

# Formelsammlung zu Multivariate Verfahren

Version 07.04.2015

Diese Formelsammlung darf in der Klausur verwendet werden. Eigene Notizen und Ergänzungen dürfen eingefügt, aber keine zusätzlichen Blätter eingheftet werden.

## Inhaltsverzeichnis

|          |           |   |           |
|----------|-----------|---|-----------|
|          | 2.5       | Fishersche Diskriminanzanalyse  | 10        |
| <b>1</b> | <b>2</b>  | <b>Multivariate Schätz- und Testprobleme</b>  | <b>3</b>  |
| 1.1      | 2         | Schätzung im Ein-Stichprobenfall  | 2         |
| 1.2      | 3         | Schätzung im Mehr-Stichprobenfall   | 3         |
| 1.3      | 4         | Tests, Konfidenzbereiche für Erwartungswerte im Ein-Stichprobenfall; $\Sigma$ bekannt   | 4         |
| 1.4      | 4         | Tests, Konfidenzbereiche für Erwartungswerte im Ein-Stichprobenfall; $\Sigma$ unbekannt | 4         |
| 1.5      | 5         | Tests im Zwei-Stichprobenfall — unabhängige Stichproben                                 | 5         |
| 1.6      | 5         | Tests im Zwei-Stichprobenfall — verbundene Stichproben                                  | 5         |
| <b>2</b> | <b>6</b>  | <b>Diskriminanzanalyse/Klassifikation</b>   | <b>6</b>  |
| 2.1      | 6         | Relevante Größen:   | 6         |
| 2.2      | 6         | Bayes-Zuordnung:  | 6         |
| 2.3      | 8         | Kostenoptimale Bayes-Zuordnung:   | 8         |
| 2.4      | 9         | Zuordnungsregel unter der Voraussetzung Normalverteilung                                | 9         |
| <b>3</b> | <b>11</b> | <b>Clusteranalyse</b>   | <b>11</b> |
| 3.1      | 11        | Distanzmaße für Objekte:  | 11        |
| 3.2      | 11        | Distanzmaße:  | 11        |
| 3.3      | 12        | Distanzmaße für Klassen:  | 12        |
| 3.4      | 13        | Einige Grundbegriffe:   | 13        |
| 3.5      | 14        | Gütekriterien: quantitative Merkmale  | 14        |
| <b>4</b> | <b>14</b> | <b>Multivariate lineare Regression</b>  | <b>14</b> |
| 4.1      | 14        | Konzept   | 14        |
| 4.2      | 16        | Schätzen  | 16        |
| 4.3      | 17        | Testverfahren   | 17        |
| <b>5</b> | <b>17</b> | <b>Assoziationsstrukturen</b>   | <b>17</b> |
| 5.1      | 17        | Marginale, bedingte und partielle Korrelation   | 17        |
| 5.2      | 18        | Korrelationskoeffizienten bei vektoriellen Größen                                       | 18        |
| 5.3      | 18        | Multiple Korrelation  | 18        |
| 5.4      | 19        | Kanonische Korrelation  | 19        |
| <b>6</b> | <b>20</b> | <b>Hauptkomponentenanalyse</b>  | <b>20</b> |
| <b>7</b> | <b>21</b> | <b>Faktorenanalyse</b>  | <b>21</b> |

## 1 Multivariate Schätz- und Testprobleme

### 1.1 Schätzung im Ein-Stichprobenfall

#### Daten:

- Seien  $\mathbf{x}_1, \dots, \mathbf{x}_n$  unabhängige Wiederholungen von  $\mathbf{x}$  mit  $E(\mathbf{x}) = \boldsymbol{\mu}$  und Kovarianz  $\text{Var}(\mathbf{x}) = \boldsymbol{\Sigma}$

- Bezeichne  $\mathbf{X}$  die  $(n \times p)$ -Datenmatrix  $\mathbf{X} = \begin{pmatrix} \mathbf{x}'_1 & \dots & \mathbf{x}'_n \\ x_{11} & \dots & x_{1p} \\ \vdots & \ddots & \vdots \\ x_{n1} & \dots & x_{np} \end{pmatrix}$

#### Erwartungswertschätzung:

$$\bar{\mathbf{x}} = \frac{1}{n} \begin{pmatrix} \sum_{i=1}^n x_{i1} \\ \vdots \\ \sum_{i=1}^n x_{ip} \end{pmatrix} = \begin{pmatrix} \bar{x}_1 \\ \vdots \\ \bar{x}_p \end{pmatrix};$$

#### Empirische Kovarianzmatrix:

$$\mathbf{S} = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})' = \frac{1}{n-1} \left( \sum_{i=1}^n \mathbf{x}_i \mathbf{x}'_i - n \bar{\mathbf{x}} \bar{\mathbf{x}}' \right)$$

#### Alternativer Schätzer für $\boldsymbol{\Sigma}$ :

$$\hat{\boldsymbol{\Sigma}} = \frac{n-1}{n} \cdot \mathbf{S} \text{ „nicht erwartungstreu“}$$

#### Schätzung der Korrelationsmatrix: $\hat{\mathbf{R}} = (r_{ij})_{p \times p}$

$$r_{ij} = \frac{\sum_{s=1}^n (x_{si} - \bar{x}_i)(x_{sj} - \bar{x}_j)}{\sqrt{\sum_{s=1}^n (x_{si} - \bar{x}_i)^2} \sqrt{\sum_{s=1}^n (x_{sj} - \bar{x}_j)^2}}$$

#### Satz:

$\mathbf{x}_1, \dots, \mathbf{x}_n$  seien unabhängig und identisch  $p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ -verteilt. Dann gilt

- $E(\bar{\mathbf{x}}) = \boldsymbol{\mu}, E(\mathbf{S}) = \boldsymbol{\Sigma}$  (Unverzerrtheit),
- $\text{cov}(\bar{\mathbf{x}}) = \frac{1}{n} \boldsymbol{\Sigma}$ ,
- $E \|\bar{\mathbf{x}} - \boldsymbol{\mu}\|^2 \leq E \|\hat{\boldsymbol{\mu}} - \boldsymbol{\mu}\|^2$  für jeden anderen unverzerrten linearen Schätzer  $\hat{\boldsymbol{\mu}} = \hat{\boldsymbol{\mu}}(\mathbf{x}_1, \dots, \mathbf{x}_n) = a_1 \mathbf{x}_1 + \dots + a_n \mathbf{x}_n$ .

Sind  $\mathbf{x}_1, \dots, \mathbf{x}_n$  zusätzlich normalverteilt, dann gilt außerdem

- $\bar{\mathbf{x}} \sim N_p \left( \boldsymbol{\mu}, \frac{1}{n} \boldsymbol{\Sigma} \right)$  und  $(n-1)\mathbf{S} = \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})' \sim \mathbf{W}_p(\boldsymbol{\Sigma}, n-1)$ .
- $\bar{\mathbf{x}}$  und  $\mathbf{S}$  sind unabhängig.

