

Přednáška III

AKM I

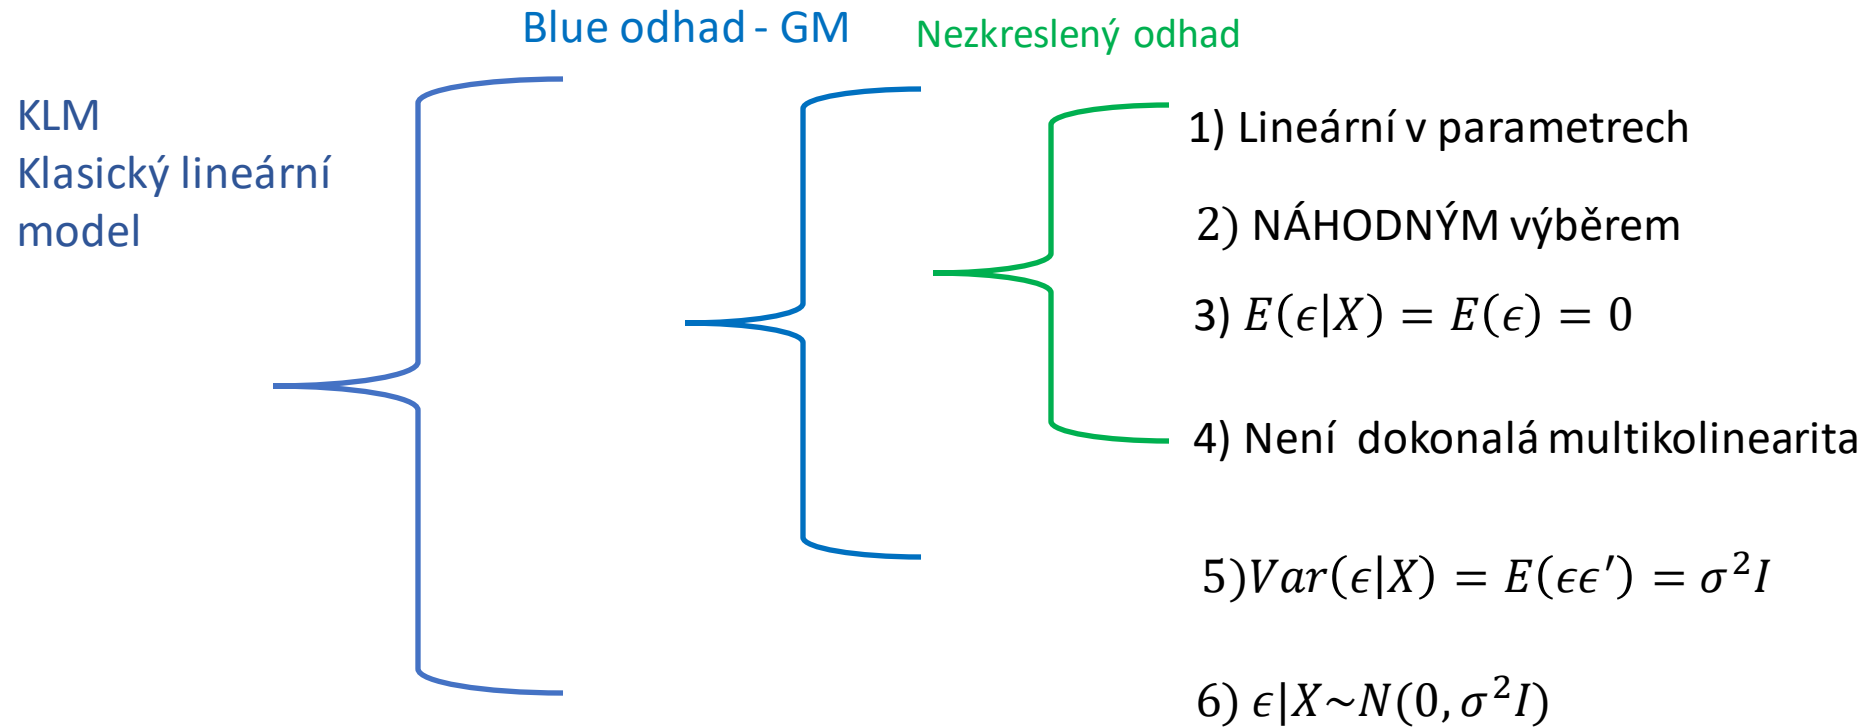
Lukáš Frýd



EVROPSKÁ UNIE
Evropské strukturální a investiční fondy
Operační program Výzkum, vývoj a vzdělávání

MŠMT
MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

Přepoklady KLM a Gauss – Markov teorém



Potom platí, že:

$$b \sim N(\beta, \sigma^2(X'X)^{-1})$$


LRM 5. Homoskedasticita

Nás samozřejmě zajímá jaký rozptyl má výběrové rozdělení pro b
A tedy i rozptyl. Odhad rozptylu je dán:

$$\text{Var}(b_j) = \frac{\sigma^2}{\sum (x_j - \bar{x}_j)^2 (1 - R_j^2)}$$

σ^2 – rozptyl náhodné složky, neznám, musím také odhadnout

$$\widehat{\sigma^2} = \frac{1}{n - k - 1} \sum e^2$$



Požadují, aby platilo: $E(\widehat{\sigma}^2) = \sigma^2$

$$1) \text{Var}(b_j) = \frac{\widehat{\sigma}^2}{\sum (x_j - \bar{x}_j)^2 (1 - R_j^2)}$$

Odhad rozptylu náhodné složky a $\text{Var}(b)$ je nezkreslený a konzistentní pokud platí $\text{Var}(\epsilon|X) = \sigma^2 I$
Tedy požadují homoskedasticitu

V případě heteroskedasticity bude odhad $\text{Var}(b)$ vychýlený a nekonzistentní.

