

Georg Hosoya

Einführung in die Analyse testtheoretischer Modelle mit \mathbb{R}

Eine praxisorientierte Ergänzung zu dem Buch

Testtheorie und Testkonstruktion von Michael Eid und Katharina Schmidt

Inhaltsverzeichnis

1	Vorbemerkungen	4
1.1	Verwendete Pakete und deren Installation	4
1.2	Wechseln des Arbeitsverzeichnisses	5
2	Beispielsyntax für Kapitel 4: Eindimensionale Modelle für dichotome Antwortvariablen	5
2.1	Überblick Gesamtsyntax	6
2.2	Daten einlesen und deskriptive Statistiken	8
2.3	Berechnung der Gamma-Koeffizienten bzw. Yules Q	8
2.4	Analysen mit den dichotomen Rasch-Modell	9
2.4.1	Laden des Paketes <code>eRm</code>	9
2.4.2	Selektion und Konvertierung der Daten	9
2.4.3	Bedingte Maximum-Likelihood-Schätzung	9
2.4.4	Maximum-Likelihood-Schätzung der Personenparameter	11
2.4.5	Der bedingte Likelihood-Quotienten-Test nach Andersen	12
2.4.6	Grafischer Modelltest	13
2.4.7	Person-Item-Karte	13
2.4.8	Darstellung der Itemcharakteristikfunktionen	14
2.4.9	Wald-Test zur Überprüfung der Gleichheit der Itemschwierigkeiten in Subgruppen... ..	14
2.4.10	Martin-Löf-Test	14
2.4.11	Residualstatistiken: Itemfit	15
2.4.12	Residualstatistiken: Personenfit	15
2.5	Analysen mit dem zweiparametrischen logistischen Modell (Birnbaum-Modell) für dichotome Antwortvariablen	16
2.5.1	Vergleich des 2PL-Modells mit dem Rasch-Modell	18
2.5.2	Die Analyse des dreiparametrischen Modells (3PL-Modell)	19
2.5.3	Die Ausgabe der Itemcharakteristikkurven	20
2.5.4	Die Schätzung der Personenwerte	20
2.6	Mischverteilungs-Rasch-Modelle	20

3	Beispielsyntax für Kapitel 5: Eindimensionale Modelle für Antwortvariablen mit geordneten Antwortkategorien.....	21
3.1	Überblick Gesamtsyntax	21
3.2	Deskriptive Statistiken und Gamma-Koeffizient	23
3.3	Berechnung des relativen Informationsgehalts.....	24
3.4	Das Partial-Credit-Modell	24
3.5	Analysen mit dem generalisierten Partial-Credit-Modell.....	25
3.6	Analyse der Items 1, 3 und 4	27
4	Beispielsyntax für Kapitel 6: Eindimensionale Modelle für metrische Antwortvariablen.....	29
4.1	Überblick Gesamtsyntax	29
4.2	Das Einlesen der Daten und die Berechnung einiger deskriptiver Statistiken	31
4.3	Mardia's Test auf multivariate Normalverteilung.....	33
4.4	Das Modell essenziell τ -äquivalenter Variablen.....	33
	Multigruppenanalyse	37
4.5	Das Modell τ -äquivalenter Variablen	39
	Weitere Anmerkungen.....	41
4.6	Das Modell essenziell τ -paralleler Messung.....	41
4.7	Das Modell τ -paralleler Variablen	44
4.8	Das Modell τ -kongenerischer Variablen.....	46
4.9	Modellvergleiche mittels Likelihood-Quotienten-Tests.....	47
4.10	Schätzung der Personenwerte.....	48
5	Beispielsyntax für Kapitel 7: Einführung in mehrdimensionale Testmodelle.....	49
5.1	Überblick Gesamtsyntax	49
5.2	Zweidimensionales Modell zur Analyse der emotionalen Klarheit	50
5.3	Multikomponentenmodell	53
5.4	Exploratorische Faktorenanalyse für kategoriale Daten.....	56
7	Literatur.....	58

1 Vorbemerkungen

Die Reihenfolge der Syntax orientiert sich an der Ordnung der Präsentation der Beispiele im Buch. Zunächst wird die gesamte kommentierte Syntax des jeweiligen Kapitels zum Überblick dargestellt. Daraufhin werden die einzelnen Befehle sowie deren Ausgaben kurz erläutert.

Die hier gegebenen kurzen Erläuterungen können keine detaillierte Auseinandersetzung mit R, den verwendeten Paketen und den mathematischen Grundlagen der Modelle ersetzen und dienen lediglich als eine Einstiegshilfe in die Materie der psychometrischen Analyse mit R.

1.1 Verwendete Pakete und deren Installation

Es wurden hauptsächlich die Pakete `eRm`, `ltm`, `lavaan`, `psych` und `psychomix` für folgende Modelle verwendet:

`eRm` (Mair & Hatzinger, 2007):

- Das dichotome Rasch-Modell
- Das Partial-Credit-Modell

`ltm` (Rizopoulos, 2006):

- Das einparametrische logistische Modell (1PL, Rasch-Modell)
- Das zweiparametrische logistische Modell (2PL, Birnbaum-Modell)
- Das dreiparametrische logistische Modell (3PL, Birnbaum-Modell mit Rateparametern)
- Das generalisierte Partial-Credit-Modell

`lavaan` (Rosseel, 2012):

- Das Modell essenziell τ -äquivalenter Messung
- Das Modell τ -äquivalenter Messung
- Das Modell essenziell τ -paralleler Messung
- Das Modell τ -paralleler Messung
- Das Modell τ -kongenerischer Messung
- Mehrdimensionales Modell für kontinuierliche Variablen
- Mehrkomponentenmodell (Latent-State-Trait-Modell)

`psych` (Revelle, 2013):

- Faktorenanalyse für kategoriale Variablen

`psychomix` (Frick et al., 2012):

- Mischverteilungs-Rasch-Modell

Um die Pakete zu nutzen, müssen diese zunächst einmal auf dem Rechner installiert werden. Der entsprechende Befehl ist z.B. für das Paket `eRm`:

```
> install.packages("eRm")
```

Hierzu ist eine Internetanbindung nötig. Das R-Skript `install.R` enthält den Code zur Installation aller benötigten Pakete. Dieses Skript sollte auf einem Rechner einmal ausgeführt werden, bevor die anderen Skripte genutzt werden können. Für eine einsteigsorientierte Einführung in R sei z.B. das Buch von Luhmann (2013) empfohlen.

1.2 Wechseln des Arbeitsverzeichnisses

Um die Skripte auszuführen, wechseln Sie in R bitte in das Verzeichnis, in dem die Daten liegen.

Die entsprechenden Befehle sind z.B.:

```
> setwd("C:/Pfad_zu_den_Daten") (für Windows)
```

oder

```
> setwd("/Pfad_zu_den_Daten") (für UNIX/Linux/Mac).
```

2 Beispielsyntax für Kapitel 4: Eindimensionale Modelle für dichotome Antwortvariablen

Für Analysen mit dem Rasch-Modell eignet sich das R-Paket `eRm`. Die Parameter des zweiparametrischen logistischen Modells und des dreiparametrischen logistischen Modells können mit dem Paket `ltm` geschätzt werden.

2.1 Überblick Gesamtsyntax

```
#### Syntax Kapitel 4 ####
# Benötigt für spss.system.file()
library("memisc")

# *.sav-file einlesen
data<-as.data.set(spss.system.file('ids_new.sav'))

# Konvertierung der Daten in den Typ data.frame
data<-data.frame(data)

# Schätzung der "klassischen" Itemschwierigkeiten
# und Itemvarianzen
mean<-apply(data,2,mean)
var<-apply(data,2,var)

# Berechnung der Gamma-Koeffizienten,
# bzw. Yules Q
library(vcdExtra)
tab1<-table(data$Freude_1, data$Wut_1)
GKgamma(tab1, level=0.95)

## Dichotomes Rasch-Modell mit eRm() #####
library("eRm")

# Konvertierung der Test-Daten in den Typ matrix
# und Auswahl der 10 Items (ohne Geschlecht)
data.mat<-as.matrix(data[,2:11], dimnames=names(data)[2:11])

# bedingte Maximum-Likelihood-Schätzung (CML-Schätzung)
# der Itemparameter
rml<-RM(data.mat)
summary(rml)

# Schätzung der Personenwerte
p.par<-person.parameter(rml)
print(p.par)
summary(p.par)

# bedingter Likelihood-Quotienten-Test mit Geschlecht
# als Split-Kriterium
lrt1<-LRtest(rml, splitcr=data$sex)
summary(lrt1)

# Grafischer Modelltest
plotGOF(lrt1, conf=list(), ylab="Jungen", xlab="Mädchen")

# Darstellung der Itemcharakteristikfunktionen
plotICC(rml)

# Gemeinsame Darstellung der Itemcharakteristikfunktionen
plotjointICC(rml)

# Darstellung der Person-Item-Map
plotPImap(rml)
```

```

# Waldtest mit Geschlecht
# als Split-Kriterium
Waldtest(rml, splitcr=data$sex)

# Martin-Loef-Test
MLoef(rml, splitcr="median")

# Item-Fit
itemfit(p.par)

# Personen-Fit
personfit(p.par)

## Zweiparametrisches logistisches Testmodell (2PL)
# mit ltm()

library("ltm")

#Schätzung des 2PL
two_pl<-ltm(data.mat~z1)
summary(two_pl)

# Schätzung des 2PL unter Annahme
# identischer Diskriminationsparameter (Rasch-Modell)
two_pl_ident<-rasch(data = data.mat)
summary(two_pl_ident)

# Likelihood-Ratio-Tests zum Vergleich
# des 2PL-Modells mit dem Rasch-Modell
anova(two_pl_ident, two_pl)

# Schätzung des 3PL mit Optimizer "nlminb"
three_pl<-tpm(data.mat, control=list(optimizer="nlminb"))
summary(three_pl)

# Darstellung der Itemcharakteristikfunktionen
plot(two_pl)

# Ausgabe der geschätzten Personenwerte
factor.scores(two_pl)

## Mischverteilungs-Rasch-Modell mit psychomix()
# Modell mit zwei Klassen

install.packages("psychomix", dependencies = TRUE)
# Das Paket muss nur einmal installiert werden, es wird dann mit dem
#"library"-Befehl geladen. Immer wenn R neu aufgerufen wird, muss ein
# Paket neu geladen werden

library("psychomix")

mrm1<-raschmix(data=data.mat, k=2, scores="meanvar")
summary(mrm1)

```

```
## Anmerkung: in Eid und Schmidt (2014)
## wurde WINMIRA (Davies, 2001) verwendet
```

2.2 Daten einlesen und deskriptive Statistiken

```
> library("memisc")
```

Zunächst muss die SPSS-Datei `ids.sav` eingelesen werden. Hierbei kommt das Paket `memisc` zum Einsatz, welches die Funktion `spss.system.file()` enthält.

```
> data<-as.data.set(spss.system.file('ids_new.sav'))
> data<-data.frame(data)
```

Die Daten werden schrittweise eingelesen. Zunächst werden sie über die Funktion `as.data.set()` in R importiert und hiernach zur einfacheren Handhabung bei folgenden Analysen in den Typ `data frame` umgewandelt.

```
> mean<-apply(data, 2, mean)
> var<-apply(data, 2, var)
```

Zur Berechnung der Mittelwerte und Varianzen der Variablen, bzw. Items im Daten-Frame kann die Funktion `apply()` verwendet werden. Hierbei ist zu beachten, dass die erste Spalte des Daten-Frames kein Item, sondern die Kodierung des Geschlechts der Teilnehmer (`sex`) enthält. Diese Schritte sind interessant, um sich einen ersten Eindruck über die deskriptiven Charakteristiken der Items zu verschaffen.

2.3 Berechnung der Gamma-Koeffizienten bzw. Yules Q

```
> library(vcdExtra)
```

Zur Berechnung der Gamma-Koeffizienten wird die Bibliothek `vcdExtra` benötigt.

```
> tab1<-table(data$Freude_1, data$Wut_1)
```

Es wird eine Kontingenztafel der gemeinsamen Verteilung von Item 1 und Item 2 erzeugt.

```
> GKgamma(tab1, level=0.95)
gamma      : 0.875
std. error : 0.068
CI         : 0.742 1
```


Der geschätzte Gamma-Koeffizient inklusive des Standardfehlers und des 95%-Konfidenzintervalls wird ausgegeben. Dieser Vorgang muss für alle Itemkombinationen wiederholt werden.

2.4 Analysen mit dem dichotomen Rasch-Modell

2.4.1 Laden des Paketes `eRm`

```
> library("eRm")
```

Das Paket `eRm` enthält umfangreiche Funktionen zur psychometrischen Analyse vor dem theoretischen Hintergrund des Rasch-Modells. Erwähnenswert ist, dass das Paket explizit auf der bedingten Maximum-Likelihood-Schätzmethode (*conditional maximum likelihood estimation*, CML) aufbaut. Dieses Paket wird zur Durchführung der Beispiel-Analysen mit dem Rasch-Modell verwendet.

2.4.2 Selektion und Konvertierung der Daten

```
> data.mat<-as.matrix(data[,2:11], dimnames=names(data)[2:11])
```

Das Paket `eRm` benötigt als Datenformat den Typ `matrix`. Von daher werden die Items im Daten-Frame `data` in den Typ `matrix` konvertiert. Es werden nur die Spalten 2 bis 11 des Daten-Frames selektiert, da die erste Spalte die Variable Geschlecht (`sex`) enthält. In die Rasch-Analyse sollen aber nur die 10 Items eingehen. Zudem werden die Namen der Items über das Argument `dimnames=names(data)[2:11]` in die neu erzeugte Matrix `data.mat` übernommen. Diese Matrix dient als Ausgangspunkt der weiteren Analysen.

