

Dall'espressione (*) si ha che:

$$\frac{\partial a^T S a}{\partial a_1} = 2 a_1 s_{11} + 2 \sum_{j=2}^9 a_j s_{1j}$$

$$= 2 \sum_{j=1}^9 a_j s_{1j}$$

Analogamente

$$\frac{\partial a^T S a}{\partial a_k} = 2 a_k s_{kk} + 2 \sum_{j=k+1}^9 a_j s_{kj} + 2 \sum_{i=1}^{k-1} a_i s_{ki}$$

$$= 2 \sum_{j=1}^9 a_j s_{kj}$$



$$\frac{\partial a^T S a}{\partial a} = 2 S a$$

Concetti preliminari

δ) Interpretazione geometrica del prodotto scalare tra due vettori

$$\underline{a} \quad ; \quad \underline{x}$$


$p \times 1$ $p \times 1$

$$|\underline{a}| = \sqrt{\underline{a}^T \underline{a}} = \sqrt{\sum a_i^2}$$

Identità fondamentale

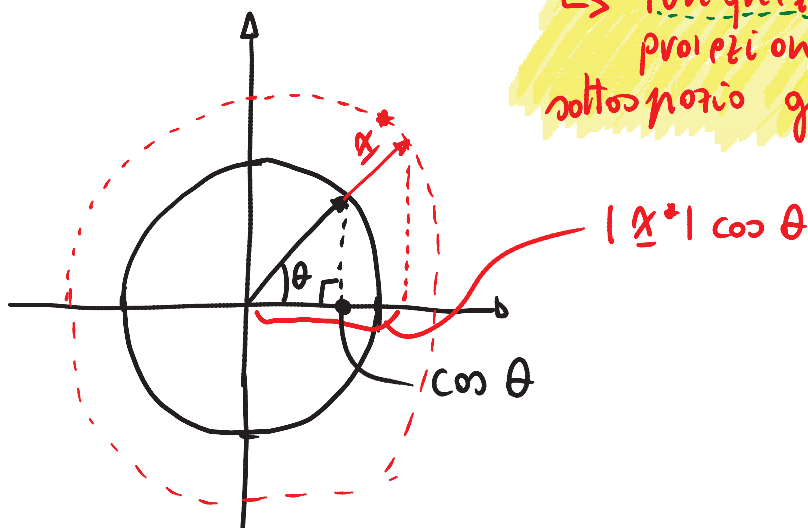
$$\underline{a}^T \underline{x} = \underline{x}^T \underline{a} = |\underline{a}| |\underline{x}| \cos \theta \quad (**)$$

dove θ è l'angolo formato tra i due vettori \underline{a} e \underline{x} .



con segno

↳ lunghezza della proiezione di \underline{x} sul sottospazio generato da \underline{a} .



Dall'identità fondamentale si ha dunque
che:

$$\frac{\underline{x}^T a}{|a|} = |\underline{x}^T| \cos \theta$$

⇓


L'identità fondamentale ****** dice dunque
che il risultato del prodotto scalare $\underline{x}^T a$
coincide con la lunghezza della proiezione
di \underline{x} sulla retta generata da a , espressa
in una unità di misura coincidente con la
lunghezza $|a|$ del vettore a .

— • — • — • —

OSSEVAZIONE: Interpretazione geometrica di $y = \underline{X} a$

Semplifichiamo: $X \Rightarrow$ matrice di
dati relativi ad n individui su cui

si mkenomo 2 corollen



ANALISI DISCRIMINANTE

Dati analizzati

Si ha una popolazione suddivisa in 2 sottopopolazioni (gruppi).

Dalla 1° sottopopolazione si estrae un campione di dimensione n_1 . Dalla 2° sottopopolazione si estrae un campione di dimensione n_2 .

In ciascuna delle $N = n_1 + n_2$ unità statistiche si rilevano q caratteri quantitativi.

Dalla rilevazione si ottiene la seguente matrice di dati:

$$X_{n \times q} = \begin{bmatrix} X_1 \\ \text{---} \\ X_2 \end{bmatrix} = \left\{ x_{ij} \right\}$$

Annotations: X_1 and X_2 are labeled $n_1 \times q$ and $n_2 \times q$ respectively. The set notation $\{x_{ij}\}$ is annotated with "gruppo" pointing to the subscript i and "variabile" pointing to the subscript j . The entire set is annotated with "unità" pointing to the subscript i .

