

# Uogolnione modele liniowe

Jerzy Mycielski

Uniwersytet Warszawski

grudzien 2013

- Zakładamy, że

$$g [E (y_i | \mathbf{x}_i)] = \mathbf{x}_i \boldsymbol{\beta}$$

- Inaczej mówiąc:

$$E (y_i | \mathbf{x}_i) = g^{-1} (\mathbf{x}_i \boldsymbol{\beta})$$

- Funkcję  $g (\cdot)$  nazywamy funkcją związku (link function)
- O zmiennej  $y_i$  zakładamy, że należy do rodziny dystrybuant wykładniczych (exponential family)

- Dystrybuanta należy do rodziny dystrybuant wykładniczych jeśli jej funkcję gęstości (prawdopodobieństwa) można przedstawić w następujący sposób:

$$f_{\theta}(y) = h(y) \exp(\boldsymbol{\eta}(\boldsymbol{\theta}) \mathbf{T}(y) - A(\boldsymbol{\theta}))$$

- Jeśli dystrybuanta jest sparametryzowana w ten sposób, że  $\boldsymbol{\eta}(\boldsymbol{\theta}) = \boldsymbol{\theta}$  to mówimy, że dystrybuanta ma formę kanoniczną a parametr  $\boldsymbol{\eta}$  nazywamy naturalnym (kanonicznym) parametrem rozkładu
- $\mathbf{T}(y)$  jest statystyką dostateczną,  $A(\boldsymbol{\theta})$  jest parametrem logpodziału (log partition parameter)
- Funkcja zwązku jest kanoniczna jeśli  $\boldsymbol{\eta}(\boldsymbol{\mu}) = \boldsymbol{g}(\boldsymbol{\mu})$  a więc jest tożsama z funkcją, która przekształca parametr związany z wartością oczekiwaną na parametr kanoniczny rozkładu

- Statystyka dostateczna jest to funkcja próby  $\mathbf{y} = [y_1, \dots, y_n]$ , że jeśli  $\mathbf{T}(\mathbf{y}_A) = \mathbf{T}(\mathbf{y}_B)$

$$\frac{f_{\theta}(\mathbf{y}_A)}{f_{\theta}(\mathbf{y}_B)} = 1 \text{ dla każdego } \theta \in \Theta$$

- Łatwo zauważyć, że dla dystrybuant z rodziny rozkładów wykładniczych  $\mathbf{T}(\mathbf{y}) = \sum_{i=1}^n \mathbf{T}(y_i)$
- Statystyka dostateczna zawiera w sobie całą istotną informację zawartą w próbie na temat nieznanego parametru  $\theta$ 
  - w związku z tym estymator efektywny jest zawsze funkcją statystyki dostatecznej

- Elementami są między innymi dystrybucje:
  - dwumianowy
  - Poissona
  - ujemny dwumianowy
  - normalny
  - odwrotny gausowski
  - gamma.

# Rodzina dystrybuant wykładniczych

## Przykład

- rozkład Bernoulliego:  $T(y) = y$ ,  $h(y) = 1$ ,  $\eta(p) = \ln \frac{p}{1-p}$ ,  
 $A(\eta) = \ln(1 + \exp \eta)$

$$\Pr(y) = p^y (1-p)^{1-y} = \exp[\eta y - \ln(1 + \exp \eta)]$$

- Rzeczywiście:

$$\begin{aligned} \exp[\eta y + \ln(1 + \exp \eta)] &= \exp(\eta y) \exp[-\ln(1 + \exp \eta)] \\ &= \left(\frac{p}{1-p}\right)^y \left(\frac{1}{1 + \frac{p}{1-p}}\right) = \exp(\eta y) \left(\frac{1}{1 + \exp \eta}\right) \\ &= \left(\frac{p}{1-p}\right)^y (1-p) = p^y (1-p)^{1-y} \end{aligned}$$

- Uogólnieniem rodziny dystrybuant wykładniczych jest rodzina dystrybuant wykładniczych z nadmierną dyspersją (overdispersed exponential family)

$$f_{\theta, \tau}(y) = h(y) \exp\left(\frac{\eta(\theta) \mathbf{T}(y) - A(\theta)}{d(\tau)}\right)$$

- Funkcje związku determinują relację między wartością oczekiwaną zmiennej zależnej  $y_i$  a wielkościami zmiennych niezależnych
- W zależności od typu funkcji związku różnić się będzie interpretacja parametrów
- Popularne postaci funkcji związku
  - identity:  $g(\mu) = \mu$
  - log:  $g(\mu) = \ln(\mu)$
  - logit:  $g(\mu) = \ln\left(\frac{\mu}{1-\mu}\right)$
  - probit:  $g(\mu) = \Phi^{-1}(\mu)$
  - cloglog:  $g(\mu) = \ln[-\ln(1-\mu)]$
  - opower:  $g(\mu) = \left[\left(\frac{\mu}{1-\mu}\right)^n - 1\right] / n$
  - power:  $g(\mu) = \mu^n$
  - nbinominal:  $g(\mu) = \ln\left(\frac{\mu}{\mu+k}\right)$
  - loglog:  $g(\mu) = -\ln(-\ln \mu)$
  - logc:  $g(\mu) = \ln(1-\mu)$



