

## Statistica Inferenziale

### Soluzioni 2. Intervalli di confidenza

#### Introduzione.

Siano  $X_1, \dots, X_n$  v.a. indipendenti e con identica distribuzione. Sia  $f(x_1, \dots, x_n; \theta)$  la densità o la distribuzione di probabilità di  $X_1, \dots, X_n$ , con parametro incognito  $\theta$ . Siano date due statistiche  $L_1 = \ell_1(X_1, \dots, X_n)$  e  $L_2 = \ell_2(X_1, \dots, X_n)$  tali che  $L_1 \leq L_2$  e

$$P(L_1 < \theta < L_2) = 1 - \alpha,$$

dove  $1 - \alpha$  è noto come il *coefficiente di confidenza* (non dipendente da  $\theta$ ). Allora, l'intervallo aleatorio  $L_1, L_2$  è detto intervallo di confidenza per  $\theta$  di livello  $(1 - \alpha)\%$ , il quale conterrà il valore vero (ignoto) di  $\theta$  con probabilità pari a  $(1 - \alpha)\%$ . Una volta ottenuto un campione di osservazioni da  $X_1, \dots, X_n$ , l'intervallo calcolato non sarà più aleatorio, ma sarà un intervallo numerico che conterrà o meno il valore vero (ignoto) di  $\theta$ .

#### Esemplificazioni.

Sia  $X$  una v.a. normale con media  $\mu$  e varianza  $\sigma^2$ . Sia dato un campione casuale di dimensione  $n$  di osservazioni da  $X$ . I seguenti casi sono di particolare interesse.

- *Intervallo di confidenza per  $\mu$  con  $\sigma^2$  noto.* Si fa riferimento alla statistica

$$Z = \frac{\sqrt{n}(\bar{X}_n - \mu)}{\sqrt{\sigma^2}} \sim N(0, 1).$$

Considerando che

$$P\left(-z_{\alpha/2} < \frac{\sqrt{n}(\bar{X}_n - \mu)}{\sqrt{\sigma^2}} < z_{\alpha/2}\right) = 1 - \alpha$$

dove  $z_{\alpha/2}$  è il quantile di ordine  $\alpha/2$  di  $Z$ , si ha che l'intervallo di confidenza per  $\mu$  al livello  $(1 - \alpha)\%$  è dato da

$$\left(\bar{X}_n - z_{\alpha/2}\sqrt{\sigma^2/n}, \bar{X}_n + z_{\alpha/2}\sqrt{\sigma^2/n}\right).$$

- *Intervallo di confidenza per  $\mu$  con  $\sigma^2$  incognito.* Si fa riferimento alla statistica

$$T = \frac{\frac{\sqrt{n}(\bar{X}_n - \mu)}{\sqrt{\sigma^2}}}{\sqrt{S^2(n-1)/\sigma^2}} \sim t_{n-1}.$$

Considerando che

$$P\left(-t_{\alpha/2} < \frac{\bar{X}_n - \mu}{\sqrt{S^2/n}} < t_{\alpha/2}\right) = 1 - \alpha,$$

dove  $t_{\alpha/2}$  è il quantile di ordine  $\alpha/2$  di  $T$ , si ha che l'intervallo di confidenza per  $\mu$  al livello  $(1 - \alpha)\%$  è dato da

$$\left(\bar{X}_n - t_{\alpha/2}\sqrt{S^2/n}, \bar{X}_n + t_{\alpha/2}\sqrt{S^2/n}\right).$$

- *Intervallo di confidenza per  $\sigma^2$  con  $\mu$  incognito.* Si fa riferimento alla statistica

$$T = \frac{S^2(n-1)}{\sigma^2} \sim \chi_{n-1}^2.$$

Considerando che

$$P\left(\chi_{n-1,1-\alpha/2}^2 < \frac{S^2(n-1)}{\sigma^2} < \chi_{n-1,\alpha/2}^2\right) = 1 - \alpha,$$

dove  $\chi_{n-1,1-\alpha/2}^2$  è il quantile di una  $\chi_{n-1}^2$  che lascia alla propria sinistra una probabilità pari a  $\alpha/2$  e  $\chi_{n-1,\alpha/2}^2$  è il quantile che lascia alla propria destra una probabilità pari a  $\alpha/2$ , si ha che l'intervallo di confidenza per  $\sigma^2$  al livello  $(1 - \alpha)\%$  è dato da

$$\left(\frac{S^2(n-1)}{\chi_{n-1,\alpha/2}^2}, \frac{S^2(n-1)}{\chi_{n-1,1-\alpha/2}^2}\right).$$

Inoltre consideriamo i seguenti risultati.

