

Appunti di Statistica C.P.

Alberto Cavalin × Francesco Ragazzo

2006/2008

Hall of fame:

► *Francesco R.* : ★ *strategical idea hunter*
★ *official licensed motivator*
★ *coffee break promoter*
★ *Marlesia's food feeder*

► *Laura P.* : ★ *sergeant major general*
★ *official study promoter*
★ *pomodorini & peperoni feeder*

► *Silvia B.* : ★ *house, food & cat provider*
★ *natural pheromone dispenser*
★ *master Cek distracter*

► *Stefano C.* : ★ *battlefield master chef*
★ *house, food & smoke provider*
★ *natural fun dispenser*
★ *"mele yeah"TM*

... e tutte le persone che mi hanno supportato finora ;-)

NB: Nel titolo il simbolo "×" indica "congiuntamente a" e non "dedicato a"!

Indice

1	Inferenza frequentista	1
1.1	Modello statistico	1
1.2	Stime e stimatori	1
1.2.1	Proprietà degli stimatori	1
1.3	Verifica d'ipotesi/Test	2
1.3.1	Livello di significatività	2
1.3.2	Funzione di potenza	2
1.3.3	Proprietà di un test	2
1.3.4	Regioni di confidenza	2
1.4	La verosimiglianza	3
1.4.1	Stima di massima verosimiglianza	4
1.5	Statistiche sufficienti	4
1.5.1	Statistiche sufficienti e criterio di Neyman-Fisher	4
1.5.2	Statistiche sufficienti minimali	4
1.6	Famiglie esponenziali	5
1.6.1	Famiglie esponenziali regolari	5
1.7	Efficienza di uno stimatore	6
1.7.1	Problemi regolari di stima	6
1.7.2	Disuguaglianza di Cramer-Rao	6
1.7.3	Teorema di Rao-Blackwell	7
1.7.4	Teorema di Lehman-Scheffé	7
1.8	Test di verosimiglianza (Wilks) e regioni di confidenza	7
1.9	Verosimiglianza profilo	8
1.10	Test ottimi	8
1.10.1	Test rapporto di verosimiglianza	9

1.10.2	Lemma di Neyman-Pearson	9
1.10.3	Ipotesi composite	10
2	Inferenza robusta	11
2.1	Equazioni di stima	11
2.2	Proprietà degli stimatori di tipo M	11
2.2.1	Normalità asintotica	12
2.3	Quasi-verosimiglianza	13
2.4	Funzionali statistici e funzione di influenza	13
2.4.1	Stimatore di Huber	14
3	Inferenza bayesiana	15
3.1	Il teorema di Bayes	15
3.1.1	Versione generale	15
3.1.2	Versione nel continuo	15
3.2	Procedure inferenziali	16
3.2.1	Stima puntuale	16
3.2.2	Regioni di confidenza HPD	16
3.2.3	Verifica d'ipotesi	17
3.3	Coniugate naturali	17
A	Richiami	19
A.1	Distribuzioni note	19
A.1.1	Alcune nozioni fondamentali	19
A.1.2	Distribuzione di media e varianza campionaria	19
A.2	Funzioni indicatrici	19
A.3	Disuguaglianza di Jensen	19
A.4	Newton-Raphson	20
A.5	Cambio di variabile	20
A.6	Metodo delta	20
A.7	Quantità pivotale	21
A.8	Partizione di un insieme	21
A.9	Promemoria per la risoluzione di un problema	21
A.9.1	Inferenza frequentista	22

A.9.2	Inferenza robusta	22
A.9.3	Inferenza bayesiana	22
B	Notazioni, tabelle, e grafici	23
B.1	Notazioni	23

Capitolo 1

Inferenza frequentista

1.1 Modello statistico

<u>Def:</u> $\mathcal{F} = \{\mathbb{P}_\theta; \theta \in \Theta\}$	$Y =$ variabile aleatoria, $\theta =$ parametro $\mathcal{Y} =$ spc campionario / supporto di Y $\Theta =$ spc parametrico / supporto di f_Y
$= \{f_Y(y; \theta); \theta \in \Theta\}$	

- \mathcal{F} non cambia se soggetto a riparametrizzazioni biunivoche
- $\hat{\theta}(\underline{y}) =$ stima di θ , $\underline{y} =$ vettore oss camp
- $\hat{\theta}(\underline{Y}) =$ stimatore di θ , $\underline{Y} =$ vettore aleatorio

1.2 Stime e stimatori

- Metodi di stima:
- sostituzione ($\tau = g(\theta) \rightarrow \hat{\tau} = g(\hat{\theta})$)
 - analogia (la qt della pop viene stimata con la qt campionaria)
 - momenti = metodo dell'analogia applicato ai momenti
 - massima verosimiglianza

1.2.1 Proprietà degli stimatori

- non distorto (corretto) $\Leftrightarrow \mathbb{E}(\hat{\theta}) = \theta$
- consistente $\Leftrightarrow \hat{\theta} \xrightarrow{p} \theta \Leftrightarrow \mathbb{E}(\hat{\theta}) = \theta \wedge \lim_{n \rightarrow +\infty} \mathbb{V}(\hat{\theta}) = 0$
- asintoticamente non distorto $\Leftrightarrow \lim_{n \rightarrow +\infty} \mathbb{E}(\hat{\theta}) = \theta$
- debolmente consistente $\Leftrightarrow \lim_{n \rightarrow +\infty} \mathbb{E}(\hat{\theta}) = \theta \wedge \lim_{n \rightarrow +\infty} \mathbb{V}(\hat{\theta}) = 0$

NB: Le proprietà di $\hat{\theta}$ dipendono dalla parametrizzazione.

1.3 Verifica d'ipotesi/Test

Sistema d'ipotesi: $\left\{ \begin{array}{l} H_0 : \theta \in \Theta_0 \\ H_1 : \theta \in \Theta \setminus \Theta_0 \end{array} \right\} \quad \left| \quad \begin{array}{l} t(y) = \text{statistica test} \\ = \text{funzione dei dati indipendente da } \theta \end{array} \right.$

- regione di accettazione : $A = \{y \in \mathcal{Y} : t(y) \text{ porta verso } H_0\}$
- regione di rifiuto : $R = \{y \in \mathcal{Y} : t(y) \text{ porta verso } H_1\}$
- errore di I tipo : rifiutare H_0 quando è vera H_0
- errore di II tipo : rifiutare H_1 quando è vera H_1

1.3.1 Livello di significatività

Def: Livello di significatività fissato α

$$\begin{aligned} \alpha &= \sup_{H_0} \mathbb{P}_\theta(Y \in R) \\ &= \max(\text{prob di errore del I tipo}) \end{aligned}$$

Def: Livello di significatività osservato α^{oss}

- unilaterale dx : $\alpha^{oss} = \sup_{H_0} \mathbb{P}_\theta(T \geq t^{oss})$
- unilaterale sx : $\alpha^{oss} = \sup_{H_0} \mathbb{P}_\theta(T \leq t^{oss})$
- bilaterale : $\alpha^{oss} = 2\sup_{H_0} \min [\mathbb{P}_\theta(T \leq t^{oss}), \mathbb{P}_\theta(T \geq t^{oss})]$

1.3.2 Funzione di potenza

$$\pi(\theta) = \mathbb{P}_\theta(Y \in R) = \left\{ \begin{array}{ll} \alpha(\theta) & , \theta \in \Theta_0 \\ 1 - \beta(\theta) & , \theta \in \Theta \setminus \Theta_0 \end{array} \right\} \quad \left| \quad \begin{array}{lll} \alpha(\theta) & = & \mathbb{P}(\text{err I tipo}) = \mathbb{P}(\text{rif. } H_0) \\ 1 - \beta(\theta) & = & 1 - \mathbb{P}(\text{err II tipo}) = \mathbb{P}(\text{rif. } H_0) \end{array} \right.$$

1.3.3 Proprietà di un test

Def: Test non distorto $\Leftrightarrow \pi(\theta) \geq \alpha, \forall \theta \in \Theta \setminus \Theta_0 \Leftrightarrow \mathbb{P}(\text{rif } H_0) \geq \alpha, \forall \theta \in \Theta \setminus \Theta_0$

Def: Test consistente $\Leftrightarrow \lim_{n \rightarrow +\infty} \pi(\theta) = 1, \forall \theta \in \Theta \setminus \Theta_0$

