

# 第 8 回 回帰係数の検定 (6.4–6.5)

村澤 康友

2020 年 6 月 9 日

## 今日のポイント

1. 誤差項が独立に  $N(0, \sigma^2)$  に従う線形回帰モデルを古典的正規線形回帰モデルという。古典的正規線形回帰モデルの回帰係数の OLS 推定量は正規分布にしたがう。誤差分散  $\sigma^2$  の不偏推定量  $s^2$  は  $(n - k)s^2/\sigma^2 \sim \chi^2(n - k)$ .
2.  $H_0$ : 「個別の回帰係数 = 0」を検定する t 統計量の値を t 値という。  $H_0$  の下で  $t \sim t(n - k)$ .
3.  $H_0$ : 「定数項を除く全ての回帰係数 = 0」を検定する F 統計量の値を F 値という。  $H_0$  の下で  $F \sim F(k - 1, n - k)$ .
4. 線形モデルで  $E(\mathbf{x}_i u_i) = \mathbf{0}$  かつ無作為標本なら OLS 推定量は一致推定量。さらに  $\text{var}(u_i | \mathbf{x}_i) = \sigma^2$  なら OLS 推定量の漸近分布は古典的正規線形回帰モデルの場合と同じ。

	2.3 t 値 . . . . .	3
3	回帰係数の F 検定	3
3.1	分散が既知 . . . . .	3
3.2	分散が未知 (p. 154) . . . . .	3
3.3	F 値 . . . . .	3
4	OLS 推定量の漸近特性	4
4.1	線形モデル (p. 157) . . . . .	4
4.2	MM (= OLS) 推定量 . . . . .	4
4.3	漸近演算 (p. 152) . . . . .	4
4.4	一致性 (p. 156) . . . . .	4
4.5	漸近正規性 (p. 157) . . . . .	4
5	今日のキーワード	5
6	次回までの準備	5

## 1 OLS 推定量の標本分布

1.1 古典的正規線形回帰モデル (p. 148)  
 $(1 + k)$  変量データを  $((y_1, \mathbf{x}_1), \dots, (y_n, \mathbf{x}_n))$  とする。ただし  $\mathbf{x}_i := (x_{i,1}, \dots, x_{i,k})'$ 。  $y_i$  の  $\mathbf{x}_i$  上への線形回帰モデルは

$$E(y_i | \mathbf{x}_i) = \boldsymbol{\beta}' \mathbf{x}_i$$

または

$$y_i = \boldsymbol{\beta}' \mathbf{x}_i + u_i$$

$$E(u_i | \mathbf{x}_i) = 0$$

## 目次

1	OLS 推定量の標本分布	1
1.1	古典的正規線形回帰モデル (p. 148)	1
1.2	回帰係数の OLS 推定量 (p. 148) . . . . .	2
1.3	誤差分散の不偏推定量 . . . . .	2
1.4	標準誤差 (p. 149) . . . . .	2
2	回帰係数の t 検定	2
2.1	分散が既知 (p. 149) . . . . .	2
2.2	分散が未知 (p. 149) . . . . .	2

定義 1.  $(\mathbf{x}_1, \dots, \mathbf{x}_n)$  を所与として  $u_1, \dots, u_n$  が独立に  $N(0, \sigma^2)$  に従う線形回帰モデルを古典的正規線形回帰モデルという。

注 1. すなわち

$$y_i = \beta' \mathbf{x}_i + u_i$$

$$\{u_i\} | \{\mathbf{x}_i\} \sim \text{IN}(0, \sigma^2)$$

または

$$\{y_i\} | \{\mathbf{x}_i\} \sim \text{IN}(\beta' \mathbf{x}_i, \sigma^2)$$

## 1.2 回帰係数の OLS 推定量 (p. 148)

既に見た通り

$$\mathbf{b} = \left( \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)^{-1} \sum_{i=1}^n \mathbf{x}_i y_i$$

定理 1. 古典的正規線形回帰モデルなら

$$\mathbf{b} | \mathbf{x}_1, \dots, \mathbf{x}_n \sim \text{N} \left( \beta, \sigma^2 \left( \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)^{-1} \right)$$

証明.  $(\mathbf{x}_1, \dots, \mathbf{x}_n)$  を所与として  $\mathbf{b}$  は  $y_1, \dots, y_n$  の線形変換だから ( $k$  変量) 正規分布. 平均と分散は既に見た.  $\square$

## 1.3 誤差分散の不偏推定量

$\hat{y}_i := \mathbf{b}' \mathbf{x}_i$  とすると,  $\sigma^2$  の不偏推定量は

$$s^2 := \frac{1}{n-k} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

ただし  $k$  は推定する係数の数.

