

Clustering hiérarchique et critères de (dis)similarité

Master parcours SSD - UE Apprentissage Statistique I

Pierre Mahé - bioMérieux & Université de Grenoble-Alpes

Rappels

Clustering
hiérarchique

Heatmaps

Distances /
Similarités

Conclusion

Exercice

Références

Rappels : clustering



Clustering = **classification** non-supervisée

- ▶ catégoriser les **observations** (sous-populations)
- ▶ ...ou catégoriser les **variables** (corrélation / redondance)

Objectifs : exploratoire

- ▶ présence de sous-groupes dans les données
- ▶ adéquation critères de similarité / données

Catégoriser les observations ?



Rappels

Clustering
hiérarchique

Heatmaps



Distances /
Similarités

Conclusion



Exercice

Références



Catégoriser les observations? Oui mais...



Catégoriser les observations? Oui mais...



Catégoriser les observations? Oui mais...



Clustering - qualité

But du clustering :

- ▶ déterminer des ensembles de points **proches**
- ▶ qui soient **distants** les uns des autres

Clustering - qualité

But du clustering :

- ▶ déterminer des ensembles de points **proches**
- ▶ qui soient **distants** les uns des autres

Fonction objective (à minimiser) = dispersion "intra" cluster

$$W(C) = \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j)$$

- ▶ K = nombre de clusters
- ▶ C = clustering : $C(i) = k \leftrightarrow x_i \in \text{cluster } k$
- ▶ $d(x, y)$ = distance/dissimilarité entre x et y

⇒ problème **combinatoire**, présence de **minima locaux**.

Questions centrales :

- ▶ choisir la **fonction de distance** entre observations
 - ▶ dicté par nature du problème et des données
- ▶ choisir le **nombre de clusters**
 - ▶ pas de réponse absolue, tester plusieurs valeurs
- ▶ évaluer la **stabilité** du clustering

Méthodes clé :

- ▶ clustering hiérarchique
- ▶ K -means
- ▶ modèles de mélanges

Clustering hiérarchique

Clustering hiérarchique




Figure: Clustering hiérarchique du jeu USArrests.

- ▶ procédure itérative d'agglomération (ou de division)
- ▶ s'appuie sur une mesure de distance
- ▶ le plus simple des algorithmes de clustering

Algorithme :

1. Introduire un cluster par observations
2. Calculer la similarité entre observations/clusters
3. Tant que le nombre de clusters est > 1
 - 3.1 fusionner les deux clusters les plus similaires
 - 3.2 re-calculer la similarité entre clusters

Algorithme :

1. Introduire un cluster par observations
2. Calculer la similarité entre observations/clusters
3. Tant que le nombre de clusters est > 1
 - 3.1 fusionner les deux clusters les plus similaires
 - 3.2 re-calculer la similarité entre clusters

⇒ définit une **hiérarchie de partitions**

Algorithme :

1. Introduire un cluster par observations
2. Calculer la similarité entre observations/clusters
3. Tant que le nombre de clusters est > 1
 - 3.1 fusionner les deux clusters les plus similaires
 - 3.2 re-calculer la similarité entre clusters

⇒ définit une **hiérarchie de partitions**

⇒ on la résume dans un **arbre** appelé **dendrogramme**

Algorithme :

1. Introduire un cluster par observations
2. Calculer la similarité entre observations/clusters
3. Tant que le nombre de clusters est > 1
 - 3.1 fusionner les deux clusters les plus similaires
 - 3.2 re-calculer la similarité entre clusters

⇒ définit une hiérarchie de partitions

⇒ on la résume dans un arbre appelé dendrogramme

⇒ le nombre de clusters n'est pas défini à l'avance

Clustering hiérarchique - illustration




Figure: Figure tirée de James et al. (2013)

Questions ouvertes :

- ▶ la mesure de **distance entre observations**
- ▶ la mesure de **distance entre clusters**
- ▶ l'**interprétation** du dendrogramme
- ▶ le choix du **nombre de clusters**

Clustering hiérarchique - distances inter-observations

Quelle critère de distance pour quelles observations ?

Clustering hiérarchique - distances inter-observations

Quelle critère de distance pour quelles observations ?