2.4.3 Bedingte Maximum-Likelihood-Schätzung

```
> rm1<-RM(data.mat)
```

Die Itemparameter des dichotomen Rasch-Modells werden anhand der Funktion `RM()` geschätzt. Die Ausgabe wird dem Objekt `rm1` zugewiesen.

```
> summary(rm1)
```

Die Ergebnisse der Schätzung werden mit der Funktion `summary()` in strukturierter Form ausgegeben. Die Ausgabe wird im Folgenden insgesamt dargestellt und dann Schritt für Schritt kurz erläutert.

```
Results of RM estimation:
```

```
Call: RM(X = data.mat)
```

```
Conditional log-likelihood: -496.0098
```

```
Number of iterations: 13
```

```
Number of parameters: 9
```

```
Item (Category) Difficulty Parameters (eta): with 0.95 CI:
```

	Estimate	Std. Error	lower CI	upper CI
Wut_1	-0.958	0.256	-1.459	-0.456
Angst_1	0.909	0.169	0.577	1.240
Trauer_1	0.705	0.173	0.366	1.045
Ueber_1	-0.115	0.202	-0.511	0.281
Trauer_2	0.645	0.174	0.303	0.987
Angst_2	1.180	0.166	0.856	1.505
Wut_2	-1.490	0.306	-2.090	-0.891
Ueber_2	1.413	0.164	1.091	1.734
Freude_2	-0.686	0.236	-1.148	-0.224

```
Item Easiness Parameters (beta) with 0.95 CI:
```

	Estimate	Std. Error	lower CI	upper CI
beta Freude_1	1.603	0.318	0.979	2.226
beta Wut_1	0.958	0.256	0.456	1.459
beta Angst_1	-0.909	0.169	-1.240	-0.577
beta Trauer_1	-0.705	0.173	-1.045	-0.366
beta Ueber_1	0.115	0.202	-0.281	0.511
beta Trauer_2	-0.645	0.174	-0.987	-0.303
beta Angst_2	-1.180	0.166	-1.505	-0.856
beta Wut_2	1.490	0.306	0.891	2.090
beta Ueber_2	-1.413	0.164	-1.734	-1.091
beta Freude_2	0.686	0.236	0.224	1.148

Die logarithmierte bedingte Likelihood am Ort des Maximums beträgt -496.01. Dieser Wert ist für Likelihood-Quotienten-Tests von Interesse, die ebenfalls im Paket `eRm` implementiert sind. Die Anzahl der Iterationen bis zur Konvergenz der Schätzung betrug 13 Schritte. Insgesamt wurden in der Implementation 9 Parameter geschätzt, da implizit eine Summennormierung durchgeführt wurde.

```
Item (Category) Difficulty Parameters (eta): with 0.95 CI:
```

	Estimate	Std. Error	lower CI	upper CI
Wut_1	-0.958	0.256	-1.459	-0.456
[...]				

Die geschätzte Schwierigkeit des Items `Wut_1` beträgt unter der Annahme des bedingten Rasch-Modells -0.958 . Der Standardfehler dieses Schätzers ist 0.256 . Das 0.95-Konfidenzintervall ist $CI[-1.459, 0.456]$. Für das Item `Freude_1` wird kein Parameter ausgegeben, da sich dessen geschätzter Schwierigkeitsparameter aufgrund der Summennormierung aus den anderen geschätzten Schwierigkeitsparametern ergibt. Für das Item `Freude_1` wird aber – wie für die anderen Items auch – der geschätzte Leichtigkeitsparameter ausgegeben (Schwierigkeitsparameter multipliziert mit -1):

```

Item easiness Parameters (beta) with 0.95 CI:
      Estimate Std. Error lower CI upper CI
beta Freude_1    1.603    0.318    0.979    2.226
[...]
```

Die Implementation der Rasch-Modelle in `eRm` baut auf einem integrativen CML-Framework auf. Für eine Vertiefung sei das Buch von Koller, Alexandrowicz und Hatzinger (2012) und die Dokumentation des Paketes `eRm` (Mair & Hatzinger, 2007) empfohlen.

2.4.4 Maximum-Likelihood-Schätzung der Personenparameter

```
> p.par<-person.parameter(rm1)
```

Mit der bedingten Maximum-Likelihood-Schätzmethode werden die Itemparameter unabhängig von den Personenwerten geschätzt. Aufbauend auf den geschätzten Itemparametern werden daraufhin die Personenwerte mit der Maximum-Likelihood-Methode geschätzt (s. Abschnitt 4.5.3.6 in Eid & Schmidt, 2014). Dies geschieht durch die Funktion `person.parameter()` im Paket `eRm`. Die Ausgabe der Funktion wird dem Objekt `p.par` zugewiesen.

```
> print(p.par)
```

Eine Tabelle der Summenwerte und der Personenwerte (`person parameters`) wird ausgegeben.

```
Person Parameters:
```

Raw Score	Estimate	Std.Error
0	-3.61779726	NA
1	-2.63251737	1.1028495
2	-1.71234712	0.8589364
3	-1.05807884	0.7702325
4	-0.49882926	0.7304911
5	0.02159298	0.7157188
6	0.53543739	0.7216184
7	1.07645082	0.7552292
8	1.70456439	0.8421463
9	2.59497001	1.0891755
10	3.54991655	NA

In der ersten Spalte sind die Rohwerte (Summenwerte) abgetragen, die zweite Spalte zeigt die geschätzten Personenwerte (Personenparameter) und die dritte Spalte enthält die entsprechenden Standardfehler der Maximum-Likelihood-Schätzer. Ein NA (*not applicable* oder *not available*) bedeutet, dass der entsprechende Standardfehler nicht geschätzt werden konnte. Dies ist für den

geringsten und höchstmöglichen Summenwert mit der Maximum-Likelihood-Methode nicht möglich (s. Abschnitt 4.5.3.6 in Eid & Schmidt, 2014).

```
> summary(p.par)
```

Dieser Befehl zeigt die geschätzten Personenwerte einer jeden Person in dem Datensatz, deren Standardfehler sowie die dazugehörigen 0.95-Konfidenzintervalle.

```
Estimation of Ability Parameters
```

```
Collapsed log-likelihood: -40.02453
```

```
Number of iterations: 9
```

```
Number of parameters: 9
```

```
ML estimated ability parameters (without spline interpolated values):
```

	Estimate	Std. Err.	2.5 %	97.5 %
theta 1	2.59497001	1.0891755	0.46022531	4.72971471
theta 3	0.53543739	0.7216184	-0.87890864	1.94978342

[...]

Der geschätzte Personenwert oder Fähigkeitsparameter (*ability parameter*) wird in der Ausgabe mit `theta1` usw. bezeichnet. Die *collapsed log-likelihood* ist die Likelihood des Modells, das der Maximum-Likelihood-Schätzung der Personenwerte zugrunde liegt. Diese ist von technischem Interesse. Die Personenwerte müssen nicht für jede Person einzeln, sondern können über Gruppen von Personen mit identischen Rohwerten geschätzt werden, da im dichotomen Rasch-Modell der Summenwert einer Person eine suffiziente Statistik für den zu schätzenden Parameter darstellt. Von daher erklärt sich der relativ geringe Wert von lediglich -40.025. „Collapsed“ bedeutet hier „zusammengefasst“. Insgesamt wurden 9 Iterationen für die Konvergenz benötigt und 9 verschiedene Personenwerte wurden geschätzt.

2.4.5 Der bedingte Likelihood-Quotienten-Test nach Andersen

```
> lrt1<-LRtest(rm1, splitcr=data$sex)
> summary(lrt1)
```

Zur Testung der Annahme der Gleichheit der Itemparameter zwischen Subpopulationen kommt der bedingte Likelihood-Quotienten-Test nach Andersen (s. Abschnitt 4.5.4.1.2 in Eid & Schmidt, 2014) mit dem Split-Kriterium „Geschlecht“ zum Einsatz. Die Funktion `LRtest()` übernimmt als Argument das Objekt `rm1`, das durch die Funktion `RM()` erzeugt wurde. Das Split-Kriterium (Trennkriterium für die beiden Gruppen) wird über das Argument `splitcr=data$sex` angegeben.

Andersen LR-test:

```
LR-value: 9.298
Chi-square df: 9
p-value: 0.41
```

```
Subject Subgroup: data$sex 0:
Log-likelihood: -276.0868
[...]
```

Die Teststatistik des bedingten Likelihood-Quotienten-Tests beträgt mit 9 Freiheitsgraden $\chi^2 = 9.30$. Die Überschreitungswahrscheinlichkeit beträgt $p = .41$. Damit kann die Nullhypothese, dass sich die Itemparameter in den Geschlechtsgruppen nicht unterscheiden, beibehalten werden.

```
Subject Subgroup: data$sex 0:
Log-likelihood: -276.0868
```

```
Beta Parameters:
      beta Freude_1
Estimate      1.4293717
Std.Err.      0.4089078
[...]
```

```
Subject Subgroup: data$sex 1:
Log-likelihood: -215.2741
```

```
Beta Parameters:
      beta Freude_1
Estimate      1.8201896
Std.Err.      0.5073775
[...]
```

Die geschätzten Itemparameter und deren Standardfehler werden für beide Geschlechtsgruppen separat ausgegeben. Gleiches gilt für die Log-Likelihood der auf die beiden Gruppen separat angepassten bedingten Rasch-Modelle.

2.4.6 Grafischer Modelltest

```
> plotGOF(lrt1, conf=list(), ylab="Jungen", xlab="Mädchen")
```

Es wird eine Grafik angezeigt, in der die geschätzten Itemparameter der Mädchen und der Jungen gegeneinander abgetragen werden (s. Abschnitt 4.5.4.1.1 in Eid & Schmidt, 2014). Das Erstellen dieser Grafik wird auch als grafischer Modelltest bezeichnet. Die Kreise geben die Größe der Konfidenzintervalle an.

2.4.7 Person-Item-Karte

```
> plotPImap(rm1)
```

Eine Person-Item-Karte (*person-item map*) wird erstellt. Im oberen Teil der Abbildung wird ein Histogramm der Personenwerte gezeigt. Im unteren Teil der Abbildung sind die Anordnungen der Itemschwierigkeiten auf der latenten Dimension abgetragen. Die „kleinen Striche“ unter dem Histogramm zeigen die Anordnungen der geschätzten Itemschwierigkeiten oder Schwellen (im Partial-Credit-Modell, s. Abschnitt 4.4) auf der latenten Dimension an.

2.4.8 Darstellung der Itemcharakteristikfunktionen

```
> plotICC(rm1)
```

Die Itemcharakteristikfunktionen (s. Abschnitt 4.5.1 in Eid & Schmidt, 2014) des auf die Daten angepassten Modells werden grafisch ausgegeben.

```
> plotjointICC(rm1)
```

Die Itemcharakteristikfunktionen werden gemeinsam dargestellt.

2.4.9 Wald-Test zur Überprüfung der Gleichheit der Itemschwierigkeiten in Subgruppen

```
> Waldtest(rm1, splitcr=data$sex)
```

Es wird ein Wald-Test (s. Abschnitt 4.5.4.1.3 in Eid & Schmidt, 2014) mit Geschlecht als Split-Kriterium durchgeführt, d.h., für jedes Item wird die Nullhypothese geprüft, dass sich die Itemschwierigkeiten in den beiden Geschlechtsgruppen nicht unterscheiden.

Wald test on item level (z-values):

	z-statistic
beta Freunde_1	-0.600
beta Wut_1	1.143
beta Trauer_1	-1.357
[...]	
	p-value
beta Freude_1	0.549
beta Wut_1	0.253
[...]	

Für jedes Item werden die Teststatistik und die entsprechende Überschreitungswahrscheinlichkeit ausgegeben.

2.4.10 Martin-Löf-Test

```
> MLoef(rm1, splitcr="median")
```

Ein Martin-Löf-Test (s. Abschnitt 4.5.4.4 in Eid & Schmidt, 2014) mit dem Split-Kriterium „Median der Rohwertverteilung der Items“ wird durchgeführt.

```
Martin-Loef-Test (split criterion: median)
LR-value: 22.668
Chi-square df: 24
p-value: 0.539
```

Die Teststatistik, deren Freiheitsgrade und die Überschreitungswahrscheinlichkeit werden ausgegeben.

2.4.11 Residualstatistiken: Itemfit

```
> itemfit(p.par)

Itemfit Statistics:
      Chisq  df p-value  Outfit MSQ  Infit MSQ  Outfit t  Infit t
Freunde_1   75.284 156  1.000    0.480   0.863   -1.38   -0.49
Wut_1      176.465 156  0.125    1.124   1.093    0.50    0.55
[...]
```

Die Itemfit-Statistiken zur Identifikation von abweichenden Items (s. Abschnitt 4.5.4.6 in Eid & Schmidt, 2014) werden berechnet und ausgegeben. Die χ^2 -Teststatistik ist ein residualbasiertes Abweichungsmaß, welches bei Geltung der Nullhypothese der Modellpassung χ^2 -verteilt ist. Die Freiheitsgrade des Tests ($df = 156$) und die Überschreitungswahrscheinlichkeiten werden pro Item dargestellt. Zudem werden der Outfit, der Infit und die dazugehörigen t -verteilten Teststatistiken ausgegeben. Out- und Infit-Statistiken werden von Eid und Schmidt (2014) nicht behandelt (s. hierzu Koller, Alexandrowicz & Hatzinger, 2012).

2.4.12 Residualstatistiken: Personenfit

```
> personfit(p.par)

Personfit Statistics:
      Chisq  df p-value  Outfit MSQ  Infit MSQ  Outfit t  Infit t
1       4.148  9  0.901    0.415   0.816   -0.04    0.00
3       7.037  9  0.633    0.704   0.825   -0.63   -0.53
[...]
```

Die entsprechenden residualbasierten Teststatistiken und Fit-Indizes werden über die Personen berechnet und ausgegeben (s. Abschnitt 4.5.4.7 in Eid & Schmidt, 2014). Person 2 taucht in der Ausgabe nicht auf, da diese alle Items gelöst hat und somit kein Personenwert mit der Maximum-Likelihood-Methode geschätzt werden konnte.

2.5 Analysen mit dem zweiparametrischen logistischen Modell (Birnbbaum-Modell) für dichotome Antwortvariablen

Zur Analyse der Daten mit dem zweiparametrischen logistischen Modell (Birnbbaum-Modell, 2PL-Modell) in R kommt das Paket `ltm` zum Einsatz.

```
> two_pl<-ltm(data.mat~z1)
> summary(two_pl)
```

Die Funktion `ltm` übernimmt als Argument die Modellformel `data.mat~z1`, welche das zweiparametrische logistische Modell (2PL-Modell) ohne Restriktionen auf den Diskriminationsparametern definiert. Das Objekt `data.mat` ist die Datenmatrix, die schon für die Analysen mit `eRm` verwendet wurde. Der Ausdruck `z1` bedeutet, dass a priori im Einklang mit der Hypothese der Eindimensionalität lediglich eine latente Variable spezifiziert wird. Das Ergebnis der Parameterschätzung wird auf der Konsole ausgegeben.

```
Call:
ltm(formula = data.mat ~ z1)
```

```
Model Summary:
      log.Lik      AIC      BIC
-876.3027 1792.605 1857.859
[...]
```

Es werden die Log-Likelihood des auf die Daten angepassten Modells und die informationstheoretischen Indizes AIC und BIC ausgegeben, die für den Modellvergleich interessant sind.

