

Základy ekonometrie

V. Uvolnění klasických předpokladů – heteroskedasticita

Obsah tématu

- 1 Nenulová střední hodnota náhodné složky
- 2 Nenormalita
 - Testování
 - Řešení nenormality
- 3 Heteroskedasticita
 - Příčiny heteroskedasticity
 - Důsledky heteroskedasticity na OLS estimátor
 - Řešení heteroskedasticity při známém rozptylu
 - Řešení heteroskedasticity při neznámém rozptylu
 - Testování heteroskedasticity

- Doposud:

$$Y_i = \alpha + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \epsilon_i.$$

- Klasické předpoklady:

- 1 $E(\epsilon_i) = 0$.
- 2 $var(\epsilon_i) = \sigma^2$.
- 3 $cov(\epsilon_i, \epsilon_j) = 0$ pro $i \neq j$.
- 4 ϵ_i má normální rozdělení.
- 5 Vysvětlující proměnné jsou fixní, tedy nenáhodné veličiny.

Teorie vs. realita

- Zcela dokonalé modely, techniky a data k dispozici nemáme.
- Teoretické předpoklady tak obvykle neodpovídají realitě používaných dat a modelů.



Obsah tématu

- 1 Nenulová střední hodnota náhodné složky
- 2 Nenormalita
 - Testování
 - Řešení nenormality
- 3 Heteroskedasticita
 - Příčiny heteroskedasticity
 - Důsledky heteroskedasticity na OLS estimátor
 - Řešení heteroskedasticity při známém rozptylu
 - Řešení heteroskedasticity při neznámém rozptylu
 - Testování heteroskedasticity

Úvod

- Předpoklad, že pracujeme se správným modelem.

$$E(Y_i) = \alpha + \beta_1 X_{1i} + \dots + \beta_k X_{ki}.$$

- Vždy splněno, pokud je v modelu úrovněová konstanta.
- V opačném případě:
 - Koeficient determinace, $1 - \frac{SSR}{TSS}$, i negativní.
 - Zkreslení odhadu parametrů + koeficient determinace ztrácí na svém původním významu → střední hodnota (výběrový průměr) závisle proměnné \neq průměru (střední hodnotě) vyrovnaných hodnot modelu ($TSS \neq RSS + SSR$).

Obsah tématu

- 1 Nenulová střední hodnota náhodné složky
- 2 **Nenormalita**
 - Testování
 - Řešení nenormality
- 3 Heteroskedasticita
 - Příčiny heteroskedasticity
 - Důsledky heteroskedasticity na OLS estimátor
 - Řešení heteroskedasticity při známém rozptylu
 - Řešení heteroskedasticity při neznámém rozptylu
 - Testování heteroskedasticity

Úvod

- Lze aproximativně uvolnit (asymptotická teorie).
- $\hat{\beta}$ aproximativně rozdělen podle $N(\beta, \frac{\sigma^2}{\sum X_i^2})$.
- Problém při práci s malými vzorky.

Obsah tématu

1 Nenulová střední hodnota náhodné složky

2 **Nenormalita**

- **Testování**

- Řešení nenormality

3 Heteroskedasticita

- Příčiny heteroskedasticity

- Důsledky heteroskedasticity na OLS estimátor

- Řešení heteroskedasticity při známém rozptylu

- Řešení heteroskedasticity při neznámém rozptylu

- Testování heteroskedasticity

Jarqueův-Berův test

- Koeficienty šikmosti a špičatosti.


$$skew = \frac{E(\epsilon^3)}{(\sigma^2)^{3/2}} \quad kurt = \frac{E(\epsilon^4)}{(\sigma^2)^2}.$$

- H_0 : výběr z normálního rozdělení:

$$JB = N \left[\frac{skew^2}{6} + \frac{(kurt - 3)^2}{24} \right] \sim \chi_2^2.$$


- $\hat{\sigma}^2 \rightarrow$ odhady šikmosti a špičatosti, \widehat{skew} resp. \widehat{kurt} (ML odhad $\frac{1}{N} \sum \hat{\epsilon}_i^2$).

