

# 高级计量经济学

理论经济学博士课程 2023-2024

## Lecture 9: Nonlinear Regression and GLS

Davidson, R. & MacKinnon, J. (2009). *Econometrics Theory and Methods*. Oxford University Press.

**黄嘉平**

工学博士 经济学博士  
深圳大学中国经济特区研究中心 讲师

**办公室** 粤海校区汇文楼1510  
**E-mail** [huangjp@szu.edu.cn](mailto:huangjp@szu.edu.cn)  
**Website** <https://huangjp.com>

# 非线性回归模型和 MM估计量

# 线性模型与非线性模型

## Linear and Nonlinear Models

线性回归模型可以表达为

$$y = X\beta + u, \quad u | X \sim \text{IID}(\mathbf{0}, \sigma^2 I)$$

或

$$y_t = X_t\beta + u_t, \quad u_t | X \sim \text{IID}(0, \sigma^2), \quad t = 1, \dots, n$$

定义信息集 (information set)  $\Omega_t$  为所有可能对  $y_t$  产生影响的变量的集合。一般情况下我们要求  $\Omega_t$  中的变量为外生或者前定变量。

基于信息集  $\Omega_t$ ，我们可以将线性模型拓展为下面的非线性模型

$$y_t = x_t(\beta) + u_t, \quad u_t | \Omega_t \sim \text{IID}(0, \sigma^2), \quad t = 1, \dots, n \quad \text{因此 } E[u_t | \Omega_t] = 0$$

这里  $x_t(\beta)$  是参数向量  $\beta$  的非线性函数。非线性模型也可以写成

$$y = x(\beta) + u, \quad u \sim \text{IID}(\mathbf{0}, \sigma^2 I)$$

注:  $x_t(\beta)$  也可以写成  $f(x_t, \beta)$ 。为了使符号和线性模型相对应，这里采用  $x_t(\beta)$  的写法。

# 矩条件

## Moment Conditions

在线性模型下，如果假设前定性  $E[u_t | X_t] = 0$ ，我们可以推出  $E[X_t^\top u_t] = \mathbf{0}$  (Lecture 5)，而这恰好是求 MM 估计量的条件 (Lecture 2)。此条件对应的样本条件是

$$X^\top (y - X\beta) = \mathbf{0} \quad \text{左式称为 moment conditions}$$

在非线形模型下，我们可以从信息集  $\Omega_t$  选择  $k$  个变量并写成  $1 \times k$  向量  $W_t$ 。此时可得  $E[u_t | W_t] = 0$ ，因此  $E[W_t^\top u_t] = \mathbf{0}$ ，对应的矩条件为

$$W^\top (y - x(\beta)) = \mathbf{0}, \quad W \text{ 的第 } t \text{ 行是 } W_t$$

非线性模型的矩条件中包含  $k$  个关于系数的非线性方程，其解（若存在）就是  $\beta$  的 MM 估计量，可记作  $\hat{\beta}_{\text{MM}}$ 。

# 关于 MM 估计量

- MM 估计量是  $W^{\top}(y - x(\beta)) = \mathbf{0}$  的解。因为条件是非线性的，我们无法获得解的一般表达式。
- 矩条件基于  $W_t$  的前定性  $E[u_t | W_t] = 0$  而非外生性，因此 MM 估计量可能有偏。
- MM 估计量的性质会随  $W$  中变量的选择而变化。 $W$  的选择一般不会影响 MM 估计量的一致性，但会影响它的渐进协方差矩阵。因此我们需要找到使 MM 估计量满足渐进有效性的  $W$ 。

# 回归系数的渐进识别

## Asymptotic Identification

识别 (Identification) 指在确定样本和估计方法后, 可以求出唯一的参数值的情况。如果一种估计方法在  $n \rightarrow \infty$  时可以求出唯一的参数值, 我们称其为渐进可识别。

在线性模型的 OLS 估计中, 如果  $X$  列满秩, 则  $\beta$  是可识别的 (标准方程有唯一解)。在非线性模型的 MM 估计中, 如果  $W^\top(\mathbf{y} - \mathbf{x}(\beta)) = \mathbf{0}$  存在唯一解, 则  $\beta$  是可识别的。

MM 估计量的渐进可识别性取决于  $\frac{1}{n}W^\top(\mathbf{y} - \mathbf{x}(\beta))$  的概率极限是否可以求出唯一的参数值。令

$$\text{plim}_{n \rightarrow \infty} \frac{1}{n}W^\top(\mathbf{y} - \mathbf{x}(\beta)) = \alpha(\beta), \quad \alpha(\beta) \text{ 为确定性函数。}$$

