

Assess the Assessment

Michaela Nettekoven und Karl Ledermüller

23. Mai 2011

Inhaltsverzeichnis

1 Einleitung	3
2 Kennzahlen des Rasch Modells	3
3 Generelle Analyse der Prüfung	6
3.1 Test auf Ein- bzw. Mehrdimensionalität	6
3.1.1 Martin-Löf Test auf Mehrdimensionalität	6
3.1.2 Faktorenanalyse	7
3.1.3 Hierarchisches Clustering	8
3.1.4 Multidimensionale Skalierung	8
3.2 Personenhomogenität	10
3.2.1 Analyse der erreichten gesamten Prozentwerte	10
3.2.2 Anderson Likelihood Ratio Test	11
3.2.3 Graphischer Modelltest	14
3.2.4 Infit/Outfit Item Map	16
3.2.5 Infit/Outfit Person Map	16
4 Fragenbasierte Auswertung	18
4.1 Frage op59	19
4.2 Frage da01	20
4.3 Frage br18	21
4.4 Frage al50	22
4.5 Frage bf05	23
4.6 Frage bf02	24
4.7 Frage mo04	25
4.8 Frage al02	26
4.9 Frage op31	27
4.10 Frage ri17	28
4.11 Frage kr08	30
4.12 Frage kw16	31
4.13 Frage iz06	32
4.14 Frage kr28	34
4.15 Frage in32	35
4.16 Frage in28	36
4.17 Frage fm31	37
4.18 Frage fm78	38
4.19 Frage ef09	39
4.20 Frage ff33	40

1 Einleitung

Das folgende Dokument analysiert automatisiert Ihre Klausur mit Hilfe verschiedener statistischer Verfahren.

Die größte Gruppe dieser statistischen Methoden ist der probabilistischen Testtheorie (Item Response Theory, IRT) entnommen, die hauptsächlich in der Psychologie und Psychometrie zur Anwendung kommen. Hier wird untersucht, wie man anhand von vorliegenden Daten (z.B. Antworten auf Prüfungsfragen) Rückschlüsse auf latente Merkmale der Testperson (z.B. Intelligenz) ziehen kann.

Das bekannteste Modell der IRT ist das Rasch-Modell. Ausgehend von einer Reihe von Fragen (Items) mit jeweils zwei Antwortmöglichkeiten (ja/nein) bzw. den vorliegenden Antworten der Testpersonen können – unabhängig voneinander – die Schwierigkeit der Test-Items (Aufgabenparameter) und die Fähigkeit der Testpersonen (Personenparameter) geschätzt werden.

2 Kennzahlen des Rasch Modells

Geschätzt wurde ein Partial-Credit-Modell, eine Erweiterung des Rasch-Modells, bei dem eine Frage mehrstufige Antwortkategorien aufweisen kann (z.B. Teilpunkte). Die Anzahl der möglichen Antwortkategorien wird automatisch aus den Daten ermittelt und richtet sich nach den möglichen Prozentwerten, die auf eine Frage erreicht werden können. Z.B. kann man beim WU-üblichen Schema der Teilpunktberechnung auf eine Frage mit 3 richtigen und 2 falschen Antwortmöglichkeiten 0%, 16.67%, 33.33%, 50%, 66.67% oder 100% der möglichen Punkte erreichen – damit ergeben sich 6 Antwortkategorien (üblicherweise mit 0 bis 5 nummeriert) im Partial-Credit-Modell. Die Kategorie 0 wird dabei als eine Art Basis angesehen, deren Erreichung keinerlei Schweirigkeiten bereitet oder Fähigkeiten erfordert, und wird daher in vielen Auswertung weggelassen.

Die geschätzten Werte für η in der ersten Tabelle geben an, wie schwierig die jeweilige Frage bzw. die Antwortkategorien der Frage ist. β in der zweiten Tabelle ist ein Indikator für die Einfachheit der Frage bzw. Antwortkategorie.

```
> summary(pm.result)
```

```
Results of PCM estimation:
```

```
Call: PCM(X = Score.pm)
```

```
Conditional log-likelihood: -12954.53
```

```
Number of iterations: 61
```

```
Number of parameters: 63
```

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

	Estimate	Std. Error	lower CI	upper CI
op59.c2	1.001	0.116	0.773	1.230
op59.c3	2.699	0.214	2.280	3.118
op59.c4	0.854	0.123	0.613	1.095
op59.c5	2.295	0.174	1.955	2.635
da01.c1	-0.550	0.131	-0.806	-0.294
da01.c2	2.185	0.317	1.564	2.806
da01.c3	-0.258	0.141	-0.535	0.019
da01.c4	0.267	0.159	-0.045	0.578
da01.c5	-0.423	0.151	-0.719	-0.127
br18.c1	-0.364	0.078	-0.517	-0.211
a150.c1	0.387	0.077	0.237	0.537

bf05.c1	1.003	0.142	0.723	1.282
bf05.c2	0.377	0.118	0.146	0.607
bf05.c3	2.812	0.279	2.266	3.358
bf05.c4	0.035	0.122	-0.205	0.275
bf05.c5	1.570	0.167	1.242	1.899
bf02.c1	-0.296	0.272	-0.830	0.237
bf02.c2	-0.009	0.295	-0.586	0.569
bf02.c3	-0.223	0.276	-0.765	0.318
bf02.c4	-2.062	0.216	-2.484	-1.639
bf02.c5	-2.806	0.211	-3.221	-2.392
mo04.c1	0.038	0.141	-0.239	0.314
mo04.c2	0.806	0.176	0.461	1.152
mo04.c3	1.490	0.219	1.060	1.920
mo04.c4	-0.730	0.134	-0.994	-0.467
mo04.c5	-0.045	0.153	-0.345	0.255
al02.c1	-0.728	0.134	-0.990	-0.466
al02.c2	3.377	0.582	2.237	4.517
al02.c3	-0.878	0.135	-1.144	-0.613
al02.c4	0.964	0.195	0.582	1.345
al02.c5	-0.346	0.157	-0.653	-0.039
op31.c1	1.180	0.086	1.013	1.348
ri17.c1	-0.729	0.174	-1.071	-0.388
ri17.c2	3.187	0.714	1.788	4.585
ri17.c3	-1.550	0.160	-1.863	-1.237
ri17.c4	0.127	0.203	-0.271	0.524
ri17.c5	-1.377	0.171	-1.713	-1.042
kr08.c1	-3.274	0.447	-4.150	-2.398
kr08.c2	-0.804	0.529	-1.841	0.232
kr08.c3	-2.095	0.444	-2.966	-1.224
kr08.c4	-4.125	0.409	-4.926	-3.324
kr08.c5	-3.599	0.400	-4.383	-2.815
kw16.c1	-1.555	0.102	-1.755	-1.355
iz06.c1	-0.383	0.116	-0.611	-0.156
iz06.c2	3.134	0.414	2.322	3.946
iz06.c3	-0.186	0.126	-0.433	0.060
iz06.c4	1.255	0.176	0.910	1.601
iz06.c5	0.246	0.149	-0.046	0.538
kr28.c1	-0.284	0.077	-0.436	-0.132
in32.c1	-1.126	0.146	-1.413	-0.839
in32.c2	1.387	0.279	0.841	1.933
in32.c3	-0.662	0.158	-0.970	-0.353
in32.c4	-0.317	0.168	-0.647	0.012
in32.c5	-0.786	0.165	-1.108	-0.463
in28.c1	-0.077	0.076	-0.227	0.072
fm31.c1	-0.984	0.166	-1.309	-0.660
fm31.c2	3.209	0.713	1.811	4.607
fm31.c3	-1.033	0.166	-1.358	-0.707
fm31.c4	0.037	0.197	-0.350	0.423
fm31.c5	-1.552	0.168	-1.882	-1.222
fm78.c1	-1.330	0.095	-1.516	-1.143
ef09.c1	1.556	0.094	1.372	1.741
ff33.c1	-1.139	0.090	-1.316	-0.962

Item Easiness Parameters (beta) with 0.95 CI:

	Estimate	Std. Error	lower CI	upper CI
beta op59.c1	-1.211	0.126	-1.457	-0.964
beta op59.c2	-1.001	0.116	-1.230	-0.773
beta op59.c3	-2.699	0.214	-3.118	-2.280
beta op59.c4	-0.854	0.123	-1.095	-0.613
beta op59.c5	-2.295	0.174	-2.635	-1.955
beta da01.c1	0.550	0.131	0.294	0.806
beta da01.c2	-2.185	0.317	-2.806	-1.564
beta da01.c3	0.258	0.141	-0.019	0.535
beta da01.c4	-0.267	0.159	-0.578	0.045
beta da01.c5	0.423	0.151	0.127	0.719
beta br18.c1	0.364	0.078	0.211	0.517
beta al50.c1	-0.387	0.077	-0.537	-0.237
beta bf05.c1	-1.003	0.142	-1.282	-0.723
beta bf05.c2	-0.377	0.118	-0.607	-0.146
beta bf05.c3	-2.812	0.279	-3.358	-2.266
beta bf05.c4	-0.035	0.122	-0.275	0.205
beta bf05.c5	-1.570	0.167	-1.899	-1.242
beta bf02.c1	0.296	0.272	-0.237	0.830
beta bf02.c2	0.009	0.295	-0.569	0.586
beta bf02.c3	0.223	0.276	-0.318	0.765
beta bf02.c4	2.062	0.216	1.639	2.484
beta bf02.c5	2.806	0.211	2.392	3.221
beta mo04.c1	-0.038	0.141	-0.314	0.239
beta mo04.c2	-0.806	0.176	-1.152	-0.461
beta mo04.c3	-1.490	0.219	-1.920	-1.060
beta mo04.c4	0.730	0.134	0.467	0.994
beta mo04.c5	0.045	0.153	-0.255	0.345
beta al02.c1	0.728	0.134	0.466	0.990
beta al02.c2	-3.377	0.582	-4.517	-2.237
beta al02.c3	0.878	0.135	0.613	1.144
beta al02.c4	-0.964	0.195	-1.345	-0.582
beta al02.c5	0.346	0.157	0.039	0.653
beta op31.c1	-1.180	0.086	-1.348	-1.013
beta ri17.c1	0.729	0.174	0.388	1.071
beta ri17.c2	-3.187	0.714	-4.585	-1.788
beta ri17.c3	1.550	0.160	1.237	1.863
beta ri17.c4	-0.127	0.203	-0.524	0.271
beta ri17.c5	1.377	0.171	1.042	1.713
beta kr08.c1	3.274	0.447	2.398	4.150
beta kr08.c2	0.804	0.529	-0.232	1.841
beta kr08.c3	2.095	0.444	1.224	2.966
beta kr08.c4	4.125	0.409	3.324	4.926
beta kr08.c5	3.599	0.400	2.815	4.383
beta kw16.c1	1.555	0.102	1.355	1.755
beta iz06.c1	0.383	0.116	0.156	0.611
beta iz06.c2	-3.134	0.414	-3.946	-2.322
beta iz06.c3	0.186	0.126	-0.060	0.433
beta iz06.c4	-1.255	0.176	-1.601	-0.910
beta iz06.c5	-0.246	0.149	-0.538	0.046
beta kr28.c1	0.284	0.077	0.132	0.436
beta in32.c1	1.126	0.146	0.839	1.413
beta in32.c2	-1.387	0.279	-1.933	-0.841
beta in32.c3	0.662	0.158	0.353	0.970

beta_in32.c4	0.317	0.168	-0.012	0.647
beta_in32.c5	0.786	0.165	0.463	1.108
beta_in28.c1	0.077	0.076	-0.072	0.227
beta_fm31.c1	0.984	0.166	0.660	1.309
beta_fm31.c2	-3.209	0.713	-4.607	-1.811
beta_fm31.c3	1.033	0.166	0.707	1.358
beta_fm31.c4	-0.037	0.197	-0.423	0.350
beta_fm31.c5	1.552	0.168	1.222	1.882
beta_fm78.c1	1.330	0.095	1.143	1.516
beta_ef09.c1	-1.556	0.094	-1.741	-1.372
beta_ff33.c1	1.139	0.090	0.962	1.316

Die Person-Item Map in Abbildung 1 stellt die Schwierigkeit der einzelnen Items sowie ihrer Kategorien und die Verteilung der Personenparameter graphisch dar. Die Werte der x-Achse beschreiben sowohl die Ausprägung der Personenfähigkeit als auch die Itemschwierigkeit. Im unteren Teil der Graphik sind die Items aufgelistet, geordnet nach der durchschnittlichen Itemschwierigkeit (ausgefüllter Punkt). Die Schwere der einzelnen Antwortkategorien wird durch die nicht ausgefüllten Punkte markiert.

