

# Odporna estymacja w wielowymiarowym rozkładzie normalnym

Agnieszka Kulawik

Doktorantka

Wydział Matematyki, Informatyki i Ekonometrii  
Uniwersytet Zielonogórski

7 grudnia 2009 r.

## 1. Informacje ogólne

Założmy, że  $J \in \mathbb{N}$ . Zdefiniujmy następujące zbiory:

$$\mathcal{G} := \{F: \mathbb{R}^J \rightarrow \mathbb{R} \mid F \text{ jest dystrybuantą}\},$$

$$\mathcal{D} := \text{lin}\{F - G \mid F, G \in \mathcal{G}\}.$$

## 1. Informacje ogólne

Założmy, że  $J \in \mathbb{N}$ . Zdefiniujmy następujące zbiory:

$$\mathcal{G} := \{F: \mathbb{R}^J \rightarrow \mathbb{R} \mid F \text{ jest dystrybuantą}\},$$

$$\mathcal{D} := \text{lin}\{F - G \mid F, G \in \mathcal{G}\}.$$

Zbiór  $\mathcal{G}$  będziemy rozpatrywać z metryką supremum:

$$\|F - G\| = \sup_{x \in \mathbb{R}^J} |F(x) - G(x)|, \quad F, G \in \mathcal{G}.$$

## 1. Informacje ogólne

Założmy, że  $J \in \mathbb{N}$ . Zdefiniujmy następujące zbiory:

$$\mathcal{G} := \{F: \mathbb{R}^J \rightarrow \mathbb{R} \mid F \text{ jest dystrybuantą}\},$$

$$\mathcal{D} := \text{lin}\{F - G \mid F, G \in \mathcal{G}\}.$$

Zbiór  $\mathcal{G}$  będziemy rozpatrywać z metryką supremum:

$$\|F - G\| = \sup_{x \in \mathbb{R}^J} |F(x) - G(x)|, \quad F, G \in \mathcal{G}.$$

Niech  $m \in \mathbb{N}$ , a  $\Theta \subset \mathbb{R}^m$  jest przestrzenią parametrów. Interesować nas będzie model statystyczny postaci

$$\{F_\theta : \theta \in \Theta\} \subset \mathcal{G}.$$

## Definicja

*Funkcję  $T: \mathcal{G} \rightarrow \Theta$  nazywamy funkcjonałem statystycznym.*

## Definicja

*Funkcję  $T: \mathcal{G} \rightarrow \Theta$  nazywamy funkcjonałem statystycznym.*

## Definicja

*Funkcjonał statystyczny  $T$  nazywamy zgodnym w sensie Fishera, gdy*

$$T(F_\theta) = \theta, \theta \in \Theta.$$

## Definicja

*Funkcję  $T: \mathcal{G} \rightarrow \Theta$  nazywamy funkcjonałem statystycznym.*

## Definicja

*Funkcjonał statystyczny  $T$  nazywamy zgodnym w sensie Fishera, gdy*

$$T(F_\theta) = \theta, \theta \in \Theta.$$

## Definicja

*Funkcjonał statystyczny  $T$  nazywamy różniczkowalnym w sensie Fréchet w punkcie  $F \in \mathcal{G}$ , gdy istnieje taki funkcjonał liniowy  $T': \mathcal{D} \rightarrow \mathbb{R}^m$ , że*

$$|T(G) - T(F) - T'(G - F)| = o(\|F - G\|),$$

*gdzie  $|\cdot|$  jest metryką euklidesową w  $\mathbb{R}^m$ .*

## 2. Wielowymiarowy rozkład normalny

Rozpatrujemy  $J$ -wymiarowy rozkład normalny

$$N(X\beta, \Sigma),$$

gdzie

- $X \in \mathbb{R}_a^J$  jest znaną macierzą o  $a$  niezależnych kolumnach;



## 2. Wielowymiarowy rozkład normalny

Rozpatrujemy  $J$ -wymiarowy rozkład normalny

$$N(X\beta, \Sigma),$$

gdzie

- $X \in \mathbb{R}_a^J$  jest znaną macierzą o  $a$  niezależnych kolumnach;
- $\Sigma = \sum_{i=1}^k \sigma_i^2 V_i$ , gdzie  $V_1, \dots, V_k \in \mathbb{R}_J^J$  są znanymi symetrycznymi, nieujemnie określonymi i liniowo niezależnymi macierzami;

## 2. Wielowymiarowy rozkład normalny

Rozpatrujemy  $J$ -wymiarowy rozkład normalny

$$N(X\beta, \Sigma),$$

gdzie

- $X \in \mathbb{R}_a^J$  jest znaną macierzą o  $a$  niezależnych kolumnach;
- $\Sigma = \sum_{i=1}^k \sigma_i^2 V_i$ , gdzie  $V_1, \dots, V_k \in \mathbb{R}_J^J$  są znanymi symetrycznymi, nieujemnie określonymi i liniowo niezależnymi macierzami;
- $\beta = (\beta_1, \dots, \beta_a)^T \in \mathbb{R}^a$ , przy czym  $\theta = (\beta_1, \dots, \beta_a, \sigma_1, \dots, \sigma_k)^T \in \Theta \subset \mathbb{R}^m$ , gdzie  $m = a + k$ , jest wektorem nieznanych parametrów.

