

Examen Final (2)

Exercice 2 (6 points)

Soient huit points donnés dans le plan.

| | | | | | | | |
|-------|-------|-------|-------|-------|-------|-------|-------|
| a | b | c | d | e | f | g | h |
| (1,3) | (3,3) | (4,3) | (5,3) | (1,2) | (4,2) | (1,1) | (2,1) |

- Appliquer la méthode k-means pour partager ces données en deux groupes. **(4 pts)**
- Vérifier que la méthode k-means tend à réduire la somme des moindres carrés suivante : **(2 pts)**

$$E = \sum_{i=1}^k \sum_{p \in C_i} |p - m_i|^2$$

Où m_i est le centre du cluster C_i et p les points de chaque cluster.

Exercice 3 (08 points)

Le dendrogramme est une représentation graphique d'une classification (clustering) hiérarchique par un arbre.

- Le dendrogramme d'une classification ascendante (ou descendante) est-il unique ? Si OUI dites Comment ? Si NON dites pourquoi ? **(2 Pts)**
- Comment déterminer le nombre de classes (clusters) à partir du dendrogramme ? Cette méthode est-elle exacte ou approximative ? Quel est le moyen le plus efficace pour avoir un nombre de classes (clusters) proche de la réalité? **(2 Pts)**
- Considérer la matrice de similarité suivante de cinq documents d1, d2, d3, d4 et d5. Déterminer le dendrogramme résultant de l'application du text clustering hiérarchique ascendant en utilisant le « **lien maximum** ». **(4 Pts)**

| | d1 | d2 | d3 | d4 | d5 |
|----|-----|-----|-----|-----|-----|
| d1 | 0 | 0.5 | 0.5 | 0.6 | 0.8 |
| d2 | 0.5 | 0 | 0.7 | 0.6 | 0.5 |
| d3 | 0.5 | 0.7 | 0 | 0.6 | 0.5 |
| d4 | 0.6 | 0.6 | 0.6 | 0 | 0.9 |
| d5 | 0.8 | 0.5 | 0.5 | 0.9 | 0 |

BONNE REUSSITE
Dr. Tahar Mehenni

Examen Final (2)

Correction

Exercice 2 (6 points)

Soient huit points donnés dans le plan.

| a | b | c | d | e | f | g | h |
|-------|-------|-------|-------|-------|-------|-------|-------|
| (1,3) | (3,3) | (4,3) | (5,3) | (1,2) | (4,2) | (1,1) | (2,1) |

a) Appliquer la méthode k-means pour partager ces données en deux groupes. (4 pts)

It0 : choix de deux centres : $m1=a=(1,3)$ et $m2=e=(1,2)$, $C1=\{a\}$, $C2=\{e\}$

It1 : calcul des distances et affectation aux clusters C1, C2

$$d^2(m1,b) = (1-3)^2 + (3-3)^2 = 4; d^2(m2,b) = (1-3)^2 + (2-3)^2 = 5, b \rightarrow C1$$

$$d^2(m1,c) = (1-4)^2 + (3-3)^2 = 9; d^2(m2,c) = (1-4)^2 + (2-3)^2 = 10, c \rightarrow C1$$

$$d^2(m1,d) = (1-5)^2 + (3-3)^2 = 16; d^2(m2,d) = (1-5)^2 + (2-3)^2 = 17, d \rightarrow C1$$

$$d^2(m1,f) = (1-4)^2 + (3-2)^2 = 10; d^2(m2,f) = (1-4)^2 + (2-2)^2 = 9, f \rightarrow C2$$

$$d^2(m1,g) = (1-1)^2 + (3-1)^2 = 4; d^2(m2,g) = (1-1)^2 + (2-1)^2 = 1, g \rightarrow C2$$

$$d^2(m1,h) = (1-2)^2 + (3-1)^2 = 5; d^2(m2,h) = (1-2)^2 + (2-1)^2 = 2, h \rightarrow C2$$

$$C1=\{a,b,c,d\}, C2=\{e,f,g,h\}$$

Calcul des nouveaux centres: $m1 = ((1+3+4+5)/4), (3+3+3+3)/4 = (3.25, 3)$

$$m2 = ((1+4+1+2)/4), (2+2+1+1)/4 = (2, 1.5)$$

It2 : calcul des distances et affectation aux clusters C1, C2

$$d^2(m1,a) = (3.25-1)^2 + (3-3)^2 = 5.06; d^2(m2,a) = (2-1)^2 + (1.5-3)^2 = 3.25, a \rightarrow C2$$

