

Statistik für Digital Humanities

Explorative Faktoranalyse

Dr. Jochen Tiepmar

Institut für Informatik
Computational Humanities
Universität Leipzig

03. August 2020

[Letzte Aktualisierung: 20/08/2020, 20:22]

Latente Variablen / Faktoren

- Latent : Nicht unmittelbar sichtbar
- Nicht beobachtbare Clustervariablen, die sich aus beobachtbaren Variablen zusammensetzen
- Identifizierbar mit Faktoranalyse 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

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

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

- $Sozialitat = b_{1Soz}ExoTalk + b_{2Soz}Sozialskill + b_{3Soz}Interesse + b_{4Soz}EgoTalk + b_{5Soz}Selbstsuchtig + b_{6Soz}LugnerIn + \epsilon$
- $Rucksichtslos = b_{1Ruck}ExoTalk + b_{2Ruck}Sozialskill + b_{3Ruck}Interesse + b_{4Ruck}EgoTalk + b_{5Ruck}Selbstsuchtig + b_{6Ruck}LugnerIn + \epsilon$
- $Sozialitat = 0.87ExoTalk + 0.96Sozialskill + 0.92Interesse + 0.00EgoTalk - 0.10Selbstsuchtig + 0.09LugnerIn + \epsilon$
- $Rucksichtslos = 0.01ExoTalk - 0.03Sozialskill + 0.04Interesse + 0.82EgoTalk + 0.75Selbstsuchtig + 0.70LugnerIn + \epsilon$

Faktormatrix / Komponentenmatrix (PCA)

- $\text{Sozialitat} = 0.87\text{ExoTalk} + 0.96\text{Sozialskill} + 0.92\text{Interesse} + 0.00\text{EgoTalk} - 0.10\text{Selbstsuchtig} + 0.09\text{LugnerIn} + \epsilon$
- $\text{Rucksichtslos} = 0.01\text{ExoTalk} - 0.03\text{Sozialskill} + 0.04\text{Interesse} + 0.82\text{EgoTalk} + 0.75\text{Selbstsuchtig} + 0.70\text{LugnerIn} + \epsilon$

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

- 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 structure coefficients in published CFA research: A reminder*

Faktorscore der Probanden

- $Sozialit\ddot{a}t_{ute} = 0.87ExoTalk + 0.96Sozialskill + 0.92Interesse + 0.00EgoTalk - 0.10Selbsts\ddot{u}chtig + 0.09L\ddot{u}gnerIn + \epsilon$
- $R\ddot{u}cksichtslos_{ute} = 0.01ExoTalk + -0.03Sozialskill + 0.04Interesse + 0.82EgoTalk + 0.75Selbsts\ddot{u}chtig + 0.70L\ddot{u}gnerIn + \epsilon$

Triviale Lösung

→ Einfach Messwerte für Person einsetzen

- $Sozialit\ddot{a}t_{ute} = 0.87 * 4 + 0.96 * 9 + 0.92 * 8 + 0.00 * 6 - 0.10 * 8 + 0.09 * 6 = 19.22$
- $R\ddot{u}cksichtslos_{ute} = 0.01 * 4 - 0.03 * 9 + 0.04 * 8 + 0.82 * 6 + 0.75 * 8 + 0.70 * 6 = 15.21$

ACHTUNG: Scores von Faktoren mit verschiedenen Skalen untereinander nicht vergleichbar

Faktorscore der Probanden

Scores von Faktoren mit verschiedenen Skalen untereinander nicht vergleichbar

→ 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

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

$$- \text{Sozialität}_{ute} = 0.343 * 4 + 0.376 * 9 + 0.362 * 8 + 0.00 * 6 - 0.037 * 8 + 0.039 * 6 = 7.59$$

$$- \text{Rücksichtslos}_{ute} = 0.006 * 4 - 0.020 * 9 + 0.020 * 8 + 0.473 * 6 + 0.437 * 8 + 0.405 * 6 = 8.768$$

