

## 5.Tutorium Generalisierte Regression

- Multinomiales/Kumulatives Logit-Modell -

Minh Anh Le:

09.01.2017 und 16.01.2017

Nicole Schüller:

12.01.2017 und 19.01.2017

Institut für Statistik, LMU München

## Gliederung

- 1 Multinomialverteilung
- 2 Multinomiales Logit-Modell
- 3 Kumulatives Logit-Modell
- 4 Mehrkategoriale Modelle mit R

# Gliederung

- 1 Multinomialverteilung
- 2 Multinomiales Logit-Modell
- 3 Kumulatives Logit-Modell
- 4 Mehrkategoriale Modelle mit R

## Multinomialverteilung mit Redundanzen:

$$Y \sim M(n, \pi^T = (\pi_1, \dots, \pi_k))$$

$$P(\mathbf{y}^T = (m_1, \dots, m_k)) = \frac{n!}{m_1! \cdot \dots \cdot m_k!} \pi_1^{m_1} \cdot \dots \cdot \pi_k^{m_k}$$

$s = 1, \dots, k$ : Index für Kategorien

$i = 1, \dots, n$ : Index für Beobachtungen

$m_s$ : Anzahl der Beobachtungen in Kategorie  $s$

$\pi_s$ : Wahrscheinlichkeit für Kategorie  $s$

## Multinomialverteilung ohne Redundanzen

Sei Kategorie  $k$  Referenzkategorie:

$$\sum_{s=1}^k \pi_s = 1 \Rightarrow \pi_k = 1 - \pi_1 - \dots - \pi_{k-1} = \pi_q$$

$$\sum_{s=1}^k m_s = n \Rightarrow m_k = n - m_1 - \dots - m_{k-1} = m_q$$

$$\forall s \quad : \quad 0 \leq \pi_s \leq 1 \wedge m_s \in \{1, \dots, n\}$$

$$P(\mathbf{y}^T = (m_1, \dots, m_k)) = \frac{n!}{m_1! \cdot \dots \cdot (n - m_1 - \dots - m_q)!} \cdot \pi_1^{m_1} \cdot \dots \cdot (1 - \pi_1 - \dots - \pi_q)^{(n - m_1 - \dots - m_q)}$$

## Gliederung

- 1 Multinomialverteilung
- 2 Multinomiales Logit-Modell**
- 3 Kumulatives Logit-Modell
- 4 Mehrkategoriale Modelle mit R

## Multinomiale Zielgrößen

- bisher:

Betrachtung des Logit-Modells für binäre Zielgrößen:

$$\log \left( \frac{P(y_i = 1 | \mathbf{x}_i)}{P(y_i = k = 2 | \mathbf{x}_i)} \right) = \mathbf{x}_i^T \boldsymbol{\beta}$$

- jetzt:

Betrachtung des Logit-Modells für **multinomialverteilte** Zielgrößen, d.h.  $y_i \in \{1, \dots, k\}$

## Link-und Responsefunktion

Multinomiales Logit-Modell für  $r = 1, \dots, \overbrace{k-1}^q$ :

$$\log \left( \frac{P(y_i = r | \mathbf{x}_i)}{P(y_i = k | \mathbf{x}_i)} \right) = \mathbf{x}_i^T \beta_r$$

bzw.

$$P(y_i = r | \mathbf{x}) = \frac{\exp\{\mathbf{x}_i^T \beta_r\}}{1 + \sum_{s=1}^{k-1} \exp\{\mathbf{x}_i^T \beta_s\}}$$

## Link- und Responsefunktion

Außerdem gilt:

$$\mathbf{x}_i^T \boldsymbol{\beta}_k = \log \left( \frac{P(y_i = k | \mathbf{x}_i)}{P(y_i = k | \mathbf{x}_i)} \right) = \log(1) = 0$$

und somit

$$P(y_i = k | \mathbf{x}_i) = \frac{\overbrace{\exp\{\mathbf{x}_i^T \boldsymbol{\beta}_k\}}^0}{1 + \sum_{s=1}^{k-1} \exp\{\mathbf{x}_i^T \boldsymbol{\beta}_s\}} = \frac{1}{1 + \sum_{s=1}^{k-1} \exp\{\mathbf{x}_i^T \boldsymbol{\beta}_s\}}$$

## Interpretation

- **Beachte:** Kategorie  $k$  ist Referenzkategorie!
- Interpretation über die logarithmierten Chancen wie beim binären Logit-Modell, jedoch jetzt immer **im Bezug auf die Referenzkategorie  $k$** .

