

Ulteriori Conoscenze di Informatica e Statistica



Carlo Meneghini

Dip. di fisica - via della Vasca Navale 84,
st. 83 (I piano) tel.: 06 55 17 72 17


meneghini@fis.uniroma3.it

Indici di forma

Descrivono le asimmetrie della distribuzione




Una distribuzione non simmetrica si dice obliqua



Distribuzione obliqua sx:

la media è minore della mediana



Distribuzione obliqua dx:

la media è maggiore della mediana

Momenti della distribuzione

$$m_z = \frac{1}{N} \sum_{i=1}^N (x_i)^z = \sum_{i=1}^N f_i (x_i)^z$$

$$f_i = \frac{N_i}{N}$$

$$\sum_{i=1}^N N_i = N$$

$$M_z = \sum_{i=1}^N f_i (x_i - m_o)^z$$

f_i = frequenza
relativa

N_i frequenza
assoluta

Momenti centrali
(momenti rispetto alla media)

Media = m_o
varianza = $\sigma^2 = M_2$

$$\bar{x} = m_o = \sum_{i=1}^N f_i x_i$$

$$\sigma^2 = \sum_{i=1}^N f_i (x_i - m_o)^2 = \sum_{i=1}^N f_i x_i^2 - \bar{x}^2 = \overline{x^2} - \bar{x}^2$$

$$m_3 = \sum_{i=1}^N f_i (x_i - m_o)^3$$


$$a_{simmm} = \frac{m_3}{\sigma^3}$$

Skewness

per la distribuzione
Normale (Gauss)

$$a_{simmm} = 0$$


Coefficiente di asimmetria (a_{simmm})



Curtosi (Kurtosis) (a_4)

$$m_4 = \sum_{i=1}^N f_i (x_i - m_o)^4$$

$$a_4 = \frac{m_4}{\sigma^4}$$



per la distribuzione
Normale (Gauss)

$$a_4 = 3$$

$a_4 > 3$ indica una
distribuzione più piatta
di una Gaussiana

$a_4 < 3$ indica una
distribuzione più
piccata di una Gaussiana

Centratura e standardizzazione

Se x è una variabile aleatoria caratterizzata da valor medio μ e varianza σ^2 la variabile

$$Z = (x - \mu) / \sigma$$

È una variabile aleatoria con media nulla e varianza unitaria

Tabelle di contingenza

Ad ogni valore i -esimo della variabile (qualitativo o quantitativa) è associato il numero delle osservazioni


Modalità

anno	I	II	III	N. stud.
2001	45	35	12	92
2002	42	38	21	98
2003	58	28	14	112
Totali	145	101	47	293

Guppi

osservazioni

Distribuzioni
marginali



anno	I	II	III	N. stud.
2001	45	35	12	92
2002	42	38	21	98
2003	58	28	14	112
Totali	145	101	47	293

$$f_{ij} = x_{ij} / N_i$$


Profili di riga

anno	I	II	III	% stud.
2001	48.91	38.04	13.04	100
2002	42.86	38.78	21.43	100
2003	51.79	25.00	12.50	100
Totali %	49.49	34.47	16.04	100

x_i ↑

→ y_j

La percentuale di promossi nei diversi anni (x) dipende dall'appello (y)?




anno	I	II	III	N. stud.
2001	45	35	12	92
2002	42	38	21	98
2003	58	28	14	112
Totali	145	101	47	293

$$f_{ij} = x_{ij} / N_j$$

Profili di colonna

anno	I	II	III	% stud.
2001	31.03	34.65	25.53	31.40
2002	28.97	37.62	44.68	33.45
2003	40.00	27.72	29.79	38.23
Totali %	100	100	100	100

La percentuale di promossi nei diversi appelli (y) dipende dall'anno (x)?



