

STATISTICA INFERENZIALE: TRE FILE PDF

Il file PDF “Statistica Inferenziale (I)” è il primo dei seguenti tre file scaricabili dal Materiale Didattico (sotto la voce “Dispense”) del Corso di Statistica (AA 2008-9)

Statistica Inferenziale (I): campionamento e stima puntuale	pag. 2-5	([1]-[8bis])
Statistica Inferenziale (II): stimatori e stima intervallare	pag. 6-9	([9]-[14bis])
Statistica Inferenziale (III): test statistici	pag. 10-12	([15]-[23bis])

I tre file sopra elencati riassumono in modo **schematico** ma **completo** i concetti e risultati principali della parte di Statistica Inferenziale del programma del Corso di Statistica già esposta agli studenti in aula a lezione dai docenti del Corso (escluso il modello di regressione lineare).

Contengono inoltre un esercizio svolto (vedi pag. 5) introduttivo all'applicazione di tali concetti e risultati (le dimostrazioni di tali risultati non sono contenute nei suddetti file, anch'esse comunque sono già state esposte a lezione dai docenti del Corso e, p. es., sono reperibili nelle copie dei lucidi delle lezioni corrispondenti presso Yellow Print).

I tre file sopra indicati, data la loro **schematicità**, possono essere particolarmente utili se vengono integrati dallo studente con **gli appunti presi alle lezioni dei docenti del Corso**, oppure, p. es., con le fotocopie dei lucidi delle lezioni reperibili presso Yellow Print, od anche, secondariamente, con i corrispondenti capitoli del libro di Ross. Un altro riferimento utile è il file PDF “Correlazione e Combinazioni Lineari” scaricabile dal Materiale Didattico del Corso. Anche questo file dà un riassunto schematico di concetti e risultati già esposti a lezione dai docenti del Corso, non contiene tuttavia le dimostrazioni di tali risultati (anch'esse comunque sono già state esposte a lezione e, p. es., sono reperibili nelle copie lucidi delle lezioni corrispondenti presso Yellow Print).

NB: Alcune parti di una prima versione parziale di questi file (qui rivista, migliorata e completata definitivamente) sono già state utilizzate da uno dei docenti del Corso come supporto didattico in aula in alcune lezioni in cui sono stati trattati i diversi argomenti di Statistica Inferenziale e quindi inserite nelle copie dei lucidi delle lezioni stesse. Un ringraziamento a chi segnalerà eventuali sviste, errori di stampa o battitura, ecc.

STATISTICA INFERENZIALE (I): campionamento e stima puntuale

Prima di tutto un breve ripasso sulle variabili aleatorie:

[1]

$$X = \begin{cases} x = 1, 2, \dots, 6 \\ p(x) = \frac{1}{6} = 0.1\bar{6} \end{cases} \Rightarrow \begin{cases} \mu_x = 1p(1) + 2p(2) + \dots + 6p(6) = \boxed{3.5} \\ E(X^2) = 1^2 p(1) + 2^2 p(2) + \dots + 6^2 p(6) = \boxed{15.1\bar{6}} \\ \sigma_x^2 = E(X^2) - (\mu_x)^2 = \boxed{2.916\bar{7}} \end{cases}$$

X = "numero dei componenti di **una qualsiasi famiglia** di un Comune di N famiglie",
p. es. $N = 1000$, e di cui si sa che non vi sono famiglie con più di 6 componenti.