- ▶ très dépendant du problème
- ▶ choix usuel / par défaut = distance Euclidienne
- ▶ voir 2nde partie du cours

Distance entre clusters : 3 stratégies principales

- ▶ "average" : distance moyenne entre observations :

$$d_C(C_1, C_2) = \frac{1}{|C_1||C_2|} \sum_{x_1 \in C_1} \sum_{x_2 \in C_2} d(x_1, x_2)$$

- ▶ "complete" : distance maximale entre observations

$$d_C(C_1, C_2) = \max\{d(x_1, x_2) : x_1 \in C_1, x_2 \in C_2\}$$

- ▶ "single" : distance minimale entre observations

$$d_C(C_1, C_2) = \min\{d(x_1, x_2) : x_1 \in C_1, x_2 \in C_2\}$$

Clustering hiérarchique - distances inter-clusters

Plan

Apprentissage
Statistique I

Rappels

Clustering
hiérarchique

Heatmaps


Distances /
Similarités

Conclusion


Exercice

Références


Distance min




Diamètre maximum



Distance moyenne



Distance des centres de gravité



Clustering hiérarchique - distances inter-clusters

Plan

Apprentissage
Statistique I

Rappels

Clustering
hiérarchique

Heatmaps


Distances /
Similarités

Conclusion

Exercice

Références

Illustration :



⇒ impact fort sur les résultats !

Clustering hiérarchique - distances inter-clusters

Comment choisir ?

- ▶ pas de règle bien définie \Rightarrow inspection du dendrogramme

Clustering hiérarchique - distances inter-clusters

Comment choisir ?

- ▶ pas de règle bien définie \Rightarrow inspection du dendrogramme

Néanmoins (en général) :

Clustering hiérarchique - distances inter-clusters

Comment choisir ?

- ▶ pas de règle bien définie \Rightarrow inspection du dendrogramme

Néanmoins (en général) :

- ▶ "single" & "complete" : sensibles aux bruit (outliers)

Comment choisir ?

- ▶ pas de règle bien définie \Rightarrow inspection du dendrogramme

Néanmoins (en général) :

- ▶ "single" & "complete" : sensibles aux bruit (outliers)
- ▶ "single" : perte de compacité
 - ▶ cluster compact : toutes les observations sont proches
 - ▶ perdu par distance minimum par effet de chaînage

Comment choisir ?

- ▶ pas de règle bien définie \Rightarrow inspection du dendrogramme

Néanmoins (en général) :

- ▶ "single" & "complete" : sensibles aux bruit (outliers)
- ▶ "single" : perte de compacité
 - ▶ cluster compact : toutes les observations sont proches
 - ▶ perdu par distance minimum par effet de chaînage
- ▶ "complete" : compacité, mais perte de "proximité"
 - ▶ "proximité" (closeness) : observations plus proches de celles de leur cluster que de celles des autres clusters.
 - ▶ pas garanti par l'utilisation du maximum


Comment choisir ?

- ▶ pas de règle bien définie \Rightarrow inspection du dendrogramme

Néanmoins (en général) :

- ▶ "single" & "complete" : sensibles aux bruit (outliers)
- ▶ "single" : perte de compacité
 - ▶ cluster compact : toutes les observations sont proches
 - ▶ perdu par distance minimum par effet de chaînage
- ▶ "complete" : compacité, mais perte de "proximité"
 - ▶ "proximité" (closeness) : observations plus proches de celles de leur cluster que de celles des autres clusters.
 - ▶ pas garanti par l'utilisation du maximum
- ▶ "average" : bon compromis, clusters équilibrés


Interprétation du dendrogramme



- ▶ on construit l'arbre de bas en haut

Interprétation du dendrogramme



Distances croissantes



- ▶ on construit l'arbre de bas en haut
- ▶ hauteur dans l'arbre = distance entre clusters

Interprétation du dendrogramme

Distances croissantes





1^{ère} étape : 5 et 7 sont les plus proches

- ▶ on construit l'arbre de bas en haut
- ▶ hauteur dans l'arbre = distance entre clusters
- ▶ hauteur d'un cluster = distance entre ses deux fils

Interprétation du dendrogramme

Distances croissantes




2^{ème} étape : 6 et 1 sont les plus proches


- ▶ on construit l'arbre de bas en haut
- ▶ hauteur dans l'arbre = distance entre clusters
- ▶ hauteur d'un cluster = distance entre ses deux fils
- ▶ ...

Interprétation du dendrogramme

Distances croissantes




3^{ème} étape




- ▶ on construit l'arbre de bas en haut
- ▶ hauteur dans l'arbre = distance entre clusters
- ▶ hauteur d'un cluster = distance entre ses deux fils
- ▶ ...

Interprétation du dendrogramme

Distances croissantes




4^{ème} étape



- ▶ on construit l'arbre de bas en haut
- ▶ hauteur dans l'arbre = distance entre clusters
- ▶ hauteur d'un cluster = distance entre ses deux fils
- ▶ ...

