


# Partial Credit Model und Tutz Model

Martina Maida, Maria Weiler

November 22, 2011



## Item Response Theory - Partial Credit Model

Einleitung

IRT-Einteilung

Datenstruktur

PCM - Herleitung

Parameterschätzung

Goodness of Fit

Beispiel

## Sequential Models for Ordered Responses

Charakteristika


Daten

Datenstruktur

Herleitung

Parameterschätzung

Goodness of Fit



# Background

Psychologische Tests verfolgen das Ziel, mit wissenschaftlichen Methoden quantitative Aussagen über den relativen Grad der individuellen Ausprägung eines Merkmals zu treffen. Um eine solche Aussage fundiert zu ermöglichen, basieren psychologische Tests auf einer Testtheorie. Sie beschreibt den Zusammenhang zwischen dem zu erfassenden Merkmal und dem Testverhalten (Rost, 1996).



# Klassische Testtheorie

- ▶ Zentrales Konzept ist Reliabilität
- ▶ Messfehlertheorie  $X = T + E$
- ▶ Reliabilität kann nicht direkt berechnet werden
- ▶ Reliabilität ist streng genommen das einzige Gütekriterium
- ▶ Messungen basieren auf Korrelationen
- ▶ -> Stichprobenabhängigkeit



# Item Response Theory

- ▶ Probabilistische Theorie oder latent trait theory
- ▶ misst latente Variablen
- ▶ Messung der Wahrscheinlichkeit von korrekten Antworten
- ▶ Mathematische Funktion von Personen und Items
- ▶ nach van der Linden Hambleton (1997) über 100 IRT Modelle



# 1 PLM Parameter Logistic Model

▶ 1 PLM

▶ 
$$P(X_{vi} = 1 | \theta_v, \beta_i) = \frac{\exp(\theta_v - \beta_i)}{1 + \exp(\theta_v - \beta_i)}$$

$X_{vi}$  ... person  $v$  agrees to statement  $i$ ,  $i = 1 \dots k$ ,  $v = 1 \dots n$

$\theta_v$  ... location of person  $v$  on latent trait (amount of trait)

$\beta_i$  ... location of item  $i$  on latent trait (stimulative nature)

in case of performance tests:

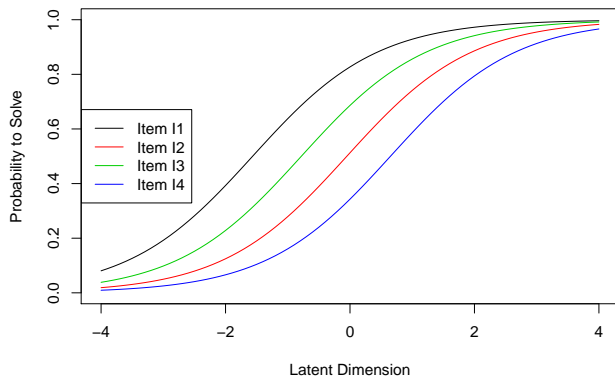
$X_{vi}$  ... person  $v$  gives correct answer to item  $i$

$\theta_v$  ... 'ability' of person  $v$

$\beta_i$  ... 'difficulty' of item  $i$



ICC plot



## 4 Items 1PLM (zB Rasch Modell)



# Rasch - Assumptions / Properties

- ▶ Lokale stochastische Unabhängigkeit
- ▶ Suffizienz der Randsummen
- ▶ Monotonie
- ▶ Eindimensionalität





## 2 PLM Parameter Logistic Model

- ▶ 2 PLM

- ▶ 
$$P(X_{vi} = 1 | \theta_v, \beta_i, \alpha_i) = \frac{\exp((\theta_v - \beta_i)\alpha_i)}{1 + \exp((\theta_v - \beta_i)\alpha_i)}$$

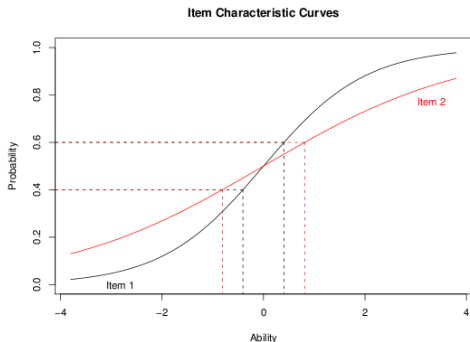
$\alpha$  ... item discriminating power,

zeigt den Anstieg der ICC für item  $i$  bei  $p = 0.5$



## 2 PLM ICC - Grafik: Psychometric Methods 2010/11

'discrimination' for Item 1:  $\alpha_1 = 1$ , for Item 2:  $\alpha_2 = 0.5$





## 3 PLM Parameter Logistic Model

- ▶ 3 PLM


- ▶ 
$$P(X_{vi} = 1 | \theta_v, \beta_i, \alpha_i) = c_i + (1 - c_i) \frac{\exp((\theta_v - \beta_i)\alpha_i)}{1 + \exp((\theta_v - \beta_i)\alpha_i)}$$

