

Exploration Statistique Multidimensionnelle

Chapitre 8 : Classification non supervisée

J-M Loubes

Laboratoire de Statistique et Probabilités

Institut de Mathématiques
www.lsp.ups-tlse.fr/Fp/Loubes

Objectifs

- ▶ Matrice $\mathbf{X}(n, p)$ des observations de p variables quantitatives et/ou qualitatives sur n individus
- ▶ Tableau de **distances** (ou dissemblance) des individus
- ▶ Recherche d'une **typologie**, **segmentation** ou partition des individus en **classes** par optimisation d'un **critère**
- ▶ Discrimination **vs.** classif. *classification vs. clustering*
- ▶ La **complexité** impose l'exécution d'un **algorithme itératif**

Choix de l'utilisateur

- ▶ Mesure d'éloignement ou distance entre individus
- ▶ Critère : trace de la matrice de **variance intra**
- ▶ Méthode : classif. **hiérarchique** ou par **réallocation dynamique**

Objectifs

- ▶ Matrice $\mathbf{X}(n, p)$ des observations de p variables quantitatives et/ou qualitatives sur n individus
- ▶ Tableau de **distances** (ou dissemblance) des individus
- ▶ Recherche d'une **typologie**, **segmentation** ou partition des individus en **classes** par optimisation d'un **critère**
- ▶ Discrimination **vs.** classif. *classification vs. clustering*
- ▶ La **complexité** impose l'exécution d'un **algorithme itératif**

Choix de l'utilisateur

- ▶ Mesure d'éloignement ou distance entre individus
- ▶ Critère : trace de la matrice de **variance intra**
- ▶ Méthode : classif. **hiérarchique** ou par **réallocation dynamique**

Indice de ressemblance ou similarité

- ▶ $\Omega = \{i = 1, \dots, n\}$ ensemble des individus
- ▶ s définie de $\Omega \times \Omega$ dans \mathbb{R}_+ avec :

$$s(i, j) = s(j, i), \forall (i, j) \in \Omega \times \Omega : \text{symétrie}$$

$$s(i, i) = S > 0, \forall i \in \Omega : \text{ressemblance de } i \text{ avec lui-même}$$

$$s(i, j) \leq S, \forall (i, j) \in \Omega \times \Omega : \text{ressemblance majorée par } S$$

- ▶ Indice de ressemblance **normé** s^* est défini à partir de s par :

$$s^*(i, j) = \frac{1}{S} s(i, j), \forall (i, j) \in \Omega \times \Omega$$

s^* est une application de $\Omega \times \Omega$ dans $[0, 1]$

Indice de ressemblance ou similarité

- ▶ $\Omega = \{i = 1, \dots, n\}$ ensemble des individus
- ▶ s définie de $\Omega \times \Omega$ dans \mathbb{R}_+ avec :

$$s(i, j) = s(j, i), \forall (i, j) \in \Omega \times \Omega : \text{symétrie}$$

$$s(i, i) = S > 0, \forall i \in \Omega : \text{ressemblance de } i \text{ avec lui-même}$$

$$s(i, j) \leq S, \forall (i, j) \in \Omega \times \Omega : \text{ressemblance majorée par } S$$

- ▶ Indice de ressemblance normé s^* est défini à partir de s par :

$$s^*(i, j) = \frac{1}{S} s(i, j), \forall (i, j) \in \Omega \times \Omega$$

s^* est une application de $\Omega \times \Omega$ dans $[0, 1]$

Indice de ressemblance ou similarité

- ▶ $\Omega = \{i = 1, \dots, n\}$ ensemble des individus
- ▶ s définie de $\Omega \times \Omega$ dans \mathbb{R}_+ avec :

$$s(i, j) = s(j, i), \forall (i, j) \in \Omega \times \Omega : \text{symétrie}$$

$$s(i, i) = S > 0, \forall i \in \Omega : \text{ressemblance de } i \text{ avec lui-même}$$

$$s(i, j) \leq S, \forall (i, j) \in \Omega \times \Omega : \text{ressemblance majorée par } S$$