Příklad – šikmost



Zdroj: Gujarati, Porter (2009) – Basic econometrics.

Příklad – špičatost



Zdroj: Gujarati, Porter (2009) – Basic econometrics.

Obsah tématu

- 1 Nenulová střední hodnota náhodné složky
- 2 **Nenormalita**
 - Testování
 - **Řešení nenormality**
- 3 Heteroskedasticita
 - Příčiny heteroskedasticity
 - Důsledky heteroskedasticity na OLS estimátor
 - Řešení heteroskedasticity při známém rozptylu
 - Řešení heteroskedasticity při neznámém rozptylu
 - Testování heteroskedasticity

Metoda maximální věrohodnosti

- „Nenormální“ věrohodnostní funkce – např. t -rozdělení (tlustší konce).
- Aplikace ve finančních – pozorování větší volatility výnosnosti aktiv než podle normálního rozdělení.
- Obecně preference OLS odhadu – dobře rozebrány vlastnosti.

Odlehlá pozorování (outliers)

- Odstranění vlivu odlehlých pozorování (pomocí umělých proměnných) × umělé zlepšení charakteristik modelu + každé pozorování je částí informace.
- Příklad: rezidua z analýzy časové řady cen akcií 1980-1990; extrémní výchylka v říjnu 1987.

$$Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_3 D_{1i} + \epsilon_i.$$

- D_1 hodnota 1 pouze pro pozorování v říjnu 1987 → jako odstranění proměnné (výsledné reziduum pro toto pozorování nulové).
- Pokud umělá proměnná – nutno věcně zdůvodnit (např. černé úterý v říjnu 1987).

Obsah tématu

- 1 Nenulová střední hodnota náhodné složky
- 2 Nenormalita
 - Testování
 - Řešení nenormality
- 3 Heteroskedasticita
 - Příčiny heteroskedasticity
 - Důsledky heteroskedasticity na OLS estimátor
 - Řešení heteroskedasticity při známém rozptylu
 - Řešení heteroskedasticity při neznámém rozptylu
 - Testování heteroskedasticity

Úvod

- Heteroskedasticita = rozptyl náhodných složek se liší v rámci jednotlivých pozorování.
- Existence heteroskedasticity:

$$\text{var}(\epsilon_i) = \sigma^2 \omega_i^2.$$

- Maticově, kovarianční matice náhodných složek:

$$\text{var}(\epsilon) = \sigma^2 \begin{pmatrix} \omega_1^2 & 0 & 0 & \dots & 0 \\ 0 & \omega_2^2 & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & \omega_N^2 \end{pmatrix} = \sigma^2 \Omega.$$


On Heteros*edasticity

- J. Huston McCulloch (1985): „On Heteros*edasticity,“ *Econometrica*, Vol. 53, No. 2, (Mar. 1985), p. 483.
- Psaní s „c“ nebo „k“? (hlavní problém ekonometrické ortografie dané doby).
- Z řečtiny: hetero- (ἕτερο-) = „jiný“, „odlišný“ a skedannumi (σκεδάω) = „rozptýlit“.
- Otázka transkripce řeckého κ do angličtiny.
- Obvykle jako k : skeptic (σκεπτικός), skeleton (σκελετός).
- Někdy jako c (pokud přes Francii nebo z vědeckého světa z latiny): sceptre (σκηπτρον), scene (σκηνή), cyclic (κυκλικός).

