

Prof. Dr. Fred Böker

28.02.2013

**Klausur zur Vorlesung Analyse mehrdimensionaler Daten, WS 2012/2013
6 Kreditpunkte, 90 min****Hinweis:**

- Bitte runden Sie alle Ergebnisse auf drei Dezimalstellen.
- Runden Sie jedoch nur die Endergebnisse und keine Zwischenergebnisse.
- Wenn Sie bereits abgefragte Ergebnisse in folgenden Berechnungen benötigen, verwenden Sie jedoch bitte die gerundeten Ergebnisse.
- Im Anhang finden Sie Tabellen der benötigten Verteilungen.

Gesamtpunkte: 44**Aufgabe 1 (Punkte: 7)**Gegeben sei die folgende Korrelationsmatrix der Zufallsvariablen $\mathbf{Y} = (Y_1, Y_2, Y_3, Y_4)^t$.

$$P = \begin{pmatrix} 1.00 & 0.90 & 0.80 & 0.05 \\ 0.90 & 1.00 & 0.80 & -0.02 \\ 0.80 & 0.80 & 1.00 & 0.15 \\ 0.05 & -0.02 & 0.15 & 1.00 \end{pmatrix}$$

a) (Punkte: 2)

Berechnen Sie die Kovarianz $\sigma_{23} = \text{Cov}(Y_2, Y_3)$, wenn die Varianzen von Y_2 und Y_3 durch $\sigma_2^2 = 9$ und $\sigma_3^2 = 196$ gegeben sind.

b) (Punkte: 2)

Nehmen Sie an, dass alle Standardabweichungen $\sigma_1, \dots, \sigma_4$ bekannt sind. Mit welchen Matrizenoperationen können Sie dann aus der Korrelationsmatrix P die Kovarianzmatrix Σ berechnen? Geben Sie insbesondere die dazu benötigte Matrix an.

c) (Punkte: 3)

Nehmen Sie an, dass es sich bei der obigen Korrelationsmatrix um eine geschätzte Korrelationsmatrix handelt. Die Stichprobengröße sei $n = 102$. Prüfen Sie die Nullhypothese $\rho_{34} = 0$ gegen die Alternativhypothese $\rho_{34} \neq 0$.

Berechnen Sie den Wert der Prüfgröße und geben Sie die Verteilung der Prüfgröße unter der Nullhypothese an.

Berechnen Sie den P-Wert mit Hilfe einer geeigneten approximierenden Verteilung, deren Verteilungsfunktion im Anhang bei den Tabellen zu finden ist. Runden Sie dazu den Wert der Prüfgröße auf zwei Stellen nach dem Dezimalpunkt.

Aufgabe 2 (Punkte: 10)

Die in Aufgabe 1 verwendete Korrelationsmatrix wurde in **R** unter dem Namen `KorrMat` gespeichert, während unter `IMat` die Einheitsmatrix der Ordnung 4 gespeichert wurde.

```
> KorrMat
      [,1] [,2] [,3] [,4]
[1,] 1.00 0.90 0.80 0.05
[2,] 0.90 1.00 0.80 -0.02
[3,] 0.80 0.80 1.00 0.15
[4,] 0.05 -0.02 0.15 1.00
> IMat
      [,1] [,2] [,3] [,4]
[1,] 1 0 0 0
[2,] 0 1 0 0
[3,] 0 0 1 0
[4,] 0 0 0 1
```

a) (Punkte: 2)

In **R** wurden mit diesen Matrizen die folgenden Berechnungen durchgeführt:

```
> det(KorrMat-2.674*IMat)
[1] 0.002209530
> det(KorrMat-1.013*IMat)
[1] -0.000522674
> det(KorrMat-0.217*IMat)
[1] 7.485132e-05
> det(KorrMat-0.097*IMat)
[1] -1.116132e-05
```

Alle Werte sind nahezu Null. (Sie wären noch näher bei Null, hätten wir bei den verwendeten Zahlen statt drei noch weitere Stellen nach dem Dezimalpunkt verwendet.) Was folgt daraus für die Koeffizienten von `IMat`?

b) (Punkte: 2)

Zeigen Sie dass der zweite Eigenvektor von P ungefähr $\mathbf{a} = (-0.05, -0.13, 0.08, 0.99)^t$ ist. Runden Sie dazu den zugehörigen Eigenwert auf eine ganze Zahl.