Rozptyl $\text{Var}(b_j)$ se vyskytuje jak u t-testu, tak u testů pro hodnocení sdružené významnosti (F, Wald)
Tedy pokud není splněn předpoklad homoskedasticity, tak nelze brát výsledky těchto testů jako relevantní!!!

Homoskedasticita

Podmíněný rozptyl je konstatní

$$\text{Var}(\varepsilon|x) = \sigma^2 I$$


Rozptyl ε , který je dán x , se nemění v závislosti se změnami x

Rozptyl y , který je dán x , se nemění v závislosti se změnami x

Platí

$$\text{Var}(\varepsilon|x) = \text{Var}(y|x) = \sigma^2 I$$

$$\text{Var}(\varepsilon_i | \text{edu}_i) = \sigma^2$$



Heteroskedasticita


Podmíněný rozptyl NENÍ konstatní

Rozptyl ε , který je dán x , se mění v závislosti se změnami x


Rozptyl y , který je dán x , se mění v závislosti se změnami x

$$\text{Var}(\varepsilon_i | x_i) = \sigma_i^2$$

Podmíněný rozptyl náhodné složky se bude měnit v závislosti na hodnotě nezávislé proměnné (x)




Jak se mění rozptyl y , když se mění (roste) x ?



Platí

$$\text{Var}(\varepsilon|x) = \text{Var}(y|x) = \sigma^2 I$$

Jak se mění rozptyl y, když se mění (roste) x?



$$\text{Var}(\varepsilon_i|x_i) = \sigma_i^2$$

Rozptyl náhodné složky – kovarianční matice

Pro jednoduchost budeme mít pouze 3 pozorování.

$$\text{Var}(\varepsilon|X) = E(\varepsilon\varepsilon'|X) = E \left[\begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \end{pmatrix} \cdot (\varepsilon_1 \quad \varepsilon_2 \quad \varepsilon_3) \middle| X \right] = E \left[\begin{pmatrix} \varepsilon_1\varepsilon_1 & \varepsilon_1\varepsilon_2 & \varepsilon_1\varepsilon_3 \\ \varepsilon_2\varepsilon_1 & \varepsilon_2\varepsilon_2 & \varepsilon_2\varepsilon_3 \\ \varepsilon_3\varepsilon_1 & \varepsilon_3\varepsilon_2 & \varepsilon_3\varepsilon_3 \end{pmatrix} \middle| X \right] =$$

$$= \begin{bmatrix} E(\varepsilon_1\varepsilon_1|X) & E(\varepsilon_1\varepsilon_2|X) & E(\varepsilon_1\varepsilon_3|X) \\ E(\varepsilon_2\varepsilon_1|X) & E(\varepsilon_2\varepsilon_2|X) & E(\varepsilon_2\varepsilon_3|X) \\ E(\varepsilon_3\varepsilon_1|X) & E(\varepsilon_3\varepsilon_2|X) & E(\varepsilon_3\varepsilon_3|X) \end{bmatrix} =$$

seriová závislost/nezávislost

$$= \begin{bmatrix} \text{Var}(\varepsilon_1) & \text{Cov}(\varepsilon_1, \varepsilon_2) & \text{Cov}(\varepsilon_1, \varepsilon_3) \\ \text{Cov}(\varepsilon_2, \varepsilon_1) & \text{Var}(\varepsilon_2) & \text{Cov}(\varepsilon_2, \varepsilon_3) \\ \text{Cov}(\varepsilon_3, \varepsilon_1) & \text{Cov}(\varepsilon_3, \varepsilon_2) & \text{Var}(\varepsilon_3) \end{bmatrix}$$

$$\begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix} = \sigma^2 I$$

$$= \begin{bmatrix} \sigma^2 & \text{Cov}(\varepsilon_1, \varepsilon_2) & \text{Cov}(\varepsilon_1, \varepsilon_3) \\ \text{Cov}(\varepsilon_2, \varepsilon_1) & \sigma^2 & \text{Cov}(\varepsilon_2, \varepsilon_3) \\ \text{Cov}(\varepsilon_3, \varepsilon_1) & \text{Cov}(\varepsilon_3, \varepsilon_2) & \sigma^2 \end{bmatrix}$$

Co jsou prvky mimo diagonálu?

$$\text{Cov}(x, y) = (x - E(x)) \cdot (y - E(y))$$

$$\text{Cov}(\varepsilon_2, \varepsilon_1) = (\varepsilon_2 - E(\varepsilon_2)) \cdot (\varepsilon_1 - E(\varepsilon_1))$$

$$\text{Cov}(\varepsilon_2, \varepsilon_1) = \varepsilon_2 \cdot \varepsilon_1 = 0$$

$$\text{Var}(b|X) = \text{Var}[\boldsymbol{\beta} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\epsilon | X]$$

$$\text{Var}(b|X) = \text{Var}[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\epsilon | X]$$

$$\text{Var}(b|X) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\text{Var}[\epsilon | X] \left((\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' \right)'$$

$$= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\text{Var}[\epsilon|X]\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}$$

$$= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\boldsymbol{\sigma}^2\mathbf{I}\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}$$

$$(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X} = \mathbf{I}$$

$\boldsymbol{\sigma}^2$ – konstanta, lze vytknout před

$$= \boldsymbol{\sigma}^2(\mathbf{X}'\mathbf{X})^{-1}$$

$$\text{Var}[\epsilon|X] \neq \boldsymbol{\sigma}^2\mathbf{I}$$

$$\text{Var}(b|X) \neq \boldsymbol{\sigma}^2(\mathbf{X}'\mathbf{X})^{-1}$$

Při heteroskedasticitě je rozptyl OLS estimatoru b :

$$\text{Var}(b|X) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\boldsymbol{\sigma}^2\boldsymbol{\Omega}\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}$$

