

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

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

rapport aux $(\hat{p}_s, I_s, \underline{l}_s)_{s=1, \dots, t-1}$. \mathbb{E}_t fixe \hat{p}_t et \underline{l}_t , le seul aléa est alors le choix aléatoire $\hat{p}_t \sim I_t$.

Ainsi,
$$\mathbb{E}_t [\ell_{I_{t,t}}] = \sum_{j=1}^N \hat{p}_j^t \ell_j^t = \hat{p}_t \cdot \underline{l}_t.$$

Il s'agit donc d'étudier la proximité de $\sum_{t=1}^n \ell_{I_{t,t}}$ à $\sum_{t=1}^n \mathbb{E}_t [\ell_{I_{t,t}}]$ ce qui se fait par inégalité de concentration pour les martingales.

P.ex., notant M_n l'étendue max. aux tours 1 jusque n ,

$$M_n = \max_{t \leq n} \left(\max_{j=1, \dots, N} \ell_j^t - \min_{i=1, \dots, N} \ell_i^t \right),$$

l'inégalité de Hoeffding-Azuma donne : Avec proba. au moins $1-\delta$,

$$\sum_{t=1}^n \ell_{I_{t,t}} \leq \sum_{t=1}^n \mathbb{E}_t [\ell_{I_{t,t}}] + M_n \sqrt{\frac{n}{2} \ln \frac{1}{\delta}}$$

$$\text{soit } R_n \leq \bar{R}_n + M_n \sqrt{\frac{n}{2} \ln \frac{1}{\delta}}.$$

Rq: en fait, Hoeffding-Azuma est une inégalité maximale :

$$\text{Avec proba. au moins } 1-\delta, \quad \forall t \leq n, \quad R_t \leq \bar{R}_t + M_n \sqrt{\frac{n}{2} \ln \frac{1}{\delta}}.$$

Stratégie: Pondération par des poids exponentiels,

$$\hat{p}_j^t = \frac{\exp(-\eta_t \sum_{s=1}^{t-1} \ell_{j,s})}{\sum_{i=1}^N \exp(-\eta_t \sum_{s=1}^{t-1} \ell_{i,s})}$$

où les η_1, η_2, \dots forment une suite décroissante choisie sur les données ($(\eta_t)_t$ est donc elle aussi aléatoire, à cause du choix randomisé des I_t).

Bornes: (1) * la plus simple (qui valait pour une borne $M \geq M_n$ connue et fixe)

$$\text{Pour toute stratégie du diable,} \quad \bar{R}_n \leq \alpha M \sqrt{n \ln N}.$$

pour tout n ,

$$\text{et utilise } \eta_t \sim \frac{1}{M} \sqrt{\frac{\ln N}{t}}.$$

En réinjectant, on a donc qu'avec proba. au moins $1-\delta$,
 $\forall t \leq n, R_t \leq \square M \sqrt{n \ln(N/\delta)}$

Par Borel-Cantelli (via les choix $n=2^r, r=1,2,\dots$ et $\delta=2^{-r}$)
 il vient alors

$$\underline{\text{ps}} \quad \overline{\lim}_{n \rightarrow +\infty} \frac{R_n}{\square M \sqrt{n \ln(N \ln n)}} = \overline{\lim}_{n \rightarrow +\infty} \frac{R_n}{\square M \sqrt{n \ln \ln n}} \leq 0$$

et en particulier, $\overline{\lim}_{n \rightarrow +\infty} \frac{R_n}{n} \leq 0$ ps.

(2) * une borne plus précise, adaptative en n et M_n , est possible (via un meilleur choix des η_t):

Pour toute stratégie du diable,
$$\bar{R}_n \leq \square \sqrt{\left(\sum_{t=1}^n \sum_{i=1}^N \hat{p}_{it} \ell_{it}^2 \right) \ln N} + \dots$$

↑
 valeur: $\sum_{i=1}^N \hat{p}_{it} (\ell_{it} - \hat{p}_{it} \ell_t)^2$

Cette fois-ci, on ne concentre plus avec Hoeffding-Azuma (sinon, on a une borne $M_n \sqrt{n \ln N}$ qui annule tous nos efforts pour trouver une borne plus précise!) mais avec l'inégalité de Bernstein-Freedman, sous une hyp. de bornitude par le haut, p.ex., $\ell_{jt} \leq B$ pour tous j et t :

Avec proba. au moins $1-\delta$ et contre toute stratégie du diable,

$$R_n \leq \bar{R}_n + \square \sqrt{\left(\sum_{t=1}^n \sum_{i=1}^N \hat{p}_{it} \ell_{it}^2 \right) \ln \frac{1}{\delta}} + \dots$$

$\geq \text{Var}_t \ell_{\cdot, t}$
 variance conditionnelle de $\ell_{\cdot, t}$

On a également une version maximale; au final:

Avec proba. au moins $1-\delta$, pour tout $t' \leq n$,

$$R_{t'} \leq \square \sqrt{\left(\sum_{t=1, \dots, n} \sum_{i=1, \dots, N} \hat{p}_{it} \ell_{it}^2 \right) \ln \frac{N}{\delta}} + \dots$$

Cette borne implique (cf. pages 7-8):

Avec proba $1-\delta$, $\forall t' \leq n$,

$$R_{t'} \leq \square \sqrt{M_n \left(\min_{j=1, \dots, N} \sum_{t=1}^n \ell_{jt} \right) \ln \frac{N}{\delta}} + \dots$$

et on peut appliquer les mêmes traitements avec Borel-Gantelli.