Hinweis: Beachten Sie, dass die Ergebnisse wegen der Rundungen nur **ungefähr** sein können.

c) (Punkte: 2)

Interpretieren Sie das Ergebnis aus b). Schauen Sie sich dazu den zweiten Eigenwert, den zweiten Eigenvektor im Zusammenhang mit einer bestimmten Spalte der Korrelationsmatrix P an.

d) (Punkte: 2)

Wieviel Prozent der Totalvariation erklärt die erste Hauptkomponente, wieviel erklären die beiden ersten zusammen?

e) (Punkte: 2)

Mit **R** wurden die folgenden Berechnungen durchgeführt:

```
> EigenVeks<-round(eigen(KorrMat)$vectors,2)
> EigenWerte<-round(eigen(KorrMat)$values,2)
> round(EigenVeks%*%sqrt(diag(EigenWerte)),2)
      [,1] [,2] [,3] [,4]
[1,] -0.95 -0.05  0.20  0.22
[2,] -0.95 -0.13  0.16 -0.23
[3,] -0.92  0.08 -0.38  0.01
[4,] -0.10  0.99  0.07 -0.02
```

Welche Werte enthält die hier ausgegebene Matrix? Interpretieren Sie insbesondere die beiden ersten Spalten.

Aufgabe 3 (Punkte: 8)

Gegeben sei die folgende geschätzte Korrelationsmatrix der Zufallsvariablen $\mathbf{Y} = (Y_1, Y_2, Y_3)^t$.

$$R = \begin{pmatrix} 1.00 & 0.90 & 0.80 \\ 0.90 & 1.00 & 0.80 \\ 0.80 & 0.80 & 1.00 \end{pmatrix}$$

Diese Matrix wurde in **R** unter dem Namen `korrmat` gespeichert. Anschließend wurden die folgenden Berechnungen durchgeführt:

```
> korrmat<-matrix(c(1,0.9,0.8,0.9,1,0.8,0.8,0.8,1),nrow=3)
> korrmat
      [,1] [,2] [,3]
[1,]  1.0  0.9  0.8
[2,]  0.9  1.0  0.8
[3,]  0.8  0.8  1.0
> eigenvek<-round(eigen(korrmat)$vectors,2)
> eigenvek
      [,1] [,2] [,3]
[1,] -0.59 -0.40  0.71
[2,] -0.59 -0.40 -0.71
[3,] -0.56  0.83  0.00
> eigenwerte<-round(eigen(korrmat)$values,2)
> eigenwerte
[1] 2.67 0.23 0.10
> round(eigenvek%*%sqrt(diag(eigenwerte)),3)
      [,1] [,2] [,3]
[1,] -0.964 -0.192  0.225
[2,] -0.964 -0.192 -0.225
[3,] -0.915  0.398  0.000
```

Es soll eine Faktorenanalyse mit zwei Faktoren nach der Hauptkomponentenmethode durchgeführt werden.

a) **(Punkte: 2)**

Schreiben Sie zunächst allgemein das Modell der Faktorenanalyse für die obige Situation auf und geben Sie alle Annahmen an.

b) **(Punkte: 1)**

Bestimmen Sie dann die Matrix $\Lambda_{(2)}$ für das Modell mit 2 Faktoren aus den obigen Berechnungen mit **R**.

c) **(Punkte: 3)**

Zerlegen Sie R in $R = \Lambda_{(2)}\Lambda_{(2)}^t - \Psi$. (Runden Sie auf drei Stellen nach dem Dezimalpunkt). Geben Sie die Kommunalitäten und die Einzelrestvarianzen an.

