

Introduction à la prédiction de suites individuelles :

(1) Inégalités d'oracle

(2) Prédiction avec information imparfaite.

Par: Gilles Stoltz (CNRS - ENS - HEC)

Au: Groupe de travail statistique, Chevaleret

Les: 12 et 26 novembre 2007.

0. Cadre (suites individuelles, information parfaite).

\mathcal{D} un ensemble convexe = l'espace des décisions du statisticien
égal au simplexe X de \mathbb{R}^N dans les cas les plus simples

Jeu de prédiction : Pour tout $t = 1, 2, \dots,$

- le statisticien choisit $\hat{p}_t \in \mathcal{D}$ (en fonction des infos des tours passés)
- la nature (le diable) choisit $l_t : \mathcal{D} \rightarrow \mathbb{R}$, fonction de perte du tour t (en fonction des infos des tours passés et même en fonction de \hat{p}_t)
- le statisticien et la nature observent \hat{p}_t et l_t ; le statisticien subit une perte $l_t(\hat{p}_t)$.

Ex 1: [Agrégation séquentielle de prédicteurs pour la prévision des pics d'ozone]
Au début du tour t , le statisticien dispose de $f_{1t}^s, \dots, f_{Nt}^s \in [0, B]$
les prédictions de N experts pour le jour t à la station s (se \mathcal{L}).
Il choisit $\hat{p}_t \in X$ (ou $\hat{p}_t \in \mathbb{R}^N$, selon qu'on autorise $\mathcal{D} = \mathbb{R}^N$
pour éventuellement débaisser, ou qu'on se restreint à $\mathcal{D} = X$) et
prédit, au point s , $\hat{y}_t^s = \hat{p}_t \cdot (f_{jt}^s)_{j=1, \dots, N} = \sum_{j=1}^N \hat{p}_{jt} f_{jt}^s$, qu'on
compare au vrai pic y_t^s observé en fin de journée.
Au total,

$$l_t(\hat{p}_t) = \sum_{s \in Y} \left(\hat{p}_t \cdot \left(\frac{p^s}{\hat{p}_t} \right)_{j=1 \dots N} - y_t^s \right)^2.$$

Note: pour les besoins d'interprétabilité, on prend le même \hat{p}_t en toutes les stations $s \in Y$.

Cf. stage M2 Boris Maurice pour les performances pratiques.

Ici, les experts sont N différents modèles physico-chimiques & numériques de propagation des polluants (& statistiques, si besoin).

Df: [regret] $R_n = \sum_{t=1}^n l_t(\hat{p}_t) - \inf_{p \in \mathcal{X}} \sum_{t=1}^n l_t(p)$

On veut $R_n = o(n)$, soit $\lim_{n \rightarrow \infty} R_n/n = 0$;

cf. si les l_t sont uniformément bornées, $R_n = O(n)$ est acquis.

Ex 1 [suite]: Alors, la RMSE du statisticien est proche de la RMSE de la meilleure combinaison convexe / linéaire constante.

Ex 2: [Quand on doit choisir 1 action ou 1 expert parmi un nombre fini d'entre eux, et que l'on ne peut agréger] \rightarrow déplacement dans un graphe.

$\{1, 2, \dots, N\}$ les N actions possibles ou f_{1t}, \dots, f_{Nt} les N avis d'experts

$\mathcal{D} = \mathcal{X}$, on choisit $\hat{p}_t \in \mathcal{X}$ et on tire $I_t \sim \hat{p}_t$; on joue alors

$I_t \in \{1, 2, \dots, N\}$ ou prédit $f_{I_t, t}$.

La perte est $l_t(I_t)$ ou $l_t(f_{I_t, t}) = l_t(I_t)$,

d'espérance conditionnelle (par rapport au choix aléatoire de I_t selon \hat{p}_t):

$$E_t [l_t(I_t)] = \sum_{j=1}^N \hat{p}_{jt} l_t(j)$$

Note: le diable peut observer \hat{p}_t mais pas I_t lorsqu'il choisit l_t .

Regret en espérance conditionnelle:

$$\bar{R}_n = \sum_{t=1}^n \underbrace{\sum_{j=1}^N \hat{p}_{jt} l_t(j)}_{\text{noté } l_t(\hat{p}_t)} - \inf_{p \in \mathcal{X}} \underbrace{\sum_{t=1}^n \sum_{j=1}^N p_j l_t(j)}_{= \min_{i=1, \dots, N} \sum_{t=1}^n l_t(i)} \quad 2.$$

Kerandomisation
↑
auxiliaire
↓

Est proche (inégalité de Hoeffding - Azuma) du regret inconditionnel

$$R_n = \sum_{t=1}^n l_t(I_t) - \min_{i=1, \dots, N} \sum_{t=1}^n l_t(i)$$

à un facteur $M \sqrt{\frac{n}{2} \ln \frac{1}{\delta}}$ près, avec probab. $1-\delta$ (où M est l'étendue max. des l_t : $M \geq \max_{t=1, \dots, n} (\max_j l_t(j) - \min_i l_t(i))$).

