

Le tab suivant est un tab d'ultramétrique

$\begin{matrix} E \\ E \end{matrix}$	1	2	3	4
1	0	6	0	6
2	6	0	5	2
3	0	5	0	5
4	6	2	5	0

Théorème : Il existe une bijection entre une hiérarchie induite et ultramétrique.

En d'autres termes, toute hiérarchie induite sur E correspond une ultramétrique et inversement.

On propose deux familles de méthodes pour obtenir une hiérarchie induite :

- Les regroupements progressifs
- Les passages directs à l'ultramétrique

V.4 / Les regroupements progressifs.

On a plusieurs étapes successives.

Sur le tableau des distances ou dissimilarité, on repère la plus petite valeur.

Soit A la classe $\{(w_i, w_{i'}) \mid d(w_i, w_{i'}) = \text{plus petite valeur}\}$.

On calcule la distance ou dissimilarité de chaque ind à A , on obtient un tableau de dim $(n-1, n-1)$.

On repère du nouveau tableau la dist ou diss la plus petite.

On répète la procédure jusqu'à obtenir un regroupement complet.

R_p si la + petite valeur correspond à une dist ou diss entre deux autres ind il seront regroupés ds une m classe, si cela correspond à dist ou diss entre un ind et A on forme une classe B de 3 ind's.

On a 3 manières de calculer les distances par utilisation d'indice au ~~titre~~ d'agrégation du ~~lien~~ minimum. d'agrégation

Def : On appelle indice d'agrégation entre deux groupes d'ind i et i' une

application $f : \mathcal{P}(E) \times \mathcal{P}(E) \rightarrow \mathbb{R}^+$
 $(h_1, h_2) \mapsto f(h_1, h_2)$ tel que $f(h_1, h_2) = f(h_2, h_1)$

1) Indice d'agregation du lien minimum (Jardin et Sibson 1967)

$$\delta(h_1, h_2) = \min_{\substack{w_i \in h_1 \\ w_j \in h_2}} d(w_i, w_j) \quad \text{d'indice de dissimilitude'}$$

Un ind^w est affecté à une classe s'il est plus proche (au sens de la dissimilitude ou distance) d'un elt de cette classe que d'un elt d'une autre classe. avec $d(w, A) = \delta(\{w\}, A)$

2) Indice d'agregation du lien maximum (Sorensen 1948)

$$\delta(h_1, h_2) = \max_{\substack{w_i \in h_1 \\ w_j \in h_2}} d(w_i, w_j)$$

un ind w est affecté à une classe A s'il est plus près de tous les elts de cette classe que de tous les elts des autres classes.

(la plus petite distance de l'indice d'agregation max)

3) Indice d'agregation de l'inertie (indice de Ward)

$$\text{le dist utilisée } \delta(h_1, h_2) = \frac{\text{Card}(h_1) \text{Card}(h_2)}{\text{Card}(h_1) + \text{Card}(h_2)} d^2(\bar{g}_{h_1}, \bar{g}_{h_2}) \quad \bar{g}_h \text{ centre de gravité de } h.$$

\bar{g}_h est le pt moyen de h .

On utilise parfois

4) indice d'agregation de la moyenne (Sokal, Nicholov 1958)

$$\delta(h_1, h_2) = \frac{1}{\text{Card}(h_1) \cdot \text{Card}(h_2)} \sum_{\substack{w_i \in h_1 \\ w_j \in h_2}} d(w_i, w_j)$$

5) l'indice d'agregation des centres de gravité.

$$\delta(h_1, h_2) = d(\bar{g}_{h_1}, \bar{g}_{h_2})$$

Exp: Soit E un ensemble à 4 ind $E = \{1, 2, 3, 4\}$, on donne le

tab des distances entre elts de E .

$i \setminus j$	1	2	3	4
1	0	7	6	7
2	7	0	5	2
3	6	5	0	6
4	7	2	6	0

a) Par l'indice d'agregation du lien minimal, pour obtenir une hierarchie

La distance minimale entre deux ind est $d = d(2, 4)$

le tabl. (3 x 3)

$E \setminus E$	1	{2,4}	3
1	0	$d(\{1,2\},\{1,4\})=7$	6
{2,4}	7	0	5
3	6	5	0

$$\delta = \min\{d(\{2,3\}, d(4,3))\}$$

On regroupe 3 et {2,4} car $d(\{3\}, \{2,4\})=5$ est la + petite.

on obtient le tabl. 2x2.

$E \setminus E$	1	{2,3,4}
1	0	6
{2,3,4}	6	0


$$d(1,2)=7, d(1,4)=7 \text{ et } d(1,3)=6$$

$$\delta(1, \{2,3,4\}) = 6 \text{ (dit min)}$$

On regroupe 1 et {2,3,4} on obtient le tabl. (1,1)

$E \setminus E$	{1,2,3,4}
{1,2,3,4}	0

Ainsi l'hierarchie induite obtenue avec le lien min est



b) Par l'indice d'agregation du lien maximal pour le m¹ exp.

etape 1: $d(\{2\}, \{4\}) = \min = 2$ on regroupe 2 et 4 ds une classe {2,4}

$E \setminus E$	1	{2,4}	3
1	0	7	6
{2,4}	7	0	5
3	6	5	0

$$d(1, \{2,4\}) = \max\{d(1,2), d(1,4)\} = \max\{7, 7\} = 7$$

$$d(\{3\}, \{2,4\}) = \max\{d(3,2), d(3,4)\} = \max\{5, 6\} = 6$$

3 est plus proche de {2,4} / on regroupe 3 et {2,4}

en une classe {2,4,3}


on regroupe {3,1}

$$d(3,1) = 6$$

	$\{1,3\}$	$\{2,4\}$
$\{1,3\}$	0	7
$\{2,4\}$	7	0

$\tau = \max d(A, B)$ $A = \{2,4\}$; $B = \{1,3\}$

On regroupe $\{1,3\}$ et $\{2,4\}$.



