

と書き換えられる。

ただし,  $\lambda_i = \frac{1}{n} - \bar{X}\omega_i$  とする。

$\lambda_i$  は  $X$  の関数である。

例： $X$  に観測誤差 ( measurement error ) が含まれる場合： 真のモデルを

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

とする。  $(Y_i^*, X_i^*)$  は非確率変数とする。

しかし,  $(Y_i^*, X_i^*)$  は観測されず, 代わりに,  $(Y_i, X_i)$  が観測されるものとする。

$(Y_i^*, X_i^*)$  と  $(Y_i, X_i)$  との関係は以下の通りとする。

$$Y_i = Y_i^* + u_i, \quad X_i = X_i^* + v_i$$

$u_i, v_i$  は観測誤差と呼ばれるもので,

$$E(u_i) = 0, \quad V(u_i) = \sigma_u^2$$

$$E(v_i) = 0, \quad V(v_i) = \sigma_v^2$$

を仮定する。

さらに， $u_i, v_i$  は互いに独立と仮定する。

すなわち， $i \neq j$  となるすべての  $i, j$  について  $\text{Cov}(u_i, u_j) = \text{Cov}(v_i, v_j) = 0$ ，  
かつ，すべての  $i, j$  について  $\text{Cov}(u_i, v_j) = 0$  とする。

$Y_i^* = \alpha + \beta X_i^*$  に  $Y_i = Y_i^* + u_i$ ， $X_i = X_i^* + v_i$  を代入する。

$$Y_i = \alpha + \beta X_i + (u_i - \beta v_i)$$

観測されるのは  $(Y_i, X_i)$  なので， $(u_i - \beta v_i)$  を誤差項として，最小二乗法で  $\hat{\beta}$  を求める。

まずは， $X_i$  と  $u_i - \beta v_i$  の共分散を求める（共分散がゼロかどうかを確認する）。

(\* 復習) 共分散について：

2つの確率変数  $(X, Y)$  を考える。

$E(X) = \mu_x$ ， $E(Y) = \mu_y$  とする。

共分散の定義は， $\text{Cov}(X, Y) = E\left((X - \mu_x)(Y - \mu_y)\right)$

書き換えると，

$\text{Cov}(X, Y) = E(XY - X\mu_y - \mu_x Y + \mu_x \mu_y) = E(XY) - E(X)\mu_y - \mu_x E(Y) + \mu_x \mu_y = E(XY) - \mu_x \mu_y$   
となる。

この場合，

$$\begin{aligned}
 \text{Cov}(X_i, u_i - \beta v_i) &= \text{Cov}(X_i^* + v_i, u_i - \beta v_i) \\
 &= E\left((X_i^* + v_i)(u_i - \beta v_i)\right) - E(X_i^* + v_i)E(u_i - \beta v_i) \\
 &= E(X_i^* u_i + v_i u_i - X_i^* \beta v_i - \beta v_i^2) \\
 &= E(X_i^* u_i) + E(v_i u_i) - E(X_i^* \beta v_i) - E(\beta v_i^2) \\
 &= X_i^* E(u_i) + E(v_i u_i) - X_i^* \beta E(v_i) - \beta E(v_i^2) \\
 &= -\beta \sigma_v^2 \neq 0
 \end{aligned}$$

となる。

したがって，観測できる  $(Y_i, X_i)$  を用いて， $\beta$  の最小二乗推定量  $\hat{\beta}$  は不偏推定量にはならない。

特に，

$$\begin{aligned}
 \hat{\beta} &= \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sum(X_i - \bar{X})^2} = \beta + \sum \omega_i(u_i - \beta v_i) \\
 &= \beta + \frac{\sum(X_i - \bar{X})(u_i - \beta v_i)}{\sum(X_i - \bar{X})^2}
 \end{aligned}$$

$$= \beta + \frac{\frac{1}{n} \sum (X_i - \bar{X})(u_i - \beta v_i)}{\frac{1}{n} \sum (X_i - \bar{X})^2}$$

と書き換えられ、右辺第2項の分母は  $X_i$  の分散に対応し、分子は  $X_i$  と  $(u_i - \beta v_i)$  との共分散  $-\beta\sigma_v^2$  に対応する。