定理 2. 古典的正規線形回帰モデルなら

$$\frac{(n-k)s^2}{\sigma^2} \sim \chi^2(n-k)$$

証明. 省略 (行列を使うと簡単).  $\square$

定理 3. 古典的正規線形回帰モデルなら  $\mathbf{b}$  と  $s^2$  は独立.

証明. 省略 (行列を使うと簡単).  $\square$

## 1.4 標準誤差 (p. 149)

定義 2. 推定量の標準偏差の推定値を標準誤差という.

注 2.  $\mathbf{b}$  の分散は  $\sigma^2 (\sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i')^{-1}$ . その推定値は  $s^2 (\sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i')^{-1}$ . この対角成分の平方根が各

係数の OLS 推定量の標準誤差. 定数項のない単回帰モデルなら  $b$  の標準誤差は

$$\text{s.e.}(b) = \sqrt{\frac{s^2}{\sum_{i=1}^n x_i^2}}$$

## 2 回帰係数の t 検定

### 2.1 分散が既知 (p. 149)

簡単化のため定数項のない単回帰モデルで考える.  $y_i$  の  $x_i$  上への古典的正規線形回帰モデルは

$$y_i = \beta x_i + u_i$$

$$\{u_i\} | \{x_i\} \sim \text{IN}(0, \sigma^2)$$

次の片側検定問題を考える.

$$H_0: \beta = c \quad \text{vs} \quad H_1: \beta > c$$

$\beta$  の OLS 推定量を  $b$  とすると

$$b | x_1, \dots, x_n \sim \text{N} \left( \beta, \frac{\sigma^2}{\sum_{i=1}^n x_i^2} \right)$$

標準化すると

$$\frac{b - \beta}{\sqrt{\sigma^2 / \sum_{i=1}^n x_i^2}} | x_1, \dots, x_n \sim \text{N}(0, 1)$$

この分布は  $x_1, \dots, x_n$  に依存しないので

$$\frac{b - \beta}{\sqrt{\sigma^2 / \sum_{i=1}^n x_i^2}} \sim \text{N}(0, 1)$$

検定統計量は

$$Z := \frac{b - c}{\sqrt{\sigma^2 / \sum_{i=1}^n x_i^2}}$$

$H_0$  の下で

$$Z \sim \text{N}(0, 1)$$

標準正規分布表より棄却域を定める.

### 2.2 分散が未知 (p. 149)

$\sigma^2$  の推定量  $s^2$  について

$$\frac{(n-k)s^2}{\sigma^2} \sim \chi^2(n-k)$$

また  $b$  と  $s^2$  は独立. したがって  $\sigma^2$  を  $s^2$  に置き換えると

$$\frac{b - \beta}{\sqrt{s^2 / \sum_{i=1}^n x_i^2}} \sim t(n-k)$$

検定統計量 (t 統計量) は

$$t := \frac{b - c}{\sqrt{s^2 / \sum_{i=1}^n x_i^2}}$$

$H_0$  の下で

$$t \sim t(n - k)$$

t 分布表より棄却域を定める.

### 2.3 t 値

定義 3.  $H_0 : \beta = 0$  を検定する t 統計量の値を  $t$  値という.