On Heteros*edasticity – závěr


- Ve francouzštině nebo latině: $\kappa \rightarrow c$ (k obvykle nepoužívané).
- Angličtina, francouzština, latina: c před e vždy měkké (ceremony, cease, cell, cent, center).
- Údajná výjimka: „Celtic“ – chybná výslovnost [keltik]! (z Francie (celtique), ne přímo z řečtiny nebo nepřímo z němčiny).
- Pokud „heteroscedasticity“: do angličtiny buď v 1066 s invazí Normanů nebo ve středověku z latiny \rightarrow výslovnost [heterossedasticity].
- Pravopisně správné tedy „heteroskedasticity“.

Homoskedastické rozdělení



Zdroj: Gujarati, Porter (2009) – Basic econometrics.

Heteroskedastické rozdělení



Zdroj: Gujarati, Porter (2009) – Basic econometrics.


Obsah tématu

- 1 Nenulová střední hodnota náhodné složky
- 2 Nenormalita
 - Testování
 - Řešení nenormality
- 3 Heteroskedasticita
 - Příčiny heteroskedasticity
 - Důsledky heteroskedasticity na OLS estimátor
 - Řešení heteroskedasticity při známém rozptylu
 - Řešení heteroskedasticity při neznámém rozptylu
 - Testování heteroskedasticity

1. Error-learning errors

- Lidé se učením dopouštějí menšího množství chyb.
- Rozptyl, σ_i^2 , klesá.
- Příklad: počet chyb při psaní na stroji v závislosti na počtu hodin strávených tréninkem.

Příklad – psaní na stroji



Zdroj: Gujarati, Porter (2009) – Basic econometrics.

2. Růst důchodu

- Růst příjmů → větší volnost s nakládáním.
- σ_i^2 roste s růstém důchodu.
- Příklad: regrese úspor na důchod, variabilita v dividendové politice firem s růstem jejich velikostí, růstově orientované × ustálené firmy a výplata dividend.


3. Zlepšení techniky sběru dat

- Pokles σ_i^2 .
- Příklad: bankovní data, kdy banky s dobrým systémem sběru dat mají při prezentaci měsíčních nebo čtvrtletních záznamů o zákaznících nižší chybu měření.

4. Přítomnost odlehlých hodnot

- Obecně: *outlier* je pozorování z jiné populace než té generované ve zbytku vzorku.
- Ovlivnění hlavně u malých vzorků.
- Příklad: procentní změna cen akcií (Y) a spotřebitelských cen (X) pro poválečné období do roku 1969 pro 20 zemí (odlehlé hodnoty pro Chile).

Příklad – odlehlá hodnota




Zdroj: Gujarati, Porter (2009) – Basic econometrics.


5. Nekorektní specifikace modelu

- Nezahrnutí důležitých vysvětlujících proměnných.
- Příklad 1: poptávková funkce po nějaké komoditě a nezahrnutí cen komplementů či substitutů.
- Příklad 2: vliv výdajů na reklamní kampaň (X) na příslušné veličiny (např. tržby, Y) – prostá regrese (a) a zahrnutí X^2 (b).

Příklad – efekt výdajů na reklamu



(a)



(b)

Zdroj: Gujarati, Porter (2009) – Basic econometrics.

6. Rozdělení jedné nebo více vysvětlujících proměnných

- Vliv šikmosti rozdělení.
- Příklad: důchod, bohatství, vzdělání.

7. Použitá data a funkční tvar

- Chybná transformace dat (poměr, první diference).
- Nekorektní funkční podoba (lineární vs. log-lineární modely).

Obsah tématu

- 1 Nenulová střední hodnota náhodné složky
- 2 Nenormalita
 - Testování
 - Řešení nenormality
- 3 Heteroskedasticita
 - Příčiny heteroskedasticity
 - **Důsledky heteroskedasticity na OLS estimátor**
 - Řešení heteroskedasticity při známém rozptylu
 - Řešení heteroskedasticity při neznámém rozptylu
 - Testování heteroskedasticity