1.3.4 Regioni di confidenza

Def: Una regione di confidenza $\hat{\Theta}(y) \subset \Theta$ di livello $(1 - \alpha)$, viene ricavata fissando la sua probabilità di copertura pari a $(1 - \alpha)$:

$$\mathbb{P}(\theta \in \hat{\Theta}(y)) = 1 - \alpha, \forall \theta \in \Theta \quad \rightsquigarrow \quad \hat{\Theta}(y)$$

oppure, quando è possibile, tramite una quantità pivotale (§A.7):

$$\mathbb{P}(a(Y, \theta) \in E) = 1 - \alpha, \forall \theta \in \Theta, E \subset \mathbb{R} \quad \rightsquigarrow \quad \hat{\Theta}(y)$$

Oss: Nel caso del p-value si ha: $\hat{\Theta}(y) = \{\theta \in \Theta : \alpha^{oss}(y, \theta) \geq \alpha\}$

1.4 La verosimiglianza

Possibili applicazioni della verosimiglianza:

- stima puntuale : $\hat{\theta} : L(\hat{\theta}) \geq L(\theta), \forall \theta \in \Theta$
- stima intervallare : $\hat{\Theta}(y) = \{\theta \in \Theta : L(\theta) \geq L(\hat{\theta}) \cdot c, 0 \leq c \leq 1\}$
- test TRV : $L(\hat{\theta})/L(\theta_0)$

Def: Funzione di verosimiglianza $L(\theta)$, e log-verosimiglianza $l(\theta)$:

$$\begin{aligned} L(\theta) &= \prod_{i=1}^n f_{X_i|X_{i-1}, \dots, X_1}(x_i|x_{i-1}, \dots, x_1; \theta), \quad X = (X_1, \dots, X_n) \\ l(\theta) &= \log L(\theta) \\ l^*(\theta) &= \nabla l(\theta) = [\partial l(\theta)/\partial \theta_i] \quad i, j = 1, \dots, p = \dim(\theta) \\ l^{**}(\theta) &= \mathbb{J}l(\theta) = [\partial^2 l(\theta)/\partial \theta_i \partial \theta_j] \quad \nabla = \text{gradiente}, \mathbb{J} = \text{jacobiano} \end{aligned}$$

Proprietà della verosimiglianza:

- $L(\theta)$ è invariante rispetto a riparametrizzazioni biunivoche
- $L(\theta) \propto L(\theta) \cdot c, \quad c = \text{costante}$
 $\Rightarrow L(\theta)$ è equivalente a $L(\theta) \cdot c \Rightarrow l(\theta)$ è equivalente a $l(\theta) + c$
- $\mathbb{E}(l^*(\theta)) = 0, \quad \mathbb{V}(l^*(\theta)) = \mathbb{E}(l^*(\theta) \cdot l^*(\theta)^T) = I(\theta) \rightsquigarrow l^*(\theta) \dot{\sim} N(0, I(\theta))$
- Informazione osservata: $J(\theta) = -l^{**}(\theta) = -\mathbb{J}l(\theta)$
- Informazione attesa: $I(\theta) = \mathbb{E}(J(\theta)) = -\mathbb{E}(l^{**}(\theta))$

Oss: Se gli X_i sono i.i.d. si ha $I(\theta) = ni(\theta)$ dove $i(\theta)$ è l'informazione osservata per X_1 .

1.4.1 Stima di massima verosimiglianza

Def: È definita stima di max verosimiglianza (o SMV) di θ la quantità¹:

$$\hat{\theta} := \left\{ \hat{\theta} \in \Theta : L(\hat{\theta}) \geq L(\theta), \forall \theta \in \Theta \setminus \{\hat{\theta}\} \right\}$$

$\hat{\theta} \sim N_p(\theta, 1/J(\hat{\theta}))$ distrib. approx, $p = \dim(\theta) \rightarrow$ più fedele al campione

$\hat{\theta} \sim N_p(\theta, 1/I(\hat{\theta}))$ distrib asintotica \rightarrow più fedele alla distrib. asintotica

Def: Equivarianza (od ~~Invarianza~~) della SMV:

Data $\hat{\theta}$ SMV per $L(\theta)$, e $\psi(\cdot) : \Theta \rightarrow \Psi$ biunivoca, allora la SMV per $\psi(\theta)$ è $\hat{\psi} = \psi(\hat{\theta})$.

1.5 Statistiche sufficienti

1.5.1 Statistiche sufficienti e criterio di Neyman-Fisher

Def: Una statistica $t(\cdot)$ è sufficiente se

$$t(y) = t(z) \Rightarrow L(\theta, y) \propto L(\theta, z), \quad \forall \theta \in \Theta, \quad \forall y, z \in \mathcal{Y}$$

o equivalentemente se e solo se

$$L(\theta) \propto h(y)k(t(y); \theta)$$

Oss: Se $t(\cdot)$ è sufficiente, allora $L(\theta)$ dipende da y solo tramite $t(y)$, cioè $L(\theta, y) = L(\theta, t(y))$.

Oss: Esiste sempre una statistica sufficiente e coincide con l'intero campione di dati y .

1.5.2 Statistiche sufficienti minimali

Def: Una statistica $t(\cdot)$ è sufficiente minimale se

$$t(y) = t(z) \Leftrightarrow L(\theta, y) \propto L(\theta, z), \quad \forall \theta \in \Theta, \quad \forall y, z \in \mathcal{Y}$$

o equivalentemente se

$$L(y; \theta)/L(z; \theta) = h(y, z) \Leftrightarrow t(y) = t(z)$$

¹Per una soluzione numerica si veda il metodo di Newton-Raphson in §A.4

NB: Considerando le curve di livello $\mathcal{Y}_V = \{y \in \mathcal{Y} : \text{le } L(\theta, y) \text{ sono proporzionali tra loro}\}$ e $\mathcal{Y}_c = \{y \in \mathcal{Y} : t(y) = c\}$, si ottengono P_V e P_t , due partizioni² di \mathcal{Y} .

Nel caso delle stat. suff. si ha che $\#P_t > \#P_V$ in quanto si ha almeno un caso in cui $\mathcal{Y}_c \subset \mathcal{Y}_V$, mentre in quelle minimali $\#P_t = \#P_V$ poiché $P_V \equiv P_t$ perché in ogni caso $\mathcal{Y}_c \equiv \mathcal{Y}_V$.

Oss: Se la stat. suff. min. esiste, essa è essenzialmente unica, ovvero le stat. suff. min. sono tutte funzioni l'una dell'altra, in quanto condividono la stessa partizione indotta.

1.6 Famiglie esponenziali

Def: In una famiglia esponenziale $L(\theta)$ assume la forma:

$$L(\theta) \propto h(y) \exp \left\{ \sum_{i=1}^k \psi_i(\theta) t_i(y) - c(\theta) \right\}, \quad \dim(\theta) = p$$

dove k è detto ordine, e $\psi = \psi(\theta)$ parametro canonico.

1.6.1 Famiglie esponenziali regolari

Def: Una famiglia esponenziale è detta regolare se:

- Θ coincide con l'intero insieme per cui $L(\theta)$ è integrabile
- la dimensione di θ coincide con l'ordine: $p = k$
- le funzioni $\psi(\theta) : \Theta \rightarrow \Psi$ sono invertibili
- le funzioni $\psi(\theta)$ sono infinitamente derivabili in θ

Parametrizzazione canonica

La funzione $\psi(\theta)$ è una riparametrizzazione, è quindi possibile scrivere:

$$\left. \begin{aligned} l(\psi) &= \sum_{i=1}^p \psi_i t_i - k(\psi), & k(\psi) &= c(\theta(\psi)) \\ l^*(\psi) &= \left[t_i - \frac{\partial k(\psi)}{\partial \psi_i} \right] \\ J(\psi) &= -l^{**}(\psi) = \left[\frac{\partial^2 k(\psi)}{\partial \psi_r \partial \psi_s} \right] \end{aligned} \right| \begin{array}{l} i = 1, \dots, p \\ r, s = 1, \dots, p \end{array}$$

