

Metoda największej wiarygodności

- Metoda Największej Wiarygodności (MNW) jest bardziej uniwersalną niż MNK metodą szacowania wartości nieznanymi parametrów

- Metoda Największej Wiarygodności (MNW) jest bardziej uniwersalną niż MNK metodą szacowania wartości nieznanymi parametrów
- Wymaga spełnienia założeń, które są mniej restrykcyjne niż założenia MNK

- Metoda Największej Wiarygodności (MNW) jest bardziej uniwersalną niż MNK metodą szacowania wartości nieznanymi parametrów
- Wymaga spełnienia założeń, które są mniej restrykcyjne niż założenia MNK
- Dzięki temu MNW może być wykorzystywana do estymacji szerszej klasy modeli ekonometrycznych

Wiarygodność

Wiarygodność jest to funkcja $\Theta \rightarrow \mathbb{R}$:

$$L(\theta) = f(\theta, x_1, \dots, x_n) = f_{\theta}(x_1, \dots, x_n)$$

Wiarygodność

Wiarygodność jest to funkcja $\Theta \rightarrow \mathbb{R}$:

$$L(\theta) = f(\theta, x_1, \dots, x_n) = f_{\theta}(x_1, \dots, x_n)$$

- W praktyce będziemy dysponowali próbą n obserwacji.
Kluczowym założeniem jest znajomość postaci funkcji $f(\cdot)$

Estymator Metody Największej Wiarygodności

Estymatorem Metody Największej Wiarygodności (MNW) dla wektora nieznanymi parametrów θ , szacowanym na podstawie wartości zmiennej zależnej y i wartości zmiennych niezależnych X , nazywamy

$$\hat{\theta} = \underset{\theta \in \Theta}{\operatorname{argmax}} f_{\theta}(y, X)$$

Estymator Metody Największej Wiarygodności

Estymatorem Metody Największej Wiarygodności (MNW) dla wektora nieznanymi parametrów θ , szacowanym na podstawie wartości zmiennej zależnej y i wartości zmiennych niezależnych X , nazywamy

$$\hat{\theta} = \underset{\theta \in \Theta}{\operatorname{argmax}} f_{\theta}(y, X)$$

- $f(\cdot)$ nazywamy łączną funkcją gęstości prawdopodobieństwa lub funkcją wiarygodności

Estymator Metody Największej Wiarygodności

Estymatorem Metody Największej Wiarygodności (MNW) dla wektora nieznanymi parametrów θ , szacowanym na podstawie wartości zmiennej zależnej y i wartości zmiennych niezależnych X , nazywamy

$$\hat{\theta} = \underset{\theta \in \Theta}{\operatorname{argmax}} f_{\theta}(y, X)$$

- $f(\cdot)$ nazywamy łączną funkcją gęstości prawdopodobieństwa lub funkcją wiarygodności
- Metoda polega na wybraniu takiej wartości parametru θ , który maksymalizuje $f(\cdot)$ dla zaobserwowanych wartości y oraz X

1 Niezależność obserwacji (losowość próby)

- 1 Niezależność obserwacji (losowość próby)
- 2 Identyfikowalność parametrów

- 1 Niezależność obserwacji (losowość próby)
- 2 Identyfikowalność parametrów
- 3 Słaba egzogeniczność

- 1 Niezależność obserwacji (losowość próby)
- 2 Identyfikowalność parametrów
- 3 Słaba egzogeniczność
- 4 Znajomość postaci funkcji wiarygodności

Niezależność obserwacji

- W przypadku danych przekrojowych jest równoważna losowości próby

Niezależność obserwacji

- W przypadku danych przekrojowych jest równoważna losowości próby
- Jeżeli próba przekrojowa nie jest losowa wymagane są dodatkowe założenia

Niezależność obserwacji

- W przypadku danych przekrojowych jest równoważna losowości próby
- Jeżeli próba przekrojowa nie jest losowa wymagane są dodatkowe założenia
- W przypadku danych czasowych zazwyczaj nie da się utrzymać założenia o losowości próby

Niezależność obserwacji

- W przypadku danych przekrojowych jest równoważna losowości próby
- Jeżeli próba przekrojowa nie jest losowa wymagane są dodatkowe założenia
- W przypadku danych czasowych zazwyczaj nie da się utrzymać założenia o losowości próby
- Jednak, w praktyce, założenie o niezależności komplikuje jedynie dowody własności estymatorów

Niezależność obserwacji

- Przy spełnionym założeniu o niezależności funkcję wiarygodności można zapisać jako

$$L_{\theta}(y|X) = f_{\theta}(y|X) = f_{\theta}(y|X_1, \dots, X_n) = \prod_{i=1}^n f_{\theta}(y_i|X_i)$$