Sandwich covariance matrix

Tedy v případě heteroskedasticity již nelze získat nevychýlený a konzistentní odhad $\text{Var}(b|X)$

Pomocí $\widehat{\boldsymbol{\sigma}}^2(\mathbf{X}'\mathbf{X})^{-1}$

Příčiny existence heteroskedasticity

Průřezová data

Značně odlišné hodnoty v jednom modelu

Variabilita závislé proměnné (y) závisí na některé nezávislé proměnné (x)

Chybná specifikace modelu

Vynechání „důležité“ nezávislé proměnné

Nevhodná funkční forma modelu

OBJEVENÍ HETEROSKEDASTICITY NÁS MŮŽE NAVÉST NA NOVÝ MODEL!



$$\log(wage) = \beta_0 + \beta_1 educ + \epsilon$$

$$wage = \beta_0 + \beta_1 educ + \epsilon$$


Chyby v měření

S rostoucí hodnotou endogenní proměnné dochází ke kumulaci chyb měření

to zvyšuje rozptyl endogenní proměnné a tedy i rozptyl reziduí



Příklad tělo mozek



```

Soubor  Upravit  Testy  Uložit  Grafy  Analýza  LaTeX
Model 1: OLS, za použití pozorování 1-28
Závisle proměnná: Brain_g

      koeficient   směř. chyba   t-podíl   p-hodnota
-----
const      576,372      265,912      2,168      0,0395   **
Body_kg    -0,000432637      0,0158853   -0,02724   0,9785

Střední hodnota závisle proměnné      574,5214
Sm. odchylka závisle proměnné          1334,929
Součet čtverců reziduí                  48113598
Sm. chyba regrese                        1360,339
Koeficient determinace                   0,000029
Adjustovaný koeficient determinace       -0,038432
F(1, 26)                                  0,000742
P-hodnota (F)                             0,978480
Logaritmus věrohodnosti                  -240,7265
Akaikovo kritérium                       485,4529
Schwarzovo kritérium                     488,1174
Hannan-Quinnovo kritétium                 486,2675
zde je poznámka o zkratkách statistik modelu

Whiteův test heteroskedasticity -
    
```

```


Model 2: OLS, za použití pozorování 1-28
Závisle proměnná: lbrain

      koeficient   směř. chyba   t-podíl   p-hodnota
-----
const      2,55490      0,413137    6,184     1,53e-06   ***
lbody      0,495995     0,0781694   6,345     1,02e-06   ***


Střední hodnota závisle proměnné      4,425446
Sm. odchylka závisle proměnné          2,399282
Součet čtverců reziduí                  60,98799
Sm. chyba regrese                        1,531565
Koeficient determinace                   0,607610
Adjustovaný koeficient determinace       0,592518
F(1, 26)                                  40,26063
P-hodnota (F)                             1,02e-06
Logaritmus věrohodnosti                  -50,62889
Akaikovo kritérium                       105,2578
Schwarzovo kritérium                     107,9222
Hannan-Quinnovo kritétium                 106,0723
zde je poznámka o zkratkách statistik modelu
    
```

$$\text{Var}(\epsilon|x) = \sigma^2 \cdot h(x)$$


homo




0.5*x



exp(x)




x^2




$$\text{Var}(\epsilon|x) = \sigma^2 \cdot h(x)$$


log(x)




x^3



$x^{0.5}$



1/x



Důsledky heteroskedasticity

$$\text{Var}[\epsilon|X] \neq \sigma^2 I$$

$$E(b) = \beta$$

$$t = \frac{b_j}{sd(b_j)}$$

Nelze použít t-test, F-test, LM-test
Konfidenční intervaly

$$\text{Var}(b) \neq \sigma^2 (X'X)^{-1}$$

NEMÁ DOPAD NA ODHAD PARAMETRŮ β – NEOVLIVNÍ ZKRESLENOST/NEZKRESLENOST pro konečný počet pozorování
Pro velký počet pozorování „large sample“ – nemá vliv na konzistenci odhadu

1) OLS odhad již není BLUE – má vliv na vydatnost odhadu

Tím, že pozoruje určitý „vzorec“ jak residua (náhodná složka) rostou/klesají
tak jsme nepostihli všechny informace v modelu a proto nemůže být BLUE (best)
Bude jiný lepší (BLUE) estimator, který postihne „tuto informaci“

2) Odhad $\text{Var}(b)$ bude nekonzistentní.

My vlastně používáme špatný estimátor.

