

# Statistik für Digital Humanities

## Explorative Faktorenanalyse

Dr. Jochen Tiepmar

Institut für Informatik  
Computational Humanities  
**Universität Leipzig**

03. August 2020

[Letzte Aktualisierung: 20/08/2020, 20:23]

"It's a good job I'll never have to do that again" *AndyField*

# Überblick

## 1 Latente Variablen / Faktoren

- Was?
- Berechnung
- Scoring

## 2 Faktoreidentifizierung

- Kommunalität
- Principal Component Analysis vs. Faktorenanalyse
- Faktorenanalyse
- Verlässlichkeitsanalyse

## 3 Anwendungsbeispiel

- Fragebögen
- Faktorenanalyse in *R*

# Latente Variablen / Faktoren

- Latent : Nicht unmittelbar sichtbar
- Nicht beobachtbare Clustervariablen, die sich aus beobachtbaren Variablen zusammensetzen
- Identifizierbar mit Faktorenanalyse und Principal Component Analyse (PCA)
- Cluster hoch korrelierender Variablen

# Latente Variablen / Faktoren

- Latent : Nicht unmittelbar sichtbar
- Nicht beobachtbare Clustervariablen, die sich aus beobachtbaren Variablen zusammensetzen
- Identifizierbar mit Faktorenanalyse und Principal Component Analyse (PCA)
- Cluster hoch korrelierender Variablen

Beispiel Burnout (Selbst nicht messbar)

- Stresslevel (messbar)
- Motivationsbereitschaft (messbar)
- Kreativität (messbar)

# Latente Variablen / Faktoren

Korrelationsmatrix:

|               | ExoTalk | Sozialskill | Interesse | EgoTalk | Selbstsüchtig | LügnerIn |
|---------------|---------|-------------|-----------|---------|---------------|----------|
| ExoTalk       | 1       |             |           |         |               |          |
| Sozialskill   | .772    | 1           |           |         |               |          |
| Interesse     | .646    | .871        | 1         |         |               |          |
| EgoTalk       | .072    | -1.20       | .054      | 1       |               |          |
| Selbstsüchtig | -.131   | .031        | -.101     | .441    | 1             |          |
| LügnerIn      | .068    | 0.12        | .110      | .361    | .277          | 1        |

Exo-Talk → Sprechen über gegenüber

Ego-Talk → Sprechen über sich selbst

# Latente Variablen / Faktoren

Korrelationsmatrix:

|               | ExoTalk | Sozialskill | Interesse | EgoTalk | Selbstsüchtig | LügnerIn |
|---------------|---------|-------------|-----------|---------|---------------|----------|
| ExoTalk       | 1       |             |           |         |               |          |
| Sozialskill   | .772*   | 1           |           |         |               |          |
| Interesse     | .646*   | .871*       | 1         |         |               |          |
| EgoTalk       | .072    | -1.20       | .054      | 1       |               |          |
| Selbstsüchtig | -.131   | .031        | -.101     | .441*   | 1             |          |
| LügnerIn      | .068    | 0.12        | .110      | .361*   | .277*         | 1        |

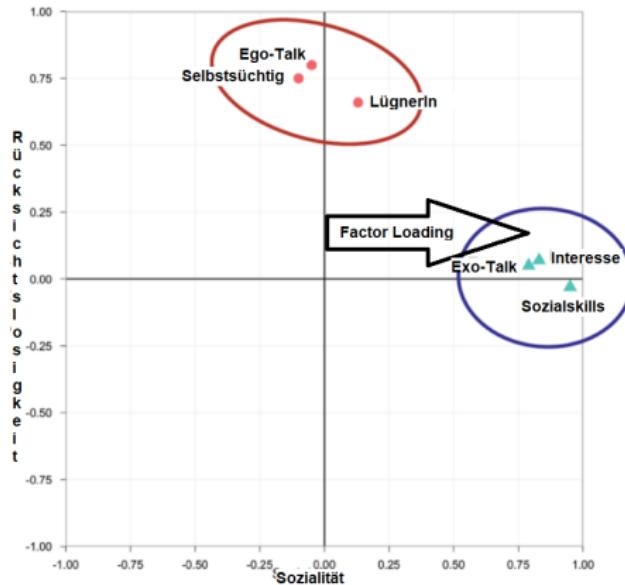
Exo-Talk → Sprechen über gegenüber

Ego-Talk → Sprechen über sich selbst

Identifizierbare Faktoren: 2 Cluster, die hoch intra- aber kaum interkorrelieren

- Sozialität:{Exo-Talk, Sozialskill, Interesse}
- Rücksichtslosigkeit:{Ego-Talk, Selbstsüchtig, LügnerIn} Lehrbuch:  
Consideration

# Latente Variablen / Faktoren



- Faktor Loading = (Pearson)Korrelation und/oder Regressionskoeffizienten zwischen einzelner Variable und Faktor, also bspw. von Variable Exo-Talk und Faktor Sozialität
- Unabhängige Faktoren → Korrelation = Regressionskoeffizienten

# Berechnung

Wir zeichnen wieder gerade Linien

# Berechnung

Wir zeichnen wieder gerade Linien

$Faktor_m = b_{1m}X_1 + b_{2m}X_2 + \dots + \epsilon$  mit  $b_{km}$  = Factor Loading von Variable  $k$  auf Faktor  $m$

# Berechnung

Wir zeichnen wieder gerade Linien

$Faktor_m = b_{1m}X_1 + b_{2m}X_2 + \dots + \epsilon$  mit  $b_{km}$  = Factor Loading von Variable  $k$  auf Faktor  $m$

- $Sozialität = b_{1Soz}ExoTalk + b_{2Soz}Sozialskill + b_{3Soz}Interesse + b_{4Soz}EgoTalk + b_{5Soz}Selbstsüchtig + b_{6Soz}LügnerIn + \epsilon$
- $Rücksichtslos = b_{1Ruck}ExoTalk + b_{2Ruck}Sozialskill + b_{3Ruck}Interesse + b_{4Ruck}EgoTalk + b_{5Ruck}Selbstsüchtig + b_{6Ruck}LügnerIn + \epsilon$

# Berechnung

Wir zeichnen wieder gerade Linien

$Faktor_m = b_{1m}X_1 + b_{2m}X_2 + \dots + \epsilon$  mit  $b_{km}$  = Factor Loading von Variable  $k$  auf Faktor  $m$