Niezależność obserwacji

- Przy spełnionym założeniu o niezależności funkcję wiarygodności można zapisać jako

$$L_{\theta}(y|X) = f_{\theta}(y|X) = f_{\theta}(y|X_1, \dots, X_n) = \prod_{i=1}^n f_{\theta}(y_i|X_i)$$

- Zatem łączna funkcja gęstości jest iloczynem funkcji gęstości dla pojedynczych obserwacji

Identyfikowalność parametrów

- Każdy z parametrów modelu powinien w odmienny sposób wpływać na prawdopodobieństwo zaobserwowania próby

Identyfikowalność parametrów

- Każdy z parametrów modelu powinien w odmienny sposób wpływać na prawdopodobieństwo zaobserwowania próby
- Dzięki tej własności można uzyskać oddzielne oszacowanie dla każdego nieznanego parametru

Identyfikowalność parametrów

- Każdy z parametrów modelu powinien w odmienny sposób wpływać na prawdopodobieństwo zaobserwowania próby
- Dzięki tej własności można uzyskać oddzielne oszacowanie dla każdego nieznanego parametru

Identyfikowalność

Niech θ_0 będzie prawdziwą wielkością wektora parametrów θ .
Wówczas istnieje taki zbiór danych, że

$$\exists (y, X) \forall \theta \neq \theta_0 : L_{\theta_0}(X, y) \neq L_{\theta}(X, y)$$

Identyfikowalność parametrów

- W otoczeniu punktu θ_0 funkcja wiarygodności nie może być lokalnie płaska

Identyfikowalność parametrów

- W otoczeniu punktu θ_0 funkcja wiarygodności nie może być lokalnie płaska
- Prawdopodobieństwo zaobserwowania próby (X,y) dla wektora parametrów θ_0 i dla wektora parametrów θ powinno być różne

Identyfikowalność parametrów

- W otoczeniu punktu θ_0 funkcja wiarygodności nie może być lokalnie płaska
- Prawdopodobieństwo zaobserwowania próby (X,y) dla wektora parametrów θ_0 i dla wektora parametrów θ powinno być różne
- Inaczej mówiąc maksimum funkcji wiarygodności powinno być jednoznacznie określone

Identyfikowalność parametrów - przykład

- Przypuśćmy, że obserwujemy zmienną losową

$$y_i = \begin{cases} y_i = 0 & y_i^* < 0 \\ y_i = 1 & y_i^* > 0 \end{cases}, \text{gdzie } y_i^* \sim \mathcal{N}(\mu, \sigma^2)$$

Identyfikowalność parametrów - przykład

- Przypuśćmy, że obserwujemy zmienną losową

$$y_i = \begin{cases} y_i = 0 & y_i^* < 0 \\ y_i = 1 & y_i^* > 0 \end{cases}, \text{gdzie } y_i^* \sim \mathcal{N}(\mu, \sigma^2)$$

- Zmienną nieobserwowaną y_i^* nazywamy zmienną ukrytą

Identyfikowalność parametrów - przykład

- Przypuśćmy, że obserwujemy zmienną losową

$$y_i = \begin{cases} y_i = 0 & y_i^* < 0 \\ y_i = 1 & y_i^* > 0 \end{cases}, \text{gdzie } y_i^* \sim \mathcal{N}(\mu, \sigma^2)$$

- Zmienną nieobserwowaną y_i^* nazywamy zmienną ukrytą
- Celem jest oszacowanie wartości parametrów rozkładu zmiennej ukrytej

Identyfikowalność parametrów - przykład

- Przypuśćmy, że obserwujemy zmienną losową

$$y_i = \begin{cases} y_i = 0 & y_i^* < 0 \\ y_i = 1 & y_i^* > 0 \end{cases}, \text{gdzie } y_i^* \sim \mathcal{N}(\mu, \sigma^2)$$

- Zmienną nieobserwowaną y_i^* nazywamy zmienną ukrytą
- Celem jest oszacowanie wartości parametrów rozkładu zmiennej ukrytej
- Wiemy, że

$$\Pr(y_i = 0) = \Pr(y_i^* < 0) = \Phi\left(\frac{\mu}{\sigma}\right)$$

$$\Pr(y_i = 1) = \Pr(y_i^* > 0) = 1 - \Phi\left(\frac{\mu}{\sigma}\right)$$

Identyfikowalność parametrów - przykład

- Niech w próbie jest n_0 obserwacji dla których $y_i = 0$, oraz n_1 obserwacji dla których $y_i = 1$

Identyfikowalność parametrów - przykład

- Niech w próbie jest n_0 obserwacji dla których $y_i = 0$, oraz n_1 obserwacji dla których $y_i = 1$
- Wówczas funkcja wiarygodności ma postać

$$L(\mu_0, \sigma_0) = \left[\Phi\left(\frac{\mu_0}{\sigma_0}\right) \right]^{n_0} \left[1 - \Phi\left(\frac{\mu_0}{\sigma_0}\right) \right]^{n_1}$$

