

## Statistica Inferenziale

### Soluzioni 1. Stima puntuale

#### Distribuzioni campionarie.

- Sia  $X$  una v.a. normale con valore atteso  $\mu$  e varianza  $\sigma^2$ ,  $X \sim N(\mu, \sigma^2)$ . Allora,  $Z = (X - \mu)/\sigma$  si distribuisce come una normale standard,  $Z \sim N(0, 1)$ .
- Sia  $Z$  la v.a. normale standard. Allora la v.a.  $T = Z^2$  segue una distribuzione chi-quadrato con un g.d.l.,  $T \sim \chi_1^2$ . Più in generale, la somma di  $n$  v.a. normali standard al quadrato, indipendenti tra loro, dà luogo ad una  $\chi_n^2$ .
- Sia  $T$  un v.a.  $\chi_n^2$ . Allora  $E(T) = n$  e  $Var(T) = 2n$ .
- Sia  $T_1$  una v.a. distribuita come un  $\chi_n^2$  e sia  $T_2$  una v.a. distribuita come un  $\chi_m^2$ , indipendente da  $T_1$ . Allora,  $T_1 + T_2 \sim \chi_{n+m}^2$ . La proprietà si generalizza alla somma di più v.a. con diversi g.d.l., purchè valga l'ipotesi di indipendenza.
- Sia  $Z$  una v.a. normale standard e sia  $T$  una v.a. chi-quadrato con  $n$  g.d.l. indipendente da  $Z$ . Allora, la v.a.  $\frac{Z}{\sqrt{T/n}}$  si distribuisce come una  $t$  di Student con  $n$  g.d.l.
- Sia  $X$  una v.a. normale con media  $\mu$  e varianza  $\sigma^2$ . Sia dato un campione casuale di dimensione  $n$  di osservazioni da  $X$ . La variabile media campionaria  $\bar{X}_n$  e la variabile varianza campionaria corretta  $S^2$  hanno distribuzione, rispettivamente,

$$\bar{X}_n \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

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

Inoltre,

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

sfruttando le distribuzioni di  $\bar{X}_n$  e di  $S^2$  sopra indicate e l'indipendenza tra le due v.a..

**Teorema del limite centrale.** Siano  $X_1, \dots, X_n$  variabili aleatorie indipendenti con valore atteso comune  $E(X_i) = \mu$  e varianza comune finita  $Var(X_i) = \sigma^2 < +\infty$ ,  $i = 1, \dots, n$ . Sia  $\bar{X}_n$  la variabile media campionaria. Allora, asintoticamente (per  $n$  sufficientemente grande) la variabile aleatoria

$$Y_n = \frac{\bar{X}_n - E(\bar{X}_n)}{\sqrt{Var(\bar{X}_n)}} = \frac{\sqrt{n}(\bar{X}_n - \mu)}{\sqrt{\sigma^2}}$$

si distribuisce come una normale standard.

**Stima puntuale.** Sia  $G$  uno *stimatore* di un parametro di interesse  $\gamma$ , vale a dire una statistica, funzione delle v.a.  $X_1, \dots, X_n$ . Il valore assunto dallo stimatore in corrispondenza del particolare campione osservato si definisce *stima*.

Esempio 1. Sia  $X$  una v.a.  $N(\mu, \sigma^2)$  e sia dato un campione casuale di numerosità  $n$  da  $X$ . Uno stimatore per  $\mu$  è rappresentato dalla v.a. media campionaria,  $\bar{X}_n$ . Tale stimatore ha distribuzione  $N(\mu, \sigma^2/n)$ . La stima  $\hat{\mu}$  di  $\mu$  sulla base del campione osservato è data dalla media delle osservazioni del campione  $\bar{x}_n$ .

Esempio 2. Sia dato un campione di numerosità  $n$  da  $X$ , v.a. Bernoulliana di parametro  $p$ . Allora una stima di  $p$  è data dalla frequenza relativa dei successi,  $\hat{p} = \sum_{i=1}^n x_i/n$ . Inoltre, lo stimatore dato da  $\sum_{i=1}^n X_i/n$  ha media  $p$  e varianza  $p(1-p)/n$ . Per  $n$  sufficientemente grande, sfruttando il teorema del limite centrale possiamo approssimare la distribuzione dello stimatore con una distribuzione  $N(p, p(1-p)/n)$ .

