

Un Programa de Síntesis para la Enseñanza de la Estadística Matemática

José-Miguel Bernardo

Universitat de València

<jose.m.bernardo@uv.es>

<http://www.uv.es/~bernardo>

27 Congreso Nacional de Estadística e I. O.

Lleida, 8 de Abril, 2003

Contenido

1. *Introducción a la teoría de decisión*
 - Axiomas de comportamiento racional
 - Concepto de probabilidad. Funciones de pérdida
2. *Modelos probabilísticos*
 - Intercambiabilidad. Teoremas de representación
 - Función de verosimilitud
3. *El paradigma bayesiano*
 - Proceso de aprendizaje
 - Comportamiento asintótico
4. *Métodos bayesianos objetivos*
 - Análisis de referencia
 - Estimación. Contraste de hipótesis
5. *Calibrado de los métodos estadísticos*
 - Simulación. Distribuciones en el muestreo
 - Comportamiento esperado en muestreo repetido

1. Introducción a la Teoría de Decisión

- *Axiomas de comportamiento racional*

- Estructura y axiomas

$$\mathcal{A} = \{a_i, i \in I\}, \quad \Theta_i = \{\theta_{ij}, j \in J_i\},$$

Comparabilidad, Transitividad, Consistencia,...

- Resultados básicos:

$$\exists \Pr(\theta_{ij} | a_i, D) > 0, \sum_j \Pr(\theta_{ij} | a_i, D) = 1$$

$$\exists l(a_i, \theta_{ij}) \in \mathfrak{R}$$

Debe minimizarse la utilidad esperada

$$\bar{l}(a_i | D) = \sum_j l(a_i, \theta_{ij}) \Pr(\theta_{ij} | a_i, D)$$

- *Concepto de probabilidad*

- Probabilidad: Medida **condicional** racional de la incertidumbre

$\Pr(A|D)$, función de **dos** argumentos

Casos particulares: Concepciones clásica y frecuentista.

- *Distribución de probabilidad como expresión de incertidumbre*

- Ejemplo: Exámenes de respuesta múltiple

Pregunta

p_1 Respuesta 1

p_2 Respuesta 2

.....

p_k Respuesta k

¿Como calificar $\mathbf{p} = \{p_1, p_2, \dots, p_k\}$, $\sum p_i = 1$ en función de la respuesta correcta, R_i ? ¿Puntuación $u(\mathbf{p}, R_i)$?

- $u(\mathbf{p}, R_i) = A \log[\Pr(R_i)] + B$, $A > 0$

$u(\mathbf{p}, R_i) = 1 - \log(p_i) / \log(1/k)$, $p_i = \Pr(R_i)$

$u(\{1, 0, \dots, 0\}, R_1) = 1$; $u(\{1/k, 1/k, \dots, 1/k\}, R_i) = 0$;

$u(\{0, p_2, \dots, p_k\}, R_1) = -\infty$

- $k = 2$, $p = \Pr(\text{Respuesta correcta})$,

$u(p) = 1 - \log(p) / \log(1/2) = 1 + \log(p) / \log(2)$

- *Funciones generales de pérdida*

- Discrepancia $l[p_{\mathbf{x}}(\cdot), q_{\mathbf{x}}(\cdot)]$ entre dos distribuciones de probabilidad del vector aleatorio $\mathbf{x} \in \mathcal{X}$, con densidades $p_{\mathbf{x}}(\cdot)$ y $q_{\mathbf{x}}(\cdot)$.

- **Discrepancia intrínseca**, $\delta(\boldsymbol{\theta}_i, \boldsymbol{\theta}_j)$

$$M \equiv \{p(\mathbf{x} | \boldsymbol{\theta}), \boldsymbol{\theta} \in \Theta\}, \quad p(\mathbf{x} | \boldsymbol{\theta}) > 0, \quad \int_{\mathcal{X}} p(\mathbf{x} | \boldsymbol{\theta}) d\mathbf{x} = 1$$

$$k(\boldsymbol{\theta}_j | \boldsymbol{\theta}_i) = \int_{\mathcal{X}} p(\mathbf{x} | \boldsymbol{\theta}_i) \log \left[\frac{p(\mathbf{x} | \boldsymbol{\theta}_i)}{p(\mathbf{x} | \boldsymbol{\theta}_j)} \right] d\mathbf{x}$$

$$\delta\{p_{\mathbf{x}}(\cdot | \boldsymbol{\theta}_i), p_{\mathbf{x}}(\cdot | \boldsymbol{\theta}_j)\} = \delta(\boldsymbol{\theta}_i, \boldsymbol{\theta}_j) = \min\{k(\boldsymbol{\theta}_i | \boldsymbol{\theta}_j), k(\boldsymbol{\theta}_j | \boldsymbol{\theta}_i)\}$$

