

## Einfache Diskriminanzanalyse

### Einführendes Beispiel

Gegeben sind zwei Gruppen von Personen, für die jeweils mehrere Merkmale erhoben wurden, z.B. Alter, Einkommen, Zahl der Kinder und Autobesitz (1 = ja). Es gibt ein weiteres (abhängiges) Merkmal, die sich in den jeweiligen Gruppen unterscheidet, z.B. „kreditwürdig“ und „nicht kreditwürdig“.

Gruppe 1 („kreditwürdig“), fiktives Beispiel:

| X1  | Alter | Einkommen | Kinder | Autobesitz |
|-----|-------|-----------|--------|------------|
| x01 | 55    | 4503      | 0      | 1          |
| x02 | 44    | 1651      | 1      | 1          |
| x03 | 32    | 1518      | 2      | 0          |
| x04 | 18    | 1253      | 1      | 0          |
| x05 | 36    | 2471      | 0      | 1          |
| x06 | 43    | 2126      | 0      | 1          |
| x07 | 40    | 1272      | 3      | 0          |
| x08 | 34    | 1393      | 2      | 1          |
| x09 | 22    | 1626      | 1      | 0          |
| x10 | 51    | 1941      | 0      | 1          |

Gruppe 2 („nicht kreditwürdig“), fiktives Beispiel:

| X2  | Alter | Einkommen | Kinder | Autobesitz |
|-----|-------|-----------|--------|------------|
| x11 | 40    | 2869      | 3      | 0          |
| x12 | 39    | 1431      | 3      | 1          |
| x13 | 34    | 1567      | 3      | 0          |
| x14 | 31    | 1323      | 5      | 0          |
| x15 | 44    | 3384      | 4      | 1          |
| x16 | 55    | 1432      | 1      | 0          |
| x17 | 56    | 2161      | 4      | 0          |
| x18 | 47    | 2476      | 3      | 1          |
| x19 | 62    | 1896      | 2      | 1          |
| x20 | 43    | 2121      | 1      | 0          |

Für eine neue Person werden die vier o.g. Merkmale erhoben:

|   | Alter | Einkommen | Kinder | Autobesitz |
|---|-------|-----------|--------|------------|
| x | 41    | 2500      | 1      | 1          |

Es soll entschieden werden, welcher der beiden Gruppen diese Person zugeordnet werden kann.

### Durchführung<sup>1</sup>

Gegeben sind zwei unabhängige Gruppen, für die (metrische) Daten mehrerer Merkmale vorliegen. Beide Gruppen entstammen mehrdimensionalen Normalverteilungen und haben gleiche<sup>2</sup> Kovarianzmatrizen  $\underline{\Sigma}^{(1)} = \underline{\Sigma}^{(2)} = \underline{\Sigma}$ .

Durch die Diskriminanzanalyse sollen die folgenden beiden Aufgaben gelöst werden:

1. Prüfung der Frage, ob die beiden Gruppen gleiche Mittelwertsvektoren haben können
2. Angabe einer linearen Funktion der Merkmalsdaten, die die Zuordnung weiterer Merkmalsträger zu einer der beiden Grundgesamtheiten ermöglicht (→ Diskriminanzfunktion)

Der Vektor  $\underline{x}' = (x_1, x_2, \dots, x_m)$  enthält die beobachteten Merkmale.

Die Erwartungswerte für die beiden Gruppen sind in vektorieller Schreibweise

$$\underline{\mu}^{(1)} = (\mu_1^{(1)}, \mu_2^{(1)}, \dots, \mu_m^{(1)}) \quad \text{bzw.} \quad \underline{\mu}^{(2)} = (\mu_1^{(2)}, \mu_2^{(2)}, \dots, \mu_m^{(2)}).$$

---

<sup>1</sup> Die Darstellung folgt einem von Prof. Kristof mündlich vorgetragenen Seminarinhalt, ca. 1994

