

4.7 特殊関数とライブラリ GPE2 と GAUSS の対応関係 ver. 0.2

以前にも繰り返しことわっているように、GPE2はサードパーティーのプログラム（こういうものはGAUSSXをはじめ数多くある）で、そのソースがコンパイルされて読めなくなっているProf.Linのアドオンパッケージ（機能を加えるもの）である。一部の読者は、彼の本を手に入れてプログラムをしている人もいると思われるので、ここでGAUSS本体およびMAXLINK / CMLライブラリとこのGPE2 パッケージとの違いについて述べます。

GPE2もライブラリーと同じようにしてGAUSSのプログラム上で動きます。しかしながら、その根幹のところで、GAUSSの文法や基本構造とはまったく別の操作を必要とするので細心の注意が必要です。

GAUSS	GPE2
プログラムの冒頭は new;	プログラムの冒頭は 必ずuse gpe2; new;どこにも書いてはいけない

GAUSSを学んだことのある人なら奇異に感じるかもしれませんが、new;文はGPE2を呼び出したGAUSSのプログラムでは使用してはいけません。結果が全く表示されなくなってしまう。また、通常ライブラリを呼び出すときには、new; cls;の後にライブラリを呼び出せますが、GPE2を呼び出すのは、必ず1行目の一番最初でなければなりません。Prof.Linの本に、new;文がないのはそういうわけである。（おそらく、new;文がuse gpe2;とする際に実行されるものと思われるし、そう希望します。）なお、Output Window上の前回までの古い表示を消してから新しく表示するには、GAUSSのプログラム構造と同様に、cls;が使えます。また、GPE2では、推定や最大最小を求める場合には、すべてestimate文を用います。OLSもQNewtonもMAXLINKもCMLもすべてestimate文で一括して扱うこととなります。GPE2とは、いわばマルチ関数estimateを扱うためのパッケージであり、それに各種専用グローバル変数を与えて、いろいろな推定をするものです。

GAUSS	GPE2
それぞれのリセット文; call それぞれの関数名; (例) maxset; call maxprt();	call reset; call estimate();

GAUSSでもリセット文は、それぞれのライブラリにあって、call文で書いても、直接書い

でも構いませんでしたから、その点はGAUSSでもGPE 2でも同じ構造になっています。なお、GPE 2においても、callなしのreset;で同じ動作をするものと思われます。

1) _nlopt=0 (デフォルト) のケース

さて、ここで基本的な線形の最小2乗法のregressionを行なって違いを見てみます。基本的には、下のような関係になっています。GPE 2の方には、estimate文の前にcall reset;がさらに必要になります。

GAUSS

```
call ols(0,y,x);  
または自作プログラム
```

GPE2

```
call estimate(y,x);
```

今、Dドライブにdatafile1.txtというyとxについてのデータがあるとします。
プログラム (GAUSS本体を用いた場合)

```
new; cls;  
load data[29,2]=d:datafile1.txt;  
data=data[2:29,.];  
y=data[:,1]; x=ones(28,1)~data[:,2];  
{b,se,t,shat,df,r2}=lse(y,x);  
print "y-intercept:" b[1] "      slope for x:" b[2];  
print "          se:" se';  
print "          t:" t';  
print "Std of est : " shat;  
print /rz "          df=" df;  
print /rz "          R2=" r2;
```

```
proc(6)=lse(y,x);  
    local b,uhat,n,k,df,s2hat,shat,varb,se,t,r2;  
    b=inv(x'x)*x'y;  
    uhat=y-x*b;  
    n=rows(x);  
    k=cols(x);  
    df=n-k;
```

```

s2hat=uhat'uhat/df;
shat=sqrt(s2hat);
varb=s2hat*inv(x'x);
se=diag(sqrt(varb));
t=b./se;
r2=1-uhat'uhat/(y'(eye(n)-1/n*ones(n,1)*ones(n,1))*y);
retp(b,se,t,shat,df,r2);

```

endp;

画面表示

```

y-intercept:      77.795      slope for x:      52.010
                se:      22.037      3.8317
                t:      3.5301      13.573
Std of est :      52.331
df=              26
R2=              0.87633