$c_i$  ... Ratewahrscheinlichkeit



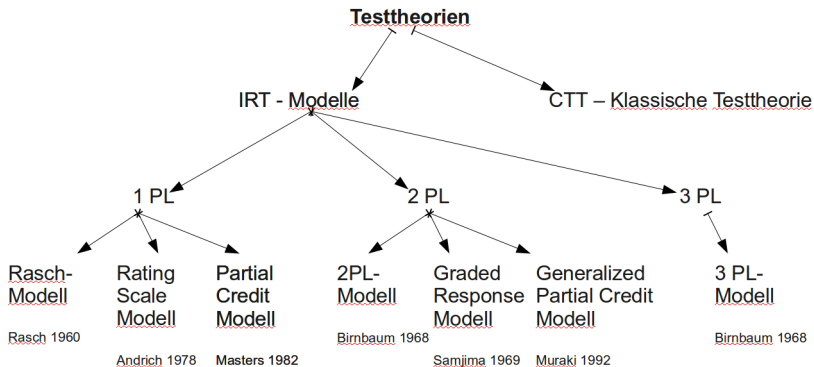
## 3 PLM ICC - Grafik: Psychometric Methods 2010/11

'guessing' probability is 0.25





# Überblick





# Modellübersicht


- ▶ RSM (Rating Scale Model) Polytome Erweiterung des Rasch-Modells, Einführung von Item-Kategorien
- ▶ PCM (Partial Credit Model) Erweiterung des Rating Scale Modells, Verschiedene Anzahl von Kategorien pro Item
- ▶ GRM (Graded Response Model) Erweiterung des 2PL-Modells auf politome Daten
- ▶ GPCM (Generalized PCM) 2PL-Modell, inkludiert den Diskriminationsparameter  $\alpha$




# Partial Credit Model

Masters (1982) erweitert das Rasch Modell um polytome Items mit geordneten Kategorien.


$$P(X_{vih} = 1) = \frac{\exp[h\theta_v - \beta_{ih}]}{\sum_{l=0}^{m_i} \exp(l\theta_v - \beta_{il})}$$



## Category Probability Curves







# Datenstruktur

Startpunkt im PCM (wie auch bei Rasch-Modellen) ist die Personen x Item Matrix.


Beispiel:

7 Aufsätze wurden von 3 Lehrpersonen mit Noten bewertet...



## PCM - Herleitung

	[,1]	[,2]	[,3]
[1,]	1	1	3
[2,]	1	2	5
[3,]	1	2	4
[4,]	2	5	5
[5,]	2	4	4
[6,]	1	1	2
[7,]	1	3	4



# PCM - Herleitung

Rasch Modell für dichotome Daten

$$\frac{P_{iv1}}{P_{iv0} + P_{iv1}} = \frac{\exp(\theta_v - \beta_i)}{1 + \exp(\theta_v - \beta_i)}$$



Erweiterung auf mehr als zwei Antwortkategorien:

$$\frac{P_{ivx}}{P_{ivx} - 1 + P_{ivx}} = \frac{\exp(\theta_v - \beta_{ix})}{1 + \exp(\theta_v - \beta_{ix})}, x = 1, 2, \dots, m_i$$




Die Konvention gibt vor, dass man dies als unbedingte Wahrscheinlichkeit für jedes mögliche Ergebnis umformuliert:

$$\sum_{h=0}^{m_i} P_{ivh} = 1$$

Die Wahrscheinlichkeit der Person  $v$ , dass sie bei Item  $i$   $x$  erzielt, wird wie folgt formuliert:

$$P_{ivx} = \frac{\exp \sum_{k=0}^x (\theta_v - \beta_{ik})}{\sum_{h=0}^{m_v} \exp \sum_{k=0}^h (\theta_v - \beta_{ik})}$$