Note: si $l_t = l(\cdot, y_t)$, les bornes sur \bar{R}_n donnent aussi des bornes sur l'espérance du regret ER_n (si X_t aléatoires), voir § sur inégalité oracle.

Lorsque $\bar{R}_n = o(n)$, par H-Az & Borel - Cantelli, on a également $R_n = o(n)$ p.s.

C'est donc pour ces 2 raisons que l'on s'intéressera à \bar{R}_n .

1. Premiers résultats (information parfaite, suites individuelles, $\mathcal{D} = \mathcal{X}$ simplexe).

1.1. Cas de l'Ex2 ($\mathcal{D} = \mathcal{X}$ et l_t linéaire $\mathcal{X} \rightarrow \mathbb{R}$): LINÉAIRE.

$$l_t(p) = \sum_{j=1}^N p_j l_t(j) \quad \text{où } p \in \mathcal{D} = \mathcal{X}$$

$$M \geq \max_{t=1, \dots, n} (\max_j l_t(j) - \min_i l_t(i)) \quad (*) \quad \text{mais pas d'hyp. de signe (pour l'instant)}$$

horizon n

1.1.1. Cas où M et n sont connus.

Stratégie : $\hat{p}_1 = (\frac{1}{N}, \dots, \frac{1}{N})$ probabilité uniforme

$$\text{et } \hat{p}_t = \frac{\exp(-\eta \sum_{s=1}^{t-1} l_s(j))}{\sum_{i=1, \dots, N} \exp(-\eta \sum_{s=1}^{t-1} l_s(i))} \quad \uparrow \quad \hat{p}_{j, t-1} \frac{e^{-\eta l_{t-1}(j)}}{\text{normalisation}}$$

implémentation aisée!

$\eta > 0$ donné par le Th.

(Sources: Littlestone & Warmuth '94, Vovk '90 puis Cesa-Bianchi et al. '97, etc.)

Th: Pour $\eta = \frac{1}{M} \sqrt{8 \ln N / m}$, on a
$$R_n = \sum_{t=1}^n \ell_t(\hat{p}_t) - \min_{i=1, \dots, N} \sum_t \ell_t(i) \leq M \sqrt{\frac{n}{2} \ln N}$$

et par conséquent, avec proba $\geq 1 - \delta$,

$$R_n \leq M \sqrt{\frac{n}{2} \ln N} + M \sqrt{\frac{n}{2} \ln 1/\delta}.$$

preuve:

$$W_t = \sum_{i=1}^N w_{it} \quad \text{ou} \quad \begin{cases} w_{it} = \exp\left(-\eta \sum_{s=1}^t \ell_s(i)\right), & t \geq 1 \\ w_{i0} = 1 \end{cases}$$

de sorte que

$$\hat{p}_{jt} = \frac{w_{jt}}{W_t}.$$

D'une part,
$$\ln \frac{W_n}{W_0} = \ln \left(\sum_j \exp\left(-\eta \sum_{s=1}^n \ell_s(j)\right) \right) - \ln N \geq \ln \left(\max_j \dots \right) - \ln N = -\eta \min_{j=1, \dots, N} \sum_{s=1}^n \ell_s(j) - \ln N$$

D'autre part, pour tout $t \geq 1$,

$$\begin{aligned} \ln \frac{W_t}{W_{t-1}} &= \ln \frac{\sum_{j=1}^N w_{jt-1} \cdot e^{-\eta \ell_t(j)}}{W_{t-1}} \\ &= \ln \sum_{j=1}^N \hat{p}_{jt} e^{-\eta \ell_t(j)} = \ln \mathbb{E}[e^{-\eta \dots}] \\ &\stackrel{\text{(lemme Hoeffding)}}{\leq} -\eta \mathbb{E}[\dots] + \frac{\eta^2}{8} M^2 \\ &= -\eta \underbrace{\sum_{j=1}^N \hat{p}_{jt} \ell_t(j)}_{\ell_t(\hat{p}_t)} + \frac{\eta^2}{8} M^2 \end{aligned}$$