```

プログラム (GAUSSのOLSコマンドを用いた場合)

```

new; cls;
load data[29,2]=d:datafile1.txt;
data=data[2:29,.];
y=data[.,1]; x=ones(28,1)~data[.,2];      /* Or x=data[.,2]; */
call ols(0,y,x);

```

画面表示

```

Valid cases:      28      Dependent variable:      Y
Missing cases:      0      Deletion method:      None
Total SS:      575746.679      Degrees of freedom:      26
R-squared:      0.876      Rbar-squared:      0.872
Residual SS:      71201.875      Std error of est:      52.331
F(1,26):      184.239      Probability of F:      0.000

```

Variable	Estimate	Standard Error	t-value	Prob > t	Standardized Estimate	Cor with Dep Var
CONSTANT	77.795198	22.037400	3.530144	0.002	---	---
X1	52.009829	3.831727	13.573468	0.000	0.936126	0.936126

プログラム (GPE2を用いた場合)

```
use gpe2;
cls;
load data[29,2]=d:datafile1.txt;
data=data[2:29,.];
y=data[:,1]; x=data[:,2];
call reset;
call estimate(y,x);
```

画面表示

Least Squares Estimation

Dependent Variable = Y

Estimation Range = 1 28

Number of Observations = 28

Mean of Dependent Variable = 345.11

Standard Error of Dependent Variable = 146.03

R-Square = 0.87633 R-Square Adjusted = 0.87157

Standard Error of the Estimate = 52.331

Log-Likelihood = -149.51

Log Amemiya Prediction Criterion (APC) = 7.9842

Log Akaike Information Criterion (AIC) = 7.9839

Log Schwarz Bayesian Information Criterion (BIC) = 8.0791

Sum of Squares	SS	DF	MSS	F	Prob>F
Explained	5.0454E+005	1	5.0454E+005	184.24	2.6071E-013
Residual	71202.	26	2738.5		
Total	5.7575E+005	27	21324.		

Variable	Estimated	Standard	t-Ratio	Prob	Partial
Name	Coefficient	Error	26 DF	> t	Regression
X1	52.010	3.8317	13.573	2.6071E-013	0.87633
CONSTANT	77.795	22.037	3.5301	0.0015710	0.32401

3つのOLSを行なうプログラムを結果とともに上に示しました。一番最初のプログラムは

再々掲になりますが、通常GAUSSでプログラムをやる際に最低限要求されるものです。通常、学部上級や大学院において、GAUSSでプログラムせよという場合には、コマンドを使わずに行列方式の計算を自分で組み立てていきます。必要な統計量の計算は自分で書いて組み入れます。また、コンスタントのところが必要な場合には、自分ですべての要素が1の列ベクトルを独立変数側にマージする必要があります。2番目のプログラムは、コマンドを用いたGAUSSの使い方ということで今まであえてとりあげなかったのですが、GPE2との比較ということで、ここに掲載してみました。文法は非常に簡単で、`ols(0,y,x)`をcall文で呼び出します。その第1要素の0が入っているところには、データセットが入るのですが、通常の使用では0または""としてnull stringをいれて無効にします。第2要素には従属変数のベクトルが、第3要素には独立変数のベクトルまたは行列はきます。なお、OLSを用いる場合には、コンスタントの1ばかりの列ベクトルを作成して独立変数側にマージしなくても、OLS関数が自動判断してコンスタントをつけた計算をしてくれます。正式の文法は、

```
{ vnam,m,b,stab,vc,stderr,sigma,cx,rsq,resid,dwstat } =ols(dataset,depvar,indvars);
```

というように11個のリターンを返す関数になっています。なおコンスタント項がないOLSをするのには、GAUSSのOLSコマンドでは、ダブルの下線のグローバル変数

```
_CON = 0; ( GAUSS OLSコマンドの場合 )
```

としてやります。その次に3番目の、GPE2のプログラムでは、独立変数には決して1のコンスタントの列ベクトルをマージしてはいけません。Perfect Colinearityのエラーを出して止まってしまいます。なお、コンスタント項がないOLSをするのには、GPE2では、

```
_const=0; ( GPE2の場合 )
```

の行を加えます。こちらは、シングルの下線です。また、変数ラベルを加える場合には、

```
_names={"Dep","Indep"}; ( GPE2の場合 )
```

