Mise en œuvre de la classification
(TP SAS)

Classification automatique sur un tableau présence absence

Il s'agit d'un tableau ayant comme individus des souches bactériennes, certaines étant étudiées au labo et inconnues, d'autres étant des souches de référence, issues de collection et parfaitement identifiées.

Les variables sont des critères biochimiques (croissance sur un substrat donné, à une température donnée, production de gaz, ...). Chaque souche peut répondre positivement (1) ou non (0) sur le test biochimique. L'objectif est de voir quelles sont les souches proches (dans le même groupe de la classification) des souches de collection (étiquetées T).

Les souches proches sont étudiées plus finement par une hybridation ADN/ADN pour valider leur appartenance à la même espèce bactérienne.

La classification est donc ici utilisée comme méthode de débroussaillage, l'hybridation étant lourde et coûteuse.

Acquisition et transformation des données

```
title1 "stat/jaccard6";

%include "stat/jaccard+"; /* inclusion du programme permettant */
                          /* de faire des beaux arbres         */

footnote;

data naza1a;
  infile "/nom du répertoire/deer301.prn" firstobs=2;
  input sou $ c4 c5 c6 c10 c12 c13 c18 c21-c28;

data naza1b;
  infile "/nom du répertoire/deer302.prn" firstobs=2;
  input c30-c37 c39 c40 e3 e4 e7 e8 e10 e11;

data naza1;
  merge naza1a naza1b;
run;

title2 "tableau d'origine";
proc print;
run;
```


Acquisition et transformation des données

Les fichiers $beer301.prn$ et $beer302.prn$ ont été sauvegardés sous word en $deer301.prn$ et $deer302.prn$ avec la commande

```
"enregistrer sous" / "texte seulement avec saut de ligne"
```

ce qui permet d'ajouter automatiquement un blanc en fin de ligne et donc de garder la valeur de la dernière variable (le blanc étant le séparateur par défaut).

Dans les deux premières étapes data, a été indiqué $firstobs = 2$. Le premier enregistrement contient en effet l'intitulé des variables (pas de même nature que les données).

tableau d'origine

11:45 Monday, October 20, 1997

OBS	SOU	C4	C5	C6	C10	C12	C13	C18	C21	C22	C23	C24	C25	C26	C27	C28	C30	C31	C32	C33	C34	C35	C36	C37	C39	C40	E3	E4	E7	E8	E10	E11
1	B2	0	0	0	1	1	1	0	1	0	0	0	1	0	0	1	1	1	0	0	1	1	1	1	0	1	1	1	1	0	0	0
2	B4	0	0	0	1	1	0	1	1	0	0	0	1	0	0	1	1	1	1	0	1	1	1	1	0	1	1	1	1	0	0	0
3	B5	0	0	0	1	1	0	0	0	0	0	0	1	0	0	1	1	1	0	0	1	1	1	1	0	1	1	1	1	1	0	0
4	B7	0	0	0	1	1	0	0	1	1	0	0	1	0	0	1	1	1	0	0	1	1	1	1	0	1	1	1	1	0	0	0
5	B8	0	0	0	1	1	0	0	0	0	1	0	0	0	0	1	1	1	0	0	0	1	1	1	0	1	1	1	1	1	0	0
6	B10	0	0	0	1	1	0	0	1	0	0	1	1	0	0	1	1	1	0	0	0	1	1	1	0	1	0	0	1	1	0	0
7	B11	0	0	0	1	1	0	0	0	0	0	0	1	0	0	1	1	1	0	0	0	1	1	1	0	1	1	1	1	1	0	0
8	B12	0	0	0	1	1	0	0	1	0	0	1	1	1	0	1	1	1	1	0	0	1	1	1	0	1	1	1	1	1	0	0
9	B14	0	0	0	1	1	0	0	1	0	0	0	1	0	0	1	1	1	0	0	0	1	1	1	0	1	1	1	1	1	0	0
10	B15	0	0	0	1	1	0	0	0	0	0	0	1	0	0	1	1	1	0	0	1	1	1	1	0	1	1	1	1	1	0	0
11	B16	0	0	0	1	1	0	0	0	0	0	0	1	0	0	1	1	1	0	0	1	1	1	1	0	1	1	1	1	1	0	0
12	B17	1	0	0	1	1	0	0	0	0	0	0	1	0	0	1	1	0	0	0	1	1	1	1	0	1	1	1	1	1	0	1
13	B18	0	0	0	1	1	0	0	1	0	0	0	1	0	0	1	1	1	1	1	1	1	1	1	0	1	1	1	1	0	0	0
14	B21	0	0	0	1	1	0	0	1	0	0	0	1	0	0	1	1	1	0	0	0	1	1	1	0	1	1	1	1	0	0	0
15	B25	1	0	0	1	1	0	0	1	0	0	0	1	0	0	1	1	1	0	0	1	1	1	1	0	1	1	1	1	1	0	0
16	B26	0	1	0	1	1	0	0	1	0	0	0	1	0	0	1	1	1	0	0	1	1	1	1	0	1	1	1	1	0	0	0
17	B27	0	0	1	1	1	0	0	1	0	0	0	1	1	0	1	1	1	0	0	0	1	1	1	0	1	1	1	1	1	0	0
18	B29	1	1	1	1	0	0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	1	1	0	0	1	1	1	1	0	0
19	T32	1	1	1	1	1	0	0	1	0	0	0	1	0	0	1	1	1	0	0	0	1	0	0	0	0	1	1	1	1	0	0
20	T33	0	1	0	0	1	1	0	0	0	1	1	1	0	0	0	0	1	0	0	0	0	0	0	0	0	1	1	1	1	0	0
21	T34	0	0	0	1	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	0	0
22	T35	0	0	0	1	0	0	0	0	0	0	0	1	0	0	1	1	1	0	0	0	1	1	1	0	0	1	1	0	0	0	0
23	T39	0	1	0	1	1	0	0	0	0	0	0	1	0	0	1	1	1	0	0	0	1	1	1	0	1	1	1	1	0	0	0
24	B9	0	0	0	1	1	0	0	0	0	0	0	1	0	0	1	1	1	0	0	0	1	1	1	0	1	1	1	1	1	0	0
25	B19	1	0	0	1	1	0	0	0	0	0	0	1	0	0	1	1	0	0	0	1	1	1	1	0	1	1	1	1	1	0	0
26	T37	1	1	1	1	0	1	0	0	0	1	0	1	0	0	1	0	0	0	0	0	0	1	1	0	0	1	1	1	0	0	0
27	T42	1	1	1	1	1	0	0	0	0	1	1	1	1	1	1	1	1	0	0	0	1	1	1	0	0	1	1	1	0	0	0
28	T43	0	0	0	0	1	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	1	1	0	1	0	0	0	0	0	0
29	T44	1	1	1	1	1	0	0	0	0	0	0	1	0	0	1	1	1	0	0	0	1	1	1	0	1	1	1	1	1	0	0
30	T45	1	1	1	1	1	1	0	1	1	1	1	1	1	0	0	1	1	1	0	0	1	0	0	0	1	1	1	1	1	0	0
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.

Étape de classification
(CAH, centres mobiles, mixte, Jaccard)

La classification automatique sera abordée de plusieurs façons :

- À partir des composantes des individus obtenues après l'AFC sur le tableau des indicatrices,
  - classification type nuées dynamiques,
  - classification hiérarchique (critère de Ward).
  - classification mixte : CAH puis nuées dynamiques.
- Enfin, classification sur les données brutes, non plus sur une matrice de distance euclidienne, mais avec l'indice de similarité de Jaccard comme matrice de distance.

ACM et récupération des coordonnées sur les axes factoriels

```
title2 "AFC sur tableau d'origine";
proc corresp data=naza1 observed outc=coor dim=31;
  tables sou , c4 c5 c6 c10 c12 c13 c18 c21-c28 c30-c37 c39 c40
               e3 e4 e7 e8 e10 e11;
run;

stat/jaccard6                              3
                          AFC sur tableau d'origine
                                           11:45 Monday, October 20, 1997
                    The Correspondence Analysis Procedure
stat/jaccard6                              4
                          AFC sur tableau d'origine
                                           11:45 Monday, October 20, 1997

                              Contingency Table
```

	0	1	0	1	0	1	.
B10	1	0	1	0	1	0	.
B11	1	0	1	0	1	0	.
B12	1	0	1	0	1	0	.
B13	1	0	1	0	1	0	.
B14	1	0	1	0	1	0	.
B15	1	0	1	0	1	0	.
B16	1	0	1	0	1	0	.
B17	0	1	1	0	1	0	.
B18	1	0	1	0	1	0	.
B19	0	1	1	0	1	0	.
B2	1	0	1	0	1	0	.
B20	0	1	0	1	0	1	.
B21	1	0	1	0	1	0	.
B25	0	1	1	0	1	0	.
B26	1	0	0	1	1	0	.
B27	1	0	1	0	0	1	.
B29	0	1	0	1	0	1	.
B30	1	0	1	0	1	0	.
B4	1	0	1	0	1	0	.
B5	1	0	1	0	1	0	.
.	.	.	.	.	.	.	.

