

CAMPIONAMENTO

Gli statistici si basano sulle leggi fondamentali della probabilità e dell'inferenza statistica, per giungere a conclusioni sui sistemi scientifici studiati.

L'obiettivo è generalizzare l'esperimento singolo alla classe di tutti gli esperimenti simili, operando un'estensione dal particolare al generale, detta **INFERENZA INDUTTIVA**.

L'inferenza induttiva è perciò un processo d'azzardo: non si possono fare generalizzazioni assolutamente certe, si possono fare inferenze incerte e misurare il grado di incertezza in termini di probabilità.

DEFINIZIONE: La totalità delle osservazioni a cui siamo interessati è detta **POPOLAZIONE OBIETTIVO**.

(il numero delle osservazioni può essere finito o infinito).

Essendo poco pratico esaminare l'intera popolazione, si può esaminare una sua parte e fare inferenze sulla popolazione obiettivo.

DEFINIZIONE: Un sottoinsieme della popolazione è detto **CAMPIONE**.

Perché il campione sia rappresentativo della popolazione è necessario che il campionamento sia casuale.

Nel **campionamento casuale semplice** ogni campione di una determinata dimensione ha la stessa probabilità di essere selezionato di qualsiasi altro campione della stessa dimensione.
(campionamenti indipendenti).

Supponiamo che la popolazione sia caratterizzata da una certa funzione di densità $f(x)$. Scegliendo un c.c. di dim = n dalla popolazione $f(x)$, definiamo le variabili casuali X_i , $i=1, \dots, n$ per rappresentare la i -esima misura del campione che si osserva.

X_1, \dots, X_n sono un c.c. semplice ottenuto da $f(x)$ se le misure sono state ottenute ripetendo l'esperimento n volte in modo indipendente e alle stesse condizioni.

$\Rightarrow X_1, \dots, X_n$ sono n v.c. indipendenti con la stessa densità di probabilità $f(x)$.

DEFINIZIONE: Sono X_1, \dots, X_n n v.c. indipendenti con funzione di densità $f(x)$. X_1, \dots, X_n è detto **CAMPIONE CASUALE** di dimensione n se

$$f_{X_1, \dots, X_n}(x_1, \dots, x_n) = f(x_1) \cdots f(x_n)$$

(f . di densità congiunta = prodotto f . di densità marginali)

DEFINIZIONE: Il campione casuale è detto **POPOLAZIONE CAMPIONATA**.

La distribuzione congiunta

$$f_{X_1, \dots, X_n}(x_1, \dots, x_n) = f(x_1) \cdots f(x_n)$$

è detto **DISTRIBUZIONE CAMPIONARIA** di X_1, \dots, X_n .

Lo scopo principale nel selezionare campioni casuali è quello di ottenere informazioni riguardo alcuni parametri sconosciuti della popolazione obiettivo.

Cioè è nota la forma di $f(\cdot, \theta)$, ma f contiene un parametro incognito θ .

Procedimento: si estrae un c.c. X_1, \dots, X_n di dim = n dalla densità $f(\cdot, \theta)$ e si stima il parametro incognito θ con il valore di una qualche funzione $t(x_1, \dots, x_n)$. Infine si determina quale tra queste funzioni sia la migliore per stimare il parametro θ .

DEFINIZIONE: una funzione t delle variabili casuali X_1, \dots, X_n che costituiscono il campione casuale è detta **STATISTICA**.

La statistica $t(x_1, \dots, x_n)$ è a sua volta una variabile casuale che **NON** contiene alcun parametro incognito

Esempi di statistiche utilizzate per misurare il centro di una serie di dati sono la media, la mediana e la moda:

Dato un c.c. di dim = n : X_1, \dots, X_n

a) **MEDIA CAMPIONARIA**

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

b) **MEDIANA CAMPIONARIA**

$$\tilde{X} = \begin{cases} X_{(\frac{n+1}{2})} & \text{se } n \text{ è dispari} \\ \frac{1}{2} \left(X_{\frac{n}{2}} + X_{\frac{n}{2}+1} \right) & \text{se } n \text{ è pari} \end{cases}$$

c) **MODA CAMPIONARIA**

È il valore del campione che si presenta più frequentemente.