という具合に、従属変数名、独立変数名の順で引用符に包んでラベル名を設定します。2個以上独立変数がある場合は、さらにラベル名を書き加えていきます。なお、コンスタント項は、最初からCONSTANTとされているので、このラベル名の指定には加えません。前述したように、GPE2を用いるときには、`call reset;`の文が必要で、これらのグローバル変数を指定する前に置きます。このように、リニアの単純なケースでも、GAUSSの構造と

GPE2の構造は似て非なるというよりも、区別するために故意に根幹のところで変更が加えられているので注意が必要です。とは言うものの、GPE2はGAUSSの上に乗っているパッケージであってGAUSSのプログラムについてこれまで習得したすべてのことができます。最終局面でestimate文を実行するために、通常のGAUSS部分と区別するために、文法に大幅な変更が加えられているのです。

上のケースは、リニアのケースでしたが、estimate文はそれ1つで、こればかりでなく最大最小を求めるケースからノンリニアの推定のケースまで幅広く使えるようになっていきます。それぞれのケースにはそれぞれのケースのグローバル変数を設定することになります。その値によって、estimate関数の内部で場合分けがなされて、何も設定されない場合はリニアのOLS、そうでない場合には、最大最小を求めたり、ノンリニアのケースになったりするわけです。

次に、GAUSSのQNewtonで扱った最小値(または極小値)をもとめるプログラムとGPE2のプログラムを比較します。グローバルな極小値をもたない最適値問題(2)で扱ったと同じ関数 $h(x_1, x_2) = x_1^3 + x_2^3 - 9x_1x_2 + 27$ を用いて極小値を求めてみます。QNewtonで扱ったのと同じプログラムを再掲します。

プログラム (GAUSSのQNewtonのケース)

```
new; cls;
qnewtonset;
fn h(x)=x[1]^3+x[2]^3-9*x[1]*x[2]+27;
x0={1,1};
call QNewton(&h,x0);
```

画面表示

return code = 0

normal convergence

Value of objective function 0.000000

Parameters	Estimates	Gradient

P01	3.0000	0.0000
P02	3.0000	0.0000

Number of iterations 9

Minutes to convergence 0.00467

プログラム (GPE2のケース)

```

use gpe2;
cls;
call reset;
fn h(data,x)=x[1]^3+x[2]^3-9*x[1]*x[2]+27;
_nlopt=0;
_b={1,1};
_method=6;      /* Or 3 or 5 */
_iter=100;
call estimate(&h,0);

```

上のように、まず 1 番目のQNewtonの場合には、1 値ベクトルの関数を立ててから、それをQNewtonでポインタのしるし&をつけて、スタートベクトルとともに呼び出しました。そのグローバル変数をリセットするには、qnewtonset;を用います。2 番目のGPE2のケースでは、まったく異なる文法体系になります。MAXLIKで呼び出す関数などと同じように、dataも含んだ 2 値関数を立てなくてはなりません。しかしながら、関数の単純な最小（極小）の場合には、全体のdataそのものが存在しませんから、一応からのままdataとしてやります。MAXLIKで呼び出される関数は、ll(b,data)のように、パラメータベクトル、そして全体のもとになるデータ行列の順でしたが、GPE 2 の場合には、この左右を逆にします。これは後で取り扱うノンリニアのMax Log-Likelihoodを求めるケースでも左右を逆にしなければなりません。（車の非関税障壁のハンドルの左右付け替えのようなことがGPE 2 パッケージではみられます。したがって、GPE2を初心者に学習させるのは将来GAUSSでプログラムする人にはふさわしくないと思われます。大きな混乱が生じます。）GPE 2 では、このような左右逆にした 2 値関数を、関数の最小（極小）を求める際にも使います。call reset;の後、_nlopt=0;によってどのようなOptimizationを行なうかを指定します。デフォルト 0 の場合は、最小化（極小化）問題を解きます。これが 1 の場合には、最大化（極大化）問題を解きます。2 の場合には、MAXLIK/CMLと同じようなベクトル形式になったLog-Likelihoodの最大化を行ないます。ですから、_nlopt=0;はこの場合任意となります。スタートベクトルはグローバル変数_bとして必ず設定しなくてはなりません。直接変数として設定してはいけません。_nlopt=0;の場合の最小化極小化の場合にはこれを取りおこなうMethodはSteep-ascent/decentなのですが、上の問題はこれでは解けなくて、Methodを設定するグローバル変数_methodで 6 としています。なお、上の問題の場合には、3 または 5 でも計算できます。ここで注意すべきことは、iterationの数の設定です。QNewton MAXLIK/CMLではデフォルトが決まっています設定する必要がありませんでしたが、GPE2では必ず設定することが必要になります。上のプログラムでは、_iterというグローバル変数に100を代入することによって、最高100回のiterationをする設定にしています。そうでなければ、iterationは 1 回で止まります。最後に、call estimate(&h,0);でその第 1