<sup>2</sup> Die Prüfung der  $H_0: \underline{\Sigma}^{(1)} = \underline{\Sigma}^{(2)}$  wird im Anhang dargestellt

Aus den beiden Gruppen werden nun zwei Stichproben der Größe  $n_1$  und  $n_2$  erhoben, es sei  $n = n_1 + n_2$ . Hieraus ergeben sich die arithmetischen Mittelwertsvektoren

$$\bar{\underline{x}}^{(1)'} = (\bar{x}_1^{(1)}, \bar{x}_2^{(1)}, \dots, \bar{x}_m^{(1)}) \quad \text{bzw.} \quad \bar{\underline{x}}^{(2)'} = (\bar{x}_1^{(2)}, \bar{x}_2^{(2)}, \dots, \bar{x}_m^{(2)}).$$

Der ersten Aufgabe entspricht die Prüfung der Nullhypothese

$$H_0: \underline{\mu}^{(1)} = \underline{\mu}^{(2)} \quad \text{bzw.} \quad H_0: \underline{\mu}^{(1)} - \underline{\mu}^{(2)} = \underline{0}.$$

Die  $H_0$  enthält mehrere skalare Gleichungen. Gleichbedeutend lässt sich auch eine skalare Gleichung

$$H_0: \underline{a}'\underline{\mu}^{(1)} = \underline{a}'\underline{\mu}^{(2)} \quad \text{bzw.} \quad H_0: \underline{a}'(\underline{\mu}^{(1)} - \underline{\mu}^{(2)}) = 0$$

schreiben, wobei  $\underline{a}$  um ein  $m$ -dimensionaler Vektor ist. Diese Gleichung soll für beliebige  $\underline{a}' = (a_1, \dots, a_m)$  gelten.

Nun wird eine skalare Variable  $Y(\underline{a})$  definiert, die von der Wahl des Vektors  $\underline{a}$  abhängt:

$$Y(\underline{a}) = \underline{a}'\underline{X} = a_1X_1 + \dots + a_mX_m, \quad \underline{a} \neq \underline{0}.$$

Für die Erwartungswerte der beiden Gruppen gilt

$$\varepsilon Y^{(1)}(\underline{a}) = \underline{a}'\underline{\mu}^{(1)} \quad \text{bzw.} \quad \varepsilon Y^{(2)}(\underline{a}) = \underline{a}'\underline{\mu}^{(2)}$$

Die Varianz von  $Y^{(1)}(\underline{a})$  und  $Y^{(2)}(\underline{a})$  ist gleich, nämlich

$$\underline{a}'\underline{\Sigma}\underline{a}.$$

Die Mittelwerte der Beobachtungsdaten in den beiden Gruppen sind

$$\bar{y}^{(1)}(\underline{a}) = \underline{a}'\bar{x}^{(1)} \quad \text{bzw.} \quad \bar{y}^{(2)}(\underline{a}) = \underline{a}'\bar{x}^{(2)}.$$

Wenn die beiden Gruppen der Beobachtungswerte die Kovarianzmatrizen  $\underline{S}^{(1)}$  und  $\underline{S}^{(2)}$  liefern, dann hat die neue Variable  $y(\underline{a})$  die Varianz

$$\underline{a}'\underline{S}^{(1)}\underline{a} \quad \text{bzw.} \quad \underline{a}'\underline{S}^{(2)}\underline{a}.$$

Folglich ergibt  $Y(\underline{a})$  zwei unabhängige und varianzhomogene Gruppen skalarer Messwerte, die Normalverteilungen entstammen. Für sie gilt:  $H_0: \varepsilon Y^{(1)}(\underline{a}) = \varepsilon Y^{(2)}(\underline{a})$ .