Nestrannost

- Rozptyl v důkazu nestrannosti OLS estimátoru nevystupuje \rightarrow OLS odhad zůstává nestranným.
- Např. pro jednoduchý regresní model (při splnění klasických předpokladů):

$$Y_i = \beta X_i + \epsilon_i,$$

$$\hat{\beta} = \frac{\sum X_i Y_i}{\sum X_i^2} = \beta + \frac{\sum X_i \epsilon_i}{\sum X_i^2},$$

$$\hat{\beta} \sim N\left(\beta, \frac{\sigma^2}{\sum X_i^2}\right).$$

Vydatnost

- OLS odhad není vydatný (OLS estimátor není BLUE).

$$\text{var}(\hat{\beta}) = \frac{\sigma^2 \sum X_i^2 \omega_i^2}{(\sum X_i^2)^2}.$$

- Důkaz:

$$\begin{aligned} \text{var}(\hat{\beta}) &= \text{var}\left(\beta + \frac{\sum X_i \epsilon_i}{\sum X_i^2}\right) = \text{var}\left(\frac{\sum X_i \epsilon_i}{\sum X_i^2}\right) \\ &= \frac{1}{(\sum X_i^2)^2} \text{var}\left(\sum X_i \epsilon_i\right) = \frac{1}{(\sum X_i^2)^2} \sum X_i^2 \text{var}(\epsilon_i) \\ &= \frac{\sigma^2}{(\sum X_i^2)^2} \sum X_i^2 \omega_i^2. \end{aligned}$$

- Odhad rozptylu vstupuje do konstrukce intervalů spolehlivosti a testování hypotéz \Rightarrow nekorektnost výsledků s využitím OLS odhadu.

Obsah tématu

- 1 Nenulová střední hodnota náhodné složky
- 2 Nenormalita
 - Testování
 - Řešení nenormality
- 3 Heteroskedasticita
 - Příčiny heteroskedasticity
 - Důsledky heteroskedasticity na OLS estimátor
 - **Řešení heteroskedasticity při známém rozptylu**
 - Řešení heteroskedasticity při neznámém rozptylu
 - Testování heteroskedasticity

Transformace modelu

- Původní model (pro $i = 1, \dots, N$):

$$Y_i = \beta X_i + \epsilon_i,$$

- Transformovaný model vydělením obou stran rovnice členy ω_i :

$$\frac{Y_i}{\omega_i} = \beta \frac{X_i}{\omega_i} + \frac{\epsilon_i}{\omega_i}.$$

- Tedy:

$$Y_i^* = \beta X_i^* + \epsilon_i^*,$$

Zobecněná metoda nejmenších čtverců

- Nový model splňuje klasické předpoklady.

$$\begin{aligned} \text{var}(\epsilon_i^*) &= \text{var}\left(\frac{\epsilon_i}{\omega_i}\right) = \frac{1}{\omega_i^2} \text{var}(\epsilon_i) \\ &= \frac{\sigma^2 \omega_i^2}{\omega_i^2} = \sigma^2. \end{aligned}$$

- Použití OLS estimátoru na transformovaný model – GLS estimátor:

$$\hat{\beta}_{GLS} = \frac{\sum X_i^* Y_i^*}{\sum X_i^{*2}}.$$

- S původními daty:

$$\hat{\beta}_{GLS} = \frac{\sum \frac{X_i Y_i}{\omega_i \omega_i}}{\sum \left(\frac{X_i}{\omega_i}\right)^2} = \frac{\sum \frac{X_i Y_i}{\omega_i^2}}{\sum \frac{X_i^2}{\omega_i^2}}.$$

Zobecněná metoda nejmenších čtverců – maticově

- Původní model: $Y = X\beta + \epsilon$, kde $\epsilon \sim N(0_N, \sigma^2\Omega)$.

$$\Omega^{-1} = P'P \quad P = \begin{pmatrix} \frac{1}{\omega_1} & 0 & 0 & \dots & 0 \\ 0 & \frac{1}{\omega_2} & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & \frac{1}{\omega_N} \end{pmatrix},$$

$$PY = PX\beta + P\epsilon,$$

$$\begin{aligned} \hat{\beta}_{GLS} &= ((PX)'PX)^{-1}(PX)'PY = (X'P'PX)^{-1}X'P'PY \\ &= (X'\Omega^{-1}X)^{-1}X'\Omega^{-1}Y, \end{aligned}$$

$$\text{var}(P\epsilon) = P'P\text{var}(\epsilon) = \Omega^{-1}\sigma^2\Omega = \sigma^2I_N.$$

- Pro případ heteroskedasticity: GLS estimátor = WLS estimátor (Weighted Least Squares).

