

# Produced with a Trial Version of PDF Annotator - www.PDFAnno

## Motivation of using OLS

- As it turns out, an extremely useful property of OLS is that, even if the relationship between the  $x$  variables and the  $y$  variable is nonlinear, OLS yields the best linear predictor (BLP) of  $y$  given  $x$ .
- The sense of “best” is that the OLS prediction is the linear prediction that minimizes the mean squared error.
- This is a significant (though often overlooked) advantage of OLS over nonlinear estimation methods.

1.  $f$ ? 标准: MSE.  $f$  是 CEF
2. CEF 假如如 Linear. LSP 就是 CEF
3. CEF 不知道. 所有线性逼近中, LSP 是最好的.

Produced with a Trial Version of PDF Annotator - www.PDFAnno

- Consider the following estimation problem: choose  $f$  so that it minimizes some function of the forecast error,  $y - f(\mathbf{x})$ .
- If the criterion is to minimize the **mean squared error**,

$$\underline{E[(y - f(\mathbf{x}))^2]},$$

then it turns out, the function  $f$  that minimizes the mean squared error is simply the **conditional expectation function** (CEF)  $E[y|\mathbf{x}]$ .

$$\begin{aligned} (y - f(\mathbf{x}))^2 &= ((y - E[y|\mathbf{x}]) + (E[y|\mathbf{x}] - f(\mathbf{x})))^2 \\ &= (y - E[y|\mathbf{x}])^2 + 2(y - E[y|\mathbf{x}])(E[y|\mathbf{x}] - f(\mathbf{x})) + (E[y|\mathbf{x}] - f(\mathbf{x}))^2 \end{aligned}$$

Take expectations, it could easily be seen

$$\begin{aligned} \text{MSE} \equiv E[(y - f(\mathbf{x}))^2] &= E[(y - E[y|\mathbf{x}])^2] + E[(E[y|\mathbf{x}] - f(\mathbf{x}))^2] \\ &\geq E[(y - E[y|\mathbf{x}])^2] \end{aligned}$$

- Note:  $E[y|\mathbf{x}]$  could be highly nonlinear.

Produced with a Trial Version of PDF Annotator - www.PDFAnno

- Therefore, the conditional expectation  $E[y|x]$  is the best predictor of  $y$  (in the sense that it minimizes the mean squared error).
- What is the best linear predictor of  $y$  based on  $x$ ?

$$\arg \min_{\tilde{\beta}} E[(y - \mathbf{x}'\tilde{\beta})^2]$$

- The first order condition gives

$$E[\mathbf{x}(y - \mathbf{x}'\tilde{\beta})] = \mathbf{0},$$

so the solution for  $\mathbf{b}$  is

$$\beta^* \equiv E[\mathbf{x}\mathbf{x}']^{-1}E[\mathbf{x}y]$$

- $\beta^*$  is defined as the **least squares projection coefficients**, while  $\mathbf{x}'\beta^*$  is defined as the **least squares (or linear) projection** of  $y$  on  $x$ .

LSP

# Produced with a Trial Version of PDF Annotator - www.PDFAnno

## CEF and linear projection

1. Suppose the CEF is linear. Then the least squares projection is the CEF.

- Proof: Suppose  $E[y|x] = x'\tilde{\beta}$  for some  $\tilde{\beta}$ . Note that  $E[x(y - E[y|x])] = 0$ , substitute  $E[y|x] = x'\tilde{\beta}$  to find that  $\tilde{\beta} = \beta^* = E[xx']^{-1}E[xy]$ .

- Therefore, if it happens that CEF is linear, then the linear projection is the best predictor.

2. The best linear approximation to  $E[y|x]$  is  $x'\beta^*$ .

- Proof: This is the same as saying that  $\beta^*$  minimizes

$$\arg \min_{\tilde{\beta}} E[(E[y|x] - x'\tilde{\beta})^2].$$

CEF

- To see why, write

$$\begin{aligned}
 (y - \mathbf{x}'\tilde{\beta})^2 &= ((y - \mathbb{E}[y|\mathbf{x}]) + (\mathbb{E}[y|\mathbf{x}] - \mathbf{x}'\tilde{\beta}))^2 \\
 &= \cancel{\beta} y - \mathbb{E}[y|\mathbf{x}]^2 + (\mathbb{E}[y|\mathbf{x}] - \mathbf{x}'\tilde{\beta})^2 \\
 &\quad + 2(y - \mathbb{E}[y|\mathbf{x}])(\mathbb{E}[y|\mathbf{x}] - \mathbf{x}'\tilde{\beta})
 \end{aligned}$$

- The first term does not involve  $\tilde{\beta}$ , and the last term has expectation zero. The CEF-approximation problem, therefore has the same solution as the best-linear-predictor problem,  $\arg \min_{\tilde{\beta}} \mathbb{E}[(y - \mathbf{x}'\tilde{\beta})^2]$
- Therefore, in the prediction context, linear projection is the best linear predictor while CEF is the best unrestricted predictor.
- On the other hand, even if CEF is nonlinear, linear regression provides the best linear approximation to it.

## 第 7 章 异方差与 GLS

### 7.1 异方差的后果

“异方差” (heteroskedasticity) 是违背球型扰动项假设的一种情形, 即  $\text{Var}(\varepsilon_i | \mathbf{X})$  依赖于  $i$ , 不是常数。

在异方差的情况下:

(1) OLS 估计量依然无偏、一致且渐近正态, 因为在证明这些性质时并未用到“同方差”的假定。

(2) OLS 估计量方差  $\text{Var}(\mathbf{b} | \mathbf{X})$  的表达式不再是  $\sigma^2(\mathbf{X}'\mathbf{X})^{-1}$ ，因为  $\text{Var}(\boldsymbol{\varepsilon} | \mathbf{X}) \neq \sigma^2 \mathbf{I}$ 。因此，通常的  $t$  检验、 $F$  检验也失效了。

(3) 高斯-马尔可夫定理不再成立，OLS 不再是 BLUE。在异方差的情况下，GLS 才是 BLUE。

为何 OLS 不再是 BLUE？

假设  $\text{Var}(\varepsilon_i | \mathbf{X})$  是某解释变量  $x_i$  的增函数，参见图 7.1。




图 7.1 异方差的一种情形

GLS 及其特例“加权最小二乘法” (Weighted Least Square, 简记 WLS), 通过对不同数据包含信息量的不同进行加权以提高效率。



## 7.2 异方差的例子

(1) 消费函数:

$$C_i = \alpha + \beta Y_i + \varepsilon_i$$

其中,  $C$ 为消费,  $Y$ 为收入。富人的消费计划较有弹性, 而穷人的消费多为必需品。富人的消费支出难测量, 包含较多测量误差。

(2) 企业的投资、销售收入与利润: 大型企业的商业活动以亿元计, 而小型企业以万元计, 扰动项规模不同。

(3) 组间异方差: 样本包含两组(类)数据, 第一组为自我雇佣者(企业主、个体户)的收入, 第二组为打工族的收入, 前者的收入波动比后者大。

John Cochrane

"Asset Pricing"