ACM et récupération des coordonnées sur les axes factoriels

Afin de pouvoir récupérer les coordonnées des individus sur les axes factoriels, on ne peut pas utiliser l'option MCA (*Analyse des Correspondances Multiples*) dans l'instruction *proc corresp*. On n'obtiendrait qu'un tableau de Burt où seules les modalités des variables sont présentes (or la classification porte sur les individus).

Il faut spécifier $dim = 31$, faute de quoi la classification ne se ferait que sur les 2 premiers axes, par défaut.

Signification des sorties

Ce qui est appelé *Contingency Table* est en fait la matrice des indicatrices. Les 2 premières colonnes concernent la première variable (C4). La première de ces 2 colonnes intitulée 0 recense les individus n'ayant pas le caractère c4, la deuxième intitulée 1 recense ceux ayant le caractère c4, et ainsi de suite pour les couples de colonnes suivants.

```
stat/jaccard6                          22
                             AFC sur tableau d'origine
                                       11:45 Monday, October 20, 1997
                        The Correspondence Analysis Procedure

                         Inertia and Chi-Square Decomposition

       Singular  Principal Chi-
       Values    Inertias  Squares Percents    3    6    9   12   15
                                             ----+----+----+----+----+---
       0.39665   0.15733   351.157  15.73% **************************
       0.34628   0.11991   267.634  11.99% ********************
       0.27675   0.07659   170.948   7.66% *************
       0.25987   0.06753   150.728   6.75% ***********
       0.24759   0.06130   136.818   6.13% **********
       0.24245   0.05878   131.196   5.88% **********
       0.22407   0.05021   112.058   5.02% ********
       0.20666   0.04271    95.327   4.27% *******
       0.19962   0.03985    88.943   3.98% *******
       0.18462   0.03408    76.073   3.41% ******
       0.17979   0.03232    72.146   3.23% *****
       0.17043   0.02904    64.828   2.90% *****
       0.16354   0.02674    59.694   2.67% ****
       0.15840   0.02509    56.004   2.51% ****
       0.15131   0.02289    51.099   2.29% ****
       0.14122   0.01994    44.515   1.99% ***
       0.13692   0.01875    41.842   1.87% ***
       0.12881   0.01659    37.031   1.66% ***
       0.12192   0.01486    33.177   1.49% **
       0.11937   0.01425    31.806   1.42% **
       0.11591   0.01344    29.987   1.34% **
       0.11122   0.01237    27.612   1.24% **
       0.10446   0.01091    24.353   1.09% **
       0.09356   0.00875    19.537   0.88% *
       0.07736   0.00598    13.358   0.60% *
       0.07397   0.00547    12.211   0.55% *
       0.06919   0.00479    10.684   0.48% *
       0.05863   0.00344     7.671   0.34% *
       0.05568   0.00310     6.920   0.31% *
       0.04625   0.00214     4.774   0.21%
       0.02891   0.00084     1.866   0.08%
                 -------   -------
                 1.00000      2232 (Degrees of Freedom = 4331)
```


Commentaires sur les sorties de l'AFC

(Seul le premier tableau est reproduit, les autres pourront être sortis par les stagiaires)

1. **Inertia and Chi-Square Decomposition** : les 2 premiers axes totalisent 15.73 % + 11.99 %, soit 27.72 % de l'inertie totale.
2. **Row coordinates** : coordonnées des lignes (des individus) sur les axes factoriels.
3. **Summary Statistics for the Row points** :
   - qualité de la projection des individus sur les axes retenus (elle est égale a 1 car on a retenu tous les axes).
   - pondération des individus ($Mass$). Il y a ici équipondération (1/72 = 0.013889).
   - contribution de chaque point à l'inertie totale.

     Cette contribution est différente selon les axes. Ceci fait l'objet de *Partial Contributions to Inertia for the Row Points.*
4. **Indices of the coordinate that Contribute ...** : individus ayant le plus contribué à la formation des axes, comme le tableau précédent, sous forme d'indices. Les individus sont choisis s'ils ont une forte contribution sur l'axe (on retient les individus jusqu'à l'obtention de 80 % de l'inertie expliquée par l'axe).

   On pourra vérifier que les nombres inscrits indiquent pour quels axes les individus retenus ont le plus contribué : ainsi B14 agit surtout sur l'axe 1, B15 sur l'axe 17 ... BEST donne le numéro de l'axe ayant reçu la plus forte contribution relative.
5. **Squared Cosines for the Row Points** : mesure la qualité de représentation du point sur l'axe.

```
title2 "Table issue de AFC sur tableau d'origine";
proc print data=coor(obs=10 drop=dim3-dim31
                              contr3-contr31
                              sqcos3-sqcos31
                              best3-best31);
run;

stat/jaccard6                          107
                Table issue de AFC sur tableau d'origine
                                       11:45 Monday, October 20, 1997

 OBS  _TYPE_    _NAME_  QUALITY    MASS     INERTIA     DIM1      DIM2

   1  INERTIA              .         .      1.00000      .          .
   2  OBS        B10       1      0.013889  0.01360  -0.31919   0.03527
   3  OBS        B11       1      0.013889  0.00332  -0.32436   0.07125
   4  OBS        B12       1      0.013889  0.00940  -0.14547  -0.37360
   5  OBS        B13       1      0.013889  0.00639  -0.33562   0.17287
   6  OBS        B14       1      0.013889  0.00357  -0.34549  -0.05197
   7  OBS        B15       1      0.013889  0.00463  -0.39893   0.06801
   8  OBS        B16       1      0.013889  0.00463  -0.39893   0.06801
   9  OBS        B17       1      0.013889  0.02436  -0.31645   0.13499
  10  OBS        B18       1      0.013889  0.01960  -0.46900  -0.31600

 OBS   CONTR1     CONTR2    SQCOS1     SQCOS2    BEST1    BEST2   BEST

   1  0.15733    0.11991      .          .          .        .       .
   2  0.00899    0.00014   0.10402    0.00127       0        0      21
   3  0.00929    0.00059   0.44073    0.02127       0        0      24
   4  0.00187    0.01617   0.03126    0.20620       0        0      28
   5  0.00994    0.00346   0.24492    0.06498       0        0       8
   6  0.01054    0.00031   0.46447    0.01051       1        0       1
   7  0.01405    0.00054   0.47776    0.01389      17        0      17
   8  0.01405    0.00054   0.47776    0.01389      17        0      17
   9  0.00884    0.00211   0.05709    0.01039       0        0      18
  10  0.01942    0.01157   0.15589    0.07077      10        0      10
```


Impression des 10 premières lignes du tableau créé par *corresp*.

La première ligne concerne l'inertie totale, les suivantes les individus, puis les variables.

Classification type nuées dynamiques sur l'ensemble des axes de l'AFC

```
title2 "nuées dynamiques issues des 31 axes factoriels de l'AFC";
run;
proc fastclus data=coor out=fast maxc=10 maxiter=7;
  where _type_ ='OBS';
  var dim1-dim31;
*  id sou;
  id _name_;
run;

stat/jaccard6                           108
           nuées dynamiques issues des 31 axes factoriels de l'AFC
                                            11:45 Monday, October 20, 1997

   FASTCLUS Procedure:  Replace=FULL  Radius=0  Maxclusters=10 Maxiter=7
   Converge=0.02

                                Initial Seeds

Cluster    DIM1      DIM2      DIM3      DIM4      DIM5      DIM6      DIM7
---------------------------------------------------------------------------
  1     0.337804 -.863009 0.097716 0.309637 -.092377 -.156062 0.029758
  2     -.319708 0.250199 0.104562 -.099779 -.354578 0.346817 -.311919
  3     0.624581 0.163032 -.289353 -.202054 -.051459 0.464818 0.125827
  4     0.526985 0.592662 0.159685 -.498219 0.165119 -.362227 -.276851
  5     -.106312 -.153132 0.387630 0.058134 -.283583 -.483853 0.983428
  6     -.518847 0.085990 0.003241 0.291296 0.513071 0.318467 -.057283
  7     0.977188 0.143284 0.333528 -.279175 -.503057 0.563297 -.190134
  8     0.029478 -.540695 -.421014 -.136465 0.644237 -.297051 -.046736
  9     0.489193 0.402006 0.216780 0.677414 0.222006 -.356101 -.106308
 10     0.467048 -.614003 0.151712 -.524233 0.569173 0.350179 0.308028
```


Classification type nuées dynamiques sur l'ensemble des axes de l'AFC

On choisit 10 classes *a priori*. Deux méthodes peuvent être appliquées, correspondant respectivement aux points 2 et 3 de la procédure *fastclus* :

1. Des observations, appelées noyaux (*cluster seed*) sont sélectionnées.
2. Des classes temporaires sont formées en affectant chaque observation au noyau le plus proche. Chaque fois qu'une observation est affectée à une classe, le noyau de la classe est recalculé comme étant le nouveau centre de gravité (option *drift*).
3. Les observations sont affectées (simultanément sans l'option *drift*) au noyau le plus proche. Les nouveaux centres sont calculés. La procédure peut être repétée un certain nombre de fois (option *maxiter*, par défaut *maxiter=1*).

