

Raschmodelle und generalisierte Regression

Sven Hilbert





Bestandteile generalisierter linearer Modelle

- Zufällige Komponente Y mit zugehöriger Wahrscheinlichkeitsverteilung
 - Mit unabhängigen Beobachtungen (y_1, \dots, y_N)
- Systematische Komponente (erklärende Größe) θ
 - Benutzt in linearer Vorhersagefunktion
- Linkfunktion spezifiziert die Funktion von $E(Y)$, die das Modell mit der systematischen Komponente verbindet



Allgemeine Form Wahrscheinlichkeitsfunktion von Y
(Exponentialfamilie):

$$f(y_i; \theta_i) = a(\theta_i) b(y_i) \exp[y_i Q(\theta_i)]$$

- $Q(\theta_i)$ wird natürlicher Parameter genannt
- Systematische Komponente verbindet einen Vektor (η_1, \dots, η_N) mit den erklärenden Variablen durch ein lineares Modell mit Prädiktoren

j ($j = 1, 2, \dots, p$):

$$\eta_i = \sum_{j=1}^p \beta_j x_{ij}$$

- Die Linearkombination der erklärenden Variablen wird linearer Prädiktor genannt



Linkfunktion: $g(\mu_i) = \eta_i$

- $\mu_i = E(Y_i)$ mit $i = 1, \dots, N$
- Verbindet zufälligen mit systematischen Komponenten

Identitätslink : $g(\mu) = \mu$

Kanonische (natürliche) Linkfunktion:

$$Q(\theta_i) = \sum_{j=1}^p \beta_j x_{ij} = \eta_i = g(\mu_i)$$

- Transformiert μ in den natürlichen Parameter η
 - Abhängig von Verteilung der y_i



Wahrscheinlichkeitsfunktion der Bernoulliverteilung:

$$f(y; \pi) = \pi^y (1 - \pi)^{1-y}$$

- $P(Y = 1) = \pi$ und $P(Y = 0) = 1 - \pi$ mit $E(Y) = \pi$

- Kanonischer Link: $Q(\pi) = \ln\left(\frac{\pi}{1 - \pi}\right)$

- Für Logistische Regression folgt: $\pi(x) = \frac{\exp(\eta)}{1 + \exp(\eta)}$
 - Hierbei $P(Y = 1) = \pi(x)$
 - Gilt für Bernoulli- und Binomialverteilung



Zweidimensionale Kontingenztafel

- Testung Unabhängigkeitshypothese
 - Systematische kategoriale Quantität
 - Multiple binäre Quantitäten

Eisaffinität abhängig von Studiengang?

- Drei Eissorten
 - Binärer Response (ja / nein)
- Zwei Studiengänge

2- dimens.	Eissorten
Studien- gänge	



2x3 Kontingenztafel

- Studiengang systematische Variable
 - 2 Level
 - Kreuzklassifiziert mit Eissorte
- Jeder Student kann 0 – 3 Sorten kaufen
- Randsummen Reihen Eissorten in Tabelle \neq Anzahl Studenten

Studiengang	Eissorte			Anzahl Studenten
	Schokolade (A)	Kirsche (B)	Gummibär (C)	
Statistik	32	65	86	160
Psychologie	87	148	157	220
Total	119	213	243	380



Spalten schließen sich nicht gegenseitig aus

- Pearson χ^2 -Test kann nicht angewandt werden

Durch Kreuzklassifikation kann 2 x 2 x 2 Tabelle für beide Studiengänge erstellt werden

- Jeweils $2^3 = 8$ Zellen
 - Möglichkeiten:
000; 100; 010; ... ; 111
- 0 = „nein“, 1 = „ja“
- Jeweils 6 Randsummen (3 Sorten Eis x „ja“ / „nein“)



Tabelle enthält also eigentlich Randsummen

- „ja“-Responses für beide Schultypen

Unabhängigkeitshypothese bezieht sich auf Randsummen

- Marginal Independence

Studiengang	Eissorte			Anzahl Studenten
	Schokolade (A)	Kirsche (B)	Gummibär (C)	
Statistik	32	65	86	160
Psychologie	87	148	157	220
Total	119	213	243	380



