

# 第8回：回帰係数の検定

## 【教科書第6章第4節～第5節】

北村 友宏

2025年11月18日

# 本日の内容

1. 単一の回帰係数の検定
2. 線形制約の検定
3. OLS 推定量の性質（大標本の場合）

# 実証分析例：ミンサー方程式の推定

就業可能年数をコントロールしたうえで、「修学年数が増えると、年収がどれだけ増えるのか」を分析するためのモデル（ミンサー方程式）

$$\ln \text{income}_i = \beta_0 + \beta_1 \text{yeduc}_i + \beta_2 \text{exper}_i + \beta_3 \text{exper}_i^2 + u_i$$

- ▶  $\text{income}_i$  : 年収（万円）
- ▶  $\text{yeduc}_i$  : 修学年数（年）
- ▶  $\text{exper}_i$  : 就業可能年数（年）
- ▶  $i$  : 個人番号

を推定する。

➡ 「年収の対数値」を「修学年数」と「就業可能年数」と「就業可能年数の2乗」に回帰する。

▶ 就業可能年数

- ▶ 最後の学校を卒業してからの年数

$$\text{就業可能年数} = \text{年齢} - \text{修学年数} - 6.$$

※ 小学校に入学する年齢が 6 歳のため, 6 を引いて  
いる。

- ▶ 熟練度を表す.  
⇒ 賃金に影響を与える.



修学年数が年収に与える純粋な効果を計測す  
るには, 熟練度 (を表す就業可能年数) をコン  
トロールする必要がある.

# モデル推定結果

gretl: モデル1

ファイル 編集(E) 検定(I) 保存(S) グラフ(G) 分析(A) LaTeX

モデル 1: 最小二乗法(OLS), 観測: 1-4299  
従属変数: lincome

	係数	標準誤差	t 値	p 値
const	2.48550	0.110782	22.44	1.64e-105 ***
yeduc	0.117547	0.00706026	16.65	2.31e-060 ***
exper	0.196174	0.00749354	26.18	2.75e-140 ***
exper2	-0.00638115	0.000316188	-20.18	1.32e-086 ***

Mean dependent var 5.290452 S.D. dependent var 0.895883  
Sum squared resid 2736.906 回帰の標準誤差 0.798267  
R-squared 0.206603 Adjusted R-squared 0.206049  
F(3, 4295) 372.8097 P-value(F) 3.4e-215  
Log-likelihood -5129.400 Akaike criterion 10266.80  
Schwarz criterion 10292.27 Hannan-Quinn 10275.79

# 出力結果の見方

- ▶ 係数: (偏) 回帰係数推定値
- ▶ 標準誤差: (偏) 回帰係数の標準誤差
- ▶ t 値: 「(偏) 回帰係数が 0」 という帰無仮説の両側  $t$  検定における検定統計量の実現値 ( $t$  値)
- ▶ p 値: 両側  $p$  値
- ▶ 回帰の標準誤差 : 誤差項の標準誤差
- ▶ R-squared: 決定係数
- ▶ Adjusted R-squared: 自由度修正済み決定係数

# 標準誤差

- ▶ 標準偏差の推定値を**標準誤差** (standard error) という.
- ▶ 重回帰モデル

$$\begin{aligned}y &= X\beta + u, \\E(u \mid X) &= \mathbf{0}, \\V(u \mid X) &= \sigma^2 I_n,\end{aligned}$$

における  $j$  番目の（偏）回帰係数の OLS 推定量  $\hat{\beta}_j$  の（デフォルトの）標準誤差は，

$$\text{s.e.} \left( \hat{\beta}_j \right) = \sqrt{\left[ \frac{\mathbf{e}'\mathbf{e}}{n - k - 1} (X'X)^{-1} \right]_{j,j}}.$$

⇒ この標準誤差は、任意の  $i$  について  $V(u_i | X)$  が一定（均一分散）の場合のみ正しい。

# 仮説検定

- ▶ 被説明変数や説明変数は様々な値をとり、観測される前はどのような値になるかが不確定（確率変数）。
- ▶ 被説明変数や説明変数を用いて計算する（偏）回帰係数の値も不確定。