Dopad na t,F,LM test, intervaly spolehlivosti. Jejich výsledky budou zavádějící. Viz předpoklady daných testů

Heteroskedasticita v průřezových datech

Homoskedasticita

$$sav = \beta_0 + \beta_1 inc + \epsilon$$

$$Var(\epsilon|inc) = \sigma^2$$

Heteroskedasticita

$$Var(\epsilon|inc) = \sigma^2 \cdot h(inc)$$

$$Var(sav|inc) = \sigma^2 \cdot h(inc)$$


$$Var(\epsilon|x) = Var(y|x)$$

$$Var(\epsilon_i|x_i) = \sigma_i^2$$

$$Var(\epsilon_i|x_i) = h(x_i)$$

$$Var(\epsilon|X) = h(X)$$

S rostoucím příjmem roste variabilita úspor –např. více možností
S rostoucím vzděláním roste možnost uplatnění a tedy i mezd





$$\text{Var}(\epsilon|x) = \text{Var}(y|x)$$


$$\text{Var}(\epsilon|x) = \sigma^2$$

$$\text{Var}(sav|inc) = \sigma^2$$

$$\text{Var}(\epsilon|inc) = \sigma^2$$




Homoskedasticita




$$\text{Var}(\epsilon|x) = \text{Var}(y|x)$$

$$\text{Var}(\epsilon|x) = \sigma^2 \cdot h(x)$$



$$\text{Var}(sav|inc) = \sigma^2 \cdot h(inc)$$



$$\text{Var}(\epsilon|inc) = \sigma^2 \cdot h(inc)$$


Heteroskedasticita

Nejprve předpokládejme, že známe $h(x)$

$$h(x) = x \quad \text{Var}(\epsilon|x) = \sigma^2 \cdot x$$

$$h(x) = x^2 \quad \text{Var}(\epsilon|x) = \sigma^2 \cdot x^2$$

$$h(x) = e^x \quad \text{Var}(\epsilon|x) = \sigma^2 \cdot e^x$$



Testování heteroskedasticity

Základní myšlenka – ovlivňují nezávislé (X) proměnné rozptyl náhodné složky?

$$y = \beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_k \cdot x_k + \varepsilon$$

$$H_0: \text{Var}(\varepsilon | x_1, x_2, \dots, x_k) = \sigma^2 I$$

$$H_0: \text{Var}(\varepsilon_i | x_i) = \sigma^2$$

$$\text{Var}(\varepsilon | X) = E(\varepsilon^2 | X) = E(\varepsilon^2) = \sigma^2$$

Reg.fce

$$\varepsilon^2 = \gamma_0 + \gamma_1 \cdot x_1 + \gamma_2 \cdot x_2 + \dots + \gamma_k \cdot x_k + v$$

$$H_0: \gamma_1 = \gamma_2 = \dots = \gamma_k = 0$$

$$H_1: \text{non } H_0$$

F-test/LM test

Breusch–Pagan Test

$$e^2 = \gamma_0 + \gamma_1 \cdot x_1 + \gamma_2 \cdot x_2 + \dots + \gamma_k \cdot x_k + v$$

H1: Parametry jsou sdruženě signifikantní, tedy alespoň jedna z proměnných ovlivňuje rozptyl residuí – heteroskedasticita

White test

Pro BP test jsme si řekli, že nepostihne nelineární vztah mezi rozptylem náhodné složky a X
Jedno z možných řešení White test

$$y = \beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \beta_3 \cdot x_3 + \varepsilon$$

$x_i x_j$ kdy $i \neq j$
cross – products

Pomocná regrese

$$e^2 = \alpha_0 + \alpha_1 x_1 + \alpha_2 x_2 + \alpha_3 x_3 + \alpha_4 x_1^2 + \alpha_5 x_2^2 + \alpha_6 x_3^2 + \alpha_7 x_1 x_2 + \alpha_8 x_1 x_3 + \alpha_9 x_2 x_3 + v$$

Testujeme koeficient determinace R^2

Využití F testu, nebo LM testu

$$n \cdot R^2 \sim \chi^2(k - 1)$$

H_0 : homoskedasticita

H_1 : heteroskedasticita

V případě „více“ proměnných snížený počet stupňů volnosti -10 x a 30 pozorování

$$e^2 = \alpha_0 + \alpha_1 \hat{y} + \alpha_2 \hat{y}^2 + v$$

Postup:

- 1) Odhadnu rovnici a získám residua (e) a naitované hodnoty \hat{y}
- 2) Pomocná regrese z kvadrátů residuí na naitované hodnoty + jejich kvadráty
- 3) Vyhodnotím pomocí LM/F-testu

Co dělat v případě přítomnosti heteroskedasticity?

Vy jste se učili, že je možné použít metodu zobecněných nejmenších čtverců (GLS)

ALE, GLS má silný a v praxi téměř nereálný předpoklad, že známe tvar heteroskedasticity - $Var(\epsilon|X) = \sigma^2 h(X)$

1) Zkuste se zamyslet

Matematická logika, ekonomická teorie. Specifikoval jsem správně tvar modelu? Viz příčiny hetero.

Mohu zkusit použít logaritmus, pokud to dává smysl.

2) Pokud úprava modelu nevyjde

Jedinou možností jak získat konzistentní odhady $Var(b)$ je použití tzv. robustních odhadů chyb.

Jelikož případná heteroskedasticita může mít velmi citelný vliv na $Var(b)$, je možné místo OLS použít tzv. FGLS (Feasible general least squares)

Metoda FGLS vychází z GLS, kdy však neznáme $h(X)$

Robustní odhad chyb

Robustní myslíme, že je rezistentní vůči „něčemu“

Zde vůči heteroskedasticitě

Heteroskedasticity-consistent, heteroscedasticity robust..

