

Apunts d'inferència estadística

Llorenç Cerdà-Alabern

llorencc@ac.upc.edu

Barcelona, juny de 2008.

Índex

1	Definicions	2
2	Propietats bàsiques de les mostres	2
3	Poblacions Normals	3
3.1	Distribució gamma i χ^2	3
3.2	Teorema de Fisher	3
3.3	Teorema de Student	3
3.4	Distribució F de Snedecor	3
3.5	Altres relacions	3
3.6	Correlació mostral	3
4	Intervals de confiança	4
4.1	Definició	4
4.2	Mètode de la quantitat pivotal	4
4.3	Mètode de Neymann	4
4.4	Distribucions normals	4
5	Estimació puntual	5
5.1	Comparació d'estimadors	5
5.2	Estimador mínimax	6
5.3	Estimador Bayes	6
6	Estimadors de risc mínim	6
6.1	Estimador centrat uniformement de mínima variança (ECUMV)	6
6.2	Acotació de la variança	7
7	Mètodes d'estimació	7
7.1	Mètode dels moments	7
7.2	Mètode de la màxima verosimilitut	8
7.3	Estimació Bayesiana	8
8	Constrast d'hipòtesi	8
8.1	Constrast simple-simple	9
8.2	Constrast unilateral	9
8.3	Constrast bilateral	10
8.4	Constrast de poblacions normals	10
9	Mètodes de constrast	10
9.1	Test de raó de verosimilituts	10
9.2	Relació entre l'estimació confidencial i el constrast d'hipòtesi	11
10	Contrasts χ^2 de bondat d'ajustament	11
10.1	Hipòtesi simple	11
10.2	Hipòtesi composta	11
10.3	Constrast d'homogeneïtat	12
10.4	Constrast d'independència	12
12	Bibliografia	12
13	Apèndixs	13
A.	Taules d'algunes distribucions	13
	Distribució Normal	13
	Distribució χ^2 de Pearson	14
	Distribució t de Student	15
	Distribució de Poisson	16
	Distribució binomial	17
	Distribució F de Snedecor	21
B.	Quadre amb algunes distribucions	29
	Prefaci	

Vaig escriure aquests apunts mentre preparava la segona part de l'assignatura *Càlculo de probabilidades y estadística* del curs 2007-08 de la carrera de matemàtiques de l'UNED. Els apunts estan basats fonamentalment en el llibre de l'assignatura [2], editats amb \LaTeX , i les taules de l'apèndix A calculades amb R (<http://www.r-project.org>).

Capítol 1

Definicions

Inferència estadística Deducir propietats d'un model probabilístic a partir d'un conjunt d'observacions x_1, \dots, x_n anomenades valors mostrals (*sample data*), o simplement mostres.

Distribució poblacional o teòrica (*population distribution*) Distribució de la variable aleatòria d'interès d'on es prenen les mostres: $X \sim F(X)$.

Mostra aleatòria simple de mida n (*random sample*) col·lecció de n V.A. independents X_1, \dots, X_n amb la mateixa distribució F . Un conjunt particular de mostres x_1, \dots, x_n s'anomena realització de la mostra.

Distribució de la mostra Com que les mostres son independents i idènticament distribuïdes (iid), amb $X_i \sim F(X)$:

$$F_n(x_1, \dots, x_n) = F(x_1)F(x_2) \cdots F(x_n)$$

Estadístic (*statistic*) Funció mesurable $T: \mathbb{R}^n \rightarrow \mathbb{R}^k$, d'una mostra aleatòria de mida n , de forma que $T(X_1, \dots, X_n)$ és una V.A. Per exemple la mitjana mostral: $T(X_1, \dots, X_n) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$

Distribució en el mostreig d'un estadístic (*sampling distribution*) És la distribució d'un estadístic.

Distribució empírica (*empirical distribution function*) Funció de distribució acumulativa que assigna probabilitat $1/n$ a cada una de les mostres:

$$F_n^*(x) = \frac{\text{nombre de mostres amb valor} \leq x}{n}$$

Capítol 2

Propietats bàsiques de les mostres

Moments poblacionals

$$\alpha_k = E_x x^k = \int_{-\infty}^{\infty} x^k f(x) dx \quad (2.1)$$

$$\mu_k = E(x - \mu)^k = \int_{-\infty}^{\infty} (x - \mu)^k f(x) dx \quad (2.2)$$

Mitjana i variances poblacional

$$\mu = \alpha_1 = \int_{-\infty}^{\infty} x f(x) dx \quad (2.3)$$

$$\sigma^2 = \mu_2 = \int_{-\infty}^{\infty} x^2 f(x) dx - \mu^2 = \alpha_2 - \mu^2 \quad (2.4)$$

Moments mostrals

$$a_k = \frac{1}{n} \sum_{i=1}^n X_i^k \quad (2.5)$$

$$b_k = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k \quad (2.6)$$

Mitjana, variança i quasi-variança mostrals

$$\bar{X} = a_1 = \frac{1}{n} \sum_{i=1}^n X_i \quad (2.7)$$

$$s^2 = b_2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2 = a_2 - \bar{X}^2 \quad (2.8)$$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2, \quad n s^2 = (n-1) S^2 \quad (2.9)$$

Propietats

$$E a_k = \frac{1}{n} \sum_{i=1}^n E X_i^k = \alpha_k, \quad E \bar{X} = \mu$$

$$\text{Var}[a_k] = E(a_k - E a_k)^2 = E \left(\frac{1}{n} \sum_{i=1}^n X_i^k - \alpha_k \right)^2 =$$

$$E \left(\frac{1}{n} \sum_{i=1}^n (X_i^k - \alpha_k) \right)^2 = \frac{1}{n^2} \sum_{i=1}^n E(X_i^k - \alpha_k)^2 =$$

$$E X^{2k} - \alpha_k^2 = \frac{\alpha_{2k} - \alpha_k^2}{n}$$

Per tant:

$$\text{Var}[\bar{X}] = \frac{\alpha_2 - \alpha_1^2}{n} = \frac{\sigma^2}{n}$$

$$\left. \begin{aligned} \sigma^2 &= \text{Var}[X] = E X^2 - \mu^2 \\ \text{Var}[\bar{X}] &= E \bar{X}^2 - \mu^2 = \sigma^2/n \\ E s^2 &= E \left[\frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2 \right] = E X^2 - E \bar{X}^2 \end{aligned} \right\} \Rightarrow$$

$$E s^2 = (\sigma^2 + \mu^2) - \left(\frac{\sigma^2}{n} + \mu^2 \right) = \frac{n-1}{n} \sigma^2 \Rightarrow E S^2 = \sigma^2$$

Relació entre la distribució empírica i poblacional

$$F_n^*(x) = \frac{1}{n} \sum_{i=1}^n I_{(-\infty, x]}(x_i) \quad (2.10)$$

$n F_n^*(x)$ té una distribució binomial $B(n, F(x))$:

$$F_n^*(x) \xrightarrow{d} N(F(x), \sqrt{F(x)(1-F(x))/n}) \quad (2.11)$$

Quantil d'ordre p

Complex: $F_n^*(c_p) \geq p$ i $F_n^*(c_p^-) \leq p$ (2.12)

$n p \notin \mathbb{N}$: $c_p = X_{(np+1)}$ (2.13)

$n p \in \mathbb{N}$: $c_p = \frac{X_{(np)} + X_{(np+1)}}{2}$ (2.14)

Nota: $x_{(n)}$ és la mostra ordenada n .

Capítol 3

Poblacions Normals

3.1 Distribució gamma i χ^2

$$\gamma(n, \theta) = \frac{\theta^n x^{n-1} e^{-\theta x}}{\Gamma(n)}, x \geq 0 \quad (3.1)$$

Mitjana: n/θ , variança: n/θ^2 .

$$\chi_n^2 = \gamma(n/2, 1/2) = \frac{1/2^n x^{n/2-1} e^{-x/2}}{\Gamma(1/2)}, x \geq 0 \quad (3.2)$$

Mitjana: n , variança: $2n$.

Propietats:

$X_i \sim \gamma(n_i, \theta) \Rightarrow \Sigma X_i \sim \gamma(\Sigma n_i, \theta)$ (3.3)

$X \sim \gamma(n, \theta) \Rightarrow 2\theta X \sim \chi_{2n}^2$ (3.4)

$\chi_n^2 + \chi_m^2 \sim \chi_{n+m}^2$ (3.5)

$X_i \sim N(0, 1) \Rightarrow \sum_{i=1}^n X_i^2 \sim \chi_n^2$ (3.6)

$X_i \sim N(0, \sigma) \Rightarrow \frac{n s^2}{\sigma^2} \sim \chi_n^2$ (3.7)

3.2 Teorema de Fisher

Si $X_i \sim N(\mu, \sigma)$:

s^2 i \bar{X} son independents

$\bar{X} \sim N(\mu, \sigma/\sqrt{n}) \Rightarrow \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$ (3.9)

$\frac{n s^2}{\sigma^2} \sim \chi_{n-1}^2$ (3.10)

3.3 Teorema de Student

$N(0, 1) \sim t_n = \frac{\Gamma(\frac{n+1}{2})}{\sqrt{n\pi}\Gamma(\frac{n}{2})} \left(1 + \frac{t^2}{n}\right)^{-\frac{n+1}{2}}, t \in (-\infty, \infty)$ (3.11)

$t = \frac{\bar{X} - \mu}{S/\sqrt{n}} = \frac{\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}}{\sqrt{\frac{1}{n-1} \frac{(n-1)S^2}{\sigma^2}}} \sim \frac{N(0, 1)}{\sqrt{\frac{1}{n-1} \chi_{n-1}^2}} \sim t_{n-1}$ (3.12)

3.4 Distribució F de Snedecor

Si: $X_i \sim N(0, 1)$ i $Y_i \sim N(0, 1)$:

$\frac{1}{n} \sum_{i=1}^n X_i^2 \sim \frac{1}{n} \chi_n^2$
 $\frac{1}{m} \sum_{i=1}^m Y_i^2 \sim \frac{1}{m} \chi_m^2$
 $\frac{1}{\frac{1}{n} \sum_{i=1}^n X_i^2} \sim F_{n,m}$

$\frac{\Gamma(\frac{n+m}{2})}{\Gamma(\frac{n}{2})\Gamma(\frac{m}{2})} \left(\frac{n}{m}\right)^{-\frac{n}{2}} \left(1 + \frac{n}{m}t\right)^{-\frac{n+m}{2}}, t \geq 0$ (3.13)

Si: $X_i \sim N(\mu_1, \sigma_1)$ i $Y_i \sim N(\mu_2, \sigma_2)$:

$\frac{S_1^2/\sigma_1^2}{S_2^2/\sigma_2^2} \sim \frac{\frac{1}{n-1}\chi_{n-1}^2}{\frac{1}{m-1}\chi_{m-1}^2} \sim F_{n-1, m-1}$ (3.14)

Nota: Com que $T \sim F_{n,m} \Rightarrow \frac{1}{T} \sim F_{m,n}$

$p = \mathcal{P}\{T > x_p\} = \mathcal{P}\{1/T < 1/x_p\} = \mathcal{P}\{T' < 1/x_p\} \Rightarrow x_{n,m;p} = 1/x_{m,n;1-p}$ (3.15)

3.5 Altres relacions

Si μ i σ son desconeguts:

$\mathcal{P}\left\{\frac{|\bar{X} - \mu|}{S/\sqrt{n}} < t_{n-1;p}\right\} = 1 - 2p$ (3.16)

Si σ és coneguda:

$\mathcal{P}\left\{\frac{|\bar{X} - \mu|}{\sigma/\sqrt{n}} < z_p\right\} = 1 - 2p$ (3.17)

Si: $X_i \sim N(\mu_1, \sigma_1)$ i $Y_i \sim N(\mu_2, \sigma_2)$:

$\frac{\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}}}{\frac{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}}} \sim \chi_{n+m-2}^2 \Rightarrow \frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}} \sim t_{n+m-2}$ (3.18)

Si $n, m \geq 15 \Rightarrow S_1^2 \approx \sigma_1^2, S_2^2 \approx \sigma_2^2$:

$\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{\sigma_1^2/n + \sigma_2^2/m}} \sim N(0, 1)$ (3.19)

3.6 Correlació mostral

Per una població normal bidimensional (X, Y) :

$R = \frac{S_{11}}{S_1 S_2}$ (3.20)

On:

$S_{11} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$

4

Teorema: Si el coeficient de correlació de la distribució normal bidimensional val $\rho = 0$:

$$R^* = \frac{R}{\sqrt{\frac{1}{n-2}(1-R^2)}} \sim t_{n-2} \quad (3.21)$$

Capítol 4

Intervals de confiança

4.1 Definició

Segui X una V.A. amb distribució poblacional $X \sim F_\theta$ que pertanyi a una família de distribucions paramètrica \mathcal{F} :

$$\mathcal{F} = \{F_\theta | \theta \in \Theta \subset \mathbb{R}^k\}$$

Segui $g(\theta) : \mathbb{R}^k \rightarrow \mathbb{R}$ i els estadístics unidimensionals $T_1 \leq T_2$ tals que:

$$F_\theta \{T_1(X_1, \dots, X_n) \leq g(\theta) \leq T_2(X_1, \dots, X_n)\} \geq 1 - \alpha \quad (4.1)$$

aleshores, $[T_1(X_1, \dots, X_n), T_2(X_1, \dots, X_n)]$ és un interval de confiança per $g(\theta)$ de nivell de confiança $1 - \alpha$. En aquesta definició $g(\theta)$ redueix el paràmetre k -dimensional, a una dimensió. Generalització al cas k -dimensional: Si $S(x_1, \dots, x_n)$ és un conjunt on $F_\theta \{\theta \in S(x_1, \dots, x_n)\} \geq 1 - \alpha$, aleshores el conjunt $S(x_1, \dots, x_n)$ és una regió de confiança per θ de nivell de confiança $1 - \alpha$.