## 1.2 Schätzung im Mehr-Stichprobenfall

**Daten:** Grundgesamtheit ist aufgespalten in disjunkten Klassen  $\Omega_1, \dots, \Omega_g$ . Separat in den Klassen werden Stichproben gezogen.

$$\begin{array}{l} \mathbf{x}_1^{(1)} \dots \mathbf{x}_{n_1}^{(1)} \text{ (aus } \Omega_1) \\ \vdots \\ \mathbf{x}_1^{(g)} \dots \mathbf{x}_{n_g}^{(g)} \text{ (aus } \Omega_g) \end{array}$$

**Arithmetisches Mittel in Klasse  $k$ :**

$$\bar{\mathbf{x}}^{(k)} = \frac{1}{n_k} \sum_{i=1}^{n_k} \mathbf{x}_i^{(k)} \rightarrow \boldsymbol{\mu}_k = \begin{pmatrix} \mu_1^{(k)} \\ \vdots \\ \mu_p^{(k)} \end{pmatrix}$$

**Empirische Kovarianzmatrix in Klasse  $k$ :**

$$\mathbf{S}^{(k)} = \frac{1}{n_k - 1} \sum_{i=1}^{n_k} (\mathbf{x}_i^{(k)} - \bar{\mathbf{x}}^{(k)})(\mathbf{x}_i^{(k)} - \bar{\mathbf{x}}^{(k)})' \rightarrow \boldsymbol{\Sigma}_k$$

Häufige Annahme:  $\boldsymbol{\Sigma}_1 = \boldsymbol{\Sigma}_2 = \dots = \boldsymbol{\Sigma}_g = \boldsymbol{\Sigma}$

Wenn Gleichheit gilt, dann nimmt man die gepoolte empirische Kovarianzmatrix:

$$\mathbf{S} = \frac{1}{n - g} \sum_{k=1}^g (n_k - 1) \mathbf{S}^{(k)} = \frac{1}{n - g} \sum_{k=1}^g \sum_{i=1}^{n_k} (\mathbf{x}_i^{(k)} - \bar{\mathbf{x}}^{(k)})(\mathbf{x}_i^{(k)} - \bar{\mathbf{x}}^{(k)})' = \frac{1}{n - g} \mathbf{W}.$$

wobei  $\mathbf{W} = \sum_{k=1}^g \sum_{i=1}^{n_k} (\mathbf{x}_i^{(k)} - \bar{\mathbf{x}}^{(k)})(\mathbf{x}_i^{(k)} - \bar{\mathbf{x}}^{(k)})'$  die Streuung innerhalb der Gruppen bezeichnet. Weiter bezeichnet

$$\mathbf{B} = \sum_{k=1}^g n_k (\bar{\mathbf{x}}^{(k)} - \bar{\mathbf{x}})(\bar{\mathbf{x}}^{(k)} - \bar{\mathbf{x}})'$$

die Streuung zwischen den Gruppen, wobei

$$\bar{\mathbf{x}} = \frac{1}{n} \sum_{k=1}^g n_k \bar{\mathbf{x}}^{(k)}$$

den großen Mittelwert über alle Klassen bezeichnet, mit

$$n = n_1 + n_2 + \dots + n_g$$

für die Gesamtstreuungsmatrix

$$\mathbf{T} = \sum_{k=1}^g \sum_{i=1}^{n_k} (\mathbf{x}_i^{(k)} - \bar{\mathbf{x}})(\mathbf{x}_i^{(k)} - \bar{\mathbf{x}})'$$

gilt die folgende Zerlegung

$$\mathbf{T} = \mathbf{W} + \mathbf{B}.$$

## 1.3 Tests, Konfidenzbereiche für Erwartungswerte im Ein-Stichprobenfall;

$\boldsymbol{\Sigma}$  bekannt

**Daten:**

- $\mathbf{x}_1, \dots, \mathbf{x}_n$  unabhängige Realisierungen der Stichprobenvariablen
- $\mathbf{x}_i \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma}); i = 1, \dots, n$

**Hypothesen:**

$$H_0 : \boldsymbol{\mu} = \boldsymbol{\mu}_0, H_1 : \boldsymbol{\mu} \neq \boldsymbol{\mu}_0$$

**Teststatistik:**

$$T^2 = n(\bar{\mathbf{x}} - \boldsymbol{\mu}_0)^T \boldsymbol{\Sigma}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}_0),$$

$$T^2 \stackrel{H_0}{\sim} \chi^2(p)$$

$H_0$  ablehnen, wenn gilt:

$$T^2 > \chi^2(p; 1 - \alpha)$$

## 1.4 Tests, Konfidenzbereiche für Erwartungswerte im Ein-Stichprobenfall;

$\boldsymbol{\Sigma}$  unbekannt

**Daten:**

- $\mathbf{x}_1, \dots, \mathbf{x}_n$  unabhängige Realisierungen der Stichprobenvariablen
- $\mathbf{x}_i \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  mit unbekanntem  $\boldsymbol{\Sigma}$

**Hypothesen:**

$$H_0 : \boldsymbol{\mu} = \boldsymbol{\mu}_0, H_1 : \boldsymbol{\mu} \neq \boldsymbol{\mu}_0$$

**Teststatistik:**

$$T_s = \frac{n(n-p)}{p(n-1)} (\bar{\mathbf{x}} - \boldsymbol{\mu}_0)^T \mathbf{S}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}_0),$$

$$T_s \stackrel{H_0}{\sim} F(p, n-p)$$

$H_0$  ablehnen, wenn gilt:

$$T_s > F(p, n-p; 1 - \alpha)$$

1.5 Tests im Zwei-Stichprobenfall — unabhängige Stichproben

Daten:

- $\mathbf{X}_1 = (\mathbf{x}_{11}, \dots, \mathbf{x}_{1n_1})^T$  ist eine unabhängige Stichprobe aus einer  $N_p(\boldsymbol{\mu}_1, \boldsymbol{\Sigma})$ -verteilten Grundgesamtheit,
- $\mathbf{X}_2 = (\mathbf{x}_{21}, \dots, \mathbf{x}_{2n_2})^T$  ist eine unabhängige Stichprobe aus einer  $N_p(\boldsymbol{\mu}_2, \boldsymbol{\Sigma})$ -verteilten Grundgesamtheit,
- Es werden gleiche Kovarianzmatrizen vorausgesetzt.

Hypothesen:

$$H_0 : \boldsymbol{\mu}_1 = \boldsymbol{\mu}_2, H_1 : \boldsymbol{\mu}_1 \neq \boldsymbol{\mu}_2$$

Teststatistik:

$$T^2 = \frac{n_1 \cdot n_2}{n_1 + n_2} \cdot (\bar{\mathbf{x}}_1 - \bar{\mathbf{x}}_2)^T \mathbf{S}^{-1} (\bar{\mathbf{x}}_1 - \bar{\mathbf{x}}_2)$$

mit  $\mathbf{S} = \frac{1}{n_1 + n_2 - 2} [(n_1 - 1)\mathbf{S}_1 + (n_2 - 1) \cdot \mathbf{S}_2]$

und  $\mathbf{S}_i = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (\mathbf{x}_j^{(i)} - \bar{\mathbf{x}}^{(i)})(\bar{\mathbf{x}}^{(i)} - \bar{\mathbf{x}}^{(i)})^T$

$H_0$  ablehnen:

$$\frac{n_1 + n_2 - p - 1}{(n_1 + n_2 - 2) \cdot p} \cdot T^2 > F(p; n_1 + n_2 - p - 1; 1 - \alpha)$$

weil  $\frac{n_1 + n_2 - p - 1}{(n_1 + n_2 - 2) \cdot p} \cdot T^2 \stackrel{H_0}{\sim} F(p; n_1 + n_2 - p - 1)$