Obiettivi:

- 1) Costruire una regola di classificazione
- 2) Individuare le variabili che maggiormente contribuiscono a spiegare l'appartenenza di una unità statistica alla prima o alla seconda sottopopolazione.

Metodologia:

Si definisce una funzione lineare delle q

validi (funzione discriminante lineare)


$$y = Xa \rightarrow \text{punteggi discriminanti (scores)}$$

determinando a in modo tale da rendere più evidenti possibili le differenze tra le unità statistiche appartenenti alle due sottopopolazioni.


Esempio fittizio:

- 2 variabili
- $n_1 = n_2 = 6$
- le 12 righe di X sono dei punti in \mathbb{R}^2 . Considerando $y = Xa$ si ottiene in sostanza proiettando i 12 punti sulla retta generata da a .

Caso 1: a scarsamente discriminante



Caso 2 : a molto discriminante



Il vettore a deve essere determinato in modo tale che le unità statistiche appartenenti al medesimo gruppo abbiano punteggi discriminanti simili mentre le unità appartenenti a gruppi diversi abbiano punteggi diversi.

In termini più tecnici desidero che gli SCORP presentino una bassa varianza nei gruppi ed un'alta varianza fra i gruppi.

- $S =$ matrice di Varianza e covarianza 9×9 ottenuta da X

- $S = S_w + S_b$

• $a^T S a = \text{Var}(y)$ (vedi β)

$$\text{Var}(y) = a^T (S_w + S_b) a$$

$$= \underbrace{a^T S_w a}_{\text{Varianza nei gruppi degli scores}} + \underbrace{a^T S_b a}_{\text{La Notionna tra i gruppi degli scores}}$$

Varianza nei gruppi degli scores

A questo punto, sembra ragionevole scegliere a in modo tale da massimizzare $a^T S_b a$.

Si giunge così al problema di ottimo vincolato

$$\begin{cases} \max_a & a^T S_b a \\ \text{sub} & a^T S a = 1 \end{cases} \rightarrow \text{perch\`e si introduce il vincolo?}$$

de viene risolto ricorrendo alla tecnica dei moltiplicatori di Lagrange.

- Si definisce la funzione Lagrangiana

$$L = a^T S_b a - \lambda (a^T S a - 1)$$

↳ moltiplicatore di Lagrange

- Si risolve il sistema $\begin{cases} \frac{\partial L}{\partial a} = 0_{9 \times 1} \\ \underline{\frac{\partial L}{\partial \lambda}} = 0 \end{cases}$

- Si risolve il sistema
$$\begin{cases} \frac{\partial L}{\partial a} = 0_{9 \times 1} \\ \frac{\partial L}{\partial \lambda} = 0 \end{cases}$$

$$\frac{\partial L}{\partial \lambda} = a^T S a - 1$$

$$\frac{\partial L}{\partial a} = \frac{\partial a^T S_b a}{\partial a} - \lambda \frac{\partial a^T S a}{\partial a}$$

$$(\text{vedi } \gamma) = 2 S_b a - 2 \lambda S a$$

$$2 S_b a - 2 \lambda S a = 0$$

$$S_b a = \lambda S a$$



$$\begin{cases} S_b a = \lambda S a & \textcircled{*} \\ a^T S a = 1 \end{cases}$$

Prendiamo in considerazione la prima equazione e moltiplichiamo entrambi i membri per S^{-1} :

membri per S^{-1} :

$$S^{-1} S_b a = \lambda a$$

S^{-1} esiste se
 $\text{Rango}(X) = q$ e
 $M-1 > q$

a è un autovettore di $S^{-1} S_b$ e λ è il corrispondente autovalore.

Inoltre, dalla $\textcircled{*}$, si ottiene premoltiplicando per a^T :

$$a^T S_b a = \lambda \underbrace{a^T S a}_{= 1} = \lambda \quad (\text{2}^\circ \text{ equazione sistema})$$

$$\lambda = a^T S_b a$$

a è l'autovettore associato all'autovalore più grande di $S^{-1} S_b$.

