

6. Intervalli di confidenza

La media campionaria e la varianza campionaria ci offrono una stima dei parametri media e varianza del campione statistico in esame. Abbiamo però bisogno di sapere *quanto ci si possa fidare di questa stima* ovvero quale sia la probabilità che il *vero* valore del parametro incognito non sia *troppo distante* dalla stima trovata.

Diamo perciò la seguente definizione:

Definizione 6.0.1 (Intervallo di confidenza). Sia X_1, X_2, \dots, X_n un campione statistico e sia θ un parametro (ignoto) che caratterizza la distribuzione del campione.

Siano $L_i = l_i(X_1, X_2, \dots, X_n)$ e $L_s = l_s(X_1, X_2, \dots, X_n)$ due statistiche del campione e sia $\alpha \in (0, 1)$. Dico che l'intervallo (L_i, L_s) è un *intervallo di confidenza* (o di fiducia) di livello $1 - \alpha$ se $\mathbb{P}(\theta \in (L_i, L_s)) \geq 1 - \alpha$, ovvero che (L_i, L_s) è un intervallo di confidenza (o di fiducia) di errore α se $\mathbb{P}(\theta \notin (L_i, L_s)) \leq \alpha$.

Dico che la semiretta $(L_i, +\infty)$ è un *intervallo di confidenza unilaterale superiore* di livello $1 - \alpha$ se $\mathbb{P}(\theta > L_i) \geq 1 - \alpha$

Dico che la semiretta $(-\infty, L_s)$ è un *intervallo di confidenza unilaterale inferiore* di livello $1 - \alpha$ se $\mathbb{P}(\theta < L_s) \geq 1 - \alpha$

Osservazione 6.0.3. 1. La scelta dei nomi delle due statistiche non è casuale: L_i sta per limitazione inferiore mentre L_s sta per limitazione superiore.

2. Di solito si è interessati a *piccoli* valori di α , più precisamente a $\alpha \in (10^{-2}, 10^{-1})$.
3. La disuguaglianza di Chebyshev ci ha fornito un intervallo di confidenza per la media μ del campione nel caso in cui la varianza σ^2 sia nota

$$\mathbb{P}(|\bar{X} - \mu| \geq t) \leq \frac{\sigma^2}{t^2} \quad \forall t > 0$$

ovvero

$$\mathbb{P}(|\bar{X} - \mu| < t) \geq 1 - \frac{\sigma^2}{t^2} \quad \forall t > 0$$

cioè

$$\mathbb{P}(\bar{X} - t < \mu < \bar{X} + t) \geq 1 - \frac{\sigma^2}{t^2} \quad \forall t > 0.$$

Fissato $\alpha \in (0, 1)$ scelgo $t = \frac{\sigma}{\sqrt{\alpha}}$. La disuguaglianza di Chebyshev si legge allora

$$\mathbb{P}\left(\bar{X} - \frac{\sigma}{\sqrt{\alpha}} < \mu < \bar{X} + \frac{\sigma}{\sqrt{\alpha}}\right) \geq 1 - \alpha \quad \forall \alpha \in (0, 1).$$

Dunque l'intervallo $\left(\bar{X} - \frac{\sigma}{\sqrt{\alpha}}, \bar{X} + \frac{\sigma}{\sqrt{\alpha}}\right)$ è un intervallo di confidenza di livello $1 - \alpha$ per la media μ del campione.

6.1. Stima per intervalli della media di campioni gaussiani

6.1.1. Campione gaussiano di cui è nota la varianza

Intervallo bilaterale

Sia X_1, X_2, \dots, X_n un campione gaussiano di media μ incognita e varianza σ^2 nota.

