

UNIwersytet Warszawski Wydział  
Matematyki, Mechaniki i Informatyki

**KONRAD FURMAŃCZYK**

ASYMPTOTYCZNE  
WŁASNOŚCI  
M-ESTYMATORÓW DLA  
DANYCH ZALEŻNYCH

AUTOREFERAT ROZPRAWY  
DOKTORSKIEJ

## *PLAN REFERATU*

- Definicja M-estymatora
- Modele zależności
- Główne wyniki
- Metody dowodów
- Pomocnicze twierdzenia probabilistyczne

# M-ESTYMATORY

Rozważmy ściśle stacjonarny ciąg zmiennych losowych  $X_1, X_2, \dots, X_n$  o wartościach w  $\mathbb{R}^m$ .

Realizacje tego ciągu będziemy nazywali obserwacjami. Rozkład brzegowy  $X_1$ , zależny od parametru  $\theta$ , oznaczmy przez  $\mathbb{P}_\theta$ , gdzie  $\theta \in \Theta \subset \mathbb{R}^k$ . Zakładamy, że z rodziną rozkładów  $\{\mathbb{P}_\theta\}$  możemy związać pewne mierzalne odwzorowanie  $\psi : \Theta \times \mathbb{R}^m \rightarrow \mathbb{R}^k$  tak, że dla każdego  $\theta \in \Theta$

$$\mathbb{E}_\theta \psi(\theta, X_1) = \int \psi(\theta, x) d\mathbb{P}_\theta(x) = 0.$$

**DEFINICJA**  $M$ -estymatorem parametru  $\theta$  nazywamy każde mierzalne rozwiązanie  $\theta_n$  równania

$$\Psi_n(\theta) := \frac{1}{n} \sum_{i=1}^n \psi(\theta, X_i) = 0.$$


## PRZYKŁADY

- metoda najmniejszych kwadratów, wtedy

$$\psi(\theta, x) = x - \theta, \quad M\text{-estymator } \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i;$$

- metoda największej wiarygodności (dla niezależnych obserwacji), przy pewnych założeniach regularności  $\psi(\theta, x) = \frac{\frac{\partial}{\partial \theta} f_{\theta}(x)}{f_{\theta}(x)}$ , gdzie  $f_{\theta}$  jest gęstością zmiennej losowej  $X_1$ ;

- estymator Hubera (odporność), dla symetrycznych rozkładów prawdopodobieństwa  $\psi(\theta, x) = \varphi(x - \theta)$ ,



# MODELE ZALEŻNOŚCI

Głównym modelem zależności rozważanym w naszej pracy jest proces liniowy

$$(LP) \quad X_j = \sum_{r=0}^{\infty} a_r Z_{j-r},$$

gdzie  $(Z_n)$  jest ciągiem zmiennych losowych i.i.d. oraz  $\mathbf{E}(Z_1) = 0$ ,  $\mathbf{E}(Z_1^2) = 1$ , zaś  $(a_n)$  jest pewnym ciągiem liczbowym takim, że  $\sum_{r=0}^{\infty} a_r^2 < \infty$ . W pracy analizujemy tylko przypadek zależności bliskiego zasięgu (**ZBL**) procesu liniowego, tzn.

$$\sum_{j=0}^{\infty} |Cov(X_1, X_{1+j})| = \sum_{j=0}^{\infty} \left| \sum_{r=0}^{\infty} a_r a_{r+j} \right| < \infty .$$

W pracy rozpatrujemy warunek  $(a_0)$   $\sum_{r=0}^{\infty} |a_r| < \infty$ , który implikuje (**ZBL**). Rozpatrywane w pracy są również pokrewne modele zależności (**ZBL**): wielowymiarowy proces liniowy (**MLP**), obustronny proces liniowy (**LPO**), przekształcony proces gaussowski (**SGauss**).

# GŁÓWNE WYNIKI

Wszystkie dalsze rozważania będą dotyczyły pewnego ustalonego (choć nieznanego)  $\theta_0$ . Oznaczamy  $\mathbb{P} = \mathbb{P}_{\theta_0}$  i  $\mathbb{E} = \mathbb{E}_{\theta_0}$ . Niech

$$\begin{aligned}\Psi(\theta) &= \mathbb{E}\psi(\theta, X_1) & \Psi_n(\theta) &= \frac{1}{n} \sum_{i=1}^n \psi(\theta, X_i), \\ \Psi(\theta_0) &= 0 & \Psi_n(\theta_n) &= 0.\end{aligned}$$

## ISTNIENIE M-ESTYMATORA

Rozważmy następujący warunek

**(D)** istnieje stała  $c > 0$  oraz funkcja  $M(x)$  takie że,

$$|D_j D_i \psi(\theta, x)| \leq M(x)$$

dla wszystkich  $x \in \mathbb{R}$ , wszystkich  $\theta$  takich, że:  $|\theta - \theta_0| < c$  oraz  $\mathbb{E} |M(X_1)| < \infty$ .

