


Intervallo di confidenza


Sezione di Epidemiologia e Statistica Medica,
Università di Verona



Dal momento che il campione viene estratto casualmente dalla popolazione, le conclusioni tratte da un campione possono essere errate.

L'inferenza statistica viene fatta "con umiltà":

- 1) si cerca di stimare la probabilità di commettere errori**
- 2) si cerca di limitare la probabilità di commettere errori**




INTERVALLO di CONFIDENZA

Lo scopo dell'inferenza statistica è la conoscenza dei **parametri** che caratterizzano una popolazione.

Per conoscere il parametro, però, dovremmo prendere in esame **tutte** le unità statistiche che costituiscono la popolazione; questo spesso è impossibile perché:


1. numerosità molto elevata
2. spesso la popolazione obiettivo è infinita



impossibile conoscere il **parametro**




Non potendo calcolare con esattezza il parametro, **ricorriamo ad una sua stima.**






La **statistica** (es \bar{x} , s) calcolata su un campione estratto dalla popolazione obiettivo è una **stima puntuale** del parametro della popolazione.

Questa stima puntuale del parametro non sarà mai identica al vero parametro della popolazione, ma sarà affetta da un **errore** per eccesso o per difetto.

In molte situazioni è preferibile **una stima intervallare** (cioè è preferibile indicare come stima del parametro un intervallo al posto di un *singolo punto* sull'asse dei valori) che esprima anche l'**errore associato alla stima** (precisione).





La **stima puntuale** fornisce un singolo valore. Tuttavia:

- 1) questo valore non coincide quasi mai con il valore vero (parametro) della popolazione;
- 2) campioni diversi forniscono stime puntuali diverse.

La **stima intervallare** fornisce un intervallo, che ha una predeterminata probabilità di contenere il valore vero della popolazione. Pertanto:

- 1) quest'intervallo ha una determinata probabilità (in genere, il 95%) di contenere il valore vero (parametro) della popolazione;
- 2) gli intervalli ottenuti da campioni diversi in genere si sovrappongono.

INTERVALLO di CONFIDENZA: DEFINIZIONE

Per intervallo di confidenza di un parametro Θ della popolazione, intendiamo un intervallo delimitato da due limiti L_{inf} (limite inferiore) ed L_{sup} (limite superiore) che abbia una definita probabilità $(1 - \alpha)$ di contenere il vero parametro della popolazione:

$$p(L_{\text{inf}} < \Theta < L_{\text{sup}}) = 1 - \alpha$$

dove:

$1 - \alpha$ = grado di confidenza


α = probabilità di errore

$$pr \left\{ \mu - 1.96 \frac{\sigma}{\sqrt{n}} \leq \bar{x} \leq \mu + 1.96 \frac{\sigma}{\sqrt{n}} \right\} = 0.95$$

e, riarrangiando le due disuguaglianze interne alla parentesi:

$$pr \left\{ \bar{x} - 1.96 \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{x} + 1.96 \frac{\sigma}{\sqrt{n}} \right\} = 0.95$$

INTERVALLO DI CONFIDENZA




L'intervallo di confidenza diminuisce se

1) diminuisce il **livello di confidenza** ($1-\alpha$)
(dal 99% al 95% al 90%)

2) aumenta la **numerosità** del campione
(da $n=4$ a $n=36$ a $n=100$)



3) diminuisce la **variabilità nella popolazione**
(da $\sigma=100$ a $\sigma=36$ a $\sigma=4$)



$$\bar{x} \pm z_{\alpha/2} \cdot ES(\bar{x})$$

la **probabilità d'errore** α determina il valore del coefficiente z:

| $1-\alpha$ | $\alpha/2$ | $z_{\alpha/2}$ |
|------------|------------|----------------|
| 0.90 | 0.05 | 1.64 |
| 0.95 | 0.025 | 1.96 |
| 0.99 | 0.005 | 2.58 |



151,1 - 158,9
147,2 - 162,8
139,3 - 170,7

RIASSUMENDO...

La **stima puntuale** fornisce un singolo valore. Tuttavia:

1. questo valore non coincide quasi mai con il valore vero (parametro) della popolazione;
2. campioni diversi forniscono stime puntuali diverse.

