

- 第三章中，我们假设了误差项同方差（MLR. 5）：

$$\text{Var}(u_i | x_{i1}, x_{i2}, \dots, x_{ik}) = \sigma^2$$

- 基于MLR.5，我们计算OLS估计值的方差，建立了高斯-马尔科夫定理，提出了假设检验方法（t检验，F检验）
- 然而，同方差性并不总是成立（例子：储蓄与收入），这种情况称之为异方差性
- 本章将讨论出现异方差性时的一些修正措施

Chapter 8

异方差性

章节框架

- 在这一章中，我们将探讨异方差性
- 首先，我们介绍异方差对OLS估计值性质的影响
- 之后，我们讨论异方差出现时的修正措施以及异方差性的检验方法
- 最后，我们提出异方差情况下最优的估计方法：加权最小二乘（GLS）

异方差性对OLS的影响

- 第三章中，考虑多元线性回归模型：

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

- 通过最小化残差平方和，我们得到OLS估计值

$$\hat{\beta} = \left(\sum_{i=1}^n X_i X_i' \right)^{-1} \sum_{i=1}^n X_i y_i$$

- 异方差性(违反MLR.5)会影响OLS哪些性质？

异方差性对OLS的影响

- **OLS有限样本性质**
 - 期望的无偏性：MLR.1 – MLR.4
 - 方差公式：MLR.1 – MLR.5
 - 高斯-马尔科夫定理：MLR.1 – MLR.5
 - 正态性：MLR.1 – MLR.6
- **OLS大样本性质**
 - 一致性：MLR.1 – MLR.4
 - 渐近正态性：MLR.1 – MLR.5
- 在异方差下，OLS仍然无偏且一致
- 但是，异方差性可能导致其他性质不成立
- OLS不再是最优线性无偏估计量（BLUE）；可能会有其他更有效的线性估计量

异方差性对OLS的影响

- 异方差性对OLS相关统计量的影响
- R方和调整R方的解释不受异方差性的影响：

$$R^2 \equiv SSE/SST = 1 - SSR/SST$$

- t统计量与F统计量在原假设下的分布依赖于OLS的方差形式与正态分布
- 因此，异方差性下t统计量与F统计量将失效

OLS估计后的异方差-稳健推断

- 已经研发出对于未知形式的异方差性稳健的OLS标准误差及其统计量
- 它们至少在大样本下是有效的
- 异方差-稳健的OLS标准误差

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

也叫作White/Huber/Eicker标准误。其中包括原回归以及 x_j 对其他解释变量回归的残差平方和。

$$se(\hat{\beta}_j) = \sqrt{\widehat{Var}(\hat{\beta}_j)}$$

- 使用异方差-稳健的标准误重新构造t检验统计量：其中 α_j 为假设值

$$t_{\hat{\beta}_j} = \frac{\hat{\beta}_j - \alpha_j}{se(\hat{\beta}_j)}$$

- 异方差-稳健的t检验是渐近有效的
- 异方差-稳健的F统计量（瓦尔德统计量）

OLS估计后的异方差-稳健推断

- 例子：小时工资方程

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

	(.105)	(.0075)	(.0052)	(.0001)
	[.107]	[.0078]	[.0050]	[.0001]

异方差稳健标准误与不稳健标准误看上去差不多

- (1) $H_0: \beta_{exper} = 0$

$$t = 7.88 \quad t_{robust} = 8.2 \quad \text{t统计量差不多}$$

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

$$F = 17.95 \quad \text{F统计量也差不多}$$

$$F_{robust} = 17.99$$

如果异方差性强，差别就会很大。

对异方差性的检验

- 我们总是关心OLS是否能保持BLUE, 通常的t检验F检验是否有效
- 因此, 我们想检验是否真的存在异方差性
- 同方差假设:

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

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

- 同方差假设下 u^2 的条件均值不随 $x_1, x_2, \dots, x_k$ 变化

对异方差性的检验

- 用残差的平方来对其他解释变量进行回归：

$$\hat{u}^2 = \delta_0 + \delta_1 x_1 + \cdots + \delta_k x_k + error$$

- F检验：

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

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

- 布罗施-帕甘（Breusch-Pagan, BP）异方差检验：

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

另一种检验统计量（拉格朗日乘数统计量，LM）。该统计量越高（高R²），越倾向于拒绝原假设

对异方差性的检验

- BP检验步骤：

(1) 计算OLS估计的残差平方 $\hat{u}^2$

(2) 进行回归 $\hat{u}^2 = \delta_0 + \delta_1 x_1 + \cdots + \delta_k x_k + error$ 并计算回归的R方: $R_{\hat{u}^2}^2$

(3) 利用 $R_{\hat{u}^2}^2$ 计算F 统计量或LM统计量的取值，并计算相应的p值，如果p值<显著性水平则拒绝同方差的原假设

对异方差性的检验

- 例子：住房价格方程中的异方差性

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

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

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

异方差

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

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

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

在log形式下，同方差假设不能被拒绝

对异方差性的检验

- F检验和BP检验只考察了残差平方与解释变量的线性关系

- White异方差检验

用残差平方对解释变量、其平方及其交互项进行回归

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

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

较BP检验来说，White检验考察更一般的异方差的偏差

$$LM = n \cdot R_{\hat{u}^2}^2 \sim \chi_9^2$$

- White检验的缺点

- 估计参数过多（例如，若 $k=6$ ，则有27个估计参数）

对异方差性的检验

- White检验的特例:

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


间接检验解释变量、其平方及其交互项对残差平方的影响，因为y的被预测值及其平方包含了以上解释变量及其变形。

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

- 例子：对数住房价格方程中怀特检验的特殊形式

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

加权最小二乘

- 在特殊的异方差结构下，我们调整估计方法以获得最有效的估计
- 除了一个常数倍数以外异方差是已知的（ Heteroskedasticity is known up to a multiplicative constant ）

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

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

除 σ^2 外异方差的函数形式是已知的

- 变换模型，使得变换之后的模型满足同方差假设

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

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

加权最小二乘

- 变形后的模型是同方差的

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

- 例子：储蓄与收入

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

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

注意：这个回归没有截距项

- 如果其他的高斯-马尔科夫假定都成立，则对变形后的模型使用OLS是最优无偏线性估计

加权最小二乘

- 变形后模型的OLS回归等价于加权最小二乘 (weighted least squares, WLS)

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

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

在优化问题中，对具有更大方差的观测值赋予更小的权重

- WLS是广义最小二乘 (generalized least squares, GLS) 的一种特殊形式

加权最小二乘

- 例子：金融财富方程

TABLE 8.1 Dependent Variable: *nettfa*

Independent Variables	(1) OLS	(2) WLS	(3) OLS	(4) WLS
<i>inc</i>	.821 (.104)	.787 (.063)	.771 (.100)	.740 (.064)
$(age - 25)^2$	—	—	.0251 (.0043)	.0175 (.0019)
<i>male</i>	—	—	2.48 (2.06)	1.84 (1.56)
<i>e401k</i>	—	—	6.89 (2.29)	5.19 (1.70)
<i>intercept</i>	-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

金融财富净值

异方差的假设形式

WLS估计量具有明显更小的标准误，符合更有效的预期。

参与401K计划

© Cengage Learning, 2016

加权最小二乘

- 例子：数据为平均值
- 如果观测值是城市/县/州/国家/公司层面的均值，则应根据单位规模进行加权

公司i的养老金计划平均投入量

公司i的平均收入
和年龄

公司为投入匹
配的数量

异方差的
误差项

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

$$Var(\bar{u}_i | \mathbf{x}_i) = Var\left(\frac{1}{m_i} \sum_{e=1}^{m_i} u_{i,e} \mid \mathbf{x}_i\right) = \frac{\sigma^2}{m_i}$$