- Aplicaciones:

$$\delta\{p_{\mathbf{x}}(\cdot), \hat{p}_{\mathbf{x}}(\cdot)\} \quad (\text{aproximaciones})$$

$$\lim_{n \rightarrow \infty} p_n(\mathbf{x}) = p(\mathbf{x}) \iff \lim_{n \rightarrow \infty} \delta\{p_n(\cdot), p(\cdot)\} = 0$$

(convergencia intrínseca)

$$l(\hat{\boldsymbol{\theta}}, \boldsymbol{\theta}) = \delta\{p_{\mathbf{x}}(\cdot | \boldsymbol{\theta}), p_{\mathbf{x}}(\cdot | \hat{\boldsymbol{\theta}})\} = \delta(\hat{\boldsymbol{\theta}}, \boldsymbol{\theta}) \quad (\text{estimación})$$

$$l(\boldsymbol{\theta}_0, \boldsymbol{\theta}) = \delta\{p_{\mathbf{x}}(\cdot | \boldsymbol{\theta}), p_{\mathbf{x}}(\cdot | \boldsymbol{\theta}_0)\} = \delta(\boldsymbol{\theta}_0, \boldsymbol{\theta}) \quad (\text{contraste})$$

2. Modelos Probabilísticos

- *Intercambiabilidad*

- $\{\mathbf{x}_1, \mathbf{x}_2, \dots\}$ “homogéneas” (orden no proporciona información).

Distribución conjunta invariante ante permutaciones:
observaciones **intercambiables**.

Caso particular: **muestras aleatorias**

- *Teorema general de representación*

- Si $\{\mathbf{x}_1, \mathbf{x}_2, \dots\}$ es una sucesión intercambiable, entonces

$$\exists g(\cdot), \exists \boldsymbol{\theta} = \lim_{n \rightarrow \infty} g(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n),$$

$$\exists p(\mathbf{x} | \boldsymbol{\theta}) > 0, \int_{\mathcal{X}} p(\mathbf{x} | \boldsymbol{\theta}) d\mathbf{x} = 1,$$

$$\exists p(\boldsymbol{\theta}) > 0, \int_{\Theta} p(\boldsymbol{\theta}) d\boldsymbol{\theta} = 1,$$

y cualquier subconjunto finito tiene una representación integral

$$p(\mathbf{x}_1, \dots, \mathbf{x}_n) = \int_{\Theta} \prod_{i=1}^n p(\mathbf{x}_i | \boldsymbol{\theta}) p(\boldsymbol{\theta}) d\boldsymbol{\theta}.$$

- Si los datos son **homogeneos (intercambiables)**, entonces:
 - (i) Son una muestra aleatoria de algún *modelo probabilístico* $p(\mathbf{x} | \boldsymbol{\theta})$, cuyo *parámetro* $\boldsymbol{\theta}$ es el límite de una función de las obervaciones,
 - (ii) La información de que se dispone sobre el valor de $\boldsymbol{\theta}$ *debe* ser descrita mediante una distribución de probabilidad $p(\boldsymbol{\theta})$.
- Se trata de un *teorema de existencia*:
Se sabe que $p(\mathbf{x} | \boldsymbol{\theta})$ y $p(\boldsymbol{\theta})$ existen, pero deben ser determinados.
- *Especificación de modelos*
 - Si $\mathbf{x} \in \{0, 1\}^k$, modelo multinomial (binomial para $k = 1$).
 - Si $\mathbf{x} \in \mathcal{R}^k$, y existe simetría esférica, modelo multinormal (normal univariante para $k = 1$).
 - Si $\mathbf{x} \in \mathcal{R}^k$, y $\{\bar{\mathbf{x}}, S, n\}$ es suficiente, modelo multinormal (normal univariante para $k = 1$).