Achtung - diese Punkte stehen nicht für einzelne Antwortmöglichkeiten der jeweiligen Prüfungfrage, sondern für die verschiedenen Prozentwerte, die bei dieser Prüfungsfrage erreicht wurden (als Ankreuz-Kombination verschiedener Antwortmöglichkeiten), wobei nicht zwischen den einzelnen Antwortmöglichkeiten unterschieden wird. Es können also keine Aussagen der Art „Antwortmöglichkeit a ist einfacher als Antwortmöglichkeit b“ getroffen werden!

Ein Stern rechts markiert ein Item, bei dem die natürliche Reihenfolge der Antwortkategorien vertauscht ist. Normalerweise würde man erwarten, dass z.B. 33,33% einfacher zu erreichen sind als 50%, diese einfacher als 66,67%, und diese wiederum einfacher als 100%. Manchmal widersprechen sich aber einzelne Antwortmöglichkeiten, oder bestimmte Antwortmöglichkeiten sind offensichtlich falsch, sodass es „schwer“ist (d.h. selten vorkommt), die Antwort bzw. Kombination von Antworten anzukreuzen, und daher ein bestimmter zu erreichender Prozentwert bei dieser Frage selten auftritt. In so einem Fall verschiebt sich die Reihenfolge der Antwortkategorien, der selten auftretende Prozentwert wird als besonders schwere Antwortkategorie interpretiert.

Im oberen Teil der Graphik wird ein Histogramm der errechneten Personen-Fähigkeits-Parameter dargestellt.

3 Generelle Analyse der Prüfung

3.1 Test auf Ein- bzw. Mehrdimensionalität

In diesem Kapitel wird untersucht, ob alle Test-Items die gleiche Eigenschaft der Studierenden messen (Eindimensionalität, z.B. räumliches Vorstellungvermögen), oder ob mehrere Kompetenzen abgeprüft werden (Mehrdimensionalität, z.B. Sprachverständnis, Auswendig-Lernen, und mathematische Kenntnisse).

3.1.1 Martin-Löf Test auf Mehrdimensionalität

Beim Martin-Löf Test auf Mehrdimensionalität werden die Items in zwei Gruppen unterteilt, die miteinander verglichen werden. Bei einem p-Wert (p-value) von mehr als 0.05 liegt Mehrdimensionalität vor.

```
Martin-Loef-Test (split criterion: median)
LR-value: -10180.041
Chi-square df: 1023
p-value: 1
```

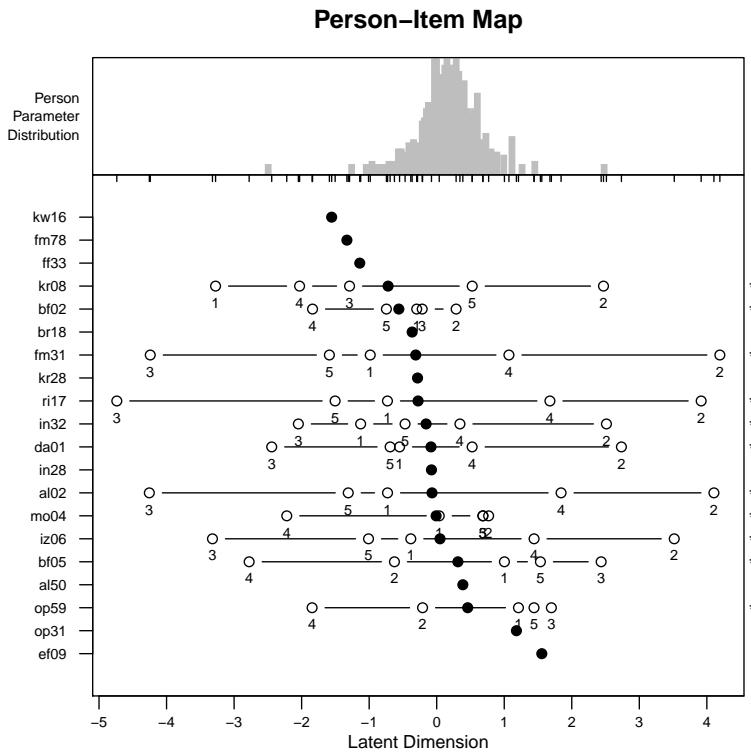


Abbildung 1: Person-Item Map

3.1.2 Faktorenanalyse

Die Faktorenanalyse reduziert eine Menge von verschiedenen Variablen auf wenige gemeinsame Einflußfaktoren. So können z.B. in einer Prüfung die Ergebnisse von Rechenbeispielen auf den gemeinsamen Faktor „Mathematikkenntnisse“ zurückgeführt werden, oder die Ergebnisse von einfachen Theoriefragen auf den Faktor „Buchwissen/Auswendig lernen“.

(Achtung: Wofür ein Faktor steht (z.B. Mathematikkenntnisse, Buchwissen, usw.) muss selbst aus den Ergebnissen gefolgert werden!)

Die in der Output-Tabelle angeführten Faktorladungen („loadings“) sind die Werte der Korrelation zwischen der Ausgangsvariable und dem Faktor.

Der p-Wert ganz unten zeigt an, ob die gewählte Anzahl an Faktoren ausreicht, um die Variablen zu beschreiben: Ist der p-Wert kleiner als 0.05, sind es zu wenige Faktoren. Wir wählen jene Anzahl der Faktoren, bei der der p-Wert erstmals größer als 0.1 ist. (max. 10 Faktoren)

```
> ff
```

```
Call:  
factanal(x = Prozent, factors = i)
```

Uniquenesses:

```
op59  da01  br18  al50  bf05  mo04  al02  op31  ri17  kr08  kw16  iz06  kr28  in32  
0.865 0.811 0.747 0.814 0.801 0.644 0.709 0.826 0.741 0.830 0.899 0.645 0.897 0.700 0.886  
in28  fm31  fm78  ef09  ff33  
0.865 0.794 0.725 0.897 0.771
```

Loadings:

	Factor1	Factor2	Factor3	Factor4	Factor5
op59	0.162	0.113	0.142	0.244	0.129
da01		0.296	0.146	0.251	
br18	0.406	0.179	0.136		0.180
a150	0.244	0.212	-0.155	0.235	
bf05		0.349	0.201	0.158	0.111
bf02	0.146	0.181	0.533	0.134	
mo04		0.183	0.164	0.470	
a102		0.192	0.191	0.228	0.214
op31	0.103		0.102		0.488
ri17	0.277		0.217	0.178	-0.114
kr08			0.280		0.111
kw16	0.403	0.384	0.193		
iz06		0.301			
kr28	0.187	0.476	0.188		
in32		0.133	0.293		
in28	0.100	0.214		0.110	0.254
fm31	0.192		0.276	0.289	
fm78	0.495			0.139	
ef09			0.210	0.207	0.111
ff33	0.438	0.142			0.101

	Factor1	Factor2	Factor3	Factor4	Factor5
SS loadings	1.073	0.957	0.904	0.709	0.490
Proportion Var	0.054	0.048	0.045	0.035	0.024
Cumulative Var	0.054	0.102	0.147	0.182	0.207

Test of the hypothesis that 5 factors are sufficient.
The chi square statistic is 106.52 on 100 degrees of freedom.
The p-value is 0.309

3.1.3 Hierarchisches Clustering

Der Begriff der Clusteranalyse umfasst verschiedene Methoden, um eine Anzahl von Variablen so zu gruppieren, dass die Elemente einer Gruppe möglichst ähnlich sind, während zwischen den unterschiedlichen Gruppen so wenig Ähnlichkeiten wie möglich auftreten sollen.

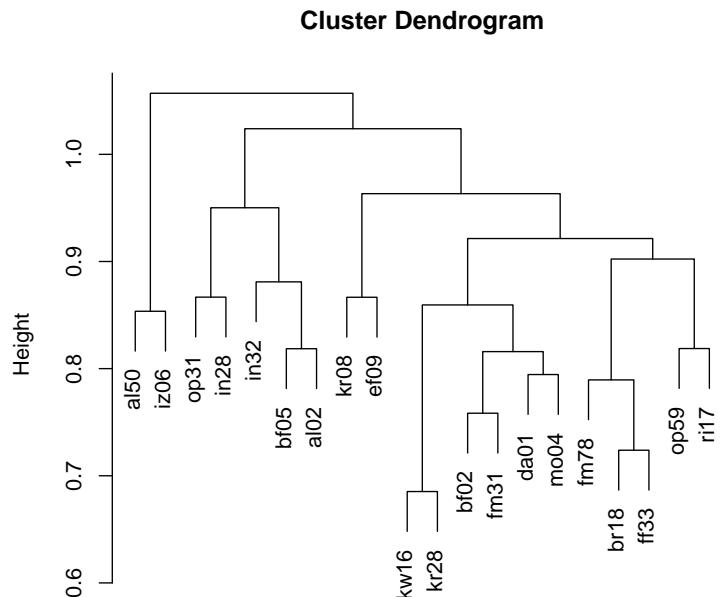
Als Ähnlichkeits- bzw. Distanzmaß zwischen zwei Elementen wird hier der Wert (1-Korrelation) angesetzt. Als Cluster-Algorithmus wird der „Complete-Linkage“ Algorithmus verwendet, bei dem zunächst die paarweisen Distanzen zwischen allen Elementen berechnet werden. Die zwei Elemente mit der geringsten Distanz werden zusammengefasst, die Distanz zwischen diesem neuen Cluster und den übrigen Elementen ist definiert als das Maximum der Einzeldistanzen der Clusterelemente zu den anderen Elementen („furthest-neighbor-principle“).

Abbildung 2 zeigt die Gruppierung der einzelnen Fragen. Fragen, die an einem gemeinsamen „Strang“ hängen, korrelieren stark und messen somit ähnliche dahinterliegende Kompetenzen.

3.1.4 Multidimensionale Skalierung

In der Multidimensionalen Skalierung (MDS) werden Variable graphisch dargestellt. Dabei liegen Variable, die stark miteinander korrelieren und damit ähnliche Konstrukte messen, nahe zusammen.

Als Distanzmaß wurde wieder der Wert (1-Korrelation) verwendet, Abbildung 3 zeigt das Ergebnis einer zweidimensionalen MDS.



```
dm
hclust(*, "complete")
```

Abbildung 2: Cluster-Dendrogramm

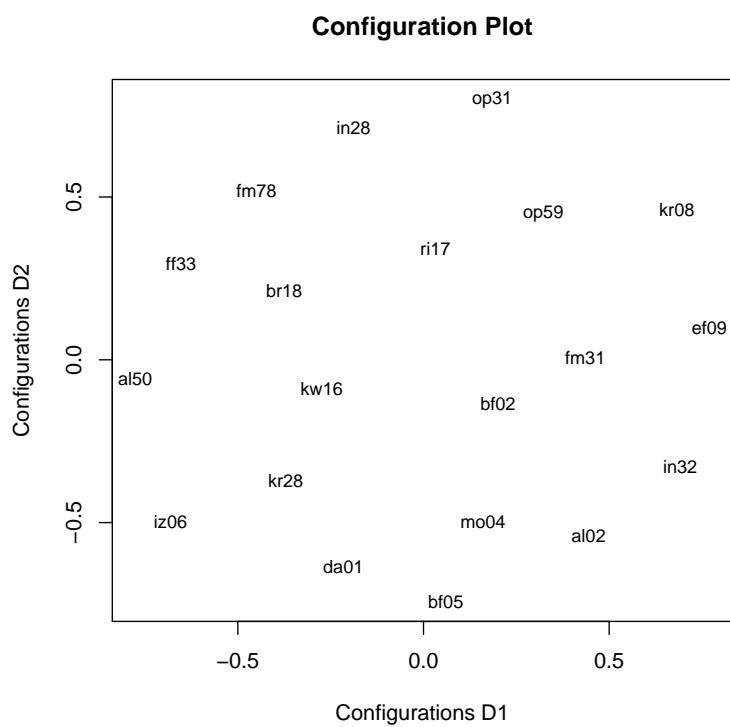


Abbildung 3: Multidimensionale Skalierung

3.2 Personenhomogenität

Die folgenden Tests untersuchen, ob die zur Prüfung angetretenen Personen eine mehr oder weniger einheitliche Gruppe bilden, oder ob anhand bestimmter Merkmale (z.B. Matr.Nr., demografische Daten) bestimmte Untergruppen identifiziert werden können.