注 3. すなわち

$$t = \frac{b}{\text{s.e.}(b)}$$

## 3 回帰係数の F 検定

### 3.1 分散が既知

簡単化のため定数項のない単回帰モデルで考える.  $y_i$  の  $x_i$  上への古典的正規線形回帰モデルは

$$y_i = \beta x_i + u_i \\ \{u_i\} | \{x_i\} \sim \text{IN}(0, \sigma^2)$$

次の両側検定問題を考える.

$$H_0 : \beta = c \quad \text{vs} \quad H_1 : \beta \neq c$$

$\beta$  の OLS 推定量を  $b$  とすると

$$b | x_1, \dots, x_n \sim N\left(\beta, \frac{\sigma^2}{\sum_{i=1}^n x_i^2}\right)$$

標準化すると

$$\frac{b - \beta}{\sqrt{\sigma^2 / \sum_{i=1}^n x_i^2}} | x_1, \dots, x_n \sim N(0, 1)$$

この分布は  $x_1, \dots, x_n$  に依存しないので

$$\frac{b - \beta}{\sqrt{\sigma^2 / \sum_{i=1}^n x_i^2}} \sim N(0, 1)$$

2 乗すると

$$\frac{(b - \beta)^2 \sum_{i=1}^n x_i^2}{\sigma^2} \sim \chi^2(1)$$

検定統計量は

$$\chi^2 := \frac{(b - c)^2 \sum_{i=1}^n x_i^2}{\sigma^2}$$

$H_0$  の下で

$$\chi^2 \sim \chi^2(1)$$

$\chi^2$  分布表より棄却域を定める.

注 4. 重回帰モデルの複数の係数の両側検定に拡張できる (行列を使うと簡単).  $r$  個の係数の検定なら  $H_0$  の下で  $\chi^2 \sim \chi^2(r)$ .

### 3.2 分散が未知 (p. 154)

$\sigma^2$  の推定量  $s^2$  について

$$\frac{(n - k)s^2}{\sigma^2} \sim \chi^2(n - k)$$

また  $b$  と  $s^2$  は独立. したがって  $\sigma^2$  を  $s^2$  に置き換えると

$$\frac{(b - \beta)^2 \sum_{i=1}^n x_i^2}{s^2} = \frac{(b - \beta)^2 \sum_{i=1}^n x_i^2 / \sigma^2}{[(n - k)s^2 / \sigma^2] / (n - k)} \\ \sim F(1, n - k)$$

検定統計量 (F 統計量) は

$$F := \frac{(b - c)^2 \sum_{i=1}^n x_i^2}{s^2}$$

$H_0$  の下で

$$F \sim F(1, n - k)$$

F 分布表より棄却域を定める.

注 5. 重回帰モデルの複数の係数の両側検定に拡張できる (行列を使うと簡単).  $r$  個の係数の検定なら  $H_0$  の下で  $F \sim F(r, n - k)$ .

### 3.3 F 値

定義 4.  $H_0 : \beta = 0$  を検定する F 統計量の値を  $F$  値という.

注 6. 次の重回帰モデルを考える.

$$y_i = \beta_1 + \beta_2 x_{i,2} + \dots + \beta_k x_{i,k} + u_i \\ \{u_i\} \sim \text{IN}(0, \sigma^2)$$

ただし  $\beta_1$  は定数項. 次の両側検定問題を考える.

$$H_0 : \begin{pmatrix} \beta_2 \\ \vdots \\ \beta_k \end{pmatrix} = \mathbf{0} \quad \text{vs} \quad H_1 : \begin{pmatrix} \beta_2 \\ \vdots \\ \beta_k \end{pmatrix} \neq \mathbf{0}$$

このとき  $H_0$  の下で

$$F \sim F(k - 1, n - k)$$

## 4 OLS 推定量の漸近特性

### 4.1 線形モデル (p. 157)

$(1+k)$  変量データを  $((y_1, \mathbf{x}_1), \dots, (y_n, \mathbf{x}_n))$  とする。ただし  $\mathbf{x}_i := (x_{i,1}, \dots, x_{i,k})'$ 。  $y_i$  の  $\mathbf{x}_i$  上への線形モデルは

$$\begin{aligned} y_i &= \boldsymbol{\beta}' \mathbf{x}_i + u_i \\ E(u_i) &= 0 \end{aligned}$$

