

Apprentissage statistique: TD2

Apprentissage en Ligne et Théorie des Jeux

Emile Contal

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

11 janvier 2016

Exercice 1.

1. (**Exponential Weighted Average**) On se donne \mathcal{C} une famille de N experts proposant à chaque temps t des prédictions $\{\hat{y}_{t,i}, 1 \leq i \leq N\}$. Soit $\ell : \mathbb{R}^2 \rightarrow [0, 1]$ une fonction de perte, convexe en son premier argument.

Fixons l'horizon T . Nous cherchons à minimiser R_T , notre regret par rapport au meilleur expert :

$$R_T = \sum_{t=1}^T \ell(\hat{y}_t, y_t) - \min_i \sum_{t=1}^T \ell(\hat{y}_{t,i}, y_t)$$

où $(\hat{y}_t)_{t \leq T}$ sont les prédictions de notre stratégie.

On rappelle l'algorithme EWA de paramètre $\eta > 0$:

Algorithm 1: Exponential Weighted Average

```

$$\begin{array}{l} \forall i \leq N, w_{1,i} \leftarrow 1 \\ \mathbf{for} \ t = 1, \dots, T \ \mathbf{do} \\ \quad \left[ \begin{array}{l} \hat{y}_t \leftarrow \frac{\sum_{i=1}^N w_{t,i} \hat{y}_{t,i}}{\sum_{i=1}^N w_{t,i}} \\ w_{t+1,i} \leftarrow w_{t,i} \exp\left(-\eta \ell(\hat{y}_{t,i}, y_t)\right) \end{array} \right. \end{array}$$

```

- (a) Soit $\Phi_t = \log \sum_{i=1}^N w_{t,i}$. Montrer que pour tout $1 < t \leq T$, on a $\Phi_t - \Phi_{t-1} \leq -\eta \ell(\hat{y}_t, y_t) + \frac{\eta^2}{8}$.
Indice : voir les moyennes pondérées comme des espérances, et utiliser l'inégalité de Hoeffding prouvée au TD précédent.
- (b) Montrer que $\Phi_T - \Phi_0 \geq -\eta \min_i \sum_{t=1}^T \ell(\hat{y}_{t,i}, y_t) - \log N$.
- (c) En déduire une borne sur R_T .
- (d) Quel choix de η préconisez vous ?

2. (**Doubling Trick**) L'horizon T est maintenant supposé fini mais inconnu. Soient $(I_k)_{k \in \mathbb{N}}$ la partition de \mathbb{R}^+ définie par les intervalles $I_k = [2^k, 2^{k+1} - 1]$. On considère l'Algorithme 1 de paramètre η_k qui dépend de l'intervalle de temps I_k . On note L_{I_k} la perte subie sur l'intervalle I_k .

- (a) Donner une majoration du regret sur I_k .
- (b) On pose $n = \lceil \log_2(T + 1) \rceil$. Dédurre une majoration de $L_T = \sum_{k=0}^n L_{I_k}$.
- (c) Choisissez η_k de sorte à optimiser la majoration précédente, puis montrer pour tout T :

$$R_T \leq \frac{1}{\sqrt{2} - 1} \sqrt{T \log N} + \frac{1}{\sqrt{2}} \sqrt{\log N}.$$

Exercice 2. (Minimisation du Regret et Théorie des Jeux)

On modélise un jeu à somme nulle en forme normale entre deux joueurs par la matrice des gains $\mathbf{M} \in \mathbb{R}^{m \times n}$, où le premier joueur choisit parmi m actions et le deuxième parmi n actions. Nous étudions le gain espéré des joueurs lorsque leurs stratégies sont aléatoires. La stratégie du premier joueur est définie par \mathbf{p} une distribution sur $\{1, \dots, m\}$ et celle du deuxième joueur par \mathbf{q} une distribution sur $\{1, \dots, n\}$. Le gain espéré du premier joueur est alors $\mathbf{p}^\top \mathbf{M} \mathbf{q}$ et celui du deuxième joueur $-\mathbf{p}^\top \mathbf{M} \mathbf{q}$. Nous souhaitons prouver le théorème du minimax de von Neumann :

$$\min_{\mathbf{p}} \max_{\mathbf{q}} \mathbf{p}^\top \mathbf{M} \mathbf{q} = \max_{\mathbf{q}} \min_{\mathbf{p}} \mathbf{p}^\top \mathbf{M} \mathbf{q}.$$

- 1. Montrer que $\min_{\mathbf{p}} \max_{\mathbf{q}} \mathbf{p}^\top \mathbf{M} \mathbf{q} \geq \max_{\mathbf{q}} \min_{\mathbf{p}} \mathbf{p}^\top \mathbf{M} \mathbf{q}$.
- 2. Pour montrer l'autre inégalité, on considère le cadre d'apprentissage en ligne suivant : à chaque itération t l'algorithme choisit \mathbf{p}_t et paye un coût $\mathbf{p}_t^\top \mathbf{M} \mathbf{q}_t$, où \mathbf{q}_t est donné par un adversaire : $\mathbf{q}_t \in \operatorname{argmax}_{\mathbf{q}} \mathbf{p}_t^\top \mathbf{M} \mathbf{q}$. On rappelle la définition du regret :

$$R_T = \sum_{t=1}^T \mathbf{p}_t^\top \mathbf{M} \mathbf{q}_t - \min_{\mathbf{p}} \sum_{t=1}^T \mathbf{p}^\top \mathbf{M} \mathbf{q}_t,$$

ainsi que l'existence d'algorithmes tels que $R_T = o(T)$.

- (a) Montrer que $\min_{\mathbf{p}} \max_{\mathbf{q}} \mathbf{p}^\top \mathbf{M} \mathbf{q} \leq \frac{1}{T} \sum_{t=1}^T \mathbf{p}_t^\top \mathbf{M} \mathbf{q}_t$.
- (b) Montrer que $\frac{1}{T} \sum_{t=1}^T \mathbf{p}_t^\top \mathbf{M} \mathbf{q}_t \leq \max_{\mathbf{q}} \min_{\mathbf{p}} \mathbf{p}^\top \mathbf{M} \mathbf{q} + \frac{R_T}{T}$.
- (c) En déduire que $\min_{\mathbf{p}} \max_{\mathbf{q}} \mathbf{p}^\top \mathbf{M} \mathbf{q} \leq \max_{\mathbf{q}} \min_{\mathbf{p}} \mathbf{p}^\top \mathbf{M} \mathbf{q}$.