Interprétation du dendrogramme



Distances croissantes



- ▶ on construit l'arbre de bas en haut
- ▶ hauteur dans l'arbre = distance entre clusters
- ▶ hauteur d'un cluster = distance entre ses deux fils
- ▶ ...on continue jusqu'à ce qu'on ait 1 seul cluster


Interprétation du dendrogramme

Attention :



Interprétation du dendrogramme



Attention :



- il est tentant de conclure que 2 et 9 sont proches...

Interprétation du dendrogramme

Attention :



- ▶ il est tentant de conclure que 2 et 9 sont proches...
- ▶ ...mais 9 n'est pas plus proche de 2 que de 5, 7 ou 8.

⇒ proximité dans l'arbre \nRightarrow distance faible

- ▶ c'est la hauteur dans l'arbre qui compte
- ▶ la topologie de l'arbre est (en partie) arbitraire

Choix du nombre de clusters

On obtient des clusters en **coupant le dendrogramme** :

Rappels

**Clustering
hiérarchique**



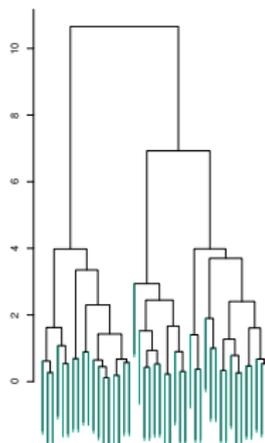
Heatmaps

Distances /
Similarités

Conclusion

Exercice

Références



Choix du nombre de clusters

On obtient des clusters en **coupant le dendrogramme** :

Rappels

Clustering
hiérarchique


Heatmaps

Distances /
Similarités

Conclusion

Exercice

Références



- ▶ choisir le **"bon" nombre de clusters** : difficile et subjectif
- ▶ intérêt du dendrogramme : continuum de solution
- ▶ choix essentiellement empirique - "à l'oeil"

(\Rightarrow à suivre la semaine prochaine)

En conclusion :

- ▶ représentation très populaire
- ▶ fournit un ensemble de solution à différents niveaux de granularité
- ▶ très simple à mettre en oeuvre
- ▶ limite : influence assez forte du critère de "linkage"

En conclusion :

- ▶ représentation très populaire
- ▶ fournit un ensemble de solution à différents niveaux de granularité
- ▶ très simple à mettre en oeuvre
- ▶ limite : influence assez forte du critère de "linkage"

Extensions :

- ▶ autres critères de **linkage**
 - ▶ meilleure interprétation de la "coupe" du dendrogramme
- ▶ **ré-échantillonnage** pour améliorer la stabilité des clusters

1. construction d'un objet de type `dist`
 - ▶ `d = dist(X)` si `X` = observations
 - ▶ `d = as.dist(D)` si `D` = matrice de distance
2. construction du dendrogramme : `hc = hclust(d)`
 - ▶ avec options de linkage
3. "coupe" du dendrogramme : `C = cutree(hc, ...)`
 - ▶ avec `hauteur` de coupe, ou `nombre de clusters`
 - ▶ `C` = vecteur donnant les indices des clusters

Heatmaps

Clustering hiérarchique & heatmaps

Clustering :

- ▶ catégoriser les **observations** (sous-populations)

Clustering hiérarchique & heatmaps

Clustering :

- ▶ catégoriser les **observations** (sous-populations)
- ▶ ...ou catégoriser les **variables** (corrélation / redondance)

Clustering hiérarchique & heatmaps


Clustering :

- ▶ catégoriser les **observations** (sous-populations)
- ▶ ...ou catégoriser les **variables** (corrélation / redondance)
- ▶ ... ou les deux !

Heatmaps :

- ▶ représentation graphique de **matrice de données**
- ▶ **clustering** hiérarchique pour ré-ordonner lignes & colonnes
- ▶ fait ressortir des **structures "de bloc"**
- ▶ très populaire en biologie
- ▶ très pratique quand on a beaucoup de variables

Heatmap



Plan

Apprentissage
Statistique I

Rappels

Clustering
hiérarchique

Heatmaps

Distances /
Similarités

Conclusion

Exercice

Références

Principe :


- ▶ représentation d'une matrice comme une image
 - ▶ "carte de chaleur" : couleur = intensité
- ▶ lignes & colonnes ré-ordonnées par clustering hiérarchique

Paramètres :

- ▶ **fonction de distance** entre lignes ou colonnes
- ▶ **stratégie d'agrégation** pour le clustering hiérarchique
 - ▶ e.g., complete, single, average
- ▶ (+ spécifier si on ré-ordonne lignes & colonnes ou seulement l'un ou l'autre)

Mise en oeuvre

- ▶ fonction "native" `heatmap(X)`
- ▶ fonction `aheatmap(X)` du package NMF
 - ▶ ajout facile d'annotations sur lignes et/ou colonnes



Distances / Similarités

Distances et (dis)similarités

Point d'entrée de l'algorithme précédent :

- ▶ matrice de distance ou disimilarité entre les observations

⇒ quelle(s) mesure(s) utiliser ?

