

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Das Mixed Rasch-Modell

Kathrin Jahreis

Vortrag im Rahmen des Masterseminars
Psychometrische Modelle: Theorie und Anwendungen
am Institut für Statistik (LMU)

06./07.06.2014

- 1 Einleitung und Überblick
- 2 Motivation des MRM
 - Limitationen des RM
 - Limitationen der LCA
 - Lokalisierte Klassen und die Linear-logistische LCA
- 3 M-Formulierung im MRM
- 4 MP-Schätzung im MRM
- 5 Anwendung des MRM
- 6 Beispiel
- 7 Zusammenfassung
- 8 Literatur

Das Mixed Rasch-Modell (MRM)

Das Mixed
Rasch-Modell

Kathrin
Jahres

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Flexible Mischverteilungs-Modellklasse für kategoriale Daten mit großer heuristischer Kraft.
- Das MRM (Rost, 1990) resultiert aus der Überwindung der Limitationen des RM und der Latent-Class-Analysis (LCA).
- Es ermöglicht die Modellierung von Differential Item Functioning (DIF). Es können z.B. kognitive Strukturen oder Lösungsstrategien aus den Daten erkannt werden.
- Das MRM kann als Modellgeltungstest für das RM fungieren.

Limitationen des RM

Das Mixed
Rasch-Modell

Kathrin
Jahres

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Annahme **paralleler** ICCs setzt voraus, dass Itemparameter (IP) σ_i für alle Personen mit Fähigkeit θ_v konstant sind.
- In der Testpraxis ist diese Annahme selten gerechtfertigt:
 - Schlecht konstruierte Items (ROST, 1990)
 - Items mit für unterschiedliche Subgruppen variierender Schwierigkeit zu diagnostischen Zwecken
- Da bei DIF das RM die Komplexität der Testsituation nicht erfasst, wird seine Passung von Modellgeltungstest kategorisch verworfen.

Die klassische LCA

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- LCA (Lazarsfeld, 1950; Lazarsfeld & Henry, 1968) verwendet kategoriales θ_g statt stetiges θ_v .
- Qualitative Zuordnung der getesteten Individuen in G diskrete Klassen (disjunkt und exhaustiv).
- Spezifische Antwortmuster je Klasse, welche jedoch zwischen Klassen divergieren.
- Konstante, klassenspezifische LWS π_{ig} ($g = 1, 2, \dots, G$), wobei $\pi_{ig} \in [0, 1]$ (Wskparameter).

Die klassische LCA

- Annahme, dass Klassen bzgl. ihres Antwortverhaltens unabhängig voneinander sind. In Klassen gilt LSU der Item-Responses.
- Klassengrößen (KG) π_g sind unbekannt (Wskparameter).

Es gilt Normierung $\sum_{g=1}^G \pi_g = 1$.

- Unbedingte PWS ist **diskrete Mischung** der bedingten PWS:

$$p(\underline{x}) = \sum_{g=1}^G \pi_g p(\underline{x}|g) \quad (1)$$

- Anzahl latenter Klassen G ist **kein**, auf g bedingte PWS sind Modellparameter (MP).
- Anzahl gelöster Aufgaben **nicht** suffizient für θ_v .

Das Mixed Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Limitationen der LCA

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- LCA ist voraussetzungsarme, flexible Modellklasse (Annahme über G als einzige Annahme bzgl. Beschaffenheit der latenten Klassen).
- LCA bzgl. Annahme von Personenhomogenität weniger restriktiv als RM (Klassen können sich durch unterschiedliche IP auszeichnen).
- Jedoch fordert LCA konstante LWS aller Klassenmitglieder für ein Item. Es ist keine Variabilität von θ in Klassen möglich.

Lokalisierte Klassen

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Lokalisierte Klassen (Lazarsfeld & Henry, 1968) setzen Existenz von stetigem θ voraus, dessen konkrete Ausprägungen sich jedoch an Verdichtungspunkten häufen.
- Eigentlich stetiges θ reduziert sich auf begrenzte Anzahl von disjunkten und exhaustiven, latenten Klassen.
- Da Klassen dennoch auf Kontinuum lokalisiert sind, können klassenspezifische LWS durch eine auf das gesamte Kontinuum bezogene ICC definiert werden.

