

Pavia, 9 aprile 2003

**Brevissime note di Statistica inferenziale**

*A cura di Luca La Rocca*

## Campione casuale estratto da una popolazione normale

Si assume che le osservazioni  $x_1, \dots, x_n$  siano realizzazioni delle variabili aleatorie  $X_1, \dots, X_n$  indipendenti e identicamente distribuite secondo la curva normale:

$$\mathbf{P}\{a \leq X_1 \leq b\} = \int_a^b \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx.$$

Parametri di popolazione:  $\mu = \mathbf{E}[X_1]$  e  $\sigma^2 = \mathbf{V}[X_1] > 0$ .

Taglia del campione:  $n \rightarrow \infty$ .


## Stima puntuale dei parametri di una popolazione normale

$$\bar{X} = \frac{X_1 + \cdots + X_n}{n}$$
$$\mathbf{E}[\bar{X}] = \mu \quad \& \quad \mathbf{V}[\bar{X}] = \frac{\sigma^2}{n} \rightarrow 0$$

$$s_{\bar{X}}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$
$$\mathbf{E}[s_{\bar{X}}^2] = \sigma^2 \quad \& \quad \mathbf{V}[s_{\bar{X}}^2] = \frac{2\sigma^4}{n-1} \rightarrow 0$$

## Distribuzione della media campionaria

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



$$\mathbf{P} \{-z_\alpha \leq Z \leq +z_\alpha\} = 1 - \alpha$$

## Intervalli di confidenza per la media di una normale

Se  $\sigma^2$  è nota, allora

$$\mathbf{P} \left\{ \bar{X} - z_\alpha \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_\alpha \frac{\sigma}{\sqrt{n}} \right\} = 1 - \alpha$$

altrimenti si considera

$$T = \frac{\sqrt{n}(\bar{X} - \mu)}{s_X} \sim \mathcal{T}(n - 1)$$


e si trova

$$\mathbf{P} \left\{ \bar{X} - t_{\alpha, n-1} \frac{s_X}{\sqrt{n}} \leq \mu \leq \bar{X} + t_{\alpha, n-1} \frac{s_X}{\sqrt{n}} \right\} = 1 - \alpha$$

che converge al precedente per  $n \rightarrow \infty$ .

## Distribuzione della varianza campionaria

$$C = ns_X^2/\sigma^2 \sim \chi_{n-1}^2$$



$$\mathbf{P}\{C > c_\alpha\} = 1 - \alpha$$

## Intervallo di confidenza per la varianza di una normale

Supponendo senz'altro che  $\mu$  non sia nota, allora

$$\mathbf{P} \left\{ \frac{(n-1)s_X^2}{c_{1-\alpha/2}} \leq \sigma^2 \leq \frac{(n-1)s_X^2}{c_{\alpha/2}} \right\} = 1 - \alpha$$

ovvero

$$\mathbf{P} \left\{ \sqrt{\frac{(n-1)s_X^2}{c_{1-\alpha/2}}} \leq \sigma \leq \sqrt{\frac{(n-1)s_X^2}{c_{\alpha/2}}} \right\} = 1 - \alpha$$

per la deviazione standard.

## Verifica dell'ipotesi di nullità della media

Il campione fornisce sufficiente evidenza statistica contro l'ipotesi che la media della popolazione sia nulla?

$$H_0 : \mu = 0$$

Non si può rispondere affermativamente se lo zero appartiene all'intervallo di confidenza per la media!

$$\bar{X} - t_{\alpha, n-1} \frac{s_X}{\sqrt{n}} \leq 0 \leq \bar{X} + t_{\alpha, n-1} \frac{s_X}{\sqrt{n}}$$



## Significatività e potenza della verifica

La significatività  $\alpha$  è la probabilità di rifiutare  $H_0$  se essa è vera:

$$\alpha = \mathbf{P}_0 \left\{ \frac{\sqrt{n}|\bar{X}|}{s_X} > t_{\alpha, n-1} \right\}$$

La potenza  $\beta$  è la probabilità di rifiutare  $H_0$  se essa è falsa:

$$\beta(\mu) = \mathbf{P}_\mu \left\{ \frac{\sqrt{n}|\bar{X}|}{s_X} > t_{\alpha, n-1} \right\}$$

Si noti come la potenza dipenda dall'effettivo valore di  $\mu \neq 0$ .

## Il cosiddetto “p-value”

Se si è osservato il valore

$$t = \frac{\sqrt{n}|\bar{x}|}{s_x}$$

per la statistica test

$$T = \frac{\sqrt{n}|\bar{X}|}{s_X}$$

il “p-value” del campione

$$p = \mathbf{P}_0 \left\{ \frac{\sqrt{n}|\bar{X}|}{s_X} > \frac{\sqrt{n}|\bar{x}|}{s_x} \right\}$$

è più piccolo valore di  $\alpha$  per cui  $H_0$  viene rifiutata.

## È un dado onesto?

Si considerano i conteggi relativi a  $n$  lanci di un dado:  $N_k, k = 1 \dots 6$ .

Il dado è descritto dalle probabilità di faccia:  $\pi_k, k = 1 \dots 6$ .

L'ipotesi nulla è che il dado sia onesto, cioè  $H_0 : \pi_1 = \dots = \pi_6$ .

Si rifiuta  $H_0$  quando la statistica test

$$C = \sum_{k=1}^6 \frac{(N_k - n/6)^2}{n/6} \sim > \chi_5^2, \quad n \rightarrow \infty$$

è “grande” rispetto al livello di significatività prescelto.

## Sono indipendenti?

Si considerano i conteggi congiunti  $N_{ij}$ ,  $i = 1 \dots I$ ,  $j = 1 \dots J$ , relativi a due variabili nominali aventi rispettivamente  $I$  e  $J$  livelli.

Il modello statistico è descritto dalle probabilità congiunte  $\pi_{ij}$ .

L'ipotesi nulla è che le variabili siano indipendenti, cioè  $H_0 : \pi_{ij} = \pi_i \pi_j$ .

Si rifiuta  $H_0$  quando la statistica test

$$C = \sum_{i=1}^I \sum_{j=1}^J \frac{(N_{ij} - N_i N_j / N)^2}{N_i N_j / N} \sim > \chi_{(I-1)(J-1)}^2, \quad N \rightarrow \infty$$

è “grande” rispetto al livello di significatività prescelto.

Queste note sono state composte in  $\text{\LaTeX}$ , consultando il libro **Keeping (1962), “Introduction to Statistical Inference”, Dover** e impiegando il linguaggio  $R$  per la realizzazione dei grafici.