要素でポインタのしるしの&をつけて関数を呼び出し、第2要素には、この場合データは空ですから0を代入して空であることをしめています。この第2要素はスタートベクトルではありませんので注意が必要です。なお、ここに空の0ではなくて、全体のdataがくると、もし定義されている関数がベクトル形式のresidual functionであれば、SSE最小化を行なうことになります。というわけで、ここの2番目の0はデータが空であるという意味です。第1番目のポインタがついた関数ではなくて従属変数名がくるとリニアのOLSを自動的に判断してやることになるのは、一番最初にやったとおりです。Methodオプションをまとめておくと、

`_method=0` (デフォルト) Steep-ascent/decent

- | | |
|---|---------------------------|
| 1 | BFGS法 |
| 2 | DEP法 |
| 3 | Greenstad法 |
| 4 | ニュートン = ラブソン法 |
| 5 | Quadratic Hill-Climbing法 |
| 6 | 修正Quadratic Hill-Climbing |

なお、デフォルトは、ノンリニアLSの場合にはガウス = ニュートン法が、ML推定の場合には、BHHHがデフォルトになり変化します。

GAUSS

`fn h(b)=...` ; 1 値関数

`b={ }` ;

`call QNewton(&h,b);`

GPE2

`fn h(data,b)=...` ; 2 値関数

`_b={ }` ; グローバルとして

`_iter=100;` 必須

`call estimate(&h,0);`

次にこれと同じ最小値を求める計算を利用してSSEを最小にするパラメータを求める計算を引き続きdatafile1.txtを用いて行ないます。今度はdataがある場合についてです。

プログラム (GAUSSのQNewtonのケース)

`new; cls;`

`load data[29,2]=d:datafile1.txt;`

`data=data[2:29,.];`

`b={1,1};`


```

qnewtonset;
_qn_ParNames={"CONST","X"};
call QNewton(&sse,b);

```

```

proc sse(b);
    local y,x;
    y=data[.,1];
    x=ones(28,1)~data[.,2];
    retp((y-x*b)'(y-x*b));
endp;

```

画面表示

```

return code =    0
normal convergence

```

Value of objective function 71201.875467

Parameters	Estimates	Gradient

CONST	77.7952	-0.0016
X	52.0098	-0.0079

```

Number of iterations        18
Minutes to convergence    0.00083

```

プログラム（ GPE2のケース ）

```

use gpe2;
cls;
load data[29,2]=d:datafile1.txt;
data=data[2:29,.];

call reset;
_b={1,1};
_method=6;
_iter=100;
_names={"CONST","X"};
call estimate(&sse,data);

```

```

proc sse(data,b);
  local y,x;
  y=data[:,1];
  x=ones(28,1)~data[:,2];
  retp(y-x*b);          /* (y-x*b)'(y-x*b) is also allowed. */
endp;

```

画面表示

Final Result:

Iterations = 66 Evaluations = 39900

Sum of Squares = 71202.

