

**NOTICE D'INSTALLATION ET D'UTILISATION  
DE PROGRAMMES BASES SUR L'ALGORITHME DE KOHONEN  
ET DEDIES A L'ANALYSE DE DONNEES**

**3/12/2005 (V8.2-V9.1.3)**

**Patrick Letrémy  
MATISSE-SAMOS UMR CNRS 8595  
Université Paris 1  
pley@univ-paris1.fr**

*Algorithme d'apprentissage de Kohonen (SOM)*

*Algorithme KACP (Analyse d'un tableau de données quantitatives)*

*Algorithme KACPX (Analyse d'un tableau de données quantitatives avec valeurs manquantes)*

*Algorithme KFAST (SCL : Kohonen à zéro voisin)*

*Algorithme KBATCH (Kohonen dans sa version déterministe)*

*Algorithme KORRESP (Analyse d'un tableau de contingence)*

*Algorithmes KACM(j=1,2) et KDISJ (Analyse d'une table de Burt ou d'un tableau Disjonctif complet)*

## **I - CONTENU DE LA DISQUETTE (OU DU REPERTOIRE), INSTALLATION**

*La distribution contient les trois fichiers suivants :*

*AVERTI.TXT : le fichier d'annonce*

*DABOR.TXT : le fichier d'introduction*

*KSET\_V8.ZIP : le fichier à décompresser*

*L'installation par DEFAULT comporte 2 étapes:*

*1) - Décompresser le fichier KSET\_V8.ZIP de la disquette (ou du répertoire) sur c:\*

*2) - Charger et soumettre (Submit ou F3) dans SAS l'exécutable KINSTAL.sas situé dans le répertoire C:\K8.*

*Pour plus de détails concernant l'installation par défaut, lire le paragraphe II "DESCRIPTION DE LA PROCEDURE D'INSTALLATION" de la présente notice.*

*L'installation terminée, il est conseillé de lire le paragraphe III "CONTENU DES PROCEDURES ET REFERENCES" de la présente notice.*

*Pour une information complète sur l'utilisation des programmes, il faut consulter les paragraphes IV,V,VI,VII et VIII du présent fichier C:\K8\LADOK.DOC.*

## **II - DESCRIPTION DE LA PROCEDURE D'INSTALLATION**

*Vous avez suivi les indications de la section I, qui consistent en deux étapes:*

*- Décompression du fichier KSET\_V8.ZIP de la disquette (ou du répertoire) sur c:\*

*- Chargement et lancement dans SAS de l'exécutable KINSTAL.sas situé dans le répertoire c:\k8.*

*Vous trouverez ci-dessous la liste des fichiers créés au cours de l'installation.*

*L'étape 1) génère sur le disque dur C: l'arborescence suivante*

*C:\K8*

*C:\K8\ABRI*

*C:\K8\ABOUL*

*C:\K8\AKOR*

*C:\K8\AMAC*

## *Contenu du répertoire K8 :*

1. *LADOK.DOC* le présent fichier.
2. *Les 7 batch de lancement des algorithmes :*  
*BKOHN.sas, DKACP.sas, DKACPX.sas, DKFAST.sas, DKBATCH.sas, DKORR.sas et DKACM.sas*
3. *KOPTIONS.sas* est une macro qui définit les chemins d'accès des catalogues et des jeux de données.
4. *KOLCLUS.sas* donne un aperçu des 22 couleurs disponibles pour les Clusters (Super Classes).
5. *KOLCAM.sas* donne un aperçu des 13 couleurs disponibles pour les secteurs de Camemberts
6. *KOMAC.sas* permet la création du catalogue de macros *SASMACR.sas7bcat* dans *C:\K8\AKOR* (cf. le paragraphe VIII " TRAITEMENTS COMPLEMENTAIRES ").
7. *KINSTAL.sas* déjà cité.
8. *DSTAT.sas* est un utilitaire qui permet de calculer, pour une classification obtenue à partir de variables quantitatives, les moyennes conditionnelles, l'analyse de la variance et certaines statistiques de tests multidimensionnels.
9. *DTAIL.sas* est un utilitaire qui permet, à partir d'un tableau de réponses, de créer le tableau disjonctif complet et la table de Burt sous forme de deux tables sas; dans le cas où les réponses sont codées sous forme numérique, l'utilitaire fournit une troisième table qui correspond à un recodage des réponses sous forme de libellés.
10. *DMISS.sas* est un utilitaire qui permet de contrôler la présence (en nombre, en pourcentage et en position) de données manquantes dans une table sas.
11. *DEVIATION.sas* est un utilitaire qui permet, à partir de classifications d'individus et de modalités, de calculer les effectifs observés et théoriques, les déviations, les contributions au Khi deux, les statistiques du khi deux et de contrôler le bon positionnement des modalités.
12. *DEVAL.SAS* est un utilitaire qui permet d'étudier le croisement d'une classification avec des variables qualitatives (questions d'enquête) et qui fournit des graphiques (camemberts et histogrammes), ainsi que des tests du khi deux, et des valeurs tests.
13. *DCAM.sas* est un utilitaire qui permet de placer, sur une structure de ficelle ou de grille, des camemberts construits à partir d'une variable qualitative.
14. *DUPLIK.sas* est un utilitaire qui permet de dupliquer les lignes d'une table sas selon une pondération donnée.
15. *DISKRETIZ.sas* est un utilitaire qui permet de discrétiser des variables continues.

*Contenu du répertoire K8\ABRI : 279 fichiers de programme qui seront compilés dans des catalogues IML permanents*

*Contenu du répertoire K8\ABOUL : jeux de données de 11 tables sas = BLAYO.sas7bdat, BLAYO2.sas7bdat, BLAYO3.sas7bdat, BOPAY3.sas7bdat, BXPAY3.sas7bdat, SUPPL96.sas7bdat, SUPPLBX3.sas7bdat, MONUMENT.sas7bdat, CHIENS.sas7bdat, PIRON.sas7bdat et TBPAY3.sas7bdat.*

*Contenu du répertoire K8\AKOR : au niveau de l'étape 1) il est vide, à l'étape 2) le batch KINSTAL.sas permet la création et le stockage dans le répertoire C:\K8\AKOR de 10 catalogues IML permanents :*

1. *KOUPEL.sas7bcat* (9 entrées) utilisé par KOHONEN
2. *KOMPA.sas7bcat* (39 entrées) qui est commun à tous les algorithmes
3. *KOKAR.sas7bcat* (40 entrées) qui est commun à l'utilisation de KACP, KFAST et KBATCHE
4. *KALO.sas7bcat* (29 entrées) qui est propre à l'utilisation de KACPX
5. *KOUL.sas7bcat* (20 entrées) qui est propre à l'utilisation de KORRESP et KDISJ
6. *KALM.sas7bcat* (24 entrées) qui est commun à l'utilisation de KACM, KACM1 et KACM2
7. *KOUTO.sas7bcat* de 28 entrées (pour les traitements complémentaires)
8. *KABA.sas7bcat* de 29 entrées (pour les traitements complémentaires)
9. *KANIF.sas7bcat* de 25 entrées (pour les traitements complémentaires)
10. *KAISSE.sas7bcat* de 36 entrées (pour les traitements complémentaires)

A la fin de l'exécution de KINSTAL, pour vérification, apparaissent dans la fenêtre OUTPUT de SAS : le nom et le contenu de ces 10 catalogues IML.

Contenu du répertoire K8\AMAC : 20 fichiers de macro-commandes = MCONT.sas, MKLOBS.sas, MKOC.sas, MDIMA.sas, MDIST.sas, MFIN.D.sas, MFMOD.sas, MGVAR.sas, MKAMF1.sas, MKAMF2.sas, MKAMG.sas, MKLUF1.sas, MKLUF2.sas, MKLUG.sas, MSCAL.sas, MSCOL.sas, MSTAT.sas, MSUPP.sas, MSUPPX.sas et MVC3D.sas qui seront, à chaque session, compilés et stockés dans le catalogue C:\K8\AKOR\SASMACR.sas7bcat après la soumission de KOMAC.sas.

### III - CONTENU DES PROCEDURES ET REFERENCES

Thème : Programmes conversationnels pour :

- l'algorithme d'apprentissage non supervisé de KOHONEN (SOM)
- l'algorithme KACP (version Kohonen de L'ACP)
- l'algorithme KACPX (version Kohonen de L'ACP avec données manquantes)
- l'algorithme KFAST (SCL : version Kohonen à zéro voisin )
- l'algorithme KBATCH (version déterministe de Kohonen)
- l'algorithme KORRESP (version Kohonen de L'AFC)
- les algorithmes KACM(j=1,2) et KDISJ (versions Kohonen de L'ACM)
- traitements complémentaires à ces algorithmes
- Le paragraphe IV décrit l'exécution de l'algorithme de KOHONEN pour des entrées qui sont des points de  $R^2$  choisis au hasard dans un carré.
- Le paragraphe V décrit le déroulement de KACP(X), KFAST et KBATCH sur un jeu de données.
- Le paragraphe VI décrit le déroulement de KORRESP sur un jeu de données.
- Le paragraphe VII décrit le déroulement de KACM(j=1,2) et de KDISJ sur un jeu de données.
- Le paragraphe VIII décrit les traitements complémentaires.

Références :

- F.Blayo et M.Verleysen, *Les réseaux de neurones artificiels*, Collection Que sais-je ?, vol 3042, PUF, 1996.
- M.Cottrell et P.Létrémy, Classification et analyse des correspondances au moyen de l'algorithme de Kohonen : application à l'étude de données socio-économiques, *Actes de Neuro Nîmes, 1994*.
- M.Cottrell et S.Ibbou, Multiple Correspondence Analysis of a crosstabulation matrix using the Kohonen algorithm, *Proc. of ESANN'95*, Editions D Facto, Bruxelles, 1995.
- M.Cottrell et E. de Bodt, A Kohonen map representation to avoid misleading interpretation, *Proc. of ESANN'96*, Editions D Facto, Bruxelles, 1996.
- Demartines, Analyse de données par réseaux de neurones auto-organisés, Thèse de Doctorat, Laboratoire TIRF, Institut National Polytechnique de Grenoble.
- Classification, Analyse des Correspondances et Méthodes Neuronales, Thèse de S. Ibbou soutenue le 20/1/98.
- Applications des Algorithmes d'Auto-Organisation à la Classification et à la Prévision, Thèse de P. Rousset soutenue le 3/12/99.
- M.Cottrell et P.Létrémy, Analysing surveys using the Kohonen algorithm, *ESANN'2003*, Bruges, 2003, M. Verleysen Ed., Editions D Facto, Bruxelles.
- M.Cottrell, S.Ibbou, P.Létrémy SOM-based algorithms for qualitative variables, *Neural Networks*, 17, p. 1149-1167, 2004.

