

Examen Final

Data Mining et Recherche d'Information

Exercice 1 (6 points) : Répondre brièvement à ces questions.

Question 1.1 : Donner le principe général de l'algorithme K-means. (1 pt)

Question 1.2 : Quelle est la complexité de K-means ? (1 pt)

Question 1.3 : Donner deux inconvénients de K-means. (2 pts)

Question 1.4 : Quelles sont les conditions d'arrêt de l'algorithme K-means ? (2 pts)

Exercice 2 (7 points)

Les données suivantes permettent à un robot de prédire si un objet ayant certaines caractéristiques (Colour, Shape, Size) appartient à la classe (+) ou la classe (-). On désire utiliser les arbres de décision pour réaliser cet apprentissage.


<i>Example</i>	<i>Colour</i>	<i>Shape</i>	<i>Size</i>	<i>Class</i>
1	Red	Square	Big	+
2	Blue	Square	Big	+
3	Red	Circle	Big	+
4	Red	Circle	Small	-
5	Green	Square	Small	-
6	Green	Square	Big	-

Question 2.1 : Quel attribut peut-on choisir comme racine de l'arbre si on utilise le Gain en information? (2 pts)

Question 2.2 : Construire l'arbre de décision complet à partir de ces données. (5 pts)

Exercice 3 (7 points)

Soit un nuage de 7 points représentés dans un espace bidimensionnel selon la figure ci-dessous.



Question 3.1 : Donner un clustering rapide de ces points, selon votre visualisation.(1 pt)

Question 3.2 : Appliquer l'algorithme k-Means sur cet ensemble de points, avec k=nombre de clusters choisi à la Question 3.1) (3 Pts). Comment les centres initiaux ont été choisis ? (0.5 pt)

Question 3.3 : Comparer votre clustering rapide avec les résultats de k-means (1 pt). Quels sont les avantages et les inconvénients de cette stratégie de clustering? (1.5 pts)

Attribut choisi comme racine: Colour $E(\text{Colour}) = 0.540852$ **(0.5 Pt)**

Pour Colour = Red

Colour	Shape	Size	Class
Red	Square	Big	+
Red	Circle	Big	+
Red	Circle	Small	-

$n = 3$
 $C1 = 2$
 $C2 = 1$ **(0.5 Pt)**
 $E = 0.9183$


Shape	+	-	Somme	ni/n		Entropie		Gain
P1 (Square)	1	0	1	0.33	0.00000	0	0.6667	0.2516
P2 (Circle)	1	1	2	0.67	1.00000	0.66667		

Size	+	-	Somme	ni/n		Entropie		Gain
P1 (Big)	2	0	2	0.67	0.00000	0	0	0.9183
P2 (Small)	0	1	1	0.33	0.00000	0		

Attribut choisi pour le branchement: size $\text{Size} = \text{Big} \rightarrow \text{Class} = +$ $\text{Size} = \text{Small} \rightarrow \text{Class} = -$ **(0.5 Pt)**

$\text{Colour} = \text{Blue} \rightarrow \text{Class} = +$ **(0.5 Pt)**
 $\text{Colour} = \text{Green} \rightarrow \text{Class} = -$

Arbre de decision



Exercice 3 (7 points)

Coordonnées des 7 points du nuage

A	B	C	D	E	F	G
(4,10)	(7,10)	(4,8)	(6,8)	(3,4)	(2,2)	(5,2)

Question 3.1 : Clustering rapide à vue : on peut voir deux clusters : $C1 = (A, B, C, D)$, $C2 = (E, F, G)$ **(1 Pt)**

Question 3.2 : Application de K-Means. On choisit $k=2$ selon la réponse à la question 3.1 **(0.25 Pt)**

Initialisation : $C1 = \{\}$, $C2 = \{\}$, avec $c1 = A$, $c2 = E$ Les centres sont choisis selon le clustering trouvé à la question 3.1
(0.5 Pt)

Etape 1 :