anno	I	II	III	N. stud.
2001	45	35	12	92
2002	42	38	21	98
2003	58	28	14	112
Totale	145	101	47	293

$$F_{ij} = x_{ij} / N = f_{ij} f_i$$

$$f_i = N_i / N$$

anno	I	II	III	N. stud.
2001	15.36	11.95	4.10	31.40
2002	14.33	12.97	7.17	33.45
2003	19.80	9.56	4.78	38.23
Totale	49.49	34.47	16.04	100

$$f_j = N_j / N$$

N

Confronto tabelle di contingenza

anno	I	II	III	N. stud.
2001	15.36	11.95	4.10	31.40
2002	14.33	12.97	7.17	33.45
2003	19.80	9.56	4.78	38.23
Totali	49.49	34.47	16.04	100

$$F_{ij} = x_{ij} / N = f_{ij} f_i$$

Frequenze osservate

Frequenze attese nel caso random

$$F_{ij} = x_{ij} / N = f_{ij} f_i$$

anno	I	II	III	N. stud.
2001	15.54	10.82	5.04	31.40
2002	16.55	11.53	5.37	33.45
2003	18.92	13.18	6.13	38.23
Totali	49.49	34.47	16.04	100

Nel caso di **indipendenza stocastica** si la probabilità congiunta è pari al prodotto delle probabilità: $P(A \cap B) = P(B) P(A)$

anno	I	II	III	N. stud.	Riga 1	Riga 2	Riga 3	col 1	col 2	col 3		
2001	45	35	12	92	Riga 1	1		col 1	1			
2002	42	38	21	98	Riga 2	0.99	1	col 2	-0.99	1		
2003	58	28	14	112	Riga 3	0.91	0.85	1	col 3	-0.47	0.57	1
Totale	145	101	47	293								

anno	I	II	III	N. stud.	Riga 1	Riga 2	Riga 3	col 1	col 2	col 3		
2001	48.91	38.04	13.04	100	Riga 1	1		col 1	1			
2002	42.86	38.78	21.43	100	Riga 2	0.99	1	col 2	-0.78	1		
2003	51.79	25.00	12.50	100	Riga 3	0.91	0.85	1	col 3	-0.96	0.59	1
Totale	49.49	34.47	16.04	100								

anno	I	II	III	N. stud.	Riga 1	Riga 2	Riga 3	col 1	col 2	col 3		
2001	31.03	34.65	25.53	31.40	Riga 1	1		col 1	1			
2002	28.97	37.62	44.68	33.45	Riga 2	-0.55	1	col 2	-0.99	1		
2003	40.00	27.72	29.79	38.23	Riga 3	-0.04	-0.81	1	col 3	-0.47	0.57	1
Totale	100	100	100	100								

anno	I	II	III	N. stud.	Riga 1	Riga 2	Riga 3	col 1	col 2	col 3		
2001	15.36	11.95	4.10	31.40	Riga 1	1		col 1	1			
2002	14.33	12.97	7.17	33.45	Riga 2	0.99	1	col 2	-0.99	1		
2003	19.80	9.56	4.78	38.23	Riga 3	0.91	0.85	1	col 3	-0.47	0.57	1
Totale	49.49	34.47	16.04	100								

anno	I	II	III	N. stud.	Riga 1	Riga 2	Riga 3	col 1	col 2	col 3		
2001	15.54	10.82	5.04	31.40	Riga 1	1		col 1	1			
2002	16.55	11.53	5.37	33.45	Riga 2	1	1	col 2	1	1		
2003	18.92	13.18	6.13	38.23	Riga 3	1	1	1	col 3	1	1	1
Totale	49.49	34.47	16.04	100								

Strumenti
Analisi dati
Correlazione

Tabella
teorica

Frequenza e Probabilità

L'insieme dei valori assunti da una variabile aleatoria come risultato di esperimenti e osservazioni costituisce una **"distribuzione"**

Per ogni valore la **"frequenza"** è il numero di volte che questo valore compare.

La **frequenza relativa** è il numero di volte che questo compare, normalizzato al numero di osservazioni.

Le frequenze sono **grandezze "sperimentali"**. La **probabilità** associata ad un dato risultato è il **risultato di un procedimento matematico**.

