

ANNA BARTKOWIAK (Wrocław)

## THE CHOICE OF REPRESENTATIVE VARIABLES BY STEPWISE REGRESSION

**1. Procedure declaration.** The procedure *idepstep* performs a stepwise search for representative variables satisfying the minimax criterium of residual sums of squares given by formulae (1)-(4). It allows some variables to be introduced obligatorily into the set of representatives  $R$ . The search can be performed upwards — introducing new variables into the already established set, and backwards — eliminating the less representative variables from the set.

Data:

- $p$  — number of variables;
- $a[1 : p \times (p + 1) \div 2]$  — the lower triangle of the matrix of corrected sums of squares and products, stored row-wise;
- $nr[1 : p]$  — primary indices of the considered variables;
- $ind[0 : p + 2]$  — integer array whose elements have the following meaning:  $ind[0]$  declares the number of variables to be introduced obligatorily into the set of representatives; if  $ind[0] \neq 0$ , then the values of  $ind[1], \dots, ind[p]$  should be set equal to 1 for these variables and equal to 0 otherwise; the value of  $ind[p + 1]$  should be set equal to the maximum number of representatives to be selected stepwise upwards, and the value of  $ind[p + 2]$  should be set equal to the minimum number of representatives to be selected stepwise backwards;
- $eps$  — a small number indicating the machine accuracy (e.g.  $eps = 10^{-11}$ ).

Results:

- $ind[0 : p]$  — indicator array designating the variables actually present in the representative set  $R$ : if the  $i$ -th variable is in  $R$ , then  $ind[i] = 1$ ;  $ind[0]$  declares for which variable not being in  $R$  the residual sum of squares is the largest;

```

procedure idepstep(p,a,nr,ind,eps,onestep,outrepr);
  value p,eps;
  real eps;
  integer p;
  array a;
  integer array nr,ind;
  procedure onestep,outrepr;
  begin
    real flag,min,x,y,z;
    integer h,i,imin,imax,i1,i2,k,l,l1,m,m1,m2;
    array residuals[1:p];
    Boolean done;
    procedure findnext;
    begin
      imin:=ind[0]:=0; min:=.23;
      comment a big number;
      for m:=1 step 1 until p do
        if ind[m]=i1
          then
            begin
              m1:=m*(m-1)+2; x:=a[m1+m];
              if flag*x>eps
                then
                  begin
                    x:=1.0/x;
                    y:=if flag=1.0 then .0 else -x;
                    h:=if flag=1.0 then 0 else m;
                    k:=0;
                    for i:=1 step 1 until p do
                      begin

```

```

    if ind[i]=0^i≠m
    then
    begin
        m2:=if i<m then m1+i else k+m;
        z:=a[k+i]-a[m2]†2>x;
        if z>y
        then
        begin
            y:=z;
            h:=i
        end z>y
        end ind[i]=0;
        k:=k+i
    end i
    end flag<x>eps
    else h:=0;
    if h>0^y<min
    then
    begin
        min:=y; imin:=m;
        imax:=h
    end h>0 ^ y<min
    end m;
if imin=0
    then done:=true
    else
    begin
        ind[0]:=imax;
        onestep(imin,flag,p,a);
        ind[imin]:=i2; l:=l+flag;

```



```

        end x>eps
        else ind[m]:=0
        end m;
        outrepr(p,nr,m,3.0,ind,residuals)
        end l#0;
        l1:=ind[p+1];
        if l<l1
        then
        begin
            done:=false;
            flag:=1.0;
            i1:=0; i2:=1;
        addition:
            findnext;
            if l<l1^~done then go to addition
            end l<l1;
            l1:=ind[p+2];
        if l>l1
        then
        begin
            done:=false;
            flag:=-1.0;
            i1:=1; i2:=0;
        elimination:
            findnext;
            if l>l1^~done then go to elimination
            end l>l1
        end idepstep

```

$a[1 : p \times (p + 1) \div 2]$  — transformed input matrix  $a$ ; the diagonal elements for the variables not being in the set of representatives  $R$  are equal to the residual sums of squares of these variables regressed on the variables being in  $R$ .

Other results, especially those concerning the choice at each step, may be obtained by the procedure *ourepr* described in the sequel.