Oss: $J(\psi)$ non stocastica $\Rightarrow I(\psi) \equiv J(\psi)$

²Si veda la definizione e relativi esempi di partizione di un insieme in §A.8

NB: Da qui possiamo ricavare valore atteso e varianza di T_i :

$$\begin{aligned} \bullet \mathbb{E}(l^*(\psi)) = 0 &\Rightarrow \mathbb{E}(T_i) = \mathbb{E}\left(\frac{\partial k(\psi)}{\partial \psi_i}\right) = \frac{\partial k(\psi)}{\partial \psi_i} \\ \bullet \mathbb{E}(l^*(\psi)l^*(\psi)^T) = I(\psi) &\Rightarrow \mathbb{E}(l_r^*(\psi; T_r)l_s^*(\psi; T_s)) = \mathbb{Cov}(T_r, T_s) = \frac{\partial^2 k(\psi)}{\partial \psi_r \partial \psi_s} \\ &\Rightarrow \mathbb{V}(T_i) = \mathbb{Cov}(T_i, T_i) = \frac{\partial^2 k(\psi)}{\partial^2 \psi_i} \end{aligned}$$

SMV per famiglie esponenziali regolari

In pratica, risolvere il sistema:

$$l^*(\psi) = \frac{\partial l(\psi)}{\partial \psi_i} = 0 \rightsquigarrow \hat{\psi}_i \rightsquigarrow \hat{\theta}_i, \quad i = 1, \dots, p$$

equivale a risolvere questo altro sistema:

$$t_i - \frac{\partial k(\psi)}{\partial \psi_i} = 0 \Leftrightarrow t_i = \mathbb{E}(T_i) \rightsquigarrow \hat{\psi}_i \rightsquigarrow \hat{\theta}_i, \quad i = 1, \dots, p$$

1.7 Efficienza di uno stimatore

1.7.1 Problemi regolari di stima

Un problema regolare di stima è caratterizzato dalle seguenti proprietà:

- il modello statistico è identificabile secondo la definizione al §1.1
- Θ è un aperto di \mathbb{R}^p , con $p = \dim(\theta)$
- le funzioni di densità f_Y hanno tutte lo stesso supporto
- per le f_Y si può scambiare due volte il simbolo di integrale e derivata rispetto a θ

1.7.2 Disuguaglianza di Cramer-Rao

In un problema regolare di stima, dato uno stimatore $\tilde{\theta}$ con $\mathbb{E}(\tilde{\theta}) = a(\theta)$, si ha che:

$$\begin{aligned} \mathbb{V}(\tilde{\theta}) &\geq [a'(\theta)]^2 / I(\theta) \quad , \quad \tilde{\theta} \text{ distorto} \\ \mathbb{V}(\tilde{\theta}) &\geq 1 / I(\theta) \quad , \quad \tilde{\theta} \text{ non distorto} \end{aligned}$$

Def: Stimatore $\tilde{\theta}$ efficiente $\Leftrightarrow \mathbb{E}(\tilde{\theta}) = \theta \wedge \mathbb{V}(\tilde{\theta}) = 1/I(\theta)$

NB: Non sempre è possibile reperire un $\tilde{\theta}$ che sia efficiente.

1.7.3 Teorema di Rao-Blackwell

$$\left. \begin{array}{l} \hat{\theta}(T) \text{ funzione dei dati solo tramite } T \text{ stat. suff.} \\ \tilde{\theta}(Y) \text{ basato sui dati non ridotti} \end{array} \right\} \Rightarrow \mathbb{V}(\hat{\theta}) \leq \mathbb{V}(\tilde{\theta})$$

Oss: Se T è stat. suff. min., e $\mathbb{E}(\hat{\theta}(T)) = \theta$ con $\hat{\theta}(T)$ unico $\Rightarrow \hat{\theta}(T)$ è efficiente.

NB: Per dimostrare l'unicità di $\hat{\theta}(T)$ suppongo che esista un altro stimatore $\hat{\theta}^*(T)$ non distorto, e poi verifico che $\mathbb{E}(\hat{\theta}^*(T) - \hat{\theta}(T)) = 0 \Leftrightarrow \hat{\theta}^*(T) = \hat{\theta}(T)$.

1.7.4 Teorema di Lehman-Scheffé

Thm: Se $\exists T$ stat. suff. completa ed $\exists \tilde{\theta}(Y)$ non distorto $\Rightarrow \exists! \tilde{\theta}^* = \mathbb{E}(\tilde{\theta}|T = t)$ ed è efficiente.

Def: Una statistica T è detta completa se $\mathbb{E}(f(T)) = 0, \forall \theta \in \Theta \Leftrightarrow f(T)$ è la v.a. degenere 0.

Oss: Alcune importanti considerazioni:

- Se t è stat. suff. completa $\Rightarrow T$ è l'unico stimatore efficiente per $\mathbb{E}(T)$
- Se $\tilde{\theta}(T)$ è non distorto e funzione biunivoca di $T \Rightarrow \tilde{\theta}(T)$ è efficiente
- Tipicamente la SMV $\hat{\theta}$ è distorta per rispettare l'equivarianza rispetto a riparametrizzazioni.

Se quindi essa non è efficiente ma esiste un $\tilde{\theta}$ che lo è, si ha che $\hat{\theta}$ è una buona approssimazione di $\tilde{\theta}$ perchè $\mathbb{E}(\hat{\theta}) \doteq \theta$ per n sufficientemente grande.

1.8 Test di verosimiglianza (Wilks) e regioni di confidenza

$$H_0 : \theta = \theta_0 \text{ vs } H_1 : \theta \neq \theta_0$$

$$W(\theta_0) = -2 \log \frac{\max_{H_0} L(\theta)}{\max_{H_1} L(\theta)} \\ = 2 \left[l(\hat{\theta}) - l(\theta_0) \right]$$

$$W(\theta_0) \sim \chi_p^2, p = \dim(\theta)$$

$$\Theta(y) \doteq \{ \theta \in \Theta : W(\theta) < \chi_{p;1-\alpha}^2 \} \\ \doteq \left\{ \theta \in \Theta : l(\theta) > l(\hat{\theta}) - \frac{1}{2} \chi_{p;1-\alpha}^2 \right\} \\ \doteq \{ \theta \in \Theta : -z_{1-\alpha} < r(\theta) < z_{1-\alpha} \}$$

$$H_0 : \theta = \theta_0 \text{ vs } H_1 : \theta \neq \theta_0$$

$$r(\theta_0) = \text{sgn}(\hat{\theta} - \theta_0) \left| \sqrt{W(\theta_0)} \right|$$

$$r(\theta_0) \sim N(0, 1)$$

$$\Theta(y) \doteq \{ \theta \in \Theta : r(\theta) < z_{1-\alpha} \}, H_1 : \theta > \theta_0 \\ \Theta(y) \doteq \{ \theta \in \Theta : r(\theta) > -z_{1-\alpha} \}, H_1 : \theta < \theta_0$$

Oss: Se W (oppure r) è funzione monotona crescente di una statistica T avente distribuzione nota sotto $H_0 \Rightarrow$ è possibile effettuare un test equivalente esatto tramite T :

$$\alpha^{oss} = \mathbb{P}(W(\theta) \geq W^{oss}) = \mathbb{P}(T \geq t^{oss}) \quad \left| \quad \alpha^{oss} = \mathbb{P}(r(\theta) \leq r^{oss}) = \mathbb{P}(T \leq t^{oss}) \right.$$

NB: Se $r(\theta)$ è funzione monotona decrescente di $\theta \Rightarrow$ è possibile utilizzare anche ipotesi nulle composite ($H_0 : \theta \leq \theta_0$) in modo del tutto identico a quelle semplici.

1.9 Verosimiglianza profilo

Def: Data $L(\theta)$ con $\theta = (\tau, \xi)$, $\dim(\theta) = p$, $\dim(\tau) = k$, $\dim(\xi) = p - k$, dove τ è il vettore di componenti d'interesse, mentre ξ è quello di disturbo, è detta verosimiglianza profilo:

$$L_p(\tau) = L(\tau, \hat{\xi}_\tau)$$

dove $\hat{\xi}_\tau$ è la SMV di ξ fatta considerando τ fissato/costante.

Oss: Si può trattare $L_p(\tau)$ come una comune verosimiglianza; è infatti possibile utilizzare i test $W_p(\tau)$ e $r_p(\tau)$ in modo del tutto analogo ai $W(\theta)$ e $r(\theta)$.