(4) 组平均数：如果数据为组平均数，则大组平均数的方差要比小组平均数的方差小。比如，全国各省的人均 GDP，人口多的省份其方差较小，方差与人口数成反比。

(5) 时间序列数据中也可能出现条件异方差，比如第 22 章的 ARCH 模型。

## 7.3 异方差的检验

### 1. 看残差图(residual plot)

看“残差 $e_i$ 与拟合值 $\hat{y}_i$ 的散点图”(residual-versus-fitted plot)，或“残差 $e_i$ 与某个解释变量 $x_{ik}$ 的散点图”(residual-versus-predictor plot)。



## 2. 怀特检验(White test)

在条件同方差下，稳健标准误还原为普通标准误，二者的差别

可用来度量条件异方差。怀特检验正是基于这一思想。

在同方差的原假设  $H_0: E(\varepsilon_i^2 | \mathbf{X}) = \sigma^2$  下，稳健协方差矩阵与普通协方差矩阵之差收敛到一个零矩阵：

$$\hat{\mathbf{S}} - s^2 \mathbf{S}_{XX} = \frac{1}{n} \sum_{i=1}^n e_i^2 \mathbf{x}_i \mathbf{x}_i' - s^2 \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' = \frac{1}{n} \sum_{i=1}^n (e_i^2 - s^2) \mathbf{x}_i \mathbf{x}_i' \xrightarrow{p} \mathbf{0}_{K \times K}$$

实际操作上，进行辅助回归：

$$e_i^2 \xrightarrow{\text{OLS}} \text{常数} + \psi' \gamma$$

并检验  $\psi_i$  中所有变量的系数  $\gamma$  均为 0。

$$\mathbf{x} = \begin{bmatrix} 1 \\ x_2 \\ x_3 \end{bmatrix}$$

$$\Psi = \begin{bmatrix} x_2 \\ x_3 \\ x_2^2 \\ x_3^2 \\ x_2 x_3 \end{bmatrix}$$

如果 $R^2$ 很低，意味着 $e_i^2$ 无法由解释变量及其平方项与交叉项来解释，故倾向于接受同方差的原假设。可以证明：

$$nR^2 \xrightarrow{d} \chi^2(m)$$

如果 $nR^2$ 很大(超过临界值)，则拒绝原假设 $H_0$ 。

在大样本中， $nR^2$ 与检验整个方程显著性的 $F$ 统计量渐近等价。

对于回归方程  $y_i = \beta_1 + \beta_2 x_{i2} + \cdots + \beta_K x_{iK} + \varepsilon_i$ ，检验原假设  $H_0: \beta_2 = \cdots = \beta_K = 0$ ，则 $F$ 统计量：

$$F = \frac{R^2 / (K - 1)}{(1 - R^2) / (n - K)} \sim F(K - 1, n - K)$$

在大样本下， $F$ 分布与 $\chi^2$ 分布等价(第5章附录，见下)，即

$$(K - 1)F = \frac{(n - K)R^2}{(1 - R^2)} \xrightarrow{d} \chi^2(K - 1) \quad "nR^2"$$

在原假设成立的情况下，当 $n \rightarrow \infty$ 时， $(n - K) \rightarrow n$ ， $(1 - R^2) \rightarrow 1$ ，故 $(K - 1)F \rightarrow nR^2$ ，故 $F$ 检验与 $nR^2$ 检验在大样本下等价。

怀特检验的优点是，可以检验任何形式的异方差；缺点是，如果 $H_0$ 被拒绝，并不提供有关异方差具体形式的信息。

### A5.3 $F$ 分布与 $\chi^2$ 分布在大样本下是等价的

**命题** 假设  $F \sim F(m, n-K)$  分布，则当  $n \rightarrow \infty$  时，  
 $mF \xrightarrow{d} \chi^2(m)$ 。

**证明：** 因为  $F \sim F(m, n-K)$ ，故可设  $F = \frac{\chi^2(m)/m}{\chi^2(n-K)/(n-K)}$ 。

根据  $\chi^2$  分布的性质， $E[\chi^2(n-K)] = n-K$ ，而  
 $\text{Var}[\chi^2(n-K)] = 2(n-K)$ 。

故  $F$  统计量分母的期望值为：

$$E\left[\chi^2(n-K)/(n-K)\right] = 1$$

$F$  统计量分母的方差为:

$$\text{Var}\left[\chi^2(n-K)/(n-K)\right] = \frac{2(n-K)}{(n-K)^2} = \frac{2}{n-K} \rightarrow 0 \quad (\text{当 } n \rightarrow \infty \text{ 时})$$

故分母依均方收敛于 1。

因此, 分母依概率收敛于 1, 即  $\chi^2(n-K)/(n-K) \xrightarrow{p} 1$ 。

所以,  $F \xrightarrow{d} \chi^2(m)/m$ 。

故  $mF \xrightarrow{d} \chi^2(m)$ 。



### 3. BP 检验(Breusch and Pagan, 1979)

假设回归模型为  $y_i = \beta_1 + \beta_2 x_{i2} + \cdots + \beta_K x_{iK} + \varepsilon_i$ , 检验以下原假设:

$$H_0: E(\varepsilon_i^2 | x_2, \cdots, x_K) = \sigma^2$$

如果  $H_0$  不成立, 则条件方差  $E(\varepsilon_i^2 | x_2, \cdots, x_K)$  是  $(x_2, \cdots, x_K)$  的函数, 称为“条件方差函数”(conditional variance function)。

BP 检验假设此条件方差函数为线性函数:

$$\varepsilon_i^2 = \delta_1 + \delta_2 x_{i2} + \cdots + \delta_K x_{iK} + u_i$$

原假设简化为

$$H_0 : \delta_2 = \dots = \delta_K = 0$$

由于  $\varepsilon_i$  不可观测，故使用  $e_i^2$  进行辅助回归：

$$e_i^2 = \delta_1 + \delta_2 x_{i2} + \dots + \delta_K x_{iK} + error_i$$

使用  $nR^2$  统计量：

$$\underline{nR^2 \xrightarrow{d} \chi^2(K-1)}$$

BP 检验与怀特检验的区别在于，后者还包括平方项与交叉项。

BP 检验的优点在于其建设性，可帮助确认异方差的具体形式。

## 7.4 异方差的处理

### 1. 使用“OLS + 稳健标准误”

一种处理方法是，仍进行 OLS 回归，但使用稳健标准误。

这是最简单，也是目前通用的方法。只要样本容量较大，即使在异方差的情况下，若使用稳健标准误，则所有参数估计、假设检验均可照常进行。

但还可能存在比 OLS 更有效的方法，比如 GLS。

## 2. 广义最小二乘法(GLS)

假设  $\text{Var}(\boldsymbol{\varepsilon} | \mathbf{X}) = \sigma^2 \mathbf{V}(\mathbf{X}) \neq \sigma^2 \mathbf{I}_n$ ，其中  $\mathbf{V}(\mathbf{X})$  为对称正定矩阵且已知，可能依赖于  $\mathbf{X}$ 。

