
EViewsによる 操作変数法入門

株式会社 ライトストーン

講習内容

1. 説明変数の誤差項の共分散
2. 観測誤差の問題
3. 二段階最小二乗法とモデルの診断
4. LIML推定量
5. GMM推定量

eviews08フォルダ

TSLSの推定例

- 消費関数の推定。

$$\begin{aligned} CP_t &= \alpha + \beta Y_t + \varepsilon_t \\ Y_t &= CP_t + Z_t \end{aligned}$$

ただし、恒等式を考慮すると、

$$\begin{aligned} CP_t &= \alpha + \beta Y_t + \varepsilon_t \\ Y_t - Z_t &= \alpha + \beta Y_t + \varepsilon_t \\ (1 - \beta)Y_t &= \alpha + Z_t + \varepsilon_t \\ Y_t &= \frac{\alpha}{1 - \beta} + \frac{Z_t}{1 - \beta} + \frac{\varepsilon_t}{1 - \beta} \end{aligned}$$

説明変数 Y_t と誤差項の間に相関があります。

OLSによる推定

- 最初にOLSでパラメータを推定します。

操作1: 実質国内総生産(Y), 民間最終消費(CP), その他の支出(Z)の入ったSNAのファイルtslstest.wf1を開きます。

EQ01:OLSの推定結果

説明変数	係数	t値
C	26568.1	3.256
Y	0.514	31.73

操作2: `cp c y`としてOLS推定します。Equationオブジェクト名はeq01とします。yの推定値を確認します。

TSLSによる推定

- TSLSでパラメータを推定します。

操作: EQ01のオブジェクトコピーEQ02を作成します。推定方法をTSLSとし、操作変数リストにはzと入力します。

The screenshot shows a software window with two tabs: 'Specification' and 'Options'. The 'Specification' tab is active and contains three sections:

- Equation specification:** A text box containing 'cp c y'. Above it is the instruction: 'Dependent variable followed by list of regressors including ARMA and PDL terms, OR an explicit equation like $Y=c(1)+c(2)*X$ '.
- Instrument list:** A text box containing 'c z'.
- Estimation settings:** A dropdown menu set to 'TSLS - Two-Stage Least Squares (TSNLS and ARMA)' and a sample range field set to '1994q1 2006q3'. A checkbox labeled 'Include lagged regressors for linear equations with ARMA terms' is checked.

EQ02:TSLSの推定結果

説明変数	係数	t値
C	41049.66	4.722
Y	0.485	28.12

推定結果の比較

OLSの推定結果:

説明変数	係数	T値
C	26568.1	3.256
Y	0.51409	31.73

TSLSの推定結果:

説明変数	係数	T値
C	41049.6	4.722
Y	0.48532	28.12

TSLSの値の方が小さくなっています(ゼロに近づいています)。

確認：TSLSの計算

ステップ1.被説明変数をYとして操作変数を使って推定します。Equationオブジェクトの名前はeq1stとします。

ステップ2.eq1stで予測計算してy_fを得ます。

ステップ3.y_fを使って推定eq2nd。被説明変数はCPです。

推定結果をEQ02と比べてみましょう。

TSLSの注意点

回帰の標準誤差 $\hat{\sigma}_w^2 = \sum \hat{w}_i^2 / (n - 2)$ 手計算

$\hat{\sigma}_u^2 = \sum \hat{u}_i^2 / (n - 2)$ 自動

操作:EQ02とEQ2ndの標準誤差の違いを確認しましょう。そして、次に示すプログラムで、説明変数を元に戻して、EQ2NDの回帰の標準誤差の計算をやり直してみましょう。

MEMO)t値やDW値など、推定結果の画面に表示される統計量は、厳密には正しくないが、そのまま使って構わない。

TSLSの回帰の標準誤差

```
'EQ2NDの回帰の標準誤差の計算  
'最初に説明変数をy_fでなく、yにして残差を求める  
!a=eq2nd.@coefs(1)  
!b=eq2nd.@coefs(2)  
!n=eq2nd.@regobs  
!k=eq2nd.@ncoef  
  
series ui=cp-(!a+!b*y)  
series ui2=ui^2  
show @sqrt(@sum(ui2)/(!n-!k))
```

回帰モデルの標準的仮定

- 推定したモデルの統計的推論を行うために、次のような仮定を行います。

$$Y_i = \alpha + \beta X_i + u_i \quad (i = 1, 2, \dots, n) \quad (1)$$

仮定1. 説明変数 X は確率変数ではなく、固定された値を持つ。

仮定2. n が ∞ の時、 X の偏差の二乗和も ∞

仮定3. $E(u_i) = 0$

仮定4. $V(u_i) = E(u_i^2) = \sigma^2$

仮定5. $Cov(u_i, u_j) = E(u_i u_j) = 0$

仮定6. $u_i \sim N(0, \sigma^2)$

推定量の確率的表現

- 式-1の両辺の期待値を取ります。

$$\bar{Y} = \alpha + \beta\bar{X} + \bar{u} \quad (2)$$

$$\begin{aligned} \hat{\beta} &= \frac{\sum_{i=1}^n (X_i - \bar{X}) \{ \beta(X_i - \bar{X}) + (u_i - \bar{u}) \}}{\sum_{i=1}^n (X_i - \bar{X})^2} \\ &= \beta + \frac{\sum_{i=1}^n (X_i - \bar{X})(u_i - \bar{u})}{\sum_{i=1}^n (X_i - \bar{X})^2} \\ &= \beta + \frac{\sum_{i=1}^n (X_i - \bar{X})u_i}{\sum_{i=1}^n (X_i - \bar{X})^2} \\ \hat{\alpha} &= \bar{Y} - \hat{\beta}\bar{X} = \alpha - (\hat{\beta} - \beta)\bar{X} + \bar{u} \end{aligned} \quad (3)$$

これを確率的表現と言います。

$\hat{\alpha}$ と $\hat{\beta}$ の期待値

$$\begin{aligned} E(\hat{\beta}) &= E(\beta) + E\left(\frac{\sum_{i=1}^n (X_i - \bar{X})u_i}{\sum_{i=1}^n (X_i - \bar{X})^2}\right) \\ &= \beta + \frac{\sum_{i=1}^n (X_i - \bar{X})E(u_i)}{\sum_{i=1}^n (X_i - \bar{X})^2} \end{aligned} \quad (4)$$

仮定3より u_i の期待値はゼロですから、

$$E(\hat{\beta}) = \beta$$

仮定3が成り立つ場合、 β にはバイアスがかかっていません。

$\hat{\alpha}$ と $\hat{\beta}$ の期待値

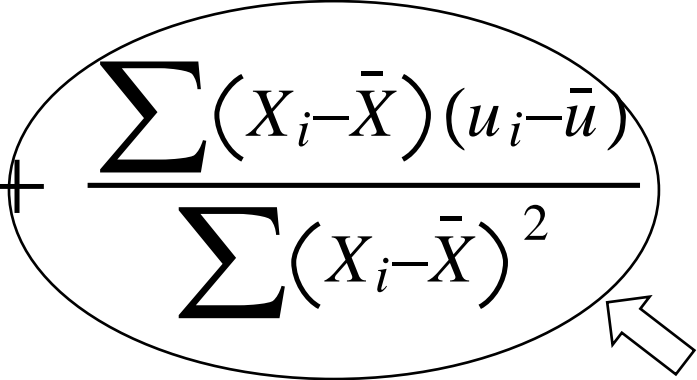
同様に、 α の期待値は式-4の関係から、

$$\begin{aligned} E(\hat{\alpha}) &= \alpha - E(\hat{\beta} - \beta)\bar{X} + E(\bar{u}) \\ &= \alpha - 0 \cdot \bar{X} + 0 = \alpha \end{aligned}$$

こちら、仮定3が成り立つ場合、バイアスがかかっていません。期待値を取った場合に、推定値に何のバイアスもかかっていない時、これを不偏推定量といいます。

X_i が確率変数の時

- 係数の推定値は偏りを持ちます。

$$\hat{\beta} = \beta + \frac{\sum (X_i - \bar{X})(u_i - \bar{u})}{\sum (X_i - \bar{X})^2} \quad (5)$$


期待値をとってもゼロ
になりません!