已知  $\frac{1}{n}W^\top(\mathbf{y} - \mathbf{x}(\beta_0)) = \frac{1}{n} \sum_{t=1}^n W_t^\top u_t$ ,  $E[W_t^\top u_t] = \mathbf{0}$ , 根据 LLN 可得

$$\text{plim}_{n \rightarrow \infty} \frac{1}{n}W^\top(\mathbf{y} - \mathbf{x}(\beta_0)) = \mathbf{0}$$

因此, 如果  $\beta_0$  是  $\alpha(\beta) = \mathbf{0}$  的唯一解, MM 估计量是渐进可识别的。

需要注意的是, 可识别性无法推出渐进可识别性, 反之亦然 (pp.217-218)。

# MM 估计量的一致性

## Consistency of MM Estimators

假设 MM 估计量是渐进可识别的，则

$$\text{plim}_{n \rightarrow \infty} \frac{1}{n} W^\top (\mathbf{y} - \mathbf{x}(\hat{\boldsymbol{\beta}}_{\text{MM}})) = \boldsymbol{\alpha}(\hat{\boldsymbol{\beta}}_{\text{MM}}) = \mathbf{0}$$

存在唯一解。如果我们假设  $\text{plim}_{n \rightarrow \infty} \hat{\boldsymbol{\beta}}_{\text{MM}} = \boldsymbol{\beta}_\infty$  (非随机)，则根据上式可得  $\boldsymbol{\alpha}(\boldsymbol{\beta}_\infty) = \mathbf{0}$ ，但是渐进可识别性的定义告诉我们只有  $\boldsymbol{\beta}_0$  满足  $\boldsymbol{\alpha}(\boldsymbol{\beta}) = \mathbf{0}$ ，因此

$$\text{plim}_{n \rightarrow \infty} \hat{\boldsymbol{\beta}}_{\text{MM}} = \boldsymbol{\beta}_0$$

即 MM 估计量满足一致性。

MM 估计量的渐进可识别性取决于如何选取  $W$  里的变量。

# MM 估计量的其他渐进性质

## Other Asymptotic Properties of MM Estimators

非线性模型的 MM 估计量还具有以下渐进性质：

- 渐进正态性： $\sqrt{n}(\hat{\beta}_{\text{MM}} - \beta_0)$  服从均值为  $\mathbf{0}$  的渐进正态分布 (pp.220-222)
- 渐进有效性： $\sqrt{n}(\hat{\beta}_{\text{MM}} - \beta_0)$  的渐进协方差矩阵是

$$\sigma_0^2 \text{plim}_{n \rightarrow \infty} \left( \frac{1}{n} X_0^\top W (W^\top W)^{-1} W^\top X_0 \right)^{-1} = \sigma_0^2 \text{plim}_{n \rightarrow \infty} \left( \frac{1}{n} X_0^\top P_W X_0 \right)^{-1}$$

其中  $X_0 = X(\beta_0) = \left[ \frac{\partial x_t(\beta)}{\partial \beta_i} \right]_{\beta=\beta_0}$ 。

当  $W = X_0$  时， $\sqrt{n}(\hat{\beta}_{\text{MM}} - \beta_0)$  在 MM 估计量当中最有效。 (pp.222-223)

需要注意的是， $X_0$  是未知量  $\beta_0$  的函数，因此这样定义的有效估计量不可行 (infeasible)。



# 线性模型与 MM 估计量

线性模型  $y = X\beta + u$  是非线形模型的一个特例，因此非线形模型的 MM 估计量也适用于线性模型。

在线性模型下，MM 估计量是

$$W^T (y - X\beta) = \mathbf{0}$$

的解。根据定义  $X(\beta) = [\partial x_t(\beta) / \partial \beta_i] = X$ ，因此  $X_0 = X$ ，最有效的 MM 估计量满足

$$X^T (y - X\hat{\beta}_{MM}) = \mathbf{0} \Rightarrow \hat{\beta}_{MM} = \hat{\beta}_{OLS}$$

# 非线性最小二乘法

## Nonlinear Least Squares

因为  $X_0 = X(\beta_0) = [\partial x_t(\beta) / \partial \beta_i]_{\beta=\beta_0}$  是未知参数  $\beta_0$  的函数，我们无法通过它求得最有效的 MM 估计量。

假设估计量  $\hat{\beta}$  是下面 MM 条件的解

$$X^\top(\beta)(y - x(\beta)) = \mathbf{0}$$

同时我们也可以考虑非线性最小二乘法

$$\min_{\beta} (y - x(\beta))^\top (y - x(\beta))$$

上面的 MM 条件等价于非线性最小二乘法的一阶条件。因此，我们将  $\hat{\beta}$  称为非线性最小二乘估计量 (NLS)，并记为  $\hat{\beta}_{\text{NLS}}$ 。

