

Analisi Esplorativa (Analisi Statistica Multivariata)

Prova d'esame

28 Febbraio 2022

Tempo a disposizione: 120 minuti

Modalità di consegna: svolgere gli esercizi di teoria (parte A) riportando le soluzioni sul foglio protocollo, e consegnare il foglio protocollo assieme al testo della prova d'esame. Successivamente, accedere alla piattaforma esaminonline tramite computer e svolgere gli esercizi di analisi dei dati (parte B). In questo caso la consegna si svolge tramite piattaforma esaminonline. Il tempo da dedicare alla parte A e alla parte B è a discrezione dello studente.

Compilare con nome, cognome e numero di matricola. E' obbligatorio consegnare il testo della prova d'esame all'interno del foglio protocollo contenente le soluzioni degli esercizi di teoria.

NOME:

COGNOME:

MATRICOLA:

PARTE A: esercizi di teoria

Esercizi da svolgere sul foglio protocollo senza l'ausilio di R/Rstudio.

Problema 1

1. Si supponga che la matrice dei dati standardizzati Z consista di due colonne z_1 e z_2 con la seguente

matrice di correlazione $R = \begin{bmatrix} 1 & r \\ r & 1 \end{bmatrix}$ dove $-1 \leq r \leq 1$. Si consideri la matrice dei dati trasformati Y dove $y_1 = z_1$ e $y_2 = b z_2$ per una costante $b > 0$.

- Calcolare la varianza totale per i dati Y .
 - Calcolare la varianza generalizzata per i dati Y .
 - Calcolare l'indice relativo di variabilità per i dati Y .
2. Si consideri il modello fattoriale con le seguenti matrici di pesi fattoriali e varianze specifiche:

$$\Lambda = \begin{bmatrix} 4 & 1 \\ 7 & 2 \\ -1 & 6 \\ 1 & 8 \end{bmatrix}, \quad \Psi = \begin{bmatrix} 2 & 0 & 0 & 0 \\ 0 & 4 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 3 \end{bmatrix}$$

- Calcolare la covarianza tra la prima variabile e il primo fattore comune, i.e. $\text{Cov}(x_1, f_1)$
- Calcolare la varianza della prima variabile, i.e. $\text{Var}(x_1)$

- c. Calcolare la covarianza tra le prime due variabili, i.e. $\text{Cov}(x_1, x_2)$
- d. Calcolare la correlazione tra le prime due variabili, i.e. $\text{Corr}(x_1, x_2)$
3. Si consideri la seguente matrice dei dati $X = \begin{bmatrix} 0 & 0 \\ 0 & 1 \\ 1 & 0 \end{bmatrix}$.
- a. Calcolare la matrice D delle distanze Euclidee al quadrato $d^2(u_i, u_l)$.
- b. Calcolare la distanza totale $T = \frac{1}{2n} \sum_{i=1}^n \sum_{l=1}^n d^2(u_i, u_l)$.
- c. Si consideri l'algoritmo delle K -medie con $K = 2$. Calcolare la distanza entro i gruppi $W = \sum_{k=1}^K W(G_k)$ dove $W(G_k) = \frac{1}{2n_k} \sum_{i:u_i \in G_k} \sum_{l:u_l \in G_k} d^2(u_i, u_l)$ per la partizione $G_1 = \{u_1\}$ e $G_2 = \{u_2, u_3\}$.

PARTE B: esercizi di analisi dei dati

Esercizi da svolgere con il computer sulla piattaforma esaminonline con l'ausilio di R/Rstudio.

Problema 2

Si consideri la matrice dei dati $X_{n \times 3}$, a cui è associata la matrice di varianze/covarianze S . Sapendo che

- la prima riga di X è pari a $u_1' = (20.6, 87, 77)$ e il baricentro è pari a $\bar{x}' = (13.9, 76.2, 32.9)$,
- la seconda colonna di V è $v_2 = (0.1, -1, 0.2)'$, dove V è la matrice degli autovettori relativa a S ,
- la varianza della prima variabile è $s_{11} = 9.8$, mentre il secondo autovalore di S è $\lambda_2 = 26.5$,

(nel vostro esercizio il valori potrebbero essere diversi).

```
u1
```

```
## [1] 20.6 87.0 77.0
```

```
xbar
```

```
##      [,1]
## [1,] 13.9
## [2,] 76.2
## [3,] 32.9
```

```
v2
```

```
##      [,1]
## [1,]  0.1
## [2,] -1.0
## [3,]  0.2
```

```
lambda2
```

```
## [1] 26.5
```

```
s11
```

```
## [1] 9.8
```