Sono di seguito elencate alcune proprietà desiderabili per uno stimatore.

- *Correttezza* (non distorsione). Uno stimatore è corretto (non distorto) se  $E(G) = \gamma$ , cioè se il suo valore atteso coincide con la quantità da stimare. In caso contrario, si dice distorto, con distorsione pari a  $D = E(G) - \gamma$ .
- *Efficienza*. Indichiamo con  $MSE(G)$  (errore quadratico medio) la quantità  $E[(G - \gamma)^2]$ , che risulta essere pari anche a  $D^2 + Var(G)$ . Allora, dati due stimatori di  $\gamma$ ,  $G_1$  e  $G_2$ , diciamo che  $G_1$  è più efficiente di  $G_2$  se  $MSE(G_1) < MSE(G_2)$ .
- *Consistenza*. Uno stimatore  $G_n$  (si indica  $n$  a pedice per evidenziare la dipendenza del campione) si dice consistente (in senso debole) per  $\gamma$  se,  $\forall \varepsilon > 0$ ,

$$\lim_{n \rightarrow \infty} P(|G_n - \gamma| < \varepsilon) = 1.$$

Si tratta di una proprietà asintotica, cioè per  $n \rightarrow \infty$ , ovvero considerando una numerosità campionaria che aumenta indefinitamente (a livello pratico, per  $n$  sufficientemente alto).

- *Correttezza asintotica*. Uno stimatore  $G_n$  è asintoticamente non corretto per  $\gamma$  se

$$\lim_{n \rightarrow \infty} E(G_n) \neq \gamma.$$

Anche in questo caso si tratta di una proprietà asintotica.

**Esercizio A.**

a) Sia  $C$  la variabile aleatoria che descrive il costo nel prossimo volo. Allora  $P(C > 576,15) = P\left(\frac{C}{6,00 \cdot 25} > \frac{576,15}{6,00 \cdot 25}\right) = P(\chi_1^2 > 3,841)$ , dove con  $\chi_1^2$  si è indicata una variabile aleatoria con distribuzione chi-quadrato con un grado di libertà. Dalle tavole si ricava che  $P(\chi_1^2 > 3,841) = 0,05$ .

b) Sia  $C_T = \sum_{i=1}^{12} C_i$  il costo aggiuntivo complessivo di 12 voli. Essendo il costo di ogni volo indipendente da quello degli altri voli,  $\frac{C_T}{6,00 \cdot 25}$  si distribuisce come una chi-quadrato con 12 g.d.l. Da cui si ricava che  $P(C_T < 3.500,55) = P\left(\frac{C_T}{6,00 \cdot 25} < \frac{3.500,55}{6,00 \cdot 25}\right) = P(\chi_{12}^2 < 23,337) = 1 - 0,025 = 0,975$ .

c) Sia  $G_i$  il guadagno dell' $i$ -esimo volo, allora  $E(G_i) = 1.500$  e  $\text{Var}(G_i) = 50^2$ . Sia  $D = G_i - G_{i+1}$  la differenza del guadagno in due voli successivi. Essa è distribuita come una v. a. normale con valore atteso pari a zero. Inoltre, essendo  $G_i$  e  $G_{i+1}$  indipendenti,  $\text{Var}(D) = \text{Var}(G_i) + \text{Var}(G_{i+1}) = 70,711^2$ . Dalla simmetria della normale,  $P(|D| > 120) = 2 \cdot P\left(\frac{D}{70,711} > \frac{120}{70,711}\right) = 2 \cdot (1 - \Phi(1,697)) = 2 \cdot (1 - 0,95513) = 0,08974$ . Il valore 0,95513 è stato ottenuto per interpolazione lineare ponendo

$$\frac{\Phi(1,697) - \Phi(1,690)}{1,697 - 1,690} = \frac{\Phi(1,70) - \Phi(1,69)}{0,01}.$$

Sostituendo si ottiene  $(\Phi(1,697) - 0,9633)/0,007 = (0,9554 - 0,9545)/0,01$ . Da cui si ricava  $\Phi(1,697) = 0,9545 + 0,01 \cdot 0,0009/0,007 = 0,95513$ .

d)  $G_T = \sum_{i=1}^6 G_i$  è la somma dei guadagni di 6 voli.  $E(G_T) = 9.000$  e  $\text{Var}(G_T) = 6 \cdot \text{Var}(G_i) = 122,474^2$ . Da cui si ricava che  $P(G_T > 9.500) = P(Z > 4,082) = 1 - \Phi(4,082) = 1 - 1 = 0$  (dove si è indicato con  $Z$  una variabile aleatoria con distribuzione normale standardizzata).