推定量はどちらも不偏推定量になりません。

$$E(\hat{\beta}) \neq \beta$$

$$E(\hat{\alpha}) \neq \alpha$$

確率極限

- 一致性を理解する上で必要になる基礎知識。 a_n と b_n は確率変数の列とする

$$\text{plim} a_n = c_1, \quad \text{plim} b_n = c_2$$

上式が成り立つ場合、

$$\text{plim} a_n b_n = \text{plim} a_n \times \text{plim} b_n = c_1 c_2$$

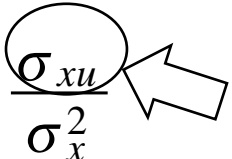
$$\text{plim} \frac{a_n}{b_n} = \frac{\text{plim} a_n}{\text{plim} b_n} = \frac{c_1}{c_2} \longleftarrow \text{重要}$$

X_i と u_i が従属である場合の一致性

- 5式の第二項を書き換えます。

$$\frac{\sum (X_i - \bar{X})(u_i - \bar{u})}{\sum (X_i - \bar{X})^2} = \frac{\frac{\sum (X_i - \bar{X})(u_i - \bar{u})}{n}}{\frac{\sum (X_i - \bar{X})^2}{n}} = \frac{s_{xu}}{s_x^2}$$


この確率極限を求めます。

$$\begin{aligned} \text{plim} \frac{\sum (X_i - \bar{X})(u_i - \bar{u})}{\sum (X_i - \bar{X})^2} &= \text{plim} \frac{s_{xu}}{s_x^2} = \frac{\text{plim} s_{xu}}{\text{plim} s_x^2} \\ &= \frac{\sigma_{xu}}{\sigma_x^2} \end{aligned}$$


共分散がゼロなら、一貫性はあります。また、共分散の符号によって5式第二項は変化します。

一 致 性

- X_i と u_i が従属である場合、不偏性は持たないが、両者の共分散がゼロとなる場合のみ、一 致 性はある。



$\sigma_{xu} \neq 0$ となるモデル

- 同時方程式モデル
- 観測誤差
- ラグ付き内生変数と攪乱項の系列相関が共存するモデル

観測誤差の問題

- 説明変数と誤差項が相関を持つ代表例

$$Y_i^* = \alpha + \beta X_i^* + u_i^* \quad (i = 1, 2, \dots, n)$$

Y_i^*, X_i^* は真の所得と消費。観測値 X_i, Y_i の関係は、

$$Y_i = Y_i^* + v_i \quad (i = 1, 2, \dots, n)$$

$$X_i = X_i^* + w_i \quad (i = 1, 2, \dots, n)$$

消費関数を観測可能な変数に変換します。

$$Y_i - v_i = \alpha + \beta(X_i - w_i) + u_i^* \quad (i = 1, 2, \dots, n)$$

$$Y_i = \alpha + \beta X_i + u_i^* - \beta w_i + v_i \quad (i = 1, 2, \dots, n) \quad (6)$$

説明変数のパラメータが誤差項にも含まれています。

観測誤差の問題

- Y_i の観測誤差
 - 誤差項の分散は大きくなるが、説明変数 X_i と誤差項は独立なので問題なし。
- X_i の観測誤差
 - 6式で w_i が存在するので、

$$\text{Cov}(X_i, u_i) = -\beta V(w_i) \neq 0, (i = 1, 2, \dots, n)$$

説明変数に観測誤差がある場合、OLS推定量は不偏推定量でもなく、かつ一致推定量でもない。

パラメータ(傾き)はゼロに近くなる。

シミュレーション実験

- シミュレーション実験のモデル

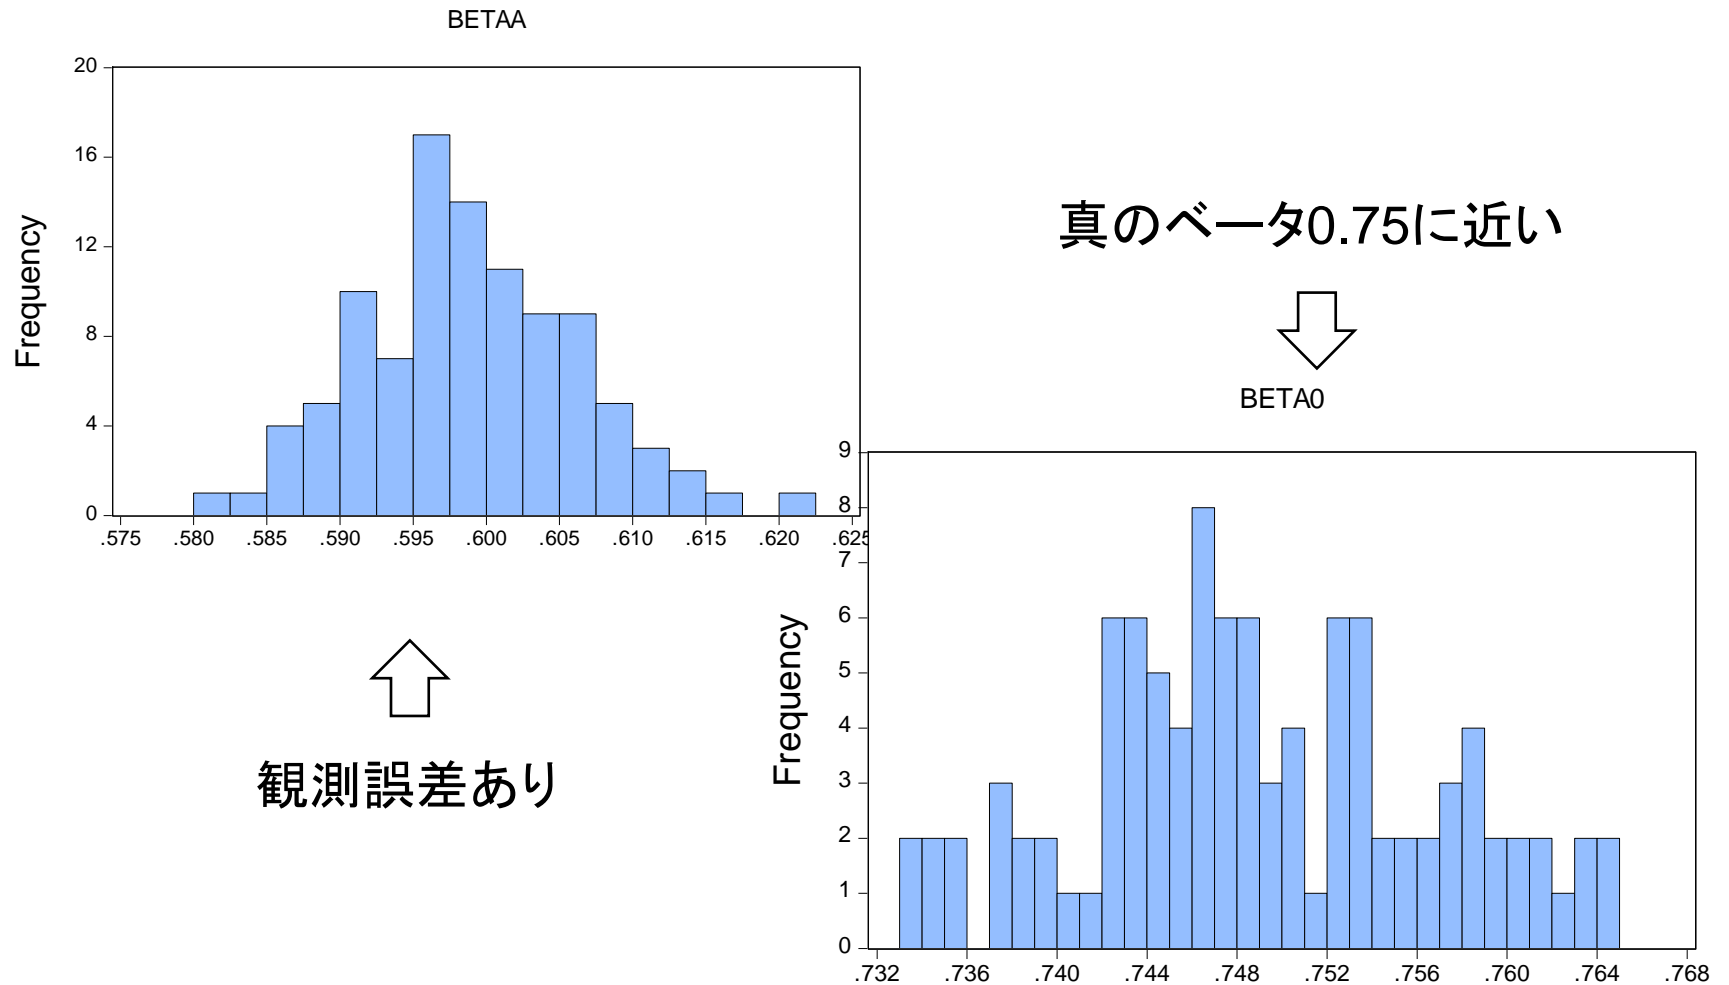
$$Y_i = 3.0 + 0.75X1_i + u_i \quad (i = 1, 2, \dots, n)$$

推定の際には誤差を含んだ次の変数を利用します。 w_i は $N(0,1)$

$$X1'_i = X1_i + w_i \quad (i = 1, 2, \dots, n)$$

操作: プログラムファイルOLSSIM02.prgを開きます。プログラムを実行し、一致性が無い事を確認しましょう。

シミュレーション実験



シミュレーション実験

'山本拓著、「計量経済学」、第10章、説明変数と攪乱項の相関
'betaaは観測誤差あり
'beta0は観測誤差なし。ここでは被説明変数には誤差は考えない
'真のbetaは0.75