Soit, en sommant sur $t=1, \dots, n$ et en combinant avec la borne inf. :

$$-\eta \min_{j=1, \dots, N} \sum_{s=1}^n \ell_s(j) - \ln N \leq -\eta \sum_{t=1}^n \ell_t(\hat{p}_t) + \frac{\eta^2}{8} M^2 \quad 4.$$

$$\text{soit } \sum_{t=1}^n \ell_t(\hat{p}_t) - \min_{j=1, \dots, N} \sum_{t=1}^n \ell_t(j) \leq \frac{\ln N}{\eta} + \eta \frac{M^2 n}{8}$$

et il suffit d'optimiser en η . (forme à retenir)

Rq1 [optimalité minimax]

$$\text{On a: } \sup \bar{R}_n \leq M \sqrt{\frac{n}{2} \ln N}$$

↑ sur les stratégies de choix séquentiel des ℓ_t tq. (*)

Et on peut montrer (cf. Cesa-Bianchi et al. '97) que

$$\lim_{N \rightarrow +\infty} \lim_{n \rightarrow +\infty} \left(\frac{\inf_{\text{stratégies statistiques}} \sup_{\text{strat. diable tq. (*)}} \bar{R}_n}{\sqrt{\frac{n}{2} \ln N}} \right) \geq 1, \text{ donc } = 1.$$

Éléments de preuve: on le fait pour $E[\bar{R}_n]$ en considérant un diable qui choisit $\ell_t(j) = j^{\text{ème}}$ composante du développement dyadique de y_t et sélectionne ensuite y_1, \dots, y_n, \dots iid $\sim \mathcal{U}[0,1]$. Or,

$$E[\bar{R}_n] = \underbrace{E\left[\sum_{t=1}^n \ell_t(\hat{p}_t)\right]}_{= \frac{n}{2}} - E\left[\min_j \sum_{t=1}^n \ell_t(j)\right]$$

N v.a. iid. $\sim \text{Bin}(n, \frac{1}{2})$, donc

$$E[\] = \frac{n}{2} - (1 + o(1)) \sqrt{\frac{n}{2} \ln N}$$

où \sqrt{n} vient du TCL, et $\sqrt{\ln N}$ du fait

$$\text{que } E\left[\min_{j=1, \dots, N} Z_j\right] \sim -\sqrt{2 \ln N} \text{ lorsque } Z_j \text{ iid } \sim \mathcal{U}(0,1)$$

On fera une autre preuve (par FANO) donnant un résultat non-asymptotique (valant pour tous n, N) dans le cadre plus général de la prédiction économe en observations.

Rq2: on n'est pas obligé d'utiliser des poids exp., des poids polynômiaux marchent bien également...

1.1.2. Adaptation en n , M connu.

$$\hat{p}_{jt} = \frac{\exp(-\eta_t \sum_{s=1}^{t-1} \ell_s(j))}{\sum_{i=1}^N \exp(-\eta_t \sum_{s=1}^{t-1} \ell_s(i))}$$

$$\bar{\Phi}(\hat{p}_t, \eta_t, \ell_t)$$

$$= \frac{1}{\eta_t} \ln \left(\sum_{i=1}^N \hat{p}_{it} e^{\eta_t (\ell_t(\hat{p}_t) - \ell_t(i))} \right)$$

ie, $\eta = \eta_t$ dépend du passé.

(Première occurrence de ce genre de mise à jour des poids: Auer, Cesa-Bianchi & Gentile '02).

Cesa-Bianchi & Lugosi '06; Cesa-Bianchi, Nannou & Stoltz '05, '07 & Gentile '02).

Lm: Pour toute stratégie de choix des ℓ_t et toute stratégie de choix des η_t tq. $\eta_t \downarrow$, la pondération par poids exponentiels sur les η_t est telle que le regret conditionnel est borné par

$$\bar{R}_n \leq \left(\frac{2}{\eta_{n+1}} - \frac{1}{\eta_1} \right) \ln N + \sum_{t=1}^n \bar{\Phi}(\hat{p}_t, \eta_t, \ell_t).$$

(où $\eta_1 \geq \eta_2$

est quelconque).

Note: aucune hypothèse sur le signe des pertes pour l'instant!

Lm: $\bar{\Phi}(\hat{p}_t, \eta_t, \ell_t) \leq \frac{\eta_t}{8} M^2$ (par lemme de Hoeffding).