したがって、 $n \rightarrow \infty$  のとき、

$$\hat{\beta} \rightarrow \beta + \frac{-\beta\sigma_v^2}{M_{xx}}$$

となる。右辺第2項の分母は必ず正、分子は  $\beta$  が正（負）の場合は負（正）となる。

すなわち、

- $\beta > 0$  のとき、 $\hat{\beta} \rightarrow \beta - \frac{\beta\sigma_v^2}{M_{xx}} < \beta$
- $\beta < 0$  のとき、 $\hat{\beta} \rightarrow \beta - \frac{\beta\sigma_v^2}{M_{xx}} > \beta$

となる。

$X$  と  $u_i$  に相関がある場合の対処法:  $Y_i = \alpha + \beta X_i + u_i$  について,  $\text{Cov}(X_i, u_i) \neq 0$  のときを考える。

$$\begin{aligned}\hat{\beta} &= \frac{\sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_i (X_i - \bar{X})^2} = \beta + \frac{\sum_i (X_i - \bar{X})u_i}{\sum_j (X_j - \bar{X})^2} \\ &= \beta + \frac{\frac{1}{n} \sum_i (X_i - \bar{X})u_i}{\frac{1}{n} \sum_j (X_j - \bar{X})^2} \rightarrow \beta + \frac{M_{xu}}{M_{xx}} \neq \beta\end{aligned}$$

右辺第 2 項の分母は  $X_i$  の分散に相当し, 分子は  $X_i$  と  $u_i$  の共分散に相当する ( $n \rightarrow \infty$  のときは, 分子・分母を別々に計算することができる)。

$\text{Cov}(X_i, u_i) \neq 0$  が問題となって,  $E(\hat{\beta}) \neq \beta$  となる。

よって, 第 2 項の分子がゼロになるような修正を加えればよい。

$\text{Cov}(Z_i, u_i) = 0$  となる  $Z_i$  が存在するとする。

このとき，下記のような推定量

$$\tilde{\beta} = \frac{\sum_i (Z_i - \bar{Z})(Y_i - \bar{Y})}{\sum_i (Z_i - \bar{Z})(X_i - \bar{X})}$$

を考えてみよう。ただし， $\bar{Z} = \frac{1}{n} \sum_i Z_i$  とする。

(\*)  $Z_i$  を  $X_i$  で置き換えると， $\tilde{\beta}$  は最小二乗推定量  $\hat{\beta} = \frac{\sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_i (X_i - \bar{X})^2}$  に等しくなる。

$\tilde{\beta}$  を変形していく。

$$\begin{aligned}
\tilde{\beta} &= \frac{\sum_i (Z_i - \bar{Z})(Y_i - \bar{Y})}{\sum_i (Z_i - \bar{Z})(X_i - \bar{X})} \\
&= \frac{\sum_i (Z_i - \bar{Z})Y_i - \bar{Y} \sum_i (Z_i - \bar{Z})}{\sum_i (Z_i - \bar{Z})(X_i - \bar{X})} \\
&= \frac{\sum_i (Z_i - \bar{Z})Y_i}{\sum_i (Z_i - \bar{Z})(X_i - \bar{X})} \quad \left( = \sum_i \omega_i^* Y_i, \quad \text{ただし, } \omega_i^* = \frac{Z_i - \bar{Z}}{\sum_j (Z_j - \bar{Z})(X_j - \bar{X})} \right) \\
&= \frac{\sum_i (Z_i - \bar{Z})(\alpha + \beta X_i + u_i)}{\sum_i (Z_i - \bar{Z})(X_i - \bar{X})} \\
&= \frac{\alpha \sum_i (Z_i - \bar{Z}) + \beta \sum_i (Z_i - \bar{Z})X_i + \sum_i (Z_i - \bar{Z})u_i}{\sum_i (Z_i - \bar{Z})(X_i - \bar{X})} \\
&= \beta + \frac{\sum_i (Z_i - \bar{Z})u_i}{\sum_i (Z_i - \bar{Z})(X_i - \bar{X})} \quad \left( = \beta + \sum_i \omega_i^* u_i \right) \\
&= \beta + \frac{\frac{1}{n} \sum_i (Z_i - \bar{Z})u_i}{\frac{1}{n} \sum_i (Z_i - \bar{Z})(X_i - \bar{X})} \rightarrow \beta + \frac{0}{M_{zx}} = \beta
\end{aligned}$$

2行目の右辺の分子の第2項目は  $\sum_i (Z_i - \bar{Z}) = \sum_i Z_i - n\bar{Z} = 0$  に注意。

3行目では、 $\tilde{\beta} = \frac{\sum_i (Z_i - \bar{Z}) Y_i}{\sum_i (Z_i - \bar{Z})(X_i - \bar{X})} = \sum_i \omega_i^* Y_i$  と書き換えることができ、 $\tilde{\beta}$  も  $Y_i$  の線形推定量と言える。

