

Stopę zbieżności

- Stopę zbieżności ciągu zmiennych losowych a_n , takiego, że $a_n \xrightarrow{p} 0$ oznaczamy jako $a_n = o_p(1)$
- Jeśli $\frac{a_n}{n^\alpha} \xrightarrow{p} 0$, to $a_n = o_p(n^\alpha)$ i mówimy a_n zbiega według prawdopodobieństwa szybciej niż n^α
- Zauważmy, że jeśli $a_n \xrightarrow{p} 0$, to $\left(\frac{n^\alpha a_n}{n^\alpha}\right) \xrightarrow{p} 0$ a więc $a_n = o_p(1) \implies n^\alpha a_n = o_p(n^\alpha)$
- Stopę zbieżności ciągu zmiennych losowych a_n , takiego, że $E(a_n) < \infty$ i $\text{Var}(a_n) < \infty$ dla wszystkich n oraz $\text{plim}[E(a_n)] < \infty$ i $\text{plim}\text{Var}(a_n) < \infty$, oznaczamy jako $a_n = O_p(1)$ (pojęcie te definiuje się czasami nieco ogólniej)

- Jeśli $\frac{a_n}{n^\alpha} = O_p(1)$, to $a_n = O_p(n^\alpha)$ i mówimy a_n zbiega co najmniej tak szybko jak n^α
- Podobnie jak w poprzednim przypadku, jeśli $a_n = O_p(1) \implies n^\alpha a_n = O_p(n^\alpha)$
- Dodatkowo $a_n = o_p(1)$ i $b_n = O_p(1)$, to $a_n b_n = o_p(1)$

Estymatory M

- Estymator M $\hat{\theta}$ jest rozwiązaniem problemu minimalizacji

$$\hat{\theta} = \arg \min_{\theta \in \Theta} \frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \theta)$$

dla pewnej funkcji celu $q(\mathbf{w}_i, \theta)$

- Zakładamy, że wektor parametrów θ_0 jest jedynym rozwiązaniem tego problemu w populacji - mówimy wtedy problem, że θ jest zidentyfikowana

$$\theta_0 = \arg \min_{\theta \in \Theta} E[q(\mathbf{w}_i, \theta)]$$

- Z Prawa Wielkich Liczb wiemy, że

$$\frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \boldsymbol{\theta}) \xrightarrow{p} \mathbb{E}[q(\mathbf{w}_i, \boldsymbol{\theta})]$$

i jeśli $\hat{\boldsymbol{\theta}}$ minimalizuje lewą stronę a $\boldsymbol{\theta}_0$ prawą stronę, to wydaje się logiczne, by $\hat{\boldsymbol{\theta}} \xrightarrow{p} \boldsymbol{\theta}_0$

Przykład Nieliniowa Metoda Najmniejszych Kwadratów

$$y_i = m(\mathbf{x}_i, \boldsymbol{\theta}_0) + u_i$$

$$\mathbb{E}(u_i | \mathbf{x}_i) = 0$$

Funkcją celu dla NMNK jest minimalizacja sumy kwadratów reszt $q_i(\mathbf{x}_i, \boldsymbol{\theta})$

$$q(y_i, \mathbf{x}_i, \boldsymbol{\theta}) = [y_i - m(\mathbf{x}_i, \boldsymbol{\theta})]^2$$

Wartość oczekiwana q_i

$$\begin{aligned} E [q (y_i, \mathbf{x}_i, \boldsymbol{\theta}) | \mathbf{x}_i] &= E [y_i - m (\mathbf{x}_i, \boldsymbol{\theta}) | \mathbf{x}_i]^2 \\ &= E [y_i - m (\mathbf{x}_i, \boldsymbol{\theta}_0) + [m (\mathbf{x}_i, \boldsymbol{\theta}) - m (\mathbf{x}_i, \boldsymbol{\theta}_0)] | \mathbf{x}_i]^2 \\ &= E (u_i^2 | \mathbf{x}_i) - 2 E (u_i | \mathbf{x}_i) [m (\mathbf{x}_i, \boldsymbol{\theta}) - m (\mathbf{x}_i, \boldsymbol{\theta}_0)] \\ &\quad + [m (\mathbf{x}_i, \boldsymbol{\theta}) - m (\mathbf{x}_i, \boldsymbol{\theta}_0)]^2 \\ &= E (u_i^2 | \mathbf{x}_i) + [m (\mathbf{x}_i, \boldsymbol{\theta}) - m (\mathbf{x}_i, \boldsymbol{\theta}_0)]^2 \end{aligned}$$

a więc

$$E [q (y_i, \mathbf{x}_i, \boldsymbol{\theta}) | \mathbf{x}_i] > E [q (y_i, \mathbf{x}_i, \boldsymbol{\theta}_0) | \mathbf{x}_i] = E (u_i^2 | \mathbf{x}_i) \text{ dla } \boldsymbol{\theta} \neq \boldsymbol{\theta}_0$$