Die Prüfung der  $H_0$  erfolgt durch den üblichen t-Test, wobei allerdings hier  $t^2$  betrachtet wird, da ohnehin nur eine zweiseitige Alternativhypothese interessiert. Also ergibt sich als Prüfgröße

$$t^2(\underline{a}) = \frac{(\bar{y}^{(1)}(\underline{a}) - \bar{y}^{(2)}(\underline{a}))^2}{\underline{a}'\underline{S}^{(1)}\underline{a}(n_1 - 1) + \underline{a}'\underline{S}^{(2)}\underline{a}(n_2 - 1)} \cdot \frac{n_1 n_2}{n_1 + n_2}.$$

Setzt man

$$\underline{S} = \frac{\underline{S}^{(1)}(n_1 - 1) + \underline{S}^{(2)}(n_2 - 1)}{n_1 + n_2 - 2}, \text{ dann wird}$$

$$\begin{aligned} t^2(\underline{a}) &= \frac{(\bar{y}^{(1)}(\underline{a}) - \bar{y}^{(2)}(\underline{a}))^2}{\underline{a}'\underline{S}\underline{a}} \cdot \frac{n_1 n_2}{n_1 + n_2} \\ &= \frac{(\underline{a}'(\bar{x}^{(1)} - \bar{x}^{(2)}))^2}{\underline{a}'\underline{S}\underline{a}} \cdot \frac{n_1 n_2}{n_1 + n_2} \\ &= \frac{\underline{a}'(\bar{x}^{(1)} - \bar{x}^{(2)})(\bar{x}^{(1)} - \bar{x}^{(2)})'\underline{a}}{\underline{a}'\underline{S}\underline{a}} \cdot \frac{n_1 n_2}{n_1 + n_2}. \end{aligned}$$

Das Ziel besteht darin,  $t^2(\underline{a})$  durch Wahl von  $\underline{a}$  zu maximieren. Aus der oben dargestellten Form ergibt sich, dass sich das maximierende  $\underline{a}$  durch jedes Vielfache seiner selbst ( $\neq \underline{0}$ ) ersetzen lässt.

Es ist (ohne Beweis) möglich,  $\underline{S} = \underline{S}^{1/2}\underline{S}^{1/2}$  zu bilden. Es gilt

$$\underline{S}^{1/2} = \underline{S}^{1/2}, \quad \text{und} \quad \underline{S}^{-1/2} = \underline{S}^{-1/2}.$$

Der o.g. Ausdruck lässt sich damit schreiben als

$$t^2(\underline{a}) = \frac{\underline{a}'\underline{S}^{1/2}\underline{S}^{-1/2}(\underline{\bar{x}}^{(1)} - \underline{\bar{x}}^{(2)})(\underline{\bar{x}}^{(1)} - \underline{\bar{x}}^{(2)})'\underline{S}^{1/2}\underline{S}^{-1/2}\underline{a}}{\underline{a}'\underline{S}^{1/2}\underline{S}^{1/2}\underline{a}} \cdot \frac{n_1 n_2}{n_1 + n_2}.$$

Wir nun gesetzt

$$\underline{h} = \underline{S}^{1/2}\underline{a} = \underline{S}^{1/2}\underline{a},$$

dann lässt sich  $t^2$  auch in Abhängigkeit von  $\underline{h}$  betrachten und schreiben als

$$t^2(\underline{h}) = \frac{\underline{h}'\underline{S}^{-1/2}(\underline{\bar{x}}^{(1)} - \underline{\bar{x}}^{(2)})(\underline{\bar{x}}^{(1)} - \underline{\bar{x}}^{(2)})'\underline{S}^{-1/2}\underline{h}}{\underline{h}'\underline{h}} \cdot \frac{n_1 n_2}{n_1 + n_2},$$

wobei  $\underline{h} \neq \underline{0}$ , wie auch von  $\underline{a}$  verlangt.

Es geht also jetzt darum,  $t^2(\underline{h})$  durch Wahl des geeigneten  $\underline{h}$  zu maximieren. Offensichtlich hängt  $t^2(\underline{h})$  nicht von der Länge von  $\underline{h}$  ab, so dass  $\underline{h}$  auch als Einheitsvektor genommen werden darf.