Zunächst werden die Prozentwerte, die von verschiedenen Personengruppen in der Prüfung insgesamt erreicht wurden, auf Unterschiede analysiert. Anschließend werden spezielle Testverfahren der IRT herangezogen, um zu prüfen, ob bestimmte Prüfungsfragen für unterschiedliche Personengruppen unterschiedlich schwer sind.

3.2.1 Analyse der erreichten gesamten Prozentwerte

Hier werden die gesamten bei der Prüfung erreichten Prozent für verschiedene Untergruppen verglichen. Dabei wurden folgende Untergruppen definiert:

1. Geschlecht: männlich/weiblich
2. Matrikelnummer: von 2010 oder früher
3. Erstantritt: ja/nein

Für jede Untergruppen-Variante werden die entsprechenden Boxplots erstellt, sowie eine Regression und ANOVA gerechnet. Der Koeffizienten der Dummy-Variable in der Regression zeigt den Unterschied im Mittelwert der erreichten Prozentpunkte der beiden Gruppen an. bei einem p-Wert kleiner als 0.05 ist Unterschied zwischen den Gruppen signifikant.

- Unterteilung nach Geschlecht:

- Boxplot: Abbildung 4
- Regression: Koeffizienten
 - > *sex* <- *group.sex*
 - > *levels(sex)* <- c("männlich", "weiblich")
 - > *coefficients(summary(lm(Prozentgesamt ~ sex)))*

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	59.962228	0.8481024	70.70164	0.000000e+00
sexweiblich	-6.199007	1.1860839	-5.22645	2.241332e-07
- p-Wert ANOVA:
 - > *anova(lm(Prozentgesamt ~ sex))\$Pr[1]*
 - [1] 2.241332e-07

- Unterteilung nach Matrikelnummer:

- Boxplot: Abbildung 5
- Regression: Koeffizienten
 - > *matr* <- *group.matr*
 - > *matr* <- *factor(matr)*
 - > *levels(matr)* <- c("2009 und früher", "2010")
 - > *coefficients(summary(lm(Prozentgesamt ~ matr)))*

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	55.138359	0.676767	81.473175	0.000000e+00
matr2010	7.159514	1.407868	5.085358	4.63824e-07

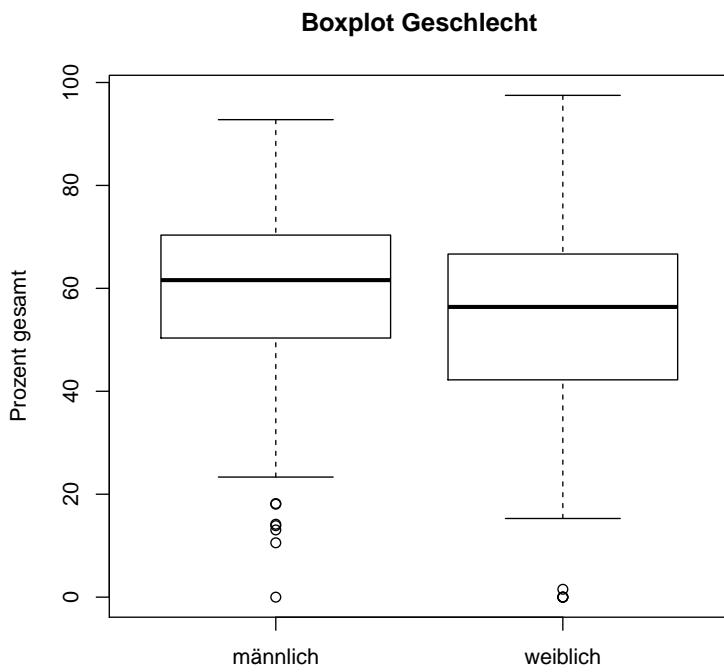


Abbildung 4: Boxplot Geschlecht

- p-Wert ANOVA:

```
> anova(lm(Prozentgesamt ~ matr))$Pr[1]
[1] 4.63824e-07
```

- Unterteilung nach Antritt:

- Boxplot: Abbildung 6
- Regression: Koeffizienten

```
> erst <- group.erst
> erst <- factor(erst)
> levels(erst) <- c("Wiederholung", "Erstantritt")
> coefficients(summary(lm(Prozentgesamt ~ erst)))
   Estimate Std. Error t value Pr(>|t|)
(Intercept) 55.562254  0.981165 56.628859 2.932693e-273
erstErstantritt 1.975614  1.243235  1.589092 1.124605e-01
```

- p-Wert ANOVA:

```
> anova(lm(Prozentgesamt ~ erst))$Pr[1]
[1] 0.1124605
```

3.2.2 Anderson Likelihood Ratio Test

Der Anderson LR Test prüft die Hypothese, ob die Prüfungsfragen für Personen mit gleicher allgemeiner Fähigkeit unterschiedlich schwierig sind. (Zum Beispiel: A und B haben insgesamt gleich viele Punkte erreicht, A fallen aber die Theoriefragen leichter, B die Rechenbeispiele.)

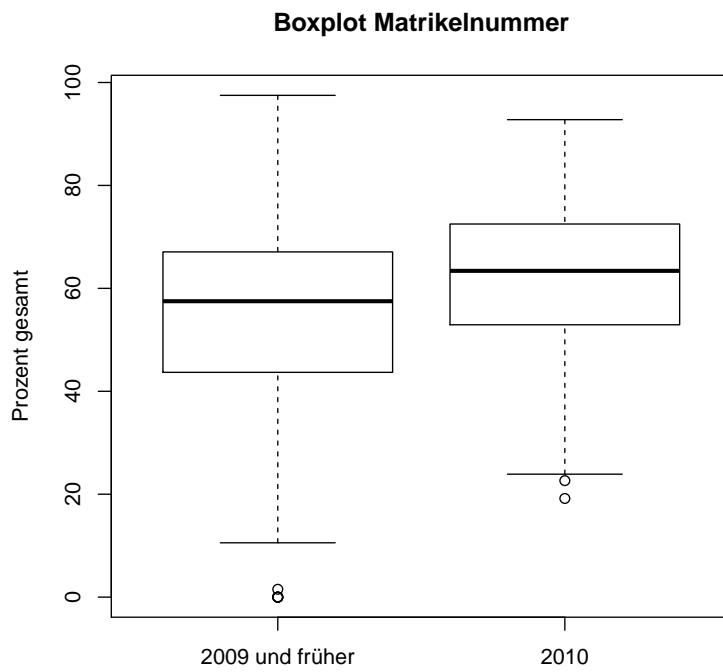


Abbildung 5: Boxplot Matrikelnummer

Dabei wird die gesamte Prüfung betrachtet, eine Analyse der einzelnen Beispiele liefert der Wald-Test weiter unten.

Ein signifikantes Ergebnis ($p < 0.05$) bedeutet, dass Fragen für Personen mit der gleichen Fähigkeit unterschiedliche Schwierigkeit haben.

Hier wird der LR Test zunächst mit der Standardunterteilung nach dem Median der erzielten Scores gerechnet, danach mit den gleichen vordefinierten Gruppen wie oben bei der ANOVA.
(sinnvoll???)

```
> lr <- LRtest(pm.result, se = TRUE)

Warning message: Persons with median raw scores are assigned to the lower raw score group!
bf02 kr08 ri17
Full and subgroup models are estimated without these items!

> lr

Andersen LR-test:
LR-value: 207.994
Chi-square df: 48
p-value: 0

> lr.matr <- LRtest(pm.result, splitcr = group.matr, se = TRUE)

kr08 ri17 iz06 fm31
Full and subgroup models are estimated without these items!
```

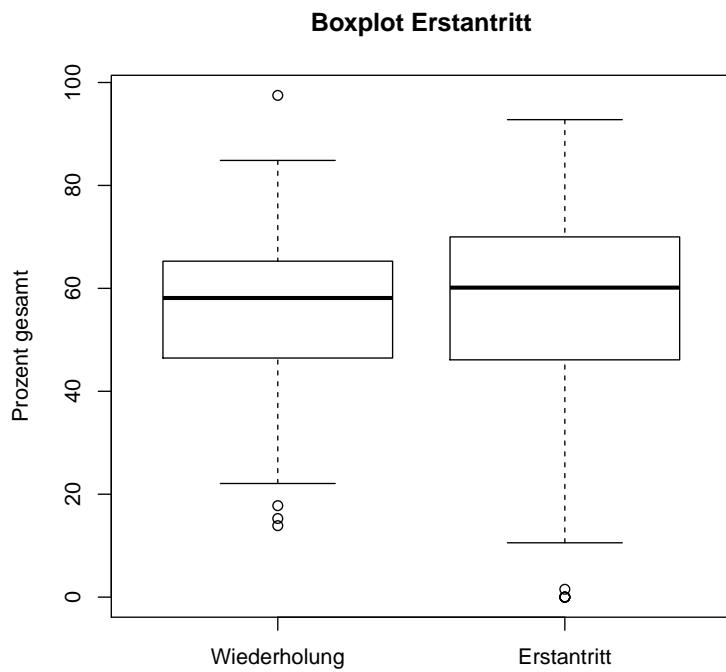


Abbildung 6: Boxplot Erstantritt

```
> lr.matr

Andersen LR-test:
LR-value: 65.081
Chi-square df: 43
p-value: 0.016

> lr.sex <- LRtest(pm.result, splitcr = group.sex, se = TRUE)

fm31
Full and subgroup models are estimated without these items!

> lr.sex

Andersen LR-test:
LR-value: 156.302
Chi-square df: 58
p-value: 0

> lr.erst <- LRtest(pm.result, splitcr = group.erst, se = TRUE)

kr08 fm31 ri17
Full and subgroup models are estimated without these items!

> lr.erst
```

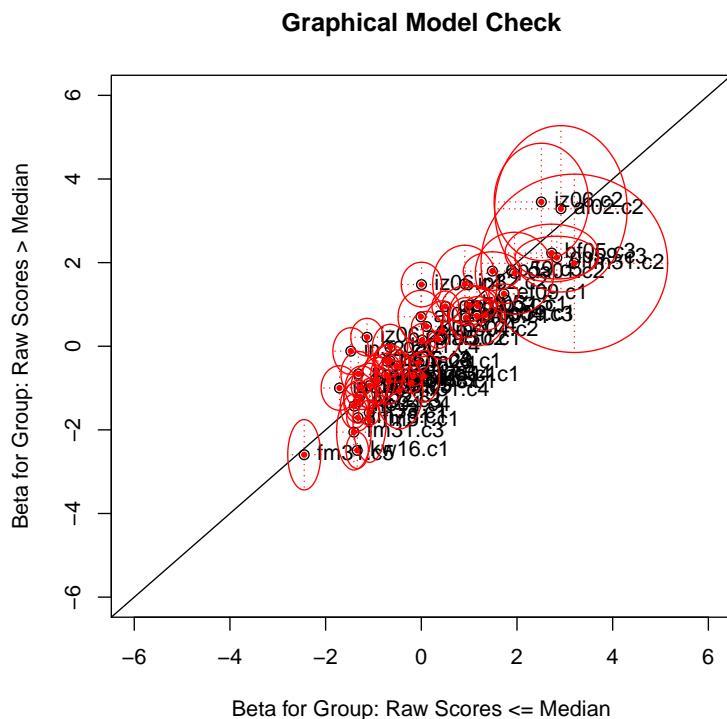


Abbildung 7: Graphischer Modelltest: Aufteilung nach Median

Andersen LR-test:

LR-value: 100.537

Chi-square df: 48

p-value: 0

bf02 kr08 ri17

Subgroup models are estimated without these items!

kr08 ri17 iz06 fm31

Subgroup models are estimated without these items!

fm31

Subgroup models are estimated without these items!

kr08 fm31 ri17

Subgroup models are estimated without these items!

3.2.3 Graphischer Modelltest

Auch beim graphischen Modelltest werden die Items für zwei verschiedenen Personengruppen verglichen. Umfasst die Konfidenzregion die 45-Grad-Gerade, fällt das Item beiden Personengruppen gleich schwer.

Die Gruppen werden wieder wie oben beim LR-Test gebildet.