Altre importanti statistiche sono:

DEFINIZIONE: Dato X_1, \dots, X_m c.c. di dim $= n$ estratto da una popolazione con densità $f(\cdot)$ si definisce

MOMENTO CAMPIONARIO DI ORDINE r (ASSOLUTO) la quantità:

$$M'_{rc} = \frac{1}{m} \sum_{i=1}^m X_i^r$$

OSSERVAZIONE

Se $r=1$ $M'_1 \equiv \bar{X}_m$.

DEFINIZIONE: Dato X_1, \dots, X_m c.c. di dim $= n$ estratto da una popolazione con densità $f(\cdot)$ si definisce

MOMENTO CAMPIONARIO DI ORDINE r RISPETTO A \bar{X}_m la quantità:

$$M_{rc} = \frac{1}{m} \sum_{i=1}^m (X_i - \bar{X}_m)^r$$

I.B.: se $r=1$ $M_1 \equiv 0$.

OSSERVAZIONE

I momenti campionari assoluti replicano i momenti della popolazione, cioè vale il seguente

TEOREMA 1: Dato X_1, \dots, X_m c.c. di dim $= n$ estratto da una popolazione con densità $f(\cdot)$ si ha:

$$E[M'_{rc}] = \mu'_{rc}$$

dove μ'_{rc} sono i momenti di ordine r della popolazione.

Dim:

$$\begin{aligned} E[M'_{rc}] &= E\left[\frac{1}{m} \sum_{i=1}^m X_i^r\right] = \frac{1}{m} E\left[\sum_{i=1}^m X_i^r\right] = \frac{1}{m} \sum_{i=1}^m E[X_i^r] \\ &= \frac{1}{m} \sum_{i=1}^m \mu'_{rc} = \frac{1}{m} \cdot n \mu'_{rc} = \mu'_{rc} \end{aligned}$$

perché X_i ha f. di densità f , $i=1, \dots, n$.

TEOREMA 1 bis : Dato X_1, \dots, X_m c.c. di dim $m = n$ estratto da una popolazione cui deviato' $f(\cdot)$ si ha:

$$\text{var} [M'_{1r}] = \frac{1}{m} [\mu'_{2r} - (\mu'_{1r})^2]$$

Dim :

$$\text{var} [M'_{1r}] = \text{var} \left[\frac{1}{m} \sum_{i=1}^m X_i^{1r} \right] = \left(\frac{1}{m} \right)^2 \text{var} \left[\sum_{i=1}^m X_i^{1r} \right]$$

$$\stackrel{(\circ)}{=} \frac{1}{m^2} \sum_{i=1}^m \text{var} [X_i^{1r}] \stackrel{(\circ)}{=} \dots$$

perche' X_i sono v.c. indipendenti

In generale se W è una v.c.

$$\text{var} [W] = E[W^2] - (E[W])^2$$

$$\stackrel{(\circ)}{=} \frac{1}{m^2} \sum_{i=1}^m \left\{ E[X_i^{2r}] - (E[X_i^{1r}])^2 \right\}$$

$$= \frac{1}{m^2} \left\{ m E[X^{2r}] - m (E[X^{1r}])^2 \right\}$$

↑ perche' X_i hanno tutte la stessa funzione di deviato' f .

$$= \frac{1}{m} [\mu'_{2r} - (\mu'_{1r})^2]$$

OSSERVAZIONE

$$\text{Se } r=1 \quad E[M'_{11}] = E[\bar{X}_m] = \mu'_1 = \mu$$

dove μ è la media della popolazione

$$\text{var} [M'_{11}] = \text{var} [\bar{X}_m] = \frac{1}{m} [\mu'_2 - (\mu'_1)^2] = \frac{\sigma^2}{m}$$

dove $\sigma^2 = \mu'_2 - (\mu'_1)^2$ è la varianza della popolazione.

$$E[\bar{X}_m] = \mu \quad \text{var} [\bar{X}_m] = \frac{\sigma^2}{m}$$

Una misura di posizione o tendenza centrale, in un campione non fornisce da sola una chiara indicazione sulla natura del campione. Deve essere sempre considerata anche una misura di variabilità del campione. Riguardo al momento campionario di ordine r rispetto alla media campionaria si ha

$$\text{se } r=2 \quad M_2 = \frac{1}{n} \sum_{i=1}^m (X_i - \bar{X}_m)^2$$

Anziché utilizzare M_2 si preferisce usare:

DEFINIZIONE: Dato X_1, \dots, X_m c.c. di dim = n estratto da una popolazione con densità $f(\cdot)$ si definisce

VARIANZA CAMPIONARIA la quantità

$$S^2 = \frac{1}{m-1} \sum_{i=1}^m (X_i - \bar{X}_m)^2$$

N.B.: se m è molto grande, non c'è differenza ^{tra} S^2 e M_2 .

OSSERVAZIONE: si usa S^2 anziché M_2 come misura della variabilità del campione poiché vale il seguente

TEOREMA 2: Dato X_1, \dots, X_m c.c. di dim = n estratto da una popolazione con funzione di densità $f(\cdot)$

si ha:

$$E[S^2] = \sigma^2$$

dove σ^2 è la varianza della popolazione.

Dim: (facoltativa).

Dimostrazione del TEOREMA 2.

$$\begin{aligned}\sum_{i=1}^m (X_i - \bar{X}_m)^2 &= \sum_{i=1}^m (X_i^2 - 2X_i \bar{X}_m + \bar{X}_m^2) = \sum_{i=1}^m X_i^2 - 2\bar{X}_m \underbrace{\sum_{i=1}^m X_i}_{m\bar{X}_m} + n\bar{X}_m^2 \\ &= \sum_{i=1}^m X_i^2 - m\bar{X}_m^2\end{aligned}$$

Perciò

$$S^2 = \frac{1}{m-1} \sum_{i=1}^m (X_i - \bar{X}_m)^2 = \frac{1}{m-1} \left[\sum_{i=1}^m X_i^2 - m\bar{X}_m^2 \right]$$

Passando al valore atteso

$$\begin{aligned}(m-1)E[S^2] &= E \left\{ \sum_{i=1}^m X_i^2 - m\bar{X}_m^2 \right\} = E \left[\sum_{i=1}^m X_i^2 \right] - mE[\bar{X}_m^2] \\ &= \sum_{i=1}^m E[X_i^2] - mE[\bar{X}_m^2] \stackrel{(*)}{=}\end{aligned}$$

Dalla definizione di varianza.

$$\forall \text{ v.c. } W. \text{ var}[W] = E[W^2] - (E[W])^2$$

si ha

$$E[W^2] = \text{var}[W] + (E[W])^2$$

$$\stackrel{(*)}{=} \sum_{i=1}^m \left\{ \text{var}[X_i] + (E[X_i])^2 \right\} - m \left\{ \text{var}[\bar{X}_m] + (E[\bar{X}_m])^2 \right\}$$

$$= m \text{var}[X] + m(E[X])^2 - m \left\{ \frac{\sigma^2}{m} + \mu^2 \right\}$$

↑ perché le X_i hanno la stessa funzione di densità

$$= m\sigma^2 + m\mu^2 - m \cdot \frac{\sigma^2}{m} - m\mu^2 = (m-1)\sigma^2$$

$$\Rightarrow E[S^2] = \sigma^2.$$

Dalle definizioni di M_2 e di S^2 si ha:

$$S^2 = \frac{m}{m-1} M_2.$$

Infatti

$$S^2 = \frac{1}{m-1} \sum_{i=1}^m (X_i - \bar{X}_m)^2 = \frac{m}{m-1} \left[\frac{1}{m} \sum_{i=1}^m (X_i - \bar{X}_m)^2 \right] = \frac{m}{m-1} M_2$$

$$M_2 = \frac{m-1}{m} S^2$$

Allora

$$E[M_2] = \frac{(m-1)}{m} E[S^2] = \frac{(m-1)}{m} \sigma^2 \neq \sigma^2$$

questo è il motivo per cui si usa la varianza campionaria al posto del momento di ordine 2 rispetto alle medie campionarie come statistica per stimare la varianza della popolazione σ^2 .