$$d^2(m1,b) = (3.25-3)^2 + (3-3)^2 = 0.06; d^2(m2,b) = (2-3)^2 + (1.5-3)^2 = 3.25, b \rightarrow C1$$

$$d^2(m1,c) = (3.25-4)^2 + (3-3)^2 = 0.56; d^2(m2,c) = (2-4)^2 + (1.5-3)^2 = 6.25, c \rightarrow C1$$

$$d^2(m1,d) = (3.25-5)^2 + (3-3)^2 = 3.06; d^2(m2,d) = (2-5)^2 + (1.5-3)^2 = 11.25, d \rightarrow C1$$

$$d^2(m1,e) = (3.25-1)^2 + (3-2)^2 = 6.06; d^2(m2,e) = (2-1)^2 + (1.5-2)^2 = 1.25, e \rightarrow C2$$

$$d^2(m1,f) = (3.25-4)^2 + (3-2)^2 = 1.56; d^2(m2,f) = (2-4)^2 + (1.5-2)^2 = 4.25, f \rightarrow C1$$

$$d^2(m1,g) = (3.25-1)^2 + (3-1)^2 = 9.06; d^2(m2,g) = (2-1)^2 + (1.5-1)^2 = 1.25, g \rightarrow C2$$

$$d^2(m1,h) = (3.25-2)^2 + (3-1)^2 = 4.56; d^2(m2,h) = (2-2)^2 + (1.5-1)^2 = 0.25, h \rightarrow C2$$

$$C1=\{b,c,d,f\}, C2=\{a,e,g,h\}$$

Calcul des nouveaux centres: $m1 = ((3+4+5+4)/4), (3+3+3+2)/4 = (4, 2.75)$

$$m2 = ((1+1+1+2)/4), (3+2+1+1)/4 = (1.25, 1.75)$$

It3 : calcul des distances et affectation aux clusters C1, C2

$$d^2(m1,a) = (4-1)^2 + (2.75-3)^2 = 9.06; d^2(m2,a) = (1.25-1)^2 + (1.75-3)^2 = 2.12, a \rightarrow C2$$

$$d^2(m1,b) = (4-3)^2 + (2.75-3)^2 = 1.06; d^2(m2,b) = (1.25-3)^2 + (1.75-3)^2 = 4.62, b \rightarrow C1$$

$$d^2(m1,c) = (4-4)^2 + (2.75-3)^2 = 0.06; d^2(m2,c) = (1.25-4)^2 + (1.75-3)^2 = 9.12, c \rightarrow C1$$

$$d^2(m1,d) = (4-5)^2 + (2.75-3)^2 = 1.06; d^2(m2,d) = (1.25-5)^2 + (1.75-3)^2 = 15.62, d \rightarrow C1$$

$$d^2(m1,e) = (4-1)^2 + (2.75-2)^2 = 9.56; d^2(m2,e) = (1.25-1)^2 + (1.75-2)^2 = 0.12, e \rightarrow C2$$

$$d^2(m1,f) = (4-4)^2 + (2.75-2)^2 = 0.56; d^2(m2,f) = (1.25-4)^2 + (1.75-2)^2 = 7.62, f \rightarrow C1$$

$$d^2(m1,g) = (4-1)^2 + (2.75-1)^2 = 12.06; d^2(m2,g) = (1.25-1)^2 + (1.75-1)^2 = 0.62, g \rightarrow C2$$

$$d^2(m1,h) = (4-2)^2 + (2.75-1)^2 = 5.06; d^2(m2,h) = (1.25-2)^2 + (1.75-1)^2 = 1.12, h \rightarrow C2$$

$$C1=\{b,c,d,f\}, C2=\{a,e,g,h\}$$

Stabilisation des clusters. Fin

Résultats : C1={b,c,d,f}, C2={a,e,g,h}

b) Vérifier que la méthode k-means tend à réduire la somme des moindres carrés suivante : **(2pts)**

$$E = \sum_{i=1}^k \sum_{p \in C_i} |p - m_i|^2$$

Où m_i est le centre du cluster C_i et p les points de chaque cluster.

