

# Statistische Analyseverfahren

## Abschnitt 6: Faktoranalyse (Faktorenanalyse)

Dr. Andreas Wünsche

TU Bergakademie Freiberg  
Institut für Stochastik

Dezember 2019/Januar 2020



## 6 Faktoranalyse (Faktorenanalyse)

- ▶ Die Faktoranalyse ist ein mathematisches Verfahren, welches (im Gegensatz zur Hauptkomponentenanalyse) auf die Erklärung der Korrelationen zwischen vielen messbaren (beobachtbaren bzw. beobachteten) Merkmalen hauptsächlich durch **wenige** zugrundeliegende (nichtbeobachtbare bzw. nicht beobachtete, „latente“) sogenannte **allgemeine Faktoren** abzielt.
- ▶ Insbesondere hohe Korrelationen zwischen den Merkmalen können darauf hindeuten, dass diese von einer oder von mehreren latenten Größen beeinflusst werden.
- ▶ Zum Beispiel sind Körpergröße und Gewicht (oder Schuhgröße) korreliert und beschreiben in etwa den latenten Faktor „Statur“).
- ▶ Die Merkmale und Faktoren sind durch lineare Beziehungen verknüpft und aus mathematischer Sicht kann man die Faktoranalyse als Strukturanalyse von Kovarianz- bzw. Korrelationsmatrizen ansehen.



## Weitere einführende Bemerkungen

- ▶ Die Faktoranalyse wurde zuerst von Psychologen entwickelt, später erfolgten statistische Begründungen, mathematische Untersuchungen und die Entwicklung weiterer Verfahren.
- ▶ Bei der Hauptkomponentenanalyse waren die Hauptkomponenten Linearkombinationen der Merkmale (und auch umgekehrt). Bei der Faktoranalyse werden umgekehrt die Merkmale als Linearkombinationen der Faktoren dargestellt.
- ▶ Ziel der Faktoranalyse ist die Extraktion der latenten Faktoren.
- ▶ Insbesondere wird untersucht, wie viele und welche Faktoren die Zusammenhänge möglichst gut „erklären“.
- ▶ Die Faktoren sollten möglichst gut interpretierbar sein.
- ▶ Ein typisches Beispiel besteht in der Extraktion von Faktoren wie Kreditwürdigkeit oder Grad der Existenzgefährdung einer Firma aus Realisierungen von Bilanzmerkmalen  $X_1, \dots, X_p$ .



## 6.1 Das $k$ -Faktor-Modell

### ► Def. 6.1.1

Sei  $\underline{\mathbf{X}}$  ein  $p$ -dimensionaler Zufallsvektor mit  $\mathbb{E}\underline{\mathbf{X}} = \underline{\underline{\boldsymbol{\mu}}}$ ,  $\text{Cov}\underline{\mathbf{X}} = \underline{\underline{\boldsymbol{\Sigma}}}$ .  
 $\underline{\mathbf{X}}$  genügt einem  $k$ -Faktor-Modell ( $k \in \mathbb{N}, k < p$ ), falls gilt

$$\underline{\mathbf{X}} = \underline{\underline{\boldsymbol{\lambda}}}\underline{\mathbf{F}} + \underline{\mathbf{U}} + \underline{\underline{\boldsymbol{\mu}}} \quad (1)$$

(**Bezeichnung:**  $\underline{\mathbf{X}} \sim F(k, \underline{\underline{\boldsymbol{\lambda}}}, \underline{\underline{\boldsymbol{\psi}}})$ ) mit

- (i)  $\underline{\mathbf{F}}$ , ein  $k$ -dimensionaler Zufallsvektor mit  $\mathbb{E}\underline{\mathbf{F}} = \underline{\mathbf{0}}_k$ ,  $\text{Cov}\underline{\mathbf{F}} = \underline{\underline{\mathbb{I}}}_k$ ,  
der **Vektor der allgemeinen Faktoren**,
  - (ii)  $\underline{\underline{\boldsymbol{\lambda}}}$ , die deterministische  $p \times k$ -**Matrix der Faktorladungen**,
  - (iii)  $\underline{\mathbf{U}}$ , ein  $p$ -dimensionaler Zufallsvektor der **spezifischen Faktoren** mit  
 $\mathbb{E}\underline{\mathbf{U}} = \underline{\mathbf{0}}_p$ ,  $\text{Cov}\underline{\mathbf{U}} = \text{diag}(\psi_1, \dots, \psi_p) =: \underline{\underline{\boldsymbol{\psi}}}$ ,  $\text{Cov}[\underline{\mathbf{F}}, \underline{\mathbf{U}}] = \underline{\mathbf{0}}_{k \times p}$ .
  - (iv)  $\underline{\underline{\boldsymbol{\mu}}}$ , der  $p$ -dimensionale deterministische Erwartungswertvektor des  
Merkmalszufallsvektors  $\underline{\mathbf{X}}$ .
- **Bem.** Die  $p$  Komponenten des Zufallsvektors  $\underline{\mathbf{X}}$  werden durch  $k + p$  andere Zufallsgrößen beschrieben.



# Komponentenweise Modellgleichungen

## Bem. 6.1.2

- ▶ Die Modellgleichung (1) komponentenweise lautet

$$X_i = \sum_{j=1}^k \lambda_{ij} F_j + U_i + \mu_i, \quad i = 1, \dots, p,$$

mit der Interpretation: wenige ( $k$ ) allgemeine Faktoren  $F_1, \dots, F_k$  und jeweils ein spezieller oder spezifischer Faktor  $U_i$  „erklären“ das Merkmal  $X_i$  (d.h. insgesamt  $k + 1$  Zufallsgrößen).