J	K
	dati
1	93
2	84
3	98
4	99
5	108
6	92
7	102
8	80
9	91
10	94
11	91
12	98
13	79
14	91
15	108
16	95
17	104
18	92
19	98
20	112
21	96
22	97
23	79
24	102
25	88
26	102
27	118
28	98
29	110
30	87

Strumenti | Dati | Finestra | ?

- Controllo ortografia... F7
- Controllo errori...
- Condividi cartella di lavoro...
- Protezione
- Conversione euro...
- Collaborazione in linea
- Verifica formule
- Servizi sul Web...
- Componenti aggiuntivi...
- Personalizza...
- Opzioni...
- Analisi dati...**

Statistica descrittiva

Input

Intervallo di input: \$K\$1:\$K\$30

Dati raggruppati per:

- Colonne
- Righe

Etichette nella prima riga

Opzioni di output:

Intervallo di output: \$M\$3

Nuovo foglio di lavoro:

Nuova cartella di lavoro

Riepilogo statistiche

Livello di confidenza per media: 95 %

K-esimo più grande: 1

K-esimo più piccolo: 1

OK | Annulla | ?

Analisi dati

Strumenti di analisi

- Analisi varianza: ad un fattore
- Analisi varianza: a due fattori con replica
- Analisi varianza: a due fattori senza replica
- Correlazione
- Covarianza
- Statistica descrittiva**
- Smorzamento esponenziale
- Test F a due campioni per varianze
- Analisi di Fourier
- Istogramma

OK | Annulla | ?

Colonna1

Media	96.2
Errore standard =dev.st/n ^{0.5}	1.75
Mediana	96.5
Moda	98
Deviazione standard	9.59
Varianza campionaria	91.89
Curtosi	-0.0662
Asimmetria	0.13
Intervallo	39
Minimo	79
Massimo	118
Somma	2886
Conteggio =n	30
Livello di confidenza(95.0%)	3.58

Frequenza e Probabilità

Come determinare la probabilità di un evento?

Insieme infinito di "prove"

$$p_i = \lim_{N \rightarrow \infty} \frac{n_i}{N} = \lim_{N \rightarrow \infty} f_i$$

$$\sum_{i=1}^M p_i = 1$$


$$p_i \geq 0$$

Calcolo delle probabilità

$P(A)$: probabilità dell'evento A

$P(B)$: probabilità dell'evento B

$$P(A+B) = P(A \cup B) = P(A) + P(B) - P(A \cap B)$$



$AB, A \cap B,$
intersezione

se $P(A \cap B) = 0$ gli eventi
si dicono indipendenti

Probabilità composta

$$P(A \cap B) = P(B) P(A|B) = P(A) P(B|A)$$

per cui la probabilità che due eventi A e B si verificano contemporaneamente è pari alla probabilità di uno dei due eventi moltiplicato con la probabilità dell'altro evento condizionato al verificarsi del primo.

Nel caso di **indipendenza stocastica** [$P(B|A) = P(B)$] la probabilità congiunta è pari al prodotto delle probabilità:

$$P(A \cap B) = P(B) P(A)$$

Lancio di 2 dadi



Risultati possibili

	m_{ij}	
2 - 1,1		$P_2 = 1/36$
3 - 1,2 2,1		$P_3 = 2/36$
4 - 1,3 2,2 3,1		$P_4 = 3/36$
5 - 1,4 2,3 3,2 4,1		$P_5 = 4/36$
6 - 1,5 2,4 3,3 4,2 5,1		$P_6 = 5/36$
7 - 1,6 2,5 3,4 4,3 5,2 6,1		$P_7 = 6/36$
8 - 2,6 3,5 4,4 5,3 6,2		$P_8 = 5/36$
9 - 3,6 4,5 5,4 6,3		$P_9 = 4/36$
10 - 4,6 5,5 6,4		$P_{10} = 3/36$
11 - 5,6 6,5		$P_{11} = 2/36$
12 - 6,6		$P_{12} = 1/36$

