

CARTES TOPOLOGIQUES

1ère séance

Introduction

- Modèles à **apprentissage non supervisé**
 - Regrouper les patients qui semblent avoir des analyses médicales semblables
 - Identifier les différents types de consommateurs (comportement d'achats)
- **But** : analyser des données d'observation par leur structures.
- **Kohonen** : Représentation de données multidimensionnelles de grande taille.
 - ◇ Projection de partitions
 - selon une structure de voisinage en dimension 1, 2 ou 3
 - ◇ **Ordre topologique**
 - les distances entre observations sont directement visibles sur la carte

Quantification Vectorielle

$\mathcal{D}$: espace des données d'observation (notées z) de dimension n .

$\mathcal{A}$: ensemble d'apprentissage $\mathcal{A} = \{\mathbf{z}_i, i = 1, \dots, N\}$

On a : $\mathcal{A} \subset \mathcal{D} \subset \mathcal{R}^n$

Réduire l'information de $\mathcal{D}$:

- En la résumant par un ensemble de **p référents**


$$\mathcal{W} = \{\mathbf{w}_c; c = 1, \dots, p\}$$

- En réalisant une partition de $\mathcal{D}$ en **p** sous-ensembles par l'intermédiaire d'une **fonction d'affectation** χ

$$\chi : \mathcal{D} \rightarrow \{1, 2, \dots, p\}$$

$$P = \{P_1, P_2, \dots, P_p\}$$

$$P_c = \{\mathbf{z} \in \mathcal{D} / \chi(\mathbf{z}) = \mathbf{c}\}$$



Différentes Méthode de Quantification Vectorielle



Différentes détermination de W et χ

- Méthode des K-moyennes
- Cartes topologiques auto-organisatrice de Kohonen (SOM)
- Cartes topologiques probabilistes (PRSOM)
- ...


☞ **Chaque méthode correspond à la minimisation d'une fonction de coût spécifique**

☞ **Algorithme en 2 étapes :**

- **Affectation $\longrightarrow$ fonction χ**
- **Minimisation $\longrightarrow$ référents W**

Méthode des k-moyennes

- Inertie intra-groupes : $\mathcal{I}_c = \sum_{\mathbf{z}_i \in \mathcal{A}} \|\mathbf{z}_i - \mathbf{w}_c\|^2$



- Minimiser la somme des inerties locales par rapport à χ et $\mathcal{W}$

$$\mathcal{I}(\mathcal{W}, \chi) = \sum_c \mathcal{I}_c$$

Soit, pour faire ressortir χ :

$$\mathcal{I}(\mathcal{W}, \chi) = \sum_c \mathcal{I}_c = \sum_c \sum_{\substack{\mathbf{z}_i \in \mathcal{A} \\ \chi(\mathbf{z}_i) = c}} \|\mathbf{z}_i - \mathbf{w}_c\|^2$$

- L'inertie $\mathcal{I}_c$ représente l'erreur de quantification obtenue si l'on remplace chaque observation de P_c par son référent $\mathbf{w}_c$
- Minimisation itérative de l'inertie qui fixe alternativement la partition (χ) puis recalcule $\mathcal{W}$

Minimisation de l'inertie $\mathcal{I}(\mathcal{W}, \chi)$

- Phase d'affectation

Pour un ensemble $\mathbf{W}$ de référents fixe, la minimisation de $\mathbf{I}$ par rapport à χ s'obtient en affectant chaque observation $\mathbf{z}$ au référent $\mathbf{w}_c$ selon la nouvelle fonction d'affectation χ

$$\chi(\mathbf{z}) = \arg \min_{\mathbf{r}} \|\mathbf{z} - \mathbf{w}_r\|^2 \quad (1)$$

- Phase de minimisation

La fonction χ est fixée. La fonction $\mathbf{I}(\mathbf{W}, \chi)$ est quadratique et convexe par rapport à $\mathbf{W}$. Le minimum global est atteint pour :

$$\frac{\partial I}{\partial \mathbf{W}} = \left[\frac{\partial I}{\partial \mathbf{w}_1}, \frac{\partial I}{\partial \mathbf{w}_2}, \dots, \frac{\partial I}{\partial \mathbf{w}_p} \right]^T = 0 \quad \Rightarrow \quad \forall c, \sum_{\mathbf{z}_i \in \mathcal{P}_c} (\mathbf{z}_i - \mathbf{w}_c) = \mathbf{0}$$