1.6 Tests im Zwei-Stichprobenfall — verbundene Stichproben

Daten:

$$\begin{pmatrix} \mathbf{x}_i^{(1)} \\ \mathbf{x}_i^{(2)} \end{pmatrix} \sim N_{2p} \left( \begin{pmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \end{pmatrix}; \begin{pmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{12} \\ \boldsymbol{\Sigma}_{12} & \boldsymbol{\Sigma}_{22} \end{pmatrix} \right)$$

Hypothesen:

$$H_0 : \boldsymbol{\mu}_1 = \boldsymbol{\mu}_2 \Leftrightarrow \boldsymbol{\mu}_1 - \boldsymbol{\mu}_2 = \mathbf{0}, H_1 : \boldsymbol{\mu}_1 \neq \boldsymbol{\mu}_2$$

$$\mathbf{d}_i = \mathbf{x}_i^{(1)} - \mathbf{x}_i^{(2)} \Rightarrow H_0 \text{ besagt: } E(\mathbf{d}_i) = \mathbf{0}$$

$$\mathbf{d}_i \sim N_p(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2; \boldsymbol{\Sigma}_{11} + \boldsymbol{\Sigma}_{22} - \boldsymbol{\Sigma}_{12} - \boldsymbol{\Sigma}_{21})$$

Unbekannte Kovarianzmatrix:

$$H_0 \text{ ablehnen} \Leftrightarrow \frac{(n-p) \cdot n}{(n-1) \cdot p} \cdot \bar{\mathbf{d}}^T \cdot \mathbf{S}_d^{-1} \bar{\mathbf{d}} > F(p; n-p; 1-\alpha)$$

mit  $\bar{\mathbf{d}} = \frac{1}{n} \sum_{i=1}^n \mathbf{d}_i$

$$\mathbf{S}_d = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{d}_i - \bar{\mathbf{d}})(\mathbf{d}_i - \bar{\mathbf{d}})^T$$

Bekannte Kovarianzmatrix von  $\mathbf{d}$  sei  $\boldsymbol{\Sigma}_d$ :

$$H_0 \text{ ablehnen} \Leftrightarrow n \cdot \bar{\mathbf{d}}^T \cdot \boldsymbol{\Sigma}_d^{-1} \cdot \bar{\mathbf{d}} > \chi^2(p; 1-\alpha)$$

2 Diskriminanzanalyse/Klassifikation

2.1 Relevante Größen:

Wichtige Größen für das Klassifikationsproblem sind

- die *a priori*-Wahrscheinlichkeiten  $p(r) = P(Y = r), r = 1, \dots, k,$
- die *a posteriori*-Wahrscheinlichkeiten  $P(r | \mathbf{x}) = P(Y = r | \mathbf{x}), r = 1, \dots, k,$
- die *Verteilung der Merkmale*, gegeben die Klasse, bestimmt durch die Dichten  $f(\mathbf{x} | 1), \dots, f(\mathbf{x} | k).$
- die *Mischverteilung* der Population  $f(\mathbf{x}) = p(1)f(\mathbf{x} | 1) + \dots + p(k)f(\mathbf{x} | k).$

Satz von Bayes:

$$P(r | \mathbf{x}) = \frac{f(\mathbf{x} | r)p(r)}{f(\mathbf{x})} = \frac{f(\mathbf{x} | r)p(r)}{\sum_{i=1}^k p(i)P(\mathbf{x} | i)}$$

2.2 Bayes-Zuordnung:

$$\delta^*(\mathbf{x}) = r \Leftrightarrow P(r | \mathbf{x}) = \max_{i=1, \dots, k} P(i | \mathbf{x})$$

**Fehlklassifikationswahrscheinlichkeiten:**

Es lassen sich verschiedene Formen der Fehlklassifikationen durch die Zuordnungsregel  $\delta$  unterscheiden.

- **Wahrscheinlichkeit einer Fehlklassifikation, gegeben der feste Merkmalsvektor  $\mathbf{x}$**

$$\begin{aligned}\varepsilon(\mathbf{x}) &= P(\delta(\mathbf{x}) \neq Y | \mathbf{x}) = 1 - P(\delta(\mathbf{x}) = Y | \mathbf{x}) \\ &= 1 - P(\delta(\mathbf{x}) | \mathbf{x}).\end{aligned}$$

- **Verwechslungswahrscheinlichkeit oder individuelle Fehlerrate**

$$\varepsilon_{rs} = P(\delta(\mathbf{x}) = s | Y = r) = \int_{\mathbf{x}: \delta(\mathbf{x})=s} f(\mathbf{x} | r) d\mathbf{x}, \quad r \neq s$$

- **Globale Fehlklassifikationswahrscheinlichkeit oder Gesamt-Fehlerrate**

$$\varepsilon = P(\delta(\mathbf{x}) \neq Y)$$

- **Wahrscheinlichkeit einer Fehlklassifikation, gegeben das Objekt entstammt der Klasse  $r$**

$$\varepsilon_r = P(\delta(\mathbf{x}) \neq r | Y = r) = \sum_{s \neq r} \varepsilon_{rs}$$

Es gilt der Zusammenhang:

$$\begin{aligned}\varepsilon &= P(\delta(\mathbf{x}) \neq Y) = \sum_{r=1}^k P(\delta(\mathbf{x}) \neq r | Y = r) p(r) = \sum_{r=1}^k \varepsilon_r p(r) \\ &= \sum_{r=1}^k \sum_{s \neq r} \varepsilon_{rs} p(r) \\ \varepsilon &= P(\delta(\mathbf{x}) \neq Y) = \int P(\delta(\mathbf{x}) \neq Y | \mathbf{x}) f(\mathbf{x}) d\mathbf{x} = \int \varepsilon(\mathbf{x}) f(\mathbf{x}) d\mathbf{x}\end{aligned}$$

**Optimalität der Bayes-Zuordnung** Die Bayes-Zuordnung

$$\delta^*(\mathbf{x}) = r \iff P(r | \mathbf{x}) = \max_{i=1, \dots, k} P(i | \mathbf{x})$$

minimiert die Gesamtfehlerrate  $\varepsilon$ .

**Äquivalente Diskriminanzfunktionen:**

- $d_r(\mathbf{x}) = P(r | \mathbf{x})$ ,
- $d_r(\mathbf{x}) = f(\mathbf{x} | r) p(r) / f(\mathbf{x})$ .
- $d_r(\mathbf{x}) = f(\mathbf{x} | r) p(r)$ .
- $d_r(\mathbf{x}) = \log(f(\mathbf{x} | r)) + \log(p(r))$ .

**Maximum-Likelihood-(ML)-Zuordnungsregel**

$$\delta_{ML}(\mathbf{x}) = r \iff f(\mathbf{x} | r) = \max_{i=1, \dots, k} f(\mathbf{x} | i)$$

**2.3 Kostenoptimale Bayes-Zuordnung:**

$$c(i, j) = c_{ij} = \text{Kosten einer Zuordnung eines Objekts aus Klasse } i \text{ in die Klasse } j.$$

Für  $I = j$  gelte  $c_{ii} = 0$ . d.h. die Kosten einer richtigen Zuordnung sind Null, während  $c_{ij} \geq 0$  für  $i \neq j$ .

