

第 13 章の答え



練習問題 1

$\beta > 0$ としよう。下図(a)では、真の関係($\alpha + \beta X$)を実線、回帰直線(当てはまりの良い線)を点線で表した。このとき、測定誤差 e_i が大きくなると、説明変数 X_i は大きくなる一方、誤差項 $u_i = u_i^* - \beta e_i$ は小さくなる。つまり、 X_i と u_i に負の相関が生じる。 X_i と u_i に負の相関があるため、 X_i が大きいと、 u_i は小さく(負の値をとる)なり、観測点は実線の下で観察される。逆に、 X_i が小さいと、 u_i は大きく(正の値をとる)なり、観測点は実線の上で観察される。このため、回帰直線は傾きがゆるやかになる傾向がある(β の推定量は負のバイアスを持つ)。

逆に、 $\beta < 0$ としよう(下図(b)参照)。このとき、測定誤差 e_i が大きくなると、説明変数 X_i と誤差項 $u_i = u_i^* - \beta e_i$ はともに大きくなる。つまり、 X_i と u_i に正の相関がある。ここで X_i と u_i に正の相関があるため、 X_i が大きいと、 u_i は大きく(正の値をとる)なり、観測点は実線の上で観察される。逆に、 X_i が小さいと、 u_i は小さく(負の値をとる)なり、観測点は実線の下で観察される。このため、 β の推定量は正のバイアスを持つ。

これまでの結果をまとめると、 $\beta > 0$ なら負のバイアス($\hat{\beta} < \beta$)、 $\beta < 0$ なら正のバイアス($\hat{\beta} > \beta$)であり、係数は 0 方向へバイアスがあるといえる。

図：内生性とバイアスの関係

(a) $\beta > 0$ の場合(b) $\beta < 0$ の場合

なお、図をみると、内生性があると、OLS 推定では係数 $\hat{\beta}$ だけでなく、定数項 $\hat{\alpha}$ にもバイアスが生じていることがわかる。この結果は重回帰分析においても当てはまる。つまり、説明変数のうち 1 つでも内生性があれば、OLS 推定

では、すべての係数や定数項にバイアスが生じるといえる。大事な点なので覚えておいて欲しい。

練習問題 2

$Y_i = Y_i^* + e_i$ を書き換えると、 $Y_i^* = Y_i - e_i$ となる。これを、 $Y_i^* = \alpha + \beta X_i + u_i^*$ の式に代入すると、

$$Y_i - e_i = \alpha + \beta X_i + u_i^*$$

となり、さらに書き換えると、

$$Y_i = \alpha + \beta X_i + (u_i^* + e_i)$$

となる。新しい誤差項を $u_i = u_i^* + e_i$ と定義すると、 Y_i と X_i には次の関係がある。

$$Y_i = \alpha + \beta X_i + u_i$$

仮定から、説明変数 X_i は、 u_i^* や e_i と無相関である。したがって、 X_i は新しい誤差項 $u_i = u_i^* + e_i$ と無相関であり、内生性の問題は生じない¹。このため、OLS 推定量を用いても、係数 β の推定にバイアスは生じない。

練習問題 3

このモデルを次のように書き換える。

$$Y_i = \alpha + \beta X_i + u_i^*$$

$$u_i^* = \gamma W_i + u_i$$

ただし、 X_i は内生変数であり、元の式における誤差項 u_i と相関している。

(a) Z_i と W_i が無相関ならば、操作変数 Z_i と誤差項 $u_i^* = \gamma W_i + u_i$ は無相関となり、欠落変数がある状況であっても、 Z_i は「操作変数の条件②(操作変数の外生性)」を満たす。このため、2SLS にバイアスは生じない。

(b) Z_i と W_i が相関するならば、操作変数 Z_i と誤差項 $u_i^* = \gamma W_i + u_i$ は相関するため、欠落変数がある状況では、 Z_i は「操作変数の条件②(操作変数の外生性)」を満たさない。このため、2SLS にバイアスが生じる。

¹ 仮に測定誤差 e_i が説明変数 X_i と相関していれば、OLS 推定量は一致性を持たない。通常、この練習問題と同様、測定誤差 e_i は説明変数と無相関と仮定される。

練習問題 4

第 1 段階では、次の式を推定する。

$$X_i = \gamma_0 + \gamma_1 Z_{1i} + \gamma_2 Z_{2i} + \gamma_3 W_{1i} + \gamma_4 W_{2i} + e_i$$

