-1} X^T$  es la pseudoinversa usual.

Entonces da igual la media  $\hat{\theta}_0$  elegida, porque  $\hat{\theta}_1$  no depende de ella:

$$\hat{\theta}_1 = \hat{\theta}_0 + (X^T X)^{-1} X^T (y - X \hat{\theta}_0) = (X^T X)^{-1} X^T y$$

# Conclusiones

- Los algoritmos recursivos de mínimos cuadrados incorporan información de nuevos datos junto a a información “a priori” .
- Reducen a mínimos cuadrados no recursivos si varianza inicial a priori fuera infinita.