GLS 的基本思想是，通过变量转换，使得转换后的模型满足球型扰动项的假定。

**命题** 对于对称正定矩阵  $\mathbf{V}_{n \times n}$ ，存在非退化矩阵  $\mathbf{C}_{n \times n}$ ，使得  $\mathbf{V}^{-1} = \mathbf{C}'\mathbf{C}$ 。

在一维情况下，“ $V$  正定”即要求  $V$  为正数，故  $\frac{1}{V}$  也是正数，可分解为  $\frac{1}{\sqrt{V}} \cdot \frac{1}{\sqrt{V}}$ ；如果  $V$  为负数，则无法进行此分解。

矩阵  $C$  不唯一，但不影响 GLS 的最终结果。

将原回归模型  $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$  两边同时左乘矩阵  $C$ ：

$$\underline{C}\mathbf{y} = \underline{C}\mathbf{X}\boldsymbol{\beta} + \underline{C}\boldsymbol{\varepsilon}$$

定义变量转换：

$$\tilde{\mathbf{y}} \equiv C\mathbf{y}, \quad \tilde{\mathbf{X}} \equiv C\mathbf{X}, \quad \tilde{\boldsymbol{\varepsilon}} \equiv C\boldsymbol{\varepsilon}$$

可将模型写为

$$\tilde{y} = \tilde{X}\beta + \tilde{\varepsilon}$$

变换后的模型仍满足严格外生性:

$$E(\tilde{\varepsilon} | \tilde{X}) = E(C\varepsilon | CX) = E(C\varepsilon | X) = CE(\varepsilon | X) = 0$$

球型扰动项的假定也得到满足:

$$\begin{aligned} \text{Var}(\tilde{\varepsilon} | \tilde{X}) &= E(\tilde{\varepsilon}\tilde{\varepsilon}' | X) = E(C\varepsilon\varepsilon'C' | X) = CE(\varepsilon\varepsilon' | X)C' = \sigma^2 CV C' \\ &= \sigma^2 C(V^{-1})^{-1} C' = \sigma^2 \boxed{C(C'C)^{-1} C'} = \sigma^2 CC^{-1}(C')^{-1} C' = \sigma^2 \mathbf{I}_n \end{aligned}$$

故高斯-马尔可夫定理成立。

$C_{n \times n}$ , 可逆.

对变换后的模型使用 OLS 即得到 GLS 估计量：

$$\begin{aligned}\hat{\beta}_{\text{GLS}} &= (\tilde{X}'\tilde{X})^{-1} \tilde{X}'\tilde{y} = \left[ (\mathbf{CX})' (\mathbf{CX}) \right]^{-1} (\mathbf{CX})' \mathbf{C}\mathbf{y} \\ &= (\mathbf{X}'\mathbf{C}'\mathbf{C}\mathbf{X})^{-1} \mathbf{X}'\mathbf{C}'\mathbf{C}\mathbf{y} = (\mathbf{X}'\mathbf{V}^{-1}\mathbf{X})^{-1} \mathbf{X}'\mathbf{V}^{-1}\mathbf{y}\end{aligned}$$

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

虽然  $\mathbf{C}$  不唯一，但  $\hat{\beta}_{\text{GLS}}$  唯一，因为  $\hat{\beta}_{\text{GLS}}$  不依赖于  $\mathbf{C}$ 。

由于高斯-马尔可夫定理成立，故  $\hat{\beta}_{\text{GLS}}$  是 BLUE，比 OLS 更有效。但前提是必须知道协方差矩阵  $\mathbf{V}$ 。

### 3. 加权最小二乘法(WLS)

假设仅存在异方差，无自相关， $V(X)$ 为对角矩阵。

方差小的数据提供的信息量大。WLS 根据信息量大小进行加权。

假定  $E(\varepsilon_i^2 | \mathbf{x}_i) = \text{Var}(\varepsilon_i | \mathbf{x}_i) = \sigma^2 v_i(\mathbf{X})$ ，即

$$V = \begin{pmatrix} v_1 & & & 0 \\ & v_2 & & \\ & & \ddots & \\ 0 & & & v_n \end{pmatrix}, \quad V^{-1} = \begin{pmatrix} 1/v_1 & & & 0 \\ & 1/v_2 & & \\ & & \ddots & \\ 0 & & & 1/v_n \end{pmatrix}$$



由于  $V^{-1} = C'C$ ，可知

$$C = C' = \begin{pmatrix} 1/\sqrt{v_1} & & & 0 \\ & 1/\sqrt{v_2} & & \\ & & \ddots & \\ 0 & & & 1/\sqrt{v_n} \end{pmatrix}$$

$$\tilde{\mathbf{y}} \equiv C\mathbf{y} = \begin{pmatrix} 1/\sqrt{v_1} & & & 0 \\ & 1/\sqrt{v_2} & & \\ & & \ddots & \\ 0 & & & 1/\sqrt{v_n} \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} y_1/\sqrt{v_1} \\ y_2/\sqrt{v_2} \\ \vdots \\ y_n/\sqrt{v_n} \end{pmatrix}$$

$$\tilde{\mathbf{X}} \equiv \mathbf{CX} = \begin{pmatrix} 1/\sqrt{v_1} & & & 0 \\ & 1/\sqrt{v_2} & & \\ & & \ddots & \\ 0 & & & 1/\sqrt{v_n} \end{pmatrix} \begin{pmatrix} x_{11} & \dots & x_{1K} \\ x_{21} & \dots & x_{2K} \\ \vdots & & \vdots \\ x_{n1} & \dots & x_{nK} \end{pmatrix}$$

$$= \begin{pmatrix} x_{11}/\sqrt{v_1} & \dots & x_{1K}/\sqrt{v_1} \\ x_{21}/\sqrt{v_2} & \dots & x_{2K}/\sqrt{v_2} \\ \vdots & & \vdots \\ x_{n1}/\sqrt{v_n} & \dots & x_{nK}/\sqrt{v_n} \end{pmatrix}$$

故权重为 $1/\sqrt{v_i}$  (标准差的倒数)。对于第  $i$  个观测值, 回归方程为

$$i, \quad \frac{y_i}{\sqrt{v_i}} = \beta_1 \frac{x_{i1}}{\sqrt{v_i}} + \beta_2 \frac{x_{i2}}{\sqrt{v_i}} + \cdots + \beta_K \frac{x_{iK}}{\sqrt{v_i}} + \frac{\varepsilon_i}{\sqrt{v_i}}$$

