

$$\left(\frac{\hat{\sigma}^2}{\sigma^2}\right) = 1 + \frac{1}{n} (\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{r})' [\hat{\sigma}^2 \mathbf{R}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{R}']^{-1} (\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{r})$$

したがって LR は次のようになる。

$$\begin{aligned} LR &= 2(\log L(\hat{\boldsymbol{\theta}}) - \log L(\tilde{\boldsymbol{\theta}})) \\ &= n \log L\left(\frac{\hat{\sigma}^2}{\sigma^2}\right) \end{aligned} \quad (2.71)$$

この LR はさらに次のように近似すれば W に等しい。

$$\begin{aligned} LR &= n \log \left\{ 1 + \frac{1}{n} (\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{r})' [\hat{\sigma}^2 \mathbf{R}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{R}']^{-1} (\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{r}) \right\} \\ &\approx (\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{r})' [\hat{\sigma}^2 \mathbf{R}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{R}']^{-1} (\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{r}) \\ &\stackrel{H_0}{\underset{\text{asy}}{\approx}} \chi^2(r) \end{aligned} \quad (2.72)$$

以上、3つの大標本検定のなかでもスコア検定（ラグランジュ乗数検定）が計量経済学でよく用いられるのは次の理由による。スコア検定は仮説  $H_0$  のもとでの制約つき MLE のみにもとづいており、仮説  $H_0$  はたとえば自己相関なし、あるいは均一分散、あるいは正規分布であり、 $H_0$  が正しいならばという制約をつけることによって、パラメータ推定量が簡単に得られることが多いからである。そこでさらに LM 検定について説明しよう。それが次の5節と6節である。

### 5 制約つき MLE の LM 検定統計量は、補助方程式の $nR^2$ に等しい

#### 5.1 補助方程式

重回帰モデル

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u} \quad (2.73)$$

$$\mathbf{u} \sim N(\mathbf{0}, \sigma^2 \mathbf{I})$$

を考えよう。  $\boldsymbol{\theta}$  を  $p \times 1$  のパラメータベクトルとする。このモデルでは

$$\boldsymbol{\theta} = \begin{bmatrix} \boldsymbol{\beta} \\ \sigma^2 \end{bmatrix}$$

であり、  $p = k + 1$  である。  $\boldsymbol{\theta}$  に関する  $r$  個の制約を

$$\mathbf{R}(\boldsymbol{\theta}) = \mathbf{0} \quad (2.74)$$

とする。  $\mathbf{R}(\boldsymbol{\theta})$  は  $\boldsymbol{\theta}$  に関する線形制約、非線形制約いずれの場合もありうる。たとえば

$$\mathbf{R}(\boldsymbol{\theta}) = \begin{bmatrix} R_1(\boldsymbol{\theta}) \\ R_2(\boldsymbol{\theta}) \\ R_3(\boldsymbol{\theta}) \end{bmatrix} = \begin{bmatrix} \theta_1 + \theta_2 - 1 \\ \theta_1 + \theta_2 \theta_3 \\ \theta_4 \theta_5 + \theta_6 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

である。

尤度関数を  $L(\boldsymbol{\theta})$  とし、次の制約つき最大問題を考えよう。すでに述べた内容もあるが、もう一度くりかえす。

$$\begin{aligned} \max L(\boldsymbol{\theta}) \\ \text{subject to } \mathbf{R}(\boldsymbol{\theta}) = \mathbf{0} \end{aligned}$$

$\boldsymbol{\theta}$  は  $p \times 1$  のパラメータベクトルである。

$\boldsymbol{\theta}^* = \mathbf{R}(\boldsymbol{\theta}) = \mathbf{0}$  の制約のもとでの  $\boldsymbol{\theta}$  の MLE

$$S(\boldsymbol{\theta}) = \frac{\partial \log L(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \text{ はスコア}$$

$$S(\boldsymbol{\theta}^*) = \frac{\partial \log L(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \Big|_{\boldsymbol{\theta} = \boldsymbol{\theta}^*}$$

とする

$$S(\boldsymbol{\theta}) \xrightarrow{d} N(\mathbf{0}, \mathbf{I}(\boldsymbol{\theta})) \quad ((1.57) \text{ 式})$$

である。

このとき  $H_0: \mathbf{R}(\boldsymbol{\theta}) = \mathbf{0}$  とすると、次式が成り立つ ((2.52) 式)。

$$LM = S(\boldsymbol{\theta}^*)' [\mathbf{I}(\boldsymbol{\theta}^*)]^{-1} S(\boldsymbol{\theta}^*) \stackrel{H_0}{\underset{\text{asy}}{\approx}} \chi^2(r) \quad (2.75)$$

