

**TD 2**

---

**Exercice 1 – Exercice 1 : Classifieur bayésien**

---

Soit  $\mathcal{X}$  un ensemble de description dans  $\mathbb{R}^d$  et  $\mathcal{Y}$  l'ensemble des labels  $\{y_1, \dots, y_l\}$ .

**Q 1.1** Rappeler ce qu'est un classifieur bayésien.

**Q 1.2** Exprimer l'erreur faite par le classifieur bayésien à un point  $\mathbf{x}$ . L'erreur est-elle minimale ?

**Q 1.3** Soit  $\lambda(y_j, y_i)$  le coût d'une erreur consistant à prédire le label  $y_j$  plutôt que  $y_i$ . Que valent les  $\lambda$  dans le cas de l'erreur 0-1 ? Donner quelques exemples de coûts asymétrique et des contextes d'utilisation.

**Q 1.4** Quelle est l'expression du risque  $R(y_i|\mathbf{x})$  de prédire  $y_i$  sachant  $\mathbf{x}$  en fonction de  $\lambda$  et des probabilités a posteriori ? Dans le cas 0-1 ?

**Q 1.5** Donner l'expression du risque sur  $\mathcal{X}$  associé au classifieur  $f$ ,  $R(f)$ .

**Q 1.6** On se place dans le cas binaire. Exprimer le critère de décision en fonction de  $\lambda$  et des probabilités a posteriori, puis donner un critère de décision en fonction de  $\lambda$ , la distribution des classes et la vraisemblance.

---

**Exercice 2 – Exercice 2 : Estimation de densité**

---

**Q 2.1** Donner l'estimation de la densité  $p_B$  d'une variable aléatoire  $X$  à l'intérieur d'une région d'intérêt  $B$  de volume  $V$ , en fonction d'un nombre  $k$  d'échantillons observés dans cette zone parmi  $n$  échantillons tirés.

**Q 2.2** Soit une variable aléatoire  $X \in \mathcal{X}$ . On souhaite estimer la densité  $p_X$  de cette variable à partir d'un ensemble d'observations  $\mathcal{X}_o$ . Décrire la manière de procéder pour réaliser cette estimation selon la méthode des histogrammes.

**Q 2.3** Discuter des méthodes d'estimation de densité à noyaux


---

**Exercice 3 – Exercice 3 : Classification selon voisinage**

---

**Q 3.1** Quelle différence entre les fenêtres de Parzen et les  $k$ -nn ? Que vérifie-t-on quand le nombre d'échantillons tend vers l'infini ?

**Q 3.2** Sur l'exemple suivant, tracez la frontière de décision pour  $k = 1$ . Quel problème peut se poser pour des valeurs de  $k$  ?



**Q 3.3** Ajouter un *outlier* en  $(-0.5, -0.5)$ . Comment évolue la frontière ?

**Q 3.4** Et si  $k = 3$ ? Que se passe-t-il quand  $k$  tend vers l'infini ?

**Q 3.5** Soit  $\mathbf{x}$  un exemple à classifier,  $(\mathbf{x}_i)_{i=1}^n$  une suite d'échantillons aléatoires et  $(\mathbf{x}'_j)_{j=1}^n$  la suite extraite de l'ensemble précédent tel que  $\mathbf{x}'_j$  soit le plus proche voisin de  $\mathbf{x}$  à l'étape  $j$  parmi les  $\{\mathbf{x}_i\}$ . Montrer que la séquence  $(\mathbf{x}'_i)_{i=1}^n$  converge vers  $\mathbf{x}$ .

**Q 3.6** Exprimez le risque  $r(\mathbf{x}, \mathbf{x}'_n)$ , la probabilité de faire une erreur de classification sur  $\mathbf{x}$  à l'étape  $n$  en considérant le plus proche voisin  $\mathbf{x}'_n$ , en fonction des  $q_k(\mathbf{x}) = P(y = k|\mathbf{x})$ .

**Q 3.7** Vers quoi converge  $r(\mathbf{x}, \mathbf{x}'_n)$  quand le nombre d'échantillons tend vers l'infini ? Nous noterons  $r(\mathbf{x})$  cette limite.

**Q 3.8** Simplifier l'expression de  $r(\mathbf{x})$ .

**Q 3.9** Montrer que  $r(\mathbf{x}) \leq 2r_b(\mathbf{x})(1 - r_b(\mathbf{x}))$  dans le cas à 2 classes, avec  $r_b(\mathbf{x})$  l'expression du risque bayésien pour  $x$ . Montrer que  $r(\mathbf{x}) \leq r_b(\mathbf{x})(2 - \frac{K}{K-1}r_b(\mathbf{x}))$  dans le cas à  $K$  classes.

Indication : utiliser l'inégalité de Cauchy  $|\sum_{i=1}^n u_i v_i|^2 \leq \sum_{i=1}^n |u_i|^2 \sum_{j=1}^n |v_j|^2$  en l'utilisant sur  $K - 1$   $q_i$  et en choisissant  $v_j = 1$ .