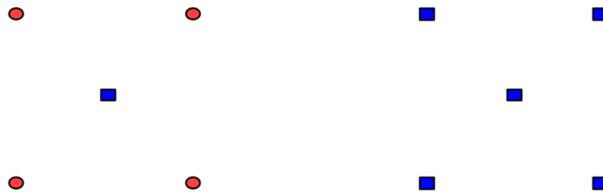


# Introduction au Machine learning : examen

## Exercice 1

On a observé les données suivantes : les features sont dans  $\mathbb{R}^2$  et les labels sont dans {rouge, bleu}.

- Donner les valeurs de l'erreur empirique associée à la perte 0/1 des classifieurs construits par
  - l'algorithme des 1-plus proche voisins (1-NN)
  - l'algorithme des 3-plus proche voisins (3-NN).
- Où mettriez vous le premier "split" d'un arbre de décision ? (vous pouvez le dessiner sur la figure)
- A partir de quelle profondeur a-t-on un arbre d'erreur empirique nulle ?
- Tracer l'hyperplan (ici la droite) associé à l'algorithme linear-SVM.



## Exercice 2

On définit  $r^*$  comme le rectangle  $[l, r] \times [b, t]$ . On considère des données  $\mathcal{D}_n = \{(X_i, Y_i), i = 1, \dots, n\}$  avec des couples features/label  $(X_i, Y_i)$  i.i.d.,  $X_i \in \mathbb{R}^2$  et  $Y_i \in \{1 = \text{rouge}, -1 = \text{bleu}\}$  dont la loi vérifie

$$\mathbb{P}(Y_i = 1 | X_i \in r^*) = 1$$

$$\mathbb{P}(Y_i = 1 | X_i \notin r^*) = 0$$

$$\mathbb{P}(X_i \in r^*) > \epsilon \text{ pour un } \epsilon > 0 \text{ fixé.}$$

On construit un classifieur en se restreignant à la classe des classifieurs indexés par des rectangles  $\{c_r, r = [a, b] \times [c, d], a < b, c < d\}$  et définis par

$$\begin{cases} c_r(x) = 1 & \text{si } x \in r \\ c_r(x) = 0 & \text{si } x \notin r. \end{cases}$$

1. Quelle est l'erreur empirique (associée à la perte 0/1) du rectangle vert dessiné sur la figure 1 que l'on note ici  $\hat{r}$  ?
2. Soit un classifieur  $c_r$ . On considère une nouvelle observation  $(X_+, Y_+)$ . Dans quelle zone du plan doit être  $X_+$  pour que cette observation soit mal classée par le classifieur  $c_r$  ?
3. On définit quatre rectangles  $r_l^*, r_t^*, r_r^*, r_b^*$  ( $l$  pour "left",  $t$  pour "top",  $r$  pour "right" et  $b$  pour "bottom"), les rectangles  $r_l^*, r_t^*$  ont été représentés sur la figure 2. Chacun de ces rectangles vérifie

$$\mathbb{P}(X_+ \in r_k^*) = \epsilon/4 \quad (k \in \{l, t, r, b\}).$$

Montrer que l'erreur de généralisation du classifieur  $c_{r_{\text{minus}}^*}$  associé au rectangle (représenté sur la figure 3)  $r_{\text{minus}}^* = r^* \setminus \cup_{k \in \{l, t, r, b\}} r_k^*$  vérifie

$$R(c_{r_{\text{minus}}^*}) \leq \sum_{k \in \{l, t, r, b\}} \mathbb{P}(X_+ \in r_k^*) = \epsilon.$$

4. On cherche maintenant à borner l'erreur de généralisation de  $c_{\hat{r}}$ .

(a) Montrer que si  $r_{\text{minus}}^* \subset \hat{r}$  alors  $R(c_{r_{\text{minus}}^*}) \geq R(c_{\hat{r}})$ .

(b) En déduire que

$$\mathbb{P}(R(c_{\hat{r}}) > \epsilon) \leq \mathbb{P}(r_{\text{minus}}^* \not\subset \hat{r}).$$

(c) Montrer que

$$\mathbb{P}(r_{\text{minus}}^* \not\subset \hat{r}) \leq \sum_{k \in \{l, t, r, b\}} \mathbb{P}(\hat{r} \cap r_k^* = \emptyset) \leq 4 \left(1 - \frac{\epsilon}{4}\right)^n.$$

(d) Que doit valoir  $n$  pour que le risque de  $c_{\hat{r}}$  dépasse  $\epsilon$  avec une probabilité inférieure à  $\delta > 0$ .

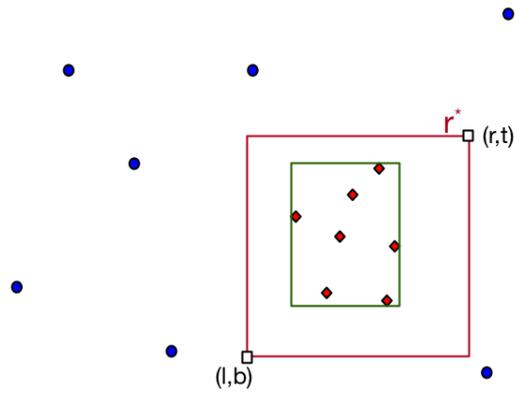


Figure 1  
les données

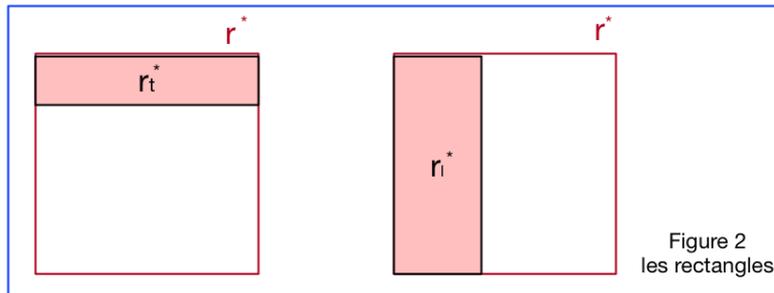


Figure 2  
les rectangles

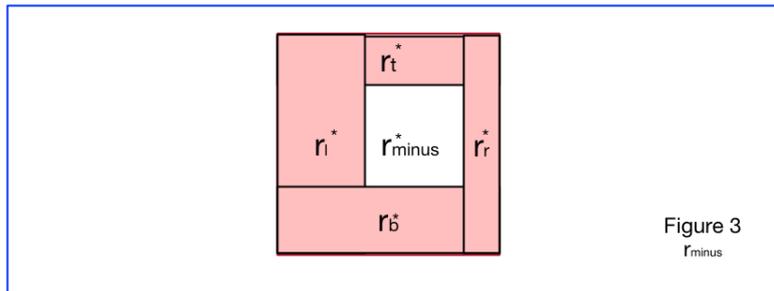


Figure 3  
 $r_{\text{minus}}$