Zufällige Variable: Eissorte

- Level: $i = 1, 2, 3$

Systematische Variable: Studiengang

- Level: $j = 1, 2$

Annahme: Alle Antwortmuster unabhängig multinomial verteilt

- Gemeinsame Verteilung der Häufigkeiten der Antwortmuster ist produkt-multinomial verteilt



π_{ij} bezeichnet Randwahrscheinlichkeit

- Person aus Studiengang j kauft Sorte i
- Parameter der Binomialverteilung, welcher Häufigkeit modelliert

Marginales Logit Modell:

Unabhängig (Modell 1):

$$\beta_i = \ln \left(\frac{\pi_i}{1 - \pi_i} \right)$$

Abhängig (Modell 2):

$$\beta_{ij} = \ln \left(\frac{\pi_{ij}}{1 - \pi_{ij}} \right)$$



Zwei grundlegende Methoden für marginales Modell

1. Likelihood basiert

- Restriktion: Randwahrscheinlichkeiten genügen marginalem Modell
- Produkt-multinomiale Likelihood Funktion wird maximiert
 - Erlaubt wenn alle möglichen Responsemuster unabhängig multinomialverteilt sind
- Allerdings sind In den vorgestellten Modellen sind Responsemuster abhängig

2. Quasi-Likelihood basiert

- Keine Annahmen zur Verteilung nötig
- Nur erste beide Momente werden genutzt (Mean-Variance Relationship)
- Bei Annahme einer aus der Exponentialfamilie bekannten Mean-Variance-Relationship äquivalent zur vollständigen Likelihood



Parameterschätzung bei ML:

$$\frac{\partial \ell_i}{\partial \beta_j} = \frac{(y_i - \mu_i)x_{ij}}{\text{var}(Y_i)} \frac{\partial \mu_i}{\partial \eta_i}, j = 1, \dots, p$$

- $\text{var}(Y_i)$ ist aufgrund der angenommenen Verteilung der Exponentialfamilie bekannt

Parameterschätzung bei QML

$$\frac{\partial \ell_i}{\partial \beta_j} = \frac{(y_i - \mu_i)x_{ij}}{v(\mu_i)} \frac{\partial \mu_i}{\partial \eta_i}, j = 1, \dots, p$$

- Varianz wird nur über die angenommenen Mean-Variance-Relationship $\text{var}(Y_i) = v(\mu_i)$ spezifiziert



Parameterschätzung bei GEE:

$$\frac{\partial \ell_i}{\partial \boldsymbol{\beta}} = \mathbf{D}_i' \mathbf{V}_i^{-1} (\mathbf{y}_i - \boldsymbol{\mu}_i(\boldsymbol{\beta}))$$

mit $\Delta_i = \frac{\partial \theta_{it}}{\partial \eta_{it}}$ als Diagonalelemente, $\mathbf{B}_i = b'(\theta_{it})$ als Diagonalelemente,

$\mathbf{D}_i = \frac{\partial \boldsymbol{\mu}_i}{\partial \boldsymbol{\beta}_i}$, $\mathbf{R}(\boldsymbol{\alpha})$ als Arbeitskovarianzmatrix und $\mathbf{V}_i = \mathbf{B}_i^{1/2} \mathbf{R}(\boldsymbol{\alpha}) \mathbf{B}_i^{1/2} \boldsymbol{\phi}$.

