

集計データによる偏よりについて

中山 慶一郎

1. 問題の所在

回帰分析において、個別データの使用が可能な時、縮約された集計データを用いることが多い。例えば、個々の世帯の調査データを用いてエンゲル関数を推定する場合のモデルは

$$Y_i = \alpha + \beta X_i + \varepsilon_i \quad i=1, 2, \dots, n \quad (1.1)$$

で表わされる。 X_i は独立変数で各世帯の所得を示し、 Y_i は X_i に対応する世帯の支出である、 ε_i は誤差項で、 α 、 β は推定すべきパラメータである。集計データでは、通常平均データを用いることが多い。そのモデルは

$$\bar{Y}_g = \alpha + \beta \bar{X}_g + \bar{\varepsilon}_g \quad g=1, 2, \dots, n \quad (1.2)$$

であり、独立変数 $\bar{X}_g$ は、あるグループ g の世帯の平均所得であり、従属変数 $\bar{Y}_g$ は同じグループの平均支出である。

集計データでは情報が縮約されているためにパラメータの推定に偏り (bias) が生ずる。これを集積による偏り (aggregation bias) という。集団レベルのモデル (macro model) から、個人レベルのモデル (micro model) を推論するときには誤まった推論を行うことが多い。この小論はこの点を明確にしようと試みるものである。

2. モデルの設定

ここで取りあげるモデルは独立変数が1つのときと、2つの場合に限定して議論する。

最も単純な場合として1変数モデルを考える。ミクロモデルとして

$$Y_i = \alpha + \beta X_i + \varepsilon_i \quad i=1, 2, \dots, n \quad (2.1)$$

ただし、 i はデータ数を示す。

マクロモデルとして

$$\bar{Y}_g = \alpha + \beta \bar{X}_g + \bar{\varepsilon}_g \quad g=1, 2, \dots, G \quad (2.2)$$

とする。ただし、 g は分類のグループとする。ここで誤差項 ε_i 、 $\bar{\varepsilon}_g$ について、以下の仮定を定める。

$$(1) \quad E(\varepsilon_i) = E(\bar{\varepsilon}_g) = 0$$

$$(2) \quad E(\varepsilon_i \varepsilon_j) = \begin{cases} 0 & i \neq j \\ \sigma^2 & i = j \end{cases}$$

$$E(\bar{\varepsilon}_g \bar{\varepsilon}_k) = \begin{cases} 0 & g \neq k \\ \frac{\sigma^2}{n_g} & g = k \end{cases}$$

$$(3) \quad E(X_i \varepsilon_i) = 0$$

$$E(\bar{X}_g \bar{\varepsilon}_g) = 0$$

これらの仮定は通常誤差項に設定されるものと同じである。(2)は誤差項が互いに独立で、分散は

homoscedasticity の場合パラメータの推定量は有効 (efficient) であるが、heteroscedasticity のときは、有効ではない。

パラメータ β の推定量 b_{YX} が不偏推定であることは、次のようにして証明される。 $Y_i = \alpha + \beta X_i + \varepsilon_i$ 、 $\bar{Y} = \alpha + \beta \bar{X} + \bar{\varepsilon}$ とすれば、 $Y_i - \bar{Y} = y$ 、 $X_i - \bar{X} = x$ 、 $\varepsilon_i - \bar{\varepsilon} = \varepsilon$ とすれば、 $y = \beta x + \varepsilon$ となる。従って

$$b_{YX} = \frac{\sum xy}{\sum x^2} = \frac{\sum x(\beta x + \varepsilon)}{\sum x^2} = \beta + \frac{\sum x\varepsilon}{\sum x^2} = \beta + \frac{s(x, \varepsilon)}{s(x^2)}$$