- Sozialität =  $b_{1Soz}ExoTalk + b_{2Soz}Sozialskill + b_{3Soz}Interesse + b_{4Soz}EgoTalk + b_{5Soz}Selbstsüchtig + b_{6Soz}LügnerIn + \epsilon$
- Rücksichtslos =  $b_{1Ruck}ExoTalk + b_{2Ruck}Sozialskill + b_{3Ruck}Interesse + b_{4Ruck}EgoTalk + b_{5Ruck}Selbstsüchtig + b_{6Ruck}LügnerIn + \epsilon$
- Sozialität =  $0.87ExoTalk + 0.96Sozialskill + 0.92Interesse + 0.00EgoTalk - 0.10Selbstsüchtig + 0.09LügnerIn + \epsilon$
- Rücksichtslos =  $0.01ExoTalk - 0.03Sozialskill + 0.04Interesse + 0.82EgoTalk + 0.75Selbstsüchtig + 0.70LügnerIn + \epsilon$

# Faktormatrix / Komponentenmatrix (PCA)

- $Sozialität = 0.87ExoTalk + 0.96Sozialskill + 0.92Interesse + 0.00EgoTalk - 0.10Selbstsüchtig + 0.09LügnerIn + \epsilon$
- $Rücksichtslos = 0.01ExoTalk - 0.03Sozialskill + 0.04Interesse + 0.82EgoTalk + 0.75Selbstsüchtig + 0.70LügnerIn + \epsilon$

Faktormatrix  $A = \begin{pmatrix} 0.87 & 0.01 \\ 0.96 & 0.03 \\ 0.92 & 0.04 \\ 0.00 & 0.82 \\ -0.10 & 0.75 \\ 0.09 & 0.70 \end{pmatrix}$

- Strukturmatrix verwendet Korrelationen Factor Structure Matrix
- Mustermatrix verwendet Regressionskoeffizienten Factor Pattern Matrix
- Bei Orthogonalen Faktoren austauschbar, aber sonst verschieden zu interpretieren

Graham, J.M. & Guthrie, A.C. & Thompson, B. (2003): *Consequences of not interpreting structurecoefficients in published CFA research: A reminder*

# Faktorscore der Probanden

- $Sozialität_{ute} = 0.87ExoTalk + 0.96Sozialskill + 0.92Interesse + 0.00EgoTalk - 0.10Selbstsüchtig + 0.09LügnerIn + \epsilon$
- $Rücksichtslos_{ute} = 0.01ExoTalk + -0.03Sozialskill + 0.04Interesse + 0.82EgoTalk + 0.75Selbstsüchtig + 0.70LügnerIn + \epsilon$

Triviale Lösung

→

# Faktorscore der Probanden

- $Sozialität_{ute} = 0.87ExoTalk + 0.96Sozialskill + 0.92Interesse + 0.00EgoTalk - 0.10Selbstsüchtig + 0.09LügnerIn + \epsilon$
- $Rücksichtslos_{ute} = 0.01ExoTalk + -0.03Sozialskill + 0.04Interesse + 0.82EgoTalk + 0.75Selbstsüchtig + 0.70LügnerIn + \epsilon$

Triviale Lösung

→ Einfach Messwerte für Person einsetzen

- $Sozialität_{ute} = 0.87 * 4 + 0.96 * 9 + 0.92 * 8 + 0.00 * 6 - 0.10 * 8 + 0.09 * 6 = 19.22$
- $Rücksichtslos_{ute} = 0.01 * 4 - 0.03 * 9 + 0.04 * 8 + 0.82 * 6 + 0.75 * 8 + 0.70 * 6 = 15.21$

# Faktorscore der Probanden

- $Sozialität_{ute} = 0.87ExoTalk + 0.96Sozialskill + 0.92Interesse + 0.00EgoTalk - 0.10Selbstsüchtig + 0.09LügnerIn + \epsilon$
- $Rücksichtslos_{ute} = 0.01ExoTalk + -0.03Sozialskill + 0.04Interesse + 0.82EgoTalk + 0.75Selbstsüchtig + 0.70LügnerIn + \epsilon$

Triviale Lösung

→ Einfach Messwerte für Person einsetzen

- $Sozialität_{ute} = 0.87 * 4 + 0.96 * 9 + 0.92 * 8 + 0.00 * 6 - 0.10 * 8 + 0.09 * 6 = 19.22$
- $Rücksichtslos_{ute} = 0.01 * 4 - 0.03 * 9 + 0.04 * 8 + 0.82 * 6 + 0.75 * 8 + 0.70 * 6 = 15.21$

**ACHTUNG:** Scores von Faktoren mit verschiedenen Skalen untereinander nicht vergleichbar 😞

## Faktorscore der Probanden

Scores von Faktoren mit verschiedenen Skalen untereinander nicht vergleichbar 😞

→

# Faktorscore der Probanden

Scores von Faktoren mit verschiedenen Skalen untereinander nicht vergleichbar 😞

→ Wir normalisieren die Faktormatrix  $A$  mit der ursprünglichen Korrelationsmatrix  $COR$

- $\frac{A}{COR} = A * COR^{-1}$  Siehe MANOVA Vorlesung

$$\begin{pmatrix} 0.87 & 0.01 \\ 0.96 & 0.03 \\ 0.92 & 0.04 \\ 0.00 & 0.82 \\ -0.10 & 0.75 \\ 0.09 & 0.70 \end{pmatrix} * \begin{pmatrix} 4.76 & -7.46 & 3.91 & -2.15 & 2.42 & -0.49 \\ -7.46 & 18.49 & -12.42 & 5.45 & -5.54 & 1.22 \\ 3.91 & -12.42 & 10.07 & -3.65 & 3.79 & -0.96 \\ -2.35 & 5.45 & -3.65 & 2.97 & -2.16 & 0.02 \\ 2.42 & -5.54 & 3.79 & -2.16 & 2.98 & -0.56 \\ -0.49 & 1.22 & -0.96 & 0.02 & -0.56 & 1.27 \end{pmatrix} =$$
$$\begin{pmatrix} 0.343 & 0.006 \\ 0.376 & -0.020 \\ 0.362 & 0.020 \\ 0.000 & 0.473 \\ -0.037 & 0.437 \\ 0.039 & 0.405 \end{pmatrix}$$

# Faktorscore der Probanden

Scores von Faktoren mit verschiedenen Skalen untereinander nicht vergleichbar 😞

→ Wir normalisieren die Faktormatrix  $A$  mit der ursprünglichen Korrelationsmatrix  $COR$