Eigenschaften:

- Multivariate Erweiterung der Quasi-Likelihood
- Computational leichter aber weniger effizient als Likelihood
- Likelihood basierte Tests können nicht verwendet werden



Generalisierte Schätzgleichung (GEE) wird verwendet

$$\hat{\beta}_i = \ln\left(\frac{n_i}{N - n_i}\right) \quad \text{und} \quad se_i = \sqrt{\left[N\hat{\pi}_i(1 - \hat{\pi}_i)\right]^{-1}} \quad \text{mit} \quad \hat{\pi}_i = \frac{\exp(\hat{\beta}_i)}{1 + \exp(\hat{\beta}_i)}$$

Werte aus Randsummentabelle:

Studiengang	Eissorte			Anzahl Studenten
	Schokolade (A)	Kirsche (B)	Gummibär (C)	
Statistik	32	65	86	160
Psychologie	87	148	157	220
Total	119	213	243	380



Resultierende Parameter für Modell (1):

$$\hat{\beta}_1 = \ln\left(\frac{119}{380 - 119}\right) \quad \hat{\beta}_2 = \ln\left(\frac{213}{380 - 213}\right) \quad \hat{\beta}_3 = \ln\left(\frac{243}{380 - 243}\right)$$

Studiengang	Eissorte			Anzahl Studenten
	Schokolade (A)	Kirsche (B)	Gummibär (C)	
Statistik	32	65	86	160
Psychologie	87	148	157	220
Total	119	213	243	380



Parameter und Standardfehler für Modelle (1) und (2):

Eis	Modell (1)	Modell (2)	
		Statistik	Psychologie
Schokolade (A)	-.773 (.111)	-1.386 (.198)	-.424 (.138)
Kirsche (B)	.254 (.103)	-.379 (.161)	.721 (.144)
Gummibär (C)	.573 (.107)	.150 (.158)	1.913 (.149)

Wald-Test: $W = 46.84$

- $df = k (I - 1) = 3$
- $p = 1.85 * 10^{-10}$

→ Eiskauf ist abhängig vom Studiengang



Erweiterte Fragestellung

- Gibt es eine andere Erklärung für den gefundenen Unterschied?
 - Könnte Eitelkeit die entscheidende Rolle spielen?
- Eitelkeit als zweite systematische Variable aufnehmen
 - Verschwindet der Effekt „Studiengang“ bedingt auf Eitelkeit?
- Eitelkeit ist nicht-beobachtbare (latente) Größe
 - Fragebogen (1 – 4 Punkte)



Modell (3) mit zwei Einflussgrößen:

$$\theta_v + \beta_i = \ln \left(\frac{\pi_{vi}}{1 - \pi_{vi}} \right)$$

π_{vi} ist Wahrscheinlichkeit dass Studierender v Sorte i wählt

Bedingtes Modell

- Kauf der Eissorten darf von Eitelkeit abhängen



Vorteil: Modell determiniert die gemeinsame Verteilung der Responses aller Items (Eissorten)

- Gegeben β_1, \dots, β_k und $\theta_1, \dots, \theta_k$ sind alle Bernoulli Variablen (Antworten) lokal unabhängig
- cML Schätzung kann verwendet werden

Gemeinsame Verteilung ist gegeben durch das Produkt der Studierenden-spezifischen Wahrscheinlichkeiten aus Modell (3)

- Über alle Eissorten und Studierende



Bedeutung des Fehlens von Studiengangsindex j :

Gegeben β_j hängt die Wahrscheinlichkeit ein Eis zu kaufen von der Eitelkeit ab

- Unabhängig vom Studiengang

Hypothese ist simultane (auf Eitelkeit) bedingte Unabhängigkeit zwischen Schultyp und Response (Eiskauf)



Eitelkeit ist unbeobachtete latente Größe und muss für jeden Studierenden geschätzt werden

- Neyman-Scott Problem
- Lösung von Andersen (1970) wird angewandt

→ Anzahl der gekauften Eissorten ist suffizient für jeden Studierenden

$r \in \{0, \dots, k\}$ ist Anzahl der gekauften Eissorten

- Wird als „Eismenge“ definiert mit k Level
 - Ersetzt die angenommene stetige latente Variable „Eisaffinität“



Modell (4) (bedingtes Rasch Modell):

$$\pi_{ir} = \frac{\exp(\beta_i) \gamma_{r-1}^{(i)}}{\gamma_r}$$

$i = 1, \dots, k$ und $r = 1, \dots, k-1$ mit $\beta_k = 0$ zur
Modellidentifizierung