4.2 Mètode de la quantitat pivotal

Segui $T(X_1, \dots, X_n; \theta) \sim G(t)$, on $G(t)$ no depèn de θ . Aleshores:

$$F_\theta \{c_1 \leq T_1(X_1, \dots, X_n; \theta) \leq c_2\} \geq 1 - \alpha \quad (4.2)$$

Per tant:

$$\begin{cases} G(c_1) = \alpha_1 \\ G(c_2) = 1 - \alpha_2 \end{cases} \Rightarrow \begin{cases} T(X_1, \dots, X_n; \theta) = c_1 \\ T(X_1, \dots, X_n; \theta) = c_2 \end{cases} \Rightarrow \begin{cases} \alpha_1 + \alpha_2 = \alpha \end{cases}$$

$$\begin{cases} g(\theta) = T_1(X_1, \dots, X_n; c_1) \\ g(\theta) = T_2(X_1, \dots, X_n; c_2) \end{cases} \Rightarrow$$

$$F_\theta \{c_1 \leq T_1(X_1, \dots, X_n; \theta), T_1(X_1, \dots, X_n; \theta) \leq c_2\} =$$

$$F_\theta \{T_1(X_1, \dots, X_n; c_1) \leq g(\theta), g(\theta) \leq T_2(X_1, \dots, X_n; c_2)\} =$$

$$G(c_2) - G(c_1) = 1 - \alpha_2 - \alpha_1 = 1 - \alpha \Rightarrow$$

$$[T_1(X_1, \dots, X_n; c_1), T_2(X_1, \dots, X_n; c_2)] \text{ és un I.C. per } g(\theta)$$

Exemple. Suposem $X \sim N(\theta, \sigma)$:

$$T = \frac{\bar{X} - \theta}{\sigma/\sqrt{n}} \sim N(0, 1) \Rightarrow$$

$$F_\theta \{-z_{\alpha/2} < T(X_1, \dots, X_n; \theta) < z_{\alpha/2}\} = 1 - \alpha \Rightarrow$$

$$[\bar{x} \pm z_{\alpha/2} \sigma / \sqrt{n}] \text{ és un I.C. per } \theta.$$

4.3 Mètode de Neymann

Agafem:

$$\begin{cases} F_\theta \{T < c_1(\theta)\} \leq \alpha_1 \\ F_\theta \{T > c_2(\theta)\} \leq \alpha_2 \end{cases}$$

On $\alpha_1 + \alpha_2 = \alpha$. La regió compresa entre les corbes $c_1(\theta)$ i $c_2(\theta)$ té $F_\theta \{c_1(\theta) \leq T \leq c_2(\theta)\} \geq 1 - \alpha$. Per tant, per un valor $T = t$:

$$\begin{cases} \theta_1(t) = c_1^{-1}(t) \\ \theta_2(t) = c_2^{-1}(t) \end{cases} \Rightarrow$$

$$F_\theta \{\theta_1(t) \leq \theta \leq \theta_2(t)\} \geq 1 - \alpha \Rightarrow$$

$$[\theta_1(t), \theta_2(t)] \text{ és un I.C. per } \theta.$$

Exemple. Suposem $X \sim$ uniforme en $(0, \theta)$:

$$T = X_{(n)} \Rightarrow G_\theta(t) = F_\theta \{X_{(n)} \leq t\} =$$

$$\begin{cases} 0 & \text{si } t \leq 0 \\ (t/\theta)^n & \text{si } 0 < t < \theta \\ 1 & \text{si } t \geq \theta \end{cases} \Rightarrow \begin{cases} G_\theta(c_1(\theta)) = \alpha_1 \\ G_\theta(c_2(\theta)) = 1 - \alpha_2 \end{cases}$$

$$\Rightarrow \begin{cases} c_1(\theta) = \theta \alpha_1^{1/n} \\ c_2(\theta) = \theta (1 - \alpha_2)^{1/n} \end{cases} \Rightarrow \begin{cases} t = X_{(n)} \\ t = X_{(n)} \end{cases}$$

$$[X_{(n)}(1 - \alpha_2)^{-1/n}, X_{(n)} \alpha_1^{-1/n}] \text{ és un I.C. per } \theta.$$

4.4 Distribucions normals

I.C. per μ , σ coneguda:

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1) \Rightarrow [\bar{x} \pm z_{\alpha/2} \sigma / \sqrt{n}]$$

I.C. per μ , σ desconeguda:

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{n-1} \Rightarrow [\bar{x} \pm t_{n-1, \alpha/2} S / \sqrt{n}]$$

I.C. per σ , μ desconeguda:

$$\frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2 \Rightarrow \left[\frac{(n-1)S^2}{\chi_{n-1, \alpha/2}^2}, \frac{(n-1)S^2}{\chi_{n-1, 1-\alpha/2}^2} \right]$$

Regió de confiança per μ , σ :

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}, \frac{(n-1)S^2}{\sigma^2} \text{ son independents } \Rightarrow$$

$$\begin{cases} P \left\{ -z_{\alpha/2} < \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < z_{\alpha/2} \right\} = 1 - \alpha \\ P \left\{ \chi_{n-1, 1-\beta/2}^2 < \frac{(n-1)S^2}{\sigma^2} < \chi_{n-1, \beta/2}^2 \right\} = 1 - \beta \end{cases} \Rightarrow$$

regió amb probabilitat $(1 - \alpha)(1 - \beta)$.

I.C. per la diferència de mitjanes amb σ_1 i σ_2 conegudes:

$$\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{\sigma_1^2/n + \sigma_2^2/m}} \sim N(0, 1) \Rightarrow$$

$$\left[\bar{x} - \bar{y} \pm z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}} \right]$$

B. Quadre amb algunes distribucions

Distribució	Paràmetres	Funció de densitat	Mitjana	Variància	Funció característica
Bernoulli	$0 \leq p \leq 1$ $q = 1 - p$	$p^k (1-p)^{1-k}$ $k = 0, 1$	p	$p(1-p)$	$q + pe^{it}$
Binomial	$0 \leq p \leq 1$ $q = 1 - p$	$\binom{n}{k} p^k (1-p)^{n-k}$ $k = 0, 1, \dots, n$	np	$np(1-p)$	$(q + pe^{it})^n$
Geomètrica	$0 \leq p \leq 1$ $q = 1 - p$	$p(1-p)^k$ $k \geq 0$	$\frac{1-p}{p}$	$\frac{1-p}{p^2}$	$\frac{p}{1-qe^{it}}$
Binomial negativa	$r > 0$ $0 \leq p \leq 1$ $q = 1 - p$	$\binom{k+r-1}{k} p^r q^k$ $k \geq 0$	$\frac{1-p}{p}$	$\frac{1-p}{r p^2}$	$\left(\frac{p}{1-qe^{it}} \right)^r$
Poisson	$\lambda > 0$	$\frac{\lambda^k}{k!} e^{-\lambda}$, $k \geq 0$	λ	λ	$\exp\{\lambda(e^{it} - 1)\}$
Normal $N(\mu, \sigma)$	$\mu \in \mathbb{R}$ $\sigma > 0$	$\frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(x-\mu)^2}{2\sigma^2}\right\}$ $x \in \mathbb{R}$	μ	σ^2	$\exp\left\{\mu it - \frac{t^2 \sigma^2}{2}\right\}$
Uniforme	$a < b$	$\frac{1}{b-a}$, $a < x < b$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$	$\frac{e^{itb} - e^{ita}}{it(b-a)}$
Exponencial	α	$\alpha e^{-\alpha x}$, $x > 0$	$\frac{1}{\alpha}$	$\frac{1}{\alpha^2}$	$\left(1 - \frac{it}{\alpha}\right)^{-1}$
Gamma $\gamma(n, \alpha)$	$\alpha > 0$, $n > 0$	$\frac{\alpha^n x^{n-1} e^{-\alpha x}}{\Gamma(n)}$, $x > 0$	$\frac{n}{\alpha}$	$\frac{n}{\alpha^2}$	$\left(1 - \frac{it}{\alpha}\right)^{-n}$
Beta	$p > 0$, $q > 0$	$\frac{\Gamma(p+q)}{\Gamma(p)\Gamma(q)} x^{p-1} (1-x)^{q-1}$ $0 < x < 1$	$\frac{p}{p+q}$	$\frac{pq}{(p+q)^2(p+q+1)}$	
Cauchy	$a > 0$, $b \in \mathbb{R}$	$\frac{a}{\pi [a^2 + (x-b)^2]}$ $x \in \mathbb{R}$	No existeix	No existeix	$e^{itb - a t }$

Taula 10.6: Distribució F de Snedecor, $\mathcal{P}\{F_{n,m} > F_{n,m;\alpha}\}$ (continuació).

n	13	14	15	16	17	18	20	24	30	40	60	120	∞
1,7708	1,7542	1,7395	1,7264	1,7146	1,7039	1,6852	1,6560	1,6252	1,5925	1,5575	1,5198	1,4784	
2,0889	2,0635	2,0411	2,0210	2,0030	1,9868	1,9586	1,9147	1,8687	1,8203	1,7689	1,7138	1,6541	
2,4089	2,3744	2,3439	2,3167	2,2924	2,2704	2,2324	2,1735	2,1121	2,0477	1,9796	1,9072	1,8291	
2,8418	2,7946	2,7530	2,7161	2,6830	2,6532	2,6017	2,5223	2,4397	2,3535	2,2629	2,1670	2,0642	
3,1803	3,1231	3,0726	3,0279	2,9880	2,9520	2,8899	2,7941	2,6949	2,5916	2,4834	2,3690	2,2470	
1,7620	1,7454	1,7306	1,7174	1,7055	1,6947	1,6759	1,6465	1,6155	1,5825	1,5472	1,5090	1,4670	
2,0755	2,0500	2,0275	2,0074	1,9893	1,9730	1,9446	1,9005	1,8543	1,8055	1,7537	1,6981	1,6376	
2,3900	2,3554	2,3248	2,2976	2,2732	2,2512	2,2131	2,1540	2,0923	2,0276	1,9591	1,8861	1,8072	
2,8144	2,7672	2,7256	2,6886	2,6555	2,6257	2,5742	2,4946	2,4118	2,3253	2,2344	2,1378	2,0342	
3,1454	3,0882	3,0379	2,9932	2,9532	2,9172	2,8552	2,7594	2,6601	2,5565	2,4480	2,3331	2,2102	
1,7538	1,7371	1,7223	1,7090	1,6970	1,6862	1,6673	1,6377	1,6065	1,5732	1,5376	1,4989	1,4564	
2,0630	2,0374	2,0148	1,9946	1,9765	1,9601	1,9317	1,8874	1,8409	1,7918	1,7396	1,6834	1,6223	
2,3724	2,3378	2,3072	2,2799	2,2554	2,2334	2,1952	2,1359	2,0739	2,0089	1,9400	1,8664	1,7867	
2,7890	2,7418	2,7002	2,6632	2,6301	2,6003	2,5487	2,4689	2,3860	2,2992	2,2079	2,1108	2,0062	
3,1132	3,0560	3,0057	2,9611	2,9211	2,8852	2,8230	2,7272	2,6278	2,5241	2,4152	2,2998	2,1760	
1,6950	1,6778	1,6624	1,6486	1,6362	1,6249	1,6052	1,5741	1,5411	1,5056	1,4672	1,4248	1,3769	
1,9738	1,9476	1,9245	1,9038	1,8851	1,8682	1,8389	1,7929	1,7444	1,6928	1,6373	1,5766	1,5089	
2,2481	2,2130	2,1819	2,1542	2,1293	2,1068	2,0677	2,0069	1,9429	1,8752	1,8028	1,7242	1,6371	
2,6107	2,5634	2,5216	2,4844	2,4511	2,4210	2,3689	2,2880	2,2034	2,1142	2,0194	1,9172	1,8047	
2,8880	2,8312	2,7811	2,7365	2,6966	2,6607	2,5984	2,5020	2,4015	2,2958	2,1838	2,0636	1,9318	
1,6602	1,6426	1,6269	1,6128	1,6000	1,5884	1,5681	1,5361	1,5018	1,4648	1,4242	1,3789	1,3267	
1,9214	1,8949	1,8714	1,8503	1,8313	1,8141	1,7841	1,7371	1,6872	1,6337	1,5756	1,5115	1,4383	
2,1759	2,1404	2,1090	2,0810	2,0558	2,0330	1,9933	1,9313	1,8659	1,7963	1,7211	1,6386	1,5452	
2,5083	2,4609	2,4190	2,3816	2,3481	2,3178	2,2652	2,1835	2,0976	2,0066	1,9090	1,8026	1,6831	
2,7599	2,7031	2,6531	2,6086	2,5686	2,5326	2,4702	2,3732	2,2717	2,1644	2,0499	1,9254	1,7863	
1,6372	1,6193	1,6034	1,5890	1,5760	1,5642	1,5435	1,5107	1,4755	1,4373	1,3952	1,3476	1,2915	
1,8870	1,8602	1,8364	1,8151	1,7959	1,7785	1,7480	1,7001	1,6491	1,5943	1,5343	1,4673	1,3893	
2,1286	2,0929	2,0613	2,0330	2,0076	1,9846	1,9445	1,8817	1,8152	1,7441	1,6668	1,5810	1,4822	
2,4419	2,3944	2,3523	2,3148	2,2811	2,2507	2,1978	2,1154	2,0285	1,9360	1,8363	1,7263	1,6006	
2,6771	2,6205	2,5705	2,5259	2,4859	2,4498	2,3872	2,2898	2,1874	2,0789	1,9622	1,8341	1,6885	
1,6086	1,5904	1,5741	1,5594	1,5461	1,5340	1,5128	1,4790	1,4426	1,4027	1,3582	1,3071	1,2446	
1,8445	1,8174	1,7932	1,7716	1,7520	1,7342	1,7032	1,6542	1,6017	1,5449	1,4821	1,4107	1,3247	
2,0706	2,0346	2,0026	1,9741	1,9483	1,9250	1,8843	1,8204	1,7523	1,6790	1,5987	1,5079	1,3998	
2,3608	2,3131	2,2709	2,2332	2,1993	2,1686	2,1153	2,0318	1,9435	1,8489	1,7459	1,6304	1,4942	
2,5767	2,5201	2,4701	2,4254	2,3854	2,3491	2,2862	2,1881	2,0845	1,9739	1,8540	1,7203	1,5634	
1,5803	1,5617	1,5450	1,5300	1,5164	1,5039	1,4821	1,4472	1,4094	1,3676	1,3203	1,2646	1,1926	
1,8026	1,7750	1,7505	1,7285	1,7085	1,6904	1,6587	1,6084	1,5543	1,4952	1,4290	1,3519	1,2539	
2,0136	1,9773	1,9450	1,9161	1,8900	1,8663	1,8249	1,7597	1,6899	1,6141	1,5299	1,4327	1,3104	
2,2818	2,2340	2,1915	2,1536	2,1194	2,0885	2,0346	1,9500	1,8600	1,7629	1,6557	1,5330	1,3805	
2,4794	2,4228	2,3727	2,3280	2,2878	2,2514	2,1881	2,0890	1,9840	1,8709	1,7469	1,6055	1,4311	
1,5240	1,5046	1,4871	1,4714	1,4570	1,4439	1,4206	1,3832	1,3419	1,2951	1,2400	1,1686	1,0000	
1,7202	1,6918	1,6664	1,6435	1,6228	1,6038	1,5705	1,5173	1,4591	1,3940	1,3180	1,2214	1,0000	
1,9027	1,8656	1,8326	1,8028	1,7759	1,7515	1,7085	1,6402	1,5660	1,4835	1,3883	1,2684	1,0000	
2,1299	2,0815	2,0385	2,0000	1,9652	1,9336	1,8783	1,7908	1,6964	1,5923	1,4730	1,3246	1,0000	
2,2938	2,2371	2,1867	2,1417	2,1011	2,0642	1,9998	1,8983	1,7891	1,6691	1,5325	1,3637	1,0000	

$T_n \xrightarrow{p\text{-th}} g(\theta) \Rightarrow \mathcal{P}_\theta\{|T_n - g(\theta)| < \epsilon\} \rightarrow 0$ (5.5)

Per exemple:

$$\begin{aligned} a_k(n) &\rightarrow \alpha_k(\theta) \\ b_k(n) &\rightarrow \mu_k(\theta) \\ F_n^*(x) &\rightarrow F_\theta(x) \end{aligned}$$

Invariança La pròpia família també ho ha de ser.