Jeśli policzymy teraz wartości oczekiwane względem \mathbf{x}_i to otrzymamy bezwarunkowe wartości oczekiwane:

$$E [q (y_i, \mathbf{x}_i, \boldsymbol{\theta})] > E [q (y_i, \mathbf{x}_i, \boldsymbol{\theta}_0)] \text{ dla } \boldsymbol{\theta} \neq \boldsymbol{\theta}_0$$

Istotnie więc w θ_0 jest minimum wartości oczekiwanej funkcji celu.

Jedynym założeniem, które było nam potrzebne do udowodnienia tego, że możemy zastosować estymator M było $E(u_i | x_i) = 0$. Estymator M można więc wyprowadzić przy znacznie słabszych założeniach niż estymator MNW dla tego modelu.

Jednostajna zbieżność i zgodność

- Aby dowieść, zgodność estymatora musimy dowieść, że $\frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \boldsymbol{\theta})$ jest jednostajnie zbieżne do swojej wartości oczekiwanej (co jest silniejszym typem zbieżności niż normalna zbieżność):

$$\max_{\boldsymbol{\theta} \in \Theta} \left| \frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \boldsymbol{\theta}) - \mathbb{E}[q(\mathbf{w}_i, \boldsymbol{\theta})] \right| \xrightarrow{p} 0$$

- **Intuicja:** jednostajna zbieżność zachodzi, gdy maksymalna różnica między funkcjami dąży według prawdopodobieństwa do zera

Przykład Nieliniowa Metoda Najmniejszych Kwadratów

$$\max_{\boldsymbol{\theta} \in \Theta} \left| \frac{1}{N} \sum_{i=1}^N [m(\mathbf{x}_i, \boldsymbol{\theta}) + u_i] - \mathbb{E}[m(\mathbf{x}_i, \boldsymbol{\theta}) + u_i] \right| \xrightarrow{p} 0$$

będzie spełnione jeśli $\frac{1}{N} \sum_{i=1}^N u_i \xrightarrow{p} 0$ i $\frac{1}{N} \sum_{i=1}^N m(\mathbf{x}_i, \boldsymbol{\theta}) \xrightarrow{p} \mathbb{E}[m(\mathbf{x}_i, \boldsymbol{\theta})]$,
dla każdego $\boldsymbol{\theta}$.

- Jeśli zachodzi jednostajna zbieżność, to

$$\begin{aligned}
 \text{plim } \hat{\boldsymbol{\theta}} &= \text{plim} \left[\arg \min_{\boldsymbol{\theta}} \frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \boldsymbol{\theta}) \right] \\
 &= \arg \min_{\boldsymbol{\theta}} \left[\text{plim} \frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \boldsymbol{\theta}) \right] \\
 &= \arg \min_{\boldsymbol{\theta}} \{E[q(\mathbf{w}_i, \boldsymbol{\theta}_0)]\} = \boldsymbol{\theta}_0
 \end{aligned}$$

przy czym jednostajna zbieżności umożliwia policzenie granicy argumentu ($\text{plim} [\arg \min_{\boldsymbol{\theta}} (\cdot)]$) jako argumentu granicy ($\arg \min_{\boldsymbol{\theta}} [\text{plim} (\cdot)]$)

- Estymator M jest zgodny.