La **stima intervallare** fornisce un intervallo:

1. quest'intervallo ha una determinata probabilità (in genere, il 95%) di contenere il valore vero (parametro) della popolazione;
2. Il metodo generale per la costruzione dell'intervallo di confidenza al $(1-\alpha)$ è:

$$\bar{x} \pm z_{\alpha/2} \cdot ES(\bar{x})$$



Esempio: Calcolo dell'intervallo di confidenza della media di una popolazione

Problema: Qual è l'intervallo di confidenza al 95% della media del peso di una popolazione, se la media di un campione di 16 soggetti è pari a 75 Kg? Nella popolazione il peso è distribuito normalmente con deviazione standard pari a 12 Kg.

Dati: $x = 75$ Kg $\sigma = 12$ Kg $n = 16$ $1-\alpha = 95\%$ $z_{\alpha/2} = 1,96$

Formula da utilizzare: $I.C._{95\%} = x \pm z_{\alpha/2} \cdot \sigma / \sqrt{n} = x \pm z_{\alpha/2} \cdot E.S.$

I passo: calcolo l'errore standard

$E.S. = \sigma / \sqrt{n} = 12 / \sqrt{16} = 12 / 4 = 3$ Kg

II passo: calcolo l'intervallo di confidenza

$I.C._{95\%} = x \pm z_{\alpha/2} \cdot E.S. = 75 \pm 1,96 \cdot 3 =$

| | |
|---|----------|
| [| 80,88 Kg |
|] | 69,12 Kg |

L'intervallo che va da 69,12 Kg (limite inferiore) a 80,88 Kg (limite superiore) ha 95 probabilità su 100 di contenere la media vera della popolazione.

INTERVALLO di CONFIDENZA di una PROPORZIONE

Per $N > 30$:
$$p \sim N\left(\pi, \sqrt{\frac{\pi(1-\pi)}{n}}\right)$$

In analogia con quanto visto per la media, segue che:

π sarà stimato da p

E che:

$$p \pm z_{\alpha/2} \cdot \sqrt{\frac{p(1-p)}{n}}$$



E se non conosco σ , la deviazione standard della popolazione?

Posso usare S (dev. standard del campione) come stima di σ

Se la numerosità campionaria è sufficientemente grande ($n \geq 30$), S è una stima precisa di σ .

$$I.C. = \bar{x} \pm z_{\alpha/2} \cdot s / \sqrt{n}$$

Se la numerosità campionaria è piccola ($n < 30$)

1. non può essere applicato il teorema del limite centrale

2. S non è una buona stima di

σ

↓
?

Per poter fare inferenze sulla media nel caso di piccoli campioni è necessario **assumere** che la variabile in studio abbia una **distribuzione approssimativamente normale**.

Sotto tale assunzione si può utilizzare la **distribuzione t di Student** con $v=(n-1)$ gradi di libertà

Nel caso di piccoli campioni l'intervallo di confidenza della media diventa quindi:

$$\bar{x} \pm t_{\alpha/2} \cdot \frac{s}{\sqrt{n}}$$







Tavola dei valori della funzione t di Student in funzione dei gradi di libertà e della probabilità in una coda della distribuzione (.100, .050, .025, .010, .005)

| DEGREES OF FREEDOM | t _{.100} | t _{.050} | t _{.025} | t _{.010} | t _{.005} |
|--------------------|-------------------|-------------------|-------------------|-------------------|-------------------|
| 1 | 3.078 | 6.314 | 12.706 | 31.821 | 63.657 |
| 2 | 1.886 | 2.920 | 4.303 | 6.965 | 9.925 |
| 3 | 1.638 | 2.353 | 3.182 | 4.541 | 5.841 |
| 4 | 1.533 | 2.132 | 2.776 | 3.747 | 4.604 |
| 5 | 1.476 | 2.015 | 2.571 | 3.365 | 4.032 |
| 6 | 1.440 | 1.943 | 2.447 | 3.143 | 3.707 |
| 7 | 1.415 | 1.895 | 2.365 | 2.998 | 3.499 |
| 8 | 1.397 | 1.860 | 2.306 | 2.896 | 3.355 |
| 9 | 1.383 | 1.833 | 2.262 | 2.821 | 3.250 |
| 10 | 1.372 | 1.812 | 2.228 | 2.764 | 3.169 |
| 11 | 1.363 | 1.796 | 2.201 | 2.718 | 3.106 |
| 12 | 1.356 | 1.782 | 2.179 | 2.681 | 3.055 |
| 13 | 1.350 | 1.771 | 2.160 | 2.650 | 3.012 |
| 14 | 1.345 | 1.761 | 2.145 | 2.624 | 2.977 |
| 15 | 1.341 | 1.753 | 2.131 | 2.602 | 2.947 |



