

応用計量経済学(11)

横浜市立大学商学部

松浦 克己

大阪大学国際公共政策研究科 Colin McKenzie

第11章 質的選択モデルとTobitモデル

1 はじめに

(質的選択とは何か)

株式の需要を考えると、家計には株式を保有する(ダミー=1)家計もあれば、株式を保有しない(ダミー=0)家計もある。また消費税について、その増税に賛成する(ダミー=1)人もいれば、賛成しない(ダミー=0)人もいるだろう。このようにある経済主体が特定の行為を行う、行わないというケースが課題となることは多い。このような1またはゼロの選択に関するモデルを質的選択モデル(qualitative response model, QR)ということがある。あるいは1とゼロの離散変数であるので離散選択モデル(discrete choice model)ということもある(言い換えればダミー変数が被説明変数となるケースである)。

このような質的選択モデル分析の必要性に迫られることは、しばしば見受けられる。たとえば自動車の市場調査では、自動車を保有するかどうかは必ずといって良いほど質問されるだろう。世論調査では、ある政策に反対か賛成かは、当然のごとく設問に含まれるであろう。

また株式の需要について考える場合、株式を保有しないサンプル以外に100万円の株式を保有する人もいれば、1億円の株式を保有する人もいる

であろう。このとき株式を保有する人については保有金額と様々な情報(たとえば所得や職業)を知ることができる。株式を所有しない人には所有しないということと所得や職業を知ることができる。需要を考えるとこのゼロ保有ということも有用な情報である。たとえば株式のマーケティングを考えると、誰がいくら株式を保有し、誰が保有しないかを考慮しない担当はいないであろう。このとき需要はゼロで検閲されている(censored)という。このようなデータをセンサーされたデータ(censored data)ということがある。その分析を考案したTobinにちなみトービット・モデル(tobit model)ということがある。

(個票データの利点と問題点)

質的選択モデルやトービット・モデルは大半の場合、アンケート調査など個々の家計や企業に対し行われた質問票を基に分析される。あるいは公開されている上場企業の財務データを用いて行われる。個別の家計や企業に対し調査されたデータの原本を個票データという。わが国の代表的な個票データとしては、家計調査、貯蓄動向調査、全国消費実態調査、国民生活基礎調査、就業構造基本調査などがある。これらは世界的にみても家計の行動を分析する上で貴重な情報を提供している。家計の消費関数、消費需要関数あるいは貯蓄関数、資産選択の分析、さらには家計の労働供給や出産行動にこれらの個票データは不可欠な情報源であ

る。

たとえば家計調査では、世帯主の年齢、性別、職業、(勤労者の場合の)勤め先の産業、企業規模、収入やその内訳を知ることができる。また世帯員についても同様の情報を得ることができる。その上で数百品目に関する消費支出が調査されている。家計の消費支出には世帯主の年齢、性別、職業、勤め先の産業、企業規模、収入等の家計の属性(attribute)が影響するであろう。それらを厳密に把握できるのは個票データだけであるといつて良い。

またこのような個票データ(アンケート調査など)の収集は中央官庁だけではなく、地方自治体や民間企業によって広範囲に行われている。企業が収集しているものの一部は市販されている。

個票データはこのように貴重な情報源であるが、利用に当たっては留意も必要である。その第一点は信頼性の確保である。アンケートには無回答の項目(欠値、missing data)や思い違いで回答したと思われる項目がある¹⁾。これら进行处理する必要がある。たとえばタバコの消費需要関数の分析を試みたとする。世帯主の性別、年齢、職業、家族人員という家計構成の基本的な項目の一つでも無回答があれば、たとえ他の項目に回答していたとしても、そのサンプルの使用は中止することである。というのはこれらの家計属性の基本について回答がなされていない場合、他の項目の回答に信頼性があるとは考えられないからである。もちろん被説明変数や説明変数となる項目について無回答のものもサンプルから除くことになる(第7章参照)。

思い違いというのも、外部からは判断しにくいものである。回答の信頼性の確保の点からは、たとえば過小な消費支出のサンプルを除くことである。いかに節約をしたとしても1ヶ月3万円以下の消費支出で家計が生活できるとは思われない。そのサンプルも、他の項目の回答状況如何に関わらず、使用を中止することである。

企業の財務データを利用するのであれば、資本金、従業員、配当、売上げという企業の基本に関する項目が無回答となっているものも、サンプルから除く必要がある²⁾。

この問題点を処理して、個票データを利用するならば、集計されたデータ(aggregated data)で行うことは困難な貴重な分析が行えるであろう。

2 プロビット・モデル、ロジット・モデル

2.1 OLSによる質的選択モデルの分析

まず被説明変数が1または0という質的選択モデルをOLSで推計することができるかどうかを考えてみよう³⁾。

$$y_i = a + bx_i + u_i \quad (11.1)$$

$y_i = 1$ ある行為を選択する場合
 0 ある行為を選択しない場合

11.1)式をみると $y_i = 1$ の時 $u_i = 1 - a - bx_i$ となり、 $y_i = 0$ の時 $u_i = -a - bx_i$ となるので、 u_i は正規分布に従はない。 $y_i = 1$ の確率($P(y_i = 1)$)を f_i として表記すると

$$E(u_i) = f_i(1 - a - bx_i) + (1 - f_i)(-a - bx_i) \quad (11.2)$$

となる。 $E(u_i) = 0$ になるためには $f_i = a + bx_i$ が成り立つ必要がある。それを仮定すると

1) 無回答(欠値)とゼロ回答は異なる。無回答はその項目(たとえば収入)について回答を拒否するものであるが、ゼロ回答は無収入という意味である。この欠値とゼロ回答を、入力段階で厳密に区別しておく必要がある。

2) 市販されている企業データの一部には、入力ミスと思われるものが混在していることがある。上場企業や金融・保険業で資本金、従業員、配当、売上げは当然に開示されている項目である。これらが無回答ということはあり得ない。これらの項目が無回答(欠値)となっている場合、それは入力ミスが疑われる。そのサンプルの使用はやめるべきである。その比率があまりに高ければデータセット自体の利用を差し控えた方がよい。

3) 1または0の選択を、選択肢が二つであることから二値的選択モデル(binary choice model)ということがある。

$$V(u_i) = f(1 - f_i) \quad (11.3)$$

である。11.1) 式をOLSで推定するとaとbの不偏推定量が得られるが、11.3) 式より分かるように分散不均一性が存在するのでOLSはBLUEではない。

$E(u_i) = 0$ が成り立つのであれば11.1) 式の y_i の期待値は

$$E[y_i] = a + bx_i \quad (11.4)$$

である。11.1) 式の被説明変数は1または0であるから、その期待値も0から1の範囲にとどまる。しかし11.1) 式をOLSで推定し、推定量を使用して11.4) 式の期待値を計算すると x_i の値によっては1を超えたり、負となることがある。これは質的選択モデルの期待値としては意味がない。このために質的選択モデルでOLSが用いられることはない。

2.2 プロビット・モデル、ロジット・モデルの考え方

11.1) 式の確率を求めるものと考え、その関数を

$$P(y_i = 1) = F(a + bx_i) \quad (11.5)$$

とする。11.5) 式から得られる確率が0から1の間となる必要がある。二つの選択しかないので

$$P(y_i = 1) + P(y_i = 0) = 1$$

$$P(y_i = 0) = 1 - P(y_i = 1) = 1 - F(a + bx_i) \quad (11.6)$$

である。 $E(y_i)$ を計算すると

$$\begin{aligned} E(y_i) &= (P(y_i = 1) \cdot 1) + (P(y_i = 0) \cdot 0) \\ &= F(a + bx_i) \end{aligned} \quad (11.7)$$

Fの関数として標準正規分布を選択し、

$$P(y_i = 1) = F(a + bx_i) = \frac{1}{2} + \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{a + bx_i} \exp\left(-\frac{z^2}{2}\right) dz \quad (11.8)$$

ここで Φ は標準正規分布関数を表すものとする。

11.6) 式と11.7) 式より

$$P(y_i = 0) = 1 - F(a + bx_i) \quad (11.9)$$

$$E(y_i) = F(a + bx_i) \quad (11.10)$$

標準正規分布は0から1の範囲におさまるので、

$$\lim_{z \rightarrow \infty} \Phi(z) = 1, \quad \lim_{z \rightarrow -\infty} \Phi(z) = 0 \quad (11.11)$$

となる。これをプロビット・モデル (probit model) という。

Fの関数としてロジスチック分布 (logistic distribution) を選ぶと以下のようなものである。

$$P(y_i = 1) = F(a + bx_i) = \frac{\exp(a + bx_i)}{1 + \exp(a + bx_i)} \quad (11.12)$$

