

# ANALYSE DES DONNEES (Partiel)

Master M1 MMD - MA, 13 mars 2017

Calculatrice autorisée, documents autorisés : 2 feuilles recto-verso.

Barème approximatif : 10 points pour chacun des deux exercices.

## Exercice 1

On considère deux nuages de points  $\mathcal{N}_1$  et  $\mathcal{N}_2$  dans  $\mathbb{R}^p$ ,  $p \geq 1$ , muni de la métrique identité  $I_p$ .

Le nuage  $\mathcal{N}_1$  est constitué de  $n$  individus  $(x_i)_{1 \leq i \leq n}$ , chaque individu a un poids  $p_i$  avec  $p_i > 0$  pour tout  $i$  et  $\sum_{i=1}^n p_i = 1$ .

De même le nuage  $\mathcal{N}_2$  est constitué de  $N - n$  individus  $(x_i)_{n+1 \leq i \leq N}$ , chaque individu a un poids  $q_i$  avec  $q_i > 0$  pour tout  $i$  et  $\sum_{i=n+1}^N q_i = 1$ .

Les résultats de l'ACP de  $\mathcal{N}_1$ , l'espace  $\mathbb{R}^p$  étant muni de la métrique identité  $I_p$ , sont notés comme suit :

- le  $\alpha^{\text{ème}}$  vecteur axial factoriel (pour le nuage des individus) est noté  $u_\alpha$ ,
- la  $\alpha^{\text{ème}}$  valeur propre est notée  $\lambda_\alpha$ ,
- la  $\alpha^{\text{ème}}$  composante principale du nuage des individus est notée  $\psi_\alpha$ ,

avec  $\alpha \in \{1, \dots, p\}$ .

Les résultats de l'ACP de  $\mathcal{N}_2$ , l'espace  $\mathbb{R}^p$  étant muni de la métrique identité  $I_p$ , sont notés comme suit :

- le  $\alpha^{\text{ème}}$  vecteur axial factoriel (pour le nuage des individus) est noté  $v_\alpha$ ,
- la  $\alpha^{\text{ème}}$  valeur propre est notée  $\mu_\alpha$ ,
- la  $\alpha^{\text{ème}}$  composante principale du nuage des individus est notée  $\phi_\alpha$ ,

avec  $\alpha \in \{1, \dots, p\}$ .

On note  $\mathcal{N}$  l'union des deux nuages, constitué de  $N$  individus  $(x_i)_{1 \leq i \leq N}$ , chaque individu a un poids  $r_i$  défini par

$$\forall 1 \leq i \leq N, \quad r_i = \begin{cases} p_i/2 & \text{si } 1 \leq i \leq n, \\ q_i/2 & \text{si } n+1 \leq i \leq N. \end{cases}$$

On note  $G_1$  le centre de gravité de  $\mathcal{N}_1$ ,  $G_2$  de  $\mathcal{N}_2$  et  $G$  de  $\mathcal{N}$ .

1. **0,5 point** Vérifier que  $r_i > 0$  et que  $\sum_{i=1}^N r_i = 1$ .

La vérification est immédiate.

2. **0,5 point** Comment se situe  $G$  par rapport à  $G_1$  et  $G_2$  ?

On a

$$G = \sum_{i=1}^n \frac{p_i x_i}{2} + \sum_{i=n+1}^N \frac{q_i x_i}{2} = \frac{1}{2}(G_1 + G_2).$$

Donc  $G$  est au milieu de  $(G_1, G_2)$ . 0,25 point seulement

3. **2 points** Exprimer l'inertie totale de  $\mathcal{N}$  en fonction de l'inertie totale de  $\mathcal{N}_1$  notée  $I_T(\mathcal{N}_1)$ , de  $\mathcal{N}_2$  notée  $I_T(\mathcal{N}_2)$  et de  $d(G_1, G_2)^2 = \|\overrightarrow{G_1 G_2}\|^2$ .

On a

$$\begin{aligned} I_T(\mathcal{N}) &= \sum_{i=1}^n \frac{p_i \|x_i - G\|^2}{2} + \sum_{i=n+1}^N \frac{q_i \|x_i - G\|^2}{2}, \text{ . 0,5 point} \\ &= \frac{1}{2} \left( I_T(\mathcal{N}_1) + \|G_1 - G\|^2 + \sum_{i=1}^n p_i \langle x_i - G_1, G_1 - G \rangle \right) + \\ &\quad \frac{1}{2} \left( I_T(\mathcal{N}_2) + \|G_2 - G\|^2 + \sum_{i=n+1}^N q_i \langle x_i - G_2, G_2 - G \rangle \right), \text{ . 1 point} \\ &= \frac{1}{2} I_T(\mathcal{N}_1) + \frac{1}{2} I_T(\mathcal{N}_2) + \frac{1}{4} d(G_1, G_2)^2. \text{ 0,5 point} \end{aligned}$$

4. On suppose que  $G_1 \neq G_2$  on pose

$$u = \frac{\overrightarrow{G_1 G_2}}{\|\overrightarrow{G_1 G_2}\|}.$$

On note  $V_1$ ,  $V_2$  et  $V$  les matrices de variance des nuages  $\mathcal{N}_1$ ,  $\mathcal{N}_2$  et  $\mathcal{N}$ .