Sandwich estimator

Získat konzistentní odhad pro A není těžké $\hat{A} = \frac{X^T X}{n}$

Estimátor poskytující konzistentní odhad matice B odvodil White

Dnes existuje více konzistentních estimátorů matice B

- HC0 - White
- HC1
- HC2
- HC3

Asymptoticky jsou odhady ekvivalentní, liší se však pro „malé“ vzorky

$$\text{Var}(\epsilon|X) = \sigma^2 \Omega$$

$$\text{Var}(b) = (X'X)^{-1} X' \sigma^2 \Omega X (X'X)^{-1}$$

$$b \sim N(\beta, \Sigma_b) \quad \Sigma_b = A^{-1} B A^{-1}$$

$$\hat{B} = \frac{1}{n} \sum_{i=1}^n e_i^2 x_i^T x_i$$

$$\text{Avar}(b) = \frac{\widehat{\Sigma}_b}{n} = (X'X)^{-1} \left(\sum_{i=1}^n e_i^2 x_i^T x_i \right) (X'X)^{-1}$$

$$\text{Avar}(b) = (X'X)^{-1} \widehat{X' \Omega X} (X'X)^{-1}$$

Zobecněná metoda nejmenších čtverců (GLS)

Pokud pomocí testů zjistíme přítomnost heteroskedasticity – můžeme se pokusit o její nápravu

Pro odstranění heteroskedasticity však musíme znát její formu - určíme funkční vztah závislosti

Potom zde představená metoda (WLS) povede k vydatnějšímu odhadu než OLS

Získáme tak „nový“ t-test a F-test, který bude mít právě t/F rozdělení
(pokud je přítomna heteroskedasticita, OLS nám neposkytne t/F test, který má t/F rozdělení)

Vážená metoda nejmenších čtverců (WLS)
je jedním ze speciálních případů
zobecněné metody nejmenších čtverců (GLS)

Vy jste se učili GLS i pro případ přítomnosti autokorelace.

Vážená metoda nejmenších čtverců (GLS)

$$sav = \beta_0 + \beta_1 inc + \epsilon$$

$$Var(\epsilon|inc) = \sigma^2 h(x) > 0$$

„Víme“

$$Var(\epsilon_i|inc_i) = \sigma^2 inc_i^2$$

S rostoucím příjmem roste variabilita úspor – např. více možností

$$Var(\epsilon|X) = E \left[\begin{array}{ccc|c} \epsilon_1^2 & \epsilon_1 \epsilon_2 & \epsilon_1 \epsilon_3 & \\ \epsilon_2 \epsilon_1 & \epsilon_2^2 & \epsilon_2 \epsilon_3 & inc \\ \epsilon_3 \epsilon_1 & \epsilon_3 \epsilon_2 & \epsilon_3^2 & \end{array} \right] = \begin{bmatrix} E[\epsilon_1^2|inc] & 0 & 0 \\ 0 & E[\epsilon_2^2|inc] & 0 \\ 0 & 0 & E[\epsilon_3^2|inc] \end{bmatrix} =$$

$$= \sigma^2 \begin{bmatrix} inc_1^2 & 0 & 0 \\ 0 & inc_2^2 & 0 \\ 0 & 0 & inc_3^2 \end{bmatrix} = \sigma^2 \Omega$$

$$\Omega = \begin{bmatrix} inc_1^2 & 0 & 0 \\ 0 & inc_2^2 & 0 \\ 0 & 0 & inc_3^2 \end{bmatrix}$$

$$Var(\epsilon|X) = \sigma^2 \Omega$$

$$sav = \beta_0 + \beta_1 inc + \epsilon \quad Var(\epsilon|inc) = \sigma^2 inc^2$$

$$\frac{sav}{inc} = \frac{\beta_0}{inc} + \frac{\beta_1 inc}{inc} + \frac{\epsilon}{inc}$$

$$Var\left(\frac{\epsilon}{inc} \middle| inc\right) = \frac{1}{inc^2} Var(\epsilon|inc) = \frac{1}{inc^2} \sigma^2 inc^2 = \sigma^2$$

Takto upravený rozptyl již nevykazuje heteroskedasticitu

$$y = \beta_0 + \beta_1 x + \epsilon$$

$$\text{Var}(\epsilon|inc) = \sigma^2 h(x)$$

předpoklad, že znám tvar $h(x)$

$$\frac{y}{\sqrt{h(x)}} = \frac{\beta_0}{\sqrt{h(x)}} + \frac{\beta_1 x}{\sqrt{h(x)}} + \frac{\epsilon}{\sqrt{h(x)}}$$

$$\text{Var}\left(\frac{\epsilon}{\sqrt{h(x)}} \middle| x\right) = \frac{1}{h(x)} \text{Var}(\epsilon|x) = \frac{1}{h(x)} \sigma^2 h(x) = \sigma^2$$

Postup maticově

- 1) Model odhadneme pomocí MNČ
- 2) Vyhodnotíme, zda-li se v modelu vyskytuje heteroskedasticita/autokorelace
- 3) Zjistit zda-li se nejedná o vynechanou proměnnou, nelineární vztah atd.
(případy existence heteroskedasticity/autokorelace)
- 4) **Nalezneme vhodnou transformační matici T**
- 5) Upravíme model
- 6) Upravený model odhadneme pomocí MNČ

$$y = X\beta + \varepsilon$$

$$\text{Var}(\varepsilon|x) = \sigma^2 \Omega$$

$$\text{Var}(\varepsilon|X) = \begin{bmatrix} E[\varepsilon_1^2|X] & 0 & 0 \\ 0 & E[\varepsilon_2^2|X] & 0 \\ 0 & 0 & E[\varepsilon_3^2|X] \end{bmatrix} = \sigma^2 \cdot \Omega$$