- *Función de verosimilitud*

- Datos D , cuya distribución depende de $\boldsymbol{\theta}$, $L(\boldsymbol{\theta} | D) = p(D | \boldsymbol{\theta})$.
Si los datos son intercambiables, $L(\boldsymbol{\theta} | D) = \prod_{i=1}^n p(\mathbf{x}_i | \boldsymbol{\theta})$.
- Estimador máximo-verosímil, $\hat{\boldsymbol{\theta}} = \hat{\boldsymbol{\theta}}(D) = \arg \max_{\Theta} L(\boldsymbol{\theta} | D)$
Análisis de existencia y unicidad.
- Condiciones de regularidad: Función de información de Fisher, $F(\boldsymbol{\theta})$
$$F(\boldsymbol{\theta})_{ij} = -\mathbb{E}_{\mathbf{x}|\boldsymbol{\theta}} \left[\frac{\partial^2}{\partial \theta_i \partial \theta_j} \log p(\mathbf{x} | \boldsymbol{\theta}) \right]$$
- Aproximación cuadrática de la verosimilitud
$$L(\boldsymbol{\theta} | D) \propto \mathbf{N}_k(\boldsymbol{\theta} | \hat{\boldsymbol{\theta}}, [nF(\hat{\boldsymbol{\theta}})]^{-1})$$

- *Suficiencia*

- Criterio de factorización
- Familia exponencial de distribuciones

3. El Paradigma Bayesiano

- *Proceso de aprendizaje*

- $D = \text{datos}, \quad \{p(D | \boldsymbol{\theta}), p(\boldsymbol{\theta})\},$

$$L(\boldsymbol{\theta} | D) = p(D | \boldsymbol{\theta})$$

$$p(\boldsymbol{\theta} | D) \propto p(D | \boldsymbol{\theta}) p(\boldsymbol{\theta})$$

- Caso particular: $D = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$, muestra aleatoria

$$L(\boldsymbol{\theta} | D) = \prod_{i=1}^n p(\mathbf{x}_i | \boldsymbol{\theta})$$

$$p(\mathbf{x} | D) = \int_{\Theta} p(\mathbf{x} | \boldsymbol{\theta}) p(\boldsymbol{\theta} | D) d\boldsymbol{\theta}$$

- Parámetros marginales: $\boldsymbol{\theta} = (\boldsymbol{\phi}, \boldsymbol{\omega}), \quad p(\boldsymbol{\theta}) = p(\boldsymbol{\phi}) p(\boldsymbol{\omega} | \boldsymbol{\phi})$

$$p(\boldsymbol{\phi} | D) = \int_{\Omega} p(\boldsymbol{\phi}, \boldsymbol{\omega} | D) d\boldsymbol{\omega}$$

$$p(\boldsymbol{\phi} | D) \propto L(\boldsymbol{\phi} | D) p(\boldsymbol{\phi})$$

$$L(\boldsymbol{\phi} | D) = \int_{\Omega} L(\boldsymbol{\phi}, \boldsymbol{\omega} | D) p(\boldsymbol{\omega} | \boldsymbol{\phi}) d\boldsymbol{\omega}$$

- *Estimación*

- El “estimador” bayesiano de θ es $p(\theta | D)$.

Estimación **puntual**, $\tilde{\theta}(D) \in \Theta$, con pérdida $l(\tilde{\theta}, \theta)$

$$\theta^* = \arg \min_{\hat{\theta} \in \Theta} \int l(\hat{\theta}, \theta) p(\theta | D) d\theta$$

El estimador resultante depende de la función de pérdida.

- Estimación por **regiones**, $C_p(D) \subset \Theta$

Confianza p ; $\int_{C_p} p(\theta | D) d\theta = p$

Existen infinitas soluciones.

Regiones de máxima densidad en θ (HPD)

- *Constraste de hipótesis*

- Con función de pérdida $l(\theta_0, \theta)$

Criterio: Rechazar $H_0 \equiv \{\theta = \theta_0\}$ sii

$$\int l(\theta_0, \theta) p(\theta | D) d\theta > l^*$$

l^* mide el valor de aceptar H_0 si es cierta.