## IV – DEMONSTRATION

### **Conseils pour la saisie dans les fenêtres IML qui sont assez rudimentaires !!**

Se déplacer de champ en champ avec la touche “ TAB ”. Pour entrer une nouvelle valeur : se placer en début de champ et supprimer ( “ Suppr ”) l'ancienne valeur avant de saisir la nouvelle valeur.

### **Algorithme d'apprentissage de KOHONEN pour des points dans un carré de $R^2$**

Charger et soumettre dans SAS le fichier BKOHN.sas qui se trouve dans c:\k8. Ce programme de démonstration ne nécessite aucune donnée. TOUTE LA SUITE EST CONVERSATIONNELLE

Une fenêtre "CHOIX" apparaît, elle correspond à une boucle sans fin dont on ne peut sortir que par choix : A (Arrêt définitif). Sinon l'utilisateur peut choisir entre un réseau de dimension 1, (ficelle choix : F) ou un réseau de dimension 2 (grille choix : G). Pour toutes les fenêtres, le choix retenu est validé par F3.

- Si le choix est : F, une fenêtre "FICELLE" s'ouvre pour demander la taille de la ficelle (n), le nombre maximum d'itérations (tmax) et la périodicité de l'affichage (periode).

Par exemple : n = 20, tmax = 200 et periode = 25 suivi de F3 pour valider.

Alors,  $200/25+1=9$  écrans graphiques seront produits et stockés provisoirement dans le catalogue WORK.GSEG.

A la fin des 200 itérations, l'utilisateur peut revenir sur l'un des 9 graphiques (à l'aide de "CATALOG WORK.GSEG") pour une éventuelle impression.

Dans le catalogue WORK.GSEG, les 9 graphiques sont nommés IMLG à IMLG8.

On peut toujours revenir à la fenêtre "CHOIX" avec la commande Window.

- Si le choix est : G, une fenêtre "GRILLE" s'ouvre pour demander la taille de la grille (m = nombre de lignes et n = nombre de colonnes), le nombre maximum d'itérations (tmax) et la périodicité de l'affichage (periode).

Par exemple : n = 7, m = 7, tmax = 500 et periode = 50 suivi de F3 pour valider.

Alors,  $500/50+1=11$  graphiques nommés IMLG à IMLG10 seront produits et stockés dans le catalogue WORK.GSEG.

Si on veut éviter un mélange de numérotation entre les graphiques "ficelles" et "grilles", on peut avant d'opter pour un nouveau choix (F ou G) détruire ou renommer le catalogue WORK.GSEG.

Il est donc possible de boucler indéfiniment sur choix : F ou G. Pour y mettre fin, il suffit de choisir: A suivi de plusieurs F3 pour revenir dans la fenêtre “ PROGRAM EDITOR ”.

## V - L'ALGORITHME KACP

### **Algorithme KACP : Analyse en Composantes Principales version KOHONEN**

Il s'agit d'une classification en classes liées par une structure de voisinage, qui utilise l'algorithme de Kohonen. On peut dire que cette analyse s'apparente à une analyse en composantes principales.

Pour illustrer le déroulement d'une session, nous utiliserons les données fournies par F.BLAYO qui concernent 53 pays en 1984 et qui sont présentées dans le Que sais-je ? vol 3042 "LES RESEAUX DE NEURONES ARTIFICIELS" de F. BLAYO et M. VERLEYSSEN.

*Pour chaque pays on dispose des valeurs de 7 variables :*

- 1. PAYS (nom du pays),*
- 2. ANCRX (croissance annuelle de la population),*
- 3. TXMORT (taux de mortalité infantile),*
- 4. TXANAL (taux d'illettrisme),*
- 5. SCOL2 (fréquentation scolaire du 2ème degré),*
- 6. PIBH (PIB par habitant),*
- 7. CRXPIB (croissance annuelle du PIB).*

*Ces données sont dans une table sas (BLAYO.sas7bdat) qui est placée dans le répertoire c:\k8\aboul . La table C:\K8\ABOUL\BOPAY3.sas7bdat (96 pays en 1996) est une mise à jour plus récente de la table BLAYO.sas7bdat, avec introduction de nouvelles variables comme les taux de chômage et d'inflation, ainsi qu'une variable qualitative indiquant le niveau de l'IDH (Indice du Développement Humain).*

### **DEBUT DE LA SESSION KACP**

*Charger et soumettre dans SAS : DKACP.sas qui se situe dans c:\k8.*

*Toute la suite est CONVERSATIONNELLE, des fenêtres s'ouvrent et guident l'utilisateur dans ses choix. Pour toutes les fenêtres, les choix retenus seront validés par F3.*

*Fenêtre n°1 : "CHEMIN".*

*L'utilisateur précise le chemin d'accès aux données (par défaut c:\k8\aboul).*

*Exemple :      path:    C:\K8\ABOUL            suivi de F3.*

*Dans le cas où le répertoire proposé est vide ou inexistant, un message d'erreur apparaît dans la fenêtre LOG, la commande WINDOW permet le passage de la fenêtre CHEMIN à celle du LOG.*

*Fenêtre n°2 : "CHOIXDAT".*

*A partir des tables sas situées dans le répertoire choisi dans "CHEMIN", l'utilisateur sélectionne (par X) la table retenue pour l'analyse.*

*Exemple :      X            BLAYO            suivi de F3.*

*Fenêtre n°3 : "CHOIXVAR".*

*A partir de la liste des variables de la table sélectionnée dans "CHOIXDAT", l'utilisateur indique (par C) la variable qui identifie les observations (cette variable sera traitée comme étant de type Caractère) et (par N) les variables Numériques à retenir pour l'analyse.*

*Exemple :*

	CHOIX	VARIABLE
	C	PAYS
	N	ANCRX
	N	TXMORT
	N	TXANAL
	N	SCOL2
	N	PIBH
	N	CRXPIB

*suivi de F3.*

*Remarque: En cas de données manquantes un message apparaît dans l'OUTPUT indiquant leur nombre, leurs positions (numéros d'observations dans la table) et le programme s'arrête en indiquant qu'il faut utiliser KACPX.*

Fenêtre n°4 : "STRUCTUR".

L'utilisateur choisit son type de réseau : F pour Ficelle, G pour Grille.

Exemple :                      choix :                      G                      suivi de F3.

Fenêtre n°5 : "PARAM\_FI" ou "PARAM\_GR".

Pour une Ficelle, "PARAM\_FI" demande sa taille (n) et le nombre maximum d'itérations (tmax).

Pour une GRille, "PARAM\_GR" demande le nombre de lignes (m), le nombre de colonnes (n) et le nombre maximum d'itérations (tmax).

Les nu unités du réseau (nu = n pour une ficelle ou nu = m×n pour une grille) seront numérotées de 1 à nu. Par exemple si nu=12 pour la ficelle de n=12, on aura : 1 2 ..... 11 12.

Pour la grille de m = 3 et n = 4 on aura :

1 4 7 10

2 5 8 11

3 6 9 12

On peut prendre pour tmax une valeur de l'ordre de 5 à 6 fois le nombre d'observations; ceci revient à dire qu'en moyenne chaque observation sera présentée 5 à 6 fois durant l'apprentissage. Notons que ce rapport peut être diminué si le nombre d'observations est très élevé.

Dans "PARAM\_FI" comme dans "PARAM\_GR" deux choix supplémentaires sont offerts.

Le premier choix (O/N) permet d'initialiser le générateur de nombre au hasard.

O : le point de départ est fixe, ce qui rend les résultats reproductibles (valeur par défaut).

N: le point de départ est calé sur l'horloge de la machine, ce qui rend les résultats NON reproductibles.

Le deuxième choix (O/N) propose le calcul et la représentation éventuels de la fonction "énergie". Cette "énergie" ou "potentiel" généralise la notion de "variance intra" en l'étendant aux plus proches voisins. Passé les trois quarts de tmax (à zéro voisin) les deux notions coïncident. En fin d'itérations, l'énergie doit se situer sur un minimum (local).

Le choix négatif (N) est la valeur par défaut; si le nombre d'itérations est élevé (dès 2000), un choix affirmatif (O) peut s'avérer coûteux en temps de calcul, il implique la création d'un graphique de nom : NRJ stocké dans un catalogue graphique permanent (cf. la fenêtre n°6 : "INFORM").

Quel que soit le choix retenu le programme affiche dans l'OUTPUT la valeur finale de la variance intra.

Exemple :

m = 8

n = 8

tmax = 300

CHOIX :                      O

CHOIX :                      O                      suivi de F3.

Fenêtre n°6 : "INFORM".

Dans cette fenêtre, l'utilisateur doit renseigner le champ Nom (fixé par défaut à \_TEMPOR\_) et décider (choix O ou N) de l'éventuel visualisation et stockage d'un graphique de type "dx-dy" (cf. : la thèse de P. DEMARTINES dont la référence est donnée dans la section III).

Le champ Nom sera utilisé pour nommer des catalogues (fichier d'extension .sas7bcat) et des tables sas (fichier d'extension .sas7bdat). Il doit comporter au moins 5 caractères; dans le cas contraire, le programme complète la réponse par des X pour obtenir un champ Nom de 5 caractères.

Le choix : N est proposé par défaut; en cas de réponse positive (O), un graphique de nom DX\_DY sera créé dans le catalogue graphique. C'est un nuage de points dans un carré de côté 1, où l'on compare les distances (normalisées à 1) théoriques entre les unités gagnantes avec les distances (normalisées à 1) euclidiennes entre les vecteurs poids associés. La situation idéale correspondant à une organisation parfaite serait celle où tous les points (représentés sur le graphique par des cercles) sont situés sur la diagonale du carré.

Exemple :

Nom : B8G3CPAY

choix : O suivi de F3.

Ces réponses impliquent la création de 5 tables sas et de 2 catalogues qui seront placés dans C:\K8\ABOUL (cf.: le champ path de la fenêtre n°1 : "CHEMIN").

Description des 5 tables sas :

1. la table B8G3C\_CL (valeur par défaut : \_TEMP\_CL) donne, pour chaque unité gagnante, le contenu de la classe correspondante.
2. la table B8G3C\_UG (valeur par défaut : \_TEMP\_UG) donne les valeurs moyennes des variables brutes pour chaque unité gagnante.
3. La table B8G3C\_WS (valeur par défaut : \_TEMP\_WS) donne pour chaque unité (gagnante ou pas) sa position dans la grille : ligne, colonne, son effectif (zéro si l'unité n'est pas gagnante) et son "vecteur poids final " ou "vecteur représentant ".
4. La table B8G3CPAY (valeur par défaut : \_TEMPOR\_) donne pour chaque modalité (ici PAYS) de la variable (C) qui identifie les observations (cf. la fenêtre n°3 : "CHOIXVAR") son unité gagnante (sa classe) : \_codage\_, sa position dans la grille : ligne, colonne et ses valeurs pour les variables brutes ainsi que pour les variables éventuellement transformées (cf.: la fenêtre n°8 "PREPROC").
5. La table INFO\_B8G3CPAY (valeur par défaut : INFO\_ \_TEMPOR\_) qui renseigne sur la structure du réseau (ici GRILLE) et sur l'algorithme (ici KACP).