Translació:

$$\begin{aligned} F_\theta(x) &= F_{\theta+c}(x+c) \\ f_\theta(x) &= f_{\theta+c}(x+c) \end{aligned} \quad (5.6)$$

Escala:

$$\begin{aligned} F_\theta(x) &= F_{b\theta}(bx) \Rightarrow F_\theta(x) = F_1(x/\theta) \\ f_\theta(x) &= b f_{b\theta}(bx) \Rightarrow f_\theta(x) = \frac{1}{\theta} f_1(x/\theta) \end{aligned} \quad (5.7)$$

Translació i escala:

$$\begin{aligned} F_{\theta_1\theta_2}(x) &= F(\frac{x-\theta_1}{\theta_2}) \\ f_{\theta_1\theta_2}(x) &= \frac{1}{\theta_2} f(\frac{x-\theta_1}{\theta_2}) \end{aligned} \quad (5.8)$$

Suficiència La distribució de la mostra condicionada per l'estadístic no depèn de θ :

$$\begin{aligned} \mathcal{P}_\theta\{X = x | T(x) = t\} &= \mathcal{P}\{X = x | T(x) = t\} \\ \text{altra notació: } \mathcal{P}\{x | t, \theta\} &= \mathcal{P}\{x | t\} \end{aligned} \quad (5.9)$$

Teorema de la factorització $T(X_1, \dots, X_n)$ és suficient si i solament si:

$$f_\theta(x_1, \dots, x_n) = g_\theta(T(x_1, \dots, x_n))h(x_1, \dots, x_n) \quad (5.10)$$

Estadístic suficient minimal T' és un estadístic suficient minimal si qualsevol altra suficient T es pot expressar com a funció de T' : $T = \varphi(T')$

Teorema: Un estadístic $T(X_1, \dots, X_n)$ és suficient minimal si i sol: si:

$$\begin{aligned} \frac{f_\theta(x_1, \dots, x_n)}{f_\theta(x'_1, \dots, x'_n)} \text{ és independent de } \theta \Leftrightarrow \\ T(x_1, \dots, x_n) = T(x'_1, \dots, x'_n) \end{aligned} \quad (5.11)$$

Un estadístic suficient minimal és únic, excepte transformacions biunívocues.

Exemple: Per a una família exponencial:

$$f_\theta(x) = c(\theta)h(x) \exp\left\{\sum_{j=1}^p q_j(\theta)T_j(x)\right\} \quad (5.12)$$

$$\begin{aligned} \frac{f_\theta(x_1, \dots, x_n)}{f_\theta(x'_1, \dots, x'_n)} &= \frac{h(x_1) \cdots h(x_n)}{h(x'_1) \cdots h(x'_n)} \times \\ &\exp\left\{\sum_{j=1}^p q_j(\theta) \left[\sum_{i=1}^n T_j(x_i) - \sum_{i=1}^n T_j(x'_i)\right]\right\} \end{aligned}$$

Que serà independent de θ només si $\sum_{i=1}^n T_j(x_i) = \sum_{i=1}^n T_j(x'_i)$. Per tant, l'estadístic $(\sum_{i=1}^n T_1(x_i), \dots, \sum_{i=1}^n T_p(x_i))$ és suficient minimal.

$$\frac{\bar{x} - \bar{y} - (m - n)\mu_2}{\sqrt{1/n + 1/m} \sqrt{nS_1^2 + mS_2^2}} \sim t_{n+m-2}$$

$$\left[\bar{x} - \bar{y} \pm t_{n+m-2, \alpha/2} \sqrt{\frac{nS_1^2 + mS_2^2}{n+m-2} \left[\frac{1}{n} + \frac{1}{m} \right]} \right]$$

Quocient de variances, σ_1/σ_2 :

$$\frac{S_1^2/\sigma_1}{S_2^2/\sigma_2} \sim F_{n-1, m-1}$$

$$\left[\frac{S_1^2/S_2^2}{F_{n-1, m-1, \alpha/2}}, \frac{S_1^2/S_2^2}{F_{n-1, m-1, 1-\alpha/2}} \right]$$

Distribucions asimptòtiques. T_n és una successió d'estadístics, i $\sigma_n(\theta)$ depèn en general de n i del paràmetre θ . Si:

$$\frac{T_n - \theta}{\sigma_n(\theta)} \xrightarrow{d} N(0, 1) \Rightarrow \mathcal{P}_\theta\left\{-z_{\alpha/2} < \frac{T_n - \theta}{\sigma_n(\theta)} < z_{\alpha/2}\right\} \approx 1 - \alpha$$

De manera que si es pot aïllar θ de la desigualtat, es té un I.C. per θ .

Capítol 5

Estimació puntual

Estimador: Estadístic $T(X_1, \dots, X_n) : \mathcal{X} \rightarrow \Theta$ que permet l'estimació d'un paràmetre θ d'una distribució $\in \mathcal{F} = \{F_\theta | \theta \in \Theta \subset \mathbb{R}^k\}$.

5.1 Comparació d'estimadors

Funció de pèrdua $L(\theta, t) : \Theta \times \Theta \rightarrow \mathbb{R}$: Dóna el cost quan s'estima t i el paràmetre real és θ .

Risc Si $G_\theta(t)$ és la distribució de l'estimador:

$$R_T(\theta) = E_\theta[L(\theta, T(X_1, \dots, X_n))] = \int_{\mathbb{R}} L(\theta, t)G_\theta(dt) \quad (5.1)$$

Error quadràtic mitjà (EQM)

$$\begin{aligned} L(\theta, t) &= (\theta - t)^2 \\ \text{EQM}(\theta) &= E_\theta(\theta - t)^2 \end{aligned} \quad (5.2)$$

Estimador inadmissible Per qualsevol θ té un risc major que un altre estimador de la mateixa família.

Biaix

$$b_T(\theta) = E_\theta[T] - g(\theta) \Rightarrow \quad (5.3)$$

$$\begin{aligned} \text{EQM}(\theta) &= E_\theta((T - E_T) - (g(\theta) - E_T))^2 = \\ &E(T - E_T)^2 + (g(\theta) - E_T)^2 = \text{Var}_\theta + b_T(\theta)^2 \end{aligned} \quad (5.4)$$

Estatístic ancilar és un estadístic amb distribució independent del paràmetre. Per exemple, si $X_i \sim N(\mu, \sigma)$, aleshores, l'estadístic $T = \frac{\sum_{i=1}^n X_i}{n}$ és ancilar de μ .

5.2 Estimator minimax

Estimator que agafant el màxim risc al variar θ , dona el mínim valor:

$$\min_{T'} \max_{\theta \in \Theta} R_{T'}(\theta) \quad (5.13)$$

5.3 Estimator Bayes

Suposem θ una V.A. amb distribució "a priori" $\pi(\theta)$. El "risc bayes" és:

$$r_T(\pi) = \int_{\Theta} R_T(\theta) \pi(\theta) d\theta \quad (5.14)$$

L'estimator Bayes és el que minimitza $r_T(\pi)$:

$$\inf_{T'} r_T(\pi) \quad (5.15)$$

Donat que $f(\theta, x_1, \dots, x_n) = \pi(\theta) f_{\theta}(x_1, \dots, x_n)$, la distribució marginal de (X_1, \dots, X_n) val:

$$f(x_1, \dots, x_n) = \int_{\Theta} f(\theta, x_1, \dots, x_n) d\theta =$$

$$\int_{\Theta} \pi(\theta) f_{\theta}(x_1, \dots, x_n) d\theta$$

i la "distribució a posteriori" de θ condicionada per (X_1, \dots, X_n) serà:

$$\pi(\theta | x_1, \dots, x_n) = \frac{\pi(\theta) f_{\theta}(x_1, \dots, x_n)}{f(x_1, \dots, x_n)} = \frac{\pi(\theta) f_{\theta}(x_1, \dots, x_n)}{\int_{\Theta} \pi(\theta) f_{\theta}(x_1, \dots, x_n) d\theta} \quad (5.16)$$

i el risc Bayes:

$$\begin{aligned} r_T(\pi) &= \int_{\Theta} R_T(\theta) \pi(\theta) d\theta = \\ &= \int_{\Theta} \int_{\mathcal{X}} L(\theta, T(x_1, \dots, x_n)) f_{\theta}(x_1, \dots, x_n) dx_1 \dots dx_n \pi(\theta) d\theta \\ &= \int_{\mathcal{X}} \int_{\Theta} L(\theta, T(x_1, \dots, x_n)) \pi(\theta | x_1, \dots, x_n) d\theta \\ &\quad f(x_1, \dots, x_n) dx_1 \dots dx_n \end{aligned}$$

Per tant, l'estimator Bayes és el que minimitza:

$$\inf_{T'} \int_{\Theta} L(\theta, T(x_1, \dots, x_n)) \pi(\theta | x_1, \dots, x_n) d\theta \Rightarrow \begin{cases} L(\theta, t) = |\theta - t| \Rightarrow T(x_1, \dots, x_n) = \text{mediana de } \pi(\theta | x_1, \dots, x_n) \\ L(\theta, t) = \text{EQM}(\theta) = (\theta - t)^2 \Rightarrow T(x_1, \dots, x_n) = \text{mitjana de } \pi(\theta | x_1, \dots, x_n) \\ E[\theta | x_1, \dots, x_n] \end{cases}$$

Propietats de l'estimator Bayes:

- Pot ser biaixat.

- $\pi(\theta | x_1, \dots, x_n)$ és funció de l'estimator minimal suficient-ent.

- Si $R_T(\theta)$ és independent de θ , T és un estimator minimax.

Capítol 6

Estimadors de risc mínim

6.1 Estimator centrat uniformement de mínima varianza (ECUMV)

Estimator centrat

$$E_{\theta} T = g(\theta) \quad (6.1)$$

L'ECUMV minimitza l'EQM:

$$\text{EQM}(\theta) = E_{\theta}(g(\theta) - T)^2 = E_{\theta}(E_{\theta} T - T)^2 = \text{Var}_{\theta} T$$

Teorema: Si l'ECUMV existeix és únic (pot not existir, p.e. si no existeix un estimator centrat de $g(\theta)$).

Teorema de Rao-Blackwell Si S és un estadístic suficient i T és un estadístic centrat, aleshores $T' = E_{\theta}[T|S]$: (i) És un estimator centrat de $g(\theta)$, (ii) $\text{Var}_{\theta}(T') \leq \text{Var}_{\theta}(T)$. Més precisament: Si $L(\theta, t)$ és convexa $\Rightarrow E[T|S]$ té sempre un risc menor que T .
Demostració:

$$\begin{aligned} \text{Var} T' &= \text{Var} E[T|S] + E \text{Var}[T|S] \Rightarrow \\ \text{Var} T' &\geq \text{Var} E[T|S] = \text{Var} T' \\ E T' &= E E[T|S] = E T \end{aligned}$$

Estatístic complet Un estadístic $T(X_1, \dots, X_n)$ és complet si complex:

$$E_{\theta} f(T) = 0 \Rightarrow f(s) = 0 \text{ c.s. per tot } \theta \in \Theta$$

Propietats:

- Un estadístic suficient complet, és suficient minimal. Si una família de distribucions té un estadístic suficient minimal complet, la família s'anomena completa.
- Si la distribució poblacional és del tipus exponencial (veure (5.12)):

$$f_{\theta}(x) = c(\theta) h(\theta) \exp \left\{ \sum_{j=1}^p q_j(\theta) T_j(x) \right\}$$

L'estadístic $(\sum_{i=1}^n T_1(x_i), \dots, \sum_{i=1}^n T_p(x_i))$ és complet si $(q_1(\theta), \dots, q_p(\theta))$ conté un conjunt obert en \mathbb{R}^p (veure [1, teorema 6.2.25, pàg. 288]).

