

## Lezione : Matrice dei dati centrati e standardizzati

Docente: Aldo Solari

### 1 Dati centrati e standardizzati

#### 1.1 Il vettore delle medie

$$\bar{x} = \frac{1}{n} X' \mathbf{1}$$

$\begin{matrix} p \times 1 & & n \times p \times n \times 1 \end{matrix}$

#### 1.2 La matrice dei dati centrati

$$\tilde{X} = X - \mathbf{1}\bar{x}' = \left( \begin{matrix} I & -\frac{1}{n} \mathbf{1} \mathbf{1}' \\ n \times n & n \times n \times 1 \times n \end{matrix} \right) X = H X$$

$\begin{matrix} n \times p & & n \times p & & n \times n \times n \times p \end{matrix}$

#### 1.3 La matrice di centramento

$$H = I - \frac{1}{n} \mathbf{1} \mathbf{1}'$$

$\begin{matrix} n \times n & & n \times n & & n \times n \times 1 \times n \end{matrix}$

**Observation 1.1.**  $H$  è una matrice simmetrica

$$H = I - \frac{1}{n} \mathbf{1} \mathbf{1}' = \begin{bmatrix} 1 - \frac{1}{n} & -\frac{1}{n} & \dots & -\frac{1}{n} & \dots & -\frac{1}{n} \\ -\frac{1}{n} & 1 - \frac{1}{n} & \dots & -\frac{1}{n} & \dots & -\frac{1}{n} \\ \vdots & \vdots & \ddots & \vdots & \dots & \vdots \\ -\frac{1}{n} & -\frac{1}{n} & \dots & 1 - \frac{1}{n} & \dots & -\frac{1}{n} \\ \vdots & \vdots & \dots & \vdots & \ddots & \dots \\ -\frac{1}{n} & -\frac{1}{n} & \dots & -\frac{1}{n} & \dots & 1 - \frac{1}{n} \end{bmatrix}$$

**Proposition 1.2.**  $H$  è una matrice idempotente

*Dimostrazione.*

$$\begin{aligned}
 H H &= \left( I - \frac{1}{n} \mathbf{1} \mathbf{1}' \right) \left( I - \frac{1}{n} \mathbf{1} \mathbf{1}' \right) \\
 &= I - 2 \frac{1}{n} \mathbf{1} \mathbf{1}' + \frac{1}{n^2} (\mathbf{1} \mathbf{1}') (\mathbf{1} \mathbf{1}') \\
 &= I - 2 \frac{1}{n} \mathbf{1} \mathbf{1}' + \frac{1}{n^2} \mathbf{1} n \mathbf{1}' \\
 &= I - \frac{1}{n} \mathbf{1} \mathbf{1}' = H
 \end{aligned}$$

□

**Observation 1.3.** *Centrare la matrice dei dati centrati non produce alcun effetto:*

$$H \tilde{X} = H H X = \tilde{X}$$

## 1.4 Matrice di varianze/covarianze

$$S = \frac{1}{n} \tilde{X}' \tilde{X}$$

Si noti che possiamo esprimere la matrice di varianza/covarianze come segue:

$$nS = \tilde{X}' \tilde{X} = (HX)'(HX) = X' H' H X = X' H X$$

sfruttando la simmetria  $H' = H$  e l'idempotenza  $HH = H$

**Proposition 1.4.**  $S$  è una matrice semidefinita positiva

*Dimostrazione.*

$$\begin{aligned}
 n a' S a &= a' \tilde{X}' \tilde{X} a \\
 &= (\tilde{X} a)' (\tilde{X} a) \\
 &= b' b \\
 &= \sum_{i=1}^n b_i^2 \geq 0 \quad \forall a
 \end{aligned}$$

dove  $b = \tilde{X} a$ .