Mějme matici T pro kterou platí: $T'T = \Omega^{-1}$

$$\Omega = \begin{bmatrix} h(X) & 0 & 0 \\ 0 & h(X) & 0 \\ 0 & 0 & h(X) \end{bmatrix}$$

$$T.y = TX\beta + T.\varepsilon$$

$$y^* = X^*\beta + \varepsilon^*$$

$$\text{Var}(A.x) = A.\text{Var}(x).A'$$

$$\text{Var}(\varepsilon^*|X) = \text{Var}(T.\varepsilon|x) = T.\sigma^2\Omega.T' = \sigma^2 T.\Omega.T' = \sigma^2 T(T'T)^{-1}T' = \sigma^2.I$$

$$I = T.\Omega.T'$$

$$T' T = \Omega^{-1}$$

$$T = \begin{bmatrix} \frac{1}{\sqrt{h(X)}} & 0 & 0 \\ 0 & \dots & 0 \\ 0 & 0 & \frac{1}{\sqrt{h(X)}} \end{bmatrix}$$

transformační matice T

$$\Omega = \begin{bmatrix} h(X) & 0 & 0 \\ 0 & h(X) & 0 \\ 0 & 0 & h(X) \end{bmatrix}$$

$$y = \beta_0 + \beta_1 x + \epsilon \quad \text{Var}(\epsilon|inc) = \sigma^2 h(x)$$

předpoklad, že znám tvar h(x)

$$T \cdot y = TX\beta + T \cdot \epsilon$$

$$\frac{y}{\sqrt{h(x)}} = \frac{\beta_0}{\sqrt{h(x)}} + \frac{\beta_1 x}{\sqrt{h(x)}} + \frac{\epsilon}{\sqrt{h(x)}}$$

$$\text{Var}(T \cdot \epsilon|x) = T \cdot \sigma^2 \Omega \cdot T' = \sigma^2 T \cdot \Omega \cdot T' = \sigma^2 \cdot I$$

$$\text{Var}\left(\frac{\epsilon}{\sqrt{h(x)}} \middle| x\right) = \frac{1}{h(x)} \text{Var}(\epsilon|x) = \frac{1}{h(x)} \sigma^2 h(x) = \sigma^2$$

$$T \cdot y = TX\beta + T \cdot \varepsilon \quad y^* = X^*\beta + \varepsilon^* \quad b_{OLS} = (X'^*X^*)^{-1} \cdot X'^*y^*$$

$$b_{GLS} = (X'T'TX)^{-1} \cdot X'T'Ty = (X'\Omega^{-1}X)^{-1} \cdot X'\Omega^{-1}y$$

$$b_{GLS} = (X'\Omega^{-1}X)^{-1} \cdot X'\Omega^{-1}y$$

Aitken estimator
GLS estimator
ZMNČ

$$\begin{aligned} \text{Var}(b_{GLS}|X) &= \text{Var}[(X'\Omega^{-1}X)^{-1} \cdot X'\Omega^{-1}\varepsilon] \\ &= (X'\Omega^{-1}X)^{-1} \cdot X'\Omega^{-1} \text{Var}(\varepsilon|X) \Omega^{-1}X \cdot (X'\Omega^{-1}X)^{-1} = \sigma^2 (X'\Omega^{-1}X)^{-1} \end{aligned}$$

$$\text{Var}(b_{GLS}|X) = \sigma^2 (X'\Omega^{-1}X)^{-1}$$

$$\text{Var}(b_{GM-OLS}|X) = \sigma^2 (X'X)^{-1}$$

Rozlišovat rozptyly výběrového rozdělení estimátoru OLS

$$\text{Var}(b_{NonGM-OLS}|X) = \sigma^2 (X'X)^{-1} \cdot X' \cdot \Omega \cdot X \cdot (X'X)^{-1}$$

$$Q_{OLS} = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \dots \min$$

$$Q_{GLS} = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n \frac{(y_i - \hat{y}_i)^2}{h(x)_i} \dots \min$$

Je to to samé, jako když rovnici roznásobím $\frac{1}{\sqrt{h(x)}}$ a následně provedu odhad pomocí OLS

$$b_{GLS} = (X'\Omega^{-1}X)^{-1}.X'\Omega^{-1}y$$

My transformujeme regresní rovnici

Následně odhadneme metodou nejmenších čtverců

Toto je metoda ZMNČ, GLS

Tento odhad je již zase BLUE!

Zpětně substituujeme pro interpretaci parametrů

$$\frac{1}{\sqrt{h(x)}}$$

$$T.y = TX\beta + T.\epsilon$$

$$\epsilon^* \sim N(0, \sigma^{2*})$$

$$y^* = X^*\beta + \epsilon^*$$

$$\widehat{\sigma^{2*}} = \frac{1}{n-k-1} \sum e^{*2}$$

Již opět platí $E(\widehat{\sigma^{2*}}) = \sigma^{2*}$

$$y^* = X^*b_{GLS} + e^*$$

Opět můžeme použít t-test, F-test

Feasible general least square (FGLS)

Je přítomná heteroskedasticita, co tedy dělat?

Použít robustní odhad chyb.

Co GLS?