# Parameterschätzung

- ▶ Mit der Parameterschätzung werden die Item- und Personenparameter geschätzt.
- ▶ Es gibt verschiedene Möglichkeiten der Schätzung:
  - ▶ Conditional Maximum Likelihood
  - ▶ Joint Maximum Likelihood (relativ einfach, aber produziert Bias)
  - ▶ Marginal Maximum Likelihood (benötigt Annahmen über die Verteilung der Personenparameter)



## Conditional Maximum Likelihood

$$L_C = \exp\left(-\sum_i \beta_i s_i\right) / \prod_r \sum_{x|r} \exp\left(-\sum_i x_i \beta_i\right)^{n_r}$$

- ▶ Keine Annahmen über Personenparameter nötig, weil sie in der Conditional Likelihood nicht vorkommen
- ▶ Konsistente Schätzer der Itemparameter
- ▶ Stichprobenunabhängigkeit
- ▶ ...in general the procedure of choice



## Goodness of Fit

- ▶ Prinzipiell gibt es Tests of Itemfit, Personfit und Globalfit
- ▶ item fit identifiziert problematische Items
- ▶ person fit identifiziert Personen mit Antworten, die nicht dem allgemeinen Antwortmuster folgen
- ▶ global fit zeigt den allgemeinen Fit des Datensatzes auf das PCM
- ▶ Für die Berechnung mit R werden die auch  $\chi^2$  basierenden Funktionen itemfit und personfit verwendet
- ▶ Zusätzlich zu diesen statistischen Tests ist eine grafische Darstellung empfehlenswert





Beispiel

# Analysis using eRm

```
> library("eRm")  
> data("pcmdat")  
> res.pcm<-PCM(pcmdat)
```



## Beispiel

```
> res.pcm
```

```
Results of PCM estimation:
```

```
Call: PCM(X = pcmdat)
```

```
Conditional log-likelihood: -121.0979
```

```
Number of iterations: 16
```

```
Number of parameters: 19
```

```
Item (Category) Difficulty Parameters (eta):
```


	I1.c2	I1.c3	I2.c1	I2.c2	I2.c3	I3.c1	I3.c2	I3.c3	I4.c1
Estimate	-0.9368481	0.3303217	-0.2508642	-0.0650128	1.431592	0.2239408	0.07447576	0.8782792	-0.4229829
Std.Err	0.5652102	0.8094052	0.5254578	0.5797920	1.023935	0.5609934	0.56794601	0.7839333	0.5467276
	I4.c3	I5.c1	I5.c2	I5.c3	I6.c1	I6.c2	I6.c3	I7.c1	I7.c2
Estimate	-0.1395695	0.9803568	-0.09620567	-0.4030339	0.5861060	-0.5041350	-1.0995166	-0.8493303	0.2980869
Std.Err	0.6497043	0.7880101	0.58461877	0.5788289	0.8264099	0.6344952	0.5869572	0.5044312	0.7005385



## Beispiel

```
> plotICC(res.pcm, item.subset = 3, xlab = "PCM ICC", mplot = TRUE, legpos = FALSE)
```

ICC plot for item I3



○○○  
 ○○○○○○○○○○  
 ○  
 ○○○  
 ○○  
 ○  
 ○○○●○○○○○

○  
 ○  
 ○  
 ○○○  
 ○  
 ○○

## Beispiel

```
> thresholds(res.pcm)
```

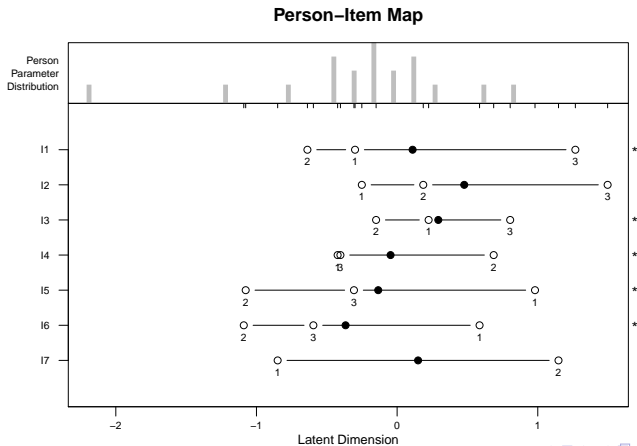
```
Design Matrix Block 1:
```

	Location	Threshold 1	Threshold 2	Threshold 3
I1	0.11011	-0.29916	-0.63769	1.26717
I2	0.47720	-0.25086	0.18585	1.49661
I3	0.29276	0.22394	-0.14947	0.80380
I4	-0.04652	-0.42298	0.68648	-0.40307
I5	-0.13434	0.98036	-1.07656	-0.30683
I6	-0.36651	0.58611	-1.09024	-0.59538
I7	0.14904	-0.84933	1.14742	NA



