


Signifikanztests bei einer einfachen Stichprobe



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests

Quellen
Tabellen



- ▶ Gegeben: Einfache Stichprobe $X_1, \dots, X_n \sim N(\mu; \sigma)$
- ▶ Hypothesenpaare:

$$\begin{aligned} \text{a) } H_0 : \sigma^2 &= \sigma_0^2 & H_1 : \sigma^2 &\neq \sigma_0^2 \\ \text{b) } H_0 : \sigma^2 &= \sigma_0^2 \quad (\text{oder } \sigma^2 \geq \sigma_0^2), & H_1 : \sigma^2 &< \sigma_0^2 \\ \text{c) } H_0 : \sigma^2 &= \sigma_0^2 \quad (\text{oder } \sigma^2 \leq \sigma_0^2), & H_1 : \sigma^2 &> \sigma_0^2 \end{aligned}$$

▶ Vorgehensweise:

Beispiel
 $\alpha = 0.1$

- 1 Festlegen des **Signifikanzniveaus** α .
- 2 Festlegen des **Verwerfungsbereichs**:

$$x_{\alpha/2} = x_{0,05} \approx$$

$$x_{1-\alpha/2} = x_{0,95} \approx$$

$$\begin{aligned} \checkmark B &= [0; x_{\alpha/2}) \cup (x_{1-\alpha/2}; \infty) && \text{im Fall a)} \\ B &= [0; x_{\alpha}) && \text{im Fall b)} \\ B &= (x_{1-\alpha}; \infty) && \text{im Fall c)} \end{aligned}$$

Fraktile
der $\chi^2(n-1)$
Verteilung

- 3 Berechnung des **Testfunktionswertes**:

$$v = \frac{(n-1)s^2}{\sigma_0^2} = \frac{1}{\sigma_0^2} \sum_{i=1}^n (x_i - \bar{x})^2$$

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests

Quellen
Tabellen



Beispiel: $G \sim N(\mu; \sigma)$

$(x_1, \dots, x_{10}) = (2100; 2130; 2150; 2170; 2210; 2070; 2230; 2150; 2230; 2200)$

Prüfe $H_0 : \sigma = 40$, $H_1 : \sigma \neq 40$ zum Signifikanzniveau $\alpha = 0,1$

Lösung: χ^2 -Test für die Varianz, Hypothese Fall a);

Voraussetzungen sind erfüllt

① $\alpha = 0,1$

② $\chi^2(9) : x_{\frac{\alpha}{2}} = x_{0,05} = 3,33; x_{1-\frac{\alpha}{2}} = x_{0,95} = 16,92$
(Tabelle der χ^2 -Verteilung)

$$\Rightarrow B = [0; 3,33) \cup (16,92; \infty)$$

③ $\bar{x} = \frac{1}{10} (2100 + 2130 + \dots + 2200) = 2164$


$$v = \frac{1}{40^2} [(2100 - 2164)^2 + \dots + (2200 - 2164)^2] = 16,65$$

$\Rightarrow v \notin B \Rightarrow H_0$ nicht verwerfen

1. Einführung
2. Deskriptive Statistik
3. W-Theorie

Freiheitsgrade: hier $10 - 1 = 9$

$\downarrow \alpha \setminus n \rightarrow$	1	2	3	4	5	6	7	8	9
0.005	0.00	0.01	0.07	0.21	0.41	0.68	0.99	1.34	1.73
0.01	0.00	0.02	0.11	0.30	0.55	0.87	1.24	1.65	2.09
0.025	0.00	0.05	0.22	0.48	0.83	1.24	1.69	2.18	2.70
0.05	0.00	0.10	0.35	0.71	1.15	1.64	2.17	2.73	3.33
0.1	0.02	0.21	0.58	1.06	1.61	2.20	2.83	3.49	4.17
0.2	0.06	0.45	1.01	1.65	2.34	3.07	3.82	4.59	5.38
0.25	0.10	0.58	1.21	1.92	2.67	3.45	4.25	5.07	5.90
0.4	0.28	1.02	1.87	2.75	3.66	4.57	5.49	6.42	7.36
0.5	0.45	1.39	2.37	3.36	4.35	5.35	6.35	7.34	8.34
0.6	0.71	1.83	2.95	4.04	5.13	6.21	7.28	8.35	9.41
0.75	1.32	2.77	4.11	5.39	6.63	7.84	9.04	10.22	11.39
0.8	1.64	3.22	4.64	5.99	7.29	8.56	9.80	11.03	12.24
0.9	2.71	4.61	6.25	7.78	9.24	10.64	12.02	13.36	14.68
0.95	3.84	5.99	7.81	9.49	11.07	12.59	14.07	15.51	16.92





- ▶ Situation: In Grundgesamtheit G: **Zwei verbundene einfache Stichproben**, also Beobachtung **zweier Merkmale X, Y**
- ▶ Hypothese:

H_0 : Die beiden Merkmale X und Y sind in G **unabhängig**.
 H_1 : X und Y sind in G **abhängig**.

Vorgehensweise Kontingenztest:

- 1 Festlegen des **Signifikanzniveaus** α .
- 2 Unterteilung der x -Achse in $k \geq 2$ und die y -Achse in $l \geq 2$ disjunkte, aneinander angrenzende Intervalle A_1, \dots, A_k bzw. B_1, \dots, B_l
- 3 Erstellen einer Kontingenztabelle mit Randhäufigkeiten:

$x \downarrow y \rightarrow$	B_1	B_2	\dots	B_l	
A_1	h_{11}	h_{12}	\dots	h_{1l}	$h_{1\bullet}$
A_2	h_{21}	h_{22}	\dots	h_{2l}	$h_{2\bullet}$
\vdots	\vdots	\vdots	\vdots	\vdots	
A_k	h_{k1}	h_{k2}	\dots	h_{kl}	$h_{k\bullet}$
	$h_{\bullet 1}$	$h_{\bullet 2}$	\dots	$h_{\bullet l}$	n

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests

Quellen
Tabellen

Vorgehensweise Kontingenztest (Fortsetzung):

- 4 Mit dem Fraktilswert $x_{1-\alpha}$ der χ^2 -Verteilung mit $(k-1) \cdot (l-1)$ Freiheitsgraden: Berechnung des **Verwerfungsbereichs**

$$B = (x_{1-\alpha}; \infty)$$

- 5 Zu jeder Kombination aus $i = 1, \dots, k$ und $j = 1, \dots, l$: Berechnung der Größe

$$\tilde{h}_{ij} = \frac{h_{i\bullet} \cdot h_{\bullet j}}{n}$$

- 6 Berechnung des **Testfunktionswerts** v :

$$v = \sum_{i=1}^k \sum_{j=1}^l \frac{(\tilde{h}_{ij} - h_{ij})^2}{\tilde{h}_{ij}} = \sum_{i=1}^k \sum_{j=1}^l \frac{h_{ij}^2}{\tilde{h}_{ij}} - n$$

- 7 **Ablehnung** von H_0 genau dann, wenn $v \in B$.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
Grundlagen
Punkt-Schätzung
Intervall-Schätzung
Signifikanztests

- Quellen
Tabellen



Kontingenztest: Beispiel

- ▶ 400 Erstkandidaten einer praktischen Führerscheinprüfung schneiden abhängig von der besuchten Fahrschule abgängermaßen ab:

	Fahrschule		
	A	B	C
bestanden	130	88	62
durchgefallen	70	38	12

- ▶ Zum Signifikanzniveau von 5% soll getestet werden, ob das Bestehen der Prüfung unabhängig von der besuchten Fahrschule ist.

Testdurchführung

- 1 Signifikanzniveau $\alpha = 5\%$
- 2 entfällt, da Skalenniveau nominal
- 3 Kontingenztafel:

	A	B	C	Σ
best.	130	88	62	280
durchg.	70	38	12	120
Σ	200	126	74	400

- 4 Berechnung der \tilde{h}_{ij} :

	A	B	C
best.	140	88,2	51,8
durchg.	60	37,8	22,2

- 5 χ^2 -Verteilung mit $(3 - 1) \cdot (2 - 1) = 2$ Freiheitsgraden:
 $x_{1-0,05} = x_{0,95} = 5,99$:

$$B = (5,99; \infty)$$

- 6
$$v = \frac{(130 - 140)^2}{140} + \dots + \frac{(12 - 22,2)^2}{22,2} \approx 9,077$$

- 7 $v \in B$: Also wird H_0 abgelehnt, die Prüfungsergebnisse sind abhängig von der Fahrschule.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests

Quellen
Tabellen

- 1 Statistik: Einführung
- 2 Deskriptive Statistik
- 3 Wahrscheinlichkeitstheorie
- 4 Induktive Statistik
- 5 Datenanalyse Einleitung
- 6 Repräsentation
- 7 Klassifikation




Bildquelle: Newton (2007)

- 6 **Repräsentation**
Einführung
Hauptkomponentenanalyse

Ziele der Repräsentation

- ▶ Anordnung der Objekte in einem möglichst niedrig dimensionierten Raum,
- ▶ so dass die relative Lage der sich ergebenden Punkte (Objekte) die Ähnlichkeit der Objekte angemessen beschreibt.



- ▶ **Aufdeckung von Gruppierungen** leichter (Kontrolle einer Klassifikation)
- ▶ Durch **Interpretation der Achsen** evtl. Aufschluss über den Grund der Lage bestimmter Objekte



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation

Einführung
Hauptkomponentenanalyse

Varianten der Repräsentation: Hauptkomponentenanalyse

- ▶ Berechnung der Repräsentation aus Varianz-Kovarianz-Strukturen der Datenmatrix

$$A = (a_{ik})_{n \times m} \xrightarrow{\text{Hauptkomponentenanalyse}} X = (x_{ik})_{n \times q}$$

z.B. 205×15 205×2

- ▶ Vorgehen: Datenmatrix wird direkt verarbeitet
- ▶ Problem: Lassen sich die m quantitativen Merkmale sinnvoll durch q (meist 2 oder 3) sogenannte **Faktoren** ersetzen?
- ▶ Voraussetzung: Datenmatrix darf nur metrische Merkmale enthalten

Typische Fragestellungen der **Hauptkomponentenanalyse** in der Marktforschung

- ▶ Läßt sich die Vielzahl der Eigenschaften, die die Käufer einer Marke als wichtig empfinden, auf wenige komplexe Faktoren reduzieren?
- ▶ Wie lassen sich darauf aufbauend die verschiedenen Marken anhand dieser Faktoren beschreiben?