Description des 2 catalogues :

1. Le catalogue iml B8G3CPAY (valeur par défaut : \_TEMPOR\_) contient tous les intermédiaires de calcul (matrices de poids initiaux et finaux, liste des unités gagnantes , etc.) qui seront ultérieurement utilisés dans les traitements complémentaires (cf. le paragraphe VIII).
2. Le catalogue graphique GACPB8G3 (valeur par défaut : GACP\_TEM) contient 10 graphiques (au plus). Chaque graphique possède son nom et sa description qui correspond aux 40 premiers caractères de son titre.

Les 10 graphiques du catalogue graphique GACPB8G3 :

Nom	Description
CELL	Contenu des 64 cellules
CELLW	Valeur Moyenne & Représentant des 64 cellules
DX_DY	dx_dy
G_DIMA	Distances (M) avec les plus proches voisins
G_PAVAGE	KACP : grille 8x8 et 300 itérations
HIS_GRI	Représentants des classes (Poids Finaux)
HIS_GRII	Moyennes des classes (valeurs normalisées)
LIN_GRI	Représentants des classes (Poids Finaux)
LIN_GRII	Moyennes des classes (valeurs normalisées)
NRJ	Variance intra étendue aux voisins

Les graphiques, dans le catalogue, sont classés en ordre alphabétique alors qu'à l'affichage l'ordre sera pour une grille :

G\_PAVAGE, CELL, CELLW, G\_DIMA, LIN\_GRI, HIS\_GRI, LIN\_GRII, HIS\_GRII, DX\_DY et NRJ

pour une ficelle :

F\_PAVAGE, F\_DIMA, LIN\_FIC, HIS\_FIC, LIN\_FIC1, HIS\_FIC1, CELL, CELLW, DX\_DY et NRJ

Le graphique CELL présente sous forme de pavage le contenu des unités (les valeurs numériques des variables, éventuellement transformées selon le choix de la fenêtre " PREPROC " et qui correspondent aux individus associés à une même unité gagnante) du réseau (grille ou ficelle).

Le graphique CELLW présente sous forme de pavage le vecteur représentant (poids final) de l'unité du réseau (grille ou ficelle) ainsi que la moyenne des variables dans le cas où l'unité est gagnante (classe non vide). Il permet de comparer l'allure du vecteur représentant d'une unité gagnante avec son vecteur moyen. (l'individu moyen de cette classe non vide).

G\_DIMA pour une Grille (ou F\_DIMA pour une Ficelle) permet d'apprécier pour chaque unité (classe) son effectif et les distances de **Mahalanobis** normalisées avec ses plus proches voisins (au plus 8 pour une grille et au plus 2 pour une ficelle). A l'exception des unités des bords, si l'unité est très proche de ses (8 ou 2) voisins, son polygone sera très proche des bords du carré. (Adapté de M. Cottrell & E. De Bodt, ESANN'96).

G\_PAVAGE pour une Grille (ou F\_PAVAGE pour une Ficelle) donne l'illustration graphique du contenu des classes (unités) du réseau (cf.: la table B8G3C\_CL).

HIS\_GRI pour une Grille (HIS\_FIC pour une Ficelle) est un pavage d'histogrammes (diagramme en bâtons) des représentants des classes (poids finaux).

HIS\_GRII pour une Grille (HIS\_FICI pour une Ficelle) est un pavage d'histogrammes des moyennes normalisées pour les classes non vides.

LIN\_GRI pour une Grille (LIN\_FIC pour une Ficelle) est un pavage de courbes des représentants des classes (poids finaux).

LIN\_GRII pour une Grille (LIN\_FICI pour une Ficelle) est un pavage de courbes des moyennes normalisées pour les classes non vides.

Il n'y a pas de graphique de pavage pour une ficelle de plus de 50 unités

Fenêtre n°7 : "INIT0".

L'utilisateur indique la façon d'initialiser les vecteurs poids initiaux

E : s'ils sont pris au hasard entre le min et le max (choix par défaut).

H : s'ils sont pris au hasard parmi les entrées.

F : s'ils sont pris dans un maillage du premier plan factoriel.

Exemple :                    choix :            E            suivi de F3.

Fenêtre n°8 : "PREPROC".

L'utilisateur choisit un éventuel type de prétraitement de ses données :

A : pour Aucun

C : pour Centrer les variables

N : pour centrer et réduire les variables (Normer)

K : pour transformer les lignes de la matrice des données en pourcentages de somme 1 (profils lignes) et utiliser la distance du Khi deux sur ces profils.

Le choix N (normer) est proposé par défaut

Exemple :                    choix :            N            suivi de F3.

**PATIENCE KACP travaille pour vous !!!!**

Avant d'afficher les graphiques du catalogue graphique IML, les 6 autres fichiers permanents sont créés.

**LA SESSION KACP EST TERMINEE**



## **L'ALGORITHME KACPX**

*C'est la version pour données manquantes de KACP. Il faut noter que KACPX produit 2 tables sas de plus que KACP nommées par défaut : `_TEMP_CMP.sas7bdat` et `_TEMP_WMQ.sas7bdat`.*

*La première est une table qui contient les **données complétées**, ainsi que le nombre et le taux de valeurs manquantes pour chaque observation. Elle peut servir d'entrée à KACP avec une autre initialisation des vecteurs poids initiaux.*

*La seconde table donne pour chaque unité du réseau son effectif, le nombre et le pourcentage de données manquantes pour cette unité, ainsi que ses variances « horizontale » et « verticale », ceci permet d'apprécier, d'une part, la dispersion des individus d'une même classe (unité gagnante) autour de leur vecteur représentant (aspect « verticale »), d'autre part d'apprécier la dispersion longitudinale du représentant de l'unité (aspect « horizontale »).*

## **L'ALGORITHME KFAST : Simple Competitive Learning (SCL).**

*C'est la version stochastique de l'algorithme de FORGY, il s'agit d'une classification qui utilise l'algorithme de KOHONEN à zéro voisin sur toutes les étapes du processus.*

## **L'ALGORITHME KBATCH**

*C est la version déterministe de l'algorithme de KOHONEN.*

*Le déroulement d'une session KACPX, KFAST ou KBATCH est similaire à celle de KACP : il suffit de charger et soumettre dans SAS : `DKACPX.sas`, `DKFAST.sas` ou `DKBATCH.sas` qui se situe dans `c:\k8`.*

## VI - L'ALGORITHME KORRESP

### *Algorithme KORRESP : Version Kohonen de l'analyse d'un tableau de contingence*

*On analyse un tableau de contingence croisant deux variables qualitatives, au moyen d'un algorithme dérivé de celui de Kohonen. (M.Cottrell et P.Létrémy, dans les Actes de Neuro Nîmes, 1994).*

*Pour illustrer le déroulement d'une session, nous utiliserons un tableau de contingence qui croise les monuments historiques en France, suivant leur catégorie (au nombre de  $p=11$ ) et leur type de propriétaire (au nombre de  $q=6$ ).*

*Ce tableau est stocké dans la table sas de nom MONUMENT qui possède  $p=11$  observations et  $q+1=7$  variables soit :*

*Une variable caractère nommée MONU dont les valeurs sont les  $p=11$  catégories et  $q=6$  variables numériques qui ont pour nom les  $q=6$  types de propriétaires.*

*Détaillons les  $p=11$  catégories de monuments :*

*preh (antiquités préhistoriques),*

*hist (antiquités historiques),*

*chat (châteaux),*

*mili (architecture militaire),*

*cath (cathédrales),*

*egli (églises),*

*chap (chapelles),*

*mona (monastères),*

*ecpu (édifices civils publics),*

*ecpr (édifices civils privés)*

*div (divers).*

*et les  $q=6$  types de propriétaires :*

*COMM (commune),*

*PRIV (privé),*

*ETAT (état),*

*DEPA (département),*

*ETPU (établissement public)*

*NDET (non déterminé).*

*L'allure de la table MONUMENT (placée dans le répertoire c:\k8\aboul) est la suivante:*

MONU	COMM	PRIV	.....	NDET
preh	244	790	.....	144
hist	246	166	.....	31
.....	.....	.....	.....	.....
ecpr	224	909	.....	4
div	967	242	.....	9

## **DEBUT DE LA SESSION KORRESP**

Charger et soumettre dans SAS : DKORR.sas qui se trouve dans c:\k8.

Toute la suite est CONVERSATIONNELLE, des fenêtres s'ouvrent et guident l'utilisateur dans ses choix.  
Pour toutes les fenêtres, les choix retenus seront validés par F3.

Fenêtre n°1 : "CHEMIN".

L'utilisateur précise le chemin d'accès aux données (par défaut c:\k8\aboutl).

Exemple : path: C:\K8\ABOUL suivi de F3.

Dans le cas où le répertoire proposé est vide ou inexistant, un message d'erreur apparaît dans la fenêtre LOG, la commande WINDOW permet le passage de la fenêtre CHEMIN à celle du LOG.

Fenêtre n°2 : "CHOIXDAT".

A partir des tables sas situées dans le répertoire choisi dans "CHEMIN", l'utilisateur sélectionne (par X) la table retenue pour l'analyse.

Exemple : X MONUMENT suivi de F3.

Fenêtre n°3 : "SELECT".

L'utilisateur doit sélectionner les éléments du tableau de contingence.

C : Pour l'identificateur des lignes du tableau de contingence.

N : Pour les colonnes (variables numériques) du tableau de contingence.

Exemple :

CHOIX	VARIABLE
C	MONU
N	COMM
N	PRIV
N	ETAT
N	DEPA
N	ETPU
N	NDET

suivi de F3.

Remarque: En cas de données manquantes un message apparaît dans l'OUTPUT indiquant leur nombre, leurs positions (numéros d'observations dans la table) et le programme s'arrête.

En absence de donnée manquante, le programme calcule et affiche dans la fenêtre "OUTPUT" la statistique du khi\_deux et sa "p-valeur". Si la p-valeur est > 5% alors un message d'avertissement apparaît dans la fenêtre "OUTPUT" qui explique en quoi l'analyse du tableau de contingence n'est pas très pertinente mais le programme KORRESP continue.

Fenêtre n°4 : "STRUCTUR".

L'utilisateur choisit son type de réseau : F pour Ficelle, G pour Grille.

Exemple : choix : G suivi de F3.

Fenêtre n°5 : "PARAM\_FI" ou "PARAM\_GR".

Pour une Ficelle, "PARAM\_FI" demande sa taille (n) et le nombre maximum d'itérations (tmax).

Pour une GRille, "PARAM\_GR" demande le nombre de lignes (m), le nombre de colonnes (n) et le nombre maximum d'itérations (tmax).

Les nu unités du réseau (nu = n pour une ficelle ou nu = m×n pour une grille) seront numérotées de 1 à nu. Par exemple si nu=12 pour la ficelle de n=12, on aura : 1 2 ..... 11 12.