Die Linear-logistische LCA

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Linear-logistische LCA nach Formann (1985) steht in direktem Zusammenhang mit lokalisierten Klassen.
- Reparametrisierung der MP der LCA (π_g, π_{ig}) durch logistische Trafo:

$$\alpha_{ig} = \log \left(\frac{\pi_{ig}}{1 - \pi_{ig}} \right) \Rightarrow \pi_{ig} = \frac{\exp(\alpha_{ig})}{1 + \exp(\alpha_{ig})} \quad (2)$$

- Parameter α_{ig}, α_g können Werte zwischen $-\infty$ und $+\infty$ annehmen.
- Nun Präzisierung der LCA durch Restriktionen (additive Zerlegungen von α_{ig}, α_{ig}) möglich.

Die Linear-logistische LCA

- Bei Zerlegung von α_{ig} in Klassenparameter θ_g und IP σ_i resultiert **Modell mit lokalisierten Klassen**, dessen **Itemfunktionen diejenigen des RM** sind:

$$p(x_{vi}) = \sum_{g=1}^G \pi_g \frac{\exp(x_{vi}(\theta_g - \sigma_i))}{1 + \exp(\theta_g - \sigma_i)} \quad (3)$$

- Im Vgl. zu RM ist θ nicht kontinuierlich, sondern diskret verteilt (Anzahl Fähigkeitsausprägungen entspricht G).
- Approximation des RM durch Modell lokalisierter Klassen erfordert nach Formann (1995):

$$G = \begin{cases} (k + 1)/2, & \text{wenn } k \text{ ungerade,} \\ k/2 + 1, & \text{wenn } k \text{ gerade.} \end{cases} \quad (4)$$

Das Mixed Rasch-Modell

Kathrin Jahreis

Einleitung und Überblick

Motivation des MRM

Limitationen des RM

Limitationen der LCA

Lokalisierte Klassen und die Linear-logistische LCA

M-Formulierung im MRM

MP-Schätzung im MRM

Anwendung des MRM

Beispiel

Die informelle Formulierung des dichotomen MRM

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- **Grundidee des MRM** nach Rost (1990):
Teile getestete Personenpopulation derart in G exhaustive und disjunkte, latente Klassen mit maximal usl. IP auf, dass klassenintern jeweils das RM gilt.
- **Fazit auf Basis der bisherigen Kenntnisse:**
Variierende Itemschwierigkeit für verschiedene Klassen UND Zulässigkeit von Fähigkeitsunterschieden innerhalb der Rasch-skalierbaren Klassen entsprechen Koexistenz der beiden Grundideen von RM und LCA.

Das formale Modell des dichotomen MRM

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

■ Notation:

- θ_{vg} : Fähigkeit von Person v aus Klasse g .
- σ_{ig} : Leichtigkeit von Item i für Individuen aus Klasse g .
- p_{vig} : Wsk, dass Person v mit Fähigkeit θ_{vg} Item i löst.

■ Annahmen:

- $\sum_{g=1}^G \pi_g = 1$: KG $\pi_g \in [0, 1]$ ergeben in Summe 1.
- $\sum_{i=1}^k \sigma_{ig} = 0 \forall g$: IP einer Klasse sind summennormiert.

Das formale Modell des dichotomen MRM

- Die **klassenspezifische LWS** p_{vig} ergibt sich wie folgt:

$$p_{vig} = p(X_{vi} = 1|g) = \frac{\exp(\theta_{vg} + \sigma_{ig})}{1 + \exp(\theta_{vg} + \sigma_{ig})} \quad (5)$$

- Wegen Annahme exhaustiver und disjunkter Klassen ergibt sich **unbedingte LWS** p_{vi} als:

$$p_{vi} = \sum_{g=1}^G \pi_g p_{vig} = \sum_{g=1}^G \pi_g \frac{\exp(\theta_{vg} + \sigma_{ig})}{1 + \exp(\theta_{vg} + \sigma_{ig})} \quad (6)$$

- MRM ist Mischverteilung mit klassenspezifischen LWS p_{vig} als Rasch-skalierte **Verteilungen** der latenten PV und den KG π_g als **Mischungskomponenten**.