Les points 2 et 3 sont optionnels. Si l'on spécifie *maxiter=0* sans spécifier *drift*, les noyaux finaux sont les noyaux initiaux.

Les observations avec valeurs manquantes ne peuvent pas être des noyaux.

L'instruction *_type_='OBS'* permet de ne retenir que les coordonnées des individus sur les axes. *OBS* doit être écrit en majuscules. *id _name_* donne l'intitulé de la variable *sou*, pour un *_type_='OBS'*.

```
              Minimum Distance Between Initial Seeds = 1.508092

                         Relative Change in Cluster Seeds
 Iteration    Criterion          1          2          3         4          5
                                 6          7          8         9         10

-------------------------------------------------------------------------------
        1       0.1974      0.4848     0.6049     0.5312    0.4887     0.4572
                            0.4821     0.4356     0.3281    0.5437          0

        2       0.1347      0.1018     0.0486     0.1551         0     0.2838
                            0.1247          0          0         0          0

        3       0.1322           0     0.0122          0         0          0
                            0.0456          0          0         0          0

        4       0.1320           0     0.0255          0         0          0
                            0.1328          0          0         0          0

        5       0.1311           0     0.0274     0.0626         0          0
                            0.1268          0          0         0          0

        6       0.1305           0          0          0         0          0
                                 0          0          0         0          0

                     Convergence criterion is satisfied.

                   Criterion Based on Final Seeds = 0.13048
```


Relative Change in Cluster Seeds : changements de position des noyaux. À la première itération, un seul noyau (correspondant à la classe 10) ne bouge pas. À la deuxième, ils sont 5 à ne pas bouger. Le critère d'arrêt est la comparaison entre la distance minimale entre noyaux initiaux et le changement maximal de position des noyaux (cf. p. 826 de SAS/STAT User's Guide).

```
stat/jaccard6                                110
          nuees dynamiques issues des 31 axes factoriels de l'AFC
                                             11:45 Monday, October 20, 1997

   FASTCLUS Procedure:  Replace=FULL  Radius=0  Maxclusters=10 Maxiter=7
   Converge=0.02

                               Cluster Summary

                                 Maximum Distance
                        RMS Std     from Seed      Nearest  Distance Between
 Cluster   Frequency  Deviation   to Observation   Cluster  Cluster Centroids
-----------------------------------------------------------------------------
      1          8       0.1664    1.0767             2           0.9979
      2         35       0.1212    1.0240             3           0.8161
      3          8       0.1524    0.8945             2           0.8161
      4          5       0.1619    0.9208             9           0.9978
      5          2       0.1712    0.6742             2           1.2405
      6          6       0.1628    1.0732             2           0.8197
      7          2       0.1669    0.6569             4           1.2289
      8          2       0.1257    0.4948             2           1.1689
      9          3       0.1725    0.8199             4           0.9978
     10          1            .         0             1           1.4407
```


Cluster Summary :

- numéro de la classe.
- effectif.
- écart-type moyen ($RMS\ Std\ Deviation$) : $\sqrt{\dfrac{Inertie}{(N_k - 1) * V}}$

  N_k est l'effectif de la classe k et V est le nombre de variables.
- distance maximale séparant le noyau d'un individu de la classe.
- classe la plus proche.
- distance au noyau de cette classe.

  La classe 10 est un singleton, c'est la plus extrême : la distance entre son centre et le centre le plus proche est de 1.44 (c'est la plus grande de toutes).

Statistics for Variables

Variable	Total STD	Within STD	R-Squared	RSQ/(1-RSQ)
DIM1	0.399430	0.167213	0.846964	5.534406
DIM2	0.348707	0.195521	0.725464	2.642513
DIM3	0.278691	0.222673	0.442528	0.793811
DIM4	0.261690	0.184018	0.568204	1.315907
DIM5	0.249323	0.177657	0.556623	1.255417
DIM6	0.244147	0.164908	0.601605	1.510071
DIM7	0.225637	0.171138	0.497655	0.990663
DIM8	0.208113	0.152104	0.533535	1.143785
DIM9	0.201023	0.187609	0.239408	0.314765
DIM10	0.185912	0.154743	0.395021	0.652950
DIM11	0.181049	0.172987	0.202793	0.254379
DIM12	0.171622	0.165192	0.190967	0.236043
DIM13	0.164686	0.155145	0.225007	0.290335
DIM14	0.159514	0.159323	0.128854	0.147913
DIM15	0.152369	0.153053	0.118905	0.134951
DIM16	0.142215	0.146562	0.072562	0.078239
DIM17	0.137878	0.132513	0.193397	0.239768
DIM18	0.129710	0.124005	0.201895	0.252968
DIM19	0.122774	0.122490	0.130802	0.150486
DIM20	0.120211	0.122458	0.093816	0.103528
DIM21	0.116723	0.122401	0.039740	0.041385
DIM22	0.112005	0.115694	0.068297	0.073303
DIM23	0.105189	0.107718	0.084268	0.092022
DIM24	0.0942156	0.0991519	0.032860	0.033976
DIM25	0.0779056	0.0819636	0.033419	0.034574
DIM26	0.0744859	0.0781559	0.038589	0.040137
DIM27	0.0696720	0.0728353	0.045664	0.047849
DIM28	0.0590368	0.0618250	0.042331	0.044202
DIM29	0.0560713	0.0583931	0.052942	0.055902
DIM30	0.0465732	0.0478222	0.079296	0.086126
DIM31	0.0291172	0.0307008	0.029191	0.030069
OVER-ALL	0.180866	0.140605	0.472259	0.894870

Statistics for Variables donne, pour chaque axe et pour l'ensemble : l'écart-type total, l'écart-type intra, R^2 et $\dfrac{R^2}{1-R^2}$.

Par défaut les variances ont pour dénominateur leur nombre de degrés de liberté : $N-1$ pour la variance totale, $N-C$ pour la variance intra (avec C le nombre de classes). Il en découle qu'on ne retrouve pas le R^2 en appliquant la formule $1-\dfrac{\textit{variance intra}}{\textit{variance totale}}$.

Il peut même arriver que, pour une variable donnée (ici un facteur), l'écart-type intra affiché soit supérieur à l'écart-type total. À cause d'un dénominateur différent et d'une mauvaise représentation des classes sur cet axe.

```
stat/jaccard6                              111
         nuees dynamiques issues des 31 axes factoriels de l'AFC
                                           11:45 Monday, October 20, 1997

   FASTCLUS Procedure:  Replace=FULL  Radius=0  Maxclusters=10 Maxiter=7
   Converge=0.02

                          Statistics for Variables

                                  Pseudo F Statistic =     6.16
            Approximate Expected Over-All R-Squared =  0.46655
                         Cubic Clustering Criterion =    0.455
     WARNING: The two above values are invalid for correlated variables.
```

Cluster Means

Cluster	DIM1	DIM2	DIM3	DIM4	DIM5	DIM6	DIM7
1	0.477809	-.585246	0.109903	0.189902	-.053914	-.036889	-.054324
2	-.267119	-.013165	0.028424	-.056893	-.081255	-.010711	-.054383
3	0.231743	0.051420	-.477447	-.001335	0.032041	0.234669	0.181257
4	0.561251	0.565100	0.178846	-.247038	0.137272	-.174213	-.137852
5	-.211382	-.009071	0.031916	-.094835	-.238779	-.561331	0.707652
6	-.325346	0.262394	0.194529	0.372981	0.261226	0.248331	0.092542
7	0.862391	0.209921	0.066677	-.338026	-.490274	0.319847	-.253780
8	-.219759	-.428349	-.183979	-.231613	0.590340	-.232107	-.133327
9	0.496345	0.466836	-.032280	0.444396	0.157813	-.409753	0.024276
10	0.467048	-.614003	0.151712	-.524233	0.569173	0.350179	0.308028

Cluster Standard Deviations

Cluster	DIM1	DIM2	DIM3	DIM4	DIM5	DIM6	DIM7
1	0.240207	0.293729	0.178111	0.307051	0.180260	0.117650	0.151047
2	0.135415	0.158182	0.202739	0.124794	0.139174	0.132442	0.160521
3	0.193530	0.130137	0.170800	0.241935	0.254970	0.279967	0.153972
4	0.198506	0.180857	0.164886	0.181085	0.176988	0.241738	0.114429
5	0.148592	0.203734	0.503055	0.216331	0.063362	0.109570	0.390006
6	0.149953	0.332798	0.288702	0.190883	0.303727	0.070813	0.212731
7	0.162348	0.094238	0.377384	0.083228	0.018078	0.344290	0.090010
8	0.352474	0.158881	0.335218	0.134559	0.076222	0.091845	0.122457
9	0.025277	0.135465	0.329418	0.239896	0.097604	0.152169	0.283084
10	.	.	.	.	.	.	.