!obs=5000

wfcreate(wf=chap10, page=p234) u !obs
matrix(100,1) betaa
matrix(100,1) beta0

rndseed 1234

for !i=1 to 100

シミュレーション実験

'N(1,4)の独立変数x1iを作成

```
series x1i=2*nrnd+1
```

'誤差項としてuiをN(0,1)で作成

```
series ui=nrnd
```

'被説明変数Yaの作成

```
series ya=3.0+0.75*x1i+ui
```

'観測誤差のあるx1idの作成。観測誤差wiはN(0,1)

```
series x1id=x1i+nrnd
```

'ここからモデル推定。最初に誤差のある説明変数を利用

```
equation eqa.ls ya c x1id  
betaa(!i,1)=eqa.@coefs(2)
```


シミュレーション実験

```
'次に観測誤差のないx1iを利用  
equation eq0.ls ya c x1i  
beta0(!i,1)=eq0.@coefs(2)
```

```
next
```

```
show betaa.distplot hist  
show beta0.distplot hist
```

まとめ1

- 不偏推定量と一致性推定量
 - 標準的仮定の「 X は確定的な値をとる」という仮定を外し、観測誤差のあるモデルを想定する。この時、OLSで推定すると、バイアスのかかった推定値を求めてしまう。

2. 操作変数法と二段階最小二乗法

- 観測誤差や内生性の問題がある場合、OLS推定で不偏推定量を求めることはできない。
- 操作変数(IV)法の拡張形である二段階最小二乗法(TSLS)を利用すると、一致推定量を求めることができる。

操作変数法

簡単化のため、相関のある次のようなモデルを仮定する。

$$Y_i = \alpha + \beta X_i + u_i \quad (i = 1, 2, \dots, n)$$
$$\text{Cov}(X_i, u_i) = \sigma_{xu} \neq 0$$

変数 Z_i が次の性質を満たす時、 Z_i を操作変数と呼びます。

$$\text{plim} s_{zu} = \text{plim} \frac{\sum (Z_i - \bar{Z})(u_i - \bar{u})}{n} = \sigma_{zu} = 0$$
$$\text{plim} s_{zx} = \text{plim} \frac{\sum (Z_i - \bar{Z})(X_i - \bar{X})}{n} = \sigma_{zx} \neq 0$$
$$\text{plim} s_{zz} = \text{plim} \frac{\sum (Z_i - \bar{Z})(Z_i - \bar{Z})}{n} = \sigma_{zz} > 0$$

操作変数法

操作変数推定量

$$\tilde{\beta} = \frac{\sum (Z_i - \bar{Z})(Y_i - \bar{Y})}{\sum (Z_i - \bar{Z})(X_i - \bar{X})} = \frac{\sum Z_i Y_i - n\bar{Z}\bar{Y}}{\sum Z_i X_i - n\bar{Z}\bar{X}}$$
$$\tilde{\alpha} = \hat{Y} - \tilde{\beta}\bar{X}$$

前出の最小二乗推定量

$$\tilde{\beta} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} = \frac{\sum X_i Y_i - n\bar{X}\bar{Y}}{\sum (X_i - \bar{X})^2}$$

操作変数法

$$\begin{aligned}\tilde{\beta} &= \frac{\sum (Z_i - \bar{Z})(Y_i - \bar{Y})}{\sum (Z_i - \bar{Z})(X_i - \bar{X})} \\ &= \frac{\sum (Z_i - \bar{Z})\{\beta(X_i - \bar{X}) + (u_i - \bar{u})\}}{\sum (Z_i - \bar{Z})(X_i - \bar{X})} \\ &= \beta + \frac{\sum (Z_i - \bar{Z})(u_i - \bar{u})}{\sum (Z_i - \bar{Z})(X_i - \bar{X})} \\ &= \beta + \frac{\frac{\sum (Z_i - \bar{Z})(u_i - \bar{u})}{n}}{\frac{\sum (Z_i - \bar{Z})(X_i - \bar{X})}{n}} = \beta + \frac{S_{Zu}}{S_{Zx}}\end{aligned}$$

操作変数法

$$\begin{aligned}\text{plim } \tilde{\beta} &= \beta + \text{plim } \frac{s_{zu}}{s_{zx}} = \beta + \frac{\text{plim } s_{zu}}{\text{plim } s_{zx}} \\ &= \beta + \frac{0}{\sigma_{zx}} = \beta\end{aligned}$$

確率極限を考えると、操作変数法はOLSでは満たさない
一貫性をもたらします。

操作変数の選択:

攪乱項に系列相関が無い場合は、説明変数のラグ
項が有力な候補になります。

二段階最小二乗法

- 操作変数の候補が多数存在する場合、推定量の分散を小さくするという意味では、操作変数は元の説明変数 X_i と相関が高いほど望ましい

相関が高くなるように操作変数の候補を組み合わせる

説明変数: X_i

操作変数の候補: X_{i-1}, X_{i-2}, W_i

操作変数を組み合わせを考えると?

$$X_i = \gamma_0 + \gamma_1 X_{i-1} + \gamma_2 X_{i-2} + \gamma_3 W_i + v_i \quad (i = 1, 2, \dots, n)$$

TSLs

- 組み合わせにより、新しい変数 X_i の計算値を作成します。

$$\hat{X}_i = \hat{\gamma}_0 + \hat{\gamma}_1 X_{i-1} + \hat{\gamma}_2 X_{i-2} + \hat{\gamma}_3 W_i \quad (i = 1, 2, \dots, n)$$

上記の計算値は個々の変数よりも X_i と相関が高くなります。

TSLs

- 操作変数として X_i の理論値 \hat{X}_i を使います。

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

ここで、 $X_i = \hat{X}_i + \hat{v}_i$ とすれば上式の分母は、

$$\begin{aligned}\sum (\hat{X}_i - \bar{X})(X_i - \bar{X}) &= \sum (\hat{X}_i - \bar{X})(\hat{X}_i + \hat{v}_i - \bar{X}) \\ &= \sum (\hat{X}_i - \bar{X})(\hat{X}_i - \bar{X}) + \sum (\hat{X}_i - \bar{X})\hat{v}_i \\ &= \sum (\hat{X}_i - \bar{X})^2\end{aligned}$$

ただし、 $\sum \hat{v}_i = 0$, $\sum \hat{X}_i \hat{v}_i = 0$

TSLS

- 結局、 Y_i を X_i の理論値に回帰した形になっています。

$$\tilde{\beta} = \frac{\sum (\hat{X}_i - \bar{X})(Y_i - \bar{Y})}{\sum (\hat{X}_i - \bar{X})(X_i - \bar{X})} = \frac{\sum (\hat{X}_i - \bar{X})(Y_i - \bar{Y})}{\sum (\hat{X}_i - \bar{X})^2}$$

回帰モデル

$$Y_i = \alpha + \beta \hat{X}_i + w_i \quad (i = 1, 2, \dots, n)$$

$$w_i = u_i + \beta v_i$$

TSLs

- TSLsの手続き
 - 攪乱項と相関を持つと思われる説明変数を被説明変数として、操作変数の候補に回帰する。
 - その理論値を X_i の代理変数として、元のモデルで利用してOLS推定する。

問題意識:需要・供給関数

- りんごへの需要量 Q_t ,その期の価格 P_t

$$Q_t = \alpha_1 + \alpha_2 P_t + u_t \quad (6)$$

- りんごの供給関数は、

$$Q_t = \beta_1 + \beta_2 P_t + v_t \quad (7)$$


両式の Q_t と P_t は同時決定されます。6式や7式を単独でOLS推定して問題ないでしょうか？

需要・供給関数

- 式1,2を連立させて Q_t を消します。

$$P_t = \frac{\alpha_1 - \beta_1}{\beta_2 - \alpha_2} + \frac{u_t - v_t}{\beta_2 - \alpha_2} \quad (8)$$

説明変数 P_t と誤差項が相関をもっています。つまり、需要・供給関数を単純にOLSで推定しても、一致推定量が得られません。



タバコの販売

- タバコの販売量についてのモデル
 - 1995年の米国におけるタバコの需要を推定。(Stock and Watson 2007,p438)

被説明変数

$\log(\text{packpc})$:一人当たり販売パック数

説明変数

$\log(\text{perinc})$:一人当たりの州税

$\log(\text{ravgprs})$:課税後の消費者の購入価格の
平均値

モデルの推定例

操作1: ワークファイルsw_cig.wf1を用いて次の需要関数EQ01を推定します。

$$\log(packpc) = c + \beta_1 \log(ravgprs) + \beta_2 \log(perinc) + u$$

係数	推定値	標準誤差	t統計量
C	10.34203	1.022681	10.11267
$\log(ravgprs)$	-1.406500	0.251375	-5.595218
$\log(perinc)$	0.343850	0.234967	1.463397