Pour la grille de  $m = 3$  et  $n = 4$  on aura :

1 4 7 10

2 5 8 11

3 6 9 12

Dans "PARAM\_FI" comme dans "PARAM\_GR" deux choix supplémentaires sont offerts.

Le premier choix (O/N) permet d'initialiser le générateur de nombre au hasard.

O : le point de départ est fixe, ce qui rend les résultats reproductibles (valeur par défaut).

N: le point de départ est calé sur l'horloge de la machine, ce qui rend les résultats NON reproductibles.

Le deuxième choix (O/N) propose le calcul et la représentation éventuels de la fonction "énergie". Cette "énergie" ou "potentiel" généralise la notion de "variance intra" en l'étendant aux plus proches voisins (à zéro voisin les deux notions coïncident). En fin d'itérations, elle doit se situer sur un minimum (local).

Le choix négatif (N) est la valeur par défaut; si le nombre d'itérations est élevé (dès 1000), un choix affirmatif (O) peut s'avérer coûteux en temps de calcul, il implique la création de 2 graphiques (nommés NRJ et NRJ1) stockés dans un catalogue graphique permanent (cf. la fenêtre n°6 : "INFORM").

Quel que soit le choix retenu le programme affiche dans l'OUTPUT la valeur finale de la variance intra pour les profils lignes et colonnes.

Exemple :

$m = 5$

$n = 5$

$tmax = 300$

CHOIX : O

CHOIX : O suivi de F3.

Si le tableau de contingence a  $p \times q$  modalités, on peut prendre pour :

- une ficelle,  $n$  au moins égal à  $\max(p, q)$

- une grille,  $m = n$ , où  $n$  est tel que  $n \times n$  est immédiatement supérieur à  $2 \max(p, q)$ .

Ici  $p=11$  et  $q=6$ , on prend une grille  $5 \times 5$  puisque 25 est le carré immédiatement supérieur à 22.

Fenêtre n°6 : "INFORM".

Dans cette fenêtre, l'utilisateur doit renseigner le champ Nom (fixé par défaut à `_TEMPOR_`) et décider (choix O/N) de l'éventuel visualisation et stockage de deux graphiques de type "dx-dy" (cf. : la thèse de P. DEMARTINES dont la référence est donnée dans la section III).

Le champ Nom sera utilisé pour nommer des catalogues (fichier d'extension `.sas7bcat`) et des tables sas (fichier d'extension `.sas7bdat`). Il doit comporter au moins 5 caractères; dans le cas contraire, le programme complète la réponse par des X pour obtenir un champ Nom de 5 caractères.

Le choix : N est proposé par défaut; en cas de réponse positive (O), deux graphiques de noms DX\_DY et DX\_DY1 seront créés et stockés dans le catalogue graphique. Un graphique de type "dx-dy" est un nuage de points dans un carré de côté 1, où l'on compare les distances (normalisées à 1) théoriques entre les unités gagnantes avec les distances (normalisées à 1) euclidiennes entre les vecteurs poids associés.

La situation idéale correspondant à une organisation parfaite serait celle où tous les points (représentés sur le graphique par des cercles) sont situés sur la diagonale du carré.

Exemple :

Nom : MO3C5G

choix : O suivi de F3.

Ces réponses impliquent la création de 4 tables sas et de 2 catalogues qui seront placés dans `C:\K8\ABOUL` (cf.: le champ path de la fenêtre n°1 : "CHEMIN").

Description des 4 tables sas :

1. La table *MO3C5\_CL* (valeur par défaut : *\_TEMP\_CL*) donne, pour chaque unité gagnante, les modalités du croisement dont elle est la référence (contenu de la classe).
2. La table *MO3C5\_WS* (valeur par défaut : *\_TEMP\_WS*) donne pour chaque unité (gagnante ou pas) sa position dans la grille : ligne, colonne, son effectif (zéro si l'unité n'est pas gagnante) et son "vecteur poids final concaténé " ou "vecteur représentant ".
3. La table *MO3C5G* (valeur par défaut : *\_TEMPOR\_*) donne pour chaque modalité du croisement son unité gagnante (sa classe) : *\_codage\_* , sa position dans la grille : ligne, colonne. Dans le prolongement des modalités du croisement (ici  $11+6=17$  valeurs) se place la table de BURT.
4. La table *INFO\_MO3C5G* (valeur par défaut : *INFO\_ \_TEMPOR\_*) qui renseigne sur la structure du réseau (ici *GRILLE*) et sur l'algorithme (ici *KORRESP*).

#### *Description des 2 catalogues :*

1. Le catalogue *iml MO3C5G* (valeur par défaut : *\_TEMPOR\_*) contient tous les intermédiaires de calcul (matrices de poids initiaux et finaux, liste des unités gagnantes, etc.) qui seront ultérieurement utilisés dans les traitements complémentaires (cf. le paragraphe VIII).
2. Le catalogue graphique *GKORMO3C* (valeur par défaut : *GKOR\_TEM*) contient 10 graphiques (au plus). Chaque graphique possède son nom et sa description qui correspond aux 40 premiers caractères de son titre.

#### *Les 10 graphiques du catalogue graphique GKORMO3C :*

<i>Nom</i>	<i>Description</i>
<i>CELLW</i>	<i>Profil colonne Moyen &amp; Représentant des 25 cellules</i>
<i>CELLW1</i>	<i>Profil ligne Moyen &amp; Représentant des 25 cellules</i>
<i>DX_DY</i>	<i>Dx_dy pour les colonnes</i>
<i>DX_DY1</i>	<i>Dx_dy pour les lignes</i>
<i>G_DIST</i>	<i>Distances (E) avec les plus proches voisins</i>
<i>G_PAVAGE</i>	<i>KORRESP : grille 5x5 et 300 itérations</i>
<i>LIN_GRI</i>	<i>Représentants (Poids Finaux) pour les colonnes</i>
<i>LIN_GRI1</i>	<i>Représentants (Poids Finaux) pour les lignes</i>
<i>NRJ</i>	<i>Potentiel pour les colonnes</i>
<i>NRJ1</i>	<i>Potentiel pour les lignes</i>

*Les graphiques, dans le catalogue, sont classés en ordre alphabétique alors qu'à l'affichage l'ordre sera Pour une grille:*

*G\_PAVAGE, LIN\_GRI, CELLW, LIN\_GRI1, CELLW1, G\_DIST, DX\_DY, DX\_DY1, NRJ et NRJ1*

*Pour une ficelle:*

*F\_PAVAGE, LIN\_FIC, CELLW, LIN\_FIC1, CELLW1, F\_DIST, DX\_DY, DX\_DY1, NRJ et NRJ1*

*Les graphiques CELLW(1) présentent sous forme de pavage le vecteur représentant pour les profils colonnes(lignes) de l'unité du réseau (grille ou ficelle) ainsi que le profil colonne(ligne) moyen dans le cas où l'unité est gagnante (classe non vide). Il permet de comparer l'allure du vecteur représentant d'une unité gagnante avec son profil moyen. (la modalité moyenne de cette classe non vide).*

*G\_DIST pour une Grille (ou F\_DIST pour une Ficelle) permet d'apprécier pour chaque unité (classe) son effectif et les distances euclidiennes normalisées avec ses plus proches voisins (8 pour une grille et 2 pour une ficelle). A l'exception des unités des bords, si l'unité est très proche de ses (8 ou 2) voisins, son polygone sera très proche des bords du carré (cf. la référence de M. Cottrell & E. De Bodt, ESANN'96).*

*G\_PAVAGE pour une Grille (ou F\_PAVAGE pour une Ficelle) donne l'illustration graphique du contenu des classes (unités) du réseau (cf. : la table MO3C5\_CL).*

*LIN\_GRI pour Grille (ou LIN\_FIC pour une Ficelle) est un pavage de courbes des vecteurs "poids finaux" ou "représentants" associés aux profils colonnes.*

*LIN\_GRII pour Grille (ou LIN\_FICI pour une Ficelle) est un pavage de courbes des vecteurs "poids finaux" ou "représentants" associés aux profils lignes.*

*Il n'y a pas de graphique de pavage pour une ficelle de plus de 50 unités.*

***PATIENCE KORRESP travaille pour vous !!!!***

*Avant d'afficher les graphiques du catalogue graphique IML, les 5 autres fichiers permanents sont créés.*

***LA SESSION KORRESP EST TERMINEE***

## VII - LES ALGORITHMES KACM, KACM1, KACM2 ET KDISJ

### Algorithmes KACM(j) (j=1,2) et KDISJ

#### Versions Kohonen de l'Analyse des Correspondances Multiples.

Il s'agit d'une analyse des relations entre plusieurs variables qualitatives. cf. la références de M.Cottrell et S.Ibbou, de l'ESANN'95 pour KACM(j=1,2) et celle de M.Cottrell et P.Letrémy de l'ESANN'2003 pour KDISJ.

Pour illustrer le déroulement d'une session, nous utiliserons les données de BREFORT,1982 (cité dans l'ouvrage de G. SAPORTA "Probabilités, analyse des données et statistique").

On dispose pour 27 races de chiens de 7 variables qualitatives :

1. TAILLE dont les 3 modalités sont : taille1, taille2 et taille3
2. POIDS dont les 3 modalités sont : poids1, poids2 et poids3
3. VELOCITE dont les 3 modalités sont : veloce1, veloce2 et veloce3
4. INTELLIG(ence) dont les 3 modalités sont : malin1, malin2 et malin3
5. AFFECTIO(n) dont les 2 modalités sont : affec1 et affec2
6. AGRESSIV(ité) dont les 2 modalités sont : agres1 et agres2
7. FONCTION dont les 3 modalités sont : chasse, compagnie et garde (soit, au total, 19 modalités différentes).

Ces données sont dans la table sas CHIENS qui est placée dans le répertoire 'c:\k8\aboul, et dont l'allure est la suivante:

RACE	TAILLE	POIDS	VELOCITE	INTELLIG	AFFECTIO	AGRESSIV	FONCTION
BEAUCERON	taille3	poids2	veloce3	malin3	affec2	agres2	garde
.....							

Notons que le programme DTAIL.sas appliqué à la table CHIENS produit le tableau disjonctif complet (CHIEN\_DJ.sas7bdat) et la table de burt (CHIEN\_BT.sas7bdat)

### DEBUT DE LA SESSION KACM(j=1,2) ou KDISJ

Charger et soumettre dans SAS : DKACM.sas qui se situe dans c:\k8.

Toute la suite est CONVERSATIONNELLE, des fenêtres s'ouvrent et guident l'utilisateur dans ses choix. Pour toutes les fenêtres, les choix retenus seront validés par F3.

Fenêtre n°1 : "CHEMIN".

L'utilisateur précise le chemin d'accès aux données (par défaut c:\k8\aboul).

Exemple : path: C:\K8\ABOUL suivi de F3.