## Beispiel

```
> plotPImap(res.pcm)
```



○○○  
○○○○○○○○○○  
○  
○○○  
○○  
○  
○○○○●○○○

○  
○  
○  
○○○  
○  
○○

## Beispiel

```
> LRtest(res.pcm)
```

```
I2 I4 I1 I5
```

```
Full and subgroup models are estimated without these items!
```

```
Andersen LR-test:
```

```
LR-value: 2.567
```

```
Chi-square df: 7
```

```
p-value: 0.922
```



## Beispiel

```
> pp<-person.parameter(res.pcm)
> personfit(pp)
```

Personfit Statistics:

	Chisq	df	p-value	Outfit MSQ	Infit MSQ	Outfit t	Infit t
P1	9.105	6	0.168	1.301	1.113	1.19	0.57
P2	5.801	6	0.446	0.829	0.721	-0.61	-1.16
P3	5.048	6	0.538	0.721	0.751	-0.72	-0.63
P4	9.581	6	0.143	1.369	1.167	0.94	0.57
P5	7.903	6	0.245	1.129	1.233	0.60	1.01
P6	6.131	6	0.409	0.876	0.924	-0.35	-0.19
P7	3.948	6	0.684	0.564	0.660	-0.06	0.00
P8	4.215	6	0.648	0.602	0.705	-1.68	-1.25
P9	4.085	6	0.665	0.584	0.452	-1.75	-2.50
P10	9.718	6	0.137	1.388	1.259	1.58	1.16
P11	7.399	6	0.286	1.057	1.050	0.35	0.33
P12	8.544	6	0.201	1.221	1.098	0.84	0.47
P13	5.388	6	0.495	0.770	0.805	-0.42	-0.36
P14	4.677	6	0.586	0.668	0.728	-1.21	-0.94
P15	7.301	6	0.294	1.043	1.207	0.29	0.91
P16	7.983	6	0.239	1.140	1.037	0.64	0.27
P17	4.671	6	0.587	0.667	0.707	-0.57	-0.54
P18	4.426	6	0.619	0.632	0.720	-1.37	-0.97
P19	6.068	6	0.416	0.867	0.881	-0.44	-0.40
P20	4.534	6	0.605	0.648	0.672	-1.44	-1.43



## Beispiel

```
> itemfit(pp)
```

```
Itemfit Statistics:
```


	Chisq	df	p-value	Outfit MSQ	Infit MSQ	Outfit t	Infit t
I1	18.689	19	0.477	0.934	0.987	-0.26	0.01
I2	24.268	19	0.186	1.213	1.110	1.12	0.70
I3	19.352	19	0.434	0.968	1.041	-0.04	0.33
I4	13.553	19	0.809	0.678	0.754	-1.71	-1.56
I5	14.376	19	0.761	0.719	0.786	-1.06	-1.52
I6	14.303	19	0.766	0.715	0.813	-1.11	-1.14
I7	21.986	19	0.285	1.099	1.048	0.63	0.36





## Beispiel

Item Map





## Beispiel


```
> lr<-LRtest(res.pcm, se = T)
```


```
I2 I4 I1 I5
```

Full and subgroup models are estimated without these items!

```
> plotGOF(lr, conf = list(), xlim = c(-3.5, 3.5), ylim = c(-3.5, 3.5))
```

## Graphical Model Check






# Sequential Models for Ordered Responses


Sequential Models for Ordered Response

Tutz Model



## Sequential Models for Ordered Responses

- ▶ Auch hier sind die Antworten ordinale Kategorien
- ▶ Im SM geht es um das sequentielle Lösen von Teilproblemen
- ▶ Die Lösung des Problems erfolgt in sukzessiven Schritten
  - ▶ Der jeweilige Folgeschritt kann erst nach erfolgreicher Absolvierung der vorhergehenden Stufe erreicht werden
  - ▶ Der Übergang von einem Level zum nächsten wird modelliert
  - ▶ Die Itemparameter werden direkt, entsprechend der Schwierigkeit dieses Übergangs, interpretiert
- ▶ Das PCM verfolgt genauso das Konzept des stufenweisen Vorgehens, diese Stufen sind aber lokal
- ▶ Sie sind bedingt durch die Antwort in der Kategorie  $h-1$  oder  $h$



