

Metoda Największej Wiarygodności

Jerzy Mycielski

WNE, UW, 2024

- Założenia
- ① $\mathbf{y}_i, \mathbf{x}_i$ zaobserwowane dla $i = 1, \dots, n$
- ② poszczególne obserwacje niezależne
- ③ obserwacje \mathbf{y}_i pochodzą z rozkładu warunkowego $f_{\theta}(\mathbf{y}_i | \mathbf{x}_i)$
- ④ θ prawdziwa wartość szacowanego wektora parametrów
- ⑤ postać funkcji $f_{\theta}(\cdot)$ nie zależy od n a jedynie od $\theta \in \Theta \subset R^k$

- Łączna funkcję gęstości wektora $\mathbf{y} = [y_1, \dots, y_n]'$

$$f_{\theta}(\mathbf{y} | \mathbf{X}) = f_{\theta}(y_1, \dots, y_n | \mathbf{x}_1, \dots, \mathbf{x}_n)$$

nazywamy funkcją wiarygodności i oznaczamy $L(\mathbf{y} | \mathbf{X}, \theta)$

- Z niezależności wynika, że funkcja wiarygodności jest równa:

$$L(\mathbf{y} | \mathbf{X}, \theta) = f_{\theta}(\mathbf{y} | \mathbf{X}) = \prod_{i=1}^n f_{\theta}(\mathbf{y}_i | \mathbf{x}_i),$$

gdzie $\mathbf{y} = [y_1, \dots, y_n]'$, $\mathbf{X} = [\mathbf{x}'_1, \dots, \mathbf{x}'_n]'$ i $\mathbf{y} \in \mathbf{Y}$

- Logarytm funkcji wiarygodności ma postać

$$\begin{aligned}\ell(\mathbf{y}|\mathbf{X}, \theta) &= \ln L(\mathbf{y}|\mathbf{X}, \theta) = \sum_{i=1}^n \ln f_{\theta}(\mathbf{y}_i|\mathbf{x}_i) \\ &= \sum_{i=1}^n \ell_i(\mathbf{y}_i|\mathbf{x}_i, \theta)\end{aligned}$$

- Będziemy pomijać \mathbf{y} i \mathbf{X} oraz y_i i \mathbf{x}_i i pisać $\ell(\theta)$, $L(\theta)$ i $\ell_i(\theta)$

Definicja

Estymatorem *MNW* jest takie θ dla której funkcja wiarygodności ma największą wartość:

$$\tilde{\theta} = \arg \max L(\theta) = \arg \max \ell(\theta)$$

Założenia

$$y_i = \mathbf{x}_i \boldsymbol{\beta} + \varepsilon_i$$

$$\varepsilon_i \sim N(0, \sigma^2)$$

i ε_i niezależne, w rezultacie

$$y_i \sim N(\mathbf{x}_i \boldsymbol{\beta}, \sigma^2)$$

warunkowa funkcja gęstości

$$f_{\boldsymbol{\beta}, \sigma^2}(y_i | \mathbf{x}_i) = (2\pi\sigma^2)^{-\frac{1}{2}} \exp\left(-\frac{(y_i - \mathbf{x}_i \boldsymbol{\beta})^2}{2\sigma^2}\right)$$

Funkcja wiarygodności

$$\begin{aligned}
 L(\boldsymbol{\beta}, \sigma^2) &= \prod_{i=1}^n (2\pi\sigma^2)^{-\frac{1}{2}} \exp\left(-\frac{(y_i - \mathbf{x}_i\boldsymbol{\beta})^2}{2\sigma^2}\right) \\
 &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\sum_{i=1}^n \frac{(y_i - \mathbf{x}_i\boldsymbol{\beta})^2}{2\sigma^2}\right) \\
 &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})\right)
 \end{aligned}$$

logarytm funkcji wiarygodności

$$\begin{aligned}
 \ell(\boldsymbol{\beta}, \sigma^2) &= -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) \\
 &\quad - \frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})
 \end{aligned}$$

- warunki pierwszego rzędu

$$\frac{\partial \ell(\beta, \sigma^2)}{\partial \beta} = -\frac{1}{2\sigma^2} (2\mathbf{X}'\mathbf{X}\beta - 2\mathbf{X}'\mathbf{y}) = 0$$

$$\frac{\partial \ell(\beta, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} (\mathbf{y} - \mathbf{X}\beta)' (\mathbf{y} - \mathbf{X}\beta) = 0$$