Dans le cas où le répertoire proposé est vide ou inexistant, un message d'erreur apparaît dans la fenêtre LOG, la commande WINDOW permet le passage de la fenêtre CHEMIN à celle du LOG.

Fenêtre n°2 : "CHOIXDAT".

A partir des tables sas situées dans le répertoire choisi dans "CHEMIN", l'utilisateur sélectionne (par X) la table retenue pour l'analyse.

Exemple : X CHIENS suivi de F3.

Fenêtre n°3 : "CHOIX".

En premier lieu, l'utilisateur précise la nature des données :

- Dans le cas où la table sas correspond à un tableau de Contingence. par : C  
(cette option permet de comparer les résultats obtenus avec KORRESP)
- Dans le cas où la table sas correspond aux Réponses d'individus. par : R
- Dans le cas où la table sas correspond à un tableau Disjonctif complet. par : D
- Dans le cas où la table sas correspond à un tableau de Burt. par : B

Ensuite, l'utilisateur précise le type des observations :

- par : O si elles sont "anonymes" (valeur par défaut),  
seules les modalités seront prises en compte : **KACM**
- par : N si les observations sont "NON anonymes",  
leurs identifiants seront traitées avec les modalités : **KACM1, KACM2 ou KDISJ**

Dans les cas C (tableau de contingence) ou B (tableau de Burt), la question ne se posant pas, l'utilisateur est contraint de garder la réponse par défaut (O).

Enfin, l'utilisateur identifie la nature des variables :

- par : K
- par : X

Le choix de K est unique et il identifie une variable considérée comme étant de type caractère.

Dans les cas R (tableau de réponses) ou D (disjonctif complet), K correspond à l'identificateur des observations (individus, répondants).

Dans les cas C (contingence) ou B (Burt), K correspond à la variable qui identifie les lignes ou les modalités du tableau.

Plusieurs choix sont possibles pour X :

Dans les cas C (contingence), D (disjonctif) ou B (Burt), l'utilisateur est contraint de prendre toutes les variables restantes dans la liste.

Dans le cas R (tableau de réponses), le choix de 2 variables est l'option minimum.

Exemple :	CHOIX	R	
	CHOIX	N	
	CHOIX	VARIABLE	
	K	RACE	
	X	TAILLE	
	X	POIDS	
	X	VELOCITE	
	X	INTELLIG	
	X	AFFECTIO	
	X	AGRESSIV	
	X	FONCTION	suivi de F3.

**Si les observations sont "NON anonymes".**

La Fenêtre n°4 : "KELKACMJ".

Propose à l'utilisateur de choisir entre KACM1 (Choix : A), KACM2 (Choix : B) et KDISJ (Choix : C)



**Pour KACM1** l'apprentissage et le classement initial s'effectuent sur les individus à l'aide du tableau disjonctif complet "corrigé" puis les modalités sont présentées comme données supplémentaires à l'aide de la table de Burt "corrigée".

**Pour KACM2** l'apprentissage et le classement initial s'effectuent sur les modalités à l'aide de la table de Burt "corrigée" puis les individus sont présentés comme données supplémentaires à l'aide du tableau disjonctif "corrigé" (à l'instar de l'ACM les modalités sont classées de façon identique pour KACM et KACM2).

**Pour KDISJ** l'apprentissage et le classement s'effectuent **simultanément** sur les modalités et les individus à l'aide du tableau disjonctif complet "corrigé".

Exemple :                    choix :                    C                    suivi de F3.

Remarque: En cas de données manquantes un message apparaît dans l'OUTPUT indiquant leur nombre, leurs positions (numéros d'observations dans la table) et le programme s'arrête.

Comme pour KORRESP, si KACM traite un tableau de contingence (C), le programme calcule et affiche dans la fenêtre "OUTPUT" la statistique du khi2 et sa "p-value". Si la p-value est > 5% alors un message d'avertissement apparaît dans la fenêtre "OUTPUT" qui explique en quoi l'analyse du tableau de contingence n'est pas très pertinente mais le programme KACM continue.

Fenêtre n°5 : "STRUCTUR".

L'utilisateur choisit son type de réseau : F pour Ficelle, G pour Grille.

Exemple :                    choix :                    G                    suivi de F3.

Fenêtre n°6 : "PARAM\_FI" ou "PARAM\_GR".

Pour une Ficelle, "PARAM\_FI" demande sa taille (n) et le nombre maximum d'itérations (tmax).

Pour une GRille "PARAM\_GR" demande le nombre de lignes (m), le nombre de colonnes (n) et le nombre maximum d'itérations (tmax).

Les nu unités du réseau (nu = n pour une ficelle ou nu = m×n pour une grille) seront numérotées de 1 à nu. Par exemple si nu=12 pour la ficelle de n=12, on aura : 1 2 ..... 11 12.

Pour la grille de m = 3 et n = 4 on aura :

1 4 7 10  
2 5 8 11  
3 6 9 12

Dans "PARAM\_FI" comme dans "PARAM\_GR" deux choix supplémentaires sont offerts.

Le premier choix (O/N) permet d'initialiser le générateur de nombre au hasard.

O : le point de départ est fixe, ce qui rend les résultats reproductibles (valeur par défaut).

N: le point de départ est calé sur l'horloge de la machine, ce qui rend les résultats NON reproductibles.

Le deuxième choix (O/N) propose le calcul et la représentation éventuels de la fonction "énergie". Cette "énergie" ou "potentiel" généralise la notion de "variance intra" en l'étendant aux plus proches voisins (à zéro voisin les deux notions coïncident). En fin d'itérations, elle doit se situer sur un minimum (local).

Le choix négatif (N) est la valeur par défaut, si le nombre d'itérations est élevé (dès 1000), un choix affirmatif (O) peut s'avérer coûteux en temps de calcul, il implique l'affichage dans l'OUTPUT de la valeur finale de la variance intra ainsi que la création de 2 graphiques de nom : NRJ, NRJ1 stockés dans un catalogue graphique permanent (cf. la fenêtre n°6 : "INFORM").

Exemple :  $m = 5$   
 $n = 5$   
 $tmax = 700$   
 CHOIX : O  
 CHOIX : O suivi de F3.

Si  $q$  est le nombre total de modalités et  $r$  le nombre d'individus, on peut prendre pour une ficelle,  $n$  de l'ordre de  $q/2$  et pour une grille où  $m = n$ ,  $n$  tel que  $n \times n$  est immédiatement supérieur à  $q$ .  
 Pour  $tmax$  une valeur de l'ordre de 15 à 20 fois le nombre d'individus+le nombre de modalités

Ici  $q=19$ ,  $r=27$  donc on prend une grille  $5 \times 5$ , puisque 25 est le carré immédiatement supérieur à 19 et  $tmax = 700 > 15 \times (27+19)$ .

Fenêtre n°7 : "INFORM".

Dans cette fenêtre, l'utilisateur doit renseigner le champ Nom (fixé par défaut à `_TEMPOR_`) et décider (choix O ou N) de l'éventuel visualisation et stockage d'un graphique de type "dx-dy" (cf. : la thèse de P. DEMARTINES dont la référence est donnée dans la section III).

Le champ Nom sera utilisé pour nommer des catalogues (fichier d'extension `.sas7bcats`) et des tables sas (fichier d'extension `.sas7bdat`). Il doit comporter au moins 5 caractères; dans le cas contraire le programme complète la réponse par des X pour obtenir un champ Nom de 5 caractères.

Le choix : N est proposé par défaut; en cas de réponse positive (O), un graphique de nom `DX_DY` sera créé dans le catalogue graphique. C'est un nuage de points dans un carré de côté 1, où l'on compare les distances (normalisées à 1) théoriques entre les unités gagnantes avec les distances (normalisées à 1) euclidiennes entre les vecteurs poids associés. La situation idéale correspondant à une organisation parfaite serait celle où tous les points (représentés sur le graphique par des cercles) sont situés sur la diagonale du carré.

Exemple : Nom : D7C5G  
 choix : O suivi de F3.

Ces réponses impliquent la création de 6 tables sas et de 2 catalogues qui seront placés dans `C:\K8\ABOUL` (cf.: le champ path de la fenêtre n°1 : "CHEMIN").

Description des 6 tables sas :

1. La table `D7C5G_CL` (valeur par défaut : `_TEMP_CL`) donne, pour chaque unité gagnante, les modalités (caractéristiques des chiens) ainsi que les identifiants des individus (race des chiens) dont elle est la référence, ceci dans le cas d'un tableau de Réponses ou d'un tableau Disjonctif portant sur des individus Non anonymes (CHOIX R ou D et N dans la fenêtre n°3 : "CHOIX").
2. La table `D7C5G_WS` (valeur par défaut : `_TEMP_WS`) donne pour chaque unité (gagnante ou pas) sa position dans la grille : ligne, colonne, son effectif (zéro si l'unité n'est pas gagnante) et son "vecteur poids final" ou "vecteur représentant".
3. La table `D7C5G` (valeur par défaut : `_TEMPOR_`) donne pour chaque modalité son unité gagnante (sa classe) : `_codage_`, sa position dans la grille : ligne, colonne. Dans le prolongement des modalités (ici 19 valeurs) se place la table de BURT. Dans le cas d'un tableau de Réponses ou d'un tableau Disjonctif portant sur des individus Non anonymes, la table donne en plus, pour chaque modalité identifiant un individu son unité gagnante (sa classe) : `_codage_`, sa position dans la grille : ligne, colonne. Dans le prolongement des identifiants des individus se place le tableau disjonctif complet.
4. La table `D7C5G_IN` (valeur par défaut : `_TEMP_IN`) donne pour chaque modalité identifiant un individu son unité gagnante (sa classe) : `_codage_`, sa position dans la grille : ligne, colonne. Dans le

prolongement des identifiants des individus (ici 27 races de chiens) se place le tableau disjonctif complet **corrigé** qui sert ici d'entrée (*\_IN*) à l'algorithme *KDISJ*.

5. La table *D7C5G \_NB* (valeur par défaut : *\_TEMP\_NB*) donne, pour chaque unité de la structure (grille ou ficelle) le nombre d'individus déclarés non anonymes et le nombre de modalités ainsi que leur total.
6. La table *INFO\_D7C5G* (valeur par défaut : *INFO\_ \_TEMPOR\_*) qui renseigne sur la structure du réseau (ici *GRILLE*) et sur l'algorithme (ici *KDISJ*).

#### *Description des 2 catalogues :*

1. Le catalogue *iml D7C5G* (valeur par défaut : *\_TEMPOR\_*) contient tous les intermédiaires de calcul (matrices de poids initiaux et finaux, liste des unités gagnantes, etc.) qui seront ultérieurement utilisés dans les traitements complémentaires (cf. le paragraphe VIII).
2. Le catalogue graphique *GACMD7C5* (valeur par défaut : *GACM\_TEM*) contient 12 graphiques (au plus). Chaque graphique possède son nom et sa description qui correspond aux 40 premiers caractères de son titre.