Riassumendo:

$$z = \frac{x - \mu}{\sigma} \quad z = \frac{\bar{x} - \mu}{\sigma / \sqrt{n}} \quad t = \frac{\bar{x} - \mu}{s / \sqrt{n}}$$

σ nota $\Rightarrow \bar{x} \pm z_{\alpha/2} * \sigma / \sqrt{n}$

σ ignota $n \geq 30 \Rightarrow \bar{x} \pm z_{\alpha/2} * s / \sqrt{n}$

σ ignota $n < 30 \Rightarrow \bar{x} \pm t_{\alpha/2, v} * s / \sqrt{n}$

Esempio: Calcolo dell'intervallo di confidenza della media di una popolazione

Problema: Qual è l'intervallo di confidenza al 95% della media del peso di una popolazione, se in un campione di 100 soggetti la media (\bar{x}) è pari a 75 Kg e la deviazione standard (s) è pari a 12 Kg.

Dati: $\bar{x} = 75$ Kg $s = 12$ Kg $n = 100$

Il livello di confidenza è pari al 95%. Pertanto la probabilità di errore ($\alpha = \text{alfa}$) è $100\% - 95\% = 5\%$.

Formula da utilizzare:

Poiché la numerosità campionaria è maggiore di 30, posso usare la distribuzione z. Essendo il livello di confidenza del 95%, $z=1,96$

Pertanto posso utilizzare la seguente formula: $I.C._{.95\%} = \bar{x} \pm 1,96 \cdot s / \sqrt{n}$

I passo: calcolo l'errore standard (= la deviazione standard della media campionaria)

E.S. (Errore Standard) = $s / \sqrt{n} = 12 / \sqrt{100} = 12 / 10 = 1,2$ Kg

II passo: calcolo l'intervallo di confidenza

$75 + 1,96 * 1,2 = 77,35$ Kg

$I.C._{.95\%} = \bar{x} \pm 1,96 \cdot E.S. = 75 \pm 1,96 * 1,2 =$

$75 - 1,96 * 1,2 = 72,65$ Kg

L'intervallo che va da 72,65 Kg (limite inferiore) a 77,35 Kg (limite superiore) ha 95 probabilità su 100 di contenere la media vera della popolazione.

Esempio: Calcolo dell'intervallo di confidenza della media di una popolazione

Problema: Qual è l'intervallo di confidenza al 95% della media del peso di una popolazione, se la media di un campione di 16 soggetti è pari a 75 Kg e la deviazione standard è pari a 12 Kg?

Dati: $\bar{x} = 75 \text{ Kg}$ $s = 12 \text{ Kg}$ $n = 16$ $1-\alpha = 95\%$ $t_{15, \alpha/2} = 2,131$

Formula da utilizzare: $I.C._{95\%} = \bar{x} \pm t_{\alpha/2} \cdot \sigma/\sqrt{n} = \bar{x} \pm t_{\alpha/2} \cdot E.S.$

I passo: calcolo l'errore standard

$$E.S. = s/\sqrt{n} = 12/\sqrt{16} = 12/4 = 3 \text{ Kg}$$

II passo: calcolo l'intervallo di confidenza

$$I.C._{95\%} = \bar{x} \pm t_{15, \alpha/2} \cdot E.S. = 75 \pm 2,131 \cdot 3 = \begin{cases} 81,39 \text{ Kg} \\ 68,61 \text{ Kg} \end{cases}$$

L'intervallo che va da 68,61 Kg (limite inferiore) a 81,39 Kg (limite superiore) ha 95 probabilità su 100 di contenere la media vera della popolazione.