Nelze, neznáme tvar heteroskedasticity

Ale můžeme použít FGLS

FGLS poskytuje asymptoticky vydatnější odhady, než OLS

Cílem je odhadnout tvar $h(X)$ z $Var(\epsilon|X) = \sigma^2 h(X)$

FGLS podle White

1. Odhadneme regresní model a uložíme residua (e)
2. Upravíme residua do tvaru $\log(e^2)$ a provedeme pomocnou regresi
3. Z bodu 2 získáme naitované hodnoty (\hat{g}) a upravíme tak, že $\hat{h} = \exp(\hat{g})$
4. Transformujeme rovnici 1.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \epsilon$$

$$\text{Var}(\epsilon|X) = \sigma^2 \exp(\gamma_0 + \gamma_1 x_1 + \gamma_2 x_2 + \dots + \gamma_k x_k)$$

$$h(X) = \exp(\gamma_0 + \gamma_1 x_1 + \gamma_2 x_2 + \dots + \gamma_k x_k)$$

$$\epsilon^2 = \sigma^2 \exp(\gamma_0 + \gamma_1 x_1 + \gamma_2 x_2 + \dots + \gamma_k x_k) u \quad u \sim \text{IID}(0, \Sigma_u)$$

$$\log(\epsilon^2) = \underbrace{\log \sigma^2 + \gamma_0}_{\alpha_0} + \gamma_1 x_1 + \gamma_2 x_2 + \dots + \gamma_k x_k + v$$



α_0

Odhad vah je pak

$$\hat{h} = \exp(\widehat{\log(\epsilon^2)})$$

Nezbavíme se heteroskedasticity!!!

Ale je pravděpodobné, že snížíme její dopad

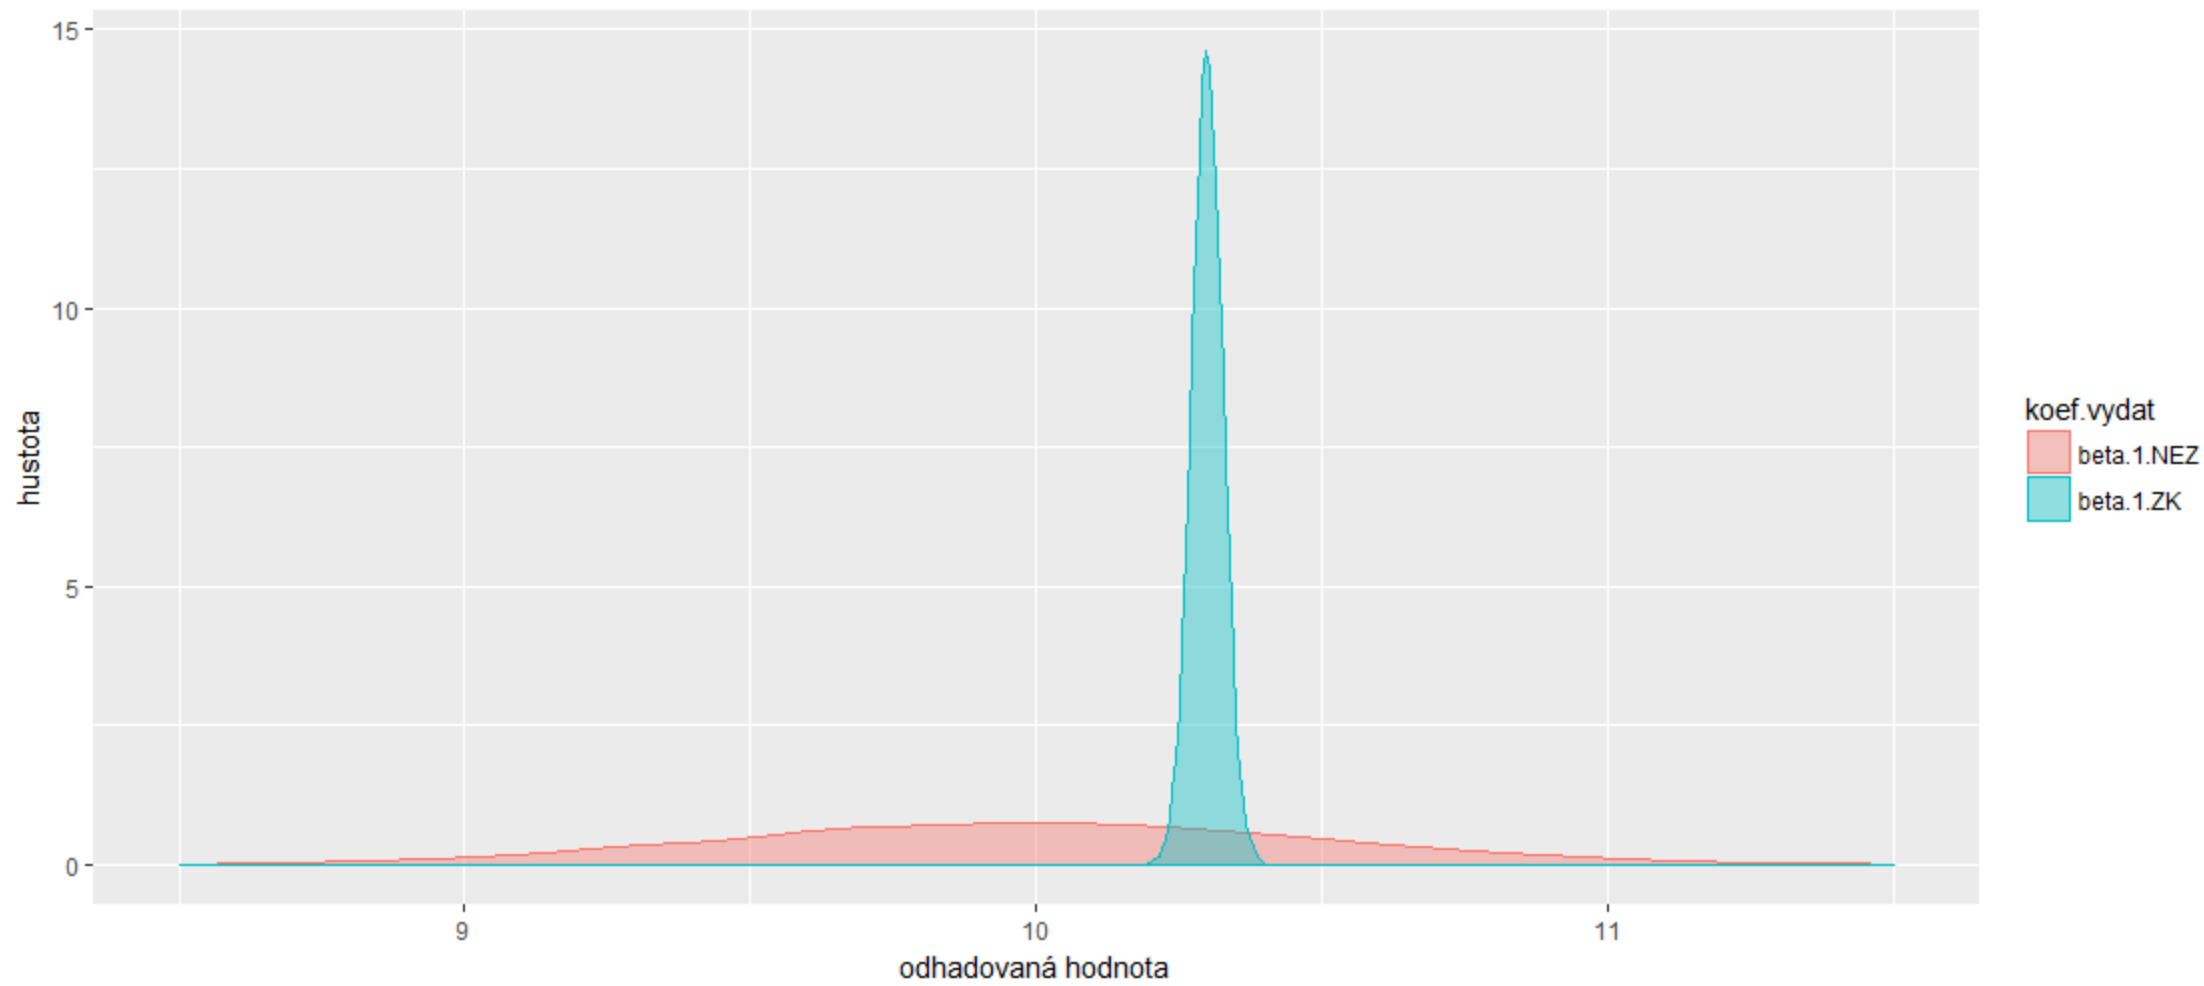
$$\frac{y}{\sqrt{\hat{h}}} = \frac{\beta_0}{\sqrt{\hat{h}}} + \beta_1 \frac{x_1}{\sqrt{\hat{h}}} + \beta_2 \frac{x_2}{\sqrt{\hat{h}}} + \dots + \beta_k \frac{x_k}{\sqrt{\hat{h}}} + \frac{\epsilon}{\sqrt{\hat{h}}}$$