ここで S はロジスチック累積分布関数を表す。

11.6) 式と11.7) 式より

$$P(y_i = 0) = \frac{1}{1 + \exp(a + bx_i)} \quad (11.13)$$

$$E(y_i) = F(a + bx_i) \quad (11.14)$$

この時もFの値は0から1の間となる。これをロジット・モデル (logit model) という⁴⁾。

(尤度関数とマージナル効果)

ある行為を選択する (たとえば自動車を購入する) のは、その行為を選択しない場合 (自動車を購入しない) に比べて効用が高いからであろう。そうすると以下のような因子関数、指標関数 (index function model) を考えることができる。

$$y_i^* = a + bx_i + u_i \quad u_i \sim iid(0, \sigma^2) \quad (11.15)$$

$$y_i = \begin{cases} 1 & \text{if } y_i^* > 0 \\ 0 & \text{otherwise} \end{cases}$$

この場合観測できる変数は y_i と x_i となり、 y_i^* を直接観測することはできない。このモデルを書き直すと

$$\begin{aligned} P(y_i = 1) &= P(y_i^* > 0) = P(a + bx_i + u_i > 0) \\ &= P(u_i > -a - bx_i) \end{aligned} \quad (11.16)$$

となる。正規分布やロジット分布は分布が対称で

4) プロビット・モデルとロジット・モデルのいずれを取るかが課題となりうるが、二値的選択モデルでは両者の差はほとんどないことが知られており、いずれによっても良い。

あるから

$$P(y_i^* > 0) = P(u_i < a + bx_i) = F(a + bx_i) \quad (11.16)$$

となる。で(11.16)式を基準化すると

$$P(y_i = 1) = P(u_i / \sigma > (-a - bx_i) / \sigma) \quad (11.17)$$

となる。(11.16)、(11.17)式をプロビット・モデルとすれば

$$P(y_i = 1) = \Phi((a + bx_i) / \sigma) \quad (11.18)$$

となる。 $P(y_i = 0)$ は(11.16)式より

$$P(y_i = 0) = 1 - \Phi((a + bx_i) / \sigma) \quad (11.18)'$$

で得ることができる。同時確率は尤度関数

$$L = \prod_{y_i=1} \Phi((a + bx_i) / \sigma) \prod_{y_i=0} (1 - \Phi((a + bx_i) / \sigma))$$

で求められる(積を表す)。計算の簡単化のために対数尤度関数を取ると

$$\text{Log}L_i = y_i \text{Log} \Phi((a + bx_i) / \sigma) + (1 - y_i) \text{Log} (1 - \Phi((a + bx_i) / \sigma)) \quad (11.19)$$

$$\text{Log}L = \sum \text{Log}L_i \quad (11.20)$$

である。これを次式のように最大化することでパラメータが求められる⁵⁾。

$$\frac{\text{Log}L_i}{a} = \frac{(y_i - \Phi(a + bx_i))}{(a + bx_i) \Phi(a + bx_i) (1 - \Phi(a + bx_i))} (a + bx_i) \quad (11.21)$$

$$\frac{\text{Log}L_i}{b} = \frac{(y_i - \Phi(a + bx_i))}{(a + bx_i) \Phi(a + bx_i) (1 - \Phi(a + bx_i))} (a + bx_i) x_i \quad (11.22)$$

ここで $\Phi(\cdot)$ は標準正規密度関数

ロジット・モデルは(11.19)式の Φ を σ に置き換えることによって、同様に尤度関数を求めることができる。

プロビット・モデルやロジット・モデルの係数の符号は、それが正(負)であれば、当該変数は正(負)の影響を与えることを示している。しかしその影響の程度(弾性値や限界性向)を示すものではない。説明変数が連続型変数(正確にいう

と微分可能な変数)か離散型変数によってマージナル効果(marginal effect)の計算方法は異なる。マージナル効果は次のように求められる。

まずプロビット・モデルを考えよう。(11.10)式より x_i が連続型変数であれば、

$$\frac{E(y_i)}{x_i} = (a + bx_i) b \quad (11.23)$$

で求められる。 $1 > (a + bx_i) > 0$ なのでマージナル効果の符号と b の符号は合致するが、マージナル効果の絶対値の方が小さい。離散型変数(例えばダミー変数)の場合(11.23)式を適用することができない。モデルがダミー変数を含む

$$y_i^* = a + b_1 x_i + b_2 \text{Dummy}_i + u_i$$

という形であれば、そのダミー変数の効果は

$$\text{Dummy}_i = 1 \text{ の場合 } P(y_i = 1) = \Phi(a + b_1 x_i + b_2) \quad (11.24a)$$

$$\text{Dummy}_i = 0 \text{ の場合 } P(y_i = 1) = \Phi(a + b_1 x_i) \quad (11.24b)$$

の差、

$$(a + b_1 x_i + b_2) - (a + b_1 x_i) \quad (11.24c)$$

として求められる。 b_2 が正(負)であればこの差も正(負)になる。

(11.15)式のロジット・モデルを考えよう。 x_i が連続型変数であればマージナル効果は、

$$p_i = \frac{\exp(a + bx_i)}{1 + \exp(a + bx_i)}$$

として(11.14)式より

$$\frac{E(y_i)}{x_i} = p_i (1 - p_i) b \quad (11.25)$$

で求められる。 $1 > p_i > 0$ と $1 > p_i (1 - p_i) > 0$ なので、マージナル効果の符号と b の符号は合致するが、マージナル効果の絶対値の方が小さい。ダミー変数の場合は、(11.24)式のような形で計算することができる。

5) このモデルにおいて a 、 b と σ を識別できないが、 a/σ 、 b/σ を識別できるので σ を1に基準化することが通常である。

また11.15) 式のプロビットモデルの場合、ある説明変数(x)が x_i から $x_i + \Delta x_i$ に変動したとき、選択確率に与える影響は

$$(a + b(x_i + \Delta x_i)) - (a + bx_i) \quad (11.26)$$

でみることができる。

(モデルの適合度)

質的選択モデルでは、通常推計された $\hat{P}_i = F(a + b x_i) > 0.5$ であれば $\hat{y}_i = 1$ 、 $\hat{P}_i < 0.5$ であれば $\hat{y}_i = 0$ として扱う。現実に観察される y_i は1か0であるが、推計された確率が1または0となることはほとんど有りそうにないので、このように考える。

質的選択モデルの適合度として最も簡明なのは、現実に観察される y_i (1または0)と推計された \hat{P}_i から得られた \hat{y}_i (1または0)の比較を行うことである。

たとえばサンプルが100個であるとする。現実に y_i が1であるものが60個、0であるものが40個であるとする。そのとき推計された \hat{y}_i で1となるものが55個(実際にも1であるものが45個、実際には0であるものが10個であったとする)、0となるものが45個(実際にも0であるものが30個、実際には1であるもの15個)がであったとする。次のように整理することができる。

		推計された値		
		1	0	
現実の値	1	45	15	60
	0	10	30	40
		55	45	100

正しく予測された割合は、現実に1であるものについて45/60、現実に0であるものについて30/40、両者の合計では75/100である。これをモデルの適合度とするのが一つの方法である。

もう一つの方法はMcFaddenによって提唱されたMcFaddenの R^2 、あるいは尤度比指標といわれるものである。定数項のみからなるモデル(言い

換えれば説明変数にゼロ制約を加えているモデル)から得られる対数尤度を $\text{Log}L_r$ とし、制約のないモデルから得られる対数尤度を $\text{Log}L_u$ とする。

$$\text{McFaddenの} R^2 = 1 - \frac{\text{Log}L_u}{\text{Log}L_r} \quad (11.27)$$

で求められる。ここで $\text{Log}L_u$ 、 $\text{Log}L_r$ である。モデルが全く説明力がない(定数項以外の全ての係数が0であるという帰無仮説が棄却できないケース)であれば11.27)式は0となる。ただしMcFaddenの R^2 はOLSの決定係数とは全く意味が異なることに留意する必要がある。

3 Eviewsでのプロビット・モデル、ロジット・モデルの推定例

Eviewsでプロビット・モデルやロジット・モデルを推定する場合は、OLSのようにコマンドで行うことができる。また自分で尤度関数を書く形でも行うことができる。ここではコマンドによる形で行ってみる。