NB: Nel caso di un test con ipotesi “multiparametriche” basta applicare una riparametrizzazione biunivoca e poi ci si riconduce ad una verosimiglianza profilo. Ad esempio:

$$\begin{cases} H_0 : \alpha \leq \beta \\ H_1 : \alpha > \beta \end{cases} \rightsquigarrow \begin{cases} H_0 : \tau \leq 0 \\ H_1 : \tau > 0 \end{cases}, \begin{cases} \tau = (\alpha - \beta) \\ \beta = \beta \end{cases} \rightsquigarrow L_p(\tau) = L(\tau, \hat{\beta}_\tau)$$

Oss: Nel caso di un test bilaterale è inoltre possibile usare il test $W(\theta)$ come segue:

$$W(H_0) = 2 [\max(l(\theta)|_{H_1}) - \max(l(\theta)|_{H_0})]$$

dove le $l(\theta)$ sono calcolate sotto i vincoli delle ipotesi. In pratica questo metodo viene impiegato quando sotto H_0 si hanno $k \leq p = \dim(\theta)$ vincoli.

1.10 Test ottimi

Def: Un test per $H_0 : \theta \in \Theta_0$ vs $H_1 : \theta \in \Theta_1 = \Theta \setminus \Theta_0$ con α fissato, avente regione di rifiuto R^* , è detto ottimo (od uniformemente più potente) se:

$$\mathbb{P}(Y \in R^*) \geq \mathbb{P}(Y \in R), \quad \forall \theta \in \Theta_1, \quad \forall \text{ altro test con regione di rif. } R$$

ovvero se e solo se:

$$\pi^*(\theta) \geq \pi(\theta), \quad \forall \theta \in \Theta_1 \quad \left| \quad \begin{array}{l} \pi^*(\theta) = \text{f.d.p. del test ottimo} \\ \pi(\theta) = \text{f.d.p. di un qualsiasi altro test} \end{array} \right.$$

1.10.1 Test rapporto di verosimiglianza

Def: Considerando il seguente sistema di ipotesi, e la statistica test associata:

$$\left\{ \begin{array}{l} H_0 : \theta = \theta_0 \\ H_1 : \theta = \theta_1 \end{array} \right., \quad \Theta = \{\theta_0, \theta_1\} \quad \left| \quad t^* = t^*(y) = \frac{L(\theta_1; y)}{L(\theta_0; y)} \right.$$

la statistica t^* è detta rapporto di verosimiglianza. Il test omonimo che ne deriva (TRV) avrà perciò come regione di rifiuto $R = \{y : t^*(y) \geq c_\alpha\}$, dove c_α soddisfa l'equazione $\mathbb{P}(t^*(Y) \geq c_\alpha; \theta_0) = \alpha$.

Varianti del TRV

- Test di Wilks:

$$W(\theta_0) = 2 \left[l(\hat{\theta}) - l(\theta_0) \right]$$

$$r(\theta_0) = \text{sgn}(\hat{\theta} - \theta_0) \left| \sqrt{W(\theta_0)} \right|, \quad p = 1$$

È il più affidabile ed usato.

- Test di Wilks con correzione di Bartlett:

$$W^*(\theta_0) = [p/\mathbb{E}(W(\theta_0))] \cdot W(\theta_0)$$

$$r^*(\theta_0) = [r(\theta_0) - \mathbb{E}(r(\theta_0))/\mathbb{V}(r(\theta_0))] , \quad p = 1$$

Ha distribuzione nulla più vicina a quella asintotica.

- Test di Wald:

$$W_e(\theta_0) = (\hat{\theta} - \theta_0)^T I(\theta_0) (\hat{\theta} - \theta_0)$$

$$r_e(\theta_0) = (\hat{\theta} - \theta_0) \sqrt{I(\theta_0)}, \quad p = 1$$

Buona interpretabilità, minor affidabilità, dipende dalla parametrizzazione, e può generare regioni di confidenza errate.

- Test di Rao:

$$W_u(\theta_0) = l^*(\theta_0)^T I(\theta_0)^{-1} l^*(\theta_0)$$

$$r_u(\theta_0) = \text{sgn}(\hat{\theta} - \theta_0) \sqrt{W_u(\theta_0)}, \quad p = 1$$

Non richiede $\hat{\theta}$ ma può generare risultati imprecisi se θ_0 è in prossimità della frontiera di Θ .

$$W_\bullet \text{ e } W^* \sim \chi_p^2, \quad p = \dim(\theta)$$

$$\underline{\text{NB:}} \quad I(\theta) \text{ può essere stimata con } I(\theta_0), I(\hat{\theta}), J(\hat{\theta})$$

$$r_\bullet \text{ e } r^* \sim N(0, 1)$$

1.10.2 Lemma di Neyman-Pearson

Def: Data una densità $f(y; \theta)$, e fissato un sistema di ipotesi:

$$\left\{ \begin{array}{l} H_0 : \theta = \theta_0 \\ H_1 : \theta = \theta_1 \end{array} \right., \quad \Theta = \{\theta_0, \theta_1\} \quad \text{oppure} \quad \left\{ \begin{array}{l} H_0 : f = f_0 \\ H_1 : f = f_1 \end{array} \right., \quad \mathcal{F} = \{f_0(\theta_0), f_1(\theta_1)\}$$

allora il TRV $t^*(y) = L(\theta_1; y)/L(\theta_0; y) = f_1(\theta_1; y)/f_0(\theta_0)$ risulta essere il più potente tra quelli di livello α fissato.

1.10.3 Ipotesi composite

Nel caso in cui il TRV $t^*(y) = h(t(y))$, con $h(\cdot)$ funzione monotona; conoscendo la distribuzione di $t(y)$ sotto H_0 , allora:

- $R^* = \{y : t^*(y) > c\} = \{y : t(y) > t_{1-\alpha}\}$, $h(\cdot)$ monotona crescente
- $R^* = \{y : t^*(y) > c\} = \{y : t(y) < t_\alpha\}$, $h(\cdot)$ monotona decrescente

Risulta quindi possibile utilizzare ipotesi composite del tipo:

$$\begin{aligned} \bullet \quad & \begin{cases} H_0 : \theta = \theta_0 \\ H_1 : \theta = \theta_1 \end{cases}, \quad \theta_1 > \theta_0 \quad \rightsquigarrow \quad \begin{cases} H_0 : \theta = \theta_0 \quad \vee \quad \theta \leq \theta_0 \\ H_1 : \theta \geq \theta_1 \end{cases} \\ \bullet \quad & \begin{cases} H_0 : \theta = \theta_0 \\ H_1 : \theta = \theta_1 \end{cases}, \quad \theta_1 < \theta_0 \quad \rightsquigarrow \quad \begin{cases} H_0 : \theta = \theta_0 \quad \vee \quad \theta \geq \theta_0 \\ H_1 : \theta \leq \theta_1 \end{cases} \end{aligned}$$

NB: Le famiglie esponenziali monoparametriche ($p = 1$) hanno sempre TRV monotono rispetto a $t(y)$ stat. suff. min.. Il verso della monotonia del TRV dipende solamente da quello della monotonia di $\psi(\theta)$.

Oss: I test $W(\theta)$ e $r(\theta)$ sono funzioni monotone del TRV, e quindi sono anch'essi dei test ottimi.

Riassumendo: una trasformazione monotona del TRV non altera la bipartizione $(\mathcal{Y}_0, \mathcal{Y}_1)$ dello spazio campionario, quindi $\mathbb{P}(Y \in R) = \pi(\theta)$ non viene alterata, e l'ottimalità permane:

$$\mathbb{P}(Y \in \{y \in \mathcal{Y} : t^*(y) > c\}) = \mathbb{P}(Y \in \{y \in \mathcal{Y} : t(y) \rightsquigarrow H_1\}) = \mathbb{P}(Y \in \{y \in \mathcal{Y}_1\})$$

Capitolo 2

Inferenza robusta

L'obiettivo è modificare l'equazione di verosimiglianza del modello \mathcal{F} in modo tale da renderla robusta rispetto a dati anomali.

2.1 Equazioni di stima

Def: Un'equazione in θ del tipo $q(\theta; y) = 0$, è detta equazione di stima e $q(\theta; y)$ funzione di stima.

Def: Una funzione di stima è detta non distorta $\Leftrightarrow \mathbb{E}(q(\theta; Y)) = 0, \forall \theta \in \Theta$

NB: Nella quasi totalità dei casi $q(\theta; y) = \sum_{i=1}^n g(\theta; y_i)$, dove $g(\theta; y_i)$ è la funzione di stima per l'osservazione i -esima; perchè $q(\theta; y)$ sia non distorta deve anche esserlo ogni singola $g(\theta; y_i)$, cioè:

$$\mathbb{E}(q(\theta; Y)) = 0, \forall \theta \in \Theta \Leftrightarrow \mathbb{E}(g(\theta; Y_i)) = 0, \forall \theta \in \Theta, i = 1, \dots, n$$

Oss: Un esempio di equazione di stima non distorta è $l^*(\theta; y) = \sum_{i=1}^n \ell(\theta; y_i) = 0$.