Other parameters:

*onestep* — identifier of the procedure calculating one step of the modified Gauss-Jordan procedure, headed as follows: **procedure** *one-step*( $q, v, p, c$ ); **value**  $q, v, p$ ; **real**  $v$ ; **integer**  $p, q$ ; **array**  $c$ ; where  $q$  is the no. of the variable to be pivoted in when  $v = 1.0$ , and pivoted out when  $v = -1.0$ ,  $p$  is the total number of variables,  $c$  is the lower triangle of the pivoted matrix given row-wise; the procedure performs the transformations given by (5) and (6);

*ourepr* — identifier of the procedure printing results of the search of representatives; the procedure should be headed as follows: **procedure** *ourepr*( $p, nr, m, flag, ind, residuals$ ); **value**  $p, flag, m$ ; **real**  $flag$ ; **integer**  $p, m$ ; **array**  $residuals$ ; **integer array**  $nr, ind$ ; where  $p$  is the total number of variables,  $nr$  — the order numbers of the  $p$  variables under consideration in the primary data set,  $m$  — the number of the variable last introduced into (eliminated from) the set of representatives  $R$ ,  $flag$  — an indicator variable with the following values:  $-1.0$  if the last step was elimination,  $+1.0$  if the last step was introduction,  $+2.0$  if the last step was obligatory introduction,  $ind[0]$  indicates for which variable not belonging to  $R$  the residual sum of squares is the largest,  $ind[1 : p]$  indicates the variables actually being in  $R$ ,  $residuals$  contains the diagonal elements of the transformed matrix  $c$ .

**2. Method used.** Let  $A$  be the matrix of adjusted sums of squares and products. Let  $l_0 = ind[0]$ ,  $l_1 = ind[p + 1]$ ,  $l_2 = ind[p + 2]$  be given integers. The procedure first introduces  $l_0$  variables into the set  $R$ .

Next, if  $l_1 > l_0$ , the search for representative variables starts. Let  $\bar{R}$  be the set of remaining variables, not being in the set  $R$ . We put each variable  $i_r \in \bar{R}$  to trial assuming it provisionally being adjoined to the representative set  $R$ , and seeking the greatest residual sum of squares (unexplained part of variance) of the remaining variables of  $\bar{R}$ , regressed on the variables being in  $R$ . Let  $SS_{i_{k0}}^{(i_r)}$  denote the maximum of them:

$$(1) \quad SS_{i_{k0}}^{(i_r)} = \max_{i_k \in \bar{R}, i_k \neq i_r} SS_{i_k}^{(i_r)}.$$

The variable  $i_0$ , for which this maximal unexplained variance is the smallest, i.e.

$$(2) \quad SS_{i_{k0}}^{(i_{r0})} = \min_{i_r \in \bar{R}} SS_{i_{k0}}^{(i_r)},$$

is chosen to be introduced into the set  $R$  of representative variables.

The elimination step is performed similarly. We move temporarily each variable  $i_r \in R$  from  $R$  to  $\bar{R}$  and seek the greatest residual sum of squares of the variables from  $\bar{R}$ . If

$$(3) \quad SS_{i_{k0}}^{(i_r)} = \max_{i_r \in \bar{R}} SS_{i_k}^{(i_r)}$$

is established for each  $i_r \in R$ , we remove finally from  $R$  that variable  $i_0$  for which

$$(4) \quad SS_{i_{k0}}^{(i_0)} = \min_{i_r \in R} SS_{i_{k0}}^{(i_r)}.$$

If a variable  $q = i_0$  to be introduced into  $R$  is chosen, we perform a full pivot transformation of the actual matrix  $A = \{a_{ij}\}$  by the use of the following formulae given by Jennrich [1]:

$$(5) \quad \begin{aligned} a'_{qq} &= -1/a_{qq}, & a'_{iq} &= a_{iq}/a_{qq}, & a'_{qj} &= a_{qj}/a_{qq}, \\ a'_{ij} &= a_{ij} - a_{iq}a_{qj}/a_{qq}, & i &\neq q, j \neq q. \end{aligned}$$

Similarly, if a variable  $q = i_0$  to be eliminated from  $R$  is chosen, perform a full inverse pivot transformation of the actual matrix  $A = \{a_{ij}\}$  by the use of the following formulae:

$$(6) \quad \begin{aligned} \tilde{a}_{qq} &= -1/a_{qq}, & \tilde{a}_{iq} &= -a_{iq}/a_{qq}, & \tilde{a}_{qj} &= -a_{qj}/a_{qq}, \\ \tilde{a}_{ij} &= a_{ij} - a_{iq}a_{qj}/a_{qq}, & i &\neq q, j \neq q. \end{aligned}$$

If the pivot element  $a_{qq}$  is less than *eps*, the declared real, then none of these transformations is performed.

