

# Statistik IV für Nebenfachstudierende

## 4.6. Inferenz für Mehrkategoriale Regression

Prof. Dr. Andreas Mayr

Institut für Statistik, LMU München

Sommersemester 2017

# Situation

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

$\rightsquigarrow$  Für eine Messung  $i$  gibt es  $n_i$  einzelne Beobachtungen (Urnenmodell)

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

## 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  $y_{ir} \in \{0, 1, \dots, n_i\}$   $\leftarrow$  absolute Häufigkeiten

- Sondern  $\bar{y}_i = (\bar{y}_{i1}, \dots, \bar{y}_{ik}) = \underline{y}_i / n_i$

mit  $\bar{y}_i = (p_{i1}, \dots, p_{ik})$   $\leftarrow$  relative Häufigkeiten

- Also:

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

$(n_i p_{i1})! \quad (n_i p_{ik})!$

weil  $n_{in} = n_i \cdot p_{in} = y_{in}$

# Exponentialfamilie

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

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

Handwritten annotations for the general form:  
- A bracket above the summation index  $k$  is labeled "k-parametrische Exponentialfamilie".  
- An arrow points from the text "natürliche Parameterisierung" to the  $\gamma_j(\theta)$  term.  
- An arrow points from the text "Statistiken" to the  $t_j(x)$  term.

In unserem Fall:

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

Handwritten annotations for the specific case:  
- An arrow points from the text "wahren Wert" to the parameter  $\pi$ .  
- An arrow points from the text "rel Häufigkeiten 'Stichprobe'" to the variable  $p$ .  
- An arrow points from the text "wahrer Parameter" to the  $\gamma_j(\pi)$  term.  
- An arrow points from the text "Stichprobe" to the  $t_j(p)$  term.

# Multinomialverteilung als Exponentialfamilie

$$f(p_{i1}, \dots, p_{iq}; \pi) = \frac{n_i!}{(n_i p_{i1})! \dots (n_i p_{iq})!} \pi_{i1}^{n_i p_{i1}} \dots \pi_{iq}^{n_i p_{iq}} (1 - \pi_{i1} - \dots - \pi_{iq})^{n_i (1 - \pi_{i1} - \dots - \pi_{iq})}$$

$$= \underbrace{\frac{n_i!}{(n_i p_{i1})! \dots (n_i p_{iq})!}}_{c_i} \left( \frac{\pi_{i1}}{1 - \pi_{i1} - \dots - \pi_{iq}} \right)^{n_i p_{i1}} \dots \left( \frac{\pi_{iq}}{1 - \pi_{i1} - \dots - \pi_{iq}} \right)^{n_i p_{iq}} (1 - \pi_{i1} - \dots - \pi_{iq})^{n_i}$$

$$= \frac{\exp(\log(\dots))}{\exp(\log(c_i) + n_i \sum_{r=1}^q p_{ir} \cdot \log\left(\frac{\pi_{ir}}{1 - \pi_{i1} - \dots - \pi_{iq}}\right) + n_i \cdot \log(1 - \pi_{i1} - \dots - \pi_{iq}))}$$

$$= \underbrace{c_i \cdot \exp(n_i \cdot (1 - \pi_{i1} - \dots - \pi_{iq}))}_{b(p)} \cdot \exp\left(n_i \cdot \sum_{r=1}^q p_{ir} \log\left(\frac{\pi_{ir}}{1 - \pi_{i1} - \dots - \pi_{iq}}\right)\right)$$

$b(p) \cdot c(\pi) \cdot \uparrow$   
 $q$ -parametrisierte Expofam

# Multinomialverteilung als Exponentialfamilie

... natürlicher  $r$ -ter Parameter

$$\eta_r(\pi) = \log\left(\frac{\pi_{ir}}{1 - \pi_{i1} - \dots - \pi_{iq}}\right)$$

Spezialfall :  $h=2$

$$\Rightarrow \log\left(\frac{\pi_i}{1 - \pi_i}\right)$$

# 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:

$$l = \sum_{i=1}^n \log f(p_{i1}, \dots, p_{in})$$

- Score-Funktion:

z.B.  $S(\beta) = \frac{\partial l(\beta)}{\partial \beta}$       Ableitung der log-LH  
nach interessierendem Parameter

- Schätzungsgleichung:

$$S(\beta) \stackrel{!}{=} 0$$

$\Rightarrow$

Äquivalent zur max. der Likelihood  
ist max. der log-LH.

$\Rightarrow$  Ableitung Null setzen.

# ML Schätzung

- Fisher-Matrix:

$$F(\beta) = E \left( - \frac{\partial^2 \ell(\beta)}{\partial \beta \partial \beta^T} \right)$$

$\hat{=}$  2. Ableitung der Log-LH,  
bzw. Ableitung der  
Scorefunktion  
"Krümmung"  
auch Fisher-Information  
genannt.

- Asymptotische Normalität des ML Schätzers:

$$\hat{\beta}_{ML} \xrightarrow{n \rightarrow \infty} N(\beta, F(\beta)^{-1})$$

$\uparrow$  asympt.  
erwarten

$\uparrow$   $\Sigma =$  Fisher Matrix

# Goodness-of-fit für mehrkategoriale Regression

- Pearson:

$$\chi^2_p = \sum_{i=1}^n n_i \sum_{r=1}^q \frac{(p_{ir} - \hat{\pi}_{ir})^2}{\hat{\pi}_{ir}}$$

rel. Häufigkeiten  
↓  
Werte aus dem Modell geschätzt  
"quadratische Differenz"

- Devianz:

$$\chi^2_D = 2 \sum_{i=1}^n n_i \sum_{r=1}^q p_{ir} \log\left(\frac{p_{ir}}{\hat{\pi}_{ir}}\right)$$

rel. Häufigkeit  
↑  
aus Modell  
"log-Verhältnis"

# Hypothesentests...

.... siehe Übung.