新扰动项为 $\varepsilon_i/\sqrt{v_i}$ , 可将 WLS 视为最小化“加权的残差平方和”:

$$\min_{\beta} \text{SSR} = \sum_{i=1}^n \left( \varepsilon_i / \sqrt{v_i} \right)^2 = \sum_{i=1}^n \frac{e_i^2}{v_i}$$

从这个角度来看, 权重为 $1/v_i$ , Stata 也是这样约定的。

$$\begin{bmatrix} \sigma_1^2 & \sigma_{12} & \sigma_{13} & \sigma_{1n} \\ & \sigma_2^2 & & \\ & & \ddots & \\ & & & \sigma_n^2 \end{bmatrix} \quad n + n-1 + \dots + 1 = \frac{(n+1)n}{2}$$

#### 4. 可行广义最小二乘法(Feasible GLS, 简记 FGLS)

必须先用样本数据估计  $V(X)$ , 然后才能使用 GLS, 称为 FGLS 或“可行加权最小二乘法”(Feasible WLS, 简记 FWLS), 即

$$\hat{\beta}_{\text{FGLS}} = (X' \hat{V}^{-1} X)^{-1} X' \hat{V}^{-1} y$$

其中,  $\hat{V}$  是  $V$  的一致估计。

$V(X)$  包含很多参数。实践中, 常考虑只有异方差, 或只有一阶自相关的情形(参见第 8 章)。

以 FWLS 为例。在作 BP 检验时, 通过辅助回归

OLS.

$$e_i^2 = \delta_1 + \delta_2 x_{i2} + \cdots + \delta_K x_{iK} + error_i \quad \hat{\sigma}_i^2 \rightarrow \hat{v}_i$$

就可获得  $\sigma_i^2$  的估计值  $\hat{\sigma}_i^2$ 。

为保证  $\hat{\sigma}_i^2$  为正，假设辅助回归为指数函数的形式：

$$e_i^2 = \sigma^2 \exp(\delta_1 + \delta_2 x_{i2} + \cdots + \delta_K x_{iK}) v_i$$

其中， $v_i$  为乘积形式的扰动项。取对数后可得

$$\ln e_i^2 = (\ln \sigma^2 + \delta_1) + \delta_2 x_{i2} + \cdots + \delta_K x_{iK} + \ln v_i$$

得到对  $\ln e_i^2$  的预测值，记为  $\ln \hat{\sigma}_i^2$ ，进而得到拟合值  $\hat{\sigma}_i^2 = e^{\ln \hat{\sigma}_i^2}$ ，然后以  $1/\hat{\sigma}_i^2$  为权重进行 WLS 估计。

## 5. 究竟使用“OLS + 稳健标准误”还是 FWLS

理论上，GLS 是 BLUE，但 FGLS 既非线性估计，也不是无偏估计，无资格参加 BLUE 的评选。

根据方程(7.22)， $\hat{\beta}_{\text{FGLS}} = (\mathbf{X}'\hat{\mathbf{V}}^{-1}\mathbf{X})^{-1}\mathbf{X}'\hat{\mathbf{V}}^{-1}\mathbf{y}$ ，而 $\hat{\mathbf{V}}$ 是数据 $(\mathbf{y}, \mathbf{X})$ 的非线性函数，故 $\hat{\beta}_{\text{FGLS}}$ 是 $\mathbf{y}$ 的非线性函数，一般来说是有偏的。

FWLS 的优点主要体现在大样本理论中。如果 $\hat{\mathbf{V}}$ 是 $\mathbf{V}$ 的一致估计，则 FWLS 一致，且在大样本下比 OLS 更有效。

FWLS 的缺点是必须估计条件方差函数 $\text{Var}(\varepsilon_i | \mathbf{x}_i)$ ，而通常不知道条件方差函数的具体形式。如果该函数的形式设定不正确，则

根据 FWLS 计算的标准误可能失效，导致不正确的统计推断。

使用“OLS + 稳健标准误”的好处是，对回归系数及标准误的估计都一致，不需要知道条件方差函数的形式。Stata 操作十分简单，只要在命令 `reg` 之后加选择项“`_robust`”即可。

总之，“OLS + 稳健标准误”更为稳健，而 FWLS 更有效。必须在稳健性与有效性之间做选择。

由于“病情”通常难以诊断，故特效药也可能失效或起反作用。如果对  $V$  的估计不准，则 FGLS 的性能可能还不如 OLS。Stock and Watson (2011) 推荐，大多数情况下应使用“OLS + 稳健标准误”。

## 第 8 章 自 相 关

$i=1, \dots, N.$

### 8.1 自相关的后果

如果存在  $i \neq j$ , 使得  $E(\varepsilon_i \varepsilon_j | \mathbf{X}) \neq 0$ , 即  $\text{Var}(\boldsymbol{\varepsilon} | \mathbf{X})$  的非主对角线元素不全为 0, 则存在“自相关”(autocorrelation)或“序列相关”(serial correlation)。

在有自相关的情况下:

(1) OLS 估计量依然无偏且一致, 因为在证明这些性质时, 并未用到“无自相关”的假定;



Gordin's CLT.

MDS. 没有自相关.

(2) OLS 估计量依然服从渐近正态分布;

(3) OLS 估计量方差  $\text{Var}(\mathbf{b} | \mathbf{X})$  的表达式不再是  $\sigma^2(\mathbf{X}'\mathbf{X})^{-1}$ , 因为  $\text{Var}(\boldsymbol{\varepsilon} | \mathbf{X}) \neq \sigma^2 \mathbf{I}$ , 通常的  $t$  检验、 $F$  检验也失效了;

(4) 高斯-马尔可夫定理不再成立, OLS 不再是 BLUE。

假设扰动项存在正自相关, 即  $E(\varepsilon_i \varepsilon_j | \mathbf{X}) > 0$ , 参见图 8.1。




图 8.1 自相关的后果

## 8.2 自相关的例子

(1) 时间序列的自相关：经济活动具有持久性，比如，相邻两年的 GDP 增长率、通货膨胀率；意外事件或新政策的效应需逐步释放；最优资本存量需若干年投资才能达到(滞后的调整过程)。

(2) 截面数据的自相关：相邻单位间可能存在“溢出效应”(spillover effect or neighborhood effect)，称为“空间自相关”(spatial autocorrelation)。比如，相邻省份、国家间的经济活动相互影响；相邻地区的农产量受类似天气影响；同一社区内房屋价格相关。