- ▶  $\lambda_{ij}$  wird als **Ladung des  $j$ -ten Faktors beim  $i$ -ten Merkmal** bezeichnet (und gibt damit den Einfluss des  $j$ -ten allgemeinen Faktors auf das  $i$ -te Merkmal an).
- ▶ Die allgemeinen Faktoren besitzen die Varianz 1 und sie sind unkorreliert.
- ▶ Die spezifischen Faktoren sind untereinander unkorreliert und unkorreliert zu den allgemeinen Faktoren, der  $i$ -te spezifische Faktor besitzt die Varianz  $\psi_i$ .



# Fundamentaltheorem der Faktoranalyse

## ► Satz 6.1.3

Für ein  $k$ -Faktor-Modell gemäß Def. 6.1.1 gelten

$$\text{Cov}\underline{\mathbf{X}} = \underline{\underline{\Sigma}} = \underline{\underline{\lambda}}\underline{\underline{\lambda}}^T + \underline{\underline{\psi}} = \underline{\underline{\lambda}}\underline{\underline{\lambda}}^T + \text{diag}(\psi_1, \dots, \psi_p); \quad (2)$$

$$\text{Var}X_i = \sigma_{ii} = \sum_{j=1}^k \lambda_{ij}^2 + \psi_i = h_i^2 + \psi_i, \quad i = 1, \dots, p. \quad (3)$$

## Bem. 6.1.4

- Bei gegebenen  $k < p$  und  $\underline{\underline{\psi}}$  sind notwendig und hinreichend für die Existenz einer solchen Kovarianzstruktur: der Rang der Matrix  $\underline{\underline{\Sigma}} - \underline{\underline{\psi}}$  ist kleiner oder gleich  $k$  und  $\underline{\underline{\Sigma}} - \underline{\underline{\psi}}$  ist positiv semidefinit.
- $h_i^2 = \sum_{j=1}^k \lambda_{ij}^2$  wird **allgemeine Varianz** oder **Kommunalität des  $i$ -ten Merkmals** genannt, sie misst den Teil der Varianz, der durch die allgemeinen Faktoren erklärt wird.
- $\psi_i$  ist die **spezifische Varianz des  $i$ -ten Merkmals**.



# Skaleninvarianz

## Bem. 6.1.5

Ein  $k$ -Faktor-Modell ist (im Gegensatz zur Hauptkomponentenanalyse) skaleninvariant im folgenden Sinn.

- (i) Es gelte  $\underline{\mathbf{X}} \sim F(k, \underline{\underline{\lambda}}, \underline{\underline{\psi}})$  und  $\underline{\underline{\mathbf{C}}} = \text{diag}(c_1, \dots, c_p)$  sei eine Skalierungsmatrix mit positiven Elementen auf der Hauptdiagonale. Dann gilt für den skalierten Zufallsvektor

$$\underline{\mathbf{Y}} := \underline{\underline{\mathbf{C}}}\underline{\mathbf{X}} \sim F(k, \underline{\underline{\mathbf{C}}}\underline{\underline{\lambda}}, \underline{\underline{\mathbf{C}}}\underline{\underline{\psi}}\underline{\underline{\mathbf{C}}}).$$

- (ii) Insbesondere kann  $c_i = \frac{1}{\sqrt{\sigma_{ii}}}$ ,  $i = 1, \dots, p$ , gewählt werden, so dass man mit standardisierten Zufallsgrößen und der zugehörigen Kovarianzmatrix, d.h. mit der Korrelationsmatrix des Zufallsvektors  $\underline{\mathbf{X}}$  arbeiten kann. In diesem Fall sind die Faktorladungen Korrelationskoeffizienten der Merkmale mit den allgemeinen Faktoren und so insbesondere betragsmäßig kleiner (oder gleich) 1.



# Nicht-Eindeutigkeit der Faktorladungen

## Bem. 6.1.6

- (i) In einem  $k$ -Faktor-Modell ist die Matrix der Faktorladungen für einen gegebenen Zufallsvektor  $\underline{\mathbf{X}}$  nicht eindeutig bestimmt. Ist  $\underline{\underline{\mathbf{g}}}$  eine orthogonale  $k \times k$ -Matrix, dann gilt mit

$$\underline{\mathbf{X}} = \underline{\underline{\lambda}} \underline{\mathbf{F}} + \underline{\mathbf{U}} + \underline{\mu} \quad \text{auch} \quad \underline{\mathbf{X}} = (\underline{\underline{\lambda}} \underline{\underline{\mathbf{g}}})(\underline{\underline{\mathbf{g}}}^T \underline{\mathbf{F}}) + \underline{\mathbf{U}} + \underline{\mu},$$

also die Definitionsbeziehung für ein  $k$ -Faktor-Modell mit der Matrix der Faktorladungen  $\underline{\underline{\lambda}} \underline{\underline{\mathbf{g}}}$  und dem Vektor der allgemeinen Faktoren  $\underline{\underline{\mathbf{g}}}^T \underline{\mathbf{F}}$ . Man spricht in diesem Zusammenhang von einer **Rotation der Faktoren**.

- (ii) Durch zusätzliche formale Nebenbedingungen, z.B.  $\underline{\underline{\lambda}}^T \underline{\underline{\psi}}^{-1} \underline{\underline{\lambda}}$  ist diagonal oder  $\underline{\underline{\lambda}}^T \text{diag}(\sigma_{11}, \dots, \sigma_{pp})^{-1} \underline{\underline{\lambda}}$  ist diagonal, kann  $\underline{\underline{\lambda}}$  im Wesentlichen eindeutig bestimmt werden (bis auf Vorzeichenwechsel in den Spalten), so dass das Fundamentaltheorem der Faktoranalyse erfüllt ist.





