

INTRODUZIONE ALL'ANALISI DISCRIMINANTE

Concetti preliminari

2) Scomposizione della matrice di Varianze e covarianze.

Si consideri una popolazione suddivisa in 2 gruppi.

$M_1 \Rightarrow$ numero di unità statistiche estratte dal primo gruppo

$M_2 \Rightarrow$ n° di unità statistiche estratte dal 2° gruppo

$$M = M_1 + M_2$$

Sulle n unità statistiche estratte vengono rilevati 2 caratteri: X e Y .

$X_{11}; X_{12}; \dots; X_{1M_1} \Rightarrow$ rilevazione di X sul gruppo 1

$X_{21}; X_{22}; \dots; X_{2M_2} \Rightarrow$ rilevazione di X sul gruppo 2

$Y_{11}; Y_{12}; \dots; Y_{1M_1} \Rightarrow$ rilevazioni di Y sul gruppo 1

$Y_{21}; Y_{22}; \dots; Y_{2M_2} \Rightarrow$ rilevazioni di Y sul gruppo 2.

Come è noto, la varianza di X (σ_x^2) è scomponibile in varianza NEI gruppi ed in varianza FRA i gruppi:

$$\sigma_x^2 = \underbrace{\frac{1}{M} \sum_{g=1}^2 \sigma_{gx}^2 \cdot M_g}_{\text{varianza nei gruppi}} + \underbrace{\frac{1}{M} \sum_{g=1}^2 (\mu_{gx} - \mu_x)^2 M_g}_{\text{varianza fra i gruppi}}$$

Vdr "NEI" gruppi

Vdr "FRA" i gruppi

$$\sigma_{gx}^2 = \frac{1}{m_g} \sum_{i=1}^{m_g} (x_{gi} - \mu_{gx})^2$$

$$\mu_{gx} = \frac{1}{m_g} \sum_{i=1}^{m_g} x_{gi} \quad \mu_x = \frac{1}{n} \sum_{g=1}^2 \mu_{gx} \cdot m_g$$

In maniera analoga si scompone la varianza di Y .

Si consideri ora la covarianza tra i caratteri X e Y .

$$\text{Cov}(X, Y) = \sigma_{xy} = \frac{1}{n} \sum_{g=1}^2 \sum_{i=1}^{m_g} (x_{gi} - \mu_x)(y_{gi} - \mu_y)$$

$$\begin{aligned} & \sum_{i=1}^{m_g} (x_{gi} - \mu_x)(y_{gi} - \mu_y) = \\ &= \sum_{i=1}^{m_g} (x_{gi} - \mu_{gx} + \mu_{gx} - \mu_x)(y_{gi} - \mu_{gy} + \mu_{gy} - \mu_y) \\ &= \sum_{i=1}^{m_g} [(x_{gi} - \mu_{gx}) + (\mu_{gx} - \mu_x)] [(y_{gi} - \mu_{gy}) + (\mu_{gy} - \mu_y)] \\ &= \sum_{i=1}^{m_g} (x_{gi} - \mu_{gx})(y_{gi} - \mu_{gy}) + \sum_{i=1}^{m_g} (x_{gi} - \mu_{gx})(\mu_{gy} - \mu_y) + \\ &+ \sum_{i=1}^{m_g} (\mu_{gx} - \mu_x)(y_{gi} - \mu_{gy}) + \sum_{i=1}^{m_g} (\mu_{gx} - \mu_x)(\mu_{gy} - \mu_y) \\ &= \sum_{i=1}^{m_g} (x_{gi} - \mu_{gx})(y_{gi} - \mu_{gy}) + m_g (\mu_{gx} - \mu_x)(\mu_{gy} - \mu_y) \end{aligned}$$

Di conseguenza:

$$\begin{aligned} \sigma_{xy} &= \frac{1}{m} \sum_{g=1}^2 \left[\sum_{i=1}^{m_g} (x_{gi} - \mu_{gx})(y_{gi} - \mu_{gy}) + m_g(\mu_{gx} - \mu_x)(\mu_{gy} - \mu_y) \right] \\ &= \frac{1}{m} \sum_{g=1}^2 \sum_{i=1}^{m_g} (x_{gi} - \mu_{gx})(y_{gi} - \mu_{gy}) + \frac{1}{m} \sum_{g=1}^2 (\mu_{gx} - \mu_x)(\mu_{gy} - \mu_y) m_g \\ &= \underbrace{\frac{1}{m} \sum_{g=1}^2 \sigma_{gxy} m_g}_{\text{Covarianza nei gruppi}} + \underbrace{\frac{1}{m} \sum_{g=1}^2 (\mu_{gx} - \mu_x)(\mu_{gy} - \mu_y) m_g}_{\text{Covarianza fra i gruppi.}} \end{aligned}$$