(3) 对数据的人为处理：数据中包含移动平均数(moving average)、内插值或季节调整时。

(4) 设定误差(misspecification): 模型设定中遗漏了某个自相关的解释变量, 被纳入到扰动项中。

## 8.3 自相关的检验

### 1. 画图

可将 $e_t$ 与 $e_{t-1}$ 画成散点图。

也可画残差的“自相关图”(correlogram), 显示各阶样本自相关系数(命令 ac)或偏自相关系数(命令 pac)。此法虽直观, 不严格。

$$\text{Corr}(y_t, y_{t-1})$$

## 2. BG 检验

对于  $y_t = \beta_0 + \beta_1 x_{t1} + \cdots + \beta_K x_{tK} + \varepsilon_t$ ，假设存在一阶自相关，即  $\varepsilon_t = \rho \varepsilon_{t-1} + u_t$ ，其中  $u_t$  为白噪声，并检验  $H_0: \rho = 0$ 。

由于可能存在高阶自相关，考虑  $p$  阶自回归：

$$\varepsilon_t = \rho_1 \varepsilon_{t-1} + \cdots + \rho_p \varepsilon_{t-p} + u_t$$

检验  $H_0: \rho_1 = \cdots = \rho_p = 0$ 。由于  $\{\varepsilon_t\}$  不可观测，故用  $\{e_t\}$  替代，并引入所有解释变量，考虑辅助回归：

$$e_t \xrightarrow{\text{OLS}} x_{t1}, \dots, x_{tK}, e_{t-1}, \dots, e_{t-p} \quad (t = p+1, \dots, n)$$

由于使用 $e_{t-p}$ ，损失 $p$ 个样本值，故样本容量仅为 $(n-p)$ 。

使用 $nR^2$ 形式的 LM 统计量：

$$(n-p)R^2 \xrightarrow{d} \chi^2(p)$$

如果 $(n-p)R^2$ 超过 $\chi^2(p)$ 的临界值，拒绝“无自相关”的原假设。  
此检验被称为“Breusch-Godfrey 检验”，简称 BG 检验。

Davidson and MacKinnon(1993)建议:

把残差向量 $\mathbf{e}$ 中因滞后而缺失的项,用其期望值 $E(\mathbf{e}) = \mathbf{0}$ 来代替;

保持样本容量仍为 $n$ ,使用统计量:

$$nR^2 \xrightarrow{d} \chi^2(p)$$

Davidson-MacKinnon 方法为 Stata 的默认设置。

### 3. Box-Pierce Q 检验

残差的各阶样本自相关系数：

$$\hat{\rho}_j \equiv \frac{\sum_{t=j+1}^n e_t e_{t-j}}{\sum_{t=1}^n e_t^2} \quad (j=1, 2, \dots, p)$$

如果  $H_0 : \rho_1 = \dots = \rho_p = 0$  成立，则  $\hat{\rho}_j \xrightarrow{p} 0$ ， $\sqrt{n}\hat{\rho}_j \xrightarrow{d}$  正态分布， $j=1, 2, \dots, p$ 。

残差的各阶样本自相关系数平方和的  $n$  倍，就是“Box-Pierce Q 统计量”：

$$Q_{BP} \equiv n \sum_{j=1}^p \hat{\rho}_j^2 \xrightarrow{d} \chi^2(p)$$



经改进的“Ljung-Box Q 统计量”:

$$Q_{LB} \equiv n(n+2) \sum_{j=1}^p \frac{\hat{\rho}_j^2}{n-j} \xrightarrow{d} \chi^2(p)$$

这两种 Q 统计量在大样本下等价，但 Ljung-Box Q 统计量的小样本性质更好，为 Stata 所采用。

*Hyper-parameter.*

如何确定自相关阶数  $p$ ? 如果  $p$  太小，可能忽略高阶自相关的存在；如果  $p$  较大，则 Q 统计量的小样本分布可能与  $\chi^2(p)$  相差较远。

Stata 默认的  $p$  值为  $p = \min\{\text{floor}(n/2) - 2, 40\}$ ，其中  $\text{floor}(n/2)$  为不超过  $n/2$  的最大整数。

## 4. DW 检验

“DW 检验” (Durbin and Watson, 1950)较早出现，已不常用。只能检验一阶自相关，且要求解释变量满足严格外生性。

DW 检验的统计量为

$$\begin{aligned} DW \equiv d &\equiv \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2} = \frac{\sum_{t=2}^n e_t^2 - 2\sum_{t=2}^n e_t e_{t-1} + \sum_{t=2}^n e_{t-1}^2}{\sum_{t=1}^n e_t^2} \\ &\approx 2 - 2\frac{\sum_{t=2}^n e_t e_{t-1}}{\sum_{t=1}^n e_t^2} \equiv 2(1 - \hat{\rho}_1) \end{aligned}$$

其中， $\hat{\rho}_1$ 为残差的一阶自相关系数。

当 $d = 2$ 时， $\hat{\rho}_1 \approx 0$ ，无一阶自相关；

当 $d = 0$ 时， $\hat{\rho}_1 \approx 1$ ，一阶正自相关；

当 $d = 4$ 时， $\hat{\rho}_1 \approx -1$ ，一阶负自相关。

<sup>分布</sup>  
DW 统计量依赖于数据矩阵  $\mathbf{X}$ ，无法制表，须使用上限分布  $d_U$  与下限分布  $d_L$  ( $d_L < d < d_U$ ) 来判断。得到  $d_U$  与  $d_L$  的临界值后，仍存在无结论区域。

DW 统计量本质就是残差的一阶自相关系数，不能指望它提供太多的信息。

## 8.4 自相关的处理

### 1. 使用“OLS + 异方差自相关稳健的标准误”

仍用 OLS 来估计回归系数，但使用“异方差自相关稳健的标准误” (Heteroskedasticity and Autocorrelation Consistent Standard Error, 简记 HAC)。

此法称为“Newey-West 估计法” (Newey and West, 1987)，只改变标准误的估计值，不改变回归系数的估计值。

为什么第 5 章的“异方差稳健标准误”不适用于自相关的情形？问题出在假定 5.5，即  $\mathbf{g}_i \equiv \mathbf{x}_i \varepsilon_i$  为鞅差分序列的假定。

MDS

**命题** 如果回归模型含有截距项, 则假定 5.5 意味着扰动项  $\varepsilon_i$  无自相关。

**证明:** 根据假定 5.5,  $\mathbf{g}_i$  为鞅差分序列, 故  $\mathbf{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_k \end{bmatrix}$

$E(\mathbf{g}_i | \mathbf{g}_{i-1}, \dots, \mathbf{g}_1) = E(\mathbf{x}_i \varepsilon_i | \mathbf{g}_{i-1}, \dots, \mathbf{g}_1) = 0$   $\vec{g} = \begin{bmatrix} \varepsilon \\ x_1 \varepsilon \\ \vdots \\ x_k \varepsilon \end{bmatrix}$