Zobecněná metoda nejmenších čtverců – závěr

- Transformovaný model splňuje klasické předpoklady.
- OLS estimátor pro transformovaný model (GLS estimátor) dle Gaussova-Markovova teorému BLUE.
- GLS estimátor je nestranný s rozptylem

$$\text{var}(\hat{\beta}_{GLS}) = \frac{\sigma^2}{\sum X_i^{*2}} = \frac{\sigma^2}{\sum \left(\frac{X_i^2}{\omega_i^2} \right)}.$$

- Rozptyl OLS estimátoru:

$$\text{var}(\hat{\beta}) = \frac{\sigma^2 \sum X_i^2 \omega_i^2}{(X_i^2)^2}.$$

- Pro konstrukci intervalů spolehlivosti a testování hypotéz:

$$\hat{\beta}_{GLS} \sim N \left(\beta, \frac{\sigma^2}{\sum X_i^{*2}} \right).$$

Obsah tématu

- 1 Nenulová střední hodnota náhodné složky
- 2 Nenormalita
 - Testování
 - Řešení nenormality
- 3 Heteroskedasticita
 - Příčiny heteroskedasticity
 - Důsledky heteroskedasticity na OLS estimátor
 - Řešení heteroskedasticity při známém rozptylu
 - **Řešení heteroskedasticity při neznámém rozptylu**
 - Testování heteroskedasticity

Úvod

- Heteroskedasticita v důsledku jedné nebo kombinace více vysvětlujících proměnných.

$$Y_i = \alpha + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \epsilon_i$$

- Splněny klasické předpoklady, s výjimkou:

$$\text{var}(\epsilon_i) = \sigma^2 \omega_i^2 = \sigma^2 f(Z_i),$$

- Z je některá z vysvětlujících proměnných a $f(\cdot)$ je kladná funkce.
- Obvyklá volba:

$$f(Z_i) = Z_i^2 \quad \text{nebo} \quad f(Z_i) = \frac{1}{Z_i^2}.$$

- Další volba: $f(Z_i) = \exp(Z_i)$ nebo $f(Z_i) = \exp(-Z_i)$.

Zobecněná metoda nejmenších čtverců

- GLS:

$$\frac{Y_i}{\omega_i} = \alpha \left(\frac{1}{\omega_i} \right) + \beta_1 \left(\frac{X_{1i}}{\omega_i} \right) + \dots + \beta_k \left(\frac{X_{ki}}{\omega_i} \right) + \left(\frac{\epsilon_i}{\omega_i} \right).$$

- Předpoklad: $\omega_i^2 = f(Z_i) \rightarrow$ snadná transformace.
- Např. pro $f(Z_i) = Z_i^2$

$$\frac{Y_i}{Z_i} = \alpha \left(\frac{1}{Z_i} \right) + \beta_1 \left(\frac{X_{1i}}{Z_i} \right) + \dots + \beta_k \left(\frac{X_{ki}}{Z_i} \right) + \left(\frac{\epsilon_i}{Z_i} \right).$$

- Pokud $f(Z_i) = \frac{1}{Z_i^2}$:

$$Y_i Z_i = \alpha Z_i + \beta_1 X_{1i} Z_i + \dots + \beta_k X_{ki} Z_i + \epsilon_i Z_i.$$

- Experimentování s funkční podobou a testování potenciálního řešení problému.
- Někdy řešení logaritmování proměnných.

