

# Statistik IV für Nebenfachstudierende

## 4.6. Inferenz für Mehrkategoriale Regression

Prof. Dr. Andreas Mayr

Institut für Statistik, LMU München

Sommersemester 2017

# Situation

Daten:  $(\underline{y}_i, \underline{x}_i)$

$$\underline{y}_i \sim M(n_i, (\pi_{i1}, \dots, \pi_{ik}))$$

## Multinomialverteilung

$\underline{y}^\top = (y_1, \dots, y_k)$  ist multinomialverteilt

$\underline{y} \sim M(n, \underline{\pi}^\top = (\pi_1, \dots, \pi_k))$  und

$$\mathbb{P}(\underline{y}^\top = (n_1, \dots, n_k)) = \frac{n!}{n_1! \cdot \dots \cdot n_k!} \pi_1^{n_1} \cdot \dots \cdot \pi_k^{n_k}$$

mit  $\sum_{r=1}^k n_r = n$  und  $n_r \in \{0, 1, \dots, n\}$ .

# Formulierung

- Jetzt nicht für  $\underline{y}_i = (y_{i1}, \dots, y_{ik})$   
mit  $y_{ir} \in \{0, 1, \dots, n_i\}$
- Sondern  $\bar{y}_i = (\bar{y}_{i1}, \dots, \bar{y}_{ik}) = \underline{y}_i/n_i$   
mit  $\bar{y}_i = (p_{i1}, \dots, p_{ik})$
- Also:

$$\mathbb{P}(\bar{y}_i^\top = (p_{i1}, \dots, p_{ik})) = \frac{n_i!}{(n_{i1}p_{i1})! \cdot \dots \cdot (n_{ik}p_{ik})!} \pi_1^{(n_{i1}p_{i1})} \cdot \dots \cdot \pi_k^{(n_{ik}p_{ik})}$$

# Exponentialfamilie

Eine Verteilungsfamilie heißt  $k$ -parametrische Exponentialfamilie, wenn sich die Dichten auf folgende Gestalt bringen lassen:

$$f(x, \theta) = c(\theta)b(x) \exp \left( \sum_{j=1}^k \gamma_j(\theta)t_j(x) \right)$$

In unserem Fall:

$$f(p, \pi) = c(\pi)b(p) \exp \left( \sum_{j=1}^k \gamma_j(\pi)t_j(p) \right)$$

# Multinomialverteilung als Exponentialfamilie

$$f(p_{i1}, \dots, p_{ik}; \pi) =$$

# Multinomialverteilung als Exponentialfamilie

... natürlicher  $r$ -ter Parameter

# Multinomialverteilung als Exponentialfamilie

- Durch die Exponentialfamilie ist die klassische ML-Inferenz verfügbar (z.B. Score Funktion, Fisher Matrix, etc).
- Bzw. die Inferenzmethoden aus dem GLM-Framework (IWLS).

# Das Maximum-Likelihood Prinzip

- Klassischerweise geht man davon aus, dass Parameter einer Verteilung fix sind.
- Die Realisierung einer Zufallsvariable ist zufällig (bei uns die Stichprobe) und folgt einer Verteilung mit Parameter  $\theta$ .
- Die Wahrscheinlichkeitsverteilung  $f(x, \theta)$  sagt etwas über das Auftreten von  $x$  gegeben  $\theta$  aus.
- Wir haben aber  $x$  schon, und suchen  $\theta$ .
- ▶ Suche nach dem  $\theta$  welches am meisten für das Auftreten von  $x$  spricht.

# Das Maximum-Likelihood Prinzip

**Graphisch:**

# ML Schätzung

- log-Likelihood:
- Score-Funktion:
- Schätzgleichung:

# ML Schätzung

- Fisher-Matrix:
  
  
  
  
  
  
  
  
  
  
- Asymptotische Normalität des ML Schätzers:

# Goodness-of-fit

- Pearson:

- Devianz:

# Hypothesentests...

.... siehe Übung.