Das Mixed Rasch-Modell

Kathrin Jahreis

Einleitung und Überblick

Motivation des MRM

Limitationen des RM

Limitationen der LCA

Lokalisierte Klassen und die Linear-logistische LCA

M-Formulierung im MRM

MP-Schätzung im MRM

Anwendung des MRM

Beispiel

Das MRM als Metamodell von RM und LCA

MRM bildet gemeinsames **Metamodell** von RM und LCA:

■ Szenario I:

- Annahme, dass $G = 1$.
- Wegen Normierung $\sum_{g=1}^G \pi_g = 1$ folgt, dass $\pi_g = \pi_1 = 1$.
- Es resultiert Modellgleichung des RM.

■ Szenario II:

- Annahme, dass es in Klassen keine Varianz in θ_{vg} gibt.
- $\theta_{vg} = \theta_g$ (LWS für Item in g für alle Personen konstant).
- Gleichung (6) kann mit (7) reparametrisiert werden:

$$p_{vig} = \frac{\exp(\theta_g + \sigma_{ig})}{1 + \exp(\theta_g + \sigma_{ig})} = \pi_{ig} \quad (7)$$

- Es resultiert Modell der LCA für LWS für Item i .

Das Mixed Rasch-Modell

Kathrin Jahreis

Einleitung und Überblick

Motivation des MRM

Limitationen des RM

Limitationen der LCA

Lokalisierte Klassen und die Linear-logistische LCA

M-Formulierung im MRM

MP-Schätzung im MRM

Anwendung des MRM

Beispiel

Die bedingte Likelihood des MRM

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Auf (6) basierende **joint Likelihood** des MRM enthält π_g , σ_{ig} und θ_{vg} als MP.
- Reparametrisierung der Likelihood (L) durch Verwendung der **bedingten** statt der **unbedingten PWS** bietet sich an.
- Inzidentelle θ_{vg} sind in **bedingter L** nicht mehr enthalten.
- Eigenschaft stellt Vorteil für Parameterschätzung dar.

Herleitung der bedingten Likelihood des MRM

- **Klassenunspezifische PWS** von $\underline{x} = (x_1, x_2, \dots, x_k)$:

$$p(\underline{x}) = \sum_{g=1}^G \pi_g p(\underline{x}|g) = \sum_{g=1}^G \pi_g p(\underline{x}|r, g) p(r|g) \quad (8)$$

- Unter Verwendung des Satzes der totalen WSK kann $p(\underline{x}|g)$ zusätzlich auf Summenwert r von \underline{x} bedingt werden.
- **Klassenspezifische SWS** $p(r|g)$ werden mit π_{rg} reparametrisiert und stellen die neuen MP dar.

- Für sie gilt $\sum_{r=1}^{k-1} \pi_{rg} = 1 \quad \forall g$.

Das Mixed Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Die bedingte Likelihood des MRM

Das Mixed
Rasch-Modell

Kathrin
Jahres

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- **Bedingte PWS** $p(\underline{x}|r, g)$ sind der Anteil, den die WSK für bestimmtes Pattern mit Score r an der GesamtWSK aller Pattern mit Score r hat:

$$p(\underline{x}|r, g) = \frac{p(\underline{x}|g)}{\sum_{\underline{x}|r, g} p(\underline{x}|g)} \quad (9)$$

- **Herleitung von $p(\underline{x}|g)$** ergibt ausgehend von (5):

$$p(\underline{x}|g) = \frac{\exp(r \theta_{vg}) \exp\left(\sum_{i=1}^k x_i \sigma_{ig}\right)}{d_{vg}} \quad (10)$$

Die bedingte Likelihood des MRM

- Die Summe der WSK aller Pattern \underline{x} mit Summenscore r ergibt sich unter Verwendung von (10) als:

$$\sum_{\underline{x}|r,g} p(\underline{x}|g) = \sum_{\underline{x}|r,g} \frac{\exp(r \theta_{vg}) \exp(\sum_{i=1}^k x_i \sigma_{ig})}{d_{vg}} \quad (11)$$

- Einsetzen von (10) und (11) in (9) ergibt:

$$p(\underline{x}|r, g) = \frac{\exp(\sum_{i=1}^k x_i \sigma_{ig})}{\sum_{\underline{x}|r,g} \exp(\sum_{i=1}^k x_i \sigma_{ig})} \quad (12)$$