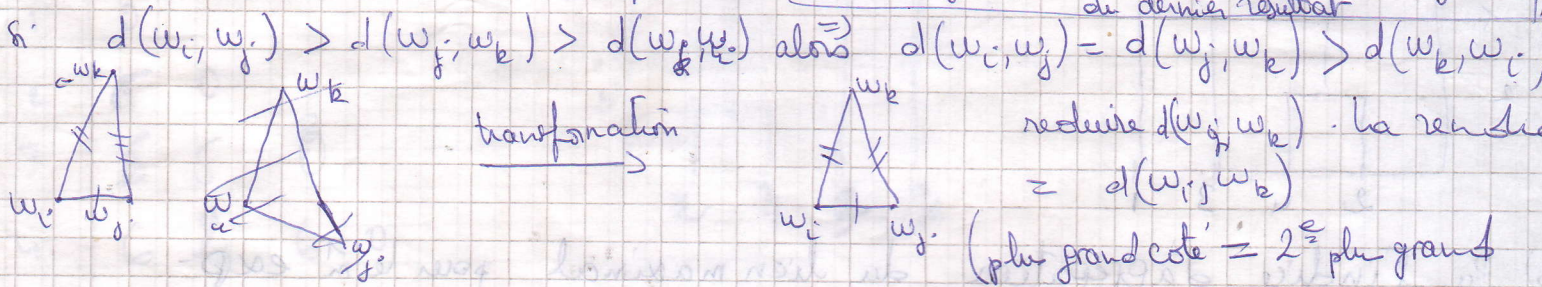
IV.5 Passage à l'ultramétrique

Le principe est de transformer la distance (ou dissimilarité) en une ultramétrique pour obtenir une hiérarchie insicée, ce qui revient à rendre tous les triangles w_i, w_j, w_k isocèles avec une base \leq aux côtés.

On propose deux façons :


1 - Passage à l'ultramétrique inférieure maximale.

Pour tout triplet $A = \{w_i, w_j, w_k\}$, rendre la plus grande distance (ou dissimilarité) entre de p^{ts} de A la plus grande = rendre plus petite moyenne du dernier résultat



2 - Passage à l'ultramétrique supérieure maximale.

Pour tout triplet $A = \{w_i, w_j, w_k\}$ rendre la distance (ou dissimilarité) la plus faible ou intermédiaire égale à la distance supérieure maximale




Exemple:

Soit l'ensemble $E = \{1, 2, 3, 4\}$; le tableau des distances est:


$E \setminus E$	1	2	3	4
1	0			
2	5	0		
3	2	5	0	
4	6	1	6	0

par la stratégie de passage à l'ultramétrique




inférieure maximale pour obtenir une hiérarchie indexée

le triangle (1,2,3)




le triangle 124




à ne pas transformer.

le triangle 134



" "


le triangle 324



on obtient le table de distance ultramétrique


la hiérarchie indexée

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




Pour le \vec{m} tab avec l'ultramétrique supérieure maximale,



le triangle 123





rien à faire





le triangle 124



le triangle 234




le triangle 134



le tableau

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



Soit une partition P d'un ensemble $E = \{w_1, \dots, w_n\}$ en k classe.

$$P = \{C_1, \dots, C_k\}.$$

On définit l'inertie d'un ensemble A par

$$I_A = \frac{1}{n} \sum_{i=1}^n d^2(w_i, G) \quad G \text{ centre de gravité de } E$$

Inertie intra-classe: intérieur de classes.

Inertie Intra-classes:

$$I_W(E) = \sum_{i=1}^k P_i I_{C_i} \quad P_i = \frac{\text{card}(C_i)}{n} \times \frac{P_i}{P_i}$$

Inertie Inter-classes

$$I_B(E) = \sum_{i=1}^k P_i d^2(G_i; G)$$

Proposition

$$I_A = I_W + I_B$$

$$I_W = \frac{1}{n} \sum_{i=1}^k P_i \sum_{j=1}^{n_i} d^2(w_{ji}; G_i)$$

$$I_W = \sum_{i=1}^k P_i I_{C_i} = \sum_{i=1}^k \frac{\text{card}(C_i)}{n} \cdot \frac{1}{\text{card}(C_i)} \sum_{j=1}^{\text{card}(C_i)} d^2(w_j, G_i)$$

$$= \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{\text{card}(C_i)} d^2(w_j, G_i)$$

$$d^2(w_j, G_i) = d^2(w_j, g) + d^2(g, G_i)$$

$$I_W = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{\text{card}(C_i)} [d^2(w_j, g) + d^2(g, G_i)]$$

$$= \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{\text{card}(C_i)} d^2(w_j, g) + \frac{1}{n} \sum_{i=1}^k \text{card}(C_i) d^2(g, G_i)$$