Deux critères de choix du nombre de classes sont proposés : *Pseudo F statistic* et *CCC*. Il est à noter que le *CCC* doit être utilisé avec des données non corrélées. Il faut donc faire une ACP ou une AFC avant la classif afin de récupérer les facteurs, non corrélés par nature, si l'on veut utiliser ce critère.

Projection des individus

```
/* cette etape permet de projeter les individus sur les axes */
data fast2;
  set fast;
clus=put(cluster,2.);   * text ne peut prendre que des chaines de;
text = substr(clus,2);  * caracteres. On traduit donc cluster en clus;

*text=_name_;        * Cette ligne aurait fait imprimer le numero des ;
                     * individus au lieu de celui des classes.;
y = dim1;
x = dim2;
xsys = '2';
ysys = '2';
size = 1;
label y = "Dimension 1";
label x = "Dimension 2";
keep x y text xsys ysys size;
run;
*proc print;
*run;
filename figure "plot1.eps";
title3 "Projection des individus sur les 2 premiers axes";
title4 "Les individus sont representes par leur numero de classe, la "
       "classe 10 devient la classe 0";
proc gplot data=fast2;
  symbol1 i=none;
  plot y*x=1 / annotate=fast2 frame;
run;
quit;
```

stat/jaccard6

nuees dynamiques issues des 31 axes factoriels de l'AFC
Projection des individus sur les 2 premiers axes
Les individus sont representes par leur numero de classe, la classe 10 devient la classe 0

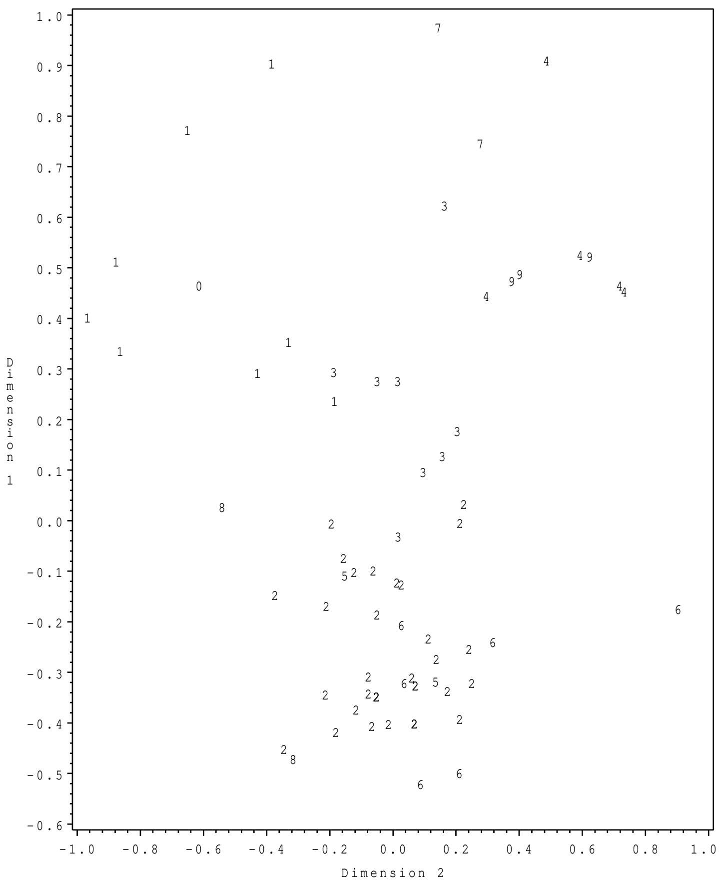

CAH sur les composantes principales

```
title2 "CAH (critere de Ward) issue des 31 axes factoriels de l'AFC";
proc cluster data=coor
             outtree=treeward
             method=ward;
  where _type_ ='OBS';
  var dim1-dim31;
*  id sou;
  id _name_;
run;
*proc print data=treeward;
*title3 "treeward";
*run;
```


CAH sur les composantes principales

L'instruction *_type_='OBS'* permet de ne retenir que les coordonnées des individus sur les axes. *OBS* doit être écrit en majuscules.

*id _name_* donne l'intitulé de la variable *sou*, pour un *_type_='OBS'*.

```
stat/jaccard6                             114
       CAH (critere de Ward) issue des 31 axes factoriels de l'AFC
                                          11:45 Monday, October 20, 1997

                     Ward's Minimum Variance Cluster Analysis
                      Eigenvalues of the Covariance Matrix
```

	Eigenvalue	Difference	Proportion	Cumulative
1	0.159544	0.037948	0.157328	0.15733
2	0.121596	0.043928	0.119908	0.27724
3	0.077668	0.009187	0.076590	0.35383
4	0.068482	0.006320	0.067530	0.42136
5	0.062162	0.002554	0.061298	0.48265
6	0.059608	0.008695	0.058780	0.54143
7	0.050912	0.007601	0.050205	0.59164
8	0.043311	0.002901	0.042709	0.63435
9	0.040410	0.005847	0.039849	0.67420
10	0.034563	0.001784	0.034083	0.70828
11	0.032779	0.003325	0.032323	0.74060
12	0.029454	0.002333	0.029045	0.76965
13	0.027121	0.001677	0.026745	0.79639
14	0.025445	0.002228	0.025091	0.82149
15	0.023216	0.002991	0.022894	0.84438
16	0.020225	0.001215	0.019944	0.86432
17	0.019010	0.002186	0.018746	0.88307
18	0.016825	0.001751	0.016591	0.89966
19	0.015073	0.000623	0.014864	0.91452
20	0.014451	0.000826	0.014250	0.92877
21	0.013624	0.001079	0.013435	0.94221
22	0.012545	0.001480	0.012371	0.95458
23	0.011065	0.002188	0.010911	0.96549
24	0.008877	0.002807	0.008753	0.97424
25	0.006069	0.000521	0.005985	0.98023
26	0.005548	0.000694	0.005471	0.98570
27	0.004854	0.001369	0.004787	0.99049
28	0.003485	0.000341	0.003437	0.99392
29	0.003144	0.000975	0.003100	0.99703
30	0.002169	0.001321	0.002139	0.99916
31	0.000848	.	0.000836	1.00000

```
       Root-Mean-Square Total-Sample Standard Deviation = 0.180866
       Root-Mean-Square Distance Between Observations   = 1.424138
```


Eingenvalue of the Covariance Matrix donne les valeurs propres ainsi que :

- **Root-Mean-Square Total-Sample Standard Deviation** : l'écart-type total (le même donc qu'avec *proc fastclus*).
- **Root-Mean-Square Distance Between Obsevations**, qui reflète la distance moyenne entre observations (en fait ce sont des distances au carré qui ont été utilisées, avec le critère de Ward ; avec *Single Linkage*, on aurait eu effectivement la distance moyenne).

```
stat/jaccard6                                115
         CAH (critere de Ward) issue des 31 axes factoriels de l'AFC
                                             11:45 Monday, October 20, 1997

                   Ward's Minimum Variance Cluster Analysis

 Number                                      Frequency
   of                                           of New Semipartial
Clusters ---------Clusters Joined---------   Cluster  R-Squared R-Squared Tie

     71  B15              B16                      2   0.000000  1.000000  T
     70  CL71             B5                       3   0.000000  1.000000  T
     69  B14              B72                      2   0.000000  1.000000  T
     68  B11              B9                       2   0.000000  1.000000  T
     67  CL69             H10                      3   0.000000  1.000000  T
     66  CL67             R58                      4   0.000000  1.000000
     65  R56              T47                      2   0.000914  0.999086
     64  B13              B30                      2   0.001084  0.998002
     63  B21              B63                      2   0.001117  0.996885
     62  B67              T44                      2   0.001731  0.995155
     61  B19              B20                      2   0.002006  0.993149
     60  CL64             B8                       3   0.002017  0.991131
     59  B26              T39                      2   0.002156  0.988976
     58  B12              B75                      2   0.002359  0.986617
     57  CL68             CL66                     6   0.002436  0.984180
     56  CL70             B25                      4   0.002827  0.981353
     55  B10              B62                      2   0.002962  0.978392
     54  H8               T42                      2   0.003115  0.975277
     53  CL63             B61                      3   0.003246  0.972031
     52  CL62             H3                       3   0.003308  0.968723
     51  R59              T69                      2   0.003846  0.964877
     50  CL57             B27                      7   0.004162  0.960715
     49  B2               CL59                     3   0.004255  0.956460
     48  CL60             R52                      4   0.004908  0.951551
     47  B64              B77                      2   0.005320  0.946231
     46  CL49             CL53                     6   0.005365  0.940866
     45  CL61             B29                      3   0.005976  0.934890
     44  B60              T70                      2   0.006210  0.928680
     43  CL46             B7                       7   0.006677  0.922003
     42  B18              R55                      2   0.006800  0.915203
     41  B65              H5                       2   0.007192  0.908010
     40  CL52             T32                      4   0.007238  0.900772
     ..  ....             ....                     .   ........  ........
```


Historique de la classification

À chaque étape on a :

- le nombre de classes.
- le nom des 2 classes jointes.
- l'effectif de la nouvelle classe ainsi formée.
- semi-partial R^2 : perte d'inertie inter (%).
- R^2 : inertie interclasse restante (%).
- *Tie* : présence d'*ex aequo*.