d) **(Punkte: 2)**

Die Ladungsmatrix $\Lambda_{(2)}$ wurde in **R** unter `Lambda2` gespeichert. Was bedeutet die folgende **R**-Ausgabe? Welche Schlüsse ziehen Sie aus diesem Ergebnis?

```
> round(varimax(Lambda2)$rotmat, 2)
      [,1] [,2]
[1,]    1    0
[2,]    0    1
```

Aufgabe 4 (Punkte: 14)

Der Datensatz `DatMV` enthält $n = 24$ Beobachtungen von $m = 4$ Variablen aus einer multivariaten Normalverteilung.

```
> DatMV
      [,1] [,2] [,3] [,4]
[1,] 7.06 0.70 1.26 0.48
[2,] 6.20 1.57 -0.03 -0.42
[3,] 6.47 1.75 -0.94 -1.05
[4,] 5.46 2.58 -0.50 -0.67
[5,] 7.42 0.41 0.55 0.74
[6,] 5.81 2.55 0.95 0.66
[7,] 6.17 2.26 1.13 1.41
[8,] 6.31 1.87 0.97 0.69
[9,] 4.16 2.24 2.44 2.46
[10,] 5.52 2.34 3.39 3.89
[11,] 4.72 3.16 1.70 1.12
[12,] 5.35 2.11 3.33 3.62
[13,] 5.35 2.39 0.78 0.85
[14,] 6.47 1.49 0.62 0.97
[15,] 4.90 3.74 -0.78 0.11
[16,] 4.01 4.06 1.75 2.04
[17,] 5.21 3.17 -0.34 -0.74
[18,] 6.07 2.03 2.20 2.40
[19,] 5.54 2.65 2.37 2.87
[20,] 6.16 1.45 1.39 1.11
[21,] 7.20 0.60 1.32 1.56
[22,] 4.92 3.47 2.08 2.68
[23,] 7.24 0.87 0.54 0.67
[24,] 4.64 2.55 1.54 1.39
```

Es soll die Nullhypothese

$$H_0 : \boldsymbol{\mu}^t = (\mu_1, \mu_2, \mu_3, \mu_4) = (6, 2, 1, 1)$$

getestet werden. Es wurden die folgenden Berechnungen mit **R** durchgeführt:

```
> xquer<-round(apply(DatMV, 2, mean), 2)
> xquer
[1] 5.76 2.17 1.16 1.20
> MUnull<-c(6, 2, 1, 1)
> MUnull
[1] 6 2 1 1
> xquer-MUnull
[1] -0.24 0.17 0.16 0.20
> SINVDatMV<-round(solve(var(DatMV)), 2)
> SINVDatMV
      [,1] [,2] [,3] [,4]
[1,] 7.04 6.27 3.77 -2.35
[2,] 6.27 6.74 4.11 -2.85
[3,] 3.77 4.11 10.83 -8.81
[4,] -2.35 -2.85 -8.81 7.85
> round(SINVDatMV**%(xquer-MUnull), 2)
      [,1]
[1,] -0.49
[2,] -0.27
[3,] -0.24
[4,] 0.24
```

a) **(Punkte: 3)**

Prüfen Sie die obige Nullhypothese mit der Prüfgröße \mathcal{T}^2 unter Verwendung der obigen Berechnungen mit **R**.

Geben Sie zwei Formeln für die Prüfgröße \mathcal{T}^2 an.

Welche Formel haben Sie verwendet? Welcher Teil dieser Formel ist durch die obigen Berechnungen mit **R** schon gegeben?

In der von Ihnen (vermutlich) verwendeten Formel kommt ein Vektor vor, der eine besondere Bedeutung hat. Welche?

b) **(Punkte: 4)**

Rechnen Sie \mathcal{T}^2 um in eine F -verteilte Prüfgröße \mathcal{F} . Welche Freiheitsgrade hat \mathcal{F} ?