# Parameteranzahl

## Bem. 6.1.7

- (i) Die Matrix  $\underline{\Sigma}$  ohne zusätzliche Struktur enthält  $\frac{1}{2}p(p+1)$  Parameter, mit der Struktur eines  $k$ -Faktor-Modells  $pk+p$  Parameter und mit einer zusätzlichen Nebenbedingung wie in 6.1.6
- (ii)  $pk+p-\frac{1}{2}k(k-1)$  Parameter. Da die Faktoranalyse nur sinnvoll ist, wenn dadurch die Anzahl der unbekannt Parameter verringert wird, fordert man im Allgemeinen

$$\frac{p(p+1)}{2} - \left( pk + p - \frac{k(k-1)}{2} \right) = \frac{(p-k)^2 - p - k}{2} := s > 0.$$

- (ii) Diese Bedingung ergibt als maximale Anzahlen  $k$  von allgemeinen Faktoren in Abhängigkeit von der Anzahl  $p$  der Variablen

| $p$                    | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 |
|------------------------|---|---|---|---|---|---|---|----|----|----|
| max $k$ für $s > 0$    |   | 1 | 2 | 2 | 3 | 4 | 5 | 5  | 6  | 7  |
| max $k$ für $s \geq 0$ | 1 | 1 | 2 | 3 | 3 | 4 | 5 | 6  | 6  | 7  |



## Fortsetzung Parameteranzahl

- (iii) Bei Nutzung standardisierter Zufallsgrößen enthält deren Kovarianzmatrix (also ggf. die Korrelationsmatrix der Ausgangszufallsgrößen)  $\frac{1}{2}p(p-1)$  Parameter. Die Bedingung für eine geringere Parameteranzahl in einem  $k$ -Faktor-Modell mit einer zusätzlichen Nebenbedingung wie in 6.1.6 (ii) ist dann

$$\frac{p(p-1)}{2} - \left( pk + p - \frac{k(k-1)}{2} \right) = \frac{(p-k)^2 - 3p - k}{2} := s > 0.$$

- (iv) Diese Bedingung ergibt als maximale Anzahlen  $k$  von allgemeinen Faktoren in Abhängigkeit von der Anzahl  $p$  der Variablen

| $p$                    | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 |
|------------------------|---|---|---|---|---|---|---|----|----|----|
| max $k$ für $s > 0$    |   |   |   | 1 | 2 | 2 | 3 | 4  | 4  | 5  |
| max $k$ für $s \geq 0$ |   |   | 1 | 1 | 2 | 2 | 3 | 4  | 4  | 5  |

- (v) Das Auffinden von allgemeinen Faktoren kann aber auch so inhaltlich von Nutzen sein.



# Beispiel 1-Faktor-Modell

## Bsp. 6.1.8

- ▶ Es seien  $p = 3$  und  $k = 1$ , dann lautet das 1-Faktor-Modell

$$\begin{pmatrix} X_1 \\ X_2 \\ X_3 \end{pmatrix} = \begin{pmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_3 \end{pmatrix} \cdot F + \begin{pmatrix} U_1 \\ U_2 \\ U_3 \end{pmatrix} + \begin{pmatrix} \mu_1 \\ \mu_2 \\ \mu_3 \end{pmatrix}.$$

- ▶ Für (2) erhält man mit  $\sigma_{ii} = \sigma_i^2 > 0$ ,  $i = 1, 2, 3$ ,

$$\begin{pmatrix} \sigma_1^2 & \rho_{12}\sigma_1\sigma_2 & \rho_{13}\sigma_1\sigma_3 \\ \rho_{12}\sigma_1\sigma_2 & \sigma_2^2 & \rho_{23}\sigma_2\sigma_3 \\ \rho_{13}\sigma_1\sigma_3 & \rho_{23}\sigma_2\sigma_3 & \sigma_3^2 \end{pmatrix} = \begin{pmatrix} \lambda_1^2 & \lambda_1\lambda_2 & \lambda_1\lambda_3 \\ \lambda_1\lambda_2 & \lambda_2^2 & \lambda_2\lambda_3 \\ \lambda_1\lambda_3 & \lambda_2\lambda_3 & \lambda_3^2 \end{pmatrix} + \begin{pmatrix} \psi_1 & 0 & 0 \\ 0 & \psi_2 & 0 \\ 0 & 0 & \psi_3 \end{pmatrix}.$$

## Fortsetzung Beispiel 1-Faktor-Modell

- ▶ Falls  $\rho_{ij} \neq 0$ ,  $i, j = 1, 2, 3$  ( $i \neq j$ ) und

$$0 \leq \frac{\rho_{12}\rho_{13}}{\rho_{23}} \leq 1, \quad 0 \leq \frac{\rho_{12}\rho_{23}}{\rho_{13}} \leq 1, \quad 0 \leq \frac{\rho_{13}\rho_{23}}{\rho_{12}} \leq 1$$

existiert eine eindeutige Lösung (bis auf die Vorzeichen der  $\lambda_i$ )

$$\lambda_1^2 = \frac{\rho_{12}\rho_{13}}{\rho_{23}}\sigma_1^2, \quad \lambda_2^2 = \frac{\rho_{12}\rho_{23}}{\rho_{13}}\sigma_2^2, \quad \lambda_3^2 = \frac{\rho_{13}\rho_{23}}{\rho_{12}}\sigma_3^2,$$

$$\psi_1 = \sigma_1^2 - \lambda_1^2, \quad \psi_2 = \sigma_2^2 - \lambda_2^2, \quad \psi_3 = \sigma_3^2 - \lambda_3^2.$$

- ▶ Nutzt man standardisierte Merkmalszufallsgrößen kann man mit der Korrelationsmatrix rechnen und obige Formeln gelten mit  $\sigma_1 = \sigma_2 = \sigma_3 = 1$ .
- ▶ Dieses Verfahren kann auch für Zufallsvektoren mit  $p > 3$  Komponenten angewandt werden. Ist die erste Zeile der Korrelationsmatrix gleich  $(1, \rho_{12}, \rho_{13}, \dots, \rho_{1p})$ , muss z.B. für die zweite Zeile eine Konstante  $c$  existieren, so dass diese lautet  $(\rho_{12}, 1, c\rho_{13}, \dots, c\rho_{1p})$ , analog für die anderen Zeilen.