Sia Z una v.a. gaussiana standard e sia $\alpha \in (0, 1)$. Calcolo $\mathbb{P}\left(|Z| \leq z_{1-\frac{\alpha}{2}}\right)$:

$$\begin{aligned} \mathbb{P}\left(|Z| \leq z_{1-\frac{\alpha}{2}}\right) &= \mathbb{P}\left(-z_{1-\frac{\alpha}{2}} \leq Z \leq z_{1-\frac{\alpha}{2}}\right) \\ &= \mathbb{P}\left(Z \leq z_{1-\frac{\alpha}{2}}\right) - \mathbb{P}\left(Z \leq -z_{1-\frac{\alpha}{2}}\right) = \mathbb{P}\left(Z \leq z_{1-\frac{\alpha}{2}}\right) - \mathbb{P}\left(Z \leq z_{\frac{\alpha}{2}}\right) \quad (6.1) \\ &= \Phi\left(z_{1-\frac{\alpha}{2}}\right) - \Phi\left(z_{\frac{\alpha}{2}}\right) = 1 - \frac{\alpha}{2} - \frac{\alpha}{2} = 1 - \alpha. \end{aligned}$$

Sappiamo che $\bar{X} \sim \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right)$ e che dunque $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim \mathcal{N}(0, 1)$. Applichiamo quindi la disuguaglianza (6.1) a $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}}$. Si ha:

$$\begin{aligned} 1 - \alpha &= \mathbb{P}\left(\left|\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}}\right| \leq z_{1-\frac{\alpha}{2}}\right) = \mathbb{P}\left(-z_{1-\frac{\alpha}{2}} \leq \frac{\mu - \bar{X}}{\frac{\sigma}{\sqrt{n}}} \leq z_{1-\frac{\alpha}{2}}\right) \\ &= \mathbb{P}\left(\frac{-\sigma z_{1-\frac{\alpha}{2}}}{\sqrt{n}} \leq \mu - \bar{X} \leq \frac{\sigma z_{1-\frac{\alpha}{2}}}{\sqrt{n}}\right) \quad (6.2) \\ &= \mathbb{P}\left(\bar{X} - \frac{\sigma z_{1-\frac{\alpha}{2}}}{\sqrt{n}} \leq \mu \leq \bar{X} + \frac{\sigma z_{1-\frac{\alpha}{2}}}{\sqrt{n}}\right) \end{aligned}$$

L'intervallo

$$\left(\bar{X} - \frac{\sigma z_{1-\frac{\alpha}{2}}}{\sqrt{n}}, \bar{X} + \frac{\sigma z_{1-\frac{\alpha}{2}}}{\sqrt{n}}\right)$$

è dunque un intervallo di confidenza di livello $1 - \alpha$ per la media μ del campione.

Osservazione 6.1.1 (Dimensionamento del campione). Fissato il livello di confidenza $1 - \alpha$, supponiamo di voler controllare l'ampiezza dell'intervallo di confidenza $L_s - L_i$.

Nel caso in esame l'ampiezza dell'intervallo di confidenza è $\frac{2\sigma z_{1-\frac{\alpha}{2}}}{\sqrt{n}}$. Se fissiamo una limitazione superiore 2δ per l'ampiezza di tale intervallo, deve dunque essere

$$\frac{2\sigma z_{1-\frac{\alpha}{2}}}{\sqrt{n}} \leq 2\delta$$

ovvero

$$n \geq \left(\frac{\sigma z_{1-\frac{\alpha}{2}}}{\delta}\right)^2.$$

Intervallo unilaterale superiore

Sia $Z \sim \mathcal{N}(0, 1)$. Sappiamo che

$$\mathbb{P}(Z \leq t) = 1 - \alpha \quad \text{se e solo se} \quad t = z_{1-\alpha}.$$

Abbiamo dunque

$$1 - \alpha = \mathbb{P}\left(\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{1-\alpha}\right) = \mathbb{P}\left(\bar{X} - \mu \leq \frac{\sigma z_{1-\alpha}}{\sqrt{n}}\right) = \mathbb{P}\left(\mu \geq \bar{X} - \frac{\sigma z_{1-\alpha}}{\sqrt{n}}\right).$$

Quindi la semiretta

$$\left(\bar{X} - \frac{\sigma z_{1-\alpha}}{\sqrt{n}}, +\infty\right)$$

è un intervallo di confidenza unilaterale superiore di livello $1 - \alpha$.