Heteroskedasticitě konzistentní estimátor

- Pokud nedokážeme (nechceme) použít GLS.
- Správný vzorec pro rozptyl odhadu parametru: $var(\hat{\beta}) = \frac{\sigma^2 \sum X_i^2 \omega_i^2}{(\sum X_i^2)^2}$.
- Využití OLS estimátoru a správný vztah \times neznáme $\sigma^2 \omega_i^2 \rightarrow$ odhad.
- Intuice: $var(\epsilon_i) = E(\epsilon_i^2) = \sigma^2 \omega_i^2$. \rightarrow OLS estimátor dává $\hat{\epsilon}_i$ pro $i = 1, \dots, N$.
- $\hat{\epsilon}_i^2 \neq \epsilon_i^2$ ani $E(\hat{\epsilon}_i^2)$ ($\hat{\epsilon}_i^2$ je dobrým estimátorem $E(\epsilon_i^2)$) a tedy $\sigma^2 \omega_i^2$):

$$\widehat{var(\hat{\beta})} = \frac{\sum X_i^2 \hat{\epsilon}_i^2}{(\sum X_i^2)^2}$$

- Příklad HCE (Whiteův estimátor).
- Různé HCE estimátory, obecně pro model vícenásobné regrese.
- OLS není vydatný \times HCE odhady vedou k širším intervalům spolehlivosti (konzervativní odhad rozptylu odhadu parametrů).

Jiné estimátory

- Řada možností, obvykle využití OLS odhadů reziduí pro odhad rozptylů náhodných složek.
- Feasible GLS estimátor: pokud známe podobu heteroskedasticity $\rightarrow \text{var}(\epsilon_i) = \sigma^2 \omega_i^2 = \sigma^2 f(Z_i)$.

$$\hat{\beta}_{FGLS} = \frac{\sum \frac{X_i Y_i}{\hat{\omega}_i^2}}{\sum \frac{X_i^2}{\hat{\omega}_i^2}}.$$

- Při známé heteroskedasticitě i ML odhady.

FGLS – rozšíření

- OLS odhad regresního modelu \rightarrow regrese čtverce OLS reziduí na (kladnou) funkci některých nebo všech vysvětlujících proměnných.
- Získané vyrovnané hodnoty = odhad jednotlivých rozptylů náhodných složek.
- Transformace modelu a aplikace OLS = FGLS.
- Obvykle:

$$\text{var}(\epsilon_i) = \sigma^2 \omega_i^2 = \exp(\alpha_0 + \alpha_1 Z_{1i} + \alpha_p Z_{pi}).$$

- Potom regrese

$$\ln(\hat{\epsilon}_i^2) = \alpha_0 + \alpha_1 Z_{1i} + \alpha_p Z_{pi} + \nu_i,$$

kde ν_i je náhodná složka s obvyklými vlastnostmi.

- Odhad OLS parametrů \rightarrow odhady rozptylů

$$\widehat{\text{var}}(\epsilon_i) = \exp(\hat{\alpha}_0 + \hat{\alpha}_1 Z_{1i} + \hat{\alpha}_p Z_{pi}).$$

- Transformace původních proměnných modelu a aplikace OLS.