Th: Pour $\eta_t = \frac{1}{M} \sqrt{\frac{8 \ln N}{t-1}}$ ($t \geq 2$), on a:

$$\bar{R}_n \leq M \left(2 \sqrt{\frac{1}{2} \ln N} + 1 \right).$$

1.1.3. Adaptation en n et M ; bornes plus fines ("data-dependent").

Lm: si $\ell_t \geq 0$, alors $\bar{\Phi}(\hat{p}_t, \eta_t, \ell_t) \leq \eta_t \sum_{i=1}^N \hat{p}_{it} \frac{\ell_t(i)^2}{2}$.

preuve: $e^{-x} \leq 1 - x + \frac{x^2}{2}$ pour $x \geq 0$, et $\ln(1+u) \leq u$, soit

$$\ln \left(\prod_{i=1}^N \hat{P}_t e^{-\eta_t l_t(i)} \right) \leq \ln \left(\prod_{i=1}^N \hat{P}_t \left(1 - \eta_t l_t(i) + (\eta_t l_t(i))^2 / 2 \right) \right)$$

$$\leq -\eta_t l_t(\hat{P}_t) + \eta_t^2 \sum_{i=1}^N \hat{P}_t l_t(i)^2 / 2$$

et $\Phi(\quad) = \frac{1}{\eta_t} \ln \left(\prod_{i=1}^N \hat{P}_t e^{-\eta_t (l_t(i) - l_t(\hat{P}_t))} \right) \leq \eta_t \sum_{i=1}^N \hat{P}_t (l_t(i))^2 / 2.$

En appliquant un lemme de la page 6: si les $l_t \geq 0$,

$$\bar{R}_n \leq \frac{2}{\eta_{0n}} \ln N + \sum_{t=1}^n \eta_t \sigma_t^2$$

et on a alors le théorème:

$$\text{où } \sigma_t^2 \triangleq \sum_{i=1}^N \hat{P}_t (l_t(i))^2 / 2$$

Th: Pour $\eta_t = \square \sqrt{\frac{\ln N}{\sum_{s=1}^{t-1} \sigma_s^2}}$, et sous la seule hyp de pertes $l_t \geq 0$,

$$\bar{R}_n \leq \square \sqrt{\left(\sum_{t=1}^n \sigma_t^2 \right) \ln N} + \dots$$

et par conséquent,

$$\bar{R}_n \leq \square \sqrt{M_n \left(\min_{j=1, \dots, N} \sum_{t=1}^n l_t(j) \right) \ln N} + \dots$$

où $M_n = \max_{t \leq n} \max l_t.$

Rq1: Cette borne implique en particulier des vitesses de convergence plus rapides que \sqrt{n} (p.ex., quand (M_n) bornée et

$$\min_{j=1, \dots, N} \sum_{t=1}^n l_t(j) \ll n, \text{ quand au moins 1 expert est bon.}$$

preuve: * suffit de voir que $\sum_t \eta_t \sigma_t \leq \square \sqrt{\left(\sum_{t=1}^n \sigma_t^2 \right) \ln N} :$

$$S_t = \sum_{s=1}^t \sigma_s^2 : \quad \sum_{t=1}^n \eta_t \sigma_t^2 = \square \sum_{t=1}^n \frac{\sqrt{\ln N}}{\sqrt{S_{t-1}}} (S_t - S_{t-1})$$

$$= \square \sum_{t=1}^n \frac{\sqrt{\ln N}}{\sqrt{S_{t-1}}} (\sqrt{S_t} - \sqrt{S_{t-1}}) (\sqrt{S_t} + \sqrt{S_{t-1}})$$

$$\leq \square \left(\sum_{t=1}^n \sqrt{S_t} - \sqrt{S_{t-1}} \right) \sqrt{\ln N} + \dots = \square \sqrt{S_n \ln N}.$$

* Puis,
$$\sum_{t=1}^n \sigma_t^2 \leq \frac{M_n}{2} \sum_{t=1}^n \hat{p}_t l_t(i) = \frac{M_n}{2} \sum_{t=1}^n l_t(\hat{p}_t)$$
 ↑
 chaque $l_t(i)^2 \leq M_n$

soit
$$\bar{R}_n = \sum_{t=1}^n l_t(\hat{p}_t) - \min_{j=1, \dots, N} \sum_{t=1}^n l_t(j)$$

$$\leq \sqrt{M_n \left(\sum_{t=1}^n l_t(\hat{p}_t) \right) \ln N}$$

et le résultat en résolvant l'inéquation en $\sum_{t=1}^n l_t(\hat{p}_t)$.

Rq2: Si l_t ont un signe arbitraire, on a le même résultat au genre de résultats totalement adaptatifs et raffinés ($M_n = \max_{t \leq n} \max l_t - \min l_t$) voir Corollaire Bianchi, Mansour & Stoltz '05, '07.

1.2. Cas plus général ($\mathcal{D} = \mathcal{X}$ et l_t convexe $\mathcal{D} \rightarrow \mathbb{R}$): CONVEXE.

On peut se ramener au cas du § 1.1 en linéarisant par l'inégalité des pentes :

$$l_t(\hat{p}_t) - l_t(p) \leq \nabla l_t(\hat{p}_t) \cdot (\hat{p}_t - p)$$

où ∇l_t est un sous-gradient de l_t au point (intérieur, cf. ci-dessous, mise à jour par poids exponentiels) \hat{p}_t .