ただし、 $\omega_i^* = \frac{Z_i - \bar{Z}}{\sum_j (Z_j - \bar{Z})(X_j - \bar{X})}$  である（分母の添字を  $i$  から  $j$  に変更）。

4行目の右辺分子の第1項目はゼロ、第2項目は  $\sum_i (Z_i - \bar{Z}) X_i = \sum_i (Z_i - \bar{Z}) X_i - \sum_i (Z_i - \bar{Z}) \bar{X} = \sum_i (Z_i - \bar{Z})(X_i - \bar{X})$  となるので分母と同じになる。このようにして、5行目が得られる。

6行目右辺第2項の分子は  $Z_i$  と  $u_i$  の共分散に対応し、分母は  $Z_i$  と  $X_i$  の共分散に対応し、 $n$  を大きくするとそれぞれゼロ、 $M_{zx}$  に収束するものとする。

すなわち、 $\tilde{\beta}$  は  $\beta$  の一致推定量となる。

$n$  が大きければ、 $E(\omega_i^* u_i) \rightarrow 0$  となる（分子・分母を別々に計算することができる）。

しかし、一般的には、 $E(\omega_i^* u_i) \neq 0$  なので（ $\omega_i^*$  の分母は  $X_i$  に依存していて、 $X_i$  と  $u_i$  は共分散がゼロでないと仮定）、 $E(\tilde{\beta}) \neq \beta$  となり、 $\tilde{\beta}$  は不偏推定量にはならない。

$Z_i$  を操作変数（instrumental variable）と呼ぶ。操作変数を用いた推定方法を操作変数法という。

$Z_i$  の選択について，(i)  $Z_i$  と  $u_i$  は相関がない，(ii)  $Z_i$  と  $X_i$  は強い相関がある，という 2 つの条件が必要になる。

(ii) については， $Z_i$  はもともと  $X_i$  の代わりに使うものなので， $X_i$  と相関の強い  $Z_i$  が望ましい。

$Z_i$  の選択について（その 1）： $i$  が時間を表す場合（時系列データの場合）， $Z_i = X_{i-1}$  を用いることが可能である。

$\text{Cov}(X_i, u_i) \neq 0$  としても， $X$  を一期ずらして  $\text{Cov}(X_{i-1}, u_i) = 0$  となるのは不自然ではない。

$Z_i$  の選択について（その 2）： $X_i$  の予測値  $\hat{X}_i$  を  $X_i$  の代わりに用いる。  
 $e_i$  を誤差項として，

$$X_i = \gamma_0 + \gamma_1 W_{1i} + \gamma_2 W_{2i} + \cdots + \gamma_m W_{mi} + e_i$$

を最小二乗法で推定して， $\hat{\gamma}_0, \hat{\gamma}_1, \cdots, \hat{\gamma}_m$  を求める。

ただし， $W_{1i}, W_{2i}, \dots, W_{mi}$  は  $u_i$  と相関のない変数でなければならない。

$W_{1i}, W_{2i}, \dots, W_{mi}$  には， $X_{i-1}, X_{i-2}, \dots$  のように  $X_i$  のラグ変数を用いてもよい。理由は，前述の通りで， $X_i$  と  $u_i$  に相関があったとしても， $X_i$  のラグ変数  $X_{i-1}, X_{i-2}, \dots$  と  $u_i$  とに相関があるとは考えにくいからである。

$X_i$  の予測値  $\hat{X}_i$  を求める。

$$\hat{X}_i = \hat{\gamma}_0 + \hat{\gamma}_1 W_{1i} + \hat{\gamma}_2 W_{2i} + \dots + \hat{\gamma}_m W_{mi}$$

を  $Z_i$  として用いる。

$Z_i$  は  $u_i$  と相関のない変数でなければならない。

$\hat{\gamma}_j$  は  $\gamma_j$  の一致推定量なので， $n \rightarrow \infty$  のとき，

$$\hat{X}_i = \hat{\gamma}_0 + \hat{\gamma}_1 W_{1i} + \hat{\gamma}_2 W_{2i} + \dots + \hat{\gamma}_m W_{mi} \rightarrow \gamma_0 + \gamma_1 W_{1i} + \gamma_2 W_{2i} + \dots + \gamma_m W_{mi}$$

