

## 4.6 特殊関数とライブラリ CML[要 full version]

ver. 0.1

引き続きパラメータに制約をかける場合のMaximum Log-Likelihoodを求めるCMLについての解説をします。少々使われる場面が限定されるのですが、パラメータ間にノンリニアな等号制約および不等号制約がある場合の設定の仕方について見てみます。まずは、非現実的なのですが、まずは、以前推定した標準Tobitを用いて、パラメータ間に次のような

$$\text{AGE} \times \text{ED} + 1 = -\text{C18}$$

ノンリニアな制約があって、その上でパラメータ推定をやってみます。

プログラム

```
new; cls;
library cml;
cmlset;
load data[51,7]=d:datafile6.txt;
data=data[2:51,.];

hour=data[.,2];
one=ones(50,1);
c18=data[.,4];
age=data[.,5];
age2=age^2;
ed1=data[.,6];
hi=data[.,7];
data=hour~one~c18~age~age2~ed1~hi;

_cml_Bounds = {-1e256  1e256,
               -1e256  1e256,
               -1e256  1e256,
               -1e256  1e256,
               -1e256  1e256,
               -1e256  1e256,
               0.0001  1e256};

fn eqproc(p)=p[3]*p[5]+p[2]+1;
_cml_EqProc=&eqproc;
_cml_ParNames = {"CONST","C18","AGE","AGE2","ED","HI","SIGMA"};
```

```

_cml_Algorithm = 4;
start={-1,0,0,0,0,0,1};
call cmlprt(cml(data,0,&ll,start));

proc ll(b,data);
    local y,x,s,beta;
    y=data[:,1];
    x=data[:,2:7];
    s=b[7];
    beta=b[1:6];
    retp( (y==0).*ln(1-cdfn(x*beta/s))+ (y.>0).*lnpdfmvn(y-x*beta,s^2) );
endp;

```

画面表示

return code = 0

normal convergence

Mean log-likelihood -3.16617

Number of cases 50

Covariance of the parameters computed by the following method:

Inverse of computed Hessian

Parameters	Estimates	Std. err.	Gradient
-----			
CONST	-40.9837	21.0024	-0.0000
C18	-7.2916	3.0156	-0.0005
AGE	2.5455	1.6281	-0.0013
AGE2	-0.0402	0.0196	-0.0000
ED	2.4717	1.3188	-0.0013
HI	0.0001	0.0002	-0.0002
SIGMA	22.4104	3.0380	0.0000

Number of iterations 1800

Minutes to convergence 3.59400

上のように、パラメータ間のノンリニアの等号制約の設定には、左辺にすべてを移行した

陰関数のような形になるようPベクトルの関数をfnまたはProcで作成したうえで、それをノンリニアの等号制約のグローバル変数にポインターのしるしをつけて設定します。上の制約の場合、すべてを左辺にもっていくと、

$$\text{AGE} \times \text{ED} + \text{C18} + 1 = 0$$

となりますから、fn関数定義を用いて、

```
fn eqproc(p)=p[3]*p[5]+p[2]+1;
```

と表します。ここでなぜ関数の引数がPで、そのほかの変数がp[3]やp[5]やp[2]になっているかと言いますと、\_cml\_ParNamesの推定パラメータ名設定のところで、もともとのパラメータのデフォルトは、P01とかP02とかいうふうに、Pのベクトルとして表現されていたためです。GAUSSの内部計算では、P01とかP02といったパラメータを推定していて、これらに名前をつけるために、グローバル変数（文字列）\_cml\_ParNamesを設定していたわけですが、したがって、この場合、pの1列目がCONSTに相当するもので、2列目がC18、さらに3列目がAGE、4列目がAGE2、5列目がED、6列目がHI、最終7列目がSIGMAということになります。これらのパラメータ間の関係を表したのが上のeqproc(p)という関数になります。なお、これはprocを用いて

```
proc eqproc(p);  
    retp( p[3]*p[5]+p[2]+1 );  
endp;
```

と書いても同じことです。プログラムの節のfn1行関数定義のところでやったように、微分積分などに使う1行で書ける関数はprocを使って表現するまでもなく、fnで1行で表現できるので、このようにしています。これらの関数をパラメータ間の等号制約として呼び出すには、この関数eqprocという関数名の前にポインタを表す&のマークをつけて、

```
_cml_EqProc = &eqproc;
```