Die Log-Likelihood des Modells beträgt -876.303. Der AIC-Index beträgt 1729.605 und der BIC beträgt 1857.859.

```
Coefficients:
              value std.err  z.vals
Dffclt.Freude_1 -1.6387  0.2374 -6.9016
Dffclt.Wut_1    -1.9338  0.4004 -4.8304
Dffclt.Angst_1  -0.7381  0.2485 -2.9703
Dffclt.Trauer_1 -1.0637  0.3330 -3.1938
Dffclt.Ueber_1  -1.3770  0.2891 -4.7637
Dffclt.Trauer_2 -1.0415  0.3063 -3.3998
Dffclt.Angst_2  -0.3845  0.1674 -2.2968
Dffclt.Wut_2    -1.4876  0.1965 -7.5704
Dffclt.Ueber_2  -0.1923  0.1564 -1.2294
```



```

Dffclt.Freude_2 -1.1954  0.1756 -6.8092
Dscrmn.Freude_1  2.7433  0.8207  3.3426
Dscrmn.Wut_1     1.3229  0.3647  3.6270
Dscrmn.Angst_1   0.9638  0.2832  3.4038
Dscrmn.Trauer_1  0.8193  0.2439  3.3592
Dscrmn.Ueber_1   1.3126  0.3395  3.8659
Dscrmn.Trauer_2  0.9097  0.2618  3.4749
Dscrmn.Angst_2   1.2615  0.3421  3.6871
Dscrmn.Wut_2     3.5343  1.1687  3.0241
Dscrmn.Ueber_2   1.2315  0.3379  3.6442
Dscrmn.Freude_2  3.1003  0.9554  3.2449
[...]

```

Die geschätzten Itemparameter werden ausgegeben. In der oberen Hälfte der Ausgabe befinden sich die Itemschwierigkeiten (`Dffclt.*`), deren Standardfehler sowie eine z -verteilte Teststatistik der Nullhypothese, dass die Schwierigkeitsparameter in der Population Null betragen. In der unteren Hälfte der Ausgabe befinden sich die geschätzten Diskriminationsparameter (`Dscrmn.*`) sowie deren Standardfehler und Teststatistiken.

```

Integration:
method: Gauss-Hermite
quadrature points: 21

```

```

Optimization:
Convergence: 0
max(|grad|): 0.0016
quasi-Newton: BFGS

```

Es werden technische Details zur Parameterschätzung ausgegeben. Die latente Variable wurde mittels der Gauss-Hermite-Quadratur mit 21 Stützpunkten „herausintegriert“. Die Parameterschätzung mittels des BFGS-Algorithmus ist konvergiert (`Convergence: 0`). Der maximale Betrag des Gradienten ist 0.0016.

```

> two_pl_ident<-rasch(data = data.mat)
> summary(two_pl_ident)

```

Das 2PL-Modell mit identischen Ladungen (das dichotome Rasch-Modell) wird mittels der Funktion `rasch()` im Paket `ltm` angepasst (s. hierzu Eid & Schmidt, 2004, Abschnitt 4.5.3.4).

```

Call:
rasch(data = data.mat)

```

```

Model Summary:
  log.Lik      AIC      BIC
-890.9735 1803.947 1839.837

```

Die Struktur der Ausgabe unterscheidet sich im Wesentlichen nicht von derjenigen des 2PL-Modells ohne Restriktionen auf den Ladungsparametern. Zunächst werden die Log-Likelihood und die informationstheoretischen Indizes ausgegeben.

```
Coefficients:
              value std.err  z.vals
Dffclt.Trauer_1  -2.2878  0.2785 -8.2132
Dffclt.Ueber_1   -1.9089  0.2405 -7.9385
[...]
Dscrmn           1.3553  0.1222 11.0924
```

Es folgen die Modellkoeffizienten in Form der Schwierigkeiten und des für alle Items identischen Diskriminationsparameters (`Dscrm`). Die entsprechenden Standardfehler und Teststatistiken werden ebenfalls berichtet.

```
Integration:
method: Gauss-Hermite
quadrature points: 21
```

```
Optimization:
Convergence: 0
max(|grad|): 5e-04
quasi-Newton: BFGS
```

Bei der Schätzung kam standardmäßig der BFGS-Algorithmus zum Einsatz und es wurde die Gauss-Hermite-Quadratur mit 21 Stützpunkten zur Integration über die latente Trait-Verteilung verwendet. Der Algorithmus ist konvergiert.

2.5.1 Vergleich des 2PL-Modells mit dem Rasch-Modell

```
> anova(two_pl_ident, two_pl)
```

Mittels eines Likelihood-Ratio-Tests wird geprüft, ob das 2PL-Modell mit frei schätzbaren Ladungen die Daten signifikant besser erklärt, als das Modell mit identischen Ladungen (Rasch-Modell).

```
Likelihood Ratio Table
              AIC      BIC log.Lik  LRT df p.value
two_pl_ident 1803.95 1839.84 -890.97
two_pl       1792.61 1857.86 -876.30 29.34 9 0.001
```

Der Likelihood-Quotienten-Test legt nahe, dass das 2PL-Modell mit frei geschätzten Ladungen (`two_pl`) die Daten besser erklärt als das Modell mit der Annahme der identischen Ladungen (`two_pl_ident`). Die χ^2 -verteilte Teststatistik beträgt 29.34 mit 9 Freiheitsgraden. Die

Überschreitungswahrscheinlichkeit ist .001. Auch der AIC-Index legt nahe, dass das 2PL-Modell mit unterschiedlichen Diskriminationsparametern die Daten besser beschreibt, der BIC-Index deutet jedoch auf eine bessere und sparsamere Passung des Modells mit identischen Ladungsparametern hin.

2.5.2 Die Analyse des dreiparametrischen Modells (3PL-Modell)

Das 3PL-Modell wird mit der Funktion `tpm()` im Paket `ltm` angepasst.

```
> three_pl<-tpm(data.mat, control=list(optimizer="nlminb"))
> summary(three_pl)
```

Das 3PL-Modell unterscheidet sich vom 2PL-Modell dahingehend, dass pro Item ein sogenannter „Rateparameter“ in die Modellgleichung eingefügt wird. Da mit dem BFGS-Algorithmus Konvergenzprobleme bei der Parameterschätzung auftraten, wurde über das Argument `control` die Optimierungs-Routine „nlminb“ ausgewählt. Das Ergebnis der Schätzung wird über die Funktion `summary()` ausgegeben.

```
Model Summary:
  log.Lik      AIC      BIC
-876.2546 1812.509 1910.39

Coefficients:
              value std.err  z.vals
Gussng.Freude_1  0.1505  0.3708  0.4059
Gussng.Wut_1     0.0000  0.0005  0.0009
[...]
Dffclt.Freude_1 -1.4363  0.5365 -2.6774
Dffclt.Wut_1    -1.9275  0.3942 -4.8900
[...]
Dscrmn.Freude_1  3.3381  2.2773  1.4658
Dscrmn.Wut_1    1.3318  0.3658  3.6413

Integration:
method: Gauss-Hermite
quadrature points: 21

Optimization:
optimizer: nlminb
Convergence: 0
max(|grad|): 0.0016
```

Der wesentliche Unterschied zu den bisherigen Ausgaben besteht darin, dass nun zusätzlich die geschätzten Rateparameter (`Gussng.*`), deren Standardfehler und Teststatistiken ausgegeben werden. Die Optimierung erfolgte mit den PORT-Routinen „nlminb“ und ist konvergiert. Eine Inspektion der Rateparameter in der Ausgabe legt nahe, dass diese für die vorliegenden Daten nicht benötigt werden.

2.5.3 Die Ausgabe der Itemcharakteristikkurven

```
> plot(two_pl)
```

Die Itemcharakteristikkurven des entsprechenden Modells (hier das 2PL-Modell) werden grafisch ausgegeben.

2.5.4 Die Schätzung der Personenwerte

```
> factor.scores(two_pl)
```

Die Personenwerte (*factor scores*) des 2PL-Modells werden für jedes Antwortmuster geschätzt und ausgegeben. Standardmäßig geschieht dies mit der Empirical-Bayes-Methode. Die Ausgabe enthält die beobachteten Antwortmuster, von daher wird die Ausgabe hier verkürzt dargestellt.

Call:

```
ltm(formula = data.mat ~ z1)
```

Scoring Method: Empirical Bayes

```
...
  Angst_2 Wut_2 Ueber_2 Freude_2 Obs   Exp   z1 se.z1
...      0    0      0         0  6  0.994 -2.295 0.487
...      0    1      0         1  1  0.042 -1.263 0.325
...      0    1      1         1  1  0.012 -1.017 0.357
...      1    1      1         1  1  0.005 -0.832 0.395
...
```

In der Ausgabe werden zunächst die Antwortmuster dargestellt. Die Spalte (Obs) enthält die beobachtete Häufigkeit des Antwortmusters, die Spalte Exp enthält die erwartete Häufigkeit des Antwortmusters, z1 ist der geschätzte Personenwert (geschätzte Personenfähigkeit) und se.z1 ist dessen Standardfehler.

2.6 Mischverteilungs-Rasch-Modelle

Eine vielversprechende Bibliothek zur Schätzung von Mischverteilungs-Rasch-Modellen ist `psychomix` (Frick et al., 2012). In Eid und Schmidt (2014) wurde WINMIRA (Davier, 2001) verwendet, von daher wird auf diese Software und deren Dokumentation verwiesen. Dennoch sei hier kurz angerissen, wie das Paket zur Anpassung von Mischverteilungs-Rasch-Modellen gehandhabt werden kann.

```
> mrm1<-raschmix(data=data.mat, k=2, scores="meanvar")
```

Ein Mischverteilungs-Rasch-Modell mit $k=2$ Klassen wird angepasst. Über das Argument `scores="meanvar"` werden die latenten Score-Verteilungen mittels eines multinomialen Logit-Modells mit einem Mittelwert- und Varianz-Parameter modelliert.

```
> summary(mrml)

Call:
raschmix(data = data.mat, k = 2,
          scores = "meanvar")

      prior size post>0 ratio
Comp.1 0.509   86    135 0.637
Comp.2 0.491   71    157 0.452
```

Die geschätzten Klassengrößen werden ausgegeben.

```
Item Parameters:
      Comp.1      Comp.2
Freude_1 -0.6710822 -2.0008396
Wut_1    0.3527830 -2.0162904
Angst_1 -6.0358533  2.9410778
Trauer_1  1.4793925  0.6053855
Ueber_1  1.0927986 -1.0038794
Trauer_2  1.6217470  0.2407851
Angst_2  0.9099259  2.3508389
Wut_2    -0.8296391 -1.6424890
Ueber_2  2.4304225  1.0354368
Freude_2 -0.3504949 -0.5100258
```

Die geschätzten und summierten Itemparameter in den Klassen werden ausgegeben.

```
'log Lik.' -851.7621 (df=25)
AIC: 1753.524   BIC: 1829.93
```

Die informationstheoretischen Indizes AIC und BIC werden ausgegeben. Für eine detaillierte Auseinandersetzung mit dem Paket sei auf dessen Dokumentation hingewiesen.

3 Beispielsyntax für Kapitel 5: Eindimensionale Modelle für Antwortvariablen mit geordneten Antwortkategorien

3.1 Überblick Gesamtsyntax

```
#### Syntax Kapitel 5 ####

library(memisc)
# *.sav-file einlesen
data<-as.data.set(spss.system.file('Daten-kapitel-5-sex.sav'))
# Konvertierung der Daten in den Typ data.frame
```

```

data<-data.frame(data)

# Deskriptive Statistiken
mean<-apply(data[2:7],2,mean)
mean
median<-apply(data[2:7],2,median)
median
var<-apply(data[2:7],2,var)
var

# Gamma-Koeffizient
library(vcdExtra)
tab1<-table(data$item_1, data$item_2)
GKgamma(tab1, level=0.95)

# relativer Informationsgehalt
item_1_factor<- factor(data$item_1, labels=c('1','2','3','4','5'))
item_1_p<-prop.table(table(item_1_factor))
item_1_i<-(-1/log(5))*sum((item_1_p*log(item_1_p)))
item_1_i

# Anpassung des Partial-Credit-Modells mit eRm()
library(eRm)

# Konvertierung der Test-Daten in den Typ matrix
data.mat<-as.matrix(data[,2:7], dimnames=names(data)[2:7])

# CML-Schätzung der Item-Parameter
pcm<-PCM(data.mat)
summary(pcm)

# Berechnung der Schwellenparameter
thresholds(pcm)

# Darstellung der Itemcharakteristikkurven
plotICC(pcm)

# Darstellung der Person-Item-Map
plotPImap(pcm)

# ML-Schätzung der Personenwerte
p.par<-person.parameter(pcm)
summary(p.par)
print(p.par)

# Likelihood-Ratio-Test mit Geschlecht
# als Split-Kriterium
lrt1<-LRtest(pcm, splitcr=data$sex)
summary(lrt1)

# Grafischer Modelltest
plotGOF(lrt1, conf=list())

# Waldtest mit Geschlecht
# als Split-Kriterium
Waldtest(pcm, splitcr=data$sex)

```

```

# Martin-Loef-Test mit
# benutzerdefiniertem Split-Kriterium
MLoef(pcm, splitcr=c(1,0,1,1,0,0))

# Item-Fit
itemfit(p.par)

# Personen-Fit
personfit(p.par)

## Anpassung des generalisierten Partial-Credit-Modells

library(ltm)
gpcm<-gpcm(data.mat)
summary(gpcm)

GoF.gpcm(gpcm, B=300) # Goodness of Fit bootstrap

## Analyse der Items 1, 3 und 4

# Auswahl der Items 1, 3 und 4
data.sub<-data.mat[,c(4,1,3)]

# Anpassen des Partial-Credit-Modells
pcm.sub<-PCM(data.sub)
summary(pcm.sub)
thresholds(pcm.sub)

# Anpassen des Ratingskalenmodells
rsm.sub<-RSM(data.sub)
summary(rsm.sub)
thresholds(rsm.sub)

```

3.2 Deskriptive Statistiken und Gamma-Koeffizient

```

> # Deskriptive Statistiken
> mean<-apply(data[2:7],2,mean)
> mean
> median<-apply(data[2:7],2,median)
> median
> var<-apply(data[2:7],2,var)
> var

> # Gamma-Koeffizient
> library(vcdExtra)
> tab1<-table(data$item_1, data$item_2)
> GKgamma(tab1, level=0.95)

```

Das Vorgehen bei der Berechnung der deskriptiven Statistiken und des Gamma-Koeffizienten gleicht im Wesentlichen dem Vorgehen, das im Kapitel 2 dargestellt wurde. Neu hinzu kommt die Berechnung des Medians.

3.3 Berechnung des relativen Informationsgehalts

```
> item_1_factor<- factor(data$item_1, labels=c('1','2','3','4','5'))
```

Item 1 wird in ein Objekt des Typs Faktor umgewandelt.

```
> item_1_h<-prop.table(table(item_1_factor))
```

Die relativen Häufigkeiten der Kategorienwahlen werden berechnet.

```
> item_1_i<-(-1/log(5))*sum((item_1_h*log(item_1_h)))
```

Der relative Informationsgehalt des Items wird berechnet.