因为模型含有截距项, 故向量  $\mathbf{g}_i \equiv \mathbf{x}_i \varepsilon_i$  的第一个元素为  $\varepsilon_i$ 。因此,  $E(\varepsilon_i | \mathbf{g}_{i-1}, \dots, \mathbf{g}_1) = 0$ 。由于  $\{\varepsilon_{i-1}, \dots, \varepsilon_1\} \subset \{\mathbf{g}_{i-1}, \dots, \mathbf{g}_1\}$  (前者是后者的子集, 故前者的信息完全包含于后者之中), 根据迭代期望定律可得

$$E[\varepsilon_i | \varepsilon_{i-1}, \dots, \varepsilon_1] = E[E[\varepsilon_i | \mathbf{g}_{i-1}, \dots, \mathbf{g}_1] | \varepsilon_{i-1}, \dots, \varepsilon_1]$$

$$E(\varepsilon_i | \varepsilon_{i-1}, \dots, \varepsilon_1) = E_{\mathbf{g}_{i-1}, \dots, \mathbf{g}_1} [E(\varepsilon_i | \varepsilon_{i-1}, \dots, \varepsilon_1) | \mathbf{g}_{i-1}, \dots, \mathbf{g}_1]$$

$$= E_{\mathbf{g}_{i-1}, \dots, \mathbf{g}_1} [\underbrace{E(\varepsilon_i | \mathbf{g}_{i-1}, \dots, \mathbf{g}_1)}_{=0}] = 0$$

"Smaller info set dominates"

$$E[\varepsilon | \mathbf{x}] = E[E[\varepsilon | \mathbf{x}]]$$

因此， $\varepsilon_i$  均值独立于  $(\varepsilon_{i-1}, \dots, \varepsilon_1)$ ，故扰动项  $\varepsilon_i$  无自相关。

根据第 5 章，异方差稳健的协方差矩阵  $\mathbf{S}_{XX}^{-1} \hat{\mathbf{S}} \mathbf{S}_{XX}^{-1}$  为夹心估计量，

其中  $\mathbf{S}_{XX} \equiv \frac{1}{n} \mathbf{X}'\mathbf{X}$ ， $\hat{\mathbf{S}} \equiv \frac{1}{n} \sum_{i=1}^n e_i^2 \mathbf{x}_i \mathbf{x}_i'$ 。

异方差自相关稳健的协方差矩阵也是夹心估计量，其形式为  $\mathbf{S}_{XX}^{-1} \hat{\mathbf{Q}} \mathbf{S}_{XX}^{-1}$ ，其中

$$\hat{\mathbf{Q}} = \hat{\mathbf{S}} + \frac{1}{n} \sum_{j=1}^p \sum_{t=j+1}^n \left( 1 - \frac{j}{p+1} \right) e_t e_{t-j} (\mathbf{x}_t \mathbf{x}_{t-j}' + \mathbf{x}_{t-j} \mathbf{x}_t')$$

Handwritten annotations: "kernel" above the fraction,  $\Gamma_j$  above the product term, and  $\Gamma_j$  below the product term.

$p$  为自相关的阶数，也称“截断参数” (truncation parameter)。  
建议令  $p = n^{1/4}$  或  $p = 0.75n^{1/3}$ ，再取整数。

考虑一元回归情形，

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, \dots, n$$

OLS 估计量为，

$$\hat{\beta}_1 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}) [\beta_1 (x_i - \bar{x}) + (\varepsilon_i - \bar{\varepsilon})]}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$

其中，由于  $\bar{y} = \beta_0 + \beta_1 \bar{x} + \bar{\varepsilon}$ ，故  $y_i - \bar{y} = \beta_1(x_i - \bar{x}) + \varepsilon_i - \bar{\varepsilon}$ 。因此，

$$\hat{\beta}_1 - \beta_1 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(\varepsilon_i - \bar{\varepsilon})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})\varepsilon_i}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$

其中， $\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(\varepsilon_i - \bar{\varepsilon}) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})\varepsilon_i - \frac{1}{n} \bar{\varepsilon} \underbrace{\sum_{i=1}^n (x_i - \bar{x})}_{=0}$ 。记

$v_i \equiv (x_i - \bar{x})\varepsilon_i$ ，在大样本中， $\hat{\beta}_1 - \beta_1 \approx \frac{\frac{1}{n} \sum_{i=1}^n v_i}{\sigma_x^2}$ ，其中  $\sigma_x^2$  为  $x_i$  的方差。



故在大样本中，

$$\text{Var}(\hat{\beta}_1) = \frac{\text{Var}\left(\frac{1}{n} \sum_{i=1}^n v_i\right)}{(\sigma_x^2)^2}$$

考虑  $n=2$  的最简单情形，则上式分子为，

$$\begin{aligned} \text{Var}\left(\frac{1}{n} \sum_{i=1}^n v_i\right) &= \text{Var}\left[\frac{1}{2}(v_1 + v_2)\right] = \frac{1}{4}[\text{Var}(v_1) + \text{Var}(v_2) + 2\text{Cov}(v_1, v_2)] \\ &= \frac{1}{2}\sigma_v^2 + \frac{1}{2}\rho_1\sigma_v^2 = \frac{1}{2}\sigma_v^2(1 + \rho_1) \equiv \frac{1}{2}\sigma_v^2 f_2 \end{aligned}$$

其中， $\sigma_v^2 \equiv \text{Var}(v_i)$ ， $\rho_1 \equiv \text{corr}(v_1, v_2)$  为一阶自相关系数，而

$f_2 \equiv (1 + \rho_1)$  是修正系数。

如不存在自相关,  $\rho_1 = 0$ ,  $f_2 = 1$ , 则  $\text{Var}\left(\frac{1}{n} \sum_{i=1}^n v_i\right) = \frac{1}{2} \sigma_v^2$ , 得到通常的方差公式。

如存在自相关,  $\rho_1 \neq 0$ , 方差公式有所不同。

考虑样本容量为  $n$  的一般情况, 则  $\text{Var}\left(\frac{1}{n} \sum_{i=1}^n v_i\right) = \frac{1}{n} \sigma_v^2 f_n$ , 其中

$f_n \equiv 1 + 2 \sum_{j=1}^{n-1} \left(\frac{n-j}{n}\right) \rho_j$  为对应于样本容量为  $n$  的修正系数, 而  $\rho_j$  为  $j$

阶自相关系数; 因此,

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma_v^2}{n(\sigma_x^2)^2} \cdot f_n$$

上式是普通方差公式的  $f_n$  倍。  $f_n$  包含未知的自相关系数  $\rho_j$ ，需对其进行估计，比如

$$\hat{f}_n \equiv 1 + 2 \sum_{j=1}^{n-1} \left( \frac{n-j}{n} \right) \hat{\rho}_j$$

其中，  $\hat{\rho}_j$  为  $j$  阶样本自相关系数。但待估计参数  $(\rho_1, \dots, \rho_{n-1})$  太多，且随样本容量  $n$  增长，导致此估计量不一致。