(a) **3 points** Montrer que

$$V = \frac{1}{2}(V_1 + V_2) + \frac{\|\overrightarrow{G_1 G_2}\|^2}{4} uu'.$$

On a 0,5 point

$$V = \sum_{i=1}^n \frac{p_i}{2} (x_i - G)(x_i - G)' + \sum_{i=n+1}^N \frac{q_i}{2} (x_i - G)(x_i - G)',$$

Or pour tout  $1 \leq i \leq n$ , on a 0,5 point

$$\begin{aligned} (x_i - G)(x_i - G)' &= (x_i - G_1 + G_1 - G)(x_i - G_1 + G_1 - G)', \\ &= (x_i - G_1)(x_i - G_1)' + (x_i - G_1)(G_1 - G)' + \\ &\quad (G_1 - G)(x_i - G_1)' + (G_1 - G)(G_1 - G)'. \end{aligned}$$

Puisque

$$\sum_{i=1}^n p_i (x_i - G_1) = 0,$$

on en déduit que 0,5 point

$$\sum_{i=1}^n \frac{p_i}{2} (x_i - G)(x_i - G)' = \frac{1}{2}(V_1 + (G_1 - G)(G_1 - G)').$$

De même 1 point

$$\sum_{i=n+1}^N \frac{q_i}{2} (x_i - G)(x_i - G)' = \frac{1}{2}(V_2 + (G_2 - G)(G_2 - G)').$$

Par ailleurs,  $G$  étant au milieu de  $(G_1, G_2)$ , on a 0,5 point

$$(G_1 - G)(G_1 - G)' = (G_2 - G)(G_2 - G)' = \frac{\|\overrightarrow{G_1 G_2}\|^2}{4} uu'$$

Par conséquent

$$V = \frac{1}{2}(V_1 + V_2) + \frac{\|\overrightarrow{G_1 G_2}\|^2}{4} uu'.$$

**On fait l'hypothèse, dans les deux dernières questions, que pour tout  $1 \leq \alpha \leq p$ ,  $u_\alpha = v_\alpha$ .**

(b) On suppose que  $u = u_1 = v_1$

i. **1 point** Montrer que  $u$  est un axe factoriel de  $\mathcal{N}$ . Est ce le premier axe factoriel ?

On a 0,5 point

$$Vu = \left( \frac{\lambda_1 + \mu_1}{2} + \frac{\|\overrightarrow{G_1 G_2}\|^2}{4} \right) u.$$

Donc  $u$  est un vecteur propre unitaire de  $V$ , c'est un axe factoriel. Soit  $\alpha > 1$ , on a 0,5 point

$$Vu_\alpha = \frac{\lambda_\alpha + \mu_\alpha}{2} \leq \frac{\lambda_1 + \mu_1}{2} < \frac{\lambda_1 + \mu_1}{2} + \frac{\|\overrightarrow{G_1 G_2}\|^2}{4}.$$

On en déduit que  $u$  est le premier axe factoriel.

ii. **1 point** Exprimer la composante principale  $H$  associée à l'axe factoriel  $u$  en fonction de  $\psi_1$  et de  $\phi_1$ .

On obtient

$$\forall 1 \leq i \leq N, \quad H_i = \begin{cases} \phi_1 - \frac{d(G_1, G_2)}{2} & \text{si } 1 \leq i \leq n, \\ \psi_1 + \frac{d(G_1, G_2)}{2} & \text{si } n + 1 \leq i \leq N. \end{cases}$$

(c) On suppose que  $u \in \ker V_1 \cap \ker V_2$ .

i. **1 point** Montrer que  $u$  est un axe factoriel de  $\mathcal{N}$  et déterminer une condition sur  $d(G_1, G_2)$  pour que  $u$  soit le premier axe factoriel de  $\mathcal{N}$ .

On a 0,5 point

$$Vu = \frac{\|\overrightarrow{G_1 G_2}\|^2}{4} u.$$

Soit  $\alpha \geq 1$ , on a

$$Vu_\alpha = \frac{\lambda_\alpha + \mu_\alpha}{2} u_\alpha.$$

Donc 0,5 point si  $\frac{\|\overrightarrow{G_1 G_2}\|^2}{4} \geq \frac{\lambda_1 + \mu_1}{2}$ , alors  $u$  est le premier axe factoriel de  $\mathcal{N}$

ii. **1 point** Montrer que  $P_u(\mathcal{N})$ , où  $P_u$  est la projection orthogonale sur la droite passant par  $G$  de vecteur directeur  $u$ , se réduit à deux points. Calculer l'inertie totale du nuage  $P_u(\mathcal{N})$ ,