- rozwiązanie

$$\tilde{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$$

$$\tilde{\sigma}^2 = \frac{(\mathbf{y} - \mathbf{X}\tilde{\beta})' (\mathbf{y} - \mathbf{X}\tilde{\beta})}{n} = \frac{\mathbf{e}'\mathbf{e}}{n}$$

- Jako estymator $\tilde{\beta}$ uzyskaliśmy dokładnie estymator *MNK*!
- Estymator $\tilde{\sigma}^2$ różni się od estymatora *MNK* ($s^2 = \frac{\mathbf{e}'\mathbf{e}}{n-k}$), więc jest obciążony ale różnica między $\tilde{\sigma}^2$ i s^2 dąży do zera.

- Zgodność

$$\tilde{\theta} \xrightarrow{P} \theta$$

- Macierz informacyjna Fishera

$$I(\theta) = \text{Var} \left(\frac{\partial \ell(\theta)}{\partial \theta} \right) = -E \left(\frac{\partial^2 \ell(\theta)}{\partial \theta \partial \theta'} \right)$$

- Zgodnie z definicją macierz informacyjna równa jest wariancji gradientu - $\text{Var} \left(\frac{\partial \ell(\theta)}{\partial \theta} \right)$, lub minus wartość oczekiwanej Hessianu logarytmu funkcji wiarygodności.
- Rozkład asymptotyczny estymator *MNW* można przybliżyć za pomocą rozkładu normalnego:

$$\tilde{\theta} - \theta \stackrel{a}{\sim} N(0, I^{-1}(\theta))$$

- Jeśli estymator $\hat{\theta}$ jest zgodny, to asymptotycznie

$$\text{Var} \left(\sqrt{n} (\hat{\theta} - \theta) \right) \geq n \mathbf{I}^{-1}(\theta)$$

- $\mathbf{I}^{-1}(\theta)$ równa najmniejszej możliwej macierzy wariancji estymatora asymptotycznie nieobciążonego
- Twierdzenie nazywane jest niekiedy twierdzeniem o dolnym ograniczeniu Cramera-Rao
- Łatwo się przekonać, że dla estymatorów nieobciążonych obowiązuje ono także w małych próbach (dolnym ograniczeniem jest wtedy macierz $\mathbf{I}^{-1}(\theta)$)
- Estymator *MNW* są asymptotycznie efektywne, ponieważ ich wariancja zbiega do dolnego ograniczenia Cramera-Rao

- Niezmienniczość: Estymator *MNW* dla $\omega = \mathbf{g}(\theta)$, jest dany wzorem $\tilde{\omega} = \mathbf{g}(\tilde{\theta})$. Jeśli $\tilde{\theta}$ jest zgodne, to $\tilde{\omega}$ jest też zgodne

$$\tilde{\theta} \xrightarrow{P} \theta \implies \tilde{\omega} \xrightarrow{P} \omega$$

- Rozkład $\tilde{\omega}$ można przybliżyć w następujący sposób (metoda delta)

$$\tilde{\omega} - \omega \stackrel{a}{\sim} N\left(0, \frac{\partial \mathbf{g}(\tilde{\theta})}{\partial \theta'} \mathbf{I}^{-1}(\tilde{\theta}) \frac{\partial \mathbf{g}(\tilde{\theta})}{\partial \theta}\right)$$

- Z asymptotycznych własności estymatora *MNW* wynika, że estymatorem wariancji $\tilde{\theta}$ jest odwrotność macierzy informacyjnej $I^{-1}(\theta)$. Z kolei macierz informacyjną $I(\theta)$ można oszacować za pomocą macierzy $I(\tilde{\theta})$.

- gradient

$$\begin{aligned}\frac{\partial \ell(\beta, \sigma^2)}{\partial \beta} &= -\frac{1}{2\sigma^2} (2\mathbf{X}'\mathbf{X}\beta - 2\mathbf{X}'\mathbf{y}) \\ &= \frac{1}{\sigma^2} \mathbf{X}'\boldsymbol{\varepsilon}\end{aligned}$$

$$\begin{aligned}\frac{\partial \ell(\beta, \sigma^2)}{\partial \sigma^2} &= -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} (\mathbf{y} - \mathbf{X}\beta)' (\mathbf{y} - \mathbf{X}\beta) \\ &= -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \boldsymbol{\varepsilon}'\boldsymbol{\varepsilon}\end{aligned}$$