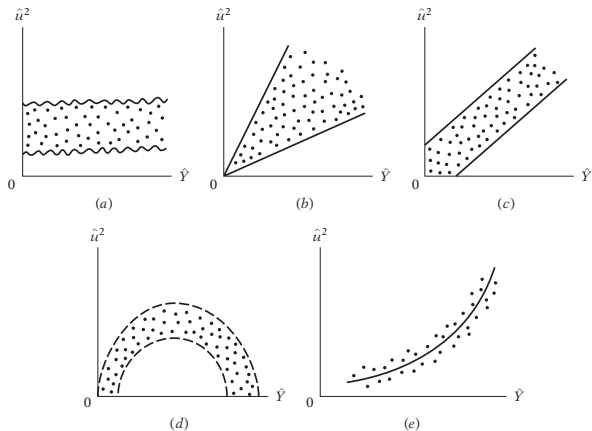
Obsah tématu

- 1 Nenulová střední hodnota náhodné složky
- 2 Nenormalita
 - Testování
 - Řešení nenormality
- 3 **Heteroskedasticita**
 - Příčiny heteroskedasticity
 - Důsledky heteroskedasticity na OLS estimátor
 - Řešení heteroskedasticity při známém rozptylu
 - Řešení heteroskedasticity při neznámém rozptylu
 - **Testování heteroskedasticity**

Grafické metody

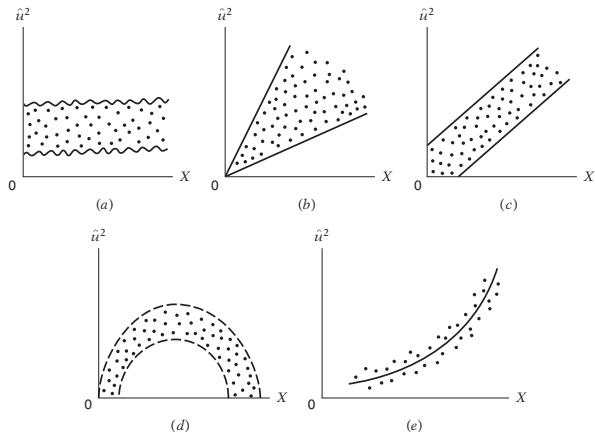
- Analýza čtverců reziduí (jako aproximace čtverců náhodných složek), jestli vykazují systematické chování.
- Vykreslení vzhledem k vyrovnaným hodnotám, \hat{Y}_i .
- Vykreslení vzhledem k jedné z vysvětlujících proměnných, X_i .

Grafické metody – obrázek 1



Zdroj: Gujarati, Porter (2009) – Basic econometrics.

Grafické metody – obrázek 2



Zdroj: Gujarati, Porter (2009) – Basic econometrics.

Parkův test

- Formalizace grafické metody.
- Předpoklad, že σ_i^2 je funkcí X_i , konkrétně:

$$\sigma_i^2 = \sigma^2 X_i^\beta e^{\nu_i}$$

nebo

$$\ln \sigma_i^2 = \ln \sigma^2 + \beta \ln X_i + \nu_i.$$

- Obecně σ_i^2 neznámý \rightarrow použití proxy proměnné čtverec reziduí, $\hat{\epsilon}_i^2$ a provedení regrese

$$\ln \hat{\epsilon}_i^2 = \ln \sigma^2 + \beta \ln X_i + \nu_i = \alpha + \beta \ln X_i + \nu_i.$$

- Pokud je β statisticky významné, napovídá to přítomnosti heteroskedasticity.
- Kritika: Goldfeld a Quandt argumentují, že ν_i nemusí splňovat klasické předpoklady a mohou vykazovat heteroskedasticitu.
- Jako orientační metoda dostačující.

Goldfeldův-Quandtův test

- Pokud heteroskedasticita v závislosti na jedné z vysvětlujících proměnných.
 - 1 Seřadíme data podle velikosti Z (rostoucí nebo klesající, dle předpokladu o vlivu na rozptyl).
 - 2 Vynecháme prostředních d pozorování (obvyklá volba $d = 0.2N$).
 - 3 Provedeme dvě oddělené regrese.
 - 4 Spočítáme součet čtverců reziduí (SSR) pro každou s obou regresí (získáme tak SSR_{LOW} a SSR_{HIGH}).
 - 5 Spočítáme Goldfeldovu-Quandtovu testovou statistiku

$$GQ = \frac{SSR_{HIGH}}{SSR_{LOW}}.$$

- Při platnosti nulové hypotézy o homoskedasticitě má GQ statistika Fisherovo-Snedecorovo rozdělení, $F_{0.5(N-d-2k-2), 0.5(N-d-2k-2)}$.
- Naznačení volby případné transformace.