Intervallo unilaterale inferiore

Sia $Z \sim \mathcal{N}(0, 1)$. Sappiamo che

$$\mathbb{P}(Z \geq t) = 1 - \alpha \quad \text{se e solo se} \quad \mathbb{P}(Z \leq t) = \alpha \quad \text{se e solo se} \quad t = z_\alpha.$$

Abbiamo dunque

$$1 - \alpha = \mathbb{P}\left(\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \geq z_\alpha\right) = \mathbb{P}\left(\bar{X} - \mu \geq \frac{\sigma z_\alpha}{\sqrt{n}}\right) = \mathbb{P}\left(\mu \leq \bar{X} - \frac{\sigma z_\alpha}{\sqrt{n}}\right).$$

Quindi la semiretta

$$\left(-\infty, \bar{X} - \frac{\sigma z_\alpha}{\sqrt{n}}\right) = \left(-\infty, \bar{X} + \frac{\sigma z_{1-\alpha}}{\sqrt{n}}\right)$$

è un intervallo di confidenza unilaterale inferiore di livello $1 - \alpha$.

6.1.2. Campione gaussiano di cui non è nota la varianza

Intervallo bilaterale

Sia X_1, X_2, \dots, X_n un campione gaussiano di media μ varianza σ^2 , entrambe incognite.

Sappiamo che la v.a. $T := \frac{(\bar{X} - \mu)\sqrt{n}}{S}$ segue la distribuzione t di Student con $n - 1$ gradi di libertà:

$$T \sim t(n - 1).$$

Sia $t_{n-1, 1-\frac{\alpha}{2}}$ il relativo quantile di livello $1 - \frac{\alpha}{2}$:

$$\mathbb{P}\left(T \leq t_{n-1, 1-\frac{\alpha}{2}}\right) = 1 - \frac{\alpha}{2}.$$

Calcolo $\mathbb{P}\left(|T| \leq t_{n-1,1-\frac{\alpha}{2}}\right)$:

$$\begin{aligned}\mathbb{P}\left(|T| \leq t_{n-1,1-\frac{\alpha}{2}}\right) &= \mathbb{P}\left(-t_{n-1,1-\frac{\alpha}{2}} \leq T \leq t_{n-1,1-\frac{\alpha}{2}}\right) \\ &= \mathbb{P}\left(T \leq t_{n-1,1-\frac{\alpha}{2}}\right) - \mathbb{P}\left(T \leq -t_{n-1,1-\frac{\alpha}{2}}\right) \\ &= \mathbb{P}\left(T \leq t_{n-1,1-\frac{\alpha}{2}}\right) - \mathbb{P}\left(T \leq t_{n-1,\frac{\alpha}{2}}\right) = 1 - \frac{\alpha}{2} - \frac{\alpha}{2} = 1 - \alpha.\end{aligned}$$

Abbiamo dunque

$$\begin{aligned}1 - \alpha &= \mathbb{P}\left(|T| \leq t_{n-1,1-\frac{\alpha}{2}}\right) = \mathbb{P}\left(\frac{|\bar{X} - \mu|\sqrt{n}}{S} \leq t_{n-1,1-\frac{\alpha}{2}}\right) \\ &= \mathbb{P}\left(|\bar{X} - \mu| \leq \frac{S}{\sqrt{n}}t_{n-1,1-\frac{\alpha}{2}}\right) \\ &= \mathbb{P}\left(\frac{-S}{\sqrt{n}}t_{n-1,1-\frac{\alpha}{2}} \leq \mu - \bar{X} \leq \frac{S}{\sqrt{n}}t_{n-1,1-\frac{\alpha}{2}}\right) \\ &= \mathbb{P}\left(\bar{X} - \frac{S}{\sqrt{n}}t_{n-1,1-\frac{\alpha}{2}} \leq \mu \leq \bar{X} + \frac{S}{\sqrt{n}}t_{n-1,1-\frac{\alpha}{2}}\right)\end{aligned}$$

L'intervallo

$$\left(\bar{X} - \frac{S t_{n-1,1-\frac{\alpha}{2}}}{\sqrt{n}}, \bar{X} + \frac{S t_{n-1,1-\frac{\alpha}{2}}}{\sqrt{n}}\right)$$

è dunque un intervallo di confidenza di livello $1 - \alpha$ per la media μ del campione.