注意: $\log(RAVGPRS)$ と誤差項に相関がありますが、参考のためOLSで推定しました。

操作変数

$$\log(packpc) = c + \beta_1 \log(ravgprs) + \beta_2 \log(perinc) + u$$

操作変数は推定するパラメータの数以上、用意します。
この場合は3個以上。

内生性の問題

$\log(ravgprs)$: 課税後の購入価格の平均値

操作変数

$rtaxso$: 州の消費税(平均)

$rtaxs$: タバコ税

$\log(perinc)$: 説明変数

操作変数のリストには外生変数を入力します。

モデルの推定

操作1: TOLSを用いたEQ02を推定します。

$$\log(packpc) = c + \beta_1 \log(ravgprs) + \beta_2 \log(perinc) + u$$

$$\widehat{\log(ravgprs)} = \hat{\gamma}_0 + \hat{\gamma}_1 \log(perinc) + \hat{\gamma}_2 rtaxso + \hat{\gamma}_2 rtaxs$$

係数	推定値	標準誤差	t統計量
C	9.894956	1.058560	9.347564
$\log(ravgprs)$	-1.277424	0.263199	-4.853462
$\log(perinc)$	0.280405	0.238565	1.175379

推定値に変化が見られます。

TSLSの推定結果

枠線内の計算結果は、OLSの時の計算式で求めたものであるが、漸近的に正しい、と解釈する。

R-squared	0.429422	Mean dependent var	4.538837
Adjusted R-squared	0.404063	S.D. dependent var	0.243346
S.E. of regression	0.187856	Sum squared resid	1.588044
F-statistic	13.28079	Durbin-Watson stat	1.946351
Prob(F-statistic)	0.000029	Second-Stage SSR	1.845868
J-statistic	0.311833	Instrument rank	4
Prob(J-statistic)	0.576557		

$$\text{J-statistic: } \frac{1}{T} u' Z (s^2 Z' Z / T)^{-1} Z' u$$

操作変数の数

$$u_t = y_t - x_t' b_{TSLS} \quad s^2 = \sum_t u_t^2 / (T - k)$$

$$E(Z' u(\beta)) = 0$$

識別問題

$$Y_i = \beta_0 + \beta_1 X_{1i} + \cdots + \beta_k X_{ki} + \beta_{k+1} W_{1i} + \cdots + \beta_{k+r} W_{ri} + u_i$$

X_i : 内生変数

k : 内生変数の個数

W_i : 外生変数

r : 外生変数の個数

Z : 操作変数

m : 操作変数の個数

$m > k$ 過剰識別 \Rightarrow バイアス発生の可能性

$m = k$ 丁度識別

$m < k$ 過小識別 \Rightarrow 推定できない

識別問題

$$\log(packpc) = c + \beta_1 \log(ravgprs) + \beta_2 \log(perinc) + u$$

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 W_{1i} + u_i$$

内生変数1個(k)、外生変数1個(r)、操作変数2個(m)

識別問題において、 $m=2 > k=1$ なので過剰識別になっている?

識別問題

過剰識別の検定: 帰無仮説は「すべての操作変数は外生的である」

R-squared	0.429422	Mean dependent var	4.538837
Adjusted R-squared	0.404063	S.D. dependent var	0.243346
S.E. of regression	0.187856	Sum squared resid	1.588044
F-statistic	13.28079	Durbin-Watson stat	1.946351
Prob(F-statistic)	0.000029	Second-Stage SSR	1.845868
J-statistic	0.311833	Instrument rank	4
Prob(J-statistic)	0.576557		

帰無仮説は棄却できない。つまり、操作変数の数が多すぎるが、推定値にバイアスは発生していない事が分かる。

J統計量は自由度 $m-k$ のカイ二乗分布となる。 $J \sim \chi_{m-k}^2$

識別問題

- 2つの操作変数のうち、片方を除いて推定値の変化や出力結果を考察しましょう。

まとめ2

■ 同時方程式

- 同時方程式を変形すると、説明変数と誤差項が相関を持ってしまう場合がある
- 二段階最小二乗法を用いて一致推定量を求める
- 識別問題

操作変数法の診断と検定

操作変数を利用して推定が完了したら、次のポイントをチェックします。

1. 操作変数と誤差項の直交性の検定:Instrument Orthogonality C-Test
2. 説明変数の内生性の検定:Durbin-Wu-Hausman検定
3. 操作変数と説明変数の弱相関:Clogg-Donald統計量

直交性の検定(1)

操作変数とモデルの誤差項が直交している事を検定します。

$$E(Z'u(\beta)) = 0$$

検定したい操作変数を Z_1 , それ以外の操作変数を Z_2 とし、これを次のように示します。

$$E(Z_1'u(\beta)) = 0$$


$$E(Z_2'u(\beta)) \neq 0$$

ここで、 $Z=(Z_1, Z_2)$ とし、 Z による推定式のJ統計量と目的の Z_1 によるJ統計量の差として次の統計量 C_T を得ます。

$$C_T = \frac{1}{T}u(\hat{\beta})'Z\hat{W}_T^{-1}Z'u(\hat{\beta}) - \frac{1}{T}u(\tilde{\beta})'Z_1\hat{W}_{T1}^{-1}Z_1'u(\tilde{\beta})$$

直交性の検定(2)

操作:EQ02でView/IV Diagnostics and Tests/Instrument Orthogonality Testと操作します。例として、操作変数rtaxsoとモデルの誤差項は直交している事を検定します。



直交性の検定(3)

Instrument Orthogonality C Test
Null hypothesis: RTAXSO are valid instruments
Equation: EQ02
Specification: LOG(PACKPC) C LOG(RAVGPRS) LOG(PERINC)
Instrument specification: RTAXSO RTAXS LOG(PERINC)
Test instruments: RTAXSO

	Value	df	Probability
Difference in J-stats	0.311833	1	0.5766

J-statistic summary:


	Value
Restricted J-statistic	0.311833
Unrestricted J-sta...	0.000000

帰無仮説は「操作変数rtaxsoと誤差項は直交している」です。
rtaxsの直交性も調べてみましょう。

内生性の検定(1)


$$\log(packpc) = c + \beta_1 \log(ravgprs) + \beta_2 \log(perinc) + u$$

説明変数内生変数であることを検定で確認します。



$$\log(ravgprs) = \gamma_0 + \gamma_1 \log(perinc) + \gamma_2 rtaxso + \gamma_2 rtaxs + e \quad (9)$$

説明変数 $\log(ravgprs)$ に内生性を仮定



内生性の検定: Durbin-Wu-Hausman検定

帰無仮説: 説明変数は外生変数である。

内生性の検定(2)

内生性の検定は、内生変数だと思っていたものが、実際には外生変数であることを検定するものです。帰無仮説は「選択した変数は実は外生変数である」です。

$$H_T = \frac{1}{T} u(\tilde{\beta})' \tilde{Z} \hat{W}_T^{-1} \tilde{Z}' u(\tilde{\beta}) - \frac{1}{T} u(\hat{\beta})' Z \hat{W}_{T^*}^{-1} Z' u(\hat{\beta})$$

第1項は内生性を仮定した式から得たJ統計量であり、第2項はTOLSによる推定値によるJ統計量です。

内生性の検定(3)

操作: EQ02でIV Diagnostics&Tests /Regressor Endogeneity Test/
ダイアログlog(ravgprs)が入っていることを確認してOKボタンをクリック
します。

	Value	df	Probability
Difference in J stats	2.933042	1	0.0868

有意水準10%で帰無仮説: 目的の変数は外生変数である、は棄却
できません。

Difference in J statsは自由度1のカイ二乗分布となります。自由度は
検定する説明変数の個数です。

弱相関の検定(1)

■ 3つの操作変数と説明変数 $\log(\text{ravgprs})$ の相関

操作変数と補助回帰の説明変数の間の相関が弱い場合、それを弱相関と呼びます。

直交性と内生性が確認できても、操作変数が弱相関であると、推定値にバイアスがかかってしまいます。

$$\log(\text{packpc}) = c + \beta_1 \log(\text{ravgprs}) + \beta_2 \log(\text{perinc}) + u$$

$$\log(\text{ravgprs}) = \gamma_0 + \gamma_1 \log(\text{perinc}) + \gamma_2 \text{rtaxso} + \gamma_2 \text{rtaxs} + e$$

弱相関がある場合、TSLSを使うより、却ってOLSで推定をした方が一致推定量からのズレが少ないこともあります。

弱相関の検定(2)