La región de rechazo depende de la función de pérdida.

- *Ejemplo: Datos exponenciales*

□ $p(x | \theta) = \theta e^{-\theta x}$, $t = \sum_j x_j$ es suficiente

$$\pi(\theta) \propto \theta^{-1}, \quad \pi(\theta | D) = \text{Ga}(\theta | n, t)$$

$$\pi(x | D) = nt^n(x + t)^{-(n+1)}$$



□ Datos D : $n = 25$, $t = 41.57$, $1/\bar{x} = 0.601$

$$\Pr[0.39 < \theta < 0.86 | D] = 0.95$$

$$\Pr[x < 0.25 | D] = 0.14$$

Estimador intrínseco, $\theta^* = 0.590$

□ Presentacion de resultados



- *Comportamiento asintótico*

□ **Caso discreto.** $\Theta = \{\theta_1, \theta_2, \dots\}$, $\theta_t \in \Theta$



$$\lim_{n \rightarrow \infty} \Pr[\theta = \theta_t \mid \mathbf{x}_1, \dots, \mathbf{x}_n] = 1$$

$$\lim_{n \rightarrow \infty} \Pr[\theta = \theta_j \mid \mathbf{x}_1, \dots, \mathbf{x}_n] = 0, \quad \forall j \neq t$$

□ **Caso continuo.** $\Theta \subset \mathbb{R}^k$ (n grande, $L(\theta \mid D)$ regular)

$$p(\theta \mid \mathbf{x}_1, \dots, \mathbf{x}_n) \approx N_k(\theta \mid \hat{\theta}, [nF(\hat{\theta})]^{-1})$$

$$F_{ij}(\theta) = -E_{\mathbf{x} \mid \theta} \left[\frac{\partial^2}{\partial \theta_i \partial \theta_j} \log p(\mathbf{x} \mid \theta) \right]; \quad (\text{margs, conds})$$



4. Métodos Bayesianos Objetivos

- *Análisis de referencia*

- Información esperada

$$p(D | \theta), \quad \theta \in \Theta \subset \mathfrak{R}, \quad D \in \mathcal{D} \subset \mathfrak{R}^n$$

$p(\theta) \in \mathcal{P}$, distribuciones admisibles

$$I^\theta\{\mathcal{D}, p(\theta)\} = \mathbb{E}_{D\theta} \left[\log \frac{p(D, \theta)}{p(D)p(\theta)} \right] \quad (\text{Shannon})$$

- Información desconocida

$$H_k\{p(\theta)\} = I^\theta\{\mathcal{D}^k, p(\theta)\}, \quad \pi_k(\theta) = \arg \sup_{p(\theta) \in \mathcal{P}} H_k\{p(\theta)\}$$

Cuando $k \rightarrow \infty$, $\pi_k(\theta)$ maximiza en \mathcal{P} la info desconocida sobre θ .

- **Distribución final de referencia**

$$\pi_k(\theta | D) \propto p(D | \theta) \pi_k(\theta)$$

$$\pi(\theta | D) = \lim_{k \rightarrow \infty} \pi_k(\theta | D) \quad (\text{convergencia intrínseca})$$

- **Función inicial de referencia**

$$\pi(\theta) > 0; \quad \forall D, \pi(\theta | D) \propto p(D | \theta) \pi(\theta)$$

- Caso **discreto finito**, $\Theta = \{\theta_1, \dots, \theta_m\}$

$$\lim_{k \rightarrow \infty} H_k\{p(\theta)\} = - \sum_{j=1}^m p_j \log p_j$$
 $\pi(\theta)$ es la distribución de máxima entropía
 (uniforme sin restricciones adicionales)
- Caso **continuo**, $\Theta \subset \mathfrak{R}$, $\hat{\theta}$ estimador consistente, asintóticamente suficiente. Sin restricciones adicionales,

$$\pi(\theta) \propto \hat{p}(\theta | \hat{\theta})|_{\hat{\theta}=\theta} \quad \text{donde } \hat{p}(\theta | \hat{\theta})$$
 es una aproximación asintótica cualquiera a la distribución final.
- Caso continuo regular univariante, sin restricciones adicionales,

$$\pi(\theta) \propto i(\theta)^{1/2}$$

$$i(\theta) = - \mathbf{E}_{D|\theta} \left[\frac{\partial^2}{\partial \theta^2} \log p(D | \theta) \right] \quad (\text{Jeffreys})$$
- Los problemas multivariantes pueden reducirse a la solución secuencial de una sucesión de problemas univariantes para obtener

$$\pi(\theta_k | \theta_1, \dots, \theta_{k-1}) \times \dots \times \pi(\theta_2 | \theta_1) \pi(\theta_1)$$