反之，仅考虑前几阶自相关系数(比如，只考虑 $\rho_1$ )的估计量也不一致，因为忽略了高阶自相关。

正确的做法是，包括足够多阶数的自相关系数，并让此阶数 $p$ 随着样本容量的增长而增长。

一般建议取 $p = n^{1/4}$ 或 $p = 0.75n^{1/3}$ ，作为截断参数。

实践中，建议使用不同的截断参数，考察 HAC 标准误是否对于截断参数的取值敏感。

## 2. 使用“OLS + 聚类稳健的标准误”

如果样本观测值可以分为不同的“聚类”(clusters)，在同一聚类里的观测值互相相关，而不同聚类之间的观测值不相关，这种样本称为“聚类样本”(cluster sample)。

**【例】**在 Nerlove(1963)对美国电力企业的研究中，同一个州的电力企业可能受到相同州政策的影响而自相关，但不同州之间的电力企业可能不相关。此时，“州”(state)被称为“聚类变量”(cluster variable)。


**【例】**如果以全班同学为样本，则聚类变量可能是宿舍或专业。

如果将观测值按聚类的归属顺序排列，则扰动项的协方差矩阵为“块对角” (block diagonal)。

仍可用 OLS 来估计系数，但需使用“聚类稳健的标准误”(cluster robust standard errors)。

假设样本容量为  $N$ ，包括  $M$  个聚类，其中第  $j$  个聚类包含  $M_j$  个个体。记第  $j$  个聚类个体  $i$  的解释变量为  $\mathbf{x}_{ij}$ ，残差为  $e_{ij}$ ，然后定义  $\mathbf{u}_j \equiv \sum_{i=1}^{M_j} e_{ij} \mathbf{x}_{ij}$ ，则聚类稳健的协方差矩阵可以写为

$$\frac{N-1}{N-K} \frac{M}{M-1} (\mathbf{X}'\mathbf{X})^{-1} \left( \sum_{j=1}^M \mathbf{u}_j' \mathbf{u}_j \right) (\mathbf{X}'\mathbf{X})^{-1}$$



其中， $\frac{N-1}{N-K} \frac{M}{M-1}$  为对自由度的调整。

聚类稳健的标准误也是夹心估计量。在推导过程中并未假定同方差，故也是异方差稳健的。

使用聚类稳健标准误的前提是，聚类中的个体数  $M_j$  较少，而聚类数很多 ( $M \rightarrow \infty$ )；则聚类稳健标准误是真实标准误的一致估计。

处理面板数据时，常使用聚类稳健的标准误。

$$\text{reg } y \ x_1 \ x_2 \ \dots \ x_K, \text{ cluster } r$$

### 3. 使用可行广义最小二乘法(FGLS)

首先估计  $\text{Var}(\boldsymbol{\varepsilon} | \mathbf{X})$ 。为减少待估参数，假设扰动项为 AR(1):

$$\varepsilon_t = \rho \varepsilon_{t-1} + u_t, \quad |\rho| < 1, \quad u_t \text{ 为白噪声}$$

$\text{Var}(\varepsilon_t) = \rho^2 \text{Var}(\varepsilon_{t-1}) + \sigma_u^2$

记扰动项的  $j$  阶协方差  $\rho_j \equiv \text{Cov}(\varepsilon_t, \varepsilon_{t-j} | \mathbf{X})$ ，则

$$\text{Var}(\boldsymbol{\varepsilon} | \mathbf{X}) = \begin{pmatrix} \rho_0 & \rho_1 & \cdots & \rho_{n-1} \\ \rho_1 & \rho_0 & \cdots & \rho_{n-2} \\ \vdots & \vdots & & \vdots \\ \rho_{n-1} & \rho_{n-2} & \cdots & \rho_0 \end{pmatrix}$$



容易证明,  $\cancel{\rho}_0 = \sigma^2 = \text{Var}(\varepsilon_t) = \frac{\sigma_u^2}{1-\rho^2}$  其中  $\sigma_u^2 \equiv \text{Var}(u_t)$ 。

$$\text{Cov}(\varepsilon_t, \varepsilon_{t+1}) = \text{Cov}(\varepsilon_t, \rho\varepsilon_t + u_{t+1}) = \rho\sigma^2$$

$\cancel{\rho}_1 = \rho\sigma^2$ , 故  $\frac{\cancel{\rho}_1}{\cancel{\rho}_0} = \frac{\rho\sigma^2}{\sigma^2} = \rho$  为一阶自相关系数;  $\cancel{\rho}_2 = \rho^2\sigma^2, \dots,$

$\cancel{\rho}_{n-1} = \rho^{n-1}\sigma^2$ , 故

$$\text{Cov}(\varepsilon_t, \varepsilon_{t+2}) = \text{Cov}(\varepsilon_t, \rho\varepsilon_{t+1} + u_{t+2}) = \text{Cov}(\varepsilon_t, \rho \cdot (\rho\varepsilon_t + u_{t+1}) + u_{t+2})$$

$$\text{Var}(\boldsymbol{\varepsilon} | \mathbf{X}) = \sigma^2 \begin{pmatrix} 1 & \rho & \dots & \rho^{n-1} \\ \rho & 1 & \dots & \rho^{n-2} \\ \vdots & \vdots & \ddots & \vdots \\ \rho^{n-1} & \rho^{n-2} & \dots & 1 \end{pmatrix} \equiv \sigma^2 \mathbf{V}$$

只要估计唯一的参数  $\rho$ , 就可使用 FGLS。Stata 默认的估计方

法为使用 OLS 对残差进行辅助回归,  $e_t = \hat{\rho}e_{t-1} + error_t$ 。也可通过残差一阶自相关系数  $\hat{\rho} = \frac{\sum_{t=2}^n e_t e_{t-1}}{\sum_{t=1}^n e_t^2}$ , 或  $\hat{\rho} = 1 - \frac{DW}{2}$  来估计  $\rho$ 。

并将  $V$  的逆矩阵分解为  $V^{-1} = C'C$ 。可以证明

$$C = \frac{1}{\sqrt{1-\rho^2}} \begin{pmatrix} \sqrt{1-\rho^2} & 0 & \dots & 0 & 0 \\ -\rho & 1 & \dots & 0 & 0 \\ 0 & -\rho & \dots & 0 & 0 \\ \vdots & \vdots & & \vdots & \vdots \\ 0 & 0 & \dots & -\rho & 1 \end{pmatrix}$$