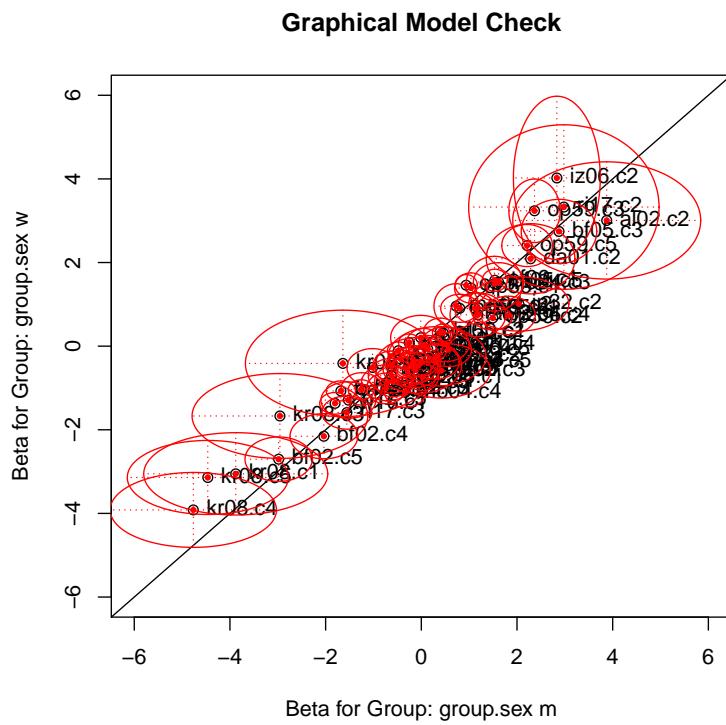


Abbildung 8: Graphischer Modelltest: Aufteilung nach Geschlecht

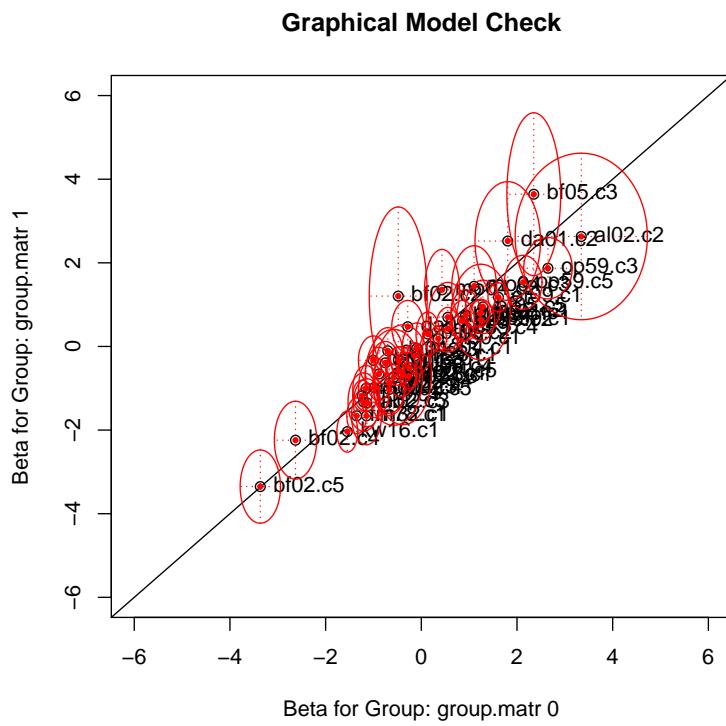


Abbildung 9: Graphischer Modelltest: Aufteilung nach Matrikelnummer: 2010 -> 1, früher -> 0

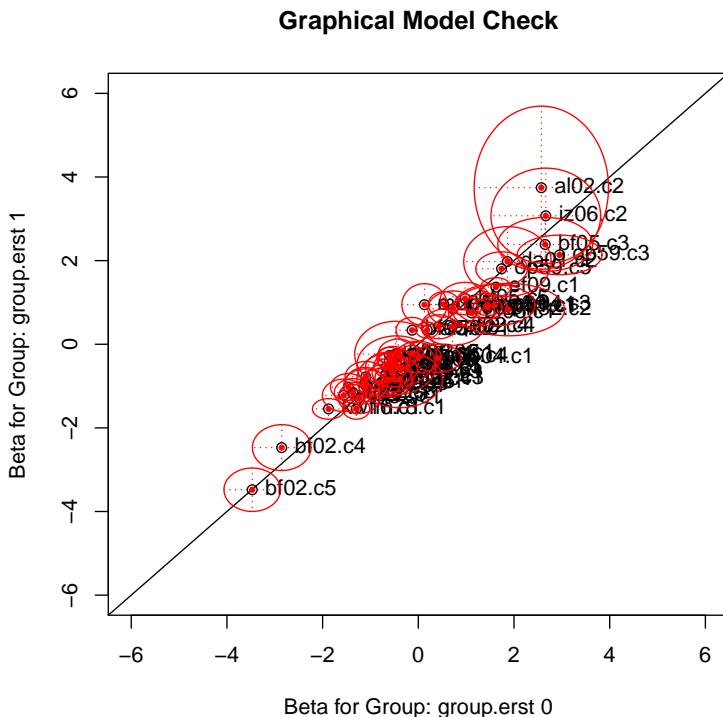


Abbildung 10: Graphischer Modelltest: Aufteilung nach Antritt: Erstantritt $\rightarrow 1$, Wiederholung $\rightarrow 0$

3.2.4 Infit/Outfit Item Map

Die Item Map zeigt, welche Items (bzw. Kategorien der Items) zu wahrscheinliche bzw. zu unwahrscheinliche Antwortmuster aufweisen.

Ein zu wahrscheinliches Antwortmuster ist z.B. eines, bei dem alle einfachen Items richtig und alle schwierigen Items falsch beantwortet werden – normalerweise passieren auch bei einfachen Items Fehler (z.B. Flüchtigkeitsfehler), bzw. beantwortet man manchmal auch zufällig ein schweres Item richtig. Bei einem zu unwahrscheinlichen Antwortmuster werden z.B. alle leichten Items falsch, und alle schwierigen Items richtig beantwortet.

Die Graphik zeigt die entsprechenden t-Statistiken. Werte unter -2 und über +2 deuten auf Items mit unrealistischen Antwortmustern hin.

3.2.5 Infit/Outfit Person Map

Ganz analog zur Item Map zeigt die Person Map, welche Personen zu wahrscheinliche bzw. zu unwahrscheinliche Antwortmuster aufweisen. Die Graphik zeigt wiederum die entsprechenden t-Statistiken. Werte unter -2 und über +2 deuten auf Personen mit unrealistischen Antwortmustern hin.

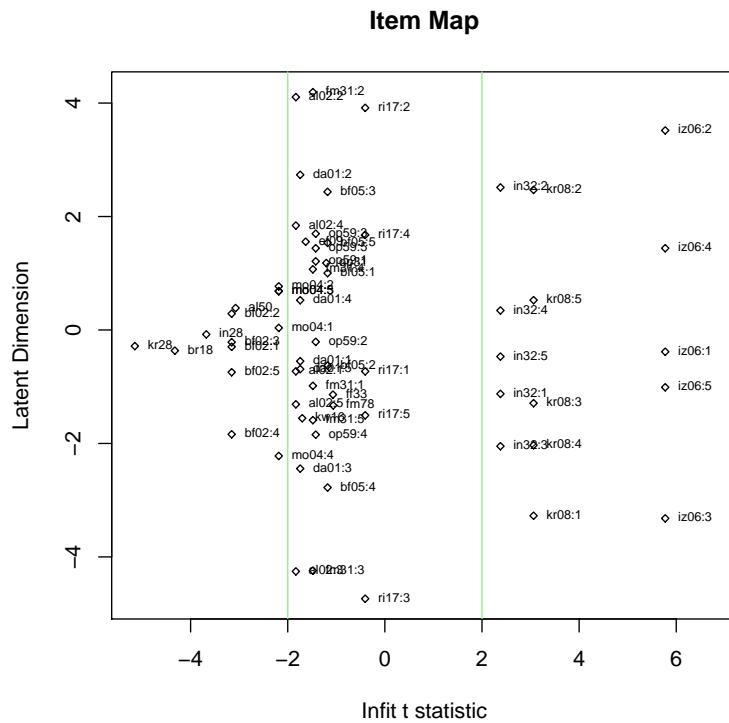


Abbildung 11: Infit/Outfit Item Map

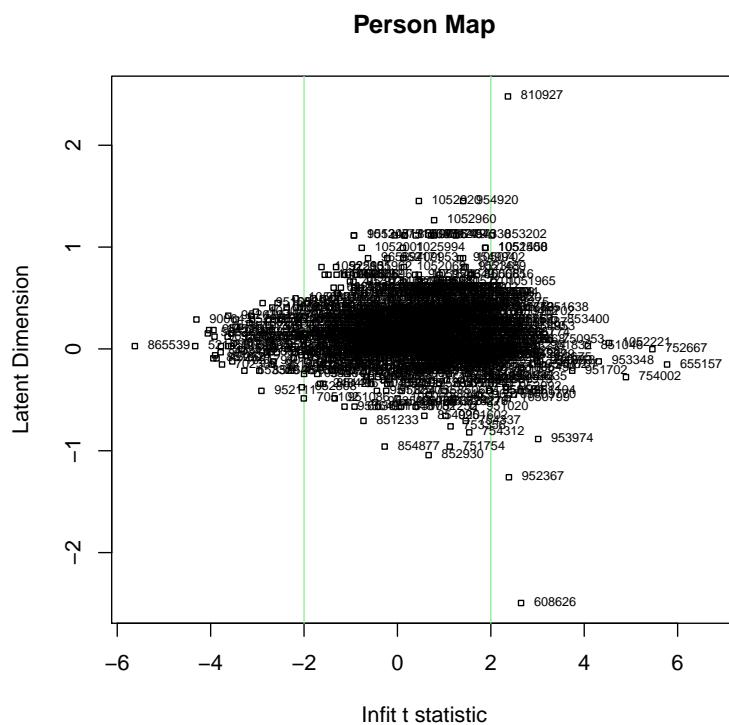


Abbildung 12: Infit/Outfit Person Map

4 Fragenbasierte Auswertung

Im Folgenden werden die einzelnen Prüfungsfragen noch genauer analysiert, dabei werden für jede Frage verschiedene Informationen gegeben:

- Der β -Parameter beschreibt die Einfachheit des Items bzw. der Antwortkategorie (vgl. auch Abschnitt 2)
- Der Wald Test prüft, ob ein Item für Personen mit gleicher allgemeiner Fähigkeit unterschiedlich schwer ist (analog zum Andersen LR-Test auf Prüfungsebene). Bei einem p-Wert kleiner als 0.05 ist dies der Fall. Die Testpersonen werden wieder nach verschiedenen Kriterien in zwei Gruppen unterteilt, und zwar nach dem Median der erreichten Testscores, nach dem Geschlecht, nach der Matrikelnummer (2010 oder früher), und nach der Anzahl der Antritte (Erstantritt oder Wiederholung).
- Die Item Characteristic Curves (ICCs) stellen die Wahrscheinlichkeit dar, mit der eine Testperson mit einer bestimmten Fähigkeit in eine bestimmte Antwortkategorie fällt.
- Die Schwellenwerte (thresholds) beschreiben die Werte auf der Fähigkeitsskala, bei denen die ICCs aufeinanderfolgender Antwortkategorien einander schneiden. Personen mit Fähigkeitsparametern zwischen zwei Schwellenwerten fallen dann am wahrscheinlichsten in jene Antwortkategorie, die von diesen zwei Schwellenwerten begrenzt wird.