Distances et (dis)similarités

Point d'entrée de l'algorithme précédent :

- ▶ matrice de distance ou disimilarité entre les observations
- ⇒ quelle(s) mesure(s) utiliser ?

1. distance vs (dis)similarité
2. variables quantitatives : distances & espaces vectoriels
3. la distance Euclidienne
4. variables qualitatives : critères de similarité usuels
5. distance & données structurées

Une **fonction de similarité** s définie sur un espace \mathcal{X} :

- ▶ est une fonction de $\mathcal{X} \times \mathcal{X}$ dans \mathbb{R} , et souvent dans \mathbb{R}^+
- ▶ qui quantifie la proximité entre couples d'instances

Une **fonction de similarité** s définie sur un espace \mathcal{X} :

- ▶ est une fonction de $\mathcal{X} \times \mathcal{X}$ dans \mathbb{R} , et souvent dans \mathbb{R}^+
- ▶ qui quantifie la proximité entre couples d'instances

Propriétés naturelles d'un critère de similarité s :

- ▶ $s(x, y) = s(y, x)$: symétrie
- ▶ $s(x, x) = 1$ (ou plus généralement $s(x, x) = S > 0$)
- ▶ $s(x, y) \leq s(x, x)$

$\Rightarrow s(x, y)$ grand si x et y proches/similaires

Distances & (dis)similarités

A partir d'un critère de **similarité** s on peut définir un critère de **dissimilarité** d :

$$d(x, y) = 1 - s(x, y)$$

(ou plus généralement $d(x, y) = S - s(x, y)$ si $s(x, x) = S$)

Distances & (dis)similarités

A partir d'un critère de **similarité** s on peut définir un critère de **dissimilarité** d :

$$d(x, y) = 1 - s(x, y)$$

(ou plus généralement $d(x, y) = S - s(x, y)$ si $s(x, x) = S$)

Conséquences :

- ▶ $d(x, x) = 0$
- ▶ $d(x, y) \geq 0$
- ▶ (+ reste **symétrique**)

$\Rightarrow d(x, y)$ grand si x et y distants/différents

Distances & (dis)similarités

A partir d'un critère de **similarité** s on peut définir un critère de **dissimilarité** d :

$$d(x, y) = 1 - s(x, y)$$

(ou plus généralement $d(x, y) = S - s(x, y)$ si $s(x, x) = S$)

Conséquences :

- ▶ $d(x, x) = 0$
- ▶ $d(x, y) \geq 0$
- ▶ (+ reste **symétrique**)

⇒ $d(x, y)$ grand si x et y distants/différents

Néanmoins, ce n'est pas suffisant pour parler de **distance**.

Distances & (dis)similarités

Une **distance** d est une fonction de $\mathcal{X} \times \mathcal{X}$ dans \mathbb{R}^+

- ▶ (NB : $d(x, y) \geq 0$)

qui vérifie les propriétés suivantes :

- ▶ **symétrie** : $d(x, y) = d(y, x)$
- ▶ **séparation** : $d(x, y) = 0 \Leftrightarrow x = y$
- ▶ **inégalité triangulaire** : $d(x, z) \leq d(x, y) + d(y, z)$




Figure: Image adaptée de Wikipedia.

Distances et (dis)similarités

1. distance vs (dis)similarité
2. variables quantitatives : distances & espaces vectoriels
3. la distance Euclidienne
4. variables qualitatives : critères de similarité usuels
5. distance & données structurées

Distances et espaces vectoriels

Distances usuelles quand $\mathcal{X} = \mathbb{R}^p$:

► distance Euclidienne : $d_2(x, y) = \sqrt{\sum_{i=1}^p (x_i - y_i)^2}$

Distances et espaces vectoriels

Distances usuelles quand $\mathcal{X} = \mathbb{R}^p$:

- ▶ distance Euclidienne : $d_2(x, y) = \sqrt{\sum_{i=1}^p (x_i - y_i)^2}$
- ▶ distance de Manhattan : $d_1(x, y) = \sum_{i=1}^p |x_i - y_i|$