操作変数の条件①は、仮説を次のようにした F 検定によって確認できる。

$$H_0: \gamma_1 = 0, \quad \gamma_2 = 0$$

H_1 : 帰無仮説 H_0 が誤りである

F 値が 10 を下回ると操作変数の条件①が満たされない可能性がある。

練習問題 5

操作変数としては、ルームメートがランダムに決まっていることを利用すればよい。たとえば、操作変数 Z_i を、ルームメートがゲーム機を持ち込んだら 1、持ち込まなかったら 0 となるダミー変数としよう²。部屋の割り振りはランダムであるため、操作変数 Z_i は誤差項 u_i と無相関となる。また、ゲーム機が持ち込まれると勉強時間は減るため、 Z_i と X_i は相関するだろう。

練習問題 6

(a) 誤差項は $u_t = \rho u_{t-1} + \varepsilon_t$ となるため、 u_{t-1} が変化すると u_t が変化する。また、 $t-1$ 期には、次の関係があるため、 u_{t-1} が変化すると Y_{t-1} も変化する。

$$Y_{t-1} = \alpha + \beta Y_{t-2} + \gamma W_{t-1} + u_{t-1}$$

以上から、 u_t と Y_{t-1} は相関しており、内生性の問題が生じる。

(b) $t-1$ 期には、 $Y_{t-1} = \alpha + \beta Y_{t-2} + \gamma W_{t-1} + u_{t-1}$ が成立するため、

$$\begin{aligned} Y_t - \rho Y_{t-1} &= (\alpha + \beta Y_{t-1} + \gamma W_t + u_t) - \rho(\alpha + \beta Y_{t-2} + \gamma W_{t-1} + u_{t-1}) \\ &= \alpha(1 - \rho) + \beta Y_{t-1} - \rho\beta Y_{t-2} + \gamma W_t - \rho\gamma W_{t-1} + (u_t - \rho u_{t-1}) \end{aligned}$$

となる。ここで、 $\varepsilon_t = u_t - \rho u_{t-1}$ であり、左辺の ρY_{t-1} を右辺に移項させると、

$$Y_t = \alpha(1 - \rho) + (\rho + \beta)Y_{t-1} - \rho\beta Y_{t-2} + \gamma W_t - \rho\gamma W_{t-1} + \varepsilon_t$$

となる。右辺にある説明変数は Y_{t-1} 、 Y_{t-2} 、 W_t 、 W_{t-1} であり、モデルは

$$Y_t = \alpha^* + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \beta_3 W_t + \beta_4 W_{t-1} + \varepsilon_t$$

² この操作変数に関心がある方は、以下の論文を参照されたい。Stinebrickner, Ralph Stinebrickner and Todd R. Stinebrickner. (2008) "The Causal Effect of Studying on Academic Performance," *The B.E. Journal of Economic Analysis and Policy*, 8(1) (Frontiers), Article 14, 1-53.

と表せる。ただし、パラメータは次のように定義される。

$$\alpha^* = \alpha(1 - \rho), \beta_1 = \rho + \beta, \beta_2 = -\rho\beta, \beta_3 = \gamma, \beta_4 = -\rho\gamma$$

ここで、誤差項は $\varepsilon_t \sim i.i.d.N(0, \sigma^2)$ であるから、誤差項 ε_t は全ての説明変数と無相関になる。

練習問題 7

2SLS の第 1 段階では、被説明変数を X とし、説明変数を Z とした OLS 推定をする。そして、 X の予測値を $\hat{X}_i = \hat{\gamma}_0 + \hat{\gamma}_1 Z_i$ とする。ただし、 $\hat{\gamma}_1$ は、次のようになる (2.3.1 節参照)。

$$\hat{\gamma}_1 = \frac{\sum_{i=1}^n (Z_i - \bar{Z})(X_i - \bar{X})}{\sum_{i=1}^n (Z_i - \bar{Z})^2}$$

2SLS の第 2 段階では、被説明変数を Y_i とし説明変数を \hat{X}_i とした OLS 推定することで、係数 β を推定する。このとき、2SLS 推定量 $\hat{\beta}_{2SLS}$ は次のようになる。

$$\hat{\beta}_{2SLS} = \frac{\sum_{i=1}^n (\hat{X}_i - \bar{\hat{X}})(Y_i - \bar{Y})}{\sum_{i=1}^n (\hat{X}_i - \bar{\hat{X}})^2}$$