- Wariancja pochodnej względem β

$$\begin{aligned} \text{Var} \left(\frac{\partial \ell(\beta, \sigma^2)}{\partial \beta} \right) \\ = \frac{1}{\sigma^4} \mathbf{X}' \text{Var}(\varepsilon) \mathbf{X} = \frac{1}{\sigma^2} (\mathbf{X}' \mathbf{X}) \end{aligned}$$

- pochodnej względem σ^2

$$\begin{aligned} \text{Var} \left(-\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \varepsilon' \varepsilon \right) \\ = \frac{1}{4\sigma^8} (n2\sigma^4) = \frac{n}{2\sigma^4} \end{aligned}$$

bo $\text{Var}(\varepsilon_i^2) = 2\sigma^4$.

- kowariancja między pochodnymi

$$E \left[\frac{1}{\sigma^2} \mathbf{X}' \boldsymbol{\varepsilon} \left(-\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \boldsymbol{\varepsilon}' \boldsymbol{\varepsilon} \right) \right] = 0$$

bo $E(\boldsymbol{\varepsilon}_j^3) = 0$, $E(\boldsymbol{\varepsilon}_i \boldsymbol{\varepsilon}_j^2) = E(\boldsymbol{\varepsilon}_i) E(\boldsymbol{\varepsilon}_j^2) = 0$

- Elementy Hessianu

$$\frac{\partial^2 \ell(\boldsymbol{\beta}, \sigma^2)}{\partial \boldsymbol{\beta} \partial \boldsymbol{\beta}'} = -\frac{1}{\sigma^2} \mathbf{X}' \mathbf{X}$$

$$\frac{\partial^2 \ell(\boldsymbol{\beta}, \sigma^2)}{\partial \sigma^2 \partial \sigma^2} = \frac{n}{2} \frac{1}{\sigma^4} - \frac{1}{\sigma^6} \boldsymbol{\varepsilon}' \boldsymbol{\varepsilon}$$

$$\frac{\partial^2 \ell(\boldsymbol{\beta}, \sigma^2)}{\partial \boldsymbol{\beta} \partial \sigma^2} = -\frac{1}{\sigma^4} \mathbf{X}' \boldsymbol{\varepsilon}$$

- Macierz informacyjna Fishera

$$\begin{aligned}
 I(\beta, \sigma^2) &= -E \begin{bmatrix} -\frac{1}{\sigma^2} \mathbf{X}'\mathbf{X} & -\frac{1}{\sigma^4} \mathbf{X}'\boldsymbol{\varepsilon} \\ -\frac{1}{\sigma^4} \mathbf{X}'\boldsymbol{\varepsilon} & \frac{n}{2} \frac{1}{\sigma^4} - \frac{1}{\sigma^6} \boldsymbol{\varepsilon}'\boldsymbol{\varepsilon} \end{bmatrix} \\
 &= \begin{bmatrix} \frac{1}{\sigma^2} \mathbf{X}'\mathbf{X} & 0 \\ 0 & \frac{n}{2\sigma^4} \end{bmatrix}
 \end{aligned}$$

- Wariancja $\tilde{\boldsymbol{\theta}} = [\tilde{\boldsymbol{\beta}}', \tilde{\sigma}^2]'$

$$I^{-1}(\beta, \sigma^2) = \begin{bmatrix} \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} & 0 \\ 0 & \frac{2\sigma^4}{n} \end{bmatrix}$$

- Estymator wariancji

$$I^{-1}(\tilde{\boldsymbol{\beta}}, \tilde{\sigma}^2) = \begin{bmatrix} \tilde{\sigma}^2 (\mathbf{X}'\mathbf{X})^{-1} & 0 \\ 0 & \frac{2\tilde{\sigma}^4}{n} \end{bmatrix}$$

- Analityczne policzenie wariancji gradientu $\text{Var}\left(\frac{\partial \ell(\theta)}{\partial \theta}\right)$ bądź minus wartość oczekiwanej Hessianu $-E\left(\frac{\partial^2 \ell(\theta)}{\partial \theta \partial \theta'}\right)$ jest w większości przypadków bardzo skomplikowane bądź wręcz niemożliwe.
- Jeśli jednak spełniony jest warunek niezależności i tych samych rozkładów poszczególnych elementów próby, to jak wcześniej wspomniano:

$$\ell(\theta) = \sum_{i=1}^n \ell_i(\mathbf{y}_i | \mathbf{x}_i, \theta)$$

- Można pokazać, że

$$E\left(\frac{\partial \ell_i(\theta)}{\partial \theta}\right) = 0 \text{ dla każdego } i$$

a więc w związku z równością rozkładów

$$\text{Var}\left(\frac{\partial \ell_i(\theta)}{\partial \theta}\right) = -E\left(\frac{\partial \ell_i(\theta)}{\partial \theta} \frac{\partial \ell_i(\theta)}{\partial \theta'}\right) \text{ dla każdego } i$$