Distances et espaces vectoriels

Distances usuelles quand $\mathcal{X} = \mathbb{R}^p$:

▶ distance Euclidienne : $d_2(x, y) = \sqrt{\sum_{i=1}^p (x_i - y_i)^2}$

▶ distance de Manhattan : $d_1(x, y) = \sum_{i=1}^p |x_i - y_i|$

▶ distance de Chebyshev : $d_\infty(x, y) = \max_{i=1, \dots, p} |x_i - y_i|$

Distances et espaces vectoriels

Distances usuelles quand $\mathcal{X} = \mathbb{R}^p$:

▶ distance Euclidienne : $d_2(x, y) = \sqrt{\sum_{i=1}^p (x_i - y_i)^2}$

▶ distance de Manhattan : $d_1(x, y) = \sum_{i=1}^p |x_i - y_i|$

▶ distance de Chebyshev : $d_\infty(x, y) = \max_{i=1, \dots, p} |x_i - y_i|$

⇒ des cas particuliers de la distance de Minkowski :

$$d_q(x, y) = \left(\sum_{i=1}^p |x_i - y_i|^q \right)^{1/q}$$

(mais en pratique on prend essentiellement $q \in \{1, 2, \infty\}$)

Distances et espaces vectoriels

Distance de **Manhattan** ?

- ▶ ou distance de **city-block**, de **taxi**.

Distances et espaces vectoriels

Distance de **Manhattan** ?

- ▶ ou distance de **city-block**, de **taxi**.




Figure: Image tirée de Wikipedia

Quiz : distance Euclidienne vs Manhattan sur cet exemple ?

Distances et (dis)similarités

1. distance vs (dis)similarité
2. variables quantitatives : distances & espaces vectoriels
3. la distance Euclidienne
4. variables qualitatives : critères de similarité usuels
5. distance & données structurées

La distance Euclidienne

Définition : $d_2(x, y) = \sqrt{\sum_{i=1}^p (x_i - y_i)^2}$

La distance Euclidienne

Définition : $d_2(x, y) = \sqrt{\sum_{i=1}^p (x_i - y_i)^2}$

Relation avec le **produit scalaire** :

$$\langle x, y \rangle = x^T y = \sum_{i=1}^p x_i y_i$$

$$\langle x, x \rangle = x^T x = \sum_{i=1}^p x_i^2 = \|x\|_2^2$$

La distance Euclidienne

Définition : $d_2(x, y) = \sqrt{\sum_{i=1}^p (x_i - y_i)^2}$

Relation avec le **produit scalaire** :

$$\langle x, y \rangle = x^T y = \sum_{i=1}^p x_i y_i$$

$$\langle x, x \rangle = x^T x = \sum_{i=1}^p x_i^2 = \|x\|_2^2$$

On a donc :

$$\begin{aligned} d_2(x, y) &= \sqrt{\langle x - y, x - y \rangle} \\ &= \|x - y\|_2. \end{aligned}$$

Distance Euclidienne & produit scalaire

On a donc :

$$\begin{aligned}d_2^2(x, y) &= \|x - y\|_2^2 \\ &= \langle x - y, x - y \rangle\end{aligned}$$

Distance Euclidienne & produit scalaire

On a donc :

$$\begin{aligned}d_2^2(x, y) &= \|x - y\|_2^2 \\ &= \langle x - y, x - y \rangle\end{aligned}$$

Par distributivité du produit scalaire, on peut écrire :

$$\begin{aligned}d_2^2(x, y) &= \langle x, x \rangle + \langle y, y \rangle - 2\langle x, y \rangle \\ &= \|x\|^2 + \|y\|^2 - 2\langle x, y \rangle\end{aligned}$$

Distance Euclidienne & produit scalaire

On a donc :

$$\begin{aligned}d_2^2(x, y) &= \|x - y\|_2^2 \\ &= \langle x - y, x - y \rangle\end{aligned}$$

Par distributivité du produit scalaire, on peut écrire :

$$\begin{aligned}d_2^2(x, y) &= \langle x, x \rangle + \langle y, y \rangle - 2\langle x, y \rangle \\ &= \|x\|^2 + \|y\|^2 - 2\langle x, y \rangle\end{aligned}$$

Si nos observations sont normées, alors $\|x\| = 1$ et :

$$d_2^2(x, y) = 2(1 - \langle x, y \rangle)$$

⇒ produit scalaire = similarité liée à la distance Euclidienne.