Das Mixed Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Die bedingte Likelihood des MRM

- (12) ist Funktion ohne θ_{vg} .
- Nenner von (12) kann umgeschrieben werden zu:

$$\sum_{\underline{x}|r,g} \exp\left(\sum_{i=1}^k x_i \sigma_{ig}\right) = \sum_{\underline{x}|r,g} \prod_{i=1}^k (\exp x_i \sigma_{ig}) = \gamma_r(\exp(\sigma)) \quad (13)$$

- Aus (12) und (13) folgt die **bedingte PWS** als:

$$p(\underline{x}|r, g) = \frac{\exp\left(\sum_{i=1}^k x_i \sigma_{ig}\right)}{\gamma_r(\exp(\sigma))} \quad (14)$$

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Die bedingte Likelihood des MRM

- **Bedingte PWS** können als schlichte Funktion der IP und ihrer symmetrischen Grundfunktionen r -ter Ordnung γ_r dargestellt werden.
- γ_r ist Funktion von delogarithmierten IP und Score r . Es umfasst alle möglichen Antwortpattern, welche zu einem Score r führen und ist unabhängig von konkreten Pattern \underline{x}_v einer Person.
- Setzt man (14) in (8) ein, ergibt sich **Modellgleichung auf Ebene der PWS**:

$$p(\underline{x}) = \sum_{g=1}^G \pi_g \pi_{rg} \frac{\exp\left(\sum_{i=1}^k x_i \sigma_{ig}\right)}{\gamma_r(\exp(\sigma))} \quad (15)$$

Das Mixed Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Die bedingte Likelihood des MRM

- Wegen Unabhängigkeit des Antwortverhaltens von Klassenmitgliedern und Klassen untereinander, ergibt sich **bedingte L der gesamten Testdatenmatrix** zu:

$$L = \prod_{\underline{x}} \left(\sum_{g=1}^G \pi_g \pi_{rg} \frac{\exp\left(\sum_{i=1}^k x_i \sigma_{ig}\right)}{\gamma_r(\exp(\sigma))} \right)^{n(\underline{x})} \quad (16)$$

- IP können geschätzt werden, ohne dass PP bekannt sind oder Annahmen bzgl. ihrer Verteilung in den Klassen getroffen werden müssen.
- Da L keine inzidentellen Parameter mehr enthält, resultieren konsistente, asymptotisch normalverteilte und asymptotisch erwartungstreue $\hat{\sigma}_{ig}$.

Das Mixed Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Parameterschätzung im MRM

Das Mixed
Rasch-Modell

Kathrin
Jahres

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Schätzung erfolgt mit dem **EM-Algorithmus** (Dempster, Laird & Rubin, 1977).
- Flexibler, iterativer Algorithmus zur Berechnung von ML-Schätzungen bei unvollständigen Daten.
- **Grundidee:** Schätzproblem auf vollständige Likelihood und somit auf Max vollständiger Daten zurückführen.
- Eine Iteration besteht aus **Expectation-Schritt** und **Maximization-Schritt**.
- Iteration bis zur Konvergenz des unbekanntenen Parameters.

Parameterschätzung im MRM

Bedingte klassenspezifischen Log-L des MRM:

$$L_g = \prod_{\underline{x}} \left(\pi_{rg} \frac{\exp\left(\sum_{i=1}^k x_i \sigma_{ig}\right)}{\gamma_r(\exp(\sigma))} \right)^{n(\underline{x})} \quad (17)$$

- G ist kein Standard-MP (wird nicht geschätzt).
- π_g , σ_{ig} und π_{rg} sind unabhängige MP.
- Scores $r = 0$ und $r = k$ sind explizit von Schätzung ausgeschlossen. Wegen bedingter ML-Schätzung beeinflusst ihr Ausschluss Schätzungen der IP nicht.