定理 4.  $E(\mathbf{x}_i u_i) = \mathbf{0}$  で  $E(\mathbf{x}_i \mathbf{x}_i')$  の逆行列が存在すれば

$$\boldsymbol{\beta} = E(\mathbf{x}_i \mathbf{x}_i')^{-1} E(\mathbf{x}_i y_i)$$

証明.  $u_i = y_i - \mathbf{x}_i' \boldsymbol{\beta}$  を代入すると

$$E(\mathbf{x}_i (y_i - \mathbf{x}_i' \boldsymbol{\beta})) = \mathbf{0}$$

すなわち

$$E(\mathbf{x}_i y_i) = E(\mathbf{x}_i \mathbf{x}_i') \boldsymbol{\beta}$$

この連立方程式を  $\boldsymbol{\beta}$  について解けばよい。 □

### 4.2 MM (= OLS) 推定量

$\boldsymbol{\beta}$  の MM (= OLS) 推定量を  $\mathbf{b}_n$  とすると

$$\frac{1}{n} \sum_{i=1}^n \mathbf{x}_i (y_i - \mathbf{x}_i' \mathbf{b}_n) = \mathbf{0}$$

すなわち

$$\sum_{i=1}^n \mathbf{x}_i y_i = \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \mathbf{b}_n$$

この連立方程式を  $\mathbf{b}_n$  について解くと

$$\mathbf{b}_n = \left( \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)^{-1} \sum_{i=1}^n \mathbf{x}_i y_i$$

### 4.3 漸近演算 (p. 152)

定理 5 (スルツキーの定理).  $\text{plim}_{n \rightarrow \infty} X_n \rightarrow c$  で  $f(\cdot)$  が  $c$  で連続なら

$$\text{plim}_{n \rightarrow \infty} f(X_n) = f(c)$$

証明. 省略 (大学院レベル)。 □

注 7. すなわち

$$\text{plim}_{n \rightarrow \infty} f(X_n) = f \left( \text{plim}_{n \rightarrow \infty} X_n \right)$$

定理 6 (クラーメルの定理).  $\text{plim}_{n \rightarrow \infty} X_n \rightarrow c$  で  $Y_n \xrightarrow{d} Y$  なら

$$X_n Y_n \xrightarrow{d} cY$$

証明. 省略 (大学院レベル)。 □

注 8. こちらをスルツキーの定理と呼ぶ場合もある。

例 1. 例えば  $\text{plim}_{n \rightarrow \infty} X_n \rightarrow c$  で  $Z_n \xrightarrow{d} N(0, 1)$  なら

$$X_n Z_n \xrightarrow{d} N(0, c^2)$$

定理 7 (連続写像定理).  $X_n \xrightarrow{d} X$  で  $f(\cdot)$  が連続なら

$$f(X_n) \xrightarrow{d} f(X)$$

証明. 省略 (大学院レベル)。 □

例 2. 例えば  $Z_n \xrightarrow{d} N(0, 1)$  なら  $Z_n^2 \xrightarrow{d} \chi^2(1)$ 。

### 4.4 一致性 (p. 156)

以下では無作為標本を仮定する。

定理 8.  $E(\mathbf{x}_i u_i) = \mathbf{0}$  で  $E(\mathbf{x}_i \mathbf{x}_i')$  の逆行列が存在すれば

$$\text{plim}_{n \rightarrow \infty} \mathbf{b}_n = \boldsymbol{\beta}$$

証明. 大数の法則より

$$\text{plim}_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' = E(\mathbf{x}_i \mathbf{x}_i')$$

$$\text{plim}_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i y_i = E(\mathbf{x}_i y_i)$$

スルツキーの定理より

$$\begin{aligned} \text{plim}_{n \rightarrow \infty} \mathbf{b}_n &= \left( \text{plim}_{n \rightarrow \infty} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)^{-1} \text{plim}_{n \rightarrow \infty} \sum_{i=1}^n \mathbf{x}_i y_i \\ &= E(\mathbf{x}_i \mathbf{x}_i')^{-1} E(\mathbf{x}_i y_i) \end{aligned}$$

$E(\mathbf{x}_i u_i) = \mathbf{0}$  よりこれは  $\boldsymbol{\beta}$ 。 □

### 4.5 漸近正規性 (p. 157)

補題 1.  $E(\mathbf{x}_i u_i) = \mathbf{0}$  で  $\text{var}(u_i | \mathbf{x}_i) = \sigma^2$  なら