En particulier,
$$R_n = \sum_{t=1}^n l_t(\hat{p}_t) - \inf_{p \in \mathcal{X}} \sum_{t=1}^n l_t(p)$$

$$\leq \sup_{p \in \mathcal{X}} \sum_{t=1}^n \nabla l_t(\hat{p}_t) \cdot (\hat{p}_t - p)$$

linéaire en p : sup atteint en 1

$$= \sum_{t=1}^n \sum_{j=1}^N \hat{p}_{tj} \tilde{l}_t(j) - \min_{i=1, \dots, N} \sum_{t=1}^n \tilde{l}_t(i)$$

(où $\tilde{l}_t(j) = (\nabla l_t(\hat{p}_t))_j$, j -ème composante du sous-gradient)

$$= \sum_{t=1}^n \tilde{l}_t(\hat{p}_t) - \min_{i=1, \dots, N} \sum_{t=1}^n \tilde{l}_t(i),$$

ce qui est exactement le cadre du § précédent: on utilise des poids exponentiels, $\hat{p}_{tj} \propto \prod_{s=1}^t \tilde{l}_s(j)$.

On retrouve donc les mêmes bornes (à peu de choses près : p.ex., l'étendue M_n est calculée sur les sous-gradients et pas directement sur les points).

Ref. Kivinen & Warmuth '97, Cesa-Bianchi '99
+ un peu de travail / simplifications de ma part.

1.3. Autre cas de vitesses rapides ($\mathcal{D} = \mathcal{X}$ et $l_t: \mathcal{X} \rightarrow \mathbb{R}$ exp-concave):

EXP-CONCAVE.

Df. [Haussler, Kivinen & Warmuth '95, '98, p.ex.;
mais des références antérieures semblent exister.]

l_t est η -exp concave si $e^{-\eta l_t(\cdot)}$ est concave.
($\eta > 0$)

Ex. $l_t(p) = \sum_{s \in \mathcal{Y}} (p \cdot (f_{jt}^s)_{j=1, \dots, N} - y_t^s)^2$ Ex. $l_t(p) = -\log p \cdot \eta$
marché boursier.

sous des hypothèses de bornitude des y_t^s et f_{jt}^s , les l_t sont
toutes η_0 -exp concaves pour η_0 suffisamment petit (et qu'il n'est
pas difficile d'expliciter).

Th. * (1) Si l_t est η_0 -exp concave, alors le prédicteur par poids exponentiels
utilisant $\eta = \eta_0$ indépendamment de t ,

$$\hat{p}_{jt} = \frac{\exp(-\eta_0 \sum_{s=1}^{t-1} l_s(j))}{\sum_{i=1}^N \exp(-\eta_0 \sum_{s=1}^{t-1} l_s(i))},$$

vérifie :

$$\sum_{t=1}^n l_t(\hat{p}_t) - \min_{j=1, \dots, N} \sum_{t=1}^n l_t(j) \leq \frac{\ln N}{\eta_0}.$$

* (2) Si l_t est η_0 -exp concave, alors le prédicteur effectuant un
mélange exponentiel sur le simplexe,

$$\hat{p}_t = \frac{\int_{\mathcal{X}} p \exp(-\eta_0 \sum_{s=1}^{t-1} l_s(p)) d\mu(p)}{\int_{\mathcal{X}} \exp(-\eta_0 \sum_{s=1}^{t-1} l_s(p)) d\mu(p)}$$

où μ est la mesure uniforme sur le simplexe, vérifie :

$$R_n = \sum_{t=1}^n \ell_t(\hat{p}_t) - \inf_{p \in X} \sum_{t=1}^n \ell_t(p) \leq \square N \ln n.$$

- Rq:
- problème d'implémentation pratique (Cover et co. pour marché boursier)
 - réf. : Cover '91 pour (1) et $\ell_t = -\log(\cdot r_t)$
Blum & Kalai '97 pour (2) et $\ell_t = -\log(\cdot r_t)$
Stoltz (thèse) '05 pour (2) en général.
 - optimalité : oui au sens des suites individuelles, cf. Ordentlich & Cover '98.