Def: Gli stimatori $\tilde{\theta}$ definiti come soluzione di $q(\theta; y) = 0$ sono detti stimatori di tipo M (ovvero stimatori di massima verosimiglianza).

2.2 Proprietà degli stimatori di tipo M

Def: Preso $\hat{\theta}$ soluzione di $l^*(\theta; y) = 0$ ed un qualsiasi altro stimatore $\tilde{\theta}$ soluzione di una $q(\theta; y) = 0$, si ha che $\mathbb{V}(\hat{\theta}) \leq \mathbb{V}(\tilde{\theta}), \forall \theta \in \Theta$, cioè $\hat{\theta}$ è lo stimatore a varianza minima tra i non distorti.

2.2.1 Normalità asintotica

Lo score $l^*(\theta; y)$ è un caso particolare di $q(\theta; y)$, cerchiamo quindi di generalizzarne i risultati. Sviluppando $q(\theta; y)$ in serie di Taylor e con opportune considerazioni, si ottiene:

$$\begin{array}{l|l} q(\theta; y) = \sum_{i=1}^n g(\theta; y_i) & l^*(\theta; y) = \sum_{i=1}^n \ell(\theta; y_i) \\ \sqrt{n}(\tilde{\theta} - \theta) = \frac{\sqrt{n}q(\theta; y)}{-\mathbb{E}(\frac{\partial}{\partial \theta} q(\theta; Y))} & \sqrt{n}(\hat{\theta} - \theta) = \frac{\sqrt{n}l^*(\theta; y)}{-\mathbb{E}(l^{**}(\theta; Y))} \end{array}$$

entrambi i membri dell'equazione hanno distribuzione asintotica normale centrata nello zero; definite le seguenti quantità:

$$\begin{array}{l|l} V_g(\theta) = \mathbb{V}(g(\theta; Y_i)) = \mathbb{E}(g(\theta; Y_i)g(\theta; Y_i)^T) & \mathbb{V}(\ell(\theta; Y_i)) = \mathbb{E}(\ell(\theta; Y_i)\ell(\theta; Y_i)^T) = i(\theta) \\ D_g(\theta) = -\mathbb{E}(\frac{\partial}{\partial \theta} g(\theta; Y_i)) & -\mathbb{E}(\ell(\theta; Y_i)) = i(\theta) \end{array}$$

dobbiamo calcolare la varianza del membro di destra:

$$\begin{array}{l|l} \mathbb{V}\left(\frac{\sqrt{n}q(\theta; y)}{-\mathbb{E}(\frac{\partial}{\partial \theta} q(\theta; Y))}\right) = \frac{n(nV_g(\theta))}{(nD_g(\theta))^2} & \mathbb{V}\left(\frac{\sqrt{n}l^*(\theta; y)}{-\mathbb{E}(l^{**}(\theta; Y))}\right) = \frac{nI(\theta)}{I(\theta)^2} = \frac{1}{i(\theta)} \end{array}$$

ora possiamo scrivere la distribuzione dello stimatore:

$$\begin{array}{l|l} \tilde{\theta} \sim N\left(\theta; \frac{V_g(\theta)}{nD_g(\theta)^2}\right), p = 1 & \hat{\theta} \sim N_p\left(\theta; \frac{1}{I(\theta)}\right), p = 1 \\ \tilde{\theta} \sim N_p\left(\theta; \frac{1}{n}[(D_g(\theta)^{-1})^T V_g(\theta) D_g(\theta)^{-1}]\right), p \geq 1 & \end{array}$$

Oss: In generale $V_g(\theta) \neq D_g(\theta)$, ma se si considera l'equazione di stima modificata:

$$\tilde{q} = D_g(\theta)^T V_g(\theta)^{-1} q(\theta; y)$$

essa ha la stessa soluzione $\tilde{\theta}$ di $q(\theta; y)$, è non distorta, e soddisfa anche $\mathbb{V}(\tilde{q}(\theta; Y)) = -\mathbb{E}\left(\frac{\partial}{\partial \theta} \tilde{q}(\theta; Y)\right)$.

Stimatore sandwich

Una scorretta specificazione del modello \mathcal{F} può far cadere la proprietà $\mathbb{V}(l^*(\theta; Y)) = I(\theta)$, perciò una stima consistente della varianza asintotica di $\hat{\theta}$ è fatta considerando $l^*(\theta; y)$ come una generica

$q(\theta; y)$, cioè senza effettuare le usuali semplificazioni:

$$\begin{aligned}\hat{V}(\hat{\theta}) &= \frac{1}{n}[(D_g(\hat{\theta}))^{-1}]^T V_g(\hat{\theta}) D_g(\hat{\theta})^{-1}] \\ &= \mathbb{E}(l^{**}(\hat{\theta}; Y))^{-1} \mathbb{V}(l^*(\hat{\theta}; Y)) (\mathbb{E}(l^{**}(\hat{\theta}; Y))^{-1})^T \\ &= J(\hat{\theta})^{-1} \left[\sum_{i=1}^n \ell(\hat{\theta}; y_i) \ell(\hat{\theta}; y_i)^T \right] J(\hat{\theta})^{-1}\end{aligned}$$

dove $\hat{V}(\hat{\theta})$ è detto stimatore sandwich.

Oss: Se \mathcal{F} è correttamente specificato si avrà $J(\hat{\theta})^{-1} \left[\sum_{i=1}^n \ell(\hat{\theta}; y_i) \ell(\hat{\theta}; y_i)^T \right] = \mathbb{1}_n$, dove $\mathbb{1}_n$ è la matrice identità di dimensione $n \times n$.

2.3 Quasi-verosimiglianza

Se è possibile reperire una $l_Q(\theta)$ primitiva di $q(\theta; y)$, utilizzabile per definire test e regioni di confidenza nel modo usuale, allora essa è detta funzione di quasi-verosimiglianza basata sullo quasi-score $q(\theta; y)$.

Se $p = 1$ e $\Theta \subset \mathbb{R}$, preso un $\theta_0 \in \Theta$ arbitrario, si ha $l_Q(\theta) = \int_{\theta_0}^{\theta} q(t; y) dt$.

Se $p > 1$, $\Theta \subset \mathbb{R}^p$, e $q \in C^1(\theta)$, è necessario per l'esistenza di l_Q che $J_Q(\theta) = -\frac{\partial}{\partial \theta} q(t; y) dt$ sia una matrice simmetrica.

NB: $W_Q(\theta) = 2 \left[l_Q(\tilde{\theta}) - l_Q(\theta) \right] \sim \chi_p^2 \Leftrightarrow V_g(\theta) = D_g(\theta)$.

2.4 Funzionali statistici e funzione di influenza

Si vuole un metodo che indipendentemente dal tipo di modello \mathcal{F} specificato, generi uno stimatore robusto rispetto a dati anomali.

Una soluzione è data dall'utilizzo della funzione di ripartizione empirica \hat{F} per stimare il parametro ignoto.

Def: Poichè si può considerare $\theta = T(F)$, allora diventa possibile stimare θ con $\hat{\theta} = T(\hat{F})$, dove $T(\cdot)$ è detto funzionale statistico. È infatti possibile ricavare $T(\cdot)$ come:

$$\mathbb{E} \{q(\theta; Y_i)\} = 0 \Leftrightarrow \int g(\theta; y) dF(\theta; y) = 0 \Leftrightarrow \int g(T(\theta); y) dT(\theta) = 0 \rightsquigarrow T(\theta)$$

oppure in base alla funzione d'influenza.

Def: La funzione d'influenza $IF(c; T, F)$ rappresenta l'effetto su $T(F)$ di una contaminazione infinitesimale nel punto c ; per uno stimatore definito da una $q(\theta; y) = \sum_{i=1}^n g(\theta; y_i) = 0$ la IF assume la forma:

$$IF(c; g, F) = \frac{g(\theta; c)}{-\mathbb{E}_F \left(\frac{\partial}{\partial \theta} g(\theta; Y_i) \right)}$$

lo stimatore $\tilde{\theta}$ è detto robusto \Leftrightarrow la funzione $g(\theta; y_i)$ è limitata.