- $\frac{A}{COR} = A * COR^{-1}$  Siehe MANOVA Vorlesung

$$\begin{pmatrix} 0.87 & 0.01 \\ 0.96 & 0.03 \\ 0.92 & 0.04 \\ 0.00 & 0.82 \\ -0.10 & 0.75 \\ 0.09 & 0.70 \end{pmatrix} * \begin{pmatrix} 4.76 & -7.46 & 3.91 & -2.15 & 2.42 & -0.49 \\ -7.46 & 18.49 & -12.42 & 5.45 & -5.54 & 1.22 \\ 3.91 & -12.42 & 10.07 & -3.65 & 3.79 & -0.96 \\ -2.35 & 5.45 & -3.65 & 2.97 & -2.16 & 0.02 \\ 2.42 & -5.54 & 3.79 & -2.16 & 2.98 & -0.56 \\ -0.49 & 1.22 & -0.96 & 0.02 & -0.56 & 1.27 \end{pmatrix} =$$
  
$$\begin{pmatrix} 0.343 & 0.006 \\ 0.376 & -0.020 \\ 0.362 & 0.020 \\ 0.000 & 0.473 \\ -0.037 & 0.437 \\ 0.039 & 0.405 \end{pmatrix} \leftarrow \text{Adjustierte Faktoren / Faktorscore-Koeffizienten}$$

# Faktorscore der Probanden

$$\begin{pmatrix} 0.343 & 0.006 \\ 0.376 & -0.020 \\ 0.362 & 0.020 \\ 0.000 & 0.473 \\ -0.037 & 0.437 \\ 0.039 & 0.405 \end{pmatrix} \leftarrow \text{Adjustierte Faktoren / Faktorscore-Koeffizienten}$$

- $Sozialität_{ute} =$

$$0.343 * 4 + 0.376 * 9 + 0.362 * 8 + 0.00 * 6 - 0.037 * 8 + 0.039 * 6 = 7.59$$

- $Rücksichtslos_{ute} =$

$$0.006 * 4 - 0.020 * 9 + 0.020 * 8 + 0.473 * 6 + 0.437 * 8 + 0.405 * 6 = 8.768$$

# Faktorscore der Probanden

$$\begin{pmatrix} 0.343 & 0.006 \\ 0.376 & -0.020 \\ 0.362 & 0.020 \\ 0.000 & 0.473 \\ -0.037 & 0.437 \\ 0.039 & 0.405 \end{pmatrix} \leftarrow \text{Adjustierte Faktoren / Faktorscore-Koeffizienten}$$

- $Sozialität_{ute} =$

$$0.343 * 4 + 0.376 * 9 + 0.362 * 8 + 0.00 * 6 - 0.037 * 8 + 0.039 * 6 = 7.59$$

- $Rücksichtslos_{ute} =$

$$0.006 * 4 - 0.020 * 9 + 0.020 * 8 + 0.473 * 6 + 0.437 * 8 + 0.405 * 6 = 8.768$$

Interpretation: Ute erreicht etwa gleich hohe Werte bei Sozialität und Rücksichtslosigkeit

**ACHTUNG:** Die Scores eines Faktors können mit Variablen anderer Faktoren korrelieren

# Überblick

## 1 Latente Variablen / Faktoren

- Was?
- Berechnung
- Scoring

## 2 Faktoreidentifizierung

- Kommunalität
- Principal Component Analysis vs. Faktorenanalyse
- Faktorenanalyse
- Verlässlichkeitsanalyse

## 3 Anwendungsbeispiel

- Fragebögen
- Faktorenanalyse in *R*

# Methoden zur Faktoreidentifizierung

2 Szenarien:

- Datenexploration: Diese Vorlesung
- Hypothesentests: Tinsley, H.E.A. & Tinsley, D.J. (1987): *Uses of factor analysis in counseling psychology research*

hohe Kommunalität ist gut für Faktorenanalyse

- Geteilte Varianz: Varianz einer Variable, die sie mit anderen teilt
- Eigene Varianz: Varianz einer Variable, die sie mit niemandem teilt
- Kommunalität =  $\frac{\text{Geteilte Varianz}}{\text{Varianz Insgesamt}}$ 
  - Kommunalität == 1 → keine eigene Varianz
  - Kommunalität == 0 → keine geteilte Varianz

# Kommunalität

hohe Kommunalität ist gut für Faktorenanalyse

- Geteilte Varianz: Varianz einer Variable, die sie mit anderen teilt
- Eigene Varianz: Varianz einer Variable, die sie mit niemandem teilt
- Kommunalität =  $\frac{\text{Geteilte Varianz}}{\text{Varianz Insgesamt}}$ 
  - Kommunalität == 1 → keine eigene Varianz
  - Kommunalität == 0 → keine geteilte Varianz

2 Wege

- Kommunalität = 1 für jede Variable angenommen → Principal Component Analysis (PCA)
- Abschätzung der Kommunalität → Faktorenanalyse
  - je Variable Multiple Regression mit ihr als Outcome und allen anderen als Prädiktoren → Multiples  $R^2$  als Kommunalität
  - weitere (weniger häufige) Methoden existieren

# Principal Component Analysis vs. Faktorenanalyse

Genauere Abgrenzung:

- Duntemann, G.E. (1989): *Principal component analysis*
- Widaman, K.F. (2007): *Common factors versus components: Principles and principles: errors and misconceptions*

# Principal Component Analysis vs. Faktorenanalyse

## Genauere Abgrenzung:

- Duntemann, G.E. (1989): *Principal component analysis*
- Widaman, K.F. (2007): *Common factors versus components: Principles and principles: errors and misconceptions*
- wenig Unterschiede im Ergebnis bei mehr als 30 Variablen und Kommunalität > 0.7
- erwartbare Unterschiede im Ergebnis bei weniger als 20 Variablen und Kommunalität < 0.4

Stevens, J. P. (2002): *Applied multivariate statistics for the social sciences*

# Principal Component Analysis vs. Faktorenanalyse

## Genauere Abgrenzung:

- Duntemann, G.E. (1989): *Principal component analysis*
- Widaman, K.F. (2007): *Common factors versus components: Principles and principles: errors and misconceptions*
- wenig Unterschiede im Ergebnis bei mehr als 30 Variablen und Kommunalität > 0.7
- erwartbare Unterschiede im Ergebnis bei weniger als 20 Variablen und Kommunalität < 0.4

Stevens, J. P. (2002): *Applied multivariate statistics for the social sciences*

"component analysis is at best a common factor analysis and at worst an unrecognizable hodgepodge of things from which nothing can be determined" Cliff, N. (1987): *Analyzing multivariate data*

