

# IRT 2: Item Response Modelle für Ordinale Items



We are happy to share our materials openly:

The content of these Open Educational Resources by Lehrstuhl für Psychologische Methodenlehre und Diagnostik, Ludwig-Maximilians-Universität München is licensed under CC BY-SA 4.0. The CC Attribution-ShareAlike 4.0 International license means that you can reuse or transform the content of our materials for any purpose as long as you cite our original materials and share your derivatives under the same license.


- Ordinale Items findet man meistens in Persönlichkeitstests bzw. Fragebögen
- Bsp: Ordentlichkeitsitem im „NEO Persönlichkeitsinventar“ (NEO-PI-R)

Ich halte meine Sachen ordentlich und sauber.

starke Ablehnung    Ablehnung    neutral    Zustimmung    starke Zustimmung

$x_{ip} \in \{0, 1, 2, 3, 4\}$

- Wir werden daher oft von der Wahrscheinlichkeit sprechen, dass eine Person bei einem Item eine bestimmte Kategorie „ankreuzt“.
- Messmodelle für ordinale Items sind jedoch auch anwendbar auf Aufgaben in Leistungstests mit Teilpunkten („Partial Credit Items“).
- Bsp: Mathematikaufgabe aus der „PISA Studie 2012“



Im Bild unten wurde ein „Bauwerk“ aus sieben identischen Würfeln gebaut, deren Flächen von 1 bis 6 nummeriert sind.

Wenn man das Bauwerk von oben betrachtet, sind nur 5 Würfeln zu sehen.

Wie viele Punkte sind insgesamt sichtbar, wenn man dieses Bauwerk von oben betrachtet?

$x_{ip} \in \{0, 1, 2\}$

$x_{ip} = 2$  („17 Punkte“)

$x_{ip} = 1$  („16 Punkte“)


$x_{ip} = 0$  (andere Anzahl Punkte)

- In Testmodellen für dichotome Items werden für die Antwort einer Person  $p$  auf einem Item  $i$  die zwei Wahrscheinlichkeiten  $P(X_{pi} = 1|\theta_p)$  und  $P(X_{pi} = 0|\theta_p)$  modelliert.
- In Testmodellen für ordinale Items mit  $K$  Kategorien werden für die Antwort einer Person  $p$  auf einem Item  $i$ ,  $K$  Wahrscheinlichkeiten betrachtet. Es gilt:  
$$P(X_{pi} = 0|\theta_p) + P(X_{pi} = 1|\theta_p) + \dots + P(X_{pi} = K - 1|\theta_p) = 1$$
  
→ Diese Wahrscheinlichkeiten nennt man „Kategorienwahrscheinlichkeiten“
- Analog zu dichotomen Items wird die niedrigste Antwortkategorie typischerweise mit 0 kodiert. Durch diese Konvention lassen sich auch für ordinale Testmodelle alle Kategorienwahrscheinlichkeiten mit einer einzigen Formel berechnen.
- Um Verwirrungen bei den Modellgleichungen zu vermeiden, muss man sich klar machen, dass bei einem Item mit  $K$  Kategorien die größtmögliche Itemausprägung  $K - 1$  beträgt.  
→ Bsp: Item mit fünf Antwortkategorien ( $K = 5$ ),  $x_{ip} \in \{0, 1, 2, 3, 4\}$

$K = 5$

**Ich halte meine Sachen ordentlich und sauber.**

Antwortkategorie:



- Im dichotomen Raschmodell gilt:

$$\frac{P(X_{pi} = 1|\theta_p)}{P(X_{pi} = 1|\theta_p) + P(X_{pi} = 0|\theta_p)} = P(X_{pi} = 1|\theta_p) = \frac{e^{(\theta_p - \sigma_i)}}{1 + e^{(\theta_p - \sigma_i)}}$$