女性の就業関数について考える。女性の就業確率は夫の賃金が高くなると、留保賃金の水準が高くなるので、低下することが知られている。また幼児がいると低下することも知られている。これを全国消費実態調査を用い、20歳から59歳の女性についてみてみよう(なお信頼性確保のため過少消費などのサンプルはあらかじめ除いてある)。所得、金融資産、負債は対数值(都道府県別物価指数で実質化した)である。

(プロビット・モデルの推計例)

```
1 workfile c : ¥data¥ework u 1 40000
```

```
2 smpl 1 34246
```

就業の有(=1)無(=0)夫の収入とその自乗、他の世帯員の収入とその自乗

```
3 read c : ¥data¥work2 .txt work husin
```

```
husin2 othin othin2
```

年齢、自乗、金融資産 持ち家ダミー 負債

4 read c : ¥data¥work3.txt age age2 money
mochiya debt

'幼児の有無ダミー、母親同居ダミー、都道府県
別IIP、有効求人倍率

'夫無しダミー

5 read c : ¥data¥work4.txt infant mom iip
yukou husnasi

'金融資産の変化の影響をみるために50%増の変
数を作っておく

6 series monplus = @mean(money)*1.5

論文報告のための記述統計量作成

7 group group1 work husin age age2 money
mochiya debt infant mom iip yukou
husnasi

8 group1 stats

'work* = c + a₁husin + a₂age + a₃age² + a₄money +
a₅mochiya + a₆debt + a₇infant + a₈mom + a₉iip + a₁₀
yukou + a₁₁husnasi + e_i をProbit Modelで推計す
るコマンド

'binaryが二値的選択モデルを推計するコマンド
である(OLSのLSに相当)

9 equation eq1 binary work c husin age age
2 money mochiya debt infnat mom iip
yukou husnasi

'予測値を保存する

10 eq1 fit pfit

'Marginal Effectsの計算

'夫の収入のMarginal Effectsの計算(11.23)式
を参考に

'(XB)を@dnorm(XB)で計算、平均値の回りで
評価する⁶⁾

11 series marxb1 = @dnorm(@coefs(1)+
coefs(2)*@mean(husin)+@coefs(3)*@
mean(age)+@coefs(4)*@mean(age2)+

@coefs(5)*@mean(money)+@coefs(6)*
@mean(mochiya)+@coefs(7)*@mean
(debt)+@coefs(8)*@mean(infant)+@
coefs(9)*@mean(mom)+@coefs(10)*@
mean(iip)+@coefs(11)*@mean(yukou)+
@coefs(12)*@mean(husnasi))*@coefs(2)

'Medianの回りで評価する場合

12 series xbmed = @dnorm(@coefs(1)+@
coefs(2)*@median(husin)+@coefs(3)*@
median(age)+@coefs(4)*@median(age
2)+@coefs(5)*@median(money)+@co-
efs(6)*@median(mochiya)+@coefs(7)*
@median(debt)+@coefs(8)*@median(in-
fant)+@coefs(9)*@median(mom)+@
coefs(10)*@median(iip)+@coefs(11)*@
median(yukou)+@coefs(12)*@median
(husnasi))*@coefs(2)

'ダミー変数(幼児の有無)のMarginal Effects
(11.24)式を参考に)

'(XB)の計算、幼児有りのケース

13 series xbd1 = @cnorm(@coefs(1)+@coefs
(2)*@mean(husin)+@coefs(3)*@mean
(age)+@coefs(4)*@mean(age2)+@coefs
(5)*@mean(money)+@coefs(6)*@mean
(mochiya)+@coefs(7)*@mean(debt)+@
coefs(8)+@coefs(9)*@mean(mom)+@
coefs(10)*@mean(iip)+@coefs(11)*@
mean(yukou)+@coefs(12)*@mean(hus-
nasi))

'(XB)の計算、幼児無しのケース

14 series xbd0 = @cnorm(@coefs(1)+@coefs
(2)*@mean(husin)+@coefs(3)*@mean
(age)+@coefs(4)*@mean(age2)+@co-
efs(5)*@mean(money)+@coefs(6)*@

6) seriesはscalarで本来よいが画面表示を容易にするためにseriesにしてある。

mean(mochiya)+ @ coefs(7)* @ mean
 (debt)+ @ coefs(9)* @ mean(mom)+ @ co-
 efs(10)* @ mean(iip)+ @ coefs(11)* @ mean
 (yukou)+ @ coefs(12)* @ mean(husnasi))

幼児有りダミーのMarginal Effects

15 series maryouji = xbd1 - xbd0

金融資産の変化の効果 (11 26) 式を参考に

金融資産が増加した場合の確率

16 series xbplus = @cnorm(@coefs(1)+ @co-
 efs(2)* @ mean(husin)+ @ coefs(3)* @
 mean(age)+ @ coefs(4)* @ mean(age2)+
 @ coefs(5)* monplus+ @ coefs(6)* @ mean
 (mochiya)+ @ coefs(7)* @ mean(debt)+ @
 coefs(8)* @ mean(infant)+ @ coefs(9)* @
 mean(mom)+ @ coefs(10)* @ mean(iip)+
 @ coefs(11)* @ mean(yukou)+ @ coefs(12)*
 @ mean(husnasi))

平均値の回りでの確率

16 series xb = @cnorm(@coefs(1)+ @coefs
 (2)* @ mean(husin)+ @ coefs(3)* @ mean
 (age)+ @ coefs(4)* @ mean(age2)+ @ coefs
 (5)* @ mean(money)+ @ coefs(6)* @ mean
 (mochiya)+ @ coefs(7)* @ mean(debt)+ @
 coefs(8)* @ mean(infant)+ @ coefs(9)* @
 mean(mom)+ @ coefs(10)* @ mean(iip)+ @
 coefs(11)* @ mean(yukou)+ @ coefs(12)*
 @ mean(husnasi))

金融資産増加による確率の変化

17 series henka = xbplus - xb

プロビットモデルの推計結果は表11.1に掲げ
 るとおりである。

夫の収入 (HUSIN) は 1 %水準で有意に負で
 ある。幼児有りダミー (INFANT) も 1 %水準
 で有意に負である。符号条件を充たしていること

表11.1

Dependent Variable : WORK				
Method : ML Binary Probit				
Date : 12/21/99 Time : 10 : 53				
Sample : 1 34246				
Included observations : 34246				
Convergence achieved after 7 iterations				
Covariance matrix computed using second derivatives				
Variable	Coefficient	Std. Error	z Statistic	Prob.
C	- 1.349776	0.179679	- 7.512144	0.0000
HUSIN	- 0.012874	0.003045	- 4.227270	0.0000
AGE	0.083548	0.007344	11.37598	0.0000
AGE2	- 0.001155	8.64E 05	- 13.36311	0.0000
MONEY	- 0.027060	0.004517	- 5.990598	0.0000
MOCHIYA	0.046752	0.019076	2.450842	0.0143
DEBT	0.030365	0.002512	12.08599	0.0000
INFANT	- 0.918258	0.023324	- 39.36938	0.0000
MOM	0.341694	0.020398	16.75134	0.0000
IIP	- 0.002505	0.001161	- 2.158646	0.0309
YUKOU	0.739655	0.031019	23.84555	0.0000
HUSNASI	0.978617	0.047521	20.59325	0.0000
Mean dependent var	0.510804	S.D. dependent var	0.499891	
S.E. of regression	0.461713	Akaike info criterion	1.228029	
Sum squared resid	7297.976	Schwarz criterion	1.230987	
Log likelihood	- 21015.54	Hannan Quinn criter .	1.228972	
Restr. log likelihood	- 23729.52	Avg. log likelihood	- 0.613664	
LR statistic (11df)	5427.969	McFadden R squared	0.114372	
Probability (LR stat)	0.000000			
Obs with Dep = 0	16753	Total obs	134246	
Obs with Dep = 1	17493			

が分かる。IIPと有効求人倍率は符号 (YUKOU)
 が逆転していることが注目される⁷⁾。

表の下欄に対数尤度 (Log likelihood
 - 21015.54) が表示されている。この対数尤度は
 論文では必ず報告する。McFaddenのR²(0.114)
 も表示されている(これは報告されないことがあ
 る)。

平均値の回りでの夫の収入のマージナル効果
 (marxb1) は - 0.00513であった。メディアンの
 回りでのマージナル効果 (xbmed) は -
 0.005105であった。夫の収入の 1 単位の増加は約
 0.5%女性の就業確率を低下させていることにな
 る。なおマージナル効果の値を報告する時は、そ
 れがどの水準 (平均かメディアンか等) により計

7) プロビット・モデル等最尤法で推計した場合、Eviewsはt値をz Statisticと表示する。これは検定が大標本に基づく漸近的なものであることを示すためである。このときt値を漸近的t値ということがある。