**Bedingtes Risiko, gegeben  $\mathbf{x}$** 

$$r(\mathbf{x}) = \sum_{i=1}^k c_{i, \delta(\mathbf{x})} P(i | \mathbf{x}).$$

**Individuelles Risiko**

$$r_{ij} = c_{ij} P(\delta(\mathbf{x}) = j | Y = i) = c_{ij} \int_{\mathbf{x}: \delta(\mathbf{x})=j} f(\mathbf{x} | i) d\mathbf{x}$$

**Risiko, gegeben Klasse  $i$** 

$$r_i = \sum_{j=1}^k r_{ij}.$$

Das **gesamte Bayes Risiko**, d.h. die zu erwartenden Kosten, lassen sich darstellen durch

$$R = E(c(Y, \delta(\mathbf{x}))) = \sum_{i=1}^k r_i p(i) = \int r(\mathbf{x}) f(\mathbf{x}) d\mathbf{x}.$$

**Bayes-Zuordnung mit Kosten** Bei Vorliegen des Beobachtungsvektors  $\mathbf{x}$  wird das Bayes-Risiko minimiert durch die Zuordnung

$$\delta^*(\mathbf{x}) = r \iff \sum_{i=1}^k P(i | \mathbf{x}) c_{ir} = \min_{j=1, \dots, k} \sum_{i=1}^k P(i | \mathbf{x}) c_{ij}$$

Mit den Diskriminanzfunktionen

$$d_r(\mathbf{x}) = - \sum_{i=1}^k P(i | \mathbf{x}) c_{ir},$$

erhält man

$$\delta^*(\mathbf{x}) = r \iff d_r(\mathbf{x}) = \max_{i=1, \dots, k} d_i(\mathbf{x}).$$

## 2.4 Zuordnungsregel unter der Voraussetzung Normalverteilung

Klassenverteilungen:

$$f(\mathbf{x} | i) = \frac{1}{(2\pi)^{p/2}(\det \Sigma_i)^{1/2}} \cdot \exp\left\{-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_i)^T \Sigma_i^{-1}(\mathbf{x} - \boldsymbol{\mu}_i)\right\}$$

Bayes-Regel:

$$\begin{aligned} d_i(\mathbf{x}) &= \ln(f(\mathbf{x} | i)) + \ln(p(i)) \\ d_i(\mathbf{x}) &= -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_i)^T \Sigma_i^{-1}(\mathbf{x} - \boldsymbol{\mu}_i) - \frac{1}{2} \ln(\det \Sigma_i) + \ln p(i), \quad i = 1, \dots, k. \end{aligned}$$

Zusätzlich unabhängige standardisierte Merkmale,  $\Sigma_i = \sigma^2 \mathbf{I}$ :

$$d_i(\mathbf{x}) = -\frac{\|\mathbf{x} - \boldsymbol{\mu}_i\|^2}{2\sigma^2} + \ln p(i)$$

Sind die a priori Wahrscheinlichkeiten gleich groß, so reduziert sich die Diskriminanzfunktion auf

$$d_i(\mathbf{x}) = -\|\mathbf{x} - \boldsymbol{\mu}_i\|^2$$

Klassenweise identische Kovarianzmatrizen;  $\Sigma_i = \Sigma$ ,  $i = 1, \dots, k$ :

$$d_i(\mathbf{x}) = -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_i)^T \Sigma^{-1}(\mathbf{x} - \boldsymbol{\mu}_i) + \ln p(i)$$

$$d_i(\mathbf{x}) = \boldsymbol{\mu}_i^T \Sigma^{-1} \mathbf{x} - \frac{1}{2} \boldsymbol{\mu}_i^T \Sigma^{-1} \boldsymbol{\mu}_i + \ln p(i), \quad i = 1, \dots, k$$

Für  $k=2$  erhält man:

$$d(\mathbf{x}) = d_1(\mathbf{x}) - d_2(\mathbf{x}) = \left[\mathbf{x} - \frac{1}{2}(\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2)\right]^T \Sigma^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) - \ln \frac{p(2)}{p(1)}$$

Für die ML-Regel sind die  $\ln$ -Terme wegzulassen.Schätzer für  $\boldsymbol{\mu}_k$  und  $\Sigma$ :  $\hat{\boldsymbol{\mu}}_i = \bar{\mathbf{x}}_i$ ,

$$\hat{\Sigma} = \mathbf{S} = \frac{1}{N-g} \sum_{i=1}^k \sum_{n=1}^{n_i} (\mathbf{x}_{in} - \bar{\mathbf{x}}_i)(\mathbf{x}_{in} - \bar{\mathbf{x}}_i)^T$$

## 2.5 Fishersche Diskriminanzanalyse

Daten:  $\mathbf{x}_{i1} \dots \mathbf{x}_{in_i}$  in der Klasse  $i$ **Grundprinzip (Zwei-Klassen-Fall):**Projektion  $y = \mathbf{a}^T \mathbf{x}$  mit  $\|\mathbf{a}\| = 1$ ,

so dass das folgende Kriterium maximiert wird

$$Q(\mathbf{a}) = \frac{(\bar{y}_1 - \bar{y}_2)^2}{s_1^2 + s_2^2},$$

wobei

$$\bar{y}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \mathbf{a}^T \mathbf{x}_{ij} = \mathbf{a}^T \bar{\mathbf{x}}_i \text{ Klassenmittelpunkt,}$$

$$s_i^2 = \sum (\mathbf{a}^T \mathbf{x}_{ij} - \mathbf{a}^T \bar{\mathbf{x}}_i)^2 \text{ Quadratische Abweichungen } i\text{-te Klasse.}$$

**Lösung:**

$$\mathbf{a} = \mathbf{W}^{-1}(\bar{\mathbf{x}}_1 - \bar{\mathbf{x}}_2)$$

mit

$$\mathbf{W} = (n_1 + n_2 - 2)\mathbf{S} = \sum_{i=1}^2 \sum_{j=1}^{n_i} (\mathbf{x}_{ij} - \bar{\mathbf{x}}_i)(\mathbf{x}_{ij} - \bar{\mathbf{x}}_i)^T.$$

**Mehr-Klassen-Fall: Kriterium:**

$$Q(\mathbf{a}) = \frac{\sum_{i=1}^g n_i (\bar{y}_i - \bar{y})^2}{\sum_{i=1}^g s_i^2} \rightarrow \max$$

**Resultierende Eigenvektoren:**

$$\mathbf{a}_1, \dots, \mathbf{a}_q, \quad q = \text{rg}(\mathbf{B})$$

**Resultierende Eigenwerte:**

$$\lambda_1 = \frac{\mathbf{a}_1^T \mathbf{B} \mathbf{a}_1}{\mathbf{a}_1^T \mathbf{W} \mathbf{a}_1}, \dots, \lambda_q = \frac{\mathbf{a}_q^T \mathbf{B} \mathbf{a}_q}{\mathbf{a}_q^T \mathbf{W} \mathbf{a}_q}$$

mit

$$\mathbf{B} = \sum_{i=1}^g n_i (\bar{\mathbf{x}}_i - \bar{\mathbf{x}})(\bar{\mathbf{x}}_i - \bar{\mathbf{x}})^T$$

$$\mathbf{W} = \sum_{i=1}^g \sum_{j=1}^{n_i} (\mathbf{x}_{ij} - \bar{\mathbf{x}}_i)(\mathbf{x}_{ij} - \bar{\mathbf{x}}_i)^T.$$

