

## Generalisierte Lineare Modelle – Übungen: Blatt 3

1. Zeige, dass bei einem logistischen Regressionsmodell mit beliebig vielen Faktoren im linearen Prädiktor  $\eta_i$  (sowohl als Haupt- als auch als Interaktionseffekte) für  $y_i \sim \text{Bernoulli}(\mu_i)$  ( $i = 1, \dots, n$ ) mit  $\text{logit}(\mu_i) = \eta_i$  immer deterministisch  $X^2 = n$  resultiert.  
(Hinweis: betrachte zuerst eine einfache Zufallsstichprobe und zeige, dass zumindest dafür diese Eigenschaft hält. Verallgemeinere die Modellannahme auf einen Prädiktor mit einem  $k$ -stufigen Effekt und weise dafür nach, dass wiederum  $X^2 = n$  gilt. Da jede Kombination von Haupteffekten und deren Interaktionen alternativ auch durch 1 mehrstufigen Faktor darstellbar ist, folgt damit die Behauptung.)
2. (Agresti Problem 7.3) Mit den folgenden Daten wird die politische Einstellung einer Person mit Geschlecht und Rasse verglichen.

|            |         | Politische Einstellung |                |            |
|------------|---------|------------------------|----------------|------------|
| Geschlecht | Rasse   | demokratisch           | republikanisch | unabhängig |
| männlich   | weiß    | 132                    | 176            | 127        |
|            | schwarz | 42                     | 6              | 12         |
| weiblich   | weiß    | 172                    | 129            | 130        |
|            | schwarz | 56                     | 4              | 15         |

- (a) Finde ein Logit-Modell welches auf Abweichungen von einer Referenzzelle basiert und gut passt. Verwende dazu `multinom` aus der `library(nnet)`.
  - (b) Schätze dasselbe Modell nur unter Verwendung von `glm` und vergleiche die Parameterschätzungen.
  - (c) Interpretiere die geschätzten Effekte auf die Chancen (odds), dass die politische Gesinnung *demokratisch* anstatt *republikanisch* ist.
3. (Agresti Problem 8.5) Aufzeichnungen über Autounfälle in Florida in 1988 ergaben:

| Verwendung der Sicherheitsgurte | aus dem Auto | Unfall endet  |         |
|---------------------------------|--------------|---------------|---------|
|                                 | geschleudert | nicht tödlich | tödlich |
| angeschnallt                    | ja           | 1105          | 14      |
|                                 | nein         | 411111        | 483     |
| nicht angeschnallt              | ja           | 4624          | 497     |
|                                 | nein         | 157342        | 1008    |

- (a) Finde ein Loglineares Modell, das die Daten gut beschreibt. Argumentiere die Suche.
- (b) Vergleiche die Beobachtungen mit den Prognosen unter den folgenden 5 Modellen:  $B + E + F$ ,  $B : E + F$ ,  $B : E + B : F$ ,  $B : E + B : F + E : F$ ,  $B : E : F$ .  
Erstelle dazu eine Tabelle, deren ersten drei Spalten die *yes, no* Stufen der drei Faktoren  $B$  (belt/Gurte),  $E$  (ejected/rausgeschleudert), und  $F$  (fatal/tödlicher Ausgang) beinhalten, gefolgt von den entsprechenden Prognosen unter diesen Modellen. Was fällt hierbei auf?
- (c) Schätze unter Verwendung aller obigen Modelle die sogenannten *konditionalen odds ratios*, bei denen jeweils ein Faktor auf einer Stufe (z.B. auf der ersten Stufe) fest gehalten ist, d.h.

$$\frac{\mu_{11(1)}\mu_{22(1)}}{\mu_{12(1)}\mu_{21(1)}}, \quad \frac{\mu_{1(1)1}\mu_{2(1)2}}{\mu_{1(1)2}\mu_{2(1)1}}, \quad \frac{\mu_{(1)11}\mu_{(1)22}}{\mu_{(1)12}\mu_{(1)21}}.$$

Wie sehen die entsprechenden Schätzungen aus, wenn der festgehaltene Faktor auf seine zweite Stufe fixiert wird. Interpretiere alle erzielten Resultate im Vergleich zum dafür verwendeten Modell.

- (d) Betrachte nun als Responsevariable die Information, ob eine Person getötet wurde oder nicht. Bezeichne  $Y$  diese 2-stufige Variable und  $X$  und  $Z$  zwei erklärende Faktoren. Für ein loglineares Modell mit allen zweifachen Interaktionen ( $X : Y$ ,  $X : Z$ ,  $Y : Z$ ) gilt dann für den Erwartungswert von  $Y$

$$\begin{aligned} \log \frac{P(Y = 1|X = i, Z = k)}{P(Y = 2|X = i, Z = k)} &= \log \frac{\mu_{i1k}}{\mu_{i2k}} = \log \mu_{i1k} - \log \mu_{i2k} \\ &= \left( \mu + \lambda_i^X + \lambda_1^Y + \lambda_k^Z + \lambda_{i1}^{XY} + \lambda_{ik}^{XZ} + \lambda_{1k}^{YZ} \right) \\ &\quad - \left( \mu + \lambda_i^X + \lambda_2^Y + \lambda_k^Z + \lambda_{i2}^{XY} + \lambda_{ik}^{XZ} + \lambda_{2k}^{YZ} \right) \\ &= (\lambda_1^Y - \lambda_2^Y) + (\lambda_{i1}^{XY} - \lambda_{i2}^{XY}) + (\lambda_{1k}^{YZ} - \lambda_{2k}^{YZ}). \end{aligned}$$

Der erste Term ist konstant, der zweite hängt nur von der Stufe  $i$  von  $X$  ab, und der dritte von der Stufe  $k$  von  $Z$ . Somit resultiert für das obige Logit-Modell

$$\text{logit } P(Y = 1|X = i, Z = k) = \alpha + \beta_i^X + \beta_k^Z.$$

Passen unter Verwendung dieser Erkenntnis ein zum *unter (a) gefundenen optimalen Modell* äquivalentes Logit Modell an. Interpretiere damit die Effekte.