■ Stock and YogoによるClogg-Donald統計量

Clogg-Donald統計量

$$G_t = \left(\frac{(T - k_1 - k_2)^2}{k_2} \right) (X'_E M_{XZ} X_E)^{-1/2} (M_X X_E)' M_X Z_Z \left((M_X Z_Z)' (M_X Z_Z) \right)^{-1} (M_X Z_Z)' (M_X X_E) (X'_E M_{XZ} X_E)^{-1/2}$$

$$M_{XZ} = I - X_Z (X'_Z X_Z)^{-1} X'_Z$$

$$M_X = I - X_X (X'_X X_X)^{-1} X'_X$$

Z_Z =説明変数リストには無い操作変数

X_Z =(X_X | Z_Z)

X_X =外生変数(説明変数と操作変数の両方のリストに入るもの)

X_E =外生変数(操作変数リストには入らない説明変数)

k_1 = X_X の列数

k_2 = Z_Z の列数

弱相関の検定(3)

■ Stock and YogoによるClogg-Donald統計量

Clogg-Donald統計量が境界値よりも大きければ、帰無仮説「Weak Instrument」(相関は弱い)は棄却できます。
操作:EQ02でIV Diagnostics&Tests /Weak Instrument Diagnosticsと操作します。

Clogg-Donald F-stats	244.7337
Stock-Yogo cv	
10%	19.93
20%	11.59
30%	8.75
40%	7.25

帰無仮説は棄却できました。

診断のまとめ

操作変数を利用して推定が完了したら、次のポイントをチェックします。

- 操作変数と誤差項の直交性の検定: Instrument Orthogonality C-Test
帰無仮説:「操作変数と誤差項は直交している」
ここではp値が0.5766で棄却できなかった!
- 説明変数の内生性の検定: Durbin-Wu-Hausman検定
帰無仮説:「説明変数は外生変数である」
ここではp値が0.0868
- 弱相関の検定: Clogg-Donald統計量
帰無仮説:「説明変数と操作変数は弱相関の関係にある」
ここではF値が244で棄却できた!

練習

松浦・マッケンジー、「EViewsによる計量経済分析」より、small.wf1を用いて次のモデルを推定してみましょう。

$$\begin{aligned} \text{delprosales}_t = & \alpha + \beta_1 \text{delloan}_t + \beta_2 \text{delcredit}_t + \beta_3 \text{deloth}_t \\ & + \beta_4 \text{deltochi2}_t + \beta_5 \text{delsurratio}_t + e_t \end{aligned}$$

delprosales:売上高利益率の変化幅

delloan:借入金比率変化幅

delcredit:企業間受信比率変化幅

deloth:その他負債の変化幅

deltochi2:担保比率変化幅

delsurratio:剰余/資産の変化幅

練習

$$\begin{aligned} \text{delprosales}_t = & \alpha + \beta_1 \text{delloan}_t + \beta_2 \text{delcredit}_t + \beta_3 \text{deloth}_t \\ & + \beta_4 \text{deltochi2}_t + \beta_5 \text{delsurratio}_t + e_t \end{aligned}$$

Step1. EQ01としてOLSで推定します。

Step2. (経済学的な理由ではなく、練習として) delsurratioと誤差項の相関を仮定します。EQ01をコピーしてEQ02を作り、TSLSで推定します。操作変数は次の通りです。

netprofitと、gyoushuが1,2,3のダミー変数

netprofit: 税引き前利益

gyoushuの1は製造業、2は卸業、3は小売業。シリーズgyoshuには1から7までの値を取る

tanpob

練習

Dependent Variable: DELPROSALES
 Method: Two-Stage Least Squares
 Date: 01/29/16 Time: 17:41
 Sample: 1 114
 Included observations: 114
 Instrument specification: DELLOAN DELCREDIT DELOTH DELTOCHI2
 NETPROFIT GYOUSHU=1 GYOUSHU=2 GYOUSHU=3 TANPOB
 Constant added to instrument list

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-2.297100	2.230436	-1.029889	0.3054
DELLOAN	-0.358425	0.166265	-2.155747	0.0333
DELCREDIT	-0.352348	0.182118	-1.934725	0.0556
DELOTH	-0.373577	0.179628	-2.079721	0.0399
DELTOCHI2	0.108919	0.059206	1.839665	0.0686
DELSURRATIO	-0.101980	0.057132	-1.784984	0.0771
R-squared	-3.275802	Mean dependent var	-0.150426	
Adjusted R-squared	-3.473755	S.D. dependent var	7.647624	
S.E. of regression	16.17568	Sum squared resid	28258.50	
F-statistic	1.218001	Durbin-Watson stat	1.883863	
Prob(F-statistic)	0.305639	Second-Stage SSR	5015.469	
J-statistic	1.087849	Instrument rank	10	
Prob(J-statistic)	0.896195			

練習

Step3.EQ02について、以下の検定を実行します。

- 操作変数と誤差項の直交性の検定: Instrument Orthogonality C-Test
帰無仮説: 「操作変数と誤差項は直交している」
- 説明変数の内生性の検定: Durbin-Wu-Hausman検定
帰無仮説: 「説明変数は外生変数である」
- 弱相関の検定: Clogg-Donald統計量
帰無仮説: 「説明変数と操作変数は弱相関の関係にある」

操作が完了したら、small.wf1を上書き保存します。

LIML(Limited Information ML)

■ 制限情報最大尤度推定法

- Anderson and Rubin(1949)がTOLSよりも以前に提案。
- TOLSと同じく、説明変数と誤差項の相関の問題に対応するための推定手法
- 推定式が丁度識別の時、LIMLとTOLSは同じ推定値を提供する
- Hahn and Inoue(2002)によれば、弱相関の変数が多い場合にTOLSより優れている。

LIML

■ パラメータ推定のアプローチ

線形なLIML推定量は次式を最小化して求める。

$$\Psi(\beta) = T \frac{(y-X\beta)'Z(Z'Z)^{-1}Z'(y-X\beta)}{(y-X\beta)'(y-X\beta)}$$

計算を効率化させるために、 $W = (y, X)$, $\tilde{\beta} = (-1, \beta)'$ として、

$$\Psi(\beta) = T \frac{\tilde{\beta}'W'Z(Z'Z)^{-1}Z'W\tilde{\beta}}{\tilde{\beta}'W'W\tilde{\beta}}$$

*非線形なLIML推定量は上記とは異なる。

LIML

■ パラメータ推定のアプローチ

非線形なLIML推定量は次の対数尤度関数を最大化して求める

$$L = -\frac{T}{2} \left(\log(u'u) + \log \left| X'AX - X'AZ(Z'AZ)^{-1}Z'AX \right| \right)$$

ここで、

$$u_t = y_t - f(X_t, \beta), \quad A = I - u(u'u)^{-1}u'$$

*操作変数の利用方法がTSLSとは異なる！

クラインのモデルI

ケインズ型のマクロモデル(Lawrence Klein(1950))
1921-41年の米国のデータを利用した。

$$CONS_t = \alpha + \beta_1 Y_t + \beta_2 Y_{t-1} + W_t + u_t$$

消費関数の推定 : Greene 2008(p.385)

操作:klein.wf1を開きます。消費関数で利用する変数は次の通りです。

被説明変数 : cons(消費)

説明変数 : 定数項、y(民間利益)、y(-1)、w(賃金)

操作変数 : 定数項、p(-1)(企業利益のラグ項)、k(-1)資本ストックのラグ項、
x(-1)(GNPのラグ項)、時間トレンド(tm)、政府賃金(wg)、
g(政府支出)、t(税)

LIMLによる消費関数の推定

Specification Options

Equation specification::
Dependent variable followed by list of regressors including ARMA and PDL terms, OR an explicit equation like $Y=c(1)+c(2)*X$.

cons c y y(-1) w

Instrument list:
p(-1) k(-1) x(-1) tm wg e t

Include a constant
K (leave blank for LIML):

Estimation settings::
Method: LIML - Limited Information Maximum Likelihood and K-Class
Sample: 1920 1941

ここに数値を入力すると、Kクラス推定量になる

LIMLによる消費関数の推定

操作:推定オブジェクトの名前をEQ01とします。

```
Dependent Variable: CONS
Method: LIML / K-Class
Date: 02/26/15 Time: 14:04
Sample (adjusted): 1921 1941
Included observations: 21 after adjustments
Covariance type: IV
Instrument specification: P(-1) K(-1) X(-1) TM WG G T
Constant added to instrument list
```

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	17.14765	2.004588	8.554203	0.0000
Y	-0.222513	0.179166	-1.241941	0.2311
Y(-1)	0.396027	0.162802	2.432565	0.0263
W	0.822559	0.061088	13.46522	0.0000

R-squared	0.956572	Mean dependent var	53.99524
Adjusted R-squared	0.948909	S.D. dependent var	6.860866
S.E. of regression	1.550791	Sum squared resid	40.88419
Durbin-Watson stat	1.487859	LIML min. eigenvalue	1.498746