Preuve (juste de (1)) : Par récurrence; pour tout j ,

celle de (2) est un peu du même acabit.

$$\begin{aligned} & \sum_{t=1}^n \ell_t(\hat{p}_t) - \sum_{t=1}^n \ell_t(j) \\ &= -\frac{1}{\eta_0} \ln \frac{\exp(-\eta_0 \sum_{t=1}^{n-1} \ell_t(\hat{p}_t)) \cdot \exp(-\eta_0 \ell_n(\hat{p}_n))}{\exp(-\eta_0 \sum_{t=1}^n \ell_t(j))} \end{aligned}$$

\leq

au num. : exp. conc.
au dénom. : majoration par Σ

$$-\frac{1}{\eta_0} \ln \frac{\exp(-\eta_0 \sum_{t=1}^{n-1} \ell_t(\hat{p}_t)) \sum_{i=1}^N \hat{p}_{jn} \exp(-\eta_0 \ell_n(i))}{\sum_{i=1}^N \exp(-\eta_0 \sum_{t=1}^n \ell_t(i))}$$

$$= -\frac{1}{\eta_0} \ln \frac{\exp(-\eta_0 \sum_{t=1}^{n-1} \ell_t(\hat{p}_t))}{\sum_{i=1}^N \exp(-\eta_0 \sum_{t=1}^{n-1} \ell_t(i))} \cdot \frac{\sum_{i=1}^N \hat{p}_{jn} e^{-\eta_0 \ell_n(i)}}{\sum_{i=1}^N \exp(-\eta_0 \sum_{t=1}^n \ell_t(i))}$$

et on continue la réc.

= 1 par def. des \hat{p}_{jn}

$$\leq \dots \leq -\frac{1}{\eta_0} \ln \frac{1}{N} = \frac{\ln N}{\eta_0}$$

2. Obtention d'inégalité oracle

Ref: Littlestone & Warmuth '89
Cesa-Bianchi, Conconi & Gentile '04 et '05
Juditzky, Nazin, Tsybakov, Györfi '05, etc.

Cadre: z_1, \dots, z_n iid $\sim \nu$ (sur un espace \mathcal{Z} arbitraire)
Ensemble de paramètres $\theta \in \Theta$, disons $\Theta = \mathcal{X}$ (voir §3 pour des Θ plus gros)
Fonction de perte fixée $Q: \Theta \times \mathcal{Z} \rightarrow \mathbb{R}$

But: Trouver $\bar{\theta}_n = \bar{\theta}_n(z_1^n)$ tq.
$$E_{\nu} [Q(\bar{\theta}_n, z)] \leq \inf_{\theta \in \Theta} E_{\nu} [Q(\theta, z)] + \Delta_n$$

où $\Delta_n = o(n)$

et $z \sim \nu$ indép. des z_1^n (l'espérance E_{ν} est prise par rapport à z et aux z_1^n).

Méthode: Faire comme si les z_1^n étaient disponibles uniquement séquentiellement,
c'est-à-dire, $\hat{\theta}_t = \hat{\theta}_t(z_1^{t-1})$ avec les expressions en termes de poids exp. des pertes cumulés, puis $\bar{\theta}_n = \frac{1}{n} (\hat{\theta}_1 + \dots + \hat{\theta}_n)$.

Ex: $l_t = Q(\cdot, z_t)$ hyp: $Q(\cdot, z)$ convexe sur \mathcal{X} pour tout $z \in \mathcal{Z}$.
$$\hat{\theta}_t = \frac{\exp(-\eta_t \sum_{s=1}^{t-1} (\nabla Q(\hat{\theta}_s, z_s))_j)}{\text{normalisation}}$$
 où (η_t) bien choisie de manière adaptative

est une suite tq.

$$\begin{aligned} \text{ps } R_n &= \sum_{t=1}^n Q(\hat{\theta}_t, z_t) - \inf_{\theta \in \mathcal{X}} \sum_{t=1}^n Q(\theta, z_t) \\ &\leq \sqrt{\left(\sum_{t=1}^n \hat{\theta}_t (\nabla Q(\hat{\theta}_t, z_t))_j^2 \right) \ln N} + \dots \\ &\leq \sqrt{\left(\sum_{t=1}^n \|\nabla Q(\hat{\theta}_t, z_t)\|_{\infty}^2 \right) \ln N} + \dots \end{aligned}$$

cf. th. page 7
Cesa-Bianchi, Mansour & Stoltz '05, '07 montrent qu'il est OK même en cas de fonctions de perte à signe quelconque.

L'inégalité valant p.s., on peut l'intégrer: on utilise que $(\hat{\theta}_t, z_t) \stackrel{(d)}{=} (\hat{\theta}_t, z)$
d'où: $E[Q(\hat{\theta}_t, z_t)] = E[Q(\hat{\theta}_t, z)]$ M.

$$\begin{aligned}
\mathbb{E}[R_n] &= \mathbb{E}\left[\sum_t \dots\right] - \mathbb{E}\left[\inf_{\theta \in \mathcal{X}} \sum_t \dots\right] \\
&\geq \mathbb{E}\left[\sum_{t=1}^n Q(\hat{\theta}_t, z_t)\right] - \inf_{\theta \in \mathcal{X}} \mathbb{E}\left[\sum_{t=1}^n Q(\theta, z_t)\right] \\
&\geq n \left(\mathbb{E}[Q(\bar{\theta}_n, z)] - \inf_{\theta \in \mathcal{X}} \mathbb{E}[Q(\theta, z)] \right)
\end{aligned}$$