## 6.2 Schätzung von $\underline{\underline{\lambda}}$ und $\underline{\underline{\psi}}$

### Bem. 6.2.1

- (i) Seien  $\underline{\underline{\mathbf{x}}}$  eine Datenmatrix, sowie  $\underline{\underline{\hat{\mu}}} = \underline{\underline{\bar{\mathbf{x}}}}$  und  $\underline{\underline{\hat{\Sigma}}} = \underline{\underline{\mathbf{s}_{\underline{\underline{\mathbf{x}}}}}}$  mit Diagonalelementen  $s_{11}, \dots, s_{pp}$  Schätzer der Parameter.
- (ii) Aufgrund der Skaleninvarianz kann man mit der standardisierten Datenmatrix  $\underline{\underline{\mathbf{y}}} := (\underline{\underline{\mathbf{I}}}_p - \frac{1}{n}\underline{\underline{\mathbf{1}}}\underline{\underline{\mathbf{1}}}^T)\underline{\underline{\mathbf{x}}}\underline{\underline{\mathbf{d}}}^{-1}$  mit  $\underline{\underline{\mathbf{d}}} = \text{diag}(s_{11}, \dots, s_{pp})$  arbeiten. Die empirische Kovarianzmatrix zu  $\underline{\underline{\mathbf{y}}}$  ist die empirische Korrelationsmatrix zur Datenmatrix  $\underline{\underline{\mathbf{x}}}$ , also  $\underline{\underline{\mathbf{r}}}_{\underline{\underline{\mathbf{x}}}} = \underline{\underline{\mathbf{r}}}$ .
- (iii) Hier wird die Datenmatrix im Folgenden weiter mit  $\underline{\underline{\mathbf{x}}}$  und die zugehörige empirische Korrelationsmatrix mit  $\underline{\underline{\mathbf{r}}}$  bezeichnet.
- (iv) Dann sind für festes  $k$  eine Matrix der Faktorladungen  $\underline{\underline{\ell}}$  und die Diagonalmatrix der spezifischen Varianzen  $\underline{\underline{\psi}}$  gesucht, so dass gilt

$$\underline{\underline{\mathbf{r}}} = \underline{\underline{\ell}}\underline{\underline{\ell}}^T + \underline{\underline{\psi}} \quad \text{bzw.} \quad \underline{\underline{\mathbf{r}}} - \underline{\underline{\psi}} = \underline{\underline{\ell}}\underline{\underline{\ell}}^T.$$

Dabei sollten die spezifischen Varianzen möglichst klein sein.

# Spezialfall 1-Faktor-Modell

## Bsp. 6.2.2

- ▶ Im Fall eines 1-Faktor-Modells (z.B. mit  $p = 3$  und standardisierten Merkmalen) können (falls  $r_{ij} \neq 0$ ,  $i, j = 1, 2, 3$ ) die theoretischen Formeln von Beispiel 6.1.8 auf die empirischen Schätzwerte der Korrelationskoeffizienten angewandt werden, um Schätzwerte für die Faktorladungen und Varianzen der spezifischen Faktoren zu erhalten:

$$\hat{\lambda}_1^2 = \ell_1^2 = \frac{r_{12}r_{13}}{r_{23}}, \quad \hat{\lambda}_2^2 = \ell_2^2 = \frac{r_{12}r_{23}}{r_{13}}, \quad \hat{\lambda}_3^2 = \ell_3^2 = \frac{r_{13}r_{23}}{r_{12}},$$

$$\hat{\psi}_1 = 1 - \hat{\lambda}_1^2, \quad \hat{\psi}_2 = 1 - \hat{\lambda}_2^2, \quad \hat{\psi}_3 = 1 - \hat{\lambda}_3^2.$$

- ▶ Gilt dabei  $\hat{\lambda}_i^2 < 0$  oder  $\hat{\psi}_i < 0$  für ein  $i \in \{1, 2, 3\}$ , dann kann kein 1-Faktor-Modell gefunden werden. Man nennt dies auch einen **HEYWOOD-Fall**.

# Klassisches Beispiel von SPEARMAN (1904)

## Bsp. 6.2.3 (SPEARMAN 1904)

- ▶ Untersuchungen von Prüfungsergebnissen von Kindern in Altphilologie ("classics",  $X_1$ ), Französisch ( $X_2$ ) und Englisch ( $X_3$ ). Die Auswertung ergab die folgende Stichproben-Korrelationsmatrix

$$\underline{\underline{\mathbf{r}}} = \begin{pmatrix} 1 & 0.83 & 0.78 \\ & 1 & 0.67 \\ & & 1 \end{pmatrix}.$$

- ▶ Diese Matrix hat vollen Rang, besitzt jedoch die Darstellung

$$\begin{aligned} \underline{\underline{\mathbf{r}}} &\approx \begin{pmatrix} 0.983 \\ 0.844 \\ 0.793 \end{pmatrix} (0.983 \ 0.844 \ 0.793) + \begin{pmatrix} 0.034 & 0 & 0 \\ 0 & 0.287 & 0 \\ 0 & 0 & 0.370 \end{pmatrix} \\ &= \underline{\underline{\ell}} \cdot \underline{\underline{\ell}}^T + \underline{\underline{\psi}}. \end{aligned}$$

## Fortsetzung Beispiel 6.2.3

- ▶ Die Ladungsmatrix ist  $\ell = (0.983 \ 0.844 \ 0.793)^T$ . Bei allen drei Merkmalen hat der eine allgemeine Faktor eine hohe Ladung.
- ▶ Den einen allgemeinen Faktor  $F$  in  $\mathbf{X} = \underline{\lambda}F + \mathbf{U} + \underline{\mu}$  könnte man als „Sprachbegabtheit“ oder „Sprachtalent“ interpretieren.
- ▶ Da  $\text{Var}X_1 = 0.983^2$  und  $\psi_1 = 1 - 0.983^2 = 0.034$  ist das Merkmal  $X_1$  („Altphilologie“) fast identisch mit dem allgemeinen Faktor.
- ▶ Das dritte Merkmal („Englisch“) lässt sich am wenigsten (aber immerhin zu  $\approx 63\%$ ) durch den allgemeinen Faktor „Sprachtalent“ erklären.