- *Estimación puntual*

- El verdadero “estimador” bayesiano objetivo de θ es su densidad final de referencia $\pi(\theta | D)$, $\theta \in \Theta \subset \mathbb{R}^k$.
- Pueden obtenerse estimadores puntuales θ^* minimizando en Θ una pérdida esperada $\int l(\tilde{\theta}, \theta) \pi(\theta | D) d\theta$

Estimador intrínseco. La función de pérdida intrínseca

$$\delta(\theta_i, \theta_j) = \min\{k(\theta_i | \theta_j), k(\theta_j | \theta_i)\}$$

$$k(\theta_j | \theta_i) = \int_{\mathcal{X}} p(\mathbf{x} | \theta_i) \log \left[\frac{p(\mathbf{x} | \theta_i)}{p(\mathbf{x} | \theta_j)} \right] d\mathbf{x}$$

da lugar a una pérdida esperada intrínseca

$$d(\tilde{\theta} | D) = \int \delta(\tilde{\theta}, \theta) \pi(\theta | D) d\theta$$

cuya minimización proporciona un único estimador invariante

$$\theta^* = \arg \min_{\tilde{\theta} \in \Theta} d(\tilde{\theta} | D)$$

el estimador intrínseco de referencia (\forall dimension k).

- *Estimación por regiones*



□ Las regiones creíbles de confianza objetivas C_p verifican

$$\int_{C_p} \pi(\boldsymbol{\theta} | D) d\boldsymbol{\theta} = p, \quad \text{donde } \pi(\boldsymbol{\theta} | D) \text{ es la posterior de referencia.}$$

□ **Regiones intrínsecas de confianza.** Las regiones de mínima pérdida esperada intrínseca

$$d(\tilde{\boldsymbol{\theta}}_1 | D) < d(\tilde{\boldsymbol{\theta}}_2 | D) \quad \forall \boldsymbol{\theta}_1 \in C_p, \quad \forall \boldsymbol{\theta}_2 \notin C_p$$

proporcionan soluciones únicas invariantes (\forall dimension k).



- *Contraste de hipótesis puntuales*

- Para una función de pérdida, $l(\theta_0, \theta)$,

- (i) calcular estadístico de contraste $t(D | \theta_0) = \int l(\theta_0, \theta) \pi(\theta | D) d\theta$

- (ii) rechazar $H_0 \equiv \{\theta = \theta_0\}$ si $t(D | \theta_0) > t^*$,
donde t^* mide el valor de aceptar H_0 si es cierta.

- La función de pérdida intrínseca, con estadístico de contraste

$$d(\theta_0 | D) = \int \delta(\theta_0, \theta) \pi(\theta | D) d\theta$$

permite calibrar el umbral d^* en términos de unidades de información:
log del cociente de verosimilitudes medio a favor del modelo correcto
(**criterio bayesiano de referencia, BRC**)


- $E[d(D | \theta_0) | H_0] = 1.$

- $d^* = \log(10) = 2.3$ (suave)

- $d^* = \log(100) = 4.6$ (fuerte)

- $d^* = \log(1000) = 6.9$ (muy fuerte)

Los valores $d^* = 2.5$ y $d^* = 5.0$
corresponden a 2 y 3 desv. típicas
en el contraste de la media normal.



5. Calibrado de los Métodos Estadísticos

- *Simulación*

- Determinar el q -cuantil $\theta_q(D)$ de la distribución final de referencia

$$\Pr[\boldsymbol{\theta} < \boldsymbol{\theta}_q | D] = \int_{\{\boldsymbol{\theta} < \boldsymbol{\theta}_q\}} \pi(\boldsymbol{\theta} | D) d\boldsymbol{\theta} = q$$

- Generar k muestras simuladas de tamaño n , $\{D_1, \dots, D_k\}$ del modelo analizado $p(D | \boldsymbol{\theta})$, para algún valor $\boldsymbol{\theta} = \boldsymbol{\theta}_t$.