2.4.1 Stimatore di Huber

Si ottengono stimatori robusti con proprietà di ottimalità utilizzando funzioni di stima tali che:

$$g^*(\theta; y_i) = [\ell(\theta; y_i) - a]_{-b}^b = \begin{cases} -b & , [\cdot] < -b \\ [\cdot] & , -b \leq [\cdot] \leq b \\ b & , [\cdot] > b \end{cases}$$

dove $a = \mathbb{E}(\ell^*(\theta; y))$ per garantire la non distorsione di $q(\theta; y)$, mentre b viene generalmente scelto in modo tale che l'efficienza di $\tilde{\theta}$ sia inferiore di un 5% rispetto quella di $\hat{\theta}$.

Capitolo 3

Inferenza bayesiana

3.1 Il teorema di Bayes

Dati due eventi A e B , la regola del prodotto è definita come:

$$\mathbb{P}(A|B) = \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)}$$

Applicando più volte la regola precedente si ottiene la formula di Bayes:

$$\mathbb{P}(A|B) = \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)} = \frac{\mathbb{P}(B|A)\mathbb{P}(A)}{\mathbb{P}(B|A)\mathbb{P}(A) + \mathbb{P}(B|A^c)\mathbb{P}(A^c)} = \frac{\mathbb{P}(B|A)\mathbb{P}(A)}{\mathbb{P}(B|A)\mathbb{P}(A) + \mathbb{P}(B|A^c)\mathbb{P}(A^c)}$$

3.1.1 Versione generale

In generale, dati gli eventi A_1, \dots, A_n a due a due disgiunti di Ω :

$\mathbb{P}(A_i B) = \frac{\mathbb{P}(B A_i)\mathbb{P}(A_i)}{\sum_{k=1}^n \mathbb{P}(B A_k)\mathbb{P}(A_k)}$	$\begin{aligned} \mathbb{P}(A_i) &= \text{prob a priori} \\ \mathbb{P}(A_i B) &= \text{prob a posteriori} \\ \mathbb{P}(B A_i) &= \text{verosimiglianza} \end{aligned}$
--	---

3.1.2 Versione nel continuo

$\pi(\theta x) = \frac{\pi(\theta)f(x \theta)}{\int_{\Theta} f(x \theta)\pi(\theta)d\theta} \propto \pi(\theta)f(x \theta)$	$\begin{aligned} \pi(\theta) &= \text{densità di } \theta \text{ a priori} \\ \pi(\theta x) &= \text{densità di } \theta \text{ a posteriori} \\ f(x \theta) &= \text{verosimiglianza} \end{aligned}$
---	---

NB: Per ottenere la $\pi(\theta|x)$ esatta, occorre prima calcolare $\pi(\theta)f(x|\theta)$ e successivamente dividerlo per la costante di normalizzazione $\int_{\Theta} \pi(\theta)f(x|\theta)d\theta$.

3.2 Procedure inferenziali

La densità ottenuta $\pi(\theta|x)$, rappresenta la distribuzione di probabilità del parametro d'interesse θ , condizionatamente al campione x rilevato. Grazie a questa quantità è possibile effettuare stime puntuali/intervallari, verifiche d'ipotesi, e previsioni.


3.2.1 Stima puntuale

- valore atteso : $\hat{\theta} = \mathbb{E}(\theta|x)$
- moda (discreto) : prendo il valore con maggior densità di prob
- mediana (discreto, valori ordinati) : prendo il valore k -mo t.c. $\sum_{i=0}^k p(x_i) \simeq 0.5$

3.2.2 Regioni di confidenza HPD

Una regione di confidenza viene calcolata nel seguente modo:

1. si fissa una soglia c pari al valore massimo di $\pi(\theta|x)$, e la si fa decrescere progressivamente
2. in corrispondenza dei punti di intersezione della retta $\pi(\theta|x) = c$ con la curva $\pi(\theta|x)$, si identifica una regione per θ
3. si interrompe la diminuzione di c non appena la somma delle densità, dei valori appartenenti alla regione identificata, è pari ad $1 - \alpha$
4. la regione di livello $1 - \alpha$ cercata è quella ottenuta in quest'ultimo passo



La regione trovata include quindi quei valori di θ ai quali corrisponde una densità a posteriori più elevata (High Posterior Density).

NB: Se nel continuo capita di avere una $\pi(\theta|x)$ monotona crescente, basta integrarla tra a e $+\inf$ (oppure tra $-\inf$ e b se decrescente); in questo modo si ottiene una funzione in a (oppure b), e non resta che porla pari ad $1 - \alpha$ per ricavare l'estremo cercato.

3.2.3 Verifica d'ipotesi

Il fattore di Bayes viene utilizzato per verificare il sistema ipotesi $H_0 : \theta \in \Theta_0$ vs $H_1 : \theta \in \Theta \setminus \Theta_0$; esso consiste nel valutare il rapporto tra le densità a posteriori calcolate sotto le due diverse ipotesi:

$$B = \begin{cases} \frac{\pi(\theta_{H0}|x)}{\pi(\theta_{H1}|x)} & \text{per ipotesi alternative semplici } (<>) \\ \frac{\pi(\theta_{H0}|x)}{1 - \pi(\theta_{H0}|x)} & \text{per ipotesi alternative composte } (\neq) \end{cases}$$

$B > 1$ porta all'accettazione di H_0 , mentre $B < 1$ porta al suo rifiuto.

3.3 Coniugate naturali

Fissata la densità a priori e la verosimiglianza, la a posteriori risulta già nota:

A priori $\pi(\theta)$	Verosimiglianza $f(x \theta)$	A posteriori $\pi(\theta x)$
Beta(a, b)	Bin(m, θ)	Beta($a + \sum x_i, b + m \cdot n - \sum x_i$)
$\Gamma(a, b)$	Exp(θ)	$\Gamma(a + n, b + \sum x_i)$
$N(\eta, \tau^2)$	$N(\mu, \sigma_0^2)$	$N\left(\frac{\sigma_0^2 \eta + \tau^2 n \bar{x}}{\sigma_0^2 + \tau^2 n}, \frac{\tau^2 \sigma^2}{\sigma_0^2 + \tau^2 n}\right)$
$\Gamma(a, b)$	Pois(θ)	$\Gamma(a + \sum x_i, b + n)$
Pareto(a, b)	U($0, \theta$)	Pareto($a + n, \max(b, x_{(n)})$)

NB: La numerosità del campione x è n .

NB: In $N(\mu, \sigma_o^2)$, il parametro d'interesse è μ con σ_o^2 noto.

Appendice A

Richiami

A.1 Distribuzioni note

A.1.1 Alcune nozioni fondamentali

$$Z \sim N(0, 1) \quad Z^2 \sim \chi_1^2 \quad \sum_{i=1}^v \chi_1^2 \sim \chi_v^2 \quad Z/\sqrt{\chi_v^2/v} \sim t_v \quad \frac{\chi_{v_1}^2/v_1}{\chi_{v_2}^2/v_2} \sim F_{v_1, v_2}$$

A.1.2 Distribuzione di media e varianza campionaria

Sia $X = (X_1, \dots, X_n)$ vettore aleatorio con $X_i \sim N(\mu, \sigma^2)$, $i = 1, \dots, n$, allora:

$$\begin{aligned} \bar{X} &= \frac{1}{n} \sum_{i=1}^n X_i & \bar{X} &\sim N(\mu, \frac{\sigma^2}{n}) \\ S^2 &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 & S^2 &\sim \frac{\sigma^2}{n-1} \chi_{n-1}^2 \end{aligned}$$

Oss: Grazie al teorema del limite centrale, questi risultati valgono anche asintoticamente.

A.2 Funzioni indicatrici

- $\mathbb{1}_{[a, b]}(x) = \mathbb{1}_{[-\infty, x]}(a) \cdot \mathbb{1}_{[x, +\infty]}(b)$
- $\mathbb{1}_{[a, b]}(x) = \mathbb{1}_{[\frac{1}{b}, \frac{1}{a}]}(\frac{1}{x})$
- $\mathbb{1}_{[a, b]}(x) = \mathbb{1}_{[ac, bc]}(xc)$
- $\mathbb{1}_{[a, b]}(x) = \mathbb{1}_{[a+c, b+c]}(x+c)$

A.3 Disuguaglianza di Jensen

- $g(\cdot)$ convessa “ \cup ” $\Rightarrow \mathbb{E}(g(X)) \geq g(\mathbb{E}(X))$
- $g(\cdot)$ concava “ \cap ” $\Rightarrow \mathbb{E}(g(X)) \leq g(\mathbb{E}(X))$

A.4 Newton-Raphson

Quando non è possibile calcolare in modo esplicito la SMV, occorre allora procedere tramite metodi numerici. Viene spesso usato il metodo iterativo di Newton-Raphson il quale, dato un punto iniziale di partenza, genera una successione di punti sempre più prossimi al valore cercato.