Intervallo unilaterale superiore

Sappiamo che

$$\mathbb{P}(T \leq t) = 1 - \alpha \quad \text{se e solo se} \quad t = t_{n-1,1-\alpha}.$$

Abbiamo dunque

$$\begin{aligned}1 - \alpha &= \mathbb{P}\left(\frac{(\bar{X} - \mu)\sqrt{n}}{S} \leq t_{n-1,1-\alpha}\right) = \mathbb{P}\left(\bar{X} - \mu \leq \frac{S t_{n-1,1-\alpha}}{\sqrt{n}}\right) \\ &= \mathbb{P}\left(\mu \geq \bar{X} - \frac{S t_{n-1,1-\alpha}}{\sqrt{n}}\right).\end{aligned}$$

Quindi la semiretta

$$\left(\bar{X} - \frac{S t_{n-1,1-\alpha}}{\sqrt{n}}, +\infty\right)$$

è un intervallo di confidenza unilaterale superiore di livello $1 - \alpha$.

Intervallo unilaterale inferiore

Sappiamo che

$$\mathbb{P}(T \geq t) = 1 - \alpha \quad \text{se e solo se} \quad \mathbb{P}(T \leq t) = \alpha \quad \text{se e solo se} \quad t = t_{n-1, \alpha}.$$

Abbiamo dunque

$$1 - \alpha = \mathbb{P}\left(\frac{(\bar{X} - \mu)\sqrt{n}}{S} \geq t_{n-1, \alpha}\right) = \mathbb{P}\left(\bar{X} - \mu \geq \frac{S t_{n-1, \alpha}}{\sqrt{n}}\right) = \mathbb{P}\left(\mu \leq \bar{X} - \frac{S t_{n-1, \alpha}}{\sqrt{n}}\right).$$

Quindi la semiretta

$$\left(-\infty, \bar{X} - \frac{S t_{n-1, \alpha}}{\sqrt{n}}\right) = \left(-\infty, \bar{X} + \frac{S t_{n-1, 1-\alpha}}{\sqrt{n}}\right)$$

è un intervallo di confidenza unilaterale inferiore di livello $1 - \alpha$.

6.2. Stima per intervalli della varianza di campioni gaussiani

Intervallo bilaterale

Sia X_1, X_2, \dots, X_n un campione gaussiano di media μ (incognita o nota) e varianza σ^2 incognita.

Sappiamo che la v.a. $V := (n-1)\frac{S^2}{\sigma^2}$ segue la distribuzione χ^2 a $n-1$ gradi di libertà.

Per ogni $\alpha \in (0, 1)$ indico con $\chi_{n-1, \alpha}^2$ il quantile di livello α della v.a. V :

$$F_V(\chi_{n-1, \alpha}^2) = \alpha \quad \forall \alpha \in (0, 1).$$

Osservazione 6.2.1. $\chi_{n-1, \alpha}^2 > 0$ per ogni $\alpha \in (0, 1)$.

Calcolo $\mathbb{P}\left(\chi_{n-1, \frac{\alpha}{2}}^2 < V < \chi_{n-1, 1-\frac{\alpha}{2}}^2\right)$:

$$\begin{aligned} \mathbb{P}\left(\chi_{n-1, \frac{\alpha}{2}}^2 < V < \chi_{n-1, 1-\frac{\alpha}{2}}^2\right) &= \mathbb{P}\left(V < \chi_{n-1, 1-\frac{\alpha}{2}}^2\right) - \\ &\quad - \mathbb{P}\left(V < \chi_{n-1, \frac{\alpha}{2}}^2\right) = 1 - \frac{\alpha}{2} - \frac{\alpha}{2} = 1 - \alpha. \end{aligned}$$