$\Downarrow$

Les p nouveaux référents

$\longrightarrow$

$$\mathbf{w}_c = \frac{\sum_{\mathbf{z}_i \in \mathcal{A}_c} \mathbf{z}_i}{n_c} \quad (2)$$

Algorithme des k-moyennes

1. Initialisation

- $t=0$: indice d'itération
- fixer le nombre maximum d'itérations : N_{iter}
- choisir les p référents initiaux (en général d'une manière aléatoire) : $\mathcal{W}^t$


2. Etape de minimisation itérative t (à partir de 1),

(à l'itération t , l'ensemble des référents $\mathcal{W}^{t-1}$ de l'étape précédente est connu)


- Phase d'affectation : mise à jour de la fonction d'affectation χ^t associée à $\mathcal{W}^{t-1}$: on affecte chaque observation $\mathbf{z}$ au référent le plus proche (1).
- Phase de minimisation : calcul des nouveaux référents $\mathcal{W}^t$ en appliquant l'équation (2).

3. Répéter l'étape itérative jusqu'à atteindre $t > N_{iter}$ itérations ou une stabilisation de $\mathbf{I}$.


Sensibilité aux conditions initiales




(a)



(b)




(c)



(d)

Comportement de l'algorithme des k-moyennes en fonctions des densités sous-jacentes



(a) Données simulées selon deux distributions gaussiennes de matrice de variance-covariance différentes.

(b) Référents et partition obtenue à la convergence avec 2 référents

(c) Avec 5 référents

Carte topologique


- L'ensemble des indices est maintenant ordonné
- Il s'agit d'un espace discret (**C**) de faible dimension à des fins de visualisation (**1-D, 2-D**).
- **C** ensemble de **neurones** connectés par une structure de graphe non-orienté muni d'une distance discrète δ sur **C** et d'une **structure de voisinage** :

$$V_c(d) = \{r \in \mathcal{C}, \delta(c, r) \leq d\}$$

↓

Voisinage d'ordre d


$\delta(c, r)$ = longueur du plus court chemin
entre c et r sur le graphe



Quantification par la carte


- Chaque neurone c de $\mathcal{C}$ est associé à un vecteur référent $\mathbf{w}_c$ de l'espace des données $\mathcal{D}$
- L'apprentissage approxime la densité sous-jacente des données tout en cherchant à respecter une contrainte de conservation de la topologie de la carte $\mathcal{C}$
- Deux neurones c et r "voisins" par rapport à la topologie discrète de la carte $\mathcal{C}$ sont associés à deux vecteurs référents $\mathbf{w}_c$ et $\mathbf{w}_r$ "proches" dans l'espace des données $\mathcal{D}$.

👉 NOTION DE CONSERVATION DE LA TOPOLOGIE




Les indices des référents
sont ordonnée par la topologie

Fonction de Voisinage



$$\bullet K^T(\delta) = \begin{cases} 1 & \text{si } \delta \leq T \\ 0 & \text{sinon} \end{cases}$$



$$\bullet K^T(\delta) = \exp(-|\delta| / T) \quad \bullet K^T(\delta) = \exp(\delta^2 / -T^2)$$

Taille du voisinage - zone d'influence - voisinage significatif

$$V_c^T = \{ r \in \mathcal{C} \mid \delta_{c,r} \leq T \}$$

$$V_c^T = \{ r \in \mathcal{C} \mid K^T(\delta_{c,r}) > \alpha \}$$

Apprentissage

Apprentissage de la carte = minimisation d'une fonction de coût

$$J_{som}^T(\chi, \mathcal{W}) = \sum_{\mathbf{z}_i \in \mathcal{A}} \sum_{c \in \mathcal{C}} K^T(\delta(c, \chi(\mathbf{z}_i)) \|\mathbf{z}_i - \mathbf{w}_c\|^2$$

La valeur de T détermine la taille du voisinage

$$V_c^T = \{r \in \mathcal{C} / K^T(\delta(c, r)) > \alpha\}$$

Remarque : $T=0 \Rightarrow$ fonction de coût des K-moyennes

Le seuil α gère l'ordre des valeurs significatives prises en compte par le calcul.

Chaque observation $\mathbf{z}$ calcul une distance généralisée à l'ensemble des neurones de la carte par l'intermédiaire de la fonction K^T

$$d^T(\mathbf{z}_i, \mathbf{w}_{\chi(\mathbf{z}_i)}) = \sum_{c \in \mathcal{C}} \mathbf{K}^T(\delta(c, \chi(\mathbf{z}_i)) \|\mathbf{z}_i - \mathbf{w}_c\|^2$$