

Traitement statistique des données

Examen

Durée : **2 heures**

Sujet à traiter **avec** documents

On considère le tableau de données noté \mathcal{C} , se trouvant en annexe, concernant 16 années sur lesquelles on s'est intéressé à la qualité du vin de Bordeaux.

On considère les variables X_1 , somme des températures moyennes journalières de l'année et X_3 , nombre de jours de grande chaleur. Les variables étudiées sont des mesures météorologiques dans la région.

- X_1 : somme des températures moyennes journalières de l'année
- X_2 : ensoleillement en heures
- X_3 : nombre de jours de grande chaleur
- X_4 : hauteur de pluies en mm

- A - Analyse des données

1. (a) Déterminer les coefficients de la régression linéaires de X_3 par rapport à X_1 .
 (b) Représenter la droite de régression sur la figure 1.
 (c) Peut-on considérer que le nombre de jours de grande chaleur dépend linéairement de températures journalières ? .
2. On a effectué une Analyse en Composantes Principales (ACP) sur les données normalisées, dont les résultats sont rassemblés à la suite des questions.
Commenter les résultats de L'ACP.

- B - Classification

Dans la suite on travaille sur les données normalisées dans le plan principal. Les coordonnées des points se trouvent en annexe.

1. On considère une classification en 3 classes par la méthode des kmeans en 2 phases :
phase1 : algorithme des centres mobiles
phase2 : algorithme de transfert
 A l'issue de l'étape m l'algorithme est toujours dans la phase 1 et la classification suivante est obtenue :
 $L_m = [2 \ 2 \ 2 \ 3 \ 2 \ 3 \ 2 \ 3 \ 2 \ 1 \ 3 \ 2 \ 3 \ 2 \ 2 \ 2]$
 Les éléments concernant cette partition sont donnés en annexe.
 A l'issue de l'algorithme on obtient la classification suivante :
 $L_{final} = [2 \ 2 \ 2 \ 3 \ 2 \ 3 \ 2 \ 1 \ 2 \ 1 \ 3 \ 2 \ 3 \ 2 \ 2 \ 2]$

- (a) *Décrire la fin de l'algorithme.*
 - (b) *Calculer la valeur finale du critère de la somme des inerties.*
2. Soient A et B , 2 groupements de points disjoints, on définit la distance du lien maximal entre ces 2 groupements par : $D(A, B) = \max_{x \in A, y \in B} d(A, B)$.

La hiérarchie obtenue sur les données à partir de ce critère a donné le dendrogramme incomplet représenté sur la Figure 2.

- (a) *Déterminer les autres éléments de la hiérarchie en utilisant l'algorithme des plus proches voisins réciproques sur les ensembles obtenus $(A_i)_{1 \leq i \leq 6}$, en l'initialisant sur A_6 et en détaillant les étapes qui suivent.*
- (b) *Représenter sur la Figure 2 le dendrogramme complet.*
- (c) *En déduire la classification en 3 classes obtenue.*
- (d) *La valeur du critère de la somme des inerties pour cette classe est $W = 18.92$. Que peut-on penser de la classification obtenue à la question - B - 1 ?*

- C - Discrimination

On considère maintenant la partition en 3 classes des données suivantes :

$$L_q = [3 \ 3 \ 3 \ 2 \ 2 \ 1 \ 2 \ 1 \ 3 \ 1 \ 2 \ 3 \ 2 \ 2 \ 3 \ 2].$$

Cette classification a été obtenue par dégustation en notant les vins :

1 : bonne année

2 : année moyenne

3 : année médiocre

Elle est représentée sur la Figure 3 et les caractéristiques des classes se trouvent en annexe.

1. (a) *Calculer la valeur finale du critère de la somme des inerties pour cette classification.*
 - (b) *Au vu du résultat précédent et de la figure 3 pensez-vous que les variables choisies sont discriminantes pour la qualité d'une année.*
 - (c) *Déterminer la limite des classes pour la discrimination par la distance au centre et représenter les sur la figure 3. Quel est le taux de points mal classés par cette méthode.*
2. On souhaite déterminer la classe de l'année 39 dont les coordonnées sont :
- $$An_{39} = [3022 \ 1285 \ 9 \ 303].$$
- (a) *Déterminer les coordonnées de An_{39} dans le plan principal et ajouter ce point à la figure 3.*
 - (b) *Dans quelle classe doit-on le classer par la méthode précédente ?*

Barème indicatif :

- **A** - : 6pts
- **B** - : 8pts
- **C** - : 6pts

Annexes

Données

	Année	X_1	X_2	X_3	X_4
1	40	3094	1329	11	339
2	41	3009	1210	15	536
3	42	3227	1331	21	414
4	43	3308	1368	24	282
5	44	3212	1289	17	302
6	45	3381	1444	25	253
7	46	3061	1175	12	261
8	47	3478	1317	42	259
9	48	3126	1248	11	315
10	49	3458	1508	43	286
11	50	3252	1361	26	346
12	51	3052	1186	14	443
13	52	3270	1399	24	306
14	53	3198	1299	20	367
15	54	2904	1164	6	311
16	55	3247	1277	19	375
	Moyenne	3205	1307	20.6	337
	Ecart-type	154.2	94.25	9.98	73.78