Taula 10.6: Distribució F de Snedecor, $\mathcal{P}\{F_{n,m} > F_{n,m;\alpha}\}$ (continuació).

m	α	1	2	3	4	5	6	7	8	9	10	11	12
0.100	2.8939	2.5028	2.2906	2.1571	2.0645	1.9958	1.9427	1.9001	1.8652	1.8359	1.8110	1.7895	
0.050	4.1960	3.3404	2.9467	2.7141	2.5581	2.4453	2.3593	2.2913	2.2360	2.1900	2.1512	2.1179	
28	0.025	5.6096	4.2205	3.6264	3.2863	3.0625	2.9026	2.7820	2.6872	2.6106	2.5473	2.4940	2.4484
	0.010	7.6356	5.4529	4.5681	4.0740	3.7539	3.5276	3.3581	3.2259	3.1195	3.0320	2.9585	2.8959
	0.005	9.2838	6.4403	5.3170	4.6977	4.2996	4.0197	3.8110	3.6488	3.5186	3.4117	3.3222	3.2460
	0.100	2.8870	2.4955	2.2831	2.1494	2.0566	1.9878	1.9345	1.8918	1.8568	1.8274	1.8024	1.7808
	0.050	4.1830	3.3277	2.9340	2.7014	2.5454	2.4324	2.3463	2.2782	2.2229	2.1768	2.1379	2.1045
	29	0.025	5.5878	4.2006	3.6072	3.2674	3.0438	2.8840	2.7633	2.6686	2.5920	2.5286	2.4752
	0.010	7.5977	5.4204	4.5378	4.0449	3.7254	3.4995	3.3302	3.1982	3.0920	3.0045	2.9311	2.8685
	0.005	9.2297	6.3958	5.2764	4.6591	4.2622	3.9831	3.7749	3.6130	3.4832	3.3765	3.2871	3.2111
	0.100	2.8807	2.4887	2.2761	2.1422	2.0492	1.9803	1.9269	1.8841	1.8490	1.8195	1.7944	1.7727
	0.050	4.1709	3.3158	2.9223	2.6896	2.5335	2.4205	2.3343	2.2662	2.2107	2.1646	2.1256	2.0921
	30	0.025	5.5675	4.1821	3.5894	3.2499	3.0265	2.8667	2.7460	2.6513	2.5746	2.5112	2.4577
	0.010	7.5625	5.3903	4.5097	4.0179	3.6990	3.4735	3.3045	3.1726	3.0665	2.9791	2.9057	2.8420
	0.005	9.1797	6.3547	5.2388	4.6234	4.2276	3.9492	3.7416	3.5801	3.4505	3.3440	3.2547	3.1787
	0.100	2.8354	2.4404	2.2261	2.0909	1.9968	1.9269	1.8725	1.8289	1.7929	1.7627	1.7369	1.7146
	0.050	4.0847	3.2317	2.8388	2.6060	2.4495	2.3359	2.2490	2.1802	2.1240	2.0772	2.0376	2.0035
	40	0.025	5.4239	4.0510	3.4633	3.1261	2.9037	2.7444	2.6238	2.5289	2.4519	2.3882	2.3343
	0.010	7.3141	5.1785	4.3126	3.8283	3.5138	3.2910	3.1238	2.9930	2.8876	2.8005	2.7273	2.6648
	0.005	8.8279	6.0664	4.9758	4.3738	3.9861	3.7129	3.5088	3.3498	3.2220	3.1168	3.0284	2.9531
	0.100	2.8087	2.4120	2.1967	2.0608	1.9660	1.8954	1.8405	1.7963	1.7598	1.7291	1.7029	1.6802
	0.050	4.0343	3.1826	2.7900	2.5572	2.4004	2.2864	2.1992	2.1299	2.0734	2.0261	1.9861	1.9515
	50	0.025	5.3403	3.9749	3.3902	3.0544	2.8327	2.6736	2.5530	2.4579	2.3808	2.3168	2.2627
	0.010	7.1706	5.0566	4.1993	3.7195	3.4077	3.1864	3.0202	2.8900	2.7981	2.7250	2.6525	2.5825
	0.005	8.6258	5.9016	4.8259	4.2316	3.8486	3.5785	3.3765	3.2189	3.0920	2.9875	2.8997	2.8247
	0.100	2.7911	2.3933	2.1774	2.0410	1.9457	1.8747	1.8194	1.7748	1.7380	1.7070	1.6805	1.6574
	0.050	4.0012	3.1504	2.7581	2.5252	2.3683	2.2540	2.1665	2.0970	2.0401	1.9926	1.9522	1.9174
	60	0.025	5.2856	3.9253	3.3425	3.0077	2.7863	2.6274	2.5068	2.4117	2.3344	2.2702	2.2159
	0.010	7.0771	4.9774	4.1259	3.6490	3.3389	3.1187	2.9531	2.8233	2.7184	2.6317	2.5587	2.4961
	0.005	8.4946	5.7950	4.7290	4.1399	3.7599	3.4918	3.2911	3.1344	3.0083	2.9042	2.8166	2.7419
	0.100	2.7693	2.3702	2.1536	2.0165	1.9206	1.8491	1.7933	1.7483	1.7110	1.6796	1.6526	1.6292
	0.050	3.9604	3.1108	2.7188	2.4859	2.3287	2.2142	2.1263	2.0564	1.9991	1.9512	1.9105	1.8753
	80	0.025	5.2184	3.8643	3.2841	2.9504	2.7295	2.5708	2.4502	2.3549	2.2775	2.2130	2.1584
	0.010	6.9627	4.8807	4.0363	3.5631	3.2551	3.0361	2.8713	2.7420	2.6374	2.5508	2.4777	2.4151
	0.005	8.3346	5.6652	4.6113	4.0285	3.6524	3.3867	3.1876	3.0320	2.9066	2.8030	2.7159	2.6413
	0.100	2.7478	2.3473	2.1300	1.9923	1.8959	1.8238	1.7675	1.7220	1.6843	1.6524	1.6250	1.6012
	0.050	3.9201	3.0718	2.6802	2.4472	2.2898	2.1750	2.0868	2.0164	1.9588	1.9105	1.8693	1.8337
	120	0.025	5.1523	3.8066	3.2269	2.8943	2.6740	2.5154	2.3948	2.2994	2.2217	2.1570	2.1021
	0.010	6.8509	4.7845	3.9491	3.4795	3.1736	2.9558	2.7918	2.6629	2.5586	2.4721	2.3990	2.3363
	0.005	8.1788	5.5393	4.4972	3.9207	3.5482	3.2849	3.0874	2.9303	2.8083	2.7052	2.6183	2.5439
	0.100	2.7055	2.3026	2.0838	1.9449	1.8473	1.7741	1.7167	1.6702	1.6315	1.5987	1.5705	1.5458
	0.050	3.8415	2.9957	2.6049	2.3719	2.2141	2.0986	2.0096	1.9384	1.8799	1.8307	1.7887	1.7522
	∞	0.025	5.0239	3.6889	3.1161	2.7858	2.5665	2.4082	2.2875	2.1918	2.1136	2.0483	1.9947
	0.010	6.6349	4.6052	3.7816	3.3192	3.0173	2.8020	2.6393	2.5113	2.4073	2.3209	2.2477	2.1848
	0.005	7.8794	5.2983	4.2794	3.7151	3.3499	3.0913	2.8968	2.7444	2.6210	2.5188	2.4324	2.3583

7.2 Mètode de la màxima verosimilitut

$$\hat{\theta} = f_{\theta}(x_1, \dots, x_n) = \max_{\theta \in \Theta} f_{\theta}(x_1, \dots, x_n) \tag{7.1}$$

Sovint és millor buscar el màxim del logaritme:

$$\hat{\theta} = \log f_{\theta}(x_1, \dots, x_n) = \max_{\theta \in \Theta} \log f_{\theta}(x_1, \dots, x_n) \tag{7.2}$$

Cal buscar els màxims relatius i comparar-los amb el màxim en la frontera de Θ . Si $\theta = (\theta_1, \dots, \theta_k)$:

$$\frac{\partial}{\partial \theta_j} \log f_{\theta}(x_1, \dots, x_n) = 0 \quad j = 1, \dots, k$$

Propietats

- Si θ és unidimensional i la família regular, si existeix un estimador centrat i eficient de θ , aleshores ha de ser l'únic estimador de màxima verosimilitut. Demostració:

$$\text{Eficient} \Rightarrow \frac{\partial}{\partial \theta} \log f_{\theta} = \frac{1}{k(\theta)} (T(x_1, \dots, x_n) - g(\theta))$$

Màxima verosimilitut \Rightarrow

$$\frac{\partial}{\partial \theta} \log f_{\theta} = 0 \Rightarrow g(\hat{\theta}) = T(x_1, \dots, x_n)$$

- Invariança: Si $\hat{\theta}$ és l'estimador de màxima verosimilitut de θ , aleshores $g(\hat{\theta})$ és l'estimador de màxima verosimilitut de $g(\theta)$. Nota: És possible que $\hat{\theta}$ sigui un estimador centrat de θ , però que $g(\hat{\theta})$ no ho sigui de $g(\theta)$.

- Propietats asimptòtiques:

- És consistent: $\hat{\theta}_n \xrightarrow{d} \theta$.
- Sota certes condicions de regularitat: $\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N(0, \sqrt{I(\theta)^{-1}})$

7.3 Estimació Bayesiana

Donada la distribució a posteriori (veure (5.16)):

$$\pi(\theta | x_1, \dots, x_n) = \frac{\pi(\theta) f_{\theta}(x_1, \dots, x_n)}{\int \pi(\theta) f_{\theta}(x_1, \dots, x_n) d\theta}$$

La mitjana minimitza l'EQM. El màxim (la moda de la distribució) també és un estimador en el sentit de màxima verosimilitut. Nota: si $\pi(\theta)$ és una distribució uniforme, aleshores la moda de $\pi(\theta | x_1, \dots, x_n)$ coincidirà amb l'estimador de màxima verosimilitut.

Capítol 8

Constrast d'hipòtesis

- Hipòtesi nul·la: $H_0 : \theta \in \Theta_0$
- Hipòtesi alternativa: $H_1 : \theta \in \Theta_1$

Capítol 8. Constrast d'hipòtesi

Test d'hipòtesi: divisió del recorregut de $X = (X_1, \dots, X_n) \in X$ en dues regions C i C^c :

- Regió crítica, C : si $X \in C$ es rebutja H_0 .
- Regió d'acceptació, C^c : si $X \in C^c$ s'accepta H_0 .

- Test aleatoritzat: $\varphi : X \rightarrow [0, 1]$. φ s'anomena funció crítica del test.
- Test no aleatoritzat:

$$\varphi(x_1, \dots, x_n) = I_C(x_1, \dots, x_n) = \begin{cases} 1 & \text{si } x_1, \dots, x_n \in C \\ 0 & \text{si } x_1, \dots, x_n \in C^c \end{cases}$$

Alternatives del contrast:

H_0 és certa	H_0 és falsa
Rebutjar H_0	error de tipus I
Acceptar H_0	error de tipus II

Criteri tradicional:

- Fixar una cota α a l'error de tipus I: Nivell de significació del contrast. Normalment $\alpha = 0,1; 0,05; \dots$
- Triar una família de tests que:
 - $P_{H_0}\{C\} \leq \alpha$ ó $E_{H_0} \varphi(x_1, \dots, x_n) \leq \alpha$
- D'entra la família, triar la que minimitza l'error de tipus II:

$$P_{H_1}\{C\} \text{ ó } E_{H_1} \varphi(x_1, \dots, x_n)$$

Funció de potència $\beta(\theta)$ Quan la distribució poblacional depèn d'un paràmetre θ , $\beta(\theta)$ és la probabilitat de que $X = (X_1, \dots, X_n) \in C$ quan el paràmetre val θ , és a dir, és la probabilitat de rebutjar H_0 quan el paràmetre val θ :

$$\beta(\theta) = P_{\theta}\{X \in C\} = E_{\theta} \varphi(X), \quad X = (X_1, \dots, X_n)$$

Un test té nivell de significació α si $\beta(\theta) \leq \alpha \forall \theta \in \Theta_0$. S'anomena mida del test el $\sup_{\theta \in \Theta_0} \beta(\theta)$. És desitjable que sigui α .

Donats 2 tests φ i φ' de significació α , es diu uniformement més potent que φ' si:

$$\beta_{\varphi}(\theta) \geq \beta_{\varphi'}(\theta), \quad \theta \in \Theta_1$$

Nota: L'error de tipus II val $1 - \beta(\theta)$, $\theta \in \Theta_1$, per tant, φ tindrà un error de tipus II menor que φ' .

Taula 10.6: Distribució F de Snedecor, $\mathcal{P}\{F_{n,m} > F_{n,m;\alpha}\}$ (continuació).