## TWIERDZENIE (tw.3.11)

Założenia Ciąg obserwacji  $(X_n)$  jest ergodyczny, istnieje  $(D\Psi(\theta_0))^{-1}$  oraz zachodzi warunek **(D)**.

**Teza** Istnieje ciąg zmiennych losowych  $\theta_n$  taki, że

$$\mathbb{P}(\Psi_n(\theta_n) = 0) \xrightarrow[n \rightarrow \infty]{} 1$$

oraz

$$\mathbb{P}(\theta_n \rightarrow \theta_0) = 1.$$

## REPREZENTACJE ASYMPTOTYCZNE

Podstawowym faktem ułatwiającym analizę  $M$ -estymatorów jest linearyzacja

$$\sqrt{n}(\theta_n - \theta_0) = -\mathbf{V}^{-1} \frac{1}{\sqrt{n}} \sum_{i=1}^n \psi(\theta_0, X_i) + R_n,$$

gdzie  $\mathbf{V} = D\mathbb{E}\psi(\theta_0, X_1)$  lub  $\mathbf{V} = \mathbb{E}D\psi(\theta_0, X_1)$ .

Gdy reszta  $R_n$  jest postaci  $R_n = o_{\mathbb{P}}(1)$ , wtedy mówimy o reprezentacji Ghosha.

Reprezentacja Ghosha umożliwia udowodnienie asymptotycznej normalności (AN)  $M$ -estymatora, gdy

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n \psi(\theta_0, X_i) \rightarrow^d \mathcal{N}_k(0, \Sigma) \text{ przy } n \rightarrow \infty .$$

Wtedy oczywiście

$$\sqrt{n}(\theta_n - \theta_0) \rightarrow^d \mathcal{N}_k(0, \mathbf{V}^{-1} \Sigma (\mathbf{V}^{-1})^T) .$$

Podamy teraz pewien wariant jednego z głównych twierdzeń naszej pracy, tw. 3.48. Rozważmy następujące warunki:

$$\mathbf{(a_0)} \quad \sum_{r=0}^{\infty} |a_r| < \infty ,$$

$\mathbf{(b_1)}$   $Z_1$  ma całkowalną funkcję charakterystyczną  $\varphi_Z$ ,  $\int |u| |\varphi_Z(u)| du < \infty$ ,

$$\mathbf{(b_2(t))} \quad \mathbb{E} |Z_1|^t < \infty \text{ dla pewnego } t \geq 2.$$

$$\mathbf{(C)} \quad \theta_n \xrightarrow{\mathbb{P}} \theta_0,$$



(V) macierz  $V = D \mathbb{E} \psi(\theta_0, X_1)$  istnieje i jest nieosobliwa oraz  $\mathbb{E} |\psi(\theta_0, X_1)|^2 < \infty$

### TWIERDZENIE

Założenia:  $\Theta$  jest zbiorem otwartym wymiaru  $k$ , zachodzą warunki:  $(\mathbf{a}_0)$ ,  $(\mathbf{b}_1)$ ,  $(\mathbf{b}_2(k+1))$ ,  $(\mathbf{C})$ ,  $(\mathbf{V})$ . Zachodzi jeden z warunków:

- $|\psi(\theta_1, x) - \psi(\theta_2, x)| \leq L(x) |\theta_1 - \theta_2|$  dla dowolnych  $\theta_1, \theta_2 \in \Theta$  i dowolnego  $x$  istnieje funkcja  $L \in \mathbb{L}^1(\mathbb{R})$  oraz  $\|L(X_1)\|_{k+1} < \infty$ ,
- istnieje pewna stała  $C$  taka, że
$$\sup_{(\theta, x) \in \Theta \times \mathbb{R}} |D_\theta D_x \psi_i(\theta, x)| < C,$$

gdzie  $\psi = (\psi_1, \psi_2, \dots, \psi_k)$  oraz dodatkowo spełniony jest jeden z warunków:

- funkcja  $\psi(\theta_0, \cdot)$  spełnia warunek Lipschitza,
- funkcja  $\psi(\theta_0, \cdot) \in \mathbb{L}^1(\mathbb{R})$ ,

Teza Zachodzi reprezentacja Ghosha  
( $R_n = o_{\mathbb{P}}(1)$ ) i asymptotyczną normalność  
 $M$ -estymatorów

$$\sqrt{n}(\theta_n - \theta_0) \rightarrow^d \mathcal{N}_k(0, \mathbf{V}^{-1}\boldsymbol{\Sigma}(\mathbf{V}^{-1})^T),$$

gdzie elementy macierzy  $\boldsymbol{\Sigma}$  są postaci

$$\begin{aligned} \sigma_{i,j} = & \mathbb{E}(\psi_i(\theta_0, X_1)\psi_j(\theta_0, X_1)) + \\ & + 2 \sum_{t=1}^{\infty} \mathbb{E}(\psi_i(\theta_0, X_1)\psi_j(\theta_0, X_{1+t})) . \end{aligned}$$