1. Calcolare $d_\infty(u_1, \bar{x})$. Riportare il risultato arrotondando al **terzo decimale** (si ricordi l'uso della **virgola** per i decimali).

```
# 1
D = max(abs(u1-t(xbar)))
round(D,3)
```

```
## [1] 44.1
```

2. Calcolare il valore del primo elemento di $y_2 = \tilde{X}v_2$, dove \tilde{X} è la matrice dei dati centrati e y_2 è il vettore dei punteggi della seconda componente principale. Riportare il risultato arrotondando al **terzo decimale** (si ricordi l'uso della **virgola** per i decimali).

```
# 2
y12 = (u1-t(xbar)) %*% v2
round(y12,3)
```

```
## [1]
## [1,] -1.31
```

3. Calcolare la correlazione tra la prima colonna \tilde{x}_1 di \tilde{X} e i punteggi y_2 della seconda componente principale. Riportare il risultato arrotondando al **terzo decimale** (si ricordi l'uso della **virgola** per i decimali).

```
# 3
C = v2[1] * sqrt(lambda2) / sqrt(s11)
round(C,3)
```

```
## [1] 0.164
```

Problema 3

Si consideri il dataset `quakes` presente nella libreria `datasets`. Si tratta di 1000 osservazioni misurate su 5 variabili:

- `lat` Latitude of event
- `long` Longitude
- `depth` Depth (km)
- `mag` Richter Magnitude
- `stations` Number of stations reporting

Sia X la matrice 999×4 corrispondente al dataset `quakes`, escludendo la riga 1 (nel vostro esercizio il numero di riga potrebbe essere diverso) e la variabile `stations`.

1. Calcolare la matrice dei dati standardizzati Z e riportare il numero di osservazioni anomale verificando se la distanza di Mahalanobis al quadrato di ciascuna osservazione di Z dal baricentro 0 è superiore alla soglia s , dove s corrisponde al quantile 0.95 di una variabile casuale χ_p^2 (dove p è il numero di colonne di Z).

```
# 1
rm(list=ls())
X <- quakes[-1,-5]
n <- nrow(X)
p <- ncol(X)
sd = sqrt(diag(var(X) * ((n-1)/n)))
Z = scale(X, center = TRUE, scale = sd)[,]
R = cor(Z)
InvR = solve(R)
dM2 = apply(Z,MARGIN=1, function(u) t(u) %*% InvR %*% u )
s = qchisq(0.95, df=p)
sum(dM2 > s)
```

```
## [1] 36
```

2. Rimuovere da Z le osservazioni anomale individuate al punto precedente e su questi dati utilizzare l'algoritmo delle K -medie

- inizializzando i centri con le prime K unità statistiche;
- impostando il numero di iterazioni (argomento `iter.max`) a 100;
- utilizzando l'algoritmo di Lloyd (argomento `algorithm`).

Decidere il numero di gruppi K ottimale secondo l'indice CH, per $K = 2, \dots, 12$. Riportare la distanza entro i gruppi W corrispondente alla scelta effettuata, arrotondando al **terzo decimale** (si ricordi l'uso della **virgola** per i decimali).

```
# 2
Z_noout <- Z[-which(dM2 > s),]
n_noout <- nrow(Z_noout)
K = 2:12
W <- B <- CH <- vector()
for (i in 1:length(K)){
  km = kmeans(Z_noout, centers = Z_noout[1:K[i],], algorithm = "Lloyd", iter.max = 100)
  W[i] = km$tot.withinss
  B[i] = km$betweenss
  CH[i] = (B[i]/(K[i]-1)) / (W[i]/(n_noout-K[i]))
}
round( W[which.max(CH)], 3)
```

```
## [1] 1601.884
```

3. Calcolare il valore medio della *silhouette* corrispondente alla raggruppamento selezionato al punto precedente, utilizzando la matrice delle distanze Euclidee. Riportare il risultato arrotondando al **terzo decimale** (si ricordi l'uso della virgola per i decimali).

```
my_K <- K[which.max(CH)]
gruppi = kmeans(Z_noout, centers = Z_noout[1:my_K,], algorithm = "Lloyd", iter.max = 100)$cluster
D = dist(Z_noout)
library(cluster)
sil_media <- summary(silhouette(gruppi, dist=D))$avg.width
round(sil_media,3)
```

```
## [1] 0.387
```