- Im „Partial Credit Modell“ für ordinale Items wird die Form des dichotomen Raschmodells zur Modellierung von  $K - 1$  dieser sogenannten „Schwellenwahrscheinlichkeiten“ übernommen:

$$\frac{P(X_{pi} = c|\theta_p)}{P(X_{pi} = c|\theta_p) + P(X_{pi} = c - 1|\theta_p)} = \frac{e^{(\theta_p - \tau_{ic})}}{1 + e^{(\theta_p - \tau_{ic})}} \text{ mit } c \in \{1, \dots, K - 1\}$$



- Die Schwellenwahrscheinlichkeiten lassen sich interpretieren, als die Wahrscheinlichkeit, eine bestimmte Kategorie  $c$  anzukreuzen, unter der Bedingung, dass entweder Kategorie  $c$  oder Kategorie  $c - 1$  angekreuzt wird.
- Anders als bei dichotomen Items gilt bei Items mit mehr als zwei Kategorien:

$$P(X_{pi} = c | \theta_p) + P(X_{pi} = c - 1 | \theta_p) < 1$$

# Exkurs: Herleitung des Partial Credit Modells

- Die Formel für die Schwellenwahrscheinlichkeit lässt sich nach  $P(X_{pi} = c | \theta_p)$  auflösen. Damit ergibt sich die folgende rekursive Gleichung:

$$P(X_{pi} = c | \theta_p) = e^{(\theta_p - \tau_{ic})} \cdot P(X_{pi} = c - 1 | \theta_p)$$

- Wählt man für  $c$  zum Beispiel den Wert  $K - 1$ , kann man die rekursive Gleichung immer wieder in sich selbst einsetzen, bis man bei  $P(X_{pi} = 0 | \theta_p)$  angekommen ist.
- Eine weitere Gleichung zur Berechnung von  $P(X_{pi} = 0 | \theta_p)$  erhält man durch die zusätzliche Information:  
$$P(X_{pi} = 0 | \theta_p) + \dots + P(X_{pi} = K - 1 | \theta_p) = 1$$
- Löst man diese Formel nach  $P(X_{pi} = 0 | \theta_p)$  auf und kombiniert diese mit der oben abgebildeten rekursiven Gleichung, erhält man die allgemeine Modellgleichung des „Partial Credit Modells“.

- Modellgleichung des „Partial Credit Modells“ (PCM) für feste Personen:

$$P(X_{pi} = x_{pi} | \theta_p) = \frac{e^{\sum_{c=1}^{x_{pi}} (\theta_p - \tau_{ic})}}{1 + \sum_{s=1}^{K-1} e^{\sum_{c=1}^s (\theta_p - \tau_{ic})}}$$

- $x_{pi}$ : beobachtete Itemantwort von Person  $p$  auf Item  $i$  ( $x_{pi} \in \{0, 1, \dots, K - 1\}$ )
- $\theta_p$ : Wert von Person  $p$  auf der latenten Variable ( $\theta_p \in ]-\infty; +\infty[$ ,  $p \in \{1, \dots, P\}$ )
- $\tau_{ic}$ : Itemparameter von Item  $i$  ( $\tau_{ic} \in ]-\infty; +\infty[$ ,  $i \in \{1, \dots, I\}$ ,  $c \in \{1, \dots, K - 1\}$ )

Plural: Jedes Item hat mehrere Parameter,  
da es mehrere Kategorienübergänge hat

- Um alle Kategorienwahrscheinlichkeiten mithilfe einer einzigen Gleichung darstellen zu können, wird die folgende übliche Konvention getroffen:

$$\sum_{c=1}^0 (\theta_p - \tau_{ic}) = 0$$

- In der Mathematik nennt man  $\sum_{c=1}^0 x$  eine leere Summe. Per Konvention hat die leere Summe immer den Wert Null, unabhängig vom Wert von  $x$ .