4.1 Frage op59

Fragschwierigkeiten der Kategorie (beta values):

```
beta op59.c1 beta op59.c2 beta op59.c3 beta op59.c4 beta op59.c5
[1,] -1.2105708 -1.0013605 -2.6991183 -0.8539661 -2.2950908
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
0.4590182	1.2105708	-0.2092103	1.6977578	-1.8451521	1.4411247

Wald test:

	beta op59.c1	beta op59.c2	beta op59.c3	beta op59.c4	beta op59.c5
z-med	-2.31151292	1.893956404	-1.38099233	1.4911595	0.8038466
p-med	0.02080454	0.058230797	0.16728132	0.1359196	0.4214856
z-matr	-2.10244744	-0.889858392	-1.70881237	-0.4361902	-1.5459714
p-matr	0.03551410	0.373541928	0.08748571	0.6626988	0.1221115
z-sex	1.39015389	-3.265131686	1.83619356	0.3846923	0.5222477
p-sex	0.16448215	0.001094132	0.06632904	0.7004654	0.6014979
z-erst	-1.87451041	1.836694735	-1.59268220	-0.0550389	0.1895267
p-erst	0.06086011	0.066254973	0.11123150	0.9561075	0.8496800

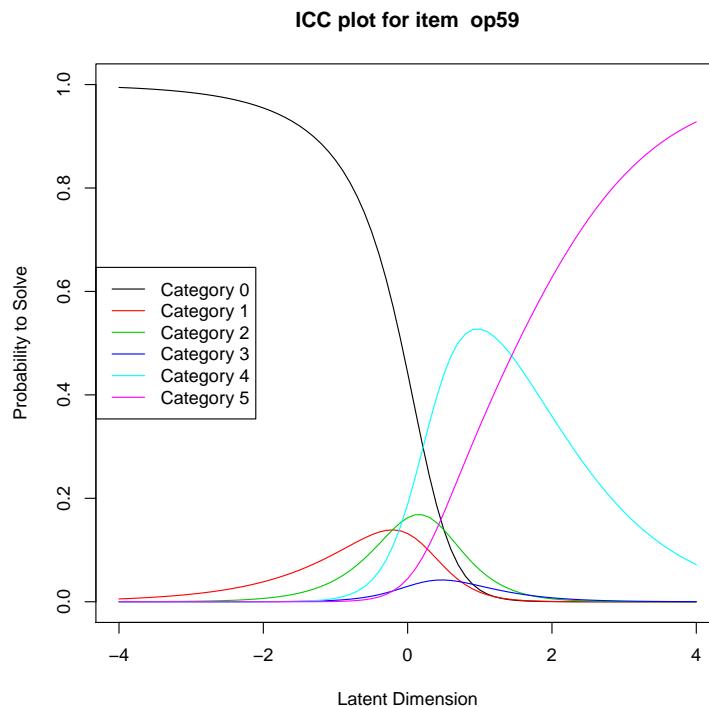


Abbildung 13: Item Characteristic Curve für Frage op59

4.2 Frage da01

Fragschwierigkeiten der Kategorie (beta values):

```
beta da01.c1 beta da01.c2 beta da01.c3 beta da01.c4 beta da01.c5
[1,] 0.5498579 -2.1851246 0.2580062 -0.2668679 0.4228472
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-0.08456944	-0.54985791	2.73498253	-2.44313081	0.52487409	-0.68971511

Wald test:

```
beta da01.c1 beta da01.c2 beta da01.c3 beta da01.c4 beta da01.c5
z-med -0.5200117 -0.3120478 0.12299376 1.86518373 0.78689743
p-med 0.6030554 0.7550042 0.90211204 0.06215566 0.43134191
z-matr 1.1973674 0.8879558 1.86469790 2.08139664 2.00808619
p-matr 0.2311634 0.3745645 0.06222376 0.03739762 0.04463413
z-sex 0.6256647 -0.3047899 -0.70500434 -1.35776179 -0.79637120
p-sex 0.5315349 0.7605262 0.48080753 0.17453928 0.42581631
z-erst -1.0956497 0.1813392 -0.42452791 -0.97941484 0.72852981
p-erst 0.2732321 0.8561013 0.67118085 0.32737505 0.46628933
```

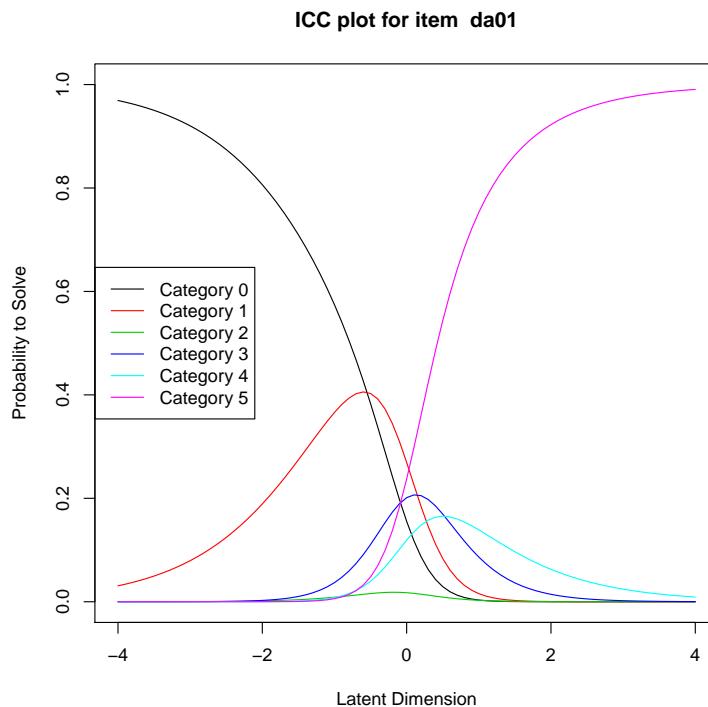


Abbildung 14: Item Characteristic Curve für Frage da01

4.3 Frage br18

Frage Schwierigkeiten der Kategorie (beta values):

```
beta br18.c1  
[1,] 0.3637956
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-0.3637956	-0.3637956				

Wald test:

	z-statistic	p-value
1	-4.0900493	4.312816e-05
2	0.8648437	3.871246e-01
3	0.7920074	4.283564e-01
4	1.3074366	1.910645e-01

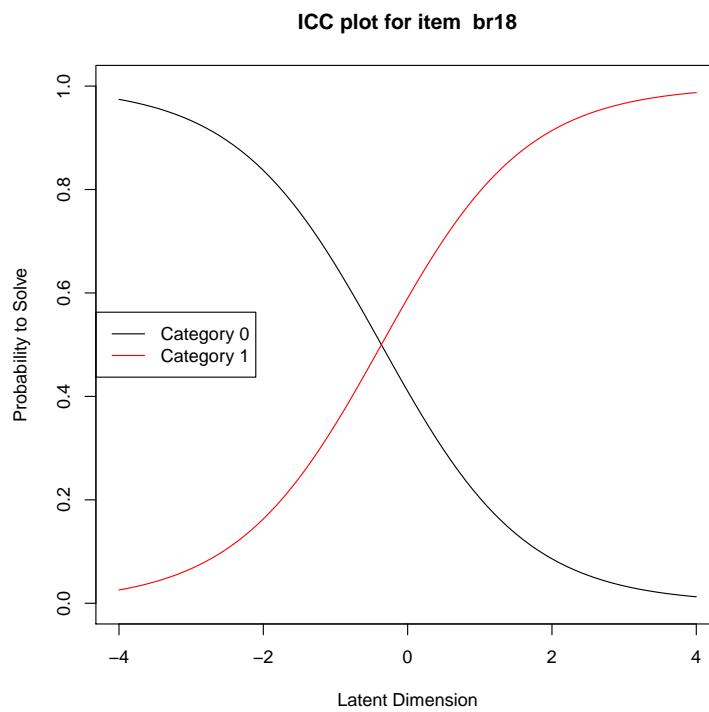


Abbildung 15: Item Characteristic Curve für Frage br18

4.4 Frage al50

Fragschwierigkeiten der Kategorie (beta values):

```
beta al50.c1  
[1,] -0.3870215
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
0.3870215	0.3870215				

Wald test:

	z-statistic	p-value
1	-1.2837494	0.1992297
2	-0.9554649	0.3393427
3	-0.8578627	0.3909683
4	0.9980362	0.3182618

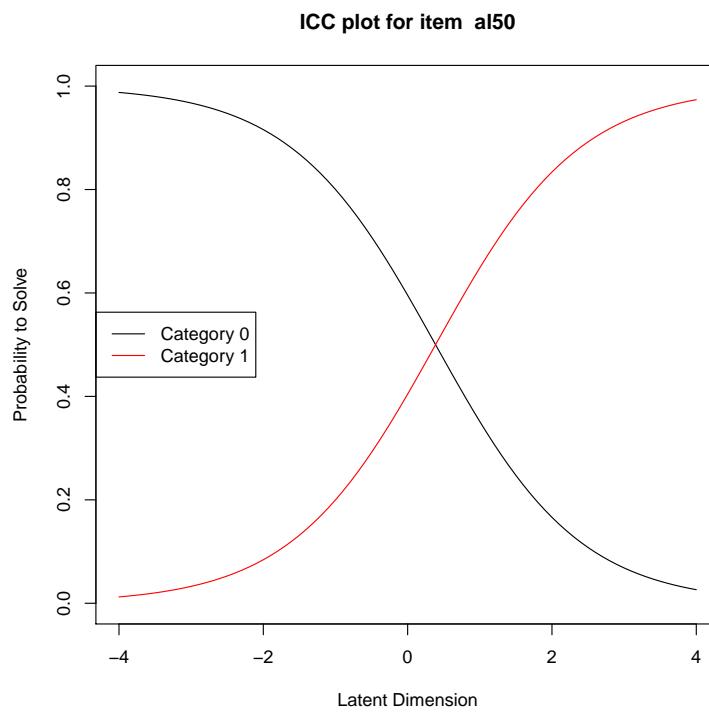


Abbildung 16: Item Characteristic Curve für Frage al50

4.5 Frage bf05

Fragschwierigkeiten der Kategorie (beta values):

```
beta bf05.c1 beta bf05.c2 beta bf05.c3 beta bf05.c4 beta bf05.c5
[1,] -1.00262717 -0.37663215 -2.81184378 -0.03483333 -1.57042274
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
0.3140845	1.0026272	-0.6259950	2.4352116	-2.7770104	1.5355894

Wald test:

	beta bf05.c1	beta bf05.c2	beta bf05.c3	beta bf05.c4	beta bf05.c5
z-med	-0.8179890	0.51594876	-0.8146703	1.4655719	-0.0420899
p-med	0.4133635	0.60589020	0.4152611	0.1427649	0.9664270
z-matr	-0.5097217	0.53205173	1.2474705	-0.8822704	-0.9072632
p-matr	0.6102465	0.59469017	0.2122250	0.3776306	0.3642676
z-sex	-0.7775781	-0.19190107	-0.2371865	-0.7749523	-0.2306097
p-sex	0.4368178	0.84781970	0.8125121	0.4383678	0.8176180
z-erst	-1.1988202	2.01872525	-0.4386893	0.7845443	0.3520420
p-erst	0.2305979	0.04351578	0.6608867	0.4327208	0.7248068

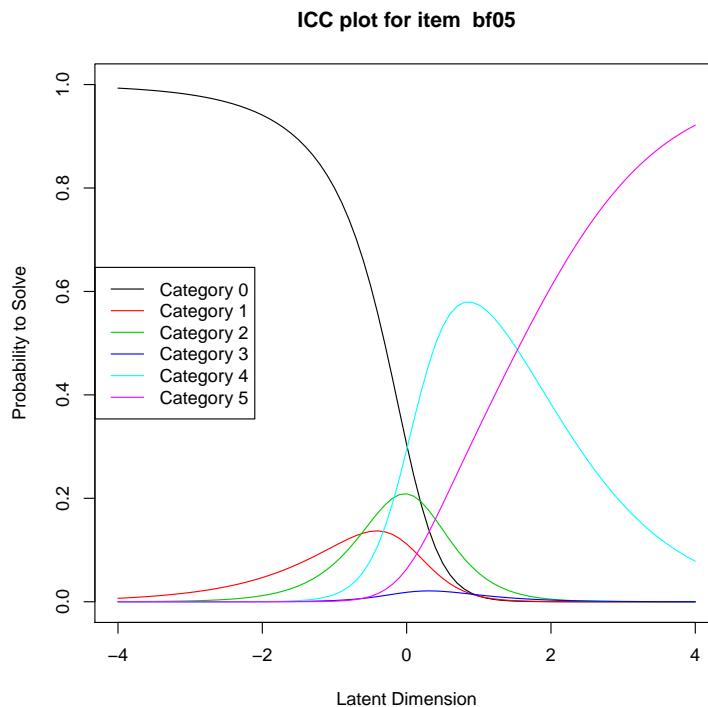


Abbildung 17: Item Characteristic Curve für Frage bf05

4.6 Frage bf02

Fragenschwierigkeiten der Kategorie (beta values):

```
  beta bf02.c1 beta bf02.c2 beta bf02.c3 beta bf02.c4 beta bf02.c5  
[1,] 0.2962624 0.0087107 0.2233678 2.0616397 2.8062486
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-0.5612497	-0.2962624	0.2875517	-0.2146571	-1.8382720	-0.7446089