以  $\sqrt{1-\rho^2}\mathbf{C}$  左乘原模型，并定义  $\tilde{\mathbf{y}} \equiv \sqrt{1-\rho^2}\mathbf{C}\mathbf{y}$ ， $\tilde{\mathbf{X}} \equiv \sqrt{1-\rho^2}\mathbf{C}\mathbf{X}$ ， $\tilde{\boldsymbol{\varepsilon}} \equiv \sqrt{1-\rho^2}\mathbf{C}\boldsymbol{\varepsilon}$ ，则变换后的扰动项  $\tilde{\boldsymbol{\varepsilon}}$  满足球型扰动项的假设，故高斯-马尔可夫定理成立(此变换是 GLS 的特例):

$$\tilde{\mathbf{y}} = \sqrt{1-\rho^2}\mathbf{C}\mathbf{y} = \begin{pmatrix} \sqrt{1-\rho^2} & 0 & \dots & 0 & 0 \\ -\rho & 1 & \dots & 0 & 0 \\ 0 & -\rho & \dots & 0 & 0 \\ \vdots & \vdots & & \vdots & \vdots \\ 0 & 0 & \dots & -\rho & 1 \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} \sqrt{1-\rho^2}y_1 \\ y_2 - \rho y_1 \\ \vdots \\ y_n - \rho y_{n-1} \end{pmatrix}$$

$$\tilde{\mathbf{X}} = \sqrt{1-\rho^2} \mathbf{C}\mathbf{X} = \begin{pmatrix} \sqrt{1-\rho^2} & 0 & \dots & 0 & 0 \\ -\rho & 1 & \dots & 0 & 0 \\ 0 & -\rho & \dots & 0 & 0 \\ \vdots & \vdots & & \vdots & \vdots \\ 0 & 0 & \dots & -\rho & 1 \end{pmatrix} \begin{pmatrix} x_{11} & \dots & x_{1K} \\ x_{21} & \dots & x_{2K} \\ \vdots & & \vdots \\ x_{n1} & \dots & x_{nK} \end{pmatrix}$$

$$= \begin{pmatrix} \sqrt{1-\rho^2} x_{11} & \dots & \sqrt{1-\rho^2} x_{1K} \\ x_{21} - \rho x_{11} & \dots & x_{2K} - \rho x_{1K} \\ \vdots & & \vdots \\ x_{n1} - \rho x_{n-1,1} & \dots & x_{nK} - \rho x_{n-1,K} \end{pmatrix}$$

$$\tilde{\boldsymbol{\varepsilon}} = \sqrt{1-\rho^2} \mathbf{C} \boldsymbol{\varepsilon} = \begin{pmatrix} \sqrt{1-\rho^2} & 0 & \dots & 0 & 0 \\ -\rho & 1 & \dots & 0 & 0 \\ 0 & -\rho & \dots & 0 & 0 \\ \vdots & \vdots & & \vdots & \vdots \\ 0 & 0 & \dots & -\rho & 1 \end{pmatrix} \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix} = \begin{pmatrix} \sqrt{1-\rho^2} \varepsilon_1 \\ \varepsilon_2 - \rho \varepsilon_1 \\ \vdots \\ \varepsilon_n - \rho \varepsilon_{n-1} \end{pmatrix}$$

写出每个观测值(个体)的回归方程:

$$\sqrt{1-\rho^2} y_1 = \sqrt{1-\rho^2} \beta_1 + \sqrt{1-\rho^2} \beta_2 x_{12} + \dots + \sqrt{1-\rho^2} \beta_K x_{1K} + \tilde{\varepsilon}_1$$

$$y_2 - \rho y_1 = (1-\rho)\beta_1 + \beta_2(x_{22} - \rho x_{12}) + \dots + \beta_K(x_{2K} - \rho x_{1K}) + \tilde{\varepsilon}_2$$

.....

$$y_n - \rho y_{n-1} = (1-\rho)\beta_1 + \beta_2(x_{n2} - \rho x_{n-1,2}) + \dots + \beta_K(x_{nK} - \rho x_{n-1,K}) + \tilde{\varepsilon}_n$$

第一个方程的形式与其他方程不同。用 OLS 估计变换后的模型，即为“Prais-Winsten 估计法”（简记 PW）。

为计算方便，将第一个方程删去，称为“Cochrane-Orcutt 估计法”（简记 CO）。该法有更简洁的推导过程。原模型为，

$$y_t = \beta_1 + \beta_2 x_{t2} + \cdots + \beta_K x_{tK} + \varepsilon_t$$

将上式滞后一期，然后方程两边同时乘以  $\rho$  得

$$\rho y_{t-1} = \rho \beta_1 + \rho \beta_2 x_{t-1,2} + \cdots + \rho \beta_K x_{t-1,K} + \rho \varepsilon_{t-1}$$

将两方程相减可得：

$$y_t - \rho y_{t-1} = (1 - \rho) \beta_1 + \beta_2 (x_{t2} - \rho x_{t-1,2}) + \cdots + \beta_K (x_{tK} - \rho x_{t-1,K}) + \varepsilon_t - \rho \varepsilon_{t-1}$$

新扰动项  $\varepsilon_t - \rho\varepsilon_{t-1} = u_t$  满足球型扰动项的古典假定。

此法也称“准差分法” (quasi differences)。

在操作中，常使用迭代法，首先用 OLS 估计原模型，作辅助回归得到  $\hat{\rho}^{(1)}$  (对  $\rho$  的第一轮估计)，再用  $\hat{\rho}^{(1)}$  进行 FGLS 估计，使用新的残差估计  $\hat{\rho}^{(2)}$  (对  $\rho$  的第二轮估计)，再用  $\hat{\rho}^{(2)}$  进行 FGLS 估计，……，直至收敛。

使用 FGLS 处理自相关，如果对自相关系数的估计较准确，且满足严格外生性的假定，则 FGLS 比 OLS 更有效率。

如果不满足严格外生性，而仅满足前定解释变量的假定，则

FGLS 可能不一致，尽管 OLS 依然一致。

使用准差分法时，变换后的新扰动项为 $(\varepsilon_t - \rho\varepsilon_{t-1})$ ，而新解释变量为 $(x_{tk} - \rho x_{t-1,k})$ ，二者可能存在相关性，导致不一致估计。

总之，FGLS 不如 OLS 稳健。

#### 4. 修改模型设定

自相关的深层原因可能是模型设定有误，比如，遗漏了自相关的解释变量；或将动态模型(解释变量中包含被解释变量的滞后值)误设为静态模型，而后者也可视为遗漏了解释变量。



假设真实模型为

$$y_t = \rho y_{t-1} + \mathbf{x}'_t \boldsymbol{\beta} + \varepsilon_t$$

由于 $y_t$ 是 $y_{t-1}$ 的函数，故 $\{y_t\}$ 存在自相关。假设这个模型被错误地估计成

$$y_t = \mathbf{x}'_t \boldsymbol{\beta} + \underbrace{[\rho y_{t-1} + \varepsilon_t]}_{=v_t}$$

$\rho y_{t-1}$ 被纳入到扰动项 $v_t$ 中，导致扰动项 $\{v_t\}$ 自相关。

时间序列的自相关，有时可通过引入被解释变量的滞后值来消除。由于模型设定误差而导致的自相关，最好改进模型。