ただし、 $\bar{\hat{X}}$ は、 $\hat{X}_i = \hat{\gamma}_0 + \hat{\gamma}_1 Z_i$ の標本平均、つまり、

$$\bar{\hat{X}} = \frac{1}{n} \sum_{i=1}^n \hat{X}_i = \frac{1}{n} \sum_{i=1}^n (\hat{\gamma}_0 + \hat{\gamma}_1 Z_i) = \hat{\gamma}_0 + \hat{\gamma}_1 \bar{Z}$$

となる。よって、偏差 $\hat{X}_i - \bar{\hat{X}}$ は次のようになる。

$$\hat{X}_i - \bar{\hat{X}} = (\hat{\gamma}_0 + \hat{\gamma}_1 Z_i) - (\hat{\gamma}_0 + \hat{\gamma}_1 \bar{Z}) = \hat{\gamma}_1 (Z_i - \bar{Z})$$

ここで、 $\hat{\beta}_{2SLS}$ の式に、 $\hat{X}_i - \bar{\hat{X}} = \hat{\gamma}_1 (Z_i - \bar{Z})$ を代入すると、次のようになる。

$$\hat{\beta}_{2SLS} = \frac{\sum_{i=1}^n (\hat{X}_i - \bar{\hat{X}})(Y_i - \bar{Y})}{\sum_{i=1}^n (\hat{X}_i - \bar{\hat{X}})^2} = \frac{\sum_{i=1}^n \hat{\gamma}_1 (Z_i - \bar{Z})(Y_i - \bar{Y})}{\sum_{i=1}^n \hat{\gamma}_1^2 (Z_i - \bar{Z})^2} = \frac{1}{\hat{\gamma}_1} \frac{\sum_{i=1}^n (Z_i - \bar{Z})(Y_i - \bar{Y})}{\sum_{i=1}^n (Z_i - \bar{Z})^2}$$

さらに、 $\hat{\gamma}_1 = \sum_{i=1}^n (Z_i - \bar{Z})(X_i - \bar{X}) / \sum_{i=1}^n (Z_i - \bar{Z})^2$ を代入すると、

$$\hat{\beta}_{2SLS} = \left\{ \frac{\sum_{i=1}^n (Z_i - \bar{Z})^2}{\sum_{i=1}^n (Z_i - \bar{Z})(X_i - \bar{X})} \right\} \frac{\sum_{i=1}^n (Z_i - \bar{Z})(Y_i - \bar{Y})}{\sum_{i=1}^n (Z_i - \bar{Z})^2} = \frac{\sum_{i=1}^n (Z_i - \bar{Z})(Y_i - \bar{Y})}{\sum_{i=1}^n (Z_i - \bar{Z})(X_i - \bar{X})}$$

最後に、偏差の和が 0 という性質 ($\sum_{i=1}^n (Y_i - \bar{Y}) = 0$, $\sum_{i=1}^n (X_i - \bar{X}) = 0$) を用いると、2SLS 推定量 $\hat{\beta}_{2SLS}$ は、次のようになる。

$$\hat{\beta}_{2SLS} = \frac{\sum_{i=1}^n (Z_i - \bar{Z})(Y_i - \bar{Y})}{\sum_{i=1}^n (Z_i - \bar{Z})(X_i - \bar{X})} = \frac{\sum_{i=1}^n Z_i (Y_i - \bar{Y}) - \bar{Z} \sum_{i=1}^n (Y_i - \bar{Y})}{\sum_{i=1}^n Z_i (X_i - \bar{X}) - \bar{Z} \sum_{i=1}^n (X_i - \bar{X})} = \frac{\sum_{i=1}^n Z_i (Y_i - \bar{Y})}{\sum_{i=1}^n Z_i (X_i - \bar{X})}$$

練習問題 8

練習問題 7 の結果から、2SLS 推定量 $\hat{\beta}_{2SLS}$ は、

$$\hat{\beta}_{2SLS} = \frac{\sum_{i=1}^n Z_i(Y_i - \bar{Y})}{\sum_{i=1}^n Z_i(X_i - \bar{X})}$$

となる。ここでは、分子と分母の別表現を、それぞれ求める。

分子の別表現： 分子は、次のように表現できる

$$\sum_{i=1}^n Z_i(Y_i - \bar{Y}) = \left(1 - \frac{n_1}{n}\right) n_1(\bar{Y}_1 - \bar{Y}_0)$$