Das Mixed Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Parameterschätzung im MRM

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

E-Schritt: Berechne **erwartete Patternhäufigkeiten** (PH)
 $\hat{n}(\underline{x}, g)$ für jede Klasse:

$$\hat{n}(\underline{x}, g) = n(\underline{x}) \frac{\pi_g p(\underline{x}|g)}{\sum_{g=1}^G \pi_g p(\underline{x}|g)} \quad (18)$$

- $n(\underline{x})$ sind global beobachtete Häufigkeiten von Pattern \underline{x} .
- $\hat{n}(\underline{x}, g)$ hängen nur von MP π_g , σ_{ig} und π_{rg} ab.
Verwende vorläufige Schätzungen oder Startwerte.
- $\hat{n}(\underline{x}, g)$ bilden Basis, um im **M-Schritt** bessere Schätzungen für π_g , π_{rg} und σ_{ig} zu berechnen.

Schätzung der IP im MRM

π_g , π_{rg} und σ_{ig} können durch Max. der **klassenspezifischen Log-L** für jede Klasse g separat geschätzt werden:

$$\log L_g = \sum_{\underline{x}} \hat{n}(\underline{x}, g) \left(\log(\pi_{rg}) + \sum_{i=1}^k x_i \sigma_{ig} - \log(\gamma_r(\exp(\sigma))) \right) \quad (19)$$

Erste partielle Abl. von (19) nach σ_{ig} gleich Null gesetzt. Es resultieren Schätzgleichungen:

$$\hat{\sigma}_{ig} = \log \frac{n_{ig}}{\sum_{r=0}^k (n_{rg} \gamma_{r-1,i} / \gamma_r)} \quad (20)$$

$\gamma_{r-1,i}$ (sym. GF (r-1)-ter Ordnung aller IP mit Ausnahme von Item i) ist erste partielle Abl. von γ_r .

Das Mixed Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Parameterschätzung im MRM

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- n_{ig} sind die vorläufigen Schätzungen für die Anzahl an Personen in Klasse g , die Item i gelöst haben.
- n_{rg} sind Schätzer für die Anzahl von Personen mit Score r in Klasse g .
- n_{ig} und n_{rg} lassen sich mittels einfacher Summen von $\hat{n}(\underline{x}, g)$ aus E-Schritt berechnen. Erwartete Counts müssen nicht ganzzahlig sein.
- Die symmetrischen GF auf rechter Seite von (20) werden mit vorläufigen IP-Schätzungen berechnet.

Parameterschätzung im MRM

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Schätzer für die SWS und die KG:

$$\hat{\pi}_{rg} = \frac{n_{rg}}{n_g} \quad (21)$$

$$\hat{\pi}_g = \frac{\sum_{\underline{x}} \hat{n}(\underline{x}, g)}{N} \quad (22)$$

- $\sum_{\underline{x}} \hat{n}(\underline{x}, g)$ sind **Klassenanteile** der beob. klassenspezifischen PH.

Schätzung der PP im MRM

θ_{vg} wurden durch Bedingen auf r aus L entfernt, können aber unter Verwendung von $\hat{\sigma}_{ig}$ und Schätzungen der Scoreparameter durch Max von L_g bzgl. θ_{vg} (hängt nur von Score r_v des Individuum S_v ab) geschätzt werden.

Intra-class L:

$$L_g = \prod_v p(\underline{x}_v | g) = \prod_v \frac{\exp(\sum_{i=1}^k x_{vi}(\theta_{vg} + \sigma_{ig}))}{\prod_{i=1}^k [1 + \exp(\theta_{vg} + \sigma_{ig})]} \quad (23)$$

$$\log L_g = \sum_v r_v \theta_{vg} + \sum_i n_{ig} \sigma_{ig} - \sum_v \sum_i \log(1 + \exp(\theta_{vg} + \sigma_{ig})) \quad (24)$$

Das Mixed Rasch-Modell

Kathrin
Jahres

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Schätzung der PP im MRM

- n_{ig} ist Anzahl von Personen, die Item i in Klasse g löst (muss nicht bekannt sein, da n_{ig} durch Ableiten von (24) nach θ_{vg} herausfällt).
- Schätzgleichungen für θ_{vg} ergeben sich durch Ableiten von (24) nach θ_{vg} und auflösen der Ableitung nach r_v :

$$r_v = \sum_{i=1}^k \frac{\exp(\theta_{vg} + \sigma_{ig})}{1 + \exp(\theta_{vg} + \sigma_{ig})} \quad (25)$$

- Wie in RM erhalten Personen mit demselben Summenscore auch denselben PP. Hier PP aber klassenspezifisch, d.h. jede Person erhält $G \theta_{vg}$.
- Schätzungen können als bedingt angesehen werden (Individuum S_v hat Parameter θ_{vg} sofern es zu g gehört).