⇒ 例えば回帰係数  $\beta_1$  の推定値として  $\hat{\beta}_1 = 0.117547$  という値が得られても、「推定値  $\hat{\beta}_1$  は真の  $\beta_1$  の値と必ずしも同じではなく、真の  $\beta_1$  は 0 で、その推定値  $\hat{\beta}_1$  は様々な値をとりうる中でたまたま 0.117547 になった」可能性もある。

⇒ 仮説検定を行い、「真の（偏）回帰係数が 0 かどうか」を検証する。

gretlなどの統計解析ソフトで線形回帰モデルを推定すると、各（偏）回帰係数  $\beta_j$ について、

$$H_0 : \beta_j = 0 \quad \text{vs} \quad H_1 : \beta_j \neq 0$$

を検定するのに必要な情報が output される。

- ▶ 回帰分析では、通常は両側検定を行う。

- ▶  $H_0$  (係数は 0) が棄却された
  - ➡ 「その（偏）回帰係数は統計的に有意に 0 と異なる」と判断。
    - ▶ 「その説明変数は被説明変数と統計的に有意に相關している」と解釈.
    - ▶ 定数項の検定の場合は「定数項は統計的に有意に 0 と異なる」と解釈.
  
- ▶  $H_0$  (係数は 0) が採択された
  - ➡ 「その（偏）回帰係数は 0 と異なるとは言えない」と判断.
    - ▶ 「その説明変数は被説明変数と相關しているとは言えない」と解釈.
    - ▶ 定数項の検定の場合は「定数項は統計的に有意に 0 と異なるとは言えない」と解釈.

# $p$ 値による判断

- ▶ 検定統計量（の絶対値）が実現値（検定統計値）を超える（以上になる）確率を  **$p$  値 (p-value)** という。
  - ▶  $p$  値が 0.1 以下（未満）：有意水準 10% で  $H_0$  を棄却。
  - ▶  $p$  値が 0.05 以下（未満）：有意水準 5% で  $H_0$  を棄却（10% でも棄却できる）。
  - ▶  $p$  値が 0.01 以下（未満）：有意水準 1% で  $H_0$  を棄却（5%, 10% でも棄却できる）。
- ⇒  $p$  値を見て、帰無仮説の採択・棄却を判断できる。
- ※ 検定統計量が連續型の確率分布（正規分布,  $t$  分布, カイ二乗分布,  $F$  分布など）に従う場合、「以上」と「超える」, 「以下」と「未満」は区別しなくて良い。

gretl では、モデル推定結果の各説明変数の行の右端にアスタリスク (\*) が表示され、\* の個数を見れば、「有意水準何%で『(偏) 回帰係数は 0』の  $H_0$  を棄却できるか」が分かる。

- ▶ (アスタリスクなし) : 有意水準 10%でも「係数は 0」の  $H_0$  採択.
- ▶ \*: 有意水準 10%で、「係数は 0」の  $H_0$  棄却.
- ▶ \*\*: 有意水準 5%で、「係数は 0」の  $H_0$  棄却 (10%でも棄却できる).
- ▶ \*\*\*: 有意水準 1%で、「係数は 0」の  $H_0$  棄却 (5%, 10%でも棄却できる).

## $t$ 値による判断

$\beta_j = 0$  という  $H_0$  を検定するための  $t$  検定統計量は、

$$t = \frac{\hat{\beta}_j}{\text{s.e.}(\hat{\beta}_j)} \sim t(n - k - 1).$$

- ▶ 観測値数が十分に大きいとき、 $t$  値の絶対値がほぼ 2 を超えていれば、 $H_0$  を棄却と判断（大雑把な判断）。
- ➡ 「有意水準何%で  $H_0$  を棄却できるか」を厳密に判断するには、 $t$  値ではなく  $p$  値を見る。