Dunque

$$\begin{aligned} 1 - \alpha &= \mathbb{P}\left(\chi_{n-1, \frac{\alpha}{2}}^2 < (n-1)\frac{S^2}{\sigma^2} < \chi_{n-1, 1-\frac{\alpha}{2}}^2\right) \\ &= \mathbb{P}\left(\frac{1}{\chi_{n-1, 1-\frac{\alpha}{2}}^2} < \frac{\sigma^2}{(n-1)S^2} < \frac{1}{\chi_{n-1, \frac{\alpha}{2}}^2}\right) = \mathbb{P}\left(\frac{(n-1)S^2}{\chi_{n-1, 1-\frac{\alpha}{2}}^2} < \sigma^2 < \frac{(n-1)S^2}{\chi_{n-1, \frac{\alpha}{2}}^2}\right) \end{aligned}$$

Quindi l'intervallo

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

è un intervallo di confidenza di livello $1 - \alpha$ per la varianza σ^2 del campione.

Intervallo unilaterale superiore

Sappiamo che

$$\mathbb{P}(V \leq t) = 1 - \alpha \quad \text{se e solo se} \quad t = \chi_{n-1, 1-\alpha}^2.$$

Dunque

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

Quindi la semiretta

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

è un intervallo di confidenza di livello $1 - \alpha$ per la varianza σ^2 del campione.

Intervallo unilaterale inferiore

Sappiamo che

$$\mathbb{P}(V \geq t) = 1 - \alpha \quad \text{se e solo se} \quad \mathbb{P}(V \leq t) = \alpha \quad \text{se e solo se} \quad t = \chi_{n-1, \alpha}^2.$$

Dunque

$$1 - \alpha = \mathbb{P}\left((n-1)\frac{S^2}{\sigma^2} > \chi_{n-1, \alpha}^2\right) = \mathbb{P}\left(\sigma^2 \leq (n-1)\frac{S^2}{\chi_{n-1, \alpha}^2}\right).$$

Quindi l'intervallo

$$\left(0, \frac{(n-1)S^2}{\chi_{n-1, \alpha}^2}\right)$$

è un intervallo di confidenza di livello $1 - \alpha$ per la varianza σ^2 del campione.

Esempio 6.2.1. Calcoliamo gli intervalli di confidenza per il carattere CO2SBW dei dati tratti da [3], nell'ipotesi che si tratti della realizzazione di v.a. normali.

```
> setwd("/home/laura/Documents/didattica/2012-13_elaborazioni_B194")
> X <-
+ read.table("/home/laura/Documents/didattica/2012-13_elaborazioni_B194/
+ table2_noR5.csv",
+ header=TRUE, sep="\t", na.strings="NA", dec=".", strip.white=TRUE)
> X
  Totpor   PRA   PV Densi TenStr CO2SBW FirTemp
1  41.46 0.528 80.0  1.55  0.403   0.38    740
2  47.21 0.467 81.2  1.65  0.645   0.70    740
3  43.67 0.697 78.5  1.71  0.527   0.46    740
4  52.39 0.422 77.3  1.52  0.143   0.48    740
5  44.70 0.411 87.4  1.50  0.593   0.29    740
```