- ▶ Indice de ressemblance **normé** s^* est défini à partir de s par :

$$s^*(i, j) = \frac{1}{S} s(i, j), \forall (i, j) \in \Omega \times \Omega$$

s^* est une application de $\Omega \times \Omega$ dans $[0, 1]$

Indice de dissemblance ou dissimilarité

- ▶ d de $\Omega \times \Omega$ dans \mathbb{R}_+ avec :

$$d(i, j) = d(j, i), \forall (i, j) \in \Omega \times \Omega : \text{symétrie ;}$$

$$d(i, i) = 0, \forall i \in \Omega :$$

- ▶ Si s est une similarité, d est une dissimilarité

$$d(i, j) = S - s(i, j), \forall (i, j) \in \Omega \times \Omega$$

- ▶ Un indice de dissemblance **normé** est défini par :

$$d^*(i, j) = \frac{1}{D} d(i, j), \forall (i, j) \in \Omega \times \Omega$$

avec $d^* = 1 - s^*$ et $s^* = 1 - d^*$

Indice de dissemblance ou dissimilarité

- ▶ d de $\Omega \times \Omega$ dans \mathbb{R}_+ avec :

$$d(i, j) = d(j, i), \forall (i, j) \in \Omega \times \Omega : \text{symétrie ;}$$

$$d(i, i) = 0, \forall i \in \Omega :$$

- ▶ Si s est une similarité, d est une dissimilarité

$$d(i, j) = S - s(i, j), \forall (i, j) \in \Omega \times \Omega$$

- ▶ Un indice de dissemblance normé est défini par :

$$d^*(i, j) = \frac{1}{D} d(i, j), \forall (i, j) \in \Omega \times \Omega$$

avec $d^* = 1 - s^*$ et $s^* = 1 - d^*$

Indice de dissemblance ou dissimilarité

- ▶ d de $\Omega \times \Omega$ dans \mathbb{R}_+ avec :

$$d(i, j) = d(j, i), \forall (i, j) \in \Omega \times \Omega : \text{symétrie ;}$$

$$d(i, i) = 0, \forall i \in \Omega :$$

- ▶ Si s est une similarité, d est une dissimilarité

$$d(i, j) = S - s(i, j), \forall (i, j) \in \Omega \times \Omega$$

- ▶ Un indice de dissemblance **normé** est défini par :

$$d^*(i, j) = \frac{1}{D} d(i, j), \forall (i, j) \in \Omega \times \Omega$$

avec $d^* = 1 - s^*$ et $s^* = 1 - d^*$

Indice de distance

- ▶ $d(i, j) = 0 \Rightarrow i = j$
- ▶ Pour éviter des incohérences entre dissemblances

Distance

- ▶ $d(i, j) = d(j, i), \forall (i, j) \in \Omega \times \Omega$;
- ▶ $d(i, i) = 0 \Leftrightarrow i = j$;
- ▶ $d(i, j) \leq d(i, k) + d(j, k); \forall (i, j, k) \in \Omega^3$.

Si Ω est fini, la distance peut être normée

Distance euclidienne

- ▶ Si Ω est muni d'un produit scalaire :
 $d(i, j) = [\langle i - j, i - j \rangle]^{1/2} = \|i - j\|$

Indice de distance

- ▶ $d(i, j) = 0 \Rightarrow i = j$
- ▶ Pour éviter des incohérences entre dissemblances

Distance

- ▶ $d(i, j) = d(j, i), \forall (i, j) \in \Omega \times \Omega$;
- ▶ $d(i, i) = 0 \Leftrightarrow i = j$;
- ▶ $d(i, j) \leq d(i, k) + d(j, k); \forall (i, j, k) \in \Omega^3$.