Gęstością rozpatrywanego rozkładu  $N(X\beta, \Sigma)$  jest

$$f(y|\theta) = (2\pi)^{-\frac{J}{2}} |\Sigma|^{-\frac{1}{2}} \exp\left[-\frac{1}{2}(y - X\beta)^T \Sigma^{-1}(y - X\beta)\right], \quad y \in \mathbb{R}^J,$$

Gęstością rozpatrywanego rozkładu  $N(X\beta, \Sigma)$  jest

$$f(y|\theta) = (2\pi)^{-\frac{J}{2}} |\Sigma|^{-\frac{1}{2}} \exp\left[-\frac{1}{2}(y - X\beta)^T \Sigma^{-1}(y - X\beta)\right], \quad y \in \mathbb{R}^J,$$

która po zlogarytmowaniu i pewnym uproszczeniu przyjmie postać

$$L(y|\theta) = \ln |\Sigma|^{\frac{1}{2}} + \frac{1}{2}(y - X\beta)^T \Sigma^{-1}(y - X\beta), \quad y \in \mathbb{R}^J.$$

Gęstością rozpatrywanego rozkładu  $N(X\beta, \Sigma)$  jest

$$f(y|\theta) = (2\pi)^{-\frac{J}{2}} |\Sigma|^{-\frac{1}{2}} \exp\left[-\frac{1}{2}(y - X\beta)^T \Sigma^{-1}(y - X\beta)\right], \quad y \in \mathbb{R}^J,$$

która po zlogarytmowaniu i pewnym uproszczeniu przyjmie postać

$$L(y|\theta) = \ln |\Sigma|^{\frac{1}{2}} + \frac{1}{2}(y - X\beta)^T \Sigma^{-1}(y - X\beta), \quad y \in \mathbb{R}^J.$$

W celu otrzymania estymatora odpornego parametru  $\theta$ , uogólniamy drugi składnik powyższej sumy i otrzymujemy:

$$\Phi(y|\theta) = \ln |\Sigma|^{\frac{1}{2}} + \varphi\left[\frac{1}{c^2}(y - X\beta)^T \Sigma^{-1}(y - X\beta)\right], \quad y \in \mathbb{R}^J,$$

gdzie  $c > 0$  jest stałą odpowiednio dobraną do funkcji  $\varphi: \mathbb{R}_{\geq} \rightarrow \mathbb{R}$ .

## Funkcjonał statystyczny

Definiujemy funkcjonal statystyczny  $T: \mathcal{G} \rightarrow \Theta$  wzorem

$$T(G) = \operatorname{argmin}_{\theta \in \Theta} \int \Phi(y|\theta) dG(y) \quad \text{dla } G \in \mathcal{G},$$

gdzie

$$\Phi(y|\theta) = \ln |\Sigma|^{\frac{1}{2}} + \varphi\left[\frac{1}{c^2}(y - X\beta)^T \Sigma^{-1}(y - X\beta)\right], \quad y \in \mathbb{R}^J.$$

## Funkcjonał statystyczny

Definiujemy funkcjonal statystyczny  $T: \mathcal{G} \rightarrow \Theta$  wzorem

$$T(G) = \operatorname{argmin}_{\theta \in \Theta} \int \Phi(y|\theta) dG(y) \quad \text{dla } G \in \mathcal{G},$$

gdzie

$$\Phi(y|\theta) = \ln |\Sigma|^{\frac{1}{2}} + \varphi\left[\frac{1}{c^2}(y - X\beta)^T \Sigma^{-1}(y - X\beta)\right], \quad y \in \mathbb{R}^J.$$

- (B1) Funkcja  $\varphi$  ma nieujemną pochodną na  $[0, +\infty)$ .
- (B2) Funkcja  $x\varphi'(x^2)$  ma nieujemną pochodną na  $[0, +\infty)$  oraz istnieje takie  $x_0 > 0$ , że  $2x_0^2\varphi'(x_0^2) > J$ .
- (B3) Funkcje  $\varphi'$  i  $\varphi''$  są ograniczone.
- (B4) Funkcje  $x\varphi'(x^2)$  i  $x^2\varphi''(x^2)$  są ograniczone.