Q convexe,
Jensen.

$$\begin{aligned}
\text{et } \mathbb{E}[R_n] &\leq \square \mathbb{E}\left[\sqrt{\left(\sum_{t=1}^n \|\nabla Q(\hat{\theta}_t, z_t)\|_\infty^2\right) \ln N}\right] + \dots \\
&\stackrel{\text{Jensen}}{\leq} \square \sqrt{\left(\sum_{t=1}^n \mathbb{E}\left[\|\nabla Q(\hat{\theta}_t, z_t)\|_\infty^2\right]\right) \ln N} + \dots \\
&= \mathbb{E}\left[\|\nabla Q(\hat{\theta}_t, z)\|_\infty^2\right] \\
&\leq \sup_{\theta \in \mathcal{X}} \mathbb{E}\left[\|\nabla Q(\theta, z)\|_\infty^2\right] \\
&\quad \text{passer par esp. cond. } t \text{ à } z^{t-1}
\end{aligned}$$

Soit au final,

$$\begin{aligned}
&\mathbb{E}[Q(\bar{\theta}_n, z)] - \inf_{\theta \in \mathcal{X}} \mathbb{E}[Q(\theta, z)] \\
&\leq \square \sqrt{\frac{\ln N}{n}} \sup_{\theta \in \mathcal{X}} \mathbb{E}\left[\|\nabla Q(\theta, z)\|_\infty^2\right] + \dots \quad (***)
\end{aligned}$$

où la borne est obtenue pour une procédure totalement adaptative.

À comparer au Th2 de Juditzky et al. '05 : c'est le même résultat à la constante \square près. Je crois me souvenir qu'elle est meilleure chez Juditzky et al. '05, qui fait une preuve directe (pour le même algo, au choix des η_t près) du résultat final et n'a pas de borne ps. intermédiaire, qui retiens-les, et beaucoup plus forte.

Q: Dans Juditzky et al. '05, voir si

(**) était obtenue de manière totalement adaptative ou pas? (Je ne me souviens plus, pour la question pendant l'exposé.)

3. Breve introduction au cas où \mathcal{D} est plus gros que le simplexe \mathcal{X} .

Rq: si perte $(\cdot)^2$, il existe une technique ad hoc pour être compétitif face à $\mathcal{D} = B_{1-n}(0, U)$ où $U > 0$ fixé, voir Kivinen & Warmuth '97.

Dans le cas général, on peut s'inspirer de Stoltz & Lugosi '07, Stoltz (thèse '05); voir aussi Vovk '07:

hyp (si on veut des vitesses de convergence uniformes):

- \mathcal{D} convexe et compact;
- perte de la forme $Q: \mathcal{D} \times \mathcal{Z} \rightarrow \mathbb{R}$ où les $Q(\cdot, z)$ sont convexes et uniformément Lipschitziennes (constante δ).

* À horizon n fixé, étant donné $\varepsilon > 0$ paramètre de couverture:

$d_1, \dots, d_{N(\varepsilon)}$ un " ε -covering" de \mathcal{D}

ie, tout point de \mathcal{D} est à ε près d'un d_j pour la métrique de \mathcal{D}

ainsi,

$$\inf_{d \in \mathcal{D}} \sum_{t=1}^n Q(d, z_t) \geq \min_{j=1, \dots, N(\varepsilon)} \sum_{t=1}^n Q(d_j, z_t) - \delta n \varepsilon$$

il suffit de se comparer à $\min_{j=1, \dots, N(\varepsilon)} \sum_{t=1}^n Q(d_j, z_t)$, ce que l'on peut faire en employant les techniques du §1 (on se ramène au simplexe de $\mathbb{R}^{N(\varepsilon)}$):

$$\hat{d}_t = \sum_{j=1, \dots, N(\varepsilon)} \hat{p}_{jt} d_j$$

où $\hat{p}_{jt} = \exp(-\eta_t \sum_{s=1}^{t-1} Q(d_j, z_s)) / \text{renormalisation}$ de sorte que, pour

$$\begin{aligned} \sum_{t=1}^n Q(\hat{d}_t, z_t) &= \min_{i=1, \dots, N(\varepsilon)} \sum_{t=1}^n Q(d_i, z_t) \leq \sum_{t=1}^n \sum_{j=1}^{N(\varepsilon)} \hat{p}_{jt} Q(d_j, z_t) = \min_{i=1, \dots, N(\varepsilon)} \sum_{t=1}^n Q(d_i, z_t) \\ &\leq \| \nabla Q \|_n \sqrt{n \ln N(\varepsilon)} \end{aligned}$$

soit au final,

$$\sum_{t=1}^n Q(\hat{d}_t, z_t) - \inf_{d \in \mathcal{D}} \sum_{t=1}^n Q(d, z_t) \leq \underbrace{\| \nabla Q \|_a \sqrt{n \ln N(\varepsilon)}}_{\text{terme regret}} + \underbrace{\delta n \varepsilon}_{\text{terme approx.}}$$