Si Ω est fini, la distance peut être **normée**

Distance euclidienne

- ▶ Si Ω est muni d'un produit scalaire :
 $d(i, j) = [\langle i - j, i - j \rangle]^{1/2} = \|i - j\|$

Indice de distance

- ▶ $d(i, j) = 0 \Rightarrow i = j$
- ▶ Pour éviter des incohérences entre dissemblances

Distance

- ▶ $d(i, j) = d(j, i), \forall (i, j) \in \Omega \times \Omega$;
- ▶ $d(i, i) = 0 \Leftrightarrow i = j$;
- ▶ $d(i, j) \leq d(i, k) + d(j, k); \forall (i, j, k) \in \Omega^3$.

Si Ω est fini, la distance peut être **normée**

Distance euclidienne

- ▶ Si Ω est muni d'un produit scalaire :
$$d(i, j) = [\langle i - j, i - j \rangle]^{1/2} = \|i - j\|$$

Données quantitatives

- ▶ p variables toutes quantitatives,
- ▶ matrice de produit scalaire sur l'espace \mathbb{R}^p ; $\mathbf{M} = \mathbf{I}_p$
- ▶ réduire les variables de variances hétérogènes : $\mathbf{M} = \Sigma^{-1}$
- ▶ Mahalanobis pour atténuer la structure de corrélation.

Données quantitatives

- ▶ p variables toutes quantitatives,
- ▶ matrice de **produit scalaire** sur l'espace \mathbb{R}^P ; $\mathbf{M} = \mathbf{I}_p$
- ▶ réduire les variables de variances hétérogènes : $\mathbf{M} = \Sigma^{-1}$
- ▶ Mahalanobis pour atténuer la structure de corrélation.

Données quantitatives

- ▶ p variables toutes quantitatives,
- ▶ matrice de **produit scalaire** sur l'espace \mathbb{R}^P ; $\mathbf{M} = \mathbf{I}_p$
- ▶ **réduire** les variables de variances hétérogènes : $\mathbf{M} = \Sigma^{-1}$
- ▶ Mahalanobis pour atténuer la structure de corrélation.

Données quantitatives

- ▶ p variables toutes quantitatives,
- ▶ matrice de **produit scalaire** sur l'espace \mathbb{R}^P ; $\mathbf{M} = \mathbf{I}_p$
- ▶ **réduire** les variables de variances hétérogènes : $\mathbf{M} = \Sigma^{-1}$
- ▶ **Mahalanobis** pour atténuer la structure de corrélation.

Variables binaires

► Notations

- a_{ij} = nombre de caractères communs à i et j sur les p considérés
- b_{ij} = nombre de caractères possédés par i mais pas par j
- c_{ij} = nombre de caractères possédés par j mais pas par i
- d_{ij} = nombre de caractères que ne possèdent ni i ni j
- avec bien sûr, $a_{ij} + b_{ij} + c_{ij} + d_{ij} = p$

► Indices :

- Concordance : $\frac{a_{ij} + d_{ij}}{p}$
- Jaccard : $\frac{a_{ij}}{a_{ij} + b_{ij} + c_{ij}}$
- Dice : $\frac{2a_{ij}}{2a_{ij} + b_{ij} + c_{ij}}$

Variables qualitatives

Distance euclidienne du χ^2 entre profils-lignes du tableau disjonctif complet

$$d_{\chi^2}^2 = \frac{n}{p} \sum_{j=1}^p \sum_{\ell=1}^{m_j} \delta_{ik}^{j\ell} \frac{1}{n_{\ell}^j}$$

- ▶ m_j : nombre de modalités de la variable qualitative Y^j
- ▶ n_{ℓ}^j : effectif de la ℓ ème modalité de Y^j
- ▶ $\delta_{ik}^{j\ell} = 1$ si les individus i et k présentent une discordance pour la ℓ ème modalité de la variables Y^j et 0 sinon

Mélange quantitatif, qualitatif

- ▶ Rendre tout qualitatif : métrique du χ^2
- ▶ Rendre tout quantitatif à l'aide d'une AFCM