Wald test:

```
$median  
  z-statistic p-value  
  
$matr  
  z-statistic p-value  
beta bf02.c1 -0.43319656 0.6648720  
beta bf02.c2  1.49184675 0.1357393  
beta bf02.c3 -0.24419543 0.8070795  
beta bf02.c4  0.73722872 0.4609833  
beta bf02.c5  0.02800458 0.9776585  
  
$sex  
  z-statistic p-value  
beta bf02.c1 -0.7003258 0.4837238  
beta bf02.c2 -0.9042941 0.3658395  
beta bf02.c3 -1.6112310 0.1071294  
beta bf02.c4 -0.2582319 0.7962279  
beta bf02.c5  0.6191423 0.5358226  
  
$erst  
  z-statistic p-value  
beta bf02.c1 -0.07663506 0.9389139  
beta bf02.c2  0.41045514 0.6814721  
beta bf02.c3 -0.77696167 0.4371814  
beta bf02.c4  0.91573754 0.3598046  
beta bf02.c5 -0.01898626 0.9848521
```

4.7 Frage mo04

Fragenschwierigkeiten der Kategorie (beta values):

```
beta mo04.c1 beta mo04.c2 beta mo04.c3 beta mo04.c4 beta mo04.c5
[1,] -0.03758711 -0.80648005 -1.48983407 0.73022746 0.04486325
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-0.00897265	0.03758711	0.76889293	0.68335402	-2.22006153	0.68536421

Wald test:

	beta mo04.c1	beta mo04.c2	beta mo04.c3	beta mo04.c4	beta mo04.c5
z-med	-2.17402764	-0.14774031	-0.92497566	-0.096746380	0.2337876
p-med	0.02970306	0.88254772	0.35497857	0.922927806	0.8151499
z-matr	0.13031586	1.74875873	0.61260096	0.495855093	-0.5157083
p-matr	0.89631653	0.08033273	0.54014023	0.619996651	0.6060582
z-sex	-0.11199749	0.62703587	-0.07341877	-2.694163485	-2.0544909
p-sex	0.91082540	0.53063572	0.94147288	0.007056554	0.0399282
z-erst	-2.41466764	2.32469292	-1.32185311	1.747372194	0.4103793
p-erst	0.01574957	0.02008839	0.18621707	0.080572798	0.6815277

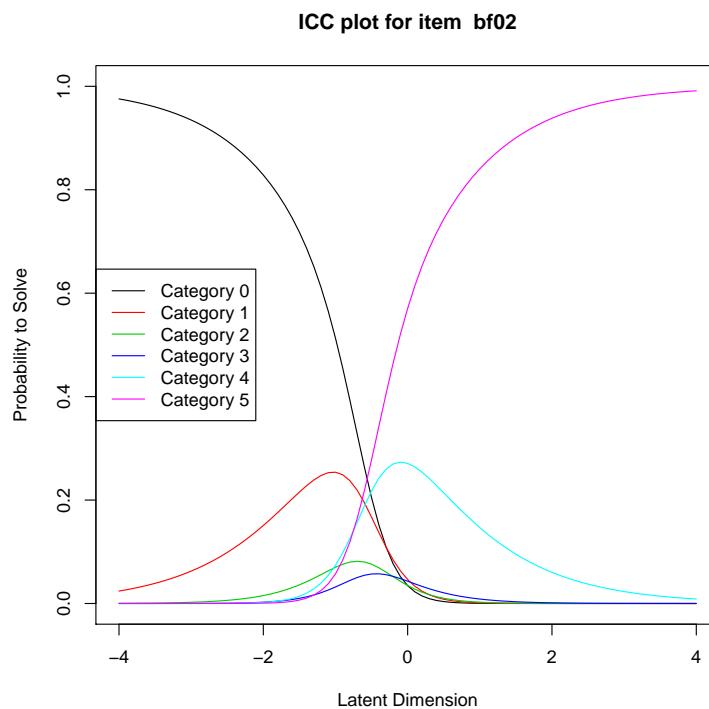


Abbildung 18: Item Characteristic Curve für Frage bf02

4.8 Frage al02

Fragenschwierigkeiten der Kategorie (beta values):

```
beta al02.c1 beta al02.c2 beta al02.c3 beta al02.c4 beta al02.c5
[1,] 0.7280509 -3.3770381 0.8781117 -0.9636471 0.3459871
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-0.06919742	-0.72805089	4.10508895	-4.25514972	1.84175874	-1.30963418

Wald test:

	beta al02.c1	beta al02.c2	beta al02.c3	beta al02.c4	beta al02.c5
z-med	0.5154534	0.2979883	-0.03959645	1.7654260	0.4233529
p-med	0.6062362	0.7657121	0.96841486	0.0774922	0.6720378
z-matr	0.6425820	-0.5763715	-0.64988388	0.3054013	-0.9864742
p-matr	0.5204954	0.5643641	0.51576723	0.7600606	0.3239005
z-sex	-0.9440073	-0.7056850	-0.97979393	-1.0822892	-1.3227810
p-sex	0.3451659	0.4803840	0.32718785	0.2791240	0.1859082
z-erst	-0.5142904	0.9571167	0.80612373	-0.7111711	1.0988856
p-erst	0.6070490	0.3385084	0.42017151	0.4769782	0.2718180

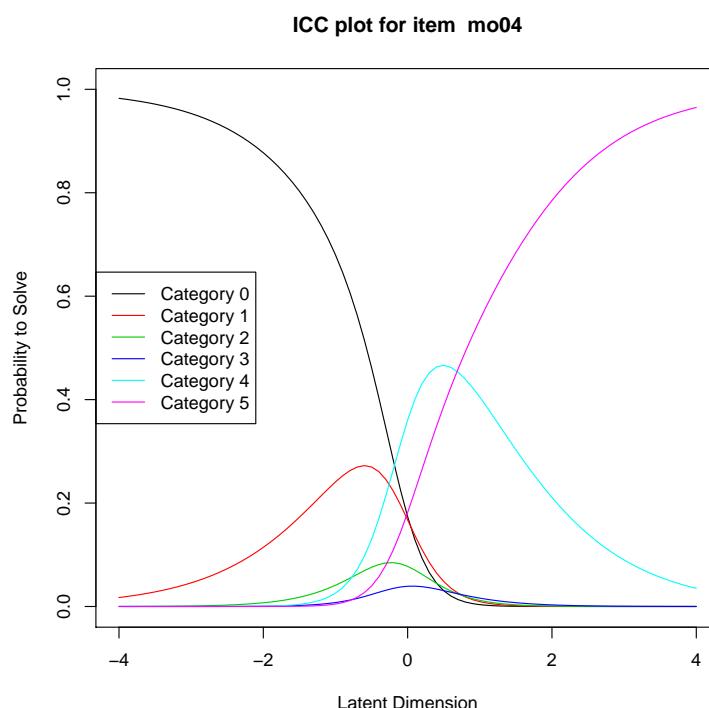


Abbildung 19: Item Characteristic Curve für Frage mo04

4.9 Frage op31

Fragenschwierigkeiten der Kategorie (beta values):

```
beta op31.c1  
[1,] -1.180427
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
1.180427		1.180427			

Wald test:

	z-statistic	p-value
1	-1.218770	0.222931408
2	-2.270275	0.023190892
3	2.963125	0.003045329
4	-3.007184	0.002636799

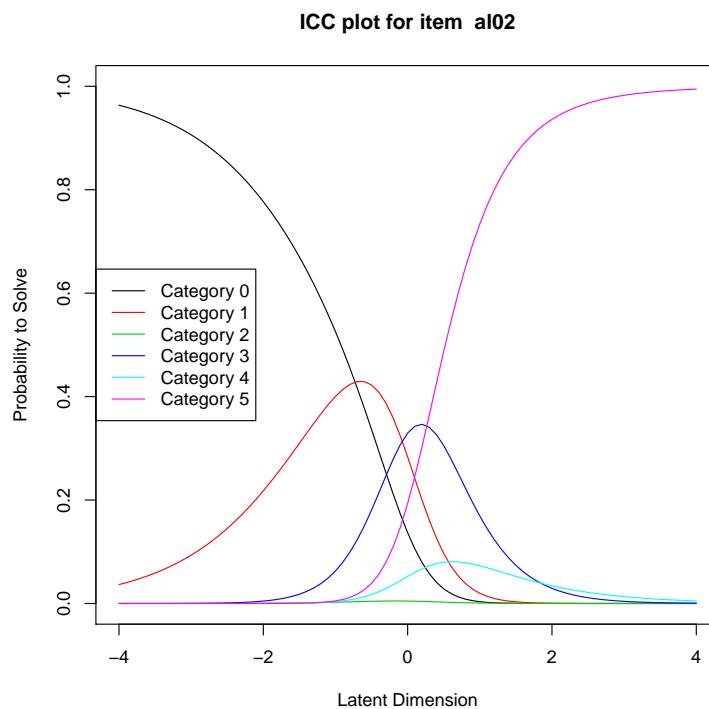


Abbildung 20: Item Characteristic Curve für Frage al02

4.10 Frage ri17

Fragenschwierigkeiten der Kategorie (beta values):

```
beta ri17.c1 beta ri17.c2 beta ri17.c3 beta ri17.c4 beta ri17.c5
[1,] 0.7294004 -3.1865354 1.5500135 -0.1265023 1.3774693
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-0.2754939	-0.7294004	3.9159358	-4.7365489	1.6765158	-1.5039717

Wald test:

```
$median
z-statistic p-value

$matr
z-statistic p-value

$sex
z-statistic p-value
beta ri17.c1 1.42979734 0.1527752
beta ri17.c2 0.24330809 0.8077667
beta ri17.c3 -0.09456202 0.9246627
beta ri17.c4 0.50903972 0.6107244
```

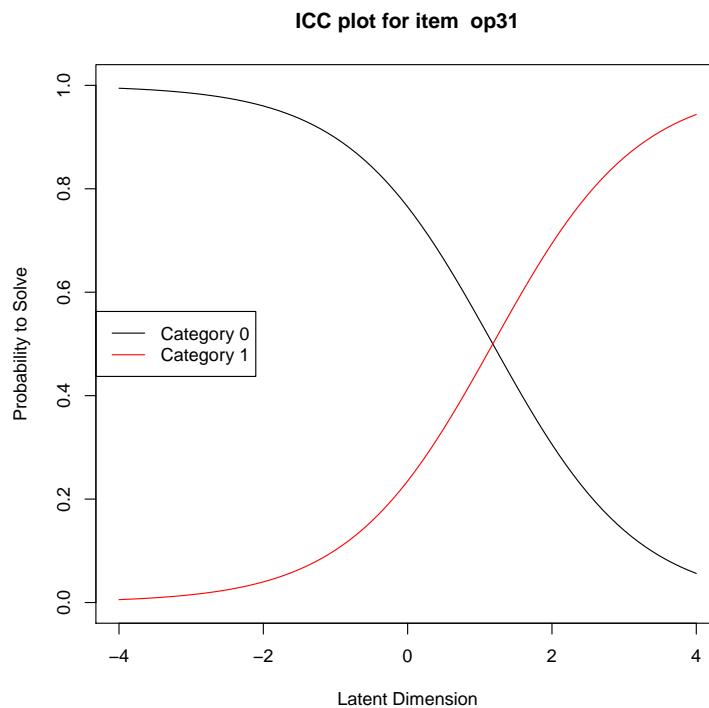


Abbildung 21: Item Characteristic Curve für Frage op31

```
beta ri17.c5 0.63484762 0.5255278
```

```
$erst  
z-statistic p-value
```

