

## Lezione n. 3 (a cura di Ubaldi Marica)

### NORMALE MULTIVARIATA

E' l'unica distribuzione relativa alle variabili casuali multiple.

Una VARIABILE CASUALE MULTIPLA può essere indicata con il vettore  $\underline{X} = (X_1, X_2, \dots, X_n)$  contenente n elementi di variabili casuali semplici.

I singoli valori sono dati dal vettore  $\underline{x} = (x_1, x_2, \dots, x_n)$

Il 1° aspetto da considerare è la FUNZIONE DI DENSITA', che può essere scritta come:

$f(x_1, x_2, \dots, x_n) = f(\underline{x})$  calcolata in un certo valore x.

La formula rappresenta un'estensione della funzione di densità della Normale:

$$f(\underline{x}) = \frac{1}{\sqrt{|2\pi \Sigma|}} \cdot e^{-\frac{1}{2}(\underline{x}-\underline{\mu})^T \Sigma^{-1}(\underline{x}-\underline{\mu})} \quad \text{dove:}$$

$$\bullet \quad \underline{\mu} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_n \end{pmatrix} \quad \text{è un vettore } n \times 1 \text{ variabili e gli elementi sono le medie delle singole variabili.}$$

$$\bullet \quad \Sigma = \begin{pmatrix} \text{Var}(X_1) & \text{Cov}(X_1, X_2) & \dots & \text{Cov}(X_1, X_n) \\ \text{Cov}(X_2, X_1) & \text{Var}(X_2) & \dots & \text{Cov}(X_2, X_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(X_n, X_1) & \dots & \dots & \text{Var}(X_n) \end{pmatrix}$$

è la matrice VARIANZA –COVARIANZA di dimensione  $n \times n$ .

Proprietà della matrice:

- *Quadrata*: ha lo stesso numero di righe e di colonne
- *Simmetrica*: poiché non dipende dall'ordine degli elementi. La  $\text{Cov}(X_i, X_j) = \text{Cov}(X_j, X_i)$
- *È sempre definita positiva*

Def: Una matrice si dice definita positiva quando:

$$\underbrace{a^T \Sigma a}_{\text{forma\_quadratica}} > 0, \quad \forall a \neq 0$$

Es:

$$\underline{X} = \begin{pmatrix} X_1 \\ X_n \end{pmatrix} \quad \text{con } n=2, \quad X_1=\text{altezza}, \quad X_2=\text{peso}$$

Scrivendo  $\underline{X} \sim N_2(\underline{\mu}, \Sigma)$  si può imporre che  $\underline{\mu} = \begin{pmatrix} 175 \\ 70 \end{pmatrix}$  e  $\Sigma = \begin{pmatrix} 50 & 20 \\ 20 & 30 \end{pmatrix}$  allora:

$$\rho = \frac{20}{\sqrt{50 \cdot 30}} > 0$$

La condizione di "sempre definita positiva" implica che le varianze sulla diagonale di  $\Sigma$  siano positive.

Confrontiamo la formula sopra di  $f(\underline{x})$  con la formula della densità della normale:

$$f(\underline{x}) = \frac{1}{\sqrt{|2\pi \Sigma|}} \cdot e^{-\frac{1}{2}(\underline{x}-\underline{\mu})' \Sigma^{-1}(\underline{x}-\underline{\mu})}$$

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

Considerando i vettori:  $\underline{x} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$ ,  $\underline{\mu} = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}$   $\underline{x} - \underline{\mu} = \begin{pmatrix} x_1 - \mu_1 \\ x_2 - \mu_2 \end{pmatrix}$

Per la forma quadratica:

$$\begin{aligned} & \begin{pmatrix} x_1 - \mu_1 & x_2 - \mu_2 \end{pmatrix} \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \begin{pmatrix} x_1 - \mu_1 \\ x_2 - \mu_2 \end{pmatrix} = \\ & = \begin{pmatrix} (x_1 - \mu_1)a_{11} + (x_2 - \mu_2)a_{21} & (x_1 - \mu_1)a_{12} + (x_2 - \mu_2)a_{22} \end{pmatrix} \begin{pmatrix} x_1 - \mu_1 \\ x_2 - \mu_2 \end{pmatrix} = \\ & = (x_1 - \mu_1)^2 a_{11} + (x_2 - \mu_2)(x_1 - \mu_1)a_{21} + (x_1 - \mu_1)(x_2 - \mu_2)a_{12} + (x_2 - \mu_2)^2 a_{22} \end{aligned}$$

PROPRIETA':

1)  $\Sigma$  è **DIAGONALE**: ha elementi =0 fuori dalla diagonale

$$\Sigma = \begin{pmatrix} 50 & 0 \\ 0 & 30 \end{pmatrix}$$

Allora  $Cov(X_j, X_j) = 0$  per  $\forall i, j$  e le variabili di  $\Sigma$  sono *incorrelate e indipendenti*.

Pur essendo concetti diversi, in caso di normale multivariata non c'è differenza tra indipendenza ed incorrelazione.