Dowód. Z definicji jednostajnej zbieżności oraz zbieżności funkcji celu

mamy:

$$\max_{\theta \in \Theta} \left| \frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \theta) - \mathbb{E}[q(\mathbf{w}_i, \theta)] \right| + \left| \mathbb{E}[q(\mathbf{w}_i, \theta_0)] - \frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \theta_0) \right| \xrightarrow{p} 0$$

Korzystając z tego, że $|x_1| + |x_2| \geq |x_1 + x_2| \geq 0$ mamy

$$\max_{\theta \in \Theta} \left| \frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \theta) - \frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \theta_0) + \mathbb{E}[q(\mathbf{w}_i, \theta_0)] - \mathbb{E}[q(\mathbf{w}_i, \theta)] \right| \xrightarrow{p} 0$$

ale z założenia, że $\mathbb{E}[q(\mathbf{w}_i, \theta_0)]$ jest minimum wynika, że $\mathbb{E}[q(\mathbf{w}_i, \theta)] - \mathbb{E}[q(\mathbf{w}_i, \theta_0)] = \alpha \geq 0$ a więc

$$\max_{\theta \in \Theta} \left| \frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \theta) - \frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \theta_0) - \alpha \right| \xrightarrow{p} 0$$

Z tego z kolei wnioskujemy, że

$$\frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \boldsymbol{\theta}) - \frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \boldsymbol{\theta}_0) \xrightarrow{p} \alpha \geq 0 \text{ dla każdego } \boldsymbol{\theta}$$

przy czym równość zachodzi jedynie dla $\boldsymbol{\theta} = \boldsymbol{\theta}_0$. Wnioskujemy z tego, że w granicy $\frac{1}{N} \sum_{i=1}^N q(\mathbf{w}_i, \boldsymbol{\theta})$ osiąga minimum dla $\boldsymbol{\theta} = \boldsymbol{\theta}_0$. ■

- Jeśli $\hat{\boldsymbol{\theta}} \xrightarrow{p} \boldsymbol{\theta}_0$ i funkcja $r(\mathbf{w}_i, \boldsymbol{\theta})$ jest jednostajnie zbieżna do $E[r(\mathbf{w}_i, \boldsymbol{\theta})]$, to

$$\frac{1}{N} \sum_{i=1}^N r(\mathbf{w}_i, \hat{\boldsymbol{\theta}}) \xrightarrow{p} E[r(\mathbf{w}_i, \boldsymbol{\theta}_0)]$$

i w związku z tym $\frac{1}{N} \sum_{i=1}^N r(\mathbf{w}_i, \hat{\boldsymbol{\theta}})$ jest zgodnym estymatorem $E[r(\mathbf{w}_i, \hat{\boldsymbol{\theta}})]$

Dowód. Z definicji jednostajnej zbieżności oraz zbieżności funkcji celu

mamy:

$$\max_{\boldsymbol{\theta} \in \Theta} \left| \frac{1}{N} \sum_{i=1}^N r(\mathbf{w}_i, \hat{\boldsymbol{\theta}}) - \mathbb{E} \left[r(\mathbf{w}_i, \hat{\boldsymbol{\theta}}) \right] \right| \xrightarrow{p} 0$$

Z twierdzenia Cramera wynika

$$\mathbb{E} \left[r(\mathbf{w}_i, \hat{\boldsymbol{\theta}}) \right] \xrightarrow{p} \mathbb{E} \left[r(\mathbf{w}_i, \boldsymbol{\theta}) \right]$$

Z kolei z jednostajnej zbieżności wnioskujemy, że

$$\frac{1}{N} \sum_{i=1}^N r(\mathbf{w}_i, \hat{\boldsymbol{\theta}}) \xrightarrow{p} \mathbb{E} \left[r(\mathbf{w}_i, \boldsymbol{\theta}) \right]$$

■

Asymptotyczna normalność estymatorów M

- Założenia:

1. spełnione są warunki, dla których estymator M jest zgodny $\hat{\theta} - \theta_0 = o_p(1)$
2. poszczególne $s(w_i, \theta)$ są niezależne i mają identyczne rozkłady bezwarunkowe
3. gradient $\frac{1}{N} \sum_{i=1}^N s(w_i, \theta) s(w_i, \theta)'$ i hessjan $\frac{1}{N} \sum_{i=1}^N \mathbf{H}(w_i, \theta)$ są jednostajnie zbieżne odpowiednio do $E[s(w_i, \theta) s(w_i, \theta)']$ i $E[\mathbf{H}(w_i, \theta)]$

gdzie $s(w_i, \theta)$ jest pierwszą pochodną $q(w_i, \theta)$

- Estymator $\hat{\theta}$ minimalizuje wartość oczekiwaną $q(w, \theta)$

- Jeśli $q(\mathbf{w}, \boldsymbol{\theta})$ jest ciągle różniczkowalna, to pierwsza pochodna $q(\mathbf{w}, \boldsymbol{\theta})$ powinna być równa 0 dla $\hat{\boldsymbol{\theta}}$