□

Se calcoliamo la matrice di varianze/covarianze per una generica matrice  $M$  abbiamo

$$nS^M = (HM)'(HM) = M' H' H M = M' H H M = M' H M$$

**Observation 1.5.** La matrice di varianze/covarianze calcolata per  $\tilde{X}$  risulta uguale alla varianze/covarianze calcolata per per  $X$

$$S^{\tilde{X}} = \frac{1}{n} \begin{pmatrix} \tilde{X}' & H' \\ p \times nm \times n \end{pmatrix} \begin{pmatrix} H & \tilde{X} \\ n \times nm \times p \end{pmatrix} = \frac{1}{n} \tilde{X}' \tilde{X} = S^X$$

## 1.5 Matrice dei dati standardizzati

$$Z = \tilde{X} D^{-1/2}$$

dove  $D^{-1/2} = \text{diag}(\sqrt{s_{11}}, \dots, \sqrt{s_{pp}})$ . La matrice

$$D^{-1/2} = \text{diag} \left( \frac{1}{\sqrt{s_{11}}}, \dots, \frac{1}{\sqrt{s_{pp}}} \right) = \begin{bmatrix} \frac{1}{\sqrt{s_{11}}} & \dots & 0 & \dots & 0 \\ 0 & \dots & 0 & \dots & 0 \\ \vdots & \dots & \vdots & \ddots & \dots \\ 0 & \dots & 0 & \dots & \frac{1}{\sqrt{s_{pp}}} \end{bmatrix}$$

è la matrice inversa di  $D^{1/2}$ . Questo richiede che  $s_{11}, \dots, s_{pp}$  siano tutti diversi da 0.

(Moltiplicare  $\tilde{X}$  da destra per  $D^{-1/2}$  equivale a moltiplicare la  $j$ -sima colonna di  $\tilde{X}$  per  $\frac{1}{\sqrt{s_{jj}}}$ )

## 1.6 Matrice di correlazione

$$R = D^{-1/2} S D^{-1/2}$$

- Moltiplicare  $S$  da sinistra per  $D^{-1/2}$  equivale a moltiplicare l' $i$ -sima riga di  $S$  per  $\frac{1}{\sqrt{s_{ii}}}$ ;
- Moltiplicare  $S$  da destra per  $D^{-1/2}$  equivale a moltiplicare la  $j$ -sima colonna di  $S$  per  $\frac{1}{\sqrt{s_{jj}}}$ ;

**Observation 1.6.**

$$S = D^{1/2} R D^{1/2}$$

$$R = D^{-1/2} S D^{-1/2}$$

$$D^{1/2} R D^{1/2} = D^{1/2} D^{-1/2} S D^{-1/2} D^{1/2}$$

e visto che  $D^{-1/2}$  è la matrice inversa di  $D^{1/2}$ , per definizione

$$D^{1/2} D^{-1/2} = D^{-1/2} D^{1/2} = I$$

e quindi  $D^{1/2} R D^{1/2} = S$

**Observation 1.7.** *La matrice di varianze/covarianze calcolata per  $Z$  risulta uguale alla matrice di correlazione calcolata per  $X$ .*

$$\begin{aligned}
 S_{p \times p}^Z &= \frac{1}{n}(Z'H')(HZ) \\
 &= \frac{1}{n}Z'Z \\
 &= \frac{1}{n}D^{-1/2}\tilde{X}'\tilde{X}D^{-1/2} \\
 &= D^{-1/2}SD^{-1/2} = R_{p \times p}^X
 \end{aligned}$$

**Example 1.8.** *Matrice*

$$X_{4 \times 2} = \begin{bmatrix} 42 & 4 \\ 52 & 5 \\ 48 & 4 \\ 58 & 3 \end{bmatrix}$$

*Vettore delle medie*

$$\bar{x}_{2 \times 1} = \frac{1}{4} \begin{bmatrix} 42 & 52 & 48 & 58 \\ 4 & 5 & 4 & 3 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 50 \\ 4 \end{bmatrix}$$