Riassumendo

M'_r stima μ'_r ; \bar{X}_m stima μ ; S^2 stima σ^2

OSSERVAZIONE

Il teorema 1 per $r=1$ ci dice che la media campionaria \bar{X}_m in media è uguale al parametro μ della popolazione ($E[\bar{X}_m] = \mu$), cioè la distribuzione di \bar{X}_m è CENTRATA attorno a μ .

Ma se $\text{var}[\bar{X}_m] = \frac{\sigma^2}{m}$ prova che la dispersione

dei valori di \bar{X}_m intorno a μ è piccola se m , e l'ampiezza del campione, è grande.

LEGGE DEI GRANDI NUMERI IN FORMA DEBOLE

La legge debole dei grandi numeri, che si dimostra usando la disuguaglianza di Chebychev, afferma che si possono fare inferenze attendibili per la media μ di una popolazione attraverso un numero finito di valori (campioni casuali di dim = n) di X .

È possibile determinare un intero positivo n tale che, se si prende un c.c. di dimensione $\geq n$ da una popolazione di densità $f(\cdot)$ con media μ , la probabilità che la differenza tra la media campionaria \bar{X}_n e la media μ della popolazione sia minore di una quantità fissata piccola a piacere, è vicina ad 1 quanto si vuole.

In formule:

$$\forall \varepsilon > 0 \text{ e } \forall \delta < 1 \quad \exists n > \frac{\sigma^2}{\varepsilon^2 \delta} :$$

$$P[|\bar{X}_n - \mu| < \varepsilon] \geq 1 - \delta$$

con μ e σ^2 rispettivamente media e varianza della densità $f(\cdot)$ della popolazione.

Dim:

Ricordiamo la disuguaglianza di Markov

$$P[g(x) \geq x] \leq \frac{E[g(x)]}{x}$$

$$\forall x > 0 \text{ e } g(x) \geq 0, \forall x \in \mathbb{R}.$$

Formulazione analoga:

$$P[g(x) < \kappa] \geq 1 - \frac{E[g(x)]}{\kappa}$$

sceita $g(x) = (\bar{x}_m - \mu)^2$

scelto $\kappa = \epsilon^2$

$$P[|\bar{X}_m - \mu| < \epsilon] = P[(\bar{X}_m - \mu)^2 < \epsilon^2] \\ \geq 1 - \frac{E[(\bar{X}_m - \mu)^2]}{\epsilon^2} =$$

dalla definizione di varianza cioè:

$$X \text{ v.c. } \text{var}[X] = E[(X - \mu_X)^2]$$

$$\text{poichè } E[\bar{X}_m] = \mu \Rightarrow E[(\bar{X}_m - \mu)^2] = \text{var}[\bar{X}_m]$$

$$\doteq 1 - \frac{\text{var}[\bar{X}_m]}{\epsilon^2} = 1 - \frac{\sigma^2}{m\epsilon^2} \geq 1 - \delta,$$

$$\text{var}[\bar{X}_m] = \frac{\sigma^2}{m}$$

$$\text{per } \delta > \frac{\sigma^2}{m\epsilon^2} \quad \text{oppure } m > \frac{\sigma^2}{\delta\epsilon^2}.$$

Esempi

- 1) Data una popolazione con media μ incognita e varianza $\sigma^2 = 1$, calcolare la dimensione del c.c. estratto affinché sia almeno del 95% la probabilità che la media campionaria disti meno di 0.5 dalla media della popolazione

$$P[|\bar{X}_m - \mu| < \varepsilon] \geq 1 - \delta \Rightarrow P[|\bar{X}_m - \mu| < 0.5] \geq 0.95$$

$$\Rightarrow \varepsilon = 0.5$$

$$\delta = 0.05$$

$$n > \frac{\sigma^2}{\delta \varepsilon^2} = \frac{1}{(0.05) \cdot (0.5)^2} = 80$$

N.B. σ^2 è nota.

- 2) Quanto deve essere grande un campione casuale per essere sicuri al 99% che la media campionaria disti meno di (0.5σ) dalla media μ della popolazione?

$$P[|\bar{X}_n - \mu| < \varepsilon] = 0.99$$

$$\Rightarrow \delta = 0.01$$

$$\varepsilon = 0.5\sigma \quad \sigma \text{ è incognita}$$

$$n > \frac{\sigma^2}{\delta \varepsilon^2} = \frac{\sigma^2}{(0.01) \cdot (0.5\sigma)^2} = \frac{1}{(0.01) \cdot (0.5)^2} = 400$$

IL TEOREMA DEL LIMITE CENTRALE

Sia \bar{X}_m la media campionaria di un c.c. di dim $n=m$ estratto da una popolazione avente funzione di densità $f(\cdot)$ INCOGNITA, con media μ e varianza finita σ^2 .

