

## 17 Aprile 2019 - Analisi Esplorativa

Cognome: .....

Nome: .....

Matricola: .....

Tipologia d'esame:     12 CFU     15 CFU

---

### Prova scritta - fila A

*Si svolgano gli esercizi riportando il risultato dove indicato. Durata: 70 minuti*

---

#### Esercizio 1 (10 punti)

Il dataset **Boston** presente nella libreria **MASS** è composto da 506 osservazioni e 14 variabili: *crim, zn, indus, chas, nox, rm, age, dis, rad, tax, ptratio, black, lstat, medv*.

Le variabili di interesse per l'analisi sono trasformazioni delle variabili originali come elencato nel seguito:

- $x_1 = \log(\text{crim})$
- $x_2 = \text{zn}/10$
- $x_3 = \log(\text{indus})$
- $x_4 = \log(\text{nox})$
- $x_5 = \log(\text{rm})$
- $x_6 = (\text{age})^{2.5}/10000$
- $x_7 = \log(\text{dis})$
- $x_8 = \log(\text{rad})$
- $x_9 = \log(\text{tax})$
- $x_{10} = \exp(0.4 \cdot \text{ptratio})/1000$
- $x_{11} = \text{black}/100$
- $x_{12} = \sqrt{\text{lstat}}$
- $x_{13} = \log(\text{medv})$

dove log indica il logaritmo naturale.

Si costruisca la matrice dei dati  $X_{506 \times 13}$  che contiene le variabili  $x_1, x_2, \dots, x_{13}$ .

- a. Si calcoli  $d_M^2(x_i, \bar{x})$ , il quadrato della distanza di Mahalanobis di ciascuna osservazione (ciascuna riga della matrice  $X$ ) dal baricentro. Si riportino i valori di  $d_M^2(x_i, \bar{x})$  solo se superano il valore 38, specificando anche l'indice della riga di  $X$  a cui si fa riferimento.

```
library(MASS)
Y = Boston
X = cbind(
  log(Y[, "crim"]),
  Y[, "zn"]/10,
  log(Y[, c("indus", "nox", "rm")]),
  (Y[, "age"]^(2.5))/10000,
```

```

log(Y[,c("dis", "rad", "tax")]),
exp(0.4*Y[, "ptratio"])/1000,
Y[, "black"]/100,
sqrt(Y[, "lstat"]),
log(Y[, "medv"])
)
n = nrow(X)
p = ncol(X)
xbar = matrix(colMeans(X), nrow=p, ncol=1)
S = var(X) * ((n-1)/n)
InvS = solve(S)
dm2 = apply(X, MARGIN=1, function(u) t(u-xbar) %*% InvS %*% (u - xbar) )
round(dm2[dm2 > 38], 2)

```

```

343 356 366 368 369 413
44.19 38.70 72.85 58.54 49.32 41.73

```

- b. Sulla base della matrice dei dati standardizzati  $_{506 \times 13} Z$ , applicare l'algoritmo delle  $K$  medie (`algorithm = "Hartigan-Wong"`) inizializzando i  $K$  centri di utilizzando le prime  $K$  osservazioni (righe  $1, \dots, K$  della matrice  $Z$ ). Arrotondando il risultato alla seconda cifra decimale, riportare per  $K = 5, 6, \dots, 10$
- il valore dell'indice  $CH(K) = \frac{B/(K-1)}{W/(n-K)}$  di Calinski and Harabasz
  - il valore medio della *silhouette* considerando come matrice delle distanze quella ottenuta con la metrica Euclidea basata su  $Z$

$K$	5	6	7	8	9	10
$CH(K)$						
<i>silhouette</i> ( $K$ )						

```

Z = scale(X, center=T, scale=diag(S)^(1/2))
D = dist(Z, method = "euclidean")
K = 5:10
CH <- vector()
sil <- vector()
library(cluster)
for (k in 1:length(K)){
km = kmeans(Z, centers=Z[1:k[k],], algorithm = "Hartigan-Wong")
CH[k] = (km$betweenss / (K[k]-1)) / (km$tot.withinss / (n-K[k]))
sil[k] = summary(silhouette(x=km$cluster, dist=D))$avg.width
}
round(rbind(K, CH, sil), 2)

```

```

[,1] [,2] [,3] [,4] [,5] [,6]
K 5.00 6.00 7.00 8.00 9.00 10.00
CH 202.35 174.22 148.52 143.76 158.47 139.62
sil 0.24 0.22 0.20 0.23 0.25 0.21