# Principal Component Analysis vs. Faktorenanalyse

## Genauere Abgrenzung:

- Duntemann, G.E. (1989): *Principal component analysis*
- Widaman, K.F. (2007): *Common factors versus components: Principles and principles: errors and misconceptions*
- wenig Unterschiede im Ergebnis bei mehr als 30 Variablen und Kommunalität > 0.7
- erwartbare Unterschiede im Ergebnis bei weniger als 20 Variablen und Kommunalität < 0.4

Stevens, J. P. (2002): *Applied multivariate statistics for the social sciences*

"component analysis is at best a common factor analysis and at worst an unrecognizable hodgepodge of things from which nothing can be determined" Cliff, N. (1987): *Analyzing multivariate data*

→ Unterschied laut Field vernachlässigbar, wir verwenden die Begriffe austauschbar

# Faktorenanalyse

Vorgehen ähnlich zu MANOVA, aber mit Korrelationsmatrix (und ohne Gruppen)

- Variaten der Korrelationsmatrix berechnen
- Anzahl der Variaten = Anzahl der Variablen
- Variaten == Komponenten
- Variate = Eigenvektoren der Matrix (lineare Funktion)
- Factor Loadings = (Eigen-)Werte der Eigenvektoren
  - Anmerkung zur Veranschaulichung: Eigenwerte analog zu Regressionskoeffizienten bei linearer Regression
- Höchster Eigenwert als Indikator des Einflusses der Variaten

- Höchster Eigenwert als Indikator des Einflusses der Variaten / Faktoren / Komponenten
- → Nicht alle Faktoren werden beachtet

## Auswahl der Faktoren

- Kaiser, H.F. (1960): *The application of electronic computers to factor analysis*  
Kaisers Kriterium → Alle mit Eigenwerten  $> 1$
- Jolliffe, I.T. (1986): *Principal component analysis*  
Jolliffes Kriterium → Alle mit Eigenwerten  $> 0.7$
- Visuell mit Scree Plot

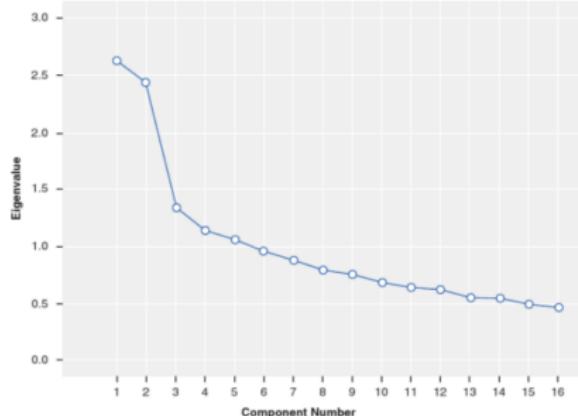
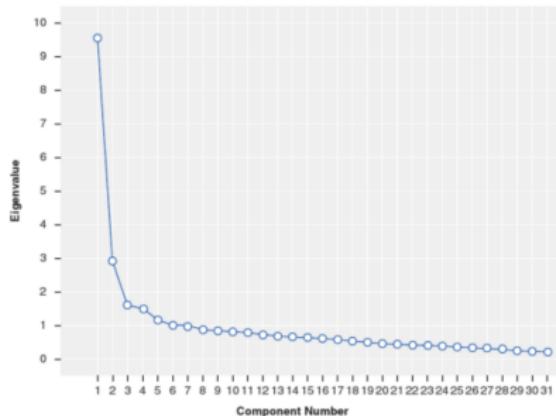
→ Kaiser möglicherweise zu großzügig, aber verlässlich bei  $n > 30$  und  
Kommunalität  $> 0.7$  oder  $n > 250$  und Kommunalität  $> 0.6$ ; Scree Plot  
verlässlich bei Stichprobengröße  $> 200$

Anwendungsbezogen (bspw. bei Reparatur von Multikollinearität lieber zu  
viele als zu wenige Faktoren)

# Scree Plot

Cattel, R.B. (1966b): *The scree test for the number of factors*

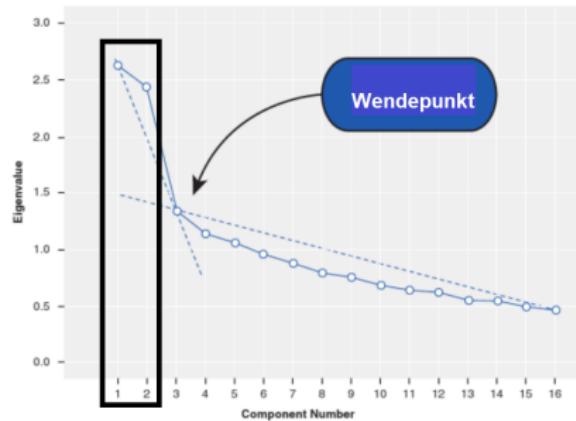
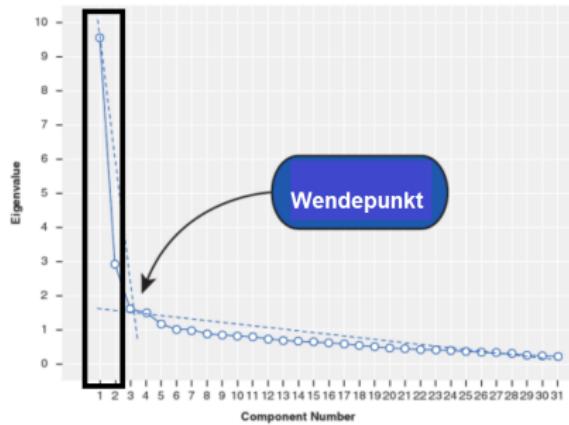
- Y = Eigenwerte
- X = Komponente / Variate / Faktor
- Abschätzung der Faktoren über Wendepunkt der Kurve



