

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.

- 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**,

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

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

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

Take expectations, it could easily be seen

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

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

- 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 ?

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

- The first order condition gives

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

so the solution for β is

$$\beta^* \equiv E[xx']^{-1}E[xy]$$

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

CEF and linear projection

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

- Proof: Suppose $E[y|\mathbf{x}] = \mathbf{x}'\tilde{\boldsymbol{\beta}}$ for some $\tilde{\boldsymbol{\beta}}$. Note that $E[\mathbf{x}(y - E[y|\mathbf{x}])] = \mathbf{0}$, substitute $E[y|\mathbf{x}] = \mathbf{x}'\tilde{\boldsymbol{\beta}}$ to find that $\tilde{\boldsymbol{\beta}} = \boldsymbol{\beta}^* = E[\mathbf{x}\mathbf{x}']^{-1}E[\mathbf{x}y]$.
 - Therefore, if it happens that CEF is linear, then the linear projection is the best predictor.
2. The best linear approximation to $E[y|\mathbf{x}]$ is $\mathbf{x}'\boldsymbol{\beta}^*$.
- Proof: This is the same as saying that $\boldsymbol{\beta}^*$ minimizes

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

- To see why, write

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

- The first term does not involve $\tilde{\boldsymbol{\beta}}$, and the last term has expectation zero. The CEF-approximation problem, therefore has the same solution as the best-linear-predictor problem, $\arg \min_{\tilde{\boldsymbol{\beta}}} \text{E}[(y - \mathbf{x}'\tilde{\boldsymbol{\beta}})^2]$.
- 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 $\text{Var}(\boldsymbol{b} | \mathbf{X})$ 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。