というふうに、グローバル変数\_cml\_EqProcの設定をします。なお、これらの制約は2乗の項があろうと何乗の項があろうと設定できますが、解けるか解けないかは、その関数の形とLog-Likelihoodとの間の関係に依存します。使える場面は限られてきますが、いざ使うとなると、手軽で興味深いグローバル変数の設定です。もちろん引数をP以外のもの、例えば微分積分でやったようにxとできますが、ここではパラメータxと混同が後のプログラム

でおきますから、Pを使います。

なお、この等号制約には、Jacobianを計算したものをさらに付け加えて計算を確実にする方法もあります。上のプログラムに加えて、次の2行

```
fn eqj(p)=0~1~p[5]~0~p[3]~0~0;  
_cml_EqJacobian=&eqj;
```

を\_cml\_EqProcの行の次あたりに挿入します。なお、等号制約と同様に、eqjはprocで書いてもかまいません。ここで等号制約についてのJacobian、すなわち各パラメータでの1階の微分の行ベクトルには注意が必要です。上のノンリニアの等号制約には、p[3]とp[5]とp[2]しか存在しませんでした。このJacobianでは、ベクトルpでの微分ということで、すべてのp、すなわち、p[1]からp[7]までの7つについてのそれぞれの微分を、横方向に行ベクトルとして表現する必要があります。また、微分はこのp[1]からp[7]までの1から7までの順序に従います。p[3]\*p[5]+p[2]+1=0について、p[1],p[2],...p[7]でのそれぞれの微分をして横方向のマージの演算記号~でくっつけあわせることになります。まず、p[1]については微分は0、p[2]については1、p[3]についてはp[5]が答えで、p[4]については0、p[5]についてはp[3]が答えで、p[6]とp[7]についてはその項がないので共に0となります。これらを行ベクトルにするために~でつなぎ合わせると、0~1~p[5]~0~p[3]~0~0 ということになります。これをpの関数eqjとしてfnで1行定義したうえで、ポインタを表す&のしるしをつけて、グローバル変数\_cml\_EqJacobianに設定します。計算結果は、この場合、等号制約式が複雑な形ではないので、上のJacobianなしのプログラムのものとほとんど同一になります。3つしかパラメータ制約がないといって、3つの微分をつなぎ合わせただけでは、行や列がマッチしないというエラーに直面することになります。すべてのパラメータ7つについての微分をこの1から7までの順序でする必要があります。

これと同様にして、異なるグローバル変数を同じように設定することにより、ノンリニアの不等号制約も設定できます。(ただし、かなりのケースで収束しないかしくいケースがでてきます。) いま、次のような

$$AGE^2 + ED^2 + 1 >= -2 \times C18$$

という不等号制約がある場合のパラメータ推定を試みます。グローバル変数は、等号制約のものに否定の意味のINをつけるだけでできます。CMLでは、>=の向きの制約がデフォルトになっています。(符号の向きが逆の場合には、リニアの場合の行列形式の制約設定と同じように、すべてのパラメータに-1をかけてやることによって、不等号の向きを逆転させます。) ここでは、上のような関係の不等号制約の設定は、Jacobianの計算では~でつなぎ合わせる時に、計算演算を含んでいれば、それぞれを丸括弧で包むことを忘れずに、

```

fn ineqproc(p)=p[3]^2+p[5]^2+2*p[2]+1;
_cml_IneqProc=&ineqproc;
fn ineqj(p)=0~2~(2*p[3])~0~(2*p[5])~0~0;
_cml_IneqJacobian=&ineqj;

```

というように書きます。上のような4行を、以前の等号制約のプログラムの等号制約部分とJacobianに相当する部分を消去して置きかえると、

画面表示

```

return code =    0
normal convergence

```

```

Mean log-likelihood      -3.16591
Number of cases         50

```

Covariance of the parameters computed by the following method:

Inverse of computed Hessian

Parameters	Estimates	Std. err.	Gradient
CONST	-47.4330	45.8227	-0.0000
C18	-7.1220	3.1961	-0.0000
AGE	2.8162	2.3679	-0.0000
AGE2	-0.0432	0.0273	-0.0000
ED	2.5322	1.3753	-0.0000
HI	0.0001	0.0002	-0.0001
SIGMA	22.4303	3.0444	0.0000

```

Number of iterations    1059
Minutes to convergence   2.50733

```

上のように、不等号制約に従ったパラメータの推定ができます。なお、定義する関数名とポインタで呼び出される関数名は一致する必要がありますが、等号制約および不等号制約、そしてそれらのJacobianを定義する関数名は任意です。等号制約同様、Jacobianをつければ計算は確かになりますが、どのような不等号制約も可能だからといって不等号制

約を設定しても、Log-Likelihoodを最大化する際に、これらはかなりきつい制約で、いつも解けるとはかぎりません。解ける場合は限られてきます。

ここで、特に注意したいことがあります。GARCHなどにも問題になりますが、パラメータ制約としてではなくて、Log-Likelihoodを定義するprocの内部で、パラメータに制約を加えたり、データの行数に変更を加えたり、中間の計算に制約を加えたり、負の数だからといって0に近い正の数に置き換えをする行為をしてはいけません。例えばGARCHでhがすべて正の値であるはずだからといって、Log-Likelihoodを定義する「procの内部で」制限を加えたり置き換えをするのは適当ではありません。たいていの場合は、こうした補正した領域でLog-Likelihoodが最大になることは稀ですが、もしそこで最大値が見つかったらそれは誤りです。「procの外部で」事後的に確認するアルゴリズムを書いてやるプログラムが正当なやり方であると思われます。もし、その確認に引っかかってしまったら、そこはローカルな極値である可能性が高く、あらためて別のスタートベクトルから始めて、違う場所の最大値を見つけることになります。もちろん、プログラムではなくて、コマンド言語では、h全体の符号を正にするためにいろいろな追加的な制約を課していることがあります。これはGAUSSのプログラムのやり方とは違うので、おそらくエラーはないものだと思いますが、GAUSSのプログラムに移植する際、特にLog-Likelihoodのprocの内部で制限を加えるには注意が必要です。

CMLにはいろいろなstatistical inferenceをともなってパラメータの推定値を表示できます。バウンダリー条件のみがある標準Tobitにおいて、通常の信頼区間を求めるのならば、

プログラム（変更箇所）

```
{x,f,g,cov,retcode}=cml(data,0,&ll,start);  
call cmlclprt(x,f,g,cmltlimits(x,cov),retcode);
```

とします。

また、WALD statisticsのinversionによってConstrained信頼区間を求めるのならば、

プログラム（変更箇所）

```
{x,f,g,cov,retcode}=cml(data,0,&ll,start);  
call cmlclprt(x,f,g,cmlclimits(x,cov),retcode);
```

とすると結果は次のようになります。

画面表示

```
return code = 0
```

normal convergence

Mean log-likelihood -3.16591

Number of cases 50

Parameters	Estimates	0.95 confidence limits		Gradient
		Lower Limit	Upper Limit	
-----				
CONST	-47.4330	-139.8330	44.9670	-0.0000
C18	-7.1220	-13.5680	-0.6761	-0.0000
AGE	2.8162	-1.9586	7.5909	-0.0000
AGE2	-0.0432	-0.0983	0.0119	-0.0000
ED	2.5322	-0.2414	5.3058	-0.0000
HI	0.0001	-0.0002	0.0004	-0.0000
SIGMA	22.4303	16.2906	28.5700	0.0000

Number of iterations 1074

Minutes to convergence 2.14483

上の結果とこの場合ほとんど同じになりますが、Inverse Hessianを用いて計算した信頼区間は、Covariance Matrixの計算方法をquasi-maximum likelihoodのオプションに設定するためにグローバル変数\_cml\_CovParを3としたうえ、

プログラム（変更箇所）

```
_cml_CovPar=3;  
{x,f,g,cov,retcode}=cml(data,0,&ll,start);  
call cmlclprt(x,f,g,cmltlimits(x,_cml_HessCov),retcode);
```

とすることで計算できます。なお、グローバル変数\_cml\_CovParは

また、このInverse Hessianを用いて計算した場合のConstrained信頼区間は、cmltlimitsのtをcに変更して、cmlclimitsを用いて、

