

STATISTICA DESCRITTIVA BIVARIATA

Si parla di Analisi Multivariata quando su ogni unità statistica, appartenente ad una determinata popolazione, si rileva un certo numero s di caratteri $X_1, X_2, \dots, X_s$.

Si parla di Analisi **Bivariata** quando su ogni unità statistica, appartenente ad una determinata popolazione, si rilevano due caratteri X e Y .

Può trattarsi di due caratteri qualitativi (ovvero mutabili), o di due caratteri quantitativi (ovvero variabili), oppure di un carattere qualitativo e di un carattere quantitativo.

Distribuzione bivariata semplice

X	x_1	x_2	...	x_i	...	x_n
Y	y_1	y_2	...	y_i	...	y_n

Distribuzione bivariata doppia o congiunta: TABELLA A DOPPIA ENTRATA (TABELLA DI CONTINGENZA)

X	Y						
	Y_1	Y_2	...	Y_j	...	Y_h	
X_1	f_{11}	f_{12}	...	f_{1j}	...	f_{1h}	$f_{1\bullet}$
X_2	f_{21}	f_{22}	...	f_{2j}	...	f_{2h}	$f_{2\bullet}$
:	:	:		:		:	:
:	:	.		:		:	:
X_i	f_{i1}	f_{i2}	...	f_{ij}	...	f_{ih}	$f_{i\bullet}$
:	:	:		:		:	:
:	:	:		:		:	:
X_k	f_{k1}	f_{k2}	...	f_{kj}	...	f_{kh}	$f_{k\bullet}$
	$f_{\bullet 1}$	$f_{\bullet 2}$	...	$f_{\bullet j}$	...	$f_{\bullet h}$	N

f_{ij} **FREQUENZA CONGIUNTA ASSOLUTA**: è il numero delle volte con cui la coppia di modalità (x_i, y_j) si presenta, ovvero la frequenza con la quale, su di un'unità statistica, il carattere X assume la modalità x_i e contemporaneamente il carattere Y assume la modalità y_j .

$f_{i\bullet} = \sum_{j=1}^k f_{ij}$ Frequenza assoluta MARGINALE per Riga (: riferita alla riga i-ma):

esprime la frequenza della modalità i-ma del carattere X per riga, senza tener conto delle modalità dell'altro carattere Y.

$f_{\bullet j} = \sum_{i=1}^h f_{ij}$ Frequenza assoluta MARGINALE per Colonna (: riferita alla colonna j-

ma): esprime la frequenza della modalità j-ma del carattere Y per colonna, senza tener conto delle modalità dell'altro carattere X.

Da cui vale la seguente uguaglianza:

$$N = \sum_{j=1}^k \sum_{i=1}^h f_{ij} = \sum_{i=1}^h f_{i\bullet} = \sum_{j=1}^k f_{\bullet j}$$

Distribuzione marginale o **Distribuzione univariata del carattere X**: data una distribuzione doppia di frequenze relativa alla rilevazione di N unità statistiche, si definisce distribuzione marginale del carattere X la distribuzione statistica semplice delle N unità statistiche secondo il carattere X.

X	f(x)
X_1	$f_{1\bullet}$
...	...
X_i	$f_{i\bullet}$
...	...
X_k	$f_{k\bullet}$
	N

Distribuzione marginale o **Distribuzione univariata del carattere Y**: data una distribuzione doppia di frequenze relativa alla rilevazione di N unità statistiche, si definisce distribuzione marginale del carattere Y la distribuzione statistica semplice delle N unità statistiche secondo il carattere Y.

Y	f(y)
Y_1	$f_{\bullet 1}$
...	...
Y_j	$f_{\bullet j}$
...	...
Y_h	$f_{\bullet h}$
	N

f_{ij}^R FREQUENZA CONGIUNTA **RELATIVA**: è la proporzione dei casi in cui, su una popolazione di N unità statistiche, la coppia di modalità (x_i, y_j) si presenta:

$$f_{ij}^R = \frac{f_{ij}}{N}$$

$$\sum_{j=1}^h \sum_{i=1}^k f_{ij}^R = 1$$

NOTAZIONE

Frequenza congiunta assoluta f_{ij} (*notazione Cicchitelli* n_{ij})

Frequenza assoluta MARGINALE per Riga $f_{i\bullet}$ (*notazione Cicchitelli* n_{i0})

Frequenza assoluta MARGINALE per Colonna $f_{\bullet j}$ (*notazione Cicchitelli* n_{0j})

ESEMPIO

Si analizzano 1000 famiglie secondo la variabile $X = \text{numero di auto possedute dalla famiglia}$ e $Y = \text{numero di componenti della famiglia}$. I risultati di tale rilevazione sono raccolti nella seguente Tabella a doppia entrata:

X	Y				
	1	2	3	4	5
0	10	20	20	150	50
1	85	85	330	50	50
2	5	85	10	0	0
3	0	10	40	0	0

X	Y					
	1	2	3	4	5	
0	10	20	20	150	50	250
1	85	85	330	50	50	600
2	5	85	10	0	0	100
3	0	10	40	0	0	50
	100	200	400	200	100	1000

Distribuzioni univariate:

X	f(x)
0	250
1	600
2	100
3	50
	1000

Y	f(y)
1	100
2	200
3	400
4	200
5	100
	1000

Tabella a doppia entrata di Frequenze congiunte **relative**:

X	Y					
	1	2	3	4	5	
0	0,01	0,02	0,02	0,15	0,05	0,25
1	0,085	0,085	0,33	0,05	0,05	0,6
2	0,005	0,085	0,01	0	0	0,1
3	0	0,01	0,04	0	0	0,05
	0,1	0,2	0,4	0,2	0,1	1

Distribuzioni univariate relative:

X	$f^R(x)$
0	0,25
1	0,60
2	0,10
3	0,05
	1,00

Y	$f^R(y)$
1	0,1
2	0,2
3	0,4
4	0,2
5	0,1
	1,0

DISTRIBUZIONI CONDIZIONATE

La Distribuzione CONDIZIONATA di X dato y_j (carattere CONDIZIONATO $X/Y=y_j$) si ottiene fissando una modalità y_j per il carattere Y ed esaminando la distribuzione di X limitatamente alle unità statistiche che possiedono quella modalità y_j per il carattere Y :

$X/Y=y_j$	frequenze	
	assolute	relative
X_1	f_{1j}	$f_{1j}/f_{\bullet j}$
...	...	...
X_i	f_{ij}	$f_{ij}/f_{\bullet j}$
...	...	...
X_k	f_{kj}	$f_{kj}/f_{\bullet j}$
	$f_{\bullet j}$	1

(per ogni j , con $j=1, \dots, h$)

La Distribuzione CONDIZIONATA di Y dato x_i (carattere CONDIZIONATO $Y/X=x_i$) si ottiene fissando una modalità x_i per il carattere X ed esaminando la distribuzione di Y limitatamente alle unità statistiche che possiedono quella modalità x_i per il carattere X :

$Y/X=x_i$	frequenze	
	assolute	relative
Y_1	f_{i1}	$f_{i1}/f_{i\bullet}$
...	...	...
Y_j	f_{ij}	$f_{ij}/f_{i\bullet}$
...	...	...
Y_h	f_{ih}	$f_{ih}/f_{i\bullet}$
	$f_{i\bullet}$	1

(per ogni i , con $i=1, \dots, k$)

Esempio di distribuzione condizionata (v. esempio precedente di tabella a doppia entrata):

X/Y=2	frequenze	
	assolute	relative
0	20	0,100
1	85	0,425
2	85	0,425
3	10	0,050
	200	1,000

Y/X=1	frequenze	
	assolute	relative
1	85	0,14167
2	85	0,14167
3	330	0,55000
4	50	0,08333
5	50	0,08333
	600	1

*Media aritmetica della **SOMMA** di 2 o più variabili statistiche*

Siano $X_1, X_2, \dots, X_s$ delle variabili statistiche costituite ognuna da n determinazioni, di media, rispettivamente $m_1, m_2, \dots, m_s$, e sia

$$Z = X_1 + X_2 + \dots + X_s$$

la loro somma.

La media della SOMMA risulta uguale alla somma delle medie dei singoli addendi:

$$M(z) = M(x_1) + M(x_2) + \dots + M(x_s) = m_1 + m_2 + \dots + m_s$$

ESERCIZIO

Sui seguenti dati:

X	Y			
	2	3	4	5
0	100	40	20	0
1	50	200	870	30
2	10	10	500	170

Determinare la variabile $Z = X + Y$. Di essa:

- presentare la distribuzione di probabilità;
- calcolare la media di Z e verificare le relazione che lega la media della somma alle medie degli addendi;

SOLUZIONI

a)

z	$f(z)$	$p(z)$	$z \cdot f(z)$
2	100	0,050	200
3	90	0,045	270
4	230	0,115	920
5	880	0,440	4400
6	530	0,265	3180
7	170	0,085	1190
	2000	1,000	10160

b) $M(z)=10160/2000=5,08$

x	f(x)	x*f(x)	y	f(y)	y*f(y)
0	160	0	2	160	320
1	1150	1150	3	250	750
2	690	1380	4	1390	5560
	2000	2530	5	200	1000
				2000	7630

$M(x)=2530/2000=1,265$

$M(y)=7630/2000=3,815$

$M(z)=5,08=M(x)+M(y)= 1,265+3,815=5,08$

Varianza della SOMMA di due o più variabili statistiche

Siano $X_1, X_2, \dots, X_s$ delle variabili statistiche costituite ognuna da n determinazioni, di media e varianza, rispettivamente $m_1, m_2, \dots, m_s$, e $\sigma_1^2, \sigma_2^2, \dots, \sigma_s^2$, sia

$$Z = X_1 + X_2 + \dots + X_s$$

la loro somma.