重回帰モデル

$$\begin{aligned} Y_t &= \beta_1 X_{1t} + \beta_2 X_{2t} + \cdots + \beta_{k-r} X_{k-r,t} + \beta_{k-r+1} X_{k-r+1,t} \\ &\quad + \cdots + \beta_k X_{kt} + u_t \end{aligned} \quad (2.76)$$

において

$$\boldsymbol{\beta}_{(k-r) \times 1} = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_{k-r} \end{bmatrix}, \quad \boldsymbol{\beta}_{r \times 1} = \begin{bmatrix} \beta_{k-r+1} \\ \vdots \\ \beta_k \end{bmatrix}$$

$$\mathbf{X}_1 = \begin{bmatrix} X_{11} & \cdots & X_{k-r,1} \\ \vdots & & \vdots \\ X_{1n} & \cdots & X_{k-r,n} \end{bmatrix}, \quad \mathbf{X}_2 = \begin{bmatrix} X_{k-r+1,1} & \cdots & X_{k1} \\ \vdots & & \vdots \\ X_{k-r+1,n} & \cdots & X_{kn} \end{bmatrix}$$

とおくと, (2.76) 式は次のように表すことができる.

$$y = \underset{n \times 1}{X_1} \underset{n \times (k-r)}{\beta_1} + \underset{(k-r) \times 1}{X_2} \underset{n \times r, r \times 1}{\beta_2} + \underset{n \times 1}{u}, \quad u \sim N(0, \sigma^2 I) \quad (2.77)$$

$$\theta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \sigma^2 \end{bmatrix} \text{ とすると, } H_0: \beta_2 = 0 \text{ の制約のもとでの } \theta \text{ の MLE は}$$

$$y = X_1 \beta_1 + u \quad (2.78)$$

における  $\beta_1$  と  $\sigma^2$  の MLE

$$\theta^* = \begin{bmatrix} \beta_1^* \\ 0 \\ \sigma^{2*} \end{bmatrix}$$

に等しい. ここで

$$\begin{aligned} \beta_1^* &= (X_1' X_1)^{-1} X_1' y \\ \sigma^{2*} &= e^{*'} e^* / n \\ e^* &= y - X_1 \beta_1^* \stackrel{H_0}{=} y - (X_1 \ X_2) \begin{pmatrix} \beta_1^* \\ 0 \end{pmatrix} \\ &\stackrel{H_0}{=} y - X \beta^* \\ \beta^* &\stackrel{H_0}{=} \begin{bmatrix} \beta_1^* \\ 0 \end{bmatrix} \end{aligned} \quad (2.79)$$

である.

(2.76) 式対数尤度関数は

$$\log L(\theta) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} (y - X\beta)' (y - X\beta)$$

であるから

$$\begin{aligned} S(\theta) &= \frac{\partial \log L(\theta)}{\partial \theta} = \begin{bmatrix} \frac{\partial \log L(\theta)}{\partial \beta} \\ \frac{\partial \log L(\theta)}{\partial \sigma^2} \end{bmatrix} \\ &= \begin{bmatrix} \frac{X'(y - X\beta)}{\sigma^2} \\ -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} (y - X\beta)' (y - X\beta) \end{bmatrix} \end{aligned}$$

$$I(\theta) = \begin{bmatrix} \frac{X'X}{\sigma^2} & 0 \\ 0' & \frac{n}{2\sigma^4} \end{bmatrix}$$

であるから

$$S(\theta^*) = \begin{bmatrix} \frac{X'e^*}{\sigma^{2*}} \\ 0 \end{bmatrix}, \quad I(\theta^*) = \begin{bmatrix} \frac{X'X}{\sigma^{2*}} & 0 \\ 0' & \frac{n}{2\sigma^{4*}} \end{bmatrix}$$

となる. これらを (2.75) 式へ代入して次式を得る.

$$\begin{aligned} LM &= \begin{bmatrix} \frac{e^{*'} X}{\sigma^{2*}} & 0 \end{bmatrix} \begin{bmatrix} \frac{X'X}{\sigma^{2*}} & 0 \\ 0' & \frac{n}{2\sigma^{4*}} \end{bmatrix}^{-1} \begin{bmatrix} \frac{X'e^*}{\sigma^{2*}} \\ 0 \end{bmatrix} \\ &= \frac{e^{*'} X (X'X)^{-1} X' e^*}{\sigma^{2*}} \underset{\text{asy}}{H_0} \chi^2(r) \end{aligned} \quad (2.80)$$

ところがこの LM の式は, 補助方程式 auxiliary equation

$$e^* = X\alpha + v \quad (2.81)$$

における  $nR^2$  に等しい.