Sia Z_m la v.c. definita da:

$$Z_m = \frac{\bar{X}_m - E[\bar{X}_m]}{\sqrt{\text{var}[\bar{X}_m]}} = \frac{\bar{X}_m - \mu}{\frac{\sigma}{\sqrt{n}}}$$

Allora la distribuzione di Z_m tende alla distribuzione normale standard $N(0, 1)$ quando $m \rightarrow \infty$.

$Z_m \dot{\sim} N(0, 1)$ $\dot{\sim}$ = approssimativamente.

Problema del TLC: Quanto deve essere grande il campione affinché l'approssimazione sia valida?

Regole empirica $\rightarrow m \geq 30$

OSSERVAZIONI

Se la densità della popolazione $f(\cdot)$ è NORMALE allora ogni elemento X_i di \bar{X}_m è normale e quindi $Z_m \sim N(0, 1)$ \sim = esattamente

indipendentemente dalla numerosità n del campione.

$$E[Z_m] = \frac{\sqrt{m}}{\sigma} E[\bar{X}_m - \mu] = \frac{\sqrt{m}}{\sigma} (\mu - \mu) = 0$$

$$\text{var}[Z_m] = \frac{m}{\sigma^2} \text{var}[\bar{X}_m - \mu] = \frac{m}{\sigma^2} \text{var}[\bar{X}_m] = \frac{m}{\sigma^2} \cdot \frac{\sigma^2}{m} = 1.$$

valgono sempre.

Esempio

Si considerino delle sbarre di lunghezza data, caratterizzate da una $f(\cdot)$ incognita con $\sigma^2 = 0.04$ metri².

Scelto un c.c. di dim = n , calcolare n in modo che la media campionaria \bar{X}_n disti dalla media della popolazione μ per meno di un centimetro, con una probabilità maggiore del 97%.

1° metodo: **LG N**

$$1 \text{ cm} = 0.01 \text{ m} \Rightarrow \varepsilon = 0.01$$

$$\sigma^2 = 0.04 \text{ m}^2 \quad \sigma = 0.02$$

$$P[|\bar{X}_n - \mu| < \varepsilon] > 1 - \delta \quad \delta > \frac{\sigma^2}{n \varepsilon^2} \quad \text{cioè } n > \frac{\sigma^2}{\delta \varepsilon^2}$$

$$\delta = 0.03$$

$$\Rightarrow \underline{n} > \frac{0.04}{(0.03) \cdot (0.01)^2} = 1.3 \cdot 10^4 \approx \underline{13333}$$

2° metodo: **TLC**

$$|\bar{X}_n - \mu| < 0.01 \Leftrightarrow -0.01 < \bar{X}_n - \mu < 0.01$$

$$\Leftrightarrow \frac{-0.01}{\frac{\sigma}{\sqrt{n}}} < \frac{\bar{X}_n - \mu}{\frac{\sigma}{\sqrt{n}}} < \frac{0.01}{\frac{\sigma}{\sqrt{n}}}$$

$$\Leftrightarrow \frac{-0.01}{\frac{0.02}{\sqrt{n}}} < \bar{Z}_n < \frac{0.01}{\frac{0.02}{\sqrt{n}}}$$

$$\Leftrightarrow |\bar{Z}_n| < \frac{\sqrt{n}}{20} = Z_\alpha$$

$$P[|\bar{X}_n - \mu| < 0.01] > 0.97 \equiv P[|\bar{Z}_n| < \frac{\sqrt{n}}{20}] > 0.97$$

$$P[|\bar{Z}_n| < Z_\alpha] = 2 [P[\bar{Z}_n < Z_\alpha] - 0.5] = 2 P[\bar{Z}_n < Z_\alpha] - 1$$

$$\Rightarrow 2 P[\bar{Z}_n < Z_\alpha] - 1 > 0.97 \quad \text{cioè } P[\bar{Z}_n < Z_\alpha] = 0.985$$