γ_r bezeichnet symmetrische Grundfunktion der Ordnung r der
Parameter $\exp(\beta_1), \dots, \exp(\beta_k)$

$\gamma_{r-1}^{(i)}$ bezeichnet die erste partielle Ableitung von γ_r nach β_i



Durch Bedingen auf Eismenge r kann die bedingte Wahrscheinlichkeitsverteilung hergeleitet werden

- Anteil, den die Wahrscheinlichkeit für ein bestimmtest Antwortmuster an der Gesamtwahrscheinlichkeit aller Muster mit Summenscore r hat

Bed. Likelihood (cML) ist Funktion der Parameter β_1, \dots, β_k

- Also nicht mehr abhängig von $\theta_1, \dots, \theta_k$
- Theoretisch könnte auch umgekehrt bedingt werden

Analog zu den bisher bekannten Personen- und Itemparametern im Rasch Modell



In Modell (4) wird implizit festgelegt:

$$\pi_{ir1} = \dots = \pi_{irl} = \pi_{ir}$$

→ Studiengang j spielt keine Rolle

Alternativ kann folgendes Modell (5) aufgestellt werden:

$$\pi_{irj} = \frac{\exp(\beta_{ij}) \gamma_{r-1}^{(ij)}}{\gamma_r}$$

Abgeleitet wird hier nach den β_{ij} → cML Schätzung

→ Studiengang j wird ebenfalls modelliert



Aufgrund der cML Schätzung können der Andersen Likelihood Ratio Test und der Wald Test angewendet werden

Vergleich der Parameter der Modell (4) und (5):

Eis	Modell (4)	Modell (5)	
		Statistik	Psychologie
Schokolade (A)	0	0	0
Kirsche (B)	-1.089 (.160)	-.961 (.253)	-1.187 (.210)
Gummibär (C)	-1.428 (.164)	-1.472 (.256)	-1.378 (.215)

$$G^2 = 1.167 \quad p = .558$$

$$df = 2$$

$$W = .220; \quad p = .390 \text{ mit}$$

→ Bedingt auf Eitelkeit ist Eisaffinität unabh. vom Studiengang



Erweiterung der Anwendbarkeit des Rasch Modells

Rasch Modell wird nicht als Messmodell sondern als Logit Modell für die Analyse von Häufigkeiten von zweidimensionalen Kontingenztafeln verwendet

- Bedingte Unabhängigkeit wird getestet

Hypothese der simultanen bedingten Unabhängigkeit wird getestet

- Zwischen systematischer (Studiengang) und dem binären Response auf multiple Items, gegeben eine zweite Variable (Eitelkeit)



- Agresti, A. (2002). *Categorical data analysis*. Hoboken: John Wiley & Sons.
- Agresti, A., & Liu, I. (1999). Modeling a categorical variable allowing arbitrarily many category choices. *Biometrics*, 55, 936–943.
- Andersen, E.B. (1970). Asymptotic properties of conditional maximum likelihood estimators. *Journal of the Royal Statistical Society, Series B*, 32, 283–301.
- Draxler, C. (2011). Logit models for the analysis of two-way categorical data. *Educational Research and Evaluation*, 17(5), 351–360.

Appendix

- Zusatzmaterial zur Erklärung und Weiterführung





$$p(0,1,0) \mid r = 1$$

$$\frac{\frac{1}{1 + \xi_1 \cdot \varepsilon_1} \cdot \frac{\xi_1 \cdot \varepsilon_2}{1 + \xi_1 \cdot \varepsilon_2} \cdot \frac{1}{1 + \xi_1 \cdot \varepsilon_3}}{\frac{\xi_1 \cdot \varepsilon_2 \cdot 1 \cdot 1}{(1 + \xi_1 \cdot \varepsilon_1) + (1 + \xi_1 \cdot \varepsilon_2) + (1 + \xi_1 \cdot \varepsilon_2)} + \frac{1 \cdot \xi_1 \cdot \varepsilon_2 \cdot 1}{(1 + \xi_1 \cdot \varepsilon_1) + (1 + \xi_1 \cdot \varepsilon_2) + (1 + \xi_1 \cdot \varepsilon_2)} + \frac{1 \cdot 1 \cdot \xi_1 \cdot \varepsilon_3}{(1 + \xi_1 \cdot \varepsilon_1) + (1 + \xi_1 \cdot \varepsilon_2) + (1 + \xi_1 \cdot \varepsilon_2)}}$$

