

## 不均一分散

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

$$\text{Var}(u | \mathbf{x}) = \sigma_i^2$$

## Ch.8 不均一分散

1. OLSでの不均一分散の帰結
2. OLS推定後の不均一分散頑健的推論
3. 不均一分散の検定
4. 加重最小二乗WLS推定
5. 線形確率モデル(再)\*

### 8-1 OLSでの不均一分散の帰結

#### ◆不均一分散のもとでのOLS推定量

- OLS推定量は依然として不偏&一致推定量
- $R^2$ の解釈も変化しない


$$R^2 \approx 1 - \frac{\sigma_u^2}{\sigma_y^2}$$

無条件誤差分散は不均一分散(条件付き誤差分散)の影響を受けない

#### ■ 注意点

- ◆ OLS推定量の分散は有効ではない
- ◆ 通常のt検定&F検定は有効でない
- ◆ OLS推定量はBLUEではない
  - より効率的な線形推定量の存在

### 8-1 OLSでの不均一分散の帰結



### 8-2 不均一分散の頑健的推論

#### ◆不均一分散頑健統計量

- すべての計算式は大標本でのみ有効
- 不均一分散頑健標準誤差HRSE

$$\widehat{\text{Var}}(\hat{\beta}_j) = \frac{\sum_{i=1}^n \hat{r}_i^2 \hat{u}_i^2}{SSR_j^2}$$

- White-Huber-Eicker標準誤差とも呼称
- 元の回帰式と $y_i$ を他の説明変数に回帰したときの式、それぞれの残差の2乗からなる。
- ◆ この計算式を用いた通常のt検定は漸的に有効
- ◆ 通常のF統計は不均一分散では有効ではないが、この計算式は多くのソフトウェアで使用可能

### 8-2 不均一分散の頑健的推論

$$\hat{\beta}_1 = \beta_1 + \frac{\sum (x_i - \bar{x}) u_i}{SST_x}, \text{ where } SST_x = \sum (x_i - \bar{x})^2$$

$$\text{Var}(\hat{\beta}_1) = \frac{\sum (x_i - \bar{x})^2 \sigma_i^2}{SST_x^2} \quad (8.2),$$

A valid estimator for this when  $\sigma_i^2 \neq \sigma^2$  is

$$\text{Est.Var}(\hat{\beta}_1) = \frac{\sum (x_i - \bar{x})^2 \hat{u}_i^2}{SST_x^2} \quad (8.3),$$

where  $\hat{u}_i$  are the OLS residuals

## 8-2 不均一分散の頑健的推論

### ◆例:賃金方程式

$$\widehat{\log(wage)} = -.128 + .0904 \widehat{educ} + .0410 \widehat{exper} - .0007 \widehat{exper}^2$$

(.105) (.0075) (.0052) (.0001)  
[.107] [0.0078] [0.0050] [0.001]

- HRSEは通常の標準誤差よりも大きくも小さくもなるが、(大標本のもとで)その差は実際には小さい
- 不均一分散によってはその差が大きいこともあるため、常にHRSEを計算する方がよい

### ■ F検定

$$H_0: \beta_{exper} = \beta_{exper^2} = 0$$

$$F = 17.95 \quad F_{robust} = 17.99$$

- F値も大きな違いはない

## 8-3 不均一分散の検定

### ◆不均一分散の検定

- 不均一分散の有無は、OLSが最も効率的な線形推定量であるかどうかと関連するため重要

### ■ MLR.5

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

- 分散の定義とMLR.4より

$$\text{Var}(u|x) = E(u^2|x) - [E(u|x)]^2 = E(u^2|x)$$

$$\text{Var}(a) = E[a - E(a)]^2 = E(a^2) - E[E(a)]^2$$

$$\text{MLR.4: } E(u|x) = 0$$

$$\Rightarrow E(u^2|x_1, \dots, x_k) = E(u^2) = \sigma^2$$

- $u^2$ の平均は $x_1, x_2, \dots, x_k$ の変動に影響を受けない

## 8-3 不均一分散の検定

### ◆Breusch-Pagan test for heteroskedasticity

- $u^2$ への $x_1, x_2, \dots, x_k$ の影響を検定 (BP)

$$\widehat{u}^2 = \delta_0 + \delta_1 x_1 + \dots + \delta_k x_k + \text{error}$$

$$H_0: \delta_1 = \delta_2 = \dots = \delta_k = 0$$

### ■ 検定統計量

$$F = \frac{R_{\widehat{u}^2}^2/k}{1 - R_{\widehat{u}^2}^2/(n - k - 1)}$$

大きな検定統計量(高い $R^2$ )は帰無仮説に反する論拠

$$LM = n \cdot R_{\widehat{u}^2}^2 \sim \chi_k^2$$

LM統計量(Lagrange multiplier)においても高い統計値(高い $R^2$ )は $u^2$ の期待値が説明変数と無相関という帰無仮説を棄却

## 8-3 不均一分散の検定

### ◆例8.4:住宅価格の不均一分散検定

#### ■ レベル(非対数)

$$\widehat{price} = -21.77 + .0021 \widehat{lotsize} + .123 \widehat{sqrtft} + 13.85 \widehat{bdrms}$$