算されたものか報告する必要がある。この場合は大きな差がなかったが、変数によってはかなり異なることがあるからである。

幼児がいる場合の女性の就業確率 (xbd1) は 0.2360であった。幼児がいない場合の就業確率 (xbd0) は0.5789であった。したがって幼児の女性の就業確率に与えるマージナル効果 (maryouji) は -0.3429となる。幼児がいると女性の就業確率は34.3%も低下する。女性の就業に育児が重要な課題となっていることが分かる。

金融資産が平均より50%増加したときの就業確率 (xbplus) は0.4807である。平均値の回りでの就業確率 (xb) は0.5139である。金融資産が50%増加すると就業確率 (henka) は -0.0332低下する。

表11.1の下の方をみると総標本数は34,236人

で就業する女性 (被説明変数が1) は17,493人に対して就業しない女性 (被説明変数が0) は16,753人である。ここで推定したモデルはどの程度適合しているかをみる。

View/Expectation Prediction Tableを選択する。cutoff valueが既定値の0.5で表示されている。それを選択する。結果は表11.2のとおりである。0を0と正しく識別したものが10,120(60.41%)、0を1と誤ったものが6,633(39.59%)である。1を正しく1と識別したものが12,030(68.77%)、0と誤ったのが5,463(31.23%)で両者合計で22,150(64.68%)が正しく識別されている。

(ロジット・モデルの推定例)

ロジット・モデルもプロビット・モデルとほぼ同様である。オプションとして (D=L) を加えればよい。

表11.2

Dependent Variable : WORK						
Method : ML Binary Probit						
Sample : 1 34246						
Included observations : 34246						
Prediction Evaluation (success cutoff C = 0.5)						
	Estimated Equation			Constant Probability		
	Dep = 0	Dep = 1	Total	Dep = 0	Dep = 1	Total
P(Dep = 1) <= C	10120	5463	15583	0	0	0
P(Dep = 1) > C	6633	12030	18663	16753	17493	34246
Total	16753	17493	34246	16753	17493	34246
Correct	10120	12030	22150	0	17493	17493
% Correct	60.41	68.77	64.68	0.00	100.00	51.08
% Incorrect	39.59	31.23	35.32	100.00	0.00	48.92
Total Gain*	60.41	-31.23	13.60			
Percent Gain**	60.41	NA	27.80			
	Estimated Equation			Constant Probability		
	Dep = 0	Dep = 1	Total	Dep = 0	Dep = 1	Total
E(# of Dep = 0)	9450.78	7306.43	16757.21	8195.50	8557.50	16753.00
E(# of Dep = 1)	7302.22	10186.57	17488.79	8557.50	8935.50	17493.00
Total	16753.00	17493.00	34246.00	16753.00	17493.00	34246.00
Correct	9450.78	10186.57	19637.35	8195.50	8935.50	17131.00
% Correct	56.41	58.23	57.34	48.92	51.08	50.02
% Incorrect	43.59	41.77	42.66	51.08	48.92	49.98
Total Gain*	7.49	7.15	7.32			
Percent Gain**	14.67	14.62	14.64			
*Change in "% Correct" from default (constant probability) specification						
**Percent of incorrect (default) prediction corrected by equation						


```

'Logit Modelの推計コマンド
equation eq2 binary(d=1) work c husin age
age2 money mochiya debt infant mom iip
yukou husnasi
'予測値の保存
eq2 fit lwfit
'XBの計算
series marxb1=@coefs(1)+@coefs(2)*@mean
(husin)+@coefs(3)*@mean(age)+@coefs
(4)*@mean(age2)+@coefs(5)*@mean
(money)+@coefs(6)*@mean(mochiya)+@
coefs(7)*@mean(debt)+@coefs(8)*@mean
(infant)+@coefs(9)*@mean(mom)+@coefs
(10)*@mean(iip)+@coefs(11)*@mean(yukou)

```

```

+@coefs(12)*@mean(husnasi)
'p(XB)の計算
series pr=exp(marxb1)/(1+exp(marxb1))
'夫の収入のMarginal Effects (11.25)式を参考
に)
series marlogit=pr*(1-pr)*@coefs(2)
推計結果は表11.3に掲げるとおりである。

```

ロジット・モデルでの夫の収入のマーヅナル効果は - 0.005436である。

ここでプロビット・モデルの予測値 (PWFIT) とロジット・モデルの予測値 (LWFIT) を最初の50サンプルを取り出して比較してみよう(図11.1参照)。両者はほとんど差がないことが分かる。

4 分散不均一、過小定式化

(分散不均一の問題)

プロビット・モデルやロジット・モデルで分散不均一や過小定式化の誤りがあるときは、その推定量には一貫性もないことがYatchewやGrilichesによって指摘されている。

個票データを使う質的選択モデルでは、特に分散不均一は深刻な課題となることがある。11.18)式で

$$P(y_i = 1) = \Phi((a + bx_i) / \sigma)$$

を考えた。分散が不均一であれば σ は i となる。推計すべきパラメータはサンプルの数 + 説明変数 + 1 (定数項) となるので、何らかの制約を加えない限り、これを推定することはできない。

HarveyやGreenelは

$$V(u_i) = \sigma_i^2 = \exp(cz_i)$$

という一般型を提案している⁸⁾。このときモデルは

$$y_i^* = a + bx_i + u_i \quad (11.27a)$$


$$V(u_i) = \exp(cz_i) \quad (11.27b)$$

表11.3

Dependent Variable : WORK				
Method : ML Binary Logit				
Sample : 1 34246				
Included observations : 34246				
Convergence achieved after 7 iterations				
Covariance matrix computed using second derivatives				
Variable	Coefficient	Std. Error	z Statistic	Prob.
C	- 2.313815	0.297069	- 7.788812	0.0000
HUSIN	- 0.021403	0.004915	- 4.354225	0.0000
AGE	0.141769	0.012184	11.63544	0.0000
AGE2	- 0.001941	0.000143	- 13.54806	0.0000
MONEY	- 0.044682	0.007486	- 5.969084	0.0000
MOCHIYA	0.082823	0.031440	2.634317	0.0084
DEBT	0.050417	0.004130	12.20825	0.0000
INFANT	- 1.494029	0.039242	- 38.07241	0.0000
MOM	0.556291	0.033687	16.51334	0.0000
IIP	- 0.004323	0.001909	- 2.264480	0.0235
YUKOU	1.217896	0.051375	23.70621	0.0000
HUSNASI	1.680335	0.081226	20.68716	0.0000
Mean dependent var	0.510804	S.D. dependent var	0.499891	
S.E. of regression	0.461670	Akaike info criterion	1.227734	
Sum squared resid	7296.599	Schwarz criterion	1.230692	
Log likelihood	- 21010.49	Hannan Quinn criter.	1.228677	
Restr. log likelihood	- 23729.52	Avg. log likelihood	- 0.613517	
LR statistic (11 df)	5438.062	McFadden R squared	0.114584	
Probability (LR stat)	0.000000			
Obs with Dep = 0	16753	Total obs	34246	
Obs with Dep = 1	17493			

8) 第4章で触れたように、 z_i としてどの変数を利用すれば良いかという問題は難しいものがある。

図11.1



となる。対数尤度関数は次式により得られる。

$$\text{LogL} = \left\{ \sum y_i \text{Log} \left(\frac{a+bx_i}{\exp(cz_i)} \right) + \sum (1-y_i) \text{Log} \left(1 - \frac{a+bx_i}{\exp(cz_i)} \right) \right\} \quad (11.28)$$

パラメータは以下のように求められる。

$$\frac{\text{LogL}}{a} = \left[\frac{\sum \left\{ \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right\} y_i - \left\{ \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right\}}{\sum \left\{ \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right\} \left[1 - \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right]} \right] \times \exp(-cz_i) \quad (11.29a)$$

$$\frac{\text{LogL}}{b} = \left[\frac{\sum \left\{ \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right\} y_i - \left\{ \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right\}}{\sum \left\{ \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right\} \left[1 - \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right]} \right] \times \exp(-cz_i) x_i \quad (11.29b)$$

$$\frac{\text{LogL}}{c} = \left[\frac{\sum \left\{ \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right\} y_i - \left\{ \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right\}}{\sum \left\{ \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right\} \left[1 - \frac{(a+bx_i)\exp(cz_i)}{\exp(cz_i)} \right]} \right] \times \exp(-cz_i) (a+bx_i) \quad (11.29c)$$