  Lors de la présence d'*ex aequo* apparaît le message suivant dans le fichier *log : Ties for minimum distance between clusters have been detected at x level(s) in the cluster history.* Selon qu'on choisira une agrégation plutôt qu'une autre, le résultat final changera. Ici, ce n'est pas le cas, les individus sont identiques, il n'y a pas de modification de la distance entre eux (elle reste nulle).

```
title2 "ARBRE DE CLASSIFICATION    (macro grftree de D. Jacobs)";
title3 "CAH sur le critere de Ward (sur les 31 axes de l'AFC)";
filename figure "cah.eps";
%grftree(clusdsn=treeward,items=72,axis=d);*!!!!!!!!!!!!!!!!!!!!;
run;
```

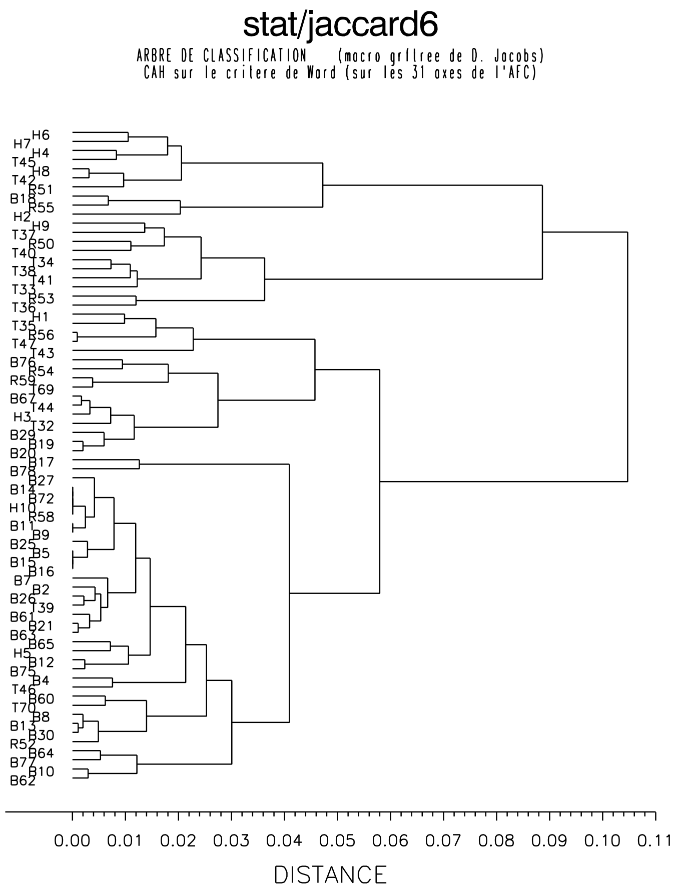

Appel de la macro *grftree* (macro faisant de beaux arbres de classification).

```
proc tree data=treeward n=10 noprint out=trees;
  id _name_;
  copy dim1--dim31;
run;

title2 "sortie de la procedure tree (10 1eres obs, 5 1ers axes)";
proc print data=trees(obs=10);
  var _name_ dim1-dim5 cluster clusname;
* on n imprime pas les axes 6 a 31;

stat/jaccard6                              117
           sortie de la procedure tree (10 1eres obs, 5 1ers axes)
                                           11:45 Monday, October 20, 1997

  OBS _NAME_    DIM1     DIM2      DIM3     DIM4     DIM5   CLUSTER CLUSNAME

    1  B15   -0.39893  0.06801 -0.044307 -0.18210 -0.03402    1     CL10
    2  B16   -0.39893  0.06801 -0.044307 -0.18210 -0.03402    1     CL10
    3  B5    -0.39893  0.06801 -0.044307 -0.18210 -0.03402    1     CL10
    4  B14   -0.34549 -0.05197  0.091357 -0.15301 -0.10554    1     CL10
    5  B72   -0.34549 -0.05197  0.091357 -0.15301 -0.10554    1     CL10
    6  B11   -0.32436  0.07125  0.028772 -0.11354 -0.15597    1     CL10
    7  B9    -0.32436  0.07125  0.028772 -0.11354 -0.15597    1     CL10
    8  H10   -0.34549 -0.05197  0.091357 -0.15301 -0.10554    1     CL10
    9  R58   -0.34549 -0.05197  0.091357 -0.15301 -0.10554    1     CL10
   10  R56   -0.49772  0.20921 -0.059343  0.33077  0.46264    2     CL12
```


La procédure *tree* permet de couper l'arbre à un certain niveau (ou de ne retenir qu'un certain nombre de classes).

La commande *copy* sélectionne les variables retenues dans la table de sortie (ici les coordonnées des individus sur les 31 axes).

La procédure *tree* construit aussi des arbres. Comme ils ne sont guère lisibles, utiliser *noprint*. La macro *grftree* dessine des arbres plus lisibles.

```
*proc print data=trees;

data trees2;
  set trees;
clus=put(cluster,2.);   * text ne peut prendre que des chaines de;
text = substr(clus,2);  * caracteres. On traduit donc cluster en clus.;
*text=_name_;
y = dim1;
x = dim2;
xsys = '2';
ysys = '2';
size = 1;
label y = "Dimension 1";
label x = "Dimension 2";
keep x y text xsys ysys size;
run;
*proc print;
*run;
filename figure "plot2.eps";
title2 "CAH sur le critere de Ward (sur les 31 axes de l'AFC)";
title3 "Projection des individus sur les 2 premiers axes";
title4 "Les individus sont representes par leur numero de classe, la "
       "classe 10 devient la classe 0";
proc gplot data=trees2;
  symbol1 i=none;
  plot y*x=1 / annotate=trees2 frame;
run;
quit;
```

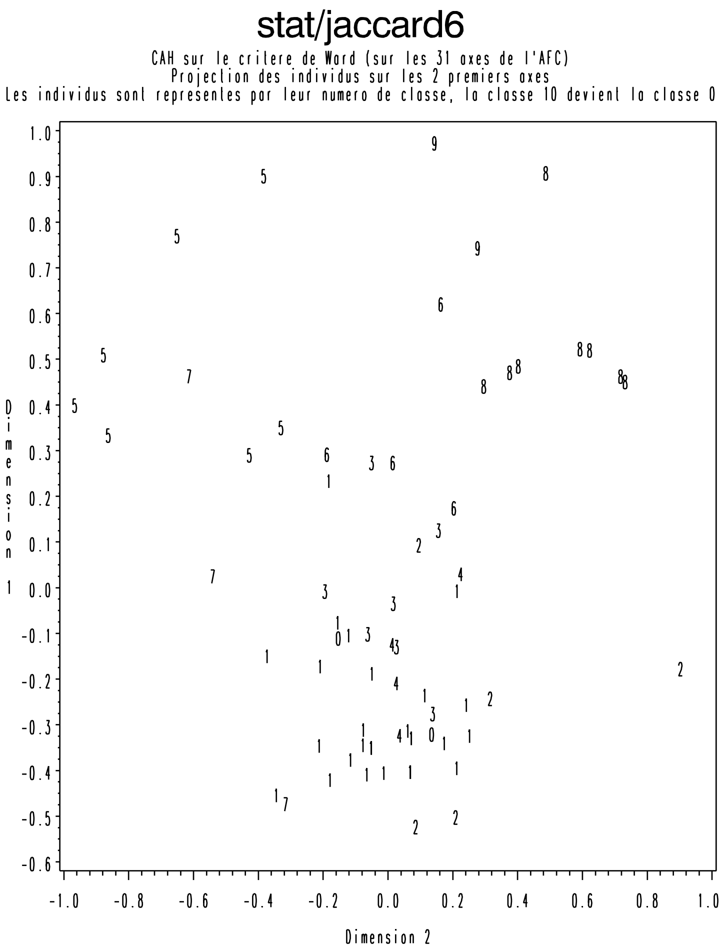
stat/jaccard6
CAH sur le critere de Ward (sur les 31 axes de l'AFC)
Projection des individus sur les 2 premiers axes
Les individus sont representes par leur numero de classe, la classe 10 devient la classe 0
Dimension 1
Dimension 2

Classification mixte
(Ward, puis nuées dynamiques)

```
proc summary nway data=trees;
  var dim1-dim31;
  class cluster;
  output out=summa mean= ;
run;

title2 "CLASSIFICATION MIXTE : CAH-Ward puis nuees dynamiques";
title3 "1) Centre de gravite des classes d'origine issues de la CAH";
proc print data=summa;
  var cluster dim1-dim5;
run;

stat/jaccard6                              118
            CLASSIFICATION MIXTE : CAH-Ward puis nuees dynamiques
         1) Centre de gravite des classes d'origine issues de la CAH
                                           11:45 Monday, October 20, 1997
```

OBS	CLUSTER	DIM1	DIM2	DIM3	DIM4	DIM5
1	1	-0.28426	-0.02630	0.08113	-0.08707	-0.07106
2	2	-0.26604	0.32174	-0.09106	0.31966	0.37942
3	3	-0.01700	0.00420	-0.45366	0.06092	-0.11749
4	4	-0.15252	0.07467	0.36376	0.20679	-0.12437
5	5	0.51210	-0.64255	0.07405	0.25917	-0.04448
6	6	0.34442	0.04826	-0.38867	-0.07470	0.10357
7	7	0.00918	-0.49023	-0.07208	-0.32915	0.58328
8	8	0.53691	0.52825	0.09967	0.01225	0.14497
9	9	0.86239	0.20992	0.06668	-0.33803	-0.49027
10	10	-0.21138	-0.00907	0.03192	-0.09483	-0.23878

Classification mixte
(Ward, puis nuées dynamiques)

Pour effectuer cette classification mixte, il faut calculer les centres de classe issus de la procédure *tree*, donc faire un *proc summary*.

