

Estimación paramétrica

Planteamiento del problema

- **Parámetro a estimar:** θ

- **Vector de observaciones:** $\mathbf{x} = [x[0] \ x[1] \ \dots \ x[N-1]]^T$

Un vector de observaciones es una realización de un vector aleatorio \mathbf{X} que depende, de alguna forma, del parámetro a estimar θ .

- **Modelo**

Define la dependencia de \mathbf{X} con θ . Dos posibilidades

- Ecuación de medida: Muestra explícitamente la dependencia de las observaciones con θ .
- Función densidad de probabilidad de \mathbf{X} dependiente de θ : $f_{\mathbf{X}}(\mathbf{x}; \theta)$

- **Estimador**

Función que proporciona una estima de θ en función del vector de observaciones: $\hat{\theta}(\mathbf{x})$. Como las observaciones son realizaciones de un vector aleatorio \mathbf{X} , un estimador es una variable aleatoria:

- Media: $E[\hat{\theta}]$
- Varianza: $\text{Var}[\hat{\theta}]$

- **Prestaciones de un estimador**

- Sesgo: $b(\hat{\theta}) = E[\hat{\theta}] - \theta$
- Varianza: $\text{Var}(\hat{\theta}) = E[(\hat{\theta} - E[\hat{\theta}])^2]$
- MSE: $MSE(\hat{\theta}) = E[(\hat{\theta} - \theta)^2] = \text{Var}(\hat{\theta}) + b(\hat{\theta})^2$

En general son función del valor de θ .

- **Generalización a la estima de varios parámetros**

$$\boldsymbol{\theta} = [\theta_1 \ \theta_2 \ \dots \ \theta_p]^T \implies \hat{\boldsymbol{\theta}}(\mathbf{x}) = [\hat{\theta}_1(\mathbf{x}) \ \hat{\theta}_2(\mathbf{x}) \ \dots \ \hat{\theta}_p(\mathbf{x})]^T$$



Estimadores de máxima verosimilitud (ML)

- **Función de verosimilitud**

Sea el modelo definido por la f.d.p. del vector de observaciones: $f_{\mathbf{X}}(\mathbf{x}; \theta)$.

Dado un vector de observaciones \mathbf{x} , la función de verosimilitud se obtiene sustituyendo el vector de observaciones en la f.d.p.:

$$L(\theta) = f_{\mathbf{X}}(\mathbf{x}; \theta)$$

Es una función de los parámetros a estimar θ . Distintos vectores de observaciones dan lugar a distintas funciones de verosimilitud.

- **Estimador ML**

Dada una observación \mathbf{x} , la estima de máxima verosimilitud es el valor de θ que maximiza la función de verosimilitud

$$\hat{\theta}_{ML}(\mathbf{x}) = \underset{\theta}{\operatorname{argmax}} L(\theta)$$

- **Propiedades de los estimadores ML**

- Son asintóticamente insesgados: $\lim_{N \rightarrow \infty} E[\hat{\theta}_{ML}] = \theta$
- Son asintóticamente Gaussianos: $\hat{\theta}_{ML} \sim \mathcal{N}(\theta, I^{-1}(\theta))$, $[I((\theta))]_{i,j} = -E \left[\frac{\partial^2 \log f_{\mathbf{X}}(\mathbf{x}; \theta)}{\partial \theta_i \partial \theta_j} \right]$
- Propiedad de invarianza: $\alpha = h(\theta) \Rightarrow \hat{\alpha}_{ML} = h(\hat{\theta}_{ML})$

Estimadores de mínimos cuadrados (LS)

- **Modelo:**

$$x[n] = s(n; \boldsymbol{\theta}) + r[n], \quad n = 0, 1, \dots, N-1,$$

donde $r[n]$ es ruido blanco y $s(n; \boldsymbol{\theta})$ es una función determinista.

En forma vectorial, $\mathbf{x} = \mathbf{s}(\boldsymbol{\theta}) + \mathbf{r}$, donde

$$\mathbf{x} = \begin{bmatrix} x[0] \\ x[1] \\ \vdots \\ x[N-1] \end{bmatrix}, \quad \mathbf{s}(\boldsymbol{\theta}) = \begin{bmatrix} s(0; \boldsymbol{\theta}) \\ s(1; \boldsymbol{\theta}) \\ \vdots \\ s(N-1; \boldsymbol{\theta}) \end{bmatrix}, \quad \mathbf{r} = \begin{bmatrix} r[0] \\ r[1] \\ \vdots \\ r[N-1] \end{bmatrix}$$

- **Función de coste:**

$$J(\boldsymbol{\theta}) = \sum_{n=0}^{N-1} |x[n] - s(n; \boldsymbol{\theta})|^2 = \|\mathbf{x} - \mathbf{s}(\boldsymbol{\theta})\|^2.$$

- **Estimador LS:**

$$\hat{\boldsymbol{\theta}}_{LS}(\mathbf{x}) = \underset{\boldsymbol{\theta}}{\operatorname{argmin}} J(\boldsymbol{\theta})$$

- **Propiedades:**

- No es necesario conocer la distribución del ruido.
- Si $r[n]$ es WGN con varianza conocida, $\hat{\boldsymbol{\theta}}_{LS}(\mathbf{x}) = \hat{\boldsymbol{\theta}}_{ML}(\mathbf{x})$.

- **Estimadores LS en modelo lineal**

- Modelo lineal: $\mathbf{s}(\boldsymbol{\theta}) = \mathbf{S} \boldsymbol{\theta}$
- $\hat{\boldsymbol{\theta}}_{LS}(\mathbf{x}) = (\mathbf{S}^T \mathbf{S})^{-1} \mathbf{S}^T \mathbf{x} = \mathbf{S}^\# \mathbf{x}$.
- Casos particulares:
 - Si las columnas de \mathbf{S} son ortogonales con norma α , $\mathbf{S}^\# = \frac{1}{\alpha^2} \mathbf{S}^T$.
 - Si $p = 1$, $\mathbf{S}^\# = \frac{1}{\alpha^2} \mathbf{s}^T$