m	α	1	2	3	4	5	6	7	8	9	10	11	12
0.10	2,9899	2,6056	2,3970	2,2663	2,1760	2,1094	2,0580	2,0171	1,9836	1,9557	1,9321	1,9117	
0.05	4,3807	3,5219	3,1273	2,8951	2,7401	2,6283	2,5435	2,4768	2,4227	2,3779	2,3402	2,3079	
19	0,025	5,9216	4,5075	3,9034	3,5587	3,3327	3,1718	3,0509	2,9563	2,8801	2,8173	2,7645	2,7196
0.010	8,1850	5,9259	5,0103	4,5003	4,1708	3,9386	3,7653	3,6305	3,5225	3,4338	3,3596	3,2965	
0.005	10,072	7,0935	5,9161	5,2681	4,8526	4,5614	4,3448	4,1770	4,0428	3,9329	3,8410	3,7631	
0.100	2,9747	2,5892	2,3801	2,2489	2,1582	2,0913	2,0397	1,9985	1,9648	1,9367	1,9129	1,8924	
0.050	4,3512	3,4928	3,0984	2,8661	2,7109	2,5990	2,5140	2,4471	2,3928	2,3479	2,3100	2,2776	
20	0,025	5,8715	4,4613	3,8587	3,5147	3,2891	3,1283	3,0074	2,9128	2,8365	2,7737	2,7209	2,6758
0.010	8,0960	5,8489	4,9382	4,4307	4,1027	3,8714	3,6987	3,5644	3,4567	3,3682	3,2941	3,2311	
0.005	9,9439	6,9865	5,8177	5,1743	4,7616	4,4722	4,2569	4,0900	3,9564	3,8470	3,7555	3,6779	
0.100	2,9610	2,5746	2,3649	2,2333	2,1423	2,0751	2,0232	1,9819	1,9480	1,9197	1,8957	1,8750	
0.050	4,3248	3,4668	3,0725	2,8401	2,6848	2,5727	2,4876	2,4205	2,3660	2,3209	2,2829	2,2504	
21	0,025	5,8266	4,4199	3,8188	3,4754	3,2501	3,0895	2,9686	2,8740	2,7977	2,7348	2,6819	2,6368
0.010	8,0166	5,7804	4,8741	4,3688	4,0421	3,8117	3,6396	3,5056	3,3981	3,3098	3,2359	3,1730	
0.005	9,8295	6,8914	5,7304	5,0911	4,6809	4,3931	4,1789	4,0128	3,8799	3,7709	3,6798	3,6024	
0.100	2,9486	2,5613	2,3512	2,2193	2,1279	2,0605	2,0084	1,9668	1,9327	1,9042	1,8801	1,8593	
0.050	4,3010	3,4434	3,0491	2,8167	2,6613	2,5491	2,4638	2,3965	2,3419	2,2967	2,2585	2,2258	
22	0,025	5,7863	4,3828	3,7829	3,4401	3,2151	3,0546	2,9338	2,8392	2,7628	2,6998	2,6469	2,6017
0.010	7,9454	5,7190	4,8166	4,3134	3,9880	3,7583	3,5867	3,4530	3,3458	3,2576	3,1837	3,1209	
0.005	9,7271	6,8064	5,6524	5,0168	4,6088	4,3225	4,1094	3,9440	3,8116	3,7030	3,6122	3,5350	
0.100	2,9374	2,5493	2,3387	2,2065	2,1149	2,0472	1,9949	1,9531	1,9189	1,8902	1,8659	1,8450	
0.050	4,2793	3,4217	3,0280	2,7955	2,6401	2,5277	2,4422	2,3748	2,3201	2,2747	2,2364	2,2036	
23	0,025	5,7498	4,3462	3,7463	3,4035	3,1785	3,0180	2,9072	2,8126	2,7362	2,6732	2,6200	2,5699
0.010	7,8811	5,6637	4,7649	4,2636	3,9392	3,7102	3,5390	3,4057	3,2986	3,2106	3,1368	3,0740	
0.005	9,6348	6,7300	5,5823	4,9501	4,5441	4,2591	4,0469	3,8822	3,7502	3,6420	3,5515	3,4745	
0.100	2,9271	2,5383	2,3274	2,1949	2,1030	2,0351	1,9826	1,9407	1,9062	1,8775	1,8530	1,8319	
0.050	4,2597	3,4028	3,0088	2,7763	2,6206	2,5082	2,4226	2,3551	2,3002	2,2547	2,2163	2,1834	
24	0,025	5,7166	4,3187	3,7211	3,3794	3,1548	2,9946	2,8738	2,7791	2,7027	2,6396	2,5865	2,5412
0.010	7,8229	5,6136	4,7180	4,2184	3,8951	3,6667	3,4959	3,3629	3,2560	3,1681	3,0944	3,0316	
0.005	9,5513	6,6609	5,5190	4,8898	4,4857	4,2019	3,9905	3,8264	3,6949	3,5870	3,4967	3,4199	
0.100	2,9177	2,5283	2,3170	2,1842	2,0922	2,0241	1,9714	1,9292	1,8947	1,8658	1,8412	1,8200	
0.050	4,2417	3,3852	2,9912	2,7587	2,6030	2,4904	2,4047	2,3371	2,2821	2,2365	2,1979	2,1649	
25	0,025	5,6864	4,2909	3,6943	3,3530	3,1287	2,9686	2,8478	2,7531	2,6766	2,6135	2,5603	2,5149
0.010	7,7698	5,5680	4,6755	4,1774	3,8550	3,6272	3,4567	3,3239	3,2172	3,1294	3,0558	2,9931	
0.005	9,4753	6,5982	5,4615	4,8351	4,4327	4,1500	3,9394	3,7758	3,6447	3,5370	3,4470	3,3704	
0.100	2,9091	2,5191	2,3075	2,1745	2,0822	2,0139	1,9610	1,9188	1,8841	1,8550	1,8303	1,8090	
0.050	4,2252	3,3690	2,9752	2,7426	2,5868	2,4741	2,3883	2,3205	2,2654	2,2197	2,1811	2,1479	
26	0,025	5,6586	4,2655	3,6697	3,3289	3,1048	2,9447	2,8240	2,7293	2,6528	2,5896	2,5363	2,4909
0.010	7,7213	5,5263	4,6366	4,1400	3,8183	3,5911	3,4210	3,2884	3,1818	3,0941	3,0205	2,9579	
0.005	9,4059	6,5409	5,4091	4,7852	4,3844	4,1027	3,8928	3,7297	3,5989	3,4916	3,4017	3,3252	
0.100	2,9012	2,5106	2,2987	2,1655	2,0730	2,0045	1,9515	1,9091	1,8743	1,8451	1,8203	1,7989	
0.050	4,2100	3,3541	2,9604	2,7278	2,5719	2,4591	2,3732	2,3053	2,2501	2,2043	2,1655	2,1323	
27	0,025	5,6331	4,2421	3,6472	3,3067	3,0828	2,9228	2,8021	2,7074	2,6309	2,5676	2,5143	2,4688
0.010	7,6767	5,4881	4,6009	4,1056	3,7848	3,5580	3,3882	3,2558	3,1494	3,0617	2,9882	2,9256	
0.005	9,3423	6,4885	5,3611	4,7396	4,3402	4,0594	3,8501	3,6875	3,5571	3,4499	3,3602	3,2839	

Taula 10.6: Distribució F de Snedecor, $\mathcal{P}\{F_{n,m} > F_{n,m;\alpha}\}$ (continuació).

		n											∞
		13	14	15	16	17	18	20	24	30	40	60	
2.2687	2.2553	2.2435	2.2330	2.2237	2.2153	2.2077	2.1784	2.1554	2.1317	2.1072	2.0818	2.0574	
2.8872	2.8647	2.8450	2.8276	2.8120	2.7980	2.7740	2.7372	2.6995	2.6609	2.6211	2.5801	2.5379	
3.5832	3.5504	3.5217	3.4963	3.4737	3.4534	3.4185	3.3654	3.3110	3.2554	3.1984	3.1399	3.0798	
4.6496	4.6008	4.581	4.5205	4.4869	4.4569	4.4054	4.3269	4.2469	4.1653	4.0819	3.9965	3.9090	
5.5887	5.5257	5.4707	5.4221	5.3789	5.3403	5.2740	5.1732	5.0705	4.9659	4.8592	4.7501	4.6385	
2.1930	2.1792	2.1671	2.1563	2.1467	2.1380	2.1231	2.1000	2.0762	2.0516	2.0261	1.9996	1.9721	
2.7614	2.7386	2.7186	2.7009	2.6851	2.6709	2.6465	2.6090	2.5705	2.5309	2.4901	2.4480	2.4045	
3.3917	3.3588	3.3299	3.3044	3.2816	3.2612	3.2261	3.1725	3.1176	3.0613	3.0035	2.9441	2.8828	
4.3416	4.2932	4.2509	4.2134	4.1801	4.1503	4.0991	4.0209	3.9411	3.8596	3.7761	3.6904	3.6024	
5.1649	5.1030	5.0489	5.0014	4.9586	4.9205	4.8552	4.7557	4.6543	4.5508	4.4450	4.3367	4.2255	
2.1313	2.1173	2.1048	2.0938	2.0839	2.0751	2.0597	2.0360	2.0115	1.9861	1.9597	1.9323	1.9036	
2.6602	2.6371	2.6168	2.5989	2.5828	2.5684	2.5436	2.5055	2.4663	2.4259	2.3842	2.3410	2.2962	
3.2393	3.2062	3.1772	3.1515	3.1286	3.1081	3.0728	3.0187	2.9633	2.9064	2.8478	2.7874	2.7249	
4.0998	4.0518	4.0096	3.9724	3.9392	3.9095	3.8584	3.7805	3.7008	3.6192	3.5355	3.4494	3.3608	
4.8358	4.7748	4.7213	4.6741	4.6321	4.5945	4.5299	4.4314	4.3309	4.2282	4.1229	4.0149	3.9039	
2.0802	2.0658	2.0532	2.0419	2.0318	2.0227	2.0070	1.9827	1.9576	1.9315	1.9043	1.8759	1.8462	
2.5769	2.5536	2.5331	2.5149	2.4987	2.4841	2.4589	2.4202	2.3803	2.3392	2.2966	2.2524	2.2064	
3.1150	3.0819	3.0527	3.0269	3.0039	2.9832	2.9477	2.8932	2.8373	2.7797	2.7204	2.6590	2.5955	
3.9052	3.8573	3.8154	3.7782	3.7452	3.7156	3.6646	3.5867	3.5070	3.4253	3.3413	3.2548	3.1654	
4.5733	4.5129	4.4600	4.4132	4.3716	4.3344	4.2703	4.1726	4.0727	3.9704	3.8655	3.7577	3.6465	
2.0370	2.0224	2.0095	1.9981	1.9878	1.9785	1.9625	1.9377	1.9119	1.8852	1.8572	1.8280	1.7973	
2.5073	2.4837	2.4630	2.4446	2.4282	2.4134	2.3879	2.3487	2.3082	2.2664	2.2229	2.1778	2.1307	
3.0119	2.9786	2.9493	2.9234	2.9003	2.8795	2.8437	2.7888	2.7324	2.6742	2.6141	2.5519	2.4872	
3.7452	3.6975	3.6557	3.6187	3.5857	3.5561	3.5052	3.4274	3.3476	3.2656	3.1813	3.0942	3.0040	
4.3591	4.2993	4.2468	4.2005	4.1592	4.1222	4.0585	3.9614	3.8619	3.7600	3.6553	3.5473	3.4359	
2.0002	1.9853	1.9722	1.9606	1.9501	1.9406	1.9243	1.8990	1.8728	1.8454	1.8168	1.7867	1.7550	
2.4481	2.4244	2.4034	2.3849	2.3683	2.3533	2.3275	2.2878	2.2468	2.2043	2.1601	2.1141	2.0659	
2.9249	2.8915	2.8621	2.8361	2.8128	2.7919	2.7559	2.7006	2.6437	2.5850	2.5242	2.4611	2.3954	
3.6115	3.5639	3.5222	3.4853	3.4523	3.4228	3.3719	3.2940	3.2141	3.1319	3.0471	2.9594	2.8684	
4.1813	4.1219	4.0698	4.0237	3.9827	3.9459	3.8826	3.7859	3.6867	3.5850	3.4803	3.3722	3.2602	
1.9682	1.9532	1.9399	1.9281	1.9175	1.9079	1.8913	1.8656	1.8388	1.8108	1.7816	1.7508	1.7182	
2.3973	2.3733	2.3522	2.3335	2.3167	2.3016	2.2756	2.2354	2.1938	2.1507	2.1058	2.0589	2.0096	
2.8506	2.8170	2.7875	2.7614	2.7380	2.7170	2.6808	2.6252	2.5678	2.5085	2.4471	2.3831	2.3163	
3.4981	3.4506	3.4089	3.3721	3.3391	3.3096	3.2587	3.1808	3.1007	3.0183	2.9331	2.8447	2.7528	
4.0314	3.9723	3.9205	3.8746	3.8338	3.7972	3.7342	3.6378	3.5389	3.4372	3.3324	3.2240	3.1115	
1.9404	1.9252	1.9117	1.8997	1.8889	1.8792	1.8624	1.8362	1.8090	1.7805	1.7506	1.7191	1.6856	
2.3531	2.3289	2.3077	2.2888	2.2719	2.2567	2.2304	2.1898	2.1477	2.1040	2.0584	2.0107	1.9604	
2.7863	2.7526	2.7230	2.6968	2.6733	2.6522	2.6158	2.5598	2.5020	2.4422	2.3801	2.3153	2.2474	
3.4007	3.3533	3.3117	3.2748	3.2419	3.2124	3.1615	3.0835	3.0032	2.9205	2.8348	2.7458	2.6530	
3.9033	3.8445	3.7929	3.7473	3.7066	3.6701	3.6073	3.5112	3.4124	3.3108	3.2058	3.0971	2.9839	
1.9158	1.9004	1.8868	1.8747	1.8638	1.8539	1.8369	1.8103	1.7827	1.7537	1.7232	1.6910	1.6567	
2.3143	2.2900	2.2686	2.2496	2.2325	2.2172	2.1907	2.1497	2.1071	2.0629	2.0166	1.9681	1.9168	
2.7302	2.6964	2.6667	2.6404	2.6168	2.5956	2.5590	2.5027	2.4445	2.3842	2.3214	2.2558	2.1869	
3.3162	3.2689	3.2273	3.1904	3.1575	3.1280	3.0771	2.9990	2.9185	2.8354	2.7493	2.6597	2.5660	
3.7926	3.7341	3.6827	3.6373	3.5967	3.5603	3.4977	3.4017	3.3030	3.2014	3.0962	2.9871	2.8732	

Nivell crític (p-valor) Donada una mostra (x_1, \dots, x_n) és el nivell de significació $\alpha(x_1, \dots, x_n)$ més petit que ens porta a rebutjar H_0 , donat que H_0 és certa. Quan es fa servir el p-valor, es rebutja H_0 en cas de resultar un p-valor inferior al nivell de significació desitjat.

Exemple: Suposem $X \sim N(\theta, \sigma)$, amb σ conegut i $H_0: \theta = \theta_0, H_1: \theta = \theta_1$, amb $\theta_1 < \theta_0$. La regió crítica és del tipus $\{\bar{x} > c\}$, on c s'anomena punt crític. Com que $\frac{\bar{x} - \theta_0}{\sigma/\sqrt{n}} \sim N(0, 1)$, la funció de potència val:

$$\beta(\theta) = \mathcal{P}_\theta \left\{ \bar{x} > c \right\} = \mathcal{P}_\theta \left\{ \frac{\bar{x} - \theta}{\sigma/\sqrt{n}} > \frac{c - \theta}{\sigma/\sqrt{n}} \right\} = \mathcal{P}_\theta \left\{ z > \frac{c - \theta}{\sigma/\sqrt{n}} \right\}; z \sim N(0, 1)$$

Si fixem un nivell de significació α (mètode tradicional), haurà de ser: $\mathcal{P}_{\theta_0} \left\{ z > \frac{c - \theta_0}{\sigma/\sqrt{n}} \right\} = \alpha \Rightarrow \frac{c - \theta_0}{\sigma/\sqrt{n}} = z_\alpha \Rightarrow c = \theta_0 + z_\alpha \sigma/\sqrt{n}$, i el test serà: Rebutjar H_0 si $\bar{x} > \theta_0 + z_\alpha \sigma/\sqrt{n}$. Amb un error de tipus II:

$$1 - \beta(\theta_1) = \mathcal{P}_{\theta_1} \left\{ z > \frac{c - \theta_1}{\sigma/\sqrt{n}} \right\} = 1 - \mathcal{P}_{\theta_1} \left\{ z > \frac{\theta_0 + z_\alpha \sigma/\sqrt{n} - \theta_1}{\sigma/\sqrt{n}} \right\} = 1 - \mathcal{P}_{\theta_1} \left\{ z > z_\alpha + \frac{\theta_0 - \theta_1}{\sigma/\sqrt{n}} \right\}$$

Amb el mètode del p-valor: Si hem mesurat la mostra \bar{x}^* , aleshores el menor nivell crític que permet rebutjar la mostra condueix a fixar: $c = \bar{x}^*$, per tant:

$$z_\alpha = \frac{c - \theta_0}{\sigma/\sqrt{n}} = \frac{\bar{x}^* - \theta_0}{\sigma/\sqrt{n}} \Rightarrow \alpha(x_1, \dots, x_n) = \mathcal{P} \left\{ z > z_\alpha \right\} = \mathcal{P} \left\{ z > \frac{\bar{x}^* - \theta_0}{\sigma/\sqrt{n}} \right\}$$

Amb un error de tipus II:

$$1 - \beta(\theta_1) = 1 - \mathcal{P}_{\theta_1} \left\{ z > z_\alpha + \frac{\theta_0 - \theta_1}{\sigma/\sqrt{n}} \right\} = 1 - \mathcal{P}_{\theta_1} \left\{ z > \frac{\bar{x}^* - \theta_0}{\sigma/\sqrt{n}} + \frac{\theta_0 - \theta_1}{\sigma/\sqrt{n}} \right\} = 1 - \mathcal{P}_{\theta_1} \left\{ z > \frac{\bar{x}^* - \theta_1}{\sigma/\sqrt{n}} \right\}$$

Per exemple, si $\theta_0 = 15, \theta_1 = 16, \sigma = 1$ i mesurem $\bar{x}^* = 15,6$ en una mostra aleatòria de mida $n = 25$:

- Mètode tradicional: Si fixem $\alpha = 0,005 \Rightarrow z_\alpha = 2,5758 \Rightarrow$ el test és rebutjar H_0 si $\bar{x} > \theta_0 + z_\alpha \sigma/\sqrt{n} = 15,5152$, per tant, amb $\bar{x}^* = 15,6$ es rebutjaria H_0 amb un error de tipus II de: $1 - \beta(\theta_1) = 1 - \mathcal{P} \{ z > -2,4242 \} = \mathcal{P} \{ z > 2,4242 \} = 0,0077$.
- Mètode del p-valor: El nivell crític val: $\alpha(x_1, \dots, x_n) = \mathcal{P} \{ z > 3 \} = 0,0013$. Com que és menor que $\alpha = 0,05$, es rebutjaria el test amb un error de tipus II: $1 - \beta(\theta_1) = 1 - \mathcal{P} \{ z > -2 \} = \mathcal{P} \{ z > 2 \} = 0,0228$.

