

# 中級統計学：後期定期試験

村澤 康友

2021年1月26日

注意：3問とも解答すること。結果より思考過程を重視するので、途中計算等も必ず書くこと（部分点は大きいに与えるが、結果のみの解答は0点とする）。教科書のみ参照してよい（他の講義資料・ノートは持込不可）。

- (20点) 以下の用語の定義を式または言葉で書きなさい（各20字程度）。
  - 帰無仮説
  - 有意水準
  - 通常の最小2乗法 (OLS)
  - ダミー変数
- (30点) ゴルトンは身長を研究した。両親の平均身長と成人した子供の身長（女性の身長は1.08倍して男性に換算）の無作為標本を  $((x_1, y_1), \dots, (x_n, y_n))$  とする（単位はインチ）。 $\ln y_i$  の  $\ln x_i$  上への古典的正規単回帰モデルは

$$\ln y_i | \ln x_i \sim N(\alpha + \beta \ln x_i, \sigma^2)$$

$\beta < 1$  となる現象を「平均への回帰」という。回帰分析の結果は次の通りであった。

$$\widehat{\ln \text{child}} = 1.49881 + 0.644298 \ln \text{parent}$$

(0.17499)      (0.041431)

$$T = 928 \quad \bar{R}^2 = 0.2062 \quad F(1, 926) = 241.84 \quad \hat{\sigma} = 0.033050$$

(丸括弧内は標準誤差)

- 「子供の身長」の「両親の平均身長」に対する弾力性の OLS 推定値・標準誤差・t 値は幾らか？
  - 「平均への回帰」の有無の検定問題を定式化しなさい。
  - 「平均への回帰」の有無の検定統計量の値を求め、有意水準5%の検定を実行しなさい。
- (50点) Go To トラベル事業の2020年8月末までの利用者と非利用者で、9月末までに発熱症状があった人の割合を  $p_X, p_Y$  とする。 $p_X$  と  $p_Y$  を比較したい。独立に抽出した大きさ  $n_X, n_Y$  の無作為標本で、発熱症状があった人の割合を  $\hat{p}_X, \hat{p}_Y$  とする。
    - 検定問題を定式化しなさい（問題意識を踏まえること）。
    - 2項母集団  $\text{Bin}(1, p_X), \text{Bin}(1, p_Y)$  の平均と分散を求めなさい。
    - $\hat{p}_X, \hat{p}_Y, \hat{p}_X - \hat{p}_Y$  の漸近分布を求めなさい。
    - 検定統計量を定義し、その  $H_0$  の下での分布から有意水準5%の検定の棄却域を定めなさい。
    - $n_X = 2500, n_Y = 6400, \hat{p}_X = .05, \hat{p}_Y = .04$  として検定統計量の値と漸近 p 値を求め、有意水準5%の検定を実行しなさい。

※数値例はフィクションです。この分析は Go To トラベル事業と発熱症状の相関関係の検証であり、結果を因果関係と解釈するのは誤りです。

解答例

1. 統計学の基本用語

- (a) とりあえず真と想定する仮説.
- (b) 許容する第 1 種の誤りの確率.
- (c) 残差 2 乗和を最小にするように回帰係数を定める方法.
- (d) あるカテゴリーに入るなら 1, 入らないなら 0 とした変数.
  - 0 か 1 をとる変数に変換するのがポイントなので, 「0 か 1 をとる変数」のみは 1 点減.

2. 単回帰分析

- (a) OLS 推定値は.644298, 標準誤差は.0414309, t 値は.644298/.0414309=15.55.

- OLS 推定値と標準誤差は各 3 点, t 値は 4 点.
- t 値 = OLS 推定値 / 標準誤差としていれば OK.

- (b)

$$H_0 : \beta = 1 \ (\alpha, \sigma^2 \text{ は任意}) \quad \text{vs} \quad H_1 : \beta < 1 \ (\alpha, \sigma^2 \text{ は任意})$$

- (c) 検定統計量は

$$\begin{aligned} t &:= \frac{b - 1}{s} \\ &= \frac{.644298 - 1}{.0414309} \\ &\approx -8.5854 \end{aligned}$$

$H_0$  の下で  $t \sim t(926)$  より (近似的な) 棄却域は  $(-\infty, -1.645]$ . 検定統計量が棄却域に入るので,  $H_0$  を棄却して  $H_1$  を採択. すなわち「平均への回帰」は存在する.