L'espressione della varianza tra i gruppi si può notevolmente semplificare. In dettaglio, si ricorrono a:

$$\underline{\mu_x} = \frac{\mu_{1x} m_1 + \mu_{2x} m_2}{m} \quad \text{da cui}$$

$$\bullet \mu_{1x} - \mu_x = \frac{1}{m} \left[\overbrace{(m - m_1)}^{m_2} \mu_{1x} - \mu_{2x} m_2 \right]$$

$$= \frac{m_2}{m} (\mu_{1x} - \mu_{2x}) \quad (\text{risultati analoghi valgono per } y)$$

$$\bullet \mu_{2x} - \mu_x = \frac{m_1}{m} (\mu_{2x} - \mu_{1x})$$

Di conseguenza \curvearrowright VDV "FRÀ".

$$\begin{aligned}
& \frac{1}{n} \sum_{g=1}^m (\mu_{gx} - \mu_x)^2 m_g \\
&= \frac{1}{n} \left[\frac{m_2^2}{n^2} (\mu_{1x} - \mu_{2x})^2 m_1 + \frac{m_1^2}{n^2} (\mu_{2x} - \mu_{1x})^2 m_2 \right] \\
&= \frac{m_1 m_2}{n^3} \left[m_2 (\mu_{1x} - \mu_{2x})^2 + m_1 (\mu_{1x} - \mu_{2x})^2 \right] \\
&= \frac{m_1 m_2}{n^2} (\mu_{1x} - \mu_{2x})^2
\end{aligned}$$

Allo stesso modo si ottiene:

$$\frac{1}{n} \sum_{g=1}^2 (\mu_{gy} - \mu_y)^2 m_g = \frac{m_1 m_2}{n^2} (\mu_{1y} - \mu_{2y})^2$$

Relativamente alla covarianza fra i gruppi si ha:

$$\begin{aligned}
& \frac{1}{n} \left[(\mu_{1x} - \mu_x) (\mu_{1y} - \mu_y) m_1 + (\mu_{2x} - \mu_x) (\mu_{2y} - \mu_y) m_2 \right] = \\
&= \frac{m_1 m_2^2}{n^3} (\mu_{1x} - \mu_{2x}) (\mu_{2y} - \mu_{2y}) + \\
&\quad + \frac{m_1^2 m_2}{n^3} (\mu_{2x} - \mu_{1x}) (\mu_{2y} - \mu_{1y}) = \\
&= \frac{m_1 m_2}{n^2} (\mu_{1x} - \mu_{2x}) (\mu_{1y} - \mu_{2y})
\end{aligned}$$

Ricapitolando:

$$\sigma_x^2 = \frac{1}{n} \left(\sigma_{1x}^2 m_1 + \sigma_{2x}^2 m_2 \right) + \frac{m_1 m_2}{n^2} (\mu_{1x} - \mu_{2x})^2$$

$$\sigma_y^2 = \frac{1}{n} (\sigma_{1y}^2 m_1 + \sigma_{2y}^2 m_2) + \frac{m_1 m_2}{n^2} (\mu_{1y} - \mu_{2y})^2$$

$$\sigma_{xy} = \frac{1}{n} (\sigma_{1xy} m_1 + \sigma_{2xy} m_2) + \frac{m_1 m_2}{n^2} (\mu_{1x} - \mu_{2x})(\mu_{1y} - \mu_{2y})$$

Matrice di Varianze - Covarianze di
X ed Y.

$$S = \begin{bmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{bmatrix} \Rightarrow \text{Scomponibile} \\ \text{algebricamente}$$

$$S = S_w + S_b$$

dove

$$S_w = \frac{m_1}{n} \begin{bmatrix} \sigma_{1x}^2 & \sigma_{1xy} \\ \sigma_{1xy} & \sigma_{1y}^2 \end{bmatrix} + \frac{m_2}{n} \begin{bmatrix} \sigma_{2x}^2 & \sigma_{2xy} \\ \sigma_{2xy} & \sigma_{2y}^2 \end{bmatrix}$$

$$S_b = \frac{m_1 m_2}{n^2} \begin{bmatrix} (\mu_{1x} - \mu_{2x})^2 & (\mu_{1x} - \mu_{2x})(\mu_{1y} - \mu_{2y}) \\ (\mu_{1x} - \mu_{2x})(\mu_{1y} - \mu_{2y}) & (\mu_{1y} - \mu_{2y})^2 \end{bmatrix}$$

$$= \frac{m_1 m_2}{n^2} \begin{bmatrix} \mu_{1x} - \mu_{2x} \\ \mu_{1y} - \mu_{2y} \end{bmatrix} \begin{bmatrix} \mu_{1x} - \mu_{2x} \\ \mu_{1y} - \mu_{2y} \end{bmatrix}^T$$

$$= \frac{m_1 m_2}{m^2} (\underline{\mu}_1 - \underline{\mu}_2) (\underline{\mu}_1 - \underline{\mu}_2)^T$$

dove $\underline{\mu}_i = \begin{bmatrix} \mu_{ix} \\ \mu_{iy} \end{bmatrix}$

È a questo punto possibile generalizzare la scomposizione appena presentata al caso di q variabili.