Identyfikowalność parametrów - przykład

- Niech w próbie jest n_0 obserwacji dla których $y_i = 0$, oraz n_1 obserwacji dla których $y_i = 1$
- Wówczas funkcja wiarygodności ma postać

$$L(\mu_0, \sigma_0) = \left[\Phi\left(\frac{\mu_0}{\sigma_0}\right) \right]^{n_0} \left[1 - \Phi\left(\frac{\mu_0}{\sigma_0}\right) \right]^{n_1}$$

- Ale połóżmy $\mu^* = \alpha\mu_0$ oraz $\sigma^* = \alpha\sigma_0$ dla dowolnego $\alpha > 0$.
Wówczas

$$L(\mu^*, \sigma^*) = \left[\Phi\left(\frac{\alpha\mu_0}{\alpha\sigma_0}\right) \right]^{n_0} \left[1 - \Phi\left(\frac{\alpha\mu_0}{\alpha\sigma_0}\right) \right]^{n_1} = L(\mu, \sigma)$$

Identyfikowalność parametrów - przykład

- Niech w próbie jest n_0 obserwacji dla których $y_i = 0$, oraz n_1 obserwacji dla których $y_i = 1$
- Wówczas funkcja wiarygodności ma postać

$$L(\mu_0, \sigma_0) = \left[\Phi\left(\frac{\mu_0}{\sigma_0}\right) \right]^{n_0} \left[1 - \Phi\left(\frac{\mu_0}{\sigma_0}\right) \right]^{n_1}$$

- Ale położmy $\mu^* = \alpha\mu_0$ oraz $\sigma^* = \alpha\sigma_0$ dla dowolnego $\alpha > 0$.
Wówczas

$$L(\mu^*, \sigma^*) = \left[\Phi\left(\frac{\alpha\mu_0}{\alpha\sigma_0}\right) \right]^{n_0} \left[1 - \Phi\left(\frac{\alpha\mu_0}{\alpha\sigma_0}\right) \right]^{n_1} = L(\mu, \sigma)$$

- Zatem funkcja nie posiada jednoznacznie wyznaczonego maksimum

Słaba egzogeniczność

- Słaba egzogeniczność w MNK utożsamialiśmy z nieskorelowaniem obserwacji z równoczesnym błędem losowym

Słaba egzogeniczność

- Słaba egzogeniczność w MNK utożsamialiśmy z nieskorelowaniem obserwacji z równoczesnym błędem losowym
- Załóżmy, że wektor parametrów θ można separować na dwie części $\theta = (\Phi, \Psi)$

Słaba egzogeniczność

- Słaba egzogeniczność w MNK utożsamialiśmy z nieskorelowaniem obserwacji z równoczesnym błędem losowym
- Załóżmy, że wektor parametrów θ można separować na dwie części $\theta = (\Phi, \Psi)$
- Załóżmy, że te części są niepowiązane, czyli $\phi \in \Phi, \psi \in \Psi$ to $\theta \in \Phi \times \Psi$

Słaba egzogeniczność

- Słaba egzogeniczność w MNK utożsamialiśmy z nieskorelowaniem obserwacji z równoczesnym błędem losowym
- Załóżmy, że wektor parametrów θ można separować na dwie części $\theta = (\Phi, \Psi)$
- Załóżmy, że te części są niepowiązane, czyli $\phi \in \Phi, \psi \in \Psi$ to $\theta \in \Phi \times \Psi$

Słaba egzogeniczność

Mówimy, że X jest słabo egzogeniczne względem wektora parametrów Ψ jeżeli łączną funkcję gęstości można następująco dekomponować

$$f_{\theta}(y, X) = f_{\Phi}(y, X)f_{\Psi}(X)$$

Słaba egzogeniczność

- Funkcja $f_{\psi}(X)$ opisuje prawdopodobieństwo zaobserwowania wartości zmiennych egzogenicznych i nie ma wpływu na prawdopodobieństwo zaobserwowania konkretnych wartości parametrów modelu

Słaba egzogeniczność

- Funkcja $f_{\psi}(X)$ opisuje prawdopodobieństwo zaobserwowania wartości zmiennych egzogenicznych i nie ma wpływu na prawdopodobieństwo zaobserwowania konkretnych wartości parametrów modelu
- Zatem

$$\max_{\theta} f_{\theta}(y, X) = \max_{\phi} (y, X) + \max_{\psi} (X)$$

Słaba egzogeniczność

- Funkcja $f_{\psi}(X)$ opisuje prawdopodobieństwo zaobserwowania wartości zmiennych egzogenicznych i nie ma wpływu na prawdopodobieństwo zaobserwowania konkretnych wartości parametrów modelu