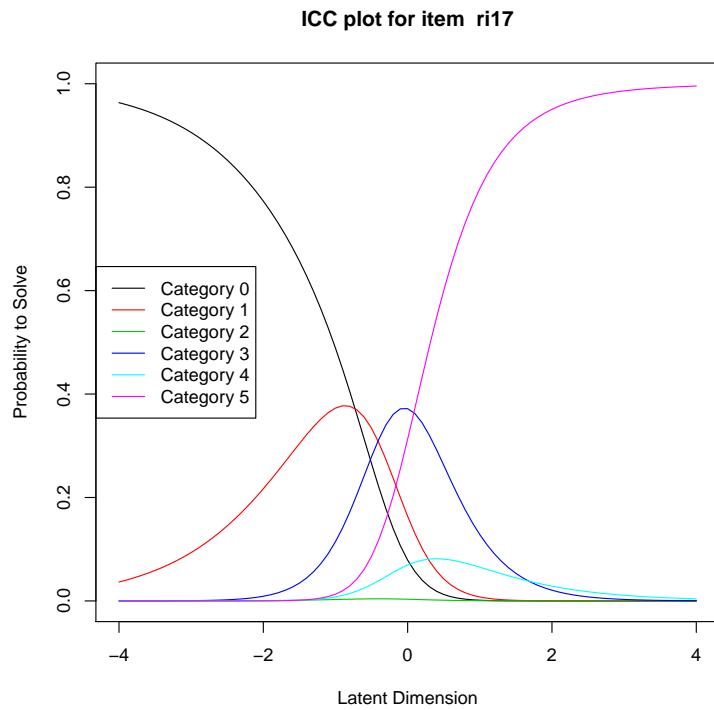


Abbildung 22: Item Characteristic Curve für Frage ri17

4.11 Frage kr08

Fragenschwierigkeiten der Kategorie (beta values):

```
beta kr08.c1 beta kr08.c2 beta kr08.c3 beta kr08.c4 beta kr08.c5  
[1,] 3.2741855 0.8044954 2.0949326 4.1250293 3.5991415
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-0.7198283	-3.2741855	2.4696900	-1.2904372	-2.0300967	0.5258878

Wald test:

```
$median  
z-statistic p-value  
  
$matr  
z-statistic p-value  
  
$sex  
z-statistic p-value  
beta kr08.c1 0.7488630 0.4539398  
beta kr08.c2 1.0009947 0.3168294  
beta kr08.c3 1.2009986 0.2297518  
beta kr08.c4 0.8511795 0.3946696  
beta kr08.c5 1.3634433 0.1727429  
  
$erst  
z-statistic p-value
```

4.12 Frage kw16

Fragenschwierigkeiten der Kategorie (beta values):

```
beta_kw16.c1  
[1,] 1.555169
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-1.555169	-1.555169				

Wald test:

	z-statistic	p-value
1	-4.592531	4.379024e-06
2	-1.783720	7.446914e-02
3	2.070895	3.836861e-02
4	1.547656	1.217052e-01

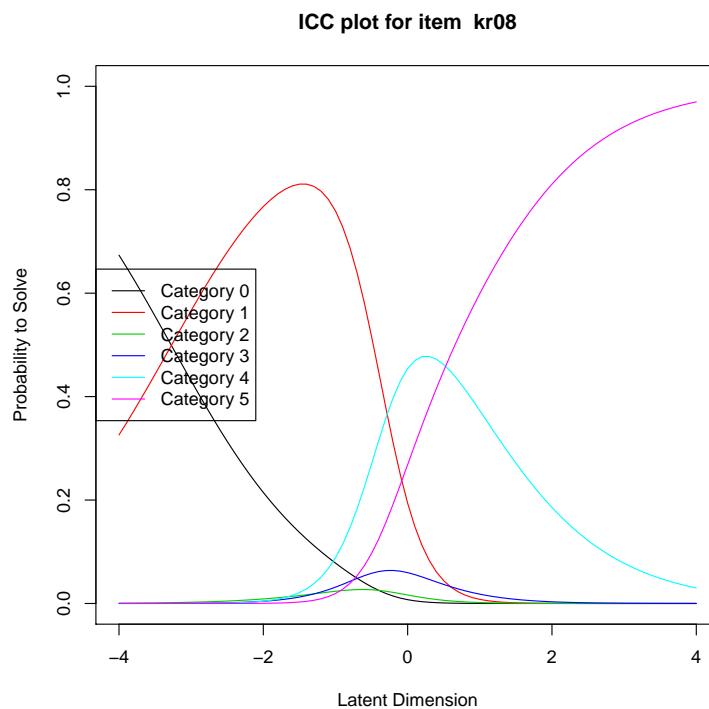


Abbildung 23: Item Characteristic Curve für Frage kr08

4.13 Frage iz06

Fragenschwierigkeiten der Kategorie (beta values):

```
beta iz06.c1 beta iz06.c2 beta iz06.c3 beta iz06.c4 beta iz06.c5  
[1,] 0.3834930 -3.1339673 0.1864536 -1.2554218 -0.2458852
```

Thresholds:

```
Location Threshold 1 Threshold 2 Threshold 3 Threshold 4 Threshold 5  
0.04917704 -0.38349298 3.51746031 -3.32042097 1.44187540 -1.00953658
```

Wald test:

```
$median  
      z-statistic      p-value  
beta iz06.c1 0.2008697 8.408004e-01  
beta iz06.c2 1.0762482 2.818163e-01  
beta iz06.c3 1.2150970 2.243291e-01  
beta iz06.c4 4.2363312 2.272016e-05  
beta iz06.c5 4.7018473 2.578183e-06  
  
$matr  
      z-statistic p-value  
  
$sex
```

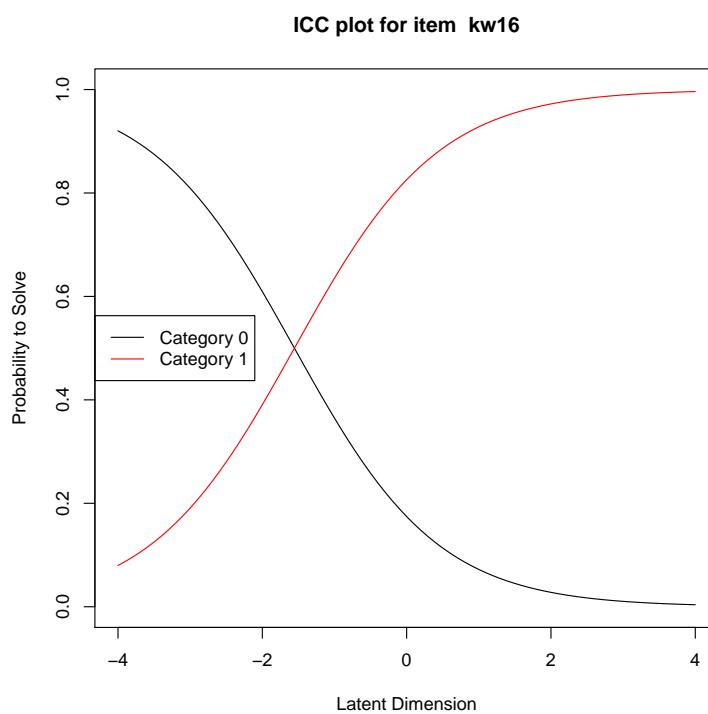


Abbildung 24: Item Characteristic Curve für Frage kw16

```

      z-statistic      p-value
beta iz06.c1   -3.261541 0.001108083
beta iz06.c2    1.081964 0.279268679
beta iz06.c3   -1.362187 0.173139029
beta iz06.c4   -2.926307 0.003430120
beta iz06.c5   -2.017798 0.043612315

```

```

$erst
      z-statistic      p-value
beta iz06.c1   -1.0077484 0.3135753
beta iz06.c2    0.4945403 0.6209247
beta iz06.c3    0.1996817 0.8417295
beta iz06.c4    0.3601030 0.7187701
beta iz06.c5    0.7125281 0.4761378

```

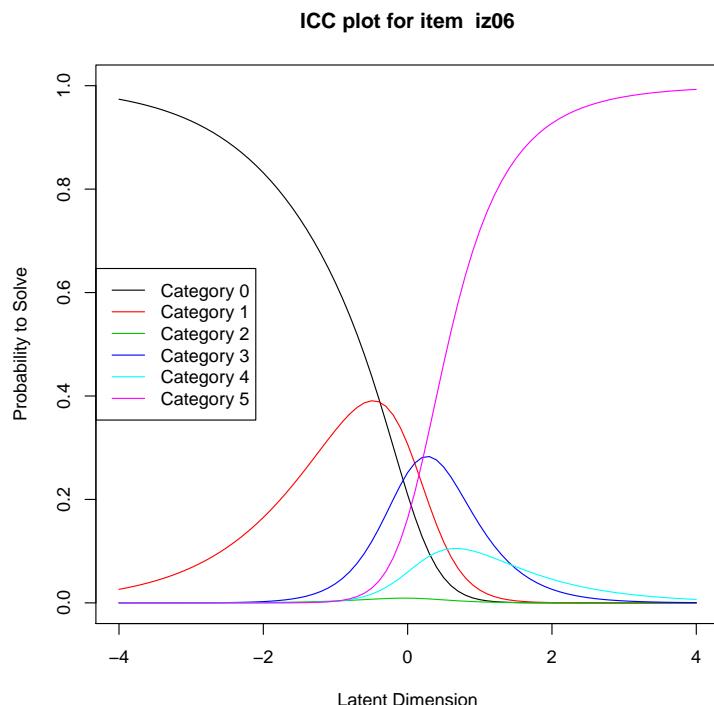


Abbildung 25: Item Characteristic Curve für Frage iz06

4.14 Frage kr28

Fragenschwierigkeiten der Kategorie (beta values):

```
beta kr28.c1  
[1,] 0.2837048
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-0.2837048	-0.2837048				

Wald test:

z-statistic	p-value
1 -3.407392	0.0006558676
2 -2.339038	0.0193334476
3 2.343690	0.0190940380
4 2.122719	0.0337773712

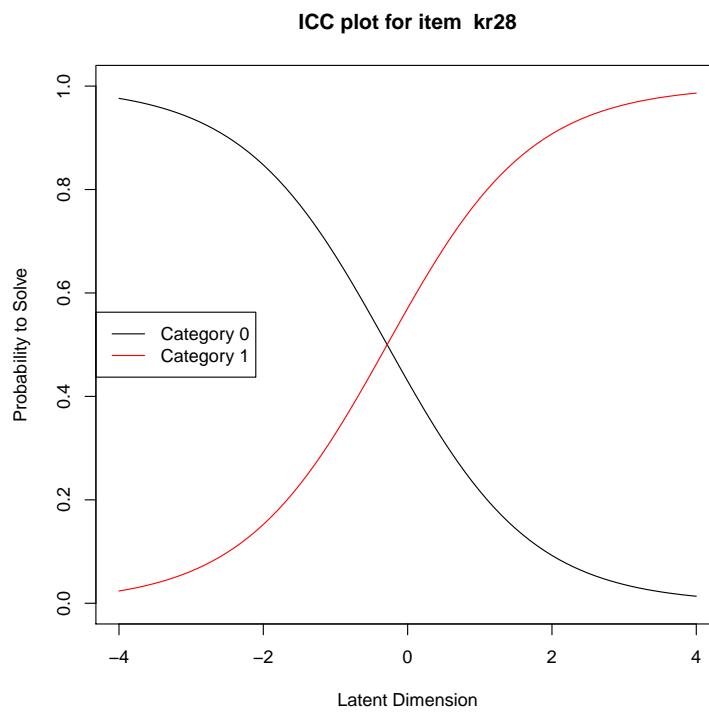


Abbildung 26: Item Characteristic Curve für Frage kr28

4.15 Frage in32

Fragenschwierigkeiten der Kategorie (beta values):

```
beta in32.c1 beta in32.c2 beta in32.c3 beta in32.c4 beta in32.c5
[1,] 1.1259781 -1.3869462 0.6615293 0.3174796 0.7857200
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-0.1571440	-1.1259781	2.5129243	-2.0484755	0.3440497	-0.4682404

Wald test:

```
beta in32.c1 beta in32.c2 beta in32.c3 beta in32.c4 beta in32.c5
z-med 0.2575029 0.9997720 1.97759666 3.953070e+00 2.12806412
p-med 0.7967906 0.3174209 0.04797423 7.715492e-05 0.03333177
z-matr -1.3214671 -0.6370669 0.01129243 -5.128978e-01 -0.31810680
p-matr 0.1863457 0.5240813 0.99099013 6.080228e-01 0.75040392
z-sex 0.7624640 -1.6350889 -0.24914407 -8.068082e-01 -0.45594417
p-sex 0.4457831 0.1020304 0.80324934 4.197770e-01 0.64843012
z-erst -0.1394572 -1.5523603 0.40593653 -7.176984e-01 1.10091225
p-erst 0.8890889 0.1205760 0.68478924 4.729432e-01 0.27093485
```