となる。ここで $s(x, \varepsilon)$ は独立変数 X と誤差項の共分散であり、 $s(x^2)$ は X の分散である。

$$E(b_{YX}) = \beta + E\left[\frac{s(x, \varepsilon)}{s(x^2)}\right]$$

従って仮定(3)が成立すると、上式の右辺の第2項は零となり、 $E(b_{YX}) = \beta$ となって不偏推定であることがわかる。

マクロモデルも同様に $E(\bar{b}_{YX}) = \beta$ となる。

個々のマイクロモデルで同一である(homoscedasticity)。マクロモデルでは分散は $\frac{\sigma^2}{n_g}$ でグループ毎に異なる(heteroscedasticity)。各グループのデータ数が等しいとき、 $N_g = n$ ($g=1, 2, \dots, G$) ならば等分散性(homoscedasticity)が成立する。仮定(3)は独立変数 X が固定した数である非確率変数であることを意味している。この仮定が成立しないときは、パラメータ β の推定量は偏よりが生じ、誤差項 ϵ と独立変数 X に相関のある変数がモデルから落ちていることを意味する。

モデルの設定には定式化誤差(specification error)が発生する。モデルが定式化誤差を持たないということは、方程式の誤差項と独立変数とが相関を持たないことであり、仮定(3)が成立する。従って定式化誤差を持つモデルは必要な独立変数がモデルにとり入れられていない場合であり、仮定(3)が成立しない。この定式化誤差の大きさは、モデルが正しいときのパラメータの不偏推定量と、モデルが正しくないときのパラメータの偏よった推定量の期待値の差に等しくなる。

次にデータのグループ化による集計の偏よりについて考えよう。モデル(2.2)は集計データによるものであるが、データのグループ化には四つのパターンが考えられる[3]。

- (1)独立変数 X の値によるグループ化。
- (2)誤差項 ϵ の値によるグループ化。
- (3)従属変数 Y の値によるグループ化。
- (4) X と Y と相関のある変数 Z の値によるグループ化。

(1)と(2)によるグループ化は定式化誤差をもたらさないが、(3)と(4)によるものは定式化誤差をもたらす。したがって集計による偏よりは定式化誤差によって表わされる。

以下ではマイクロモデルが正しい場合と正しくない場合について、四つのグループ化に関する偏より(bias)について考察することにする。

3. 正しく設定されたマイクロモデルにおける集計の偏より

マイクロレベルにおける正しいモデルを

$$Y = \beta X + \epsilon \quad (3.1)$$

とし、マクロレベルにおけるモデルを

$$\bar{Y} = \beta \bar{X} + \bar{\epsilon} \quad (3.2)$$

とする。誤差項 ϵ についての仮定は

$$E(\epsilon) = 0, V(\epsilon) = \sigma^2, E(X, \epsilon) = 0$$

である。(3.1)の β の推定量 b_{yx} を最小2乗法で求めると、

$$b_{yx} = \beta + \frac{\sum X \epsilon}{\sum X^2}$$

となり、期待値をとると

$$E(b_{yx}) = \beta + E\left[\frac{s(x, \epsilon)}{s(x^2)}\right] \quad (3.3)$$

従って正しいマイクロモデルは

$$E(b_{yx}) = \beta \quad (3.4)$$

となり不偏推定量が得られる。集計データを用いるマクロモデル(3.2)の β の推定量も

$$E(\bar{b}_{yx}) = \beta + E\left[\frac{s(\bar{x}, \bar{\epsilon})}{s(\bar{x}^2)}\right] \quad (3.5)$$

となり、 $E[s(\bar{x}, \bar{\epsilon})]$ が零であるかないかによって偏よりが生じるかということになる。

(a). 独立変数 x の値によるグループ化。

独立変数 X による分類は、マイクロレベルでは X と ϵ は相関をもたないと仮定されているので独立変数と誤差項は独立である。マクロレベルでも X によって分類された $\bar{X}$ と $\bar{\epsilon}$ は相関をもたず独立である。例えば所得水準 Y が両親の社会経済的地位 X によって決まるモデルを考えたとき、住居地域で分類したデータを用いると、住居地域による分類が社会経済階層による分類に近似しているものと考えられる。同じ地域のデータは比較的同質で誤差項と独立変数 X とは相関を持たないと仮定出来る。即ち、 $E[s(\bar{x}, \bar{\epsilon})] = 0$ で $E[b_{yx}] = E[\bar{b}_{yx}] = \beta$ となる。