e) Ponendo  $U_T = \sum_{i=1}^6 U_i$  si ha che  $U_T$  è una v. a. normale con  $E(U_T) = 720$  e  $\text{Var}(U_T) = 216^2$ . Inoltre,  $C_T/(6 \cdot \text{Var}(T))$  è una v. a. chi-quadrato con 6 g.d.l. Da cui si ricava che  $R \cdot \sqrt{6 \cdot 6 \cdot \text{Var}(T)}/\sqrt{\text{Var}(U_T)}$  si distribuisce come una  $t$  di Student con 6 g.d.l., per cui  $P(R > 13,99) = P(R \sqrt{6 \cdot 6 \cdot 25}/216 > 1,943)$ . Dalle tavole si ricava che la probabilità richiesta è data da  $P(t > 1,943) = 0,05$ , dove con  $t$  si è indicata una v. a. con distribuzione  $t$  di Student.

f) Il 90-esimo percentile di una  $t$  di Student con 6 g.d.l. è pari a 1,44. Ovvero possiamo scrivere

$$P\left(R \cdot \frac{\sqrt{6 \cdot 6 \cdot \text{Var}(T)}}{\sqrt{\text{Var}(U_T)}} < 1,44\right) = 0,90,$$

da cui  $r = 1,44 \sqrt{\text{Var}(U_T)}/\sqrt{6 \cdot 6 \cdot \text{Var}(T)} = 10,368$ .

**Esercizio B.**

a) Considerando  $n = 30$ , la probabilità richiesta è data da

$$P(|\bar{X}_A - \mu_A| \geq 0,5 \cdot \sqrt{\sigma_A^2}) = P\left(\frac{|\bar{X}_A - \mu_A|}{\sqrt{\sigma_A^2/n}} \geq 0,5 \cdot \sqrt{n}\right) = 2 \cdot (1 - \Phi(2,7386)) = 0,0062.$$

b) Considerando che  $n = 30$ , possiamo scrivere

$$0,95 = P\left(\frac{|\bar{X}_A - \mu_A|}{\sqrt{S_A^2}} \leq y\right) = P\left(\frac{\frac{|\bar{X}_A - \mu_A|}{\frac{\sigma_A}{\sqrt{n}}}}{\sqrt{\frac{S_A^2}{\sigma_A^2}}} \leq y \cdot \sqrt{n}\right) = P(|t_{29}| \leq y \cdot \sqrt{n}).$$

Dalle tavole si trova che  $y \cdot \sqrt{n} = 2,045$  da cui  $y = 2,045/\sqrt{30} = 0,3734$ .

c) Considerando che  $n = 30$ , possiamo scrivere

$$0,95 = P\left(\frac{|\bar{X}_A - \mu_A|}{\sqrt{D_A^2}} \leq z\right) = P\left(\frac{\frac{\sqrt{n}|\bar{X}_A - \mu_A|}{\sigma_A}}{\sqrt{\frac{D_A^2}{\sigma_A^2}}} \leq z \cdot n\right) = P(|t_{30}| \leq z \cdot n).$$

Dalle tavole si ricava che  $z \cdot n = 2,042$  da cui  $z = 2,042/30 = 0,0681$ .

d) Possiamo scrivere

$$P[(\bar{X}_B - \bar{X}_A) - (\mu_B - \mu_A) \leq 2] = P\left[\frac{(\bar{X}_B - \bar{X}_A) - (\mu_B - \mu_A)}{\sqrt{\frac{\sigma_A^2}{30} + \frac{\sigma_B^2}{20}}} \leq \frac{2}{\sqrt{\frac{\sigma_A^2}{30} + \frac{\sigma_B^2}{20}}}\right],$$

da cui, indicando con  $Z$  una variabile aleatoria normale standardizzata, si ha che la probabilità richiesta è data da  $\Phi(Z \leq 1,92154) = 0,97267$ .

e) Possiamo scrivere

$$0,05 = P(S_A^2 \geq d) = P\left(\frac{S_A^2}{\sigma_A^2} \cdot 29 \geq \frac{d}{\sigma_A^2} \cdot 29\right) = \left(\chi_{29}^2 \geq \frac{d}{10} \cdot 29\right).$$

Dalle tavole si trova che  $29 \cdot d/30 = 42,557$  da cui  $d = 14,6748$ .