当  $n \rightarrow \infty$  时， $\hat{\beta}_{\text{NLS}}$  收敛于有效 MM 估计量 ( $W = X_0$ )。

# 广义最小二乘法

# 线性模型与广义最小二乘法

OLS 和 NLS 估计量都需要误差项满足同方差性。下面我们放松这个假设，考虑线性模型

$$y = X\beta + u, \quad E[uu^T] = \Omega$$

一般情况下  $\Omega \neq \sigma^2 I$ ，因此不满足 Gauss-Markov 定理的条件。

为了获得有效估计量，我们可以将原模型变换为满足条件的新模型，并将新模型的 OLS 估计量作为  $\beta$  的估计量。这种方法被称为广义最小二乘法（generalized least squares, GLS）。

# 广义最小二乘估计量

## GLS Estimator

已知  $\Omega$  是正定矩阵且可逆，因此存在  $n \times n$  非奇异矩阵  $\Psi$  满足

$$\Omega^{-1} = \Psi\Psi^T$$

将回归方程  $y = X\beta + u$  从左侧乘以  $\Psi^T$  可得  $\Psi^T y = \Psi^T X\beta + \Psi^T u$ 。

GLS 估计量  $\hat{\beta}_{\text{GLS}}$  是变换后模型的 OLS 估计量，即

$$\hat{\beta}_{\text{GLS}} = (X^T \Psi \Psi^T X)^{-1} X^T \Psi \Psi^T y = (X^T \Omega^{-1} X)^{-1} X^T \Omega^{-1} y$$

变换后的误差项的协方差矩阵是

$$E[\Psi^T u u^T \Psi] = \Psi^T E[u u^T] \Psi = \Psi^T (\Psi \Psi^T)^{-1} \Psi = I$$

由此可得到 GLS 估计量的协方差矩阵

$$\text{Var}(\hat{\beta}_{\text{GLS}}) = 1 \cdot (X^T \Psi \Psi^T X)^{-1} = (X^T \Omega^{-1} X)^{-1}$$

# 广义最小二乘法

变换后模型  $\Psi^T y = \Psi^T X\beta + \Psi^T u$  的 OLS 估计量是 SSR 最小化问题的解，该问题可以写成

$$\begin{aligned} & \min_{\beta} (\Psi^T y - \Psi^T X\beta)^T (\Psi^T y - \Psi^T X\beta) \\ &= \min_{\beta} (\Psi^T (y - X\beta))^T (\Psi^T (y - X\beta)) \\ &= \min_{\beta} (y - X\beta)^T \Psi \Psi^T (y - X\beta) \\ &= \min_{\beta} (y - X\beta)^T \Omega^{-1} (y - X\beta) \end{aligned}$$

我们将目标函数  $(y - X\beta)^T \Omega^{-1} (y - X\beta)$  称为 GLS 准则函数 (GLS criterion function)。

# GLS 估计量是 MM 估计量

最小化问题  $\min_{\beta} (\mathbf{y} - \mathbf{X}\beta)^\top \mathbf{\Omega}^{-1} (\mathbf{y} - \mathbf{X}\beta)$  的一阶条件是

$$\mathbf{X}^\top \mathbf{\Omega}^{-1} (\mathbf{y} - \mathbf{X}\beta) = \mathbf{0}$$

因此,  $\hat{\beta}_{\text{GLS}}$  也可以看作满足矩条件  $\mathbf{X}^\top \mathbf{\Omega}^{-1} (\mathbf{y} - \mathbf{X}\hat{\beta}_{\text{GLS}}) = \mathbf{0}$  的 MM 估计量。一般情况下, 矩条件  $\mathbf{W}^\top (\mathbf{y} - \mathbf{X}\beta) = \mathbf{0}$  的解可以写成

$$\hat{\beta}_{\mathbf{W}} = (\mathbf{W}^\top \mathbf{X})^{-1} \mathbf{W}^\top \mathbf{y}$$

$\hat{\beta}_{\text{GLS}}$  是  $\mathbf{W} = \mathbf{\Omega}^{-1} \mathbf{X}$  时的  $\hat{\beta}_{\mathbf{W}}$ 。

# GLS 估计量的统计学性质

GLS 估计量的统计学性质类似于 MM 估计量的统计学性质。

- 当  $X$  和  $W$  外生时, 即  $E[u | X, W] = \mathbf{0}$  时,  $\hat{\beta}_W$  非偏。
- 当  $W$  满足前定性, 即  $E[u_t | W_t] = 0$  时,  $\hat{\beta}_W$  满足一致性。
- $\hat{\beta}_W$  的协方差矩阵是

$$\begin{aligned}\text{Var}(\hat{\beta}_W) &= E[(\hat{\beta}_W - \beta_0)(\hat{\beta}_W - \beta_0)^\top] \\ &= E[(W^\top X)^{-1} W^\top u u W^\top (X^\top W)^{-1}] \\ &= (W^\top X)^{-1} W^\top \Omega W^\top (X^\top W)^{-1}\end{aligned}$$