Les 12 graphiques du catalogue graphique *GACMD6C5* :

<i>Nom</i>	<i>Description</i>
<i>CELLW</i>	<i>Individu Moyen et Représentant des 25 cellules</i>
<i>CELLW1</i>	<i>Modalité Moyenne et Représentant des 25 cellules</i>
<i>DX_DY</i>	<i>dx_dy pour les individus</i>
<i>DX_DY1</i>	<i>dx_dy pour les modalités</i>
<i>G_DIMA</i>	<i>Distances (M) avec les plus proches voisins</i>
<i>G_DIST</i>	<i>Distances (E) avec les plus proches voisins</i>
<i>G_PAVAG1</i>	<i>KDISJ : grille 5x5 et 300 itérations</i>
<i>G_PAVAGE</i>	<i>KDISJ : grille 5x5 et 300 itérations</i>
<i>LIN_GRI</i>	<i>Représentants (Poids Finaux) pour les individus</i>
<i>LIN_GRI1</i>	<i>Représentants (Poids Finaux) pour les modalités</i>
<i>NRJ</i>	<i>Variance intra étendue aux voisins pour les individus</i>
<i>NRJ1</i>	<i>Variance intra étendue aux voisins pour les modalités</i>

Les graphiques, dans le catalogue, sont classés en ordre alphabétique alors qu'à l'affichage l'ordre sera Pour une grille :

*G\_PAVAGE(1), LIN\_GRI, CELLW, LIN\_GRI1, CELLW1, G\_DIMA, G\_DIST, DX\_DY(1), NRJ(1)*

Pour une ficelle :

*F\_PAVAGE(1), LIN\_FIC, CELLW, LIN\_FIC1, CELLW1, F\_DIMA, F\_DIST, DX\_DY(1), NRJ(1)*

Les graphiques *CELLW(1)* présentent sous forme de pavage le vecteur représentant pour les individus(modalités) de l'unité du réseau (grille ou ficelle) ainsi que l'individu moyen(la modalité moyenne) dans le cas ou l'unité est gagnante (classe non vide). Il permet de contrôler la qualité de la convergence de l'algorithme.

*G\_DIMA* pour une Grille (ou *F\_DIMA* pour une Ficelle) permet d'apprécier pour chaque unité (classe) son effectif et les distances de **Mahalanobis** normalisées avec ses plus proches voisins (au plus 8 pour une grille et au plus 2 pour une ficelle). A l'exception des unités des bords, si l'unité est très proche de ses (8 ou 2) voisins, son polygone sera très proche des bords du carré.

*G\_DIST pour une Grille (ou F\_DIST pour une Ficelle) permet d'apprécier pour chaque unité (classe) son effectif et les distances euclidiennes normalisées avec ses plus proches voisins (8 pour une grille et 2 pour une ficelle). A l'exception des unités des bords, si l'unité est très proche de ses (8 ou 2) voisins, son polygone sera très proche des bords du carré.*

*G\_PAVAGE pour une Grille (ou F\_PAVAGE pour une Ficelle) donne l'illustration graphique du contenu des classes (les modalités pour KACM et les individus en plus pour KACM1, KACM2 et KDISJ) du réseau (cf. D7C5G\_CL).*

*G\_PAVAG1 pour une Grille (ou F\_PAVAG1 pour une Ficelle) donne l'illustration graphique des seules modalités.*

*LIN\_GRI pour une Grille (LIN\_FIC pour une Ficelle) est un pavage de courbes des représentants (poids finaux) pour les individus*

*LIN\_GRI1 pour une Grille (LIN\_FIC1 pour une Ficelle) est un pavage de courbes des représentants (poids finaux) pour les modalités*

*Il n'y a pas de graphique de pavage pour une ficelle de plus de 50 unités.*

***PATIENCE KACM travaille pour vous !!!!***

*Avant d'afficher les graphiques du catalogue graphique IML, les 7 autres fichiers permanents sont créés.*

***LA SESSION KACM EST TERMINEE***

## VIII - TRAITEMENTS COMPLEMENTAIRES

### A) GENERALITES CONCERNANT LES MACROS

Les 20 macros (MKLUG.sas, MKLUF1.sas, MKLUF2.sas, MSTAT.sas, MCONT.sas, MKLOBS.sas, MKOC.sas, MSCAL.sas, MSCOL.sas, MSUPP.sas, MSUPPX.sas, MGVAR.sas, MVC3D.sas, MKAMG.sas, MKAMF1.sas, MKAMF2.sas, MDIMA.sas, MDIST.sas, MFMOD.sas, MFIND.sas) sont des traitements qui peuvent être envisagés à la suite des programmes KACP, KACPX, KFAST, KBATCH, KORRESP, KACM(j=1,2) ou KDISJ.

**A chaque session**, la soumission de KOMAC.sas, situé dans C:\K8, permet de les compiler et de les stocker dans le catalogue permanent SASMACR.sas7bcat placé dans C:\K8\AKOR.

L'appel d'une macro s'obtient en soumettant l'instruction **%nom\_de\_la\_macro** dans la fenêtre PROGRAM EDITOR

exemple :      %MKLUG

Chaque macro est conversationnelle et s'ouvre sur une fenêtre où est indiqué son domaine d'application: COMPLEMENT(S) TOUT PROGRAMME signifie qu'elle est applicable aux sorties des 9 programmes KACP, KACPX, KFAST, KBATCH, KORRESP, KACM(j=1,2)) ou KDISJ.

C'est par le biais du champ " type du catalogue " que l'utilisateur précise le type de programme (gacp pour KACP, KACPX, KFAST, et KBATCH, gkor pour KORRESP et gacm pour KACM(j=1,2) et KDISJ).

Le vocable : TOUTE STRUCTURE signifie que le traitement peut s'appliquer aussi bien à une ficelle qu'à une grille.

Par exemple pour la macro MKLUG, il est indiqué dans la fenêtre " SURCLASS " :  
COMPLEMENTS TOUT PROGRAMME POUR UNE GRILLE

Suite au domaine d'application, il est donné une brève description de la nature du traitement.

Par exemple pour la macro MKLUG il est indiqué :

=>>> PAVAGE EN SUPER CLASSES (CLUSTERS)

Deux champs sont communs à toutes ces macros : " librairie " et " nom commun ".

La valeur par défaut de " librairie " est C:\K8\ABOUL, ce champ est équivalent au champ "path " de la fenêtre " CHEMIN "; il correspond au chemin d'accès des données et de certains catalogues (comme le catalogue graphique).

La valeur par défaut de " nom commun " est \_TEMPOR\_; ce champ est équivalent au champ " Nom " de la fenêtre " INFORM "; il correspond au nom utilisé pour nommer des tables sas et le catalogue graphique.

Pour abandonner l'exécution de la macro, il suffit de taper O dans le champ " STOP ".

En bas de la fenêtre de chaque macro il est stipulé que la touche F3 valide les choix et qu'en cas de problèmes de cohérence dans la saisie des réponses, l'utilisateur reste dans la fenêtre de la macro avec les réponses par défaut, il doit consulter les messages d'erreurs de la fenêtre LOG avant de reprendre la saisie dans la fenêtre de la macro.

## **B) DESCRIPTION ET EXEMPLE D'APPLICATION POUR CHAQUE MACRO**

**MKLUG :** (fenêtre " SURCLASS ", domaine : *tout programme pour une grille* ).

*Création de Super-Classes via une Classification Ascendante Hiérarchique (cf. PROC CLUSTER avec la méthode de Ward) appliquée aux vecteurs poids finaux (représentants) des unités de la grille.*

*Dans le cas de KORRESP, KACM, KACM1, KACM2 et KDISJ on tient compte dans la CAH des effectifs dans les unités de la grille et on adjoint aux représentants leurs coordonnées dans la grille.*

*Cette macro produit au plus 7 graphiques rajoutés au catalogue graphique déjà existant (cf.: le champ "nom commun ") et une table sas placée dans le répertoire des données (cf.: le champ "librairie").*

*Description des 7 graphiques :*

*Le graphique nommé TREE, qui représente le dendrogramme associé à la classification hiérarchique ascendante, est précédé de l'historique de la classification qui apparaît dans la fenêtre OUTPUT et permet de confirmer a posteriori le choix du nombre de super-classes.*

*Le graphique nommé CLUSPAV représente la grille, où dans chaque unité figure le vecteur poids final (le représentant) avec le numéro de son cluster*

*Les 5 autres graphiques nommés : CLUSCOUL, CLUSCOLH, CLUSCOL1, CLUSDIMA et CLUSDIST ne seront produits que dans la mesure où l'utilisateur a choisi (cf. le champ " nombre de super-classes " de la fenêtre " SURCLASS ") un nombre de clusters qui ne dépasse pas 22, qui est le nombre de couleurs disponibles (cf. le programme KOLCLUS.sas dans C:\K8).*

*Le graphique nommé CLUSCOUL est la version couleur de CLUSPAV .*

*Dans les graphique nommés CLUSCOLT et (ou) CLUSCOL1, figurent les "valeurs" associées aux unités de la grille ainsi que les couleurs des clusters.*

*Par "valeurs" on entend :*

- *les individus pour KACP, KACPX, KFAST ou KBATCH*
- *les modalités pour KORRESP et KACM*
- *les modalités et les individus pour KACM1, KACM2 et KDISJ*

*Ainsi, pour KACM1, KACM2 et KDISJ, nous aurons deux graphiques du même type (CLUSCOLH et CLUSCOL1) le premier dédié aux seules modalités et le second comprenant modalités et individus.*

*Dans le graphique nommé CLUSDIMA, on colorie le graphique G\_DIMA avec les couleurs associées aux clusters (super-classes).*

*Dans le graphique nommé CLUSDIST, on colorie le graphique G\_DIST avec les couleurs associées aux clusters (super-classes).*

*La table sas nommée CLUSTn (où n correspond au nombre de clusters retenu par l'utilisateur) donne, pour chaque unité de la grille, son numéro de cluster ainsi que son vecteur poids final. Cette table sas sera utilisée par les macros MSTAT, MCONT, MKLOBS, MKOC, MSCOL, MVC3D, MKAMG, MFINd et MFMOD, qui effectuent des représentations graphiques ou des calculs impliquant les clusters.*

*Exemple :*

<i>librairie :</i>	<i>C:\K8\ABOUL</i>	
<i>nom commun :</i>	<i>B8G3CPAY</i>	
<i>type du catalogue :</i>	<i>GACP</i>	
<i>nombre de super-classes :</i>	<i>5</i>	<i>suivi de F3</i>

*Ces réponses impliquent la création du fichier C:\K8\ABOUL\CLUST5.sas7bdat, et portent à 13 le nombre de graphiques du catalogue graphique GACPB8G3.sas7bcat placé dans C:\K8\ABOUL.*

**MKLUF1 :** (fenêtre “ SURFIC10 ”, domaine : **tout programme pour une ficelle (<=10)**).

**MKLUF2 :** (fenêtre “ SURFICEL ”, domaine : **tout programme pour une ficelle (>10 et <=50)** ).

*Ces deux macros effectuent sur une **ficelle** un traitement qui est équivalent à celui de MKLUG pour une grille.*