Parameters = 77.795 52.010

Gradient Vector = -5.6919e-005 -7.1731e-005

		Asymptotic	Asymptotic
	Parameter	Std. Error	t-Ratio
CONST	77.795	21.236	3.6634
X	52.010	3.6923	14.086

上のように、まず 1 番目のQNewtonを用いた方法では、1 値関数のSSE(b)を作成したうえで、qnewtonset;でグローバル変数をリセットしてから、QNewtonでポインタ&をとまってその関数を、スタートベクトルとともに呼び出して最小化します。パラメータにラベルをつける場合には、グローバル変数_qn_ParNamesを設定します。一方、2 番目のGPE2を用いた方法では、SSE(data,b)というふうに 1 値関数ではなくて 2 値関数を作成したうえでcall reset;でグローバル変数をリセットしてから、グローバル変数_bとしてスタートベクトルを設定し、_namesでラベルを設定します。この際、最大iteration数は必ず設定しないと動きませんので、_iter=100;としています。SSE(data,b)のところは、GPE 2 の場合、通常のGAUSSの計算と同じようにSSEをe'eを計算することによって用いるほかに、直前に述べたように、eのままのresidual functionをリターンにして、これを呼び出してもGPE2の内部で判断して、SSEを最小にするパラメータを計算してくれます。

2) _nlopt=1のケース

これまでのケースは_nlopt=0のリニアなケースの最小 2 乗法および最小値をもとめる計算でした。今度の_nlopt=1というのは、Log-Likelihoodを直接最大にするオプションです。ベクトル形ではなくて、すでに足し合わせたLog-Likelihoodそのものを最大化します。MAXLIKであえて扱いませんでしたが、ベクトル形だけでなく、下のようにLog-Likelihood

そのものも最大化も可能です。

プログラム

```
new; cls;
library maxlik;
maxset;
load data[29,2]=d:datafile1.txt;
data=data[2:29,.];

start={0,0,1};
_max_Algorithm = 2;
_max_ParNames = {"CONST","X","s"};
call maxprt(maxlik(data,0,&ll,start));

proc ll(b,data);
  local beta, s, y, x, e,n;
  y=data[.,1];
  x=ones(28,1)~data[.,2];
  beta=b[1:2];
  s=b[3];
  e=y-x*beta;
  n=rows(data);
  retp(-1/2*n*ln(2*pi)-1/2*n*ln(s^2)-1/2*e'e/s^2);
endp;
```

画面表示

return code = 0

normal convergence

Mean log-likelihood -5.33947

Number of cases 28

Covariance matrix of the parameters computed by the following method:

Inverse of computed Hessian

Parameters	Estimates	Std. err.	Est./s.e.	Prob.	Gradient
------------	-----------	-----------	-----------	-------	----------

CONST	77.7952	21.2356	3.663	0.0001	-0.0000
X	52.0098	3.6923	14.086	0.0000	-0.0000
s	50.4274	6.7387	7.483	0.0000	0.0000

Correlation matrix of the parameters

1.000	-0.894	-0.000
-0.894	1.000	0.000
-0.000	0.000	1.000

Number of iterations 91

Minutes to convergence 0.11250

プログラム (GPE2のケース)

```

use gpe2;
cls;
load data[29,2]=d:datafile1.txt;
data=data[2:29,.];

```

```

call reset;
_nlopt=1;
_method=5;
_iter=10000;
_b={0,0,1};
_names = {"CONST","X","s"};
call estimate(&ll,data);

```

```

proc ll(data,b);
  local beta, s, y, x, e,n;
  y=data[.,1];
  x=ones(28,1)~data[.,2];
  beta=b[1:2];
  s=b[3];
  e=y-x*beta;
  n=rows(data);

```

```

      retp(-1/2*n*ln(2*pi)-1/2*n*ln(s^2)-1/2*e'e/s^2);
    endp;

```

画面表示

Final Result:

```

Iterations = 83          Evaluations = 2227
Function Value =      -149.51
Parameters =      77.795      52.010      50.427
Gradient Vector =      0.00000      0.00000  2.6490e-006

```

		Asymptotic	Asymptotic
	Parameter	Std. Error	t-Ratio
CONST	77.795	21.236	3.6634
X	52.010	3.6923	14.086
S	50.427	6.7389	7.4831

上の2つの違いは、ll関数のインプットの順序が逆になることです。MAXLIKでは、パラメータベクトル、そしてデータ行列の順です。GPE2ではこれが左右逆転します。ll関数は、 $-1/2*n*ln(2*pi)-1/2*n*ln(s^2)-1/2*e'e/s^2$ というふうに、すでに足し合わされた形をどちらも使っています。