- Z prawa wielkich liczb

$$\frac{1}{n} \sum_{i=1}^n \frac{\partial \ell_i(\theta)}{\partial \theta} \frac{\partial \ell_i(\theta)}{\partial \theta'} \xrightarrow{p} E\left(\frac{\partial \ell_i(\theta)}{\partial \theta} \frac{\partial \ell_i(\theta)}{\partial \theta'}\right)$$

- Z niezależności

$$\begin{aligned} I(\beta, \sigma^2) &= \text{Var} \left(\frac{\partial \ell(\theta)}{\partial \theta} \right) = \text{Var} \left(\sum_{i=1}^n \frac{\partial \ell_i(\theta)}{\partial \theta} \right) \\ &= \sum_{i=1}^n \text{Var} \left(\frac{\partial \ell_i(\mathbf{y}_i | \mathbf{x}_i, \theta)}{\partial \theta} \right) \\ &= nE \left(\frac{\partial \ell_i(\theta)}{\partial \theta} \frac{\partial \ell_i(\theta)}{\partial \theta'} \right) \approx \sum_{i=1}^n \frac{\partial \ell_i(\theta)}{\partial \theta} \frac{\partial \ell_i(\theta)}{\partial \theta'} \end{aligned}$$

- Estymator macierzy wariancji można więc wyznaczyć jako odwrotność sumy iloczynów gradientów logarytmów funkcji gęstości dla poszczególnych zdarzeń: ten estymator określany jest niekiedy mianem *OPG* (**O**uter **P**roduct of **G**radients)

- Podobnie pokazujemy, że

$$I(\beta, \sigma^2) = -E\left(\frac{\partial^2 \ell(\theta)}{\partial \theta \partial \theta'}\right) \stackrel{a}{\approx} -\sum_{i=1}^n \frac{\partial^2 \ell_i(\tilde{\theta})}{\partial \theta \partial \theta'}$$

- Estymator macierzy wariancji możemy więc też uzyskać jako odwrotność minusa sumy Hessianów logarytmów funkcji wiarygodności dla poszczególnych zdarzeń. Czasami estymator ten jest nazywany estymatorem empirycznego Hessianu.

- Wady i zalety poszczególnych estymatorów:
 - Dla estymatorów opartych na wzorach analitycznych $Var\left(\frac{\partial \ell(\theta)}{\partial \theta}\right) = -E\left(\frac{\partial^2 \ell(\theta)}{\partial \theta \partial \theta'}\right)$. Wybieramy wersję, którą łatwiej wyprowadzić. Uzyskany estymator jest zawsze nieujemnie określony i daje najlepsze oszacowanie wariancji. Wyprowadzenie postaci tych estymatorów w przypadku funkcji nieliniowych jest jednak zazwyczaj niemożliwe.
 - *OPG* - wyprowadzenie tego estymatora jest względnie łatwa, wymaga on policzenia jedynie wektora pierwszych pochodnych, uzyskana macierz jako suma macierzy nieujemnie określonych jest zawsze nieujemnie określona.
 - Empiryczny Hessian - wyprowadzenie go może być nieco trudniejsze ze względu na konieczność policzenia macierzy drugich pochodnych. Estymator ten jest nieujemnie określony jeśli udało nam się znaleźć minimum funkcji wiarygodności.
- Uwaga: niektóre współczesne programy ekonometryczne są w stanie policzyć numerycznie pochodne $\frac{\partial \ell(\theta)}{\partial \theta}$ i $\frac{\partial^2 \ell(\theta)}{\partial \theta \partial \theta'}$.