### 3 Clusteranalyse

Objektmenge  $\Omega = \{a_1, \dots, a_n\}$

Zugehörige Merkmalsvektoren  $\{x_1, \dots, x_n\}$

Gesucht: Partition = disjunkte vollständige Zerlegung  $C_1, \dots, C_g$  so daß

$$\bigcup_{i=1}^g C_i = \{a_1, \dots, a_n\}, C_i \cap C_j = \emptyset$$

#### 3.1 Distanzmaße für Objekte:

$$d: \Omega \times \Omega \rightarrow \mathbb{R}_+$$

mit

$$d(a_i, a_i) = 0,$$

$$d(a_i, a_j) \geq 0,$$

$$d(a_i, a_j) = d(a_j, a_i).$$

Für metrische Distanzmaße: zusätzlich Dreiecksungleichung

$$d(a_i, a_j) \leq d(a_i, a_m) + d(a_m, a_j) \text{ für alle } a_i, a_j, a_m$$

#### 3.2 Distanzmaße:

**Binäre Merkmale**

$$\mathbf{x}_i^T = (x_{i1}, \dots, x_{ip}) \text{ mit } x_{ij} \in \{0, 1\}$$

$h_{ij}(y, z)$  bezeichnet die Anzahl der übereinstimmenden Komponenten in  $\mathbf{x}_i$  und  $\mathbf{x}_j$  mit Ausprägung  $y$  in  $\mathbf{x}_i$  und  $z$  in  $\mathbf{x}_j$ .

$$h_{ij}(y, z) = |\{s \mid (x_{is}, x_{js}) = (y, z)\}| \text{ für } (y, z) \in \{(0, 0), (0, 1), (1, 0), (1, 1)\}.$$

Matching-Koeffizient

$$s_{ij} = \frac{h_{ij}(1, 1) + h_{ij}(0, 0)}{p}$$

Distanz Matching-Koeffizient (Anzahl nicht übereinstimmender Merkmale)

$$d_{ij} = 1 - s_{ij}$$

**Metrische Merkmale**

$$\mathbf{x} = (x_1, \dots, x_p), \mathbf{y} = (y_1, \dots, y_p)$$

$L_q$ -Metrik

$$d(\mathbf{x}, \mathbf{y}) = \left( \sum_{i=1}^p |x_i - y_i|^q \right)^{1/q}$$

$q = 1$  City-Block-Metrik

$q = 2$  Euklidische Metrik

Mahalanobis-Distanz

$$d(\mathbf{x}, \mathbf{y}) = (\mathbf{x} - \mathbf{y})^T \mathbf{S}^{-1} (\mathbf{x} - \mathbf{y})$$

mit empirischer Kovarianzmatrix  $\mathbf{S}$

#### 3.3 Distanzmaße für Klassen:

Form:  $D(C_r, C_s)$  wobei  $C_r, C_s \subset \Omega$

1. Single Linkage-Verfahren

$$D(C_r, C_s) = \min_{\substack{a_i \in C_r \\ a_j \in C_s}} d(a_i, a_j)$$

2. Complete Linkage-Verfahren

$$D(C_r, C_s) = \max_{\substack{a_i \in C_r \\ a_j \in C_s}} d(a_i, a_j)$$

3. Average Linkage-Verfahren

$$D(C_r, C_s) = \frac{1}{n_r n_s} \sum_{a_i \in C_r} \sum_{a_j \in C_s} d(a_i, a_j)$$

$$\text{mit } n_i = |C_i|$$

4. Zentroid-Verfahren

$$D(C_r, C_s) = \|\bar{\mathbf{x}}_r - \bar{\mathbf{x}}_s\|^2$$

$$\text{mit } \bar{\mathbf{x}}_i = \frac{1}{n_i} \sum_{\mathbf{x}_j \in C_i} \mathbf{x}_j$$

### 3.4 Einige Grundbegriffe:

Mittelwert in Klasse  $C_k$

$$\bar{\mathbf{x}}_k = \frac{1}{n_k} \sum_{i=1}^{n_k} \mathbf{x}_i \text{ mit } n_k = |C_k|$$

Streuung in Klasse  $C_k$

$$\mathbf{W}(C_k) = \sum_{\mathbf{x}_i \in C_k} (\mathbf{x}_i - \bar{\mathbf{x}}_k)(\mathbf{x}_i - \bar{\mathbf{x}}_k)^T$$

Streuung der Partition  $\mathbb{C}$  innerhalb der Klassen

$$\mathbf{W}(\mathbb{C}) = \sum_{k=1}^g \mathbf{W}(C_k)$$

Streuung der Partition  $\mathbb{C}$  zwischen den Klassen

$$\mathbf{B}(\mathbb{C}) = \sum_{k=1}^g n_k (\bar{\mathbf{x}}_k - \bar{\mathbf{x}})(\bar{\mathbf{x}}_k - \bar{\mathbf{x}})^T \text{ mit } \bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i$$

Die Gesamtstreuung

$$\mathbf{T} = \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T$$

ist zerlegbar in

$$\mathbf{T} = \mathbf{W}(\mathbb{C}) + \mathbf{B}(\mathbb{C})$$

### 3.5 Gütekriterien: quantitative Merkmale

Partition  $\mathbb{C} = \{C_1, \dots, C_g\}$

#### 1. Varianzkriterium

$$H(\mathbb{C}) = \sum_{k=1}^g \sum_{\mathbf{x}_i \in C_k} \|\mathbf{x}_i - \bar{\mathbf{x}}_k\|^2$$

Minimum-Distanz-Eigenschaft

$$\|\mathbf{x}_i - \bar{\mathbf{x}}_k\| \leq \|\mathbf{x}_i - \bar{\mathbf{x}}_j\| \text{ für } \mathbf{x}_i \in C_k$$

#### 2. Determinantenkriterium

$$H(\mathbb{C}) = |\mathbf{W}(\mathbb{C})|$$

Minimum-Distanz-Eigenschaft

$$(\mathbf{x}_i - \bar{\mathbf{x}}_k)^T \mathbf{W}(\mathbb{C})^{-1} (\mathbf{x}_i - \bar{\mathbf{x}}_k) \leq (\mathbf{x}_i - \bar{\mathbf{x}}_j)^T \mathbf{W}(\mathbb{C})^{-1} (\mathbf{x}_i - \bar{\mathbf{x}}_j) \text{ für } \mathbf{x}_i \in C_k$$

#### 3. Verallgemeinertes Determinantenkriterium

$$H(\mathbb{C}) = \sum_{k=1}^g n_k \ln\left(\frac{1}{n_k} \mathbf{W}(C_k)\right)$$

## 4 Multivariate lineare Regression

### 4.1 Konzept

Daten:

$$(\mathbf{y}_i, \mathbf{x}_i), \quad i = 1, \dots, n \text{ mit}$$

$$\mathbf{y}_i^T = (y_{i1}, \dots, y_{iq}) \quad q \text{ abhängige Variablen}$$

$$\mathbf{x}_i^T = (1, x_{i1}, \dots, x_{ip}) \quad p \text{ konstante und fixe Prädiktoren}$$

**Klassisches lineares Modell:**

$$y_{ij} = \mathbf{x}_i^T \boldsymbol{\beta}_{(j)} + \varepsilon_{ij}, i = 1, \dots, n, j = 1, \dots, q,$$