(b). 誤差項 ϵ の値による分類。

データが誤差項の値によって分類することは、データをランダムに分類することを意味する。実験データの分類のような特殊な場合しか、このような分類は行われぬ。社会調査データにこのような分類がなされることはほとんどない。ランダム分類であるので誤差項の仮定(3)は満されている。 $E[s(\bar{x}, \bar{\epsilon})] = 0$ で β の推定量は不偏である。

(c). 従属変数 Y の値による分類。

前述の例で従属変数である所得水準 Y でデータを分類すれば、両親の社会経済的地位 X と相関が

生じ、その結果 $\bar{X}$ と $\bar{\varepsilon}$ との間に相関が生じる。従って、 $E[s(\bar{x}, \bar{\varepsilon})] \neq 0$ で β の推定量 $\bar{b}_{yx}$ の期待値は、

$$E(\bar{b}_{yx}) = \beta + E\left[\frac{s(\bar{x}, \bar{\varepsilon})}{s(\bar{x}^2)}\right]$$

であるから、 $\bar{X}$ と $\bar{\varepsilon}$ の相関が正か負になるにつれて、 $E(\bar{b}_{yx})$ はパラメータ β より大きくなったり、小さくなったりする偏りを生ずることになる。その偏りの大きさは

$$|\beta - E(\bar{b}_{yx})| = \left| E\left[\frac{s(\bar{x}, \bar{\varepsilon})}{s(\bar{x}^2)}\right] \right| \quad (3.6)$$

となる。Y による分類は Y の値の変動に応じて X と ε の値が変動する。

(d) 従属変数 Y と独立変数 X によらない変数 Z の値による分類。

X, Y 以外の第 3 の変数 Z に従って分類された場合、マクロモデルの正しい定式化は独立変数 $\bar{Z}$ を導入して

$$\bar{Y} = \alpha + \beta_{yx \cdot z} \bar{X} + \beta_{yz \cdot x} \bar{Z} + \bar{\varepsilon} \quad (3.7)$$

となる。このとき

$$E(\bar{b}_{yx \cdot z}) = E(b_{yx}) = \beta$$

となるので、 $\beta_{yx \cdot z}$ の推定量 $\bar{b}_{yx \cdot z}$ は不偏でありマイクロモデルの推定量に等しい。ここでマクロモデルで独立変数 $\bar{Z}$ を除いて

$$\bar{Y} = \alpha + \beta_{yx} \bar{X} + \bar{\varepsilon} \quad (3.8)$$

とすれば、マクロモデルは誤まって定式化されたものとなる。すなわち、適切な説明変数を省略した為に生じる定式化誤差 (specification error) が発生する。

$$Y = \alpha + \beta_{yx \cdot z} X + \beta_{yz \cdot x} Z + \varepsilon \quad \text{とすると}$$

$$E(b_{yz \cdot x}) = E\left[\frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sum (X - \bar{X})^2}\right] \quad (3.8)$$

$$Y - \bar{Y} = \beta_{yx \cdot z} (X - \bar{X}) + \beta_{yz \cdot x} (Z - \bar{Z}) + (\varepsilon_1 - \bar{\varepsilon})$$

を (3.8) に代入すると

$$E(b_{yz \cdot x}) = \beta_{yx \cdot z} + \beta_{yz \cdot x} E\left[\frac{\sum (X - \bar{X})(Z - \bar{Z})}{\sum (X - \bar{X})^2}\right] \quad (3.9)$$