L'equazione di aggiornamento di indice $s = 0, 1, \dots$ è la seguente:

$$\begin{aligned}\hat{\theta}_{s+1} &= \hat{\theta}_s - \frac{l'(\hat{\theta}_s)}{l''(\hat{\theta}_s)} \quad , \quad \dim(\theta) = 1 \\ \hat{\theta}_{s+1} &= \hat{\theta}_s - \left(\mathbb{J}l(\hat{\theta}_s) \right)^{-1} \cdot \nabla l(\hat{\theta}_s) \quad , \quad \dim(\theta) > 1\end{aligned}$$

Il punto iniziale di partenza viene scelto tramite un metodo alternativo (ad es. quello dei momenti).

A.5 Cambio di variabile

Def: Una funzione g è detta diffeomorfismo $\Leftrightarrow \exists h = g^{-1} \wedge g, h \in \mathcal{C}^1$

Def: Data una funzione $f(x) : \mathcal{X} \rightarrow \mathbb{R}$ ed un diffeomorfismo $g(x) : \mathcal{X} \rightarrow \mathcal{Y}$, si effettua un cambio di variabile in f ponendo $y = g(x)$, perciò $x = g^{-1}(y) = h(y)$, e:

$$f(y) = |\det(\mathbb{J}h(y))| \cdot f(h(y))$$

NB: Si effettua un cambio di variabile, non di parametro!

A.6 Metodo delta

Def: Dato un $\hat{\theta} \xrightarrow{d} N_p(\theta, 1/I(\theta))$, se si effettua una riparametrizzazione $\psi = g(\theta)$, $g \in \mathcal{C}^2$ allora:

$$\hat{\psi} = g(\hat{\theta}) \xrightarrow{d} N_p\left(\psi, (\Delta^T \cdot I(\theta)|_{\psi=\psi(\theta)} \cdot \Delta)^{-1}\right) \quad , \quad \Delta = \begin{pmatrix} \nabla g^{-1}(\psi_1) \\ \vdots \\ \nabla g^{-1}(\psi_p) \end{pmatrix}$$

dove $p = \dim(\theta) = \dim(\psi)$, e Δ è la matrice delle derivate parziali prime delle componenti di $\theta = g^{-1}(\psi)$ (cioè si derivano le componenti di θ dopo averle esplicitate in funzione di ψ).

A.7 Quantità pivotale

Data una funzione $a : \mathcal{Y} \times \Theta \rightarrow \mathbb{R}$, la v.c. $a(Y, \theta)$ è detta quantità pivotale se, per ogni fissato $\theta \in \Theta$, essa ha distribuzione di probabilità che non dipende da θ .

Oss: Il p-value α^{oss} è per costruzione una qt. pivotale, in quanto $\alpha^{oss}(Y, \theta) \stackrel{H_0}{\sim} U(0, 1)$.

A.8 Partizione di un insieme

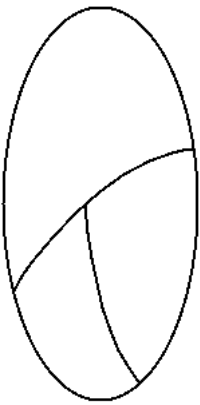
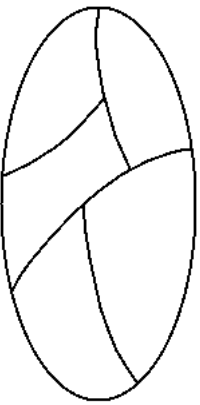
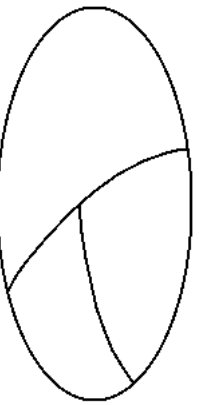
Una partizione di un insieme \mathcal{Y} è definita come una collezione di sottoinsiemi di \mathcal{Y} non vuoti, mutuamente disgiunti, e tali che la loro unione è l'insieme \mathcal{Y} stesso.

I sottoinsiemi che costituiscono una partizione vengono detti parti, orbite o curve di livello.

Es. 1:

$$\mathcal{Y} = \{1, 2, 3, 4, 5, 6, 7, 8\} \quad \rightsquigarrow \quad P = \{\{1, 3, 5, 7\}, \{2, 6\}, \{4, 8\}\}, \quad \#P = 3$$

Es. 2:

partizioni indotte su \mathcal{Y}		
<i>verosim.</i>	<i>stat. suff.</i>	<i>stat. suff. min.</i>
P_V	P_{ss}	P_{ssm}
		
$\#P_V = 3$	$\#P_{ss} = 5$	$\#P_{ss} = 3$

A.9 Promemoria per la risoluzione di un problema

Per qualunque problema si devono effettuare i seguenti passi:

- identificare il vettore aleatorio relativo all'esperimento
- identificare il parametro d'interesse ($p \geq 1$)

mentre i restanti variano a seconda del tipo di quesito posto.

A.9.1 Inferenza frequentista

- durante la scrittura della verosimiglianza, ricordarsi di usare la formula estesa (quella con le densità condizionate), che al più verrà ridotta se sussiste l'indipendenza tra le osservazioni
- la funzione di potenza $\pi(\theta)$ è sempre definita come la probabilità di rifiutare H_0 quando H_0 è vera; e la porzione di funzione d'interesse è sempre quella definita nell'intervallo di Θ indotto da H_1 (cioè in $\Theta \setminus \Theta_0$)
- per calcolare la SMV bisogna trovare il punto di massimo della verosimiglianza $L(\theta)$; non sempre questo si ricava tramite $l^*(\theta) = 0$ e bisogna quindi usare altri metodi alternativi
- un test del tipo definito in §1.10.1, avente una statistica T funzione monotona del TRV, è anch'esso un test ottimo (altresì detto uniformemente più potente)

A.9.2 Inferenza robusta

- lo stimatore sandwich stima la varianza dello stimatore di tipo M considerato
- uno stimatore è robusto se tutte le $g(\theta; y_i)$ (le generiche componenti di $q(\theta; y)$) sono limitate

A.9.3 Inferenza bayesiana

- nella densità a priori la variabile d'interesse coincide col parametro!!
Es: $\theta \sim \text{Exp}(\lambda) \rightsquigarrow \pi(\theta) = \lambda \exp(-\lambda\theta)$
- quando necessario, per semplificare i calcoli, basta identificare solamente il nucleo di una distribuzione, vengono cioè eliminate tutte le costanti proporzionali che non dipendono dal parametro

Appendice B

Notazioni, tabelle, e grafici

B.1 Notazioni

$v.a.$: variabile aleatoria
$f.d.p.$: funzione di potenza
$f.d.r.$: funzione di ripartizione
$\mathbb{1}_{[a, b]}(x)$: funzione indicatrice per l'intervallo $[a, b]$
$\ell(\theta, y_i)$: componente i -esima dello score di verosimiglianza $l^*(\theta, y) = \sum_{i=1}^n \ell(\theta, y_i)$

$\exists \cdot, \exists! \cdot$: esiste un \cdot , esiste un unico (uno ed uno solo) \cdot
\leadsto	: “porta a”
\vee, \wedge	: “o, oppure”, “e, congiuntamente”
$f \in C^n$: f è continua e derivabile assieme alle sue derivate fino all'ordine n
$\mathbb{1}_n$: matrice identità di dimensioni $n \times n$

$J(\theta)$: informazione osservata
$I(\theta)$: informazione attesa
$i(\theta)$: informazione attesa per una singola componente del vettore aleatorio

$t = t(y)$: una statistica test con le parentesi omesse per brevità
$T = t(Y)$	



















∇	: simbolo del gradiente
\mathbb{J}	: simbolo del jacobiano

$X \perp\!\!\!\perp Y$: X è indipendente da Y
$X \not\perp\!\!\!\perp Y$: X è dipendente da Y