Pour B : $d^2(c1,B) = |7-4|^2 + |10-10|^2 = 9$, $d^2(c2,B) = |7-3|^2 + |10-4|^2 = 52$ d'où $C1 = C1 + \{B\}$
Pour C : $d^2(c1,C) = |4-4|^2 + |8-10|^2 = 4$, $d^2(c2,C) = |4-3|^2 + |8-4|^2 = 17$ d'où $C1 = C1 + \{C\}$ (1 Pt)
Pour D : $d^2(c1,D) = |6-4|^2 + |8-10|^2 = 8$, $d^2(c2,D) = |6-3|^2 + |8-4|^2 = 25$ d'où $C1 = C1 + \{D\}$
Pour F : $d^2(c1,F) = |2-4|^2 + |2-10|^2 = 68$, $d^2(c2,F) = |2-3|^2 + |2-4|^2 = 5$ d'où $C2 = C2 + \{F\}$
Pour G : $d^2(c1,G) = |5-4|^2 + |2-10|^2 = 65$, $d^2(c2,G) = |5-3|^2 + |2-4|^2 = 8$ d'où $C2 = C2 + \{G\}$

$\Rightarrow C1 = \{ A,B,C,D \}$, $c1 = ((4+7+4+6)/4, (10+10+8+8)/4) = (5.25, 9)$ (0.25 Pt)
 $\Rightarrow C2 = \{ E,F,G \}$, $c2 = ((3+2+5)/3, (4+2+2)/3) = (3.33, 2.66)$

Etape 2 :

$C1 = \{\}$, $C2 = \{\}$ avec $c1 = (5.25, 9)$, $c2 = (3.33, 2.66)$ (0.25 Pt)

Pour A : $d^2(c1,A) = |4-5.25|^2 + |10-9|^2 = 2.56$, $d^2(c2,A) = |4-3.33|^2 + |10-2.66|^2 = 54.32$ d'où $C1 = C1 + \{A\}$
Pour B : $d^2(c1,B) = |7-5.25|^2 + |10-9|^2 = 4.06$, $d^2(c2,B) = |7-3.33|^2 + |10-2.66|^2 = 67.34$ d'où $C1 = C1 + \{B\}$
Pour C : $d^2(c1,C) = |4-5.25|^2 + |8-9|^2 = 2.56$, $d^2(c2,C) = |4-3.33|^2 + |8-2.66|^2 = 28.96$ d'où $C1 = C1 + \{C\}$ (1 Pt)
Pour D : $d^2(c1,D) = |6-5.25|^2 + |8-9|^2 = 2.56$, $d^2(c2,D) = |6-3.33|^2 + |8-2.66|^2 = 36.64$ d'où $C1 = C1 + \{D\}$
Pour E : $d^2(c1,E) = |3-5.25|^2 + |4-9|^2 = 30.06$, $d^2(c2,E) = |3-3.33|^2 + |4-2.66|^2 = 1.90$ d'où $C2 = C2 + \{E\}$
Pour F : $d^2(c1,F) = |2-5.25|^2 + |2-9|^2 = 59.56$, $d^2(c2,F) = |2-3.33|^2 + |2-2.66|^2 = 0.54$ d'où $C2 = C2 + \{F\}$
Pour G : $d^2(c1,G) = |5-5.25|^2 + |2-9|^2 = 49.06$, $d^2(c2,G) = |5-3.33|^2 + |2-2.66|^2 = 3.22$ d'où $C2 = C2 + \{G\}$

\Rightarrow Il y a stabilité des clusters. Les clusters sont $C1 = \{ A,B,C,D \}$, $C2 = \{ E,F,G \}$ (0.25 Pt)

(a) K-means a donné les mêmes résultats que le clustering rapide. (1 Pt)

Avantages : (1 Pt)

- k est choisi selon le clustering rapide
- Convergence rapide (stabilité rapide, nombre d'étapes réduit, temps d'exécution court) .
- Confirmation du clustering à vue.

Inconvénients : (0.5 Pt)

- Résultat biaisé, dû au clustering rapide (choix de k et des centres initiaux)

Rédigé par T. Mehenni