Das Mixed Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

Parameterschätzung im MRM

Das Mixed
Rasch-Modell

Kathrin
Jahres

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Varianz von θ_{vg} zw. Klassen hängt nur von $\hat{\sigma}_{ig}$ ab und nicht davon, welche Items von Individuum gelöst wurden.
- Umgekehrt hängt wahrscheinlichste Klassenzugehörigkeit von Individuum wenig von r_v , sondern von \underline{x} (Welche Items wurden gelöst?) ab.
- **FAZIT:** MRM erlaubt es, quantitativen und qualitativen Aspekt eines Response-Patterns voneinander zu trennen. Stetige Mischvariable hängt davon ab, wie viele Items gelöst wurden (RM) und die diskrete Mischvariable davon, welche Items gelöst wurden (LCA).

Anwendung des MRM

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Vielzahl von Einsatzgebieten (Psychologie, Sprachwissenschaft, Genetik...).
- Zwar muss Klassenanzahl a priori vorgegeben werden, über Beschaffenheit ist aber kein Vorwissen notwendig.
- A posteriori folgt ggf. substanzwissenschaftliche Untersuchung der vom MRM identifizierten Klassen.
- **Beispiele aus Literatur:**
 - Praktische versus theoretische Kompetenzen von Schülern in Physik (Rost, Häußler & Hoffmann, 1989)
 - Identifizierung von Lösungsstrategien (Mislevy & Verhelst, 1990)

Simulationsdaten von Rost (1990) in R

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Simulationsdaten von Rost (1990) sind in R-Paket **psychomix** als Funktion *simRaschmix()* implementiert:
- Betrachte drei DGPs mit je $N=1800$ ($r = 0$ und $r = k$ ausgeschlossen) und 10 Items.
 - **DGP1:** $G = 1$ (Rasch-skalierbar) mit IP-Vektor $\underline{\beta}_1$
 - **DGP2:** $G = 2$, $\underline{\beta}_1 = -\underline{\beta}_2$ (umgekehrte RF der IP)
 - **DGP3:** $G = 3$, $\underline{\beta}_3$ (fast keine Varianz der IP)
- Schätzung von MRM erfolgt mit Funktion *raschmix()* aus **psychomix**.

Simulationsdaten von Rost (1990) in R

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel




Figure: Modellwahl bei DGP1 mittels Informationskriterien

Simulationsdaten von Rost (1990) in R

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel




Figure: Modellwahl bei DGP2 mittels Informationskriterien

Simulationsdaten von Rost (1990) in R

Das Mixed Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel




Figure: Modellwahl bei DGP3 mittels Informationskriterien

Simulationsdaten von Rost (1990) in R

Das Mixed Rasch-Modell

Kathrin
Jahreis

Einleitung und Überblick

Motivation des MRM

Limitationen des RM

Limitationen der LCA

Lokalisierte Klassen und die Linear-logistische LCA

M-Formulierung im MRM

MP-Schätzung im MRM

Anwendung des MRM

Beispiel




Figure: Schätzungen der IP bei DGP3

Fazit

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Bei MRM ist Annahme von Eindimensionalität in Gesamtpopulation der getesteten Personen nicht notwendig. Es ist somit ein zuverlässiges Verfahren zur Modellierung bzw. Identifizierung von DIF.
- MRM setzt a priori weder Annahmen über Ordnung der Items in Klassen noch bzgl. Klassengröße voraus.
- Anzahl latenter Klassen G ist (wie bei LCA) kein Modellparameter und muss a priori festgesetzt werden.
- Wie im RM gibt es Möglichkeit, IP verteilungsfrei zu schätzen.
- Es gibt auch eine Erweiterung des MRM auf mehrstufige ordinale Daten (Rost, 1991).