**Matrixdarstellungen:**  
**Vektorielle Form**

$$\begin{pmatrix} y_{i1} \\ \vdots \\ y_{iq} \end{pmatrix} = \begin{pmatrix} \mathbf{x}_i^T & & \\ & \mathbf{x}_i^T & \\ & & \ddots \\ & & & \mathbf{x}_i^T \end{pmatrix} \begin{pmatrix} \boldsymbol{\beta}_{(1)} \\ \vdots \\ \boldsymbol{\beta}_{(q)} \end{pmatrix} + \begin{pmatrix} \varepsilon_{i1} \\ \vdots \\ \varepsilon_{iq} \end{pmatrix}$$

bzw.

$$\mathbf{y}_i = \mathbf{X}_i \boldsymbol{\beta} + \boldsymbol{\varepsilon}_i$$

und als Gesamtmodell

$$\mathbf{y} = \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\varepsilon}.$$

wobei

$$\boldsymbol{\beta}_{(j)}^T = (\beta_{0j}, \beta_{1j}, \dots, \beta_{qj}), \quad \boldsymbol{\beta}^T = (\boldsymbol{\beta}_{(1)}^T, \dots, \boldsymbol{\beta}_{(q)}^T).$$

**Multivariate Formulierung I**

$$\begin{pmatrix} \mathbf{y}_1^T \\ \vdots \\ \mathbf{y}_n^T \end{pmatrix} = \begin{pmatrix} \mathbf{x}_1^T \\ \vdots \\ \mathbf{x}_n^T \end{pmatrix} (\boldsymbol{\beta}_{(1)}, \dots, \boldsymbol{\beta}_{(q)}) + \begin{pmatrix} \boldsymbol{\varepsilon}_1^T \\ \vdots \\ \boldsymbol{\varepsilon}_n^T \end{pmatrix}$$

**Multivariate Formulierung II**

$$(\mathbf{y}_{(1)}, \dots, \mathbf{y}_{(q)}) = \begin{pmatrix} \mathbf{x}_1^T \\ \vdots \\ \mathbf{x}_n^T \end{pmatrix} (\boldsymbol{\beta}_{(1)}, \dots, \boldsymbol{\beta}_{(q)}) + (\boldsymbol{\varepsilon}_{(1)}, \dots, \boldsymbol{\varepsilon}_{(q)})$$

bzw. als Gesamtmodell

$$\mathbf{Y} = \mathbf{X}_0 \mathbf{B} + \mathbf{E}$$

mit  $\mathbf{X}_0 = \begin{pmatrix} \mathbf{x}_1^T \\ \vdots \\ \mathbf{x}_n^T \end{pmatrix}, \boldsymbol{\beta}_{(j)} = \begin{pmatrix} \beta_{0j} \\ \vdots \\ \beta_{pj} \end{pmatrix}, \mathbf{y}_{(j)} = \begin{pmatrix} y_{1j} \\ \vdots \\ y_{nj} \end{pmatrix}, \boldsymbol{\varepsilon}_{(j)} = \begin{pmatrix} \varepsilon_{1j} \\ \vdots \\ \varepsilon_{nj} \end{pmatrix}.$

**Annahmen:**

- (1)  $E(\boldsymbol{\varepsilon}_i) = \mathbf{0}$
- (2)  $\text{cov}(\boldsymbol{\varepsilon}_i) = \boldsymbol{\Sigma}, i = 1, \dots, n$   
 $\text{cov}(\boldsymbol{\varepsilon}_s, \boldsymbol{\varepsilon}_t) = \mathbf{0}, s \neq t$   
 $\Rightarrow \text{cov}(\boldsymbol{\varepsilon}_{(s)}, \boldsymbol{\varepsilon}_{(t)}) = \sigma_{st} \mathbf{I}, s \neq t$
- (3) Normalverteilung,  $\boldsymbol{\varepsilon}_i \sim N(\mathbf{0}, \boldsymbol{\Sigma})$

## 4.2 Schätzen

**Kleinste Quadrate-Schätzung**

$$\sum_{j=1}^q (\mathbf{y}_{(j)} - \mathbf{X}_0 \boldsymbol{\beta}_{(j)})^T (\mathbf{y}_{(j)} - \mathbf{X}_0 \boldsymbol{\beta}_{(j)}) \rightarrow \min$$

Lösung (voller Rang von  $\mathbf{X}$ ):

$$\hat{\boldsymbol{\beta}}_{(j)} = (\mathbf{X}_0^T \mathbf{X}_0)^{-1} \mathbf{X}_0^T \mathbf{y}_{(j)} \text{ bzw. } \hat{\mathbf{B}} = (\mathbf{X}_0^T \mathbf{X}_0)^{-1} \mathbf{X}_0^T \mathbf{Y}$$

Als Vektor

$$\hat{\boldsymbol{\beta}} = \mathbf{B} \text{Diag}\{(\mathbf{X}_0^T \mathbf{X}_0)^{-1} \mathbf{X}_0^T\} \mathbf{y}_0 \text{ oder } \hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}.$$

mit

$$\mathbf{y}_0^T = (\mathbf{y}_{(1)}^T, \dots, \mathbf{y}_{(q)}^T), \mathbf{y}^T = (\mathbf{y}_1^T, \dots, \mathbf{y}_n^T).$$

**Schätzung der Kovarianz:**

$$\hat{\boldsymbol{\Sigma}} = \frac{1}{n-p-1} \sum_{i=1}^n (\mathbf{y}_i - \mathbf{X}_i \hat{\boldsymbol{\beta}})(\mathbf{y}_i - \mathbf{X}_i \hat{\boldsymbol{\beta}})^T$$

$$\hat{\boldsymbol{\Sigma}} = \frac{1}{n-p-1} \mathbf{E}^T \mathbf{E}$$

wobei

$$\mathbf{E} = \mathbf{Y} - \mathbf{X}_0 \hat{\mathbf{B}} \text{ Residuenmatrix.}$$

**Gauß-Markov-Theorem** (Annahmen (1) und (2))

- (1)  $E(\hat{\mathbf{B}}) = \mathbf{B}, E(\hat{\boldsymbol{\Sigma}}) = \boldsymbol{\Sigma}$
- (2)  $\text{Var}(\hat{\boldsymbol{\beta}}_{(i)}, \hat{\boldsymbol{\beta}}_{(j)}) = \sigma_{ij} (\mathbf{X}_0^T \mathbf{X}_0)^{-1}$
- (3)  $\hat{\mathbf{B}}$  ist BLUE

Weiter gilt mit Normalverteilungsannahme

- (4)  $\hat{\mathbf{B}}$  ist normalverteilt
- (5)  $\mathbf{Q}_e = \hat{\mathbf{E}}^T \hat{\mathbf{E}} \sim W_p(\boldsymbol{\Sigma}, n-p-1)$
- (6)  $\hat{\mathbf{B}}$  und  $\hat{\boldsymbol{\Sigma}}$  sind unabhängig



### 4.3 Testverfahren

**Tests:** (Unter Normalverteilungsannahme)

$$H_0 : \mathbf{CB} = \mathbf{\Gamma} \quad H_1 : \mathbf{CB} \neq \mathbf{\Gamma} \quad \text{rg}(\mathbf{C}) = s$$

$$\Lambda = \frac{|\mathbf{Q}_e|}{|\mathbf{Q}_0|} \sim \Lambda(q, n - p - 1, s)$$

mit  $\mathbf{Q}_e = (\mathbf{Y} - \mathbf{X}_0\hat{\mathbf{B}})^T(\mathbf{Y} - \mathbf{X}_0\hat{\mathbf{B}})$  ohne Restriktion