# モデル推定結果

## ▶ 修学年数の係数

- ▶ 0.117547 (符号は正)
- ▶  $t$  値は 16.65,  $p$  値は  $2.31 \times 10^{-60}$ .
  - ➡ 仮に「yeduc の係数が 0」だとすると, 16.65 という  $t$  値は  $2.31 \times 10^{-60}$ , つまりほぼ 0% の確率 (1% を下回る確率) でしか出てこない.
  - ➡ 有意水準 1% で, 「係数は 0」の  $H_0$  が棄却される (5% や 10% でも棄却される).
  - ➡ 修学年数は年収と統計的に有意に相関している.
- ▶ 年収と修学年数についてはログ=レベル・モデルの関係.
  - ➡ 就業可能年数 (とその 2 乗) を一定としたうえで, 修学年数が 1 年長くなると, 年収が平均して 11.7547% 高くなる傾向がある.

- ▶ 就業可能年数の 1 乗の係数
  - ▶ 0.196174 (符号は正)
  - ▶  $t$  値は 26.18,  $p$  値は  $2.75 \times 10^{-140}$ .
    - ▶ 仮に「exper の係数が 0」だとすると, 26.18 という  $t$  値は  $2.75 \times 10^{-140}$ , つまりほぼ 0% の確率 (1% を下回る確率) でしか出てこない.
    - ▶ 有意水準 1% で, 「係数は 0」の  $H_0$  が棄却される (5% や 10% でも棄却される).
    - ▶ 就業可能年数の 1 乗は年収と統計的に有意に相關している.

この係数の解釈は, 次回の授業で説明する.

- ▶ 就業可能年数の 2 乗の係数
  - ▶  $-0.00638115$  (符号は負)
  - ▶  $t$  値は  $-20.18$ ,  $p$  値は  $1.32 \times 10^{-86}$ .
    - ▶ 仮に「exper2 の係数が 0」だとすると,  $-20.18$  という  $t$  値は  $1.32 \times 10^{-86}$ , つまりほぼ 0% の確率 (1% を下回る確率) でしか出てこない.
    - ▶ 有意水準 1% で, 「係数は 0」の  $H_0$  が棄却される (5% や 10% でも棄却される).
    - ▶ 就業可能年数の 2 乗は年収と統計的に有意に相關している.

この係数の解釈は, 次回の授業で説明する.

## ▶ 定数項

- ▶ 2.4855 (符号は正)
- ▶  $t$  値は 22.44,  $p$  値は  $1.64 \times 10^{-105}$ 
  - ➡ 仮に「定数項が 0」だとすると, 22.44 という  $t$  値は  $1.64 \times 10^{-105}$ , つまりほぼ 0% の確率 (1% を下回る確率) でしか出てこない.
  - ➡ 有意水準 1% で, 「係数は 0」の  $H_0$  が棄却される (5% や 10% でも棄却される).
  - ➡ 定数項は統計的に有意に 0 と異なる.

# 線形制約の検定

## ミンサー方程式

$$\ln \text{income}_i = \beta_0 + \beta_1 \text{yeduc}_i + \beta_2 \text{exper}_i + \beta_3 \text{exper}_i^2 + u_i$$

について、

$$H_0 : \beta_2 = 0 \text{かつ} \beta_3 = 0 \quad \text{vs} \quad H_1 : \beta_2 \neq 0 \text{または} \beta_3 \neq 0$$

を検定することを考える。

### ▶ $H_0$ の意味 :

- ▶  $\beta_2$  と  $\beta_3$  はどちらも 0.  
➡ モデルの説明変数に  $\text{exper}_i$  と  $\text{exper}_i^2$  は両方とも不要。

### ▶ $H_1$ の意味 :

- ▶ 少なくとも  $\beta_2$  か  $\beta_3$  のどちらか一方は 0 でない。  
➡ モデルの説明変数に少なくとも  $\text{exper}_i$  と  $\text{exper}_i^2$  のどちらかが必要。

- ▶  $H_0$  が真という仮定の下で、ミンサー方程式には  $\beta_2 = 0$  と  $\beta_3 = 0$  の 2 つの線形制約を課していることになる。  
→ 制約の数は 2.