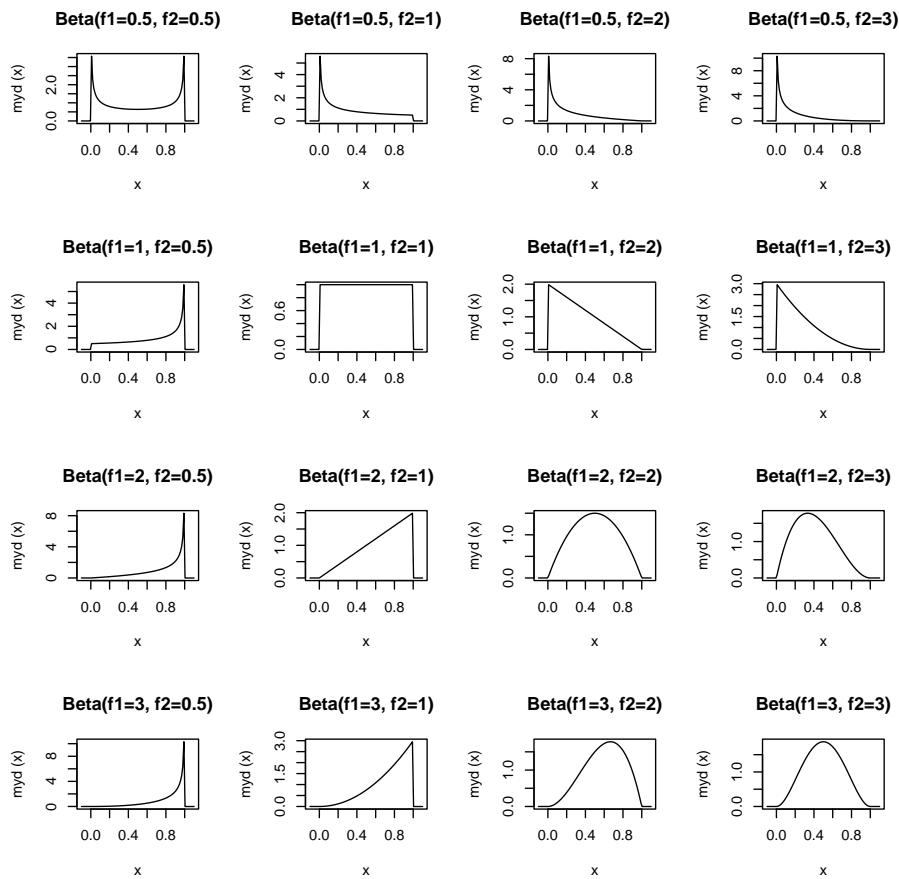
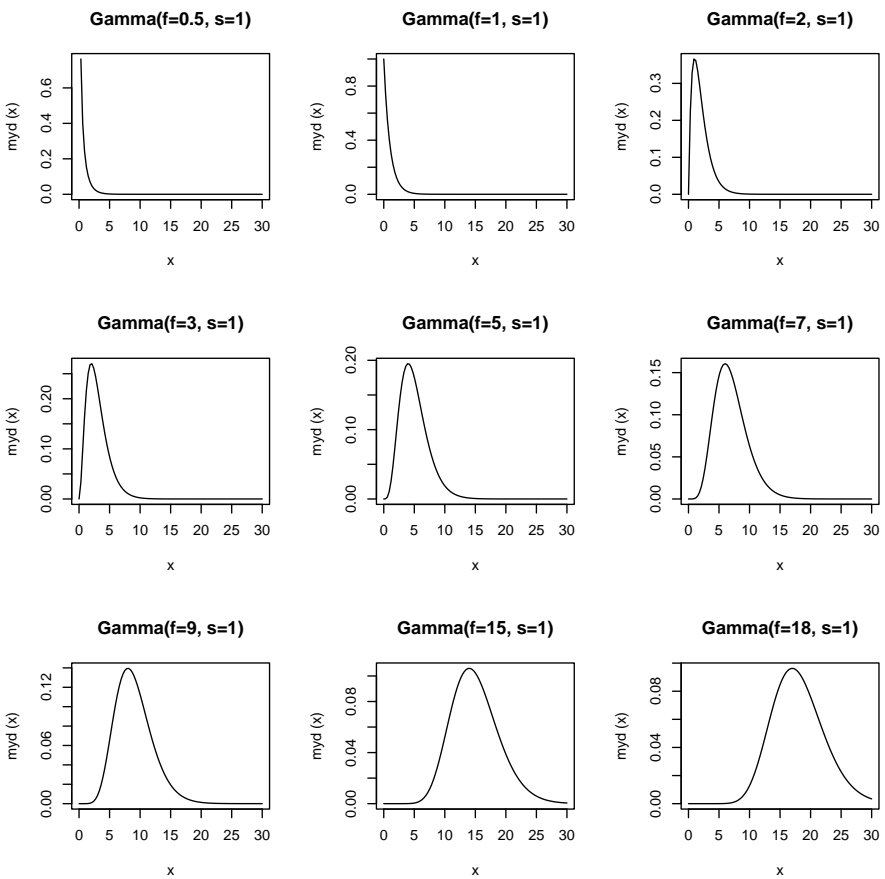
A^c	: indica l'evento complementare di A
-------	--

Tipo	Θ	\mathcal{Y}	Densità	\mathbb{E}	\mathbb{V}	Proprietà
$U(a, b)$	$a < b \in \mathbb{R}$	$[a, b]$	$\frac{1}{b-a} \mathbb{I}_{[a,b]}(y)$	$\frac{(a+b)}{2}$	$\frac{(b-a)^2}{12}$	—
$\text{Exp}(\lambda)$	$\lambda > 0$	\mathbb{R}^+	$\lambda \exp\{-\lambda y\}$	$1/\lambda$	$1/\lambda^2$	—
$N(\mu, \sigma^2)$	$\mu \in \mathbb{R}, \sigma > 0$	\mathbb{R}	$\frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{1}{2\sigma^2}(y-\mu)^2\right\}$	μ	σ^2	$\text{Bi}(n, \pi) \dot{\sim} N(n\pi, n\pi(1-\pi))$ $\text{Pois}(\lambda) \dot{\sim} N(\lambda, \lambda), \lambda > 10$ $\chi_v^2 \dot{\sim} N(v, 2v), v > 30$
$\Gamma(a, b)$	$a, b > 0$	\mathbb{R}^+	$\frac{b^a}{\Gamma(a)} y^{a-1} \exp\{-by\}$	a/b	a/b^2	$\text{Exp}(b) \sim \Gamma(1, b)$ $\chi_v^2 \sim \Gamma(v/2, 1/2)$ $\Gamma(n) = (n-1)!, n \in \mathbb{N} \setminus \{0\}$
$\text{Beta}(a, b)$	$a, b > 0$	$[0, 1]$	$\frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} y^{a-1} (1-y)^{b-1}$	$\frac{a}{a+b}$	$\frac{ab}{(a+b)^2(a+b+1)}$	$\text{Beta}(1, 1) \sim U(0, 1)$

Tabella B.1: Principali densità e relative proprietà



f = forma, s = scala, p = posizione, df = gradi di libertà



f = forma, s = scala, p = posizione, df = gradi di libertà

Attribuzione-Non commerciale-Condividi allo stesso modo 2.5 Italia

► Tu sei libero di:



riprodurre, distribuire, comunicare al pubblico, esporre in pubblico, rappresentare, eseguire e recitare quest'opera



modificare quest'opera

► Alle seguenti condizioni:



Attribuzione. Devi attribuire la paternità dell'opera nei modi indicati dall'autore o da chi ti ha dato l'opera in licenza e in modo tale da non suggerire che essi avallino te o il modo in cui tu usi l'opera.



Non commerciale. Non puoi usare quest'opera per fini commerciali.



Condividi allo stesso modo. Se alteri o trasformi quest'opera, o se la usi per crearne un'altra, puoi distribuire l'opera risultante solo con una licenza identica o equivalente a questa.

Si ricorda che questo documento rappresenta degli appunti personali e che gli autori, nonostante i loro sforzi, non ne garantiscono in alcun modo la correttezza dei contenuti.

Per errori e/o commenti mandate una mail con oggetto
“statcp” all'indirizzo steelgunblade@yahoo.it