なぜならば (2.81) 式の  $e^*$  の平均は 0 であるから, (2.81) 式の OLS の決定係数は

$$R^2 = \frac{(X\bar{\alpha})' X\bar{\alpha}}{e^{*'} e^*}$$

によって与えられる.

$$\bar{\alpha} = (X'X)^{-1} X' e^*$$

であるから

$$\begin{aligned} (X\bar{\alpha})' X\bar{\alpha} &= e^{*'} X (X'X)^{-1} X' X (X'X)^{-1} X' e^* \\ &= e^{*'} X (X'X)^{-1} X' e^* \end{aligned}$$

となる. 他方

$$e^{*'} e^* = n\sigma^{2*}$$

であるから

$$nR^2 = \frac{ne^{*'} X (X'X)^{-1} X' e^*}{e^{*'} e^*} = \frac{e^{*'} X (X'X)^{-1} X' e^*}{\left(\frac{e^{*'} e^*}{n}\right)}$$

$$= \frac{e^{*'} X(X'X)^{-1} X' e^*}{\sigma^{2*}}$$

となり, これは (2.80) 式に等しい。

## 5.2 別の証明

$LM = nR^2$  は次のようにして証明することもできる。

$$X(X'X)^{-1} X' = I - M$$

$$e^* = e - X(\beta^* - \hat{\beta}) \quad (2.2 \text{ 節参照})$$

$$e^* = y - X\beta^*, \quad e = y - X\hat{\beta}, \quad \hat{\beta} = (X'X)^{-1} X'y$$

であるから

$$e^{*'} X(X'X)^{-1} X' e^* = e^{*'} (I - M) e^* = e^{*'} e^* - e^{*'} M e^*$$

$$e^{*'} M e^* = [e - X(\beta^* - \hat{\beta})]' M [e - X(\beta^* - \hat{\beta})]$$

$$= e' M e = e'e$$

ゆえに

$$e^{*'} X(X'X)^{-1} X' e^* = e^{*'} e^* - e'e$$

したがって

$$nR^2 = n \frac{e^{*'} e^* - e'e}{e^{*'} e^*} = \frac{e^{*'} e^* - e'e}{\sigma^{2*}}$$

となる。

他方, (2.70) 式と (2.15) 式を用いれば

$$LM = \frac{e^{*'} e^* - e'e}{\sigma^{2*}}$$

と表すこともできるから,  $LM = nR^2$  に等しい。

## 5.3 非線形モデルの LM

$LM = nR^2$  は非線形モデルの特別な場合として求めることもできる。

未知パラメータに関して非線形のモデル

$$y = f(X, \beta) + u$$

において,  $R(\beta) = 0$  の制約の LM テストは, (次章 (3.75) 式で示すが),  $e^*$

の  $Z(b^*)$  への回帰を行ったときの決定係数  $R^2$  に  $n$  をかけたものに等しい。

ここで

$$e^* = y - f(X, b^*)$$

$b^* = R(\beta) = 0$  の制約のもとでの  $\beta$  の MLE

$$Z(b^*) = \left\{ \begin{array}{l} \frac{\partial f_i}{\partial \beta_j} \Big|_{\beta_j = b_j^*}, \quad i=1, \dots, n \\ \quad \quad \quad \quad \quad \quad \quad \quad \quad \quad j=1, \dots, k \end{array} \right\}$$

である。

未知パラメータ  $\beta$  に関して線形るとき

$$\frac{\partial f_i}{\partial \beta_j} = X_{ji}, \quad i=1, \dots, n, \quad j=1, \dots, k$$

となるから  $Z(b^*) = X$  となり,  $e^*$  の  $Z(b^*)$  への回帰は  $e^*$  の  $X$  への回帰に等しい。

## 例 2.6 除外変数の検定

(2.73) 式の定式化には  $r$  個の変数  $Z_1, \dots, Z_r$  が除外されているのではないかとこの仮説を検定しよう。モデルを

$$y = X\beta + Z\gamma + \varepsilon \quad (2.82)$$

$$\varepsilon \sim N(0, \sigma^2 I)$$

と定式化する。検定したい仮説は  $H_0: \gamma = 0$  である。通常の  $F$  検定ではなく、補助方程式を用いる検定を説明しよう。

(2.82) 式で  $H_0: \gamma = 0$  の制約が正しいとき (2.73) 式になる。(2.73) 式の OLS 残差を  $e^*$ ,  $\beta$  の推定量を  $\hat{\beta}$  とすると

$$e^* = y - X\hat{\beta} = M_X y$$

ここで

$$M_X = I - X(X'X)^{-1} X'$$

である。

(2.82) 式の OLS 残差を  $e$  とし,  $\beta, \gamma$  の推定量をそれぞれ  $\hat{\beta}, \hat{\gamma}$  とすると

