

第7章 ダミー変数

7.1 異常値ダミー

データに異常値が含まれている場合，経済構造がある時期から変化した場合，ダミー変数を使う。

ダミー変数とは，0と1から成る変数のことである。

例えば，データが20期間あるとして，9期目のデータが，回帰直線から離れている場合(異常値の場合)を考える。

$$D_i = \begin{cases} 0, & i \neq 9 \text{ のとき} \\ 1, & i = 9 \text{ のとき} \end{cases}$$

という変数を作り，

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


を推定する。 δ の推定値 $\hat{\delta}$ の有意性を調べることによって，異常値かどうかの検定ができる。

数値例： 今までと同様に，以下の数値例をとりあげる。

i	Y_i	X_i	D_i
1	6	10	0
2	9	12	0
3	10	14	0
4	10	16	0
5	20	12	1

第5期目が異常値である。

図 3 : 異常値



(A) は $i = 1, 2, 3, 4$ のデータを使って、推定した回帰直線である。(B) は $i = 1, 2, 3, 4, 5$ のデータを使って、推定した回帰直線である。(A), (B) の推定結果は以下のとおりである。

$$(A): Y_i = \begin{array}{c} 0.3 \\ (0.095) \end{array} + \begin{array}{c} 0.65 \\ (2.708) \end{array} X_i, \\ R^2 = 0.786, \quad s^2 = 1.072^2,$$

$$(B): Y_i = \begin{array}{c} 8.54 \\ (0.49) \end{array} + \begin{array}{c} 0.19 \\ (0.14) \end{array} X_i, \\ R^2 = 0.007, \quad s^2 = 6.09^2,$$

ただし、係数の推定値の下の括弧内は t 値を表すものとする。

このように、結果が大幅に変わる。第5期は異常値なので、ダミー変数を用いて、

$$Y_i = \alpha + \beta X_i + \gamma D_i + u_i,$$

として推定を行う。 $i = 1, 2, 3, 4$ について, $D_i = 0$ とし, $i = 5$ について, $D_i = 1$ とする変数である。この回帰式の意味は,

$$Y_i = \begin{cases} \alpha + \beta X_i + u_i, & i = 1, 2, 3, 4 \text{ のとき,} \\ (\alpha + \gamma) + \beta X_i + u_i, & i = 5 \text{ のとき,} \end{cases}$$

となる。推定結果は,

$$Y_i = \underset{(0.095)}{0.3} + \underset{(2.708)}{0.65} X_i + \underset{(9.73)}{11.9} D_i,$$

$$R^2 = 0.979, \quad s^2 = 1.072^2,$$

となる。この場合, $\hat{Y}_5 = Y_5$, すなわち, $\hat{u}_5 = 0$ となることに注意。

7.2 構造変化ダミー

次に, 9 期目以前と以降とで, 経済構造が変化している場合を考える。

$$D_i = \begin{cases} 0, & i = 1, 2, \dots, 8 \text{ のとき} \\ 1, & i = 9, 10, \dots, 20 \text{ のとき} \end{cases}$$

という変数を作り，

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

を推定する(定数項だけが変化したと考えた場合)。または，

$$Y_i = \alpha + \delta D_i + \beta X_i + \gamma D_i X_i + u_i$$

を推定する(定数項も係数も変化)。

δ や γ の推定値の有意性を調べることによって，構造変化の検定を行うことができる。

上の例でデータを示すと，

i	Y_i	X_i	D_i	$D_i X_i$
1	Y_1	X_1	0	0
2	Y_2	X_2	0	0
\vdots	\vdots	\vdots	\vdots	\vdots
8	Y_8	X_8	0	0
9	Y_9	X_9	1	X_9
10	Y_{10}	X_{10}	1	X_{10}
\vdots	\vdots	\vdots	\vdots	\vdots
20	Y_{20}	X_{20}	1	X_{20}

となる。

7.3 季節ダミー

季節性のあるデータを扱う場合，

$$D_{li} = \begin{cases} 1, & i \text{ が第一四半期のとき} \\ 0, & \text{他} \end{cases}$$

$$D_{2i} = \begin{cases} 1, & i \text{ が第二四半期のとき} \\ 0, & \text{他} \end{cases}$$

$$D_{3i} = \begin{cases} 1, & i \text{ が第三四半期のとき} \\ 0, & \text{他} \end{cases}$$

という3つのダミー変数を作り、

7.4 地域差ダミー

関西と関東とで賃金格差があるかどうかを調べたい。

$$w_i = \alpha + \beta D_i + \cdots + u_i$$

添え字 i は個人を表すものとする。

$$D_i = \begin{cases} 1, & i \text{ 番目の人が関東に住んでいるとき} \\ 0, & i \text{ 番目の人が関西に住んでいるとき} \end{cases}$$