Résumé

i2i

- ▶ soit un **tableau de mesures** $n \times p$ associé à un **produit scalaire** $p \times p$ (en général \mathbf{I}_p)
- ▶ soit un tableau $n \times n$ de **dissemblances** ou **distances** entre individus
- ▶ **Attention**, si n grand, problèmes de stockage d'un tableau $n \times n$

Mélange quantitatif, qualitatif

- ▶ Rendre tout qualitatif : métrique du χ^2
- ▶ Rendre tout quantitatif à l'aide d'une AFCM

Résumé

i2i

- ▶ soit un **tableau de mesures** $n \times p$ associé à un **produit scalaire** $p \times p$ (en général \mathbf{I}_p)
- ▶ soit un tableau $n \times n$ de **dissemblances** ou **distances** entre individus
- ▶ **Attention**, si n grand, problèmes de stockage d'un tableau $n \times n$

Mélange quantitatif, qualitatif

- ▶ Rendre tout qualitatif : métrique du χ^2
- ▶ Rendre tout quantitatif à l'aide d'une AFCM

Résumé

i2i

- ▶ soit un **tableau de mesures** $n \times p$ associé à un **produit scalaire** $p \times p$ (en général \mathbf{I}_p)
- ▶ soit un tableau $n \times n$ de **dissemblances** ou **distances** entre individus
- ▶ **Attention**, si n grand, problèmes de stockage d'un tableau $n \times n$

CAH : Objectif

- ▶ **Agglomération** itérative de 2 éléments de la partition
- ▶ Construction d'un **dendrogramme** ou arbre binaire
- ▶ **Problème** : définir $d(A, B)$ A et B deux groupes ou éléments d'une partition à partir de
 - ▶ w_A et w_B leurs pondérations
 - ▶ $d_{i,j}$ la dissemblance ou distance entre deux individus

CAH : Objectif

- ▶ **Agglomération** itérative de 2 éléments de la partition
- ▶ Construction d'un **dendrogramme** ou arbre binaire
- ▶ **Problème** : définir $d(A, B)$ A et B deux groupes ou éléments d'une partition à partir de
 - ▶ w_A et w_B leurs pondérations
 - ▶ $d_{i,j}$ la dissemblance ou distance entre deux individus

CAH : Objectif

- ▶ **Agglomération** itérative de 2 éléments de la partition
- ▶ Construction d'un **dendrogramme** ou arbre binaire
- ▶ **Problème** : définir $d(A, B)$ A et B deux groupes ou éléments d'une partition à partir de
 - ▶ w_A et w_B leurs pondérations
 - ▶ $d_{i,j}$ la dissemblance ou distance entre deux individus

CAH : Objectif

- ▶ **Agglomération** itérative de 2 éléments de la partition
- ▶ Construction d'un **dendrogramme** ou arbre binaire
- ▶ **Problème** : définir $d(A, B)$ A et B deux groupes ou éléments d'une partition à partir de
 - ▶ w_A et w_B leurs pondérations
 - ▶ $d_{i,j}$ la dissemblance ou distance entre deux individus

CAH : Objectif

- ▶ **Agglomération** itérative de 2 éléments de la partition
- ▶ Construction d'un **dendrogramme** ou arbre binaire
- ▶ **Problème** : définir $d(A, B)$ A et B deux groupes ou éléments d'une partition à partir de
 - ▶ w_A et w_B leurs pondérations
 - ▶ $d_{i,j}$ la dissemblance ou distance entre deux individus

Cas d'une dissemblance

- ▶ $d(A, B) = \min_{i \in A, j \in B} (d_{ij})$ saut minimum, single linkage
- ▶ $d(A, B) = \sup_{i \in A, j \in B} (d_{ij})$ saut maximum ou diamètre, complete linkage
- ▶ $d(A, B) = \frac{1}{\text{card}(A)\text{card}(B)} \sum_{i \in A, j \in B} d_{ij}$ saut moyen, group average linkage