Bei  $\underline{S}^{-1/2}(\underline{\bar{x}}^{(1)} - \underline{\bar{x}}^{(2)})(\underline{\bar{x}}^{(1)} - \underline{\bar{x}}^{(2)})'\underline{S}^{-1/2}$  handelt es sich um eine symmetrische Matrix mit Rang 1, denn  $\underline{S}^{-1/2}(\underline{\bar{x}}^{(1)} - \underline{\bar{x}}^{(2)})$  ist ein Spaltenvektor.

Also ist  $\underline{h}'\underline{S}^{-1/2}(\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})$  ein Skalar, dessen Quadrat in  $t^2(\underline{h})$  entscheidend eingeht. Soll diese Zahl und damit ihr Quadrat maximal werden, dann muss  $\underline{h}$  als der parallel zu  $\underline{S}^{-1/2}(\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})$  verlaufende Einheitsvektor gewählt werden, also wird

$$\underline{h} = \underline{S}^{-1/2}(\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)}).$$

Da  $\underline{a} = \underline{S}^{-1/2}\underline{h}$ , wird entsprechend das maximierende

$$\underline{a} = \underline{S}^{-1}(\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)}).$$

Die Länge von  $\underline{a}$  ist unwesentlich, aber  $\underline{a} \neq \underline{0}$ .

Damit erhält man die Diskriminanzfunktion  $Y(\underline{a}) = \underline{a}'\underline{X}$ , die die Gruppen am besten trennt

$$Y = (\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})'\underline{S}^{-1}\underline{X}.$$

Damit wird die zweite Aufgabe, die Zuweisung zukünftiger Fälle zu einer der beiden Gruppen, gelöst: Ist  $\underline{x}$  ein Vektor, der neue Messwerte enthält, dann wird  $\underline{x}$  der Gruppe  $i = 1$  oder  $i = 2$  zugeordnet, zu der der Abstand von

$$(\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})'\underline{S}^{-1}\underline{x} \quad \text{zu} \quad (\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})'\underline{S}^{-1}\underline{x}^{(i)}$$

der kleinere ist.

Zu lösen ist noch die erste Aufgabe, nämlich die Frage, ob die beiden Gruppen gleiche Mittelwertsvektoren haben. Hierfür wird das maximale  $t^2(\underline{a}) = t^2_{\max}$  berechnet. Hierfür muss  $\underline{a} = \underline{S}^{-1}(\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})$  in die Formel zur Bestimmung des  $t^2(\underline{a})$  eingesetzt werden. Dies ergibt

$$t_{\max}^2 = \frac{(\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})' \underline{\underline{S}}^{-1} (\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)}) (\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})' \underline{\underline{S}}^{-1} (\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})}{\underbrace{(\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})' \underline{\underline{S}}^{-1} \underline{\underline{S}} \underline{\underline{S}}^{-1} (\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})}_{=1}} \cdot \frac{n_1 n_2}{n_1 + n_2}.$$

Durch Kürzen durch die Zahl  $(\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})' \underline{\underline{S}}^{-1} (\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})$  ergibt sich

$$t_{\max}^2 = (\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})' \underline{\underline{S}}^{-1} (\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)}) \cdot \frac{n_1 n_2}{n_1 + n_2}.$$

Bei  $(\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})' \underline{\underline{S}}^{-1} (\bar{\underline{x}}^{(1)} - \bar{\underline{x}}^{(2)})$  handelt es sich um die sog. quadrierte „Mahalanobis-Distanz“ zwischen den Gruppen  $D^2$ .  $D$  lässt eine Verallgemeinerung auf  $m \geq 2$  Gruppen zu. Damit wird

$$t_{\max}^2 = \frac{n_1 n_2}{n_1 + n_2} D^2.$$

Die Prüfung der  $H_0$  kann nun (ohne weiteren Beweis) erfolgen durch die Prüfgröße

$$F = \frac{n_1 + n_2 - m - 1}{m(n_1 + n_2 - 2)} \cdot t_{\max}^2, \quad df_1 = m, \quad df_2 = n_1 + n_2 - m - 1.$$

Damit sind beide Aufgaben gelöst.