Ne pas oublier de spécifier les variables à classifier, sinon la variable *cluster* aurait été introduite.

Dans le cas où le nombre d'individus est tres élevé (ex. 10 000), on a interêt à faire la classification mixte en trois étapes :

1. nuées dynamiques avec un certain nombre de classes (ex. 100 ou 200).
2. CAH sur ces 100 (ou 200) classes pour aboutir à x classes.
3. nuées dynamiques sur ces x classes (pour diminuer encore l'inertie intra).

```
title2 "CLASSIFICATION MIXTE : CAH-Ward puis nuees dynamiques";
title3 "2) Nuees dyn. avec les centres de gravite des classes d'origine"
       "comme noyaux initiaux";
proc fastclus seed=summa data=trees mean=moy2 out=mixt maxc=10 maxiter=7;
id _name_;
var dim1-dim31;
run;

stat/jaccard6                              119
            CLASSIFICATION MIXTE : CAH-Ward puis nuees dynamiques
2) Nuees dyn. avec les centres de gravite des classes d'origine comme
noyaux i
                                           11:45 Monday, October 20, 1997

   FASTCLUS Procedure:  Replace=FULL  Radius=0  Maxclusters=10 Maxiter=7
   Converge=0.02

                                Initial Seeds

Cluster    DIM1      DIM2      DIM3      DIM4      DIM5      DIM6     DIM7
---------------------------------------------------------------------------
  1     -.284264 -.026300 0.081128 -.087072 -.071056 0.018886 -.075814
  2     -.266041 0.321743 -.091063 0.319657 0.379421 0.322640 0.007877
  3     -.017004 0.004200 -.453656 0.060923 -.117495 -.128833 -.000910
  4     -.152519 0.074673 0.363764 0.206794 -.124366 0.049513 0.309153
  5     0.512101 -.642554 0.074052 0.259174 -.044475 -.056695 -.071105
  6     0.344420 0.048263 -.388671 -.074698 0.103573 0.404548 0.292461
  7     0.009177 -.490233 -.072082 -.329153 0.583284 -.038012 0.013792
  8     0.536911 0.528251 0.099674 0.012250 0.144975 -.262541 -.077054
  9     0.862391 0.209921 0.066677 -.338026 -.490274 0.319847 -.253780
 10     -.211382 -.009071 0.031916 -.094835 -.238779 -.561331 0.707652
```


Remarquer que le premier tableau est identique au tableau précédent.

```
            Minimum Distance Between Initial Seeds = 0.684557

                       Relative Change in Cluster Seeds
 Iteration   Criterion         1         2         3        4         5
                               6         7         8        9        10

------------------------------------------------------------------------
       1       0.1295          0    0.3666         0        0         0
                          0.2816         0         0        0         0

       2       0.1287          0         0         0        0         0
                               0         0         0        0         0

                   Convergence criterion is satisfied.

                 Criterion Based on Final Seeds = 0.12874

stat/jaccard6                              121
            CLASSIFICATION MIXTE : CAH-Ward puis nuees dynamiques
2) Nuees dyn. avec les centres de gravite des classes d'origine comme
noyaux i
                                           11:45 Monday, October 20, 1997

   FASTCLUS Procedure:  Replace=FULL  Radius=0  Maxclusters=10 Maxiter=7
   Converge=0.02
                               Cluster Summary

                                 Maximum Distance
                     RMS Std      from Seed     Nearest   Distance Between
 Cluster  Frequency  Deviation   to Observation   Cluster  Cluster Centroids

----------------------------------------------------------------------------
     1         30      0.1165    1.0085             3              0.6846
     2          4      0.1569    1.0237             1              0.9557
     3          7      0.1112    0.7351             1              0.6846
     4          4      0.1259    0.6495             1              0.7830
     5          7      0.1648    1.0481             3              1.0511
     6          5      0.1555    0.8804             3              0.8431
     7          3      0.1775    0.9880             1              1.1279
     8          8      0.1791    1.0645             3              1.0262
     9          2      0.1669    0.6569             8              1.2774
    10          2      0.1712    0.6742             1              1.2647
```

Statistics for Variables

Variable	Total STD	Within STD	R-Squared	RSQ/(1-RSQ)
DIM1	0.399430	0.185968	0.810709	4.282874
DIM2	0.348707	0.182697	0.760296	3.171807
DIM3	0.278691	0.184186	0.618583	1.621799
DIM4	0.261690	0.212406	0.424702	0.738229
DIM5	0.249323	0.158127	0.648744	1.846924
DIM6	0.244147	0.154506	0.650279	1.859426
DIM7	0.225637	0.154370	0.591267	1.446586
DIM8	0.208113	0.155585	0.511940	1.048928
DIM9	0.201023	0.182558	0.279816	0.388535
DIM10	0.185912	0.148528	0.442639	0.794170
DIM11	0.181049	0.173358	0.199371	0.249018
DIM12	0.171622	0.162791	0.214313	0.272771
DIM13	0.164686	0.167767	0.093778	0.103482
DIM14	0.159514	0.161893	0.100520	0.111754
DIM15	0.152369	0.153998	0.107991	0.121065
DIM16	0.142215	0.142531	0.122867	0.140078
DIM17	0.137878	0.137006	0.137779	0.159795
DIM18	0.129710	0.127201	0.160216	0.190783
DIM19	0.122774	0.126123	0.078466	0.085147
DIM20	0.120211	0.119386	0.138701	0.161036
DIM21	0.116723	0.120450	0.070109	0.075394
DIM22	0.112005	0.118682	0.019546	0.019936
DIM23	0.105189	0.107198	0.093078	0.102631
DIM24	0.0942156	0.0963707	0.086355	0.094517
DIM25	0.0779056	0.0797048	0.085962	0.094046
DIM26	0.0744859	0.0758317	0.094919	0.104874
DIM27	0.0696720	0.0732036	0.035987	0.037331
DIM28	0.0590368	0.0618636	0.041135	0.042900
DIM29	0.0560713	0.0584869	0.049898	0.052518
DIM30	0.0465732	0.0477307	0.082817	0.090295
DIM31	0.0291172	0.0306241	0.034037	0.035236
OVER-ALL	0.180866	0.138733	0.486215	0.946340

```
                        Pseudo F Statistic =     6.52
      Approximate Expected Over-All R-Squared =  0.46655
                Cubic Clustering Criterion =    1.587
   WARNING: The two above values are invalid for correlated variables.
```

Cluster Means

Cluster	DIM1	DIM2	DIM3	DIM4	DIM5	DIM6	DIM7
1	-.284264	-.026300	0.081128	-.087072	-.071056	0.018886	-.075814
2	-.356999	0.378226	0.077243	0.382998	0.406920	0.282554	-.034900
3	-.017004	0.004200	-.453656	0.060923	-.117495	-.128833	-.000910
4	-.152519	0.074673	0.363764	0.206794	-.124366	0.049513	0.309153
5	0.512101	-.642554	0.074052	0.259174	-.044475	-.056695	-.071105
6	0.295095	0.057774	-.463794	-.046500	0.136744	0.420235	0.269766
7	0.009177	-.490233	-.072082	-.329153	0.583284	-.038012	0.013792
8	0.536911	0.528251	0.099674	0.012250	0.144975	-.262541	-.077054
9	0.862391	0.209921	0.066677	-.338026	-.490274	0.319847	-.253780
10	-.211382	-.009071	0.031916	-.094835	-.238779	-.561331	0.707652