- Logarytm funkcji gęstości dla poszczególnego zdarzenia

$$\begin{aligned} \ell_i(\beta, \sigma^2) &= -\frac{1}{2} \ln(2\pi) - \frac{1}{2} \ln(\sigma^2) \\ &\quad - \frac{1}{2\sigma^2} (y_i - \mathbf{x}_i\beta)' (y_i - \mathbf{x}_i\beta) \end{aligned}$$

- Pierwsza pochodna

$$\frac{\partial \ell_i(\beta, \sigma^2)}{\partial \theta} = \frac{1}{\sigma^2} (\mathbf{x}'_i y_i - \mathbf{x}'_i \mathbf{x}_i \beta) = \mathbf{x}'_i (y_i - \mathbf{x}_i \beta)$$

$$\frac{\partial \ell_i(\beta, \sigma^2)}{\partial \sigma^2} = -\frac{1}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} (y_i - \mathbf{x}_i \beta)^2$$

- Z powyższych wzorów wynika, że pierwsza pochodna policzona dla wcześniej uzyskanych oszacowań $\tilde{\beta}, \tilde{\sigma}^2$ ma postać:

$$\frac{\partial \ell_i(\tilde{\beta}, \tilde{\sigma}^2)}{\partial \beta} = \frac{1}{\tilde{\sigma}^2} \mathbf{x}_i e_i$$

$$\frac{\partial \ell_i(\tilde{\beta}, \tilde{\sigma}^2)}{\partial \sigma^2} = \frac{1}{2\tilde{\sigma}^2} \left(\frac{e_i^2}{\tilde{\sigma}^2} - 1 \right)$$

gdzie reszta $e_i = y_i - \mathbf{x}_i \tilde{\beta}$

- Estymator *OPG* macierzy informacyjnej

$$\begin{aligned}
 & \sum_{i=1}^n \frac{\partial \ell_i(\tilde{\theta})}{\partial \theta} \frac{\partial \ell_i(\tilde{\theta})}{\partial \theta'} \\
 &= \frac{1}{\tilde{\sigma}^4} \begin{bmatrix} \sum_{i=1}^n \mathbf{x}'_i \mathbf{x}_i e_i^2 & \frac{1}{2} \sum_{i=1}^n \mathbf{x}_i e_i \left(\frac{e_i^2}{\tilde{\sigma}^2} - 1 \right) \\ \frac{1}{2} \sum_{i=1}^n \mathbf{x}_i e_i \left(\frac{e_i^2}{\tilde{\sigma}^2} - 1 \right) & \frac{1}{4} \sum_{i=1}^n \left(\frac{1}{\tilde{\sigma}^2} e_i^2 - 1 \right)^2 \end{bmatrix} \\
 &= \frac{1}{\tilde{\sigma}^4} \begin{bmatrix} \sum_{i=1}^n \mathbf{x}'_i \mathbf{x}_i e_i^2 & \frac{1}{2} \sum_{i=1}^n \mathbf{x}_i e_i^3 \\ \frac{1}{2} \sum_{i=1}^n \mathbf{x}_i e_i^3 & \frac{1}{4} \left(\sum_{i=1}^n \frac{e_i^4}{\tilde{\sigma}^4} - n \right) \end{bmatrix}
 \end{aligned}$$

przy czym skorzystaliśmy z tego, że $\sum_{i=1}^n \mathbf{x}_i e_i = 0$ (z własności hiperpłaszczyzny regresji) a $n\tilde{\sigma}^2 = \sum_{i=1}^n e_i^2$. Estymator ten ma wyraźnie różną postać od estymatora macierzy $\mathbf{I}(\tilde{\theta})$, który policzyliśmy wcześniej licząc analitycznie wariancję gradientu. Odwrotność tej macierzy da nam estymator *OPG* wariancji.

- Estymator empirycznego Hessianu

$$\frac{\partial^2 \ell_i(\beta, \sigma^2)}{\partial \beta \partial \beta'} = -\frac{1}{\widehat{\sigma}^2} \mathbf{x}'_i \mathbf{x}_i$$

$$\frac{\partial^2 \ell_i(\beta, \sigma^2)}{\partial \sigma^2 \partial \sigma^2} = \frac{1}{\widehat{\sigma}^4} \left(\frac{1}{2} - \frac{e_i^2}{\widehat{\sigma}^2} \right)$$

$$\frac{\partial^2 \ell_i(\beta, \sigma^2)}{\partial \beta \partial \sigma^2} = -\frac{1}{\sigma^4} \mathbf{x}'_i e_i$$