Quanti autovalori non nulli ha la matrice $S^{-1} S_b$?

\rightarrow (vedi 2)

Esempio $\text{Rango}(S_b) = 1$, allora anche $\text{Rango}(S^{-1} S_b) = 1 \Rightarrow S^{-1} S_b$ ha un unico autovalore non nullo.

Ricordando che

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

risulta semplice calcolare analiticamente il valore di λ e l'espressione di a .

In particolare, sia

$$h = \frac{\sqrt{m_1 m_2}}{m} (\underline{\mu}_1 - \underline{\mu}_2)$$

Si ha che:

$$S_b = h h^T$$

$$- S^{-1} S_b a = \lambda a \Rightarrow S^{-1} h h^T a = \lambda a$$

$$\underbrace{h^T S^{-1} h}_{\text{scalare}} h^T a = \lambda h^T a \Rightarrow \lambda = h^T S^{-1} h$$

$$\lambda = \frac{m_1 m_2}{m} (\underline{\mu}_1 - \underline{\mu}_2)^T S^{-1} (\underline{\mu}_1 - \underline{\mu}_2)$$

Per quanto riguarda la determinazione del vettore a :

$$S_b a = \lambda S a \Rightarrow S a = \frac{1}{\lambda} S_b a$$

$$S a = \frac{1}{\lambda} h h^T a$$

$$S a = h \left(\frac{h^T a}{\lambda} \right) \quad \text{scalare}$$

$$S a = \frac{h^T a}{\lambda} h$$

→ non influisce

$$S a = \frac{h^T a}{\lambda} h$$

$$a = \frac{h^T a}{\lambda} S^{-1} h$$

$$a = \frac{h^T a}{\lambda} \cdot \sqrt{\frac{m_1 m_2}{m}} S^{-1} (\underline{u}_1 - \underline{u}_2)$$

non influisce sulla direzione di a ma solo sul suo modulo.

scalare

$$a = \gamma \sqrt{\frac{m_1 m_2}{m}} S^{-1} (\underline{u}_1 - \underline{u}_2) \quad \gamma = \frac{h^T a}{\lambda}$$

γ viene determinato in modo tale da soddisfare il vincolo $a^T S a = 1$

$$a = \gamma S^{-1} h \Rightarrow a^T S a = \gamma^2 h^T S^{-1} S S^{-1} h$$

$$\gamma^2 h^T \underbrace{S^{-1} S S^{-1}}_{I_q} h = 1$$

$$\gamma^2 \underbrace{h^T S^{-1} h}_{\lambda} = 1 \Rightarrow \gamma^2 \lambda = 1$$

$$\gamma = \frac{1}{\sqrt{\lambda}}$$

Concludendo:

$$a = \frac{1}{m} \sqrt{\frac{m_1 m_2}{\lambda}} S^{-1} (\underline{u}_1 - \underline{u}_2)$$

|

L'operativamente si è soliti porre

$$a = S^{-1} (\underline{\mu}_1 - \underline{\mu}_2)$$

OSSERVAZIONE: Molto spesso la f. d. è definita come segue:

$$a^* = S_w^{-1} (\underline{\mu}_1 - \underline{\mu}_2)$$

Ciò deriva dal fatto che i problemi di ottimizzazione

$$\begin{cases} \max_a & a^T S_b a \\ \text{sub} & a^T S a = 1 \end{cases}$$

$$\begin{cases} \max_a & \frac{a^T S_b a}{a^T S_w a} \\ \text{sub} & a^T S a = 1 \end{cases}$$

risultano equivalenti in virtù del fatto

$$\text{che } S_b = S - S_w$$

Di conseguenza a e a^* differiscono solo nel modulo ma non nella direzione.

UTILIZZO dei PUNTEGGI DISCRIM.