3) _nlopt=2のケース

最後に、足し合わせる前のベクトル形のLog-Likelihoodを最大にする方法をGAUSSのMAXLIKによる従来の方法とGPE2による方法の2つを示して比較します。

プログラム (GAUSSのMAXLIKを用いたケース)

```

new; cls;
library maxlik;
maxset;

load data[29,2]=d:datafile1.txt;
data=data[2:29,.];
start={0,0,1};
_max_Algorithm = 2;
_max_ParNames = {"CONST","X","s"};
call maxprt(maxlik(data,0,&ll,start));

```

```

proc ll(b,data);
  local beta, s, y, x, e;
  y=data[:,1];
  x=ones(28,1)~data[:,2];
  beta=b[1:2];
  s=b[3];
  e=y-x*beta;
  retp(-1/2*ln(2*pi)-1/2*ln(s^2)-1/2*e^2/s^2);
endp;

```

画面表示

```

return code =    0
normal convergence

```

```

Mean log-likelihood      -5.33947
Number of cases         28

```

Covariance matrix of the parameters computed by the following method:
Inverse of computed Hessian

Parameters	Estimates	Std. err.	Est./s.e.	Prob.	Gradient
CONST	77.7945	21.2356	3.663	0.0001	-0.0000
X	52.0099	3.6923	14.086	0.0000	-0.0000
s	50.4275	6.7388	7.483	0.0000	0.0000

Correlation matrix of the parameters

```

  1.000 -0.894 -0.000
-0.894  1.000  0.000
-0.000  0.000  1.000

```

```

Number of iterations    91
Minutes to convergence  0.11800

```

プログラム (GPE2のケース)

```

use gpe2;

```

```

cls;
load data[29,2]=d:datafile1.txt;
data=data[2:29,.];

```

```

call reset;
_nlopt=2;
_method=5;
_iter=10000;
_b={0,0,1};
_names = {"CONST","X","s"};
call estimate(&ll,data);

```

```

proc ll(data,b);
    local beta, s, y, x, e;
    y=data[.,1];
    x=ones(28,1)~data[.,2];
    beta=b[1:2];
    s=b[3];
    e=y-x*beta;
    retp(-1/2*ln(2*pi)-1/2*ln(s^2)-1/2*e^2/s^2);
endp;

```

画面表示

Final Result:

```

Iterations = 83          Evaluations = 62356
Log Likelihood =      -149.51
Parameters =      77.795      52.010      50.427
Gradient Vector = -2.2834e-009 -1.7077e-009  2.6966e-006

```

	Parameter	Asymptotic Std. Error	Asymptotic t-Ratio
CONST	77.795	21.236	3.6634
X	52.010	3.6923	14.086
S	50.427	6.7389	7.4831

今度は、 $-1/2 \cdot \ln(2 \cdot \pi) - 1/2 \cdot \ln(s^2) - 1/2 \cdot e^2/s^2$ という具合に、ll関数を足し合わせる前のベクトルの形でリターンさせたものを呼び出します。そのほかの部分は、オプション2のときと基本的に同じプログラムです。習慣的に、また経験的に、このベクトルの形の方が収束する確率が高いとされており、この方法がLog-Likelihoodを直接最大化するよりも用いられる傾向にあります。そういった意味で、MAXLIKのところでは、直接最大化する方法は示していませんでした。

GAUSS

```
library maxlik;
maxset;
b={  };

call maxprt(maxlik(data,0,&ll,start));
proc ll(b,data);
```

GPE2

```
use gpe2;
call reset;
_b={  };
_nlopt=2;または_nlopt=3;

call estimate(&ll,data);
proc ll(data,b);
```

今度は、最大化をする機能ではなくて、リニアの制約を加えて、F分布に関するテストをするオプションを考えます。いま、Dドライブにdatafile10.txtという30×3のデータがあるとします(Judge[1988]Ch.12より)。1列目はL、2列目はK、最終3列目にQとします。これをトランスログ関数として、2次項にすべて0の同時制約をかけてコブダグラス型にできるかどうかテストします。その次に、このトランスログ型関数が成立しているものとして、1次同次を満たすかどうかを係数の線形制約からテストします。モデルは

$$\ln Q = \alpha_0 + \alpha_1 \ln L + \alpha_2 \ln K + 0.5 \alpha_3 (\ln L)^2 + \alpha_4 (\ln L)(\ln K) + 0.5 \alpha_5 (\ln K)^2$$

