

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

## 1 Relay (5 points)

Soit un problème de classification à deux classes dont les données sont  $\{(x_i, y_i) \in \mathbb{R} \times \{\mathcal{C}_1, \mathcal{C}_2\}\}_{i=1}^N$ . On suppose que pour la classe  $\mathcal{C}_1$   $x$  suit une loi normale  $p(x|\mathcal{C}_1) = \mathcal{N}(\mu, \sigma^2)$  et pour  $\mathcal{C}_2$   $x$  suit une loi de Rayleigh  $p(x|\mathcal{C}_2) = \frac{x}{\lambda^2} \exp^{-\frac{x^2}{\lambda^2}}$ .

On suppose que les deux classes sont équiprobables.

1. On veut déterminer les paramètres de la loi de distribution conditionnelle des classes 1 et 2. Estimer les paramètres  $\hat{\lambda}$ ,  $\hat{\mu}$  et  $\hat{\sigma}$  au sens du maximum de vraisemblance.

Pour classer les données avec l'approche de Bayes, on prend des coûts 0-1 suivants.

2. Donner l'expression des risques conditionnels  $R(\mathcal{C}_k|x)$ . Sous quelle condition sur  $P(\mathcal{C}_1|x)$  et  $P(\mathcal{C}_2|x)$  on décide d'affecter  $\mathbf{x}$  à la classe  $\mathcal{C}_1$  ?
3. Donner l'expression de la fonction de décision en fonction de  $x$ , des paramètres  $\hat{\mu}$ ,  $\hat{\sigma}$  et  $\hat{\lambda}$ .

## 2 Un Nu nommé SVM (11 points)

Soit un ensemble de données  $\mathcal{D} = \mathcal{D}_+ \cup \mathcal{D}_-$  avec  $\mathcal{D}_+ = \{(\mathbf{x}_i, y_i = 1)\}_{i=1}^m$  l'ensemble des points avec le label +1 et  $\mathcal{D}_- = \{(\mathbf{x}_i, y_i = -1)\}_{i=m+1}^n$  celui des points de label -1. Chaque point  $\mathbf{x} \in \mathbb{R}^d$ . On veut apprendre une variante de SVM (appelé  $\nu$ -SVM) qui pondère différemment les erreurs sur les classes  $\mathcal{D}_+$  et  $\mathcal{D}_-$ . Le modèle recherché est  $f(\mathbf{x}) = \mathbf{w}^\top \mathbf{x} + b$  avec  $\mathbf{w} \in \mathbb{R}^d$  et  $b \in \mathbb{R}$ . On veut résoudre le problème suivant

$$\min_{\mathbf{w}, b, \rho, \{\xi_i\}} \frac{1}{2} \|\mathbf{w}\|^2 - \nu \rho + \frac{\gamma}{n} \sum_{i=1}^m \xi_i + \frac{1-\gamma}{n} \sum_{i=m+1}^n \xi_i \quad (1)$$

sous les contraintes

$$y_i(\mathbf{w}^\top \mathbf{x}_i + b) \geq \rho - \xi_i \quad \forall i = 1, \dots, n$$

$$\xi_i \geq 0, \quad \forall i = 1, \dots, n$$

$$\rho \geq 0$$

avec  $\rho$  la marge qu'on souhaite maximiser.  $\nu > 0$  et  $0 \leq \gamma \leq 1$  sont des hyper-paramètres fixés par l'utilisateur.

1. Donner le nombre de contraintes du problème
2. Montrer que la fonction (1) à minimiser peut s'écrire sous la forme

$$\frac{1}{2} \|\mathbf{w}\|^2 - \nu \rho + \sum_{i=1}^n C_i \xi_i$$

avec l'expression des coefficients  $C_i$  à spécifier en fonction de  $\gamma, n$ .

3. Écrire le Lagrangien correspondant à ce problème d'optimisation

4. Donner les conditions d'optimalité par rapport aux variables primales  $\mathbf{w}$ ,  $b$ ,  $\xi_k$  ( $\forall k = 1, \dots, n$ ) et  $\rho$ . En déduire l'expression de  $\mathbf{w}$ .
5. Formuler alors le problème dual correspondant.
6. Soit le vecteur  $\alpha^*$ , la solution du problème dual.
  - (a) Comment peut-on reconnaître les points sur la marge à partir de  $\alpha^*$ ? Justifier la réponse.
  - (b) Connaissant ces points, proposer une façon de calculer  $b$  et  $\rho$ .
7. Pour sélectionner le modèle optimal quelqu'un propose la procédure suivante : "on choisit plusieurs valeurs de  $\gamma$ ,  $\nu$  et  $\rho$ , on apprend un modèle pour chaque triplet  $(\gamma, \nu, \rho)$ , on l'évalue sur le jeu d'apprentissage et on retient le modèle donnant la meilleure performance en apprentissage". Est-ce que cette procédure vous semble correcte? Si non que quelle solution vous proposez?

### 3 Regroupement hiérarchique

(4 points)

Le tableau suivant contient la matrice de distances entre six points A, B, C, D, E, F.

	A	B	C	D	E	F
A	0					
B	0.12	0				
C	0.51	0.25	0			
D	.0.84	0.16	0.14	0		
E	0.28	0.77	0.7	0.45	0	
F	0.34	0.61	0.93	0.20	0.67	0

1. Réaliser le clustering de ces données en utilisant la CHA avec une métrique de type *saut minimal*. On dessinera le dendrogramme et on indiquera le résultat du clustering pour  $K = 2$
2. Répondre à la même question en considérant cette fois une métrique de type *saut maximal*.
3. Pour déterminer le nombre de clusters, on envisage les solutions suivantes :
  - faire une validation croisée,
  - Calculer le critère  $J(K) = \sum_{k=1}^K \sum_{i \in \mathcal{C}_k} \|\mathbf{x}_i - \mathbf{c}_k\|^2$  pour différentes valeurs de  $K$  et choisir le nombre de clusters correspondant au minimum de  $J(K)$
 Qu'en pensez-vous? Justifiez vos réponses.