Distance Euclidienne & produit scalaire

Remarque : fonction de similarité du cosinus =

$$\cos(x, y) = \frac{\langle x, y \rangle}{\|x\| \|y\|}$$

⇒ correspond au produit scalaire entre vecteurs normalisés :

$$\cos(x, y) = \langle \tilde{x}, \tilde{y} \rangle, \quad \text{avec } \tilde{x} = \frac{x}{\|x\|}.$$



Distance Euclidienne généralisée

Si les variables ont des **variances différentes**, il peut être judicieux de le prendre en compte par :

$$d(x, y) = \sqrt{\sum_{i=1}^p \frac{(x_i - y_i)^2}{s_i^2}},$$

où s_i est l'écart type (empirique) de la i ème variable.


Distance Euclidienne généralisée

Si les variables ont des **variances différentes**, il peut être judicieux de le prendre en compte par :

$$d(x, y) = \sqrt{\sum_{i=1}^p \frac{(x_i - y_i)^2}{s_i^2}},$$

où s_i est l'écart type (empirique) de la i ème variable.

Rappel :



- ▶ une différence sur l'axe 1 comptera moins qu'une différence sur l'axe 2.

Distance Euclidienne généralisée

Distance Euclidienne normalisée :

$$d(x, y) = \sqrt{\sum_{i=1}^p \frac{(x_i - y_i)^2}{s_i^2}},$$

où s_i est l'écart type empirique de la i ème variable.

Ecriture matricielle :

$$d(x, y) = \sqrt{(x - y)^T M (x - y)},$$


avec $M = \text{diag}(1/s_1^2, \dots, 1/s_p^2)$.

Distance Euclidienne généralisée

Plus généralement, la **distance de Mahalanobis** :

$$d(x, y) = \sqrt{(x - y)^T M (x - y)},$$

où $M = S^{-1}$ est la **matrice de covariance empirique**, permet de prendre en compte les corrélations entre variables.



Distances et (dis)similarités

1. distance vs (dis)similarité
2. variables quantitatives : distances & espaces vectoriels
3. la distance Euclidienne
4. variables qualitatives : critères de similarité usuels
5. distance & données structurées

Variables qualitatives

Variable qualitative :

- ▶ prend des valeurs 0 ou 1
- ▶ code pour la présence / l'absence d'une caractéristique

Variables qualitatives

Variable qualitative :

- ▶ prend des valeurs 0 ou 1
- ▶ code pour la présence / l'absence d'une caractéristique

Pourquoi un traitement particulier ?

Variables qualitatives

Variable qualitative :

- ▶ prend des valeurs 0 ou 1
- ▶ code pour la présence / l'absence d'une caractéristique

Pourquoi un traitement particulier ?

Exemple du produit scalaire :

$$\langle x, y \rangle = \{ \# \text{ de variables présentes en même temps} \}$$

Variables qualitatives

Variable qualitative :

- ▶ prend des valeurs 0 ou 1
- ▶ code pour la présence / l'absence d'une caractéristique

Pourquoi un traitement particulier ?

Exemple du produit scalaire :

$$\langle x, y \rangle = \{ \# \text{ de variables présentes en même temps} \}$$

$$\langle \begin{matrix} \square \\ \square \\ \blacksquare \\ \square \\ \square \end{matrix}, \begin{matrix} \square \\ \square \\ \square \\ \blacksquare \\ \square \end{matrix} \rangle = 0$$

$$\langle \begin{matrix} \square \\ \square \\ \blacksquare \\ \square \\ \square \end{matrix}, \begin{matrix} \square \\ \square \\ \square \\ \blacksquare \\ \square \end{matrix} \rangle = 1$$

$$\langle \begin{matrix} \square \\ \square \\ \blacksquare \\ \square \\ \square \end{matrix}, \begin{matrix} \square \\ \square \\ \square \\ \blacksquare \\ \blacksquare \end{matrix} \rangle = 1$$

⇒ quid des variables absentes en même temps ?

⇒ $s(x, y) = s(x, x)$ pour des x et y très différents

Variables qualitatives

Beaucoup de **critères de similarité** pour données qualitatives.

Motivations = prendre en compte :

- ▶ la **présence conjointe** de variables dans x et y
- ▶ l'**absence conjointe** de variables dans x et y
- ▶ le **nombre de variables** présentes dans x ou y

Variables qualitatives

Beaucoup de **critères de similarité** pour données qualitatives.