La varianza della somma risulta uguale a

$$V(z) = \sigma_1^2 + \sigma_2^2 + \dots + \sigma_s^2 + 2 \sum_{i=1}^{s-1} \sum_{j=i+1}^s \text{Cov}(x_i, x_j)$$

Dove il simbolo $\sum_{i=1}^{s-1} \sum_{j=i+1}^s \text{Cov}(x_i, x_j)$ indica la somma di tutte le

$$\binom{s}{2} = \frac{s!}{2!(s-2)!}$$

Covarianze ottenibili associando fra di loro s variabili prese 2 a 2.

ESERCIZIO (Variabile SOMMA)

Le famiglie di un Comune sono state classificate secondo i caratteri **X** n. di viaggi all'estero e **Y** n. di viaggi in Italia. I risultati sono i seguenti:

X	Y		
	0	2	4
0	30	20	10
1	30	100	20
3	0	10	180

- a) definire la variabile somma $Z = X + Y$ e dare la distribuzione di frequenze di **Z**.
- b) Verificare la relazione esistente fra la media della somma e le medie delle variabili;
- c) Verificare la relazione esistente fra la varianza della somma e le varianze delle variabili.

SOLUZIONI

a)

z	f(z)
0	30
1	30
2	20
3	100
4	10
5	30
7	180
	400

b)

z	f(z)	$z \cdot f(z)$
0	30	0
1	30	30
2	20	40
3	100	300
4	10	40
5	30	150
7	180	1260
	400	1820

$$M(z) = 1820/400 = 4,55$$

X	f(x)	x*f(x)
0	60	0
1	150	150
3	190	570
	400	720

y	f(y)	y*f(y)
0	60	0
2	130	260
4	210	840
	400	1100

$$M(x)=720/400=1,8$$

$$M(y)=1100/400=2,75$$

$$M(z)= M(x)+M(y)=1,8+2,75=4,55$$

c)

z	f(z)	z*f(z)	z ² *f(z)
0	30	0	0
1	30	30	30
2	20	40	80
3	100	300	900
4	10	40	160
5	30	150	750
7	180	1260	8820
	400	1820	10740

$$\text{Var}(z)=10740/400-(4,55)^2=26,85-20,7025=6,1475$$

$$\text{Var}(z)= \text{V}(x)+\text{V}(y)+2*\text{Cov}(x,y)$$

X	f(x)	x*f(x)	x ² *f(x)
0	60	0	0
1	150	150	150
3	190	570	1710
	400	720	1860

$$\text{Var}(x)=1860-(1,8)^2=1,41$$

y	f(y)	y*f(y)	y ² *f(y)
0	60	0	0
2	130	260	520
4	210	840	3360
	400	1100	3880

$$\text{Var}(y)=3880/400-(2,75)^2=2,1375$$

$$\text{Cov}(x,y)=M(x*y)-M(x)*M(y)$$

$x*y$	f_{xy}	$x*y*f_{xy}$
0	90	0
2	100	200
4	20	80
6	10	60
12	180	2160
	400	2500

$$M(x*y)=2500/400=6,25$$

$$Cov(x,y)=6,25-(1,8)*(2,75)=1,3$$

$$\mathbf{Var(z)= V(x)+V(y)+2*Cov(x,y)=1,41+2,1375+2*1,3=6,1475 \text{ (c.v.d)}}$$

*Media aritmetica del **PRODOTTO** di 2 variabili statistiche*

Sia X una variabile di media $M(x)=m_x$ e Y una variabile di media $M(y)=m_y$. Sia $Z=X \cdot Y$ la *variabile PRODOTTO* delle due variabili.

La media aritmetica di Z risulta:

$$M(Z) = M(X \cdot Y) = m_x \cdot m_y + Cov(x, y)$$

ESERCIZIO (Variabile PRODOTTO)

Date le variabili X e Y, calcolare la media del prodotto $Z=X \cdot Y$.

X	Y
1	8
2	7
3	6
4	5
5	4

Metodo diretto di calcolo:

X	Y	Z
1	8	8
2	7	14
3	6	18
4	5	20
5	4	20
		80

$$M(Z)=80/5=16$$

Metodo indiretto di calcolo:

X	Y	$x-m_x$	$y-m_y$	$(x-m_x)(y-m_y)$
1	8	-2	2	-4
2	7	-1	1	-1
3	6	0	0	0
4	5	1	-1	-1
5	4	2	-2	-4
15	30			-10

$$M(x)=15/5=3$$

$$M(y)=30/5=6$$

$$M(z)=3*6+(-10/5)=18-2=16$$