如果在个人层面的误差是同方差时的误差方差

如果误差在个人层面是同方差的，则应该使用等同于企业规模 m_i 权重的WLS。如果个人层面的同方差不是一定的，那可以在WLS后计算稳健的标准误（即对于变化后模型）。

加权最小二乘

- 模型化异方差形式（可行GLS, feasible GLS, FGLS）

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

假设异方差的一般形式；
指数函数用来保证为正

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

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

倍数误差（假设：独立于解释变量）

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

使用异方差函数估计值的倒数
作为WLS的权重

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

可行GLS是一致的，而且比OLS更加渐近有效

加权最小二乘

- 例子：对香烟的需求
- OLS估计

每天抽烟数量

$$\begin{aligned}\widehat{cigs} = & -3.64 + .880 \log(income) - .751 \log(cigpric) \\ & (24.08) \quad (.728) \quad (5.773) \\ & - .501 educ - .771 age - .0090 age^2 - 2.83 restaurn \\ & (.167) \quad (.160) \quad (.0017) \quad (1.11)\end{aligned}$$

log的收入和香烟价格

在餐馆禁止抽烟
(虚拟变量)

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

拒绝同方差性

加权最小二乘

- FGLS估计

现在统计上显著了

$$\widehat{cigs} = - \frac{5.64}{(17.80)} + \frac{1.30}{(.44)} \log(income) - \frac{2.94}{(4.46)} \log(cigpric)$$
$$- \frac{.463}{(.120)} educ + \frac{.482}{(.097)} age - \frac{.0056}{(.0009)} age^2 - \frac{3.46}{(.80)} restaurn$$

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

- 讨论

- 收入弹性现在是统计显著的

加权最小二乘

- 如果异方差函数错了会怎样？

- 如果异方差函数被错误设定，在MLR. 1 - MLR. 4下，WLS仍然是一致的，但是应该计算稳健标准误
- WLS在MLR. 4下是一致的，但在MLR. 4' 下却不一定一致

$$E(u_i | \mathbf{x}_i) = 0 \quad \Rightarrow \quad E \left(\left(u_i / \sqrt{h(\mathbf{x}_i)} \right) | \mathbf{x}_i \right) = 0$$

- 如果OLS和WLS的估计值差别很大，这意味着可能一些假定（例如MLR. 4）错了
- 如果异方差函数被错误设定，那理论上不能保证WLS比OLS更有效
- （注意：经验上讲，如果具有很强的异方差性，使用一个错误的异方差形式来提高有效性也是不错的选择）

再议线性概率模型

- 在线性概率模型（LPM）中的WLS

$$P(y = 1|\mathbf{x}) = p(\mathbf{x}) = \beta_0 + \beta_1 x_1 + \cdots + \beta_k x_k$$

$$\Rightarrow \text{Var}(y|\mathbf{x}) = p(\mathbf{x}) [1 - p(\mathbf{x})]$$

在LPM中，异方差的准确形式是知道的

$$\Rightarrow \hat{h}_i = \hat{y}_i (1 - \hat{y}_i)$$

在WLS中使用倒数来作为权重

- 讨论

- 如果LPM的预测值小于0或大于1，则WLS不可行
- 如果这种情况很少见，可以将其调整为0.01/0.99这种值
- 否则，最好使用考虑稳健标准误的OLS回归

本章小节

- 异方差性虽然不会导致 OLS 估计量的偏误和不一致性，却致通常的标准误和检验统计量都不再成立
- 我们说明了如何计算异方差—稳健的标准误和 t 统计量
- 我们讨论了检验异方差性的两种常见方法:布罗施-帕甘检验和怀特检验
- 出现异方差性时，OLS 就不再是最优线性无偏的估计量。若知道异方差性的形式，则可使用WLS/GLS
- 更常见的是，我们在应用 WLS之前必须先估计一个异方差模型，由此得到可行的 GLS (FGLS) 估计量