- Zatem

$$\max_{\theta} f_{\theta}(y, X) = \max_{\phi} (y, X) + \max_{\psi} (X)$$

- Więc estymator MNW można obliczyć jako sumę dwóch oszacowań

Słaba egzogeniczność

- Funkcja $f_{\psi}(X)$ opisuje prawdopodobieństwo zaobserwowania wartości zmiennych egzogenicznych i nie ma wpływu na prawdopodobieństwo zaobserwowania konkretnych wartości parametrów modelu

- Zatem

$$\max_{\theta} f_{\theta}(y, X) = \max_{\phi} (y, X) + \max_{\psi} (X)$$

- Więc estymator MNW można obliczyć jako sumę dwóch oszacowań
- Wniosek: Wartość parametru ϕ można oszacować na podstawie warunkowej funkcji gęstości $f_{\phi}(y|X)$

- W praktyce zamiast funkcji wiarygodności $L(\theta)$ posługujemy się logarytmem funkcji wiarygodności $\ell(\theta)$

- W praktyce zamiast funkcji wiarygodności $L(\theta)$ posługujemy się logarytmem funkcji wiarygodności $\ell(\theta)$
- Jest to uprawnione, ponieważ nie interesuje nas wartość funkcji, a wielkość oszacowań nieznanymi parametrami

- W praktyce zamiast funkcji wiarygodności $L(\theta)$ posługujemy się logarytmem funkcji wiarygodności $\ell(\theta)$
- Jest to uprawnione, ponieważ nie interesuje nas wartość funkcji, a wielkość oszacowań nieznanymi parametrami
- Logarytm jako monotoniczna transformacja zachowuje ekstrema

- W praktyce zamiast funkcji wiarygodności $L(\theta)$ posługujemy się logarytmem funkcji wiarygodności $\ell(\theta)$
- Jest to uprawnione, ponieważ nie interesuje nas wartość funkcji, a wielkość oszacowań nieznanymi parametrami
- Logarytm jako monotoniczna transformacja zachowuje ekstrema
- Jeżeli obserwacje są niezależne to logarytm funkcji wiarygodności dany jest przez

$$\ell_{\theta}(y|X) = \ln \prod_{i=1}^N f_{\theta}(y_i|x_i) = \sum_{i=1}^N \ln f_{\theta}(y_i|x_i) = \sum_{i=1}^N \ln \ell(y_i|X_i;\theta)$$

- W praktyce zamiast funkcji wiarygodności $L(\theta)$ posługujemy się logarytmem funkcji wiarygodności $\ell(\theta)$
- Jest to uprawnione, ponieważ nie interesuje nas wartość funkcji, a wielkość oszacowań nieznanymi parametrami
- Logarytm jako monotoniczna transformacja zachowuje ekstrema
- Jeżeli obserwacje są niezależne to logarytm funkcji wiarygodności dany jest przez

$$\ell_{\theta}(y|X) = \ln \prod_{i=1}^N f_{\theta}(y_i|x_i) = \sum_{i=1}^N \ln f_{\theta}(y_i|x_i) = \sum_{i=1}^N \ln \ell(y_i|X_i;\theta)$$

- Logarytm funkcji gęstości jest sumą logarytmów warunkowych gęstości dla poszczególnych obserwacji

- Estymatory MNW wyznacza się maksymalizując funkcję wiarygodności korzystając z warunków pierwszego i drugiego rzędu na istnienie ekstremum funkcji

- Estymatory MNW wyznacza się maksymalizując funkcję wiarygodności korzystając z warunków pierwszego i drugiego rzędu na istnienie ekstremum funkcji
- Pewien problem może stanowić brak rozwiązań analitycznych

- Estymatory MNW wyznacza się maksymalizując funkcję wiarygodności korzystając z warunków pierwszego i drugiego rzędu na istnienie ekstremum funkcji
- Pewien problem może stanowić brak rozwiązań analitycznych
- Dla programów komputerowych nie stanowi to problemu, gdyż one znajdują pochodne w sposób numeryczny

Przykład

- Znajdź estymatory MNW dla parametrów KMRL

$$y_i = X_i\beta + \varepsilon_i \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2)$$

Przykład

- Znajdź estymatory MNW dla parametrów KMRL

$$y_i = X_i\beta + \varepsilon_i \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2)$$

- Z założeń modelu wynika, że

$$y_i|x_i \sim \mathcal{N}(x_i\beta, \sigma^2)$$

Przykład

- Znajdź estymatory MNW dla parametrów KMRL

$$y_i = X_i\beta + \varepsilon_i \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2)$$