$\mathbf{Q}_0 = (\mathbf{Y} - \mathbf{X}_0\hat{\mathbf{B}}_0)^T(\mathbf{Y} - \mathbf{X}_0\hat{\mathbf{B}}_0)$  mit Restriktion

$H_0$  ablehnen, wenn  $\Lambda < \Lambda_\alpha(q, n - p - 1, s)$

## 5 Assoziationsstrukturen

### 5.1 Marginale, bedingte und partielle Korrelation

**Marginale Korrelation** von  $Y$  und  $X$

$$\rho_{YX} = \frac{\text{cov}(Y, X)}{\sigma_Y \sigma_X}$$

**Bedingte Korrelation** von  $Y$  und  $X$ , gegeben  $Z = z$

$$\rho_{YX|Z=z} = \frac{\text{cov}(Y, X|Z=z)}{\sqrt{\text{var}(Y|Z=z)}\sqrt{\text{var}(X|Z=z)}}$$

**Partielle Korrelation** von  $Y$  und  $X$  nach Elimination des linearen Anteils von  $Z$

$$\rho_{XY \cdot Z} = \frac{\text{cov}(\varepsilon_{Y \cdot Z}, \varepsilon_{X \cdot Z})}{\sqrt{\text{var}(\varepsilon_{Y \cdot Z})}\sqrt{\text{var}(\varepsilon_{X \cdot Z})}} = \frac{\rho_{YX} - \rho_{XZ}\rho_{YZ}}{\sqrt{1 - \rho_{YZ}^2}\sqrt{1 - \rho_{XZ}^2}},$$

mit  $\varepsilon_{Y \cdot Z}, \varepsilon_{X \cdot Z}$  als Residuen aus den Regressionsmodellen

$$Y = \beta_0 + \beta Z + \varepsilon_{Y \cdot Z} \quad \text{und} \quad X = \gamma_0 + \gamma Z + \varepsilon_{X \cdot Z}.$$

Für  $(Y, X, Z)$  gemeinsam normalverteilt gilt

$$\rho_{YX|Z=z} = \rho_{XY \cdot Z}.$$

### 5.2 Korrelationskoeffizienten bei vektoriellen Größen

**Ausgangspunkt:** Zufallsvektoren  $y, x$  und  $z$  mit

$$\boldsymbol{\mu} = \mathbf{E} \begin{pmatrix} y \\ x \\ z \end{pmatrix} = \begin{pmatrix} \mu_y \\ \mu_x \\ \mu_z \end{pmatrix}, \quad \boldsymbol{\Sigma} = \text{cov} \begin{pmatrix} y \\ x \\ z \end{pmatrix} = \begin{pmatrix} \Sigma_{yy} & \Sigma_{yx} & \Sigma_{yz} \\ \Sigma_{xy} & \Sigma_{xx} & \Sigma_{xz} \\ \Sigma_{zy} & \Sigma_{zx} & \Sigma_{zz} \end{pmatrix}$$

**Marginale Korrelationsmatrix** für  $y$  gegeben  $x$ :

$$\mathbf{K} = (k_{ij}) \text{ mit } k_{ij} = \sigma_{y_i x_j} / (\sigma_{y_i} \sigma_{x_j}),$$

wobei  $\sigma_{y_i x_j}$  Einträge von  $\boldsymbol{\Sigma}_{yx}$ .

Matrix der **bedingten Kovarianzen** für  $y$  und  $x$  gegeben  $z = \bar{z}$ :

$$\boldsymbol{\Sigma}_{yx|z=\bar{z}} = (\text{cov}(y_i, x_j | z = \bar{z}))_{ij}.$$

**Partielle Korrelation** skalarer Merkmale  $y$  und  $x$  nach Elimination des linearen Anteils von  $z$ :

$$\varrho_{xy \cdot z} = \frac{\text{cov}(\varepsilon_{y \cdot z}, \varepsilon_{x \cdot z})}{\sqrt{\text{var}(\varepsilon_{y \cdot z})}\sqrt{\text{var}(\varepsilon_{x \cdot z})}} = \frac{\sigma_{yx} - \boldsymbol{\Sigma}_{yz} \boldsymbol{\Sigma}_z^{-1} \boldsymbol{\Sigma}_{zx}}{\sqrt{\sigma_y^2 - \boldsymbol{\Sigma}_{yz} \boldsymbol{\Sigma}_z^{-1} \boldsymbol{\Sigma}_{zy}} \sqrt{\sigma_x^2 - \boldsymbol{\Sigma}_{xz} \boldsymbol{\Sigma}_z^{-1} \boldsymbol{\Sigma}_{zx}}},$$

wobei  $\varepsilon_{y \cdot z} = y - \mathbf{z}^T \boldsymbol{\beta}$  und  $\varepsilon_{x \cdot z} = x - \mathbf{z}^T \boldsymbol{\gamma}$ .

### 5.3 Multiple Korrelation

**Ausgangspunkt:** lineares Regressionsmodell  $y = \mathbf{x}^T \boldsymbol{\beta} + \varepsilon_{y \cdot \mathbf{x}}$ , damit ergibt sich

$$\text{var}(\mathbf{x}^T \boldsymbol{\beta}) = \boldsymbol{\Sigma}_{yx} \boldsymbol{\Sigma}_x^{-1} \boldsymbol{\Sigma}_{xy} = \text{cov}(y, \mathbf{x}^T \boldsymbol{\beta})$$

$$\text{var}(y|\mathbf{x}) = \text{var}(\varepsilon_{y \cdot \mathbf{x}}) = \sigma_y^2 - \boldsymbol{\Sigma}_{yx} \boldsymbol{\Sigma}_x^{-1} \boldsymbol{\Sigma}_{xy}$$

und die Zerlegung

$$\text{var}(y) = \text{var}(\mathbf{x}^T \boldsymbol{\beta}) + \text{var}(y|\mathbf{x}).$$

**Multipler Korrelationskoeffizient:**

$$R = \varrho(y, \mathbf{x}^T \boldsymbol{\beta}) = \frac{\text{cov}(y, \mathbf{x}^T \boldsymbol{\beta})}{\sqrt{\text{var}(y)}\sqrt{\text{var}(\mathbf{x}^T \boldsymbol{\beta})}}.$$

Es gilt

$$R^2 = \frac{\text{var}(\mathbf{x}^T \boldsymbol{\beta})}{\text{var}(y)} = 1 - \frac{\text{var}(y|\mathbf{x})}{\text{var}(y)}.$$

## 5.4 Kanonische Korrelation

**Ausgangspunkt:** Zufallsvektoren  $\mathbf{y}$  und  $\mathbf{x}$  der Länge  $p$  bzw.  $q$  mit  $\Sigma_{\mathbf{xy}} = \text{cov}(\mathbf{x}, \mathbf{y})$ .