$$\sum_{i=1}^n \frac{\partial^2 \ell_i(\tilde{\theta})}{\partial \theta \partial \theta'} = \frac{1}{\tilde{\sigma}^2} \begin{bmatrix} \sum_{i=1}^n \mathbf{x}'_i \mathbf{x}_i & 0 \\ 0 & \frac{n}{2\tilde{\sigma}^2} \end{bmatrix}$$

a więc estymator wariancji ma postać

$$\begin{bmatrix} \tilde{\sigma}^2 (\mathbf{X}'\mathbf{X})^{-1} & 0 \\ 0 & \frac{n}{2} \tilde{\sigma}^4 \end{bmatrix}$$

równą wcześniej policzonej jako wariancja gradientu i wartość oczekiwana minus Hessianu. Jest to jednak wyjątkowy wynik.

- Testowana ogólna hipoteza nieliniowa: $H_0: \mathbf{h}(\boldsymbol{\theta}) = 0$, gdzie $\mathbf{h}(\boldsymbol{\theta})$ jest funkcją wektorową $\mathbf{h}(\boldsymbol{\theta}) = \begin{cases} h_1(\boldsymbol{\theta}) \\ \vdots \\ h_g(\boldsymbol{\theta}) \end{cases}$.
- Oznaczmy przez $\mathbf{H}(\boldsymbol{\theta})$ macierz pochodnych wektora $\mathbf{h}(\boldsymbol{\theta})$ względem $\boldsymbol{\theta}$ (Jakobian)
- Do weryfikacji tak sformułowanej hipotezy najczęściej używa się jednego z trzech testów.

- Test ilorazu wiarygodności (**Likelihood Ratio**) (LR),

$$LR = 2 \left(\ell(\tilde{\theta}) - \ell(\tilde{\theta}_R) \right) \xrightarrow{D} \chi_g^2$$

gdzie g jest liczbą nałożonych ograniczeń

- wymaga policzenia $\tilde{\theta}$ i $\tilde{\theta}_R$
- wymaga policzenia różnicy funkcji wiarygodności (naogół łatwe)

- Test **W**alda (W)

$$W = \mathbf{h}(\tilde{\boldsymbol{\theta}})' [\mathbf{H}(\tilde{\boldsymbol{\theta}}) \mathbf{I}^{-1}(\tilde{\boldsymbol{\theta}}) \mathbf{H}'(\tilde{\boldsymbol{\theta}})]^{-1} \mathbf{h}(\tilde{\boldsymbol{\theta}}) \xrightarrow{D} \chi_g^2$$

gdzie g jest liczbą nałożonych ograniczeń

- wymaga policzenia jedynie $\tilde{\boldsymbol{\theta}}$
- wymaga policzenia odpowiedniej formy kwadratowej
- nie jest niezmiennicza ze względu na sposób zdefiniowania $\mathbf{h}(\boldsymbol{\theta})$

- mnożników Lagrange'a (**L**agrange **M**ultipliers) (*LM*).

$$LM = \frac{\partial \ell(\theta)}{\partial \theta'} \Big|_{\theta = \tilde{\theta}_R} I^{-1}(\tilde{\theta}_R) \frac{\partial \ell(\theta)}{\partial \theta} \Big|_{\theta = \tilde{\theta}_R} \xrightarrow{D} \chi_g^2$$


gdzie g jest liczbą nałożonych ograniczeń

- wymaga policzenia jedynie $\tilde{\theta}_R$
- wymaga policzenia gradientu lub $\tilde{\lambda}$ i odpowiedniej formy kwadratowej

- Intuicja: jeśli warunki poboczne są prawdziwe, to
 - LR wartość $\ell(\tilde{\theta})$ nie powinna istotnie różnić się od $\ell(\tilde{\theta}_R)$
 - W wartość $\tilde{\theta}$ powinna być zbliżona do $\tilde{\theta}_R$
 - LM wartość $\frac{\partial \ell_i(\tilde{\theta}_R)}{\partial \theta}$ powinna być bliska 0 (wartość gradientu powinna być bliska zeru)
- Dla modeli liniowych

$$LM \leq LR \leq W$$

Testowanie hipotez w MNW



Rysunek: Testy LM, W i LR

- *Efekty cząstkowe* (partial effects) dla zmiennej ciągłej:

$$\frac{\Delta E(y|\mathbf{x})}{\Delta x_k} = \frac{\partial E(y|\mathbf{x})}{\partial x_k}$$