Dalle tabelle della $N(0,1)$ $Z_\alpha = 2.17$

$$\Rightarrow \frac{\sqrt{n}}{20} = 2.17 \Rightarrow n = 1883.56 \Rightarrow \underline{n = 1884}$$

CAMPIONAMENTO DA DI STRIBUZIONI NORMALI

Dato una popolazione con funzione di densità normale $N(\mu, \sigma^2)$ abbiamo visto che la distribuzione della media campionaria \bar{X}_m è **ESATTAMENTE** $N(\mu, \frac{\sigma^2}{m})$.
e quindi Z_m è **ESATTAMENTE** $N(0, 1)$.

Per ogni X_i e c.c. di dim = n si ha $X_i \sim N(\mu, \sigma^2)$
e quindi $Z_i = \frac{X_i - \mu}{\sigma} \sim N(0, 1)$.

Definiamo la funzione:

$$U = \sum_{i=1}^m Z_i^2 = \sum_{i=1}^m \left(\frac{X_i - \mu}{\sigma} \right)^2 = \frac{1}{\sigma^2} \sum_{i=1}^m (X_i - \mu)^2$$

(somma di quadrati di normali standard).

Si può provare

TEOREMA 3:

$$U \sim \chi_m^2 \quad \text{CHI-QUADRO con } m \text{ gradi di libertà}$$

Il "grado di libertà" è il n° di quadrati indipendenti nella sommatoria.

(χ^2 è una f. GAMMA con $\alpha = \frac{1}{2}$, $\lambda = \frac{m}{2}$)

Poiché $Z_m = \frac{\bar{X}_m - \mu}{\frac{\sigma}{\sqrt{m}}} \sim N(0, 1)$, in base al TH. 3 si ha

$$Z_m^2 \sim \chi_1^2 \quad \text{CHI-QUADRO con } m=1 \text{ gradi di libertà}$$

Definiamo la funzione:

$$V = \frac{(m-1)S^2}{\sigma^2} = \frac{1}{\sigma^2} \sum_{i=1}^m (X_i - \bar{X}_m)^2 \stackrel{(*) \text{ conti}}{=} \sum_{i=1}^m Z_i^2 - Z_m^2 = U - Z_m^2$$

$\downarrow \sim \chi_m^2$ $\downarrow \sim \chi_1^2$

Si può provare:

TEOREMA 4

$$V \sim \chi^2_{m-1}$$

CHI-QUADRO con $(m-1)$ gradi di libertà

In analogia a $\bar{X}_m = \frac{1}{m} \sum_{i=1}^m X_i$ è possibile definire

$$\bar{Z}_m = \frac{1}{m} \sum_{i=1}^m Z_i = \frac{1}{m} \sum_{i=1}^m (X_i - \mu) = \frac{1}{m\sigma} (m\bar{X}_m - m\mu) = \frac{\bar{X}_m - \mu}{\frac{\sigma}{\sqrt{m}}}$$

allora vale la relazione

$$\sum_{i=1}^m (Z_i - \bar{Z}_m) \equiv 0 \quad \text{VINCOLO che abbassa il grado di libertà.}$$

Definiamo la funzione:

$$T = \frac{\bar{X}_m - \mu}{\frac{\sigma}{\sqrt{m}}} = \frac{\frac{\bar{X}_m - \mu}{\sigma/\sqrt{m}}}{\frac{\sigma}{\sqrt{m}}} = \frac{Z_m}{\sqrt{\frac{V}{m-1}}}$$

Perché \bar{X}_m e S^2 sono statistiche indipendenti si può provare che Z_m e V sono indipendenti.