Odhady pomocí FGLS jsou konzistentní

Ne však nevychýlené.

Tade off vychýlenost vs. vydatnost

Tade off vychýlenost vs. vydatnost



Heteroskedasticita praktické otázky

1) Když máme robustní odhad chyb, proč testujeme model na přítomnost heteroskedasticity?

Robustní odhady jsou pouze asymptoticky validní. To má dopad i na t, F, LM testy.

Ty mají potom pouze asymptoticky t, F, χ^2 rozdělení – tedy v případě málo pozorování, můžeme být „hodně mimo“ **UKAŽ R!**

2) Máme používat FGLS v případě přítomnosti heteroskedasticity?

Nelze jednoznačně říci, zdali skutečně FGLS poskytuje vydatnější odhady, nežli OLS. Asymptoticky však ano.

Záleží jakou funkci $h(x)$ použijeme.

Ukážeme si na cviku případ silné heteroskedasticity

Vždy zkuste více testů heteroskedasticity. Pokud vyjde alespoň u jednoho z nich, že můžeme zamítnout hypotézu o homoskedasticite, tak automaticky berte, že je přítomna heteroskedasticita, přestože to jiný test nepotvrzuje.

Pokud vyjde p-value u testů „blízko“ 10%, opět raději použijte robustní odhad chyb.

Například () pomocí simulací zjistil, že je vždy lepší použít robustní odhady chyb.

Jiní např. s tímto závěrem zase nesouhlasí.

Zkuste například porovnat výsledky t-testu pro „normální“ a pro robustní odhad.

Pozor na předpoklady dalších testů – bude často potřeba použít jejich robustní verzi

Heteroskedasticity robust F,LM-test



EVROPSKÁ UNIE
Evropské strukturální a investiční fondy
Operační program Výzkum, vývoj a vzdělávání



Toto dílo podléhá licenci Creative Commons
Uveďte původ – Zachovejte licenci 4.0 Mezinárodní.