ただし、 \bar{Y}_1 は $Z_i = 1$ のときの Y の平均、 \bar{Y}_0 は $Z_i = 0$ のときの Y の平均となる。

$$\bar{Y}_1 = \frac{1}{n_1} \sum_{i=1}^{n_1} Y_i \qquad \bar{Y}_0 = \frac{1}{n - n_1} \sum_{i=n_1+1}^n Y_i$$

[証明] この別表現が正しいことを確認しよう。分子は、

$$\sum_{i=1}^n Z_i(Y_i - \bar{Y}) = \sum_{i=1}^{n_1} Z_i(Y_i - \bar{Y}) + \underbrace{\sum_{i=n_1+1}^n Z_i(Y_i - \bar{Y})}_{=0} = \sum_{i=1}^{n_1} (Y_i - \bar{Y})$$

となる。式展開では、 $i = 1, 2, \dots, n_1$ なら $Z_i = 1$ 、 $i = n_1 + 1, n_1 + 2, \dots, n$ なら $Z_i = 0$ となることを用いた。さらに右辺は次のようになる。

$$\sum_{i=1}^{n_1} (Y_i - \bar{Y}) = \sum_{i=1}^{n_1} Y_i - n_1 \bar{Y} = n_1 \bar{Y}_1 - n_1 \bar{Y}$$

ここで、標本平均 \bar{Y} は次のように分解できる。

$$\bar{Y} = \frac{1}{n} \left(\sum_{i=1}^{n_1} Y_i + \sum_{i=n_1+1}^n Y_i \right) = \frac{1}{n} (n_1 \bar{Y}_1 + (n - n_1) \bar{Y}_0)$$

この式を、 $\sum_{i=1}^{n_1} (Y_i - \bar{Y}) = n_1 \bar{Y}_1 - n_1 \bar{Y}$ の式に代入すると、

$$\begin{aligned} \sum_{i=1}^{n_1} (Y_i - \bar{Y}) &= n_1 \bar{Y}_1 - n_1 \left\{ \frac{1}{n} (n_1 \bar{Y}_1 + (n - n_1) \bar{Y}_0) \right\} \\ &= n_1 \bar{Y}_1 - \frac{n_1}{n} n_1 \bar{Y}_1 - \left(1 - \frac{n_1}{n}\right) n_1 \bar{Y}_0 \\ &= \left(1 - \frac{n_1}{n}\right) n_1 \bar{Y}_1 - \left(1 - \frac{n_1}{n}\right) n_1 \bar{Y}_0 \\ &= \left(1 - \frac{n_1}{n}\right) n_1 (\bar{Y}_1 - \bar{Y}_0) \end{aligned}$$

分母の別表現：分母は、次のように表現できる。

$$\sum_{i=1}^n Z_i(X_i - \bar{X}) = \left(1 - \frac{n_1}{n}\right) n_1(\bar{X}_1 - \bar{X}_0)$$

ただし、 \bar{X}_1 は $Z_i = 1$ のときの X の平均、 \bar{X}_0 は $Z_i = 0$ のときの X の平均とする。

$$\bar{X}_1 = \frac{1}{n_1} \sum_{i=1}^{n_1} X_i \qquad \bar{X}_0 = \frac{1}{n - n_1} \sum_{i=n_1+1}^n X_i$$

[証明] この別表現が正しいことを確認しよう。分母は、

$$\sum_{i=1}^n Z_i(X_i - \bar{X}) = \sum_{i=1}^{n_1} Z_i(X_i - \bar{X}) + \underbrace{\sum_{i=n_1+1}^n Z_i(X_i - \bar{X})}_{=0} = \sum_{i=1}^{n_1} (X_i - \bar{X})$$

となる。さらに右辺は、

$$\sum_{i=1}^{n_1} (X_i - \bar{X}) = n_1\bar{X}_1 - n_1\bar{X}$$

となり、これに

$$\bar{X} = \frac{1}{n} (n_1\bar{X}_1 + (n - n_1)\bar{X}_0)$$

を代入すると、分母は次のようになる。

$$\begin{aligned} \sum_{i=1}^{n_1} (X_i - \bar{X}) &= n_1\bar{X}_1 - n_1 \left\{ \frac{1}{n} (n_1\bar{X}_1 + (n - n_1)\bar{X}_0) \right\} \\ &= \left(1 - \frac{n_1}{n}\right) n_1(\bar{X}_1 - \bar{X}_0) \end{aligned}$$

