

# Apprentissage statistique: TD 7

## Applications of Stone's Theorem

Emile Contal

<http://econtal.perso.math.cnrs.fr/teaching>

7 mars 2016

### Rappels.

Soit  $Z_m = (U_1, \dots, U_m)$  une suite de variables aléatoires iid et  $x, U \mapsto g_n(x, U)$  un classifieur *randomisé*. On rappelle la définition du *classifieur par votes* :

$$\bar{g}_n(x, Z_m) = \mathbb{1}_{\frac{1}{m} \sum_{j=1}^m g_n(x, U_j) \geq \frac{1}{2}}.$$

On définit également le *classifieur par espérance* :

$$\tilde{g}_n(x) = \mathbb{1}_{\mathbf{E}_U[g_n(x, U)] \geq \frac{1}{2}} = \lim_{m \rightarrow \infty} \bar{g}_n(x, Z_m).$$

**Théorème 1** (Stone, 1977). Soient  $W_{ni}(x)$  des poids positifs dépendants de  $X_1, \dots, X_n$ , tels que  $\sum_{i=1}^n W_{ni}(x) = 1$ . Soit  $(g_n)$  une suite de classifieurs pondérés :

$$g_n = 1 \text{ ssi } \sum_{i=1}^n \mathbb{1}_{Y_i=1} W_{ni}(x) \geq \sum_{i=1}^n \mathbb{1}_{Y_i=0} W_{ni}(x).$$

On a que  $(g_n)$  est universellement consistante lorsque :

- (1) Il existe une constante  $c$  telle que pour toute fonction  $f$  mesurable positive d'espérance finie,  $\mathbf{E}[\sum_{i=1}^n W_{ni}(X) f(X_i)] \leq c \mathbf{E}[f(X)]$ ,
- (2) Pour tout  $a > 0$ ,  $\mathbf{E}[\sum_{i=1}^n W_{ni}(X) \mathbb{1}_{\|X_i - X\| > a}] \rightarrow 0$ ,
- (3)  $\mathbf{E}[\max_{1 \leq i \leq n} W_{ni}(X)] \rightarrow 0$ .

**Lemme 1** (Stone, 1977). Pour toute fonction mesurable  $f$ , tout entiers  $n$  et  $k \leq n$ , il existe une constante  $c_d > 0$  telle que :

$$\sum_{i=1}^k \mathbf{E}[|f(X_{(i)}(X))|] \leq c_d k \mathbf{E}[|f(X)|],$$

avec  $c_d \leq (1 + 2/\sqrt{2 - \sqrt{3}})^d - 1$ .

**Exercice 1. (Consistency by Randomization)**

On se place pour simplifier dans le cas  $d = 1$  et on considère que le support de  $X$  n'est pas atomique. Pour un  $x$  fixé, soient  $X_{(1)}(x), \dots, X_{(n)}(x)$  les points  $X_1, \dots, X_n$  triés selon leur distance à  $x$ , et  $Y_{(1)}(x), \dots, Y_{(n)}(x)$  les données correspondantes. Soient  $U = (U_1, \dots, U_n)$  des variables aléatoires uniformes sur  $[0, 1]$ . On définit une règle du plus proche voisin randomisée comme suit :

$$g_n(x, U) = Y_{(i_U)}(x) \text{ où } i_U = \underset{i}{\operatorname{argmin}} \max(i, mU_i),$$

où  $m \leq n$  est un paramètre.

Soit  $\tilde{g}_n(x) = \mathbf{1}_{\mathbf{E}_U g_n(x, U) \geq 1/2}$  le classifieur par espérance, Montrer que  $\tilde{g}_n$  est consistant lorsque  $m \rightarrow \infty$  et  $\frac{m}{n} \rightarrow 0$ . Vous pourrez utiliser le fait que pour  $X$  indépendant des  $X_i$ ,  $\|X_{(k)}(X) - X\| \rightarrow 0$  avec probabilité 1 lorsque  $\frac{k}{n} \rightarrow 0$ .

**Exercice 2. (Random Forests)**

On suppose que le support de  $\mu$  est  $\mathcal{X} = [0, 1]^d$ . Un *arbre de décision randomisé*  $g_n(x, U)$  est un classifieur qui construit une partition hiérarchique de  $\mathcal{X}$  sous forme d'arbre binaire dont les noeuds correspondent à une partie rectangulaire de  $\mathcal{X}$ . La racine de l'arbre est associée à  $\mathcal{X}$  en entier. A chaque noeud, on découpe le rectangle correspondant en deux sous-rectangles suivant une certaine coordonnée et un certain seuil. L'ensemble des cellules associées aux feuilles maintient en permanence une partition de  $\mathcal{X}$ . Un *arbre de décision purement randomisé* de taille  $k$  est construit en répétant  $k$  fois la procédure :

- choisir une feuille uniformément parmi les feuilles de l'arbre,
- choisir une coordonnée uniformément parmi les  $d$  variables,
- choisir un seuil uniformément dans la longueur du rectangle correspondante,
- découper la feuille suivant la variable et le seuil en deux sous feuilles.

Une *forêt aléatoire* est le classifieur par votes associé à une séquence d'arbres de décision  $(g_n(x, U))_n$ .

Montrer qu'une forêt purement aléatoire est consistante lorsque  $k \rightarrow \infty$  et  $\frac{k}{n} \rightarrow 0$ .