已知,  $\text{Var}(\hat{\beta}_{\text{GLS}}) = (X^\top \Omega^{-1} X)^{-1}$ , 可以通过证明两者之差是半正定矩阵证明 GLS 估计量的有效性。

OLS 估计量也是 MM 估计量, 因此 GLS 估计量至少和 OLS 估计量同样有效, 且在大多数情况下比 OLS 估计量更有效。



# GLS 估计量的计算

虽然 GLS 估计量有很好的性质，但是并不容易计算。

$\hat{\beta}_{\text{GLS}} = (X^T \Omega^{-1} X)^{-1} X^T \Omega^{-1} y$ ，即使  $\Omega$  已知，我们需要求它的逆矩阵。当  $n$  很大时， $\Omega^{-1}$  的计算需要占用大量的计算和储存资源（例如  $n = 10,000$  时，储存  $\Omega$  和  $\Omega^{-1}$  需要 1600Mb 空间）。

如果  $\Psi$  已知，且我们可以将数据变换为  $\Psi^T y$  和  $\Psi^T X$  而不需要储存  $\Psi$ ，就可以通过 OLS 估计  $\hat{\beta}_{\text{GLS}}$ 。

OLS 估计不需要用到误差项的方差，因此我们可以利用这一特性。如果  $\Omega = \sigma^2 \Delta$ ，且  $\Delta$  为已知，则可以用  $\Delta$  替代  $\Omega$  求  $\hat{\beta}_{\text{GLS}}$ 。具体做法是找到满足  $\Delta^{-1} = \Psi \Psi^T$  的  $\Psi$ ，并对原模型进行变换，再用变换后模型进行 OLS 估计，所获得的估计量就是原模型的 GLS 估计量：

$$(X^T \Delta^{-1} X)^{-1} X^T \Delta^{-1} y = (X^T \Omega^{-1} X)^{-1} X^T \Omega^{-1} y = \hat{\beta}_{\text{GLS}}$$

这时 GLS 估计量的协方差矩阵可以写成  $\sigma^2 (X^T \Delta^{-1} X)^{-1}$ 。如果  $\sigma^2$  未知，我们依然要对其进行估计，即  $\widehat{\text{Var}}(\hat{\beta}_{\text{GLS}}) = s^2 (X^T \Delta^{-1} X)^{-1}$ ， $s^2$  是变换后模型误差项的估计量。

# 加权最小二乘估计量

## Weighted Least Square Estimator

如果误差项是**异方差**但是**无自相关**，那么就可以很容易地计算 GLS 估计量。这时的  $\mathbf{\Omega}$  是对角矩阵，我们将其第  $t$  对角要素写为  $\omega_t^2$ ，即  $\mathbf{\Omega} = \text{diag}(\omega_1^2, \dots, \omega_n^2)$ ，则可得

$$\mathbf{\Omega}^{-1} = \text{diag}(\omega_1^{-2}, \dots, \omega_n^{-2}), \quad \mathbf{\Psi} = \text{diag}(\omega_1^{-1}, \dots, \omega_n^{-1})$$

变换后的模型可以写成

$$\omega_t^{-1}y_t = \omega_t^{-1}\mathbf{X}_t\boldsymbol{\beta} + \omega_t^{-1}u_t, \quad t = 1, \dots, n$$

通过对这个模型进行 OLS 估计得到的估计量被称为加权最小二乘估计量（WLS 估计量），因为这可以看作是用权重  $\omega_t^{-1}$  给样本中第  $t$  观测值进行加权。

因为变换后模型的误差项  $\omega_t^{-1}u_t$  满足同方差性，WLS 估计可以作为应对异方差性的一种方法。

# 如何决定 $\omega_t$

WLS 估计的难点是如何决定  $\omega_t$ 。这可以分为以下几种情况：

- 通过理论或者对样本数据的检验，我们相信  $E[u_t^2]$  和某个可观测变量  $z_t^2$  成正比。此时可以用  $z_t^{-1}$  作为权重。
- 样本变量是针对不同大小的集合获得的统计数据。
  - 如果变量是集合中的均值，例如不同城市的人均可支配收入，则  $u_t$  的方差和集合的要素数  $N_t$  呈反比。此时可用  $N_t^{1/2}$  作为权重。
  - 如果变量是总和而不是均值，则  $u_t$  的方差和  $N_t$  成正比，此时需用  $N_t^{-1/2}$  作为权重。