

Apprentissage statistique: TD6
Maximum Likelihood
ℰ Data-Dependant Partitioning

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

20 février 2015

Exercice 1.

Soit (X, Y) et D_n comme précédemment. Soit η_n une estimation de η . On définit la vraisemblance $\ell_n(\eta_n)$ et la log-vraisemblance $\mathcal{L}_n(\eta_n)$ comme suit :

$$\ell_n(\eta_n) = \prod_{i=1}^n \eta_n(X_i)^{Y_i} (1 - \eta_n(X_i))^{1-Y_i},$$
$$\mathcal{L}_n(\eta_n) = \frac{1}{n} \sum_{i=1}^n Y_i \log \eta_n(X_i) + (1 - Y_i) \log (1 - \eta_n(X_i)).$$

Soit \mathcal{F} une famille de fonctions de régression telle que $\eta \in \mathcal{F}$. Le classifieur par maximum de vraisemblance \hat{g}_n est donné par :

$$\hat{g}_n(x) = \mathbb{1}_{\hat{\eta}_n(x) \geq \frac{1}{2}} \text{ où } \hat{\eta}_n = \operatorname{argmax}_{\eta_n \in \mathcal{F}} \mathcal{L}_n(\eta_n).$$

1. Pour les familles suivantes, donner le classifieur \hat{g}_n :

- (a) $\mathcal{F}_1 = \{ \eta = \mathbb{1}_{[a,b]}, -\infty \leq a \leq b \leq \infty \}$
- (b) $\mathcal{F}'_1 = \{ \eta = c \mathbb{1}_{[a,b]}, -\infty \leq a \leq b \leq \infty, c \in [0, 1] \}$
- (c) $\mathcal{F}_2 = \{ \eta = \mathbb{1}_{[a_1, b_1] \times \dots \times [a_d, b_d]}, -\infty \leq a_i \leq b_i \leq \infty \}$
- (d) $\mathcal{F}_3 = \{ \eta(x) = \frac{cx}{1+cx}, x \geq 0, c \geq 0 \}$
- (e) $\mathcal{F}_4 = \{ \eta \text{ est décroissante sur } [0, 1] \}$
- (f) $\mathcal{F}_5 = \{ \eta(x) = \frac{1}{1+\|x-m\|^2}, m \in \mathbb{R}^d \}$
- (g) $\mathcal{F}_6 = \{ \eta(x) = \sin^2(\theta x), \theta \in \mathbb{R} \}$

2. Dire pour ces familles si \hat{g}_n est universellement consistant, soit :

$$\lim \Pr[\hat{g}_n(X) \neq Y \mid D_n] \rightarrow L^*.$$

On pourra utiliser pour certaines le théorème suivant :

Théorème 1 (Consistance et ϵ -entropie). *Soit \mathcal{F} une famille de fonctions de régression, on appelle $N(\epsilon)$ son ϵ -entropie définie comme la cardinalité du plus petit ensemble de fonctions \mathcal{F}_ϵ tel que pour tout η' dans \mathcal{F} il existe η'_L et η'_U dans \mathcal{F}_ϵ avec :*

$$\begin{aligned}\eta'_L &\leq \eta' \leq \eta'_U, \\ \mathbf{E}[\eta'_U(X) - \eta'_L(X)] &\leq \epsilon.\end{aligned}$$

Lorsque $N(\epsilon) < \infty$ pour toute distribution X et $\epsilon > 0$, le classifieur par maximum de vraisemblance est universellement consistant.

Exercice 2. On considère ici les classifieurs par partitionnement de \mathbb{R} où les partitions dépendent des données D_n de façon déterministes suivant la règle $\mathcal{P}_n = \pi_n(D_n)$. Soit la séquence de règles (π_n) , le classifieur associé fonctionne par vote à l'intérieur des cellules. On notera \mathcal{F}_n la famille de toutes les partitions possibles pour la règle π_n : $\mathcal{F}_n = \{\pi_n(D) : D \in (\mathbb{R} \times \{0, 1\})^n\}$. En utilisant le théorème et les lemmes suivants, montrer qu'un classifieur par partitionnement de \mathbb{R} tel que les intervalles contiennent au moins a_n et au plus b_n points, est fortement consistant lorsque $a_n \rightarrow \infty$ et $\frac{b_n}{n} \rightarrow 0$.

Théorème 2 (Consistance forte). *On note $\text{diam}(A) = \sup_{x,y \in A} \|x - y\|$, S_M la boule fermée de rayon M centrée à l'origine, et $\mathcal{P}^{(M)}$ la restriction d'une partition \mathcal{P} à la boule S_M . De même si \mathcal{F} est une collection de partitions, on note $\mathcal{F}^{(M)} = \{\mathcal{P}^{(M)} : \mathcal{P} \in \mathcal{F}\}$. On introduit $\Delta_n(\mathcal{F}^{(M)})$ une mesure de complexité¹ d'une famille de partition. Soient $\mathcal{F}_1, \mathcal{F}_2, \dots$ comme précédemment, si on a :*

$$\begin{aligned}\forall M < \infty, \frac{\log \Delta_n(\mathcal{F}_n^{(M)})}{n} &\rightarrow 0, \\ \forall S_M \text{ et } \gamma > 0, \mu\left(\left\{x : \text{diam}(A_n(x) \cap S_M) > \gamma\right\}\right) &\rightarrow 0 \text{ p.s.},\end{aligned}$$

alors le classifieur associé est fortement consistant.

Lemme 1. *Soit $\mathcal{F}^{(M)}$ une famille de partitions telle qu'il existe une constante N vérifiant pour tout $P^{(M)} \in \mathcal{F}^{(M)}$ que $|P^{(M)}| \leq N$, alors :*

$$\Delta_n(\mathcal{F}^{(M)}) \leq 2^N \Delta_n^*(\mathcal{F}^{(M)}),$$

où $\Delta_n^(\mathcal{F}^{(M)})$ est le nombre maximal de façons de partitionner n points avec des éléments de $\mathcal{F}^{(M)}$.*

Lemme 2. *Soit \mathcal{I} l'ensemble des intervalles de \mathbb{R} , $\sup_{I \in \mathcal{I}} |\mu(I) - \mu_n(I)| \rightarrow 0$ p.s.*

Lemme 3. *Soit H l'entropie binaire, alors $\log \binom{s}{t} \leq sH\left(\frac{t}{s}\right)$.*

¹On ne donne pas sa définition ici mais on pourra la borner en utilisant le Lemme 1. Les plus curieux iront voir le "shatter coefficient" et la "VC dimension".