(29.48) (.0006) (.013) (9.01)

$$\Rightarrow R_{\widehat{u}^2}^2 = .1601, p\text{-value}_F = .002, p\text{-value}_{LM} = .0028$$

#### ■ 対数

$$\widehat{\log(price)} = -1.30 + .168 \widehat{\log(lotsize)} + .700 \widehat{\log(sqrtft)} + .037 \widehat{bdrms}$$

(.65) (.038) (.093) (.028)

$$\Rightarrow R_{\widehat{u}^2}^2 = .0480, p\text{-value}_F = .245, p\text{-value}_{LM} = .2390$$

- 対数化は不均一分散を緩和

## 8-3 不均一分散の検定

### ◆The White test for heteroskedasticity

- $u^2$ への $x_1, x_2, \dots, x_k$ の影響を検定 (White)

$$\widehat{u}^2 = \delta_0 + \delta_1 x_1 + \delta_2 x_2 + \delta_3 x_3 + \delta_4 x_1^2 + \delta_5 x_2^2 + \delta_6 x_3^2 + \delta_7 x_1 x_2 + \delta_8 x_1 x_3 + \delta_9 x_2 x_3 + \text{error}$$

$$H_0: \delta_1 = \delta_2 = \dots = \delta_9 = 0$$

- 検定統計量  $LM = n \cdot R_{\widehat{u}^2}^2 \sim \chi_9^2$

### ■ White testのメリット&デメリット

- 2乗項、交差項との関係も考慮し、BP検定より一般的
- すべての2乗項・交差項を含むと、係数の数が膨大に(例:k=6のとき27係数)

## 8-3 不均一分散の検定

### ◆Alternative form of the White test

- $u^2$ への $x_1, x_2, \dots, x_k$ の影響を検定 (White 2)

$$\widehat{u}^2 = \delta_0 + \delta_1 \widehat{y} + \delta_2 \widehat{y}^2 + \text{error}$$

- $u^2$ への影響を $y$ と $y^2$ の予測値を用いて間接的に検定

- $y$ と $y^2$ の予測値が説明変数、2乗項、交差項を含むと仮定

$$H_0: \delta_1 = \delta_2 = 0, LM = n \cdot R_{\widehat{u}^2}^2 \sim \chi_2^2$$

### ■ 例8.5:住宅価格の不均一分散検定(対数版)

$$R_{\widehat{u}^2}^2 = .0392, LM = 88(.0392) \approx 3.45, p\text{-value}_{LM} = .178$$

- 不均一分散の帰無仮説を棄却できない

## 8-4 加重最小二乗法WLS

### ◆ Weighted least squares estimation

#### ■ 8-4a 不均一分散が既知のケース

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + u_i$$

$$\text{Var}(u_i|x_i) = \sigma^2 h(x_i), \quad h(x_i) = h_i > 0$$

- 不均一分散の関数形は既知

#### ◆ 変換

$$\Rightarrow \left[ \frac{y_i}{\sqrt{h_i}} \right] = \beta_0 \left[ \frac{1}{\sqrt{h_i}} \right] + \beta_1 \left[ \frac{x_{i1}}{\sqrt{h_i}} \right] + \dots + \beta_k \left[ \frac{x_{ik}}{\sqrt{h_i}} \right] + \left[ \frac{u_i}{\sqrt{h_i}} \right]$$

$$\Leftrightarrow y_i^* = \beta_0 x_{i0}^* + \beta_1 x_{i1}^* + \dots + \beta_k x_{ik}^* + u_i^*$$

## 8-4 加重最小二乗法WLS

### ◆ 例: 貯蓄と所得

$$sav_i = \beta_0 + \beta_1 inc_i + u_i, \quad \text{Var}(u_i|inc_i) = \sigma^2 inc_i$$

$$\left[ \frac{sav_i}{\sqrt{inc_i}} \right] = \beta_0 \left[ \frac{1}{\sqrt{inc_i}} \right] + \beta_1 \left[ \frac{inc_i}{\sqrt{inc_i}} \right] + u_i^*$$

- 変換後の回帰式には切片がないことに注意

#### ■ 変換後のモデルは均一分散

$$E(u_i^2|x_i) = E\left[\left(\frac{u_i}{\sqrt{h_i}}\right)^2|x_i\right] = \frac{E(u_i^2|x)}{h_i} = \frac{\sigma^2 h_i}{h_i} = \sigma^2$$