Motivations = prendre en compte :

- ▶ la **présence conjointe** de variables dans x et y
- ▶ l'**absence conjointe** de variables dans x et y
- ▶ le **nombre de variables** présentes dans x ou y

On définit les quantités suivantes :

	$y = 1$	$y = 0$
$x = 1$	M_{11}	M_{10}
$x = 0$	M_{01}	M_{00}

(NB : $M_{11} + M_{10} + M_{01} + M_{00} = p$)

Rappels

Clustering
hiérarchique

Heatmaps

Distances /
Similarités

Conclusion

Exercice

Références

Critères de similarité usuels

Produit scalaire :

$$s(x, y) = M_{11}$$

Simple Matching coefficient :

$$s(x, y) = \frac{M_{11} + M_{00}}{M_{11} + M_{10} + M_{01} + M_{00}} = \frac{M_{11} + M_{00}}{p}$$

Coefficient de Jaccard :

$$s(x, y) = \frac{M_{11}}{M_{11} + M_{01} + M_{10}}$$

Coefficient de Dice :

$$s(x, y) = \frac{2M_{11}}{2M_{11} + M_{01} + M_{10}}$$

Critères de similarité usuels - interprétation

Produit scalaire :

$$s(x, y) = M_{11}$$

⇒ nombre de variables présentes en même temps

Critères de similarité usuels - interprétation

Produit scalaire :

$$s(x, y) = M_{11}$$

⇒ nombre de variables présentes en même temps

Simple Matching coefficient :

$$s(x, y) = \frac{M_{11} + M_{00}}{M_{11} + M_{10} + M_{01} + M_{00}} = \frac{M_{11} + M_{00}}{p}$$

⇒ proportion de variables identiques en même temps

- ▶ présentes OU absentes


Critères de similarité usuels - interprétation

Coefficient de Jaccard :

$$s(x, y) = \frac{M_{11}}{M_{11} + M_{01} + M_{10}} = \frac{|X \cap Y|}{|X \cup Y|}$$

Coefficient de Dice :

$$s(x, y) = \frac{2M_{11}}{2M_{11} + M_{01} + M_{10}} = \frac{2|X \cap Y|}{|X| + |Y|}$$



Rappels

Clustering
hiérarchique

Heatmaps

Distances /
Similarités

Conclusion

Exercice

Références

Critères de similarité usuels - implémentation

Produit scalaire :

$$s(x, y) = \langle x, y \rangle$$

Critères de similarité usuels - implémentation

Produit scalaire :

$$s(x, y) = \langle x, y \rangle$$

Simple Matching coefficient :

$$s(x, y) = \frac{\langle x, y \rangle + \langle \neg x, \neg y \rangle}{p}$$

Critères de similarité usuels - implémentation

Produit scalaire :

$$s(x, y) = \langle x, y \rangle$$

Simple Matching coefficient :

$$s(x, y) = \frac{\langle x, y \rangle + \langle \neg x, \neg y \rangle}{p}$$

Coefficient de Jaccard :

$$s(x, y) = \frac{|X \cap Y|}{|X \cup Y|} = \frac{\langle x, y \rangle}{\langle x, x \rangle + \langle y, y \rangle - \langle x, y \rangle}$$

Critères de similarité usuels - implémentation

Produit scalaire :

$$s(x, y) = \langle x, y \rangle$$

Simple Matching coefficient :

$$s(x, y) = \frac{\langle x, y \rangle + \langle \neg x, \neg y \rangle}{p}$$

Coefficient de Jaccard :

$$s(x, y) = \frac{|X \cap Y|}{|X \cup Y|} = \frac{\langle x, y \rangle}{\langle x, x \rangle + \langle y, y \rangle - \langle x, y \rangle}$$

Coefficient de Dice :

$$s(x, y) = \frac{2|X \cap Y|}{|X| + |Y|} = \frac{2\langle x, y \rangle}{\langle x, x \rangle + \langle y, y \rangle}$$

Distances et (dis)similarités

1. distance vs (dis)similarité
2. variables quantitatives : distances & espaces vectoriels
3. la distance Euclidienne
4. variables qualitatives : critères de similarité usuels
5. distance & données structurées

Distances & données structurées

Données structurées :

- ▶ pas de représentation vectorielle naturelle
- ▶ présentes dans bon nombre d'applications réelles

Données structurées :

- ▶ pas de représentation vectorielle naturelle
- ▶ présentes dans bon nombre d'applications réelles

2 approches :

1. se ramener à une **représentation vectorielle**
 - ▶ "feature extraction" - quantitatif vs qualitatif (0/1)
2. définir des mesures de **similarité entre objets**

Données structurées :

- ▶ pas de représentation vectorielle naturelle
- ▶ présentes dans bon nombre d'applications réelles

2 approches :