分子と分母の別表現を代入する：

$$\hat{\beta}_{2SLS} = \frac{\sum_{i=1}^n Z_i(Y_i - \bar{Y})}{\sum_{i=1}^n Z_i(X_i - \bar{X})} = \frac{\left(1 - \frac{n_1}{n}\right) n_1(\bar{Y}_1 - \bar{Y}_0)}{\left(1 - \frac{n_1}{n}\right) n_1(\bar{X}_1 - \bar{X}_0)} = \frac{\bar{Y}_1 - \bar{Y}_0}{\bar{X}_1 - \bar{X}_0}$$

上式の意味を考えよう。まず、 \bar{X}_0 は $Z_i = 0$ のときの X の平均、 \bar{X}_1 は $Z_i = 1$ のときの X の平均であるため、分母は「 Z が 0 から 1 に変化したとき、 X の平均がどれぐらい変化したか」を表す。同様に、分子は、「 Z が 0 から 1 に変化したとき、 Y の平均がどれぐらい変化したか」を表す。まとめると、2SLS 推定量 $\hat{\beta}_{2SLS}$ は次のように解釈できる。

$$\hat{\beta}_{2SLS} = \frac{Z \text{が変化したときの} Y \text{の平均の変化}}{Z \text{が変化したときの} X \text{の平均の変化}}$$

練習問題 9、10

ウェブサイトにデータと再現に必要なコードが掲載されている。

こちらは初版(第1刷)には掲載されていない新しい問題になります。

練習問題 11、12、13

練習問題 11★ 内生性の有無を検証する方法を述べよ。Hint: ハウスマン検定

練習問題 12 ★ 効果の異質性を考慮したモデル $Y_i = \alpha_i + \beta_i X_i + u_i$ を考えよう。

(a) X_i に内生性の問題はないとし、パラメータ (α_i, β_i) は X_i と独立な確率変数としよう。 n が大きくなると、OLS 推定量 $\hat{\beta}$ は $E[\beta_i]$ に収束することを示せ。Hint: n が大きくなると、標本分散と標本共分散は、それぞれ分散と共分散に収束する(『入門 実践する統計学』(巻末参考文献[5])の 5.3 節参照)。

(b) X_i に内生性の問題があるとする。また、操作変数 Z_i に対する反応度にも異質性があるとしよう。

$$X_i = c_i + \gamma_i Z_i + e_i$$

ここで、 Z_i はダミー変数とし、パラメータ $(\alpha_i, \beta_i, c_i, \gamma_i)$ は Z_i と独立な確率変数とする。 n が大きくなると、2段階最小乗推定量 $\hat{\beta}_{2SLS}$ は次の値に収束することを示せ。

$$\frac{E[\gamma_i \beta_i]}{E[\gamma_i]}$$

また、この式が何を意味しているかを述べよ。

Hint: n が大きくなると、平均は期待値に収束する(『入門 実践する統計学』(巻末参考文献[5])の 5.2 節参照)。このため、推定量 $\hat{\beta}_{2SLS}$ は次式で表せる(練習問題 8 参照)。

$$\frac{E[Y_i|Z_i = 1] - E[Y_i|Z_i = 0]}{E[X_i|Z_i = 1] - E[X_i|Z_i = 0]}$$

なお、 $E[Y_i|Z_i = 1]$ は $Z_i = 1$ のときの Y_i の期待値、 $E[Y_i|Z_i = 0]$ は $Z_i = 0$ のときの Y_i の期待値である(X_i の期待値も同様に定義される)。

練習問題 13 ★ パネル分析において、次のモデルを考える。

$$Y_{i,t} = \alpha + \beta X_{i,t} + \theta W_i + Z_i + u_{i,t}$$

このとき、個別要因 Z_i を考慮しながら、パラメータ(β, θ)を推定したい。ここで、誤差項は $Z_i + u_{i,t}$ としよう。なお、 $X_{i,t}$ と W_i は $u_{i,t}$ と無相関とし、 Z_i は $X_{i,t}$ と相関するが W_i とは無相関とする(つまり、 W_i は外生変数だが、 $X_{i,t}$ は内生変数となる)。パラメータを推定する方法を述べよ。Hint: 操作変数を用いた 2 段階最小 2 乗法を用いる。

練習問題 11、12、13 の答え

練習問題 11 の答え

OLS 推定量は、説明変数に内生性がなければ一致性は満たされる一方、内生性があれば一致性は満たされない。これに対し、2SLS 推定量は、内生性の有無に関係なく一致性を満たす。教科書では、OLS 推定量と 2SLS 推定量の結果を比較することで、OLS 推定量に、どれぐらいのバイアスが生じているかを確認した(例 13-2、例 13-3 参照)。これは 2 つの推定結果の差が小さければ、内生性は生じていない可能性を示唆している。以下では、これを厳密に行うハウスマン検定(Hausman test)を紹介する(11 章では、ハウスマン検定をモデル選択に用いた)³。