- Beispiel: Berechnung aller Kategorienwahrscheinlichkeiten bei einem Item  $i$  mit  $K = 3$  Antwortkategorien ( $\tau_{i1} = -1, \tau_{i2} = 1$ ) für eine Person  $p$  mit  $\theta_p = 1$ .

$$\begin{aligned}
 P(X_{pi} = 0 | \theta_p) &= \frac{e^{\sum_{c=1}^0 (\theta_p - \tau_{ic})}}{1 + \sum_{s=1}^2 e^{\sum_{c=1}^s (\theta_p - \tau_{ic})}} = \frac{e^0}{1 + e^{\sum_{c=1}^1 (\theta_p - \tau_{ic})} + e^{\sum_{c=1}^2 (\theta_p - \tau_{ic})}} = \\
 &= \frac{1}{1 + e^{(\theta_p - \tau_{i1})} + e^{(\theta_p - \tau_{i1}) + (\theta_p - \tau_{i2})}} = \frac{1}{1 + e^{(1 - (-1))} + e^{(1 - (-1)) + (1 - 1)}} = 0,06
 \end{aligned}$$


$$\begin{aligned}
 P(X_{pi} = 1 | \theta_p) &= \frac{e^{\sum_{c=1}^1 (\theta_p - \tau_{ic})}}{1 + \sum_{s=1}^2 e^{\sum_{c=1}^s (\theta_p - \tau_{ic})}} = \frac{e^{(\theta_p - \tau_{i1})}}{1 + e^{\sum_{c=1}^1 (\theta_p - \tau_{ic})} + e^{\sum_{c=1}^2 (\theta_p - \tau_{ic})}} = \\
 &= \frac{e^{(\theta_p - \tau_{i1})}}{1 + e^{(\theta_p - \tau_{i1})} + e^{(\theta_p - \tau_{i1}) + (\theta_p - \tau_{i2})}} = \frac{e^2}{1 + e^2 + e^{2+0}} = 0,47
 \end{aligned}$$

$$\begin{aligned}
 P(X_{pi} = 2 | \theta_p) &= \frac{e^{\sum_{c=1}^2 (\theta_p - \tau_{ic})}}{1 + \sum_{s=1}^2 e^{\sum_{c=1}^s (\theta_p - \tau_{ic})}} = \frac{e^{(\theta_p - \tau_{i1}) + (\theta_p - \tau_{i2})}}{1 + e^{\sum_{c=1}^1 (\theta_p - \tau_{ic})} + e^{\sum_{c=1}^2 (\theta_p - \tau_{ic})}} = \\
 &= \frac{e^{(\theta_p - \tau_{i1}) + (\theta_p - \tau_{i2})}}{1 + e^{(\theta_p - \tau_{i1})} + e^{(\theta_p - \tau_{i1}) + (\theta_p - \tau_{i2})}} = \frac{e^{2+0}}{1 + e^2 + e^{2+0}} = 0,47
 \end{aligned}$$


- Die komplizierte „Normierungskonstante“ im Nenner der Modellgleichung des PCM sorgt dafür, dass sich die Kategorienwahrscheinlichkeiten eines Items  $i$  für ein beliebiges  $\theta_p$  zu 1 aufsummieren.
- Veranschaulichung am Beispiel eines Items mit drei Antwortkategorien:


$$\begin{aligned}
 & P(X_{pi} = 0|\theta_p) + P(X_{pi} = 1|\theta_p) + P(X_{pi} = 2|\theta_p) = \\
 &= \frac{1}{1 + e^{(\theta_p - \tau_{i1})} + e^{(\theta_p - \tau_{i1}) + (\theta_p - \tau_{i2})}} + \\
 &\quad \frac{e^{(\theta_p - \tau_{i1})}}{1 + e^{(\theta_p - \tau_{i1})} + e^{(\theta_p - \tau_{i1}) + (\theta_p - \tau_{i2})}} + \\
 &\quad \frac{e^{(\theta_p - \tau_{i1}) + (\theta_p - \tau_{i2})}}{1 + e^{(\theta_p - \tau_{i1})} + e^{(\theta_p - \tau_{i1}) + (\theta_p - \tau_{i2})}} = \\
 &= \frac{1 + e^{(\theta_p - \tau_{i1})} + e^{(\theta_p - \tau_{i1}) + (\theta_p - \tau_{i2})}}{1 + e^{(\theta_p - \tau_{i1})} + e^{(\theta_p - \tau_{i1}) + (\theta_p - \tau_{i2})}} = 1
 \end{aligned}$$

