

Lezione 2

La statistica inferenziale: concetti di base

Argomenti della lezione:

- ➔ **Campionamento**
- ➔ **Stima**
- ➔ **Distribuzione campionaria**

Popolazione (o universo)

Insieme di tutti gli elementi
cui si rivolge il ricercatore
nell'indagine

Campione

Sottoinsieme degli elementi
dell'insieme oggetto
dell'indagine

- 📄 **Campione rappresentativo**
- 📄 **Campione casuale**

Campionamento casuale semplice

➔ Estrarre a caso da una
popolazione

➔ Tutti gli elementi della
popolazione hanno la stessa
probabilità di essere estratti

Campionamento casuale stratificato

Suddivisione della popolazione
in sub-popolazioni omogenee.
Estrazione casuale dalle
sub-popolazioni

Parametri e indicatori

Caratteristica studiata riferita:

alla popolazione \Rightarrow parametro
 al campione \Rightarrow indicatore

Stima dei parametri

Conoscere parametri della popolazione tramite dati del campione

- ☞ **Stima puntuale o del valore**
- ☞ **Stima intervallare o dell'intervallo**

Stimatore o statistica

- ☞ **Metodo di calcolo impiegato per ottenere una stima**
- ☞ **La media campionaria $\sum X_i/n$ è uno stimatore della media μ della popolazione**
- ☞ **Funzione dei valori osservati**

Proprietà degli stimatori

Correttezza

$$E(t) = \theta$$

Consistenza

$$\lim_{n \rightarrow \infty} E(t) = \theta \quad \lim_{n \rightarrow \infty} \text{VAR}(t) = 0$$

Efficienza

Varianza campionaria minima

Distribuzione campionaria

- ☞ **Estrazione da una popolazione di N elementi, di tutti i possibili campioni di $n < N$ elementi**
- ☞ **Calcolo dell'indicatore (per es. \bar{x}) in ogni campione**
- ☞ **Distribuzione di frequenza degli indicatori**

Distribuzione campionaria della media

Popolazione: 5 7 9

Parametri:


$\mu = 7, \sigma^2 = 2.66, \sigma = 1.63$
 $N = 3, n = 2$

Campioni di ampiezza n = 2

Campioni	5-5	5-7	5-9	7-5	7-7	7-9	9-5	9-7	9-9
Medie	5	6	7	6	7	8	7	8	9

Distr. Campionaria della media

\bar{x}	5	6	7	8	9
Frequenza	1	2	3	2	1



$$\mu_{\bar{x}} = 7 \Rightarrow \mu_{\bar{x}} = \mu$$

$$\sigma_{\bar{x}}^2 = 1.33 \Rightarrow \sigma_{\bar{x}}^2 = \frac{\sigma^2}{n} ; \sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$$

Numerosità del campione (n)

Influenza la forma; la precisione della media; l'efficienza della stima

Al crescere di n (n>30):

Forma \Rightarrow Normale

Media \Rightarrow Media della popolazione

Errore standard \Rightarrow Minimo

Spesso la varianza della popolazione (σ^2) non è nota

La varianza della DCM può essere stimata dai dati del campione nel modo seguente:

$$\hat{\sigma}_{\bar{x}}^2 = \frac{s^2}{n-1} \quad \hat{\sigma}_{\bar{x}} = \frac{s}{\sqrt{(n-1)}}$$

Uso della distribuzione campionaria della media (DCM)

Campione: n, \bar{x} , s^2
Media μ della popolazione ?

$$\mu_{\bar{x}} = \mu$$

"quale sarà $\mu_{\bar{x}}$?"

Intervallo di confidenza nel quale ricade μ con una probabilità elevata (es., $p=.95$)

$$P(\bar{X} - c \leq \mu \leq \bar{X} + c) = .95$$

Utilizzare le proprietà della DCM per definire l'intervallo

Proprietà della DCM:

Forma normale (per $n>30$)

Media = media della popolazione

$$(\mu_{\bar{x}} = \mu)$$

Errore standard:

$$\sigma_{\bar{x}} = \sigma/\sqrt{n}$$

$$\hat{\sigma}_{\bar{x}} = s/\sqrt{(n-1)}$$

$$z_{\bar{x}} = (\bar{X} - \mu_{\bar{x}})/\sigma_{\bar{x}}$$

**Poiché la DCM è normale:
 $P(-1.96 \leq z_{\bar{x}} \leq 1.96) = .95$**

ovvero

$$P(-1.96 \leq (\bar{X} - \mu_{\bar{x}})/\sigma_{\bar{x}} \leq 1.96) = .95$$

Tramite alcuni passaggi algebrici:

$$P(-1.96\sigma_{\bar{x}} \leq \bar{X} - \mu_{\bar{x}} \leq 1.96\sigma_{\bar{x}}) = .95$$

$$P(-\bar{X} - 1.96\sigma_{\bar{x}} \leq -\mu_{\bar{x}} \leq -\bar{X} + 1.96\sigma_{\bar{x}}) = .95$$

$$P(\bar{X} + 1.96\sigma_{\bar{x}} \geq \mu_{\bar{x}} \geq \bar{X} - 1.96\sigma_{\bar{x}}) = .95$$

$$P(\bar{X} - 1.96\sigma_{\bar{x}} \leq \mu_{\bar{x}} \leq \bar{X} + 1.96\sigma_{\bar{x}}) = .95$$