³ 同じ検定を、コントロール関数を用いて行うこともできる。モデルは $Y_i = \alpha + \beta X_i + u_i$ 、 $X_i = \gamma_0 + \gamma_1 Z_i + e_i$ としよう。操作変数の条件②によって、 Z_i は u_i と無相関となる。内生性の有無は、 u_i と e_i が相関しているかで判断される。 u_i と e_i が相関したら(関係式 $X_i = \gamma_0 + \gamma_1 Z_i + e_i$ から)、 u_i と X_i も相関する(内生性あり)。これを確認するため、 $u_i = \theta e_i + \varepsilon_i$ と定義しよう($\theta = E[u_i e_i] / E[e_i^2]$ とする)。 u_i は、 X_i と相関する部分(θe_i)、相関しない部分(ε_i)に分解される。 $\theta \neq 0$ なら内生性あり、 $\theta = 0$ なら内生性なしとなる。コントロール関数は、 Y_i の式に $u_i = \theta e_i + \varepsilon_i$ を代入することで、

$$Y_i = \alpha + \beta X_i + \theta e_i + \varepsilon_i$$

と定義される。なお、 e_i と ε_i は無相関となる(これは $\theta = E[u_i e_i] / E[e_i^2]$ に注意すると、 $E[e_i \varepsilon_i] = E[e_i(u_i -$

この検定では、仮説を次のように設定する。

帰無仮説 H_0 : 説明変数に内生性が存在しない

対立仮説 H_1 : 説明変数に内生性が存在する

帰無仮説が正しいもとで、OLS 推定量と 2SLS 推定量の差は 0 に近い値をとる。

$$\text{OLS 推定量} - \text{2SLS 推定量} \approx 0$$

しかし、対立仮説が正しいもとで、この差は 0 から乖離するだろう。したがって、この差が十分に大きいとき、帰無仮説は棄却される。こうしたハウスマン検定は、Durbin-Wu-Hausman 検定、Wu-Hausman 検定とも呼ばれる⁴。

練習問題 12 の答え

(a) このモデルでは、定数項や係数は個人によって異なる。たとえば、賃金を Y_i 、教育年数を

を X_i としよう。教育の効果 β_i は、個人の属性(才能など)によって異なる可能性がある。こうした効果の異質性がある場合、OLS 推定量は

$$E[\beta_i]$$

となる。これは、OLS 推定量が平均効果であることを意味している。

OLS 推定量は $E[\beta_i]$ となることを確認しよう。 n が大きくなると、標本平均が期待値に収束するように、標本分散は分散に、標本共分散は共分散に収束する。このため、 n が大きくなると、OLS 推定量は次のようになる。

$\theta e_i] = E[u_i e_i] - \theta E[e_i^2] = 0$ と確認できる)。また、 X_i と ε_i も無相関である (ε_i は、 X_i と相関しない部分である)。ただし、 e_i は観察できないため、 $X_i = \gamma_0 + \gamma_1 Z_i + e_i$ を OLS 推定して得られた残差 \hat{e}_i を用いる。つまり、被説明変数を Y_i とし、説明変数を X_i と \hat{e}_i とした OLS 推定によって、パラメータをバイアスなく推定できる。内生性の有無は、帰無仮説 $H_0: \theta = 0$ 、対立仮説 $H_1: \theta \neq 0$ とした検定によって確認できる。

⁴ なお、 Y を被説明変数、 $X1$ を外生変数、 $X2$ を内生変数、 Z を操作変数とすると、Stata では、`ivregress 2sls Y X1 (X2=Z), r` の後に `estat endogenous` と入力することで、 F 検定の結果が **Robust regression F** として出力される。帰無仮説が採択されたら、内生性の問題が無かった(小さかった)ということで、棄却されたら、内生性の問題が生じている、と判断される。

$$\begin{aligned} \frac{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2} &\rightarrow \frac{\text{Cov}(Y_i, X_i)}{\text{Var}(X_i)} \\ &= \frac{\text{Cov}(\alpha_i + \beta_i X_i + u_i, X_i)}{\text{Var}(X_i)} \\ &= E[\beta_i] \end{aligned}$$