## Anhang

### Prüfung der Gleichheit der Kovarianzmatrizen

Für die Prüfung der Gleichheit von Kovarianzmatrizen sind mehrere Verfahren bekannt. Ein Verfahren zur Prüfung der  $H_0: \underline{\Sigma}^{(1)} = \underline{\Sigma}^{(2)}$  findet sich z.B. bei Hartung/Elpelt, Multivariate Statistik, 7. Auflage, Oldenbourg 2007:

Die Prüfung der  $H_0$  erfolgt durch einen  $\chi^2$ -Test mit der Prüfgröße

$$\chi^2 = c \left[ \left( \sum_j n_j - k \right) \cdot \ln |\underline{S}| - \sum_j (n_j - 1) \cdot \ln |\underline{S}^{(j)}| \right], \text{ df} = m(m+1)(k-1)/2, \text{ wobei}$$

$$c = 1 - \frac{2m^2 + 3m - 1}{6(m+1)(k-1)} \left( \sum_j \frac{1}{n_j - 1} - 1 / \left( \sum_j (n_j - 1) \right) \right)$$

k bezeichnet die Zahl der Gruppen, hier also  $k = 2$ .

### Rechenbeispiel

#### Ausgangsdaten

Gruppe 1 („kreditwürdig“), fiktives Beispiel:

| x1  | Alter | Einkommen | Kinder | Autobesitz |
|-----|-------|-----------|--------|------------|
| x01 | 55    | 4503      | 0      | 1          |
| x02 | 44    | 1651      | 1      | 1          |
| x03 | 32    | 1518      | 2      | 0          |
| x04 | 18    | 1253      | 1      | 0          |
| x05 | 36    | 2471      | 0      | 1          |
| x06 | 43    | 2126      | 0      | 1          |
| x07 | 40    | 1272      | 3      | 0          |
| x08 | 34    | 1393      | 2      | 1          |
| x09 | 22    | 1626      | 1      | 0          |
| x10 | 51    | 1941      | 0      | 1          |

## Gruppe 2 („nicht kreditwürdig“), fiktives Beispiel:

X2

|     | Alter | Einkommen | Kinder | Autobesitz |
|-----|-------|-----------|--------|------------|
| x11 | 40    | 2869      | 3      | 0          |
| x12 | 39    | 1431      | 3      | 1          |
| x13 | 34    | 1567      | 3      | 0          |
| x14 | 31    | 1323      | 5      | 0          |
| x15 | 44    | 3384      | 4      | 1          |
| x16 | 55    | 1432      | 1      | 0          |
| x17 | 56    | 2161      | 4      | 0          |
| x18 | 47    | 2476      | 3      | 1          |
| x19 | 62    | 1896      | 2      | 1          |
| x20 | 43    | 2121      | 1      | 0          |

## Testvektor

|   | Alter | Einkommen | Kinder | Autobesitz |
|---|-------|-----------|--------|------------|
| x | 41    | 2500      | 1      | 1          |

## Kovarianzmatrizen

S1

|            | Alter       | Einkommen   | Kinder       | Autobesitz  |
|------------|-------------|-------------|--------------|-------------|
| Alter      | 136.944444  | 7115.8889   | -4.3333333   | 4.2222222   |
| Einkommen  | 7115.888889 | 938955.3778 | -620.6666667 | 248.0666667 |
| Kinder     | -4.3333333  | -620.6667   | 1.1111111    | -0.3333333  |
| Autobesitz | 4.222222    | 248.0667    | -0.3333333   | 0.2666667   |