- Modele z zerojedynkową zmienną zależną
  - rozkład zmiennej zależnej  $y$ : Bernoulliego

$$y_i = \begin{cases} 1 & \text{z p-stwem } p \\ 0 & \text{z p-stwem } 1 - p \end{cases}$$

- Wartość oczekiwana  $w$  z rozkładzie dwumianowym  $E(y_i) = p$

# Uogólniony model liniowy

Przykłady c.d.

- Model logitowy
  - funkcja związku: logit

$$E(y_i | \mathbf{x}_i) = \mu_i = \frac{\exp(\mathbf{x}_i \boldsymbol{\beta})}{1 + \exp(\mathbf{x}_i \boldsymbol{\beta})}$$

$$g[E(y_i | \mathbf{x}_i)] = \ln\left(\frac{\mu_i}{1 - \mu_i}\right) = \mathbf{x}_i \boldsymbol{\beta}$$

- • zauważmy, że w tym przypadku funkcja związku jest kanoniczna
- Model probitowy
  - funkcja związku: probit

$$E(y_i | \mathbf{x}_i) = \mu_i = \Phi(\mathbf{x}_i \boldsymbol{\beta})$$

$$g[E(y_i | \mathbf{x}_i)] = \Phi^{-1}(\mu_i) = \mathbf{x}_i \boldsymbol{\beta}$$

# Uogólniony model liniowy

Dystrybuanty i funkcje związku

	gauss.	igauss.	binominal	Poisson	nbinomina	gamma
id	x	x	x	x	x	x
log	x	x	x	x	x	x
logit			x			
probit			x			
clog			x			
pow			x			
opower			x			
nbinominal					x	
loglog			x			
logc			x			

# Uogólniony model liniowy

## Estymacja

- Najbardziej popularna jest MNW
- Inną możliwością jest zastosowanie ważonej nieliniowej metody najmniejszych kwadratów (WNMNK)
- Estymujemy nieliniwe równanie regresji

$$y_i = g^{-1}(\mathbf{x}_i\boldsymbol{\beta}) + \varepsilon_i$$

- W przypadku zmiennych losowych o dystrybucanie z rodziny rozkładów wykładniczych, wariancja jest z reguły funkcją wartości oczekiwanej  $\text{Var}(y_i | \mathbf{x}_i) = w_i = w(\boldsymbol{\mu}_i)$ 
  - np. w przypadku rozkładu Bernoulliego  
 $w(\boldsymbol{\mu}_i) = \text{Var}(y_i | \mathbf{x}_i) = \text{Var}(\varepsilon_i | \mathbf{x}_i) = \boldsymbol{\mu}_i(1 - \boldsymbol{\mu}_i)$
- Estymatorem efektywnym w takim przypadku jest WNMNK

- Funkcja kryterium:

$$\min_{\beta} \sum_{i=1}^n w_i^{-1} [y_i - g^{-1}(\mathbf{x}_i \beta)]^2$$

gdzie  $w_i$  jest proporcjonalne do wielkości wariancji.

- Ponieważ wariancja  $w_i = w(\mu_i) = w(g^{-1}(\mathbf{x}_i \beta))$  jest funkcją nieznanymi parametrów więc stosujemy wersję iterowaną WNMNK.
- 1 Uzyskujemy wstępne oszacowania  $\hat{\beta}_{(0)}$  dla wag  $w_i = 1$
  - 2 Znajdujemy oszacowania wariancji  $\hat{w}_{i,(k)} = w(g^{-1}(\mathbf{x}_i \hat{\beta}_{(k-1)}))$
  - 3 Szacujemy model przy użyciu wag  $\hat{w}_{i,(k)}$ , uzyskujemy oszacowania  $\hat{\beta}_{(k)}$
  - 4 Jeśli kryterium zbieżności nie jest spełnione przechodzimy do kroku 2.