3.4 Das Partial-Credit-Modell

Zur psychometrischen Analyse mit dem Partial-Credit-Modell (PCM) kann das Paket `eRm` verwendet werden. Die Analyseschritte und die Syntax unterscheiden sich im Wesentlichen nicht von denjenigen, die schon in dem Abschnitt zum dichotomen Rasch-Modell (Kapitel 2) dargestellt wurden. Es werden hier nur die abweichenden Punkte erläutert.

```
> pcm<-PCM(data.mat)
> summary(pcm)
```

Zur Schätzung der Parameter des Partial-Credit-Modells wird der Funktion `PCM()` die Datenmatrix als Argument übergeben. Die Ergebnisse der Analyse werden mit der Funktion `summary()` ausgegeben.

Results of PCM estimation:

Call: PCM(X = data.mat)

Conditional log-likelihood: -2387.655
Number of iterations: 36
Number of parameters: 23

Item (Category) Difficulty Parameters (eta): with 0.95 CI:

	Estimate	Std. Error	lower CI	upper CI
item_1.c2	-1.541	0.238	-2.007	-1.075
item_1.c3	-0.651	0.243	-1.128	-0.174
item_1.c4	1.054	0.264	0.536	1.573
item_2.c1	-1.398	0.220	-1.828	-0.968

[...]

Item Easiness Parameters (beta) with 0.95 CI:

	Estimate	Std. Error	lower CI	upper CI
beta item_1.c1	1.306	0.245	0.826	1.787
beta item_1.c2	1.541	0.238	1.075	2.007


```
beta item_1.c3    0.651    0.243    0.174    1.128
beta item_1.c4   -1.054    0.264   -1.573   -0.536
[...]
```

Die Itemparameter wurden mit der Conditional-Maximum-Likelihood-Methode geschätzt. Die Log-Likelihood auf Basis des angepassten bedingten Partial-Credit-Modells beträgt -2387.655. Die Parameterschätzung konvergierte nach 36 Iterationen, insgesamt wurden 23 Parameter geschätzt. In der oberen Hälfte des Outputs werden die mit der Parametrisierung von Mair und Hatzinger (2007) geschätzten Kategorien-Schwierigkeiten inklusive Standardfehler und Konfidenzintervalle ausgegeben. In der unteren Hälfte des Outputs stehen die entsprechenden geschätzten Kategorien-Leichtigkeiten und deren Standardfehler und Konfidenzintervalle. Das Objekt `pcm` bildet den Ausgangspunkt für die weiteren anstehenden Analysen.

Die Parameter in der Ausgabe sind nicht mit den klassischen Schwellenparametern zu verwechseln. Diese ergeben sich jedoch durch eine lineare Transformation. Für Details sei die Original-Dokumentation zum Paket `eRm` empfohlen.

```
> thresholds(pcm)
```

Es werden die Schwellenparameter des PCM und Lokalisationen der Items (mittlere Schwellenparameter, Itemschwierigkeiten) auf der latenten Variablen berechnet.

```
Design Matrix Block 1:
      Location Threshold 1 Threshold 2 Threshold 3 Threshold 4
item_1 0.26360   -1.30633   -0.23456    0.89008    1.70523
item_2 0.54355   -1.39812    0.20236    1.27090    2.09906
item_3 0.74698   -0.48717    0.49736    0.86477    2.11297
item_4 -0.33903   -2.03104   -0.71493    0.25209    1.13777
item_5 1.70473   -0.01890    1.10021    2.12426    3.61335
item_6 0.33337   -1.72420   -0.06733    0.91611    2.20890
```

Die Schwellenparameter der Items und deren Lokalisationen werden ausgegeben. Der Teil der Ausgabe „Design Matrix Block 1“ weist darauf hin, dass das Paket `eRm` sich auch dazu eignet, das linear-logistische Testmodell (s. z.B. Fischer, 1995) anzupassen.

3.5 Analysen mit dem generalisierten Partial-Credit-Modell

Das generalisierte Partial-Credit-Modell kann mit dem R-Paket `ltm` angepasst werden.

```
> library(ltm)
> gpcm<-gpcm(data.mat)
```

```
> summary(gpcm)
```

Die Ergebnisse der Schätzung werden ausgegeben.

Call:

```
gpcm(data = data.mat)
```

Model Summary:

log.Lik	AIC	BIC
-3850.295	7760.59	7886.968

Coefficients:

```
$item_1
      value std.err z.value
Catgr.1 -1.744  0.149 -11.720
Catgr.2 -0.997  0.102  -9.736
Catgr.3 -0.162  0.089  -1.814
Catgr.4  0.582  0.091   6.424
Dscrmn   2.049  0.215   9.527
```

[...]

```
$item_6
      value std.err z.value
Catgr.1 -2.622  0.343  -7.645
Catgr.2 -1.123  0.195  -5.766
Catgr.3 -0.136  0.164  -0.832
Catgr.4  0.987  0.179   5.505
Dscrmn   0.792  0.086   9.228
```

Integration:

method: Gauss-Hermite

quadrature points: 21

Optimization:

Convergence: 0

max(|grad|): 0.028

optimizer: nlminb

Für jedes Item werden der geschätzte itemspezifische Diskriminationsparameter und die geschätzten Schwellen ausgegeben. Die übrigen Angaben wurden bereits weiter oben im Abschnitt zum Birnbaum-Modell besprochen.

```
> GoF.gpcm(gpcm, B=300)
```

Zusätzlich wird die Anpassungsgüte des Modells mittels einer Bootstrap-Goodness-of-Fit-Statistik bewertet. Insgesamt werden 300 Bootstrap-Samples aus dem angepassten Modell angefordert.

Parametric Bootstrap Approximation to Pearson chi-squared Goodness-of-Fit Measure

```
Call:
gpcm(data = data.mat)
```

```
Tobs: 279726.7
# data-sets: 301
p-value: 0.003
```

Die Ergebnisse zeigen an, dass die Hypothese der Modellpassung verworfen werden muss ($p = 0.003$). Der Wert der χ^2 -Statistik für die beobachteten Daten beträgt 279726.7.

3.6 Analyse der Items 1, 3 und 4

```
# Auswahl der Items 1, 3 und 4
> data.sub<-data.mat[,c(1,3,4)]
```

Aus dem Gesamtdatensatz werden die Items 1, 3 und 4 ausgewählt und in das Data-Frame `data.sub` geschrieben.

```
> pcm.sub<-PCM(data.sub)
> summary(pcm.sub)
```

Das Partial-Credit-Modell wird auf die Items angepasst und die Ergebnisse der Schätzung der Basisparameter werden ausgegeben. Für technische Details zwischen dem Zusammenhang von Basisparametern und Schwellenparametern in eRm siehe Mair und Hatzinger (2007).

Results of PCM estimation:

```
Call: PCM(X = data.sub)
```

```
Conditional log-likelihood: -650.7847
Number of iterations: 22
Number of parameters: 11
```

Item (Category) Difficulty Parameters (eta): with 0.95 CI:

	Estimate	Std. Error	lower CI	upper CI
item_1.c2	-1.593	0.260	-2.102	-1.084
item_1.c3	0.015	0.279	-0.532	0.562
item_1.c4	3.466	0.371	2.739	4.193
item_3.c1	-0.519	0.189	-0.889	-0.148
item_3.c2	0.398	0.233	-0.059	0.854
item_3.c3	2.163	0.309	1.557	2.769
item_3.c4	6.371	0.458	5.473	7.269
item_4.c1	-2.581	0.441	-3.445	-1.718
item_4.c2	-3.315	0.399	-4.098	-2.533
item_4.c3	-2.628	0.340	-3.296	-1.961
item_4.c4	-0.202	0.309	-0.808	0.405

Item Easiness Parameters (beta) with 0.95 CI:

	Estimate	Std. Error	lower CI	upper CI
beta item_1.c1	1.573	0.264	1.056	2.090
beta item_1.c2	1.593	0.260	1.084	2.102
beta item_1.c3	-0.015	0.279	-0.562	0.532
beta item_1.c4	-3.466	0.371	-4.193	-2.739
beta item_3.c1	0.519	0.189	0.148	0.889
beta item_3.c2	-0.398	0.233	-0.854	0.059
beta item_3.c3	-2.163	0.309	-2.769	-1.557
beta item_3.c4	-6.371	0.458	-7.269	-5.473
beta item_4.c1	2.581	0.441	1.718	3.445
beta item_4.c2	3.315	0.399	2.533	4.098
beta item_4.c3	2.628	0.340	1.961	3.296
beta item_4.c4	0.202	0.309	-0.405	0.808

Um die Schwellenparameter zu berechnen wird die Funktion `thresholds()` verwendet.

```
> thresholds(pcm.sub)
```

Design Matrix Block 1:

	Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4
item_4	-0.05044	-2.58135	-0.73394	0.68684	2.42669
item_1	0.86646	-1.57340	-0.01973	1.60797	3.45100
item_3	1.59268	-0.51889	0.91642	1.76580	4.20740

```
> rsm.sub<-RSM(data.sub)
```

```
> summary(rsm.sub)
```

Das Ratingskalenmodell wird auf die Items angepasst, und die Ergebnisse der Schätzung der Basisparameter werden ausgegeben.

```
Number of iterations: 18
```

```
Number of parameters: 5
```

Item (Category) Difficulty Parameters (eta): with 0.95 CI:

	Estimate	Std. Error	lower CI	upper CI
item_3	0.724	0.064	0.598	0.849
item_4	-0.805	0.068	-0.939	-0.672
Cat 2	1.423	0.218	0.996	1.850
Cat 3	4.189	0.424	3.357	5.020
Cat 4	8.954	0.685	7.612	10.296

Item Easiness Parameters (beta) with 0.95 CI:

	Estimate	Std. Error	lower CI	upper CI
beta item_1.c1	-0.082	0.055	-0.189	0.025
beta item_1.c2	-1.587	0.245	-2.067	-1.106
beta item_1.c3	-4.434	0.459	-5.333	-3.535
beta item_1.c4	-9.281	0.728	-10.707	-7.855
beta item_3.c1	-0.724	0.064	-0.849	-0.598
beta item_3.c2	-2.871	0.277	-3.413	-2.328
beta item_3.c3	-6.360	0.523	-7.384	-5.335
beta item_3.c4	-11.849	0.829	-13.473	-10.225
beta item_4.c1	0.805	0.068	0.672	0.939
beta item_4.c2	0.188	0.230	-0.263	0.638

```
beta item_4.c3    -1.772      0.402    -2.560    -0.985
beta item_4.c4    -5.733      0.615    -6.938    -4.527
```

Eine Annahme des Ratingskalenmodells besteht darin, dass die Schwellenabstände für jedes Item identisch sind. Es ist also eine restringierte Form des Partial-Credit-Modells. Weitere Analyseschritte, wie z.B. die Durchführung eines Likelihood-Quotienten-Tests, die Schätzung der Personenparameter und die Bewertung der Residualstatistiken wurden bereits weiter oben im Abschnitt zum Partial-Credit-Modell besprochen. In der Syntax werden zusätzlich die Schwellenparameter mit der Funktion `thresholds()` berechnet und der Funktion `plotPImap()` grafisch dargestellt, um einen Vergleich der Ergebnisse mit denjenigen in Eid und Schmidt (2014) zu erleichtern:

```
> thresholds(rsm.sub)

Design Matrix Block 1:
      Location Threshold 1 Threshold 2 Threshold 3 Threshold 4
item_4  1.43318    -0.80540     0.61780     1.96007     3.96025
item_1  2.32028     0.08169     1.50490     2.84717     4.84735
item_3  2.96229     0.72371     2.14692     3.48919     5.48937.
```

4 Beispielsyntax für Kapitel 6: Eindimensionale Modelle für metrische Antwortvariablen

4.1 Überblick Gesamtsyntax

Hinweis: Die Analysen in Eid und Schmidt (2014) wurden mit dem Computerprogramm Mplus durchgeführt. Im Folgenden wird gezeigt, wie entsprechende Analysen mit der Programmierumgebung R durchgeführt werden können. Unterschiede zu den Resultaten im Buch sind auf die unterschiedlichen Computerprogramme zurückführbar.

```
# Syntax Kapitel 6
library(memisc) # Für den Import von SPSS-Datei
library(psych)  # Für Schiefe und Kurtosis
library(semTools) # Nützliche Tools zur
                  # Strukturgleichungsmodellierung
library(MVN)    # Wird für Mardias Test auf multivariate
                  # Normalverteilung gebraucht
library(MBESS)  # Wird zur Schätzung von Konfidenzintervallen
                  # von Cronbachs alpha und McDonalds omega
                  # benötigt.

# *.sav-file einlesen
data<-as.data.set(spss.system.file('daten-kapitel-6.sav'))

# Umwandlung in den Typ data.frame
data<-data.frame(data)
```

```

# Auswahl der Items 1 bis 6 aus der Datenmatrix
data.mat<-data[,2:7]

# Berechnung der Stichprobenkovarianzmatrix
cov(data.mat)

# Berechnung der Stichprobenkorrelationsmatrix
cor(data.mat)

# Berechnung der Mittelwerte der Items
apply(data.mat,2,mean)

# Berechnung der Standardabweichungen der Items
apply(data.mat,2,sd)

# Berechnung der Schiefe der Items
apply(data.mat,2,skew)

# Berechnung der Kurtosis der Items
apply(data.mat,2,kurtosi)

# Mardia's Test auf multivariate Normalverteilung
mardiaTest(data.mat)

# Laden des Pakets lavaan
library(lavaan)

# Modell essentiell tau-äquivalenter Variablen
m1<-'eta=~item_1+1*item_2+1*item_3+1*item_4+1*item_5+1*item_6'
fit1<-sem(m1, data=data.mat, meanstructure=TRUE, estimator="MLR")
summary(fit1, fit.measures=TRUE, standardized=TRUE)

# Ausgabe der Konfidenzintervalle der Schätzer
parameterEstimates(fit1, ci=TRUE, level=0.95)

# Schätzung diverser Reliabilitätskoeffizienten
reliability(fit1)

# Schätzung von Cronbachs alpha inklusive
# des Konfidenzintervalls
ci.reliability(data.mat, type="alpha", conf.level=0.95)

# Multigruppenanalyse
measurementInvariance(m1, data, group="geschl")

# Modell tau-äquivalenter Variablen
m2<-'eta=~item_1+1*item_2+1*item_3+1*item_4+1*item_5+1*item_6
      item_1~v1*1
      item_2~v1*1
      item_3~v1*1
      item_4~v1*1
      item_5~v1*1
      item_6~v1*1'

fit2<-sem(m2, data=data.mat, meanstructure=TRUE, estimator="MLR")