- *Intervallo di confidenza per la probabilità di successo in una popolazione dicotomica (grandi campioni).* Siano  $X_1, \dots, X_n$  v.a. indipendenti ed identicamente distribuite di tipo Bernoulliano con probabilità di successo  $p$ . Consideriamo lo stimatore di  $p$  fornito da  $\sum_{i=1}^n X_i/n$  e la sua distribuzione per  $n$  grande ottenuta sulla base del teorema del limite centrale

$$\frac{\hat{p} - p}{\sqrt{p(1-p)/n}} \approx N(0, 1).$$

Un'estensione del teorema del limite centrale ci porta a

$$\frac{\hat{p} - p}{\sqrt{\hat{p}(1-\hat{p})/n}} \approx N(0, 1).$$

Allora, un intervallo di confidenza per  $p$  al livello  $(1 - \alpha)\%$  è dato da

$$\left(\hat{p} - z_{\alpha/2}\sqrt{\hat{p}(1-\hat{p})/n}, \hat{p} + z_{\alpha/2}\sqrt{\hat{p}(1-\hat{p})/n}\right),$$

dove  $z_{\alpha/2}$  è il quantile di ordine  $\alpha/2$  di una  $N(0, 1)$ .

- *Intervallo di confidenza per la media di una popolazione qualsiasi (grandi campioni).* Siano  $X_1, \dots, X_n$  v.a. indipendenti ed identicamente distribuite con valore atteso  $E(X_i) = \mu$  e varianza  $Var(X_i) = \sigma^2$ ,  $i = 1, \dots, n$ . Per  $n$  sufficientemente grande, dall'applicazione del teorema del limite centrale si ha che

$$\frac{\bar{X}_n - \mu}{\sqrt{\sigma^2/n}} \approx N(0, 1)$$

e, per un'estensione del teorema del limite centrale,

$$\frac{\bar{X}_n - \mu}{\sqrt{S^2/n}} \approx N(0, 1).$$

Allora un intervallo di confidenza approssimato al livello  $(1 - \alpha)\%$  per  $\mu$  è dato da

$$\bar{X}_n - z_{\alpha/2}\sqrt{S^2/n}; \bar{X}_n + z_{\alpha/2}\sqrt{S^2/n},$$

dove  $z_{\alpha/2}$  è il quantile di ordine  $\alpha/2$  di una  $N(0, 1)$ .

**Esercizio A.**

a) Il carattere in considerazione nella popolazione di riferimento non è distribuito normalmente, per cui l'intervallo di confidenza richiesto non si costruisce usando i quantili della distribuzione  $t$  di Student. Si può invece, sfruttando l'estensione del teorema del limite centrale, ricorrere al fatto che per grandi campioni la grandezza  $(\bar{X} - \mu_x)/\sqrt{S^2/n}$  si distribuisce approssimativamente come una normale standardizzata. Di conseguenza, se il campione è grande, si può determinare l'intervallo di confidenza utilizzando i quantili di una normale standardizzata. Essendo  $\alpha = 0,01$ , si cerca il quantile  $z_{0,005}$ , ovvero quel valore tale che  $P(Z \geq z_{0,005}) = 0,005$ ; esso è pari a 1,96. Quindi, l'intervallo cercato è dato da  $[53,00 - 1,96 \cdot 20/\sqrt{50}; 53,00 + 1,96 \cdot 20/\sqrt{50}]$ , ovvero da  $[47,46; 58,54]$ .

b) L'ampiezza dell'intervallo precedentemente calcolato è pari a 11,08. L'intervallo di livello 99%, per una generica numerosità campionaria  $n$ , ha ampiezza pari a  $2 \cdot 2,576 \cdot 20/\sqrt{n}$ . Da qui, ponendo  $2 \cdot 2,576 \cdot 20/\sqrt{n} = 11,08$ , si ottiene  $n = 87$  (arrotondando il risultato al fine di garantire  $n$  valore intero).