Formula generale per il calcolo dell'intervallo di confidenza

$$\bar{X} - z_{\text{area}} \sigma_{\bar{x}} \leq \mu_{\bar{x}} \leq \bar{X} + z_{\text{area}} \sigma_{\bar{x}}$$

Esempio

Campione:

$$\bar{x} = 19, s = 1.8, n = 50$$

$p = .95$

$$\bar{X} - 1.96\sigma_{\bar{x}} \leq \mu_{\bar{x}} \leq \bar{X} + 1.96\sigma_{\bar{x}}$$

Stima dell'errore standard tramite il campione

$$\hat{\sigma}_{\bar{x}} = s/\sqrt{(n-1)}$$

Intervallo di fiducia al 95%:

$$\bar{X} - 1.96 \frac{s}{\sqrt{(n-1)}} \leq \mu_x \leq \bar{X} + 1.96 \frac{s}{\sqrt{(n-1)}}$$

Limite inferiore:

$$19 - 1.96 \left(\frac{1.8}{\sqrt{50-1}} \right) = 18.49$$

Limite superiore:

$$19 + 1.96 \left(\frac{1.8}{\sqrt{50-1}} \right) = 19.51$$

$$P(18.49 \leq \mu_{\bar{x}} \leq 19.51) = .95$$

Intervallo di fiducia al 99%:

$$\bar{X} - 2.58\sigma_{\bar{x}} \leq \mu_{\bar{x}} \leq \bar{X} + 2.58\sigma_{\bar{x}}$$

$$P(18.33 \leq \mu_{\bar{x}} \leq 19.67) = .99$$

Campioni piccoli ($n \leq 30$)

Se $n \leq 30$, la DCM non si approssima alla normale

Al posto di z si utilizza la t di Student per $n-1$ gradi di libertà

$$\bar{X} - t_{\text{area}} \sigma_{\bar{x}} \leq \mu_{\bar{x}} \leq \bar{X} + t_{\text{area}} \sigma_{\bar{x}}$$

Campione:

$$n=30, \bar{X} = 4.03, s=1.58$$

Intervallo di fiducia al 95%

La t di Student corrispondente alla probabilità .05 con $(n-1) = 29$ gdl è: 2.045

$$\sigma_{\bar{x}} = 1.58/\sqrt{30-1} = .29$$

$$\text{Lim. Inf} = 4.03 - 2.045 * .29 = 3.43$$

$$\text{Lim. Sup} = 4.03 + 2.045 * .29 = 4.63$$

$$3.43 \leq \mu \leq 4.63$$

Intervallo di fiducia al 99%

La *t* di Student corrispondente
alla probabilità .01
con $(n-1) = 29$ gdl è: 2.756

$$\sigma_{\bar{x}} = 1.58 / \sqrt{30-1} = .29$$

$$\text{Lim. Inf} = 4.03 - 2.756 * .29 = 3.22$$

$$\text{Lim. Sup} = 4.03 + 2.756 * .29 = 4.84$$

$$3.22 \leq \mu \leq 4.84$$

Gradi di libertà

Siano *N* osservazioni
indipendenti, libere di assumere
qualsiasi valore

$$x_1 \ x_2 \ x_3 \ \dots \ x_i \ \dots \ x_N$$

i gradi di libertà (gdl) sono = *N*

Se si impongono vincoli i gdl
sono *N* meno il numero di vincoli

Sia *N* = 3, ovvero $x_1 \ x_2 \ x_3$
e $(x_1 + x_2 + x_3) = 10$

due degli *x* possono assumere
qualsiasi valore, il terzo è
vincolato a riportare la somma
a 10

I gdl sono 2

$$7 + 2 + (1) = 10$$

$$100 - 99 + (9) = 10$$

$$-50 + 50 + (10) = 10$$

gdl = numero di elementi liberi
di variare - numero di vincoli

$$N - 1 = 3 - 1 = 2$$

GDL: numero di valori indipendenti
che generano una distribuzione

CONCLUSIONE

- Concetti fondamentali per la statistica inferenziale
- Distribuzione Campionaria
- Intervallo di confidenza
- Gradi di libertà