```

```

summary(fit2, fit.measures=TRUE, standardized=TRUE)

# Modell essentiell tau-paralleler Variablen
m3<-'eta=~item_1+1*item_2+1*item_3+1*item_4+1*item_5+1*item_6
      item_1~~v1*item_1
      item_2~~v1*item_2
      item_3~~v1*item_3
      item_4~~v1*item_4
      item_5~~v1*item_5
      item_6~~v1*item_6'

fit3<-sem(m3, data=data.mat, meanstructure=TRUE, estimator="MLR")
summary(fit3, fit.measures=TRUE, standardized=TRUE)

# Modell tau-paralleler Variablen
m4<-'eta=~item_1+1*item_2+1*item_3+1*item_4+1*item_5+1*item_6
      item_1~v1*1
      item_2~v1*1
      item_3~v1*1
      item_4~v1*1
      item_5~v1*1
      item_6~v1*1
      item_1~~v2*item_1
      item_2~~v2*item_2
      item_3~~v2*item_3
      item_4~~v2*item_4
      item_5~~v2*item_5
      item_6~~v2*item_6'

fit4<-sem(m4, data=data.mat, meanstructure=TRUE, estimator="MLR")
summary(fit4, fit.measures=TRUE, standardized=TRUE)

# Das Modell tau-kongenerischer Variablen
m5<-'eta=~item_1+item_2+item_3+item_4+item_5+item_6'

fit5<-sem(m5, data=data.mat, meanstructure=TRUE, estimator="MLR")
summary(fit5, fit.measures=TRUE, standardized=TRUE)

# Modellvergleich
fit1_ml<-sem(m1, data=data.mat, meanstructure=TRUE)
fit2_ml<-sem(m2, data=data.mat, meanstructure=TRUE)
anova(fit1_ml, fit2_ml)

# Extraktion der Personenwerte (Faktorwerte)
predict(fit1)

```

4.2 Das Einlesen der Daten und die Berechnung einiger deskriptiver Statistiken

```

> library(memisc) # Für den Import von SPSS-Datei
> library(psych)  # Für Schiefe und Kurtosis
> library(semTools) # Nützliche Tools zur
                    # Strukturgleichungsmodellierung
> library(MVN)    # Wird für Mardia's Test auf multivariate
                    # Normalverteilung gebraucht
> library(MBESS)  # Wird zur Schätzung von Konfidenzintervallen

```

```
# von Cronbachs alpha und McDonalds omega
# benötigt.
```

Die SPSS-Datei wird eingelesen und in den Objekt-Typ `data.frame` umgewandelt. Zudem werden lediglich die Items (Spalten 2 bis 7) in das Objekt `data.mat` geschrieben. Die erste Spalte der Datei enthält die Variable Geschlecht, die anderen Spalten enthalten logarithmierte Reaktionszeiten.

```
> # *.sav-file einlesen
> data<-as.data.set(spss.system.file('daten-kapitel-6.sav'))

> # Umwandlung in den Typ data.frame
> data<-data.frame(data)

> # Auswahl der Items 1 bis 6 aus der Datenmatrix
> data.mat<-data[,2:7]

> # Berechnung der Stichprobenkovarianzmatrix
> cov(data.mat)

      item_1  item_2  item_3  item_4  item_5  item_6
item_1 0.12892429 0.06372098 0.06387506 0.06694482 0.04484940 0.05684147
item_2 0.06372098 0.13601262 0.06692212 0.06995322 0.06573506 0.05659685
item_3 0.06387506 0.06692212 0.15389888 0.08154838 0.06597039 0.06510418
item_4 0.06694482 0.06995322 0.08154838 0.16613492 0.07229804 0.07579945
item_5 0.04484940 0.06573506 0.06597039 0.07229804 0.14207685 0.05470620
item_6 0.05684147 0.05659685 0.06510418 0.07579945 0.05470620 0.14692864
```

Es wird die Stichprobenkovarianzmatrix der Items berechnet. Insgesamt zeigen sich positive Kovarianzen zwischen den Items.

```
> # Berechnung der Stichprobenkorrelationsmatrix
> cor(data.mat)

      item_1  item_2  item_3  item_4  item_5  item_6
item_1 1.0000000 0.4811999 0.4534675 0.4574242 0.3313810 0.4129949
item_2 0.4811999 1.0000000 0.4625539 0.4653585 0.4728744 0.4003589
item_3 0.4534675 0.4625539 1.0000000 0.5099964 0.4461385 0.4329502
item_4 0.4574242 0.4653585 0.5099964 1.0000000 0.4705810 0.4851570
item_5 0.3313810 0.4728744 0.4461385 0.4705810 1.0000000 0.3786358
item_6 0.4129949 0.4003589 0.4329502 0.4851570 0.3786358 1.0000000
```

Es wird die Stichprobenkorrelationsmatrix zwischen den Items berechnet. Insgesamt zeigen sich relativ hohe und homogene Interkorrelationen.

```
> apply(data.mat,2,mean)
> apply(data.mat,2,sd)
> apply(data.mat,2,skew)
> apply(data.mat,2,kurtosi)
```

Die Mittelwerte, Standardabweichung, Schiefe und die Kurtosis der Items werden berechnet.

4.3 Mardia's Test auf multivariate Normalverteilung

```
> mardiaTest(data.mat)

Mardia's Multivariate Normality Test
-----
data : data.mat

g1p          : 3.743293
chi.skew     : 148.484
p.value.skew : 2.624706e-10

g2p          : 52.6799
z.kurtosis   : 3.684338
p.value.kurt : 0.000229298

chi.small.skew : 150.8968
p.value.small  : 1.203472e-10

Result      : Data are not multivariate normal.
-----
```

Es werden Tests auf multivariate Normalverteilung durchgeführt. Die Tests auf multivariate Schiefe ($p.value.skew = 2.624706e-10$), multivariate Schiefe für kleine Stichproben ($p.value.small = 0.000229298$) und multivariate Kurtosis ($p.value.kurt = 0.000229298$) werden signifikant, so dass die Nullhypothese der multivariaten Normalverteilung verworfen werden muss.

4.4 Das Modell essenziell τ -äquivalenter Variablen

```
> m1<-'eta=~item_1+1*item_2+1*item_3+1*item_4+1*item_5+1*item_6'
```

Das Modell wird in der `lavaan`-Syntax mit einem String spezifiziert, der den Namen `m1` erhält. Die Terme `1*item_2` bis `1*item_6` geben zum Ausdruck, dass die Ladungen dieser Items auf 1 restringiert werden. Die Ladung des ersten Items wird per Voreinstellung auf den Wert 1 restringiert.

```
> fit1<-sem(m1, data=data.mat, meanstructure=TRUE, estimator="MLR")
```

Der Modell-String `m1` wird der Funktion `sem()` zusammen mit dem Namen der Datenmatrix übergeben. Das Argument `meanstructure=TRUE` bewirkt die Ausgabe der Leichtigkeitsparameter der itemspezifischen Regressionen. Zudem wurde die Maximum-Likelihood-Schätzung mit robusten Standardfehlern über `estimator="MLR"` angefordert. Mit dem Argument `estimator="ML"` kann die gewöhnliche Maximum-Likelihood-Schätzung angefordert werden.

```
> summary(fit1, fit.measures=TRUE, standardized=TRUE)
```

Das Ergebnis der Schätzung wird auf der Konsole ausgegeben. Über die Argumente `fit.measures=TRUE` und `standardized=TRUE` werden Fit-Statistiken und zusätzlich standardisierte Koeffizienten angefordert. Es wird sehr empfohlen, den Umgang mit dem Paket `lavaan` anhand dessen Dokumentation zu vertiefen.

```
lavaan (0.5-14) converged normally after 12 iterations
```

Number of observations	238	
Estimator	ML	Robust
Minimum Function Test Statistic	16.949	16.161
Degrees of freedom	14	14
P-value (Chi-square)	0.259	0.304
Scaling correction factor for the Yuan-Bentler correction		1.049

```
Model test baseline model:
```

Minimum Function Test Statistic	435.847	424.389
Degrees of freedom	15	15
P-value	0.000	0.000

```
Full model versus baseline model:
```

Comparative Fit Index (CFI)	0.993	0.995
Tucker-Lewis Index (TLI)	0.992	0.994

```
Loglikelihood and Information Criteria:
```

Loglikelihood user model (H0)	-435.870	-435.870
Scaling correction factor for the MLR correction		1.127
Loglikelihood unrestricted model (H1)	-427.396	-427.396
Scaling correction factor for the MLR correction		1.087
Number of free parameters	13	13
Akaike (AIC)	897.740	897.740
Bayesian (BIC)	942.880	942.880
Sample-size adjusted Bayesian (BIC)	901.674	901.674

```
Root Mean Square Error of Approximation:
```

RMSEA		0.030	0.025
90 Percent Confidence Interval	0.000	0.073	0.000 0.069
P-value RMSEA <= 0.05		0.737	0.781

```
Standardized Root Mean Square Residual:
```

SRMR	0.053	0.053
------	-------	-------

Informationen zur Konvergenz und eine Auswahl an Fit-Indizes und Fit-Statistiken werden ausgegeben. Insgesamt zeigt sich eine recht gute Passung des Modells. Ferner werden die geschätzten Parameter ausgegeben.

Parameter estimates:

Information				Observed		
Standard Errors				Robust.huber.white		
	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Latent variables:						
eta =~						
item_1	1.000				0.253	0.682
item_2	1.000				0.253	0.689
item_3	1.000				0.253	0.664
item_4	1.000				0.253	0.656
item_5	1.000				0.253	0.657
item_6	1.000				0.253	0.650

Alle Ladungen der Items wurden auf 1 fixiert, daher werden keine Standardfehler und entsprechende z-Statistiken nach Wald ausgegeben. In der Spalte `Std.lv` sind die Ladungen angegeben, die auf Basis der auf eine Varianz von 1 standardisierten latenten Variable berechnet wurden. Die Spalte `Std.all` gibt die Ladungen an, die sich ergeben, wenn alle Variablen standardisiert werden. Diese entsprechen den Korrelationen der Items mit der latenten Variablen.

	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Intercepts:						
item_1	1.504	0.023	64.757	0.000	1.504	4.047
item_2	1.423	0.024	59.647	0.000	1.423	3.870
item_3	1.392	0.025	54.862	0.000	1.392	3.647
item_4	1.305	0.026	49.486	0.000	1.305	3.376
item_5	1.346	0.024	55.221	0.000	1.346	3.488
item_6	1.306	0.025	52.662	0.000	1.306	3.350
eta	0.000				0.000	0.000

Die Intercepts sind die geschätzten Itemleichtigkeiten. Wald-Tests zur Überprüfung der Hypothese, dass die entsprechenden Parameter in der Population gleich 0 sind, und die standardisierten Lösungen werden ausgegeben. Der Mittelwert der latenten Variablen (`eta`) ist auf 0 fixiert.

	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Variances:						
item_1	0.074	0.008			0.074	0.535
item_2	0.071	0.008			0.071	0.525
item_3	0.081	0.009			0.081	0.559
item_4	0.085	0.010			0.085	0.570
item_5	0.085	0.010			0.085	0.569
item_6	0.088	0.009			0.088	0.577
eta	0.064	0.011			1.000	1.000

Die geschätzten Varianzen der Items sowie deren Standardfehler und die standardisierten Koeffizienten werden ausgegeben. Im Rahmen der Klassischen Testtheorie sind diese Varianzen die Fehlervarianzen der Items. Die vollständig standardisierte Lösung (`Std.all`) ist hier von besonderem Interesse, da sich auf ihrer Basis die Item-Reliabilität berechnen lässt ($Rel(\text{Item } 1) = 1 - 0.535$, etc.).

```
> parameterEstimates(fit1, ci=TRUE, level=0.95)
```

Die Parameterschätzer werden separat angefordert. Die 95%-Konfidenzintervalle der geschätzten Parameter werden über die Argumente `ci=TRUE` und `level=0.95` zusätzlich ausgegeben.

	lhs	op	rhs	est	se	z	pvalue	ci.lower	ci.upper
1	eta	==	item_1	1.000	0.000	NA	NA	1.000	1.000
2	eta	==	item_2	1.000	0.000	NA	NA	1.000	1.000
3	eta	==	item_3	1.000	0.000	NA	NA	1.000	1.000
4	eta	==	item_4	1.000	0.000	NA	NA	1.000	1.000
5	eta	==	item_5	1.000	0.000	NA	NA	1.000	1.000
6	eta	==	item_6	1.000	0.000	NA	NA	1.000	1.000
7	item_1	~~	item_1	0.074	0.008	9.383	0	0.058	0.089
8	item_2	~~	item_2	0.071	0.008	9.197	0	0.056	0.086
9	item_3	~~	item_3	0.081	0.009	9.544	0	0.065	0.098
10	item_4	~~	item_4	0.085	0.010	8.584	0	0.066	0.105
11	item_5	~~	item_5	0.085	0.010	8.908	0	0.066	0.103
12	item_6	~~	item_6	0.088	0.009	9.564	0	0.070	0.106
13	eta	~~	eta	0.064	0.011	5.822	0	0.043	0.086
14	item_1	~1		1.504	0.023	64.757	0	1.458	1.550
15	item_2	~1		1.423	0.024	59.647	0	1.376	1.470
16	item_3	~1		1.392	0.025	54.862	0	1.342	1.442
17	item_4	~1		1.305	0.026	49.486	0	1.253	1.356
18	item_5	~1		1.346	0.024	55.221	0	1.299	1.394
19	item_6	~1		1.306	0.025	52.662	0	1.257	1.354
20	eta	~1		0.000	0.000	NA	NA	0.000	0.000

In den ersten drei Spalten werden die geschätzten Parameter in der lavaan-Syntax zur Modellspezifikation dargestellt. Die folgenden Spalten enthalten die Schätzer der entsprechenden Komponenten (`est`), die geschätzten Standardfehler (`se`), die z - und p -Werte (`z`, `pvalue`) sowie die angeforderten Konfidenzintervalle (`ci.lower`, `ci.upper`). Ein `NA` gibt an, dass ein entsprechender Wert aufgrund der Modellspezifikation nicht geschätzt wurde. Dies macht Sinn, da im vorliegenden Modell die Ladungen auf 1 fixiert wurden.

```
> reliability(fit1)
      alpha      omega      omega2      omega3
0.8275283 0.8269606 0.8269606 0.8247808
```

Die Reliabilitätskoeffizienten werden ausgegeben. Diese sind Cronbachs α (`alpha`), Raykovs ω (`omega`), Bentlers ω (`omega2`) und McDonalds ω (`omega3`). Nähere Informationen inklusive Formeln und Literatur finden sich in der R-Hilfe (`?reliability`). Für das Modell der essenziell τ -äquivalenten Messung ist lediglich Cronbachs α von Belang. Im Gegensatz zu den im Lehrbuch berichteten Koeffizienten wird bei der Berechnung dieser Koeffizienten z.T. nicht auf die vom Modell implizierten Varianzen und Kovarianzen zurückgegriffen, sondern auf die beobachteten Varianzen und Kovarianzen, wodurch sich Unterschiede ergeben.

```
> ci.reliability(data.mat, type="alpha", conf.level=0.95)
```

```

$est
[1] 0.8275283

$se
[1] 0.01738553

$ci.lower
[1] 0.7934532

$ci.upper
[1] 0.8616033

$conf.level
[1] 0.95

$est.type
[1] "alpha"

$analysis.type
[1] "analytic"

$interval.type
[1] "normal-theory"

$call
ci.reliability(data = data.mat, type = "alpha", conf.level = 0.95)

$boot
NULL

```

Im Paket MBESS befindet sich die Funktion `ci.reliability()`, mit der sich Konfidenzintervalle für Reliabilitätskoeffizienten berechnen lassen. Diese Funktion bietet zahlreiche Zusatzoptionen, die der Dokumentation der Funktion entnommen werden können (`?ci.reliability()`). Hier wird das 95%-Konfidenzintervall für Cronbachs α angefordert.