$$\sum_{i=1}^N \mathbf{s}(\mathbf{w}_i, \hat{\boldsymbol{\theta}}) = 0$$

- Funkcja $\mathbf{s}(\mathbf{w}_i, \boldsymbol{\theta})$ jest gradientem elementu funkcji $q(\mathbf{w}_i, \boldsymbol{\theta})$ celu (*score*)
- Rozwinięcie Taylora $\sum_{i=1}^N \mathbf{s}(\mathbf{w}_i, \hat{\boldsymbol{\theta}})$ wokół $\boldsymbol{\theta}_0$ daje

$$\sum_{i=1}^N \mathbf{s}(\mathbf{w}_i, \hat{\boldsymbol{\theta}}) = \sum_{i=1}^N \mathbf{s}(\mathbf{w}_i, \boldsymbol{\theta}_0) + \left(\sum_{i=1}^N \mathbf{H}_i \right) (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0) + o_p(1)$$

gdzie $\mathbf{H}_i = \mathbf{H}(\mathbf{w}_i, \hat{\boldsymbol{\theta}})$ jest hessjanem funkcji celu. Zbieżność reszty

wynika z tego, że $\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0 = o_p(1)$.

- Jak już wspomniano $\sum_{i=1}^N \mathbf{s}(\mathbf{w}_i, \hat{\boldsymbol{\theta}}) = 0$

$$\sum_{i=1}^N \mathbf{s}(\mathbf{w}_i, \boldsymbol{\theta}_0) = - \left(\sum_{i=1}^N \mathbf{H}_i \right) (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0) + o_p(1)$$

- Z Prawa Wielkich Liczb wynika, że $N^{-1} \sum_{i=1}^N \mathbf{H}_i \xrightarrow{p} \mathbb{E}[\mathbf{H}(\mathbf{w}, \boldsymbol{\theta}_0)] = \mathbf{A}_0 = O_p(1)$ (zakładamy dodatkowo, że \mathbf{A}_0 jest nieosobliwa).
- Mnożąc obie strony przez $\frac{1}{N}$ uzyskujemy

$$\frac{1}{N} \sum_{i=1}^N \mathbf{s}(\mathbf{w}_i, \boldsymbol{\theta}_0) = - \left(\frac{1}{N} \sum_{i=1}^N \mathbf{H}_i \right) (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0) + o_p\left(\frac{1}{N}\right)$$

dzieląc obie strony przez $\frac{1}{N} \sum_{i=1}^N \mathbf{H}_i = O_p(1)$, przenosząc na drugą stronę i mnożąc przez \sqrt{N} uzyskujemy

$$\sqrt{N} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0) = - \left(\frac{1}{N} \sum_{i=1}^N \mathbf{H}_i \right)^{-1} \left[-\frac{1}{\sqrt{N}} \sum_{i=1}^N \mathbf{s}(\mathbf{w}_i, \boldsymbol{\theta}_0) \right] + o_p \left(\frac{1}{\sqrt{N}} \right)$$

- A więc

$$\sqrt{N} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0) = \mathbf{A}_0^{-1} \left[-\frac{1}{\sqrt{N}} \sum_{i=1}^N \mathbf{s}(\mathbf{w}_i, \boldsymbol{\theta}_0) \right] + o_p \left(\frac{1}{\sqrt{N}} \right)$$

- Zauważmy, że przy spełnionych warunkach regularności:

$$\frac{\partial}{\partial \boldsymbol{\theta}} \mathbb{E} [q(\mathbf{w}, \boldsymbol{\theta})]_{\boldsymbol{\theta}=\boldsymbol{\theta}_0} = \mathbb{E} \left[\frac{\partial}{\partial \boldsymbol{\theta}} q(\mathbf{w}, \boldsymbol{\theta}) \right]_{\boldsymbol{\theta}=\boldsymbol{\theta}_0} = \mathbb{E} [\mathbf{s}(\mathbf{w}, \boldsymbol{\theta}_0)] = 0$$