8.1 Contrast simple-simple

Lema de Neyman-Pearson Sigui $X = (X_1, \dots, X_n)$ amb funció de distribució $f_{\theta_0}(x_1, \dots, x_n)$ i funció de densitat $f_{\theta}(x_1, \dots, x_n)$. Donades les hipòtesis $H_0: \theta = \theta_0$ i $H_1: \theta = \theta_1$, el test de regió crítica C que:

$$\begin{cases} f_{\theta_0}(x_1, \dots, x_n) > k f_{\theta_0}(x_1, \dots, x_n), & (x_1, \dots, x_n) \in C \\ f_{\theta_0}(x_1, \dots, x_n) < k f_{\theta_0}(x_1, \dots, x_n), & (x_1, \dots, x_n) \in C^c \\ k > 0 \end{cases} \quad (8.1)$$

$$\mathcal{P}_{\theta_0} \{ (x_1, \dots, x_n) \in C \} = \alpha$$

és un de nivell de significació α de màxima potència. Pel test aleatoritzat:

$$\varphi(x_1, \dots, x_n) = \begin{cases} 1, & f_{\theta_0}(x_1, \dots, x_n) > k f_{\theta_0}(x_1, \dots, x_n) \\ \gamma, & f_{\theta_0}(x_1, \dots, x_n) = f_{\theta_0}(x_1, \dots, x_n) \\ 0, & f_{\theta_0}(x_1, \dots, x_n) < k f_{\theta_0}(x_1, \dots, x_n) \end{cases}$$

$$E\varphi(x_1, \dots, x_n) = \alpha$$

Exemple: Sigui $X \sim N(\theta, \sigma)$, $H_0: \theta = \theta_0$ i $H_1: \theta = \theta_1, \theta_0 < \theta_1$. Les condicions (8.1) porten a la regió crítica: $\{\bar{x} > c\}$, on $c > 0$ depèn de $k, \sigma, \theta_0, \theta_1$. Com que $\bar{X} \sim N(\theta, \sigma/\sqrt{n})$:

$$\mathcal{P}_{\theta_0} \{ \bar{x} > c \} = \mathcal{P}_{\theta_0} \left\{ \frac{\bar{x} - \theta_0}{\sigma/\sqrt{n}} > \frac{c - \theta_0}{\sigma/\sqrt{n}} \right\} = \mathcal{P} \left\{ z > \frac{c - \theta_0}{\sigma/\sqrt{n}} \right\} = \alpha \Rightarrow \frac{c - \theta_0}{\sigma/\sqrt{n}} = z_\alpha \Rightarrow c = \theta_0 + z_\alpha \frac{\sigma}{\sqrt{n}}$$

Per tant, si $\bar{x} > \theta_0 + z_\alpha \frac{\sigma}{\sqrt{n}}$ es rebutja H_0 , altrament s'accepta.

8.2 Contrast unilateral

Raó de verosimilitud monòtona Es diu que un estadístic T té una raó de verosimilitud monòtona si per cada $\theta < \theta'$ el quocient:

$$\frac{f_{\theta'}(x_1, \dots, x_n)}{f_{\theta}(x_1, \dots, x_n)}$$

$$\frac{f_{\theta'}(x_1, \dots, x_n)}{f_{\theta}(x_1, \dots, x_n)} = \frac{c(\theta')}{c(\theta)} e^{(\theta' - \theta)T(x)}$$

que és monòtona (creix amb T).

Teorema de Karlin-Rubin Per un contrast $H_0: \theta \leq \theta_0, H_1: \theta > \theta_0$, per un estadístic T amb raó de verosimilitud monòtona existeix el test φ de mida de significació α uniformement de màxima potència:

$$\varphi(x_1, \dots, x_n) = \begin{cases} 1, & T(x_1, \dots, x_n) > c \\ \gamma, & T(x_1, \dots, x_n) = c \\ 0, & T(x_1, \dots, x_n) < c \end{cases} \quad (8.2)$$

$$E\varphi(x_1, \dots, x_n) = \alpha$$

Per el contrast $H_0: \theta \geq \theta_0, H_1: \theta < \theta_0$ basta invertir les desigualtats del test.

Exemple: Sigui $X \sim N(\theta, \sigma)$, $H_0: \theta \leq \theta_0$ i $H_1: \theta > \theta_0$. La raó de verosimilitut és monòtona amb \bar{x} , per tant, les condicions (8.2) porten a:

$$\varphi(x_1, \dots, x_n) = \begin{cases} 1, & \bar{x} > c \\ 0, & \bar{x} < c \end{cases}$$

$$E\varphi(x_1, \dots, x_n) = \alpha$$

Com que $\bar{X} \sim N(\theta, \sigma/\sqrt{n})$ i la funció de potència creix amb θ , el màxim s'assoleix per $\theta = \theta_0$:

$$\mathcal{P}_{\theta_0} \{ \bar{x} > c \} = \mathcal{P}_{\theta_0} \left\{ \frac{\bar{x} - \theta_0}{\sigma/\sqrt{n}} > \frac{c - \theta_0}{\sigma/\sqrt{n}} \right\} = \mathcal{P} \left\{ z > \frac{c - \theta_0}{\sigma/\sqrt{n}} \right\} = \alpha \Rightarrow \frac{c - \theta_0}{\sigma/\sqrt{n}} = z_\alpha \Rightarrow c = \theta_0 + z_\alpha \frac{\sigma}{\sqrt{n}}$$

Per tant, si $\bar{x} > \theta_0 + z_\alpha \frac{\sigma}{\sqrt{n}}$ es rebutja H_0 , altrament s'accepta.

8.3 Contrast bilateral

Per contrastar $H_0: \theta = \theta_0, H_1: \theta \neq \theta_0$ ó $H_0: \theta \in [\theta_0, \theta_1], H_1: \theta \notin [\theta_0, \theta_1]$. En general no existeix un test uniformement de màxima potència. Per això definim un test no biaixat:

$$\text{Té nivell de significació } \alpha: \beta(\theta) = E_0\varphi \leq \alpha, \theta \in \Theta_0$$

$$\beta(\theta) = E_0\varphi \geq \alpha, \theta \in \Theta_1 \tag{8.3}$$

Nota: Un test uniformement de màxima potència és no biaixat.

Teorema de Lehmann Si la distribució poblacional és exponencial uniparamètrica, aleshores existeix un test no biaixat uniformement de màxima potència pel contrast $H_0: \theta = \theta_0, H_1: \theta \neq \theta_0$ ó $H_0: \theta \in [\theta_0, \theta_1], H_1: \theta \notin [\theta_0, \theta_1]$:

$$\varphi(x_1, \dots, x_n) = \begin{cases} 1, & T(x_1, \dots, x_n) \notin [c_1, c_2] \\ \gamma_1, & T(x_1, \dots, x_n) = c_1 \\ \gamma_2, & T(x_1, \dots, x_n) = c_2 \\ 0, & T(x_1, \dots, x_n) \in (c_1, c_2) \end{cases} \tag{8.4}$$

On les constants $\gamma_1, \gamma_2, c_1, c_2$ han de verificar:

- Si $H_0: \theta = \theta_0$:
 - $E_{\theta_0}[\varphi] = \alpha$
 - $E_{\theta_0}[\varphi T] = \alpha E_{\theta_0}[T]$

- Si $H_0: \theta \in [\theta_0, \theta_1]$:

$$E_{\theta_0}[\varphi] = \alpha$$

$$E_{\theta_1}[\varphi] = \alpha$$

8.4 Contrast de poblacions normals

$H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$

$$C = \left\{ \frac{|\bar{x} - \mu_0|}{S/\sqrt{n}} > t_{n-1, \alpha/2} \right\}$$

$H_0: \mu \leq \mu_0, H_1: \mu > \mu_0$

$$C = \left\{ \frac{\bar{x} - \mu_0}{S/\sqrt{n}} > t_{n-1, \alpha} \right\}$$

$H_0: \sigma = \sigma_0, H_1: \sigma \neq \sigma_0$

$$C = \left\{ \frac{(n-1)S^2}{\sigma_0^2} < \chi_{n-1, 1-\alpha/2}^2 \right\} \cup \left\{ \frac{(n-1)S^2}{\sigma_0^2} > \chi_{n-1, \alpha/2}^2 \right\}$$

$H_0: \sigma \leq \sigma_0, H_1: \sigma > \sigma_0$

$$C = \left\{ \frac{(n-1)S^2}{\sigma_0^2} > \chi_{n-1, \alpha}^2 \right\}$$

Capítol 9

Mètodes de contrast

9.1 Test de raó de verosimilituts

Per contrastar $H_0: \theta \in \Theta_0, H_1: \theta \in \Theta_1, \Theta = \Theta_0 \cup \Theta_1$:

$$\Lambda(x_1, \dots, x_n) = \frac{\sup_{\theta \in \Theta_0} f(x_1, \dots, x_n)}{\sup_{\theta \in \Theta} f(x_1, \dots, x_n)} = \frac{f_{\theta_0}(x_1, \dots, x_n)}{f_{\hat{\theta}}(x_1, \dots, x_n)} \tag{9.1}$$

on θ_0 i $\hat{\theta}$ són els estadístics de màxima verosimilitut de θ segons es consideri Θ_0 o Θ com espai paramètric, amb regió crítica:

$$C = \{ \Lambda(x_1, \dots, x_n) < c \}$$

$$\mathcal{P}_{\theta_0} \{ X_1, \dots, X_n \in C \} = \alpha$$

El test es pot aleatoritzar:

$$\varphi(x_1, \dots, x_n) = \begin{cases} 1, & \Lambda(x_1, \dots, x_n) < c \\ \gamma, & \Lambda(x_1, \dots, x_n) = c \\ 0, & \Lambda(x_1, \dots, x_n) > c \end{cases}$$

$$\sup_{\theta \in \Theta_0} E\varphi(x_1, \dots, x_n) = \alpha$$

Nota: En el cas de simple-simple:

$$\Lambda(x_1, \dots, x_n) = \frac{f_{\theta_0}(x_1, \dots, x_n)}{\max \{ f_{\theta_0}(x_1, \dots, x_n), f_{\theta_1}(x_1, \dots, x_n) \}}$$

La regió crítica: $C = \{ \Lambda(x_1, \dots, x_n) < c \}$ equival al lema de Neyman-Pearson: $f_{\theta_1}(x_1, \dots, x_n) > k f_{\theta_0}(x_1, \dots, x_n)$.

Taula 10.6: Distribució F de Snedecor, $\mathcal{P} \{ F_{n,m} > F_{n,m;\alpha} \}$ (continuació).

