

### 3 Generalisierte lineare Modelle

#### Aufgabe 3

Gegeben seien Beobachtungen  $(y_i, \mathbf{x}_i)$ ,  $i = 1, \dots, n$ . Dabei sei  $y_i \in \{0, 1\}$  eine binäre Responsevariable und  $\mathbf{x}_i = (1, x_{i1}, \dots, x_{ip})^T$  ein Vektor mit  $p$  Kovariablen. Der lineare Prädiktor ist durch  $\eta = \mathbf{x}^T \boldsymbol{\beta}$  gegeben.

- (a) Zunächst soll ein Probit-Modell gefittet werden. Leiten Sie die Score-Funktion  $s(\boldsymbol{\beta})$  her.  
(b) Die erwartete Fisher-Informationsmatrix  $F(\boldsymbol{\beta})$  ist für GLMs allgemein gegeben durch

$$F(\boldsymbol{\beta}) = \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^T \left( \frac{\partial h(\eta_i)}{\partial \eta} \right)^2 / \sigma_i^2,$$

mit  $\sigma_i^2 = \text{var}(y_i)$ .

Berechnen Sie mit Hilfe dieser Formel  $F(\boldsymbol{\beta})$  für das Logit- und das Probit-Modell.

- (c) Für die beobachtete Fisher-Informationsmatrix  $F_{\text{obs}}(\boldsymbol{\beta})$  erhält man im Logit-Modell

$$F_{\text{obs}}(\boldsymbol{\beta}) = \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^T \frac{\exp(\mathbf{x}_i^T \boldsymbol{\beta})}{(1 + \exp(\mathbf{x}_i^T \boldsymbol{\beta}))} \left( 1 - \frac{\exp(\mathbf{x}_i^T \boldsymbol{\beta})}{(1 + \exp(\mathbf{x}_i^T \boldsymbol{\beta}))} \right).$$

Im Probit-Modell erhält man

$$F_{\text{obs}}(\boldsymbol{\beta}) = \sum_{i=1}^n \frac{\mathbf{x}_i \mathbf{x}_i^T}{\Phi^2(\mathbf{x}_i^T \boldsymbol{\beta})(1 - \Phi(\mathbf{x}_i^T \boldsymbol{\beta}))^2} \left( \phi'(\mathbf{x}_i^T \boldsymbol{\beta}) \Phi^2(\mathbf{x}_i^T \boldsymbol{\beta})(1 - \Phi(\mathbf{x}_i^T \boldsymbol{\beta})) + \phi^2(\mathbf{x}_i^T \boldsymbol{\beta}) \Phi^2(\mathbf{x}_i^T \boldsymbol{\beta}) - y_i (\Phi(\mathbf{x}_i^T \boldsymbol{\beta})(1 - \Phi(\mathbf{x}_i^T \boldsymbol{\beta})) \phi'(\mathbf{x}_i^T \boldsymbol{\beta}) - \phi^2(\mathbf{x}_i^T \boldsymbol{\beta})(1 - 2\Phi(\mathbf{x}_i^T \boldsymbol{\beta}))) \right),$$

wobei  $\phi$  die Dichtefunktion und  $\Phi$  die Verteilungsfunktion der  $N(0,1)$ -Verteilung bezeichnen.

Vergleichen Sie diese Formeln qualitativ mit Ihren Ergebnissen aus Teilaufgabe (b). Woraus ergeben sich diese Unterschiede?

- (d) Zeigen Sie, dass in allen GLMs mit kanonischem Link  $\frac{\partial h(\eta)}{\partial \eta} = \frac{\text{var}(y)}{\phi}$  gilt. Welche weiteren Vorteile bietet die Verwendung des kanonischen Links im Vergleich zu anderen Linkfunktionen?

#### Aufgabe 4

Der Fisher-Scoring-Algorithmus zur Berechnung des ML-Schätzers des Parametervektors  $\boldsymbol{\beta}$  ist in der Form der *iteratively weighted least squares* (IWLS), in der  $k$ -ten Iteration, gegeben durch

$$\hat{\boldsymbol{\beta}}^{(k+1)} = (\mathbf{X}^T \mathbf{W}(\hat{\boldsymbol{\beta}}^{(k)}) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(\hat{\boldsymbol{\beta}}^{(k)}) \tilde{\boldsymbol{\eta}}(\hat{\boldsymbol{\beta}}^{(k)}),$$

wobei  $\mathbf{X}$  die Designmatrix inkl. Intercept,  $\mathbf{W}(\boldsymbol{\beta})$  die Gewichtsmatrix und  $\tilde{\boldsymbol{\eta}}(\boldsymbol{\beta}) = \mathbf{X}\boldsymbol{\beta} + \mathbf{D}(\boldsymbol{\beta})^{-1}(\mathbf{y} - \hat{\boldsymbol{\mu}})$  den Vektor der Pseudo-Beobachtungen bezeichnet.

- (a) Implementieren Sie schrittweise den IWLS-Algorithmus für das Logit-Modell. Schreiben Sie dafür eine Funktion `iwls_logit()`, welcher der Response-Vektor  $\mathbf{y}$ , die Designmatrix  $\mathbf{X}$  und ein Startwert für den Parametervektor  $\boldsymbol{\beta}$  als Argumente übergeben werden. Als Abbruchkriterium bietet sich z.B.  $\frac{\|\hat{\boldsymbol{\beta}}^{(k+1)} - \hat{\boldsymbol{\beta}}^{(k)}\|}{\|\hat{\boldsymbol{\beta}}^{(k)}\|} < 10^{-5}$  an.

Bestimmen Sie hierfür zunächst  $\mathbf{D}(\boldsymbol{\beta})$  und  $\mathbf{W}(\boldsymbol{\beta})$  für das Logit-Modell.

- (b) Wenden Sie ihre Funktion aus Teilaufgabe (a) auf den Datensatz `shuttle` von Übungsblatt 2 an. Verwenden Sie die Startwerte  $(0, 0)$ ,  $(4, -0.1)$  und  $(2, -2)$  für  $\boldsymbol{\beta}$ . Was fällt dabei auf? Vergleichen Sie Ihre Ergebnisse mit denen der Funktion `glm()` (Blatt 2/Aufgabe 1).