$X_t = X$ = "numero dei componenti della t -esima famiglia ($t = 1, 2, \dots, N = 1000$) del Comune"

Poiché le **probabilità** $p(x)$ sono note si può determinare il **valore esatto** di μ_x , $E(X^2)$ e σ_x^2 applicando le loro formule come fatto sopra (nel ns. caso, per semplicità, le probabilità sono costanti $\forall x$, ma in generale ovviamente non lo sono). Si ricordi inoltre che:

$$p(x) = \frac{1}{6} = 0.1\bar{6} \quad (x = 1, 2, \dots, 6)$$

è la probabilità che una qualsiasi famiglia del Comune abbia $x (= 1, 2, \dots, 6)$ componenti
è la probabilità di estrarre a caso dalle N famiglie del Comune una famiglia con $x (= 1, 2, \dots, 6)$ componenti (nel ns. caso è costante $\forall x$)

è frequenza relativa delle famiglie con $x (= 1, 2, \dots, 6)$ componenti (nel ns. caso è costante $\forall x$)

$p(x)$ dà, moltiplicata per 100, $16.\bar{6}\%$ cioè la percentuale delle famiglie con $x (= 1, 2, \dots, 6)$ componenti (nel ns. caso è costante $\forall x$)

$p(x)$ dà, moltiplicata per $N = 1000$, $166.\bar{6}$ cioè il numero delle famiglie con $x (= 1, 2, \dots, 6)$ componenti (nel ns. caso è costante $\forall x$)

$p(x)$ dà, con la opportuna formula, $\mu_x = 3.5$ cioè il numero medio di componenti delle famiglie del Comune

In generale nelle

[2]

APPLICAZIONI ECONOMICO-AZIENDALI, INGEGNERISTICHE e FISICHE

le **PROBABILITA'** (o DENSITA'), e quindi μ_x , $E(X^2)$ e σ_x^2

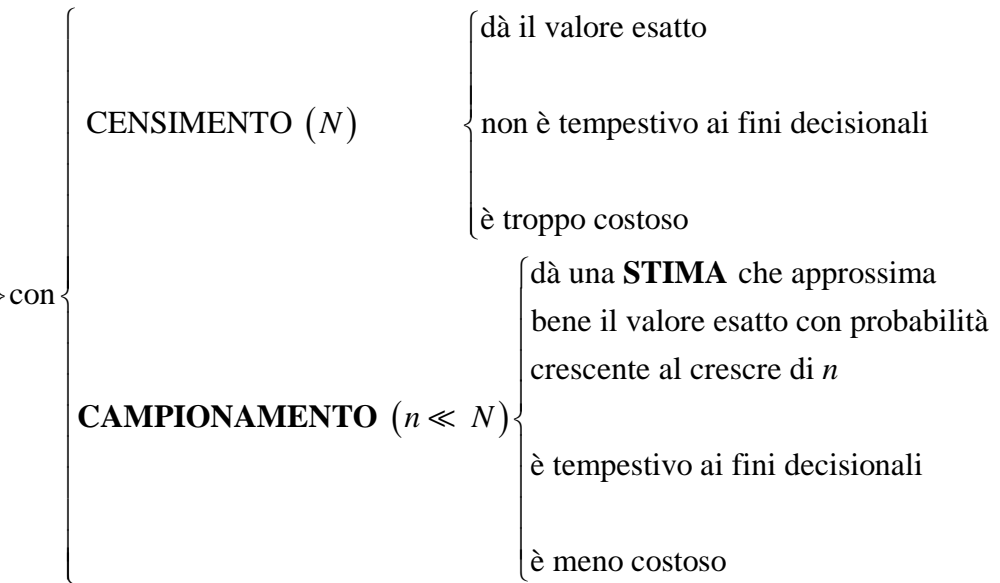
NON HANNO VALORI NOTI

$$X = \begin{cases} x = 1, 2, \dots, 6 \\ p(x) = \boxed{?} \end{cases} \Rightarrow \begin{cases} \mu_x = 1p(1) + 2p(2) + \dots + 6p(6) = \boxed{?} \\ E(X^2) = 1^2 p(1) + 2^2 p(2) + \dots + 6^2 p(6) = \boxed{?} \\ \sigma_x^2 = E(X^2) - (\mu_x)^2 = \boxed{?} \end{cases}$$

COME SI DETERMINANO TALI VALORI [?]