分散が均一であれば $c = 0$ である。分散が均一で

あるという帰無仮説 $H_0: c = 0$ と対立仮説 $H_1: c$

0 に関して尤度比検定やWald検定を行えばよい。

モデルの定式化が正しいにも関わらず分散不均一が存在する場合の修正としては、OLSの分散不均一の修正のアナロジーであるWhiteの提案した修正方法がある⁹⁾。

分散不均一は過小定式化の時にしばしば起きることが知られている。これも除外変数テストの考え方を用い、次のような制約のないモデルと制約のあるモデルを考え、

$$y_i^* = a + b_1 x_{1i} + b_2 x_{2i} + u_i \quad \text{対数尤度を } \text{LogL}_u \text{ とする}$$

$$y_i^* = a + b_1 x_{1i} + e_i \quad \text{対数尤度を } \text{LogL}_r \text{ とする}$$

$$\text{LR} = -2(\text{LogL}_r - \text{LogL}_u) \quad (11.30)$$

の尤度比検定を行えばよい。これが制約の数を自由度とする χ^2 分布に従う。

9) quasi maximum likelihood (QMLE) ということがある。OLSの場合第4章を参照。

(Eviewsでの推定例)

$$\text{work}_i^* = a_1 + a_2 \text{husin}_i + a_3 \text{infant}_i + a_4 \text{money}_i + a_5 \text{debt}_i + u_i \quad (11.31)$$

をプロビット・モデルで推計した。結果は次のようであった(なおプロビットモデルの報告は通例以下のように行う)。

$$\begin{aligned} \text{work}_i^* = & 0.747 - 0.0445 \text{husin}_i - 0.854 \text{infant}_i \\ & (22.75) \quad (-25.22) \quad (-43.69) \\ & - 0.0320 \text{money}_i + 0.0382 \text{debt}_i + \hat{u}_i \\ & (-7.51) \quad (16.62) \end{aligned}$$

N = 34246 POSITIVE SAMPLES 17493

カッコ内は漸近的t値 LogL = -22102.59

表11.1をみるとその対数尤度は-21015.54である。

これから尤度比検定統計量 = $-2 * (-22102.59 + 21015.54) = 2194.1$ である。自由度8の χ^2 の臨界値(5%)は15.51である。表11.1の結果から容易に予想されるように、8個の変数を除いた(11.31)式のモデルは過小定式化ということになる。

(11.31)式について分散不均一を考える。その候補としてhusin(夫の収入)をここでは取り上げよう。(11.27)式を推定するためには、EviewsではLog Likelihood Object(LogL)で関数型を指定する必要がある。ここではそれを試みる。

分散は均一という帰無仮説の下での推計

```
1 equation eq3 binary work c husin infant
   money debt
```

帰無仮説(eq3)の5個の係数を尤度関数の初期値に使うためにalphaと名付けて保存¹⁰⁾

```
2 coe(5)alpha = eq3.@coefs
```

'exp(c*husin)の係数をgamと名付け初期値を-0.1とする。

```
3 coe(1)gam = -0.1
```

尤度関数の特定化

'LogLであることを宣言。名前をll1とする(ここに結果が保存される)。

```
4 logl ll1
```

'対数尤度を最大化するための要素をlogl1と名付けることを宣言する。

```
5 ll1 append @logl logl1
```

(a + bx_i)/exp(cz_i)を作成。

```
6 ll1 append index = (alpha(1) + alpha(2)*
   husin + alpha(3)*infant + alpha(4)*money
   + alpha(5)*debt) / exp(gam(1)husin)
```

(11.29a)、(11.29b)、(11.29c)式のΣ[]の中の部分を作成。

```
7 ll1 append mills = @dnorm(index)*
   (work - @cnorm(index)) /
   (@cnorm(index)*(1 - @cnorm(index)))
```

(11.28)式に対数尤度関数を指定

```
8 ll1 append logl1 = work*log(@cnorm(index))
   + (1 - work)*log(1 - @cnorm(index))
```

'数値解析方法を指定(@deriv)。(11.29a)、(11.29b)、(11.29c)式より説明変数のパラメータ毎に指定する。

```
9 ll1 append @deriv alpha(1) grad1 alpha
   (2) grad2 alpha(3) grad3 alpha(4) grad4
   alpha(5) grad5 gam(1) grad6
```

(11.29a)式の計算

```
10 ll1 append grad1 = mills / exp(gam(1)*
   husin)
```

(11.29b)式の計算

```
11 ll1 append grad2 = grad1*husin
```

```
12 ll1 append grad3 = grad1*infant
```

```
13 ll1 append grad4 = grad1*money
```

```
14 ll1 append grad5 = grad1*debt
```

10) 尤度関数のプログラムを独自に書くケースでは、初期値の設定は必ず行った方がよい。また初期値の設定を誤ると関数が収束しないことがある。その初期値にはbinaryのコマンドで推計したプロビット・モデルやOLSの推計結果を用いるとよい。

表11.4

LogL : LL 1				
Method : Maximum Likelihood (Marquardt)				
Sample : 1 34246				
Included observations : 34246				
Evaluation order : By observation				
Initial Values : ALPHA(1)= 0 .74749 , ALPHA(2)= - 0 .04446 , ALPHA(3)= - 0 .85424 , ALPHA(4)= - 0 .03199 , ALPHA(5)= 0 .03821 , GAM(1)= - 0 .10000				
Convergence achieved after 12 iterations				
	Coefficient	Std. Error	z-Statistic	Prob.
ALPHA(1)	0 .539345	0 .020331	26 .52780	0 .0000
ALPHA(2)	- 0 .042740	0 .001607	- 26 .59215	0 .0000
ALPHA(3)	- 0 .054734	0 .002659	- 20 .58738	0 .0000
ALPHA(4)	0 .001122	0 .000257	4 .364080	0 .0000
ALPHA(5)	0 .002808	0 .000177	15 .82457	0 .0000
GAM(1)	- 0 .227211	0 .003663	- 62 .03499	0 .0000
Log likelihood	- 21576 .64	Akaike info criterion	1 .260447	
Avg. log likelihood	- 0 .630049	Schwarz criterion	1 .261926	
Number of Coefs.		Hannan-Quinn criter .	1 .260919	

11 29c) 式の計算

15 ll1 append grad6 = mills*husin*(- index)
'最尤法を実施する (MLがそのコマンドである)。

16 ll1 ml (d)

結果を表示する (表11.4 参照)

17 show ll1 .output

gam(1)のt値は - 62 .03でp値は0 .0000である。

gam(1)= 0 のWald検定を

Views/Wald Coefficient Testsで行うと結果は3848 .34であった。11 31) 式の結果との尤度比検定は1051 .9である。分散均一という帰無仮説は強く棄却される。これは過小定式化による影響が現れていると考えられる。このケースでは定式化を改めない限り問題は解決しないであろう。

ここでは定式化は正しいものとしてWhiteの修正方法の例を示す。オプションとしてhを加えてやればよい。

equation eqh . binary (h) work c husin infant money debt

結果は次のようであった。

$$\text{work}_i^* = 0.747 - 0.0445\text{husin}_i - 0.854\text{infant}_i \\ (22.93) \quad (-24.79) \quad (-43.65)$$

$$- 0.0320\text{money}_i + 0.0382\text{debt}_i + \hat{u}_i \\ (-7.36) \quad (16.54)$$

カッコ内はWhiteの修正による漸近的t値である。

N = 34246 POSITIVE SAMPLES 17493

LogL = - 22102 .59

5 被説明変数に制約のあるモデル

ある値以上取る場合に観察されるデータがある (株式を保有する場合の保有金額は0を超える場合に観察される。ゼロ保有世帯は0ということが分かるだけである)。逆にある値以下を取る場合に観察されるケースもある (低所得者を対象に所得を調査する場合、高所得者の所得は調査されない)。さらにはある範囲を取る場合に観察されるケースもある (たとえば試験の成績が60点以上80点以下の学生を調べるとき。81点以上や59点以下の学生の成績は調査されない)。これらを被説明変数とするととき (たとえば株式保有金額)、それは下限がゼロで制約されている。このようにセンサーされたデータ (censored data) を被説明変数とするととき、それをlimited dependent variableという。

これはアンケート調査などでよく見られる事態である。株式を保有するかどうか、保有するならばいくら保有するのかというようなケースである。このような分析をcensored regression model、あるいはトービット・モデル (tobit model、Tobin のprobit) という。

トービット・モデルはランダムサンプルから選ばれ、それがある値 (閾値) で実数とゼロとに区分されるが、データによっては株式を保有する世帯だけを対称にしているものもある。このようなケースも多いであろう (たとえば大学生のいる家計だけに大学教育費用を聞く場合)。このような