従って誤差の大きさは

$$E(b_{yx}) - \beta_{yx \cdot z} = \beta_{yz \cdot x} b_{zx} \quad (3.10)$$

となる。マイクロモデルでは、 $Y = \alpha + \beta_{yx} X + \varepsilon$ が正しいモデルであるので $\beta_{yz \cdot x} = 0$ となるが、マクロモデルでは $\bar{X}$ と $\bar{Z}$ との間に相関が生ずるので、 $\bar{b}_{zx} \neq 0$ でなく、定式化誤差が生じ、その大

きさは

$$E(\bar{b}_{yx}) - \beta_{yx \cdot z} = \beta_{yz \cdot x} \bar{b}_{zx}$$

となる。マクロモデルでは Z の大きさに従って X が分類されるために $\bar{b}_{zx}$ は零にならない。マクロモデルより除いた説明変数 Z と、モデルに含まれている説明変数が独立であれば、 $\bar{b}_{yx}$ は不偏であるが、Z によって分類されるため一般に X と Z は相関をもつ。 $\bar{b}_{yx}$ の偏りの方向は、 $\beta_{yz \cdot x}$ の符号によって決まる。

4. 誤まって設定されたマイクロモデルにおける集計の偏り。

マイクロレベルにおける正しいモデルは

$$Y = \alpha + \beta_{yx \cdot z} X + \beta_{yz \cdot x} Z + u \quad (4.1)$$

で、誤まったモデルは

$$Y = \alpha + \beta_{yx} X + v \quad (4.2)$$

とする。

マクロレベルにおける正しいモデルは

$$\bar{Y} = \alpha + \beta_{yx \cdot z} \bar{X} + \beta_{yz \cdot x} \bar{Z} + \bar{u} \quad (4.3)$$

で、誤まったモデルは

$$\bar{Y} = \alpha + \beta_{yx} \bar{X} + \bar{v} \quad (4.4)$$

とする。このときマイクロモデルの定式化誤差は

$$E(b_{yx}) - \beta_{yx \cdot z} = \beta_{yz \cdot x} b_{zx} \quad (4.5)$$

で、マクロモデルの定式化誤差は

$$E(\bar{b}_{yx}) - \beta_{yx \cdot z} = \beta_{yz \cdot x} \bar{b}_{zx} \quad (4.6)$$

である。集計によるマクロモデルの偏りは、二つのモデルの定式化誤差の差で表わされ、

$$\beta_{yz \cdot x} (\bar{b}_{zx} - b_{zx}) \quad (4.7)$$

である。この場合定式化誤差 (specification bias) は常に存在し、分類による集計の偏り (aggregation bias) はマクロレベルで発生し、 $\beta_{yz \cdot x}$ と $\bar{b}_{zx}$ と b_{zx} の差に依存する。

(a) 独立変数 X による分類

モデルに含まれている独立変数 X によって分類されたデータを考える。この場合 $\bar{b}_{ix}$ と b_{ix} は等しいので集計による偏りは生じない。この点を (4.1), (4.2) で考えてみる。まず Z の X に対する回帰式を

$$Z_i = \beta X_i + w_i \quad (4.8)$$

とする。(4.8) に最小 2 乗法を適用して、 β の推定量 b_{zx} は

$$b_{zx} = \frac{\sum X_i Z_i}{\sum X_i^2} \quad (4.9)$$

となる。ここで

$$\begin{aligned} E(b_{zx}) &= E\left[\frac{\sum X_i Z_i}{\sum X_i^2}\right] = E\left[\frac{\sum X_i (\beta X_i + w_i)}{\sum X_i^2}\right] \\ &= \beta + E\left[\frac{\sum X_i w_i}{\sum X_i^2}\right] \end{aligned}$$