*Dans le cas de KORRESP, KACM, KACM1, KACM2 et KDISJ on tient compte dans la CAH des effectifs dans les unités de la ficelle et on adjoint aux représentants leurs positions dans la ficelle.*

*Les graphiques :*

*CLUSPAV, CLUSCOUL, CLUSTCOLH, CLUSTCOLI, CLUSDIMA, CLUSDIST.*

*Deviennent respectivement :*

*Pour MKLUF1:*

*CLUFPA10, CLUFCO10, CLUFCT10, CLUFCT11, CLUFDMA10, CLUFDE10.*

*Pour MKLUF2:*

*CLUFPAV, CLUFCOUL, CLUFCTXT, CLUFCTX1, CLUFDMAH, CLUFDEUC.*

*La table sas nommé CLUSFn (l'équivalent de la table CLUSTn) donne pour chaque unité de la ficelle son numéro de cluster ainsi que son vecteur poids final. Cette table sera utilisée par les macros MSTAT, MCONT, MKLOBS, MKOC, MSCOL, MVC3D, MKAMFj (j=1,2), MFINd et MFMOD qui effectuent des représentations graphiques ou des calculs impliquant les clusters.*

**MSTAT :** (fenêtre “ STATCLUS ”, domaine : **KACP, KACPX, KFAST, KBATCH** et toute structure ).

Cette macro doit faire suite à MKLUG ou MKLUFj (j=1,2), elle considère les super-classes (la variable cluster) comme une variable de classification et affiche dans la fenêtre OUTPUT les moyennes conditionnelles des variables brutes (cf. la sélection de la fenêtre “ CHOIXVAR ” dans KACP(X), KFAST, KBATCH).

Pour chaque variable figure dans L’OUTPUT la décomposition de la variance, la statistique de Fisher et la P-value associée. Enfin, y apparaissent les tests multidimensionnels de Wilks et Hotelling avec leur valeur approchée en terme de khi-deux ainsi que leur p-value.

La macro MSTAT produit 4 tables sas qui sont placées dans le répertoire des données (cf.: le champ “librairie”).

La table B8G3\_MOY (valeur par défaut : \_TEM\_MOY) où sont stockées les moyennes conditionnelles de la fenêtre OUTPUT.

La table B8G3\_ANO (valeur par défaut : \_TEM\_ANO) où sont stockées les décompositions de la variance de la fenêtre OUTPUT.

La table B8G3\_MAN (valeur par défaut : \_TEM\_MAN) où sont stockés les tests multidimensionnels de la fenêtre OUTPUT

Enfin dans le cas d'une Grille (respectivement d'une Ficelle) la table sas nommée CLASGn (respectivement CLASFn), où n correspond au nombre de clusters retenu dans MKLUG (respectivement dans MKLUFj ( j=1,2)).

La table CLASGn (respectivement CLASFn) fournit pour chaque observation (ici chaque PAYS) ses numéros de cluster et de classe (unité gagnante) ainsi que ses valeurs pour les variables brutes et les variables "éventuellement prétraitées" qui servent d'entrées à KACP, KFAST ou KBATCH.

Dans le cas de KACPX ce sont les **données complétées** qui sont prises, ainsi que le nombre et le taux de valeurs manquantes de chaque observation.

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	B8G3CPAY	
nombre de clusters :	5	suivi de F3

Outre les sorties dans la fenêtre OUTPUT, ces réponses impliquent la création de 4 fichiers: CLASG5.sas7bdat, B8G3\_MOY.sas7bdat, B8G3\_ANO.sas7bdat et B8G3\_MAN.sas7bdat, placés dans le répertoire C:\K8\ABOUL\.

A noter que, dans le cas où tous les individus seraient placés dans la même superclasse, un message s’affiche dans l’output et la macro MSTAT s’arrête.



**MCONT :** (fenêtre “ REPCLUST ”, domaine : **tout programme et toute structure**).

Cette macro doit faire suite à MKLUG ou MKLUFj (j=1,2); elle ajoute un graphique nommé REPCLU au catalogue graphique déjà existant.

Ce graphique représente sous forme de pavage les vecteurs représentants (poids finaux) des unités du réseau (grille ou ficelle) associés à un même cluster (les REPrésentants des CLUsters). Il permet d'évaluer l'homogénéité des clusters (super-classes) au niveau de ses représentants.

Si le nombre de clusters, choisi par l'utilisateur, ne dépasse pas le nombre de couleurs disponibles, le graphique REPCLU est colorié (une même couleur par contenu de cluster).

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	B8G3CPAY	
nombre de clusters :	5	suivi de F3

Ces réponses portent à 15 le nombre de graphiques du catalogue graphique GACPB8G3.sas7bcat placé dans C:\K8\ABOUL.

**MKLOBS :** (fenêtre “ OBSCLUST ”, domaine : **KACP, KACPX, KFAST, KBATCH et toute structure**).

Cette macro doit faire suite à MKLUG ou MKLUFj (j=1,2); elle ajoute un graphique nommé OBSCLU au catalogue graphique déjà existant

Ce graphique représente sous forme de pavage les valeurs (éventuellement prétraitées) des observations (individus) qui servent d'entrées à KACP, KFAST ou KBATCH et qui sont associées à un même cluster (les OBServations des CLUsters).

Dans le cas de KACPX ce sont les **données complétées** qui servent à la construction du graphique.

Ce graphique permet d'évaluer l'homogénéité des clusters (super-classes) au niveau de ses observations.

Si le nombre de clusters, choisi par l'utilisateur, ne dépasse pas le nombre de couleurs disponibles, le graphique OBSCLU est colorié (une même couleur par contenu de cluster).

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	B8G3CPAY	
nombre de clusters :	5	suivi de F3

Ces réponses portent à 16 le nombre de graphiques du catalogue graphique GACPB8G3.sas7bcat placé dans C:\K8\ABOUL.

**MKOC :** (fenêtre “ KOCs ”, domaine : **KACP, KACPX, KFAST, KBATCH et toute structure**).

Cette macro doit faire suite à MKLUG ou MKLUFj (j=1,2); elle ajoute un graphique nommé CCOL au catalogue graphique déjà existant.

Ce graphique représente sous forme de pavage les valeurs (éventuellement prétraitées) des observations (individus) qui servent d'entrées à KACP, KFAST ou KBATCH et qui sont associées à une même unité gagnante, chaque unité gagnante étant colorisée au couleur de son cluster.

Dans le cas de KACPX ce sont les **données complétées** qui servent à la construction du graphique.

Ce graphique permet d'apprécier l'homogénéité des unités gagnantes à l'intérieur d'un même cluster. Si le nombre de clusters, choisi par l'utilisateur, dépasse le nombre de couleurs disponibles, le graphique CCOL n'est pas produit.

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	B8G3CPAY	
nombre de clusters :	5	suivi de F3

Ces réponses portent à 18 le nombre de graphiques du catalogue graphique GACPB8G3.sas7bcat placé dans C:\K8\ABOUL.

**MSCAL :** (fenêtre “ ESCALING ”, domaine : **tout programme et toute structure**).

L'utilisation de la technique Multi Dimensional Scaling (cf. PROC MDS qui fournit une représentation graphique des unités du réseau (grille ou ficelle) à partir des distances **euclidiennes** entre les différents représentants (poids finaux) de ces unités, permet de valider la structure du réseau a posteriori.

Cette macro produit un graphique nommé ESCALING qui est rajouté au catalogue graphique déjà existant et une table sas nommée par défaut \_TEMP\_DE.sas7bdat qui est placée dans le répertoire des données. Cette table sas fournit les distances euclidiennes entre les vecteurs poids finaux des unités du réseau.

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	B8G3CPAY	
type du catalogue :	GACP	suivi de F3

Ces réponses impliquent la création du fichier C:\K8\ABOUL\B8G3C\_DE.sas7bdat, et portent à 19 le nombre de graphiques du catalogue graphique GACPB8G3.sas7bcat placé dans C:\K8\ABOUL.

**MSCOL :** (fenêtre “ ESCALCLU ”, domaine : **tout programme et toute structure**).

Cette macro doit faire suite à MKLUG ou MKLUFj (j=1,2); elle effectue le même traitement que la macro MSCAL en ajoutant à chaque unité la couleur associée à son cluster.

Cette macro produit un graphique nommé ESCALCLU (version couleur de ESCALING) qui est rajouté au catalogue graphique déjà existant et une table sas nommée par défaut \_TEMP\_DE.sas7bdat qui est placée dans le répertoire des données.

Cette table sas fournit les distances euclidiennes entre les vecteurs poids finaux des unités du réseau.

Si le nombre de clusters dépasse 22 il faut utiliser la macro MSCAL.

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	B8G3CPAY	
type du catalogue :	GACP	
nombre de clusters :	5	suivi de F3

Ces réponses portent à 20 le nombre de graphiques du catalogue graphique GACPB8G3.sas7bcat placé dans C:\K8\ABOUL.

**MSUPP :** (fenêtre “ EN\_PLUS ”, domaine : **KACP, KFAST, KBATCH et toute structure**).

Cette macro effectue le traitement des données (observations) supplémentaires (avec éventuellement des valeurs manquantes).

Elle produit 2 graphiques nommés G\_PAVAG1 et G\_PAVAG2 ou F\_PAVAG1 et F\_PAVAG2 (selon que le réseau est une grille ou une ficelle) qui sont rajoutés au catalogue graphique déjà existant.

Le graphique G\_PAVAG1 pour une grille (ou F\_PAVAG1 pour une ficelle) représente la position des données (individus) supplémentaires sur le réseau.

Le graphique G\_PAVAG2 pour une grille (ou F\_PAVAG2 pour une ficelle) représente la position des données supplémentaires (écrites en italique rouge) sur le réseau, ainsi que celles des données d'apprentissage (d'origine) écrites en bleu.

Elle produit aussi deux tables sas, le nom de la première table est construit à partir du nom de la table contenant les données supplémentaires suivies de "\_SG" ou "\_SF" (selon que le réseau est une grille ou une ficelle), pour la deuxième table son nom est aussi construit à partir du nom de la table des données supplémentaires suivies de "\_PROBG" ou "\_PROBF" (selon que le réseau est une grille ou une ficelle). Ces deux tables sont placées dans le répertoire des données

La table dont le nom se termine par de "\_SG" ou "\_SF" donne pour chaque modalité de la variable qui identifie les données (observations) supplémentaires son numéro d'unité gagnante (sa classe), sa position dans le réseau et ses valeurs (éventuellement manquantes) pour les variables éventuellement transformées par le traitement initial.

La table dont le nom se termine par de "\_PROBG" ou "\_PROBF" donne pour chaque modalité de la variable qui identifie les données (observations) supplémentaires son numéro d'unité gagnante, son

« résidu », sa probabilité d'appartenir à l'unité gagnante, ainsi que les probabilités d'appartenir aux autres unités du réseau.