式展開では、 X_i は α_i 、 β_i 、 u_i とは独立であるため、

$$\text{Cov}(\alpha_i + \beta_i X_i + u_i, X_i) = E[\beta_i] \text{Var}(X_i)$$

となることを用いた⁵。

(b) この問題では、効果の異質性が考慮されており、パラメータはすべて i によって異なる。

$$Y_i = \alpha_i + \beta_i X_i + u_i$$

$$X_i = c_i + \gamma_i Z_i + e_i,$$

$X_i = c_i + \gamma_i Z_i + e_i$ から、 $Z_i = 1$ なら $X_i = c_i + \gamma_i + e_i$ となり、 $Z_i = 0$ なら $X_i = c_i + e_i$ となる。よって、 X_i の期待値は、それぞれ次のようになる⁶。

$$E[X_i | Z_i = 1] = E[c_i] + E[\gamma_i]$$

$$E[X_i | Z_i = 0] = E[c_i]$$

また、 $X_i = c_i + \gamma_i Z_i + e_i$ を代入すると、 Y_i は次式となる。

$$Y_i = \alpha_i + \beta_i(c_i + \gamma_i Z_i + e_i) + u_i$$

$$= \alpha_i + \beta_i c_i + \beta_i \gamma_i Z_i + u_i + \beta_i e_i$$

つまり、 $Z_i = 1$ なら $Y_i = \alpha_i + \beta_i c_i + \beta_i \gamma_i + u_i + \beta_i e_i$ となり、 $Z_i = 0$ なら $Y_i = \alpha_i + \beta_i c_i + u_i + \beta_i e_i$ となる。よって、期待値はそれぞれ次のようになる。

$$E[Y_i | Z_i = 1] = E[\alpha_i] + E[\beta_i c_i] + E[\beta_i \gamma_i]$$

$$E[Y_i | Z_i = 0] = E[\alpha_i] + E[\beta_i c_i]$$

以上から、サンプルサイズが大きいとき、2SLS 推定量は

$$\frac{E[Y_i | Z_i = 1] - E[Y_i | Z_i = 0]}{E[X_i | Z_i = 1] - E[X_i | Z_i = 0]} = \frac{(E[\alpha_i] + E[\beta_i c_i] + E[\beta_i \gamma_i]) - (E[\alpha_i] + E[\beta_i c_i])}{(E[c_i] + E[\gamma_i]) - (E[c_i])} = \frac{E[\beta_i \gamma_i]}{E[\gamma_i]}$$

⁵
$$\begin{aligned} \text{Cov}(\alpha_i + \beta_i X_i + u_i, X_i) &= E[(\alpha_i + \beta_i X_i + u_i - E[\alpha_i + \beta_i X_i + u_i])(X_i - E[X_i])] \\ &= E[(\alpha_i - E[\alpha_i])(X_i - E[X_i])] + E[(\beta_i X_i - E[\beta_i X_i])(X_i - E[X_i])] + E[(u_i - E[u_i])(X_i - E[X_i])] \\ &= E[(\beta_i X_i - E[\beta_i X_i])(X_i - E[X_i])] \\ &= E[\beta_i X_i (X_i - E[X_i])] - E[\beta_i X_i] E[(X_i - E[X_i])] \\ &= E[\beta_i X_i (X_i - E[X_i])] \\ &= E[\beta_i] E[X_i (X_i - E[X_i])] \\ &= E[\beta_i] \text{Var}(X_i) \end{aligned}$$

式展開では、 X_i と β_i が独立であるため、 $E[\beta_i X_i (X_i - E[X_i])] = E[\beta_i] E[X_i (X_i - E[X_i])]$ とした。

⁶ パラメータ $(\alpha_i, \beta_i, c_i, \gamma_i)$ は Z_i と独立であるため、 $E[c_i | Z_i = 1] = E[c_i]$ 、 $E[\gamma_i | Z_i = 1] = E[\gamma_i]$ となる。

として表現できる。

この式の意味を考えてみよう。まず、効果の異質性がないとしよう(つまり、 β_i は固定した値 β をとる($\beta_i = \beta$)。このとき、 β_i は固定した値 β であるから、

$$\frac{E[\gamma_i \beta_i]}{E[\gamma_i]} = \frac{\beta E[\gamma_i]}{E[\gamma_i]} = \beta$$