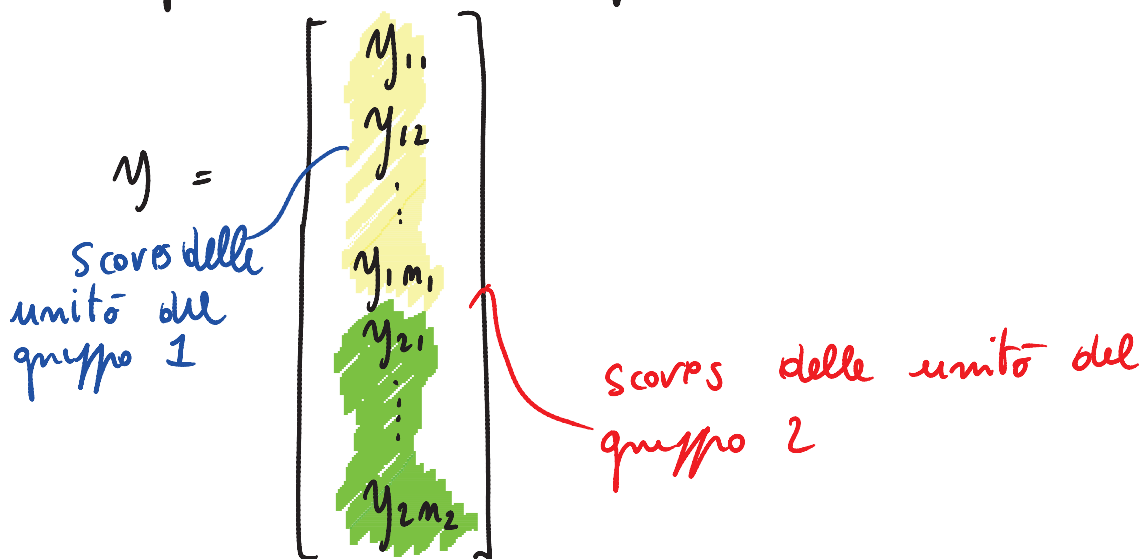
- $y = Xa$

Definizione di un criterio di classificazione.

Analizzando una NUOVA unità statistica si è ottenuto il seguente vettore di dati:

$$\underline{x}^* = [x_1^*, \dots, x_q^*]$$

È più verosimile ritenere che \underline{x}^* provenga dal gruppo 1 o dal gruppo 2?



CENTROIDI :

Centraide del 1° gruppo :

$$\bar{x}_1 \quad | \quad \begin{matrix} m_1 \\ \sum \\ n \dots \end{matrix}$$

$$\bar{y}_1 = \frac{1}{n_1} \sum_{i=1}^{n_1} y_{1i}$$

Centroide del 1° gruppo :

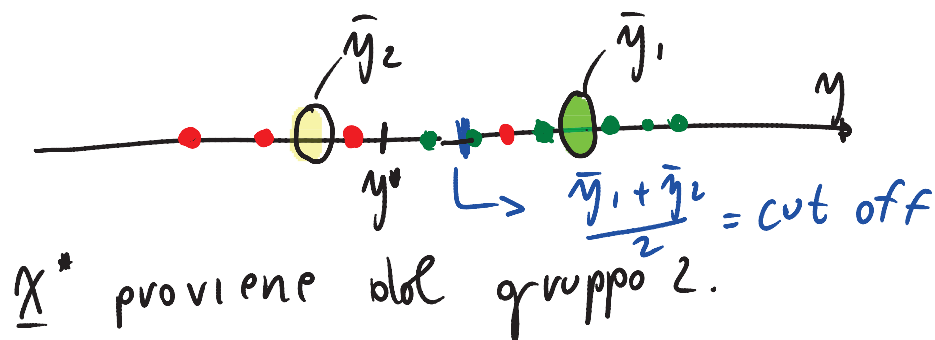
$$\bar{y}_2 = \frac{1}{n_2} \sum_{i=1}^{n_2} y_{2i}$$

Scorp della nuova unità statistica

$$y^* = \underline{x}^* a$$

Regola di classificazione : se y^* è più vicino a \bar{y}_1 di quanto non lo sia a \bar{y}_2 allora classifichiamo \underline{x}^* come appartenente al gruppo 1. Al contrario, se y^* è più vicino a \bar{y}_2 allora classifichiamo \underline{x}^* come appartenente al gruppo 2.

ES :



In formule :

2) Sia $\bar{y}_1 < \bar{y}_2$, allora

• se $y^* < \frac{\bar{y}_1 + \bar{y}_2}{2} \Rightarrow \underline{x}^*$ proviene