別の例として、コブ・ダグラス型生産関数

$$\ln y_i = \beta_0 + \beta_k \ln k_i + \beta_l \ln l_i + u_i$$

に対して、規模に関して収穫一定の線形制約

$$\beta_k + \beta_l = 1$$

を  $H_0$  とし、

$\beta_k + \beta_l \neq 1$  (規模に関して収穫一定でない)

$\beta_k + \beta_l > 1$  (規模に関して収穫遞増)

$\beta_k + \beta_l < 1$  (規模に関して収穫遞減)

のどれか 1 つを  $H_1$  とした検定をすることもできる。

→ 制約の数は 1 (「 $\beta_k + \beta_l = 1$ 」の 1 つ).

- ▶  $y_i$ : 生産量または生産額
- ▶  $k_i$ : 資本量または資本額
- ▶  $l_i$ : 労働量

定数項以外に説明変数が  $k$  個ある重回帰モデルにおいて,  $r$  個の線形制約を検定するための検定統計量とその分布は,

$$F = \frac{(Q_R - Q_{UR})/r}{Q_{UR}/(n - k - 1)} \sim F(r, n - k - 1).$$

- ▶  $Q_R$ : 制約付きモデルの残差二乗和
- ▶  $Q_{UR}$ : 制約なしモデルの残差二乗和

( $F$  分布に従うことの証明は省略)



$F$  検定をすればよい.

この検定統計量は、決定係数を用いて以下のように書き換えることもできる。

$$F = \frac{(R_{UR}^2 - R_R^2)/r}{(1 - R_{UR}^2)/(n - k - 1)} \sim F(r, n - k - 1).$$

- ▶  $R_{UR}^2$ : 制約なしモデルの決定係数
  - ▶  $R_R^2$ : 制約付きモデルの決定係数
- ※  $R_{UR}^2$  と  $R_R^2$  はどちらも、自由度を「修正していない」決定係数。

(証明)

$$TSS = \sum_{i=1}^n (y_i - \bar{y})^2$$

とすると、決定係数の定義より、

$$R_R^2 = 1 - \frac{Q_R}{TSS},$$

$$R_{UR}^2 = 1 - \frac{Q_{UR}}{TSS},$$

なので、

$$\frac{Q_R}{TSS} = 1 - R_R^2,$$

$$\frac{Q_{UR}}{TSS} = 1 - R_{UR}^2.$$

よって、

$$\begin{aligned}\frac{Q_R - Q_{UR}}{TSS} &= \frac{Q_R}{TSS} - \frac{Q_{UR}}{TSS} \\ &= (1 - R_R^2) - (1 - R_{UR}^2) \\ &= R_{UR}^2 - R_R^2.\end{aligned}$$

したがって、

$$\begin{aligned}F &= \frac{(Q_R - Q_{UR})/r}{Q_{UR}/(n - k - 1)} \\ &= \frac{\frac{Q_R - Q_{UR}}{TSS}/r}{\frac{Q_{UR}}{TSS}/(n - k - 1)} \\ &= \frac{(R_{UR}^2 - R_R^2)/r}{(1 - R_{UR}^2)/(n - k - 1)}. \text{ (証明終)}$$

- ▶ 大標本の場合、以下の検定統計量を用いて線形制約の検定を行うこともできる。

$$\chi^2 = (n - k - 1) \cdot \frac{Q_R - Q_{UR}}{Q_{UR}} \sim \chi^2(r),$$

$$\chi^2 = (n - k - 1) \cdot \frac{R_{UR}^2 - R_R^2}{1 - R_{UR}^2} \sim \chi^2(r).$$

(証明は省略)



カイニ乗検定をすればよい。

# gretl で複数の係数が 0 の $H_0$ を検定する方法

1. モデルを推定した後、結果ウィンドウの「検定」→「変数を取り除く」と操作.
2. 出てきたウィンドウ左側の変数リストの中から、 $H_0$ において係数を 0 にしたい説明変数を選び、2つの矢印のうち上の緑の右向きの矢印をクリック.
  - ▶ 右側のリストに、 $H_0$  が真であるという仮定の下で係数を 0 とする説明変数が追加される.
3. 「変数を減らしたモデルを推定する」をクリック.
4. 「OK」をクリック.

