

## Statistische Modelle

- Lineare Modelle

$$Y_i \sim N(\mu_i, \sigma^2) \quad \text{und} \quad E[Y] = X\beta$$

$Y$  stetig  $X$  stetig und/oder kategoriell

- Logistische Regression

$$Y_i \sim B(1, \pi_i) \quad \text{und} \quad E[Y] = \frac{1}{1 + e^{-X\beta}}$$

$Y$  binär  $X$  stetig und/oder kategoriell

- Loglineare Modelle

$$Y_i \sim P(\lambda_i) \quad \text{und} \quad E[Y] = e^{X\beta}$$

$Y$  ganzzahlig  $X$  kategoriell

Und in jedem Fall sind die  $\{Y_i\}$  als unabhängig betrachtet.

## Verallgemeinerte lineare Modelle

Gegeben  $\{X_j = x_j\}$  seien die  $\{Y\}$  Werte unabhängig und

$$E[Y|X] = \mu = h(X\beta)$$

$\eta = X\beta$  ist der lineare Prädiktor

$\eta = g(\mu)$  ist die Linkfunktion

Die (bedingte) Verteilung von  $Y$  soll zu einer einfachen Exponentialfamilie gehören:

$$f(y, | \theta, \varphi) = \exp \left\{ w \frac{y\theta - b(\theta)}{\varphi} + c\left(y, \frac{\varphi}{w}\right) \right\}$$

- $c\left(y, \frac{\varphi}{w}\right) \geq 0$
- $\theta$  der "kanonischer" (Lokations-) Parameter
- $\varphi > 0$  der Streuungs- oder Störparameter (unabhängig von  $\theta$ ), und  $w$  bekannte Gewichte

## Momente

$b(\theta)$  ist im Innern des Parameterraums beliebig oft differenzierbar, und alle Momente von  $Y$  existieren.

$$\int f(y; \theta, \varphi) dy = 1$$

$$\frac{\partial \int f(y; \theta, \varphi) dy}{\partial \theta} = 0$$

Daraus folgt unter schwachen Regularitätsbedingungen

$$\int \frac{\partial f(y; \theta, \varphi)}{\partial \theta} dy = 0$$

$$\frac{\partial f(y; \theta, \varphi)}{\partial \theta} = (y - b'(\theta)) f(y; \theta, \varphi)$$

und deshalb gilt

$$E_{\theta}[Y] = \mu(\theta) = \frac{\partial b(\theta)}{\partial \theta}$$

Mit analogen Argumenten können wir zeigen, dass

$$VAR_{\theta}[Y] = \Sigma(\theta) = \frac{\varphi}{w} \frac{\partial^2 b(\theta)}{\partial \theta \partial \theta'} = \frac{\varphi}{w} V[\mu]$$

Bsp: **Normalverteilung:**  $Y_i \sim N(\mu_i, \sigma^2)$ .

$$\begin{aligned} f(y_i, \mu_i, \sigma^2) &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp -\left\{\frac{1}{2\sigma^2}(y_i - \mu_i)^2\right\} \\ &= \exp \left\{ \frac{1}{\sigma^2}(y_i\mu_i - \frac{1}{2}\mu_i^2 - \frac{1}{2}y_i^2) - \frac{1}{2} \ln(2\pi\sigma^2) \right\} \\ &= \exp \left\{ \frac{1}{\sigma^2}(y_i\mu_i - \frac{1}{2}\mu_i^2) - \frac{1}{2} \left( \frac{y_i^2}{\sigma^2} + \ln(2\pi\sigma^2) \right) \right\} \end{aligned}$$

also,

$$\begin{aligned} f(y_i | \theta_i, \varphi) &= \exp \left\{ \frac{1}{\varphi}(y_i\theta_i - b(\theta_i)) - \frac{1}{2} \left( \frac{y_i^2}{\varphi} + \ln(2\pi\varphi) \right) \right\} \end{aligned}$$

mit

$$\begin{aligned} \theta_i &= \mu_i \\ b(\theta_i) &= \theta_i^2/2 = \mu_i^2/2 \\ \varphi &= \sigma^2 \\ w_i &= 1 \\ c(y_i, \frac{\varphi}{w_i}) &= -\frac{1}{2} \left( \frac{y_i^2}{\varphi} + \ln(2\pi\varphi) \right) \end{aligned}$$

**Poisson:**  $Y_i \sim P(\lambda_i)$

$$\begin{aligned} f(y_i, \lambda_i) &= \exp(-\lambda_i) \frac{\lambda_i^{y_i}}{y_i!} \\ &= \exp(-\lambda_i + y_i \ln \lambda_i - \ln(y_i!)) \\ &= \exp(y_i \ln \lambda_i - \lambda_i - \ln(y_i!)) \end{aligned}$$

also,

$$\begin{aligned} \theta_i &= \ln \lambda_i \\ b(\theta_i) &= \exp(\theta_i) = \lambda_i \\ \varphi &= 1 \\ w_i &= 1 \\ c(y_i, 1) &= \ln(y_i!) \end{aligned}$$

Das Poisson Modell gilt nicht nur für loglineare Modelle, sondern auch für Poisson Regressionsmodelle, z.B.  $Y$  als Anzahl Unfälle an verschiedenen Stellen und  $X$  die erklärenden Variablen.

