

Exercice 1**L'éclat (de rire de) moi hyène****7 points**

L'algorithme des K -moyennes est une procédure qui vise à partitionner un ensemble de données en K clusters distincts (d'intersection nulle). Considérons $n \geq 1$ observations (X_1, \dots, X_n) à valeurs dans \mathbb{R}^p . L'algorithme des K -moyennes cherche à minimiser sur toutes les partitions $C = (C_1, \dots, C_K)$ de $\{1, \dots, n\}$ le critère suivant :

$$J(C) = \sum_{k=1}^K \frac{1}{2|C_k|} \sum_{a,b \in C_k} \|X_a - X_b\|^2,$$

où pour tout $1 \leq i \leq n$, $1 \leq k \leq K$, $i \in C_k$ si et seulement si X_i est dans le cluster k .

1. Symétrisation

(a) Montrez que

$$J(C) = \sum_{k=1}^K \frac{1}{|C_k|} \sum_{a,b \in C_k} \langle X_a, X_a - X_b \rangle = \sum_{k=1}^K \sum_{a \in C_k} \|X_a - \bar{X}_{C_k}\|^2,$$

où

$$\bar{X}_{C_k} = \frac{1}{|C_k|} \sum_{b \in C_k} X_b.$$

2. Supposons que les observations soient aléatoires et indépendantes et que, pour tout $1 \leq a \leq n$, $\mathbb{E}[X_a] = \mu_a \in \mathbb{R}^p$ de sorte que $X_a = \mu_a + \varepsilon_a$, avec $(\varepsilon_1, \dots, \varepsilon_n)$ des variables aléatoires centrées et indépendantes. Pour tout $1 \leq a \leq n$, notons $v_a = \text{trace}(\text{cov}(X_a))$.

(a) Vérifiez que l'espérance du critère est

$$\mathbb{E}[J(C)] = \frac{1}{2} \sum_{k=1}^K \frac{1}{|C_k|} \sum_{a,b \in C_k} (\|\mu_a - \mu_b\|^2 + v_a + v_b) \mathbf{1}_{a \neq b}.$$

(b) Que devient cette valeur de $\mathbb{E}[J(C)]$ quand, pour tout $1 \leq k \leq K$, il existe $m_k \in \mathbb{R}^p$ tel que, pour tout $a \in C_k$, $\mu_a = m_k$?

3. Supposons maintenant qu'il existe une partition $C^* = (C_1^*, \dots, C_K^*)$ telle qu'il existe m_1^*, \dots, m_K^* in \mathbb{R}^p et $\gamma_1^*, \dots, \gamma_K^*$ dans \mathbb{R}_+ vérifiant $\mu_a = m_k^*$ et $v_a = \gamma_k^*$ pour tout $a \in C_k^*$ et $k = 1, \dots, K$. Nous allons maintenant étudier dans quelles conditions la valeur attendue du critère des K -moyenne est minimum pour C^* .

(a) Quelle est dans ce cas la valeur de $\mathbb{E}[J(C^*)]$?

(b) Dans le cas particulier où $\gamma_1^* = \dots = \gamma_K^* = \gamma$, quelle est la partition $C = (C_1, \dots, C_K)$ qui minimise $\mathbb{E}[J(C)]$? Sous quelle(s) hypothèse(s) cette solution est-elle unique ?

(c) Supposons maintenant que C^* contienne $K = 3$ groupes de taille s (avec s pair),

$$m_1 = (1, 0, 0)^T, \quad m_2 = (0, 1, 0)^T, \quad m_3 = (0, 1 - \tau, \sqrt{1 - (1 - \tau)^2})^T,$$

avec $\tau > 0$, et

$$\gamma_1 = \gamma_+, \quad \gamma_2 = \gamma_3 = \gamma_-.$$

Quelle est alors la valeur de $\|m_2 - m_3\|^2$?(d) Calculer $\mathbb{E}[J(C^*)]$.

(e) Définir C' obtenu en divisant C_1^* en deux groupes C'_1, C'_2 de même taille $\frac{s}{2}$ et en fusionnant C_2^* et C_3^* dans un seul et même groupe C'_3 de taille $2s$. Vérifier que, dans ce cas,

$$\mathbb{E}[J(C')] = s(\gamma_+ + 2\gamma_- + \tau) - (2\gamma_+ + \gamma_-).$$

(f) Sous quelle(s) hypothèse(s) $\mathbb{E}[J(C^*)] < \mathbb{E}[J(C')]$?

Exercice 2

L'épreuve du réel

8 points

Le but de cet exercice est d'écrire la fonction en python, Julia, R ou matlab permettant de prédire une sortie associée à un vecteur X de 64 composants. Pour ce faire, nous allons utiliser les données présentes dans le fichier `digits` disponible dans l'API sklearn qui contient :

- observations (entrées) X
- étiquettes y

Pour accéder à ces données, vous pourrez utiliser les instructions suivantes :

```
from sklearn.datasets import load_digits

X,y = load_digits(n_class=10, return_X_y=True)
```

```
%whos
```

| Variable | Type | Data/Info |
|-------------|----------|---|
| X | ndarray | 1797x64: 115008 elems, type 'float64', 920064 bytes (898.5 kb) |
| load_digits | function | <function load_digits at 0x120f98048> |
| y | ndarray | 1797: 1797 elems, type 'int64', 14376 bytes |

1. Traitement des données en mode non supervisé (en ignorant les étiquettes y)
 - a) Visualisez l'ensemble des données.
 - b) Proposez un découpage non supervisée des données en groupes homogènes.
2. Traitement des données en mode supervisé (en utilisant les étiquettes y). Donner un programme (en python, R ou matlab) permettant de prédire si une entrée future x_f , un vecteur de 64 composants représente un chiffre pair ou impair. On insistera sur la méthodologie mise en œuvre et sur la mesure des performances.

Exercice 3

Questions courtes

5 points

1. Que'est-ce que la malédiction de la dimensionnalité ?
 2. Quel est le rôle de la programmation quadratique dans le Lasso ?
 3. Quel est le rôle du stacking dans les méthodes de type autoML ?
 4. Quel est le rôle du graphe de proximité en l'apprentissage non supervisé ?
 5. Expliquez le principe d'une attaque en machine learning.
-