- Ponieważ zgodnie z założeniami $q(\mathbf{w}_i, \boldsymbol{\theta})$ są niezależne i mają identyczne rozkłady więc $s(\mathbf{w}_i, \boldsymbol{\theta}_0)$ spełnia Centralnego Twierdzenia Granicznego i

$$\frac{1}{\sqrt{N}} \sum_{i=1}^N s(\mathbf{w}_i, \boldsymbol{\theta}_0) \xrightarrow{D} N(0, \mathbf{B}_0)$$

gdzie

$$\mathbf{B}_0 = E[s(\mathbf{w}_i, \boldsymbol{\theta}_0) s(\mathbf{w}_i, \boldsymbol{\theta}_0)']$$

- W rezultacie

$$\sqrt{N} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0) \xrightarrow{D} N(0, \mathbf{A}_0^{-1} \mathbf{B}_0 \mathbf{A}_0^{-1})$$

- Rozkład estymatora M jest normalny!
- Aasymptotyczna aproksymacja wariancji estymatora może być znaleziona

jako

$$\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0 \stackrel{a}{\sim} N \left(\mathbf{0}, \frac{1}{N} \mathbf{A}_0^{-1} \mathbf{B}_0 \mathbf{A}_0^{-1} \right)$$

Estymatory macierzy wariancji dla estymatorów M

- Często trudno jest bezpośrednio znaleźć $B_0 = E [s (w, \theta_0) s (w, \theta_0)']$ i $A_0 = E [H (w, \theta_0)]$.
- Jednak używając poprzednio wprowadzonego Lematu:

$$\hat{A} = N^{-1} \sum_{i=1}^N H (w_i, \hat{\theta}) = N^{-1} \sum_{i=1}^N \hat{H}_i \xrightarrow{p} E [H (w, \theta_0)] = A_0$$

- Wady tego estymatora:
 - konieczne policzenie macierzy drugich pochodnych
 - estymator nie zawsze musi być dodatnio określony

- W wielu zastosowaniach ekonomicznych wnioskowanie prowadzimy warunkowo względem \mathbf{x}_i i liczymy w związku z tym warunkową macierz:

$$\mathbf{A}_i = \mathbf{A}(\mathbf{x}_i, \boldsymbol{\theta}_0) = \mathbb{E}[\mathbf{H}(\mathbf{w}_i, \boldsymbol{\theta}) | \mathbf{x}_i]$$

- Zgodnie z prawem iterowanych wartości oczekiwanych $\mathbb{E}[\mathbf{A}(\mathbf{x}_i, \boldsymbol{\theta}_0)] = \mathbb{E}[\mathbf{H}(\mathbf{w}_i, \boldsymbol{\theta})] = \mathbf{A}_0$

- Dalej

$$\widehat{\mathbf{A}} = N^{-1} \sum_{i=1}^N \mathbf{A}(\mathbf{x}_i, \widehat{\boldsymbol{\theta}}) = N^{-1} \sum_{i=1}^N \widehat{\mathbf{A}}_i \xrightarrow{p} \mathbf{A}_0$$

- Ten estymator ma sens jeśli można łatwo uzyskać $\mathbb{E}[\mathbf{H}(\mathbf{w}_i, \boldsymbol{\theta}) | \mathbf{x}_i]$. W wielu przypadkach można pokazać, że estymator ten jest dodatnio określony.

- Estymator B_0 można uzyskać w sposób analogiczny:

$$\hat{B} = N^{-1} \sum_{i=1}^N s(w_i, \hat{\theta}) s(w_i, \hat{\theta})' = N^{-1} \sum_{i=1}^N \hat{s}_i \hat{s}_i' \xrightarrow{p} B_0$$

- W rezultacie zgodnym estymatorem wariancji $\sqrt{N} (\hat{\theta} - \theta_0)$ będzie

$$\hat{V} = \hat{A}^{-1} \hat{B} \hat{A}^{-1}$$

- A asymptotyczną aproksymacją wariancji $\hat{\theta}$ jest

$$Avar(\hat{\theta}) = \hat{A}^{-1} \hat{B} \hat{A}^{-1} / N$$

- W wielu przypadkach można uzyskać znaczne uproszczenie, jeśli

$$E [s(w, \theta) s(w, \theta)'] = -\sigma_0^2 E [H(w, \theta_0)] \quad (*)$$

albo $B_0 = \sigma^2 A_0$

- W tym szczególnym (choć częstym - tak jest np. w *MNW* dla $\sigma_0^2 = 1$) przypadku:

$$\hat{V} = -\hat{\sigma}^2 \hat{A}^{-1} = \hat{B}^{-1}$$

- Macierz wariancji kowariancji $Av\hat{a}r(\hat{\theta}) = \hat{A}^{-1} \hat{B} \hat{A}^{-1} / N$ jest niekiedy nazywana odporną macierz wariancji kowariancji (*robust*), ponieważ daje prawidłowe oszacowania nawet wtedy, gdy nie jest spełnione założenie *

Przykład Szacowanie macierzy wariancji kowariancji w MNK w przypadku występowania heteroskedastyczności.