Cas d'une distance euclidienne

g_A et g_B : barycentres des classes

$$d(A, B) = d(g_A, g_B) \quad (\text{distance des barycentres, centroïd})$$

$$d(A, B) = \frac{w_A w_B}{w_A + w_B} d(g_A, g_B) \quad (\text{saut de Ward})$$


Saut de **Ward** et maximisation de la **variance inter**

Algorithme de classification ascendante hiérarchique


- ▶ **Initialisation** : singletons, calcul des distances
- ▶ **Itérer** jusqu'à agrégation en une seule classe :
 1. **regrouper** les deux classes les plus proches au sens de la "distance" entre groupes choisie
 2. **mise à jour du tableau de distance** en remplaçant les deux classes par la nouvelle et en calculant sa "distance" avec les autres classes

Nombre de classes : **Rupture** dans la décroissance du R^2 partiel (Ward)


Villes : Décroissance de la variance inter classes



Villes : Exemple d'un dendrogramme



Villes : Représentation des classes avec MDS



Principe des centres mobiles

- ▶ **réallocation dynamique** des individus à des classes
- ▶ Le nombre de classes k est fixé *a priori*

Algorithme de Forgy

- ▶ **Initialisation** Tirer au hasard ou sélectionner, k points dans l'espace des individus, en général k individus de l'ensemble, appelés **centres** ou **noyaux**
- ▶ **Itérer** jusqu'à stagnation du critère de **variance inter-classe**
 1. **Allouer** chaque individu à l'un des **noyaux**, c'est-à-dire à une classe
 2. Calculer le **centre de gravité** de chaque classe, il devient le **nouveau noyau**

Attention : optimum local

Principe des centres mobiles

- ▶ **réallocation dynamique** des individus à des classes
- ▶ Le nombre de classes k est fixé *a priori*

Algorithme de Forgy

- ▶ **Initialisation** Tirer au hasard ou sélectionner, k points dans l'espace des individus, en général k individus de l'ensemble, appelés **centres** ou **noyaux**
- ▶ **Itérer** jusqu'à stagnation du critère de **variance inter-classe**
 1. **Allouer** chaque individu à l'un des **noyaux**, c'est-à-dire à une classe
 2. Calculer le **centre de gravité** de chaque classe, il devient le **nouveau noyau**

Attention : optimum local

Variantes

- ▶ **Algorithme *kmeans*** : les **noyaux** des classes, ici les barycentres, sont recalculés à chaque **allocation** d'un point à une **classe** ; algorithme plus efficace
- ▶ **Nuées dynamiques** : Un **centre** de classes est un noyau d'éléments **représentatifs** d'une classe
- ▶ **Partitionning Around Medoids**


Variantes

- ▶ **Algorithme *kmeans*** : les **noyaux** des classes, ici les barycentres, sont recalculés à chaque **allocation** d'un point à une **classe** ; algorithme plus efficace
- ▶ **Nuées dynamiques** : Un **centre** de classes est un noyau d'éléments **représentatifs** d'une classe
- ▶ Partitioning Around Medoids

Variantes

- ▶ **Algorithme *kmeans*** : les **noyaux** des classes, ici les barycentres, sont recalculés à chaque **allocation** d'un point à une **classe** ; algorithme plus efficace
- ▶ **Nuées dynamiques** : Un **centre** de classes est un noyau d'éléments **représentatifs** d'une classe
- ▶ **Partitionning Around Medoids**

Villes : Classes d'un PAM avec MDS



Classification de grands tableaux

1. Réallocation dynamique avec un grand nombre de classes ($n/10$)
2. Classification hiérarchique des barycentres
3. détermination d'un nombre “optimal” k de classes
4. Réallocation dynamique de l'ensemble avec k classes en choisissant pour noyaux les barycentres des classes de l'étape précédente

Conclusion

- ▶ **Résultat** : une **variable qualitative T** dont les modalités précisent la **classe** retenue pour chaque individu
- ▶ **Problèmes** : **interprétation** des classes
- ▶ Surtout dans le cas de variables qualitatives