となる。

操作変数法による推定量  $\tilde{\beta}$  が  $\beta$  の一致推定量になる理由は，

$$\tilde{\beta} = \beta + \frac{\frac{1}{n} \sum_i (Z_i - \bar{Z}) u_i}{\frac{1}{n} \sum_i (Z_i - \bar{Z})(X_i - \bar{X})} \rightarrow \beta + \frac{0}{M_{zx}} = \beta$$

から，操作変数  $Z_i$  と誤差項  $u_i$  との相関がゼロという条件（2 項目の分子）が重要なポイントとなっている。

$Z_i$  に  $\hat{X}_i$  を用いると， $n \rightarrow \infty$  のとき， $\hat{X}_i \rightarrow \gamma_0 + \gamma_1 W_{1i} + \gamma_2 W_{2i} + \cdots + \gamma_m W_{mi}$  となることから， $W_{1i}, W_{2i}, \cdots, W_{mi}$  が  $u_i$  と相関がなければ， $\frac{1}{n} \sum_i (\hat{X}_i - \bar{X}) u_i \rightarrow 0$  となる（ $\bar{\hat{X}} = \bar{X}$  に注意）。

この方法は，二段階最小二乗法（two-stage least squares method）と呼ばれる。1 段階目で  $\hat{X}_i$  を求める。2 段階目で  $\tilde{\beta}$  を得る。



## 第13章 識別性について


### 13.1 例：需要関数・供給関数

ある財の需要関数・供給関数を推定することを考える。


需要量と供給量が等しいところで取引される。

すなわち，需要量と供給量が等しいところでデータが観測されるものとする。

下図のように黒丸で需要量  $Q_i$  と価格  $P_i$  のデータが観測されたとする。



最小二乗法によって，下図のように  $(Q_i, P_i)$  の関係を表す線を引く。



この直線は何を表す直線か？

価格  $P_i$  が上がれば，需要量  $Q_i$  が下がるので，需要関数か？

それとも、供給関数か？

実は、この直線は需要関数でも供給関数でもどちらでもない。


需要関数は、

$$Q_i^D = \alpha_0 + \alpha_1 P_i + \alpha_2 Y_i + u_i$$

となる。

価格  $P_i$  が上がるにつれて、需要量  $Q_i^D$  は減少する（右下がり）。すなわち、 $\alpha_1 < 0$

所得  $Y_i$  が増加するにつれて、需要量  $Q_i^D$  が増加する。すなわち、 $\alpha_2 > 0$



この例では、 $Q_1^D, Q_2^D, \dots, Q_5^D$  の順に所得が増加する（ $Y_1$  が最も小さく、 $Y_5$  が最も大きい）。

所得  $Y_i$  が大きくなるにつれて、切片が大きくなる（この場合、 $\alpha_0 + \alpha_2 Y_i$  が切片）。

同じ価格の下では、所得が増加すれば需要量が増える。

供給関数は、

$$Q_i^S = \beta_0 + \beta_1 P_i + \beta_2 Z_i + v_i$$

と表される。

価格  $P_i$  が上がるにつれて、供給量  $Q_i^S$  は増加する（右上がり）。すなわち、 $\beta_1 > 0$

価格が上がれば、生産を増やして売の方が儲けが多い。

変数  $Z_i$  は財の種類によって異なる。

$\beta_2$  の符号も  $Z_i$  によって正負のどちらにもなり得る。

農作物の需給を考えるのであれば、供給量は天候に大きく依存するので、 $Z_i$  は日照時間、降水量などが適切な変数となる。


または、 $Z_i$  に作付面積なども考えられる。

作付面積が増えれば供給量も増える。


車、PCなどは工場設備などの稼働率が考えられる。

いずれにしても， $Z_i$  は供給関数にとって，重要な変数となる。

供給関数が次の図で表される。供給関数は右上がりであり， $\beta_0 + \beta_2 Z_i$  が切片となる。



下図のように，需要と供給が交わるところで，需要量（供給量）と価格が決まる。



需要関数の形状が決まるためには、 $Q_i, P_i$  以外の需要要因の変数が必要となる（この場合は、所得  $Y_i$ ）。

同様に，供給関数の形状が決まるためには， $Q_i, P_i$  以外の供給要因の変数が必要となる（この場合は， $Z_i$ ）。

この問題を，識別問題（identification problem）と呼ぶ。

需要関数と供給関数を区別して推定できるのかという問題である。

$Q_i, P_i$  だけでは，何を推定しているのか分からなくなる。

何かを推定するうえでは，常に念頭に置いておかなければならない事項である。