m	α	1	2	3	4	5	6	7	8	9	10	11	12
0.100	0.100	3.2850	2.9245	2.7277	2.6053	2.5216	2.4606	2.4140	2.3771	2.3473	2.3226	2.3018	2.2841
0.050	0.050	4.9646	4.1028	3.7083	3.4781	3.3258	3.2172	3.1355	3.0717	3.0204	2.9782	2.9430	2.9130
10	0.025	6.9367	5.4564	4.8256	4.4683	4.2361	4.0721	3.9498	3.8549	3.7790	3.7168	3.6649	3.6210
0.010	0.010	10.044	7.5594	6.5523	5.9943	5.6363	5.3858	5.2001	5.0567	4.9424	4.8491	4.7715	4.7059
0.005	0.005	12.826	9.4270	8.0808	7.3428	6.8724	6.5446	6.3025	6.1159	5.9676	5.8467	5.7462	5.6613
0.100	0.100	3.2252	2.8595	2.6602	2.5362	2.4512	2.3891	2.3416	2.3040	2.2735	2.2482	2.2269	2.2087
0.050	0.050	4.8443	3.9823	3.5874	3.3567	3.2039	3.0946	3.0123	2.9480	2.8962	2.8536	2.8179	2.7876
11	0.025	6.7241	5.2559	4.6300	4.2751	4.0440	3.8807	3.7586	3.6638	3.5879	3.5257	3.4737	3.4296
0.010	0.010	9.6460	7.2057	6.2167	5.6683	5.3160	5.0692	4.8861	4.7445	4.6315	4.5393	4.4624	4.3974
0.005	0.005	12.226	8.9123	7.6004	6.8809	6.4218	6.1015	5.8647	5.6821	5.5368	5.4183	5.3197	5.2363
0.100	0.100	3.1766	2.8068	2.6055	2.4801	2.3940	2.3310	2.2828	2.2446	2.2135	2.1878	2.1660	2.1474
0.050	0.050	4.7472	3.8853	3.4903	3.2592	3.1059	2.9961	2.9134	2.8486	2.7964	2.7534	2.7173	2.6866
12	0.025	6.5538	5.0959	4.4742	4.1212	3.8911	3.7283	3.6065	3.5118	3.4358	3.3735	3.3215	3.2773
0.010	0.010	9.3302	6.9266	5.9525	5.4120	5.0643	4.8206	4.6395	4.4994	4.3875	4.2961	4.2198	4.1553
0.005	0.005	11.754	8.5096	7.2258	6.5211	6.0711	5.7570	5.5245	5.3451	5.2021	5.0855	4.9884	4.9062
0.100	0.100	3.1362	2.7632	2.5603	2.4337	2.3467	2.2830	2.2341	2.1953	2.1638	2.1376	2.1155	2.0966
0.050	0.050	4.6672	3.8056	3.4105	3.1791	3.0254	2.9153	2.8321	2.7669	2.7144	2.6710	2.6347	2.6037
13	0.025	6.4143	4.9653	4.3472	3.9959	3.7667	3.6043	3.4827	3.3880	3.3120	3.2497	3.1975	3.1532
0.010	0.010	9.0738	6.7010	5.7394	5.2053	4.8616	4.6204	4.4410	4.3021	4.1911	4.1003	4.0245	3.9603
0.005	0.005	11.373	8.1865	6.9258	6.2335	5.7910	5.4819	5.2529	5.0761	4.9351	4.8199	4.7241	4.6429
0.100	0.100	3.1022	2.7265	2.5222	2.3947	2.3069	2.2426	2.1931	2.1539	2.1220	2.0954	2.0730	2.0537
0.050	0.050	4.6001	3.7389	3.3439	3.1122	2.9583	2.8477	2.7642	2.6987	2.6458	2.6022	2.5655	2.5342
14	0.025	6.2979	4.8567	4.2417	3.8919	3.6634	3.5014	3.3799	3.2853	3.2093	3.1469	3.0946	3.0501
0.010	0.010	8.8616	6.5149	5.5639	5.0354	4.6950	4.4558	4.2779	4.1399	4.0297	3.9394	3.8640	3.8001
0.005	0.005	11.060	7.9216	6.6803	5.9984	5.5623	5.2574	5.0313	4.8566	4.7173	4.6034	4.5085	4.4281
0.100	0.100	3.0732	2.6952	2.4898	2.3614	2.2730	2.2081	2.1582	2.1185	2.0862	2.0593	2.0366	2.0171
0.050	0.050	4.5431	3.6823	3.2874	3.0556	2.9013	2.7905	2.7066	2.6408	2.5876	2.5437	2.5068	2.4753
15	0.025	6.1995	4.7650	4.1528	3.8043	3.5764	3.4147	3.2934	3.1987	3.1227	3.0602	3.0078	2.9633
0.010	0.010	8.6831	6.3589	5.4170	4.8932	4.5556	4.3183	4.1415	4.0045	3.8948	3.8049	3.7299	3.6662
0.005	0.005	10.798	7.7008	6.4760	5.8029	5.3721	5.0708	4.8473	4.6744	4.5364	4.4235	4.3295	4.2497
0.100	0.100	3.0481	2.6682	2.4618	2.3327	2.2438	2.1783	2.1280	2.0880	2.0553	2.0282	2.0051	1.9854
0.050	0.050	4.4940	3.6337	3.2389	3.0069	2.8524	2.7413	2.6572	2.5911	2.5377	2.4935	2.4564	2.4247
16	0.025	6.1151	4.6867	4.0768	3.7294	3.5021	3.3406	3.2194	3.1248	3.0488	2.9862	2.9337	2.8891
0.010	0.010	8.5310	6.2262	5.2922	4.7726	4.4374	4.2016	4.0259	3.8896	3.7804	3.6909	3.6162	3.5527
0.005	0.005	10.575	7.5138	6.3034	5.6379	5.2117	4.9134	4.6920	4.5207	4.3838	4.2719	4.1785	4.0994
0.100	0.100	3.0262	2.6446	2.4374	2.3077	2.2182	2.1524	2.1017	2.0613	2.0284	2.0009	1.9777	1.9577
0.050	0.050	4.4513	3.5915	3.1968	2.9647	2.8100	2.6987	2.6143	2.5480	2.4943	2.4499	2.4126	2.3807
17	0.025	6.0420	4.6189	4.0112	3.6648	3.4379	3.2767	3.1556	3.0610	2.9849	2.9222	2.8696	2.8249
0.010	0.010	8.3997	6.1121	5.1850	4.6690	4.3359	4.1015	3.9267	3.7910	3.6822	3.5931	3.5185	3.4552
0.005	0.005	10.384	7.3536	6.1556	5.4967	5.0746	4.7789	4.5594	4.3894	4.2535	4.1424	4.0496	3.9709
0.100	0.100	3.0070	2.6239	2.4160	2.2858	2.1958	2.1296	2.0785	2.0379	2.0047	1.9770	1.9535	1.9333
0.050	0.050	4.4139	3.5546	3.1599	2.9277	2.7729	2.6613	2.5767	2.5102	2.4563	2.4117	2.3742	2.3421
18	0.025	5.9780	4.5597	3.9539	3.6083	3.3820	3.2209	3.0999	3.0053	2.9291	2.8664	2.8137	2.7689
0.010	0.010	8.2854	6.0129	5.0919	4.5790	4.2479	4.0146	3.8406	3.7054	3.5971	3.5082	3.4338	3.3706
0.005	0.005	10.218	7.2148	6.0278	5.3746	4.9560	4.6627	4.4448	4.2759	4.1410	4.0305	3.9382	3.8599

Taula 10.6: Distribució F de Snedecor, $\mathcal{P}\{F_{n,m} > F_{n,m;\alpha}\}$ (continuació).

		n										∞		
		13	14	15	16	17	18	20	24	30	40	60	120	∞
60,903	61,073	61,220	61,350	61,464	61,566	61,740	62,002	62,265	62,529	62,794	63,061	63,328		
244,69	245,36	245,95	246,46	246,92	247,32	248,01	249,05	250,09	251,14	252,20	253,25	254,31		
979,84	982,53	984,87	986,92	988,73	990,33	993,10	997,25	1001,4	1005,6	1009,8	1014,0	1018,3		
6125,9	6142,7	6157,3	6170,1	6181,4	6191,5	6208,7	6234,6	6260,6	6286,8	6313,0	6339,4	6365,9		
24504	24572	24630	24682	24727	24767	24836	24940	25044	25148	25253	25359	25464		
9,4145	9,4200	9,4247	9,4289	9,4325	9,4358	9,4413	9,4496	9,4579	9,4662	9,4746	9,4829	9,4912		
19,419	19,424	19,429	19,433	19,437	19,440	19,446	19,454	19,462	19,471	19,479	19,487	19,496		
39,421	39,426	39,431	39,435	39,439	39,442	39,448	39,456	39,465	39,473	39,481	39,490	39,498		
99,422	99,428	99,433	99,437	99,440	99,444	99,449	99,457	99,466	99,474	99,483	99,491	99,499		
199,42	199,43	199,43	199,44	199,44	199,44	199,45	199,46	199,47	199,47	199,48	199,49	199,50		
5,2098	5,2047	5,2003	5,1964	5,1929	5,1898	5,1845	5,1764	5,1681	5,1597	5,1512	5,1425	5,1337		
8,7287	8,7149	8,7029	8,6923	8,6829	8,6745	8,6602	8,6385	8,6166	8,5944	8,5720	8,5494	8,5265		
14,305	14,277	14,253	14,232	14,213	14,196	14,167	14,124	14,081	14,037	13,992	13,947	13,902		
26,983	26,924	26,872	26,827	26,787	26,751	26,690	26,598	26,505	26,411	26,316	26,221	26,125		
43,272	43,172	43,085	43,008	42,941	42,880	42,778	42,622	42,466	42,308	42,149	41,989	41,828		
3,8859	3,8776	3,8704	3,8639	3,8582	3,8531	3,8443	3,8310	3,8174	3,8036	3,7896	3,7753	3,7607		
5,8911	5,8734	5,8578	5,8441	5,8320	5,8211	5,8025	5,7744	5,7459	5,7170	5,6877	5,6581	5,6281		
8,7150	8,6838	8,6565	8,6326	8,6113	8,5924	8,5599	8,4613	8,4111	8,3604	8,3092	8,2573			
14,306	14,249	14,198	14,154	14,115	14,079	14,020	13,929	13,838	13,745	13,652	13,558	13,463		
20,603	20,515	20,438	20,371	20,311	20,258	20,167	20,030	19,892	19,752	19,611	19,468	19,325		
3,2567	3,2468	3,2380	3,2303	3,2234	3,2172	3,2066	3,1905	3,1741	3,1573	3,1402	3,1228	3,1050		
4,6552	4,6358	4,6188	4,6038	4,5904	4,5785	4,5581	4,5271	4,4957	4,4638	4,4314	4,3985	4,3650		
6,4876	6,4556	6,4277	6,4032	6,3814	6,3619	6,3286	6,2780	6,2269	6,1750	6,1225	6,0693	6,0153		
9,8248	9,7700	9,7222	9,6802	9,6429	9,6096	9,5526	9,4665	9,3793	9,2912	9,2020	9,1118	9,0204		
13,293	13,215	13,146	13,086	13,033	12,985	12,903	12,780	12,656	12,530	12,402	12,274	12,143		
2,8920	2,8809	2,8712	2,8626	2,8550	2,8481	2,8363	2,8183	2,8002	2,7812	2,7620	2,7423	2,7222		
3,9764	3,9559	3,9381	3,9223	3,9083	3,8957	3,8742	3,8415	3,8082	3,7743	3,7398	3,7047	3,6689		
5,3290	5,2968	5,2687	5,2439	5,2218	5,2021	5,1684	5,1172	5,0652	5,0125	4,9589	4,9044	4,8491		
7,6575	7,6049	7,5590	7,5186	7,4827	7,4507	7,3958	7,3127	7,2285	7,1432	7,0567	6,9690	6,8800		
9,9501	9,8774	9,8140	9,7582	9,7086	9,6644	9,5888	9,4742	9,3582	9,2409	9,1219	9,0015	8,8793		
2,6545	2,6426	2,6322	2,6230	2,6148	2,6074	2,5947	2,5753	2,5555	2,5351	2,5142	2,4928	2,4708		
3,5503	3,5292	3,5107	3,4944	3,4799	3,4669	3,4445	3,4105	3,3758	3,3404	3,3043	3,2675	3,2298		
4,6285	4,5961	4,5678	4,5428	4,5206	4,5008	4,4667	4,4150	4,3624	4,3089	4,2544	4,1989	4,1423		
6,4100	6,3590	6,3143	6,2750	6,2401	6,2089	6,1554	6,0743	5,9920	5,9085	5,8236	5,7373	5,6495		
8,0968	8,0279	7,9678	7,9148	7,8678	7,8258	7,7540	7,6450	7,5345	7,4225	7,3087	7,1933	7,0760		
2,4876	2,4752	2,4642	2,4545	2,4458	2,4381	2,4246	2,4041	2,3830	2,3614	2,3391	2,3162	2,2926		
3,2590	3,2374	3,2184	3,2016	3,1867	3,1733	3,1503	3,1152	3,0794	3,0428	3,0053	2,9669	2,9276		
4,1622	4,1297	4,1012	4,0761	4,0538	4,0338	3,9994	3,9472	3,8940	3,8398	3,7845	3,7279	3,6702		
5,6089	5,5589	5,5151	5,4765	5,4423	5,4116	5,3591	5,2793	5,1981	5,1156	5,0316	4,9460	4,8588		
6,9384	6,8721	6,8143	6,7633	6,7180	6,6775	6,6082	6,5030	6,3961	6,2875	6,1772	6,0649	5,9505		
2,3640	2,3510	2,3396	2,3295	2,3207	2,3123	2,2983	2,2768	2,2547	2,2320	2,2085	2,1843	2,1592		
3,0476	3,0255	3,0061	2,9890	2,9737	2,9600	2,9365	2,9005	2,8636	2,8259	2,7872	2,7475	2,7067		
3,8306	3,7980	3,7694	3,7441	3,7216	3,7015	3,6669	3,6142	3,5604	3,5055	3,4493	3,3918	3,3329		
5,0545	5,0052	4,9621	4,9240	4,8902	4,8599	4,8080	4,7290	4,6486	4,5667	4,4831	4,3978	4,3106		
6,1530	6,0887	6,0325	5,9829	5,9388	5,8994	5,8318	5,7292	5,6248	5,5186	5,4104	5,3001	5,1875		

Distribució asimptòtica Si no hi ha un estadístic de distribució coneguda per determinar la regió crítica $C = \{\Lambda < c\}$, ni és possible conèixer la distribució de Λ , aleshores es fa servir la distribució asimptòtica de Λ .

Teorema: Si θ té un recorregut en $\Theta \subset \mathbb{R}^k$, $\Theta_0 = \{\theta \in \Theta \mid g_i(w_1, \dots, w_q), (v_1, \dots, v_j) \in \Theta\}$ amb Θ un conjunt obert en \mathbb{R}^k i g_i amb derivades d'ordre 1 contínues, sota unes condicions de regularitat (veure [2, teorema 7.2, pàg. 294 i teorema 9.1, pàg. 395]):

$$-2 \log \Lambda(x_1, \dots, x_n) \xrightarrow{d} \chi_{k-q}^2$$

on k és el nombre de paràmetres prescindint de H_0 , i q és el nombre de paràmetres amb H_0 .

9.2 Relació entre l'estimació confidencial i el contrast d'hipòtesi

- Interval de confiança: es tracta de buscar un conjunt $S(x_1, \dots, x_n) \subset \Theta$ on es compleix:

$$\mathcal{P}_\theta \{\theta \in S(x_1, \dots, x_n)\} \geq 1 - \alpha$$
- Contrast d'hipòtesi $H_0 : \theta = \theta_0$: Es tracta de buscar una regió crítica $C(\theta_0) \subset X$ de forma que obtenint una mostra en $C(\theta_0)$ succeeixi amb $\mathcal{P}_{\theta_0} \{X_1, \dots, X_n \in C\} \leq \alpha$

Per tant, el conjunt de Θ :

$$S(x_1, \dots, x_n) = \{\theta \in \Theta \mid x_1, \dots, x_n \notin C(\theta)\}$$

és un interval de confiança per θ de nivell de confiança $1 - \alpha$:

$$\mathcal{P}_\theta \{\theta \in S(x_1, \dots, x_n)\} = \mathcal{P}_\theta \{x_1, \dots, x_n \notin C(\theta)\} \geq 1 - \alpha$$

Recíprocament:

$$C(\theta_0) = \{x_1, \dots, x_n \in X \mid \theta_0 \notin S(x_1, \dots, x_n)\}$$

és la regió crítica d'un test de significació α per l'hipòtesi $\theta = \theta_0$:

$$\mathcal{P}_\theta \{x_1, \dots, x_n \in C(\theta_0)\} = \mathcal{P}_\theta \{\theta_0 \notin S(x_1, \dots, x_n)\} \leq \alpha$$

La diferència radica en que el criteri d'optimalitat d'un test uniformement de màxima potència és més precís que en l'interval de confiança. Per un interval de confiança es pot definir el concepte de precisió, de forma que l'interval de màxima precisió es correspon amb el de màxima potència del contrast, i viceversa (veure [2, pàg. 404]).