**3. Test example.** Let  $p = 6$ , and

$$\begin{aligned} a[1:15] &= [1.0 \\ &\quad .5353 \quad 1.0 \\ &\quad .6346 \quad .7075 \quad 1.0 \\ &\quad .7037 \quad .6785 \quad .8902 \quad 1.0 \\ &\quad .3851 \quad .0971 \quad .0853 \quad .2263 \quad 1.0 \\ &\quad -.5425 \quad -.4333 \quad -.5389 \quad -.5830 \quad -.5606 \quad 1.0], \\ nr[1:p] &= [1 \quad 2 \quad 3 \quad 4 \quad 5 \quad 6], \\ ind[0:8] &= [2 \quad 0 \quad 0 \quad 1 \quad 0 \quad 1 \quad 0 \quad 5 \quad 2], \quad eps =_{10} -10. \end{aligned}$$

```
procedure onestep(q,v,p,c);  
  value q,v,p;  
  real v;  
  integer p,q;  
  array c;  
  begin  
    real x;  
    integer i,j,k;  
    array d[1:p];  
    k:=q*(q-1)÷2;  
    for i:=1 step 1 until q do  
      begin  
        k:=k+1;  
        d[i]:=c[k];  
        c[k]:=0  
      end i;  
    x:=1.0/d[q];  
    d[q]:=-v;  
    k:=k+q;  
    for i:=q+1 step 1 until p do  
      begin  
        d[i]:=c[k];  
        c[k]:=0;  
        k:=k+i  
      end i;  
    k:=0;  
    for i:=1 step 1 until p do  
      begin  
        v:=d[i]*x;  
        for j:=1 step 1 until i do
```



```

begin
  k:=k+1;
  c[k]:=c[k]-v*d[j]
end j
end i
end onestep
    
```

Using the procedures *onestep* and *ourepr*, given as an appendix, we obtain the following results.

(A) Results obtained by the procedure *ourepr*, called 8 times during the run of *idepstep*, are presented in Table 1.

TABLE 1

Step after which the procedure was called	No. of variable	Set of representatives	Residual sums of squares
1st	3, chosen obligatorily		
2nd	5, chosen obligatorily	{3, 5}	[1] .48694; [2] .49808; [4] .18477; [6] .44280
3rd	2, chosen	{2, 3, 5}	[1] .47593; [4] .18104; [6] .44062
4th	4, chosen	{2, 3, 4, 5}	[1] .43857; [6] .43783
5th	1, chosen	{1, 2, 3, 4, 5}	[6] .43739
6th	3, eliminated	{1, 2, 4, 5}	[3] .17473; [6] .45790
7th	4, eliminated	{1, 2, 5}	[3] .39500; [4] .37713; [6] .50999
8th	1, eliminated	{2, 5}	[1] .60143; [3] .49917; [4] .51366; [6] .54082

(B) Results obtained as output parameters of *idepstep* are the following:

$$ind[0:p] = [1 \ 0 \ 1 \ 0 \ 0 \ 1 \ 0],$$

$$a[1:15] = \begin{bmatrix} .60142716 \\ .50264594 & -1.0095182 \\ .25029220 & .70587263 & .49916551 \\ .28655160 & .66277519 & .40747269 & .51365899 \\ .33629308 & .09802421 & .01675977 & .16194453 & -1.0095182 \\ -.13617761 & -.38247184 & -.22364987 & -.20503341 & -.52346198 & .54082216 \end{bmatrix}$$

```

procedure outrepr(p,nr,m,flag,ind,residuals);
  value p,flag,m;
  real flag;
  integer p,m;
  array residuals;
  integer array nr,ind;
begin
  integer i;
  format('??variable←now123←');
  if flag≠3.0 then print(nr[m]);
  if flag=1.0 then print('chosen')
    else if flag=-1.0
      then print('eliminated')
    else if flag=2.0
      then print('chosen←obligatorily');
  if flag≠2.0
    then
      begin
        format('1234');
        print('?the set of representants:');
        m:=0;
        for i:=1 step 1 until p do
          if ind[i]=1
            then
              begin
                m:=m+1; if m=21
                  then m:=line(1);
                print(nr[i])
              end i;
      end

```

```

print('Residual sums of squares:');
format('%[1234]u1234567.12345u');
m:=ind[0];
for i:=1 step 1 until p do
  if ind[i]=0
    then
      begin
        print(nr[i],residuals[i]);
        if i=m then print('(maxres)')
      end 1
    end flag+2.0;
  line(2)
end outrepr

```

#### Reference

- [1] R. I. Jennrich, *Stepwise regression*, p. 58-75 in: K. Enslein, A. Ralston and H. Wilf (eds.), *Statistical methods for digital computers*, Vol. 3, Wiley, New York 1977.