S2

|            | Alter      | Einkommen   | Kinder      | Autobesitz  |
|------------|------------|-------------|-------------|-------------|
| Alter      | 99.655556  | 765.8889    | -5.6555556  | 1.2888889   |
| Einkommen  | 765.888889 | 466357.1111 | 139.4444444 | 102.5555556 |
| Kinder     | -5.655556  | 139.4444    | 1.6555556   | 0.0444444   |
| Autobesitz | 1.288889   | 102.5556    | 0.0444444   | 0.2666667   |

## Gesamtkovarianzmatrix

|            | Alter       | Einkommen   | Kinder       | Autobesitz  |
|------------|-------------|-------------|--------------|-------------|
| Alter      | 118.300000  | 3940.8889   | -4.9944444   | 2.7555556   |
| Einkommen  | 3940.888889 | 702656.2444 | -240.6111111 | 175.3111111 |
| Kinder     | -4.9944444  | -240.6111   | 1.3833333    | -0.1444444  |
| Autobesitz | 2.755556    | 175.3111    | -0.1444444   | 0.2666667   |

## Prüfung auf Gleichheit der Kovarianzen

"Chi<sup>2</sup>-Test auf Varianzhomogenität"

"Chi<sup>2</sup>="

12.92608

"Freiheitsgrade df="

10

"Irrtumswahrscheinlichkeit"

0.2278344 → *Die H<sub>0</sub> ist nicht widerlegt – gleiche Kovarianzen.*

## Prüfung auf Gleichheit der Mittelwertsvektoren

"F-Test auf Mittelwertunterschiede"

"F =

12.36453

"Freiheitsgrade df1="

2

"Freiheitsgrade df2="

17

"Irrtumswahrscheinlichkeit"

0.0004842702 → *Die H<sub>0</sub> ist widerlegt – es gibt unterschiedliche Mittelwertsvektoren.*

## Ergebnis unter Anwendung der Diskriminanzfunktion

"Diskriminanzfunktion  $Y = (x1_{\text{quer}} - x2_{\text{quer}})'S^{(-1)}X$ "

" $(x1_{\text{quer}} - x2_{\text{quer}})'S^{(-1)} =$ "

| Alter      | Einkommen     | Kinder    | Autobesitz |
|------------|---------------|-----------|------------|
| -0.1755371 | -0.0002046068 | -1.866666 | 1.687284   |

"Abstand Testvektor zu Gruppe 1: "

0.04680291

"Abstand Testvektor zu Gruppe 2: "

5.189939 → *Damit ist der Testvektor der Gruppe 1 zuzuordnen (die Person ist „kreditwürdig“).*

## R-Datenskript (Beispiel)

```
# Demo Matrix "Datensatz Diskriminanzanalyse"

# Eingabe der Datenfelder zunächst als Vektor,
# byrow = T: Zeilenweises einlesen!

# Alle Variablen löschen

rm(list=ls())

rnamen1 <- c("x01", "x02", "x03", "x04", "x05", "x06", "x07", "x08", "x09", "x10")
rnamen2 <- c("x11", "x12", "x13", "x14", "x15", "x16", "x17", "x18", "x19", "x20")
cnamen <- c("Alter", "Einkommen", "Kinder", "Autobesitz")

X1 <- matrix(c( 55, 4503, 0, 1,
               44, 1651, 1, 1,
               32, 1518, 2, 0,
               18, 1253, 1, 0,
               36, 2471, 0, 1,
               43, 2126, 0, 1,
               40, 1272, 3, 0,
               34, 1393, 2, 1,
               22, 1626, 1, 0,
               51, 1941, 0, 1
             ),
            nrow=10,
            byrow=T,
            dimnames = list(rnamen1, cnamen)
          )

X2 <- matrix(c( 40, 2869, 3, 0,
               39, 1431, 3, 1,
               34, 1567, 3, 0,
               31, 1323, 5, 0,
               44, 3384, 4, 1,
               55, 1432, 1, 0,
               56, 2161, 4, 0,
               47, 2476, 3, 1,
```

```
        62, 1896, 2, 1,  
        43, 2121, 1, 0  
    ),  
    nrow=10,  
    byrow=T,  
    dimnames = list(rnamen2, cnamen)  
  )  
  
# Zahl der Gruppen k  
  
k <- 2  
  
# Prüfvektor  
  
x <- c(41, 2500, 1, 1)
```