- Z założeń modelu wynika, że

$$y_i|x_i \sim \mathcal{N}(x_i\beta, \sigma^2)$$

- Więc funkcja gęstości dla pojedynczej obserwacji jest dana przez

$$f_{\beta, \sigma^2}(y_i|x_i) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y_i - X_i\beta)^2}{2\sigma^2}\right)$$

Przykład

- Znajdź estymatory MNW dla parametrów KMRL

$$y_i = X_i\beta + \varepsilon_i \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2)$$

- Z założeń modelu wynika, że

$$y_i|x_i \sim \mathcal{N}(x_i\beta, \sigma^2)$$

- Więc funkcja gęstości dla pojedynczej obserwacji jest dana przez

$$f_{\beta, \sigma^2}(y_i|x_i) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y - X_i\beta)^2}{2\sigma^2}\right)$$

- Zatem funkcja wiarygodności ma postać

$$L(\beta, \sigma^2) = \left[\frac{1}{\sqrt{2\pi\sigma^2}}\right]^n \exp\left(-\frac{1}{2\sigma^2}(y - X\beta)'(y - X\beta)\right)$$

Przykład - cd

- A logarytm funkcji wiarygodności

$$\ell(\beta, \sigma^2) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} (y - X_i\beta)'(y - X_i\beta)$$

Przykład - cd

- A logarytm funkcji wiarygodności

$$\ell(\beta, \sigma^2) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} (y - X_i\beta)'(y - X_i\beta)$$

- Zatem warunki pierwszego rzędu dane są przez

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

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

Przykład - cd

- A logarytm funkcji wiarygodności

$$\ell(\beta, \sigma^2) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} (y - X_i\beta)'(y - X_i\beta)$$

- Zatem warunki pierwszego rzędu dane są przez

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

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

- Uwaga: warunki drugiego rzędu wyprowadzimy później

Przykład - cd

- A logarytm funkcji wiarygodności

$$\ell(\beta, \sigma^2) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} (y - X_i\beta)'(y - X_i\beta)$$

- Zatem warunki pierwszego rzędu dane są przez

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

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

- Uwaga: warunki drugiego rzędu wyprowadzimy później
- Wynika z tego, że

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

$$\tilde{\sigma}^2 = \frac{1}{n} (y - X_i\beta)'(y - X_i\beta) = \frac{e'e}{n}$$

Przykład - cd

- WNIOSEK: estymator MNW dla parametru β ma taką samą postać jak estymator MNK; estymatory dla wariancji różnią się

Przykład - cd

- WNIOSEK: estymator MNW dla parametru β ma taką samą postać jak estymator MNK; estymatory dla wariancji różnią się
- Obliczmy wartość oczekiwaną estymatora MNW dla wariancji

$$E(\tilde{\sigma}^2) = E\left(\frac{e'e}{n}\right) = \frac{n-k}{n}E(s^2) = \frac{n-k}{n}\sigma^2 \xrightarrow{n \rightarrow \infty} \sigma^2$$

Przykład - cd

- WNIOSEK: estymator MNW dla parametru β ma taką samą postać jak estymator MNK; estymatory dla wariancji różnią się
- Obliczmy wartość oczekiwaną estymatora MNW dla wariancji

$$E(\tilde{\sigma}^2) = E\left(\frac{e'e}{n}\right) = \frac{n-k}{n}E(s^2) = \frac{n-k}{n}\sigma^2 \xrightarrow{n \rightarrow \infty} \sigma^2$$

- Zatem estymator MWN dla wariancji jest zgodny, ale obciążony w małych próbach

1 Zgodność

- 1 Zgodność
- 2 Asymptotyczna normalność

- 1 Zgodność
- 2 Asymptotyczna normalność
- 3 Asymptotyczna efektywność

Zgodność

Zgodność

Estymator nazywamy zgodnym, gdy

$$\forall \delta > 0 \lim_{n \rightarrow \infty} \Pr(|\hat{\theta} - \theta| < \delta) = 1$$

Zgodność

Zgodność

Estymator nazywamy zgodnym, gdy

$$\forall \delta > 0 \lim_{n \rightarrow \infty} \Pr(|\hat{\theta} - \theta| < \delta) = 1$$

- Inaczej mówiąc estymator dąży według prawdopodobieństwa do prawdziwej wartości parametru, co zapisujemy

$$\hat{\theta} \xrightarrow{P} \theta \quad \text{plim } \hat{\theta} = \theta$$

Zgodność

Zgodność

Estymator nazywamy zgodnym, gdy

$$\forall \delta > 0 \lim_{n \rightarrow \infty} \Pr(|\hat{\theta} - \theta| < \delta) = 1$$