INSTITUTE OF COMPUTER SCIENCE  
UNIVERSITY OF WROCLAW  
51-151 WROCLAW

*Received on 30. 12. 1978*

ALGORYTM 84

ANNA BARTKOWIAK (Wrocław)

### WYBIERANIE REPREZENTACJI CECH METODĄ KROKOWEJ ANALIZY REGRESJI

#### STRESZCZENIE

Procedura *idepstep* wybiera reprezentację cech w następujący sposób:  
Założmy, że zbiór reprezentantów  $R$  zawiera  $r$  zmiennych (dopuszcza się możliwość, że  $r = 0$ ).

Każdą z pozostałych zmiennych nie należących do  $R$  włączamy chwilowo do tego zbioru, po czym obliczamy regresję wielokrotną pozostałych zmiennych od zmiennych tworzących aktualny zbiór  $R$ . Rozważając kolejne zmienne nie należące do  $R$  znajdujemy tę, dla której regresja jest najgorsza, a więc zmienność resztowa jest największa.

Kontynuując to postępowanie znajdujemy zmienną, której włączenie do zbioru reprezentantów powoduje, że maksymalna zmienność resztowa (obliczona przy chwilowym włączeniu tej zmiennej do zbioru  $R$ ) jest najmniejsza w porównaniu ze zmiennościami resztowymi otrzymywanymi przy włączaniu innych zmiennych.

Procedura *idepstep* dopuszcza możliwość startowania od pustego zbioru  $R$  lub też na życzenie wprowadza podane zmienne do zbioru  $R$ , po czym rozpoczyna się właściwe działanie procedury. Powiększanie zbioru reprezentantów  $R$  odbywa się na zasadzie krokowej — aż do osiągnięcia liczby reprezentantów równej wartości  $ind[p+1]$ . W dalszym ciągu następuje eliminacja zmiennych ze zbioru  $R$ , aż liczebność tego zbioru zostanie zredukowana do liczby reprezentantów równej wartości elementu  $ind[p+2]$ .

Dane:

- $p$  — liczba rozważanych zmiennych;
- $a[1 : p \times (p+1) \div 2]$  — tablica zawierająca dolny trójkąt macierzy korelacyjnej (lub macierzy poprawionych iloczynów), zapamiętana wierszami;
- $nr[1 : p]$  — numery rozważanych zmiennych w pierwotnej numeracji danych (wykorzystywane przy drukowaniu wyników za pomocą procedury *ourepr*);
- $ind[0 : p+2]$  — tablica, której elementy mają następujące znaczenie:  $ind[0]$  — liczba zmiennych, które mają być wprowadzone do zbioru reprezentantów  $R$  obowiązkowo; jeśli  $ind[0] \neq 0$ , to kolejne wartości tej tablicy powinny być określone dla  $i = 1, 2, \dots, p$  jak następuje:  $ind[i] = 1$ , jeśli zmienna o numerze  $i$  ma być wprowadzona obowiązkowo do zbioru  $R$ , oraz  $ind[i] = 0$  w przeciwnym razie;  $ind[p+1]$  — maksymalna liczba reprezentantów;  $ind[p+2]$  — minimalna liczba reprezentantów;
- $eps$  — mała liczba, oznaczająca zero maszynowe.

Wyniki:

- $ind[0]$  — numer zmiennej najgorzej reprezentowanej przez zbiór  $R$ ;
- $ind[1 : p]$  — tablica wskazująca, które zmienne znajdują się aktualnie w zbiorze  $R$ ; jeśli  $ind[i] = 1$  ( $i = 1, 2, \dots, p$ ), to zmienna o numerze  $i$  znajduje się w zbiorze  $R$ ,  $ind[i] = 0$  w przeciwnym wypadku;
- $a[1 : p \times (p+1) \div 2]$  — tablica zawierająca dolny trójkąt przetransformowanej macierzy  $a$ .

Inne parametry:

- onestep* — nazwa procedury pomocniczej wykonującej na tablicy  $a$  zmodyfikowaną transformację Gaussa-Jordana według sposobu opisanego w [1], przykład realizacji takiej procedury jest podany;
- ourepr* — nazwa procedury drukującej wyniki pośrednie; przykład realizacji takiej procedury w języku Algol 1204 jest podany.