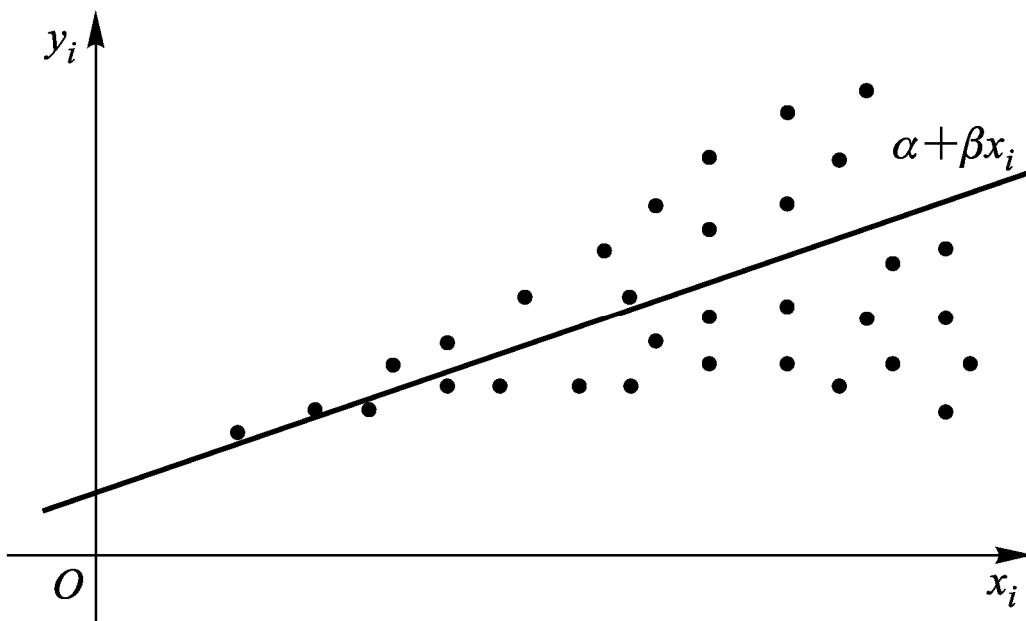


图 7.1 异方差的一种情形

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。

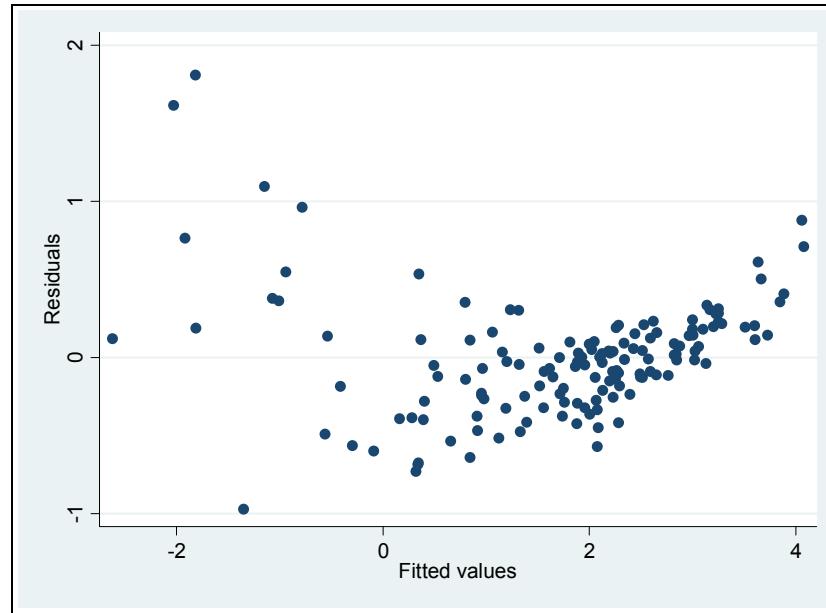
(3) 组间异方差：样本包含两组(类)数据，第一组为自我雇佣者(企业主、个体户)的收入，第二组为打工族的收入，前者的收入波动比后者大。

- (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：

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

并检验 $\boldsymbol{\psi}_i$ 中所有变量的系数 $\boldsymbol{\gamma}$ 均为 0。

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 χ^2 分布等价(第 5 章附录，见下)，即

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

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 χ^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 χ^2 分 布 的 性 质 , $E[\chi^2(n-K)] = n-K$, 而
 $Var[\chi^2(n-K)] = 2(n-K)$ 。

故 F 统计量分母的期望值为:

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

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:

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

如果 H_0 不成立, 则条件方差 $E(\varepsilon_i^2 | x_2, \dots, x_K)$ 是 (x_2, \dots, 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

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

由于 ε_i 不可观测，故使用 e_i^2 进行辅助回归：

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

使用 nR^2 统计量：

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

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 $y = X\beta + \varepsilon$ 两边同时左乘矩阵 C ：

$$Cy = CX\beta + C\varepsilon$$

定义变量转换：

$$\tilde{y} \equiv Cy, \tilde{X} \equiv CX, \tilde{\varepsilon} \equiv C\varepsilon$$

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：

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

球型扰动项的假定也得到满足：

$$\begin{aligned} \text{Var}(\tilde{\varepsilon} | \tilde{X}) &= E(\tilde{\varepsilon} \tilde{\varepsilon}' | X) = E(C\varepsilon \varepsilon' C' | X) = C E(\varepsilon \varepsilon' | X) C' = \sigma^2 C V C' \\ &= \sigma^2 C (V^{-1})^{-1} C' = \sigma^2 C (C' C)^{-1} C' = \sigma^2 C C^{-1} (C')^{-1} C' = \sigma^2 I_n \end{aligned}$$

故高斯-马尔可夫定理成立。

对变换后的模型使用 OLS 即得到 GLS 估计量：

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

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

$$C = C' = \begin{pmatrix} 1/\sqrt{\nu_1} & & & 0 \\ & 1/\sqrt{\nu_2} & & \\ & & \ddots & \\ 0 & & & 1/\sqrt{\nu_n} \end{pmatrix}$$

$$\tilde{y} \equiv Cy = \begin{pmatrix} 1/\sqrt{\nu_1} & & & 0 \\ & 1/\sqrt{\nu_2} & & \\ & & \ddots & \\ 0 & & & 1/\sqrt{\nu_n} \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} y_1/\sqrt{\nu_1} \\ y_2/\sqrt{\nu_2} \\ \vdots \\ y_n/\sqrt{\nu_n} \end{pmatrix}$$