# Verschiedene Schätzmethoden

## Bem. 6.2.4

Es existieren verschiedene Schätzmethoden, z.B.

- (i) die **Hauptfaktorenanalyse** (engl. "principal factor analysis"), dabei wird die Spektralzerlegung symmetrischer Matrizen in einem iterativen Verfahren genutzt;
- (ii) die **Maximum-Likelihood-Faktor-Analyse** unter der Voraussetzung, dass die Daten normalverteilt sind,

$$\underline{\mathbf{X}} \sim N(\underline{\boldsymbol{\mu}}, \underline{\boldsymbol{\Sigma}} = \underline{\boldsymbol{\lambda}}\underline{\boldsymbol{\lambda}}^T + \underline{\boldsymbol{\psi}}),$$

$\boldsymbol{\lambda}$  und  $\boldsymbol{\psi}$  werden in einem iterativen Verfahren geschätzt;

- (iii) die **Zentroid-Methode** (THURSTONE, 1931), die relativ einfach, aber auch mit viel Willkür verbunden ist; oder
- (iv) die **kanonische Faktoranalyse** (RAO, 1955), bei der ein Anliegen ist, dass die Korrelation zwischen den  $p$  Merkmalen und den zu bestimmenden  $k$  allgemeinen Faktoren so groß wie möglich sein soll.



# Algorithmus für die Hauptfaktorenanalyse

## Algorithmus 6.2.5

(Quelle: HANDL, KUHLENKASPER, Multivariate Analysemethoden, Springer 2017, Kap. 9)

1. Mit dem Bestimmtheitsmaß  $b_i^2$  einer Regression von  $X_i$  auf die restlichen Variablen sei  $\hat{\psi}_i = 1 - b_i^2$  der Schätzer der  $i$ -ten spezifischen Varianz ( $i = 1, \dots, p$ ).
2. Aufstellen von  $\underline{\underline{\hat{\psi}}} = \text{diag}(\hat{\psi}_1, \dots, \hat{\psi}_p)$ .
3. Berechnung von  $\underline{\underline{\mathbf{r}}} - \underline{\underline{\hat{\psi}}}$ .
4. Spektralzerlegung von  $\underline{\underline{\mathbf{r}}} - \underline{\underline{\hat{\psi}}}$  zur Bestimmung von  $\underline{\underline{\hat{\lambda}}}$ .
5. Neue Diagonalmatrix  $\underline{\underline{\hat{\psi}}}$  mit den Hauptdiagonalelementen von  $\underline{\underline{\mathbf{r}}} - \underline{\underline{\hat{\lambda}}}\underline{\underline{\hat{\lambda}}}^T$  auf der Hauptdiagonalen.
6. Wiederholung der Schritte 3., 4. und 5. so lange, bis aufeinander folgende Paare von  $\underline{\underline{\hat{\psi}}}$  und  $\underline{\underline{\hat{\lambda}}}$  in einer vorgegebenen Genauigkeit identisch sind.



# Beispiel für die Hauptfaktorenanalyse

**Bsp. 6.2.6** (Quelle: HANDL, KUHLENKASPER, Multivariate Analysemethoden, Springer 2017, Kap. 9, Bsp. 40)

- ▶ Empirische Korrelationsmatrix und deren Inverse.

$$\underline{\underline{\mathbf{r}}} = \begin{pmatrix} 1.000 & 0.223 & 0.133 & 0.625 & 0.506 & 0.500 \\ 0.223 & 1.000 & 0.544 & 0.365 & 0.320 & 0.361 \\ 0.133 & 0.544 & 1.000 & 0.248 & 0.179 & 0.288 \\ 0.625 & 0.365 & 0.248 & 1.000 & 0.624 & 0.630 \\ 0.506 & 0.320 & 0.179 & 0.624 & 1.000 & 0.625 \\ 0.500 & 0.361 & 0.288 & 0.630 & 0.625 & 1.000 \end{pmatrix}$$

$$\underline{\underline{\mathbf{r}^{-1}}} = \begin{pmatrix} 1.731 & 0.040 & 0.060 & -0.810 & -0.250 & -0.231 \\ 0.040 & 1.578 & -0.740 & -0.234 & -0.170 & -0.123 \\ 0.060 & -0.740 & 1.451 & -0.070 & 0.124 & -0.215 \\ -0.810 & -0.234 & -0.070 & 2.365 & -0.600 & -0.605 \\ -0.250 & -0.170 & 0.124 & -0.600 & 1.974 & -0.705 \\ -0.231 & -0.123 & -0.215 & -0.605 & -0.705 & 2.043 \end{pmatrix}$$



## Bsp. 6.2.6 Schätzung der Kommunalitäten

- ▶ Es gilt  $\underline{\underline{\mathbf{r}}} - \underline{\underline{\hat{\psi}}} = \underline{\underline{\hat{\lambda}}}\underline{\underline{\hat{\lambda}}}^T$ . Die Matrizen  $\underline{\underline{\mathbf{r}}}$  und  $\underline{\underline{\mathbf{r}}} - \underline{\underline{\hat{\psi}}}$  unterscheiden sich nur auf der Hauptdiagonalen, auf der rechten Seite stehen dort die Schätzungen der Kommunalitäten  $\hat{h}_i^2, i = 1, \dots, p$ . Diesen Schätzwert erhält man, indem man die  $i$ -te Variable auf die anderen Variablen regressiert, der Wert ist das Bestimmtheitsmaß  $b_i^2$ , für welches gilt  $b_i^2 = 1 - \frac{1}{r^{ii}}$ , wobei  $r^{ii}$  das  $i$ -te Element der Hauptdiagonale von  $\underline{\underline{\mathbf{r}}}^{-1}$  ist.
- ▶ So erhält man die Schätzungen

$$\begin{aligned}\hat{h}_1^2 &= 0.422, & \hat{h}_2^2 &= 0.366, & \hat{h}_3^2 &= 0.311, \\ \hat{h}_4^2 &= 0.577, & \hat{h}_5^2 &= 0.493, & \hat{h}_6^2 &= 0.511.\end{aligned}$$