Multigruppenanalyse

```
> measurementInvariance(m1, data, group="geschl")
```

Zur Prüfung der Messinvarianz in unterschiedlichen Subgruppen (hier Geschlecht), wird eine Mehrgruppenanalyse durchgeführt.

```

Multig Measurement invariance tests:
Model 1: configural invariance:
  chisq      df  pvalue      cfi   rmsea      bic
  27.735  28.000   0.479   1.000   0.000  994.493

Model 2: weak invariance (equal loadings):
  chisq      df  pvalue      cfi   rmsea      bic
  27.735  28.000   0.479   1.000   0.000  994.493

```

```
[Model 1 versus model 2]
delta.chisq      delta.df delta.p.value
      0             0             1
delta.cfi
      0
```

Das Modell der konfiguralen Invarianz (identische Faktorstruktur in den Subgruppen) wird gegen das Modell der *schwachen Invarianz* (identische Faktorladungen in den Subgruppen) getestet. Im vorliegenden Fall sind beide Modelle identisch, da die Faktorladungen auf 1 fixiert wurden.

Model 3: strong invariance (equal loadings + intercepts):

```
chisq      df  pvalue      cfi  rmsea      bic
35.089  33.000  0.369    0.995  0.023  974.485
```

```
[Model 1 versus model 3]
delta.chisq      delta.df delta.p.value
      7.354             5.000      0.196
delta.cfi
      0.005
```

```
[Model 2 versus model 3]
delta.chisq      delta.df delta.p.value
      7.354             5.000      0.196
delta.cfi
      0.005
```

Das Modell der *starken Invarianz* (identische Ladungen und Itemleichtigkeiten in den Subgruppen) wird angepasst. Dieses Modell entspricht der Annahme der Gleichheit der Leichtigkeitparamter des Modells essenziell τ -äquivalenter Variablen in beiden Subpopulationen. Dieses Modell (Modell 3) wird gegen das Modell der konfiguralen Invarianz (Modell 1) und das Modell der schwachen Invarianz (Modell 2) getestet. Beide Tests werden nicht signifikant.

Model 4: equal loadings + intercepts + means:

```
chisq      df  pvalue      cfi  rmsea      bic
35.999  34.000  0.375    0.995  0.022  969.922
```

```
[Model 1 versus model 4]
delta.chisq      delta.df delta.p.value
      8.264             6.000      0.219
delta.cfi
      0.005
```

```
[Model 3 versus model 4]
delta.chisq      delta.df delta.p.value
      0.91             1.00      0.34
delta.cfi
      0.00
```

Das Modell der *strikten Invarianz* (identische Ladungen, Itemleichtigkeiten und Varianzen) wird angepasst und gegen die Modelle 1 und 3 getestet. Beide Tests werden nicht signifikant. Aus diesen Modellvergleichen lässt sich schließen, dass das Modell der strikten Invarianz in den Geschlechtsgruppen die Daten am sparsamsten erklärt. Für nähere Hinweise und weiterführende Literatur sei auf die R-Hilfe der Funktion verwiesen (`?measurementInvariance`).

4.5 Das Modell τ -äquivalenter Variablen

```
# Modell tau-äquivalenter Variablen
m2<- 'eta~item_1+1*item_2+1*item_3+1*item_4+1*item_5+1*item_6
      item_1~v1*1
      item_2~v1*1
      item_3~v1*1
      item_4~v1*1
      item_5~v1*1
      item_6~v1*1'

fit2<-sem(m2, data=data.mat, meanstructure=TRUE)
summary(fit2)
```

Bei der Verwendung des Modells τ -äquivalenter Messung wird davon ausgegangen, dass die Ladungen der Items alle 1 sind und dass die Items identische Leichtigkeitsparameter besitzen. Die Fehlervarianzen können frei variieren. Die Spezifikation der Restriktion der identischen Leichtigkeitsparameter der Items erfolgt durch folgenden Syntax-Block:

```
item_1~v1*1
item_2~v1*1
item_3~v1*1
item_4~v1*1
item_5~v1*1
item_6~v1*1
```

`v1` ist ein sogenanntes Parameter-Label. Da die Syntax-Zeilen für alle Items dasselbe Label verwenden, werden für jedes Item identische Leichtigkeitsparameter (Achsenabschnitte) geschätzt. Details sind der `lavaan`-Dokumentation zu entnehmen.

```
> fit2<-sem(m2, data=data.mat, meanstructure=TRUE, estimator="MLR")
```

Das Modell wird an die Daten angepasst. Es werden die Leichtigkeitsparameter (Achsenabschnitte) angefordert (`meanstructure=TRUE`).

```
> summary(fit2, fit.measures=TRUE, standardized=TRUE)
```

Es werden zusätzlich zu den geschätzten Parametern die Fit-Statistiken und die standardisierten Lösungen ausgegeben.

lavaan (0.5-14) converged normally after 16 iterations

Number of observations	238	
Estimator	ML	Robust
Minimum Function Test Statistic	100.116	95.652
Degrees of freedom	19	19
P-value (Chi-square)	0.000	0.000
Scaling correction factor for the Yuan-Bentler correction		1.047

Model test baseline model:

Minimum Function Test Statistic	435.847	424.389
Degrees of freedom	15	15
P-value	0.000	0.000

Full model versus baseline model:

Comparative Fit Index (CFI)	0.807	0.813
Tucker-Lewis Index (TLI)	0.848	0.852

Loglikelihood and Information Criteria:

Loglikelihood user model (H0)	-477.454	-477.454
Scaling correction factor for the MLR correction		1.182
Loglikelihood unrestricted model (H1)	-427.396	-427.396
Scaling correction factor for the MLR correction		1.087
Number of free parameters	8	8
Akaike (AIC)	970.908	970.908
Bayesian (BIC)	998.686	998.686
Sample-size adjusted Bayesian (BIC)	973.329	973.329

Root Mean Square Error of Approximation:

RMSEA		0.134	0.130
90 Percent Confidence Interval	0.109	0.160	0.105 0.156
P-value RMSEA <= 0.05		0.000	0.000

Standardized Root Mean Square Residual:

SRMR	0.111	0.111
------	-------	-------

Insgesamt deuten die Fit-Statistiken darauf hin, dass die Annahme identischer Leichtigkeitsparameter zu restriktiv ist und die Daten nicht gut beschreibt.

Information		Observed				
Standard Errors		Robust.huber.white				
	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Latent variables:						
eta =~						
item_1	1.000				0.252	0.637

item_2	1.000	0.252	0.683
item_3	1.000	0.252	0.663
item_4	1.000	0.252	0.639
item_5	1.000	0.252	0.655
item_6	1.000	0.252	0.634

Die Ladungen aller Items wurden auf 1 fixiert, von daher wurden keine Parameter geschätzt.

		Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Intercepts:							
item_1	(v1)	1.381	0.019	72.678	0.000	1.381	3.485
item_2	(v1)	1.381	0.019	72.678	0.000	1.381	3.736
item_3	(v1)	1.381	0.019	72.678	0.000	1.381	3.630
item_4	(v1)	1.381	0.019	72.678	0.000	1.381	3.496
item_5	(v1)	1.381	0.019	72.678	0.000	1.381	3.585
item_6	(v1)	1.381	0.019	72.678	0.000	1.381	3.471
eta		0.000				0.000	0.000

Konsistent mit der Modellspezifikation sind die geschätzten Leichtigkeitsparameter identisch. Der Mittelwert der latenten Variablen ist per Voreinstellung auf 0 fixiert.

		Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Variances:							
item_1		0.093	0.011			0.093	0.594
item_2		0.073	0.008			0.073	0.534
item_3		0.081	0.009			0.081	0.560
item_4		0.092	0.009			0.092	0.592
item_5		0.085	0.009			0.085	0.571
item_6		0.095	0.009			0.095	0.598
eta		0.064	0.011			1.000	1.000

Die geschätzten Fehlervarianzen der Items und die Varianz der latenten Variablen, die Standardfehler sowie die standardisierten Lösungen werden ausgegeben.

Weitere Anmerkungen

Natürlich können die Funktionen zur Berechnung der Reliabilitätskoeffizienten und der Konfidenzintervalle dieser Koeffizienten, die im Rahmen des Modells essenziell τ -äquivalenter Variablen behandelt wurden, auch auf das Modell τ -äquivalenter Variablen angewendet werden. Gleiches gilt für die Berechnung der Konfidenzintervalle der Schätzer und die weiteren Modelle, die im Folgenden dargestellt werden.

4.6 Das Modell essenziell τ -paralleler Messung

```
> m3<-'eta=~item_1+1*item_2+1*item_3+1*item_4+1*item_5+1*item_6
  item_1~~v1*item_1
  item_2~~v1*item_2
  item_3~~v1*item_3
  item_4~~v1*item_4
  item_5~~v1*item_5'
```

```
item_6~~v1*item_6'
```

Bei der Verwendung des Modells essenziell τ -paralleler Messung wird davon ausgegangen, dass die Fehlervarianzen der Items identisch sind. Die Leichtigkeitsparameter können frei variieren und die Ladungen sind alle gleich 1.

Die Restriktion der Fehlervarianzen erfolgt über den Syntax-Block:

```
item_1~~v1*item_1
item_2~~v1*item_2
item_3~~v1*item_3
item_4~~v1*item_4
item_5~~v1*item_5
item_6~~v1*item_6
```

Es wird ein Parameter-Label `v1` verwendet, was zur Folge hat, dass die geschätzten Fehlervarianzen der einzelnen Items identisch sind.

```
> fit3<-sem(m3, data=data.mat, meanstructure=TRUE, estimator="MLR")
> summary(fit3, fit.measures=TRUE, standardized=TRUE)
```

Das Modell wird an die Daten angepasst, und eine detaillierte Ausgabe wird angefordert.

Estimator	ML	Robust
Minimum Function Test Statistic	19.886	19.166
Degrees of freedom	19	19
P-value (Chi-square)	0.401	0.446
Scaling correction factor for the Yuan-Bentler correction		1.038

Model test baseline model:

Minimum Function Test Statistic	435.847	424.389
Degrees of freedom	15	15
P-value	0.000	0.000

Full model versus baseline model:

Comparative Fit Index (CFI)	0.998	1.000
Tucker-Lewis Index (TLI)	0.998	1.000

Loglikelihood and Information Criteria:

Loglikelihood user model (H0)	-437.339	-437.339
Scaling correction factor for the MLR correction		1.203
Loglikelihood unrestricted model (H1)	-427.396	-427.396
Scaling correction factor for the MLR correction		1.087
Number of free parameters	8	8

Akaike (AIC)	890.677	890.677
Bayesian (BIC)	918.455	918.455
Sample-size adjusted Bayesian (BIC)	893.098	893.098

Root Mean Square Error of Approximation:

RMSEA	0.014	0.006
90 Percent Confidence Interval	0.000 0.059	0.000 0.056
P-value RMSEA <= 0.05	0.884	0.908

Standardized Root Mean Square Residual:

SRMR	0.059	0.059
------	-------	-------

Insgesamt deuten die Fit-Statistiken darauf hin, dass das Modell gut passt.

Parameter estimates:

Information			Observed			
Standard Errors			Robust.huber.white			
	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Latent variables:						
eta =~						
item_1	1.000				0.254	0.667
item_2	1.000				0.254	0.667
item_3	1.000				0.254	0.667
item_4	1.000				0.254	0.667
item_5	1.000				0.254	0.667
item_6	1.000				0.254	0.667

Gemäß der Modellspezifikation sind alle Diskriminationsparameter (Ladungen) auf 1 fixiert.

	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Intercepts:						
item_1	1.504	0.023	64.757	0.000	1.504	3.949
item_2	1.423	0.024	59.647	0.000	1.423	3.736
item_3	1.392	0.025	54.862	0.000	1.392	3.655
item_4	1.305	0.026	49.486	0.000	1.305	3.426
item_5	1.346	0.024	55.221	0.000	1.346	3.535
item_6	1.306	0.025	52.662	0.000	1.306	3.428
eta	0.000				0.000	0.000

Die geschätzten Itemleichtigkeiten dürfen variieren. Insgesamt ist Item 1 am leichtesten. Per Voreinstellung ist der Mittelwert der latenten Variablen auf 0 fixiert.

	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Variances:						
item_1 (v1)	0.081	0.004			0.081	0.556
item_2 (v1)	0.081	0.004			0.081	0.556
item_3 (v1)	0.081	0.004			0.081	0.556
item_4 (v1)	0.081	0.004			0.081	0.556
item_5 (v1)	0.081	0.004			0.081	0.556
item_6 (v1)	0.081	0.004			0.081	0.556
eta	0.064	0.011			1.000	1.000

In Einklang mit der Modellspezifikation sind die geschätzten Fehlervarianzen der Items identisch.

4.7 Das Modell τ -paralleler Variablen

```
> m4<-'eta=~item_1+1*item_2+1*item_3+1*item_4+1*item_5+1*item_6
  item_1~v1*1
  item_2~v1*1
  item_3~v1*1
  item_4~v1*1
  item_5~v1*1
  item_6~v1*1
  item_1~~v2*item_1
  item_2~~v2*item_2
  item_3~~v2*item_3
  item_4~~v2*item_4
  item_5~~v2*item_5
  item_6~~v2*item_6'
```

Die Verwendung des Modells τ -paralleler Messung impliziert die Annahme der Gleichheit der Fehlervarianzen und der Leichtigkeitsparameter (Intercepts). Zur Spezifikation dieser Restriktionen werden die Intercepts (z.B. `item_1~v1*1`) und die Varianzkomponenten (z.B. `item_1~~v2*item_1`) mithilfe von jeweils zwei Wertelabels (`v1` und `v2`) gleichgesetzt.

```
> fit4<-sem(m4, data=data.mat, meanstructure=TRUE, estimator="MLR")
> summary(fit4, fit.measures=TRUE, standardized=TRUE)
```

Das Modell wird an die Daten angepasst, und eine detaillierte Ausgabe wird angefordert.