という2次形式までの近似式とします。ここではMulticollinearityを無視して、上の関係を直接このまま推定するものとします。

プログラム

```
use gpe2;
cls;
load data[30,3]=d:datafile10.txt;
l=data[:,1];k=data[:,2];q=data[:,3];
y=ln(q);x=ln(l)~ln(k)~(0.5*(ln(l)^2))~(ln(l).*ln(k))~(0.5*(ln(k)^2));

_restr={0 0 1 0 0 0,
        0 0 0 1 0 0,
        0 0 0 0 1 0};
```


call estimate(y,x);

**_restr={1 1 0 0 1,
0 0 1 1 0 0,
0 0 0 1 1 0};**

call estimate(y,x);

画面表示

Least Squares Estimation

Dependent Variable = Y

Estimation Range = 1 30

Number of Observations = 30

Mean of Dependent Variable = -1.5327

Standard Error of Dependent Variable = 1.4538

WARNING: Linear Restrictions Imposed.

R-Square, AOV, SE, and t may not be reliable!

Wald F-Test for Linear Restrictions

F(3, 24) Prob>F

12.995 3.0389E-005

R-Square = 0.91833 R-Square Adjusted = 0.91229

Standard Error of the Estimate = 0.43056

Log-Likelihood = -15.708

Log Amemiya Prediction Criterion (APC) = -1.5030

Log Akaike Information Criterion (AIC) = -1.3907

Log Schwarz Bayesian Information Criterion (BIC) = -1.1105

Sum of Squares	SS	DF	MSS	F	Prob>F
Explained	56.285	2	28.142	151.81	2.0535E-015
Residual	5.0053	27	0.18538		
Total	61.290	29	2.1135		

Variable	Estimated	Standard	t-Ratio	Prob	Partial
Name	Coefficient	Error	27 DF	> t	Regression
X1	0.73581	0.065797	11.183	1.2237E-011	0.82244

X2	0.94899	0.062907	15.086	1.1213E-014	0.89394
X3	0.00000	0.00000	0.00000	0.00000	0.00000
X4	2.6645E-015	0.00000	0.00000	0.00000	0.00000
X5	-8.8818E-016	0.00000	0.00000	0.00000	0.00000
CONSTANT	0.42480	0.13781	3.0825	0.0046895	0.26031

Least Squares Estimation

Dependent Variable = Y

Estimation Range = 1 30

Number of Observations = 30

Mean of Dependent Variable = -1.5327

Standard Error of Dependent Variable = 1.4538

WARNING: Linear Restrictions Imposed.

R-Square, AOV, SE, and t may not be reliable!

Wald F-Test for Linear Restrictions

F(3, 24)	Prob>F
2.1255	0.12345

R-Square = 0.96061 R-Square Adjusted = 0.95770

Standard Error of the Estimate = 0.29901

Log-Likelihood = -4.7691

Log Amemiya Prediction Criterion (APC) = -2.2323

Log Akaike Information Criterion (AIC) = -2.1199

Log Schwarz Bayesian Information Criterion (BIC) = -1.8397

Sum of Squares	SS	DF	MSS	F	Prob>F
Explained	57.304	2	28.652	320.47	1.5469E-019
Residual	2.4139	27	0.089405		
Total	61.290	29	2.1135		

Variable	Estimated	Standard	t-Ratio	Prob	Partial
Name	Coefficient	Error	27 DF	> t	Regression
X1	0.43043	0.029075	14.804	1.7678E-014	0.89032

X2	0.56957	0.029075	19.590	1.7209E-017	0.93427
X3	-0.18945	0.016672	-11.364	8.5432E-012	0.82707
X4	0.18945	0.016672	11.364	8.5432E-012	0.82707
X5	-0.18945	0.016672	-11.364	8.5432E-012	0.82707
CONSTANT	-0.024217	0.062320	-0.38859	0.70063	0.0055615