データを切断されたデータ (truncated data) とい
い、それを被説明変数とするとき切断分布モデ
ル (truncated regression model) という。

5.1 切断分布モデル

y^* が平均が a 、分散 σ^2 の正規分布に従うとする。
閾値 c を超えるデータのみが集められて分析対象
となったとする。 y^* が c を超える確率は

$$P(y^* > c) = 1 - \Phi\left(\frac{c - a}{\sigma}\right) \quad (11.32)$$

で求められる。確率密度関数 $f(\cdot)$ は

$$f(y^* | y^* > c) = \frac{1/\sigma \cdot ((y^* - a)/\sigma)}{1 - \Phi((c - a)/\sigma)} \quad (11.33)$$

で求められる¹¹⁾。表記の簡単化のために $(c - a)/\sigma$
= d とする。期待値は次による。

$$E(y^* | y^* > c) = a + \frac{\sigma}{1 - \Phi(d)} \phi(d) \quad (11.34)^{2)}$$

分散は次のようである。

$$V(y^* | y^* > c) = \sigma^2 \left[\frac{\phi(d)}{1 - \Phi(d)} - \left(\frac{\phi(d)}{1 - \Phi(d)} \right)^2 \right] \quad (11.35)$$

閾値 c を超えるデータのみからなる切断分布モデ
ルの回帰を考えてみよう。

$$y_i^* = a + bx_i + u_i \quad u_i \sim \text{NII}(\mu, \sigma^2) \quad (11.36)$$

$y_i^* > c$ のデータしか観測されないのでこの場合

$$E(u_i | y_i^* > c) = E(u_i | a + bx_i + u_i > c) \\ = E(u_i | u_i > c - a - bx_i) \quad (11.37)$$

11.34) 式の結果より

$$E(u_i | u_i > c - a - bx_i) = 0$$

なので $y_i^* > c$ を満たすデータのみを使用し、
11.36) 式を OLS で推定すると OLS 推定量は不偏
性は持たない。

11.33) 式より 11.36) 式の対数尤度関数は次の
通りとなる (n はサンプル数)。

$$\text{LogL} = -(n/2) \text{Log}(2\pi) - (n/2) \text{Log} \sigma^2 - (1/2) \sum_{i=1}^n \frac{(y_i^* - a - bx_i)^2}{\sigma^2} - \text{Log}(1 - \Phi(d_i)) \quad (11.38)$$

ここで再び $d_i = (c - a - bx_i)/\sigma$ と置くと 1 階の条
件は次の通りである¹³⁾。

$$\frac{\text{LogL}}{a} = \frac{1}{2} \sum (y_i^* - a - bx_i) + \frac{(d_i)}{(1 - \Phi(d_i))} = 0 \quad (11.39a)$$

$$\frac{\text{LogL}}{b} = \frac{1}{2} \sum (y_i^* - a - bx_i) x_i + \frac{(d_i) x_i}{(1 - \Phi(d_i))} = 0 \quad (11.39b)$$

$$\frac{\text{LogL}}{\sigma^2} = \frac{-n}{2} + \sum (y_i^* - a - bx_i)^2 - \frac{1}{2} \sum \frac{(d_i) d_i}{1 - \Phi(d_i)} = 0 \quad (11.39c)$$

5.2 トービット・モデル

ランダムサンプルで市場調査を行えば、その中
には財・サービスを購入した人もいれば購入して
いない人もいる。両者を合わせて分析する (この
点で切断分布モデルと異なる)。財・サービスの

11) c を下回るデータのみが集められているとすると密度関数等は以下のようである。

$$f(y^* | y^* < c) = \frac{1/\sigma \cdot ((y^* - a)/\sigma)}{\Phi((c - a)/\sigma)} \quad (s1)$$

$$E(y^* | y^* < c) = a - \frac{\sigma}{\Phi(d)} \phi(d) \quad (s2)$$

$$V(y^* | y^* < c) = \sigma^2 \left[\frac{\phi(d)}{\Phi(d)} - \left(\frac{\phi(d)}{\Phi(d)} \right)^2 \right] \quad (s3)$$

12) 11.34) 式の $(d)/(1 - \Phi(d))$ 、s2) 式の $-\phi(d)/\Phi(d)$ をミルズの比率の逆数 (inverse Mills ratio) という。

13) c を下回るデータのみが集められている場合は s1) 式より以下の通りである。

$$\text{LogL} = -(n/2) \text{Log}(2\pi) - (n/2) \text{Log} \sigma^2 - (1/2) \sum_{i=1}^n \frac{(y_i^* - a - bx_i)^2}{\sigma^2} - \text{Log}(\Phi(d_i)) \quad (s4)$$

$$\frac{\text{LogL}}{a} = \frac{1}{2} \sum (y_i^* - a - bx_i) + \sum \frac{(d_i)}{\Phi(d_i)} = 0 \quad (s5)$$

$$\frac{\text{LogL}}{b} = \frac{1}{2} \sum (y_i^* - a - bx_i) x_i + \sum \frac{(d_i) x_i}{\Phi(d_i)} = 0 \quad (s6)$$

$$\frac{\text{LogL}}{\sigma^2} = \frac{-n}{2} + \frac{1}{2} \sum \frac{(y_i^* - a - bx_i)^2}{\sigma^2} + \sum \frac{(d_i) d_i}{\Phi(d_i)} = 0 \quad (s7)$$

購入で支払った金額（連続変数）を知ることができればその金額についても分析する（この点で質的選択モデルと異なる）。これがトービット・モデルの例である。

データには上限で区切られているもの、下限で区切られているもの、上限・下限の両側で区切ら


れているものがある（図11.2 参照）。

トービット・モデルはプロビット・モデル、ロジット・モデルや切断分布モデルの延長線上で考えることができる。その簡単な例をみてみよう。


$$y_i^* = a + bx_i + u_i \quad u_i \sim N(0, \sigma^2) \quad (11.40)^{14)}$$

$$y_i = y_i^* \quad \text{if } y_i^* > 0$$


図11.2



(下限で切断)



(上限で切断)



(上限と下限で切断)

$$= 0 \text{ if } y_i^* > 0$$

$y_i^* > 0$ となる確率は

$$\begin{aligned} P(y_i^* > 0) &= P(a + bx_i - u_i) \\ &= P(-u_i / \sigma > -(a + bx_i) / \sigma) \\ &= 1 - \Phi(-(a + bx_i) / \sigma) \end{aligned} \quad 11.41)$$

その対数尤度は

$$\begin{aligned} \text{LogL} &= \sum y_i^* \text{Log} [1 - \Phi(-(a + bx_i) / \sigma)] \\ &= \sum y_i^* \text{Log} \Phi((a + bx_i) / \sigma) \end{aligned} \quad 11.42)$$

となる (以下表記の簡単化のためにここでも $d_i = (a + bx_i) / \sigma$ とする)

$y_i^* > 0$ となる密度は

$$\frac{\Phi((y_i^* - a - bx_i) / \sigma)}{P(y_i^* > 0)}$$

である。上式に $P(y_i^* > 0)$ を乗じると、

$$(d_i) \Phi(d_i) \{ \Phi((y_i^* - a - bx_i) / \sigma) / \Phi(d_i) \}$$

となる。この対数を取ると

$$\begin{aligned} \text{LogL} &= \sum y_i^* \text{Log} \left(\frac{1}{\sigma} \Phi\left(\frac{y_i^* - a - bx_i}{\sigma}\right) \right) \\ &= \sum y_i^* \left[\text{Log} \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right) - \left(\frac{1}{2} \right) \right. \\ &\quad \left. \left(\frac{(y_i^* - a - bx_i)^2}{\sigma^2} \right) \right] \end{aligned} \quad 11.43)$$

となる。トービットモデルの尤度関数は11.42)

式と11.43) 式を足して

$$\begin{aligned} \text{LogL} &= \sum y_i^* \text{Log} \left(\frac{1}{\sigma} \Phi(d_i) \right) + \sum y_i^* \text{Log} \left(\frac{1}{\sigma} \Phi\left(\frac{y_i^* - a - bx_i}{\sigma}\right) \right) \\ &= \sum y_i^* \text{Log} [1 - \Phi(-d_i)] + \sum y_i^* \text{Log} \left[\frac{1}{\sqrt{2\pi\sigma^2}} \right] - \left(\frac{1}{2} \right) \sum y_i^* \left(\frac{(y_i^* - a - bx_i)^2}{\sigma^2} \right) \end{aligned} \quad 11.44)$$

$$\left(\frac{(y_i^* - a - bx_i)^2}{\sigma^2} \right)$$

で求めることができる¹⁵⁾¹⁶⁾。

この時 $y_i^* > 0$ の条件付き期待値は

$$\begin{aligned} E(y_i | y_i > 0) &= a + bx_i + E(u_i | u_i > -a - bx_i) \\ &= a + bx_i + \frac{\phi(d_i)}{\Phi(d_i)} \end{aligned} \quad 11.45a)$$