となり、 $\hat{\beta}_{2SLS}$ は係数 β を正しく推定できる⁷。

次に、効果の異質性がある状況を考える。ここで、確率変数 γ_i には n 通りの可能性があり、それぞれ $1/n$ の確率で生じるとしよう。このとき、次式が成立する。

$$E[\gamma_i] = \frac{1}{n} \sum_{i=1}^n \gamma_i = \bar{\gamma}$$

$$E[\gamma_i \beta_i] = \frac{1}{n} \sum_{i=1}^n \gamma_i \beta_i$$

したがって、 $\hat{\beta}_{2SLS}$ は次式となる。

$$\frac{E[\gamma_i \beta_i]}{E[\gamma_i]} = \frac{1}{n} \sum_{i=1}^n \frac{\gamma_i}{\bar{\gamma}} \beta_i$$

これは、係数 β_i を加重 $\gamma_i/\bar{\gamma}$ を用いて平均した加重平均値となる。加重は、操作変数に対する反応度 γ_i が大きいほど大きくなる。つまり、 $\hat{\beta}_{2SLS}$ は、遵守者(操作変数に対して強く反応する人)に対する平均効果といえる。

これは操作変数を変えると、 $\hat{\beta}_{2SLS}$ が変化する可能性を示唆している。操作変数が2つあるとき(Z_1, Z_2)、各操作変数に対する X_i の反応度 γ_i は異なるため、 $\hat{\beta}_{2SLS}$ は、どの操作変数を用いるかで値が異なるだろう。たとえば、教育年数 X_i が賃金 Y_i に与える影響に関心があるとしよう。操作変数 Z_1 は、女性進学希望者にランダムに割り当てられる奨学金のダミー変数とする(対象者なら1となり、非対象者なら0となる)。同様に、 Z_2 は男性進学希望者にランダムに割り当てられる奨学金のダミー変数とする。このとき、操作変数 Z_1 を用いた2SLS推定では、女性に対する教育の平均効果が推定される一方、操作変数 Z_2 を用いると、男性に

⁷ 操作変数に対する反応度が同じであると(γ_i は固定した値 γ である)、

$$\frac{E[\gamma_i \beta_i]}{E[\gamma_i]} = \frac{\gamma E[\beta_i]}{\gamma} = E[\beta_i]$$

となり、 $\hat{\beta}_{2SLS}$ は平均効果を推定することができる。

対する教育の平均効果が推定される。

練習問題 13 の答え

固定効果モデルは、説明変数と個別効果の相関を許容したが、時間を通じて一定の変数はすべて個別効果に含まれ、その係数が推定できない問題がある。これに対し、変量効果モデルは、説明変数と個別効果は無相関と仮定しているが、時間を通じて一定の変数の係数が推定できるという利点がある。時間を通じて一定の変数に関心があるとき、固定効果モデルを用いることができない一方、変量効果モデルは非現実的な仮定を課しているため、その使用には問題がある。この練習問題では、個別効果を考慮しながら、時間を通じて一定の変数の係数を推定する方法であるテイラー=ハウスマン法を学習する。

11.2 節の(3)式では、 $Y_{i,t} = \alpha + \beta X_{i,t} + Z_i + u_{i,t}$ とした。これに時間を通じて一定の変数 W_i を加えると、練習問題で与えられた式となる。

$$Y_{i,t} = \alpha + \beta X_{i,t} + \theta W_i + Z_i + u_{i,t}$$

モデルの誤差項は、 $Z_i + u_{i,t}$ となる。説明変数($X_{i,t}$ 、 W_i)は $u_{i,t}$ と無相関である。また、個別効果を構成する Z_i は、固定効果と変量効果の間をとるものとする。具体的には、 Z_i は $X_{i,t}$ と相関するが、 Z_i は W_i とは無相関とする。

これらの仮定より、 W_i は外生変数であるが、 $X_{i,t}$ は内生変数となる。まず、 $X_{i,t}$ は Z_i と相関しているため、 $X_{i,t}$ から Z_i と相関している部分をすべて取り除く。具体的には、被説明変数を $X_{i,t}$ とし、説明変数を N 個のダミー変数($D1_i, D2_i, \dots, DN_i$)とした OLS 推定を行う(ダミー変数は 11.3.1 節参照)。得られた残差 $\hat{X}_{i,t}$ は、 $X_{i,t}$ と相関しているが、(個別要因が取り除かれているため) Z_i とは無相関となる。よって、操作変数を残差 $\hat{X}_{i,t}$ とした 2 段階最小 2 乗法を行うことで、パラメータ(β と θ)を推定することができる。