# Scree Plot

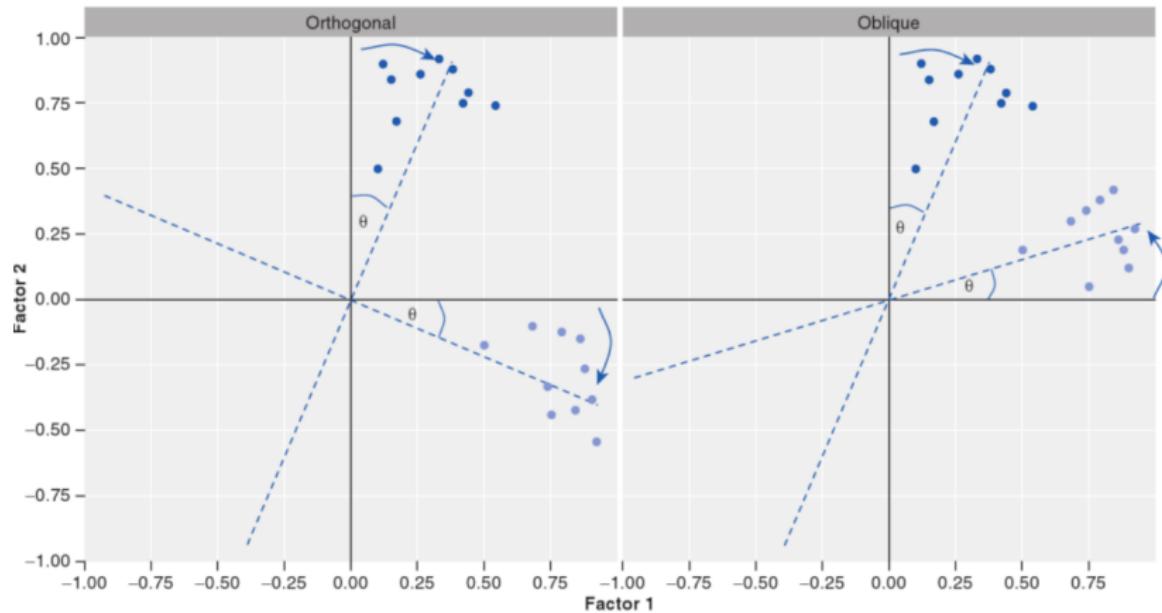
Cattel, R.B. (1966b): *The scree test for the number of factors*

- Y = Eigenwerte
- X = Komponente / Variate / Faktor
- Abschätzung der Faktoren über Wendepunkt der Kurve



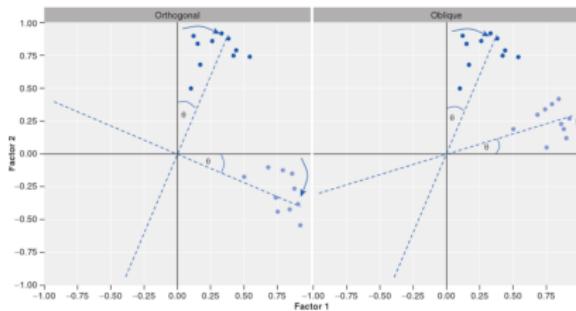
# Faktorrotation

Ziel: Verbesserung der Aussagekraft durch Maximierung der starken und Minimierung der schwachen Faktorloadings



# Faktorrotation

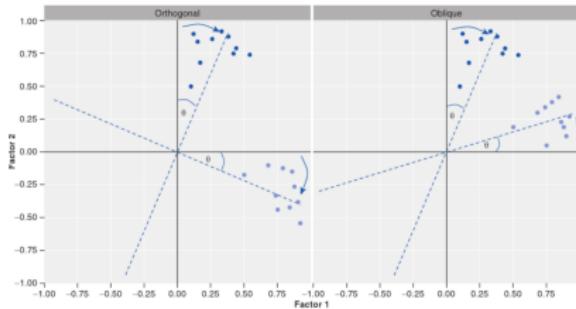
Ziel: Verbesserung der Aussagekraft durch Maximierung der starken und Minimierung der schwachen Faktorloadings



- Orthogonal: Faktoren korrelieren nicht und das wird beibehalten  
 $R \rightarrow \text{varimax}, \text{quartimax}(), \text{BentlerT}, \text{geominT}$ )
- Oblique: Korrelation zwischen Faktoren erlaubt / angenommen  
 $R \rightarrow \text{oblimin}, \text{promax}(), \text{simplimax}, \text{BentlerQ}, \text{geominQ}$ )

# Faktorrotation

Ziel: Verbesserung der Aussagekraft durch Maximierung der starken und Minimierung der schwachen Faktorloadings



- Orthogonal: Faktoren korrelieren nicht und das wird beibehalten  
 $R \rightarrow \text{varimax}, \text{quartimax}(), \text{BentlerT}, \text{geominT}$ )
- Oblique: Korrelation zwischen Faktoren erlaubt / angenommen  
 $R \rightarrow \text{oblimin}, \text{promax}(), \text{simplimax}, \text{BentlerQ}, \text{geominQ}$ )

Am besten beide beachten und mit deren Unterschieden argumentieren

# Faktorvariablen

Welche Variablen sollten zu einem Faktor zählen?

Theoretisch Signifikanztest möglich aber problematisch, deshalb typischerweise einfach Faktorloadings > 0.3

# Faktorvariablen

Welche Variablen sollten zu einem Faktor zählen?

Theoretisch Signifikanztest möglich aber problematisch, deshalb typischerweise einfach Faktorloadings > 0.3

$\alpha = 0.01$ , two tailed

- $n > 50 \rightarrow \text{Loading} > 0.722$
- $n > 100 \rightarrow \text{Loading} > 0.512$
- $n > 200 \rightarrow \text{Loading} > 0.364$
- $n > 300 \rightarrow \text{Loading} > 0.298$
- $n > 600 \rightarrow \text{Loading} > 0.210$
- $n > 1000 \rightarrow \text{Loading} > 0.162$
- weitere siehe Stevens, J. P. (2002): *Applied multivariate statistics for the social sciences*

# Faktorvariablen

Welche Variablen sollten zu einem Faktor zählen?

Korrelationen zwischen Variablen beachten

Zu gering

- $< 0.3$  (Willkürliche Grenze)
- Bartletts Test testet auf Unterschied zu Identitätsmatrix (== geringe Korrelation)
- Signifikant bedeutet Signifikante Korrelationen

Zu hoch

- $> 0.8$  (Willkürliche Grenze)
- Perfekte Korrelation = Singularität
- Multikorrelation vermeiden (egal bei PCA)
- Determinante der Korrelationsmatrix  $> 0.00001 \rightarrow$  Gut
- Berechnung:  
<https://mathworld.wolfram.com/Determinant.html>

# Verlässlichkeitsanalyse

Faktoren können als Messgerät für eine Eigenschaft verstanden werden

- Verlässlichkeit (analog zu Vorlesung 2)
  - Erzeugt der Faktor dieselben Scores bei gleichartigen Fällen?
  - Erzeugt das Messgerät dieselben Messwerte in denselben Situationen?
- Split-Half Verlässlichkeit
  - Teile Daten anhand der Variablen zufällig in 2 Teile
  - Scores für beide Hälften sollten ähnlich sein
  - Nachteil: Zufällige Aufteilung erzeugt Schwankung