Calcular de las correspondientes distribuciones finales.

Determinar la proporción q_{obs} de las k regiones $]-\infty, \boldsymbol{\theta}_q(D_i)]$ que contienen a $\boldsymbol{\theta}_t$.


Para k grande, $q_{obs} \approx q$.

- $p(x | \theta) = \text{Po}(x | \theta)$

$$\theta_t = 3, n = 20$$

con $k = 1000$ simul,

$$q = 0.90, q_{obs} = 0.91$$



- *Distribuciones en el muestreo*

- A partir de $p(D | \boldsymbol{\theta})$, $\boldsymbol{t} = \boldsymbol{t}(D)$, determinación de $p(\boldsymbol{t} | \boldsymbol{\theta})$.
Métodos analíticos y cálculo por simulación.

- *Comportamiento esperado en muestreo repetido*

- $D = \{\boldsymbol{x}_1, \dots, \boldsymbol{x}_n\}$. Calibrado de regiones creíbles en términos de un estadístico suficiente $\boldsymbol{t} = \boldsymbol{t}(\boldsymbol{x}_1, \dots, \boldsymbol{x}_n)$.

$$\Pr[\boldsymbol{\theta} \leq \boldsymbol{\theta}_q(\boldsymbol{t}) | \boldsymbol{t}] = \int_{\boldsymbol{\theta} \leq \boldsymbol{\theta}_q(\boldsymbol{t})} \pi(\boldsymbol{\theta} | \boldsymbol{t}) d\boldsymbol{\theta} = q$$

$$\Pr[\boldsymbol{\theta}_q(\boldsymbol{t}) \geq \boldsymbol{\theta} | \boldsymbol{\theta}] = \int_{\boldsymbol{\theta}_q(\boldsymbol{t}) \geq \boldsymbol{\theta}} p(\boldsymbol{t} | \boldsymbol{\theta}) d\boldsymbol{t} = \hat{q}_n$$

- Para **toda** distribución inicial $p(\boldsymbol{\theta})$, $\hat{q}_n = q + O\left(\frac{1}{\sqrt{n}}\right)$

$$\text{Para la inicial de referencia } \pi(\boldsymbol{\theta}), \quad \hat{q}_n = q + O\left(\frac{1}{n}\right)$$

- *Interpretación de las regiones creíbles*

□ Cuando el estadístico suficiente $\mathbf{t} = \mathbf{t}(D)$ es un **pivote**, (su distribución exacta en el muestreo sólo depende de $\boldsymbol{\theta}$), frecuente doble interpretación *exacta* de las regiones $C_q(\mathbf{t}) \subset \Theta$:

(i) **Región creíble**. Subconjunto de Θ al que, dados los datos obtenidos \mathbf{t} , pertenece el verdadero valor $\boldsymbol{\theta}$ del parámetro con grado racional de creencia q (en una escala $[0, 1]$): $\int_{C_q(\mathbf{t})} \pi(\boldsymbol{\theta} | \mathbf{t}) d\boldsymbol{\theta} = q$

(ii) **Región de confianza**. Construcción de regiones $\{C_q(\mathbf{t}), \mathbf{t} \in \mathcal{T}\}$ que, en muestreo repetido de $p(\mathbf{t} | \boldsymbol{\theta})$, contienen al verdadero valor de $\boldsymbol{\theta}$ en una proporción \hat{q} que tiende a q cuando el número de repeticiones tiende a infinito: $\int_{\{\mathbf{t}; \boldsymbol{\theta} \in C_q(\mathbf{t})\}} p(\mathbf{t} | \boldsymbol{\theta}) d\mathbf{t} = q$.

Ejemplos: datos normales (t de Student), datos exponenciales,...

□ En general, se trata sólo de una **aproximación asintótica** ($\hat{q}_n \approx q$) con serios problemas en el caso de muestras extremas.