Estimator	ML	Robust
Minimum Function Test Statistic	104.462	101.211
Degrees of freedom	24	24
P-value (Chi-square)	0.000	0.000
Scaling correction factor for the Yuan-Bentler correction		1.032

Model test baseline model:

Minimum Function Test Statistic	435.847	424.389
Degrees of freedom	15	15
P-value	0.000	0.000

Full model versus baseline model:

Comparative Fit Index (CFI)	0.809	0.811
Tucker-Lewis Index (TLI)	0.881	0.882

Loglikelihood and Information Criteria:

Loglikelihood user model (H0)	-479.627	-479.627
Scaling correction factor		1.523

```

for the MLR correction
Loglikelihood unrestricted model (H1)      -427.396      -427.396
Scaling correction factor                    1.087
for the MLR correction

Number of free parameters                    3            3
Akaike (AIC)                                965.254      965.254
Bayesian (BIC)                              975.670      975.670
Sample-size adjusted Bayesian (BIC)        966.161      966.161

```

Root Mean Square Error of Approximation:

```

RMSEA                                       0.119        0.116
90 Percent Confidence Interval             0.096 0.142   0.094 0.140
P-value RMSEA <= 0.05                     0.000        0.000

```

Standardized Root Mean Square Residual:

```

SRMR                                       0.109        0.109

```

Insgesamt zeigt sich eine sehr schlechte Passung des Modells.

Parameter estimates:

```

Information                                Observed
Standard Errors                            Robust.huber.white

          Estimate  Std.err  Z-value  P(>|z|)  Std.lv  Std.all
Latent variables:
eta =~
  item_1          1.000          0.252    0.650
  item_2          1.000          0.252    0.650
  item_3          1.000          0.252    0.650
  item_4          1.000          0.252    0.650
  item_5          1.000          0.252    0.650
  item_6          1.000          0.252    0.650

```

Gemäß der Modellspezifikation sind alle Ladungen auf 1 restringiert.

```

          Estimate  Std.err  Z-value  P(>|z|)  Std.lv  Std.all
Intercepts:
  item_1 (v1)     1.379    0.018   76.247   0.000    1.379   3.561
  item_2 (v1)     1.379    0.018   76.247   0.000    1.379   3.561
  item_3 (v1)     1.379    0.018   76.247   0.000    1.379   3.561
  item_4 (v1)     1.379    0.018   76.247   0.000    1.379   3.561
  item_5 (v1)     1.379    0.018   76.247   0.000    1.379   3.561
  item_6 (v1)     1.379    0.018   76.247   0.000    1.379   3.561
  eta           0.000          0.000    0.000

```

Die geschätzten Itemleichtigkeiten sind aufgrund der Modellrestriktion alle identisch.

```

          Estimate  Std.err  Z-value  P(>|z|)  Std.lv  Std.all
Variances:
  item_1 (v2)     0.087    0.004          0.087   0.577
  item_2 (v2)     0.087    0.004          0.087   0.577
  item_3 (v2)     0.087    0.004          0.087   0.577
  item_4 (v2)     0.087    0.004          0.087   0.577
  item_5 (v2)     0.087    0.004          0.087   0.577

```

item_6	(v2)	0.087	0.004	0.087	0.577
eta		0.063	0.011	1.000	1.000

Die geschätzten Fehlervarianzen der Items sind aufgrund der Modellrestriktion alle identisch.

4.8 Das Modell τ -kongenerischer Variablen

```
> m5<-'eta=~item_1+item_2+item_3+item_4+item_5+item_6'
```

Das Modell τ -kongenerischer Messung ist das allgemeinste der vorgestellten Messmodelle für kontinuierliche abhängige Variablen. Die Fehlervarianzen, Ladungen und Leichtigkeitparameter werden frei geschätzt.

```
> fit5<-sem(m5, data=data.mat, meanstructure=TRUE)
> summary(fit5, fit.measures=TRUE, standardized=TRUE)
```

Das Modell wird an die Daten angepasst, und eine detaillierte Ausgabe wird angefordert.

Minimum Function Test Statistic	9.568	8.894
Degrees of freedom	9	9
P-value (Chi-square)	0.387	0.447
Scaling correction factor for the Yuan-Bentler correction		1.076

Model test baseline model:

Minimum Function Test Statistic	435.847	424.389
Degrees of freedom	15	15
P-value	0.000	0.000

Full model versus baseline model:

Comparative Fit Index (CFI)	0.999	1.000
Tucker-Lewis Index (TLI)	0.998	1.000

Loglikelihood and Information Criteria:

Loglikelihood user model (H0)	-432.180	-432.180
Scaling correction factor for the MLR correction		1.092
Loglikelihood unrestricted model (H1)	-427.396	-427.396
Scaling correction factor for the MLR correction		1.087
Number of free parameters	18	18
Akaike (AIC)	900.360	900.360
Bayesian (BIC)	962.861	962.861
Sample-size adjusted Bayesian (BIC)	905.806	905.806

Root Mean Square Error of Approximation:

RMSEA		0.016	0.000	
90 Percent Confidence Interval	0.000	0.076	0.000	0.070
P-value RMSEA <= 0.05		0.763	0.815	

Standardized Root Mean Square Residual:

SRMR	0.021	0.021
------	-------	-------

Die Fit-Indizes zeigen insgesamt eine gute Passung des Modells.

Parameter estimates:

Information				Observed		
Standard Errors				Robust.huber.white		
	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Latent variables:						
eta =~						
item_1	1.000				0.229	0.638
item_2	1.098	0.123	8.925	0.000	0.251	0.682
item_3	1.194	0.146	8.163	0.000	0.273	0.697
item_4	1.294	0.158	8.213	0.000	0.296	0.728
item_5	1.032	0.146	7.053	0.000	0.236	0.628
item_6	1.049	0.149	7.037	0.000	0.240	0.628

Die geschätzten Ladungen, die Standardfehler, entsprechende z-Tests und die standardisierten Koeffizienten werden ausgegeben.

Intercepts:						
item_1	1.504	0.023	64.757	0.000	1.504	4.198
item_2	1.423	0.024	59.647	0.000	1.423	3.866
item_3	1.392	0.025	54.862	0.000	1.392	3.556
item_4	1.305	0.026	49.486	0.000	1.305	3.208
item_5	1.346	0.024	55.221	0.000	1.346	3.579
item_6	1.306	0.025	52.662	0.000	1.306	3.414
eta	0.000				0.000	0.000

Die geschätzten Leichtigkeitsparameter und der auf 0 fixierte Mittelwert der Verteilung der latenten Variablen werden ausgegeben.

Variances:						
item_1	0.076	0.008			0.076	0.593
item_2	0.072	0.008			0.072	0.534
item_3	0.079	0.009			0.079	0.514
item_4	0.078	0.010			0.078	0.471
item_5	0.086	0.010			0.086	0.606
item_6	0.089	0.010			0.089	0.606
eta	0.052	0.014			1.000	1.000

Die geschätzten Varianzen der Items und die Varianzen der latenten Variablen werden ausgegeben.

4.9 Modellvergleiche mittels Likelihood-Quotienten-Tests

```
> fit1_ml<-sem(m1, data=data.mat, meanstructure=TRUE)
> fit2_ml<-sem(m2, data=data.mat, meanstructure=TRUE)
> anova(fit1_ml, fit2_ml)
```

Mit der Funktion `anova()` können Likelihood-Quotienten-Tests durchgeführt werden, die es erlauben zu prüfen, ob ein Modell A die Daten besser beschreibt als ein Modell B, sofern die Modelle ineinander verschachtelt sind bzw. durch Parameter-Restriktionen ineinander überführbar sind. Zudem müssen beide Modelle mit der Maximum-Likelihood-Methode angepasst worden sein. Für die MLR-Methoden muss auf die bei Eid und Schmidt (2014, Abschnitt 6.4.5.1.2) beschriebene Korrektur zurückgegriffen werden. Hier wird ein Vergleich des Modells essenziell τ -äquivalenter Variablen mit einem Modell τ -äquivalenter Variablen vorgenommen. Es interessiert, ob das Modell mit mehr Parametern, also das Modell essenziell τ -äquivalenter Variablen, die Daten besser beschreibt als das Modell τ -äquivalenter Variablen.

Chi Square Difference Test

```

      Df    AIC    BIC   Chisq Chisq diff
fit1_ml 14 897.74 942.88  16.949
fit2_ml 19 970.91 998.69 100.116      83.168
      Df diff Pr(>Chisq)
fit1_ml
fit2_ml      5 < 2.2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

In der Ausgabe werden die Freiheitsgrade, die informationstheoretischen Indizes AIC und BIC, die χ^2 -Teststatistik des jeweiligen Modells, die Differenz der χ^2 -Quadrat-Statistiken und die Parameterdifferenz sowie die Überschreitungswahrscheinlichkeit angegeben. Alle Angaben beziehen sich auf die ML-Methode.

Das Ergebnis des Tests legt nahe, dass das Modell der essenziell τ -äquivalenten Variablen die Daten besser beschreibt als das Modell der τ -äquivalenten Variablen. Dies zeigt auch der AIC-Koeffizient an.

Die informationstheoretischen Indizes sprechen allerdings eher für eine Präferenz des sparsameren Modells.

4.10 Schätzung der Personenwerte

```
> predict(fit1)
```

Es werden die Personenwerte (Faktorwerte) des Modells essenziell τ -äquivalenter Variablen (Objekt `fit1`) geschätzt.


```

      eta
[1,] 0.132
[2,] 0.261
[3,] 0.004
[4,] -0.006
[5,] -0.245
[6,] -0.205
[7,] 0.441
[...]
```

5 Beispielsyntax für Kapitel 7: Einführung in mehrdimensionale Testmodelle

Das Paket `lavaan` kann zur Schätzung mehrdimensionaler Modelle verwendet werden, sofern das Messmodell mit der konfirmatorischen Faktorenanalyse kompatibel ist.

Mehrdimensionale Modelle mit ordinalen und kontinuierlichen Variablen und Mehrkomponentenmodelle, wie z.B. Latent-State-Trait-Modelle gehören zu dieser Klasse.

Die explorative Faktorenanalyse für ordinale Daten kann mit der Software Mplus durchgeführt werden. Aber auch die Funktion `fa()` im Paket `psych` eignet sich für die Analyse, sofern diese auf der polychorischen Korrelationsmatrix aufbaut.

5.1 Überblick Gesamtsyntax

```

# Syntax Kapitel 7
library(lavaan)
library(memisc)

## Zweifaktorielles Modell der emotionalen Klarheit
data1<-
as.data.set(spss.system.file('kapitel_7_beispiel_1_emotionale_klarhe
it.sav'))

# Umwandlung in den Typ data.frame
data1<-data.frame(data1)

m_emo<-'rakt=~reakt_1+1*reakt_2+1*reakt_3+1*reakt_4+
1*reakt_5+1*reakt_6
klar=~1*kla_th1+1*kla_th2
reakt_1~~v1*reakt_1
reakt_2~~v1*reakt_2
reakt_3~~v1*reakt_3
reakt_4~~v1*reakt_4
reakt_5~~v1*reakt_5
reakt_6~~v1*reakt_6
kla_th1~~v2*kla_th1
kla_th2~~v2*kla_th2'
```

```

fit_emo<-sem(m_emo, data=data1, meanstructure=TRUE, estimator="MLR")
summary(fit_emo, fit.measures=TRUE, standardized=TRUE)

## Multikomponenten-Modell
# Einlesen der Daten
data2<-read.table("kapitel_7_lst_beispiel.dat", col.names=c("Y1",
"Y2", "Y3","Y4"))

m_lst<-'eta1=~Y1+1*Y2+1*Y3+1*Y4
      eta2=~Y1 + 1*Y2
      eta3=~Y3 + 1*Y4
      eta1~~0*eta2
      eta1~~0*eta3
      eta2~~0*eta3
      Y1~~v*Y1
      Y2~~v*Y2
      Y3~~v*Y3
      Y4~~v*Y4'

fit_lst<-sem(m_lst, data=data2, meanstructure=TRUE, estimator="MLR")
summary(fit_lst, fit.measures=TRUE, standardized=TRUE)

## Exploratorische Faktorenanalyse (Alternative: Mplus)
# Einlesen der Daten
data3<-
as.data.set(spss.system.file('kapitel_7_beispiel_exploratorische_fak
torenanalyse.sav'))
data3<-data.frame(data3)

N=dim(data3) [1]

# Laden der benötigten Pakete
library(psych)
library(polycor)
library(GPARotation)

# Schätzung der polychorischen Korrelationsmatrix
poly_cor<-polychoric(data3)

# Ausgabe der Ergebnisse
# (Korrelations-Matrix und Schwellen tau)
print(poly_cor)

# Durchführung der Analyse mit Oblimin-Rotation
faPC <- fa(r=poly_cor$rho, nfactors=2,n.obs=N, rotate="oblimin")

# Darstellung der Ergebnisse
print(faPC)

```

5.2 Zweidimensionales Modell zur Analyse der emotionalen Klarheit

Das Laden von Daten wurde in vorherigen Abschnitten beschrieben, von daher wird hier nicht mehr darauf eingegangen.

```

m_emo<- 'rakt=~reakt_1+1*reakt_2+1*reakt_3+1*reakt_4+
1*reakt_5+1*reakt_6
klar=~1*kla_th1+1*kla_th2
reakt_1~~v1*reakt_1
reakt_2~~v1*reakt_2
reakt_3~~v1*reakt_3
reakt_4~~v1*reakt_4
reakt_5~~v1*reakt_5
klar_th1~~v2*klar_th1
klar_th2~~v2*klar_th2'

```

In dem spezifizierten Modell wird davon ausgegangen, dass die logarithmierten Reaktionszeiten und die Selbstratings jeweils auf einen Faktor laden, wobei jeweils essenzielle τ -Äquivalenz vorliegt. Die zwei latenten Variablen können miteinander kovariieren.

In der Syntax werden zwei Faktoren definiert. Die Items `reakt_1` bis `reakt_6` laden jeweils auf dem Faktor `reakt` und die Items `kla_th1` und `kla_th2` laden jeweils auf dem Faktor `klar`. Per Standardeinstellung wird die Kovarianz zwischen den latenten Variablen geschätzt.

Weiterhin wurden die Fehlervarianzen der konstruktsspezifischen Items jeweils gleichgesetzt, sodass zwei Modelle essenziell τ -paralleler Variablen vorliegen.