プログラム（変更箇所）

```
_cml_CovPar=3;  
{x,f,g,cov,retcode}=cml(data,0,&ll,start);  
call cmlclprt(x,f,g,cmlclimits(x,_cml_HessCov),retcode);
```

とすることで計算できます。なお、グローバル変数 `_cml_CovPar` は上の 2 つにおいては必ず 3 である必要があります。ちなみに、0 がデフォルトで、iteration 結果の最終 `information matrix` の `inverse` から求める `Covariance Matrix` となっています。1 は `Hessian` の `inverse`、2 は 1 階の微分の外積によるものです。上で設定した 4 つの信頼区間計算は、上の例では、不等号制約上でパラメータ解が決まっていなかったために、通常の `Maxlik` と同じ計算をしているので、すべて結果が同じになります。もし、パラメータの一部が、制約条件上で決まってくると、これらのパラメータの信頼区間は若干の違いが出てきます。

さらに、通常の `Wald` タイプの信頼区間ではなくて、`likelihood ratio` の `inversion` から計算する `profile likelihood` の信頼区間を求めるのには、次のように設定して計算をします。

プログラム（変更箇所）

```
{x,f,g,cov,retcode}=cml(data,0,&ll,start);
call cmlclprt(x,f,g,cmlpfclimits(x,f,data,0,&ll),retcode);
```

画面表示

```
return code =    0
normal convergence
```

```
Mean log-likelihood      -3.16591
```

```
Number of cases        50
```

0.95 confidence limits				
Parameters	Estimates	Lower Limit	Upper Limit	Gradient
-----				
CONST	-47.4330	-146.2462	40.9367	-0.0000
C18	-7.1220	-13.9683	-0.9374	-0.0000
AGE	2.8162	-1.6781	8.0404	-0.0000
AGE2	-0.0432	-0.1047	0.0078	-0.0000
ED	2.5322	-0.2588	5.3379	-0.0000
HI	0.0001	-0.0003	0.0004	-0.0000
SIGMA	22.4303	17.5442	29.9622	0.0000

```
Number of iterations    1074
```

```
Minutes to convergence   2.74817
```

上と同じパラメータ推定を `Weighted Bayesian Bootstrap` によって行ない、さらにその結果を `bootstrap` による信頼区間とともに表示するには、



プログラム（変更箇所）

```
_cml_BootFname="tobit";  
{x,f,g,cov,retcode}=cmlboot(data,0,&ll,start);  
call cmlclprt(x,f,g,cmlblimits(_cml_BootFname),retcode);
```

画面表示

```
return code =    0  
normal convergence
```

Mean log-likelihood            -3.14952

Number of cases            50

0.95 confidence limits				
Parameters	Estimates	Lower Limit	Upper Limit	Gradient
CONST	-57.1415	-145.2310	-3.8253	-0.0000
C18	-6.5568	-14.4458	-2.4693	-0.0000
AGE	3.4539	-0.5019	6.9244	-0.0000
AGE2	-0.0503	-0.0939	-0.0155	-0.0000
ED	2.2270	-0.2350	3.9731	-0.0000
HI	0.0001	-0.0004	0.0003	-0.0000
SIGMA	21.0420	14.7670	26.5213	0.0000

Number of iterations        144

Minutes to convergence      0.05686

上のように表示されるまでアウトプットウィンドウはしばらくの間、空白になります。ただし、あらかじめ\_cml\_BootFnameによって、Bootstrap信頼区間のパラメータが格納される場所を指定することが必要です。この格納されたデータセットの入ったグローバル変数\_cml\_BootFnameをもとにcmlblimitsによって、信頼区間が計算され、信頼区間の場合の表示フォーマットであるcmlclprtによって、パラメータとともにBootstrap信頼区間が画面表示されます。

このようにConstrained Maximum Likelihoodのケースには、パラメータに制約が課されるため、通常のstandard errorに依存するsymmetricな信頼区間ではなくて、制約にもとづいた信頼区間を計算する必要があります。その信頼区間計算にいろいろな方法があるわけです。従来のstandard errorから計算したt比などではなくて、実際の非対称な信頼区間が重要になってくるわけです。