Betrachte **Maximierungsproblem**

$$\varrho(\mathbf{a}^T \mathbf{x}, \mathbf{b}^T \mathbf{y}) \xrightarrow{\mathbf{a}, \mathbf{b}} \max$$

mit der Nebenbedingung  $\text{var}(\mathbf{a}^T \mathbf{x}) = \text{var}(\mathbf{b}^T \mathbf{y}) = 1$ .

wobei

$$\varrho(\mathbf{a}, \mathbf{b}) = \varrho(\mathbf{a}^T \mathbf{x}, \mathbf{b}^T \mathbf{y}) = \frac{\text{cov}(\mathbf{a}^T \mathbf{x}, \mathbf{b}^T \mathbf{y})}{\sqrt{\text{var}(\mathbf{a}^T \mathbf{x})} \sqrt{\text{var}(\mathbf{b}^T \mathbf{y})}} = \frac{\mathbf{a}^T \Sigma_{\mathbf{xy}} \mathbf{b}}{\sqrt{\mathbf{a}^T \Sigma_{\mathbf{xx}} \mathbf{a}} \sqrt{\mathbf{b}^T \Sigma_{\mathbf{yy}} \mathbf{b}}}.$$

Lösen des Maximierungsproblems für  $i = 1, \dots, s = \min\{p, q\}$  mit

$$\text{cov}(\mathbf{a}_i \mathbf{x}, \mathbf{a}_j \mathbf{x}) = \text{cov}(\mathbf{b}_i \mathbf{y}, \mathbf{b}_j \mathbf{y}) = 0 \quad \text{für } i \neq j.$$

ergibt

$\mathbf{a}_i, \mathbf{b}_i$  als die *iten Korrelationsvektoren*,

$u_i = \mathbf{a}_i^T \mathbf{x}, v_i = \mathbf{b}_i^T \mathbf{y}$  als *ite Korrelationsvariablen* und

$\varrho_i = \varrho(u_i, v_i)$  als *ite kanonische Korrelationskoeffizienten*.

Für  $\mathbf{u}^T = (u_1, \dots, u_s)$  und  $\mathbf{v}^T = (v_1, \dots, v_s)$  gilt

$$\text{cor} \begin{pmatrix} \mathbf{u} \\ \mathbf{v} \end{pmatrix} = \begin{pmatrix} 1 & \cdots & 0 & \varrho_1 & \cdots & 0 \\ \vdots & & \vdots & \vdots & & \vdots \\ 0 & \cdots & 1 & 0 & \cdots & \varrho_s \\ \varrho_1 & \cdots & 0 & 1 & \cdots & 0 \\ \vdots & & \vdots & \vdots & & \vdots \\ 0 & \cdots & \varrho_s & 0 & \cdots & 1 \end{pmatrix}.$$

**Schärfere Formulierung** des Maximierungsproblems:

$$\varrho(\mathbf{a}_i^T \mathbf{x}, \mathbf{b}_i^T \mathbf{y}) \xrightarrow{\mathbf{a}_i, \mathbf{b}_i} \max$$

mit den Nebenbedingungen

$$\text{var}(\mathbf{a}_i^T \mathbf{x}) = \text{var}(\mathbf{b}_i^T \mathbf{y}) = 1, \quad i = 1, \dots, s$$

$$\text{cov}(\mathbf{a}_i^T \mathbf{x}, \mathbf{a}_j^T \mathbf{x}) = \text{cov}(\mathbf{b}_i^T \mathbf{y}, \mathbf{b}_j^T \mathbf{y}) = 0, \quad j = 1, \dots, i-1.$$

Lösungen  $(\mathbf{a}_i, \mathbf{b}_i)$  über das **kombinierte Eigenwertproblem**

$$(\Sigma_{\mathbf{xy}} \Sigma_{\mathbf{yy}}^{-1} \Sigma_{\mathbf{yx}} - \lambda_i \Sigma_{\mathbf{xx}}) \mathbf{a}_i = 0$$

$$(\Sigma_{\mathbf{yx}} \Sigma_{\mathbf{xx}}^{-1} \Sigma_{\mathbf{xy}} - \lambda_i \Sigma_{\mathbf{yy}}) \mathbf{b}_i = 0$$

## 6 Hauptkomponentenanalyse

**Ausgangsgrößen:**

$$\mathbf{x}^T = (x_1, \dots, x_p)$$

$$\boldsymbol{\mu} = \mathbf{E}(\mathbf{x}), \Sigma = \text{cov}(\mathbf{x})$$

**Problem:**

$y_i = \mathbf{a}_i^T \mathbf{x}, i = 1, \dots, p$  so dass

$$\text{var}(y_i) = \mathbf{a}_i^T \Sigma \mathbf{a}_i, \text{ maximal}$$

**Restriktionen:**

$$(1) \mathbf{a}_i^T \mathbf{a}_i = 1$$

$$(2) \mathbf{a}_i^T \mathbf{a}_j = 0, j = 1, \dots, i-1$$

Äquivalent ist

$$\text{cov}(y_i, y_j) = 0, j = 1, \dots, i-1$$

**Lösung:**

$$\mathbf{y} = \Psi^T \mathbf{x} \quad \text{mit } \mathbf{y}^T = (y_1, \dots, y_p)$$

wobei

$$\Sigma = \Psi \Lambda \Psi^T$$

$$\Lambda = \text{diag}(\lambda_1, \dots, \lambda_p), \lambda_1 \geq \lambda_2 \geq \dots \lambda_p$$

$$\Psi = (\mathbf{a}_1, \dots, \mathbf{a}_p)$$

**Eigenschaften:**

$$(1) \text{cov}(\mathbf{y}) = \Lambda \quad (\text{var}(y_i) = \lambda_i, \text{cov}(y_i, y_j) = 0, i \neq j)$$

$$(2) \text{tr}(\Sigma) = \text{tr}(\Lambda)$$

## 7 Faktorenanalyse

### Modell:

$$\mathbf{X} - \boldsymbol{\mu} = \boldsymbol{\Gamma}\mathbf{F} + \mathbf{U},$$

wobei

- $\mathbf{X}$  ( $p \times 1$ ) - Vektor der beobachtbaren Größen
- $\boldsymbol{\mu}$  Erwartungswert von  $\mathbf{X}$
- $\mathbf{F}$  ( $k \times 1$ ) - Vektor der Faktoren
- $\boldsymbol{\Gamma}$  ( $p \times k$ ) - Matrix der Faktorladungen
- $\mathbf{U}$  ( $p \times 1$ ) - Vektor der spezifischen Faktoren

### Annahmen:

- (1)  $E(\mathbf{F}) = \mathbf{0}$
- (2)  $\mathbf{U} \sim V(0, \boldsymbol{\Psi})$ , mit  $\boldsymbol{\Psi} = \text{diag}(\Psi_1^2, \dots, \Psi_p^2)$
- (3)  $\text{cov}(\mathbf{F}, \mathbf{U}) = \mathbf{0}$
- (4)  $\text{cov}(\mathbf{F}) = \mathbf{I}$  orthogonales Faktormodell

Fundamentaltheorem für  $\mathbf{s} = \text{cov}(\mathbf{X})$ .

$$\mathbf{s} = \boldsymbol{\Gamma}\boldsymbol{\Gamma}' + \boldsymbol{\Psi}$$

Insbesondere:

$$\text{var}(X_i) = \sum_{j=1}^m \gamma_{ij}^2 + \Psi_i^2, \quad \text{cov}(\mathbf{X}, \mathbf{F}) = \boldsymbol{\Gamma}$$

**Rotationsproblem** (Eindeutigkeit von  $\boldsymbol{\Gamma}$  bei gegebenem  $k, \boldsymbol{\Psi}$ )

$$\boldsymbol{\Gamma}'\boldsymbol{\Psi}^{-1}\boldsymbol{\Gamma} = \text{diag}(\lambda_1, \dots, \lambda_k), \quad \lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k.$$