1. se ramener à une **représentation vectorielle**
 - ▶ "feature extraction" - quantitatif vs qualitatif (0/1)
2. définir des mesures de **similarité entre objets**

Illustrations :

1. distance d'édition & données de séquences
2. "dynamic time warping" & séries temporelles

Distance d'édition pour chaînes de caractères

Distance d'édition = similarité entre chaînes de caractères

3 opérations élémentaires :

1. insertion : $ac \rightarrow abc$ ($\epsilon \rightarrow b$)
2. délétion : $abc \rightarrow ac$ ($b \rightarrow \epsilon$)
3. substitution : $abd \rightarrow abc$ ($d \rightarrow c$)


\Rightarrow chaque opération = un coût

$\Rightarrow d(x, y)$ = transformation de coût minimal

Très utilisée en bioinformatique et traitement du langage.

Distance d'édition pour chaînes de caractères

Illustration :



Rappels

Clustering
hiérarchique

Heatmaps

Distances /
Similarités

Conclusion

Exercice


Références

- ▶ aussi appelée **distance de Levenshtein**
- ▶ une **vraie distance**
 - ▶ sous certaines conditions (assez générales) sur les coûts.
- ▶ calcul par algorithmes de **programmation dynamique**


"Dynamic Time Warping" pour séries temporelles

DTW = similarité entre séries temporelles

- ▶ univariées et + généralement "séquences" (e.g., vidéos)



Euclidean Matching



Dynamic Time Warping Matching

- ▶ appariement optimal par "déformation du temps"
- ▶ calcul par algorithmes de programmation dynamique
- ▶ pas une vraie distance
- ▶ applications : reconnaissance de la parole, vidéo

Conclusion

Clustering hiérarchique :

- ▶ algorithme de base de clustering
- ▶ hiérarchie de partitions : **dendrogramme**

Heatmaps :

- ▶ clustering hiérarchique pour la visualisation
- ▶ identification de structures de bloc

Distance/similarités :

- ▶ choix propre à l'application
- ▶ rarement anodin

TP : matrices de distance, clustering hiérarchique, heatmaps.

Exercice

Soit la matrice de distance suivante :

$$D = \begin{bmatrix} 0 & 0.5 & 3 & 1.3 & 4 \\ 0.5 & 0 & 1 & 3.5 & 5 \\ 3 & 1 & 0 & 1.5 & 2.2 \\ 1.3 & 3.5 & 1.5 & 0 & 6 \\ 4 & 5 & 2.2 & 6 & 0 \end{bmatrix}$$

Calculer (à la main) le dendrogramme par la méthode d'agrégation de votre choix.

Exercice - solution (1/2)

	1	2	3	4	5
1	0	0.5	3	1.3	4
	2	0	1	3.5	5
		3	0	1.5	2.2
			4	0	6
				5	0

step 1 : merge 1 & 2

	1	2	3	4	5
1	0	0.5	3	1.3	4
	2	0	1	3.5	5
		3	0	1.5	2.2
			4	0	6
				5	0

SINGLE

step 2 : merge 1/2 & 3

	1\2	3	4	5
1\2	0	1	1.3	4
	3	0	1.5	2.2
		4	0	6
			5	0

step 3 : merge 1/2/3 & 4

	1\2\3	4	5
1\2\3	0	1.3	2.2
	4	0	6
		5	0

step 3 : merge 1/2/3/4 & 5

	1\2\3\4	5
1\2\3\4	0	2.2
	5	0

COMPLETE

step 2 : merge 3 & 4

	1\2	3	4	5
1\2	0	3	3.5	5
	3	0	1.5	2.2
		4	0	6
			5	0

step 3 : merge 1/2 & 3/4

	1\2	3\4	5
1\2	0	3.5	5
	3\4	0	6
		5	0

step 3 : merge 1/2/3/4 & 5

	1\2\3\4	5
1\2\3\4	0	6
	5	0

AVERAGE

step 2 : merge 3 & 4

	1\2	3	4	5
1\2	0	2	2.4	4.5
	3	0	1.5	2.2
		4	0	6
			5	0

step 3 : merge 1/2 & 3/4


	1\2	3\4	5
1\2	0	2.2	4.5
	3\4	0	4.1
		5	0

step 3 : merge 1/2/3/4 & 5


	1\2\3\4	5
1\2\3\4	0	4.3
	5	0

Exercice - solution (2/2)


SINGLE



COMPLETE



AVERAGE



G. James, D. Witten, T. Hastie, and R. Tibshirani. *An Introduction to Statistical Learning with Applications in R*. Springer, 2013.