### Esercizio C.

a) Sia  $X_A$  la v. a. che conta il numero di clienti attivi nel primo campione di numerosità  $n_A = 50$  e sia  $\hat{P}_A = \frac{X_A}{n_A}$ . Per il teorema del limite centrale,  $\hat{P}_A$  ha approssimativamente distribuzione normale con media  $p_A$  e varianza  $\frac{p_A(1-p_A)}{n_A}$ . Analogamente sia  $X_B$  la v. a. che conta il numero di clienti attivi nel secondo campione di numerosità  $n_B = 50$  e sia  $\hat{P}_B = \frac{X_B}{n_B}$ . Per il teorema del limite centrale  $\hat{P}_B$  ha approssimativamente distribuzione normale con media  $p_B$  e varianza  $\frac{p_B(1-p_B)}{n_B}$ . Quindi  $\hat{P}_B - \hat{P}_A$  ha approssimativamente distribuzione normale con media  $p_B - p_A$  e varianza pari alla somma delle due varianze asintotiche. Si vuole la probabilità di osservare uno scostamento fra le due frequenze campionarie superiore a quello osservato, cioè si vuole

$$P\left(\hat{P}_B - \hat{P}_A > \frac{27}{50} - \frac{23}{50}\right),$$

nel caso in cui  $p_A = p_B = p$ . In tale caso, approssimativamente,  $\frac{\hat{P}_B - \hat{P}_A}{\sqrt{\frac{2p(1-p)}{50}}} \sim N(0; 1)$  dove il valore di  $p$  non si conosce. Per un'estensione del teorema del limite centrale, l'approssimazione alla distribuzione normale continua a valere anche sostituendo a  $p$  nella espressione di sopra la stima  $\hat{p}$ . Avendo noi  $\hat{p} = (\hat{p}_A 50 + \hat{p}_B 50)/100 = 50/100 = 0,5$  si ha  $P(\hat{P}_B - \hat{P}_A > 0,54 - 0,46) = P\left(\frac{\hat{P}_B - \hat{P}_A}{\sqrt{2 \cdot \frac{0,5^2}{50}}} > \frac{0,54 - 0,46}{\sqrt{2 \cdot \frac{0,5^2}{50}}}\right) \approx P(Z > 0,8) = 1 - \Phi(0,8) = 0,2119$ , dove con  $Z$  si è indicata una v. a. con distribuzione normale standardizzata.

### Esercizio D.

Entrambi gli stimatori di  $\mu$  sono stimatori non distorti, essendo

$$E(T_1) = \frac{E(X_1 + X_2 + 3X_3)}{5} = \frac{\mu + \mu + 3\mu}{5} = \mu$$

e

$$E(T_2) = \frac{E(2X_1 + X_3)}{3} = \frac{2\mu + \mu}{3} = \mu.$$

Inoltre,  $T_1$  ha varianza

$$\text{Var}(T_1) = \frac{\sigma^2 + \sigma^2 + 9\sigma^2}{25} = 11/25 \text{ e}$$

mentre  $T_2$  ha varianza

$$\text{Var}(T_2) = \frac{4\sigma^2 + \sigma^2}{9} = 5/9.$$

Essendo i due stimatori entrambi non distorti, risulta preferibile quello con varianza minore, vale a dire  $T_1$ , essendo  $11/25 < 5/9$ . (Nel caso venisse meno la non distorsione degli stimatori, il confronto va fatto sulla base del MSE.)

### Esercizio E.

**a)** Sia  $\mu_R$  il valore atteso di  $R_i$ , allora  $\mu_R = 5 + 0,5\mu_X$ . Ora,  $\bar{R}$  è corretto se  $E(\bar{R}) = \mu_R$ . Per le proprietà di linearità del valore atteso, si ha  $E(\bar{R}) = E(5 + 0,5\bar{X}) = 5 + 0,5 \cdot E(\bar{X}) = 5 + 0,5\mu_X = \mu_R$ , per cui possiamo affermare che  $\bar{R}$  è corretto per  $\mu_R$ .

**b)** La varianza dello stimatore  $\bar{R}$  è data da  $\text{Var}(\bar{R}) = 0,5^2 \cdot \text{Var}(\bar{X}) = (0,5 \cdot \sigma_X)^2/50 = 1$ .