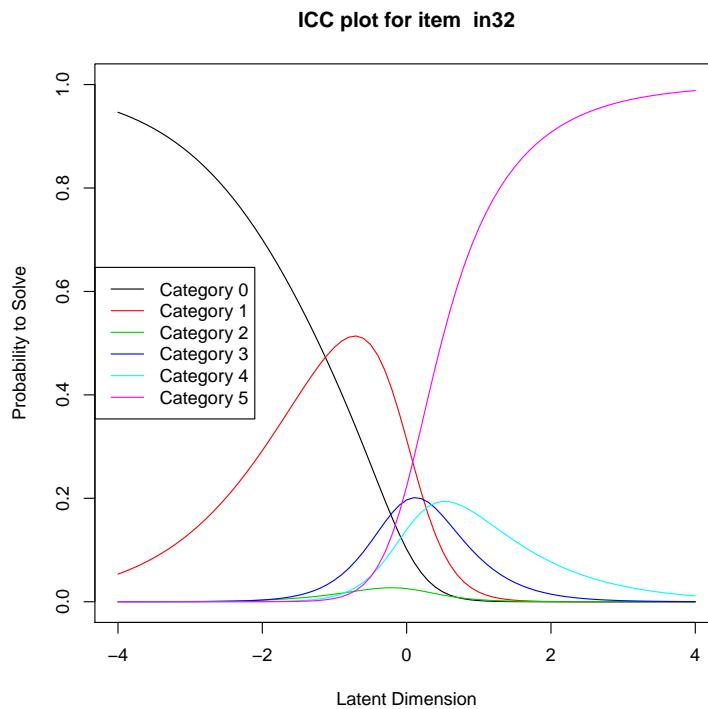


Abbildung 27: Item Characteristic Curve für Frage in32

4.16 Frage in28

Fragenschwierigkeiten der Kategorie (beta values):

```
beta_in28.c1  
[1,] 0.07738514
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
	-0.07738514	-0.07738514			

Wald test:

	z-statistic	p-value
1	-2.1644605	0.03042903
2	-0.4823945	0.62952572
3	2.1633792	0.03051203
4	-0.5709505	0.56803321

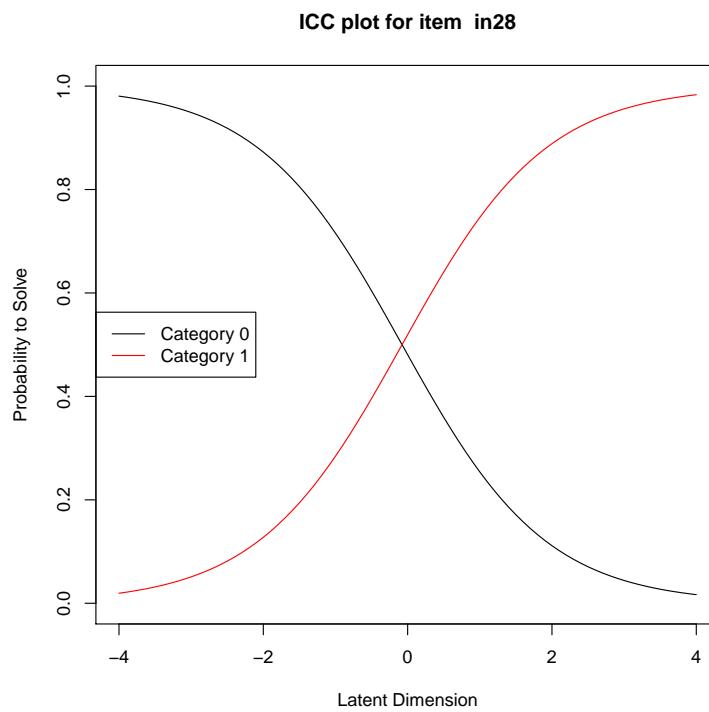


Abbildung 28: Item Characteristic Curve für Frage in28

4.17 Frage fm31

Frage Schwierigkeiten der Kategorie (beta values):

```
beta fm31.c1 beta fm31.c2 beta fm31.c3 beta fm31.c4 beta fm31.c5  
[1,] 0.98412042 -3.20866768 1.03271787 -0.03685394 1.55212831
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-0.3104257	-0.9841204	4.1927881	-4.2413856	1.0695718	-1.5889823

Wald test:

```
$median  
      z-statistic   p-value  
beta fm31.c1 -1.2758144 0.2020211  
beta fm31.c2 -0.8237856 0.4100614  
beta fm31.c3 -1.2914608 0.1965439  
beta fm31.c4 -1.1518181 0.2493958  
beta fm31.c5 -0.3167505 0.7514329  
  
$matr  
      z-statistic   p-value  
  
$sex  
      z-statistic   p-value  
  
$erst  
      z-statistic   p-value
```

4.18 Frage fm78

Fragenschwierigkeiten der Kategorie (beta values):

```
beta fm78.c1  
[1,] 1.329755
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-1.329755	-1.329755				

Wald test:

z-statistic	p-value
1 -1.911816	0.055899759
2 -1.264037	0.206216667
3 3.067864	0.002155948
4 -1.306839	0.191267340

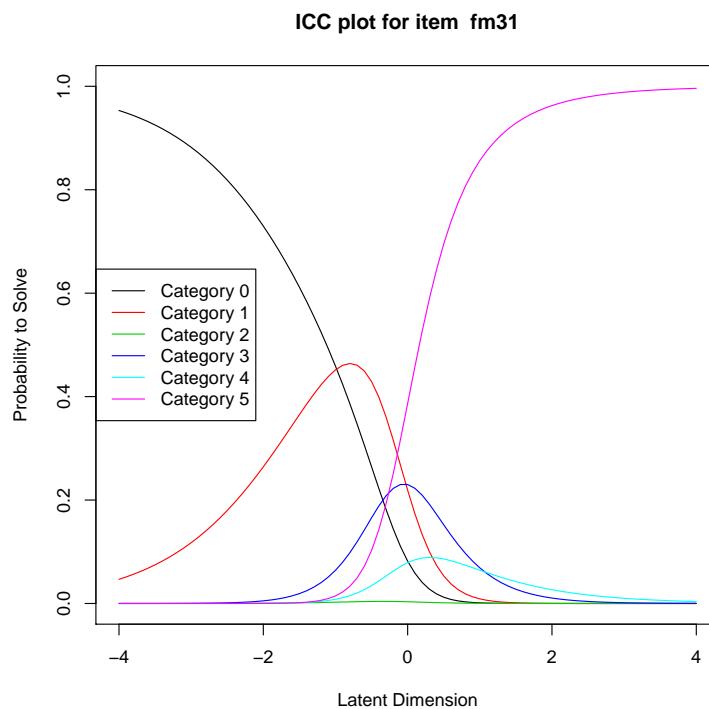


Abbildung 29: Item Characteristic Curve für Frage fm31

4.19 Frage ef09

Fragenschwierigkeiten der Kategorie (beta values):

```
beta_ef09.c1  
[1,] -1.556307
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
1.556307	1.556307				

Wald test:

z-statistic	p-value
1 -2.3564225	0.01845192
2 -2.0874942	0.03684348
3 0.2109942	0.83289178
4 -1.2815422	0.20000330

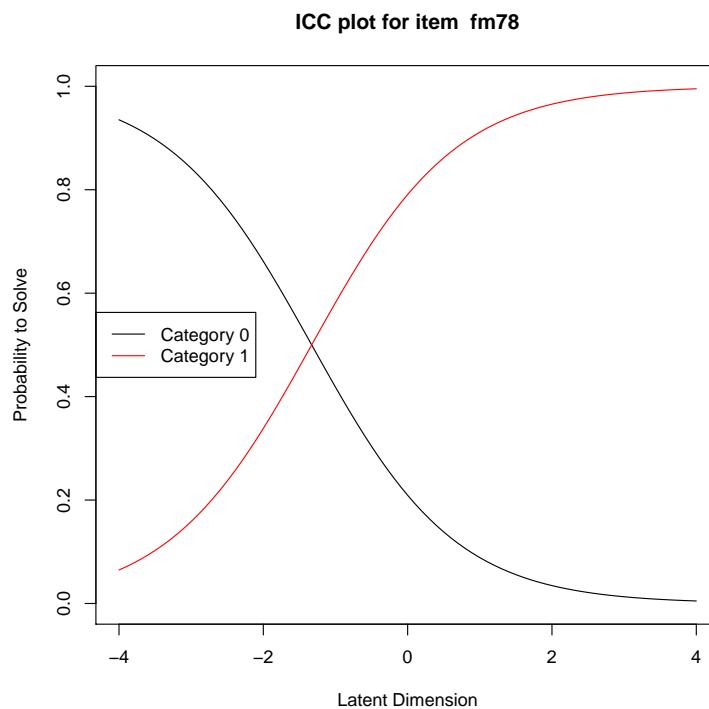


Abbildung 30: Item Characteristic Curve für Frage fm78

4.20 Frage ff33

Fragenschwierigkeiten der Kategorie (beta values):

```
beta_ff33.c1  
[1,] 1.139302
```

Thresholds:

Location	Threshold 1	Threshold 2	Threshold 3	Threshold 4	Threshold 5
-1.139302	-1.139302				

Wald test:

z-statistic	p-value
1 -2.6178421	0.008848774
2 0.2747749	0.783489168
3 1.1712307	0.241506051
4 0.9411055	0.346650788

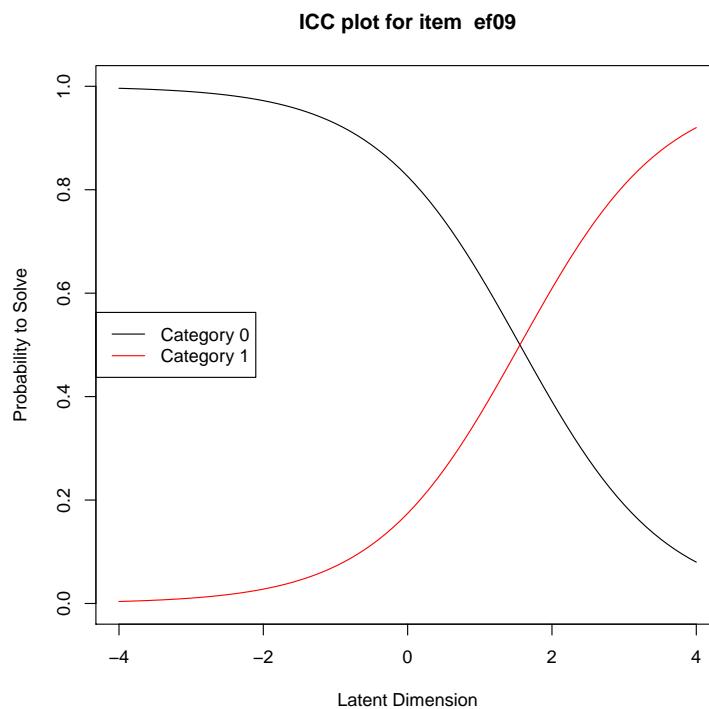


Abbildung 31: Item Characteristic Curve für Frage ef09

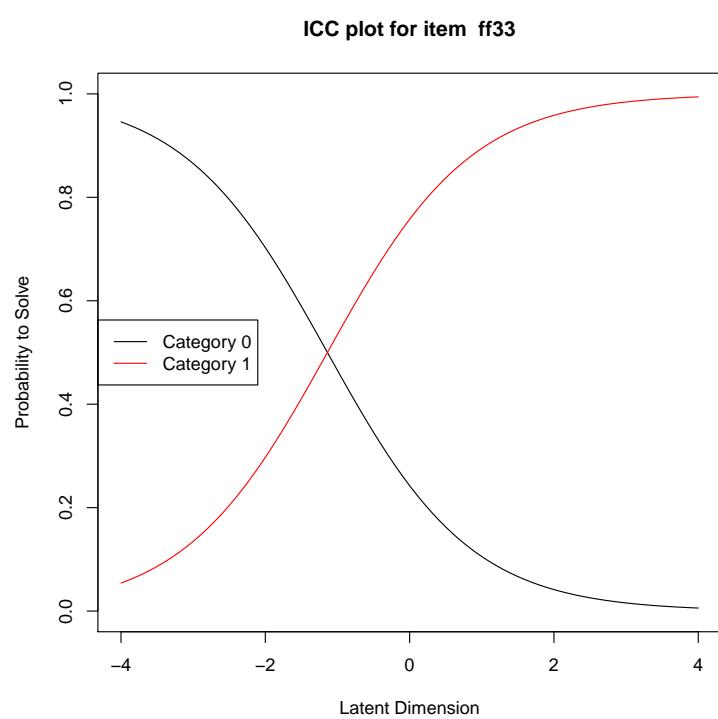


Abbildung 32: Item Characteristic Curve für Frage ff33