# Datensatz

- ▶ Bereits in der Aufgabenstellung, die zum Datensatz führt, ist sequenzielles Vorgehen notwendig.
- ▶ Beispiel: Es gibt 6 Fragen mit 3 Stufen, die 99 Studierenden präsentiert werden.
- ▶ Die Aufgabenstellung aus einem Test aus der Lehrveranstaltung Statistik ist
  - ▶ 1. Finde die passende Methode zu vorgegebenen Variablen/ oder Problemen
  - ▶ 2. Berechne mit Hilfe der Methode die Werte
  - ▶ 3. Interpretiere die Werte

```

○○○
○○○○○○○○○○
○
○○○
○○
○
○○○○○○○○○

```

```

○
○
●
○○○
○
○○

```


# Datenstruktur

Startpunkt im Tutz-Modell (wie auch bei Rasch-Modellen) ist die Personen x Item Matrix. Die Items werden hier mit 0 nicht bestanden bzw. 1 bestanden angegeben.

Andrich "Rating Scale" model  
Masters "Partial Credit" model

Rating level	Step 1	Step 2	Step 3	Steps Tried	Successes Scored
3-Hard	1	1	1	3	3
2	1	1	0	3	2
1	1	0	0	3	1
0-Easy	0	0	0	3	0

Key: 1=Passed, 0=Failed, M=Not administered



## Herleitung Sequential Model

Um die beobachteten Punkte und Fähigkeiten zu erhalten, müssen die Schritte modelliert werden. Ein erfolgreicher Übergang wird dargestellt als

$$U_{i v h} \equiv \theta_v + \varepsilon_{i v h}$$

$\theta$  = Fähigkeit der Person  $v$ ,  $\varepsilon$  = noise Variable.

Ein weiterer erfolgreicher Übergang wird modelliert durch:

$$U_{i v, h+1} = 1 \text{ für } U_{i v, h+1} \geq b_{i, h+1}$$

$b_{i, h+1}$  ist die Schwierigkeit des  $h + 1$ sten Schrittes.


## Herleitung Sequential Model

Der  $h + 1$ ste Schritt ist durch ein dichotomes Response Model gegeben:

$$P(U_{iv,h+1} = 1) = F(\theta_v - b_{i,h+1})$$

$F$  ist eine Funktion, die den Noise Variablen  $\varepsilon$  zu Grunde liegt.





## Herleitung Sequential Model


Wenn diese eine Logistische Funktion ist

$$F(x) = \exp(x)/(1 + \exp(x)),$$

kann jeder Schritt mit einem dichotomen Rasch Modell modelliert werden.


Das Sequential Model hat dann die Form:

$$P(U_{iv} > h | U_{iv} \geq h) = F(\theta_v - b_{i,h+1}), h = 0, \dots, m_i - 1$$




# Parameterschätzung

- ▶ Mit der Parameterschätzung werden die Itemparameter geschätzt
- ▶ Diese sind durch Personenparameter bedingt (Es gibt keine Personenparameterschätzung)
- ▶ Es gibt verschiedene Möglichkeiten der Schätzung:
  - ▶ Joint Maximum Likelihood (relativ einfach, aber produziert Bias)
  - ▶ Marginal Maximum Likelihood (benötigt Annahmen über die Verteilung der Personenparameter)
- ▶ Da man eine Verteilung für die Personen annimmt, kommt letztlich die Marginal Maximum Likelihood in Frage



# GoF

Goodness of Fit Checks gründen auf der dichotomen Natur der Übergänge in höhere Level. Für dichotome Modelle kommen viele Methoden in Frage (siehe Andersen (1973), Kelderman (1984), Hembleton und Swaminathan (1985)).




# GoF

Wählt man zB. eine log-likelihood-ratio Statistik, kann man die GoF bei den Übergängen messen.

Ein Vergleich mit der asymptotischen  $\chi^2$  Verteilung zeigt, ob das Modell zu den Steps passt.

Durch die daraus resultierende Vielfalt der Tests wird empfohlen, ein Signifikanzlevel hinzu zu fügen.

GoF muss auf die genaue Erhebung abgestimmt werden.



# Übungsbeispiele

Viel Erfolg!