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
 - Einführung
 - Hauptkomponentenanalyse

Repräsentation: Beispiel Hauptkomponentenanalyse




```
require(FactoMineR)
data(decathlon)
summary(decathlon)
```

```
##      100m      Long_jump      Shot.put
## Min. :10.4 Min. :6.61 Min. :12.7
## 1st Qu.:10.8 1st Qu.:7.03 1st Qu.:13.9
## Median :11.0 Median :7.30 Median :14.6
## Mean :11.0 Mean :7.26 Mean :14.5
## 3rd Qu.:11.1 3rd Qu.:7.48 3rd Qu.:15.0
## Max. :11.6 Max. :7.96 Max. :16.4
## High_jump      400m      110m.hurdle
## Min. :1.85 Min. :46.8 Min. :14.0
## 1st Qu.:1.92 1st Qu.:48.9 1st Qu.:14.2
## Median :1.95 Median :49.4 Median :14.5
## Mean :1.98 Mean :49.6 Mean :14.6
## 3rd Qu.:2.04 3rd Qu.:50.3 3rd Qu.:15.0
## Max. :2.15 Max. :53.2 Max. :15.7
## Discus      Pole.vault      Javeline
## Min. :37.9 Min. :4.20 Min. :50.3
## 1st Qu.:41.9 1st Qu.:4.50 1st Qu.:55.3
## Median :44.4 Median :4.80 Median :58.4
## Mean :44.3 Mean :4.76 Mean :58.3
## 3rd Qu.:46.1 3rd Qu.:4.92 3rd Qu.:60.9
## Max. :51.6 Max. :5.40 Max. :70.5
## 1500m      Rank      Points
## Min. :262 Min. : 1.0 Min. :7313
## 1st Qu.:271 1st Qu.: 6.0 1st Qu.:7802
## Median :278 Median :11.0 Median :8021
## Mean :279 Mean :12.1 Mean :8005
## 3rd Qu.:285 3rd Qu.:18.0 3rd Qu.:8122
## Max. :317 Max. :28.0 Max. :8893
## Competition
## Decastar:13
## OlympicG:28
##
##
##
```

```
decathlon$Long_jump = 10 - decathlon$Long_jump
decathlon.pca = prcomp(decathlon[,1:10], scale=TRUE)
round(decathlon.pca$sdev, 3)
```

```
## [1] 1.809 1.318 1.185 1.028 0.828 0.774 0.672 0.630
## [9] 0.463 0.427
```

```
biplot(decathlon.pca, cex=0.5)
```



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
- Einführung
Hauptkomponentenanalyse

Varianten der Repräsentation: Mehrdimensionale Skalierung

- ▶ Berechnung der Repräsentation aus der Distanzmatrix

$$A = (a_{ik})_{n \times m} \xrightarrow{\text{Distanz}} D = (d_{ij})_{n \times n} \xrightarrow{\text{MDS}} X = (x_{il})_{n \times q}$$

- ▶ Meistens: $q \in \{1, 2, 3\}$
- ▶ Datenmatrix wird nicht direkt verarbeitet; Umweg über Distanzmatrix
- ▶ Keine Anforderung an das Skalenniveau der Merkmale

Typische Fragestellungen der MDS in der BWL:

- ▶ Welche Produkte einer Gruppe sind sich ähnlich/unähnlich?
- ▶ Inwieweit entspricht das eigene Produkt den Idealvorstellungen der Konsumenten?
- ▶ Welches Image besitzt eine bestimmte Marke?
- ▶ Hat sich die Einstellung der Konsumenten zu einer Marke in den letzten Jahren verändert



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation

Einführung
Hauptkomponentenanalyse



Faktorenanalyse: Grundlegende Idee

- ▶ Welche Aussagen lassen sich über die Struktur des Zusammenhangs von Merkmalsvariablen treffen?
- ▶ Idee: Darstellung der Struktur in den Daten durch **paarweise Korrelationen**
- ▶ Bei m gemessenen Merkmalen gibt es $\frac{m \cdot (m-1)}{2}$ Korrelationen
- ▶ m groß: Analyse des gesamten Variablenkomplexes dann oft schwierig.
- ▶ Einschränkung: HKA ist **bivariate Analyse**; betrachtet also nur jeweils den Zusammenhang je zweier Variablen; Beziehungen zwischen mehr als zwei Merkmalen werden nicht berücksichtigt

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

5. Datenanalyse

6. Repräsentation

Einführung

Hauptkomponentenanalyse



Hauptaufgaben der Faktorenanalyse

- ▶ Extraktion von hypothetischen Merkmalen, den sog. **Faktoren**, aus den Merkmalen und ihren Beziehungen
- ▶ Also: Korrelierende Merkmale werden zu Merkmalspaketen zusammengefasst (**Faktorextraktion**)
- ▶ Damit **Reduktion** der Komplexität in den Ausgangsdaten: Anstelle von m Variablen wenige Faktoren
- ▶ Dabei: Möglichst **wenig Informationsverlust**
- ▶ Durch Datenkompression: Evtl. leichtere Interpretation und Übersicht
- ▶ Außerdem: Faktoren sind konstruktionsbedingt unkorreliert und damit qualifiziert als Ausgangsbasis für korrelationsensible Verfahren (z.B. Regression)

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

5. Datenanalyse

6. Repräsentation

Einführung

Hauptkomponentenanalyse



- ▶ Bevorzugte Variante der Faktorenanalyse bei metrischen Datenmatrizen: **Hauptkomponentenanalyse**.
- ▶ Dabei unterstellt: Lineare Beziehung zwischen den ursprünglich erhobenen und den neu zu bestimmenden hypothetischen Größen (Faktoren).
- ▶ Damit: Merkmalsvektoren α^k (Spaltenvektor) lassen sich als Linearkombination von q Faktoren x^1, \dots, x^q (Spaltenvektoren) darstellen.
- ▶ Im Falle $q = m$ immer möglich:

$$\alpha^k = \sum_{i=1}^m f_{ki} x^i \quad (k = 1, \dots, m)$$

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation

Einführung
Hauptkomponentenanalyse



Faktoren und Ladungsvektoren

- ▶ Matriziell: $A = X \cdot F^T$ bzw. mit Koeffizienten:

$$\begin{pmatrix} a_{11} & \cdots & a_{1m} \\ \vdots & & \vdots \\ a_{i1} & \cdots & a_{im} \\ \vdots & & \vdots \\ a_{n1} & \cdots & a_{nm} \end{pmatrix} = \begin{pmatrix} x_{11} & \cdots & x_{1q} \\ \vdots & & \vdots \\ \vdots & x_{ik} & \vdots \\ \vdots & & \vdots \\ x_{n1} & \cdots & x_{nq} \end{pmatrix} \cdot \begin{pmatrix} f_{11} & \cdots & f_{k1} & \cdots & f_{m1} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ f_{1q} & \cdots & f_{kq} & \cdots & f_{mq} \end{pmatrix}$$

- ▶ Mit:

x_{ip}	als	Faktorwert	f_{kp}	als	Faktorladung
x^p	als	Faktor	f^k	als	Ladungsvektoren
X	als	Faktorwertematrix	F	als	Faktorladungsmatrix

- ▶ Damit: Ein Objekt i , dargestellt durch die Zeile i der Datenmatrix A wird nun mit Hilfe der **Zeile i der Faktorwertematrix X** repräsentiert


1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
 - Einführung
 - Hauptkomponentenanalyse



- ▶ Problem: Ist diese Darstellung **ohne großen Informationsverlust** möglich?
- ▶ Dazu nötig: Maß für den **Informationsgehalt** einer Daten- bzw. Faktorwertematrix
- ▶ Also: Kovarianzmatrizen $S = \text{Cov}(A)$ und $C = \text{Cov}(X)$ als Basis für Informationsmaß
- ▶ Übliche Annahme: Informationsgehalt von Merkmalen/Faktoren ist umso größer, je größer die **Varianz** dieser Merkmale/Faktoren ist.
- ▶ Damit: Maß für **Gesamtvariabilität** aller Merkmale/Faktoren über Summe der Varianzen aller betrachteten Merkmale/Faktoren
- ▶ $\text{Spur}(S)$ bzw. $\text{Spur}(C)$ ermöglicht so einen Vergleich des Informationsgehaltes der beiden Matrizen.
(Summe der Varianzen entspricht Spur der Kovarianzmatrix)

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation

Einführung
Hauptkomponentenanalyse



$$A = \begin{pmatrix} 22 & 5 \\ 25 & 10 \\ 21 & 4 \\ 28 & 13 \\ 24 & 8 \end{pmatrix} \Rightarrow \text{Varianz-} \begin{matrix} \text{S} \\ \text{Kovarianz-} \\ \text{matrix} \end{matrix} = \begin{pmatrix} 6 & 8 \\ 8 & 10,8 \end{pmatrix}$$

Annotations: δ_x^2 (variance of x), δ_y^2 (variance of y), $r \cdot \delta_x \cdot \delta_y$ (covariance), r (correlation coefficient).

$$\text{Varianz (Altu)} : \frac{1}{n} \sum (a_i^{\text{Altu}} - \bar{a}^{\text{Altu}})^2$$

$$\text{Semester} : \frac{1}{n} \sum (a_i^{\text{Semester}} - \bar{a}^{\text{Semester}})^2$$

$$S = \text{Cov}(A) = \begin{pmatrix} \text{Var}(\text{Altu}) & \text{Cov}(\text{Altu}, \text{Semester}) \\ \text{Cov}(\text{Altu}, \text{Semester}) & \text{Var}(\text{Semester}) \end{pmatrix}$$

$$\text{Cov}(\text{Altu}, \text{Semester}) = \frac{1}{n} \sum (a_i^{\text{Altu}} - \bar{a}^{\text{Altu}})(a_i^{\text{Semester}} - \bar{a}^{\text{Semester}})$$

$$\text{TR} : r \cdot \delta_x \cdot \delta_y$$

Berechnung des Informationsgehaltes

- Für Datenmatrix A : Kovarianzmatrix $S = (s_{kl})_{m \times m}$:

$$s_{kl} = \frac{1}{n} \sum_{i=1}^n (a_{ik} - \bar{a}_{\cdot k})(a_{il} - \bar{a}_{\cdot l}) \quad \text{mit} \quad \bar{a}_{\cdot k} = \frac{1}{n} \sum_{i=1}^n a_{ik}$$

- Maß für die **Gesamtinformation** von A :

$$\text{Spur } S = \sum_{k=1}^m s_{kk} = \frac{1}{n} \sum_{i=1}^n \sum_{k=1}^m (a_{ik} - \bar{a}_{\cdot k})^2$$

- Analog für Faktorwertematrix X : Kovarianzmatrix $C = (c_{kl})_{q \times q}$ und $\text{Spur}(C)$:

$$\text{Spur}(C) = \sum_{k=1}^q c_{kk} = \frac{1}{n} \sum_{i=1}^n \sum_{k=1}^q (x_{ik} - \bar{x}_{\cdot k})^2$$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation

Einführung
Hauptkomponentenanalyse



- ▶ Gegeben: Datenmatrix $A = \begin{matrix} & \begin{matrix} \text{Altes} \\ \downarrow \end{matrix} & \begin{matrix} \text{Semester} \\ \downarrow \end{matrix} \\ \begin{pmatrix} 22 & 5 \\ 25 & 10 \\ 21 & 4 \\ 28 & 13 \\ 24 & 8 \end{pmatrix} \end{matrix}$
- ▶ A soll mit Hilfe zweier unterschiedlicher Faktorkombinationen repräsentiert werden
- ▶ Faktorkombination 1 bzw. 2 ist dabei gegeben durch die Faktorladungsmatrizen F' bzw. F'' gemäß

$$F' = \begin{pmatrix} 0,6 & 0,8 \\ 0,8 & -0,6 \end{pmatrix} \quad \text{bzw.} \quad F'' = \begin{pmatrix} 0,9 & 0,2 \\ 0,8 & -0,5 \end{pmatrix}$$

- ▶ **Frage:** Wie gut sind die beiden daraus resultierenden Repräsentationen?

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation

Einführung
Hauptkomponentenanalyse



Beispiel - Berechnung Kombination 1

Berechnet man für die Matrix A die Kovarianzmatrix S und die Spur S , so ergeben sich folgende Werte:

$$S = \begin{pmatrix} 6 & 8 \\ 8 & 10,8 \end{pmatrix} \Rightarrow \text{Spur}(S) = 6 + 10,8 = 16,8$$

Var 1. Merkmal (above 6)
Cov(a¹, a²) (above 8)
Var 2. Merkmal (below 10,8)

Mit Hilfe der Faktorladungsmatrix F' und $X = A \cdot (F'^T)^{-1}$ ergibt sich für X' folgendes:

$$X' = \begin{pmatrix} 17,2 & 14,6 \\ 23 & 14 \\ 15,8 & 14,4 \\ 27,2 & 14,6 \\ 20,8 & 14,4 \end{pmatrix} \quad \text{sowie } C = \begin{pmatrix} 16,752 & -0,064 \\ -0,064 & 0,048 \end{pmatrix}$$

$$\Rightarrow \text{Spur}(C) = 16,752 + 0,048 = 16,8$$

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
 - Einführung
 - Hauptkomponentenanalyse



Beispiel - Interpretation Kombination 1

Mit Hilfe der neuen Repräsentation kann die Objektmenge **ohne Informationsverlust** dargestellt werden.