で与えられる。全サンプルの期待値は

$$\begin{aligned} E(y_i) &= P(y_i > 0) E(y_i | y_i > 0) \\ &\quad + P(y_i = 0) E(y_i | y_i = 0) \\ &= \frac{\phi(d_i)}{\Phi(d_i)} (a + bx_i) + (1 - \frac{\phi(d_i)}{\Phi(d_i)}) E(y_i | y_i = 0) \end{aligned}$$

この時右辺第二項は0となるので、

$$= \frac{\phi(d_i)}{\Phi(d_i)} (a + bx_i) \quad 11.45b)$$

で与えられる。

なおマージナル効果については

$$\frac{\partial E(y_i^* | a + bx_i)}{\partial x_i} = b \quad 11.46a)$$

$$\frac{\partial E(y_i | a + bx_i)}{\partial x_i} = \frac{\phi(d_i)}{\Phi(d_i)} b \quad 11.46b)$$

$$\begin{aligned} \frac{\partial E(y_i | y_i^* > 0)}{\partial x_i} &= \left\{ 1 - \frac{\phi(d_i)}{\Phi(d_i)} \right\} b \\ &\quad - \left(\frac{\phi(d_i)}{\Phi(d_i)} \right)^2 b \end{aligned} \quad 11.46c)$$

によることをMaddala [1983] は示している¹⁷⁾。

5.3 仮説の検定

(トービットモデルの制約)

トービットモデルは、11.44) 式にみられるよ

14) 一般性を失うことなく

$$y_i = y_i^* \text{ if } y_i > c, \quad y_i = 0 \text{ if } y_i \leq c$$

と変形することができる。

15) 1階の条件についてはMaddala [1983] を参照されたい。

16) 上限 (c_1) と下限 (c_2) の双方の閾値がある場合は対数尤度関数は次のように書くことができる。

$$\begin{aligned} \text{LogL} &= \sum_{y_i^* > c_1} \text{Log} \left(\frac{1}{\sigma} \Phi\left(\frac{y_i^* - a - bx_i}{\sigma}\right) \right) + \sum_{y_i^* < c_2} \text{Log} \left(\frac{1}{\sigma} \Phi\left(\frac{y_i^* - a - bx_i}{\sigma}\right) \right) \\ &\quad + \sum_{c_2 < y_i^* < c_1} \text{Log} \left(\frac{1}{\sigma} \Phi\left(\frac{y_i^* - a - bx_i}{\sigma}\right) \right) \end{aligned} \quad s.8)$$

17) McDonaldとMoffittは11.46c) 式を次のように分解している。

$$\left\{ \frac{\phi(d_i)}{\Phi(d_i)} \left[1 - \frac{\phi(d_i)}{\Phi(d_i)} \right] + \left(\frac{\phi(d_i)}{\Phi(d_i)} \right)^2 \right\} b \quad s.9)$$

これから x_i の変動の効果を

$$P(y_i^* > 0) \frac{\partial E(y_i | x_i, y_i^* > 0)}{\partial x_i} + E(y_i | x_i, y_i^* > 0) \frac{\partial P(y_i^* > 0)}{\partial x_i} \quad s.10)$$

の二つの効果に分解できる。

うにプロビット・モデル(11.18)式)と切斷分布モデル(11.38)式)の結合型と考えることができる。言い換えればトービット・モデルはプロビット・モデルと切斷分布モデルの説明変数が同じであり、かつそのパラメータは共通であることを仮定している。

しかし株式を買うかどうかの意志決定と、買うとした場合にいくら買うかの意志決定に、ある変数が与える効果は共通とは限らない。その効果が異なるならば、トービットモデルを用いることはできないことをCraggは指摘した。プロビット部分と切斷分布部分とでパラメータが共通するかどうかの検定を行う必要がある。

$$y_i^* = a + bx_i + u_i$$

のモデルに関し、トービット・モデルの対数尤度 L 、プロビットモデル(すなわち y_i^* が正かゼロという情報のみを利用する)の対数尤度を L_p 、切斷分布モデル(すなわち、 $y_i^* > 0$ のデータのみを利用する)の対数尤度を L_t とすると、パラメータは共通であるという帰無仮説の下で

$$L = -2(L_c - (L_p + L_t)) \quad (11.47)$$

の尤度比検定統計量が自由度2(パラメータが k 個であれば k)の χ^2 分布に従うことを行うことができる¹⁸⁾。

(分散均一と正規分布の仮定)

トービット・モデルや切斷分布モデルは誤差項が正規分布に従い、分散は均一であるという仮定に決定的に依存している。これらの仮定が充たされないときその推定量は一致性もない。たとえば $V(u_i) = \sigma^2 = \sigma^2 \exp(cz_i)$ のように分散が不均一となるケースである。

正規性の検定についてはPaganやVellaによって提唱されている。その場合の推計方法がPowellによって提案されている。

5.4 Eviewsでの推計例

有価証券の需要をトービット・モデルで推計してみよう。第1章で用いた「金融資産の選択に関する調査」を利用する。有価証券の需要を世帯所得、金融資産、負債、世帯主年齢とその最終学歴(大卒)でみている。有価証券の需要への効果は所得(I_{setai})、資産(I_{money})は正、負債(I_{debt})は負が期待される。投資が情報分析能力に影響されるならば学歴($daigaku$)は正である。

1 workfile a : tobit u 1 1600

2 smpl 1 1561

有価証券、金融資産、負債、年齢とその自乗

3 read c : %data%temp1.txt stock money debt age age2

世帯年収(対数値)、高卒、短大卒、大卒ダミー

4 read c : %data%temp2.txt Isetai high tandai daigaku

5 series debt = 1*(debt=0)+debt*(debt>0)

6 series kabu = 1*(stock=0)+stock*(stock>0)

7 series lkabu = log(kabu)

8 series Imoney = log(money)

9 series ldebt = log(debt)

10 series kabusiki = 1*(stock>0)

Tobitモデルの推定。下が0でcensored、上はのケース(既定値)¹⁹⁾

Tobitモデル $lkabu_i^* = a_0 + a_1 I_{setai} + a_2 I_{money} + a_3 I_{debt} + a_4 age_i + a_5 daigaku_i + u_i$ の推定。

censoredが従属変数に制約がある推計のコマン

18) 11.44)式に $\sum y_i^* > 0 \cdot \text{Log}(-d_i)$ を足して、引いた上で書き直すと

$$\text{Log}L = \sum y_i^* > 0 \cdot \text{Log}(-d_i) + \sum y_i^* > 0 \cdot \text{Log}(-d_i) + \sum y_i^* > 0 \cdot \text{Log}(1/\sigma) \left((y_i^* - a - bx_i) / \sigma \right) - \sum y_i^* > 0 \cdot \text{Log}(-d_i) \quad (s11)$$

となる。s11)式の最初の行はプロビット・モデルの対数尤度関数、第2行は切斷分布モデルの対数尤度関数である。

19) 上限下限の双方に制約がある場合は、以下のように $L=c1$ 、 $R=c2$ のオプションで行うことができる。下が0でcensored、上は8.15でcensoredのケース

equation eqdce. censored (L=0 R=8.15)lkabu c Isetai Imoney ldebt age daigaku

ド (binaryに相当)

11 equation eqtobit. censored lkabu c lsetai
lmoney ldebt age daigaku

対数尤度を保存

12 series ltobit = @logl
平均値の回りでのbxの作成

13 series heikin = @coefs(1)+@coefs(2)*@
mean(lsetai)+@coefs(3)*@mean(lmoney)
+@coefs(4)*@mean(ldebt)+@coefs(5)*
@mean(age)+@coefs(6)*@mean(dai-
gaku)

tdの作成

14 series xbs = heikin/@se
E(y_i | y_i>0)の時の平均値の回りでの期待値
(11.45a)式を参考に)

15 series hkitai = heikin + @se*@dnorm(xbs)
/@cnorm(xbs)

全サンプルの平均値の回りでの確率

16 series prob = @cnorm(xbs)
全サンプルの平均値の回りでの期待値(11.45b)
式を参考に)