Bestimmen Sie den Ablehnungsbereich für \mathcal{F} , wenn $\alpha = 0.05$.

Würden Sie die Nullhypothese ablehnen?

Nutzen Sie die folgende **R**-Ausgabe, um den P-Wert annähernd zu bestimmen. Dabei sind $df1$ und $df2$ die Freiheitsgrade der F -Prüfgröße unter der Nullhypothese.

```
> round(qf((1:9)/10, df1, df2), 3)
[1] 0.261 0.409 0.551 0.699 0.863 1.055 1.295 1.627 2.195
```

c) **(Punkte: 2)**

Die obige Nullhypothese $(\mu_1, \mu_2, \mu_3, \mu_4) = (6, 2, 1, 1)$ ist ein Spezialfall der allgemeineren Nullhypothese

$$H_0 : \begin{array}{rcl} \mu_1 & - & \mu_2 & = & 4 \\ & & \mu_3 & + & \mu_4 & = & 2 \\ \mu_1 & & + & \mu_3 & = & 7 \end{array}$$

Geben Sie eine geeignete Matrix C und einen geeigneten Vektor ϕ an, mit denen man die Nullhypothese formulieren kann. Geben Sie dann die Formel zur Berechnung der Prüfgröße an.

d) **(Punkte: 2)**

Die Berechnung der Prüfgröße mit \mathbf{R} ergab $\mathcal{T}^2 \approx 1.9$.

Berechnen Sie den zugehörigen Wert von F und geben Sie die Verteilung von F unter der Nullhypothese an.

Wie kann man in \mathbf{R} den zugehörigen P-Wert berechnen?

e) **(Punkte: 3)**

Es sollen simultane und „gewöhnliche Konfidenzintervalle“ für die vier Erwartungswerte μ_i ; $i = 1, 2, \dots, 4$ berechnet werden. Rechnen Sie die Konfidenzintervalle nicht aus, sondern geben Sie für beide Fälle die benötigten Formeln und die benötigten Quantile an, wenn $1 - \alpha = 0.9$.

Aufgabe 5 (Punkte: 5)

Im Rahmen einer Diskriminanzanalyse sollen neue Individuen einer von zwei Gruppen zugeordnet werden. Es gelte $\pi_1 = \pi_2$ und $C(1|2) = C(2|1)$. Für Fishers lineare Diskriminanzfunktion ergab sich

$$\mathbf{L}^t \mathbf{x} = 28x_1 + 0.2x_2$$

Die Mittelwertvektoren seien

$$\bar{\mathbf{x}}_1 = (3.5, 550) \quad \bar{\mathbf{x}}_2 = (2.5, 450)$$

a) **(Punkte: 2)**

Berechnen Sie \hat{m} und entscheiden Sie mit Hilfe von \hat{m} , welcher Gruppe ein Individuum mit den Merkmalen $(3, 540)$ zuzuordnen ist.

b) **(Punkte: 3)**

Nehmen Sie an, es gebe eine dritte Gruppe.

Für das obige \mathbf{L} gelte

$$\mathbf{L}^t = \mathbf{L}_1^t - \mathbf{L}_2^t = (106, 0.3) - (78, 0.1)$$

Ferner sei $\bar{\mathbf{x}}_3 = (3, 450)$ und $\mathbf{L}_3^t = (93, 0.15)$.

Nehmen Sie an, dass $\pi_1 = \pi_2 = \pi_3$.

Berechnen Sie für das obige neue Individuum mit den Merkmalen $(3, 540)$ die Diskriminanzwerte w_i ; $i = 1, 2, 3$ und vernachlässigen Sie dabei den Term $\ln \pi_i$, da er für alle drei Gruppen gleich groß ist.

Welcher Gruppe wird das neue Individuum jetzt zugeordnet?

Ende der Klausur