(Spur S = Spur C = 16,8)

Die neue Darstellung hat darüber hinaus den Vorteil, dass die entstandenen Faktoren (nahezu) **unkorreliert** sind, während die ursprünglichen Merkmale eine hohe Korrelation aufweisen. Es gilt nämlich:

$$\rightarrow \text{Korrelation } (a^1, a^2) = 0,9938$$


$$\rightarrow \text{Korrelation } (x^1, x^2) = -0,0714$$

Beschränkt man sich auf eine Darstellung der Objekte mit Hilfe des ersten Faktors, so können immerhin noch $\frac{c_{11}}{c_{11} + c_{22}} \approx 99,71\%$ der Informationen dargestellt werden.

$$\text{Bsp. : } \frac{16,752}{16,752 + 0,048}$$


1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
 - Einführung
 - Hauptkomponentenanalyse

Beispiel: Graphik der Datenmatrix mit Faktorladungen von F'



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
- Einführung
Hauptkomponentenanalyse

Beispiel: Graphik der Datenmatrix mit Faktorladungen von F'



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
- Einführung
Hauptkomponentenanalyse





Beispiel - Berechnung Kombination 2

$$F'' = \begin{pmatrix} 0,9 & 0,2 \\ 0,8 & -0,5 \end{pmatrix}$$

- ▶ Wie oben bereits erwähnt ergibt sich für die Matrix A die Kovarianzmatrix S und die $\text{Spur}(S)$ wie folgt:

$$S = \begin{pmatrix} 6 & 8 \\ 8 & 10,8 \end{pmatrix} \Rightarrow \text{Spur}(S) = 6 + 10,8 = 16,8$$

- ▶ Mit Hilfe der Faktorladungsmatrix F'' und $X = A \cdot (F^T)^{-1}$ ergibt sich für X'' folgendes:

$$X'' = \begin{pmatrix} 19,67 & 21,47 \\ 23,77 & 18,03 \\ 18,52 & 21,63 \\ 27,21 & 17,54 \\ 22,29 & 19,67 \end{pmatrix} \quad \text{sowie } C = \begin{pmatrix} 9,49 & -5,01 \\ -5,01 & 2,87 \end{pmatrix}$$

$$\Rightarrow \text{Spur}(C) = 9,49 + 2,87 = 12,36$$

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
 - Einführung
 - Hauptkomponentenanalyse




Beispiel - Interpretation Kombination 2

- ▶ Mit Hilfe dieser zweiten Repräsentation kann die Objektmenge **nicht ohne Informationsverlust** dargestellt werden. (Spur $S = 16,8$ und $\text{Spur}(C) = 12,36$)
- ▶ Die neue Darstellung hat darüber hinaus den Nachteil, dass die entstandenen Faktoren fast genauso **hoch** (absolut) **korreliert** sind wie die ursprünglichen Merkmale. Es gilt nämlich:
 - Korrelation $(a^1, a^2) = -0,9938$
 - Korrelation $(x^1, x^2) = -0,9597$
- ▶ Somit stellt sich also die Frage, wie die Repräsentation und damit die Faktorladungsmatrix F optimal gewählt werden soll.


1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
 - Einführung
 - Hauptkomponentenanalyse

Beispiel: Graphik der Datenmatrix mit Faktorladungen von F'



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
- Einführung
Hauptkomponentenanalyse

Beispiel: Graphik der Datenmatrix mit Faktorladungen von F''



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
- Einführung
Hauptkomponentenanalyse



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
- 5. Datenanalyse
- 6. Repräsentation

Einführung
Hauptkomponentenanalyse

Satz 1 der Hauptkomponentenanalyse

Sei $A = X \cdot F^T$ und F orthogonal (d.h. $F^T \cdot F = F \cdot F^T = E$), dann gilt:

- 1 Spur $S = \text{Spur } C$
- 2 $C = F^T \cdot S \cdot F$

Bemerkungen:

- ▶ Spur $S = \text{Spur } C \iff$ Information bleibt erhalten
- ▶ F orthogonal $\Rightarrow A = X \cdot F^T \iff A \cdot F = X \cdot F^T \cdot F = X$
- ▶ $c_{kk} = f^{kT} \cdot S \cdot f^k$, d.h. der durch den Faktor x^k erklärte Anteil der Varianz hängt nur von f^k ab.

$$\text{Orthogonal} (\Leftrightarrow) F^T = F^{-1}$$



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
- 5. Datenanalyse
- 6. Repräsentation
 - Einführung
 - Hauptkomponentenanalyse

Hauptkomponentenanalyse: Problem der Faktorenwahl

- ▶ Ziel der HKA: Merkmalsreduktion, d.h., man möchte mit wenigen, unkorrelierten Faktoren auskommen und trotzdem einen Großteil der Information darstellen.
- ▶ Die durch die Faktoren erklärten Varianzanteile sollen mit wachsendem Index abnehmen, d.h., Faktor χ^1 soll den größtmöglichen Varianzanteil erklären, Faktor χ^2 den zweitgrößten Anteil ...
- ▶ Also: $c_{11} \geq c_{22} \geq c_{33} \geq \dots \geq c_{qq}$ für $q \leq m$
- ▶ Optimierungsproblem:

- 1 $\max c_{11} = \max f^{1T} \cdot S \cdot f^1$ mit $f^{1T} \cdot f^1 = 1$

- 2 $\max c_{22} = \max f^{2T} \cdot S \cdot f^2$ mit $f^{2T} \cdot f^2 = 1$ und $f^{2T} \cdot f^1 = 0$

- 3 ...

$$C = \begin{pmatrix} 16,752 & -0,064 \\ -0,064 & 0,048 \end{pmatrix}$$

$$F' = \begin{pmatrix} 0,6 & 0,8 \\ 0,8 & -0,6 \end{pmatrix}$$

- ▶ Oder Allgemein: Optimierungsproblem (*):

$$\max c_{kk} = \max f^{kT} \cdot S \cdot f^k \quad \text{mit } f^{kT} \cdot f^k = 1$$

$$\text{und } f^{kT} \cdot f^l = 0 \text{ für } l = 1, \dots, k-1$$



- 1. Einführung
 - 2. Deskriptive Statistik
 - 3. W-Theorie
 - 4. Induktive Statistik
 - 5. Datenanalyse
 - 6. Repräsentation
- Einführung
Hauptkomponentenanalyse

Satz 2 der Hauptkomponentenanalyse

Die Lösung der Optimierungsprobleme (*) impliziert folgendes Eigenwertproblem von S:

$$(S - \lambda \cdot E) \cdot f = 0$$

mit

$c_{11}, c_{22}, c_{33}, \dots, c_{mm} \geq 0$ sind Eigenwerte von S

f^1, f^2, \dots, f^q mit $f^{kT} \cdot f^k = 1, f^{kT} \cdot f^l = 0 (l \neq k)$ sind Eigenvektoren von S

Für die Matrix C gilt:
$$C = \begin{pmatrix} c_{11} & & 0 \\ & \ddots & \\ 0 & & c_{qq} \end{pmatrix}$$



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
- 5. Datenanalyse
- 6. Repräsentation
- Einführung
- Hauptkomponentenanalyse

Konsequenzen aus Satz 2 der HKA

$$A = X \cdot F^T \leftrightarrow X = A \cdot F$$

→ Faktoren $x^1 = A \cdot f^1, \dots, x^m = A \cdot f^m$

C ist Diagonalmatrix

→ Faktoren sind **paarweise unkorreliert**.

Numerierung der Faktoren x^1, \dots, x^m derart, dass

$$\lambda_1 = c_{11} \geq \lambda_2 = c_{22} \geq \dots \geq \lambda_m = c_{mm} \geq 0$$

→ x^1 erklärt mit $\lambda_1 / \sum \lambda_k$ den größten Anteil der Varianz

→ x^2 erklärt mit $\lambda_2 / \sum \lambda_k$ den zweitgrößten Anteil ...

Bewertung des Informationsverlustes einer Merkmalsreduktion auf $q < m$ Faktoren

$$b(q) = 1 - \frac{\lambda_1 + \dots + \lambda_q}{\lambda_1 + \dots + \lambda_m} = \left[1 - \frac{c_{11} + \dots + c_{qq}}{c_{11} + \dots + c_{mm}} \right] \in [0, 1] \text{ und } b(m) = 0$$



Vorgehensweise der HKA

Datenmatrix A , maximaler Informationsverlust b_0

Berechne Kovarianzmatrix S

Löse Eigenwertproblem $(S - \lambda \cdot E) \cdot f = 0$

$$\lambda_1 = c_{11} \geq \lambda_2 = c_{22} \geq \dots \geq \lambda_m = c_{mm} \geq 0$$

$$(f^1, f^2, \dots, f^m) = F$$

Bestimme q minimal, so dass $b(q) = 1 - \frac{\lambda_1 + \dots + \lambda_q}{\lambda_1 + \dots + \lambda_m} \leq b_0$

Ladungsmatrix $F_q = (f^1, f^2, \dots, f^q)$

Faktorwertematrix $X_q = A \cdot F_q = (x^1, x^2, \dots, x^q)$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

5. Datenanalyse

6. Repräsentation

Einführung

Hauptkomponentenanalyse

Beispiel: 3 Merkmale, 4 Objekte

$$A = \begin{pmatrix} a_1 & a_2 & a_3 \\ 6 & 0 & 0 \\ 8 & 8 & 4 \\ 0 & 4 & 0 \\ 2 & 8 & 8 \end{pmatrix} \Rightarrow S = \begin{pmatrix} 10 & 0 & 0 \\ 0 & 11 & 9 \\ 0 & 9 & 11 \end{pmatrix}$$

$Cov(a_1, a_1) = Var(a_1)$
 $Cov(a_1, a_2)$
 $Cov(a_1, a_3)$

Eigenwert: $\det(S - \lambda E) = \det \begin{pmatrix} 10-\lambda & 0 & 0 \\ 0 & 11-\lambda & 9 \\ 0 & 9 & 11-\lambda \end{pmatrix}$

$$= (10-\lambda)(11-\lambda)^2 - 9^2 \cdot (10-\lambda) = 0$$

$$\Leftrightarrow (10-\lambda) \cdot [121 - 22\lambda + \lambda^2 - 81] = 0$$

$$\Leftrightarrow (10-\lambda) \cdot [\lambda^2 - 22\lambda + 40] = 0$$

$$\Leftrightarrow (10-\lambda)(\lambda-2)(\lambda-20) = 0$$

$$\Rightarrow \lambda_1 = 20, \lambda_2 = 10, \lambda_3 = 2$$

Wähle max. 10% Informationsverlust

probiere 1 Hauptkomponente:

$$\Rightarrow \text{Info. gehalt} \frac{20}{20+10+2} = 0,625$$

(Verlust: $1 - 0,625 = 0,375 \rightarrow$ zu viel)

$$2 \text{ Hauptkomponenten: } \frac{20+10}{20+10+2} = \frac{30}{32} = 0,9375$$

(Verlust: $1 - 0,9375 = 0,0625 \checkmark$)

Also berechne 2 H.K. (Eigenvektoren zu EW. λ_1, λ_2)