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

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

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

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

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”：

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

从这个角度来看，权重为 $1/v_i$ ，Stata 也是这样约定的。

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

$e_i^2 = \delta_1 + \delta_2 x_{i2} + \cdots + \delta_K x_{iK} + error_i$ 就可获得 σ_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)， $\hat{\beta}_{\text{FGLS}} = (\mathbf{X}' \hat{V}^{-1} \mathbf{X})^{-1} \mathbf{X}' \hat{V}^{-1} \mathbf{y}$ ，而 \hat{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{V} 是 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

8.1 自相关的后果

如果存在 $i \neq j$, 使得 $E(\varepsilon_i \varepsilon_j | X) \neq 0$, 即 $\text{Var}(\boldsymbol{\varepsilon} | X)$ 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;

- (2) OLS 估计量依然服从渐近正态分布；
- (3) OLS 估计量方差 $\text{Var}(\boldsymbol{b} | \mathbf{X})$ 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。

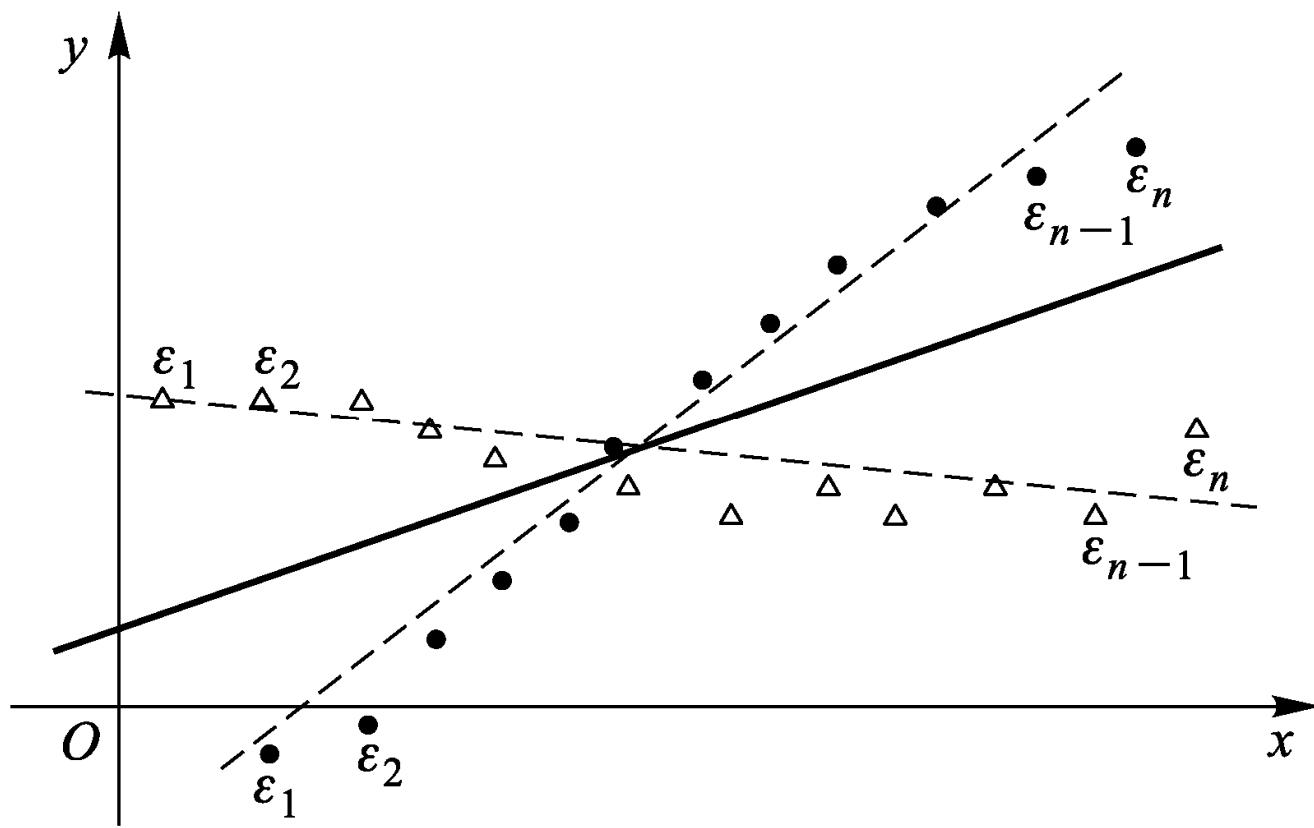


图 8.1 自相关的后果

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。

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”:

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

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。

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

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

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。

DW 统计量依赖于数据矩阵 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。

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

证明：根据假定 5.5， \mathbf{g}_i 为鞅差分序列，故

$$E(\mathbf{g}_i | \mathbf{g}_{i-1}, \dots, \mathbf{g}_1) = E(\mathbf{x}_i \varepsilon_i | \mathbf{g}_{i-1}, \dots, \mathbf{g}_1) = 0$$

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 ε_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

$$\begin{aligned} E(\varepsilon_i | \varepsilon_{i-1}, \dots, \varepsilon_1) &= E_{\mathbf{g}_{i-1}, \dots, \mathbf{g}_1} [E(\varepsilon_i | \varepsilon_{i-1}, \dots, \varepsilon_1) | \mathbf{g}_{i-1}, \dots, \mathbf{g}_1] \\ &= E_{\mathbf{g}_{i-1}, \dots, \mathbf{g}_1} [\underbrace{E(\varepsilon_i | \mathbf{g}_{i-1}, \dots, \mathbf{g}_1)}_{=0}] = 0 \end{aligned}$$

因此， ε_i 均值独立于 $(\varepsilon_{i-1}, \dots, \varepsilon_1)$ ，故扰动项 ε_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