**c)** Lo stimatore  $\bar{R}$  è consistente per  $E(R_i)$  se  $\lim_{n \rightarrow \infty} P[|\bar{R} - \mu_R| \leq \epsilon] = 1$ , per ogni  $\epsilon > 0$ , dove  $n$  è la numerosità campionaria. Dalla disuguaglianza di Tchebycheff si sa che  $P[|\bar{R} - \mu_R| \leq k\sigma_{\bar{R}}] \geq 1 - 1/k^2$ . Ponendo  $\epsilon = k \cdot \sigma_{\bar{R}} = k \cdot 0,5 \sigma_X/\sqrt{n}$ , si ha che  $\lim_{n \rightarrow \infty} P[|\bar{R} - \mu_R| \leq \epsilon] \geq \lim_{n \rightarrow \infty} \left(1 - \frac{0,25\sigma_X^2}{\epsilon^2 n}\right)$ , ed essendo il limite a destra della disuguaglianza pari a 1 si ha la consistenza.

Si noti che la probabilità non può mai superare 1, da cui l'uguaglianza.

**d)** Per determinare la numerosità campionaria richiesta, consideriamo che  $P[|\bar{X} - \mu_X| \leq 10] = P\left[|Z| \leq \frac{10\sqrt{n}}{\sigma_X}\right] = 0,95$ , dove  $Z = (\bar{X} - \mu_X)/\sqrt{\sigma_X^2/n}$ . Per il teorema del limite centrale si può approssimare la distribuzione di  $Z$  con una  $N(0, 1)$ . Quindi, considerando che il percentile (della normale standardizzata) che lascia alla sua destra una probabilità di 0.975 è pari a 1,96, ponendo  $1,96 = 10/\sqrt{\sigma_X^2/n}$ , si ricava  $\sqrt{n} = 0,196 \cdot \sqrt{200}$ , ovvero  $n \approx 8$ . Si noti che la numerosità campionaria richiesta  $n$  è direttamente proporzionale alla varianza  $\sigma_X^2$  e inversamente proporzionale all'errore di stima (che è stato posto pari a 10).

### Esercizio F.

**a)** Si indichi con  $A$  l'affluenza alle urne, cioè il numero di elettori che andranno a votare. Allora,  $A = Np$  e si vuole verificare se  $N\hat{p}$  è uno stimatore corretto di  $A$ . Ora,  $E(N\hat{p}) = N \cdot E(\hat{p}) = Np = A$ , per cui  $N\hat{p}$  è uno stimatore corretto per  $A$ .

**b)** Si vuole trovare la numerosità campionaria  $n$  tale che

$$P[|\hat{p} - p| \leq 0,05] = 0,95 = P\left[\frac{|\hat{p} - p|}{\sqrt{\frac{p(1-p)}{n}}} \leq \frac{0,05}{\sqrt{\frac{p(1-p)}{n}}}\right].$$

Essendo la varianza  $p(1-p)/n$  incognita, questa si può porre pari al suo valore massimo  $0,25/n$ . Quindi, considerando che  $P\left[\frac{|\hat{p} - p|\sqrt{n}}{0,5} \leq \frac{0,05\sqrt{n}}{0,5}\right] = 0,95$ , usando l'approssimazione alla normale, si trova che l'evento  $\frac{|\hat{p} - p|\sqrt{n}}{0,5} \leq \frac{0,05\sqrt{n}}{0,5}$  si verifica con probabilità pari a 0,95 se  $0,05\sqrt{n}/0,5 = 1,96$ . Da questo si ricava che la numerosità campionaria  $n$  cercata è approssimativamente pari a 384.

### Esercizio G.

**a)** Il valore atteso dello stimatore  $T$  è dato da  $E(T) = (3E(X_1) + 4E(X_2) + 2E(X_3))/7 + a$ . Essendo  $E(X_1) = E(X_2) = E(X_3) = \mu$ , si ha che  $E(T) = (9/7)\mu + a$ . Imponendo la condizione di correttezza  $E(T) = \mu$ , si ricava che questa è verificata solo se  $a = -(2/7)\mu$ .

**b)** La distorsione di  $T$  per  $a = 10$  è pari a  $E(T) - \mu = (2/7)\mu + 10$ . Si noti che tale distorsione vale zero se  $\mu = -35$ .