- In Item Response Modellen betrachtet man zur grafischen Interpretation eines Items  $i$  häufig die Kategorienwahrscheinlichkeiten als Funktion in Abhängigkeit des Werts einer Person auf der latenten Variablen  $\theta_p$ .
- Wie bereits erwähnt, betrachtet man bei dichotomen Items meist nur die Funktion  $P(X_{pi} = 1 | \theta_p)$  und bezeichnet diese als ICC des Items  $i$ .




- Bei ordinalen Items mit mehr als zwei Antwortkategorien werden hingegen sinnvollerweise alle  $K$  „Category Characteristic Curves“ (CCCs) betrachtet.
- Für jeden Wert  $\theta_p$  gilt:  $P(X_{pi} = 0|\theta_p) + \dots + P(X_{pi} = K - 1|\theta_p) = 1$






- Der „Schwellenparameter“  $\tau_{ic}$  markiert die Stelle, an denen sich die CCCs der Kategorien  $c$  und  $c - 1$  von Item  $i$  schneiden.
- Für eine Person mit  $\theta_p = \tau_{ic}$  ist die Wahrscheinlichkeit Kategorie  $c$  anzukreuzen genauso groß wie die Wahrscheinlichkeit Kategorie  $c - 1$  anzukreuzen.

Wie sehr stimmen Sie dieser Aussage zu? „Die Vorlesung in Item Response Theorie gefällt mir gut.“




„Die Vorlesung war das  
Schlimmste, was mir jemals in  
meinem Leben passiert ist“




- Zur Interpretation der CCCs eines Items ist es hilfreich sich zu überlegen, welche theoretische Verteilung der Itemantworten durch die CCCs impliziert wird.
- Man beachte dabei, dass die Itemantworten nicht nur von den Itemparametern, sondern auch von der Verteilung der Personen auf der latenten Variable abhängen.
- Aus Gründen der Normierung, die im Kapitel zur Modellschätzung noch genauer behandelt werden, nimmt man für die Verteilung der Personen auf der latenten Variable in der Regel eine Standardnormalverteilung an.
- Um für ein Item mit gegebenen Schwellenwerten die Verteilung der Itemantworten grafisch in einem Balkendiagramm darstellen zu können, zieht man zunächst eine große Menge von  $\theta_p$  aus der Standardnormalverteilung und simuliert dann für jedes  $p$  eine Itemantwort mithilfe der Modellgleichung.
- **Hinweis:**  
Für alle Beispiele wurden zur Darstellung der Balkendiagramme immer  $P = 1000$  „Personen“ zufällig aus der Standardnormalverteilung gezogen.

# 1000 simulierte Personen




Simulierte Verteilung der Personenparameter  
(standardnormalverteilt)





- Die zwei Histogramme für das rote und das blaue Item zeigen die simulierten Itemantworten von den 1000 simulierten Personen.
- Das rote Item ist „leichter“: Es werden eher hohe Antwortkategorien angekreuzt. Das blaue Item ist schwerer: Bei denselben Ausprägungen der Personenparameter werden eher niedrige Antwortkategorien angekreuzt.

# Jede CCC eines Items hängt von allen Schwellen ab




# Jede CCC eines Items hängt von allen Schwellen ab





- Im PCM wird die „Schwierigkeit“ eines Items nicht mehr durch einen einzelnen Itemparameter charakterisiert, sondern hängt von der Lage aller Schwellen ab.
- Eine sinnvolle Möglichkeit, „die Schwierigkeit“ eines Items im PCM zu quantifizieren ist der Mittelwert der Schwellen  $\frac{1}{K-1} \sum_{c=1}^{K-1} \tau_{ic}$

- Zur Interpretation der CCCs eines Items ist es sinnvoll zu betrachten, welche Antwortkategorie an einem bestimmten Punkt  $\theta_p$  am wahrscheinlichsten ist:



- Als Alternative zu den Regionen mit der höchsten Wahrscheinlichkeit für eine bestimmte Antwortkategorie anhand der CCCs, kann auch die ICC für ein ordinale Item grafisch veranschaulicht werden.
- Bei dichotomen Items gibt die ICC die erwartete Itemantwort für einen bestimmten Wert auf der latenten Variable an:

$$E(X_{pi}|\theta_p) = P(X_{pi} = 1|\theta_p)$$


- Interpretation: Angenommen Person  $p$  bearbeitet Item  $i$  unendlich oft, dann entspricht  $E(X_{pi}|\theta_p)$  dem Mittelwert dieser unendlich vielen Itemantworten.
- Die erwartete Itemantwort, bedingt auf den Wert der Person auf der latenten Variable lässt sich im Rahmen des PCMs auch für ordinale Items berechnen:

$$E(X_{pi}|\theta_p) = \sum_{k=0}^{K-1} k \cdot P(X_{pi} = k|\theta_p)$$


Allgemeine Form des (bedingten)  
Erwartungswert einer diskreten  
Zufallsvariable

Formel für die Berechnung  
Kategorienwahrscheinlichkeiten  
aus der Modellgleichung des PCM

# Erwartungswert einer Person mit $\theta_1 = -2$




$$E(X_{1i} | \theta_1 = -2) = 0.47 \cdot 0 + 0.47 \cdot 1 + 0.06 \cdot 2 + 0.00 \cdot 3 + 0.00 \cdot 4 = 0.59$$




- Die Grenzen in dieser Darstellung der ICC des ordinalen Items von Folie 21 entsprechen nicht den Schwellenwerten  $\tau_{ic}$ , sondern stellen eine alternative Unterteilung der latenten Variable dar.  
→  $E(X_{pi}|\theta_p)$  wird über alle Antwortkategorien berechnet und „gerundet“

CCC



Was ist die wahrscheinlichste  
Antwortkategorie gegeben einer  
latenten Ausprägung?


ICC



Was ist der erwartete Antwortwert  
gegeben einer latenten  
Ausprägung (d.h., gemittelt über  
alle Antwortkategorien)?


- In den bisherigen Beispielen galt implizit immer  $\tau_{i1} < \tau_{i2} < \dots < \tau_{i,K-1}$ .
- Diese intuitive Ordnung der Schwellen ist jedoch durch das PCM nicht vorgeschrieben. Tatsächlich erlaubt das Modell beliebige Rangreihen der Schwellenparameter  $\tau_{ic}$ .
- Damit ist das PCM flexibel genug, um auch Items mit komplizierten Verteilungen der Antwortkategorien abbilden zu können.
- Items mit ungeordneten Schwellen sind keine rein theoretische Konstruktion, sondern treten auch in der praktischen Auswertung von Fragebögen häufig auf.
- Obwohl ungeordnete Schwellen an sich keine Verletzung des Testmodells darstellen, deuten sie trotzdem häufig auf Probleme etwa bei der Itemformulierung, dem Itemverständnis oder der Wahl der Antwortkategorien hin.

# CCCs mit ungeordneten Schwellen



- Bei ungeordneten Schwellen gibt es bestimmte Antwortkategorien, die für keine Ausprägung der Personen auf der latenten Variable am wahrscheinlichsten sind. Diese Items weisen häufig eine auffällige Verteilung der Itemantworten auf.

# CCCs mit ungeordneten Schwellen




- Angenommen, das abgebildete Item stellt eine Klausuraufgabe dar: In dieser Aufgabe ist es für Philipp ebenso wahrscheinlich 2 Punkte zu erzielen, wie 3 Punkte. Er erhält wahrscheinlicher 0 Punkte als 1 Punkt. Am wahrscheinlichsten ist es jedoch, dass Philipp 4 Punkte erzielt.