Résultat de l'itération 1 : C1={a,b,c,d}, C2={e,f,g,h} avec $m_1 = (3.25, 3)$, $m_2 = (2, 1.5)$

$$E1 = (|1-3.25|^2 + |3-3.25|^2 + |4-3.25|^2 + |5-3.25|^2 + |3-3|^2 + |3-3|^2 + |3-3|^2 + |3-3|^2) + (|1-2|^2 + |4-2|^2 + |1-2|^2 + |2-2|^2 + |2-1.5|^2 + |2-1.5|^2 + |1-1.5|^2 + |1-1.5|^2)$$

$$E1 = (5.06 + 0.06 + 0.56 + 3.06 + 0 + 0 + 0 + 0) + (1 + 4 + 1 + 0 + 0.25 + 0.25 + 0.25 + 0.25) = 15.74$$

Résultat de l'itération 2 : C1={b,c,d,f}, C2={a,e,g,h} avec $m_1 = (4, 2.75)$, $m_2 = (1.25, 1.75)$

$$E2 = (|3-4|^2 + |4-4|^2 + |5-4|^2 + |4-4|^2 + |3-2.75|^2 + |3-2.75|^2 + |3-2.75|^2 + |2-2.75|^2) + (|1-1.25|^2 + |1-1.25|^2 + |1-1.25|^2 + |2-1.25|^2 + |3-1.75|^2 + |2-1.75|^2 + |1-1.75|^2 + |1-1.75|^2)$$

$$E2 = (1 + 0 + 1 + 0 + 0.06 + 0.06 + 0.06 + 0.56) + (0.06 + 0.06 + 0.06 + 0.56 + 1.56 + 0.06 + 0.56 + 0.56) = 6.22$$

Conclusion : $E2 < E1$ d'où la formule est vérifiée.

Exo3 : (08 points)

- Le dendrogramme d'un clustering n'est pas unique ; il dépend de la stratégie de regroupement : lien minimum, maximum ou moyen. En plus, si la distance minimale choisie n'est pas unique, le choix aléatoire diversifie le dendrogramme.
- On détermine le nombre de clusters à partir d'un dendrogramme, en déterminant le nombre de points d'intersection entre la droite $y=d$ et le dendrogramme, d étant la distance choisie. Cette méthode est exacte. Le moyen le plus efficace pour avoir un nombre de classes (clusters) proche de la réalité se fait généralement à l'aide de l'avis d'un expert dans le domaine.
- Le dendrogramme résultant de l'application du text clustering hiérarchique ascendant de cinq documents d1, d2, d3, d4 et d5, en utilisant le « **lien maximum** ».

| | | | | | |
|----|------------|-----|-----|-----|----|
| | d1 | d2 | d3 | d4 | d5 |
| d1 | 0 | | | | |
| d2 | <u>0.5</u> | 0 | | | |
| d3 | 0.5 | 0.7 | 0 | | |
| d4 | 0.6 | 0.6 | 0.6 | 0 | |
| d5 | 0.8 | 0.5 | 0.5 | 0.9 | 0 |

grouper (d1, d2)

| | | | | |
|------|------|------------|-----|----|
| | d1d2 | d3 | d4 | d5 |
| d1d2 | 0 | | | |
| d3 | 0.7 | 0 | | |
| d4 | 0.6 | 0.6 | 0 | |
| d5 | 0.8 | <u>0.5</u> | 0.9 | 0 |

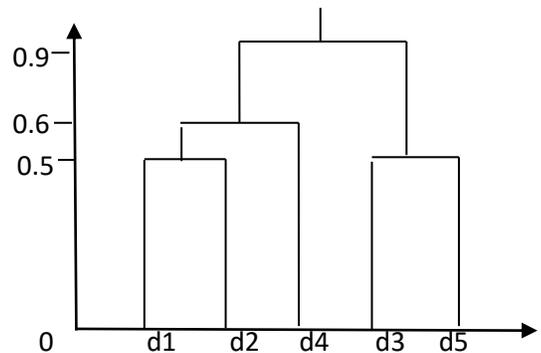
grouper (d3, d5)

| | | | |
|------|------------|------|----|
| | d1d2 | d3d5 | d4 |
| d1d2 | 0 | | |
| d3d5 | 0.8 | 0 | |
| d4 | <u>0.6</u> | 0.9 | 0 |

grouper (d1d2, d4)

| | | |
|--------|------------|------|
| | d1d2d4 | d3d5 |
| d1d2d4 | 0 | |
| d3d5 | <u>0.9</u> | 0 |

grouper(d1d2d4, d3d5)



Dendrogramme