```

- c. Si consideri la stima di massima verosimiglianza per il modello fattoriale con  $k$  fattori basato sui dati standardizzati  $Z$ . Riportare il  $p$ -value del primo test non significativo al livello 5% (e il corrispondente valore di  $k$ ) per la sequenza di ipotesi nulle  $H_0(k = 1), H_0(k = 2), H_0(k = 3), \dots$  dove  $H_0(k)$ ="il modello fattoriale con  $k$  fattori è corretto".

```
k = which.max(sapply(1:8, function(k) factanal(Z,factors=k)$PVAL > 0.05 ))
k
```

```
objective
      7
```

```
round(factanal(Z,factors=k)$PVAL,4)
```

```
objective
0.0806
```

- d. Stimare il modello fattoriale con  $k = 5$  fattori con il metodo della massima verosimiglianza utilizzando i dati standardizzati  $Z$  e senza effettuare alcuna rotazione. Riportare il valore della statistica test rapporto di verosimiglianza  $T = n \log \left( \frac{\det(\hat{\Lambda}\hat{\Lambda}' + \hat{\Psi})}{\det(R)} \right)$  (arrotondando al terzo decimale)

```
R = cor(X)
af5 = factanal(Z,factors=5, rotation="none", method="mle")
Lambda = af5$loadings[,]
Psi = diag(af5$uniqueness)
fit = Lambda %*% t(Lambda) + Psi
lrt = n*log(det(fit)/det(R))
round(lrt,3)
```

```
[1] 111.317
```

- e. Stimare il modello fattoriale con  $k = 7$  fattori con il metodo della massima verosimiglianza utilizzando i dati standardizzati  $Z$  e senza effettuare alcuna rotazione. Riportare i punteggi fattoriali  $\hat{f}_i$  con il metodo di Thompson (arrotondando alla seconda cifra decimale) per l'unità statistica corrispondente alla riga  $i = 100$  della matrice  $Z$ .

```
af7 = factanal(Z, factors=7, rotation="none", method="mle", scores = "regression")
round(af7$scores[100,],2)
```

```
Factor1 Factor2 Factor3 Factor4 Factor5 Factor6 Factor7
-1.26    0.85   -0.08   -0.18   -0.37   -0.65    0.42
```

## Esercizio 2 (6 punti)

Sia

$$R = \begin{bmatrix} 1 & r \\ r & 1 \end{bmatrix}$$

con  $0 < r < 1$ .

- a. Determinare gli autovalori di  $R$ :

$$\lambda_1 = \dots \qquad \lambda_2 = \dots$$

b. Determinare gli autovettori normalizzati di  $R$ :

$$v_1 = \begin{bmatrix} \dots\dots\dots \\ \dots\dots\dots \\ \dots\dots\dots \end{bmatrix}, \quad v_2 = \begin{bmatrix} \dots\dots\dots \\ \dots\dots\dots \\ \dots\dots\dots \end{bmatrix}$$

c. Determinare i punteggi delle componenti principali

$$y_{i1} = \dots\dots\dots, \quad y_{i2} = \dots\dots\dots, \quad i = 1, \dots, n$$

### Esercizio 3 (4 punti)

Dimostrare, esplicitando tutti i passaggi e le quantità coinvolte, che il vettore  $u$  di lunghezza unitaria che risolve il problema di massimo

$$\max_{u: \|u\|=1} u' S u$$

è l'autovettore  $v_1$  (con segno positivo o negativo) della matrice di varianze/covarianze  $S$ .

**Esercizio 4 (3 punti)**

Si consideri la seguente matrice di varianze/covarianze  $S_{3 \times 3} = \begin{bmatrix} a & 0 & 0 \\ 0 & b & 0 \\ 0 & 0 & c \end{bmatrix}$

dove  $a > 0$ ,  $b > 0$  e  $c > 0$  sono costanti non note.

a. Calcolare la varianza totale

= .....

b. Calcolare la varianza generalizzata

= .....

c. Calcolare l'indice di variabilità relativo

= .....

d. Determinare l'inversa della matrice di correlazione

$$R_{3 \times 3}^{-1} = \begin{bmatrix} \dots & \dots & \dots \\ \dots & \dots & \dots \\ \dots & \dots & \dots \end{bmatrix} .$$

**Esercizio 5 (3 punti)**

Enunciare il teorema di Eckart-Young.