- Wielkość efektu cząstkowego zależy od wielkości \mathbf{x}
- Zazwyczaj liczymy go dla średnich wartości zmiennych egzogenicznych albo jako średnią wyliczoną dla obserwacji w próbie (APE - Average Partial Effect)

$$APE = \frac{1}{n} \sum_{i=1}^n \frac{\partial E(y_i|\mathbf{x}_i)}{\partial x_k}$$

- Dla zero-jedynkowej zmiennej objaśniającej x_k efekt krańcowy definiuje się jako:

$$\Delta E(y|\mathbf{x}) = E(y|\bar{\mathbf{x}}_{k1}) - E(y|\bar{\mathbf{x}}_{k0}),$$

gdzie $\mathbf{x}_{k1} = [x_1, \dots, x_{k-1}, 1, x_{k+1}, \dots, x_K]$,

$\mathbf{x}_{k0} = [x_1, \dots, x_{k-1}, 0, x_{k+1}, \dots, x_K]$ lub jako średni efekt cząstkowy:

$$APE = \frac{1}{n} \sum_{i=1}^n [E(y_i|\mathbf{x}_{i,k1}) - E(y_i|\mathbf{x}_{i,k0})]$$

a więc jako różnice między wartościami oczekiwanymi y_i dla danej zerojedynkowej zmiennej objaśniającej równej zero i równej 1.

- W modelach nieliniowych dobrze interpretowalne są zazwyczaj jedynie wielkości efektów cząstkowych
- Oszacowanych współczynników w różnych modelach nieliniowych o tej samej zmiennej zależnej i zmiennych niezależnych nie można zazwyczaj porównywać.
- Porównywać można efekty cząstkowe.

- W wielu zastosowaniach ekonomicznych forma liniowa modelu nie jest zadowalająca.
- W tych przypadkach możemy posłużyć się *NMNK*.
- Zależność y_i od \mathbf{x}_i w *NMNK* dana jest równaniem:

$$y_i = f(\mathbf{x}_i, \boldsymbol{\theta}) + \varepsilon_i$$

gdzie

$$\varepsilon \sim N(0, \sigma^2 \mathbf{I})$$

a funkcja $f(\mathbf{x}_i, \boldsymbol{\theta})$ jest nieliniowa względem wektora parametrów $\boldsymbol{\theta}$.

- Zauważmy, że błąd losowy jest addytywny.

- Zlogarytmowana funkcja wiarygodności dla tego modelu ma postać

$$\begin{aligned} \ell(\mathbf{y}|\mathbf{X}, \theta, \sigma^2) &= -\left(\frac{n}{2}\right) \ln(2\pi) - \left(\frac{n}{2}\right) \ln(\sigma^2) \\ &\quad - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - f(\mathbf{x}_i, \theta))^2 \end{aligned}$$

- Parametr $\tilde{\theta}$, maksymalizujący funkcję wiarygodności powinien minimalizować sumę kwadratów reszt

$$\min_{\tilde{\theta}} \sum_{i=1}^n (y_i - f(\mathbf{x}_i, \tilde{\theta}))^2 = \min_{\tilde{\theta}} \sum_{i=1}^n e_i^2(\tilde{\theta})$$

gdzie $e_i^2(\tilde{\theta}) = y_i - f(\mathbf{x}_i, \tilde{\theta})$

Przykład: Model CES

- Uogólnieniem modelu Cobba-Douglasa jest model *CES* (**C**onstant **E**lasticity of **S**ubstitution)

$$y = [a_1 x_1^\rho + a_2 x_2^\rho]^{\frac{1}{\rho}}$$

- Funkcja ta sprowadza się do funkcji Cobba-Douglasa dla $\rho \rightarrow 0$ (ale jej szczególnymi przypadkami są także liniowa funkcja produkcji ($\rho = 1$) i Leontiefa ($\rho \rightarrow -\infty$)).

- Jeśli założymy, że funkcja produkcji ma postać funkcji CES to mamy otrzymamy model:

$$y_t = [a_1 x_{1t}^\rho + a_2 x_{2t}^\rho]^{\frac{1}{\rho}} \eta_t$$

po zlogarytmowaniu stronami mamy

$$\ln y_t = \frac{1}{\rho} \ln [a_1 x_{1t}^\rho + a_2 x_{2t}^\rho] + \varepsilon_t$$

i jeśli η_t miało rozkład lognormalny to $\varepsilon_t = \ln(\eta_t)$ ma rozkład normalny, to do estymacji tego modelu można użyć nieliniowej metody najmniejszych kwadratów.