7.5 男女別ダミー

男女間で賃金格差があるかどうかを調べたい。

$$w_i = \alpha + \beta D_i + \cdots + u_i$$

添え字 i は個人を表すものとする。

$$D_i = \begin{cases} 1, & i \text{ 番目の人が女性るとき} \\ 0, & i \text{ 番目の人が男性るとき} \end{cases}$$

第8章 関数型について

線型：

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

この場合，

$$\beta = \frac{dY_i}{dX_i}$$

なので， β は， X_i が一単位上昇（下落）したとき， Y_i は何単位上昇（下落）するのかを表す。すなわち， β は限界係数と呼ばれる。

成長率：

$$100 \times \frac{Y_i - Y_{i-1}}{Y_{i-1}} = \alpha + \beta X_i + u_i,$$

として、成長率を被説明変数として用いる場合もある。 $100 \times \frac{Y_i - Y_{i-1}}{Y_{i-1}}$ という変数をあらかじめ作っておき、これをこれまでの Y_i として扱う。

注意：

$Y_i = \alpha + \beta X_i + u_i$ と $100 \times \frac{Y_i - Y_{i-1}}{Y_{i-1}} = \alpha + \beta X_i + u_i$ では、得られる決定係数の大きさが全く異なる。単純に、 R^2 や \bar{R}^2 による比較はこの場合出来ない。
 $\Rightarrow s^2$ で比較すればよい。

対数線型：

$$\log(Y_i) = \alpha + \beta \log(X_i) + u_i,$$

この場合，

$$\beta = \frac{d \log(Y_i)}{d \log(X_i)} = \frac{\frac{dY_i}{Y_i}}{\frac{dX_i}{X_i}} = \frac{100 \frac{dY_i}{Y_i}}{100 \frac{dX_i}{X_i}}$$

となる。

2つ目の等号では， $\frac{d \log(Y_i)}{dY_i} = \frac{1}{Y_i}$ が利用される。

3つ目の等号の分子 $100 \frac{dY_i}{Y_i}$ や分母 $100 \frac{dX_i}{X_i}$ は上昇率を表す。

したがって， β は， X_i が1%上昇(下落)したとき， Y_i は何%上昇(下落)するのかを表す。 β は弾力性と呼ばれる。

例：コブ＝ダグラス型生産関数：

$$Q_i = \beta_1 K_i^{\beta_2} L_i^{\beta_3}$$

ただし， Q_i は生産量， K_i は資本， L_i は労働である。この場合，対数変換によって，

$$\log(Q_i) = \beta_1' + \beta_2 \log(K_i) + \beta_3 \log(L_i) + u_i,$$

として, $\log(Q_i)$, $\log(K_i)$, $\log(L_i)$ のデータをあらかじめ変換しておき, 最小二乗法で $\beta'_1, \beta_2, \beta_3$ を推定する。また, 生産関数には一次同次の制約 $\beta_2 + \beta_3 = 1$ を置く場合が多い。この場合は,

$$\begin{aligned}\log(Q_i) &= \beta'_1 + \beta_2 \log(K_i) + \beta_3 \log(L_i) \\ &= \beta'_1 + \beta_2 \log(K_i) + (1 - \beta_2) \log(L_i) + u_i \\ &= \beta'_1 + \beta_2(\log(K_i) - \log(L_i)) + \log(L_i) + u_i,\end{aligned}$$

となるので,

$$\log(Q_i) - \log(L_i) = \beta'_1 + \beta_2(\log(K_i) - \log(L_i)) + u_i,$$

を最小二乗法で推定し, β'_1, β_2 を求めることになる。この場合も同様に, 各変数をあらかじめ, $\log(Q_i) - \log(L_i)$, $\log(K_i) - \log(L_i)$ としてデータを作っておく必要がある。

