

- Durée : 2h
- Documents autorisés : cours, notes de cours et calculatrice

## 1 Non, pas encore du Bayes !

(7 points)

Soit un problème de classification à deux classes. Chaque classe  $\mathcal{C}_k, k \in \{1, 2\}$  est caractérisée par une probabilité a priori  $P(\mathcal{C}_k)$  et une loi conditionnelle  $p(x|\mathcal{C}_k)$  définie par

$$p(x|\mathcal{C}_k) = \frac{x}{a_k^2} e^{-\frac{x^2}{a_k^2}}$$

avec  $a_k \in \mathbb{R}$  le paramètre inconnu et  $x \in \mathbb{R}^+ - \{0\}$ . On dispose d'un ensemble de données  $\mathcal{D} = \{(x_i, y_i)\}_{i=1}^N$  avec  $y \in \{\mathcal{C}_1, \mathcal{C}_2\}$

1. Pour une classe  $\mathcal{C}_k$  donnée, on veut déterminer à partir des données le paramètre  $a_k$  de sa loi par la méthode du maximum de vraisemblance.
  - (a) Donner l'expression de la log-vraisemblance.
  - (b) En déduire l'estimation de  $\hat{a}_k$  au sens du maximum de vraisemblance.
2. Pour classer les données avec l'approche de Bayes, on prend les coûts suivants :  $\ell_{12} = 2\beta$ ,  $\ell_{21} = \beta$  et  $\ell_{11} = \ell_{22} = 0$  avec  $\beta > 0$ . On considère que les classes sont équiprobables c'est-à-dire  $P(\mathcal{C}_1) = P(\mathcal{C}_2)$ .
  - (a) Donner l'expression des risques conditionnels  $R(\mathcal{C}_k/x)$
  - (b) Sous quelle condition sur  $P(\mathcal{C}_1|x)$  et  $P(\mathcal{C}_2|x)$  on décide d'affecter  $x$  à la classe  $\mathcal{C}_1$  ?
  - (c) Donner alors l'expression de la frontière de décision en fonction de  $x$  et des  $\hat{a}_k$ .
3. On introduit maintenant le rejet en ambiguïté avec un coût  $\alpha = r\beta$ . Montrer qu'un point  $x$  sera rejeté si  $r < P(\mathcal{C}_1|x) < \frac{2-r}{r}$ . Analyser en fonction des valeurs de  $r$  comment se passe le rejet.

## 2 Logistique plus un - moins un

(10 points)

On veut élaborer un module de reconnaissance de visages. Pour faire simple on considère deux personnes dont on a pris les photos dans différentes conditions. Chaque image  $I_i \in \mathbb{R}^{50 \times 50}$  est convertie en un vecteur  $x_i \in \mathbb{R}^{2500}$ . On a donc un ensemble de données  $\mathcal{D} = \{(x_i, y_i) \in \mathbb{R}^{2500} \times \{-1, 1\}\}_{i=1}^n$ .

On va utiliser la régression logistique avec des classes codées en -1 et 1. On modélise

$$P(y = -1/x) = \frac{\exp(\theta^\top x)}{1 + \exp(\theta^\top x)}$$

avec  $\theta$  le vecteur de paramètres inconnus.

1. Donner l'expression de la log-vraisemblance  $J(\theta)$  du problème de régression logistique.
2. Expliquer comment procéder pour déterminer  $\theta$  et comment vous pouvez vérifier que le modèle appris est performant (*NB : aucun calcul n'est demandé*).

Le modèle est lourd à apprendre et à utiliser car la dimension de  $\theta$ ,  $D = 2500$  est grande. On souhaite donc mettre à zéro les paramètres les moins significatifs en pénalisant la valeur absolue des coefficients  $\theta_j$ . On résoud le problème d'optimisation

$$\max_{\theta \in \mathbb{R}^D} J(\theta) - \lambda \sum_{j=1}^D |\theta_j| \quad \text{avec} \quad \lambda > 0$$

$|\theta_j|$  n'étant pas différentiable on utilise la décomposition suivante

$$\theta_j = \theta_j^+ - \theta_j^- \quad \text{et} \quad |\theta_j| = \theta_j^+ + \theta_j^- \quad \text{avec} \quad \theta_j^+ \geq 0, \theta_j^- \geq 0$$

Posons  $V(\theta^+, \theta^-) = J(\theta^+ - \theta^-) = J(\theta)$ . Le problème d'optimisation devient

$$\begin{aligned} \min_{\theta^+ \in \mathbb{R}^D, \theta^- \in \mathbb{R}^D} \quad & -V(\theta^+, \theta^-) + \lambda \sum_{j=1}^D (\theta_j^+ + \theta_j^-) \\ \text{sous les contraintes} \quad & \theta_j^+ \geq 0 \quad \forall j = 1, \dots, D \\ & \theta_j^- \geq 0 \quad \forall j = 1, \dots, D \end{aligned}$$

3. Ecrire le lagrangien correspondant à ce problème
4. On montre que  $\nabla_{\theta_j^+} V(\theta^+, \theta^-) = \nabla_{\theta_j} J(\theta)$  et  $\nabla_{\theta_j^-} V(\theta^+, \theta^-) = -\nabla_{\theta_j} J(\theta)$ .

En utilisant ce résultat, donner en fonction de  $\nabla_{\theta_j} J(\theta)$  et  $\lambda$  les conditions KKT d'optimalité du lagrangien par rapport à  $\theta_j^+$  et  $\theta_j^-$ ,  $\forall j$ .

5. On veut déterminer sous quelle condition cette méthode peut mettre des coefficients à 0
  - (a) Ecrire les conditions KKT de complémentarité correspondant à ce problème.
  - (b) Montrer que  $\theta_j^+ > 0 \Rightarrow \theta_j^- = 0$ . De même établir que  $\theta_j^- > 0 \Rightarrow \theta_j^+ = 0$ .
  - (c) En déduire alors que pour tout paramètre  $\theta_j \neq 0$  on a la condition  $|\nabla_{\theta_j} J(\theta)| = \lambda$  et que seuls ces paramètres restent

### 3 Coloriage

(3 points)

Les réponses à cet exercice sont à porter sur les graphiques de la feuille 3. Cette feuille est à rendre avec votre copie

On veut regrouper les points représentés sur la feuille 3 en utilisant l'algorithme de K-means avec  $K=2$ . Deux initialisations des centres des clusters vous sont proposées. Les centres initiaux sont les triangles. Détailler sur les figures en annexe chaque itération de l'algorithme jusqu'à convergence pour chaque initialisation.