**Binomial:**  $\tilde{Y}_i \sim B(n_i, \pi_i)$  ersetzt durch  $Y_i = \frac{\tilde{Y}_i}{n_i}$

$$\begin{aligned} f(n_i y_i, \pi_i) &= \binom{n_i}{n_i y_i} \pi_i^{n_i y_i} (1 - \pi_i)^{n_i - n_i y_i} \\ &= \exp[n_i y_i \ln \pi_i + (n_i - n_i y_i) \ln(1 - \pi_i) + \ln \binom{n_i}{n_i y_i}] \\ &= \exp\left\{n_i \left[y_i \ln \frac{\pi_i}{1 - \pi_i} + \ln(1 - \pi_i)\right] + \ln \binom{n_i}{n_i y_i}\right\} \end{aligned}$$

also,

$$\begin{aligned} \theta_i &= \ln\left(\frac{\pi_i}{1 - \pi_i}\right) \\ b(\theta_i) &= \ln(1 + e^{\theta_i}) = -\ln(1 - \pi_i) \\ \varphi &= 1 \\ w_i &= n_i \\ c(y_i, 1/n_i) &= \ln \binom{n_i}{n_i y_i} \end{aligned}$$

Andere mögliche (nicht-kanonische Linkfunktionen) sind:

Probit (Invers Normal)  $g(\pi) = \Phi^{-1}(\pi)$

"Complementary" log-log  $g(\pi) = \log(-\log(1 - \pi))$

Alle sind Inverse bekannter Verteilungsfunktionen.

$V(\mu)$  für obige Beispiele

$$V(\mu) = \frac{\partial^2 b(\theta(\mu))}{\partial \theta \partial \theta'}$$

**Normalverteilung:**  $b(\theta) = \frac{\theta^2}{2}$

$$\begin{aligned} V(\mu) &= I \\ \Rightarrow VAR_{\theta}[Y] &= \frac{\varphi}{w_i} V(\mu) = \sigma^2 I \end{aligned}$$

**Poissonverteilung:**  $b(\theta_i) = e^{\theta_i}$

$$\begin{aligned} V(\lambda) &= \frac{\partial^2 (e^{\theta_1}, \dots, e^{\theta_n})}{\partial \theta \partial \theta'} \\ &= \text{diag}(e^{\theta_i}) \\ &= \text{diag}(\lambda_i) \\ \Rightarrow VAR_{\theta}[Y] &= \frac{\varphi}{w_i} V(\lambda) = \text{diag}(\lambda_i) \end{aligned}$$

**Binomialverteilung:**  $b(\theta_i) = \ln(1 + e^{\theta_i})$

$$\begin{aligned} V(p) &= \frac{\partial \left( \frac{1}{1+e^{\theta_1}}, \dots, \frac{1}{1+e^{\theta_n}} \right)}{\partial \theta'} \\ &= \text{diag}(e^{-\theta_i} (1 + e^{-\theta_i})^{-2}) \\ &= \text{diag}\left(\frac{1 - \pi_i}{\pi_i} \cdot \left(\frac{1}{\pi_i}\right)^{-2}\right) \\ &= \text{diag}(\pi_i(1 - \pi_i)) \\ \Rightarrow VAR_{\theta}[Y] &= \frac{\varphi}{w_i} V(\pi) = \text{diag}\left(\frac{\pi_i(1 - \pi_i)}{n_i}\right) \end{aligned}$$

## Weitere Verteilungen in der Exponential-Familie

### Gamma Verteilung

$$f(y; \mu, \nu) = \frac{1}{\Gamma(\nu)} \left(\frac{\nu}{\mu}\right)^\nu y^{\nu-1} e^{-\frac{\nu y}{\mu}}$$

$$y, \mu, \nu > 0$$

### Invers Gauß Verteilung

$$f(y; \mu, \alpha) = \sqrt{\frac{\alpha}{2\pi y^3}} e^{-\frac{\alpha(y-\mu)^2}{2\mu^2 y}}$$

$$y, \mu, \alpha > 0$$

Diese Verteilung modelliert die erste Übertrittszeit einer bestimmten Schwelle in einer Brownschen Bewegung (Zufallsprozess) oder die asymptotische Anzahl von Versuchen in einer sequenziellen Studie.