制約なしモデルを通常の最小二乗法で推定した場合、 $F$  検定が行われる.

# 線形制約の検定結果

gretl: モデル2

ファイル 編集(E) 検定(I) 保存(S) グラフ(G) 分析(A) LaTeX

モデル1についての検定:

帰無仮説: 以下の変数の回帰パラメータはゼロである  
exper, exper2

検定統計量:  $F(2, 4295) = 499.754$ , p値  $7.46163e-196$

変数を取り除くことにより、%d個（全0個の内）の情報量規準が改善しました

モデル 2: 最小二乗法(OLS), 観測: 1-4299

従属変数: lincome

	係数	標準誤差	t 値	p 値	
const	4.30955	0.100755	42.77	0.0000	***
yeduc	0.0707721	0.00720383	9.824	1.53e-022	***

---

Mean dependent var	5.290452	S.D. dependent var	0.895883
Sum squared resid	3373.823	回帰の標準誤差	0.886091
R-squared	0.021968	Adjusted R-squared	0.021740
F(1, 4297)	96.51560	P-value(F)	1.53e-22
Log-likelihood	-5579.116	Akaike criterion	11162.23
Schwarz criterion	11174.96	Hannan-Quinn	11166.73

- ▶ 検定統計量の実現値（検定統計値）は 499.754,  
 $p$  値は  $7.46163 \times 10^{-196}$ 
  - ➡ 仮に「exper と exper2 の係数がどちらも 0」だとすると、499.754 という検定統計値は  $7.46163 \times 10^{-196}$ , つまりほぼ 0% の確率 (1% を下回る確率) でしか出てこない.
  - ➡ 有意水準 1% で、「exper と exper2 の係数がどちらも 0」の  $H_0$  が棄却される (5% や 10% でも棄却される).
  - ➡ exper と exper2 の係数のうち少なくとも一方は 0 でないと判断される.



就業可能年数およびその 2 乗項をミンサー方程式に含めることには統計的にも意味がある.

# OLS 推定量の性質 (大標本の場合)

大標本の場合,

- ▶ 誤差項の (条件なし) 期待値は 0

$$E(\boldsymbol{u}) = \mathbf{0}.$$

- ▶ すべての説明変数と誤差項は無相関

$$\text{Cov}(x_{ji}, u_i) = 0, \quad j = 1, 2, \dots, k.$$

の仮定の下で, 重回帰モデルの OLS 推定量  $\hat{\beta}$  は一致性をもつ.

$$\operatorname{plim}_{n \rightarrow \infty} \hat{\beta} = \beta.$$

→ 標本サイズが十分に大きい (観測値数が十分に多い) とき, 重回帰モデルの偏回帰係数の OLS 推定量は真の偏回帰係数に確率収束する. (証明は省略)

前スライドの 2 つの仮定に加え、

- ▶ 任意の  $i$  について、すべての説明変数を所与とした誤差項の条件付き分散は一定

$$V(u_i \mid X) = \sigma^2 \quad \text{for all } i.$$

の仮定の下で、重回帰モデルの OLS 推定量  $\hat{\beta}$  は漸近正規性をもつ。

$$\hat{\beta} \stackrel{a}{\sim} N\left(\beta, \frac{\sigma^2}{n} M_{XX}^{-1}\right).$$

- ▶  $M_{XX}^{-1} = \operatorname{plim}_{n \rightarrow \infty} \left( \frac{1}{n} X' X \right)^{-1}$ .

⇒ 標本サイズが十分に大きい（観測値数が十分に多い）とき、重回帰モデルの偏回帰係数の OLS 推定量は近似的に正規分布に従う。（証明は省略）

# 今日のキーワード

標準誤差,  $p$  値

# 次回までの準備

- ▶ 今回の講義スライドを読み直す.
- ▶ 「提出課題 5」に取り組む.
- ▶ 教科書第 7 章第 1 節～第 3 節の「例 7.3：教育の収益率の男女差をチョウ検定で調べる」までを読む.