$$= \frac{\xi_1 \cdot \varepsilon_2}{\xi_1 \cdot \varepsilon_1 + \xi_1 \cdot \varepsilon_2 + \xi_1 \cdot \varepsilon_3}$$

$$= \frac{\varepsilon_2}{\varepsilon_1 + \varepsilon_2 + \varepsilon_3}$$

← Bedingte Wahrscheinlichkeit

➤ Nur noch der Itemparameter (ε) ist in der Formel enthalten



Die Antworten einer Person v auf alle k Items wird auch als Antwortmuster $\mathbf{x}_v = (x_{v1}, \dots, x_{vk})$ bezeichnet.

Formal erhalten wir dann für das oben behauptete

$$P = (x_v | r_v) = \frac{\exp\left(\sum_{i=1}^k -x_{vi}\beta_i\right)}{\gamma_{r_v}(\boldsymbol{\beta})},$$

für $v = 1, \dots, n$, wobei $\gamma_r(\boldsymbol{\beta})$ die so genannte symmetrische Grundfunktion r -ter Ordnung ist.



Die Symmetrische Grundfunktion:

$$\gamma_1(\boldsymbol{\beta}) = \exp(-\beta_1) + \exp(-\beta_2) + \dots + \exp(-\beta_k)$$

$$\gamma_2(\boldsymbol{\beta}) = \exp(-\beta_1 - \beta_2) + \exp(-\beta_1 - \beta_3) + \dots + \exp(-\beta_{k-1} - \beta_k)$$

$$\gamma_3(\boldsymbol{\beta}) = \exp(-\beta_1 - \beta_2 - \beta_3) + \exp(-\beta_1 - \beta_2 - \beta_4) + \dots + \exp(-\beta_{k-2} - \beta_{k-1} - \beta_k)$$

.

.

.

$$\gamma_k(\boldsymbol{\beta}) = \exp(-\beta_1 - \beta_2 - \dots - \beta_k),$$

wobei $\gamma_0(\boldsymbol{\beta}) = 1$ und $\gamma_r(\boldsymbol{\beta}) = 0$ für $r < 0$ und $r > k$.

(zur Erinnerung: $\varepsilon_i = \exp(-\beta_k)$)



Formel: $\sum_{x|r} \prod_{i=1}^k \exp(-x_i \sigma_i)$

Kurzform: $\gamma_r(\exp(-\sigma))$

Eingesetzt im Nenner der cML: $cL = \prod_{v=1}^N \frac{\exp(-\sum_{i=1}^k x_{vi} \sigma_i)}{\gamma_r(\exp(-\sigma))}$



Linearer Prädiktor: $g(\mu_{it}) = \mathbf{x}'_{it} \boldsymbol{\beta} + \mathbf{z}'_{it} \mathbf{u}_i$

- y_{it} ist Beobachtung t in cluster i
- $\mathbf{u}_i \sim N(\mathbf{0}, \boldsymbol{\Sigma})$ angenommen
- $\text{var}(Y_{it} | u_i) = \Phi_{it} v(\mu_{it})$
- Bedingt auf \mathbf{u}_i , behandelt das Modell y_{it} unabhängig über i und t

Als logit Modell: $\text{logit}[P(Y_{it} = 1 | u_i)] = \beta_t + u_i$

- u_i wird im Raschmodell zwar als fester Effekt behandelt, allerdings durch cML eliminiert
- Andere Autoren: Random Effects Modell mit Probit-Link