- Inaczej mówiąc estymator dąży według prawdopodobieństwa do prawdziwej wartości parametru, co zapisujemy

$$\hat{\theta} \xrightarrow{P} \theta \quad \text{plim } \hat{\theta} = \theta$$

- Estymator nazywamy zgodnym, gdy wartość oszacowania parametru zbiega do prawdziwej wartości estymatora

Zgodność

Zgodność

Estymator nazywamy zgodnym, gdy

$$\forall \delta > 0 \lim_{n \rightarrow \infty} \Pr(|\hat{\theta} - \theta| < \delta) = 1$$

- Inaczej mówiąc estymator dąży według prawdopodobieństwa do prawdziwej wartości parametru, co zapisujemy

$$\hat{\theta} \xrightarrow{P} \theta \quad \text{plim } \hat{\theta} = \theta$$

- Estymator nazywamy zgodnym, gdy wartość oszacowania parametru zbiega do prawdziwej wartości estymatora
- Bardziej potocznym językiem: jeżeli liczebność próby rośnie to różnica między wartością estymatora a prawdziwą wartością parametru jest nieskończenie bliska 0

Asymptotyczna normalność

- Graniczny (asymptotyczny) rozkład estymatora to rozkład normalny

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{D} \mathcal{N}(0, I^{-1}(\theta))$$

gdzie

$$i(\theta) = \lim_{N \rightarrow \infty} \left[\frac{1}{N} \mathbb{I}(\theta) \right] \text{ oraz } \mathbb{I}(\theta) = \text{var} \left[\frac{\partial \ell(\theta)}{\partial \theta} \right] = -E \left[\frac{\partial^2 \ell(\theta)}{\partial \theta \partial \theta'} \right]$$

jest macierzą informacyjną Fishera

Asymptotyczna normalność

- Macierz informacyjna jest równa wariancji gradientu logarytmu funkcji wiarygodności

Asymptotyczna normalność

- Macierz informacyjna jest równa wariancji gradientu logarytmu funkcji wiarygodności
- lub minus wartości oczekiwanej jej Hessianu

Asymptotyczna normalność - przykład

- Znajdziemy gradient i Hessian dla KMRL

Asymptotyczna normalność - przykład

- Znajdziemy gradient i Hessian dla KMRL
- Gradient jest równy

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

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

Asymptotyczna normalność - przykład

- Wariancja wektora pochodnych względem β wynosi

$$\text{var}\left(\frac{\partial \ell(\beta, \sigma^2)}{\partial \beta}\right) = \frac{1}{\sigma^2} X' \text{var}(\varepsilon) X = \frac{1}{\sigma^2} X' X$$

Asymptotyczna normalność - przykład

- Wariancja wektora pochodnych względem β wynosi

$$\text{var}\left(\frac{\partial \ell(\beta, \sigma^2)}{\partial \beta}\right) = \frac{1}{\sigma^2} X' \text{var}(\varepsilon) X = \frac{1}{\sigma^2} X' X$$

- Wariancja wektora pochodnych względem σ^2 wynosi

$$\text{var}\left(\frac{\partial \ell(\beta, \sigma^2)}{\partial \sigma^2}\right) = \text{var}\left(-\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^2} \varepsilon' \varepsilon\right) = \frac{1}{4\sigma^8} N 2\sigma^4 = \frac{N}{2\sigma^4}$$

Asymptotyczna normalność - przykład

- Wariancja wektora pochodnych względem β wynosi

$$\text{var}\left(\frac{\partial \ell(\beta, \sigma^2)}{\partial \beta}\right) = \frac{1}{\sigma^2} X' \text{var}(\varepsilon) X = \frac{1}{\sigma^2} X' X$$

- Wariancja wektora pochodnych względem σ^2 wynosi

$$\text{var}\left(\frac{\partial \ell(\beta, \sigma^2)}{\partial \sigma^2}\right) = \text{var}\left(-\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^2} \varepsilon' \varepsilon\right) = \frac{1}{4\sigma^8} N 2\sigma^4 = \frac{N}{2\sigma^4}$$

- Ponieważ $E\left(\frac{1}{\sigma^2} X' \varepsilon\right) = 0$, więc kowariancja między pochodnymi wynosi zero

Asymptotyczna normalność - przykład

- Zatem Hessian jest równy

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

Asymptotyczna normalność - przykład

- Te same wyniki uzyskamy obliczając wartości oczekiwane elementów Hessianu

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

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

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

Asymptotyczna efektywność

Twierdzenie Rao-Cramera

Jeżeli estymator $\hat{\theta}$ jest zgodny to jego asymptotyczna wariancja jest nie mniejsza niż dolne ograniczenie Rao-Cramera

$$\lim_{N \rightarrow \infty} \text{var} [\sqrt{n}(\tilde{\theta} - \theta)] \geq i^{-1}(\theta) = \lim_{N \rightarrow \infty} \frac{1}{N} \mathbb{I}(\theta)$$