*操作変数に関する検定機能なし。

GMM(一般化積率法)

K個のパラメータ β を推定する時、L個のモーメント条件を利用する

$$L \geq K$$

モーメント条件とは、

$$E(m(y_t, \beta)) = 0 \quad (11)$$

このモーメント条件をL個考える。もう、少し具体的に書くと、残差を次のように表現して、

$$u_t(\beta) = u(y_t, X_t, \beta)$$

$$E(Z_t u_t(\beta)) = 0 \quad (\text{操作変数の条件})$$

Z_t が操作変数である。

GMM

11式のモーメント条件を標本を使って表現する

$$m_T(\beta) = \frac{1}{T} \sum Z_t u_t(\beta) = \frac{1}{T} \mathbf{Z}' \mathbf{u}(\beta) = 0 \quad (12)$$

L個のモーメント条件について12式を β について解く。

L>Kの時、12式は過剰識別だが、その時はできるだけゼロに近くなるようにして解く。

その時、次のJ統計量がモーメント条件とゼロとの距離を示す。

$$J(\beta, W_T) = \frac{1}{T} \mathbf{u}(\beta)' \mathbf{Z} \hat{\mathbf{W}}_T^{-1} \mathbf{Z}' \mathbf{u}(\beta)$$

GMMの入力例1

推定式 $y_t = \alpha + \beta x_t + u_t$

操作変数 定数項、 Z_t 、 W_t を利用する

この時、直交条件は次のように考える。

$$\begin{aligned}\sum (y_t - c(1) - c(2)x_t) &= 0 \\ \sum (y_t - c(1) - c(2)x_t)z_t &= 0 \\ \sum (y_t - c(1) - c(2)x_t)w_t &= 0\end{aligned}$$

GMMの入力例2

操作:Quick/Estimate Equationと操作して推定手法はGMMを選択し、次のダイアログを表示します。

Specification Options

Equation specification
Dependent followed by regressors, AR and PDL terms, OR an explicit equation.

Instrument list

Include a constant

Estimation weighting matrix
HAC (Newey-West) HAC options

Weight updating
N-Step Iterative
Number of iterations: 1

Estimation settings
Method: GMM - Generalized Method of Moments
Sample: 1920 1941

$$y_t = \alpha + \beta x_t + u_t$$

y C X

操作変数は仮に、

C Z W

GMMの入力例2

推定式 $\alpha \log y_t + x_t^\beta = 0$

操作変数 定数項、 Z_t 、 Z_{t-1} を利用する

この時、直交条件は次のように考える。

$$\begin{aligned}\sum (c(1) \log y_t + x_t^{c(2)}) &= 0 \\ \sum (c(1) \log y_t + x_t^{c(2)}) z_t &= 0 \\ \sum (c(1) \log y_t + x_t^{c(2)}) z_{t-1} &= 0\end{aligned}$$

GMMの入力例2

非線形モデルの入力例

Specification Options

Equation specification
Dependent followed by regressors, AR and PDL terms, OR an explicit equation.

Instrument list

Include a constant

Estimation weighting matrix
HAC (Newey-West)
HAC options

Weight updating
N-Step Iterative
Number of iterations: 1

Estimation settings
Method: GMM - Generalized Method of Moments
Sample: 1920 1941

$$\alpha \log y_t + x_t^\beta = 0$$

$$c(1)*\log(y)+x^c(2)$$

*等号とゼロは入力しない

操作変数は仮に、
 $c \ z \ z(-1)$

推定例

操作:LIMLで推定式オブジェクトをコピーしてEQ02を作成します。推定手法をGMMに変更して、そのままOKボタンをクリックします。

```
Dependent Variable: CONS
Method: Generalized Method of Moments
Date: 02/26/15   Time: 14:31
Sample (adjusted): 1921 1941
Included observations: 21 after adjustments
Linear estimation with 1 weight update
Estimation weighting matrix: HAC (Bartlett kernel, Newey-West
fixed bandwidth = 3.0000)
Standard errors & covariance computed using estimation weighting
matrix
Instrument specification: P(-1) K(-1) X(-1) TM WG G T
Constant added to instrument list
```

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	15.24476	1.178380	12.93705	0.0000
Y	0.054195	0.142449	0.380450	0.7083
Y(-1)	0.179962	0.111554	1.613227	0.1251
W	0.839522	0.044014	19.07378	0.0000
R-squared	0.977745	Mean dependent var	53.99524	
Adjusted R-squared	0.973818	S.D. dependent var	6.860866	
S.E. of regression	1.110147	Sum squared resid	20.95125	
Durbin-Watson stat	1.501409	J-statistic	3.558152	
Instrument rank	8	Prob(J-statistic)	0.469091	

H0: 目的関数の
最小値はゼロ(過
剰識別でない)

操作変数
の数



推定オプション

GMM推定の設定で一番重要が加重行列 W_T の設定。

The screenshot shows a software interface for GMM estimation. At the top, there is a checkbox labeled 'Include a constant' which is checked. Below this, the 'Estimation weighting matrix' is set to 'HAC (Newey-West)', with an 'HAC options' button below it. To the right, the 'Weight updating' method is set to 'N-Step Iterative', and the 'Number of iterations' is set to 1. Below these, the 'Estimation settings' section shows the 'Method' as 'GMM - Generalized Method of Moments' and the 'Sample' as '1920 1941'. Two arrows point from the text above to the 'HAC (Newey-West)' dropdown and the 'N-Step Iterative' dropdown.

加重行列の設定でWhiteまたはHACを選択したら、引き続き、加重の更新方法を選択する。

練習)

small.wf1のワークファイルを開き、EQ02をコピーしてEQGMMを作成します。そして、設定は変更せずに、GMMを推定し、最後に、内生性の検定を実行します。

GMM推定

松浦/マッケンジ-、「EViewsによる計量経済分析 第2版 p203」より、

練習:

EViewsワークファイル korea.wf1を利用してアジア通貨危機(1997年秋)後の韓国の鉱工業生産指数KIIPの動きをモデル化する。

$$KIIP_t = \alpha + \beta_1 KOREAWAN_t + \beta_2 KOREAWAN_t \times HIGH_t \\ + \beta_3 LENDRATE_t + \beta_4 LM1_t + e_t$$

操作変数 $KOREAWAN_t, KOREAWAN_{t-1}, KOREAWAN_{t-2}$
 $KOREAWAN_t \times HIGH_t, LENDRATE_t, LENDRATE_{t-1}$
 $LENDRATE_{t-2}, LENDRATE_{t-3}, LM1_{t-1}, LM_{t-2}$

ただし、HIGHはKOREAWANが1000以上のとき、1を取るダミー変数

自習)

目的:“new Keynesian Philips curve”と呼ばれる次のモデルのパラメータを推定します。 π はインフレ率、 un は失業率とします。ここで β は近似的に1で、 γ はマイナスになることが期待されているものとします。

$$\pi_t = \alpha + \beta\pi_{t+1} + \gamma un_{t-1}$$

不況になって失業率 un が上がれば、物価がさがる。

分析の動機:現時点で予測する一期先のインフレ率には観測誤差が含まれています。最小二乗法で推定すると、パラメータはどうなるでしょうか?

自習)

操作1: EViewsファイル「CPI_AND_UNEMPLOYMENT.wf1」を開きます。

操作2: 次の式を推定します。オブジェクト名はEQ01とします。

inf c inf(1) unrate(-1)

Dependent Variable: INF
Method: Least Squares
Date: 07/17/09 Time: 08:59
Sample (adjusted): 1948M02 2005M02
Included observations: 685 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.086076	0.554900	1.957248	0.0507
INF(1)	0.495433	0.033356	14.85304	0.0000
UNRATE(-1)	0.136110	0.094558	1.439444	0.1505

R-squared	0.250938	Mean dependent var	3.691521
Adjusted R-squared	0.248741	S.D. dependent var	4.340267
S.E. of regression	3.761935	Akaike info criterion	5.492114
Sum squared resid	9651.769	Schwarz criterion	5.511951
Log likelihood	-1878.049	Hannan-Quinn criter.	5.499790
F-statistic	114.2358	Durbin-Watson stat	2.244407
Prob(F-statistic)	0.000000		

1が期待されるインフレ率 β は0.50、負の値が期待される γ は0.14となり、理論とはかなり異なる値が計算されました。

自習)

操作: 推定式と操作変数を次のようにして、GMM推定を実行します。
推定式はEQGMMとします。

推定式: `inf c inf(1) unrate(-1)`

操作変数: `c unrate(-1) inf(-1) inf(-2)`

1に近い β は1.14、負が期待される γ は-0.03になりました。

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.370071	0.494054	-0.749049	0.4541
INF(1)	1.140793	0.113617	10.04069	0.0000
UNRATE(-1)	-0.030448	0.069702	-0.436839	0.6624
R-squared	-0.160212	Mean dependent var		3.691521
Adjusted R-squared	-0.163614	S.D. dependent var		4.340267
S.E. of regression	4.681887	Sum squared resid		14949.48
Durbin-Watson stat	2.814909	J-statistic		0.000000
Instrument rank	3			

ここでは推定式として線形モデルを利用しましたが、TSLSとは異なり、GMMでは非線形式の推定ができるのも大きな特徴の一つです。

パネルデータにおける推定

パネルデータにおいては不均一分散や系列相関が生じやすいという問題があります。GMMを利用することで、これらの問題を回避できます。

パネルデータにおける自己回帰モデルでは一時系列モデルとは異なる特別な問題が発生します。

Arellano and Bond(1991)

ダイナミックパネルデータモデル

■ ラグ項を含むモデル

$$y_{it} = \delta y_{i,t-1} + u_{it} \quad (13)$$

$$u_{it} = \mu_i + v_{it}$$

固定効果を除去するためにwithin推定を実行します

$$(y_{it} - \bar{y}_i) = \delta(y_{i,t-1} - \bar{y}_{i-1}) + (u_{it} - \bar{u}_i) \quad (14)$$

$(y_{i,t-1} - \bar{y}_{i-1})$ と $(u_{it} - \bar{u}_i)$ に相関が生じてしまう!