プログラムの前半部分は、30行3列のデータをdataという行列に読みこんで、1行目をL、2行目をK、3行目をQに割り当てます。従属変数 y に $\ln(q)$ を、独立変数に、 $\ln L$ 、 $\ln K$ 、 $0.5(\ln L)^2$ 、 $\ln L \ln K$ 、 $0.5(\ln K)^2$ の5変数と定数項（つけなければ自動的につきます）とします。これを一番最初にやったcall estimateをリニアのケースに使う方法で推定をします。その際に、estimateの第1要素は従属変数で、第2変数は独立変数を水平方向に～のしるしでマージしたのになります。その際に、リニアの制約を加えます。最初の制約は、

$$3=0 \quad \text{かつ} \quad 4=0 \quad \text{かつ} \quad 5=0$$

ですから、 $R = q$ 方式で、定数項を除いた形で、

$$\begin{matrix} & & & & & \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \\ \beta_4 \\ \beta_5 \end{bmatrix} \\ \begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} & = & \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} & \text{ですから} \\ 3 \times 5 & & 5 \times 1 & & 3 \times 1 \end{matrix}$$

GAUSSでは、GPE2のグローバル変数_restrのパラメータを、Rとqを[R q]というふうに水平方向にマージした3行6列の行列に設定します。すなわち、ここでは

```
_restr={0 0 1 0 0 0,
        0 0 0 1 0 0,
        0 0 0 0 1 0};
```

となります（定数項の係数は含まれませんので注意を）。F分布はパラメータ制約が3本（すなわち、Rまたはqの行数が3）、N-Kの自由度は $30 - 6 = 24$ になります（6は定数項も含むXの行列の列数に相当）。 $F(3,24)$ が約13で十分に大きくP値もほとんど0で、F分布のかなり右のテイルにきますから、

$H_0 : 3=0 \quad \text{かつ} \quad 4=0 \quad \text{かつ} \quad 5=0$ （すなわちコブダグラス型）

$H_1 : H_0 \text{ is NOT true.}$

でH0の帰無仮定は棄却されますから、この場合、二者選択なら、コブダグラス型ではなくてトランスログ型が選択されることになります。同様に、これがトランスログだとした上で、今度は1次同次であるかどうかをテストします。1次同次のこの場合の条件は、

$$\begin{aligned} 1 + 2 &= 1 \\ 3 + 4 &= 0 \\ 4 + 5 &= 0 \end{aligned}$$

を同時に満たすことですから、R = q方式で、

$$\begin{matrix} & & & & & \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \\ \beta_4 \\ \beta_5 \end{bmatrix} \\ \begin{bmatrix} 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 \\ 0 & 0 & 0 & 1 & 1 \end{bmatrix} & = & \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} & \text{ですから} \\ 3 \times 5 & & 5 \times 1 & 3 \times 1 \end{matrix}$$

GAUSSでは、Rとqを水平方向にマージして3 × 6の行列のパラメータ

```
_restr={1 1 0 0 0 1,
        0 0 1 1 0 0,
        0 0 0 1 1 0};
```

と設定します。この場合も制約式は3本で、N Kは24でかわりませんから、F(3,24)が2.1255で、P値も0.1を超えていますから、10%に対しても5%に対しても

H0 : 1 + 2 = 1 かつ 3 + 4 = 0 かつ 4 + 5 = 0 (すなわち1次同次)
H1 : H0 is NOT true.

で帰無仮説H0は棄却されないので、この場合、1次同次と言えます。要するに、リニアの制約を与えるパラメータ_restrにはRとqの両方をマージした(定数項を含まない)行列を使うということです。なお、GPE2の回帰分析の結果には定数項が一番最後にくるようにデザインされています。また、定数項が自動に付け加えられるのはデフォルト設定です。

GAUSS(3.9章自作プログラム)

GPE2

定数項を含むRとqを用いる

_restrは定数項を除いた[R q]

(水平方向のマージ)

この他に、さらに諸テストに関するオプション、ラグやARおよびMAに関するオプション、それにForecastに関するオプションなどがグローバル関数で与えられているいろいろな計算がプログラムをすることなくできるようになったのがGPE 2です。冒頭に述べたように、最初の行の最初にuse gpe2;としなくてはいけないこととnew;としてはいけないのを除くと、ほぼすべてのGAUSSの文法と関数が使えます。また、MAXLIKなしにLog-Likelihoodの最大化ができます。