Cluster Standard Deviations

Cluster	DIM1	DIM2	DIM3	DIM4	DIM5	DIM6	DIM7
1	0.148395	0.161667	0.122344	0.109183	0.143916	0.113428	0.149325
2	0.176892	0.361813	0.289531	0.232684	0.255831	0.056605	0.096724
3	0.178904	0.121365	0.137892	0.176088	0.099856	0.161158	0.063935
4	0.148838	0.100374	0.077885	0.194960	0.123571	0.158956	0.080947
5	0.237361	0.264582	0.158159	0.255356	0.192556	0.111746	0.154884
6	0.200786	0.154835	0.189106	0.285562	0.259603	0.102086	0.109149
7	0.468352	0.155277	0.306184	0.193895	0.055265	0.342399	0.269127
8	0.154363	0.162851	0.241826	0.404028	0.143996	0.234241	0.193440
9	0.162348	0.094238	0.377384	0.083228	0.018078	0.344290	0.090010
10	0.148592	0.203734	0.503055	0.216331	0.063362	0.109570	0.390006

```
title2 "data=moy2 (table issue de la classif mixte)";
title3 "elle donne les moyennes des classes ainsi que d'autres
statistiques";
proc print data=moy2(drop=dim3-dim31);
* var dim1 dim2;
run;

stat/jaccard6                                126
                 data=moy2 (table issue de la classif mixte)
     elle donne les moyennes des classes ainsi que d'autres statistiques
                                           11:45 Monday, October 20, 1997

OBS  _CRIT_ CLUSTER _FREQ_ _RMSSTD_ _RADIUS_ _NEAR_  _GAP_    DIM1    DIM2

  1 0.12874    1     30    0.11645  1.00853    3   0.68456 -0.28426 -0.02630
  2 0.12874    2      4    0.15686  1.02369    1   0.95574 -0.35700  0.37823
  3 0.12874    3      7    0.11117  0.73510    1   0.68456 -0.01700  0.00420
  4 0.12874    4      4    0.12585  0.64953    1   0.78302 -0.15252  0.07467
  5 0.12874    5      7    0.16482  1.04807    3   1.05107  0.51210 -0.64255
  6 0.12874    6      5    0.15551  0.88039    3   0.84306  0.29509  0.05777
  7 0.12874    7      3    0.17753  0.98804    1   1.12793  0.00918 -0.49023
  8 0.12874    8      8    0.17914  1.06450    3   1.02619  0.53691  0.52825
  9 0.12874    9      2    0.16686  0.65692    8   1.27736  0.86239  0.20992
 10 0.12874   10      2    0.17124  0.67418    1   1.26473 -0.21138 -0.00907
```


La table issue de *mean* = *moy2* (cf. transparent 24) donne :

- la valeur du critère de convergence.
- le numéro de la classe.
- sa fréquence.
- *RMSSTD* : la distance quadratique moyenne entre les observations de la classe.
- *Radius* : distance maximale du noyau à un individu de la classe.
- *Near* : la classe la plus proche.
- *Gap* : distance entre le noyau de la classe (son centre de gravité) et celui de la classe la plus proche.
- *Dim*1, ..., coordonnée moyenne de la classe sur l'axe 1, ...

```
data mixt2;
set mixt;
clus=put(cluster,2.); * text ne peut prendre que des chaines de;
text = substr(clus,2); * caracteres. On traduit donc cluster en clus;
*text=_name_;
y = dim1;
x = dim2;
xsys = '2';
ysys = '2';
size = 1;
label y = "Dimension 1";
label x = "Dimension 2";
keep x y text xsys ysys size;
run;
*proc print;
*run;
filename figure "plot3.eps";
title2 "CLASSIFICATION MIXTE (CAH-Ward puis nuees dynamiques)";
title3 "Projection des individus sur les 2 premiers axes";
title4 "Les individus sont representes par leur numero de classe, la "
       "classe 10 devient la classe 0";
proc gplot data=mixt2;
symbol1 i=none;
plot y*x=1 / annotate=mixt2 frame;
run;
quit;
```

stat/jaccard6

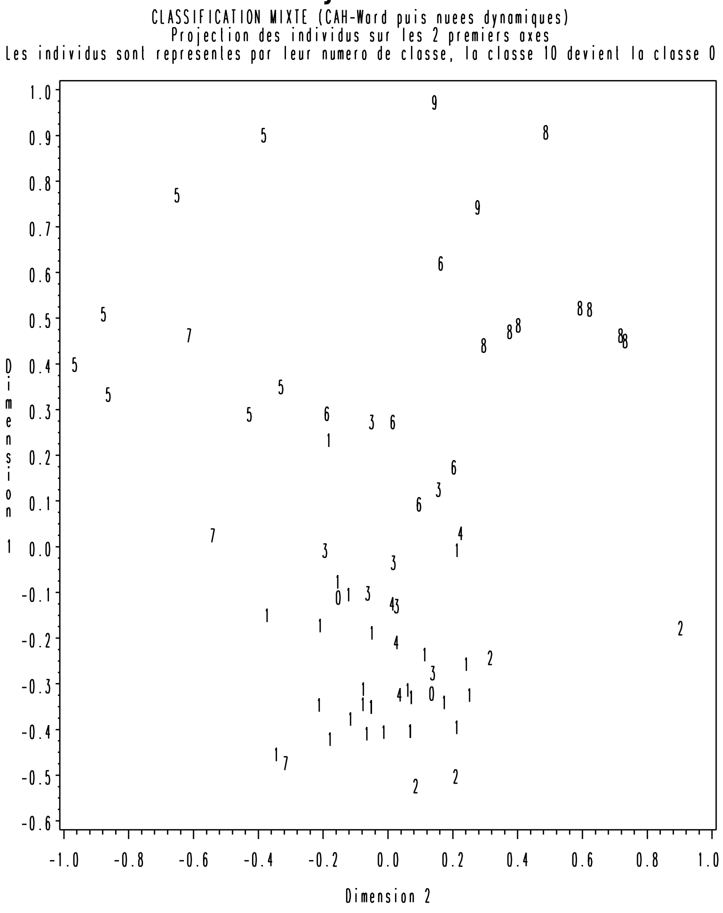

Méthode des bactériologistes
Distance Jaccard

```
data distjacc(type=distance);  *la table creee est une table de dist.;
  array dj(*) dj1-dj72;        * il y a 72 individus;
  retain dj1-dj72 .;           *initialisation des 72 ind. (a val.manq.);
do row=1 to 72;
  set naza1 point=row;
  array caract(*) c4--e11;             * liste des variables numeriques;
  array save(*) save1-save31;          * il y en a 31;
  do g=1 to 31;
    save(g)=caract(g);
  end;

    do col=1 to row;
      set naza1(drop=sou) point=col;
      cont00=0;
      cont01=0;
      cont10=0;
      cont11=0;
      do g=1 to 31;
        if caract(g)=0 and save(g)=1 then cont01=cont01+1;
        if caract(g)=1 and save(g)=0 then cont10=cont10+1;
        if caract(g)=0 and save(g)=0 then cont00=cont00+1;
        if caract(g)=1 and save(g)=1 then cont11=cont11+1;
      end;
      dj(col)=1-(cont11/(cont01+cont10+cont11));
    end;
    output;
  end;
  stop;
*  keep dj1-dj72 sou;*!!!!!!!!!!!!!!!!!!!!!!!!!;
   keep sou dj1-dj72;*!!!!!!!!!!!!!!!!!!!!!!!!!;
 run;

title2 "tableau de distance : 1 - indice de Jaccard";
proc print data=distjacc(obs=10);
  id sou;
  var dj1-dj10;
run;
```


Méthode des bactériologistes : indice de Jaccard

Méthode employée par les bactériologistes :

Indice de similitude : au numérateur, le nombre de fois où les deux souches ont repondu 1 au test. Au dénominateur, le total des réponses (0,1), (1,0) ou (1,1) pour les deux souches (on ne prend pas en compte les réponses (0,0) pour ne pas rapprocher des individus sur la base d'une réponse négative à un caractère donné.

Indice de distances : complément à 1 de l'indice de similitude. Sur cette distance est bâtie une classification hiérarchique ascendante, critère du saut moyen.

Distance Jaccard

```
stat/jaccard6                               127
                 tableau de distance : 1 - indice de Jaccard
                                            11:45 Monday, October 20, 1997

SOU   DJ1     DJ2     DJ3     DJ4     DJ5     DJ6     DJ7     DJ8   DJ9  DJ10

B2  0.00000  .       .       .       .       .       .       .      .     .
B4  0.16667 0.00000  .       .       .       .       .       .      .     .
B5  0.17647 0.22222 0.00000  .       .       .       .       .      .     .
B7  0.11765 0.16667 0.17647 0.00000  .       .       .       .      .     .
B8  0.33333 0.36842 0.18750 0.33333 0.00000  .       .       .      .     .
B10 0.33333 0.36842 0.29412 0.33333 0.35294 0.00000  .       .      .     .
B11 0.23529 0.27778 0.06667 0.23529 0.13333 0.25000 0.00000  .      .     .
B12 0.30000 0.25000 0.26316 0.30000 0.31579 0.22222 0.22222 0.00000 .     .
B14 0.17647 0.22222 0.12500 0.17647 0.18750 0.18750 0.06667 0.166670.000  .
B15 0.17647 0.22222 0.00000 0.17647 0.18750 0.29412 0.06667 0.263160.125  0
```

CAH sur le tableau de distance de Jaccard

```
title2 "CAH sur le tableau de distance (de Jaccard)";
proc cluster data=distjacc rsquare rmsstd
             outtree=treejacc
             method=average;
  var dj1-dj72;
  id sou;
  run;
```

```
stat/jaccard6                                 128
                 CAH sur le tableau de distance (de Jaccard)
                                              11:45 Monday, October 20, 1997

                       Average Linkage Cluster Analysis

         Root-Mean-Square Distance Between Observations   = 0.458716
```