$$p_i = \frac{1}{6}$$

$$p_{ij} = m_{ij}p_i p_j = \frac{m_{ij}}{36}$$

Distribuzione di Bernulli

Descrive una variabile casuale che può assumere solo valori 0,1: $X=[0,1]$

$$P(1) = P(X=1) = p$$

$$P(0) = P(X=0) = 1-p$$

$$\mu = p$$

$$\sigma^2 = p(1-p)$$

Distribuzione Binomiale

Descrive una variabile casuale X che rappresenta il numero di successi su n prove, ognuna con probabilità di successo p (X è una sommadi variabili casuali di tipo "bernulli")

$$p(k) = \mathbb{P}(X = k) = \binom{n}{k} p^k (1 - p)^{n-k}$$

k =numero di successi,
 n = numero di prove

$$\binom{n}{k} = \frac{n!}{k!(n - k)!}$$

$$\mu = np$$

$$\sigma = \sqrt{npq}$$

Distribuzione Binomiale (Bernulli)

Pb.: Lancio 5 (N=5) volte una moneta, quale è la probabilità di avere 3 (k=3) teste

1 ● ● ● ○ ○

2 ○ ● ● ● ○

3 ○ ○ ● ● ●

4 ● ● ○ ● ○

5 ● ● ○ ○ ●

6 ○ ● ● ○ ●


7 ● ○ ● ● ○

8 ○ ● ○ ● ●

9 ● ○ ○ ● ●

10 ● ○ ● ○ ●

$$P(N, k) = \binom{N}{k} p^k q^{N-k} = \frac{N!}{k!(N-k)!} p^k (1-p)^{N-k}$$



Valore atteso

$$\mu = np$$

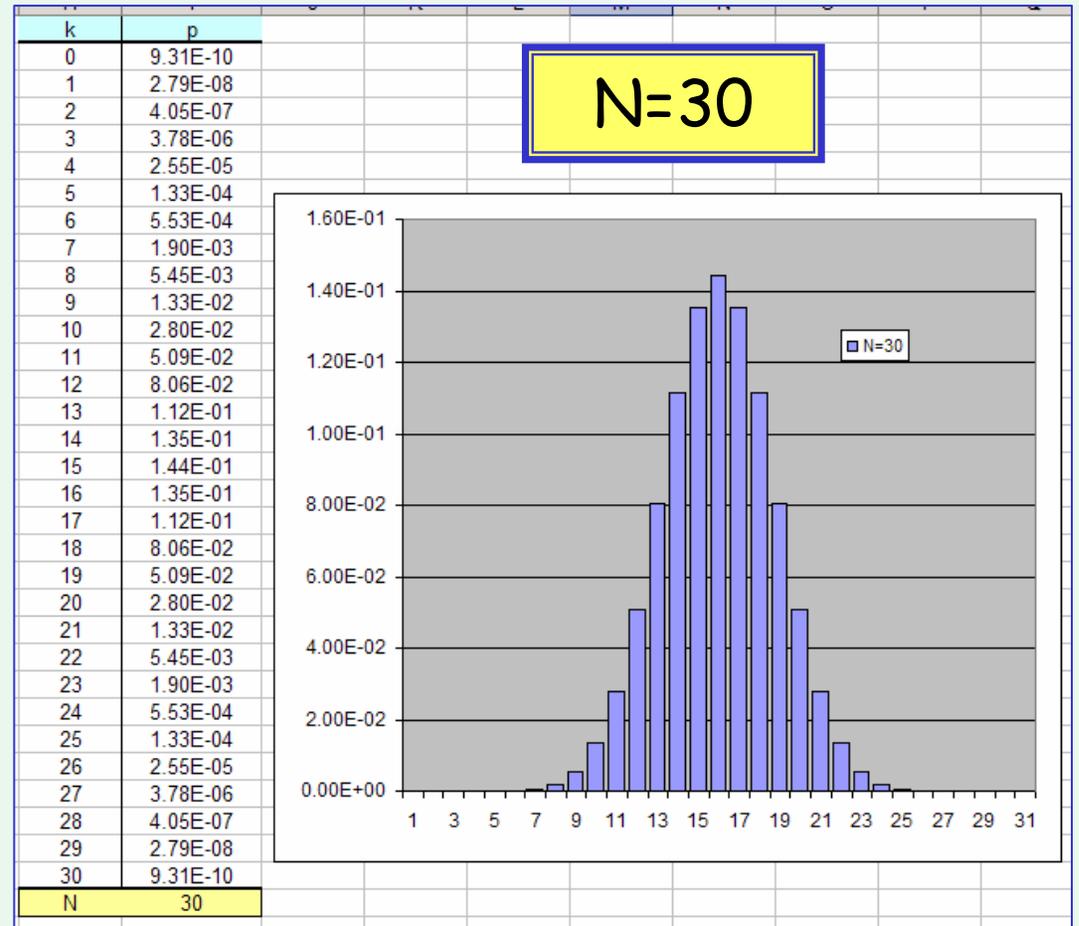

Dev. St.

$$\sigma = \sqrt{npq}$$

Distribuzione Binomiale (Bernulli)

$$p = q = 0.5$$

$$P(N, k) = \binom{N}{k} p^k q^{N-k} =$$



Distribuzione di Poisson

La variabile stocastica X può assumere valori discreti $X=\{0,1,2,3,4,\dots\}$

Distribuzione Binomiale con:
 $N \gg 1$
 $p \ll 1$

$$p(k) = \frac{\lambda^k}{k!} e^{-\lambda}$$


Valore atteso: $\mu = \lambda$

varianza: $\sigma^2 = \lambda$

Può essere usata per descrivere il numero di cellule in una data area, il numero di errori di battitura per pagina, etc...

Descrive distribuzioni di oggetti caratterizzati da:

- densità costante (numero di oggetti proporzionale alla dimensione della regione di campionamento (superficie, volume, lunghezza etc..))
- i conteggi in regioni disgiunte sono indipendenti
- il numero di conteggi tende a zero se le dimensioni della regione tendono a zero.




Distribuzioni di probabilità notevoli

Distribuzione Poisson

$$p(k) = \frac{\lambda^k}{k!} e^{-\lambda}$$

Distribuzione Binomiale con: $N \gg 1$
 $p \ll 1$

Valore atteso: $\mu = \lambda$




1	27	29	22	31	30	26	28	30	28	26
0.9	33	24	32	28	27	23	32	27	37	33
0.8	29	28	32	22	30	30	35	25	44	29
0.7	30	33	33	27	27	26	39	33	27	31
0.6	41	23	29	36	27	30	30	28	25	31
0.5	22	41	36	24	25	33	30	37	37	42
0.4	32	27	31	20	32	35	35	30	19	44
0.3	30	22	29	38	26	28	27	30	32	34
0.2	37	33	26	26	32	24	35	23	31	28
0.1	33	32	30	26	24	19	27	24	36	43
0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1

1	27	29	22	31	30	26	28	30	28	26
0.9	33	24	32	28	27	23	32	27	37	33
0.8	29	28	32	22	30	30	35	25	44	29
0.7	30	33	33	27	27	26	39	33	27	31
0.6	41	23	29	36	27	30	30	28	25	31
0.5	22	41	36	24	25	33	30	37	37	42
0.4	32	27	31	20	32	35	35	30	19	44
0.3	30	22	29	38	26	28	27	30	32	34
0.2	37	33	26	26	32	24	35	23	31	28
0.1	33	32	30	26	24	19	27	24	36	43
0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1

CAT.	n _i	f _i		
	19	2	0.02	
STATISTICHE	20	1	0.01	
MASSIMO	44	21	0	0.00
MINIMO	19	22	4	0.04
MEDIA	30	23	3	0.03
VARIANZA	28.85	24	5	0.05
DEV.ST.	5.371	25	3	0.03
	26	7	0.07	
	27	10	0.10	
	28	7	0.07	
	29	5	0.05	
	30	12	0.12	
	31	5	0.05	
	32	8	0.08	
	33	8	0.08	
	34	1	0.01	
	35	4	0.04	
	36	3	0.03	
	37	4	0.04	
	38	1	0.01	
	39	1	0.01	
	40	0	0.00	
	41	2	0.02	
	42	1	0.01	
	43	1	0.01	
	44	2	0.02	
Totale	100	1		