Eigenvektor zu $\lambda_1 = 20$:

$$(S - \lambda_1 \cdot E) \cdot x = 0$$

$$\Leftrightarrow \begin{pmatrix} 10-20 & 0 & 0 \\ 0 & 11-20 & 9 \\ 0 & 9 & 11-20 \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}$$

$$\Leftrightarrow \begin{pmatrix} -10 & 0 & 0 \\ 0 & -9 & 9 \\ 0 & 9 & -9 \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = 0$$

$$\Leftrightarrow x_1 = 0, -x_2 + x_3 = 0 \Leftrightarrow x_2 = x_3$$

$$\Rightarrow \text{EV: } \begin{pmatrix} 0 \\ a \\ a \end{pmatrix} \text{ wähle } a \text{ so, dass} \\ \text{EV Länge 1 hat} \\ \Rightarrow 0^2 + a^2 + a^2 = 1 \\ \Leftrightarrow a = \frac{1}{\sqrt{2}}$$

EV zu $\lambda_2 = 10$:

$$(S - \lambda_2 E) \cdot x = \begin{pmatrix} 10-10 & 0 & 0 \\ 0 & 11-10 & 9 \\ 0 & 9 & 11-10 \end{pmatrix} \cdot x = 0$$


$$x_2 + 9x_3 = 0, 9x_2 + x_3 = 0 \Rightarrow x_2 = x_3 = 0$$

$$\Rightarrow \text{EV} = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$$

Repräsentationsmatrix X

$$X = A \cdot F = \begin{pmatrix} 6 & 0 & 0 \\ 8 & 8 & 4 \\ 0 & 4 & 0 \\ 2 & 8 & 8 \end{pmatrix} \cdot \begin{pmatrix} 0 & 1 \\ \frac{1}{\sqrt{2}} & 0 \\ \frac{1}{\sqrt{2}} & 0 \end{pmatrix} = \begin{pmatrix} 0 & 6 \\ 6\sqrt{2} & 8 \\ 2\sqrt{2} & 0 \\ 8\sqrt{2} & 2 \end{pmatrix}$$

Matrix der Eigenvektoren 4×3 3×2



erste Hauptkomponente


Einbetten der Originalmerkmale:

$$\begin{aligned}
 a^1: & (1 \ 0 \ 0) \cdot F = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix} \\
 a^2: & (0 \ 1 \ 0) \cdot F = \begin{pmatrix} 1/\sqrt{2} \\ 0 \\ 0 \end{pmatrix} \\
 a^3: & (0 \ 0 \ 1) \cdot F = \begin{pmatrix} 1/\sqrt{2} \\ 0 \\ 0 \end{pmatrix}
 \end{aligned}$$

für Zeichnung! mal 5

$$\begin{pmatrix} 0 \\ 5 \\ 3.5 \\ 0 \\ 3.5 \\ 0 \end{pmatrix}$$

Lineare Diskriminanzanalyse



Gesucht: Projektion von x_1 und x_2 auf Gerade, so dass Klassen A und B optimal getrennt werden


$$y = x_1 \cdot g_1 + x_2 \cdot g_2$$

Kriterien:

- ① Innerklassenvarianzen w sollten möglichst klein sein



- ② Zwischenklassenvarianz b soll möglichst groß sein



⇒ Diskriminanzkriterium von Fisher

$$\lambda(g) = \frac{b}{w} \rightarrow \max$$

$$b = g^T Z g, \quad w = g^T V g$$

↓
Zwischenklassenkov. matrix

↓
Inneklassenkov. matrix

$$\Rightarrow \dots \Rightarrow \underbrace{V^{-1} \cdot Z}_{\text{Matrix}} \cdot g = \underbrace{\lambda}_{\text{Zahl}} \cdot g$$

- ⇒ • Eigenwerte von $V^{-1} \cdot Z$ maximieren $\lambda(g)$
• Eigenvektoren sind die Gewichte g

Beispiel:

Innenklassenkov. matrix V :

$$\begin{array}{l} \left. \begin{array}{l} 4 \quad 1 \\ 2 \quad 4 \\ 2 \quad 3 \\ 3 \quad 6 \\ 4 \quad 4 \end{array} \right\} A \\ \text{Cov}(A) = \begin{pmatrix} 0.8 & -0.4 \\ -0.4 & 2.64 \end{pmatrix} = V^A \\ \text{Cov}(B) = \begin{pmatrix} 1.84 & -0.04 \\ -0.04 & 2.64 \end{pmatrix} = V^B \\ \Rightarrow V = \frac{1}{10} (5 \cdot V^A + 5 \cdot V^B) \\ = \begin{pmatrix} 1.32 & -0.22 \\ -0.22 & 2.64 \end{pmatrix} \end{array}$$

Zwischenklassenkov. matrix Z

Mittelwerte: $A \quad \bar{x}^A = (3.0 \quad 3.6)$
 $B \quad \bar{x}^B = (3.4 \quad 7.6)$
 gesamt $\bar{x} = (5.7 \quad 5.6)$

für TR: $\left. \begin{array}{l} 3.0 \quad 3.6 \quad 5 \\ 8.4 \quad 7.6 \quad 5 \end{array} \right\} \text{Cov.} = \begin{array}{l} r \cdot x_1 \cdot y_2 \\ r \cdot z_1 \cdot z_2 \end{array}$

$$\Rightarrow Z = \begin{pmatrix} 7.29 & 5.4 \\ 5.4 & 4.0 \end{pmatrix}$$

Exkurs: Invertieren einer 2x2 Matrix

$$A = \begin{pmatrix} a & b \\ c & d \end{pmatrix} \Rightarrow A^{-1} = \frac{1}{ad-bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$$

$$\Rightarrow V^{-1} \approx \begin{pmatrix} 0.768 & 0.064 \\ 0.064 & 0.384 \end{pmatrix}$$

$$\Rightarrow M = V^{-1} Z = \begin{pmatrix} 5.946 & 4.405 \\ 2.541 & 1.882 \end{pmatrix}$$

$$\Rightarrow \text{Eigenwert: } \lambda_1 = 7.82, \quad \lambda_2 = 0$$

$$\text{Eigenvektoren } \begin{pmatrix} 0.9196 \\ 0.3930 \end{pmatrix} = \begin{pmatrix} z_1 \\ z_2 \end{pmatrix}$$

Berechne $\hat{Y} = X \cdot g$

$$\hat{Y} = X \cdot \begin{pmatrix} 0.9196 \\ 0.3930 \end{pmatrix} = \begin{array}{l} 4.09 \\ 3.41 \\ 3.02 \\ 5.12 \\ 5.25 \end{array} \left\} A \quad \begin{array}{l} 72.2 \\ 8.66 \\ 10.24 \\ 10.11 \\ 12.34 \end{array} \right\} B$$



$$\hat{y}_1 = \bar{x} \cdot \begin{pmatrix} 91 \\ 92 \end{pmatrix} = 7.44$$

$$\hat{y}_1^A = \bar{x}^A \cdot \begin{pmatrix} 91 \\ 92 \end{pmatrix} = 4.17$$

$$\hat{y}_1^B = \dots = 10.71$$

neues Objekt soll zugeordnet werden! z.B. $x = (7 \quad 3)$

$$\Rightarrow y = (7 \quad 3) \begin{pmatrix} 0.9196 \\ 0.3930 \end{pmatrix} \approx 7.62 > 7.44 \rightarrow B$$

Beispiel: 3 Merkmale, 4 Objekte

$$A = \begin{pmatrix} 6 & 0 & 0 \\ 8 & 8 & 4 \\ 0 & 4 & 0 \\ 2 & 8 & 8 \end{pmatrix}$$

$$\Rightarrow S = \begin{pmatrix} 10 & 0 & 0 \\ 0 & 11 & 9 \\ 0 & 9 & 11 \end{pmatrix}$$

$\text{Cov}(a^1, a^1) = \text{Var}[a^1]$
 $\text{Cov}(a^1, a^2) = r \cdot b_{a^1} \cdot b_{a^2}$
 $\text{Cov}(a^2, a^3)$

Eigenwerte:

$$\det(S - \lambda E) = \det \begin{pmatrix} 10-\lambda & 0 & 0 \\ 0 & 11-\lambda & 9 \\ 0 & 9 & 11-\lambda \end{pmatrix} = 0$$

$$\Leftrightarrow (10-\lambda)(11-\lambda)^2 - 9 \cdot 9 \cdot (10-\lambda) = 0$$

$$\Leftrightarrow (10-\lambda)[121 - 22\lambda + \lambda^2 - 81] = 0$$

$$\Leftrightarrow (10-\lambda) \cdot [\lambda^2 - 22\lambda + 40] = 0$$

$$\Leftrightarrow (10-\lambda)(\lambda-2)(\lambda-20) = 0$$

$$\Rightarrow \lambda_1 = 20, \lambda_2 = 10, \lambda_3 = 2$$

maximal 10% Informationsverlust: nur 1 Hauptkomp.:

$$\text{Gesamt inform.} : \frac{20}{20+10+2} = \frac{20}{32} = 0,625$$

$$(\text{Verlust} : 1 - 0,625 = 0,375)$$

$$2 \text{ Hauptk.} : \frac{20+10}{32} = \frac{30}{32} = 0,9375$$

$$(\text{Verlust} : 1 - 0,9375 = 0,0625 \checkmark)$$

Also: Berechne Eigenvektoren zu λ_1, λ_2 :

$$x = A \cdot F = \begin{pmatrix} 6 & 0 & 0 \\ 8 & 8 & 4 \\ 0 & 4 & 0 \\ 2 & 8 & 8 \end{pmatrix} \cdot \begin{pmatrix} 0 \\ \frac{1}{\sqrt{2}} \\ 0 \\ \frac{1}{\sqrt{2}} \end{pmatrix} = \begin{pmatrix} 0 & 6 \\ 6\sqrt{2} & 8 \\ 2\sqrt{2} & 0 \\ 8\sqrt{2} & 2 \end{pmatrix}$$

EV zu λ_1 :

$$(S - \lambda_1 E) \cdot x = 0$$

$$\Leftrightarrow \begin{pmatrix} 10-20 & 0 & 0 \\ 0 & 11-20 & 9 \\ 0 & 9 & 11-20 \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = 0$$

$$\Leftrightarrow \begin{pmatrix} -10 & 0 & 0 \\ 0 & -9 & 9 \\ 0 & 9 & -9 \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = 0 \Leftrightarrow \left. \begin{matrix} x_1 = 0 \\ x_2 = x_3 \end{matrix} \right\}$$

$$\Rightarrow \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix} \rightarrow \begin{pmatrix} 0 \\ \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{pmatrix} = f^1$$

normiere mit $\sqrt{f^1}$
($\sqrt{0^2 + 1^2 + 1^2}$)


EV zu $\lambda_2 = 10$:

$$\begin{pmatrix} 10-10 & 0 & 0 \\ 0 & 11-10 & 9 \\ 0 & 9 & 11-10 \end{pmatrix} x = 0$$

$$\begin{pmatrix} 0 & 0 & 0 \\ 0 & 1 & 9 \\ 0 & 9 & 1 \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = 0 \left\{ \begin{matrix} x_1 \text{ beliebig} \\ x_2 + 9x_3 = 0 \\ 9x_2 + x_3 = 0 \end{matrix} \right.$$

$$\Rightarrow x_1 = 1, x_2 = x_3 = 0$$

$$\Rightarrow f^2 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$$



$$\begin{pmatrix} 0 & 6 \\ 6 & 8 \\ 2 & 0 \\ 8 & 2 \end{pmatrix} \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \end{matrix}$$

Originalmerkmale einbetten: $a^1: (1 \ 0 \ 0) \cdot F = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}$

$$a^2: (0 \ 1 \ 0) \cdot F = \begin{pmatrix} \frac{1}{\sqrt{2}} \\ 0 \\ 0 \end{pmatrix}$$

$$a^3: (0 \ 0 \ 1) \cdot F = \begin{pmatrix} \frac{1}{\sqrt{2}} \\ 0 \\ 0 \end{pmatrix}$$