二次式:

$$Y_i = \alpha + \beta X_i + \gamma X_i^2 + u_i,$$

⇒ 平均費用と生産量との関係等

逆数：

$$Y_i = \alpha + \beta \frac{1}{X_i} + u_i,$$

⇒ 賃金上昇率と失業率との関係（フィリップス曲線）

遅れのある変数： 習慣的効果を考慮に入れたモデル：

$$Y_i = \alpha + \beta X_i + \gamma Y_{i-1} + u_i,$$

ラグ付き内生変数が説明変数に用いられる。

X_i の Y_i への効果は、短期効果、長期効果の2つある。 β は短期効果を表す係数である。長期効果とは、 $Y_i = Y_{i-1}$ となるときの、 X_i から Y_i への影響を示す効果である。

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

として、 Y_i について解くと、

$$Y_i = \frac{\alpha}{1-\gamma} + \frac{\beta}{1-\gamma} X_i + \frac{1}{1-\gamma} u_i,$$

となり、 $\frac{\beta}{1-\gamma}$ が X_i の Y_i への長期効果を表す係数となる。

問題点：

1. 最小二乗法の仮定の一つに、説明変数は確率変数ではないという仮定がある。ラグ付き内生変数を説明変数に加えることによって、この仮定が満たされなくなる。最小二乗推定量は最小分散線型不偏推定量ではなくなる。
2. Y_i と X_i とは、経済理論的に考えると、相関が高いはず。 Y_i と Y_{i-1} は相関が高い。当然、 Y_{i-1} と X_i も高い相関を示す。
⇒ 多重共線性の可能性が高い。
3. DW 統計量は意味をなさない。(DW については、後述)

遅れのある変数の解釈 (部分調整モデル)： X_i が与えられたときの Y の最適水準を Y_i^* とする。

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

現実の水準 Y_i は、最適水準 Y_i^* と前期の水準 Y_{i-1} との差の一定割合と前期の水準 Y_{i-1} との和で与えられるとする。調整関数を考える。

$$Y_i - Y_{i-1} = \lambda(Y_i^* - Y_{i-1}) + u_i,$$

ただし、 u_i は互いに独立で同一な分布の誤差項、 $0 < \lambda < 1$ とする。

よって、

$$Y_i = \lambda\alpha + \lambda\beta X_i + (1 - \lambda)Y_{i-1} + u_i,$$

を得る。

Y_{i-1} と u_i との相関はない。

しかし、 Y_{i-1} が説明変数の一つに入っている（説明変数間が確率変数でないという仮定に反する）。

推定量は不偏推定量ではないが、一致推定量である（証明略）。

第9章 雑多なこと

9.1 系列相関：DW について

9.1.1 DW について

最小自乗法の仮定の一つに、「攪乱項 u_1, u_2, \dots, u_n はそれぞれ独立に分布する」というものがあった。ダービン・ワトソン比 (DW) とは、誤差項の系列相関、すなわち、 u_i と u_{i-1} との間の相関の有無を検定するために考案された。

⇒ 時系列データのときのみ有効

u_1, u_2, \dots, u_n の系列について、それぞれの符号が、+++-----++-----++のように、プラスが連続で続いた後で、マイナスが連続で続くというような場

合, u_1, u_2, \dots, u_n は正の系列相関があると言う。また, $+-+-+-$ のように交互にプラス, マイナスになる場合, u_1, u_2, \dots, u_n 負の系列相関があると言う。

特徴: u_1, u_2, \dots, u_i から u_{i+1} の符号が予想できる。 \Rightarrow 「 u_1, u_2, \dots, u_n はそれぞれ独立に分布する」という仮定に反する。

すなわち, ダービン・ワトソン比とは, 回帰式が

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

$$u_i = \rho u_{i-1} + \epsilon_i,$$

のときに, $H_0: \rho = 0, H_1: \rho \neq 0$ の検定である。ただし, $\epsilon_1, \epsilon_2, \dots, \epsilon_n$ は互いに独立とする。

ダービン・ワトソン比の定義は次の通りである。

$$DW = \frac{\sum_{i=2}^n (\hat{u}_i - \hat{u}_{i-1})^2}{\sum_{i=1}^n \hat{u}_i^2}$$

DW は近似的に, 次のように表される。

$$DW = \frac{\sum_{i=2}^n (\hat{u}_i - \hat{u}_{i-1})^2}{\sum_{i=1}^n \hat{u}_i^2} = \frac{\sum_{i=2}^n \hat{u}_i^2 - 2 \sum_{i=2}^n \hat{u}_i \hat{u}_{i-1} + \sum_{i=2}^n \hat{u}_{i-1}^2}{\sum_{i=1}^n \hat{u}_i^2}$$