Standardowa postać macierzy wariancji kowariancji estymator MNK została wyprowadzona przy założeniu braku heteroskedastyczności ($KMRL$). Dowiedliśmy wcześniej, że estymator M oparty na minimalizacji sumy kwadratów reszt dla modelu postaci $y_i = m(\mathbf{x}_i, \boldsymbol{\theta}_0) + u_i$ jest zgodny jeśli tylko $E(u_i | \mathbf{x}_i) = 0$. Odnosi się to oczywiście także do modelu do modelu liniowego $m(\mathbf{x}_i, \boldsymbol{\beta}) = \mathbf{x}_i \boldsymbol{\beta}$, $q(y_i, \mathbf{x}_i, \boldsymbol{\beta}) = (y_i - \mathbf{x}_i \boldsymbol{\beta})^2$. Zakładamy dodatkowo, że $\text{Var}(u_i) = \sigma^2$, że u_i, u_j są niezależne i u_i ma ten sam rozkład dla każdego i .

Różnica w stosunku do $KMRL$. Nie zakładamy braku zależności między wariancją a zmiennymi objaśniającymi. $\text{Var}(u_i | \mathbf{x}_i)$ może nie być stała dla każdego i . Zakładamy jedynie, że $E_x[\text{Var}(u_i | \mathbf{x}_i)] = \text{Var}(u_i) = \sigma^2$.

Dla modelu liniowego wektor score i oszacowania z parametru $\boldsymbol{\beta}$

oznaczonego b mamy

$$\begin{aligned} s(y_i, \mathbf{x}_i, \mathbf{b}) &= 2\mathbf{x}'_i \mathbf{x}_i \mathbf{b} - 2\mathbf{x}'_i y_i = \\ &= -\mathbf{x}'_i (y_i - \mathbf{x}_i \mathbf{b}) = -2\mathbf{x}'_i e_i \end{aligned}$$

W związku z tym oszacowaniem B jest równe $\hat{B} = 4N^{-1} \sum_{i=1}^N \mathbf{x}'_i \mathbf{x}_i e_i^2$.
Hessian funkcji celu jest równy

$$H(y_i, \mathbf{x}_i, \beta) = 2\mathbf{x}'_i \mathbf{x}_i$$

a więc oszacowaniem macierzy A_0 będzie

$$\hat{A} = N^{-1} \sum_{i=1}^N 2\mathbf{x}'_i \mathbf{x}_i = 2\mathbf{X}'\mathbf{X}$$

W rezultacie oszacowaniem macierzy wariancji kowariancji będzie

$$Avar(\mathbf{b}) = (\mathbf{X}'\mathbf{X})^{-1} \left(\sum_{i=1}^N \mathbf{x}'_i \mathbf{x}_i e_i^2 \right) (\mathbf{X}'\mathbf{X})^{-1}$$

a więc macierz odporna White'a.

Testowanie hipotez

- Podobnie jak w przypadku MNW dla estymatorów M można zastosować odpowiedniki testów Walda, mnożników Lagrange'a LM i ilorazu wiarygodności LR .
- Przy ogólnej hipotezie nieliniowej $h(\theta) = 0$ i założeniu, że $H(\theta) = \frac{\partial h(\theta)}{\partial \theta}$ ma pełen rząd
- Test Walda ma postać

$$W = \hat{h}' \left[\widehat{H} \widehat{V} \widehat{H}' \right]^{-1} \hat{h} \xrightarrow{D} \chi_g^2$$

gdzie \widehat{V} jest asymptotyczną wariancją $\tilde{\theta}$, $\hat{h} = h(\hat{\theta})$, $\widehat{H} = H(\hat{\theta})$

- Test mnożników Lagrange'a

$$\left(\sum_{i=1}^N \hat{s}_i \right)' \hat{A}^{-1} \hat{H}' \left(\hat{H} \hat{V} \hat{H}' \right)^{-1} \hat{H} \hat{A}^{-1} \left(\sum_{i=1}^N \hat{s}_i \right) / N \xrightarrow{d} \chi_Q^2$$

gdzie wszystkie $\hat{s}_i = s_i(\hat{\theta}_R)$, $\hat{H} = H(\hat{\theta}_R)$.