Si può provare:

TEOREMA 5

$$T \sim t_{m-1}$$

t di STUDENT con $(n-1)$ gradi di libertà

CONTI
(*)

$$\begin{aligned} \frac{1}{\sigma^2} \sum_{i=1}^m (X_i - \bar{X}_m)^2 &= \frac{1}{\sigma^2} \sum_{i=1}^m ((X_i - \mu) - (\bar{X}_m - \mu))^2 = \frac{1}{\sigma^2} \sum_{i=1}^m (X_i - \mu)^2 \\ &\quad - \frac{2}{\sigma^2} (\bar{X}_m - \mu) \sum_{i=1}^m (X_i - \mu) + \frac{1}{\sigma^2} (\bar{X}_m - \mu)^2 \cdot m \\ &= \sum_{i=1}^m \frac{(X_i - \mu)^2}{\sigma^2} - \frac{m}{\sigma^2} (\bar{X}_m - \mu)^2 = \sum_{i=1}^m Z_i^2 - m \left(\frac{\bar{X}_m - \mu}{\frac{\sigma}{\sqrt{m}}} \right)^2 \\ &= \sum_{i=1}^m Z_i^2 - m \bar{Z}_m^2 = \sum_{i=1}^m Z_i^2 - Z_m^2 \end{aligned}$$

TABELLA RIASSUNTIVA

Z_m è la statistica in grado di fare inferenza sulla media μ della popolazione quando σ^2 è nota


T_m è la statistica in grado di fare inferenza sulla media μ della popolazione quando σ^2 è incognita.
(in realtà vale per $n < 30$)

V è la statistica in grado di fare inferenza sulla variante della popolazione σ^2 quando μ è incognita

U è la statistica in grado di fare inferenza sulla variante σ^2 quando μ è nota.

Esempio

Si vuole localizzare un oggetto nello spazio, ma la misurazione porta un errore (in ognuna delle 3 direzioni x, y, z) che è una v.c. normale $N(\mu=0, \sigma=2m)$. Supponendo i 3 errori indipendenti, calcolare la probabilità che la distanza tra posizione misurata e posizione reale sia maggiore di 3 metri.



$P(x, y, z)$ REALE

$\tilde{P}(x_1, y_1, z_1)$ MISURATA

$$x_1 = x + E_1$$

$$y_1 = y + E_2 \quad E_i \text{ errori}$$

$$z_1 = z + E_3 \quad i = 1, 2, 3$$

$D =$ distanza tra P e \tilde{P} .

$$D^2 = \overline{P\tilde{P}}^2 = (x_1 - x)^2 + (y_1 - y)^2 + (z_1 - z)^2 = E_1^2 + E_2^2 + E_3^2$$

$$E_i \sim N(0, 2)$$

$$\hat{z}_i = \frac{E_i - \mu}{\sigma} = \frac{E_i}{2} \sim N(0, 1)$$

$$Y = \sum_{i=1}^3 \hat{z}_i^2 \quad \text{somma di quadrati di normali standard}$$

Per il TEOREMA 3 $Y \sim \chi^2_{n=3}$

$$P[D > 3] = P[D^2 > 9] = P[E_1^2 + E_2^2 + E_3^2 > 9] = P[\hat{z}_1^2 + \hat{z}_2^2 + \hat{z}_3^2 > \frac{9}{4}]$$

$$= P[Y > \frac{9}{4}] = 1 - P[Y \leq \frac{9}{4}] \approx 0.5222$$

$$\approx 0.4778$$

Se il problema della localizzazione avviene nel piano

allora $P(x, y)$ $\tilde{P}(x_1, y_1)$

$$D^2 = E_1^2 + E_2^2 \Rightarrow Y \sim \chi^2_{m=2}$$

$$\text{Ma } \chi^2_{m=2} = \Gamma\left(\lambda = \frac{1}{2}, \kappa = \frac{m}{2} = 1\right) = \Gamma\left(\frac{1}{2}, 1\right) \equiv \exp\left(\lambda = \frac{1}{2}\right)$$

Quindi $Y \sim \exp(\lambda = \frac{1}{2})$ cioè:

$$f(y) = \lambda e^{-\lambda y}, \quad y \geq 0$$

$$F(y) = 1 - e^{-\lambda y}$$

Allora

$$P[D > 3] = P[D^2 > 9] = P\left[Y > \frac{9}{4}\right] = 1 - P\left[Y \leq \frac{9}{4}\right] = 1 - F\left(\frac{9}{4}\right)$$

$$= e^{-\lambda y} \Big|_{\lambda = \frac{1}{2}, y = \frac{9}{4}} = e^{-9/8} \approx 0.3247$$