Przy pewnych założeniach na gładkość funkcji  $\psi$  otrzymujemy reprezentację Ghosha z resztą postaci  $R_n = \mathcal{O}_{\mathbb{P}}(n^{-\frac{1}{2}})$  (p. tw. 4.1). Spora część pracy poświęcona jest wyciąganiu wniosków z udowodnionej reprezentacji Ghosha w szczególnych przypadkach problemów  $M$ -estymacji takich jak estymacja parametru położenia (wn. 3.37) i estymacja współczynników regresji w modelach liniowych (tw. 3.56).

Wzmocnieniem reprezentacji Ghosha jest reprezentacja Bahadura, tzn. gdy reszta w linearyzacji estymatora jest postaci  $R_n = \mathcal{O}_{p.n.}(\delta_n)$  dla pewnego ciągu  $\delta_n \rightarrow 0$  przy  $n \rightarrow \infty$ .

Rozważmy następujący warunek:

( $\mathbf{V}_1$ ) macierz  $\mathbf{V} = \mathbb{E}D\psi(\theta_0, X_1)$  istnieje i jest nieosobliwa oraz  $\mathbb{E}|\psi(\theta_0, X_1)|^2 < \infty$ ,

TWIERDZENIE (wersja wn. 4.14)

Założenia Zachodzą warunki:  $(\mathbf{a}_0)$ ,  $(\mathbf{b}_1)$ ,  $(\mathbf{b}_2(Q))$  dla  $Q > 2$ ,  $(\mathbf{D})$ ,  $(\mathbf{V}_1)$  oraz spełniony jest jeden z warunków:

- funkcje  $\psi(\theta_0, \cdot)$  i  $D\psi(\theta_0, \cdot)$  spełniają warunek Lipschitza,
- funkcje  $\psi(\theta_0, \cdot)$ ,  $D\psi(\theta_0, \cdot) \in \mathbb{L}^1(\mathbb{R})$ .

Teza

$$\sqrt{n}(\theta_n - \theta_0) = -\mathbf{V}^{-1} \frac{1}{\sqrt{n}} \sum_{i=1}^n \psi(\theta_0, X_i) + R_n,$$

gdzie  $\mathbf{V} = \mathbb{E}D\psi(\theta_0, X_1)$  oraz dla dowolnego  $\beta > 0$

$$R_n = \mathcal{O}_{p.n.} \left( \frac{(\log n)^{\frac{1}{Q}} (\log \log n)^{\frac{1+\beta}{Q}}}{\sqrt{n}} \right).$$

Ponadto otrzymujemy własność  $(\mathbf{AN})$ .

# METODY DOWODÓW

Metoda Pollarda, odwołuje się do teorii procesów empirycznych. W powyższej metodzie oprócz kilku łatwych do sprawdzenia warunków występuje warunek asymptotycznej jednakowej ciągłości (**ASE**) procesu empirycznego

$$v_n\psi(\theta, \cdot) : = \frac{1}{\sqrt{n}} \sum_{i=1}^n \{\psi(\theta, X_i) - \mathbb{E}\psi(\theta, X_i)\} = \sqrt{n}(\Psi_n(\theta) - \Psi(\theta)).$$

$$(\text{ASE}) \quad \forall \varepsilon > 0 \forall \eta > 0 \exists \delta > 0$$

$$\limsup_{n \rightarrow \infty} \mathbb{P} \left( \sup_{|\theta - \theta_0| < \delta} |v_n\psi(\theta, \cdot) - v_n\psi(\theta_0, \cdot)| > \eta \right) < \varepsilon.$$

Warunek (**ASE**) otrzymamy z poniższego lematu, który jest wnioskiem twierdzenia Ledoux i Talaganda (91), wn. 11.8.

**LEMAT** (lemat 3.8)

**Założenia** Jeśli  $\dim(\Theta) = k$ , proces empiryczny  $v_n\psi(\theta, \cdot)$  posiada ciągłe trajektorie oraz dla pewnego  $Q \geq 1$  spełnione są następujące warunki:

- $\|v_n\psi(\theta_1, \cdot) - v_n\psi(\theta_2, \cdot)\|_Q \leq C |\theta_1 - \theta_2|$  dla dowolnych  $\theta_1, \theta_2 \in \Theta_\delta$  (z pewnego otoczenia  $\theta_0$ ), gdzie  $C$  jest pewną stałą;
- $\int_0^\delta \sqrt[Q]{N(\Theta_\delta, r)} dr < \infty$ , gdzie  $N(\Theta_\delta, r)$  oznacza minimalną liczbę kul o promieniach  $\leq r$  pokrywających zbiór  $\Theta_\delta$ .