## Bsp. 6.2.6 Spektralzerlegung

- ▶ Mit diesen Schätzern gilt

$$\underline{\underline{\mathbf{r}}} - \underline{\underline{\hat{\boldsymbol{\psi}}}} = \begin{pmatrix} 0.422 & 0.223 & 0.133 & 0.625 & 0.506 & 0.500 \\ 0.223 & 0.366 & 0.544 & 0.365 & 0.320 & 0.361 \\ 0.133 & 0.544 & 0.311 & 0.248 & 0.179 & 0.288 \\ 0.625 & 0.365 & 0.248 & 0.577 & 0.624 & 0.630 \\ 0.506 & 0.320 & 0.179 & 0.624 & 0.493 & 0.625 \\ 0.500 & 0.361 & 0.288 & 0.630 & 0.625 & 0.511 \end{pmatrix}$$

- ▶ Die Spektralzerlegung ergibt

$$\underline{\underline{\mathbf{r}}} - \underline{\underline{\hat{\boldsymbol{\psi}}}} = \underline{\underline{\mathbf{v}}} \underline{\underline{\mathbf{d}}} \underline{\underline{\mathbf{v}}}^T$$

mit einer Diagonalmatrix  $\underline{\underline{\mathbf{d}}}$ , deren Diagonalelemente im Allgemeinen nicht alle nichtnegativ sind.



## Bsp. 6.2.6 Approximation von $\underline{\hat{\lambda}}$

- ▶ Sei  $\underline{\mathbf{v}}_1$  die Matrix mit den normierten Eigenvektoren zu den  $k$  größten Eigenwerten, wobei vorausgesetzt wird, dass diese positiv sind,  $\underline{\mathbf{d}}_1$  sei die Diagonalmatrix mit diesen Eigenwerten.
- ▶ Eine neue Approximation von  $\underline{\mathbf{r}} - \underline{\hat{\psi}}$  ist

$$\underline{\mathbf{r}} - \underline{\hat{\psi}} \approx \underline{\mathbf{v}}_1 \underline{\mathbf{d}}_1^{1/2} (\underline{\mathbf{v}}_1 \underline{\mathbf{d}}_1^{1/2})^T =: \underline{\hat{\lambda}}_1 \underline{\hat{\lambda}}_1^T.$$

Diese Schätzung kann in die Ausgangsgleichung in 5. eingesetzt und damit die Iterationen fortgesetzt werden.

## Fortsetzung Beispiel 6.2.6

- ▶ Im Beispiel gibt es zwei positive Eigenwerte  $d_1 = 2.606$ ,  $d_2 = 0.573$  mit zugehörigen Eigenvektoren

$$\underline{\mathbf{v}}_1 = (0.403, 0.322, 0.248, 0.497, 0.452, 0.470)^T$$

$$\underline{\mathbf{v}}_2 = (0.316, -0.602, -0.669, 0.191, 0.219, 0.081)^T$$

- ▶ Durch Multiplikation von  $\underline{\mathbf{v}}_1$  mit  $\sqrt{d_1} = 1.614$  und von  $\underline{\mathbf{v}}_2$  mit  $\sqrt{d_2} = 0.757$  erhalten wir die Spalten der Matrix  $\hat{\underline{\lambda}}_1$

$$\hat{\underline{\lambda}}_1 = \begin{pmatrix} 0.650 & 0.519 & 0.400 & 0.803 & 0.730 & 0.759 \\ 0.239 & -0.455 & -0.506 & 0.145 & 0.165 & 0.061 \end{pmatrix}^T.$$

## Fortsetzung Beispiel 6.2.6

- ▶ Man erhält

$$\hat{\underline{\lambda}}_1 \hat{\underline{\lambda}}_1^T = \begin{pmatrix} 0.480 & 0.229 & 0.139 & 0.557 & 0.514 & 0.508 \\ 0.229 & 0.477 & 0.438 & 0.351 & 0.304 & 0.366 \\ 0.139 & 0.438 & 0.416 & 0.248 & 0.208 & 0.272 \\ 0.557 & 0.351 & 0.248 & 0.666 & 0.610 & 0.618 \\ 0.514 & 0.304 & 0.208 & 0.610 & 0.560 & 0.564 \\ 0.508 & 0.366 & 0.272 & 0.618 & 0.564 & 0.580 \end{pmatrix}.$$

- ▶ Also gilt

$$\begin{aligned} \hat{\psi}_1 &= 0.520, & \hat{\psi}_2 &= 0.523, & \hat{\psi}_3 &= 0.584, \\ \hat{\psi}_4 &= 0.334, & \hat{\psi}_5 &= 0.440, & \hat{\psi}_6 &= 0.420. \end{aligned}$$

Mit dieser neuen Matrix  $\hat{\underline{\psi}}$  kann ein neuer Schätzer  $\hat{\underline{\lambda}}$  bestimmt werden.





# Anzahl der allgemeinen Faktoren

Eine praktische Bestimmung der Anzahl  $k$  der Faktoren kann z.B. erfolgen als

- ▶ die Anzahl der Eigenwerte der empirischen Korrelationsmatrix, die größer als 1 sind;
- ▶ die Anzahl der positiven Eigenwerte der Matrix  $\underline{\underline{\mathbf{r}}} - \underline{\underline{\hat{\psi}}}$  im Algorithmus 6.2.5 5.;
- ▶ die kleinste Anzahl  $k$ , bei der die Summe der  $k$  größten Eigenwerte von  $\underline{\underline{\mathbf{r}}} - \underline{\underline{\hat{\psi}}}$  im Algorithmus 6.2.5 5. die Summe aller Eigenwerte übertrifft.
- ▶ Daneben kann man sich auch an den Ergebnissen einer Hauptkomponentenanalyse der (skalierten) Daten orientieren.