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

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

Methoden zur Faktorenidentifizierung

2 Szenarien:

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

Kommunalität

hohe Kommunalität ist gut für Faktoranalyse

- 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 → Faktoranalyse
 - 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. Faktoranalyse

Genauere Abgrenzung:

- Duntemann, G.E. (1989): *Principal component analysis*
- Widaman, K.F. (2007): *Common factors versus components: Principals 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

Faktoranalyse

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

Faktorextraktion

- 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

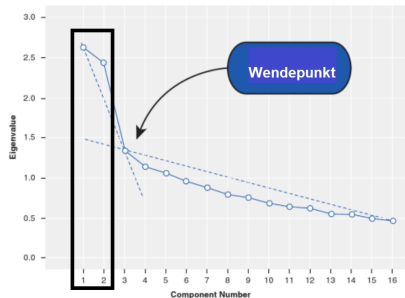

→ Kaiser möglicherweise zu großzügig, aber verlässlich bei $n > 30$ und Kommunalität > 0.7 oder $n > 250$ und Kommunalität > 0.6 ; Scree Plot verlässlich bei Stichprobengröße > 200

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

Scree Plot


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

- λ = 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
 $R \rightarrow \text{oblimin}, \text{promax}(), \text{simplimax}, \text{BentlerQ}, \text{geominQ}$

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

$\alpha = 0.01$, *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
- Cronbachs α

Cronbachs α

- 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

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 → 100 ok
 - > 0.5 → 100 bis 200 ok
 - < 0.5 → 500
 - Kayser-Mayer-Olkin Maß
 - 0 (schlecht) ... 1 (gut)
 - < 0.5 → Faktoranalyse ungeeignet
 - 0.5 ... 0.7 → Mittelmäßig
 - 0.7 ... 0.8 → gut
 - 0.8 ... 0.9 → sehr gut
 - > 0.9 → 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"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
2	My friends will think I'm stupid for not being able to cope with R	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
3	Standard deviations excite me	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
4	I dream that Pearson is attacking me with correlation coefficients	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
5	I don't understand statistics	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
6	I have little experience of computers	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
7	All computers hate me	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
8	I have never been good at mathematics	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
9	My friends are better at statistics than me	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
10	Computers are useful only for playing games	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
11	I did badly at mathematics at school	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
12	People try to tell you that R makes statistics easier to understand but it doesn't	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
13	I worry that I will cause irreparable damage because of my incompetence with computers	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
14	Computers have minds of their own and deliberately go wrong whenever I use them	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
15	Computers are out to get me	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
16	I weep openly at the mention of central tendency	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
17	I slip into a coma whenever I see an equation	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
18	R always crashes when I try to use it	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
19	Everybody looks at me when I use R	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
20	I can't sleep for thoughts of eigenvectors	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
21	I wake up under my duvet thinking that I am trapped under a normal distribution	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
22	My friends are better at R than I am	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
23	If I am good at statistics people will think I am a nerd	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Faktoranalyse 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 raq.dat im Moodle

```
library(corpcor)
library(GPArotation)
library(psych)
```

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

Faktoranalyse 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 *NaNs produced* → non positive definite matrix.

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

Faktoranalyse in R

Bartlett's 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
```

Faktoranalyse 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

Faktoranalyse in *R*

Determinante

```
det(raqMatrix)
```

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

Faktoranalyse

Faktoranalyse (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 ... # Varianz erklärt durch Faktor
Proportion Var   0.32 0.08 ... # Anteilig (7.29 / 23)
Cumulative Var   0.32 0.39 ...
```

Faktoranalyse in R

Scree Plot

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



Interpretation schwierig, aber 4 Faktoren scheinen sinnvoll

Faktoranalyse in R

Faktoranalyse (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

Faktoranalyse in R

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

– 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*

Faktoranalyse 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 Faktoranalyse, 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
 - Bartlett's Test und Kaiser-Meyer-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