DETERMINAZIONE DEI VALORI di $p(x)$, μ_x , $E(X^2)$ e σ_x^2 [3]

Determinazione di $p(x), \mu_x, E(X^2)$, e σ_x^2



**LA STATISTICA INFERENZIALE DA' I METODI DI CAMPIONAMENTO [4]
PER STIMARE I VALORI NON NOTI DI**

$p(x), \mu_x, E(X^2), \sigma_x^2$, ecc.

**Metodo di CAMPIONAMENTO CASUALE SEMPLICE (CCS) [5]
di dimensione $n (\ll N)$**

$X = X_1$	$X = X_2$	$X = X_3$	$X = X_4$	$X = X_5$	$X = X_6$...	$X = X_n$
X_1	X_2	X_3	X_4	X_5	X_6	...	X_n
↓	↓	↓	↓	↓	↓	...	↓
$x_1 = 5$	$x_2 = 3$	$x_3 = 2$	$x_4 = 3$	$x_5 = 6$	$x_6 = 2$...	$x_n = 1$

X v.a. di riferimento = **Popolazione statistica X**

(X_1, X_2, \dots, X_n) = **Campione statistico**, $(x_1 = 5, x_2 = 3, \dots, x_n = 1)$ = **realizzazione campionaria**

DEFINIZIONE FORMALE DI CAMPIONE STATISTICO CASUALE SEMPLICE

Le n v.a. X_t ($t = 1, 2, \dots, n$) che costituiscono il campione statistico (X_1, X_2, \dots, X_n) sono **tutte uguali** (ovvero, **tutte distribuite identicamente**) alla v.a. X di riferimento cioè alla **popolazione statistica X** (vedi anche il riquadro [1]). Inoltre il CSC richiede l'**indipendenza stocastica** di tali n v.a. Si ha dunque che:

un Campione Statistico Casuale Semplice è dato da

n v.a. (X_1, X_2, \dots, X_n) I.I.D.

dove la prima "I." è l'iniziale di "Indipendenti" (o "Independent"), la seconda "I." è l'iniziale di "Identicamente" (o "Identically") e "D." è l'iniziale di "Distribuite" (o "Distributed"). **L'ipotesi di indipendenza stocastica delle n v.a. X_t assicura che** la probabilità (o densità) dei valori possibili della v.a.

X non cambi passando da una osservazione alla successiva. **In pratica l'indipendenza stocastica si realizza (a)** rappresentando l'insieme dei valori possibili della v.a. X di riferimento come un'urna da cui si estraggono casualmente n dei valori possibili, e **(b)** re-immettendo nell'urna ciascun valore osservato prima di effettuare l'estrazione successiva.

DETERMINAZIONE DELLE STIME DI

[6]

$p(x), \mu_x, E(X^2), \sigma_x^2, \text{ecc.}$

$X = X_1$	$X = X_2$	$X = X_3$	$X = X_4$	$X = X_5$	$X = X_6$...	$X = X_n$
X_1	X_2	X_3	X_4	X_5	X_6	...	X_n
↓	↓	↓	↓	↓	↓	...	↓
$x_1 = 5$	$x_2 = 3$	$x_3 = 2$	$x_4 = 3$	$x_5 = 6$	$x_6 = 2$...	$x_n = 1$

X v.a. di riferimento = **popolazione statistica** X

(X_1, X_2, \dots, X_n) = **Campione statistico**, $(x_1 = 5, x_2 = 3, \dots, x_n = 1)$ = **realizzazione campionaria**