# Verlässlichkeitsanalyse

Faktoren können als Messgerät für eine Eigenschaft verstanden werden

- Verlässlichkeit (analog zu Vorlesung 2)
  - Erzeugt der Faktor dieselben Scores bei gleichartigen Fällen?
  - Erzeugt das Messgerät dieselben Messwerte in denselben Situationen?
- Split-Half Verlässlichkeit
  - Teile Daten anhand der Variablen zufällig in 2 Teile
  - Scores für beide Hälften sollten ähnlich sein
  - Nachteil: Zufällige Aufteilung erzeugt Schwankung
- Cronbachs  $\alpha$

# Cronbachs $\alpha$

- Cronbachs  $\alpha \approx$  Konzeptionell Durchschnitt der Korrelationskoeffizienten aller möglichen Splits
- Berechnung siehe Cronbach (1951): *Coefficient alpha and the internal structure of tests*

# Cronbachs $\alpha$

- Cronbachs  $\alpha \approx$  Konzeptionell Durchschnitt der Korrelationskoeffizienten aller möglichen Splits
- Berechnung siehe Cronbach (1951): *Coefficient alpha and the internal structure of tests*

## Interpretation

- Negative Werte zeigen gespiegelte Variablen (besonders relevant bei Fragebögen)
- $> 0.8$  ist gut,  $> 0.7$  ist ok
- Steigt mit Anzahl der Variablen
- ... Die Experten sind sich uneinig 😕

# Überblick

## 1 Latente Variablen / Faktoren

- Was?
- Berechnung
- Scoring

## 2 Faktoreidentifizierung

- Kommunalität
- Principal Component Analysis vs. Faktorenanalyse
- Faktorenanalyse
- Verlässlichkeitsanalyse

## 3 Anwendungsbeispiel

- Fragebögen
- Faktorenanalyse in *R*

# Fragebögen

- Fragebögen als Anwendungsszenario
- Einzelne Fragen als Variablen
- Fragenbündel als Faktoren, die eine gewisse Eigenschaft messen
- Do's and Dont's der Fragebogenerstellung → Siehe Moodle

# Fragebögen und Stichprobengröße

- ... Die Experten sind sich uneinig 😕
- 300 ist gut, 1000 super
- Abhängig von Kommunalität
  - $> 0.6 \rightarrow 100$  ok
  - $> 0.5 \rightarrow 100$  bis 200 ok
  - $< 0.5 \rightarrow 500$
  - Kayser-Mayer-Olkin Maß
    - 0 (schlecht) ... 1 (gut)
    - $< 0.5 \rightarrow$  Faktorenanalyse ungeeignet
    - $0.5 \dots 0.7 \rightarrow$  Mittelmäßig
    - $0.7 \dots 0.8 \rightarrow$  gut
    - $0.8 \dots 0.9 \rightarrow$  sehr gut
    - $> 0.9 \rightarrow$  Superb

# Beispiel R Anxiety Questionnaire

SD = Strongly Disagree, D = Disagree, N = Neither, A = Agree, SA = Strongly Agree

|   | SD                    | D                     | N                     | A                     | SA                    |
|---|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|
| 1 Statistics make me cry  | <input type="radio"/> |
| 2 My friends will think I'm stupid for not being able to cope with R                      | <input type="radio"/> |
| 3 Standard deviations excite me   | <input type="radio"/> |
| 4 I dream that Pearson is attacking me with correlation coefficients                      | <input type="radio"/> |
| 5 I don't understand statistics   | <input type="radio"/> |
| 6 I have little experience of computers   | <input type="radio"/> |
| 7 All computers hate me   | <input type="radio"/> |
| 8 I have never been good at mathematics   | <input type="radio"/> |
| 9 My friends are better at statistics than me   | <input type="radio"/> |
| 10 Computers are useful only for playing games  | <input type="radio"/> |
| 11 I did badly at mathematics at school   | <input type="radio"/> |
| 12 People try to tell you that R makes statistics easier to understand but it doesn't     | <input type="radio"/> |
| 13 I worry that I will cause irreparable damage because of my incompetence with computers | <input type="radio"/> |
| 14 Computers have minds of their own and deliberately go wrong whenever I use them        | <input type="radio"/> |
| 15 Computers are out to get me  | <input type="radio"/> |
| 16 I weep openly at the mention of central tendency                                       | <input type="radio"/> |
| 17 I slip into a coma whenever I see an equation  | <input type="radio"/> |
| 18 R always crashes when I try to use it  | <input type="radio"/> |
| 19 Everybody looks at me when I use R   | <input type="radio"/> |
| 20 I can't sleep for thoughts of eigenvectors   | <input type="radio"/> |
| 21 I wake up under my duvet thinking that I am trapped under a normal distribution        | <input type="radio"/> |
| 22 My friends are better at R than I am   | <input type="radio"/> |
| 23 If I am good at statistics people will think I am a nerd                               | <input type="radio"/> |

# Faktorenanalyse in R

Daten:

- 23 Fragen mit 5 Punkte Likert Skala
- 2571 Antworten (also offensichtlich fiktive Daten)

| Q01 | Q02 | ... | Q22 | Q23 |
|-----|-----|-----|-----|-----|
| 4   | 5   | ... | 2   | 4   |

Siehe rq.dat im Moodle

```
library(corrplot)
library(GPArotation)
library(psych)

raqData<-read.delim("raq.dat", header = TRUE)
raqMatrix<-cor(raqData)    # Korrelationsmatrix
round(raqMatrix, 2)
```

# Faktorenanalyse in R

## Korrelationsmatrix

|     | Q01   | Q02   | Q03   | Q04   | Q05   | Q06   | Q07   | ... |
|-----|-------|-------|-------|-------|-------|-------|-------|-----|
| Q01 | 1.00  | -0.10 | -0.34 | 0.44  | 0.40  | 0.22  | 0.31  | ... |
| Q02 | -0.10 | 1.00  | 0.32  | -0.11 | -0.12 | -0.07 | -0.16 | ... |
| Q03 | -0.34 | 0.32  | 1.00  | -0.38 | -0.31 | -0.23 | -0.38 | ... |
| ... | ...   | ...   | ...   | ...   | ...   | ...   | ...   | ... |
| Q21 | 0.33  | -0.20 | -0.42 | 0.41  | 0.33  | 0.27  | 0.48  | ... |
| Q22 | -0.10 | 0.23  | 0.20  | -0.10 | -0.13 | -0.17 | -0.17 | ... |
| Q23 | 0.00  | 0.10  | 0.15  | -0.03 | -0.04 | -0.07 | -0.07 | ... |