STATISTICHE		STATISTICHE	
MASSIMO	41	MASSIMO	44
MINIMO	22	MINIMO	23
MEDIA	29.2	MEDIA	30.12
VARIANZA	18.58	VARIANZA	23.03
DEV.ST.	4.311	DEV.ST.	4.799
STATISTICHE		STATISTICHE	
MASSIMO	41	MASSIMO	38
MINIMO	20	MINIMO	19
MEDIA	29.36	MEDIA	28.72
VARIANZA	28.91	VARIANZA	24.71
DEV.ST.	5.376	DEV.ST.	4.971



Globuli_rossi.xls

Distribuzione di Gauss o Normale


$$\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\bar{x})^2}{2\sigma^2}}$$

 \bar{x}

Valor medio

 σ

Dev. standard



$$P(x_1 \leq x \leq x_2) = \int_{x_1}^{x_2} f(x) dx$$

Distribuzioni continue

$$P(x_1 \leq x \leq x_2) = \int_{x_1}^{x_2} f(x)dx$$

probabilità

Densità di
probabilità

$$\bar{x} = \int_{x_1}^{x_2} x f(x)dx$$

$$\sigma^2 = \int_{x_1}^{x_2} (x - \bar{x})^2 f(x)dx$$

$$M_z = \int_{x_1}^{x_2} (x - \bar{x})^z f(x)dx$$

Distribuzione uniforme


$$f(x) = \frac{1}{B - A} \quad A \leq x \leq B$$

$$\bar{x} = \frac{B + A}{2}$$

$$\sigma^2 = \frac{|B - A|^2}{12}$$

I risultati di un esperimento sono variabili aleatorie.

Un esperimento non consente di esaminare ogni elemento di una popolazione o di effettuare tutte le misure possibili.



Teorema del limite centrale

La distribuzione delle medie campionari ($\langle x \rangle_i$) segue una distribuzione normale indipendentemente dalla distribuzione della popolazione d'origine

Il valor medio della distribuzione delle media campionarie è uguale alla media della popolazione d'origine

La deviazione standard dell'insieme di tutte le medie campionarie (errore standard della media $\sigma_{\bar{x}}$) è una funzione della deviazione standard della popolazione originaria e del numero di elementi del campione.

$$\frac{1}{\sqrt{2\pi\sigma_{\bar{x}}^2}} e^{-\frac{(\bar{x}_i - \mu)^2}{2\sigma_{\bar{x}}^2}}$$

nota: dev.st.
della popolazione

$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{m}}$$

Dato un campione n estratto da una popolazione N è possibile fornire una stima $(\langle x \rangle, s)$ dei parametri reali della distribuzione (m, s) .

I risultati ottenuti su un campione rappresentano una stima dei valori "veri"

I valori stimati sono variabili aleatorie

Quanto sono accurate queste stime?

Popolazione

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i = \sum_{k=1}^{n_c} x_k p(x_k)$$

Valore atteso (media)

Varianza

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 = \sum_{k=1}^{n_c} p(x_k) (x_k - \mu)^2$$

Campione

$$\bar{x} = \frac{1}{m} \sum_{j=1}^m x_j = \sum_{k=1}^{n_c} x_k f(x_k)$$

Media campionaria

Varianza campionaria

$$s^2 = \frac{1}{m-1} \sum_{j=1}^m (x_j - \bar{x})^2$$

L'errore standard della media

$$\sigma_{\bar{x}}$$

indica il grado di incertezza da associare alla stima della media ottenuta utilizzando un campione dell'intera popolazione

Accuratezza delle stime

Il valor medio ottenuto da un solo campione di **m** elementi è una stima del valore aspettato della popolazione.

L'errore standard della media rappresenta una stima dell'errore fatto nella stima del valore atteso.