stima di θ : $\hat{\theta}$	$n = 1$	$n = 2$	$n = 3$	$n = 4$	$n = 5$	$n = 6$	n	\rightarrow	∞
$p(1): \hat{p}(1)$	0	0	0	0	0	0	...	" \rightarrow "	$p(1)$
$p(2): \hat{p}(2)$	0	0	1/3	1/4	1/5	2/6	...	" \rightarrow "	$p(2)$
$p(3): \hat{p}(3)$	0	1/2	1/3	2/4	2/5	2/6	...	" \rightarrow "	$p(3)$
$p(4): \hat{p}(4)$	0	0	0	0	0	0	...	" \rightarrow "	$p(4)$
$p(5): \hat{p}(5)$	1	1/2	1/3	1/4	1/5	1/6	...	" \rightarrow "	$p(5)$
$p(6): \hat{p}(6)$	0	0	0	0	1/5	1/6	...	" \rightarrow "	$p(6)$
$\mu_x: \hat{\mu}_x = \bar{x}_n$	5	4	3. $\bar{3}$	3.25	3.8	" \rightarrow "	μ_x
$E(X^2): \hat{E}(X^2)$	25	17	12. $\bar{6}$	11.45	16.6	" \rightarrow "	$E(X^2)$
$\sigma_x^2: \hat{\sigma}_x^2 = s_n^2$	0	1	1.5	1.1875	2.16	" \rightarrow "	σ_x^2

QUALI SONO LE FORMULE USATE PER CALCOLARE LE STIME ?

[7]

SONO QUELLE GIA' USATE PER I DATI OSSERVATI IN STATISTICA DESCRITTIVA CON I SIMBOLI CAMBIATI

Ad esempio nella colonna $n = 5$ del riquadro [6] si ha

$$M(X) = 5 \frac{1}{5} + 3 \frac{2}{5} + 2 \frac{1}{5} + 6 \frac{1}{5} = 3.8 = \frac{5+3+2+3+6}{5} = \frac{x_1 + \dots + x_5}{5} = \frac{1}{5} \sum_{t=1}^5 x_t = \boxed{\bar{x}_5 = \hat{\mu}_X}$$

$$M(X^2) = 5^2 \frac{1}{5} + 3^2 \frac{2}{5} + 2^2 \frac{1}{5} + 6^2 \frac{1}{5} = 16.6 = \frac{5^2 + 3^2 + 2^2 + 3^2 + 6^2}{5} = \frac{x_1^2 + \dots + x_5^2}{5} = \frac{1}{5} \sum_{t=1}^5 x_t^2 = \boxed{\hat{E}(X^2)}$$

$$V(X) = M(X^2) - M(X)^2 = 2.16 = \hat{E}(X^2) - (\bar{x}_5)^2 = \boxed{s_5^2 = \hat{\sigma}_X^2}$$

N.B. (I) in realtà per **piccoli campioni** (con $n < 30$) la stima di σ_x^2 data da s_n^2 si corregge con il

fattore di correzione $\frac{n}{n-1}$, cioè si utilizza $s_n^2 \frac{n}{n-1} = s_c^2 = \hat{\sigma}_x^2$, **vedi riquadro [11]**

N.B. (II): le stime si calcolano **SOLO e DIRETTAMENTE** per la dimensione n del campione prefissata, p. es. se è fissato $n = 5$ allora per ottenere le stime si calcola **solo e direttamente** la colonna con $n = 5$ del riquadro [6].

N.B. (III): rispondere alle domande (1), (2), (3a) e (4a) dell'Esercizio nel riquadro [8].

Esercizio di Statistica inferenziale

[8]

(Nota Bene: in quanto primo esercizio di questo tipo nel Corso di Statistica, il testo che segue è molto più dettagliato ed esplicito di quanto non saranno gli esercizi successivamente svolti in aula o che si possono trovare nei testi di esame)

E' noto che il reddito di esercizio di una qualsiasi azienda di un dato settore industriale (composto da $N = 973$ aziende) è una v.a. $X \sim N(\mu_X; \sigma_X^2)$ con reddito medio atteso μ_X e varianza σ_X^2 non noti. In realtà tali due parametri si potrebbero determinare in modo esatto facendo il censimento dei redditi delle aziende del settore, cioè: (a) rilevando tutti gli $N = 973$ redditi delle imprese del settore industriale e (b) calcolando con gli $N = 973$ redditi osservati le formule di media e varianza viste nella parte di Statistica descrittiva del corso. Tuttavia, poiché determinare in modo esatto reddito medio atteso μ_X e varianza σ_X^2 con il censimento richiede troppo tempo ed è troppo costoso, si preferisce stimare il valore di tali due parametri mediante un campione casuale semplice $(X_1, X_2, \dots, X_{80}, X_{81})$ con $n = 81$. La corrispondente realizzazione campionaria $(x_1, x_2, \dots, x_{80}, x_{81})$ degli $n = 81$ redditi osservati è stata riassunta nei due valori:

$$\sum_{t=1}^{81} x_t = 3321, \quad \sum_{t=1}^{81} x_t^2 = 180441$$

- (1) Specificare quale è la popolazione statistica (ovvero la v.a. di riferimento)
- (2) Specificare quali sono le formule che si usano per determinare μ_X e varianza σ_X^2 con il censimento delle $N = 973$ aziende del settore.
- (3a) Determinare la stima del reddito medio atteso μ_X delle $N = 973$ aziende del settore sulla base della realizzazione campionaria di dimensione $n = 81$ osservata; (3b) si indichi inoltre lo stimatore utilizzato e le sue proprietà (la risposta è nel riquadro [14bis] e richiede la lettura dei riquadri [9] e [10]).
- (4a) Determinare la stima della varianza σ_X^2 dei redditi delle $N = 973$ aziende del settore sulla base della realizzazione campionaria di dimensione $n = 81$ osservata. (4b) si indichi inoltre lo stimatore utilizzato e le sue proprietà (la risposta è nel riquadro [14bis] e richiede la lettura dei riquadri [9] e [11]).
- (5) Determinare, sulla base della realizzazione campionaria osservata, l'intervallo di confidenza del reddito medio atteso μ_X con coefficiente di confidenza $1 - \alpha = 0.95$ (la risposta è nel riquadro [14bis] e richiede la lettura del riquadro [13]).
- (6) Infine, sulla base della realizzazione campionaria osservata, si esegua il test statistico bilaterale per il reddito medio atteso μ_X : $H_0: \mu_X = 43.5$ contro $H_1: \mu_X \neq 43.5$ al livello di significatività $\alpha = 0.05$ (la risposta è nel riquadro [23bis] e richiede la lettura dei riquadri da [15] a [21]).

[8bis]

Risposta alla Domanda (1). (vedi riquadri da [1], [3] e [5]). La v.a. di riferimento o popolazione statistica è la v.a. "reddito di esercizio" $X \sim N(\mu_X; \sigma_X^2)$ con reddito medio atteso μ_X e varianza σ_X^2 non noti.

Risposta alla Domanda (2). (vedi riquadri [1], [3], [6] e [7]).

$$M(X) = \frac{1}{N} \sum_{t=1}^N x_t = \frac{1}{973} \sum_{t=1}^{973} x_t = \mu_X$$

$$V(X) = M(X^2) - M(X)^2 = \frac{1}{N} \sum_{t=1}^N x_t^2 - M(X)^2 = \frac{1}{973} \sum_{t=1}^{973} x_t^2 - M(X)^2 = \sigma_X^2$$

Risposta alla Domanda (3a). (vedi riquadri [6] e [7]). La stima di μ_X è data da:

$$\bar{x}_{81} = \frac{1}{81} \sum_{t=1}^{81} x_t = \frac{1}{81} 3321 = 41 = \hat{\mu}_X$$

Risposta alla Domanda (4a). (vedi riquadri [6] e [7]). E' $n = 81 > 30$, per stimare σ_X^2 va bene sia s_{81}^2 sia s_c^2 :

$$s_{81}^2 = \frac{1}{81} \sum_{t=1}^{81} x_t^2 - (\bar{x}_{81})^2 = \frac{1}{81} \sum_{t=1}^{81} 180441 - 41^2 = 2227.6667 - 1681 = 546.6667 = \hat{\sigma}_X^2$$

$$s_c^2 = \frac{81}{81-1} s_{81}^2 = 1.0125 \times 546.6667 = 553.5000 = \hat{\sigma}_X^2 (\cong 546.6667 = s_{81}^2)$$