- ◆ 他のGauss-Markov仮定も同様に成立する場合、変換されたモデルに適用されるOLSは、最良線形不偏推定量を得る

## 8-4 加重最小二乗法WLS

### ◆ WLSについて

#### ■ 加重残差平方和の最小化

$$\min \sum_{i=1}^n \left( \left[ \frac{y_i}{\sqrt{h_i}} \right] - b_0 \left[ \frac{1}{\sqrt{h_i}} \right] - b_1 \left[ \frac{x_{i1}}{\sqrt{h_i}} \right] - \dots - b_k \left[ \frac{x_{ik}}{\sqrt{h_i}} \right] \right)^2$$

$$\Leftrightarrow \min \sum_{i=1}^n (y_i - b_0 - b_1 x_{i1} - \dots - b_k x_{ik})^2 / h_i$$

- 最適化問題において、PRFからの乖離が大きい観測値ほどその重要性を低くするように計算 (=より大きい $h_i$ )

#### ◆ なぜWLSはOLSよりも効率的なのか?

- 大きなばらつきを伴う観測値は、小さなばらつきを伴う観測値ほど有益でないため、より少なくて加重

- ◆ WLSは、一般化最小二乗 (GLS) の特殊ケース

## 8-4 加重最小二乗法WLS

### ◆ 例8.6: 金融資産

純金融資産

不均一分散の関数形を想定

TABLE 8.1 Dependent Variable: netffa

Independent Variables	(1) OLS	(2) WLS	(3) OLS	(4) WLS
inc	.821 (.104)	.787 (.106)	.771 (.100)	.740 (.084)
(age - 25) <sup>2</sup>	—	—	-.951 (.0043)	.0175 (.0019)
male	—	—	2.48 (2.06)	1.84 (1.56)
401K年金制度参加	—	—	6.89 (2.29)	5.19 (1.70)
intercept	-10.57 (2.53)	-9.58 (1.65)	-20.98 (3.50)	-16.70 (1.96)
Observations	2,017	2,017	2,017	2,017
R-squared	.0827	.0709	.1279	.1115

WLS推定値の標準誤差はかなり小さい(より効率的になるという理論と整合的)

## 8-4 加重最小二乗法WLS

### ◆ 重要な特殊ケース

- 観測値が都市/郡/州/国/会社ごとの平均値である場合は、その構成要素の数で加重が必要

$$\overline{contrib}_i = \beta_0 + \beta_1 \overline{earn}_i + \beta_2 \overline{age}_i + \beta_3 \overline{mrate}_i + \overline{u}_i$$

企業iの年金制度への平均寄与      企業の平均収入&年齢      企業の制度への寄与率      各企業での誤差の平均

$$\Rightarrow \text{Var}(\overline{u}_i) = \text{Var}\left(\frac{1}{m_i} \sum_{j=1}^{m_i} u_{i,j}\right) = \frac{\sigma^2}{m_i}$$

- 個人レベルで均一分散 → グループ平均では不均一分散
- 企業規模 $m_i$ と等しいウェイトを使用したWLSで推定
- 個人レベルでの均質分散の仮定が正確でない場合、WLS推定後にHRSEを計算

## 8-4 加重最小二乗法WLS

### ◆ 8-4b 未知の不均一分散関数 (feasible GLS)

#### ■ 不均一分散の一般形を想定

$$\text{Var}(u|x) = \sigma^2 \exp(\delta_0 + \delta_1 x_1 + \dots + \delta_k x_k) = \sigma^2 h(x)$$

- 誤差分散 $>0$ であるため、指数関数を使用

$$u^2 = \sigma^2 \exp(\delta_0 + \delta_1 x_1 + \dots + \delta_k x_k) \cdot v$$

- $v$ : 説明変数とは独立している部分の誤差

$$\Rightarrow \log(u^2) = \alpha_0 + \delta_1 x_1 + \dots + \delta_k x_k + e$$

$$\log(\hat{u}^2) = \hat{\alpha}_0 + \hat{\delta}_1 x_1 + \dots + \hat{\delta}_k x_k + error$$

$$\Rightarrow \hat{h}_i = \exp(\hat{\alpha}_0 + \hat{\delta}_1 x_1 + \dots + \hat{\delta}_k x_k)$$

- 推定した不均一分散関数の逆数をWLSのウェイトとして使用

- ◆ Feasible GLSは一致推定量&OLSよりも漸近的効率的

## 8-4 加重最小二乗法WLS

### ◆例8.7 タバコの需要

#### ■ OLSによる推定

$$\widehat{cigs} = -3.64 + .880 \log(\text{income}) - .751 \log(\text{cigpric}) - .501 \text{educ} - .771 \text{age} - .0090 \text{age}^2 - 2.83 \text{restaurn}$$