# Faktorenanalyse in R

## Korrelationsmatrix

|     | Q01   | Q02   | Q03   | Q04   | Q05   | Q06   | Q07   | ... |
|-----|-------|-------|-------|-------|-------|-------|-------|-----|
| Q01 | 1.00  | -0.10 | -0.34 | 0.44  | 0.40  | 0.22  | 0.31  | ... |
| Q02 | -0.10 | 1.00  | 0.32  | -0.11 | -0.12 | -0.07 | -0.16 | ... |
| Q03 | -0.34 | 0.32  | 1.00  | -0.38 | -0.31 | -0.23 | -0.38 | ... |
| ... | ...   | ...   | ...   | ...   | ...   | ...   | ...   | ... |
| Q21 | 0.33  | -0.20 | -0.42 | 0.41  | 0.33  | 0.27  | 0.48  | ... |
| Q22 | -0.10 | 0.23  | 0.20  | -0.10 | -0.13 | -0.17 | -0.17 | ... |
| Q23 | 0.00  | 0.10  | 0.15  | -0.03 | -0.04 | -0.07 | -0.07 | ... |

Fehlermeldung *NaN's produced* → non positive definite matrix.

- Sackgasse, Daten sind schlecht 😞
- Singularität in den Daten, zu wenig Antworten, ...
- Eventuell Variablen reduzieren oder mehr Antworten sammeln

# Faktorenanalyse in R

## Bartletts Test

```
cortest.bartlett(raqData) # Von Daten  
cortest.bartlett(raqMatrix, n = 2571) # Von Kor.Matrix  
  
$chisq  
[1] 19334.49  
$p.value  
[1] 0      #<-- Wahrscheinlichkeit < 0.01 -> PCA angemessen  
$df       #Korrelationen sind hoch genug  
[1] 253
```

# Faktorenanalyse in R

## Kayser-Mayer-Olkin Test

- Nicht in R enthalten
- Function by G. Jay Kerns <http://tolstoy.newcastle.edu.au/R/e2/help/07/08/22816.html>

```
kmo(raqData)

$overall
[1] 0.9302245
$report
[1] "The KMO test yields a degree of common variance marvelous.

$individual
      Q01       Q02       Q03     ...
0.9297610 0.8747754 0.9510378     ..."
```

- Entfernung von Variablen mit Individuellen  $KMO < 0.5$  sinnvoll
- Wiederholung nach Entfernung

# Faktorenanalyse in R

## Determinante

```
det(raqMatrix)
```

```
[1] 0.0005271037 # > 0.00001, also gut
```

# Faktorenanalyse

Faktorenanalyse (unrotiert, Jede Variable ist ein Faktor)

```
pc1 <- principal(raqData, nfactors = length(raqData), rotate = "none")
pc1

Call: principal(r = raqData, nfactors = length(raqData), rotate = "none")
Standardized loadings (pattern matrix) based upon correlation matrix
    PC1    PC2    PC3    PC4    PC5    PC6    ...
Q01  0.59  0.18 -0.22  0.12 -0.40 -0.11  ...
Q02 -0.30  0.55  0.15  0.01 -0.03 -0.38  ...
...
PC21   PC22   PC23 h2      u2 com
Q01 -0.21  0.05  0.01  1 -1.1e-15 6.0
Q02 -0.02  0.03  0.02  1 -3.8e-15 6.1
# h2 = Kommunalitäten (alle 1 weil jede Variable ein Faktor ist)
# u2 = Uniqueness = 1 - Kommunalität
```

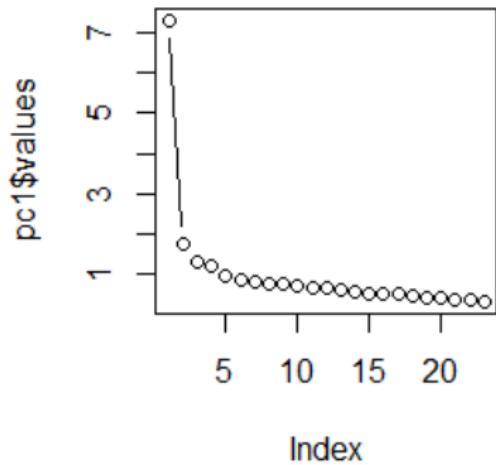
|                | PC1  | PC2  | ... |
|----------------|------|------|-----|
| SS loadings    | 7.29 | 1.74 | ... |
| Proportion Var | 0.32 | 0.08 | ... |
| Cumulative Var | 0.32 | 0.39 | ... |

# Varianz erklärt durch Faktor  
# Anteilig (7.29 / 23)

# Faktorenanalyse in R

## Scree Plot

```
plot(pc1$values, type = "b")
```



Interpretation schwierig, aber 4 Faktoren scheinen sinnvoll

# Faktorenanalyse in R

## Faktorenanalyse (unrotiert, 4 Faktoren)

```
pc2 <- principal(raqData, nfactors = 4, rotate = "none")
pc2
```

```
Call: principal(r = raqData, nfactors = 4, rotate = "none")
Standardized loadings (pattern matrix) based upon correlation matrix
      PC1    PC2    PC3    PC4    h2    u2 com
Q01  0.59  0.18 -0.22  0.12  0.43  0.57  1.6
Q02 -0.30  0.55  0.15  0.01  0.41  0.59  1.7
...
          PC1    PC2    PC3    PC4
SS loadings   7.29  1.74  1.32  1.23
Proportion Var 0.32  0.08  0.06  0.05
Cumulative Var 0.32  0.39  0.45  0.50
```

Abgesehen von den Kommunalitäten und der Faktoranzahl hat sich nichts geändert

# Faktorenanalyse in R

## Faktorenanalyse (Rotiert, 4 Faktoren)

```
pc3 <- principal(raqData, nfactors = 4, rotate = "varimax")
print.psych(pc3, cut = 0.3, sort = FALSE) # Filter und Sortieren nach Loading
```

Standardized loadings (pattern matrix) based upon correlation matrix

|                | item | RC3  | RC1  | RC4  | RC2  | h2   | u2   | com  |
|----------------|------|------|------|------|------|------|------|------|
| Q06            | 6    | 0.80 |      |      |      | 0.65 | 0.35 | 1.0  |
| Q18            | 18   | 0.68 | 0.33 |      |      | 0.60 | 0.40 | 1.5  |
| ...            |      |      |      |      |      |      |      |      |
| Q20            | 20   |      | 0.68 |      |      | 0.48 | 0.52 | 1.1  |
| Q21            | 21   |      | 0.66 |      |      | 0.55 | 0.45 | 1.5  |
| ...            |      |      |      |      |      |      |      |      |
| Q11            | 11   |      |      | 0.75 |      | 0.69 | 0.31 | 1.5  |
| Q09            | 9    |      |      |      | 0.65 | 0.48 | 0.52 | 1.3  |
| ...            |      |      |      |      |      |      |      |      |
|                |      |      |      |      | RC3  | RC1  | RC4  | RC2  |
| SS loadings    |      |      |      |      | 3.73 | 3.34 | 2.55 | 1.95 |
| Proportion Var |      |      |      |      | 0.16 | 0.15 | 0.11 | 0.08 |
| Cumulative Var |      |      |      |      | 0.16 | 0.31 | 0.42 | 0.50 |