Asymptotyczna efektywność

Twierdzenie Rao-Cramera

Jeżeli estymator $\hat{\theta}$ jest zgodny to jego asymptotyczna wariancja jest nie mniejsza niż dolne ograniczenie Rao-Cramera

$$\lim_{N \rightarrow \infty} \text{var} [\sqrt{n}(\tilde{\theta} - \theta)] \geq i^{-1}(\theta) = \lim_{N \rightarrow \infty} \frac{1}{N} \mathbb{I}(\theta)$$

- Estymatory MNW są asymptotycznie efektywne ponieważ ich wariancja zbiega do dolnego ograniczenia Rao-Cramera

Asymptotyczna efektywność

Twierdzenie Rao-Cramera

Jeżeli estymator $\hat{\theta}$ jest zgodny to jego asymptotyczna wariancja jest nie mniejsza niż dolne ograniczenie Rao-Cramera

$$\lim_{N \rightarrow \infty} \text{var} [\sqrt{n}(\tilde{\theta} - \theta)] \geq i^{-1}(\theta) = \lim_{N \rightarrow \infty} \frac{1}{N} \mathbb{I}(\theta)$$

- Estymatory MNW są asymptotycznie efektywne ponieważ ich wariancja zbiega do dolnego ograniczenia Rao-Cramera
- Zatem estymatory MNW są estymatorami zgodnymi o minimalnej wariancji

- Na podstawie własności estymatorów MNW można wyprowadzić rozkłady statystyk testowych dla ogólnych hipotez

- Na podstawie własności estymatorów MNW można wyprowadzić rozkłady statystyk testowych dla ogólnych hipotez
- Zakładamy, że hipoteza ma postać (nie)liniowego układu równań

$$H_0 : \begin{cases} h_1(\theta) = 0 \\ \vdots \\ h_q(\theta) = 0 \end{cases}$$

- Na podstawie własności estymatorów MNW można wyprowadzić rozkłady statystyk testowych dla ogólnych hipotez
- Zakładamy, że hipoteza ma postać (nie)liniowego układu równań

$$H_0 : \begin{cases} h_1(\theta) = 0 \\ \vdots \\ h_q(\theta) = 0 \end{cases}$$

- Przyjmując $h(\theta) = (h_1(\theta), \dots, h_q(\theta))$ zapisujemy układ

$$H_0 : h(\theta) = 0$$

- Na podstawie własności estymatorów MNW można wyprowadzić rozkłady statystyk testowych dla ogólnych hipotez
- Zakładamy, że hipoteza ma postać (nie)liniowego układu równań

$$H_0 : \begin{cases} h_1(\theta) = 0 \\ \vdots \\ h_q(\theta) = 0 \end{cases}$$

- Przyjmując $h(\theta) = (h_1(\theta), \dots, h_q(\theta))$ zapisujemy układ

$$H_0 : h(\theta) = 0$$

- Hipotezy należy sformułować w taki sposób, aby macierz pierwszych pochodnych $h'(\theta) = \frac{\partial h(\theta)}{\partial \theta}$ miała pełen rząd

- Jest to w praktyce najłatwiejszy do przeprowadzenia test

- Jest to w praktyce najłatwiejszy do przeprowadzenia test
- Ale wymaga oszacowania dwóch modeli

- Jest to w praktyce najłatwiejszy do przeprowadzenia test
- Ale wymaga oszacowania dwóch modeli
- Weryfikowane jest J ograniczeń

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

- $\ell(\tilde{\theta})$ jest logarytmem funkcji wiarygodności dla modelu bez ograniczeń
- $\ell(\tilde{\theta}_R)$ jest logarytmem funkcji wiarygodności dla modelu ze spełnionymi ograniczeniami

- Idea testu bazuje na spostrzeżeniu, iż łatwiej jest zmaksymalizować funkcję bez ograniczeń, niż z narzuconymi na parametry restrykcjami

- Idea testu bazuje na spostrzeżeniu, iż łatwiej jest zmaksymalizować funkcję bez ograniczeń, niż z narzuconymi na parametry restrykcjami
- Nazwa testu wywodzi się z faktu, że statystykę testową można zapisać jako

$$LR = 2 \ln \left(\frac{L(\tilde{\theta})}{L(\tilde{\theta}_R)} \right)$$

- Idea testu bazuje na spostrzeżeniu, iż łatwiej jest zmaksymalizować funkcję bez ograniczeń, niż z narzuconymi na parametry restrykcjami
- Nazwa testu wywodzi się z faktu, że statystykę testową można zapisać jako

$$LR = 2 \ln \left(\frac{L(\tilde{\theta})}{L(\tilde{\theta}_R)} \right)$$

- Wadą testu jest konieczność oszacowania dwóch modeli

- Do obliczenia wartości statystyki Walda wystarczająca jest znajomość oszacowań modelu bez narzuconych ograniczeń

$$W = h'(\theta) [H(\theta) \mathbb{I}^{-1}(\theta) H'(\theta)]^{-1} h(\theta) \xrightarrow{D} \chi^2_J$$