## R-Programmskript

```
# Programm zur Durchführung einer einfachen Diskriminanzanalyse

# V 0.2 vom 24./25.01.2010

# (c) Dr. Alexander Preuß

# Eine vollständige Datenmatrix X muss vorhanden sein!

# Bestimmung von n1, n2 und p (=Zahl der Merkmale)

n1 <- nrow(X1)

n2 <- nrow(X2)

m <- ncol(X1)

# Bestimmung der Mittelwertvektoren x1quer und x2quer

einsi1 <- c(rep(1,times=n1))
x1quer <- t(X1)%*%einsi1/n1

einsi2 <- c(rep(1,times=n2))
x2quer <- t(X2)%*%einsi2/n2

# Bestimmung der Kovarianzmatrizen S1 und S2

S1 <- cov(X1)
S2 <- cov(X2)

# Bildung der Gesamtkovarianzmatrix S

S <- (S1*(n1-1)+S2*(n2-1))/(n1+n2-2)

# Prüfung auf Varianzhomogenität der Kovarianzmatrizen

c <- 1-(((2*m*m+3*m-1)/(6*(m+1)*(k-1)))*(((1/(n1-1))-1)/(n1-1+n2-1))+(((1/(n2-1))-1)/(n1-1+n2-1)))
```

```
chi2 <- c*((n1+n2-2)*log(det(S))-(n1-1)*log(det(S1))-(n2-1)*log(det(S2)))
```

```
df_chi2 = m*(m+1)*(k-1)/2
```

```
print ("Chi2-Test auf Varianzhomogenität")
```

```
print ("Chi2=")
```

```
print (chi2)
```

```
print ("Freiheitsgrade df=")
```

```
print (df_chi2)
```

```
print ("Irrtumswahrscheinlichkeit")
```

```
print (1-pchisq(chi2,df_chi2))
```

```
print ("-----")
```

```
# Bestimmung der quadrierten Mahalanobisdistanz
```

```
D <- t((x1quer-x2quer))%*%solve(S)%*%(x1quer-x2quer)
```

```
# Bestimmung von t2max
```

```
t2max <- D*(n1*n2/(n1+n2))
```

```
# Bestimmung der Prüfgröße F
```

```
F <- (n1+n2-k-1)/(k*(n1+n2-2))*t2max
```

```
df_f1 <- k
```

```
df_f2 <- n1+n2-k-1
```

```
print ("F-Test auf Mittelwertunterschiede")
```

```
print ("F =")
```

```
print (F)
```

```
print ("Freiheitsgrade df1=")
```

```
print (df_f1)
```

```
print ("Freiheitsgrade df2=")
```

```
print (df_f2)
```

```
print ("Irrtumswahrscheinlichkeit")
```

```
print (1-pf(F,df_f1,df_f2))
```

```
print ("-----")
```

```
# Bestimmung der Entfernung des Prüfvektors zu den beiden Gruppen
```

```
d1 <- t((x1quer-x2quer))%*%solve(S)%*%x1quer
d2 <- t((x1quer-x2quer))%*%solve(S)%*%x2quer
d <- t((x1quer-x2quer))%*%solve(S)%*%x

a1 <- abs(d1-d)
a2 <- abs(d2-d)

print ("Diskriminanzfunktion  $Y = (x1quer-x2quer)'S^{(-1)}X$ ")
print ("( $x1quer-x2quer)'S^{(-1)} =$ ")
print (t((x1quer-x2quer))%*%solve(S))
print ("-----")

print ("Abstand Testvektor zu Gruppe 1: ")
print (a1)
print ("Abstand Testvektor zu Gruppe 2: ")
print (a2)
```