$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{m}} \sim \frac{s}{\sqrt{m}}$$

Risultato di un'osservazione:

$$\bar{x} \pm \sigma_{\bar{x}}$$

Accuratezza delle stime

Per migliorare la stima del valore atteso si può ripetere l'esperimento utilizzando K campioni indipendenti

In questo caso la migliore stima del valore atteso è la media delle medie campionarie:

$$\bar{x} = \frac{1}{K} \sum_{i=1}^K \bar{x}_i$$


Utilizzando K campioni indipendenti l'errore standard della media è:

$$\sigma_{\bar{x}}^2 = \frac{1}{K} \sum_{i=1}^K (\bar{x}_i - \bar{x})^2$$

Risultato di un'osservazione:

$$\bar{x} \pm \sigma_{\bar{x}}$$


Proprietà della distribuzione di Gauss



$$\int_{\mu-\sigma}^{\mu+\sigma} g(x)dx = 0.68$$

$$\int_{\mu-2\sigma}^{\mu+2\sigma} g(x)dx = 0.95$$

$$\int_{\mu-3\sigma}^{\mu+3\sigma} g(x)dx = 0.997$$



Date due variabili aleatorie indipendenti X_a, X_b caratterizzate da $\mu_a, \sigma_a, \mu_b, \sigma_b$, la variabile $Z = X_a + X_b$ è una variabile aleatoria con:

$$\mu_z = \mu_a + \mu_b$$

$$\sigma_z = \sigma_a + \sigma_b$$

Teorema del limite centrale

La distribuzione delle medie campionarie \bar{x} su campioni di m elementi segue una distribuzione **normale** indipendentemente dalla distribuzione della popolazione d'origine

$$\frac{1}{\sqrt{2\pi\sigma_{\bar{x}}^2}} e^{-\frac{(\bar{x}_i - \mu)^2}{2\sigma_{\bar{x}}^2}}$$

La variabile: $t = \frac{\bar{x} - \mu}{\sigma_{\bar{x}}}$

è una variabile aleatoria che, per m molto grande, ha una distribuzione Normale Standard (ha media nulla e varianza unitaria):

$$g(t) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$$

Confidenza

Pb.: un'osservazione su un campione di m elementi fornisce come risultato il valor medio \bar{x} di una variabile aleatoria.

1) costruisco una variabile aleatoria con distribuzione nota, es.:


$$t = \frac{\bar{x} - \mu}{\sigma_{\bar{x}}}$$

$$g(t) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$$

2) sulla base della $g(t)$ determino i valori di t che hanno una bassa probabilità di essere osservati, cioè:

- fisso un livello di confidenza α .
- determino un intervallo di valori $t_{\alpha_1} - t_{\alpha_2}$ (intervallo di confidenza) tale che la probabilità di osservare t all'esterno dell'intervallo dato sia minore di α

$$P(t < \alpha) = P(t < t_1) + P(t > t_2) = \int_{-\infty}^{t_1} g(t)dt + \int_{t_2}^{\infty} g(t)dt = \alpha$$



Se $t_1 < t < t_2$ la probabilità di osservare il valore di t , calcolato in base ai dati, è $(1-\alpha)$

Se $t < t_1$ o $t > t_2$ la probabilità di osservare il valore di t , calcolato in base ai dati, è α

$$P(t > \alpha) = P(t_1 < t < t_2) = \int_{t_1}^{t_2} g(t)dt = 1 - \alpha$$

probabilità che t appartenga all'intervallo $t_1 - t_2$

$$t = \frac{\bar{x} - \mu}{\sigma_{\bar{x}}}$$

$$P(t_1 < t < t_1) = P(\bar{x} - \sigma_{\bar{x}}t_1 < \mu < \bar{x} + \sigma_{\bar{x}}t_1) = 1 - \alpha$$

dato il valore medio \bar{x} , osservato su un campione di **m** elementi, il valore aspettato della popolazione (μ) è contenuto nell'intervallo:

$$[\bar{x} - \sigma_{\bar{x}}t_1; \bar{x} + \sigma_{\bar{x}}t_1]$$

con probabilità $1-\alpha$.