$$e = y - X\hat{\beta} - Z\hat{\gamma} = y - (X \ Z) \begin{bmatrix} \hat{\beta} \\ \hat{\gamma} \end{bmatrix}$$

$$= y - W\hat{\delta} = M_W y$$

と表すことができる。ここで

$$W = (X \ Z)$$

$$\hat{\delta} = \begin{bmatrix} \hat{\beta} \\ \hat{\gamma} \end{bmatrix}$$

$$M_w = I - W(W'W)^{-1}W'$$

である。

ところが

$$e^* = y - X\hat{\beta} = y - W\hat{\delta} - (X\hat{\beta} - W\hat{\delta}) = e - (X\hat{\beta} - W\hat{\delta})$$

であるから、 $e^*$  の  $W$  への回帰を行ったときの残差

$$M_w e^* = M_w e - (M_w X\hat{\beta} - M_w W\hat{\delta})$$

において

$$M_w W = M_w (X \ Z) = (M_w X \ M_w Z) = 0$$

であるから

$$M_w e^* = M_w e = M_w (M_w y) = M_w y$$

となる。すなわち

$$\begin{aligned} e^* \text{ の } W \text{ への回帰を行ったときの残差 } M_w e^* \\ = y \text{ の } W \text{ への回帰を行ったときの残差 } M_w y \end{aligned}$$

である。つまり補助方程式

$$e^* = X\beta + Z\gamma + v \quad (2.83)$$

の OLS 残差  $\hat{v} = M_w e^*$  と (2.82) 式の OLS 残差  $M_w y$  は等しい。(2.82) 式に

において  $H_0: \gamma = 0$  が正しいとき、すなわち (2.73) 式が正しいとき

$$\frac{e^{*'} e^*}{\sigma^2} \sim \chi^2(n-k)$$

である。他方 (2.82) 式のモデルのとき

$$\frac{e' e}{\sigma^2} \sim \chi^2(n-k-r)$$

であるから、 $H_0$  が正しいとき

$$\frac{e^{*'} e^* - e' e}{\sigma^2} \sim \chi^2(r)$$

となる。

$\sigma^2$  を  $e^{*'} e^* / n$  で推定し、 $n$  が十分大きければ

$$\frac{e^{*'} e^* - e' e}{\sigma^2} \approx \frac{e^{*'} e^* - e' e}{(e^{*'} e^* / n)} = n \left( 1 - \frac{e' e}{e^{*'} e^*} \right)$$

と表すことができる。ところが

$e^{*'} e^* = (2.83)$  式的全変動

$$e' e = (M_w y)' (M_w y) = (M_w e^*)' (M_w e^*)$$

$= (2.83)$  式の残差平方和

であるから、(2.83) 式の決定係数を  $R^2$  とすると

$$n \left( 1 - \frac{e' e}{e^{*'} e^*} \right) = n R^2$$

となる。したがって

$$n R^2 \stackrel{H_0}{\underset{\text{asy}}{\sim}} \chi^2(r)$$

が、 $H_0: \gamma = 0$  の検定統計量である。すなわち (2.82) 式における  $\gamma = 0$  の検定統計量は、大標本のとき、補助方程式 (2.83) 式の  $n R^2$  に等しい。

## 6 ラグランジュ乗数検定の別の展開

ラグランジュ乗数検定は次のように展開することもできる。スコア  $S(\theta)$  を

$$S(\theta) = \frac{\partial \log L(\theta)}{\partial \theta} = \sum_{i=1}^n w_i(\theta) = W'(\theta) i \quad (2.84)$$

と表す。ここで

$$w_i(\theta) = \frac{\partial \log L_i(\theta)}{\partial \theta}$$

$$L_i(\theta) = L(\theta; y_i, X_i)$$

$$W(\theta) = \begin{bmatrix} w_1'(\theta) \\ w_2'(\theta) \\ \vdots \\ w_n'(\theta) \end{bmatrix}$$

$$i' = (1 \ 1 \ \cdots \ 1)$$

である。

モデルの誤差項に  $u_i \sim \text{NID}(0, \sigma^2)$  を仮定しているから、 $w_1(\theta), \dots, w_n(\theta)$  も独立で均一分散をもつ。したがって

$$\begin{aligned} \text{var}[S(\theta)] &= \text{var}\left(\sum_{i=1}^n w_i(\theta)\right) = \sum_{i=1}^n \text{var}[w_i(\theta)] \\ &= n \text{var}[w_i(\theta)] = n E[w_i(\theta) w_i(\theta)'] \\ &= I(\theta) \end{aligned}$$