2)  $X \sim N(\underline{\mu}, \Sigma) \Rightarrow X_i \sim N(\mu_i, \sigma_{ii})$ ,  $\forall_j$ .

Ciò vuol dire che se la normale multivariata "è vera", ogni variabile ha distribuzione Normale e posso ricavare direttamente la distribuzione marginale.

3) Considerando le *distribuzioni condizionate*  $X_2 | X_1 = 180 \sim N(\mu_2^*, (\sigma^2)^*)$

4) Date n variabili, la *combinazione lineare* è:

$$Y = a_1 X_1 + a_2 X_2 + \dots + a_n X_n = \underline{a}' \underline{X} \text{ (generale)}$$

utilizzando la nozione matriciale, si ha:

$$Y = \underline{a}' \underline{X} \text{ dove } \underline{a} = \begin{pmatrix} a_1 \\ a_2 \\ \cdot \\ a_n \end{pmatrix}$$

Ritornando a livello generale:

$$X \sim N(\underline{a}' \underline{\mu}, \underline{a}' \underline{\Sigma} \underline{a})$$

Ogni combinazione lineare di variabili casuali normali ha ancora distribuzione normale.

## CONCETTI DI INFERENZA STATISTICA

Si è interessati ad una variabile  $X$  (es. reddito) con una certa distribuzione nella popolazione di riferimento:  $X \sim f(x, \theta)$  dove  $\theta$  è il parametro.

Il problema dell'inferenza è che si conosce la distribuzione ma non il parametro.

Si procede estraendo un campione dalla popolazione e si fa inferenza attribuendo un valore a  $\theta$  (metodo della stima puntuale).

Vi sono 3 metodi per effettuare l'inferenza:

- Stima puntuale
- Stima per intervallo
- Verifica per ipotesi

### METODO DELLA STIMA PUNTUALE

Si assegna un unico valore a  $\theta$  applicando una certa formula ai dati del campione (es. media):

$T = t(X_1, X_2, \dots, X_n)$  dove  $T =$  stimatore

Critero di massima verosimiglianza:

è un metodo generale per costruire uno stimatore di  $\sigma$ .

Questo si basa sulla *funzione di verosimiglianza*:

$$L(\theta) = \prod_i f(x_i; \theta)$$

è la probabilità o densità del campione osservato vista come funzione di  $\theta$ .

Non è altro che una misura di evidenza fornita dal campione a favore di ogni valore di  $\theta$ .

### **Esempio:**

Se  $L(\theta_1) > L(\theta_2) \Rightarrow \theta_1$  è più plausibile/attendibile di  $\theta_2$

$X \sim \text{Bernulli}(p)$  con  $\theta = p$

$$X = \begin{cases} 0, 1-p \\ 1, p \end{cases} \quad f(x, p) = p^x (1-p)^{1-x}$$

La verosimiglianza sarà:

$$L(p) = \prod_i p^{x_i} (1-p)^{(1-x_i)} = p^{\sum_i x_i} (1-p)^{\sum_i (1-x_i)} = p^s (1-p)^{n-s} \quad \text{con } S = \sum_i x_i$$

Es: Si considera un campione  $n=100$  (0,0,1,0,1...)

$S=25$  (tra i 100 studenti almeno 25 hanno sostenuto più di 5 esami il 1° anno di università)

Se, osservando 2 valori,  $L(0,5) > L(0,7)$  allora il valore più plausibile è 0,5.

Il valore più plausibile in assoluto:

$\max_{\theta} L(\theta) \rightarrow$  il valore corrispondente è  $\hat{\theta} =$  STIMATORE DI MASSIMA VEROSIMIGLIANZA

Per trovare  $\hat{\theta}$  si deve risolvere il problema di ottimizzazione attraverso le seg. fasi:

1) Passo dalla verosimiglianza alla log-verosimiglianza :

$$l(\theta) = \log L(\theta) = \sum_i \log f(x_i; \theta)$$

2) Calcolo la derivata prima e la pongo =0:  $\frac{d}{d\theta} l(\theta) = 0$

- 3) Verifico che è un punto di max; calcolando la derivata seconda e osservando che sia negativa:

$$\frac{d^2}{d\theta^2} l(\theta) < 0$$

Esempio:  $L(p) = p^s (1-p)^{n-s}$

1)  $l(p) = S \log(p) + (n-S) \log(1-p)$

2)  $\frac{d}{dp} l(p) = \frac{s}{p} - \frac{n-S}{1-p} = \frac{S(1-p) - p(n-S)}{p(1-p)} = \frac{s-pn}{p(1-p)} = 0$

Il denominatore lo posso trascurare poiché sempre positivo e avrò:

$S - pn = 0 \Rightarrow p = \frac{S}{n}$  è un punto di ottimo, ora per capire se è min o max facciamo la derivata seconda.

3)  $\frac{d^2}{dp^2} l(p) = -\frac{S}{p^2} - \frac{n-S}{(1-p)^2} < 0$  è sempre negativo quindi è un punto di max.