ARELLANO and Bond 推定量

14式のwithin推定量ではなく、階差モデルを考える

$$y_{it} - y_{i,t-1} = \delta(y_{i,t-1} - y_{i,t-2}) + (v_{it} - v_{i,t-1}) \quad (15)$$

t=3で具体的に書くと、

$$y_{i3} - y_{i2} = \delta(y_{i2} - y_{i1}) + (v_{i3} - v_{i2}) \quad (16)$$

y_{i1} が操作変数として利用できる

t=4の場合は、


$$y_{i4} - y_{i3} = \delta(y_{i3} - y_{i2}) + (v_{i4} - v_{i3}) \quad (17)$$

y_{i1}, y_{i2} が操作変数として利用できる

GMM

操作1: EViewsのサンプルデータ、Abond_pan.wf1を開きます。このファイルは第41章のサンプルデータとしてEViewsフォルダに入っています。

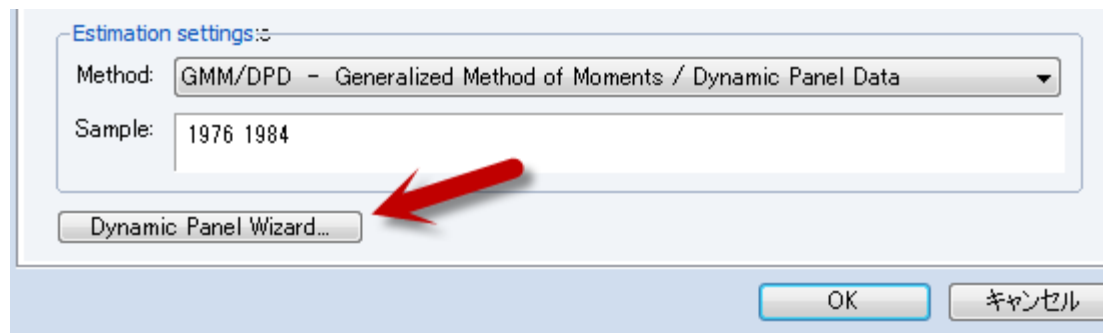
1976年-1984年までの140の企業のデータ
N: 企業の従業員数の対数值(被説明変数)
W: 実質賃金の対数值
K: 資本ストックの対数值
YS: 工業生産の対数值



操作2: Quick/Estimate Equationと操作し、GMM/DPDを選択します。パネルデータの場合のみDPDという表示が表れます。

ダイナミックパネル

操作2: Quick/Estimate Equationと操作し、GMM/DPDを選択します。パネルデータの場合のみDPDという表示が表れます。



操作3: ダイアログの下側にあるDynamic Panel Wizard...というボタンをクリックします。

ダイナミックパネル

操作4: Welcomeダイアログで「次へ」をクリックし、被説明変数の設定画面を表示します。

Dynamic Panel Data Model Wizard

Specify dependent variable - Step 1 of 6

Dynamic panel data models have the feature that lags of the dependent variable appear as regressors.

What is your dependent variable? n

The specification in this wizard uses lags (from one up to a specified maximum) of the dependent variable as regressors. How many lags of the dependent variable do you want to use as regressors?

From one up to 2 lag(s)

< 戻る(B) 次へ(N) > キャンセル

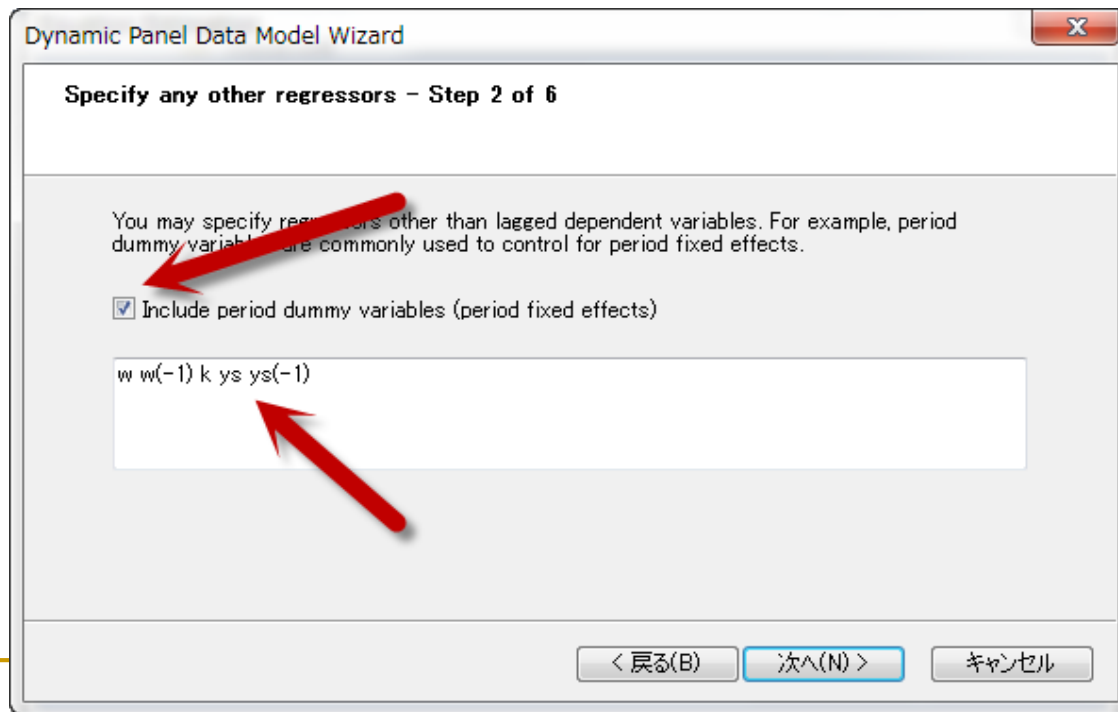
操作5: 被説明変数に「n」、ダイナミックモデルの説明変数として利用するラグ項の次数を「2」として、「次へ」をクリックします。

ダイナミックパネル

操作6: 説明変数を次のように入力します。

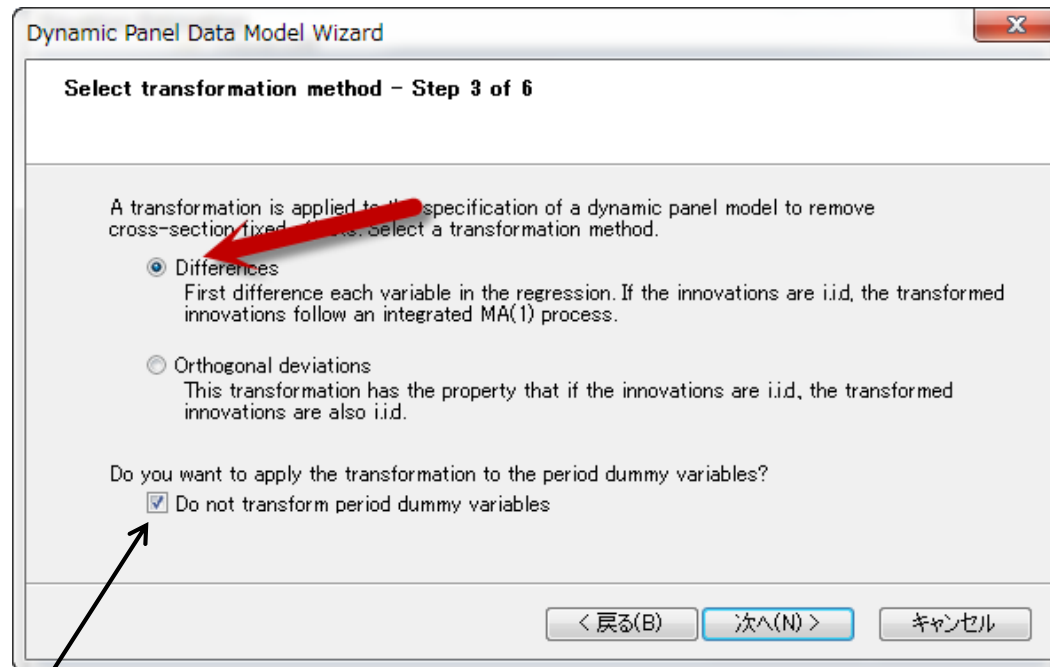
w w(-1) k ys ys(-1)