Beispiel 1 - Hauptkomponentenanalyse

Für die Produkte P_1, P_2, P_3 und P_4 konnten bezüglich der Merkmale M_1, M_2 und M_3 folgende Werte erhoben werden:

$$A = \begin{pmatrix} 6 & 0 & 0 \\ 8 & 8 & 4 \\ 0 & 4 & 0 \\ 2 & 8 & 8 \end{pmatrix}$$

- ▶ Berechnen Sie die Kovarianzmatrix der Merkmale und interpretieren Sie diese.
- ▶ Lösen Sie das zugehörige Eigenwertproblem und interpretieren Sie die Ergebnisse.
- ▶ Bestimmen Sie die Faktorwertematrix und stellen Sie diese zweidimensional dar.
- ▶ Betten Sie die ursprünglichen Merkmalsvektoren in den Faktorwertepplot ein.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation

Einführung
Hauptkomponentenanalyse



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
- Einführung
Hauptkomponentenanalyse

```
Farben = c("#dd100070", "#1000dd70")
# Beispiel 1 HKA
A <- data.frame(
  a1=c(6,8,0,2),
  a2=c(0,8,4,8),
  a3=c(0,4,0,8))
A
##   a1 a2 a3
## 1  6  0  0
## 2  8  8  4
## 3  0  4  0
## 4  2  8  8

S <- cov(A)*3/4
S
##   a1 a2 a3
## a1 10  0  0
## a2  0 11  9
## a3  0  9 11


F <- eigen(S)$vectors
round(F, 3)
##           [,1] [,2] [,3]
## [1,] 0.000    1  0.000
## [2,] 0.707    0 -0.707
## [3,] 0.707    0  0.707
```

```
# Beispiel 1 HKA
L <- eigen(S)$values
L
## [1] 20 10  2

A.pca <- princomp(A)
summary(A.pca)

## Importance of components:
##                               Comp.1 Comp.2 Comp.3
## Standard deviation            4.472  3.1623  1.4142
## Proportion of Variance        0.625  0.3125  0.0625
## Cumulative Proportion         0.625  0.9375  1.0000

biplot(A.pca, col=Farben)
```



Beispiel 2 - Hauptkomponentenanalyse

Gegeben ist die folgende Datenmatrix:

$$A = \begin{pmatrix} -9 & -9 & 1 \\ 3 & 1 & 7 \\ 16 & 16 & -2 \\ -12 & -11 & 20 \\ 0 & -2 & -1 \end{pmatrix}$$

- ▶ Berechnen Sie die Kovarianzmatrix der Merkmale und interpretieren Sie diese.
- ▶ Lösen Sie das zugehörige Eigenwertproblem und interpretieren Sie die Ergebnisse.
- ▶ Bestimmen Sie die Faktorwertematrix und stellen Sie diese zweidimensional dar.
- ▶ Betten Sie die ursprünglichen Merkmalsvektoren in den Faktorwerteplot ein.




1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation

Einführung
Hauptkomponentenanalyse



```
# Beispiel 2 HKA
S=cov(A)*(n-1)/n
pairs(A,pch=19,col="blue")
F <- eigen(S)$vectors
round(F,3)
```

```
##          [,1] [,2] [,3]
## [1,] -0.660 0.252 0.708
## [2,] -0.633 0.320 -0.705
## [3,]  0.405 0.913  0.052
```




```
# Beispiel 1 HKA
L <- eigen(S)$values
L
```

```
## [1] 218.6298  36.2523  0.5579
```

```
A.pca <- princomp(A)
summary(A.pca)
```

```
## Importance of components:
##                               Comp.1 Comp.2  Comp.3
## Standard deviation           14.7861  6.0210  0.746909
## Proportion of Variance        0.8559  0.1419  0.002184
## Cumulative Proportion         0.8559  0.9978  1.000000
```

```
biplot(A.pca, col=Farben)
```



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
- Einführung
Hauptkomponentenanalyse

```
# Beispiel 2 HKA
A = MyData[,c(1,2,4:8,10:12)]
str(A)

## 'data.frame': 205 obs. of 10 variables:
## $ Alter      : int  21 20 19 20 20 24 20 27 23 21 ...
## $ Groesse    : int  173 164 172 168 169 185 170 165 184 178 ...
## $ AlterV     : int  54 57 49 45 43 54 49 53 52 55 ...
## $ AlterM     : int  51 57 58 49 42 52 53 53 48 55 ...
## $ GroesseV   : int  187 172 193 185 182 179 182 175 182 180 ...
## $ GroesseM   : int  170 166 162 164 164 163 172 165 175 168 ...
## $ Geschwister: int  1 0 3 3 5 2 2 1 2 1 ...
## $ AusgKomm   : num  156 450 240 35.8 450 250 100 300 450 1300 ...
## $ AnzSchuhe  : int  17 22 15 15 22 8 20 10 3 7 ...
## $ AusgSchuhe : int  50 500 400 100 450 90 250 200 300 200 ...
```

```
MD.pca = princomp(A, cor=TRUE)
summary(MD.pca, digits=3)
```

```
## Importance of components:
##                Comp.1 Comp.2 Comp.3 Comp.4
## Standard deviation  1.4558 1.3194 1.2384 1.0462
## Proportion of Variance 0.2119 0.1741 0.1534 0.1095
## Cumulative Proportion 0.2119 0.3860 0.5394 0.6488
##                Comp.5 Comp.6 Comp.7 Comp.8
## Standard deviation  0.96679 0.91429 0.77335 0.71009
## Proportion of Variance 0.09347 0.08359 0.05981 0.05042
## Cumulative Proportion 0.74231 0.82590 0.88571 0.93613
##                Comp.9 Comp.10
## Standard deviation  0.64469 0.47232
## Proportion of Variance 0.04156 0.02231
## Cumulative Proportion 0.97760 1.00000
```




1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
- Einführung
Hauptkomponentenanalyse

```
# Beispiel 1 HKA
```

```
Farben = c("#dd100060", "#1000ddff")
```

```
biplot(MD.pca, col=Farben, xlim=c(-0.172,0.25), ylim=c(-0.17,0.16))
```



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
- Einführung
Hauptkomponentenanalyse



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
- 5. Datenanalyse
- 6. Repräsentation

Einführung
Hauptkomponentenanalyse

Interpretationshilfen

- ▶ **Aussage über den Zusammenhang** r_{kp} zwischen den ursprünglichen Merkmalen α^k und den Hauptkomponenten (Faktoren) x^p z.B. wie folgt:

$$r_{kp} = \frac{\frac{1}{n} \sum_{i=1}^n (a_{ik} - \bar{a}_{.k})(x_{ip} - \bar{x}_{.p})}{\sqrt{s_{kk}} \sqrt{c_{pp}}}, \quad \begin{array}{l} k = 1, \dots, m \\ p = 1, \dots, q \end{array}$$

- ▶ Korrelationskoeffizient r_{kp} : Zusätzlicher Anhaltspunkt bei der Interpretation der Analyseergebnisse

Kommunalitäten

- ▶ Mit **Korrelationskoeffizienten** r_{kp} : Anteil der auf die ersten q Faktoren ($p = 1, \dots, q$) übertragene Information des k -ten Merkmals α^k berechenbar
- ▶ Dazu: **Kommunalität** k_k mit

$$k_k = \sum_{p=1}^q r_{kp}^2 \in [0,1] \text{ für } k = 1, \dots, m$$

- ▶ k_k gibt an, wieviel Prozent der Informationen des (standardisierten) Merkmals α^k noch in den Faktoren $x^1 \dots x^q$ enthalten sind.



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
- 5. Datenanalyse
- 6. Repräsentation

Einführung
Hauptkomponentenanalyse

Wahl der Repräsentationsdimension

Allgemeingültige Kriterien zur Bestimmung einer problem-adäquaten **Repräsentationsdimension** q sind nicht bekannt. Man kann sich aber an den folgenden Regeln orientieren:

- ▶ Man wählt ein q aus, bei dem man bei weiterer Reduktion der Faktorenzahl einen verhältnismäßig hohen zusätzlichen Informationsverlust hätte (**Ellenbogenkriterium**).
- ▶ Man wählt ein minimales $q \geq 1$ mit $b(q) < b_{\max}$, d.h. ein q mit maximal zu akzeptierendem Informationsverlust, (mit z.B.: $b_0 = 10\%$ oder $b_0 = 25\%$).
- ▶ Man wählt ein maximales $q \leq m$ mit $\lambda_q \geq (\lambda_1 + \dots + \lambda_m)/m$, d.h. man gibt vor, dass jeder Faktor mindestens die durchschnittliche Merkmalsvarianz erklären soll (**Kaiser-Kriterium**).

Schlußbemerkungen zur Hauptkomponentenanalyse

- ▶ Die HKA hat einige Vorteile:
- ▶ Statt Untersuchungsobjekte durch kaum übersehbare und hochkorrelierte Merkmalsbatterien zu beschreiben, gelangt man zu **wenigen und wichtigen** und weitgehend orthogonalen **Dimensionen** des Merkmalsraumes,
- ▶ in dem Untersuchungsobjekte anhand ihrer Faktorwerte positioniert sind

Fehlinterpretationsmöglichkeiten I

- ▶ Die HKA projiziert mit Hilfe einer linearer Abbildung
 - die m -dimensionalen Untersuchungsobjekte (unter Verwendung der Matrix X_q) und
 - die m Merkmale a^k (unter Verwendung der Matrix F_q)in einen gemeinsamen q -dimensionalen Teilraum.
- ▶ Deswegen: Sowohl die Objekte als auch die Merkmalsvektoren dürfen nur **relativ zueinander interpretiert** werden.
- ▶ Absolute Aussagen über die Lage der Objekte hinsichtlich der einzelnen Merkmalsvektoren gelten nur approximativ.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation

Einführung
Hauptkomponentenanalyse

Fehlinterpretationsmöglichkeiten II

- ▶ Wesentlich: Zahl und Art der Merkmale, die in die FA eingehen. Aus den entsprechenden Gleichungen wird deutlich, daß auf einem Faktor jene Merkmale **hoch laden**, die auch **hoch korreliert** sind. Wenn ein Faktor durch sehr viele gleichartige Merkmale vertreten ist, so laden diese auch hoch auf ihm.
- ▶ Die **Extraktion** des ersten Faktors nach dem Kriterium des **höchsten Varianzbeitrages** wird dann als bedeutendsten Faktor jenen präsentieren, der durch viele Merkmale vertreten ist.
- ▶ Damit zeigt sich aber, daß die FA für sich allein genommen nicht in der Lage ist, die Wichtigkeit von Merkmalsbereichen zu ermitteln (→ **Conjointanalyse**)
- ▶ Bei Wahl von Merkmalen aus unterschiedlichen Bereichen (z.B. soziodemographische und psychographische Merkmale), so kommt es vor, dass die unterschiedlichen Merkmale auf ein und denselben Faktor laden. Interpretation des Faktors dann wenig sinnvoll bzw. schwierig.
- ▶ Gängig: Faktoren nach dem am höchsten ladenden Merkmalen benennen (**Leitvariablenkonzept**). Führt unter Umständen zu einer Vernachlässigung relevanter Informationen für die Beschreibung der Untersuchungsobjekte.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation

Einführung
Hauptkomponentenanalyse



Kovarianz- oder Korrelationsmatrix?