Se le osservazioni sono distribuite con:

$$\begin{array}{l} \text{valor medio } \bar{x} \\ \text{dev.st. } \sigma_{\bar{x}} = \frac{\sigma}{\sqrt{m}} \end{array}$$

funzione EXCEL:

CONFIDENZA(α , dev.st, m)

Intervalli di confidenza: varianza nota

Se le osservazioni sono distribuite con:

$$\begin{array}{l} \text{valor medio } \bar{x} \\ \text{dev.st. } \sigma_{\bar{x}} = \frac{\sigma}{\sqrt{m}} \end{array}$$

funzione EXCEL: **CONFIDENZA**(α , dev.st, m)

La resistenza elettrica di un cavo viene misurata con uno strumento che ha un'incertezza $\sigma=0.5 \Omega$. Vengono effettuate 5 misure, ne risulta un valor medio $\bar{R}=4.52 \Omega$

$$\text{CONFIDENZA}(0.05, 0.5, 5)=0.438$$

La resistenza vera del cavo è nell'intervallo :

$$R = 4.52 \pm 0.44 \Omega \quad \text{oppure:} \quad R = [4.08, 4.96]$$

Nota: α rappresenta il rischio di sbagliare, cioè la probabilità che il valore vero della resistenza sia esterno all'intervallo dato

Intervalli di confidenza: varianza campionaria

Molto piú spesso non conosco la varianza della distribuzione. La migliore stima della varianza in un campione di m elementi è:

$$\sigma_{\bar{x}} = \frac{s}{\sqrt{m}}$$

da cui: $t = \frac{\bar{x} - \mu}{\sqrt{s^2/m}}$

$$P\left(\bar{x} - t_1 \frac{s}{\sqrt{m}} < \mu < \bar{x} + t_1 \frac{s}{\sqrt{m}}\right) = 1 - \alpha$$

probabilità che il valore vero (μ) sia nell'intervallo:

$$\left[\bar{x} - t_1 \frac{s}{\sqrt{m}}; \bar{x} + t_1 \frac{s}{\sqrt{m}}\right]$$

funzione EXCEL: $\text{INV.T}(\alpha, m-1) = t_1 \frac{s}{\sqrt{m}}$.

Nota: la variabile t così definita ha una distribuzione nota (t-Student) con $v = m-1$ gradi di libertà. La t-Student approssima una distribuzione Gaussiana per v che tende a infinito

Una misura dell'altezza di un gruppo di 20 studenti fornisce il valore medio: $H = 1.68$ m con la deviazione standard stimata $s = 9$ cm.

Determinare l'intervallo di confidenza dell'1%

Dati			
numero di osservazioni: m		20	
valor medio		1.68	
dev. standard: s		0.09	
Confidenza	α	0.01	
	t_a	2.86	
μ	1.68	\pm	0.06

inv.T(α ; m-1)

$$t_{\alpha} \frac{s}{\sqrt{m}}$$

valore medio

Test di ipotesi, test statistici

1) ipotesi da verificare

Es.: il valore misurato è compatibile con il valore vero?

2) costruisco una variabile aleatoria con distribuzione nota, es.:


$$t = \frac{\bar{x} - \mu}{\sigma_{\bar{x}}}$$

$$g(t) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$$

3) sulla base della $g(t)$ determino i valori di t che hanno una bassa probabilità di essere osservati, fissando il livello di confidenza α . Se, in base alla distribuzione scelta, il valore osservato fornisce un valore di t con bassa probabilità di essere osservato, l'ipotesi deve essere rifiutata, altrimenti può essere accettata.

$$P(t < \alpha) = P(t < t_1) + P(t < t_1) = \int_{-\infty}^{t_1} g(t)dt + \int_{t_2}^{\infty} g(t)dt = \alpha$$

$$P(t > \alpha) = P(t_1 < t < t_1) = \int_{t_1}^{t_2} g(t)dt = 1 - \alpha$$



~~Se $t_1 < t < t_2$ il risultato (cui è associato il valore t) è compatibile l'ipotesi fatta con una probabilità del $P = (1-\alpha)$~~

Se $t < t_1$ o $t > t_2$ il risultato (cui è associato il valore t) non è compatibile l'ipotesi fatta con una probabilità del $P = (1-\alpha)$

Nota: α rappresenta la probabilità di sbagliare e scartare un'ipotesi corretta.