XはWと独立であるので

$$E(b_{zx}) = \beta$$

となる。マクロモデルも同様に

$$E(\bar{b}_{zx}) = \beta$$

となる。従って、 $\beta_{yz \cdot x}(\bar{b}_{zx} - b_{zx}) = 0$ となって、集計による偏よりは存在しない。

(b)省略された独立変数Zによる分類

この場合、モデル(4.2)、(4.4)は定式化誤差が生じその大きさは、 $\beta_{yx \cdot z} b_{zx}$ 、 $\beta_{yz \cdot x} \bar{b}_{zx}$ である。独立変数XはZに従って分類されるので、(a)のときとは異なりZに関連した誤差項wとXは独立にならないので、 $b_{zx} \neq \bar{b}_{zx}$ で分類による誤差(aggregation bias)が生ずる。分類による誤差の大きさは(4.7)によって定まる。

(c). 独立変数と相関をもつ変数による分類。

一般に考えられる分類は他に第三の変数によるものであるが、XとZに相関関係のある変数Aに基づく分類であることが多い。この場合、ミクロの定式化誤差は

$$E(b_{yx}) - \beta_{yx \cdot z} = \beta_{yz \cdot x} b_{zx}$$

で、マクロの定式化誤差は


$$E(\bar{b}_{yx}) - \beta_{yx \cdot z} = \beta_{yz \cdot x} \bar{b}_{zx}$$

であって、分類による集計の偏よりは、

$$\beta_{yz \cdot x} (\bar{b}_{zx} - b_{zx})$$

となる。

このときのモデルとして



と考えると、独立変数間に次のような回帰モデルが考えられる。

$$Z = \beta_{zx \cdot A} X + \beta_{za \cdot x} A + w \quad (4.10)$$

$$Z = \beta_{zx} X + u \quad (4.11)$$

(4.11)から、 β_{zx} の推定量 b_{zx} は

$$\begin{aligned} b_{zx} &= \frac{\sum XZ}{\sum X^2} = \frac{\sum X (\beta_{zx \cdot A} X + \beta_{za \cdot x} A + w)}{\sum X^2} \\ &= \beta_{zx \cdot A} + \beta_{za \cdot x} \cdot \frac{\sum XA}{\sum X^2} + \frac{\sum Xw}{\sum X^2} \end{aligned}$$

となり、XとAは相関があり、Xとwは独立であるので、

$$E(b_{zx}) = \beta_{zx \cdot A} + \beta_{za \cdot x} b_{AX} \quad (4.12)$$

となる。マクロレベルも同様に考えると、

$$E(\bar{b}_{zx}) = \beta_{zx \cdot A} + \beta_{za \cdot x} \bar{b}_{AX} \quad (4.13)$$

となる。

(4.13)を利用すると集計の偏よりは

$$\beta_{yz \cdot x} (\bar{b}_{zx} - b_{zx}) = \beta_{yz \cdot x} \beta_{za \cdot x} (\bar{b}_{AX} - b_{AX}) \quad (4.14)$$

となる。

推定量の変動について

推定量の偏よりの他に考察する必要があるものは推定値の変動の大きさである。この点についてはCramer [1] によって論じられている。

モデルを次のように設定しよう。元のミクロモデルを

$$Y_{ig} = \alpha + \beta X_{ig} + \epsilon_{ig}$$

$$i=1, 2, \dots, n_g; \quad g=1, 2, \dots, G \quad (5.1)$$

とする。添字 ig は g 番目のグループの i 番目のデータを意味する。従って、 $N = \sum n_g$ である。

マクロモデルは

$$\bar{Y}_g = \alpha + \beta \bar{X}_g + \bar{\epsilon}_g \quad (5.2)$$

であり、 $\bar{Y}_g$ 、 $\bar{X}_g$ は g 番目のグループの平均値である。データをグループ化することにより全体のデータの変動は、分散分析の考えに従うと、グループ内分散とグループ間分散との和に分解出来る。

$$\begin{aligned} \sum_i \sum_g (X_{ig} - \bar{X})^2 &= \sum_i \sum_g (X_{ig} - \bar{X}_g)^2 \\ &\quad + \sum_g n_g (\bar{X}_g - \bar{X})^2 \end{aligned} \quad (5.3)$$