- Betrachte:  $\log \left( \frac{P(y=r|\mathbf{x}_i)}{P(y=k|\mathbf{x}_i)} \right) = \log \left( \frac{\pi_r}{\pi_k} \right) = \mathbf{x}_i^T \boldsymbol{\beta}_r$

⇒ Steigt  $x_j$  um eine Einheit, so ändert sich die logarithmierte Chance von  $Y=r$  zu  $Y=k$  um  $\beta_{rj}$  (Effekt von der  $j$ -ten Einflussgröße aus der  $r$ -ten Kategorie).

⇒ Steigt  $x_j$  um eine Einheit, so ändert sich die Chance von  $Y=r$  zu  $Y=k$  um  $\exp(\beta_{rj})$

# Gliederung

- 1 Multinomialverteilung
- 2 Multinomiales Logit-Modell
- 3 Kumulatives Logit-Modell**
- 4 Mehrkategoriale Modelle mit R

## Problemstellung

- Betrachte wieder eine Zielgröße  $Y \in \{1, \dots, k\}$ , jedoch nun ist  $Y$  **ordinalskaliert**, d.h. die Kategorien lassen sich ordnen.
- Bisheriges multinomiales Modell ist anwendbar, nutzt jedoch die ordinale Struktur der Daten nicht aus  
⇒ **kumulatives** Modell!
- Allgemeine Modellformulierung:

$$P(Y \leq r | \mathbf{x}_i) = F(\gamma_{0r} + \mathbf{x}_i^T \boldsymbol{\gamma})$$

## Logistische Verteilungsfunktion

Nimmt man für  $F$  die logistische Verteilungsfunktion an, so erhält man folgendes Modell:

$$P(y \leq r | \mathbf{x}_i) = \frac{\exp\{\gamma_{0r} + \mathbf{x}_i^T \boldsymbol{\gamma}\}}{1 + \exp\{\gamma_{0r} + \mathbf{x}_i^T \boldsymbol{\gamma}\}}$$

bzw.

$$\underbrace{\log \left( \frac{P(y \leq r | \mathbf{x}_i)}{P(y > r | \mathbf{x}_i)} \right)}_{\text{kumulierte Logits}} = \gamma_{0r} + \mathbf{x}_i^T \boldsymbol{\gamma}$$

## Besonderheit des Modells

- Betrachtet man zwei Populationen  $x_1$  und  $x_2$  (z.B. jung und alt), so gilt:

$$\frac{P(Y \leq r | \mathbf{x}_1) / P(Y > r | \mathbf{x}_1)}{P(Y \leq r | \mathbf{x}_2) / P(Y > r | \mathbf{x}_2)} = \frac{\exp(\gamma_{0r} + \mathbf{x}_1^T \gamma)}{\exp(\gamma_{0r} + \mathbf{x}_2^T \gamma)} = \exp((\mathbf{x}_1^T - \mathbf{x}_2^T) \gamma)$$

→ das Odds-Ratio ist **unabhängig von Kategorie r**

⇒ **Proportional Odds Model**

- Interpretation:  
Die Chancenverhältnisse sind unabhängig von der betrachteten Schwelle  $r$  und nur proportional zum Unterschied von  $x_1$  und  $x_2$

## Gliederung

- 1 Multinomialverteilung
- 2 Multinomiales Logit-Modell
- 3 Kumulatives Logit-Modell
- 4 Mehrkategoriale Modelle mit R**

## Nützliche R-Funktionen

- `multinom()` aus Paket "nnet"

multinomialer Logit-Modell mit beobachtungsspezifischem

Prädiktor  $\eta_{ir} = \mathbf{x}_i^T \boldsymbol{\beta}_r$

- `polr()` aus Library "MASS"

**proportional odds logistic regression**

→ Fit ordinaler Logit-Modelle (per Default)

→ Fit ordinaler Probit-Modelle bei Angabe des Arguments

`method = "probit"`