6	51.33	0.422	88.6	1.48	0.463	0.33	740
7	31.46	0.718	80.6	1.90	0.955	0.23	740
8	40.90	0.458	80.4	1.68	0.195	0.41	740
9	45.54	0.492	80.8	1.62	1.328	0.50	750
10	45.62	0.734	86.2	1.62	1.405	0.34	750
11	44.14	0.730	85.7	1.59	0.256	0.42	750
12	40.71	0.543	87.8	1.75	0.309	0.20	750
13	35.70	0.686	84.3	1.52	0.472	0.05	740
14	40.29	0.306	43.5	1.76	0.520	0.43	740
15	36.57	0.625	42.3	1.75	0.738	0.36	740
16	42.13	0.249	63.2	1.63	0.410	0.25	740
17	37.83	0.731	47.9	2.02	0.601	0.28	740
18	42.18	0.407	59.4	1.58	0.376	0.34	740
19	41.60	0.446	42.8	1.85	0.473	0.26	740
20	32.66	0.664	64.3	1.85	0.695	0.25	740
21	36.07	0.673	58.2	1.78	0.624	0.29	740
22	36.04	1.397	55.6	1.73	0.582	0.38	740
23	36.64	0.861	45.2	1.75	0.650	0.47	740
24	42.89	0.785	10.2	1.54	0.453	1.04	850
25	26.85	0.315	14.7	2.01	1.124	1.86	960
26	28.55	0.158	18.6	1.92	0.937	1.96	850
27	29.86	0.158	15.3	1.89	1.020	1.48	850
28	54.64	1.525	12.5	1.34	0.267	0.67	750
29	27.55	2.657	14.6	1.92	0.892	0.40	730
30	40.82	0.622	15.3	1.57	0.502	1.94	860

```
> numSummary(X[,c("CO2SBW", "Densi", "FirTemp", "PRA", "PV", "TenStr", "Totpor")],
statistics=c("mean", "sd", "quantiles"), quantiles=c(0,.25,.5,.75,1))
      mean      sd      0%      25%      50%      75%      100%  n
CO2SBW  0.5816667 0.5259152 0.050 0.29000 0.3900 0.49500 1.960 30
Densi   1.6993333 0.1691548 1.340 1.57250 1.6950 1.83250 2.020 30
FirTemp 763.6666667 53.4649955 730.000 740.00000 740.0000 750.00000 960.000 30
PRA     0.6629000 0.4806106 0.158 0.42200 0.5825 0.72700 2.657 30
PV      56.7466667 27.9061201 10.200 42.42500 61.3000 80.75000 88.600 30
TenStr  0.6186000 0.3153048 0.143 0.42075 0.5545 0.72725 1.405 30
Totpor  39.9333333 7.0795326 26.850 36.04750 40.8600 44.02250 54.640 30
```

```
> ## definisco la funzione che calcola l'intervallo bilaterale con varianza nota
```

```
> bilat.norm = function(x,sigma,conf) { n = length(x); xbar=mean(x);
+ alpha = 1 - conf;
+ zstar = qnorm(1-alpha/2);
+ SE = sigma/sqrt(n);
+ xbar + c(-zstar*SE,zstar*SE)
+ }
```

```
> bilat.norm(X[,c("CO2SBW")],1,.9) ## supponiamo deviazione standard = 1
[1] 0.2813589 0.8819745
```

```
> bilat.norm(X[,c("CO2SBW")],2,.9) ## supponiamo deviazione standard = 2
[1] -0.01894896  1.18228229

> bilat.norm(X[,c("CO2SBW")],1,.95) ## supponiamo deviazione standard = 1
[1] 0.2238278 0.9395055

> bilat.norm(X[,c("CO2SBW")],2,.95) ## supponiamo deviazione standard = 2
[1] -0.134011  1.297344

> ## definisco la funzione che calcola l'intervallo bilaterale con varianza ignota

> bilat.stud = function(x,conf) { n = length(x); m = n-1; xbar=mean(x);
+ alpha = 1 - conf;
+ zstar = qt(1-alpha/2, m, lower.tail=TRUE);
+ SE = sd(x)/sqrt(n);
+ xbar + c(-zstar*SE,zstar*SE)
+ }

> bilat.stud(X[,c("CO2SBW")],.9)
[1] 0.4185190 0.7448144

> bilat.stud(X[,c("CO2SBW")],.95)
[1] 0.3852867 0.7780466

> ## definisco la funzione che calcola l'intervallo bilaterale per la varianza

> bilat.chi = function(x,conf) { n = length(x); m = n-1;
+ alpha = 1 - conf;
+ zsup = qchisq(alpha/2, m, lower.tail=TRUE);
+ zinf = qchisq(1 - alpha/2, m, lower.tail=TRUE);
+ SE = sd(x)*sd(x)*m;
+ c(SE/zinf,SE/zsup)
+ }

> bilat.chi(X[,c("CO2SBW")],.9)
[1] 0.1884772 0.4529507

> bilat.chi(X[,c("CO2SBW")],.95)
[1] 0.175429 0.499843
```