NCL	-Clusters Joined-		FREQ	RMS STD	SPRSQ	RSQ	Norm RMS Dist	Tie
71	B5	B15	2	0.00000	0.000000	1.000000	0.000000	T
70	CL71	B16	3	0.00000	0.000000	1.000000	0.000000	T
69	B11	B9	2	0.00000	0.000000	1.000000	0.000000	T
68	B14	R58	2	0.00000	0.000000	1.000000	0.000000	T
67	CL68	H10	3	0.00000	0.000000	1.000000	0.000000	T
66	CL67	B72	4	0.00000	0.000000	1.000000	0.000000	
65	T44	H3	2	0.03928	0.000207	0.999793	0.121111	
64	B17	B19	2	0.04419	0.000261	0.999532	0.136250	T
63	CL66	B75	5	0.02795	0.000418	0.999114	0.136250	
62	CL70	CL69	5	0.03651	0.000714	0.998400	0.145333	T
61	B21	B63	2	0.04714	0.000297	0.998102	0.145333	
60	T47	R56	2	0.05051	0.000342	0.997761	0.155714	T
59	B8	B13	2	0.05051	0.000342	0.997419	0.155714	T
58	B30	B60	2	0.05439	0.000396	0.997023	0.167692	
57	CL65	B67	3	0.05611	0.000636	0.996387	0.193799	
56	B4	B18	2	0.07857	0.000826	0.995560	0.242222	
55	CL63	CL61	7	0.05918	0.002098	0.993463	0.245717	
54	H4	H7	2	0.08159	0.000891	0.992571	0.251538	
53	B2	B7	2	0.08319	0.000926	0.991645	0.256471	T
52	CL53	B26	3	0.08319	0.000926	0.990719	0.256471	T
51	T69	R59	2	0.08319	0.000926	0.989792	0.256471	
50	B77	B78	2	0.08839	0.001046	0.988746	0.272500	
49	B10	B62	2	0.09428	0.001190	0.987556	0.290667	
48	T39	R52	2	0.10102	0.001366	0.986190	0.311429	T
47	T42	H8	2	0.10102	0.001366	0.984824	0.311429	
46	CL62	CL59	7	0.07501	0.003464	0.981360	0.311795	
45	CL64	B25	3	0.08711	0.001770	0.979590	0.314474	T
44	CL57	B20	4	0.08364	0.001966	0.977624	0.321021	
43	CL55	B27	8	0.07450	0.002387	0.975237	0.333339	
42	CL52	CL56	5	0.10501	0.003225	0.972011	0.363333	T
..	....	....	.	....	....	....	....	

L'historique de la CAH Jaccard donne :

- *RMSSTD* : Root Mean Square Std Deviation.
- *SPRSQ* : semi partial R^2.
- *RSQ* : R^2.
- *Norm RMS Dist* : distance quadratique moyenne entre 2 objets, chacun d'eux appartenant à une des 2 classes se réunissant.

```
title2 "ARBRE DE CLASSIFICATION    (macro grftree de D. Jacobs)";
title3 "CAH sur le tableau de distance (de Jaccard)";
filename figure "jacc.eps";
%grftree(clusdsn=treejacc,items=72,axis=d);*!!!!!!!!!!!!!!!!!!!;
run;
```

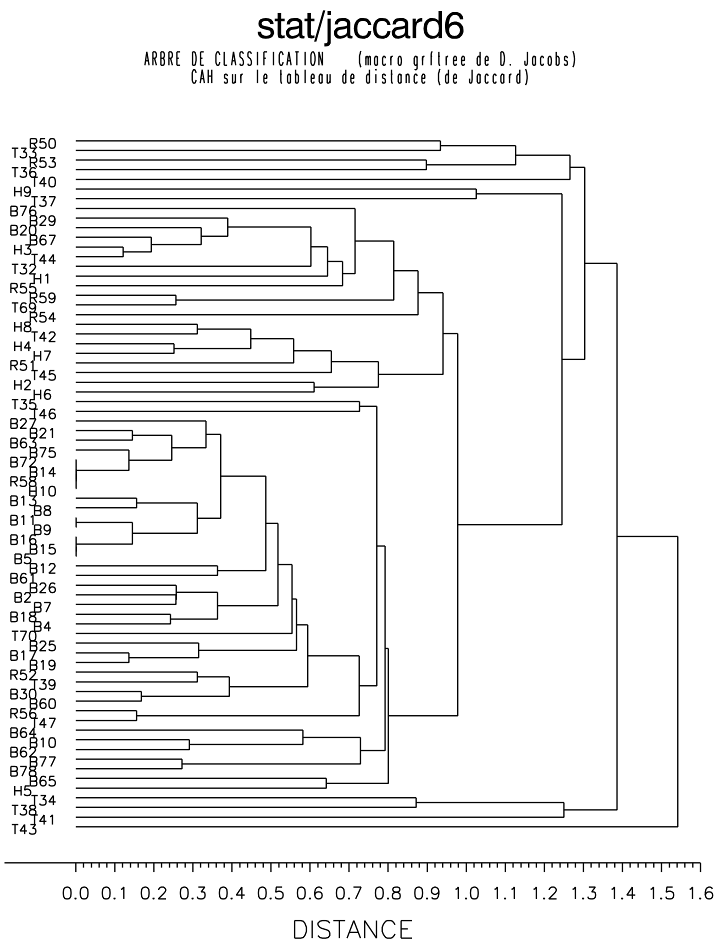

Appel de la macro *grftree* (macro faisant de beaux arbres de classification).

```
proc tree data=treejacc noprint n=10 out=treej;
  id sou;
run;

proc sort data=trees; by _name_;
proc sort data=treej; by sou;

data treej2;
  merge treej trees(keep=_name_ dim1 dim2 rename=(_name_=sou));
  by sou;
clus=put(cluster,2.);   * text ne peut prendre que des chaines de;
text = substr(clus,2);  * caracteres. On traduit donc cluster en clus;
*text=_name_;
y = dim1;
x = dim2;
xsys = '2';
ysys = '2';
size = 1;
label y = "Dimension 1";
label x = "Dimension 2";
keep x y text xsys ysys size;
run;
*proc print;
*run;
filename figure "plot4.eps";
title2 "CAH sur tableau de distance de JACCARD";
title3 "Projection des individus sur les 2 premiers axes";
title4 "Les individus sont representes par leur numero de classe, la "
       "classe 10 devient la classe 0";
footnote1 "Cette projection est discutable puisque les distances "
          "utilisees ";
footnote2 "dans la CAH-Jaccard et dans l'AFC ne sont pas les meme"
          "s        ";
proc gplot data=treej2;
  symbol1 i=none;
  plot y*x=1 / annotate=treej2 frame;
run;
*footnote;
run;
quit;
```


Projection des individus

Projection des individus

stat/jaccard6

CAH sur tableau de distance de JACCARD
Projection des individus sur les 2 premiers axes
Les individus sont representes par leur numero de classe, la classe 10 devient la classe 0

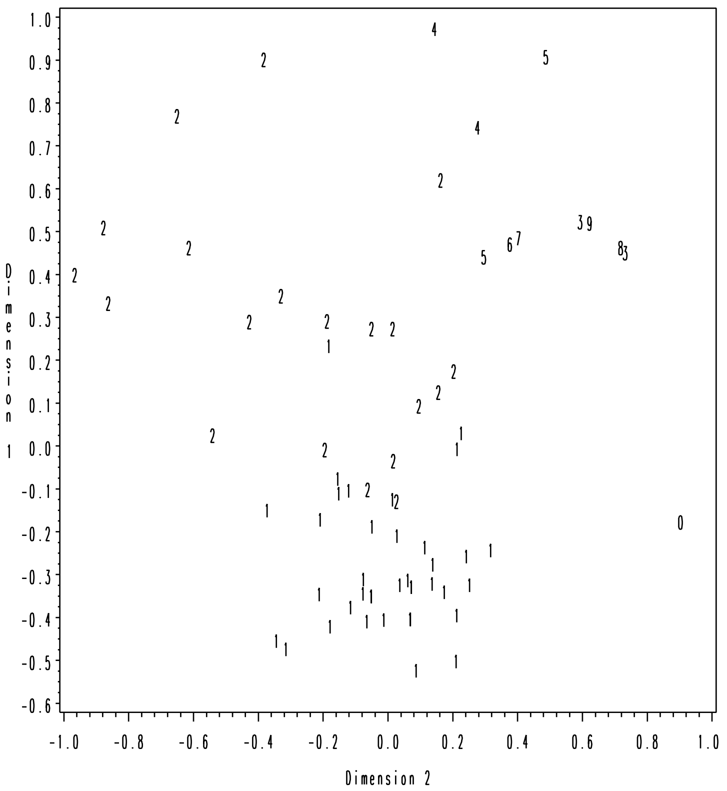

Cette projection est discutable puisque les distances utilisees
dans la CAH-Jaccard et dans l'AFC ne sont pas les memes