- Do obliczenia wartości statystyki Walda wystarczająca jest znajomość oszacowań modelu bez narzuconych ograniczeń

$$W = h'(\theta) [H(\theta) \mathbb{I}^{-1}(\theta) H'(\theta)]^{-1} h(\theta) \xrightarrow{D} \chi^2_J$$

- Macierz w nawiasach kwadratowych jako macierz wariancji jest dodatnio określona

- Do obliczenia wartości statystyki Walda wystarczająca jest znajomość oszacowań modelu bez narzuconych ograniczeń

$$W = h'(\theta) [H(\theta) \mathbb{I}^{-1}(\theta) H'(\theta)]^{-1} h(\theta) \xrightarrow{D} \chi_J^2$$

- Macierz w nawiasach kwadratowych jako macierz wariancji jest dodatnio określona
- Zatem statystyka $W = 0$, gdy ograniczenia narzucone na parametry są spełnione

- Do obliczenia wartości statystyki Walda wystarczająca jest znajomość oszacowań modelu bez narzuconych ograniczeń

$$W = h'(\theta) [H(\theta) \mathbb{I}^{-1}(\theta) H'(\theta)]^{-1} h(\theta) \xrightarrow{D} \chi^2_J$$

- Macierz w nawiasach kwadratowych jako macierz wariancji jest dodatnio określona
- Zatem statystyka $W = 0$, gdy ograniczenia narzucone na parametry są spełnione
- Statystyka Walda nie jest niezmiennicza ze względu na sposób zapisania hipotezy zerowej

- Statystyka mnożników Lagrangea wymaga znajomości estymatora dla modelu z narzuconymi ograniczeniami

$$LM = \frac{\partial \ell(\theta)}{\partial \theta} \Big|_{\theta=\theta_R} \mathbb{I}^{-1}(\theta_R) \frac{\partial \ell(\theta)}{\partial \theta} \Big|_{\theta=\theta_R} \xrightarrow{D} \chi^2_J$$

- Statystyka mnożników Lagrangea wymaga znajomości estymatora dla modelu z narzuconymi ograniczeniami

$$LM = \frac{\partial \ell(\theta)}{\partial \theta} \Big|_{\theta=\theta_R} \mathbb{I}^{-1}(\theta_R) \frac{\partial \ell(\theta)}{\partial \theta} \Big|_{\theta=\theta_R} \xrightarrow{D} \chi^2_J$$

- Dla maksimum bez ograniczeń wartość gradientu wynosi zero

- Statystyka mnożników Lagrangea wymaga znajomości estymatora dla modelu z narzuconymi ograniczeniami

$$LM = \frac{\partial \ell(\theta)}{\partial \theta} \Big|_{\theta=\theta_R} \mathbb{I}^{-1}(\theta_R) \frac{\partial \ell(\theta)}{\partial \theta} \Big|_{\theta=\theta_R} \xrightarrow{D} \chi^2_J$$

- Dla maksimum bez ograniczeń wartość gradientu wynosi zero
- Zatem wartość gradientu niesie informację o spełnieniu ograniczeń przez parametry modelu

- W modelach szacowanych MNW nie są szacowane sumy kwadratów

- W modelach szacowanych MNW nie są szacowane sumy kwadratów
- Miary dopasowania są przybliżonymi statystykami określanymi jako pseudo- R^2

- W modelach szacowanych MNW nie są szacowane sumy kwadratów
- Miary dopasowania są przybliżonymi statystykami określanymi jako pseudo- R^2
- Najczęściej stosowaną miarą jest R^2 Mc-Faddena

$$R_{McFadden}^2 = 1 - \frac{\ell(\theta)}{\ell(\theta_0)}$$

- W modelach szacowanych MNW nie są szacowane sumy kwadratów
- Miary dopasowania są przybliżonymi statystykami określanymi jako pseudo- R^2
- Najczęściej stosowaną miarą jest R^2 Mc-Faddena

$$R_{McFadden}^2 = 1 - \frac{\ell(\theta)}{\ell(\theta_0)}$$

- Podobnie jak $adj - R^2$ istnieje

$$\bar{R}_{McFadden}^2 = 1 - \frac{\ell(\theta) - K}{\ell(\theta_0)}$$

gdzie L_0 to logarytm funkcji wiarygodności modelu ze stałą jako jedyną zmienną objaśniającą