- Test *QLR* (quasi iloraz wiarygodności) ma postać

$$QLR = 2 \left[\sum_{i=1}^N q(w_i, \hat{\theta}_R) - \sum_{i=1}^N q(w_i, \hat{\theta}) \right] \xrightarrow{d} \chi_Q^2$$

gdzie $\hat{\theta}_R$ jest estymatorem z ograniczeniami $\hat{\theta}$ bez ograniczeń

Estymatory *MNW* i pseudo *MNW*

- W przypadku modelu estymowanego *MNW* funkcja gęstości musimy znać warunkową funkcję gęstości dla każdej obserwacji

$$f(y_i | \mathbf{x}_i; \boldsymbol{\theta}) = p_0(y_i | \mathbf{x}_i)$$

- Estymatory *MNW* są specjalnym przypadkiem estymatorów *M*, ponieważ

$$E[\ell_i(\boldsymbol{\theta}_0) | \mathbf{x}_i] \geq E[\ell_i(\boldsymbol{\theta}) | \mathbf{x}_i] \text{ dla każdego } \boldsymbol{\theta} \in \Theta$$

gdzie $\ell_i(\boldsymbol{\theta}) = \ell_i(\mathbf{y}_i, \mathbf{x}_i, \boldsymbol{\theta}) = \log[f(y_i | \mathbf{x}_i; \boldsymbol{\theta})]$

Dowód. Z własności prawdopodobieństwa $\int_Y f(y_i | \mathbf{x}_i; \boldsymbol{\theta}_0) dy_i = 1$. Z warunkowej wersji nierówności Jensena

$$\begin{aligned} \mathbb{E} \left[\log \left(\frac{f(y_i | \mathbf{x}_i; \boldsymbol{\theta})}{f(y_i | \mathbf{x}_i; \boldsymbol{\theta}_0)} \right) \middle| \mathbf{x}_i \right] &\leq \log \left\{ \mathbb{E} \left[\frac{f(y_i | \mathbf{x}_i, \boldsymbol{\theta})}{f(y_i | \mathbf{x}_i, \boldsymbol{\theta}_0)} \middle| \mathbf{x}_i \right] \right\} = \\ &= \log \left\{ \int_Y \frac{f(y_i | \mathbf{x}_i, \boldsymbol{\theta})}{f(y_i | \mathbf{x}_i, \boldsymbol{\theta}_0)} f(y_i | \mathbf{x}_i, \boldsymbol{\theta}_0) dy_i \right\} \\ &= \log \left[\int_Y f(y_i | \mathbf{x}_i; \boldsymbol{\theta}) dy_i \right] = 0 \end{aligned}$$

i z definicji $\ell_i(\boldsymbol{\theta})$

$$\mathbb{E}[\ell_i(\boldsymbol{\theta}_0) | \mathbf{x}_i] \geq \mathbb{E}[\ell_i(\boldsymbol{\theta}) | \mathbf{x}_i]$$

a więc w $\boldsymbol{\theta}_0$ wartość oczekiwana funkcji celu przyjmuje wartość *maksymalną*

■

- W tym przypadku *maksymalizujemy* funkcję celu

$$\max_{\theta \in \Theta} \sum_{i=1}^N \ell_i(\theta)$$

- Założenie, przy którym wyprowadza się standardowe własności estymatora *MNW* mówi, że

$$L(\theta) = f(\mathbf{y} | \mathbf{x}; \theta) = \prod_{i=1}^N f(y_i | \mathbf{x}_i, \theta_0)$$

jest poprawną funkcją wiarygodności dla całej próby.

- Implikuje to, że poszczególne obserwacje są niezależne co często nie jest prawdą.