## 6.3 Rotation der Faktorladungsmatrix

### Bem. 6.3.1

- (i) Liegen Schätzwerte für die Faktorladungsmatrix und die Varianzen der spezifischen Faktoren vor, beginnt das Problem der Deutung des Ergebnisses. Dabei kann die Nicht-Eindeutigkeit der Faktorladungen (siehe Bem. 6.1.6) genutzt werden.
- (ii) Eine Interpretation von Faktorladungen ist einfacher, wenn
  - ▶ jedes Merkmal eine hohe Ladung wenigstens eines Faktors hat,
  - ▶ jede Faktorladung entweder hoch oder nahe Null ist, d.h. es möglichst wenige „mittlere“ Ladungen gibt. Man spricht auch von Faktorladungen mit einer sogenannten **Einfachstruktur**.
- (iii) Eine Rotation muss nicht zur besseren Interpretation führen.
- (iv) Zur Bestimmung einer geeigneten orthogonalen Matrix  $\underline{\underline{\mathbf{g}}}$  können verschiedene Prinzipien genutzt werden, hier sollen kurz die **Varimax-Rotation** und die **Quartimax-Rotation** erläutert werden. Dabei wird in den Formeln auf die Kennzeichnung der Schätzungen durch  $\hat{\cdot}$  verzichtet.



# Varimax-Rotation

## Bem. 6.3.2

- (i) Gesucht wird eine transformierte Matrix der Faktorladungen  $\underline{\underline{\Delta}} = \underline{\underline{\lambda}} \mathbf{g}$ , die möglichst viele kleine oder große Ladungen hat.
- (ii) Es sei  $\underline{\underline{\Delta}} = (\delta_{ij})_{i=1, \dots, p; j=1, \dots, k}$  und  $d_{ij} = \frac{\delta_{ij}}{h_i}$ , hier sind  $h_i, i = 1, \dots, p$ , wieder die Kommunalitäten.
- (iii) Bei der **Varimax-Rotation** wird die Matrix  $\underline{\underline{\Delta}}$  so bestimmt, dass die quadrierten Ladungen maximal streuen (die Varianzen der Ladungsquadrate eines Faktors werden maximiert), d.h. durch das Extremwertproblem

$$\sum_{j=1}^k \sum_{i=1}^p \left( d_{ij}^2 - \overline{(d_{\bullet j}^2)} \right)^2 \stackrel{!}{=} \max \quad \text{mit} \quad \overline{(d_{\bullet j}^2)} := \frac{1}{p} \sum_{i=1}^p d_{ij}^2.$$

- (iv) Die numerische Lösung der Optimierungsaufgabe erfolgt sukzessive für je zwei Faktoren.



# Varimax-Rotation: Erster Schritt Optimierungsaufgabe

(v) Man beginnt mit  $j = 1$  und  $j = 2$ .

Seien  $\mathbf{g}_{(1\ 2)} = \begin{pmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{pmatrix}$  die Rotationsmatrix mit dem Rotationswinkel  $\theta$  und  $\underline{\lambda}_{(1\ 2)}$  die auf die ersten zwei Spalten reduzierte Faktorladungsmatrix.

(vi) Dann ergeben sich die Elemente der ersten zwei Spalten der normierten und rotierten Faktorladungsmatrix zu  $(i = 1, \dots, p)$

$$d_{i1} = \frac{1}{h_i}(\lambda_{i1} \cos \theta - \lambda_{i2} \sin \theta), \quad d_{i2} = \frac{1}{h_i}(\lambda_{i1} \sin \theta + \lambda_{i2} \cos \theta).$$

(vii) Mit diesen  $d_{i1}$  und  $d_{i2}$  löst man die Optimierungsaufgabe

$$\sum_{i=1}^p \left( d_{i1}^2 - \overline{(d_{\bullet 1}^2)} \right)^2 + \sum_{i=1}^p \left( d_{i2}^2 - \overline{(d_{\bullet 2}^2)} \right)^2 \stackrel{!}{=} \max_{\theta}.$$



## Varimax-Rotation: Fortsetzung Optimierungsaufgabe

- (viii) Anschließend werden die dritte, vierte,  $\dots$ , und letzte Spalte der unrotierten Faktorladungsmatrix  $\underline{\lambda}$  mit der rotierten ersten Spalte auf obige Weise rotiert.
- (ix) Daran anschließend wird die rotierte zweite Spalte mit der rotierten dritten, vierten,  $\dots$ , rotierten letzten Spalte rotiert.
- (x) Dieses Verfahren wird fortgesetzt, bis insgesamt  $k(k - 1)/2$  Rotationen durchgeführt sind.
- (xi) Mitunter wird in (ii) auch die Skalierung durch die Kommunalitäten nicht durchgeführt.



# Quartimax-Rotation

## Bem. 6.3.3

- ▶ Bei der **Quartimax-Rotation** möchte man möglichst jedes Merkmal durch **wenige** allgemeinen Faktor erklären.
- ▶ Praktisch sucht man die Rotation, bei der die Summe der Varianzen der gewichteten Ladungsquadrate einer Variablen

$$\sum_{i=1}^p \sum_{j=1}^k \sum_{i=1}^p \left( \delta_{ij}^2 - \overline{(\delta_{i\bullet}^2)} \right)^2 \stackrel{!}{=} \max \quad \text{mit} \quad \overline{(\delta_{i\bullet})} := \frac{1}{k} \sum_{i=1}^p \delta_{ij}^2.$$

maximiert wird.