$$S = \underbrace{S_W}_{q \times q} + \underbrace{\frac{m_1 m_2}{m^2} (\underline{\mu}_1 - \underline{\mu}_2) (\underline{\mu}_1 - \underline{\mu}_2)^T}_{q \times q}$$

dove

$$S_W = \frac{m_1}{m} S_1 + \frac{m_2}{m} S_2$$

$S_i \equiv$ matrice di varianza covarianza delle q variabili rilevate sull' i -esimo gruppo

$\underline{\mu}_i \equiv$ vettore delle medie delle q variabili rilevate sull' i -esimo gruppo.

Osservazione: $\text{Rango}(S_b) = 1$

Concetti preliminari

B) Varianza della somma e Varianza di una combinazione lineare

Siano X_1, \dots, X_q dei caratteri quantitativi che vengono rilevati su n unità statistiche.

Si ottiene così la matrice di dati

$$X_{n \times q} = \begin{bmatrix} X_{11} & X_{12} & \dots & X_{1j} & \dots & X_{1q} \\ \vdots & \vdots & & \vdots & & \vdots \\ X_{i1} & X_{i2} & \dots & X_{ij} & \dots & X_{iq} \\ \vdots & \vdots & & \vdots & & \vdots \\ X_{n1} & X_{n2} & \dots & X_{nj} & \dots & X_{nq} \end{bmatrix}$$

dalla quale si deriva la matrice di varianza-covarianza

$$S = \frac{1}{n} X^T \left[I_n - \frac{1}{n} U_n \right] X$$

dove I_n indica la matrice identità di dimensione $n \times n$ mentre U_n indica la matrice $n \times n$ i cui elementi sono tutti pari ad 1.

Si è interessati ad ottenere la varianza del carattere

$$V = \sum_{i=1}^q X_i$$

Come noto:

$$\sigma^2 = \sum_{i=1}^q \sigma_{X_i}^2 + 2 \sum_{i=1}^q \sum_{j=1}^q \sigma_{X_i X_j}$$

$$\sigma_y^2 = \sum_{i=1}^q \sigma_{x_i}^2 + 2 \sum_{i=1}^q \sum_{j=i+1}^q \sigma_{x_i x_j}$$

$$= \mathbb{1}_q^T S \mathbb{1}_q$$

dove $\mathbb{1}_q$ è il vettore di q i uni elementi sono tutti pari ad 1.

Più in generale, se si è interessati alla varianta di

$$y^* = \sum_{i=1}^q a_i x_i,$$

sfruttando le ben note proprietà della varianta e della covarianza, si ottiene:

$$\sigma_{y^*}^2 = \sum_{i=1}^q a_i^2 \sigma_{x_i}^2 + 2 \sum_{i=1}^q \sum_{j=i+1}^q a_i a_j \sigma_{x_i x_j}$$

$$= a^T S a$$

dove $a = \begin{bmatrix} a_1 \\ \vdots \\ a_i \\ \vdots \\ a_q \end{bmatrix}$.

OSSERVAZIONE: Utilizzando la notazione matriciale, i valori dei caratteri y e y^* corrispondenti alle osservazioni sulle n unità statistiche si ottengono così:

$$Y_{m \times 1} = \underline{X}_{m \times q} \mathbb{1}_q$$

$$Y^*_{m \times 1} = \underline{X}_{m \times q} a \quad |$$

Concetti preliminari

8) Derivazione di una forma quadratica simmetrica.

$S \Rightarrow$ matrice $q \times q$ simmetrica di elementi s_{ij}

$$\begin{aligned} a^T S a &= \sum_{i=1}^q \sum_{j=1}^q a_i a_j s_{ij} \\ &= \sum_{i=1}^q a_i^2 s_{ii} + \sum_{i=1}^q \sum_{\substack{j=1 \\ i \neq j}}^q a_i a_j s_{ij} \\ &= \sum_{i=1}^q a_i^2 s_{ii} + 2 \sum_{i=1}^q \sum_{j=i+1}^q a_i a_j s_{ij} \quad (*) \end{aligned}$$

Si è interessati a ricavare il vettore delle derivate parziali di $a^T S a$ rispetto agli elementi di a :

$$\frac{\partial a^T S a}{\partial a} = \begin{bmatrix} \frac{\partial a^T S a}{\partial a_1} \\ \vdots \\ \frac{\partial a^T S a}{\partial a_i} \\ \vdots \\ \frac{\partial a^T S a}{\partial a_q} \end{bmatrix}$$