17 series expect = @cnorm(xbs)*hkitai
LMONEYのマーシナル効果(11.46b)式を参
考に)

18 series expkabu = @cnorm(xbs)*@coefs(3)
McDonald, Moffitの分解(s8)式を参考に)

19 series mc1 = @cnorm(xbs)*(1-xbs*(
dnorm(xbs)/@cnorm(xbs))-(
dnorm(xbs)/@cnorm(xbs))^2)

20 series mc2 = @dnorm(xbs)*xbs + @dnorm
(xbs)*(@dnorm(xbs)/@cnorm(xbs))

分解の合計値

21 series mcd = mc1 + mc2
Craggの検定のためのProbitモデルの推定

22 equation eqprobit. binary kabusiki c lsetai
lmoney ldebt age daigaku

Probitモデルの対数尤度を保存

23 series lprobit = eqprobit . @logl
有価証券を保有するサンプルだけを選択

24 smpl if lkabu>0
切断分布モデルの推定。(t)がtruncated regres-
sionのオプション

25 equation eqtrunc. censored(t) lkabu c lse-
tai lmoney ldebt age daigaku
切断分布モデルの対数尤度を保存

26 series ltrunc = eqtrunc. @logl
Craggの検定

27 series ltest = -2*(ltobit - lprobit - ltrunc)
χ²統計量を計算し、有意水準をみる

28 series pchisq = 1 - @chisq(ltest,eqtobit .
@ncoef)

29 smpl @all

11行のトービット・モデルの推計結果は表11.5
に掲げるとおりである。上欄に推定法がトービッ
ト・モデル(最尤法)であることが示されている。
下限0が閾値であることも表示されている。中欄
にあるError Distribution, scale(7)がである(こ
こでは7番目のパラメータである)。下欄にセン
サーされたサンプルが1,282個、有価証券を保有
しているサンプルが279個であることが表示され
ている。約18%が有価証券を保有している。

なおトービット・モデルの推計結果の報告は通
常次のように行う。

$$lkabu = -38.80 + 1.74lsetai + 2.95lmoney$$

(-11.74) (3.96) (9.19)

$$+ 0.19ldebt + 0.022age + 2.57daigaku + \hat{u}_i$$

(2.42) (0.88) (4.65)

カッコ内は漸近的t値 対数尤度 -1291.48 保有
サンプル279 N=1,561

15行で有価証券を保有するときの、平均値回り
での期待値(11.45a)式)を計算している。結果
は0.3814であった。16行で平均値回りでの保有確

表11.5

Dependent Variable : LKABU				
Method : ML-Censored Normal (TOBIT)				
Sample : 1 1561				
Included observations : 1561				
Left censoring (value) at zero				
Convergence achieved after 9 iterations				
Covariance matrix computed using second derivatives				
	Coefficient	Std. Error	z-Statistic	Prob.
C	- 38.80377	3.305719	- 11.73838	0.0000
LSETAI	1.740643	0.439524	3.960292	0.0001
LMONEY	2.946342	0.320456	9.194212	0.0000
LDEBT	0.186948	0.077238	2.420423	0.0155
AGE	0.021971	0.024974	0.879765	0.3790
DAIGAKU	2.574385	0.553295	4.652826	0.0000
Error Distribution				
SCALE : $\chi(7)$	6.530102	0.336047	19.43209	0.0000
R-squared	0.186629	Mean dependent var	0.918748	
Adjusted R-squared	0.183489	S.D. dependent var	2.039722	
S.E. of regression	1.843114	Akaike info criterion	1.663650	
Sum squared resid	5279.043	Schwarz criterion	1.687654	
Log likelihood	- 1291.478	Hannan-Quinn criter.	1.672574	
Avg. log likelihood	- 0.827340			
Left censored obs	1282	Right censored obs	0	
Uncensored obs	279	Total obs	1561	

表11.6

Dependent Variable : LKABU				
Method : ML-Censored Normal (TOBIT)				
Sample (adjusted) : 3 1557 IF LKABU > 0				
Included observations : 279 after adjusting endpoints				
Truncated sample				
Left censoring (value) at zero				
Convergence achieved after 3 iterations				
Covariance matrix computed using second derivatives				
	Coefficient	Std. Error	z-Statistic	Prob.
C	- 1.806846	0.741548	- 2.436588	0.0148
LSETAI	0.138619	0.105798	1.310224	0.1901
LMONEY	0.758392	0.083223	9.112747	0.0000
LDEBT	0.009008	0.018865	0.477484	0.6330
AGE	0.009552	0.006012	1.588786	0.1121
DAIGAKU	0.109409	0.132059	0.828484	0.4074
Error Distribution				
SCALE : $\chi(7)$	1.011143	0.042844	23.60064	0.0000
R-squared	0.345689	Mean dependent var	5.140379	
Adjusted R-squared	0.331256	S.D. dependent var	1.252064	
S.E. of regression	1.023897	Akaike info criterion	2.909842	
Sum squared resid	285.1555	Schwarz criterion	3.000948	
Log likelihood	- 398.9230	Hannan-Quinn criter.	2.946389	
Avg. log likelihood	- 1.429832			
Left censored obs	0	Right censored obs	0	
Uncensored obs	279	Total obs	279	

率が計算されている。その値は4.63E06と極めて低い。これは全体での保有が18%にすぎないことを反映している。17行で全サンプルについて平均値での期待値が計算されている（値は1.77E06であった）。18行で金融資産のマージナル効果（11.46b）式のケース）が計算されている。これも1.37E05であった。これらの結果は有価証券の需要が相当の高所得者、高資産家、高学歴者に偏っていることを示唆している。

19～21行でMcDonaldとMoffitの分解を行い、その合計が平均値回りの確率に等しいことを確かめている。

22行のプロビット・モデルの対数尤度は - 605.7093であった。25行の切断分布モデルの対数尤度は - 398.923であった。これからCraggの検定結果は

$$l_{test} = - 2 * (- 1291.478 + (605.7093 + 398.923)) = 573.6962$$

20) Craggの検定で保有確率にかかる係数と需要にかかる係数が同一であるという帰無仮説が棄却された場合、サンプル・セレクション・モデル (sample selection model) として知られる方法で推計を行う必要がある。DavidsonとMacKinnonは以下のような対数尤度関数を提案している。

$$z_i = ew_i + u_{1i} \quad z_i = 1 \quad \text{if } z_i^* > 0 \quad z_i = 0 \quad \text{otherwise}$$

$$y_i = bx_i + u_{2i} \quad y_i = y_i^* \quad \text{if } z_i^* > 0 \quad y_i = 0 \quad \text{otherwise}$$

$\begin{pmatrix} u_{1i} \\ u_{2i} \end{pmatrix} \sim \text{NID} \left(0, \begin{bmatrix} \sigma_1^2 & \rho \\ 0 & \sigma_2^2 \end{bmatrix} \right)$ は u_{1i} と u_{2i} の相関を表す。

$$\text{Log L} = \sum_{z_i=0} \text{Log} (- ew_i) + \sum_{z_i=1} \text{Log} (1 / (\sigma_2 \cdot (y_i - bx_i))) +$$

$$\sum_{z_i=1} \text{Log} \left(\frac{ew_i + ((y_i - bx_i) / \sigma_2)}{(1 - \rho^2)^{1/2}} \right) \quad \text{s12)}$$

となる。自由度6の χ^2 統計量の5%点は12.592であるから帰無仮説は棄却される²⁰⁾。

なお切斷分布モデルの結果は表11.6に掲げるとおりである。有意な変数が金融資産(LMONEY)のみである。質的選択モデルやトービット・モデル等最尤法で推計するとき、大

標本であることを前提にして検定が行われる。標本が少ない場合その係数に安定性が欠け、検定もうまくいかないことが多い。経験則からいえばサンプルは少なくとも500以上あることが望ましい。この切斷分布モデルはサンプル数(279)が少ないことを反映していると考えられる。

参考文献

縄田和満 [1997] 『Probit, Logit, Tobit』 応用計量経済学、多賀出版

Davidson, R. and J.G. MacKinnon [1993] *Estimation and Inference in Econometrics*, Oxford University PressのCh15

Greene, W.H. [1999] *Econometric Analysis*, 4th ed, Prentice HallのCh19.1 4, Ch20.1 3

Johnston, J. and J. DiNardo [1997] *Econometric Methods*, 4th ed, McGraw HillのCh13

Maddala, G.S. [1983] *Limited Dependent and Qualitative Variables in Econometrics*, Cambridge University PressのCh2, Ch6