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n \mathbf{x}_i u_i \xrightarrow{d} N(\mathbf{0}, \sigma^2 E(\mathbf{x}_i \mathbf{x}_i'))$$

証明.  $E(\mathbf{x}_i u_i) = \mathbf{0}$  なので中心極限定理より

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n \mathbf{x}_i u_i \xrightarrow{d} N(\mathbf{0}, \text{var}(\mathbf{x}_i u_i))$$

繰り返し期待値の法則より

$$\begin{aligned} \text{var}(\mathbf{x}_i u_i) &= E(\mathbf{x}_i u_i (\mathbf{x}_i u_i)') \\ &= E(u_i^2 \mathbf{x}_i \mathbf{x}_i') \\ &= E(E(u_i^2 \mathbf{x}_i \mathbf{x}_i' | \mathbf{x}_i)) \\ &= E(E(u_i^2 | \mathbf{x}_i) \mathbf{x}_i \mathbf{x}_i') \\ &= E(\text{var}(u_i | \mathbf{x}_i) \mathbf{x}_i \mathbf{x}_i') \\ &= E(\sigma^2 \mathbf{x}_i \mathbf{x}_i') \\ &= \sigma^2 E(\mathbf{x}_i \mathbf{x}_i') \end{aligned}$$

□

定理 9.  $E(\mathbf{x}_i u_i) = \mathbf{0}$  で  $E(\mathbf{x}_i \mathbf{x}_i')$  の逆行列が存在し,  $\text{var}(u_i | \mathbf{x}_i) = \sigma^2$  なら

$$\sqrt{n}(\mathbf{b}_n - \boldsymbol{\beta}) \xrightarrow{d} N(\mathbf{0}, \sigma^2 E(\mathbf{x}_i \mathbf{x}_i')^{-1})$$

証明.  $y_i = \mathbf{x}_i' \boldsymbol{\beta} + u_i$  より

$$\begin{aligned} \mathbf{b}_n &= \left( \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)^{-1} \sum_{i=1}^n \mathbf{x}_i (\mathbf{x}_i' \boldsymbol{\beta} + u_i) \\ &= \boldsymbol{\beta} + \left( \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)^{-1} \sum_{i=1}^n \mathbf{x}_i u_i \end{aligned}$$

変形すると

$$\sqrt{n}(\mathbf{b}_n - \boldsymbol{\beta}) = \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)^{-1} \frac{1}{\sqrt{n}} \sum_{i=1}^n \mathbf{x}_i u_i$$

大数の法則より

$$\text{plim}_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' = E(\mathbf{x}_i \mathbf{x}_i')$$

補題より

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n \mathbf{x}_i u_i \xrightarrow{d} N(\mathbf{0}, \sigma^2 E(\mathbf{x}_i \mathbf{x}_i'))$$

スルツキーの定理とクラームの定理より

$$\begin{aligned} &\left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)^{-1} \frac{1}{\sqrt{n}} \sum_{i=1}^n \mathbf{x}_i u_i \\ &\xrightarrow{d} N(\mathbf{0}, \sigma^2 E(\mathbf{x}_i \mathbf{x}_i')^{-1}) \end{aligned}$$

□

注 9. したがって

$$\mathbf{b}_n \overset{a}{\sim} N(\boldsymbol{\beta}, \sigma^2 (n E(\mathbf{x}_i \mathbf{x}_i')^{-1}))$$

または

$$\mathbf{b}_n | \mathbf{x}_1, \dots, \mathbf{x}_n \overset{a}{\sim} N\left(\boldsymbol{\beta}, \sigma^2 \left( \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)^{-1}\right)$$

すなわち OLS 推定量の漸近分布は古典的正規線形回帰モデルの場合と同じ。

## 5 今日のキーワード

古典的正規線形回帰モデル, 標準誤差, t 値, F 値

## 6 次回までの準備

提出 宿題 4, 復習テスト 1-8 (提出方法は追って連絡)

復習 教科書第 6 章 4-5 節, 復習テスト 8

試験 準備中 (実施方法は追って連絡)