**Teza**

$$\mathbb{E} \sup_{|\theta - \theta_0| < \delta} |v_n\psi(\theta, \cdot) - v_n\psi(\theta_0, \cdot)| \leq$$

$$K \int_0^\delta \sqrt[Q]{N(\Theta_\delta, r)} dr \leq K' \int_0^\delta r^{-\frac{k}{Q}} dr.$$

Jak widzimy, żeby otrzymać warunek (ASE) wystarczy kontrolować przyrosty procesu empirycznego w normie  $k + 1$ -szej (dla  $Q = k + 1$ ).

Metoda elementarna polega na rozwinięciu funkcji  $\psi$  w szereg Taylora i prowadzi do silniejszej tezy, ale przy silniejszych założeniach na gładkość funkcji  $\psi$ . W ten sposób otrzymaliśmy reprezentację Bahadura (p. tw. 4.9) i reprezentację Ghosha z resztą postaci  $\mathcal{O}_{\mathbb{P}}(n^{-\frac{1}{2}})$  (p. tw. 4.1).

## Pomocnicze twierdzenia probabilistyczne

### Oszacowania momentów

#### TWIERDZENIE (tw. 6.2)

Założenia:  $(\mathbf{a}_0), (\mathbf{b}_1), (\mathbf{b}_2(Q))$  dla  $Q \geq 2$  oraz  $\mathbb{E} |G(X_1)|^Q < \infty$ . Jeśli spełniony jest jeden z warunków:

- funkcja  $G$  spełnia warunek Lipschitza,
- funkcja  $G$  jest całkowalna.

Teza

$$\mathbb{E} \left| \sum_{j=1}^n (G(X_j) - \mathbb{E}G(X_j)) \right|^Q \leq C_* n^{\frac{Q}{2}},$$

gdzie  $C_* = CC(G)$ . W pierwszym przypadku

$$C(G) = (\text{Lip}(G))^Q, \quad C = C_{Q,Z} \left( \sum_{r=0}^{\infty} |a_r| \right)^Q,$$

oraz w drugim przypadku

$$C(G) = \left( \|G(X_1)\|_Q + \int |G(x)| dx \right)^Q,$$

$C = C_{Q,Z} \left( \sum_{r=0}^{\infty} |a_r| \right)^Q$ , gdzie stała  $C_{Q,Z}$  zależy od rozkładu innowacji  $Z_1$  i  $Q$ .



Pierwszy warunek występujący w Lemacie 3.8 otrzymujemy z Twierdzenia 6.2 podstawiając  $G(x) = \psi(\theta_1, x) - \psi(\theta_2, x)$ .

Centralne twierdzenie graniczne było nam potrzebne do wykazania asymptotycznej normalności  $M$ -estymatorów.

TWIERDZENIE (tw. 7.2)

Założenia:  $(\mathbf{a}_0)$ ,  $(\mathbf{b}_1)$ ,  $(\mathbf{b}_2(2))$ . Jeśli zachodzi jeden z warunków:

- funkcja  $G$  spełnia warunek Lipschitza,
- funkcja  $G$  jest całkowalna

oraz

$$\sigma^2 := \mathbb{E} (G(X_1))^2 + 2 \sum_{j=1}^{\infty} \mathbb{E} (G(X_1)G(X_{1+j})) > 0.$$

Teza

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n (G(X_i) - \mathbb{E}G(X_i)) \rightarrow^d \mathcal{N}(0, \sigma^2).$$

Wykazaliśmy również przy pewnych technicznych założeniach centralne twierdzenie graniczne dla ważonych sum  $\sum_{i=1}^n b_i G(X_i)$  (p. tw. 7.10). Uzupełnieniem powyższych wyników było oszacowanie *p.n.* z góry typu prawo iterowanego logarytmu (p. tw. 8.3) będące bezpośrednim wnioskiem z twierdzenia Moricza (76).

### TWIERDZENIE

Założenia:  $(\mathbf{a}_0)$ ,  $(\mathbf{b}_1)$ ,  $(\mathbf{b}_2(Q))$  dla  $Q > 2$ . Jeśli zachodzi jeden z warunków:

- funkcja  $G$  spełnia warunek Lipschitza,
- funkcja  $G$  jest całkowalna,

to dla dowolnego  $\beta > 0$

$$\sum_{i=1}^n G(X_i) - \mathbb{E}G(X_i) = \mathcal{O}_{p.n.}(\sqrt{n}\delta_n),$$

gdzie  $\delta_n = (\log \sqrt{n})^{\frac{1}{Q}} (\log \log \sqrt{n})^{\frac{1+\beta}{Q}}$ .