- ▶ Die Hauptkomponentenanalyse kann statt mittels der Kovarianzmatrix von A auch auf Basis der Korrelationsmatrix von A durchgeführt werden.
- ▶ Aber: die Eigenwerte und Eigenvektoren der Kovarianzmatrix können nicht in die der Korrelationsmatrix überführt werden und geben deshalb unterschiedliche Informationen.
- ▶ Vorteile der Korrelationsmatrix:
 - Die Ergebnisse zweier Analysen können direkt miteinander verglichen werden
 - Hauptkomponentenanalyse basierend auf Kovarianzmatrizen ist sehr sensitiv bzgl. der Einheiten der Merkmale
- ▶ Vorteil der Kovarianzmatrix:
 - Hauptkomponentenanalyse basierend auf Kovarianzmatrizen ist sehr sensitiv bzgl. der Einheiten der Merkmale (Manchmal möchte man diesen Umstand benutzen)

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation

Einführung
Hauptkomponentenanalyse

- 1 Statistik: Einführung
- 2 Deskriptive Statistik
- 3 Wahrscheinlichkeitstheorie
- 4 Induktive Statistik
- 5 Datenanalyse Einleitung
- 6 Repräsentation
- 7 Klassifikation



Bildquelle: Newton (2007)

- 7 **Klassifikation**
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

Kreditausfälle

- ▶ Mai 2009:
Kreditkartenkonzern
American Express Co.:
Kreditausfallraten im April
2009 erstmals auf mehr als
10 Prozent
- ▶ Herbst 2013: Commerzbank: Kreditausfallrate bei
Mittelstandskrediten stark gestiegen
- ▶ Typisches Problem: Wie kann bekannte Information über
Kreditantragsteller benutzt werden, um Bonität zu beurteilen?



Problemstellung in der Klassifikation

- ▶ Ausgangssituation: Daten von Objekten, bei denen jeweils die Zugehörigkeit zu einer (von mehreren möglichen) Gruppen bekannt ist
- ▶ Problem: Bei einem neuen Objekt fehlt Information zur Gruppenzugehörigkeit
- ▶ Aufgabe: Mittels der bekannten Daten ein Modell bestimmen, dass die Gruppenzugehörigkeit des neuen Objektes aufgrund der vorhandenen Informationen ermöglicht

Genauer:

- ▶ **Abhängiges** Merkmal Y (Gruppenzugehörigkeit) soll mit Hilfe der **unabhängigen** Merkmale X_1, X_2, \dots, X_m erklärt (= klassifiziert, identifiziert) werden.
- ▶ Dazu nötig: Bestimmung einer Funktion $f(x_{i1}, \dots, x_{im})$, die Objekte i ihrer „richtigen“ Klasse k_i zuordnet.
- ▶ Unabhängige Merkmale können sowohl **metrisch** als auch **nominal** interpretierbar sein.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation


Problemstellung

- Beispielproblem
- Lineare Diskriminanzanalyse
- Klassifikationsbäume
- Support-Vector-Machines

Lineare Trennfunktion

- ▶ Manche Methoden erzeugen Trennmodelle aus **linearen Funktionen**:
- ▶ Dann Aufgabe: Ermittlung von „Gewichten“ $\alpha_1, \alpha_2, \dots, \alpha_m$ und Merkmale X_1, X_2, \dots, X_m mit

$$Y = \alpha_1 \cdot X_1 + \alpha_2 \cdot X_2 + \dots + \alpha_m \cdot X_m$$



Lineare Trennung möglich



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. Klassifikation
- Problemstellung
- Beispielproblem
- Lineare Diskriminanzanalyse
- Klassifikationsbäume
- Support-Vector-Machines

Nichtlineare Modelle

- ▶ Für manche Situationen hilfreich: **Nichtlineare Trennmodelle**:
- ▶ Dann Modell allgemeiner: Eine Funktion f und Merkmale X_1, X_2, \dots, X_m mit

$$Y = f(X_1, X_2, \dots, X_m)$$





Bild: Lineare Trennung beschreibt Struktur nicht ideal



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. Klassifikation
- Problemstellung
Beispielproblem
Lineare Diskriminanzanalyse
Klassifikationsbäume
Support-Vector-Machines




Qualität des Modells

- ▶ Maßzahlen für die Güte eines Modells: Anteil der korrekt/falsch klassifizierten Objekte
- ▶ Aber: Durch viele Modellvarianten und Parametrisierungen Gefahr der Anpassung des Modells an die Stichprobe und nicht an die Struktur in den Daten (**Overfitting**)
- ▶ Sinnvoll deswegen: Dreiteilung der Daten nach Berry und Linoff (2004) in Trainingsdaten, Testdaten und Evaluierungsdaten [▶ Mehr](#)






1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. **Klassifikation**
- Problemstellung
- Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

- ▶ Beispieldaten in 2 Klassen,
- ▶ pro Klasse jeweils 60 Objekte und zwei metrische Merkmale



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. Klassifikation
- Problemstellung
- Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

- ▶ Beispieldaten in 2 Klassen,
- ▶ pro Klasse jeweils 60 Objekte und zwei metrische Merkmale



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation

Problemstellung



Beispielproblem

Lineare Diskriminanzanalyse



Klassifikationsbäume

Support-Vector-Machines

- ▶ Daten von 72 vergebenen Krediten, 2 metrische Merkmale, 1 nominales Merkmal
- ▶ Geschichtete Lernstichprobe mit jeweils 36 guten ("ok") und 36 schlechten ("g"eplatzen) Krediten
- ▶ Ziel: Abschätzen der Bonität von potentiellen Kreditnehmern
- ▶ Metrische Merkmale: **Einkommen** des Kreditnehmers, **Dauer** des Beschäftigungsverhältnisses bei Kreditantrag (in Monaten)




1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. Klassifikation
- Problemstellung
Beispielproblem
Lineare Diskriminanzanalyse
Klassifikationsbäume
Support-Vector-Machines



- ▶ Dichte-Plots nach Merkmal und Bonität
- ▶ Anscheinend: Trennung bezüglich eines Merkmals nicht sinnvoll

1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. Klassifikation
- Problemstellung
- Beispielproblem
- Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. Klassifikation
- Problemstellung
Beispielproblem
Lineare Diskriminanzanalyse
Klassifikationsbäume
Support-Vector-Machines

Zuordnung von Skalenniveaus zu Verfahren


unabhängige Variablen X_i	quantitativ	nominal
abhängige Variable Y		
quantitativ	multiple Regression	Varianzanalyse
quantitativ	Kovarianzanalyse	
ordinal		Conjointanalyse
nominal	Diskriminanz- analyse	
binär	Logistische Regression	

- ▶ Y heißt auch **endogene Variable**
- ▶ X_1, \dots, X_m : **exogene Variablen**
- ▶ Zu beachten: **Kausale Abhängigkeit** muss vorliegen



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

- ▶ **Lineare Diskriminanzanalyse:** Klassisches lineares Verfahren nach Fisher (1936)
- ▶ Keine Verteilungsannahmen nötig, gleich mächtige Klassengrößen aber sinnvoll
- ▶ Idee: Lineare Reduktion aller Merkmale auf eine (oder mehrere) Response-Variablen



Ronald Aylmer Fisher
(1890 – 1962)



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. Klassifikation
- Problemstellung
Beispielproblem
Lineare Diskriminanzanalyse
Klassifikationsbäume
Support-Vector-Machines

- ▶ **Lineare Diskriminanzanalyse:** Klassisches lineares Verfahren nach Fisher (1936)
- ▶ Keine Verteilungsannahmen nötig, gleich mächtige Klassengrößen aber sinnvoll
- ▶ Idee: Lineare Reduktion aller Merkmale auf eine (oder mehrere) Response-Variablen
- ▶ Bestimmung linearer Gewichte und einer Diskriminanzfunktion

$$Y = g_1 \cdot X_1 + g_2 \cdot X_2 + \dots + g_m \cdot X_m$$



Ronald Aylmer Fisher
(1890 – 1962)



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. Klassifikation
- Problemstellung
Beispielproblem
Lineare Diskriminanzanalyse
Klassifikationsbäume
Support-Vector-Machines

- ▶ Wähle g_i so, dass Streuung zwischen Klassenmitten bzgl. Y groß und innerhalb der Klassen klein wird (Optimale Werte: Eigenwertproblem)
- ▶ Geometrisch: Projektion der Daten auf Ursprungsgerade in Richtung von α



Eigenschaften

- ▶ Gegeben: m **metrische Merkmale** X_1, \dots, X_m sowie ein **nominales Merkmal** Y .
- ▶ Y entsteht häufig aufgrund einer Zerlegung der Objektmenge in disjunkte Klassen K_1, \dots, K_s .
- ▶ Gesucht: Lineare Funktion, d.h. **eine Gewichtung** der Merkmale X_1, \dots, X_m , so dass die Variable Y bestmöglich approximiert wird ($1 < s < n$):

$$Y \cong g_1 X_1 + \dots + g_m X_m$$

$$\text{bzw. } Y = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} \cong \begin{pmatrix} x_{11} & \cdots & x_{1m} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{nm} \end{pmatrix} \cdot \begin{pmatrix} g_1 \\ \vdots \\ g_m \end{pmatrix} = X \cdot g$$

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

Wann ist Gewichtung gut gewählt?

- ▶ Gewichtung der unabhängigen Variablen so,
- ▶ dass die Unterschiede zwischen den prognostizierten Werten **einer Klasse möglichst klein**,
- ▶ die **verschiedener Klassen aber möglichst groß** sind, d.h.

$$\begin{array}{ll}
 i, j \in K_k & \rightarrow (\hat{y}_i - \hat{y}_j)^2 \rightarrow \min \\
 i \in K_k \text{ und } j \in K_l \text{ mit } k \neq l & \rightarrow (\hat{y}_i - \hat{y}_j)^2 \rightarrow \max
 \end{array}$$


- ▶ Deswegen: Varianzen **innerhalb** der Klassen sollen **möglichst klein** und die Varianz **zwischen** den Klassen **möglichst groß**.
- ▶ Kriterium sichert, dass Gewichtung gefunden wird, bei der die Mittelwerte der einzelnen Klassen - und damit auch die Klassen selbst - sehr verschieden sind und gleichzeitig auch die Homogenität innerhalb der Klassen sehr groß ist. Überschneidungen bleiben trotzdem möglich.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

Lineare Diskriminanzanalyse

Einfaches Beispiel: 2 Klassen, 2 unabh. Merkmale



- Gesucht: Projektion von x^1 und x^2 auf Gerade, so dass Klassen A, B optimal getrennt werden

$$y_i = x_{i1}g_1 + x_{i2}g_2 \quad i = 1, \dots, n$$

- Kriterien: ① Innerklassenvarianzen sollen möglichst klein sein



Klasse A: $w_A = \frac{1}{|K_A|} \sum_{i \in K_A} (y_i - \bar{y}_{K_A})^2$

Anzahl Obj. in Klasse A

analog Klasse B: w_B

gesamte Innerklassenvarianz w :

$$w = \frac{1}{n} (|K_A| \cdot w_A + |K_B| \cdot w_B)$$

② Zwischenklassenvarianz soll möglichst groß sein



$$b = \frac{1}{n} (|K_A| (\bar{y}_A - \bar{y})^2 + |K_B| (\bar{y}_B - \bar{y})^2)$$

Betrachte Kovarianzmatrizen der unabh. Merkmale

① Innerklassen Kovarianzmatrix

$$V_{k\ell}^A = \frac{1}{|K_A|} \sum_{i \in K_A} (x_{ik} - \bar{x}_{kA})(x_{i\ell} - \bar{x}_{\ell A})$$

k, ℓ sind Indizes der X_i , also z.B.

$$\begin{matrix} 1,1 & 1,2 \\ 2,1 & 2,2 \end{matrix}$$

Mittelwert im Merkmal k in der Klasse A

analog $V_{k\ell}^B$

$$\text{Gesamt: } V_{k\ell} = \frac{1}{n} (|K_A| \cdot V_{k\ell}^A + |K_B| \cdot V_{k\ell}^B)$$