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

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

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

故在大样本中，

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

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 ρ_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 ρ_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 ρ_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。

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)：

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

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, $\rho_0 = \sigma^2 = \text{Var}(\varepsilon_t) = \frac{\sigma_u^2}{1 - \rho^2}$, 其中 $\sigma_u^2 \equiv \text{Var}(u_t)$ 。

$\rho_1 = \rho\sigma^2$, 故 $\frac{\rho_1}{\rho_0} = \frac{\rho\sigma^2}{\sigma^2} = \rho$ 为一阶自相关系数; $\rho_2 = \rho^2\sigma^2, \dots,$
 $\rho_{n-1} = \rho^{n-1}\sigma^2$, 故

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

只要估计唯一的参数 ρ , 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 ρ 。

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):

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

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

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

$$\tilde{\boldsymbol{\varepsilon}} = \sqrt{1-\rho^2} \mathbf{C} \boldsymbol{\varepsilon} = \begin{pmatrix} \sqrt{1-\rho^2} & 0 & \dots & 0 & 0 \\ -\rho & 1 & \dots & 0 & 0 \\ 0 & -\rho & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & -\rho & 1 \end{pmatrix} \begin{pmatrix} \boldsymbol{\varepsilon}_1 \\ \boldsymbol{\varepsilon}_2 \\ \vdots \\ \boldsymbol{\varepsilon}_n \end{pmatrix} = \begin{pmatrix} \sqrt{1-\rho^2} \boldsymbol{\varepsilon}_1 \\ \boldsymbol{\varepsilon}_2 - \rho \boldsymbol{\varepsilon}_1 \\ \vdots \\ \boldsymbol{\varepsilon}_n - \rho \boldsymbol{\varepsilon}_{n-1} \end{pmatrix}$$

写出每个观测值(个体)的回归方程:

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

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

.....

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

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 ρ 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 ρ 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 ρ 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

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

ρy_{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。