Twierdzenie (Dobór stałej  $c$ )

Jeżeli funkcja  $\varphi: \mathbb{R}_{\geq} \rightarrow \mathbb{R}$  spełnia warunki (B1) i (B2) oraz  $(Y_1, \dots, Y_J)^T$  ma  $J$ -wymiarowy rozkład normalny  $N(0_J, \mathbb{I}_J)$ , to istnieje takie jednoznacznie wyznaczone  $c_\varphi > 0$ , w którym funkcja

$$c \mapsto J \ln(c) + \mathbb{E} \varphi \left( \sum_{j=1}^J \frac{Y_j^2}{c^2} \right), \quad c > 0,$$

osiąga minimum globalne.



## Twierdzenie (Zgodność w sensie Fishera)

Jeżeli funkcja  $\varphi: \mathbb{R}_{\geq} \rightarrow \mathbb{R}$  spełnia warunki (B1) i (B2) oraz  $c = c_{\varphi}$ , to funkcja

$$\theta \mapsto \int \Phi(y|\theta) dF_{\theta_0}(y), \quad \theta \in \Theta,$$

osiąga minimum globalne w punkcie  $\theta = \theta_0$ .

## Twierdzenie (Zgodność w sensie Fishera)

Jeżeli funkcja  $\varphi: \mathbb{R}_{\geq} \rightarrow \mathbb{R}$  spełnia warunki (B1) i (B2) oraz  $c = c_{\varphi}$ , to funkcja

$$\theta \mapsto \int \Phi(y|\theta) dF_{\theta_0}(y), \quad \theta \in \Theta,$$

osiąga minimum globalne w punkcie  $\theta = \theta_0$ .

## Twierdzenie (Różniczkowalność w sensie Fréchet)

Jeżeli funkcja  $\varphi: \mathbb{R}_{\geq} \rightarrow \mathbb{R}$  spełnia warunki (B1)-(B4) oraz  $c = c_{\varphi}$ , to

$$T(G) - T(F_{\theta}) = -M(\theta)^{-1} \int \psi(y|\theta) dG(y) + o(\|G - F_{\theta}\|),$$

gdzie  $\psi(\cdot|\theta) = \frac{\partial \Phi(\cdot|\theta)}{\partial \theta}$ , a  $M(\theta) = \int \left\{ \frac{\partial \psi(y|\theta)}{\partial \theta} \right\} dF_{\theta}(y)$ .

### 3. Wnioski

Jeżeli funkcja  $\varphi: \mathbb{R}_{\geq} \rightarrow \mathbb{R}$  spełnia warunki (B1)-(B4) oraz  $c = c_{\varphi}$ , to funkcjonal statystyczny

$$T(G) = \operatorname{argmin}_{\theta \in \Theta} \int \Phi(y|\theta) dG(y) \quad \text{dla } G \in \mathcal{G},$$

gdzie

$$\Phi(y|\theta) = \ln |\Sigma|^{\frac{1}{2}} + \varphi\left[\frac{1}{c^2}(y - X\beta)^T \Sigma^{-1}(y - X\beta)\right], \quad y \in \mathbb{R}^J,$$

jest zgodny w sensie Fishera i różniczkowalny w sensie Fréchet w  $F_{\theta}$ ,  $\theta \in \Theta$ .

#### Estymator odporny parametru $\theta \in \Theta$

Dla  $n \in \mathbb{N}$  estymator parametru  $\theta \in \Theta$  definiujemy następująco:

$$\hat{\theta}_n := T(\hat{F}_n),$$

gdzie  $\hat{F}_n$  jest dystrybuantą empiryczną.




Dla tak zdefiniowanego estymatora mamy

$$\sqrt{n}(\hat{\theta}_n - \theta) = -M(\theta)^{-1} \sqrt{n} \int \Psi(y|\theta) d\hat{F}_n(y) + \sqrt{n} \|\hat{F}_n - F_\theta\| \frac{o(\|\hat{F}_n - F_\theta\|)}{\|\hat{F}_n - F_\theta\|},$$

a więc jego rozkład można przybliżyć rozkładem normalnym z wartością oczekiwaną  $\theta$  i macierzą kowariancji postaci

$$\frac{1}{n} M(\theta)^{-1} \left\{ \int \Psi(y|\theta) \Psi(y|\theta)^T dF_\theta(y) \right\} [M(\theta)^{-1}]^T.$$

## 4. Literatura

-  Bednarski, T., Zontek, S., *Robust estimation of parameters in a mixed unbalanced model*, The Annals of Statistics 24 (4), pp.1493-1510, 1996.
-  Clarke, B.R., *Uniqueness and Fréchet differentiability of functional solutions to maximum likelihood type equations*, The Annals of Statistics 11 (4), pp.1196-1205, 1983.
-  Zmyślony, R., Zontek, S., *Robust M-estimator of parameters in variance components model*, Discussiones Mathematicae Probability and Statistics 22, pp.61-71, 2002.