- Im PCM wird jedes Item durch  $K - 1$  Parameter charakterisiert.
- Analog zum 2PL Modell für dichotome Items, lässt sich auch das PCM durch Aufnahme eines zusätzlichen Parameters  $\beta_i$  für jedes Item zum „Generalized Partial Credit Modell“ (GPCM) erweitern.
- Allgemeine Modellgleichung:

$$P(X_{pi} = x_{pi} | \theta_p) = \frac{e^{\sum_{c=1}^{x_{pi}} \beta_i (\theta_p - \tau_{ic})}}{1 + \sum_{s=1}^{K-1} e^{\sum_{c=1}^s \beta_i (\theta_p - \tau_{ic})}}$$


- Wie im 2PL Modell kann der Parameter  $\beta_i$  auch im GPCM nur positive Werte annehmen ( $\beta_i \in ]0; +\infty[$ ).
- Wie im PCM gilt auch für die Modellgleichung des GPCM die Konvention:

$$\sum_{c=1}^0 (\theta_p - \tau_{ic}) = 0$$



- Der Itemparameter  $\beta_i$  hängt mit der Steigung der CCCs von Item  $i$  zusammen.
- Je größer  $\beta_i$ , desto stärker verändern sich die Kategorienwahrscheinlichkeiten für Werte von  $\theta_p$  nahe der  $\tau_{ic}$  (desto „steiler“ sind die CCCs nahe der Schwellen)
- Wie im 2PL Modell wird  $\beta_i$  daher als „Diskrimination“ von Item  $i$  interpretiert.

# Beispiel: CCCs für ein Item mit 7 Antwortkategorien



# GPCM vs. PCM: Gemeinsamkeiten und Unterschiede

- Das GPCM stellt eine naheliegende Erweiterung des PCM dar. Durch die zusätzlichen Diskriminationsparameter ist das GPCM das flexiblere Testmodell und kann damit noch komplexere Zusammenhänge zwischen der latenten Variable und den manifesten Itemantworten abbilden.
  - Wie im PCM müssen auch im GPCM die Schwellen nicht geordnet sein
  - Wie im PCM können auch im GPCM für die latente Variable Regionen mit der höchsten Kategorienwahrscheinlichkeit grafisch dargestellt werden
  - Wie im PCM können auch im GPCM völlig analog ICCs berechnet werden
- Für das PCM gilt durch die Verwendung des dichotomen Raschmodells für die Modellierung der Schwellenwahrscheinlichkeiten die Eigenschaft der spezifischen Objektivität („ordinales Raschmodell“).
- Da im GPCM das 2PL Modell zur Modellierung der Schwellenwahrscheinlichkeit herangezogen wird, liegt hier keine spezifische Objektivität vor. Dies hat jedoch praktisch keine Auswirkungen und es gilt dieselbe Argumentation wie bei den Testmodellen für dichotome Items.

- PCM („Ordinales Raschmodell“):

$$P(X_{pi} = x_{pi} | \theta_p) = \frac{e^{\sum_{c=1}^{x_{pi}} (\theta_p - \tau_{ic})}}{1 + \sum_{s=1}^{K-1} e^{\sum_{c=1}^s (\theta_p - \tau_{ic})}}$$

- Items unterscheiden sich in ihrer „Schwierigkeit“
- Gegenstück zum 1PL Modell bei Items mit dichotomem Antwortformat

- GPCM:

$$P(X_{pi} = x_{pi} | \theta_p) = \frac{e^{\sum_{c=1}^{x_{pi}} \beta_i (\theta_p - \tau_{ic})}}{1 + \sum_{s=1}^{K-1} e^{\sum_{c=1}^s \beta_i (\theta_p - \tau_{ic})}}$$

- Items unterscheiden sich in ihrer „Schwierigkeit“ und in ihrer „Diskrimination“
- Gegenstück zum 2PL Modell bei Items mit dichotomem Antwortformat

In beiden Modellen ergibt sich die „Schwierigkeit“ eines Items nicht mehr durch einen einzigen Parameter, sondern durch die Lage der  $K - 1$  Schwellen.