## 6.4 Schätzung der allgemeinen Faktoren für einen Merkmalsvektor

- ▶ Bisher wurden für eine Datenmatrix  $\underline{\underline{\mathbf{x}}}$  die Schätzungen  $\underline{\underline{\ell}}$  für die Faktorladungsmatrix,  $\underline{\underline{\psi}}$  für die Matrix der spezifischen Varianzen und  $\underline{\underline{\bar{x}}}$  für die Erwartungswerte betrachtet.
- ▶ In bestimmten Situationen kann es aber auch von großem Interesse sein, für einen gegebenen konkreten Merkmalsvektor  $\underline{\underline{\mathbf{x}}}$  die zugehörigen Ausprägungen der allgemeinen Faktoren zu schätzen, d.h. einen  $k$ -dimensionalen Vektor  $\underline{\underline{\hat{\mathbf{f}}}}$ , so dass gilt

$$\underline{\underline{\mathbf{x}}} = \underline{\underline{\ell}} \underline{\underline{\hat{\mathbf{f}}}} + \underline{\underline{\hat{\mathbf{u}}}} + \underline{\underline{\bar{\mathbf{x}}}}.$$

- ▶ Genutzt werden bei den Schätzungen oft der zentrierte Merkmalsvektor  $\underline{\underline{\mathbf{y}}} = \underline{\underline{\mathbf{x}}} - \underline{\underline{\bar{\mathbf{x}}}}$  oder der standardisierte Merkmalsvektor mit den Komponenten  $y_j = \frac{x_j - \bar{x}_j}{s_{jj}}$ .



# BARTLETT- und THOMPSON-Faktor-Schätzung

- ▶ Es gibt verschiedene Schätzmethoden für die Faktorwerte, z.B. basierend auf einer Regression oder die Schätzung nach ANDERSON-RUBIN.
- ▶ Die **BARTLETT-Faktor-Schätzung** nutzt die Formel

$$\hat{\underline{\mathbf{f}}} = \left( \underline{\underline{\ell}}^T \underline{\underline{\boldsymbol{\psi}}}^{-1} \underline{\underline{\ell}} \right)^{-1} \underline{\underline{\ell}}^T \underline{\underline{\boldsymbol{\psi}}}^{-1} \underline{\mathbf{y}}.$$

- ▶ Die **THOMPSON-Faktor-Schätzung** nutzt die Formel

$$\hat{\underline{\mathbf{f}}} = \left( \underline{\underline{\ell}}^T \underline{\underline{\boldsymbol{\psi}}}^{-1} \underline{\underline{\ell}} + \underline{\underline{\mathbb{I}}}_k \right)^{-1} \underline{\underline{\ell}}^T \underline{\underline{\boldsymbol{\psi}}}^{-1} \underline{\mathbf{y}}.$$





## 6.5 Beispiel Autokaufentscheidung

- ▶ Quelle: HORST RINNE, Statistische Analyse multivariater Daten : Einführung, R.Oldenbourg Verlag, München, Wien, 2000; Beispiel 5/1; siehe auch Vorlesungsskript Prof. Dr. Fred Böker, Georg-August-Universität Göttingen, Analyse mehrdimensionaler Daten, Kap. 5 Faktorenanalyse, <https://www.uni-goettingen.de/de/304527.html>.
- ▶ Vergebene Punktzahlen (zwischen 0 und 20) von 25 Käufern eines neuen Autos in einem Autohaus hinsichtlich der Wichtigkeit der Merkmale (in dieser Reihenfolge)
  - ▶ Anschaffungspreis,
  - ▶ Betriebskosten,
  - ▶ Umfang der Serienausstattung,
  - ▶ Styling der Karosserie,
  - ▶ Prestige der Marke,
  - ▶ Fahrkomfort,
  - ▶ Raumangebot.



## Fortsetzung Bsp. 6.5

- ▶ Es gibt zwei Eigenwerte der Korrelationsmatrix größer als 1.
- ▶ Eine Hauptkomponentenanalyse der nicht skalierten und der skalierten Daten ergibt jeweils zwei Hauptkomponenten, die zusammen mehr als 91 % der Gesamtstreuung erklären, bei 3 Hauptkomponenten sind es jeweils mehr als 94 % der Gesamtstreuung.
- ▶ Die Scree-Plots ergeben auch die Nutzung von 2 oder 3 Faktoren, hier werden 2 gewählt.



## 2. Fortsetzung Bsp. 6.5

- ▶ In R kann eine Faktoranalyse z.B. mit dem Befehl `factanal()` durchgeführt werden. Dabei wird eine Normalverteilung der Daten angenommen und die Maximum-Likelihood-Faktor-Analyse mit Varimax-Rotation berechnet.
- ▶ Man erhält für die Daten die folgende Faktorladungsmatrix und ein entsprechendes Schema für die Faktorladungen betragsmäßig größer als 0.5:


$$\underline{\underline{\ell}} = \begin{pmatrix} -0.2522 & 0.9539 \\ -0.0322 & 0.8431 \\ 0.0964 & 0.9383 \\ 0.8995 & -0.0007 \\ 0.9093 & -0.2814 \\ 0.8713 & 0.4080 \\ 0.9415 & -0.2049 \end{pmatrix}, \quad \begin{array}{|c|c|} \hline & \times \\ \hline & \times \\ \hline & \times \\ \hline \times & \\ \hline \times & \\ \hline \times & \\ \hline \times & \\ \hline \end{array} .$$

- ▶ Den ersten Faktor könnte man als „Produktdesign“, den zweiten als „Wirtschaftlichkeit“ bezeichnen.



### 3. Fortsetzung Bsp. 6.5

- Die Variablen können in Faktorraum wie folgt dargestellt werden:



- Eine Berechnung der THOMPSON-Faktorschätzwerte erfolgt z.B. durch `factanal(..., scores='regression')`.
- Eine Varimax-Rotation der ersten beiden Hauptkomponenten ergibt eine Ladungsmatrix, die sich nur wenig von der Ladungsmatrix bei der Maximum-Likelihood-Faktoranalyse mit Varimax-Rotation unterscheidet.