② Zwischenklassenkovarianzmatrix

$$z_{k\ell} = \frac{1}{n} [|K_A| \cdot (\bar{x}_{kA} - \bar{x}_k)(\bar{x}_{\ell A} - \bar{x}_\ell) + |K_B| \cdot (\bar{x}_{kB} - \bar{x}_k)(\bar{x}_{\ell B} - \bar{x}_\ell)]$$

mit $y = X \cdot g$ folgt für Inneklassenvarianz

$$\Leftrightarrow w = g^T V g$$

analog Zwischenklassenvarianz:

$$b = g^T z g$$

Fishers Diskriminanzkriterium:

$$\lambda(g) = \frac{b}{w} = \frac{g^T z g}{g^T V g} \rightarrow \max$$

.... \Rightarrow $V^{-1} z \cdot g = \lambda \cdot g$ Zahl

Matrix Vektor

\Rightarrow - Eigenwerte von $V^{-1} z$ maximieren $\lambda(g)$

- Projektionsgewichte sind Eigenvektoren

Beispiel: Inneklassenkov. matrix V:

$$\begin{matrix} 4 & 1 \\ 2 & 4 \\ 2 & 3 \\ 3 & 6 \\ 4 & 4 \end{matrix} \left. \vphantom{\begin{matrix} 4 \\ 2 \\ 2 \\ 3 \\ 4 \end{matrix}} \right\} A$$

$$\text{Cov}(X^A) = \begin{pmatrix} 0.8 & -0.4 \\ -0.4 & 2.64 \end{pmatrix} = V^A$$

$$\text{Cov}(X^B) = \begin{pmatrix} 1.84 & -0.04 \\ -0.04 & 2.64 \end{pmatrix} = V^B$$

$$\Rightarrow V = \frac{1}{10} (5 \cdot V^A + 5 \cdot V^B)$$

$$= \begin{pmatrix} 1.32 & -0.22 \\ -0.22 & 2.64 \end{pmatrix}$$

$$\begin{matrix} 9 & 10 \\ 6 & 8 \\ 9 & 5 \\ 8 & 7 \\ 10 & 8 \end{matrix} \left. \vphantom{\begin{matrix} 9 \\ 6 \\ 9 \\ 8 \\ 10 \end{matrix}} \right\} B$$

Zwischenklassenkov. matrix z:

$$\bar{x}^A = (3.0 \ 3.6) ; \bar{x}^B = (8.4 \ 7.6) ; \bar{x} = (5.7 \ 5.6)$$

Für TR:

$$\left. \begin{matrix} 3.0 & 3.6 \\ 3.0 & 3.6 \\ \vdots & \vdots \\ 3.0 & 3.6 \\ 8.4 & 7.6 \\ \vdots & \vdots \\ 8.4 & 7.6 \end{matrix} \right\} \begin{matrix} \text{Smal} \\ \\ \\ \text{Smal} \end{matrix} \left. \vphantom{\begin{matrix} 3.0 \\ 3.0 \\ \vdots \\ 3.0 \\ 8.4 \\ \vdots \\ 8.4 \end{matrix}} \right\} \begin{matrix} \\ \\ \\ \\ \text{Cov} = r \cdot \sigma_x \cdot \sigma_y \\ \text{Var} = \sigma_x^2 \end{matrix}$$

$$\Rightarrow z = \begin{pmatrix} 7.29 & 5.4 \\ 5.4 & 4.0 \end{pmatrix}$$

Exkurs: Invertierung einer 2x2-Matrix

$$A = \begin{pmatrix} a & b \\ c & d \end{pmatrix} \Rightarrow A^{-1} = \frac{1}{ad-bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$$

$$\text{damit } V^{-1} \approx \begin{pmatrix} 0.768 & 0.064 \\ 0.064 & 0.384 \end{pmatrix}$$

$$\Rightarrow M = V^{-1} z = \begin{pmatrix} 5.946 & 4.405 \\ 2.541 & 1.882 \end{pmatrix}$$

\Rightarrow Eigenwerte: $\lambda_1 = 7.82$, $\lambda_2 = 0$

Eigenvektor zu λ_1 : $\begin{pmatrix} 0.9196 \\ 0.3930 \end{pmatrix} = \begin{pmatrix} g_1 \\ g_2 \end{pmatrix}$

Berechne $\hat{y} = X \cdot g$

$$\hat{y} = X \cdot \begin{pmatrix} 0.9196 \\ 0.3930 \end{pmatrix} = \begin{matrix} 4.07 \\ 3.41 \\ 3.02 \\ 5.12 \\ 5.25 \end{matrix} \left. \vphantom{\begin{matrix} 4.07 \\ 3.41 \\ 3.02 \\ 5.12 \\ 5.25 \end{matrix}} \right\} A$$

$$\left. \begin{matrix} 12.2 \\ 8.66 \\ 10.24 \\ 10.11 \\ 12.34 \end{matrix} \right\} B$$



$$\begin{aligned} \bar{y} &= \bar{X} \cdot \begin{pmatrix} g_1 \\ g_2 \end{pmatrix} = 7.44 & \text{neues Objekt soll} \\ & & \text{zugeordnet werden} \\ \bar{y}_A &= \bar{X}_A \cdot \begin{pmatrix} g_1 \\ g_2 \end{pmatrix} = 4.17 & \text{z.B. } x = (7 \ 3) \\ \bar{y}_B &= \bar{X}_B \cdot \begin{pmatrix} g_1 \\ g_2 \end{pmatrix} = 10.71 & \Rightarrow y = (7 \ 3) \begin{pmatrix} 0.9196 \\ 0.3930 \end{pmatrix} \\ & & = 7.6162 > 7.44 \rightarrow B \end{aligned}$$


Trennebene (hier: -gerade)

dazu: Suche (x_1, x_2) , so dass $(x_1, x_2)g = \bar{y}$

$$\Leftrightarrow 0.9196 \cdot x_1 + 0.393 x_2 = 7.44$$

$$\Leftrightarrow x_2 = \frac{7.44}{0.393} - \frac{0.9196}{0.393} x_1$$

$$\Leftrightarrow x_2 = 18.9 - 2.3 x_1$$



4	1	} A
2	4	
2	3	
3	6	
4	4	
9	10	} B
6	8	
9	5	
8	7	
10	8	



Definition Innergruppen- und Zwischengruppenvarianz

- ▶ Innergruppenvarianz der Klasse K

$$w_K = \frac{1}{|K|} \sum_{i \in K} (\hat{y}_i - \bar{y}_K)^2 \quad \text{mit} \quad \bar{y}_K = \frac{1}{|K|} \sum_{i \in K} \hat{y}_i$$

- ▶ Gesamt-Innergruppenvarianz (gewichtete Summe der w_K)

$$w = \frac{1}{n} \sum_K |K| \cdot w_K$$

- ▶ Zwischengruppenvarianz

$$b = \frac{1}{n} \sum_K |K| (\bar{y}_K - \bar{y})^2 \quad \text{mit} \quad \bar{y} = \frac{1}{n} \sum_i \hat{y}_i$$

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
- 5. Datenanalyse
- 6. Repräsentation
- 7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines



Definition entsprechender **Kovarianzmatrizen** für unabhängige Variablen X_1, \dots, X_m gemäß $X = (x_{ik})_{n \times m}$

► Innergruppenkovarianzmatrix $V^K = (v_{kl}^K)_{m \times m}$

$$v_{kl}^K = \frac{1}{|K|} \sum_{i \in K} (x_{ik} - \bar{x}_{Kk})(x_{il} - \bar{x}_{Kl}) \quad \text{mit} \quad \bar{x}_{Kk} = \frac{1}{|K|} \sum_{i \in K} x_{ik}$$

► Gesamt-Innergruppenkovarianzmatrix

$$V = \frac{1}{n} \sum_K |K| \cdot V^K$$

► Zwischengruppenkovarianzmatrix $Z = (z_{kl})_{m \times m}$

$$z_{kl} = \frac{1}{n} \sum_K |K| (\bar{x}_{Kk} - \bar{x}_{\cdot k})(\bar{x}_{Kl} - \bar{x}_{\cdot l}) \quad \text{mit} \quad \bar{x}_{\cdot k} = \frac{1}{n} \sum_i x_{ik}$$

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

Definitionen

- ▶ Gegeben: Datenmatrix $X = (x_{ik})_{n \times m}$ der m unabhängigen Variablen,
- ▶ und es gelte $y = X \cdot g$.
- ▶ Ferner gegeben: Kovarianzmatrizen $V_K (k = 1, \dots, s)$, V , Z und $S = \text{Cov}(X)$ gegeben.

$$\begin{aligned} b &= g^T Z g & \text{und} & & c &= g^T S g \\ w_K &= g^T V_K g & \text{und} & & w &= g^T V g \end{aligned}$$

- ▶ Zu beachten dabei: Gesamtvarianz c von Y ist gemäß $c = w + b$ zu berechnen
- ▶ Daraus: **Diskriminanzkriterium (D)**:

$$\lambda = \frac{b}{w} = \frac{g^T Z g}{g^T V g} \rightarrow \max_g$$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines



Satz

- ▶ V sei regulär und positiv definit.
- ▶ Dann impliziert die Lösung von (D) ein **Eigenwertproblem** der Matrix $V^{-1}Z$ gemäß

$$(V^{-1}Z + \lambda \cdot E)g = 0.$$

- ▶ Es existieren dann q Eigenwerte der Form

$$\lambda = \frac{b}{w} = \frac{g^T Z g}{g^T V g} > 0$$

- ▶ wobei $q = \text{Rg}Z \leq \min\{m, s - 1\}$ ist.
- ▶ Die zugehörigen Eigenvektoren g^1, \dots, g^q sind linear unabhängig.

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

- ▶ Mit den Eigenwerte $\lambda_1, \dots, \lambda_q$
- ▶ und den zugehörigen Eigenvektoren g^1, \dots, g^q folgt:

$$\hat{y}^k = Xg^k$$

- ▶ Gewichtungsvektor g^1 trennt die Klassen bestmöglich,
- ▶ Gewichtungsvektor g^2 trennt die Klassen am zweitbesten, usw.
- ▶ wobei die \hat{y}^k paarweise unkorreliert sind.
- ▶ Terminologie ($k = 1, \dots, q$):

$$\hat{y}_{ik} = x_i^T g^k$$

$$\hat{y}_{ik}$$
$$g^k$$

k-te **Diskriminanzfunktion**

Diskriminanzvariable

k-ter **Diskriminanzkoeffizientenvektor**



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines



Man erhält folgende Mittelwerte:

- ▶ **Klassenmittelwerte** bzgl. der k -ten DA-Funktion

$$\bar{y}_{Kk} = \bar{x}_K^T g^k \quad \text{mit} \quad \bar{x}_K = (\bar{x}_{Kl})_{m \times 1}$$

- ▶ **Globalmittelwerte** bzgl. der k -ten DA-Funktion

$$\bar{y}_{\cdot k} = \bar{x}^T g^k \quad \text{mit} \quad \bar{x} = (\bar{x}_{\cdot l})_{m \times 1}$$

- ▶ Und: **Trennebenen** bzgl. der k -ten DA-Funktion:

$$\bar{y}_{\cdot k} = \bar{x}^T g^k = x^T g^k \quad (\text{mit } x \text{ als Variablenvektor})$$

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation

Problemstellung
Beispielproblem
Lineare Diskriminanzanalyse
Klassifikationsbäume
Support-Vector-Machines