Capítol 10

Contrasts χ^2 de bondat d'ajustament

10.1 Hipòtesi simple

$H_0 : F = F_0, H_1 : F \neq F_0$, on F_0 és una funció coneguda.

Mètode: dividir el recorregut de F en k conjunts A_1, \dots, A_k , on $p_i^0 = \mathcal{P}_{F_0} \{A_i\}$, $\mathbf{p}^0 = (p_1^0, \dots, p_k^0)$ i p_i la probabilitat descoguda $p_i = \mathcal{P}_F \{A_i\}$, $\mathbf{p} = (p_1, \dots, p_k)$. La V.A. (N_1, \dots, N_k) amb el nombre d'observacions en cada conjunt A_1, \dots, A_k té una distribució multinomial amb paràmetres n i \mathbf{p} :

$$\mathcal{P} \{N_1 = n_1, \dots, N_k = n_k\} = \frac{n!}{n_1! \dots n_k!} p_1^{n_1} \dots p_k^{n_k} \quad (10.1)$$

Ara substituïm el contrast no paramètric inicial pel contrast paramètric $H_0 : \mathbf{p} = \mathbf{p}^0, H_1 : \mathbf{p} \neq \mathbf{p}^0$ en base als valors obtinguts (n_1, \dots, n_k) .

Com que els estimadors de màxima verosimilitud de p_i valen $\hat{p}_i = n_i/n$, la raó de verosimilitud val:

$$\Lambda(n_1, \dots, n_k) = \frac{(p_1^0)^{n_1} \dots (p_k^0)^{n_k}}{p_1^{n_1} \dots p_k^{n_k}}$$

amb una regió crítica $\{\Lambda < c\}$, on la distribució asimptòtica de $-2 \log \Lambda \xrightarrow{d} \chi_{k-1}^2$, donat que hi ha 0 paràmetres a estimar en H_0 i $k-1$ en H_1 . En la pràctica es fa servir el test de Pearson:

$$D = -2 \log \Lambda \approx \sum_{i=1}^k \frac{(N_i - n p_i^0)^2}{n p_i^0} \xrightarrow{d} \chi_{k-1}^2 \quad (10.2)$$

Per tant, amb regió crítica: $\{D > \chi_{k-1;\alpha}^2\}$.

Usualment es considera que ha de ser: $n p_i \geq 5$, per tant, els conjunts han de ser $n p_i^0 \geq 5$. Per a la partició es considera $k \geq 5$, per tant, hi ha d'haver $n \geq 25$ mostres. Per a calcular D és convenient la relació:

$$D = \sum_{i=1}^k \frac{(n_i - n p_i^0)^2}{n p_i^0} = -n + \sum_{i=1}^k \frac{n_i^2}{n p_i^0}$$

10.2 Hipòtesi composta

Quan es desconeix algun paràmetre de la distribució poblacional, $H_0 : F \in \{F_\theta \mid \theta \in \Theta \subset \mathbb{R}^q\}$. Ara es divideix el recorregut de F en k conjunts A_1, \dots, A_k . Igual que abans, (N_1, \dots, N_k) és multinomial, però per cada valor de θ hi ha un $\mathbf{p} = \pi(\theta)$, on $p_i = \pi(\theta_1, \dots, \theta_q), i = 1, \dots, k$. Aplicant el principi de màxima verosimilitud, el màxim s'assoleix per $\frac{\partial}{\partial \theta} \sum_{i=1}^k N_i \log \pi_i(\theta)$:

$$\sum_{i=1}^k \frac{N_i}{\pi_i(\theta)} \frac{\partial}{\partial \theta_j} \pi_i(\theta) = 0, \quad j = 1, \dots, q$$

Determinats $\pi_i(\theta)$, igual que abans s'obté:

$$D = \sum_{i=1}^k \frac{(N_i - n \pi_i(\hat{\theta}))^2}{n \pi_i(\hat{\theta})} = -n + \sum_{i=1}^k \frac{n_i^2}{n \pi_i(\hat{\theta})} \xrightarrow{d} \chi_{k-1-q}^2 \quad (10.3)$$

Per tant, amb regió crítica: $\{D > \chi_{k-1-q;\alpha}^2\}$.

10.3 Contrast d'homogeneïtat

H_0 : La distribució poblacional F és la mateixa per m poblacions de les que s'han pres n_1, \dots, n_m mostres.

Taula de contingència:

Mostra	A_1	\dots	A_k	total
1	n_{11}	\dots	n_{1k}	n_1
\vdots	\vdots	\vdots	\vdots	\vdots
m	n_{m1}	\dots	n_{mk}	n_m
total	n_1	\dots	n_k	n

$$D = \sum_{i=1}^m \sum_{j=1}^k \frac{(n_{ij} - n_i n_j / n)^2}{n_i n_j / n} = n \left(-1 + \sum_{j=1}^k \frac{n_j^2}{n_i n_j} \right) \xrightarrow{d} \chi_{(m-1)(k-1)}^2$$

Amb regió crítica: $\{D > \chi_{(m-1)(k-1); \alpha}^2\}$.

10.4 Contrast d'independència

Mostres: $(X_1, Y_1) \dots (X_m, Y_m)$. Dividim el recorregut de X en k conjunts A_1, \dots, A_k , i el recorregut de Y en r conjunts: B_1, \dots, B_r . Independència $\Rightarrow P_{ij} = P_i P_j$.

Taula de contingència:

	B_1	\dots	B_r	total
A_1	n_{11}	\dots	n_{1k}	n_1
\vdots	\vdots	\vdots	\vdots	\vdots
A_k	n_{k1}	\dots	n_{kk}	n_k
total	n_1	\dots	n_r	n

$$D = \sum_{i=1}^k \sum_{j=1}^r \frac{(n_{ij} - n_i n_j / n)^2}{n_i n_j / n} = n \left(-1 + \sum_{j=1}^r \frac{n_j^2}{n_i n_j} \right) \xrightarrow{d} \chi_{(k-1)(r-1)}^2$$

Amb regió crítica: $\{D > \chi_{(k-1)(r-1); \alpha}^2\}$.

Bibliografia

- [1] George Casella and Roger L. Berger. *Statistical Inference*. Duxbury, 2nd edition, 2002.
- [2] Ricardo Véllez-Ibarrola and Alfonso García-Pérez. *Cálculo de probabilidades y estadística matemática*. Edicions UNED, 1993.

Taula 10.6: Distribució F de Snedecor. En la taula hi ha els quantils $\mathcal{P}\{F_{n,m} > F_{n,m;\alpha}\}$.

m	α	1	2	3	4	5	6	7	8	9	10	11	12
0.100	39,864	49,500	53,593	55,833	57,240	58,204	58,906	59,439	59,858	60,195	60,473	60,705	60,705
0.050	161,45	199,50	215,71	224,58	230,16	233,99	236,77	238,88	240,54	241,88	242,98	243,91	243,91
1	0,025	647,79	799,50	864,16	899,58	921,85	937,11	948,22	956,66	963,28	968,63	973,02	976,71
0.010	4052,2	4999,5	5403,4	5624,6	5763,6	5859,0	5928,4	5981,1	6022,5	6055,9	6083,3	6106,3	6106,3
0.005	16211	20000	21615	22500	23056	23437	23715	23925	24091	24224	24334	24426	24426
0.100	8,5263	9,0000	9,1618	9,2434	9,2926	9,3255	9,3491	9,3668	9,3805	9,3916	9,4006	9,4081	9,4081
0.050	18,513	19,0000	19,164	19,247	19,296	19,329	19,353	19,371	19,385	19,396	19,405	19,413	19,413
0.025	38,506	39,0000	39,166	39,248	39,298	39,331	39,355	39,373	39,387	39,398	39,407	39,415	39,415
0.010	98,502	99,0000	99,166	99,249	99,299	99,333	99,356	99,374	99,388	99,399	99,408	99,416	99,416
0.005	198,50	199,0000	199,17	199,25	199,30	199,33	199,36	199,38	199,39	199,40	199,41	199,42	199,42
0.100	5,5383	5,4624	5,3908	5,3426	5,3092	5,2847	5,2662	5,2517	5,2400	5,2304	5,2224	5,2156	5,2156
0.050	10,128	9,5521	9,2766	9,1172	9,0135	8,9406	8,8867	8,8452	8,8123	8,7855	8,7633	8,7446	8,7446
3	0,025	17,443	16,044	15,439	15,101	14,885	14,735	14,624	14,540	14,473	14,419	14,374	14,337
0.010	34,116	30,817	29,457	28,710	28,237	27,911	27,672	27,489	27,345	27,229	27,133	27,052	27,052
0.005	55,552	49,799	47,467	46,195	45,392	44,839	44,434	44,126	43,882	43,686	43,524	43,387	43,387
0.100	4,5448	4,3246	4,1909	4,1072	4,0506	4,0098	3,9790	3,9549	3,9357	3,9199	3,9067	3,8955	3,8955
0.050	7,7086	6,9443	6,5914	6,3882	6,2561	6,1631	6,0942	6,0410	5,9988	5,9644	5,9358	5,9117	5,9117
4	0,025	12,218	10,649	9,9792	9,6045	9,3645	9,1973	9,0741	8,9796	8,9047	8,8439	8,7935	8,7512
0.010	21,198	18,000	16,694	15,977	15,522	15,207	14,976	14,799	14,659	14,546	14,452	14,374	14,374
0.005	31,333	26,284	24,259	23,154	22,456	21,975	21,622	21,352	21,139	20,967	20,824	20,705	20,705
0.100	4,0604	3,7797	3,6195	3,5202	3,4530	3,4045	3,3679	3,3393	3,3163	3,2974	3,2816	3,2682	3,2682
0.050	6,6079	5,7861	5,4094	5,1922	5,0503	4,9503	4,8725	4,8183	4,7725	4,7351	4,7040	4,6777	4,6777
5	0,025	10,007	8,4336	7,7636	7,3879	7,1464	6,9777	6,8531	6,7572	6,6810	6,6192	6,5678	6,5245
0.010	16,258	13,274	12,060	11,392	10,967	10,672	10,456	10,289	10,158	10,051	9,9627	9,8883	9,8883
0.005	22,785	18,314	16,530	15,556	14,940	14,513	14,200	13,961	13,772	13,618	13,491	13,384	13,384
0.100	3,7759	3,4633	3,2888	3,1808	3,1075	3,0545	3,0145	2,9830	2,9577	2,9369	2,9195	2,9047	2,9047
0.050	5,9874	5,1433	4,7571	4,5337	4,3874	4,2839	4,2067	4,1468	4,0990	4,0600	4,0274	3,9999	3,9999
6	0,025	8,8131	7,2599	6,5988	6,2272	5,9876	5,8198	5,6955	5,5996	5,5234	5,4613	5,4098	5,3662
0.010	13,745	10,925	9,7795	9,1483	8,7459	8,4661	8,2600	8,1016	7,9761	7,8741	7,7896	7,7183	7,7183
0.005	18,635	14,544	12,917	12,027	11,464	11,073	10,786	10,566	10,392	10,250	10,133	10,034	10,034
0.100	3,5894	3,2574	3,0741	2,9605	2,8833	2,8274	2,7849	2,7516	2,7247	2,7025	2,6839	2,6681	2,6681
0.050	5,5915	4,7374	4,3468	4,1203	3,9715	3,8660	3,7870	3,7257	3,6767	3,6365	3,6030	3,5747	3,5747
7	0,025	8,0727	6,5415	5,8898	5,5226	5,2852	5,1186	4,9949	4,8993	4,8232	4,7611	4,7095	4,6658
0.010	12,246	9,5466	8,4513	7,8467	7,4604	7,1914	6,9928	6,8400	6,7188	6,6201	6,5382	6,4691	6,4691
0.005	16,236	12,404	10,882	10,050	9,5221	9,1553	8,8854	8,6781	8,5138	8,3803	8,2697	8,1764	8,1764
0.100	3,4579	3,1131	2,9238	2,8064	2,7264	2,6683	2,6241	2,5894	2,5612	2,5380	2,5185	2,5020	2,5020
0.050	5,3177	4,4590	4,0662	3,8378	3,6875	3,5806	3,5005	3,4381	3,3881	3,3472	3,3129	3,2839	3,2839
8	0,025	7,5709	6,0595	5,4160	5,0526	4,8173	4,6517	4,5286	4,4333	4,3572	4,2951	4,2434	4,1997
0.010	11,259	8,6491	7,5910	7,0061	6,6318	6,3707	6,1776	6,0289	5,9106	5,8143	5,7343	5,6667	5,6667
0.005	14,688	11,042	9,5965	8,8051	8,3018	7,9520	7,6941	7,4959	7,3386	7,2106	7,1045	7,0149	7,0149
0.100	3,3603	3,0065	2,8129	2,6927	2,6106	2,5509	2,5053	2,4694	2,4403	2,4163	2,3961	2,3789	2,3789
0.050	5,1174	4,2565	3,8626	3,6331	3,4817	3,3737	3,2927	3,2296	3,1789	3,1373	3,1025	3,0730	3,0730
9	0,025	7,2093	5,7147	5,0781	4,7181	4,4844	4,3197	4,1970	4,1020	4,0260	3,9639	3,9121	3,8682
0.010	10,561	8,0215	6,9919	6,4221	6,0569	5,8018	5,6129	5,4671	5,3511	5,2565	5,1779	5,1114	5,1114
0.005	13,614	10,107	8,7171	7,9559	7,4712	7,1338	6,8849	6,6933	6,5411	6,4172	6,3142	6,2274	6,2274

Nota: Per valors de $\alpha > 0,5$ tenir en compte que $F_{n,m;\alpha} = 1/F_{m,n;1-\alpha}$.

Taula 10.4: Distribució de Poisson. En la taula hi ha les probabilitats $\mathcal{P}\{X \leq k\} = \sum_{i=0}^k \frac{\lambda^i}{i!} e^{-\lambda}$.

Table with 12 columns (lambda) and 11 rows (k). Values range from 0.1 to 1.0 across the top and left, with numerical values in the cells.

Taula 10.5: Distribució Binomial. En la taula hi ha les probabilitats $\mathcal{P}\{X \leq k\} = \sum_{i=0}^k \binom{n}{i} p^i (1-p)^{n-i}$.

Table with 12 columns (n) and 11 rows (k). Values range from 0 to 8 across the top and left, with numerical values in the cells.