(5.3)を利用すると、(5.1)から β の推定量 $\hat{\beta}$ の分散は、

$$\text{Var}(\hat{\beta}) = \frac{\sigma^2}{\sum_i \sum_g (\bar{X}_{ig} - \bar{X})^2} \quad (5.4)$$

となり、(5.2)から β の推定量 $\tilde{\beta}$ の分散は、

$$\text{Var}(\tilde{\beta}) = \frac{\sigma^2}{\sum_g n_g (\bar{X}_g - \bar{X})^2} \quad (5.5)$$

となる。

この二つの分散の比は

$$\frac{\text{Var}(\tilde{\beta})}{\text{Var}(\hat{\beta})} = 1 + \frac{\sum_i \sum_g (X_{ig} - \bar{X}_g)^2}{\sum_g n_g (\bar{X}_g - \bar{X})^2} \quad (5.6)$$

右辺の第2項が分類による推定値の変動の大きさ、即ちデータからの情報量の損失を表わすもので、この比率はグループ間変動とグループ内変動の比である。

次に定式化誤差をもつモデルの推定値の変動について、竹内[2]に従って考察することにする。

正しいモデルを

$$Y_i = \beta_1 X_{1i} + \beta_2 X_{2i} + \varepsilon_i \quad i=1, \dots, n \quad (5.7)$$

とし、誤まったモデルを

$$Y_i = \alpha X_{1i} + u_i \quad i=1, \dots, n \quad (5.8)$$

とする。 u_i は単なる誤差項でないで、 X_2 に対する X_1 の回帰を考える。

$$X_{2i} = \gamma X_{1i} + v_i \quad (5.9)$$

(5.9)に最小2乗法を適用し

$$\gamma = \frac{\sum X_{1i} X_{2i}}{\sum X_{1i}^2} \quad (5.10)$$

となる。

$$\sum v_i X_{1i} = \sum (X_{2i} - \gamma X_{1i}) X_{1i} = 0$$

であるから、 v_i と X_{1i} は独立である。

(5.9)を(5.7)に代入して

$$\begin{aligned} Y_i &= \beta_1 X_{1i} + \beta_2 (\gamma X_{1i} + v_i) + \varepsilon_i \\ &= (\beta_1 + \beta_2 \gamma) X_{1i} + \beta_2 v_i + \varepsilon_i \end{aligned} \quad (5.11)$$

$\beta_1 + \beta_2 \gamma$ の最小2乗推定量は

$$(\hat{\beta}_1 + \hat{\beta}_2 \gamma) = \frac{\sum Y_i X_{1i}}{\sum X_{1i}^2} = \hat{\alpha} \quad (5.12)$$

で、(5.8)の α の推定量に等しい。

$$\text{Var}(\hat{\alpha}) = \frac{\sigma^2}{\sum X_{1i}^2} = \text{Var}(\beta_1 + \beta_2 \gamma)$$

従って、 X_1 と X_2 が独立であれば、 $\gamma = 0$ となって $\text{Var}(\hat{\alpha}) = \text{Var}(\hat{\beta}_1)$ であるが、独立でないときは、 $\text{Var}(\hat{\alpha}) > \text{Var}(\hat{\beta}_1)$ となる。

6. おわりに

本稿は主として「生態学的推論」[3]に従って、集計の偏りについて統計学的な意味づけを述べたものである。LangbeinとLichtmanはこの問題の解決に生態学的回帰を提案しているが、この点はここではふれない。

参考文献

- [1] Cramer, J.S.(1964), "Efficient grouping, regression and correlation in Engel curve analysis", J.A.S.A., 59
- [2] 竹内 啓 (1973) 数理統計学的方法的基礎 東洋経済
- [3] L.I. Langbein and A. J. Lichtman(1978), Ecological Inference. Sage Pub.
(生態学的推論 長谷川政美訳 朝倉書店)