Das Mixed Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Baghaei, P. & Carstensen, C.H. (2013). Fitting the Mixed Rasch Model to a Reading Comprehension Test: Identifying Reader Types. *Practical Assessment, Research & Evaluation*, 18, 5, 1-8.
- Dempster, A.P., Laird, N.M., Rubin, D.B. (1977). Maximum Likelihood from Incomplete Data via the EM-algorithm. *Journal of the Royal Statistical Society*, 39, 1, 1-38.
- Fischer, G.H. (1974). Einführung in die Theorie psychologischer Tests. Bern: Huber.
- Formann, A.K. (1985). Constrained Latent Class Models: Theory and Applications. *British Journal of Mathematical and Statistical Psychology*, 38, 87-111.
- Formann, A.K. (1995). Linear Logistic Latent Class Analysis and the Rasch Model. In G.H. Fischer & I.W. Molenaar (Hrsg.), *Rasch models: Foundations, recent developments, and applications* (S.239-255). Berlin: Springer.
- Frick, H., Strobl, C., Leisch, F., Zeileis, A. (2011). Flexible Rasch Mixture Models with Package psychomix. *Working Papers in Economics and Statistics, Research Platform Empirical and Experimental Economics*. Universität Innsbruck.
- Lazarsfeld, P.F. (1950). The Logical and Mathematical Foundation of Latent Structure Analysis, in: S. Stouffer (Hrsg.), *Measurement and Prediction* (S. 362-412). NJ: Princeton University Press.
- Lazarsfeld, P. F., Henry, N. W. (1968). *Latent Structure Analysis*. Boston: Houghton Mifflin.
- Mislevy, R.J., Verhelst, N.D. (1990). Modeling Item Responses when different subjects employ different solution strategies. *Psychometrika* Vol. 55, Nr. 2, S. 195-215.
- Pawitan, Y. (2001). *In All Likelihood. Statistical Modelling and Inference Using Likelihood*. Oxford: Clarendon Press.

Das Mixed
Rasch-Modell

Kathrin
Jahreis

Einleitung und
Überblick

Motivation
des MRM

Limitationen des
RM

Limitationen der
LCA

Lokalisierte
Klassen und die
Linear-
logistische
LCA

M-
Formulierung
im MRM

MP-
Schätzung im
MRM

Anwendung
des MRM

Beispiel

- Rost, J. (1990). Rasch models in latent classes: An integration of two approaches to item analysis, *Applied Psychological Measurement* 14(3), S. 271.
- Rost, J. (1991). A logistic mixture distribution model for polychotomous item responses, *British Journal of Mathematical and Statistical Psychology* 44(1), S.75-92.
- Rost, J. (1996). *Lehrbuch Testtheorie, Testkonstruktion*. Bern: Huber.
- Rost, J., Langeheine, R. (1997). A guide through latent structure models for categorical data. In J. Rost & Langeheine, R. (Hrsg.), *Applications of Latent Trait and Latent Class Models in the Social Sciences* (S.13 -37). Münster: Waxmann.
- Rost, J. (2006). Item-Response-Theorie, in: Petermann, F., Eid, M. (Hrsg.). *Handbuch der Psychologischen Diagnostik* (Band 4), S. 261 - 274. Göttingen: Hogrefe.
- Rost, J. (2006). Latent-Class-Analyse, in: Petermann F., Eid, M. (Hrsg.). *Handbuch der Psychologischen Diagnostik* (Band 4), S. 275-287. Göttingen: Hogrefe.
- Rost, J., Von Davier, M. (1995). Mixture Distribution Rasch Models. In G.H. Fischer & I.W. Molenaar (Hrsg.), *Rasch models: Foundations, recent developments, and applications* (S.257-268). Berlin: Springer.
- Rost, J., Eid, M. (2009): Mischverteilungsmodelle. In: H. Holling (Hrsg.). *Grundlagen und statistische Methoden der Evaluationsforschung* (Enzyklopädie der Psychologie, Themenbereich B, Serie IV, Band 1), 14. Kapitel, S.483-524. Göttingen: Hogrefe.
- Schmid, H. (1992). *Psychologische Tests: Theorie und Konstruktion*. Freiburg (Schweiz): Universitätsverlag.
- Rost, J., von Davier, M. (1995). Mixture distribution Rasch Models, in: Fischer, G., Molenaar, I. (Hrsg.). *Rasch Models: Foundations, recent developments, and applications*, Springer, S.257-268.
- Smit, A., Kelderman, H., van der Flier, H. (1999). Collateral information and Mixed Rasch models. *Methods of Psychological Research Online*, Vol. 4, No. 3.