Identifikation neuer Objekte

- ▶ Durch Trennebenen: Neue, in der Analyse von X und Y noch nicht enthaltene Objekte x_j können durch Vergleich mit Globalmittelwerten den verschiedenen Klassen zugeordnet werden.
- ▶ Schema:

$$\text{Falls } x_j^T g^k \begin{cases} \geq \bar{y}_{\cdot k} & \text{Zuordnung zu } K \text{ mit } \bar{y}_{Kk} \geq \bar{y}_{\cdot k} \\ < \bar{y}_{\cdot k} & \text{Zuordnung zu } K \text{ mit } \bar{y}_{Kk} < \bar{y}_{\cdot k} \end{cases}$$

1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. Klassifikation
- Problemstellung
Beispielproblem
Lineare Diskriminanzanalyse
Klassifikationsbäume
Support-Vector-Machines

Trefferquote

- ▶ Oft: Mit Identifikationsregeln für neue Objekte wird eine Identifikation der Objekte erstellt, die zur Generierung des Modells verwendet wurden.
- ▶ Durch einen Vergleich der prognostizierten Klassenzugehörigkeit und der wahren Klassenzugehörigkeit kann dann der Anteil der richtig klassifizierten Objekte bestimmt werden.
- ▶ Also: **Trefferquote** TQ gemäß

$$TQ = \frac{1}{n} \cdot \text{Anzahl korrekt klassifizierter Objekte}$$

- ▶ Deskriptives Maß TQ kann als Maß für die **Güte der Diskriminanzanalyse** verwendet werden.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation

Problemstellung
Beispielproblem
Lineare Diskriminanzanalyse
Klassifikationsbäume
Support-Vector-Machines



Anzahl der Trennebenen

- ▶ Jede DA-Funktion trennt genau in zwei Gruppen.
- ▶ Konsequenz für den Mehrgruppen-Fall: Zur korrekten Trennung der s Klassen sind $s - 1$ DA-Funktionen notwendig.
- ▶ Maß für die **relative Wichtigkeit** der einzelnen Diskriminanz-Funktionen: Eigenwertanteil gemäß

$$EA_k = \frac{\lambda_k}{\lambda_1 + \dots + \lambda_q}$$

- ▶ EA_k : Anteil der durch die k -te DA-Funktion erklärten Streuung an der durch alle DA-Funktionen erklärten Gesamtstreuung

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

Modellerstellung

- 1 Gegeben: Matrix X , Klassifikation K_1, \dots, K_s
- 2 Berechne $V, V^{-1}, Z, RgZ, V^{-1} \cdot Z$
- 3 Löse Eigenwertproblem $(V^{-1}Z - \lambda \cdot E)g = 0$
- 4 Bestimme $\lambda_1 \geq \dots \geq \lambda_q > 0$
- 5 Bestimme $G = (g^1, \dots, g^q)$
- 6 Berechne $\hat{Y} = X \cdot G$ ($n \times q$)-Matrix der DA-Variablen
- 7 sowie Klassenmittelwerte $\bar{y}_K^T = \bar{x}_K^T \cdot G$
- 8 Globalmittelwerte $\bar{y}^T = \bar{x}^T \cdot G$
- 9 Trennebenen $\bar{y}^T = x^T \cdot G$ mit variablem x

Identifikation

$$\text{Falls } x_j^T g^k \begin{cases} \geq \bar{y}_{Kk} & \text{Zuordnung zu } K \text{ mit } \bar{y}_{Kk} \geq \bar{y}_{\cdot k} \\ < \bar{y}_{Kk} & \text{Zuordnung zu } K \text{ mit } \bar{y}_{Kk} < \bar{y}_{\cdot k} \end{cases}$$



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
- 5. Datenanalyse
- 6. Repräsentation
- 7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

Anwendung der LDA mit R

```
set.seed(1504)
s = sample(1:72, 10)
bank.lda = lda(geplatzt ~ .,
               bankLong[-s,])
bank.lda

## Call:
## lda(geplatzt ~ ., data = bankLong[-s, ])
##
## Prior probabilities of groups:
##      g      ok
## 0.5323 0.4677
##
## Group means:
##      Einkommen DauerStelle
## g          56.91      17.23
## ok         85.86      42.06
##
## Coefficients of linear discriminants:
##              LD1
## Einkommen  0.04879
## DauerStelle 0.03923
```

```
test = bankLong[s,]
test$Prognose =
  predict(bank.lda,
          test[,c("Einkommen",
                 "DauerStelle")])$class


test

## Einkommen DauerStelle geplatzt Prognose
## 11      51.00      68.00      ok      ok
## 35      52.74      69.36      ok      ok
## 3       64.80      59.00      ok      ok
## 12      81.00      32.00      ok      ok
## 62      51.15      57.99      g       ok
## 22      33.00      19.00      g       g
## 5       87.00     120.00      ok      ok
## 25      66.69      32.00      ok      g
## 68      52.85      13.37      g       g
## 26      77.10      13.56      ok      g
```



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

Beispieldaten Bank



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. **Klassifikation**
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines



Grundprinzip Klassifikationsbäume


- ▶ Merkmalsraum soll pro Merkmal so aufgeteilt werden, dass Untermengen in sich möglichst homogen, untereinander möglichst heterogen sind
- ▶ Grundlegende Arbeit: Von Breiman et al. (1984)

Schrittweiser Aufbau eines Entscheidungsbaumes


- 1 Suche Merkmal und Trennpunkt mit bester Unterscheidung zwischen Klassen
- 2 Teile Daten gemäß dieser Regel
- 3 Für jeden der beiden Bereiche wende **1.** analog an, bis Stopkriterium erfüllt

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
- 5. Datenanalyse
- 6. Repräsentation
- 7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

Entscheidungsbaum der Beispieldaten



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines




- Entscheidungsbäume sind nichtlineare Klassifikationsverfahren:
Damit Gefahr des Overfitting

1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. Klassifikation
- Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines




- ▶ Komplexität der Bäume a priori festlegen ist i.a. nicht optimal
- ▶ Idee: Bäume erst wachsen lassen, anschließend zurückstutzen (**Pruning**)

Entscheidungsbaum, unbeschnitten



Entscheidungsbaum, beschnitten



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines



- ▶ Komplexität der Bäume a priori festlegen ist nicht optimal
- ▶ Idee: Bäume erst wachsen lassen, anschließen zurückstutzen (**Pruning**)
- ▶ Bewertung des zurückgeschnittenen Baumes z.B. mittels **Kosten-Komplexitäts-Maß**

$$R_{\alpha}(T) = R(T) + \alpha|\tilde{T}|$$

- ▶ Dabei bedeutet:
 - $R(T)$: Fehlklassifikationsrate durch den Baum T
 - $|\tilde{T}|$: Anzahl der Knoten im Baum T
 - $\alpha > 0$: Faktor des Komplexitäts-Bestrafungs-Terms

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines



Vorgehen beim Beschneiden von Bäumen


- 1 Beschneide Baum um die Äste, die die Fehlklassifikationsrate nicht verbessern
- 2 Bewerte bei allen Nicht-Endknoten A_t und den davon ausgehenden Ästen $T(A_t)$ mittels Kosten-Komplexitäts-Maß
 - den Knoten, wenn er ein Endknoten wäre $R_\alpha(A_t)$ und
 - den kompletten Ast ab diesem Knoten $R_\alpha(T(A_t))$
- 3 Stutze Baum beim Knoten mit dem kleinsten Unterschied von

$$R_\alpha(A_t) - R_\alpha(T(A_t))$$

- 4 Gehe zu Schritt 2. solange $R_\alpha(A_t) - R_\alpha(T(A_t)) > 0$


1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

Entscheidungsbaum, beschnitten



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

- ▶ Klassifikationsverfahren seit Mitte der 1990er Jahre (siehe Vapnik, 1999)
- ▶ Idee: Unterteilung der Daten in 2 Klassen durch Abbildung der Daten in höhere Dimension
- ▶ In höherer Dimension: Benutzung einer einfachen Funktion zur Abstandsbestimmung und Bestimmung einer "Trennungslinie"
- ▶ Dabei möglichst: Abstand der Klassen zur Trennungslinie maximal
- ▶ Äußerste Punkte der Klassen: **Stützvektoren (Support Vector)**
- ▶ Falsch klassifizierte Objekte erhöhen eine **Kostenfunktion** [▶ Mehr](#)



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines



- ▶ Kernel Methoden: Nutzen Informationen über das innere Produkt zwischen Objekten
- ▶ Viele Algorithmen lassen sich umformulieren, so dass sie nur noch das innere Produkt zwischen Daten benötigen
- ▶ Wenn der Kernel bekannt ist, muss man die Eigenschaften der Daten nicht spezifizieren
- ▶ Unabh. Daten im Raum: $x \in X$, Abhängige Daten in $y \in Y = \{-1, 1\}$; Zum Beispiel

$$f(x) = \langle w, x \rangle + b, \quad h(x) = \text{sign}(f(x))$$

[1. Einführung](#)[2. Deskriptive Statistik](#)[3. W-Theorie](#)[4. Induktive Statistik](#)[5. Datenanalyse](#)[6. Repräsentation](#)[7. Klassifikation](#)

Problemstellung

Beispielproblem

Lineare Diskriminanzanalyse

Klassifikationsbäume


Support-Vector-Machines

- ▶ d.h. Transformation in Feature-Raum muss nicht gemacht werden, es genügt, wenn die zugehörige Kernel-Funktion bekannt ist.
- ▶ Das heißt für einen Kernel


$$K(x_1, x_2) = \langle \phi(x_1), \phi(x_2) \rangle$$

muss weder die Dimension, noch die Transformation ϕ bekannt sein. Es genügt der Kernel

- ▶ Kernel-Trick: Bilde Daten in Repräsentationsraum ab, in dem sie (einigermaßen vernünftig) linear separierbar sind,
- ▶ Messe Kosten aber nur via Kernelfunktion...




1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines




1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
 5. Datenanalyse
 6. Repräsentation
 7. Klassifikation
- Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume


Support-Vector-Machines



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines



- ▶ Gefahr des Overfitting durch sukzessives Anpassen der Methodenparameter sehr groß
- ▶ Teil der Daten als Test- und ggf. Validierungsdaten unbedingt erforderlich

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

```
partimat(Geschlecht ~ Groesse + AnzSchuhe + Alter + AusgKomm, data=MyData, method="lda")
```

```
set.seed(1504)
```

```
M = as.data.frame(sapply(MyData[,c(1,2,11)], jitter))
```

```
M$Geschlecht = factor(MyData$Geschlecht, levels=c("Frau", "Mann"))
```

```
drawparti(M$Geschlecht, M$Groesse,  
          M$AnzSchuhe, method="lda",  
          prec=drawpartiprecision,  
          ylab="Ausgaben Schuhe", xlab="Groesse",  
          cex.mean=0, cex=2,  
          imageplot=TRUE,  
          image.colors=c(blue20, red20) )
```

```
M.lda = lda(Geschlecht ~ Groesse + AnzSchuhe, data=M)
```

```
M.predict = predict(M.lda, data=M)
```

```
errormatrix(M$Geschlecht, M.predict$class)
```

```
##      predicted  
## true   Frau Mann -SUM-  
## Frau  127   7    7  
## Mann   7   64   7  
## -SUM-  7    7   14
```

```
# percentages
```

```
round(100 * errormatrix(M$Geschlecht, M.predict$class, relative=TRUE), 1)
```

```
##      predicted  
## true   Frau Mann -SUM-  
## Frau  94.8  5.2  5.2  
## Mann   9.9 90.1  9.9  
## -SUM- 50.0 50.0  6.8
```



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
6. Repräsentation
7. Klassifikation
 - Problemstellung
 - Beispielproblem
 - Lineare Diskriminanzanalyse
 - Klassifikationsbäume
 - Support-Vector-Machines