```

> fit_emo<-sem(m_emo, data=data1, meanstructure=TRUE,
estimator="MLR")
> summary(fit_emo, fit.measures=TRUE, standardized=TRUE)

```

lavaan (0.5-14) converged normally after 28 iterations

Number of observations	238	
Estimator	ML	Robust
Minimum Function Test Statistic	23.560	23.223
Degrees of freedom	31	31
P-value (Chi-square)	0.828	0.841
Scaling correction factor		1.015
for the Yuan-Bentler correction		

Model test baseline model:

Minimum Function Test Statistic	666.758	649.897
Degrees of freedom	28	28
P-value	0.000	0.000

Full model versus baseline model:

Comparative Fit Index (CFI)	1.000	1.000
Tucker-Lewis Index (TLI)	1.011	1.011

Loglikelihood and Information Criteria:

Loglikelihood user model (H0)	-1283.975	-1283.975
Scaling correction factor		1.160
for the MLR correction		
Loglikelihood unrestricted model (H1)	-1272.195	-1272.195

Scaling correction factor 1.057
for the MLR correction

Number of free parameters	13	13
Akaike (AIC)	2593.950	2593.950
Bayesian (BIC)	2639.090	2639.090
Sample-size adjusted Bayesian (BIC)	2597.884	2597.884

Root Mean Square Error of Approximation:

RMSEA	0.000	0.000
90 Percent Confidence Interval	0.000 0.030	0.000 0.028
P-value RMSEA <= 0.05	0.996	0.997

Standardized Root Mean Square Residual:

SRMR	0.049	0.049
------	-------	-------

Insgesamt deuten die Fit-Statistiken auf eine sehr gute Passung des Modells hin.

Parameter estimates:

Information			Observed			
Standard Errors			Robust.huber.white			
	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Latent variables:						
rakt =~						
reakt_1	1.000				0.254	0.667
reakt_2	1.000				0.254	0.667
reakt_3	1.000				0.254	0.667
reakt_4	1.000				0.254	0.667
reakt_5	1.000				0.254	0.667
reakt_6	1.000				0.254	0.667
klar =~						
kla_th1	1.000				1.611	0.886
kla_th2	1.000				1.611	0.886

Gemäß der Modelldefinition sind alle Ladungen auf 1 fixiert.

	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Covariances:						
rakt ~~						
klar	-0.009	0.031	-0.276	0.782	-0.021	-0.021

Die geschätzte Korrelation (Std.all) der latenten Variablen beträgt -0.021 und ist nicht signifikant von 0 verschieden.

	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Intercepts:						
reakt_1	1.504	0.023	64.757	0.000	1.504	3.949
reakt_2	1.423	0.024	59.647	0.000	1.423	3.736
reakt_3	1.392	0.025	54.862	0.000	1.392	3.655
reakt_4	1.305	0.026	49.486	0.000	1.305	3.426
reakt_5	1.346	0.024	55.221	0.000	1.346	3.535

reakt_6	1.306	0.025	52.662	0.000	1.306	3.428
kla_th1	9.189	0.117	78.282	0.000	9.189	5.051
kla_th2	9.206	0.118	77.711	0.000	9.206	5.060
rakt	0.000				0.000	0.000
klar	0.000				0.000	0.000

Die geschätzten Leichtigkeitsparameter der Items und die Mittelwerte der latenten Variablen werden ausgegeben.

		Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Variances:							
reakt_1	(v1)	0.081	0.004			0.081	0.556
reakt_2	(v1)	0.081	0.004			0.081	0.556
reakt_3	(v1)	0.081	0.004			0.081	0.556
reakt_4	(v1)	0.081	0.004			0.081	0.556
reakt_5	(v1)	0.081	0.004			0.081	0.556
reakt_6	(v1)	0.081	0.004			0.081	0.556
kla_th1	(v2)	0.714	0.080			0.714	0.216
kla_th2	(v2)	0.714	0.080			0.714	0.216
rakt		0.064	0.011			1.000	1.000
klar		2.596	0.268			1.000	1.000

Die geschätzten Fehlervarianzen der Items und die geschätzten Varianzen der latenten Variablen werden ausgegeben.

5.3 Multikomponentenmodell

```
m_lst<- 'eta1=~Y1+1*Y2+1*Y3+1*Y4
eta2=~Y1 + 1*Y2
eta3=~Y3 + 1*Y4
eta1~~0*eta2
eta1~~0*eta3
eta2~~0*eta3
Y1~~v*Y1
Y2~~v*Y2
Y3~~v*Y3
Y4~~v*Y4'
```

In diesem Multikomponentenmodell, einem Latent-State-Trait-Modell, laden alle Items mit einer Ladung von 1 auf der latenten Variablen η_1 , die den Trait repräsentiert. Zudem werden die messgelegenheitsspezifischen latenten Variablen η_2 und η_3 definiert, auf welche die zu dem jeweiligen Messzeitpunkt erhobenen Items ebenfalls mit einer Ladung von 1 laden. Korrelationen zwischen den latenten Variablen werden nicht zugelassen und alle Fehlervarianzen der Items werden über das Label v gleich gesetzt. Damit wird eine essenziell τ -parallele Messstruktur impliziert.

```
> fit_lst<-sem(m_lst, data=data2, meanstructure=TRUE,
estimator="MLR")
> summary(fit_lst, fit.measures=TRUE, standardized=TRUE)
```

Das Modell wird angepasst und ein detaillierter Output wird angefordert.

lavaan (0.5-14) converged normally after 16 iterations

Number of observations	212	
Estimator	ML	Robust
Minimum Function Test Statistic	6.340	4.089
Degrees of freedom	6	6
P-value (Chi-square)	0.386	0.665
Scaling correction factor for the Yuan-Bentler correction		1.550

Model test baseline model:

Minimum Function Test Statistic	362.843	193.124
Degrees of freedom	6	6
P-value	0.000	0.000

Full model versus baseline model:

Comparative Fit Index (CFI)	0.999	1.000
Tucker-Lewis Index (TLI)	0.999	1.010

Loglikelihood and Information Criteria:

Loglikelihood user model (H0)	-922.363	-922.363
Scaling correction factor for the MLR correction		1.381
Loglikelihood unrestricted model (H1)	-919.193	-919.193
Scaling correction factor for the MLR correction		1.453
Number of free parameters	8	8
Akaike (AIC)	1860.725	1860.725
Bayesian (BIC)	1887.578	1887.578
Sample-size adjusted Bayesian (BIC)	1862.229	1862.229

Root Mean Square Error of Approximation:

RMSEA	0.016	0.000
90 Percent Confidence Interval	0.000 0.092	0.000
0.056		
P-value RMSEA <= 0.05	0.676	0.928

Standardized Root Mean Square Residual:

SRMR	0.041	0.041
------	-------	-------

Insgesamt deuten die Fit-Statistiken auf eine gute Modellpassung hin.

Parameter estimates:

Information	Observed
-------------	----------

	Standard Errors	Robust.huber.white				
	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Latent variables:						
eta1 =~						
Y1	1.000				0.641	0.719
Y2	1.000				0.641	0.719
Y3	1.000				0.641	0.726
Y4	1.000				0.641	0.726
eta2 =~						
Y1	1.000				0.354	0.397
Y2	1.000				0.354	0.397
eta3 =~						
Y3	1.000				0.331	0.375
Y4	1.000				0.331	0.375

Gemäß der Modelldefinition sind alle Ladungen auf 1 fixiert.

	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Covariances:						
eta1 ~~						
eta2	0.000				0.000	0.000
eta3	0.000				0.000	0.000
eta2 ~~						
eta3	0.000				0.000	0.000

Die Kovarianzen zwischen den latenten Variablen sind alle auf 0 fixiert.

	Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Intercepts:						
Y1	3.880	0.064	60.523	0.000	3.880	4.352
Y2	4.059	0.058	69.451	0.000	4.059	4.553
Y3	3.960	0.060	65.874	0.000	3.960	4.487
Y4	4.066	0.061	66.789	0.000	4.066	4.608
eta1	0.000				0.000	0.000
eta2	0.000				0.000	0.000
eta3	0.000				0.000	0.000

Die geschätzten Itemleichtigkeiten und die Mittelwerte der latenten Variablen werden ausgegeben.

		Estimate	Std.err	Z-value	P(> z)	Std.lv	Std.all
Variances:							
Y1	(v)	0.259	0.031			0.259	0.326
Y2	(v)	0.259	0.031			0.259	0.326
Y3	(v)	0.259	0.031			0.259	0.332
Y4	(v)	0.259	0.031			0.259	0.332
eta1		0.410	0.067			1.000	1.000
eta2		0.125	0.044			1.000	1.000
eta3		0.109	0.046			1.000	1.000

Die geschätzten Fehlervarianzen der Items und die geschätzten Varianzen der latenten Variablen werden ausgegeben.

5.4 Exploratorische Faktorenanalyse für kategoriale Daten

Die exploratorische Faktorenanalyse für kategoriale Daten ist relativ unkompliziert mit der Analyse-Software Mplus (Muthén & Muthén, 2012) durchführbar. Mplus stellt auch Konfidenzintervalle und Modellgütekoeffizienten zur Verfügung. In R ist es möglich, mit der Funktion `fa()` im Paket `psych` eine exploratorische Faktorenanalyse für ordinale Daten auf Basis der polychorischen Korrelationen durchzuführen.

```
data3<-  
as.data.set(spss.system.file('kapitel_7_beispiel_exploratorische_fak  
torenanalyse.sav'))  
data3<-data.frame(data3)
```

Zunächst werden die Daten geladen und in das Format `data.frame` konvertiert.

```
> N=dim(data3)[1]
```

Die Anzahl der Personen im Datensatz wird ermittelt.

```
> library(psych)  
> library(polycor)  
> library(GPARotation)
```

Die benötigten Pakete werden geladen. Im Paket `psych` ist die exploratorische Faktorenanalyse implementiert. Das Paket `polycor` wird für die Schätzung der polychorischen Korrelationsmatrix benötigt. Im Paket `GPARotation` sind verschiedene Rotationsmethoden implementiert, u.a. die Oblimin-Rotation.

```
> poly_cor<-polychoric(data3)
```

Die polychorische Korrelationsmatrix der Items im Daten-Frame `data3` wird geschätzt.

```
> print(poly_cor)  
Call: polychoric(x = data3)  
Polychoric correlations  
      itm_1 itm_2 itm_3 itm_4 itm_5 itm_6  
itm_1 1.00  
itm_2 0.71 1.00  
itm_3 0.43 0.50 1.00  
itm_4 0.70 0.78 0.50 1.00  
itm_5 0.31 0.42 0.59 0.45 1.00  
itm_6 0.51 0.57 0.65 0.58 0.70 1.00  
  
with tau of  
      1 2 3 4  
itm_1 -2.6 -1.4 -0.356 1.03
```



```

item_2 -2.6 -1.7 -0.683 0.99
item_3 -2.3 -1.2 -0.258 1.05
item_4 -2.5 -1.7 -0.599 0.90
item_5 -2.5 -1.2 -0.013 1.29
item_6 -2.2 -1.1 0.039 1.55

```

Die geschätzte polychorische Korrelationsmatrix und die geschätzten Schwellenparameter werden ausgegeben. Insgesamt zeigen sich relativ hohe Interkorrelationen zwischen den Items.

```
> faPC <- fa(r=poly_cor$rho, nfactors=2, n.obs=N, rotate="oblimin")
```

Die exploratorische Faktorenanalyse wird auf Basis der polychorischen Korrelationsmatrix `poly_cor$roh` durchgeführt. Es werden zwei Faktoren extrahiert. Die Anzahl der Beobachtungen `n.obs` entspricht `N=482`, die Rotationsmethode wird mit `rotate="oblimin"` eingestellt.

```
> print(faPC)
```

Das Ergebnis der Analyse wird ausgegeben.

```

Factor Analysis using method = minres
Call: fa(r = poly_cor$rho, nfactors = 2, n.obs = N, rotate =
"oblimin")
Standardized loadings (pattern matrix) based upon correlation matrix
      MR1   MR2   h2   u2 com
item_1 0.84 -0.06 0.65 0.35 1.0
item_2 0.87 0.02 0.79 0.21 1.0
item_3 0.14 0.64 0.55 0.45 1.1
item_4 0.82 0.08 0.76 0.24 1.0
item_5 -0.11 0.90 0.70 0.30 1.0
item_6 0.16 0.76 0.75 0.25 1.1

```

Zur Schätzung kam standardmäßig die Methode Residuenminimierung (`minres`) zum Einsatz. Es werden die standardisierten Ladungen der Items auf den Faktoren (`MR1`, `MR2`), die Kommunalitäten (`h2`) und Fehlervarianzen ausgegeben (`u2`).

```

      MR1   MR2
SS loadings      2.30 1.89
Proportion Var   0.38 0.32
Cumulative Var   0.38 0.70
Proportion Explained 0.55 0.45
Cumulative Proportion 0.55 1.00

```

Es folgen Statistiken zur Varianzaufklärung durch die Faktoren. Die Zeile `SS loadings` bezeichnet die Summe der quadrierten Faktorladungen, die Zeile `Proportion Var` bezeichnet die Varianzaufklärung der jeweiligen Faktoren und `Proportion Explained` gibt an, wie viel

Prozent der durch die zwei Faktoren aufgeklärten Varianz auf den jeweiligen Faktor zurückzuführen sind. Die entsprechenden kumulierten Statistiken werden ebenfalls ausgegeben.

```
With factor correlations of
      MR1  MR2
MR1  1.00  0.63
MR2  0.63  1.00
```

Die Interkorrelationsmatrix der extrahierten Faktoren wird ausgegeben. Die geschätzte Korrelation der Faktoren beträgt $r=0.63$.

7 Literatur

Davier, M. von (2001). *WINMIRA 2001* [Computer-Programm]. Verfügbar unter www.von-davier.com (27.09.2013).

Eid, M. & Schmidt, K. (2014). *Testtheorie und Testkonstruktion*. Göttingen: Hogrefe.

Fischer, G. H. (1995). The linear logistic test model. In G.H. Fischer & I.W. Molenaar (Eds.), *Rasch models – foundations, recent developments and applications*. Berlin: Springer.

Frick, H., Strobl, C., Leisch, F. & Zeileis, A. (2012). Flexible Rasch mixture models with package psychomix. *Journal of Statistical Software*, 48 (7), 1–25.

Koller, I., Alexandrowicz, R. & Hatzinger, R. (2012). *Das Rasch-Modell in der Praxis. Eine Einführung in eRm*. Wien: Facultas.

Luhmann, M. (2013). *R für Einsteiger. Einführung in die Statistiksoftware für die Sozialwissenschaften*. Weinheim: Beltz.

Mair, P. & Hatzinger, H. (2007). Extended Rasch modeling: the eRm package for the application of Rasch models in R. *Journal of Statistical Software*, 20 (9).

Muthén, L.K. & Muthén, B.O. (2012). *Mplus user's guide* (7th ed.). Los Angeles, CA: Muthén & Muthén.

Revelle, W. (2013). *Package 'psych': Procedures for psychological, psychometric, and personality research*. Verfügbar unter <http://cran.r-project.org/web/packages/psych/psych.pdf> (24.02.2014).

Rizopoulos, D. (2006). ltm: an R package for latent variable modeling and item response theory analyses. *Journal of Statistical Software*, 17 (5).

Rosseel, Y. (2012). lavaan: an R package for structural equation modeling. *Journal of Statistical Software*, 48 (5).