Puisque  $u \in \ker V_1$ , la projection de  $\mathcal{N}_1$  sur la droite de vecteur directeur  $u$ , se réduit au point  $G_1$ . Donc  $P_u(\mathcal{N})$  se réduit aux points  $G_1$  et  $G_2$ . 0,5 point On a 0,5 point

$$I_T(P_u(\mathcal{N})) = \frac{1}{2}(d(G, G_1)^2 + d(G, G_2)^2) = \frac{\|\overrightarrow{G_1 G_2}\|^2}{4}.$$

## Exercice 2

On considère le tableau de données, noté  $X$ , qui est défini par :

$$X = \begin{pmatrix} 2 & 1 & -1 & 3 & -3 \\ 0 & 3 & -1 & 2 & -2 \\ 1 & 2 & -1 & 1 & -1 \end{pmatrix}$$

où la  $i^{\text{ème}}$  ligne désigne l'individu  $x_i$  et la  $j^{\text{ème}}$  colonne désigne la variable  $x^j$ .

Chaque individu possède un poids égal à  $1/3$ . On considère les résultats de l'ACP du tableau  $X$  lorsque  $\mathbb{R}^5$  est muni de la métrique identité.

1. **0,5 point** Déterminer le tableau centré  $Y$ .

On a

$$Y = \begin{pmatrix} 1 & -1 & 0 & 1 & -1 \\ -1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & -1 & 1 \end{pmatrix}$$

2. **1 point** Sans calculer la matrice variance  $V$  du tableau  $X$ , combien existe-t-il d'axes factoriels non triviaux ?

Le rang de  $Y$  est 2 puisque la colonne 1 est l'opposé de la colonne 2, la colonne 4 est l'opposé de la colonne 5 et la colonne 3 est nulle. Enfin la première et la cinquième colonne ne sont pas colinéaires. Donc le rang de  $Y$  est 2 donc celui de  $V$  aussi. Il y a donc deux axes factoriels non triviaux.

3. **1 point** Calculer  $V$ . En déduire l'inertie totale du nuage étudié.

On a 0,5 point

$$V = \frac{1}{3} Y'Y = \frac{1}{3} \begin{pmatrix} 2 & -2 & 0 & 1 & -1 \\ -2 & 2 & 0 & -1 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 1 & -1 & 0 & 2 & -2 \\ -1 & 1 & 0 & -2 & 2 \end{pmatrix}$$

L'inertie totale du nuage étudié est la trace de  $V$  soit  $8/3$ . 0,5 point

4. On pose  $u = \begin{pmatrix} 1 \\ -1 \\ 0 \\ 1 \\ -1 \end{pmatrix}$ .

- (a) **0,5 point** Vérifier que  $u$  est un vecteur propre de  $V$  associé à la valeur propre 2.

On a

$$Vu = 2u.$$

- (b) **1 point** En déduire les valeurs propres de  $V$ .

Puisqu'il n'y a que deux axes factoriels non triviaux, il y a trois valeurs propres nulle, 2 et une dernière valeur propre. 0,5 point

Or la trace vaut  $8/3$  donc la dernière valeur propre est  $2/3$  1 point

(c) **2 points** Déterminer, pour chacun des axes factoriels non triviaux, l'unique vecteur axial factoriel qui le dirige et dont la première coordonnée est positive.

1 point Pour la valeur propre 2, on a  $u_1 = \frac{1}{2}u$  et pour la valeur propre 2/3, on a

$$u_2 = \frac{1}{2} \begin{pmatrix} 1 \\ -1 \\ 0 \\ -1 \\ 1 \end{pmatrix}.$$

1 point Pour obtenir  $u_2$ , on cherche un vecteur unitaire orthogonal à  $u$  ainsi qu'à une

base du noyau de  $V$  ou de  $Y$  soit  $\left( \begin{pmatrix} 1 \\ 1 \\ 0 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 0 \\ 0 \\ 1 \\ 1 \end{pmatrix} \right)$ .

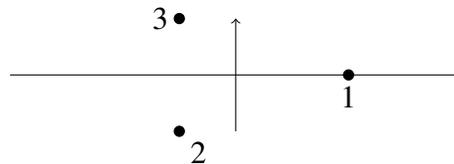
Enlever la moitié des points si oublié de normaliser.

5. **1 point** Calculer les deux premières composantes principales, notée  $\Psi_1$  et  $\Psi_2$ .

On a

$$\Psi_1 = Yu_1 = \begin{pmatrix} 2 \\ -1 \\ -1 \end{pmatrix} \text{ et } \Psi_2 = Yu_2 = \begin{pmatrix} 0 \\ -1 \\ 1 \end{pmatrix}.$$

6. **1 point** Représenter les trois individus dans le plan factoriel constitué des deux premiers axes.



7. **1 point** Calculer la contribution relative de chaque individu à l'inertie du premier axe.

La contribution de l'individu 1 à l'axe 1 est 2/3, à l'axe 2 est 0.

La contribution de l'individu 2 à l'axe 1 est 1/6, à l'axe 2 est 1/2.

La contribution de l'individu 3 à l'axe 1 est 1/6, à l'axe 2 est 1/2.

8. **1 point** Représenter les 5 variables dans le plan factoriel constitué des deux premiers axes.