操作7: 時点ダミーを利用します。Include period dummy variables をチェックして「次へ」をクリックします。



ダイナミックパネル

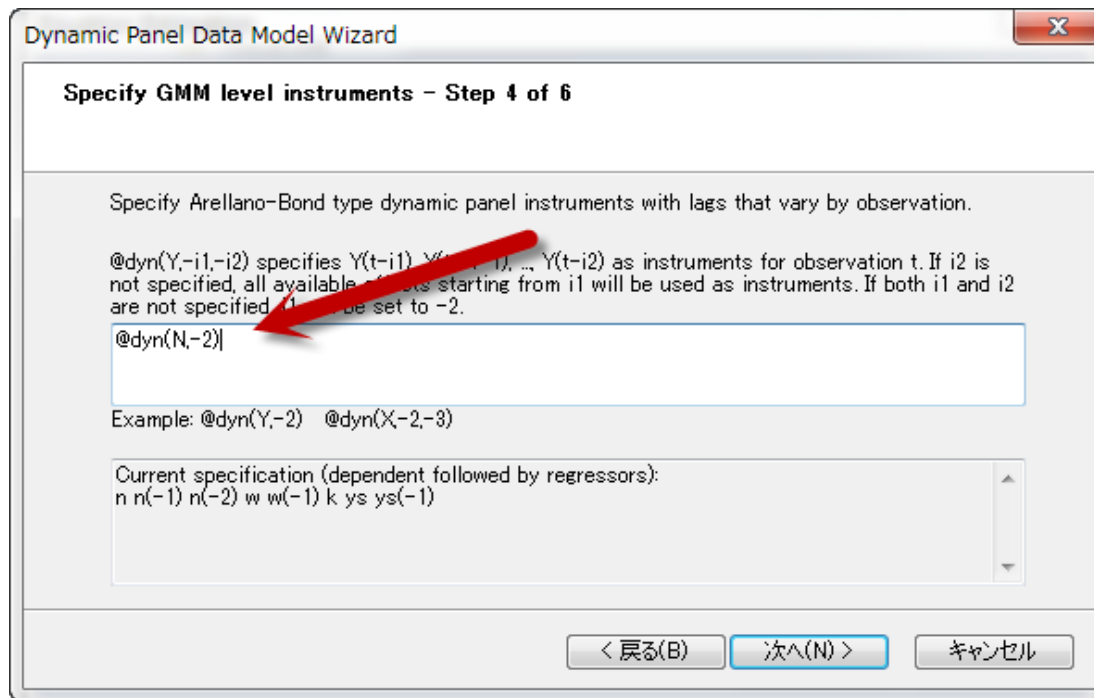
操作8: 「Difference」を選択し、クロスセクション方向の固定効果を削除します。そして「次へ」をクリックします。



時点ダミーを選択した場合、自動的に「ダミー変数は変換しない」というオプションのチェックを付けます。

ダイナミックパネル

操作9: 時点について操作変数を設定します。ここではnのラグ項をそのまま、操作変数とします。



時点ダミーを選択した場合、自動的に「ダミー変数は変換しない」というオプションのチェックを付けます。

ダイナミックパネル

操作10: 一般的な操作変数を設定します。ここでは階差を取る選択をしていますので、左側のダイアログに入力し、「次へ」をクリックします。

$c \ w \ w(-1) \ k \ ys \ ys(-1)$

Dynamic Panel Data Model Wizard

Specify regular instruments - Step 5 of 6

List all other instruments in one of the following edit boxes, depending on whether you wish to apply the transformation to the instrument.

Transform (differences):
c w w(-1) k ys ys(-1)

No transformation:

Note: the period dummies will automatically be added to the no-transformation list.

Current specification (dependent followed by regressors):
n n(-1) n(-2) w w(-1) k ys ys(-1)

< 戻る(B) 次へ(N) > キャンセル

通常はダイアログ下にある情報を入力します。

ダイナミックパネル

操作11:加重行列の設定を行います。ここは難しい所です。ここでは変更せずに「次へ」をクリックします。

Dynamic Panel Data Model Wizard

Select estimation method - Step 6 of 6

Dynamic panel data models are estimated by GMM. Specify the number of iterations, the weighting matrix, and a method to compute standard errors.

GMM iterations: 2-step (update weights once)

GMM weighting matrix:

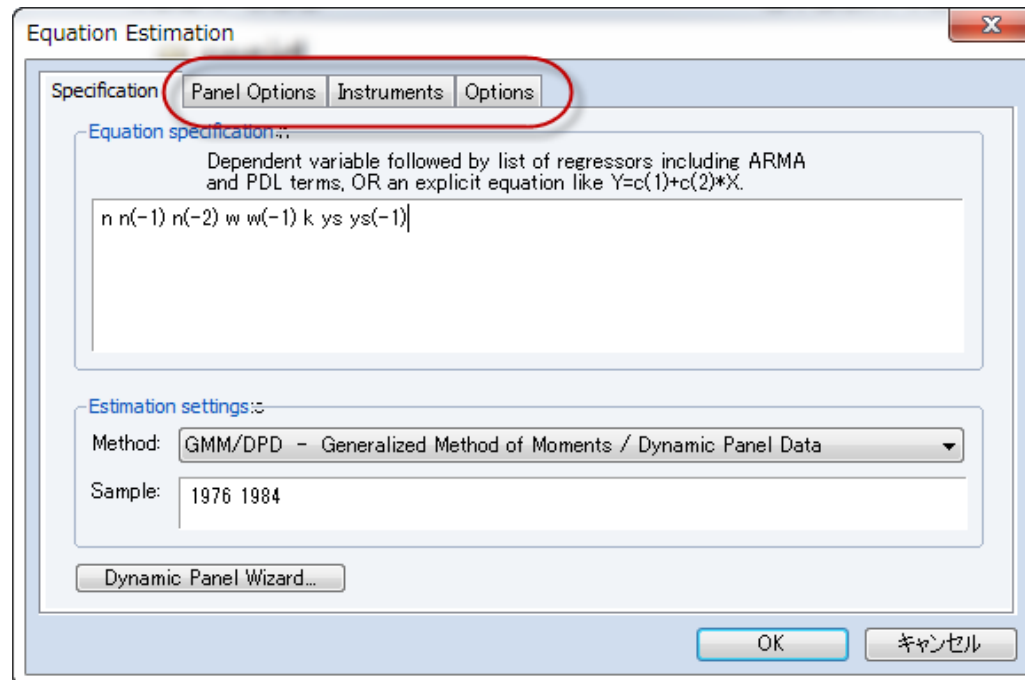
- Period SUR
(innovations have same time series correlation structure for all cross-sections)
- White period
(innovations have time series correlation structure that varies by cross-section)

Standard errors:
Robust - White period weights from final iteration

< 戻る(B) 次へ(N) > キャンセル

ダイナミックパネル

操作12: すべての操作が完了すると、選択項目を反映した推定のダイアログを表示します。



操作13: 各オプションタブの内容を確認したら、OKボタンをクリックし、推定を実行します。

サーガンテスト

パネルデータによるモデル推定のEquationオブジェクトに用意されている検定機能は系列相関の検定だけで、外生性に関するものは無い。

操作1:手作業でサーガンテスト(操作変数の外生性の検定)を実行します。

```
scalar pval=@chisq(30.11247,25)
```

自由度=操作変数のランク(個数)-パラメータの個数

帰無仮説:採用した過剰識別の状態の操作変数は適切である。

まとめ

- 説明変数と誤差項の相関
- TSLSと一致性
- TSLS後の診断(直交性、内生性、弱相関)
- LIML(TSLSよりも優れる場合がある)
- LIMLとGMMはTSLSとは違う方法でIVを利用する
- GMMの利点?
- ダイナミックパネル

参考文献

- Stock and Watson (2015) “Introduction to Econometrics”
- 飯塚信夫、加藤久和「EViewsによる経済予測とシミュレーション入門」、日本評論社
- 縄田和満、「EViewsによる計量経済分析入門」、朝倉書店
- 松浦克己、コリン・マッケンジー「EViewsによる計量経済分析」、東洋経済新報社
- 山本 拓、「計量経済学」、新世社