* On en déduit une borne uniforme en partitionnant le temps

$1, 2, \dots, n, \dots$

en régimes R_r , $r=1, 2, \dots$. Au début de chaque régime, on fait repartir l'algo précédent avec ε_r et pour une durée L_r .

Soit r_n le régime dans lequel se situe n :

$$\begin{aligned} R_n &= \sum_{t=1}^n Q(\hat{d}_t, z_t) - \inf_{d \in \mathcal{D}} \sum_{t=1}^n Q(d, z_t) \\ &\leq \sum_{r=1, \dots, r_n} \underbrace{\sum_{t \in R_r} Q(\hat{d}_t, z_t) - \inf_{d \in \mathcal{D}} \sum_{t \in R_r} Q(d, z_t)}_{\leq \| \nabla Q \|_a \sqrt{L_r \ln N(\varepsilon_r)} + \delta L_r \varepsilon_r} \\ &\leq \sum_{r=1, \dots, r_n} \| \nabla Q \|_a \sqrt{L_r \ln N(\varepsilon_r)} + \delta L_r \varepsilon_r. \end{aligned}$$

↑ c'est typiquement $o(n)$:

le choix précis de

L_r, ε_r etc. est à faire

dans chaque cas particulier,

voir 1 ex. dans Stoltz & Lugosi '07

(\mathcal{D} = ensemble des fonctions

Lipsch. de cste $\leq C$ fixe).

- $\sum L_r = n$ mais comme $\varepsilon_r \rightarrow 0$,

$\sum L_r \varepsilon_r = o(n)$

- $\sum \sqrt{L_r} \sim \sqrt{n}$ pour $L_r = 2^r$ p.ex.

et donc souvent, $\sum \sqrt{L_r \ln N(\varepsilon_r)} = o(n)$

si \mathcal{D} n'est pas trop massif.

Rq : là, on a uniformité en $d \in \mathcal{D}$. Si l'on veut juste

$$\forall d \in \mathcal{D}, \quad \sum_{t=1}^n Q(\hat{d}_t, z_t) - \sum_{t=1}^n Q(d, z_t) = o(n),$$

alors des hyp. d'absolue continuité de Q et de séparabilité de \mathcal{D} suffisent.

Partie 2: INFORMATION IMPARFAITE.

0. Résumé de l'épisode précédent (de la partie 1), pour le cas de l'agrégation linéaire.

Le statisticien a un nombre fini d'actions $\{1, \dots, N\}$ et il est autorisé à utiliser des actions randomisées : il choisit à chaque tour $\hat{p}_t \in \mathcal{D}$ (qui est le simplexe \mathcal{X} de \mathbb{R}^N) puis tire son action $I_t \in \{1, \dots, N\}$ selon \hat{p}_t .

Jeu de prédiction : Pour tout $t = 1, 2, \dots$

- le statisticien choisit $\hat{p}_t \in \mathcal{X}$ (en fonction des infos des tours passés);
- le diable choisit $\underline{l}_t = (l_{jt})_{j=1, \dots, N} \in \mathbb{R}^N$, vecteur des pertes (en fonction des infos des tours passés et même en fonction de \hat{p}_t);
- le statisticien tire $I_t \sim \hat{p}_t$ et subit la perte $l_{I_t, t}$;
- le statisticien et le diable observent I_t et \underline{l}_t .

But : Avoir un regret (inconditionnel) faible :

$$\begin{aligned} R_n &= \sum_{t=1}^n l_{I_t, t} - \min_{j=1, \dots, N} \sum_{t=1}^n l_{jt} \\ &= \sum_{t=1}^n l_{I_t, t} - \min_{p \in \mathcal{X}} \sum_{t=1}^n p \cdot \underline{l}_t \end{aligned}$$

Moyen : Considérer le regret conditionnel : $\bar{R}_n = \sum_{t=1}^n \hat{p}_t \cdot \underline{l}_t - \min_{p \in \mathcal{X}} \sum_{t=1}^n p \cdot \underline{l}_t$

En effet : soit \mathbb{E}_t l'espérance conditionnelle

par rapport à l'inf disponible au début du tour t (ie, par