Elle produit enfin un catalogue iml des résultats intermédiaires de même nom que celui de la première table sas précédemment créée.

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	B8G3CPAY	suivi de F3

Suite à cette soumission, s'ouvre la fenêtre " WHAT\_NEW " qui permet de sélectionner la table qui contient les données supplémentaires.

Exemple :	CHOIX	Nom de la Table	
	X	BLAYO3	suivi de F3.

Puis s'ouvre la fenêtre " QUEL\_VAR " qui permet la sélection par C de la variable qui identifie les observations supplémentaires et par N des variables numériques déjà retenues dans l'analyse.

Exemple :	CHOIX	VARIABLE	
	C	PAYS	
	N	ANCRX	
	N	TXMORT	
	N	TXANAL	
	N	SCOL2	
	N	PIBH	
	N	CRXPIB	suivi de F3.

Ces réponses impliquent la création des tables sas BLAYO3\_SG.sas7bdat et BLAYO3\_PROBG.sas7bdat ainsi que du catalogue iml BLAYO3\_SG.sas7bcat et portent à 22 le nombre de graphiques du catalogue graphique GACPB8G3.sas7bcat placé dans C:\K8\ABOUL.

**MSUPPX :** (fenêtre " ENPLUX ", domaine : **KACPX pour toute structure**).  
C'est la version de la macro MSUPP pour KACPX.

**MGVAR :** (fenêtre " GRAF\_VAR ", domaine : **tout programme et toute structure**).

Représentations graphiques (profils) des variables ou des modalités (mais pas des individus) à travers la structure du réseau (grille ou ficelle).

Pour éviter d'alourdir le contenu du catalogue graphique déjà existant, cette macro crée son propre catalogue graphique (par défaut GVAR\_TEM.sas7bcat) qui est placé dans le répertoire des données et contient un nombre total de graphiques égal à deux fois le nombre de variables (ou de modalités) retenues dans l'étude.

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	B8G3CPAY	suivi de F3

Ces réponses impliquent la création du catalogue graphique GVARB8G3.sas7bcat placé dans C:\K8\ABOUL; ce nouveau catalogue graphique contient  $2 \times 6 = 12$  graphiques.

**MVC3D :** (fenêtre “ G3DVACLU ”, domaine : **tout programme et toute structure**).

Cette macro doit faire suite à MKLUG ou MKLUFj (j=1,2). Comme la macro MGVAR, elle présente l'influence des variables ou des modalités (mais pas des individus) à travers le réseau (grille ou ficelle), mais en plus, elle tient compte de la répartition en super-classes (clusters) en faisant apparaître les couleurs des différents clusters.

Si le nombre de clusters dépasse 22 il faut utiliser la macro MGVAR.

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	B8G3CPAY	
nombre de clusters :	5	suivi de F3

Ces réponses rajoutent 6 graphiques au catalogue graphique GVARB8G3.sas7bcat placé dans C:\K8\ABOUL et portent à 18 son nombre total de graphiques.

**MKAMG :** (fenêtre “ CAMGRID ”, domaine : **KACP, KACPX, KFAST, KBATCH pour une grille** ).

Il s'agit d'une méthode qui permet de croiser une variable qualitative avec les variables quantitatives utilisées dans le cadre de KACP, KACPX, KFAST ou KBATCH (cf. la thèse P. ROUSSET dont la référence est donnée dans la section III).

Cette macro doit faire suite à MKLUG, elle produit au plus 4 graphiques rajoutés au catalogue graphique déjà existant.

Description et chronologie des 4 graphiques :

Le graphique nommé CLUSPAC représente sur la grille, pour chaque unité gagnante, la répartition sous forme sectorielle (camembert) des modalités d'une variable qualitative .

Suit le graphique nommé CLUSCAM; ici on colorie CLUSPAC en remplaçant les valeurs numériques (modalités) de la variable qualitative par des couleurs.

Puis vient le graphique nommé CANCLU qui produit un camembert de la variable qualitative pour chaque cluster.

Arrive enfin, le graphique nommé CAMCLU; là encore on colorie le graphique précédent (CANCLU).

Les graphiques, en couleurs, nommés *CLUSCAM* et *CAMCLU* ne seront produits que dans la mesure où le nombre de modalités de la variable qualitative et le nombre de clusters ne dépassent pas respectivement 13 et 22 (cf. : les programmes *KOLCLUS.sas* et *KOLCAM.sas* dans C:\K8).

Dans le cas où la variable qualitative n'est pas numérique, le programme la recode et affiche dans la fenêtre *OUTPUT* le tableau de conversion.

La table temporaire *sas WORK.GG* fournit, pour chaque observation, son unité gagnante (variable *\_codage\_*), sa super-classe (variable *cluster*) et la valeur de la variable qualitative (variable *var\_qual*).

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	B8G3CPAY	
nombre de clusters :	5	suivi de F3

Suite à cette soumission, s'ouvre la fenêtre "*QUELDSN*" qui permet de sélectionner la table qui contient la variable qualitative.

Exemple :	CHOIX	Nom de la Table	
	X	BLAYO2	suivi de F3.

Puis, s'ouvre la fenêtre "*QUEL\_VAR*" qui permet la sélection par **V** de la variable qualitative et par **O** de la variable qui identifie les observations.

Exemple :	CHOIX	VARIABLE	
	O	PAYS	
	V	IDH	suivi de F3.

IDH correspond à 6 niveaux (codés de 1 à 6) de l'Indice du Développement Humain.

Ces réponses portent à 26 le nombre de graphiques du catalogue graphique *GACPB8G3.sas7bcat* placé dans C:\K8\ABOUL.

**MKAMF1 :** (fenêtre "*CAMFIC10*", domaine : **KACP(X)**, **KFAST**, **KBATCH** pour une ficelle (<=10).

**MKAMF2 :** (fenêtre "*CAMFICEL*", domaine : **KACP(X)**, **KFAST**, **KBATCH** pour une ficelle ]10,50].

Ces deux macros doivent faire suite à *MKLUFj* (j=1,2). Elles réalisent sur une **ficelle** un traitement qui est équivalent à celui de *MKAMG* pour une grille.

Les graphiques *CLUSPAC*, *CLUSCAM*, *CANCLU* et *CAMCLU* deviennent respectivement :

Pour <i>MKAMF1</i> :	<i>CANBF110</i> , <i>CACOF110</i> , <i>CANCLU</i> et <i>CAMCLU</i>
Pour <i>MKAMF2</i> :	<i>CANBFIC</i> , <i>CACOLFIC</i> , <i>CANCLU</i> et <i>CAMCLU</i>

La table temporaire *sas WORK.GG* (pour *MKAMG*) devient la table temporaire *WORK.F1* (pour *MKAMF1*) et la table temporaire *WORK.F2* (pour *MKAMF2*).

**MDIMA :**(fenêtre “ DIMAWS ”, domaine : **tout programme et toute structure**).

Cette macro produit une table sas nommée par défaut *\_TEMP\_DM.sas7bdat* qui est placée dans le répertoire des données.

Elle fournit les distances de Mahalanobis entre tous les vecteurs poids finaux des unités du réseau (grille ou ficelle).

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	B8G3CPAY	
type du catalogue :	GACP	suivi de F3

Ces réponses impliquent la création du fichier C:\K8\ABOUL\B8G3C\_DM.sas7bdat

**MDIST :** (fenêtre “ DISTWS ”, domaine : **tout programme et toute structure**).

Cette macro produit une table sas nommée par défaut *\_TEMP\_DE.sas7bdat* qui est placée dans le répertoire des données.

Elle fournit les distances euclidiennes entre tous les vecteurs représentants (poids finaux) des unités du réseau (grille ou ficelle).

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	D7C5G	suivi de F3

Ces réponses impliquent la création du fichier C:\K8\ABOUL\D7C5G\_DE.sas7Bdat.

**MFMOD :** (fenêtre "FILEMOD", domaine : **KORRESP, KACM(j=1,2), KDISJ pour toute structure**).

Cette macro doit faire suite à *MKLUG* ou *MKLUFj* (j=1,2); elle produit deux tables sas nommées *MODALn.sas7bdat* et *MODALTRIn.sas7bdat* où *n* correspond au nombre de clusters retenu dans *MKLUG* ou dans *MKLUFj* (j=1,2). Ces fichiers seront placés dans le répertoire des données.

La table *MODALn* fournit pour chaque modalité (variable *idobs*) son numéro de super-classes (variable *cluster*) et son unité gagnante (variable *\_codage\_*) et sa position (variables: ligne, colonne) si le réseau est une grille.

La table *MODALTRIn* est la version triée sur la clef=cluster de la précédente table.

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	D7C5G	
type du catalogue :	GACM	
nombre de clusters :	5	suivi de F3

Ces réponses impliquent la création des fichiers *MODAL5.sas7bdat* et *MODALTRI5.sas7bdat* dans le répertoire C:\K8\ABOUL.

**MFIND :** (fenêtre “ FICKACMj ”, domaine : **KACMj** (j=1,2), **KDISJ** pour toute structure.

Cette macro doit faire suite à **MKLUG** ou **MKLUFj** (j=1,2), elle produit une table sas nommée **INDIVn.sas7bdat** où n correspond au nombre de clusters retenu dans **MKLUG** ou dans **MKLUFj** (j=1,2).

La table **INDIVn**, placée dans le répertoire des données, ne sera créée que si les individus ont été déclarés non anonymes (**KACMj** pour j=1,2 ou **KDISJ**); elle fournit pour chaque individu (variable **idobs**) son numéro de super-classes (variable **cluster**), son unité gagnante (variable **\_codage\_**) et ses modalités de réponses (les autres variables de la table).

Supposons que l'on ait soumis au préalable la macro **MKLUG** avec les renseignements suivants :

librairie : C:\K8\ABOUL  
nom commun : D7C5G  
type du catalogue : GACM  
nombre de super-classes : 5.

Exemple :

librairie :	C:\K8\ABOUL	
nom commun :	D7C5G	
nombre de clusters :	5	suivi de F3

Suite à cette soumission, s'ouvre la fenêtre "CHOIXREP" qui permet de sélectionner le nom de la table qui contient les réponses des individus aux questions posées.

Exemple :	CHOIX	Nom de la Table	
	X	CHIENS	suivi de F3.

Puis, s'ouvre la fenêtre “ CHOIXQST ” qui permet de sélectionner par **I** la variable identifiant les individus et **Q** les variables qui correspondent aux questions posées.

Exemple :

CHOIX	QUESTION	
I	RACE	
Q	TAILLE	
Q	POIDS	
Q	VELOCITE	
Q	INTELLIG	
Q	AFFECTIO	
Q	AGRESSIV	
Q	FONCTION	suivi de F3.

Ces réponses impliquent la création du fichier **INDIV5.sas7bdat** dans le répertoire **C:\K8\ABOUL**.