*Matrice di centramento*

$$\begin{aligned}
 H_{4 \times 4} &= I_{4 \times 4} - \frac{1}{4} \mathbf{1}_{1 \times 4} \mathbf{1}'_{4 \times 1} \\
 &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} - \frac{1}{4} \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \end{bmatrix} \\
 &= \begin{bmatrix} 1 - 1/4 & -1/4 & -1/4 & -1/4 \\ -1/4 & 1 - 1/4 & -1/4 & -1/4 \\ -1/4 & -1/4 & 1 - 1/4 & -1/4 \\ -1/4 & -1/4 & -1/4 & 1 - 1/4 \end{bmatrix}
 \end{aligned}$$

*Matrice dei dati centrati:*

$$\begin{aligned} \tilde{X}_{4 \times 2} &= HX \\ &= \begin{bmatrix} 1 - 1/4 & -1/4 & -1/4 & -1/4 \\ -1/4 & 1 - 1/4 & -1/4 & -1/4 \\ -1/4 & -1/4 & 1 - 1/4 & -1/4 \\ -1/4 & -1/4 & -1/4 & 1 - 1/4 \end{bmatrix} \begin{bmatrix} 42 & 4 \\ 52 & 5 \\ 48 & 4 \\ 58 & 3 \end{bmatrix} \\ &= \begin{bmatrix} -8 & 0 \\ 2 & 1 \\ -2 & 0 \\ 8 & -1 \end{bmatrix} \end{aligned}$$

*Matrice di varianze/covarianze*

$$\begin{aligned} S_{2 \times 2} &= \frac{1}{4} \tilde{X}' \tilde{X} \\ &= \frac{1}{4} \begin{bmatrix} -8 & 2 & -2 & 8 \\ 0 & 1 & 0 & -1 \end{bmatrix} \begin{bmatrix} -8 & 0 \\ 2 & 1 \\ -2 & 0 \\ 8 & -1 \end{bmatrix} = \begin{bmatrix} 34 & -1.5 \\ -1.5 & 0.5 \end{bmatrix} \end{aligned}$$

*Matrice di correlazione:*

$$\begin{aligned} R_{2 \times 2} &= D^{-1/2} S D^{-1/2} \\ &= \begin{bmatrix} 1/\sqrt{34} & 0 \\ 0 & 1/\sqrt{0.5} \end{bmatrix} \begin{bmatrix} 34 & -1.5 \\ -1.5 & 0.5 \end{bmatrix} \begin{bmatrix} 1/\sqrt{34} & 0 \\ 0 & 1/\sqrt{0.5} \end{bmatrix} \\ &= \begin{bmatrix} 1 & -1.5/(\sqrt{34}\sqrt{5}) \\ -1.5/(\sqrt{34}\sqrt{5}) & 1 \end{bmatrix} \end{aligned}$$

*Matrice dei dati standardizzati:*

$$Z_{4 \times 2} = \begin{bmatrix} -8 & 0 \\ 2 & 1 \\ -2 & 0 \\ 8 & -1 \end{bmatrix} \begin{bmatrix} 1/\sqrt{34} & 0 \\ 0 & 1/\sqrt{0.5} \end{bmatrix} = \begin{bmatrix} -8/\sqrt{34} & 0 \\ 2/\sqrt{34} & 1/\sqrt{0.5} \\ -2/\sqrt{34} & 0 \\ 8/\sqrt{34} & -1/\sqrt{0.5} \end{bmatrix}$$

Matrice dei dati	Vettore delle medie	Matrice di varianze/covarianze	Matrice di correlazione
$X$ $n \times p$	$\bar{x}$ $p \times 1$	$S$ $p \times p$	$R$ $p \times p$
$\tilde{X}$ $n \times p$	$0$ $p \times 1$	$S^{\tilde{X}} = S$ $p \times p$ $p \times p$	$R^{\tilde{X}} = R$ $p \times p$ $p \times p$
$Z$ $n \times p$	$0$ $p \times 1$	$S^Z = R$ $p \times p$ $p \times p$	$R^Z = R$ $p \times p$ $p \times p$