(24.08) (.728)                      (5.773)                      (1.17)                      (.167)                      (.160)                      (.0017)                      (1.11)                      (1.11)

喫煙本数/日                      所得                      煙草価格                      禁煙レストランの有無

$$n = 807, R^2 = .0526, p\text{-value}_{\text{Breusch-Pagan}} = .000$$

- ◆ 不均一分散の検定: 「均一分散」の仮説を棄却

## 8-4 加重最小二乗法WLS

#### ■ FGLSによる推定

$$\widehat{cigs} = -5.64 + 1.30 \log(\text{income}) - 2.94 \log(\text{cigpric}) - .463 \text{educ} + .482 \text{age} - .0056 \text{age}^2 - 3.46 \text{restaurn}$$

(17.80) (.44)                      (4.46)                      (.120)                      (.097)                      (.0009)                      (.80)

$$n = 807, R^2 = .1134$$

#### ■ 考察

- ◆ 所得弾力性がFGLSでは統計的に有意
- ◆ FGLSは全係数の標準誤差がOLSより小さく、より正確な推定を示唆

## 8-4 加重最小二乗法WLS

### ◆8-4c 不均一分散関数の誤った特定化

#### ■ 不均一分散関数が誤って特定化されると...

- ◆ MLR.1-4のもとでWLSは依然として一致推定量

- しかし頑健な標準誤差HRSEを計算すべき
- また必ずしもMLR.4が成立しているとは限らない

$$E(u_i | x_i) = 0 \Rightarrow E\left(\frac{u_i}{\sqrt{h(x_i)}} \mid x_i\right) = 0$$

- ◆ OLSとWLSの推定値が非常に異なる場合、通常、仮定(例えばMLR.4)が間違っていることを示唆
- ◆ 強い不均一分散がある場合、効率性のために誤った特定化関数を使う方が良いケースが多い

## 8-5 線形確率モデル(再)

### ◆線形確率モデルでのWLS

$$P(y = 1 | x) = p(x) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$$

$$\Rightarrow \text{Var}(y | x) = p(x) [1 - p(x)] \quad \leftarrow \text{LPMでは不均一分散の関数形は既知}$$

$$\Rightarrow \tilde{h}_i = \hat{y}_i (1 - \hat{y}_i) \quad \leftarrow \text{この逆数をWLSのウェイトとして使用}$$

#### ■ 考察

- ◆ LPM予測がゼロ以下または1より大きい場合、実行不可能
- ◆ そのようなケースがまれである場合、数値を0.01 / 0.99に調整
- ◆ それ以外の場合は、OLSで頑健な標準誤差HRSEを計算する方が良い

## 付論 不均一分散の対数

### ◆ Under heteroskedasticity, we assume:

- $\text{Var}[y_i | x_i] = E[y_i - E[y_i | x_i] | x_i]^2 = \sigma_i^2$  (a.1)
- $E[y_i | x_i] = \beta_0 + \beta_1 x_i = \mu_i$  (a.2)

### ◆ By **Taylor series expansion**, we can get

$$\text{■ } f(y_i) \approx f(\mu_i) + f'(\mu_i)(y_i - \mu_i) \quad (\text{a.3})$$

### ◆ Here, since $f(\mu_i)$ can be treated as nonrandom variable under conditional $x$ ,

$$\text{■ } E[f(y_i) | x_i] = f(\mu_i) \quad (\text{a.4})$$

## Cont. 不均一分散の対数

$$\text{Var}[f(y_i) | x_i] = E[f(y_i) - E[f(y_i) | x_i] | x_i]^2 \quad \leftarrow (\text{a.1})$$

$$= E[f(y_i) - f(\mu_i) | x_i]^2 \quad \leftarrow (\text{a.4})$$

$$= E\{f''(\mu_i)(y_i - \mu_i) | x_i\}^2 \quad \leftarrow (\text{a.3})$$

$$= \{f''(\mu_i)\}^2 E[(y_i - \mu_i) | x_i]^2$$

$$= \{f''(\mu_i)\}^2 \sigma_i^2 \quad \leftarrow (\text{a.1})$$

$$\text{If we assume } f(y_i) = \ln(y_i) \text{ \& } \sigma_i^2 = \sigma^2 E[y_i | x_i]^2,$$

$$\{f''(\mu_i)\}^2 \sigma_i^2 = \{1/\mu_i\}^2 \sigma^2 \mu_i^2 \quad \leftarrow (\text{a.2})$$

$$= \sigma^2 \quad (\text{Homoskedasticity})$$