**Esercizio B.**

a) Sia  $\bar{R}$  la v. a. che esprime la media del campione. Essendo l'alternativa  $H_1 : \mu_R < 0,5$  composta da valori della media più piccoli che sotto  $H_0$ , si rifiuterà l'ipotesi nulla  $H_0$  per piccoli valori di  $\bar{R}$ . Essendo  $\alpha = 0,05$ , si rifiuterà  $H_0$  per valori di  $\bar{R}$  inferiori a  $R_\alpha$ , dove  $R_\alpha$  è tale che  $P(\bar{R} \leq R_\alpha; H_0) = 0,05$ . Per trovare il valore  $R_\alpha$  si consideri che le  $R_i$  sono distribuite normalmente e che se è vera  $H_0$  queste hanno media pari a 0,5. Quindi, potendo scrivere  $P(\bar{R} \leq R_\alpha; H_0) = 0,05 = P\left(\frac{\bar{R}-0,5}{\frac{s}{\sqrt{n}}} \leq \frac{R_\alpha-0,5}{\frac{s}{\sqrt{n}}}; H_0\right)$ , ed essendo  $(\bar{R} - 0,5)/\sqrt{S^2/n}$  distribuita come una  $t$  di Student con g.d.l. pari a 29, il valore  $(R_\alpha - 0,5)/\sqrt{S^2/n}$  deve essere pari a  $-1,699$ , ovvero  $R_\alpha = -1,699 \frac{s}{\sqrt{n}} + 0,5 = -1,113$ . La zona di rifiuto di  $H_0$  è pertanto costituita dai valori osservati di  $\bar{R}$  inferiori a  $-1,113$ , ed essendo il valore osservato  $\bar{R} = 0,3$  superiore a  $-1,113$  si accetta  $H_0$ . Un procedimento alternativo consiste nel confrontare  $(0,3 - 0,5)\sqrt{n}/(5,2)$  con  $-1,699$  e rifiutare  $H_0$  se tale valore è inferiore a  $-1,699$ , dal momento che se la disuguaglianza di sopra risulta verificata anche questa disuguaglianza risulta verificata, e viceversa.

b) Per trovare l'intervallo di confidenza richiesto si consideri che  $\frac{(n-1)S^2}{\sigma^2} \sim \chi_{29}^2$ , per cui l'intervallo di confidenza al 95% è dato da  $\left[\frac{29 \times (5,2)^2}{45,722}; \frac{29 \times (5,2)^2}{16,047}\right] = [17,150; 48,866]$ .

c) Il "Value at Risk"  $T$  soddisfa alla relazione  $P(R_i \leq T) = 0,01 = P(Z \leq \frac{T-0,5}{6,99})$ , dove  $Z$  è una v. a. con distribuzione normale standardizzata. Essendo che il percentile della normale standardizzata che lascia alla sua sinistra un'area pari a 0,01 è pari a  $-2,326$ , si ricava che  $T = -2,326 \cdot 6,99 + 0,5 = 15,759$ , ovvero che la riserva patrimoniale a fronte di tale investimento deve essere pari a circa 15 milioni e 760 mila euro. Questa riserva fronteggia perdite che sono estremamente rare.

**Esercizio C.**

a) Per l'estensione del teorema del limite centrale, abbiamo che  $\frac{\hat{p}-p}{\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}} \approx N(0, 1)$ , per  $n$  grande.

Quindi, l'intervallo di confidenza ha estremi  $\hat{p} - 1,96\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$  e  $\hat{p} + 1,96\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$ , dove  $n = 351$ , ovvero, l'intervallo è dato da  $[0,598; 0,698]$ .

b) L'errore di stima è pari a  $|\hat{p} - p|$ . Si richiede di calcolare  $n$  tale per cui

$$P(|\hat{p} - p| < 0.02) = 0.90.$$

Considerando la distribuzione di  $\frac{\hat{p}-p}{\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}}$  ottenuta tramite il teorema del limite centrale,  $n$  deve essere tale per cui

$$\Phi\left(\frac{0,02}{\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}}\right) = \frac{1,90}{2}.$$

Da qui si ricava che  $n = 1534$ .