Breuschův-Paganův-(Godfreyho) test

- Pokud více proměnných způsobujících heteroskedasticitu.

$$\text{var}\epsilon_i = \sigma^2 f(\gamma_0 + \gamma_1 Z_{1i} + \dots + \gamma_p Z_{pi}).$$

- Test $H_0 : \gamma_1 = \gamma_2 = \dots = \gamma_p = 0$ (LM test).

- OLS regrese původního modelu, získání reziduí, $\hat{\epsilon}_i$, a spočítáme

$$\hat{\sigma}^2 = \frac{\sum \hat{\epsilon}_i^2}{N}.$$

- Provedeme druhou regresi rovnice

$$\frac{\hat{\epsilon}_i^2}{\hat{\sigma}^2} = \gamma_0 + \gamma_1 Z_{1i} + \dots + \gamma_p Z_{pi} + \nu_i.$$

- Spočítáme Breuschovu-Paganovu statistiku s využitím regresního součtu RSS z této druhé regrese:

$$BP = \frac{RSS}{2}.$$

- Testová statistika má chí-kvadrát rozdělení s p stupni volnosti, $\chi^2(p)$.

Whiteův test

- Podobný k Breusch-Paganovu testu, jen odlišná druhá regrese.
 - OLS regrese na původních datech a modelu a získání rezidua, $\hat{\epsilon}_i$.
 - Provedeme druhou OLS regresi rovnice

$$\hat{\epsilon}_i^2 = \gamma_0 + \gamma_1 Z_{1i} + \dots + \gamma_p Z_{pi} + \nu_i$$

a získáme koeficient determinace, R^2 .

- Spočítáme Whiteovu testovou statistiku

$$W = NR^2.$$

- Testová statistika má chí-kvadrát rozdělení s p stupni volnosti, $\chi^2(p)$.
- Proměnné Z_1, \dots, Z_p libovolné, obvykle vysvětlující proměnné původní regrese.
- Obvykle všechny, $Z_1 = X_1, \dots, Z_k = X_k +$ Whiteův test využívá obvykle jedinečné čtverce a vzájemné (křížové) součiny.
- Příklad: X_1 a $X_2 \rightarrow$ použití $Z_1 = X_1, Z_2 = X_2, Z_3 = X_1^2, Z_4 = X_2^2$ a $Z_5 = X_1 X_2$ (nutné ošetřit multikolinearitu).

Koenkerův-Bassetův test

- Založen na čtvercích reziduí, $\hat{\epsilon}_i^2$.
- Regrese na čtverec vyrovnaných hodnot, \hat{Y}_i^2 .
- Model: $Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + \epsilon_i$.
- Odhad: $\hat{\epsilon}_i^2 = \alpha_1 + \alpha_2 \hat{Y}_i^2 + \nu_i$.
- Nulová hypotéza $\alpha_2 = 0$ na základě t -testu nebo F -test ($F_{1,k} = t_k^2$).
- Pokud logaritmický model, regrese na $(\log \hat{Y}_i)^2$.
- Aplikovatelný i v případě nenormality náhodných složek v původní regresi.

Praktická doporučení

- V případě heteroskedasticity zkusit model transformovat pro odstranění tohoto problému.
- Někdy stačí logaritmování některých nebo všech proměnných v modelu.
- Někdy dostačuje násobení nebo dělení všech proměnných nějakou proměnnou Z .
- Vždy po transformaci potřeba testovat heteroskedasticitu.
- Pokud nedokážeme nalézt transformaci, využijme HCE.
- Při existenci heteroskedasticity jsou testy hypotéz nekorektní \Rightarrow před testováním hypotéz třeba problém vyřešit nebo použít HCE.