- Z ogólnych własności prawdopodobieństwa

$$\int_{\mathbf{Y}} L(\theta) d\mathbf{y} = 1$$

gdzie \mathbf{Y} zbiorem możliwych wartości \mathbf{y}

- Zauważmy, że

$$\frac{\partial \ell(\theta)}{\partial \theta} = \frac{1}{L(\theta)} \frac{\partial L(\theta)}{\partial \theta}$$

- Jeśli spełnione są warunki regularności

$$\begin{aligned}\frac{\partial}{\partial \theta} \int_{\mathbf{Y}} L(\theta) d\mathbf{y} &= \int_{\mathbf{Y}} \frac{\partial L(\theta)}{\partial \theta} d\mathbf{y} \\ &= \int_{\mathbf{Y}} \frac{\partial \ell(\theta)}{\partial \theta} L(\theta) d\mathbf{y} \\ &= E\left(\frac{\partial \ell(\theta)}{\partial \theta}\right) = 0\end{aligned}$$

ponieważ

$$\frac{\partial}{\partial \theta} \int_{\mathbf{Y}} L(\theta) d\mathbf{y} = \frac{\partial 1}{\partial \theta} = 0$$

- Wariancja pochodnej $\ell(\theta)$ jest równa wartości oczekiwanej Hessianowi $-\ell(\theta)$:

$$\begin{aligned}\frac{\partial^2}{\partial\theta\partial\theta'} \int_{\mathbf{Y}} L(\theta) d\mathbf{y} &= \int_{\mathbf{Y}} \frac{\partial}{\partial\theta} \left(\frac{\partial\ell(\theta)}{\partial\theta} L(\theta) \right) d\mathbf{y} \\ &= \int_{\mathbf{Y}} \frac{\partial^2\ell(\theta)}{\partial\theta\partial\theta'} L(\theta) d\mathbf{y} + \int_{\mathbf{Y}} \frac{\partial\ell(\theta)}{\partial\theta} \frac{\partial L(\theta)}{\partial\theta'} d\mathbf{y} = 0\end{aligned}$$

- Wynika z tego, że:

$$\begin{aligned}\int_{\mathbf{Y}} \frac{\partial \ell(\theta)}{\partial \theta} \frac{\partial L(\theta)}{\partial \theta'} d\mathbf{y} &= \int_{\mathbf{Y}} \frac{\partial \ell(\theta)}{\partial \theta} \frac{\partial \ell(\theta)}{\partial \theta'} L(\theta) d\mathbf{y} \\ &= \text{Var} \left(\frac{\partial \ell(\theta)}{\partial \theta} \right) \\ &= - \int_{\mathbf{Y}} \frac{\partial^2 \ell(\theta)}{\partial \theta \partial \theta'} L(\theta) d\mathbf{y} \\ &= -E \left(\frac{\partial^2 \ell(\theta)}{\partial \theta \partial \theta'} \right) = \mathbf{I}(\theta)\end{aligned}$$

- Rozwinięcie warunków pierwszego rzędu dla θ_{t+1} wokół θ_t ma postać

$$\frac{\partial F(\theta_{t+1})}{\partial \theta_{t+1}} \approx \mathbf{g}_t + \mathbf{H}_t(\theta_{t+1} - \theta_t) = 0$$

gdzie \mathbf{H}_t macierz drugich pochodnych $F(\theta)$ policzona dla θ_t


- Rozwiązując dla θ_{t+1}

$$\theta_{t+1} \approx \theta_t - \mathbf{H}_t^{-1} \mathbf{g}_t$$

- Niech $\mathbf{\Delta}_t = \theta_{t+1} - \theta_t = -\mathbf{H}_t^{-1} \mathbf{g}_t$
- Z rozwinięcia Taylora:

$$\begin{aligned} F(\theta_{t+1}) &= F(\theta_t + \mathbf{\Delta}_t) \approx F(\theta_t) + \mathbf{\Delta}_t' \mathbf{g}_t \\ &= F(\theta_t) - \mathbf{g}_t' \mathbf{H}_t^{-1} \mathbf{g}_t \end{aligned}$$

- Dla ujemnie określonego \mathbf{H}_t (a taki powinien być w otoczeniu maksimum) funkcja celu powinna rosnać w każdym kroku!



Rysunek: Kolejne kroki optymalizacji