Kommunalitäten haben sich nicht geändert, aber Loadings sind eindeutiger

- RC\* sind die Faktoren

# Identifizierte Faktoren

SD = Strongly Disagree, D = Disagree, N = Neither, A = Agree, SA = Strongly Agree

|   | SD | D | N | A | SA |
|---|----|---|---|---|----|
| 1 Statistics make me cry  | ○  | ○ | ○ | ○ | ○  |
| 2 My friends will think I'm stupid for not being able to cope with R                      | ○  | ○ | ○ | ○ | ○  |
| 3 Standard deviations excite me   | ○  | ○ | ○ | ○ | ○  |
| 4 I dream that Pearson is attacking me with correlation coefficients                      | ○  | ○ | ○ | ○ | ○  |
| 5 I don't understand statistics   | ○  | ○ | ○ | ○ | ○  |
| 6 I have little experience of computers   | ○  | ○ | ○ | ○ | ○  |
| 7 All computers hate me   | ○  | ○ | ○ | ○ | ○  |
| 8 I have never been good at mathematics   | ○  | ○ | ○ | ○ | ○  |
| 9 My friends are better at statistics than me   | ○  | ○ | ○ | ○ | ○  |
| 10 Computers are useful only for playing games  | ○  | ○ | ○ | ○ | ○  |
| 11 I did badly at mathematics at school   | ○  | ○ | ○ | ○ | ○  |
| 12 People try to tell you that R makes statistics easier to understand but it doesn't     | ○  | ○ | ○ | ○ | ○  |
| 13 I worry that I will cause irreparable damage because of my incompetence with computers | ○  | ○ | ○ | ○ | ○  |
| 14 Computers have minds of their own and deliberately go wrong whenever I use them        | ○  | ○ | ○ | ○ | ○  |
| 15 Computers are out to get me  | ○  | ○ | ○ | ○ | ○  |
| 16 I weep openly at the mention of central tendency                                       | ○  | ○ | ○ | ○ | ○  |
| 17 I slip into a coma whenever I see an equation  | ○  | ○ | ○ | ○ | ○  |
| 18 R always crashes when I try to use it  | ○  | ○ | ○ | ○ | ○  |
| 19 Everybody looks at me when I use R   | ○  | ○ | ○ | ○ | ○  |
| 20 I can't sleep for thoughts of eigenvectors   | ○  | ○ | ○ | ○ | ○  |
| 21 I wake up under my duvet thinking that I am trapped under a normal distribution        | ○  | ○ | ○ | ○ | ○  |
| 22 My friends are better at R than I am   | ○  | ○ | ○ | ○ | ○  |
| 23 If I am good at statistics people will think I am a nerd                               | ○  | ○ | ○ | ○ | ○  |

- Faktor 1: Q6, Q18, Q13, Q7, Q14, Q10, Q15 *Angst vor Computern*
- Faktor 2: Q20, Q21, Q3, Q12, Q4, Q16, Q1, Q5 *Angst vor Statistik*
- Faktor 3: Q8, Q17, Q11 *Angst vor Mathematik*
- Faktor 4: Q9, Q22, Q2, Q19 *Angst vor bösem Feedback*

# Faktorenanalyse in R

## Faktorscores

```
pc5 <- principal(raqData, nfactors = 4, rotate = "oblimin", scores = TRUE)
pc5$scores
head(pc5$scores, 10) # Nur die ersten 10 anzeigen
```

|       | TC1         | TC4        | TC3         | TC2        |
|-------|-------------|------------|-------------|------------|
| [1,]  | 0.37296709  | 1.8808424  | 0.95979596  | 0.3910711  |
| [2,]  | 0.63334164  | 0.2374679  | 0.29090777  | -0.3504080 |
| [3,]  | 0.39712768  | -0.1056263 | -0.09333769 | 0.9249353  |
| [4,]  | -0.78741595 | 0.2956628  | -0.77703307 | 0.2605666  |
| [5,]  | 0.04425942  | 0.6815179  | 0.59786611  | -0.6912687 |
| [6,]  | -1.70018648 | 0.2091685  | 0.02784164  | 0.6653081  |
| [7,]  | 0.66139239  | 0.4224096  | 1.52552021  | -0.9805434 |
| [8,]  | 0.59491329  | 0.4060248  | 1.06465956  | -1.0932598 |
| [9,]  | -2.34971189 | -3.6134797 | -1.42999472 | -0.5443773 |
| [10,] | 0.93504597  | 0.2285419  | 0.96735727  | -1.5712753 |

Beachte die geänderte Rotation

Score von jedem Proband auf jeden Faktor

- RC\* sind die Faktoren
- Variablen, die nur auf 1 Faktor laden, sind sichere Kandidaten

# DH - Beispiele

<https://handbuch.tib.eu/w/DH-Handbuch/Tools>

- Strukturen erkennen im hochdimensionalen Raum: Die Principal Component Analysis
- Stilometrie

Luhmann, J. & Burghardt, M. & Tiepmar, J. (2020): *Subrosa: Determining Movie Similarities based on Subtitles (currently in review)*

- Nicht explizit PCA oder Faktorenanalyse, aber ähnliches "Mindset"
- Vergleich verschiedener Arten von Vektoren auf Basis von Filmuntertiteln

# Zusammenfassung

- Latente Variablen / Faktoren sind hochkorrelierende Variablencluster
  - Korrelation zwischen 0.3 und 0.8
  - Bartletts Test und Kayser-Mayer-Olkin Maß
- Faktorloading = Einfluss von Variable auf Faktor
- Kommunalität =  $\frac{\text{Geteilte Varianz}}{\text{Varianz Insgesamt}}$
- Screeplot zeigt empfehlenswerte Faktorenanzahl
- Rotation optimiert Loadings
- Faktorscores pro Proband berechenbar
- Flexibles Werkzeug mit hohem Willkürfaktor

"It's a good job I'll never have to do that again" *Jochen Tiepmar*