Ejemplos: datos Binomiales, datos Poisson, datos Student

- *Datos binomiales extremos*

$$\square p(x | \theta) = \theta^x (1 - \theta)^{1-x}, x \in \{0, 1\}, \quad \pi(\theta) = \text{Be}(\theta | \frac{1}{2}, \frac{1}{2})$$

$$D = (r, n), \quad \pi(\theta | D) = \text{Be}(\theta | r + \frac{1}{2}, n - r + \frac{1}{2}) \quad n = 100, r = 0$$

$$\pi(\theta | D) = \text{Be}(\theta | 0.5, 100.5)$$


$$\Pr(\theta > 0.05 | D) \approx 0.001$$

$$\Pr(\theta < 0.01 | D) \approx 0.844$$

$$\Pr(\theta < 0.0023 | D) \approx 0.5$$

$$\Pr(x = 1 | D) = \text{E}[\theta | D] \approx 0.0050$$

$$\theta^*(D) \approx 0.0032$$



- Con muestras extremas $r = 0$, ó $r = n$, el estimador máximo verosímil $\hat{\theta} = r/n$ es totalmente inapropiado, $\hat{\theta} = 0$, ó $\hat{\theta} = 1$.
- El estimador insesgado de $\psi = \theta^2$, $\tilde{\psi} = r(r - 1)/\{n(n - 1)\}$, puede producir resultados absurdos: si $r = 1$, $\tilde{\psi} = 0$
- El buen comportamiento “en valor medio” **no garantiza** un buen comportamiento para datos concretos.

6. Algunas Conclusiones

- **Inevitabilidad** *lógica de la metodología Bayesiana*
 - Fundamentos basados en la teoría de la decisión.
 - Existencia de la inicial basada en la teoría de la probabilidad.
- **Resultados objetivos**, *directamente relevantes*
 - El análisis de referencia proporciona soluciones que sólo dependen del modelo aceptado y de los datos obtenidos.
 - La distribución final (en particular sus regiones de confianza) corresponden directamente a las preguntas formuladas por científicos y técnicos.
 - Con cualquier modelo, se obtienen resultados válidos para cualquier tamaño muestral y para cualquier muestra (el análisis es siempre condicional a los datos obtenidos, no a su comportamiento medio)
- **Facilidad de interpretación**
 - Graficas: distribución final, estimadores, regiones creíbles, contrastes.

- *Reformulación de la enseñanza de la estadística matemática*
 - Elementos de teoría de decisión.
 - Intercambiabilidad, modelos y verosimilitud.
 - Métodos bayesianos objetivos.
 - Calibrado de los métodos estadísticos
- *Referencias básicas*

Libros

Bernardo, J. M. & Smith, A. F. M. (1994).

Bayesian Theory. Chichester: Wiley.

DeGroot, M. H. & Shervish, M. J. (2002).

Probability and Statistics. Reading, MA: Addison-Wesley.

Berger, J. O., Bernardo, J. M. & Sun, D. (2003).

Objective Bayesian Statistics (en preparación).

Artículos

On line: <http://www.uv.es/~bernardo/publications.html>

Generales

Bernardo, J. M. (2001). Un programa de síntesis para la enseñanza de la estadística matemática contemporánea. *Rev. Real Acad. Ciencias* **95**, 87–105.

Bernardo, J. M. (2003). Bayesian Statistics. *Encyclopedia of Life Support Systems (EOLSS)*. Paris: UNESCO (en prensa).

Específicos

Bernardo, J. M. & Juárez, M. A. (2003). Intrinsic Estimation. *Bayesian Statistics 7*. Oxford: University Press, 465–475.

Bernardo, J. M. & Ramón, J. M. (1998). An introduction to Bayesian reference analysis. *J. Roy. Statist. Soc. D* **47**, 1–35.

Bernardo, J. M. & Rueda, R. (2002). Bayesian hypothesis testing: A reference approach. *Internat. Statist. Rev.* **70**, 351–372.

**4th International Meeting on
OBJECTIVE BAYESIAN STATISTICS**

Aussois, (Alpes Franceses)

15 – 20 Junio, 2003

www.ceremade.dauphine.fr/xian/OBayes03.html
Prof. Christian P. Robert, <xian@ceremade.dauphine.fr>