- X_1 :somme des températures moyennes journalières de l'année
- X_2 :ensoleillement en heures
- X_3 :nombre de jours de grande chaleur
- X_4 :hauteur de pluies en mm

- A - Analyse des données

Matrice de corrélation :



$$R = \begin{pmatrix} 1.0000 & 0.8319 & 0.9173 & -0.4852 \\ 0.8319 & 1.0000 & 0.7427 & -0.3973 \\ 0.9173 & 0.7427 & 1.0000 & -0.3341 \\ -0.4852 & -0.3973 & -0.3341 & 1.0000 \end{pmatrix}$$

Valeurs propres :

$$\begin{aligned} \lambda_1 &= 2.92 \\ \lambda_2 &= 0.75 \\ \lambda_3 &= 0.27 \\ \lambda_4 &= 0.06 \end{aligned}$$

Vecteurs propres :

$$U = \begin{pmatrix} -0.5682 & 0.1202 & 0.2007 & -0.7889 \\ -0.5234 & 0.1682 & -0.8120 & 0.1960 \\ -0.5334 & 0.3068 & 0.5449 & 0.5696 \\ 0.3444 & 0.9291 & -0.0589 & -0.1215 \end{pmatrix}$$



- B - Classification

Coordonnées des points dans le plan principal :

	Année	C_1	C_2		Année	C_1	C_2
1	40	0.81	-0.32	9	48	1.03	-0.74
2	41	2.49	2.01	10	49	-3.49	0.60
3	42	0.12	1.04	11	50	-0.72	0.41
4	43	-1.16	-0.40	12	51	2.08	0.79
5	44	0.10	-0.58	13	52	-1.08	-0.07
6	45	-2.04	-0.54	14	53	0.24	0.34
7	46	1.37	-1.57	15	54	2.56	-1.27
8	47	-2.57	-0.10	16	55	0.27	0.41

B - 1 : Kmeans

Partition à l'étape m $L_m = [2 \ 2 \ 2 \ 3 \ 2 \ 3 \ 2 \ 3 \ 2 \ 1 \ 3 \ 2 \ 3 \ 2 \ 2 \ 2]$

Centres de gravités à l'étape m :

$$G_1^m = (-3.49; 0.60)$$

$$G_2^m = (1.11; 0.01)$$

$$G_3^m = (-1.51; -0.14)$$

Distances aux centres des classes :

	Année	$d(M, G_1^m)$	$d(M, G_2^m)$	$d(M, G_3^m)$
1	40	4.39	0.45	2.33
2	41	6.13	2.43	4.54
3	42	3.63	1.42	2.02
4	43	2.53	2.30	0.44
5	44	3.78	1.17	1.67
6	45	1.84	3.19	0.66
7	46	5.32	1.60	3.22
8	47	1.15	3.68	1.06
9	48	4.71	0.76	2.61
10	49	0	4.63	2.11
11	50	2.77	1.87	0.96
12	51	5.57	1.25	3.72
13	52	2.50	2.18	0.44
14	53	3.74	0.93	1.82
15	54	6.33	1.94	4.23
16	55	3.76	0.92	1.87

Somme des inerties $W = 22.51$

B - 2 : Classification hiérarchique

Partition obtenue

- $A_1 = \{42 \ 53 \ 55\}$
- $A_2 = \{43 \ 50 \ 52\}$
- $A_3 = \{40 \ 44 \ 48\}$
- $A_4 = \{41 \ 51\}$
- $A_5 = \{46 \ 54\}$
- $A_6 = \{45 \ 47 \ 49\}$

Tableau des distances pour le lien maximal

A_1	3.76					
A_2	2.77	1.92				
A_3	4.70	1.99	2.21			
A_4	6.13	2.79	4.36	3.51		
A_5	6.32	3.35	3.83	2.55	3.74	
	A_6	A_1	A_2	A_3	A_4	

- C - Discrimination

Caractéristiques des classes

- $C_1 = \{45 \ 47 \ 49\}$
- $C_2 = \{43 \ 44 \ 46 \ 50 \ 52 \ 53 \ 55\}$
- $C_3 = \{40 \ 41 \ 42 \ 48 \ 51 \ 54\}$


Caractéristiques

	C_1		C_2		C_3	
Centre	-2.70	0.01	-0.14	-0.21	1.51	0.25
Inertie	0.578		1.144		2.109	

Ne pas oublier de rendre cette page et les suivantes avec la copie

NOM :

Question - A - 2 : Figure 1



NOM :
Question - B - 2 : Figure 2

Dendrogramme