### Form der Verteilungen

Sowohl stetige Verteilungen (Normal, Gamma,...) als auch diskrete Verteilungen (Binomial, Poisson) sind Mitglieder der Exponential-Familie.

## Kanonische Link-Funktionen

Für jede Verteilung gibt es eine besondere Linkfunktion, die kanonische Linkfunktion, wo  $\theta = \eta = X\beta$ . In diesem Fall gibt es suffiziente Statistiken  $X'y$ , wie aus der Maximum Likelihood Gleichungen zu sehen ist:

$$\ell(\theta, \varphi; Y) = \sum_{i=1}^n \left\{ \frac{w_i}{\varphi} (y_i \theta_i - b(\theta_i)) + c(y_i, \frac{\varphi}{w_i}) \right\}$$

Mit  $w_i = w$  und  $\frac{\partial \ell(\theta, \varphi; Y)}{\partial \beta} = 0$  gilt:

$$X'y = X'\hat{\mu}$$

Verteilung	Kanonischer Link	
Normal	Identität	$\eta_i = \mu_i$
Binomial	Logit	$\eta_i = \log \left[ \frac{\pi_i}{1-\pi_i} \right] = \log \left[ \frac{\mu_i}{n_i - \mu_i} \right]$
Poisson	Log	$\eta_i = \log(\mu_i)$
Gamma	Invers	$\eta_i = \frac{1}{\mu_i}$
Invers Gauß	Invers <sup>2</sup>	$\eta_i = \frac{1}{\mu_i^2}$

## Schätzung im GLM ML-Ansatz:

Log-Likelihood eines GLM:

$$\ell(\theta, \varphi; Y) = \sum_{i=1}^n \left\{ \frac{w_i}{\varphi} (y_i \theta_i - b(\theta_i)) + c(y_i, \frac{\varphi}{w_i}) \right\}$$

Wir setzen  $a_i(\varphi) = \frac{\varphi}{w_i}$ ,  $i = 1, \dots, n$ .

Für ML-Schätzer für  $\beta$  setzen wir die Ableitung der Log-likelihood nach gesuchten Parametern gleich 0, also

$$\frac{\partial \ell(\theta, \varphi; Y)}{\partial \beta} = 0$$

Mit den gegebenen Parametrisierungen gilt:

$$\frac{\partial \ell(\theta, \varphi; Y)}{\partial \beta} = \frac{\partial \ell(\theta, \varphi; Y)}{\partial \theta} \frac{\partial \theta}{\partial \mu} \frac{\partial \mu}{\partial \eta} \frac{\partial \eta}{\partial \beta}$$

Es gilt

$$\frac{\partial \eta}{\partial \beta} = X,$$

und die Ableitung

$$\frac{\partial \mu}{\partial \eta}$$

hängt von der Link-Funktion ab.

$$E_{\theta}[Y] = \mu(\theta) = \frac{\partial b(\theta)}{\partial \theta}$$

$$\frac{\partial^2 b(\theta)}{\partial \theta \partial \theta'} = \text{diag}\left(\frac{1}{a_i(\varphi)}\right) \cdot \text{VAR}[Y]$$

Des weiteren gilt

$$\frac{\partial \mu}{\partial \theta} = \frac{\partial^2 b(\theta)}{\partial \theta \partial \theta'} = V(\mu)$$

Somit erhalten wir mit  $v_i = (V(\mu))_{ii}$

$$\begin{aligned} \frac{\partial \ell(\theta_i, \varphi; Y)}{\partial \beta_j} &= \frac{w_i(y_i - \mu_i)}{\varphi} \frac{\partial \theta_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \eta_i} x_{ij} \\ &= \frac{w_i(y_i - \mu_i)}{v_i \varphi} \frac{\partial \mu_i}{\partial \eta_i} x_{ij} \end{aligned}$$

Setzen wir nun

$$\begin{aligned} W &= \text{diag}\left(v_i \left(\frac{\partial \eta_i}{\partial \mu_i}\right)^2 \frac{\varphi}{w_i}\right) \\ &= \text{diag}(W_i) \end{aligned}$$

und

$$z_i = \eta_i + (y_i - \mu_i) \frac{\partial \eta_i}{\partial \mu_i}$$

erhalten wir die Normalgleichungen eines gewichteten KQ-Problems

$$E[z] = \eta, \quad \text{VAR}[z] = W,$$

also

$$X'W^{-1}X\beta = X'W^{-1}z$$

jedoch mit iterativen Gewichten  $W_i^{-1}$ .

Lösung dieser Normalgleichungen liefert

$$\hat{\beta} = (X'W^{-1}X)^{-1} X'W^{-1}z.$$

Die Schätzer für  $\eta$  und  $\mu$  erhält man dann durch

$$\hat{\eta} = X\hat{\beta}, \quad \hat{\mu} = g^{-1}(X\hat{\beta}).$$