- 検定統計量で 5 点, 棄却域で 5 点.

3. 母比率の差の検定

- (a)

$$H_0 : p_X = p_Y \quad \text{vs} \quad H_1 : p_X > p_Y$$

- 両側検定は 2 点.

- (b)  $\text{Bin}(1, p_X)$  の平均は

$$1 \cdot p_X + 0 \cdot (1 - p_X) = p_X$$

分散は

$$\begin{aligned} (1 - p_X)^2 \cdot p_X + (0 - p_X)^2 \cdot (1 - p_X) &= (1 - p_X)^2 p_X + p_X^2 (1 - p_X) \\ &= p_X (1 - p_X) \end{aligned}$$

$\text{Bin}(1, p_Y)$  についても同様.

- (c)

$$\begin{aligned} \hat{p}_X &\stackrel{a}{\sim} N\left(p_X, \frac{p_X(1 - p_X)}{n_X}\right) \\ \hat{p}_Y &\stackrel{a}{\sim} N\left(p_Y, \frac{p_Y(1 - p_Y)}{n_Y}\right) \\ \hat{p}_X - \hat{p}_Y &\stackrel{a}{\sim} N\left(p_X - p_Y, \frac{p_X(1 - p_X)}{n_X} + \frac{p_Y(1 - p_Y)}{n_Y}\right) \end{aligned}$$

- $\hat{p}_X, \hat{p}_Y$  は各 3 点,  $\hat{p}_X - \hat{p}_Y$  は 4 点.

(d) 標準化すると

$$\frac{\hat{p}_X - \hat{p}_Y - (p_X - p_Y)}{\sqrt{p_X(1-p_X)/n_X + p_Y(1-p_Y)/n_Y}} \stackrel{a}{\sim} N(0, 1)$$

検定統計量は

$$Z := \frac{\hat{p}_X - \hat{p}_Y}{\sqrt{\hat{p}_X(1-\hat{p}_X)/n_X + \hat{p}_Y(1-\hat{p}_Y)/n_Y}}$$

棄却域は  $[1.645, \infty]$ .

- 検定統計量で 5 点, 棄却域で 5 点.

(e)

$$\begin{aligned} \frac{\hat{p}_X(1-\hat{p}_X)}{n_X} &= \frac{(1/20)(1-1/20)}{2500} \\ &= \frac{(1/20)(19/20)}{50^2} \\ &= \frac{19}{1000^2} \\ \frac{\hat{p}_Y(1-\hat{p}_Y)}{n_Y} &= \frac{(1/25)(1-1/25)}{6400} \\ &= \frac{(1/25)(24/25)}{80^2} \\ &= \frac{24}{25^2 80^2} \\ &= \frac{6}{25^2 40^2} \\ &= \frac{6}{1000^2} \end{aligned}$$

したがって

$$\begin{aligned} \frac{\hat{p}_X(1-\hat{p}_X)}{n_X} + \frac{\hat{p}_Y(1-\hat{p}_Y)}{n_Y} &= \frac{19}{1000^2} + \frac{6}{1000^2} \\ &= \frac{25}{1000^2} \end{aligned}$$

すなわち

$$\begin{aligned} \sqrt{\frac{\hat{p}_X(1-\hat{p}_X)}{n_X} + \frac{\hat{p}_Y(1-\hat{p}_Y)}{n_Y}} &= \frac{5}{1000} \\ &= \frac{1}{200} \end{aligned}$$

検定統計量は

$$\begin{aligned} Z &:= \frac{.05 - .04}{1/200} \\ &= 2 \end{aligned}$$

漸近 p 値は .02275. したがって有意水準 5% で  $H_0$  を棄却する.

- 検定統計量と p 値は各 4 点, 検定は 2 点.