- Zauważmy, że do zbieżności estymatora M (a więc i estymatora MNW) wystarczy, by poprawnie była wyspecyfikowana funkcja gęstości dla *pojedynczego* zdarzenia
- **Uwaga:** w dowodzie dla $\text{Var} \left(\frac{\partial \ell(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \right) = -\text{E} \left(\frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}'} \right) = \mathbf{I}(\boldsymbol{\theta})$ używaliśmy założenia, że funkcja wiarygodności jest poprawnie wyspecyfikowana, tylko dla tego przypadku macierzą wariancji kowariancji będzie $\mathbf{I}(\boldsymbol{\theta})^{-1}$.
- **Wniosek:**
 - jeśli poprawnie wyspecyfikowana jest jedynie funkcja gęstości dla pojedynczego zdarzenia to estymator MNW jest dalej zgodny
 - aby poprawnie wyestymować macierz wariancji estymatora należy zastosować wersję odporną macierzy wariancji estymatora M

Przykład (Próbkowanie warstwami) Załóżmy, że chcemy wyestymować model probitowy dla próby, która została wylosowana w sposób następujący:

najpierw losowano gospodarstwa a później zadawano pytania wszystkim członkom gospodarstwa (tak losowana jest np. próba BAEL). Załóżmy dla uproszczenia, że badano jedynie gospodarstwa k osobowe. Problem estymacji w tym przypadku związany jest z ewentualnym zależnością między elementami losowymi wewnątrz gospodarstwa - poszczególne obserwacje mogą być zależne. Załóżmy, że model ma następującą postać:

$$\begin{aligned}
 y_{ij}^* &= \mathbf{x}_{ij}\boldsymbol{\beta} + \varepsilon_{ij} \\
 y_{ij} &= \begin{cases} 1 & \text{dla } y_{ij}^* > 0 \\ 0 & \text{dla } y_{ij}^* \leq 0 \end{cases} \\
 \varepsilon_i &\sim N(\mathbf{0}, \boldsymbol{\Sigma})
 \end{aligned}$$

gdzie i jest indeksem gospodarstwa, j jest indeksem osoby wewnątrz, ε_{ij} jest czynnikiem losowym. Zakładamy, że czynniki losowe mogą być skorelowane wewnątrz gospodarstwa $E(\varepsilon_i \varepsilon_i') = \boldsymbol{\Sigma} \neq \sigma^2 I$ ale są niezależne dla różnych gospodarstw $E(\varepsilon_i \varepsilon_j') = 0$. Sformułowanie pełnej funkcji

wiarygodności dla tego problemu byłoby bardzo trudne, ponieważ trudne jest policzenie dystrybuanty wielowymiarowego rozkładu normalnego. Można jednak zauważyć, że dla każdej z k obserwacji spełnione jest, że

$$E[\ell_{ij}(\boldsymbol{\theta}_0) | y_i, \mathbf{x}_i] \geq E[\ell_{ij}(\boldsymbol{\theta}) | y_i, \mathbf{x}_i]$$

Dalej suma $\ell_i(\boldsymbol{\theta}_0) = \sum_{j=1}^k \ell_{ij}(\boldsymbol{\theta}_0)$ będzie też maksymalizowane przez $\boldsymbol{\theta}_0$.

$$E[\ell_i(\boldsymbol{\theta}_0) | y_i, \mathbf{x}_i] \geq E[\ell_i(\boldsymbol{\theta}) | y_i, \mathbf{x}_i]$$

Z kolei z racji na założony brak korelacji między obserwacjami dla różnych gospodarstw, poszczególne $\ell_i(\boldsymbol{\theta})$ będą niezależne. Wynika z tego, że zgodnym estymator M oparty na funkcji celu $\ell(\boldsymbol{\theta}) = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^k \ell_{ij}(\boldsymbol{\theta})$, gdzie N jest liczbą przebadanych gospodarstw. Estymator ten będzie miał

asymptotyczny rozkład normalny o wariancji:

$$\mathbf{A}_0 = \mathbf{E} [\mathbf{H} (y_i, \mathbf{x}_i, \boldsymbol{\theta}_0)]$$

$$\mathbf{B}_0 = \mathbf{E} [\mathbf{s} (y_i, \mathbf{x}_i, \boldsymbol{\theta}) \mathbf{s} (y_i, \mathbf{x}_i, \boldsymbol{\theta})']$$

gdzie $\mathbf{s} (y_i, \mathbf{x}_i, \boldsymbol{\theta}) = \frac{\partial \sum_{j=1}^k \ell_{ij}(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}}$ a $\mathbf{H} (y_i, \mathbf{x}_i, \boldsymbol{\theta}) = \frac{\partial^2 \sum_{j=1}^k \ell_{ij}(\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}}$.