# Uogólniony model liniowy

## Estymacja na próbach panelowych

- Zakładamy, że

$$E(y_{it} | \mathbf{x}_{it}, c_i) = g^{-1}(\mathbf{x}_{it} \boldsymbol{\beta} + c_i)$$

oraz, że  $\mathbf{x}_i$  i  $c_i$  są niezależne

- W przypadku estymowania modelu GLM z efektami losowymi na próbie panelowej można zastosować MNW
  - w tym przypadku do obliczania funkcji wiarygodności musimy zastosować kwadratury, ponieważ funkcja wiarygodności ma postać

$$f(\mathbf{y}_i | \mathbf{x}_i) = \int_{-\infty}^{\infty} \prod_{t=1}^T f(\mathbf{x}_{it} \boldsymbol{\beta} + c_i | c_i) f(c_i) dc_i$$

$$\ell(\boldsymbol{\beta}) = \sum_{i=1}^N \ln f(\mathbf{y}_i | \mathbf{x}_i)$$

- metoda ta może okazać się w praktyce bardzo czasochłonna
- Alternatywą jest zastosowanie Ogólnych Równań Estymacyjnych (GEE)

# Uogólniony model liniowy

GEE (general estimating equations)

- Specyfikujemy model dla warunkowej średniej oczekiwanej uśrednionej po wielkościach efektów indywidualnych

$$E(y_{it} | \mathbf{x}_{it}) = E_{c_i} [E(y_{it} | \mathbf{x}_{it}, c_i)] = \mathbf{g}_*^{-1}(\mathbf{x}_{it}\boldsymbol{\beta}) = \boldsymbol{\mu}_{it}$$

- Model taki określamy jako model uśredniony po populacji (PPA - population averaged model)
- Minimalizowana funkcja kryterium

$$\min_{\boldsymbol{\beta}, \boldsymbol{\alpha}} \sum_{i=1}^N [\mathbf{y}_i - \boldsymbol{\mu}_i(\boldsymbol{\beta})]' [\mathbf{W}(\boldsymbol{\alpha}, \boldsymbol{\beta})]^{-1} [\mathbf{y}_i - \boldsymbol{\mu}_i(\boldsymbol{\beta})]$$

- Nawet w przypadku błędnego wyspecyfikowania modelu dla wariancji  $\mathbf{W}(\boldsymbol{\alpha})$  estymator ten jest estymatorem zgodnym
- Estymator macierzy wariancji oszacowań  $\text{Var}(\hat{\boldsymbol{\beta}})$  można zbudować tak, by był zgodny w przypadku błędnej specyfikacji  $\mathbf{W}(\boldsymbol{\alpha})$  (wersja estymatora odpornego Hubera/White'a)

# Uogólniony model liniowy

## Różnice między MNW i GEE

- Poza szczególnym przypadkiem identycznościowej funkcji związku funkcja związku stosowane w GEE nie jest tożsama z funkcją związku w MNW (tw. Jensena):

$$g_*^{-1}(\mathbf{x}_{it}\boldsymbol{\beta}) = E_{c_i} [g^{-1}(\mathbf{x}_{it}\boldsymbol{\beta} + c_i)] \neq g^{-1}[\mathbf{x}_{it}\boldsymbol{\beta} + E_{c_i}(c_i)] = g^{-1}(\mathbf{x}_{it}\boldsymbol{\beta})$$

- W szczególności za pomocą modelu wyestymowany GEE można uzyskać jedynie efekt cząstkowy uśredniony po cechach populacji (Averaged Partial Effect - APE)

$$APE = E_c \left[ \frac{\partial E(y|\mathbf{x}, c)}{\partial \mathbf{x}} \right] = \frac{\partial g_*^{-1}(\mathbf{x}\boldsymbol{\beta})}{\partial \mathbf{x}}$$

- szacując *APE* zastępujemy  $\boldsymbol{\beta}$  oszacowaniem  $\hat{\boldsymbol{\beta}}_{GEE}$



# Uogólniony model liniowy

Różnice między MNW i GEE c.d.

- W przypadku modelu estymowane MNW możliwe jest oszacowanie efektu cząstkowego dla danej jednostki  $i$

$$\frac{\partial E(y|\mathbf{x}, c)}{\partial \mathbf{x}} = \frac{g^{-1}(\mathbf{x}\boldsymbol{\beta} + c_i)}{\partial \mathbf{x}}$$

- Szacując efekt cząstkowy dla jednostki  $i$ , zastępujemy parametr  $\boldsymbol{\beta}$  oszacowaniem  $\hat{\boldsymbol{\beta}}_{ML}$  a  $c_i$  oszacowaniem  $\hat{c}_i$ .
- Oszacowanie  $c_i$  bazuje na rozkładzie a posteriori  $c_i$ :

$$f(c_i | \mathbf{x}_i, \mathbf{y}_i) = \frac{f(\mathbf{y}_i | \mathbf{x}_i, c_i) f(c_i)}{f(\mathbf{y}_i | \mathbf{x}_i)}$$

- Wartość oczekiwana  $c_i$  z rozkładu a posteriori

$$E(c_i | \mathbf{x}, \mathbf{y}_i) = \frac{1}{f(\mathbf{y}_i | \mathbf{x}_i)} \int c_i f(\mathbf{y}_i | \mathbf{x}_i, c) f(c_i) dc_i$$

- Oszacowanie  $c_i$  znajdujemy zastępując nieznanne parametry rozkładów ich oszacowaniami i apoksymując całki kwadraturami.