Rappels : * Pour avoir des bornes en espérance (cf. § nég. oracle), on prend l'espérance de \bar{R}_n , pas celle de R_n

* Le cadre simple proposé ici englobe la prédiction avec avis d'experts, cf. $l_{j,t} = l'_t(f_{j,t})$ si l'avis de l'expert j au tour t est $f_{j,t}$ et que les performances sont mesurées par l'_t .

1. Bandits à N bras.

Origine du nom : Une machine à sous est aussi appelée "bandit manchot".

On suppose qu'on a N bandits manchots (ou, de manière équivalente, un bandit à N bras). A chaque tour, on choisit une machine et joue avec elle. On n'observe que le gain procuré par cette machine et pas le gain qu'on aurait obtenu en choisissant une autre.

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

- le statisticien choisit \hat{p}_t probab. sur $\{1, \dots, N\}$ (en fonction des infos des tours passés : $(I_s, p_s)_{s=1, \dots, t-1}$);
- le diable choisit $(l_{j,t})_{j=1, \dots, N} = \underline{l}_t$ (en fonction des infos des tours passés : $(I_s, \hat{p}_s)_{s=1, \dots, t-1}$ et de \hat{p}_t); $\underline{l}_t \in (\mathbb{R}^+)^N$ pour simplifier.
- le statisticien tire $I_t \sim \hat{p}_t$ et subit la perte $l_{I_t, t}$; il n'observe pas \underline{l}_t mais seulement $l_{I_t, t}$, sa propre perte;
- le diable observe I_t (il aurait déjà observé \hat{p}_t).

Bert (rappel) : regret $R_n = \sum_{t=1}^n l_{I_t, t} - \min_{j=1, \dots, N} \sum_{t=1}^n l_{j, t}$ à minimiser

typiquement : $\leq O(\sqrt{n \ln(N/s)})$ avec probab. $1-s$ 18.

(notez le facteur \sqrt{N} supplémentaire par rapport au cas d'information parfaite).

Moyen: Estimer les pertes non observées, et utiliser l'algo de pondération par poids exponentiels sur les pertes estimées :

$$\tilde{l}_{jt} = \frac{l_{I_t, t}}{\hat{p}_{jt}} \mathbb{1}[I_t = j] \text{ est bien un estimateur;}$$

il est conditionnellement sans biais (E_t est l'espérance conditionnelle par rapport à l'info procurée par les tours $1, 2, \dots, t-1$: sa fixe \hat{p}_t et \underline{l}_t , le seul aléa est le choix $I_t \sim \hat{p}_t$):

$$E_t [\tilde{l}_{jt}] = \hat{p}_{jt} \cdot \frac{l_{jt}}{\hat{p}_{jt}} + 0 = l_{jt}.$$

Algo:
$$\hat{p}_{jt} = \frac{\exp(-\eta_t \sum_{s=1}^{t-1} \tilde{l}_{js})}{\sum_{i=1}^N \exp(-\eta_t \sum_{s=1}^{t-1} \tilde{l}_{is})}$$

où
$$\eta_t \approx \square \sqrt{\frac{\ln N}{\sum_{s=1}^{t-1} \sum_{i=1}^N \hat{p}_{is} (\tilde{l}_{is})^2}}$$
 (choix adaptatif en tous les paramètres)

Borne: P. ex. en appliquant (2) page 17, qui valait pour toute suite de pertes :

$$\begin{aligned} \sum_{t=1}^n \sum_{j=1}^N \hat{p}_{jt} \tilde{l}_{jt} &= \min_{i=1, \dots, N} \sum_{t=1}^n \tilde{l}_{it} \\ &\leq \square \sqrt{\left(\sum_{t=1}^n \sum_{i=1}^N \hat{p}_{it} (\tilde{l}_{it})^2 \right) \ln N} + \dots \end{aligned}$$

or,
$$\sum_{j=1}^N \hat{p}_{jt} \tilde{l}_{jt} = l_{I_t, t} \text{ par def. des } \tilde{l}_{jt}$$

et aussi
$$\sum_{i=1}^N \hat{p}_{it} (\tilde{l}_{it})^2 = \sum_{i=1}^N l_{it} \cdot \tilde{l}_{it}$$

soit
$$\sum_{t=1}^n l_{I_t, t} = \min_{i=1, \dots, N} \sum_{t=1}^n \tilde{l}_{it} \leq \square \sqrt{\left(\sum_{t=1}^n \sum_{i=1}^N l_{it} \tilde{l}_{it} \right) \ln N} + \dots$$

* Borne en espérance du regret: il suffit de prendre l'espérance dans les 2 membres et d'utiliser l'inégalité de Jensen,

$$\mathbb{E} \left[\sum_{t=1}^n \ell_{I_{t,t}} \right] - \min_{j=1, \dots, N} \mathbb{E} \left[\sum_{t=1}^n \ell_j^t \right]$$

$$\leq \mathbb{E} \left[\sum_{t=1}^n \ell_{I_{t,t}} - \min_{j=1, \dots, N} \sum_{t=1}^n \tilde{\ell}_j^t \right]$$

$$\leq \mathbb{E} \left[\square \sqrt{\left(\sum_{t=1}^n \sum_{i=1}^N \ell_t^i \tilde{\ell}_t^i \right) \ln N} + \dots \right]$$

$$\stackrel{\text{(Jensen)}}{\leq} \square \sqrt{\left(\sum_{t=1}^n \sum_{i=1}^N \mathbb{E}[(\ell_t^i)^2] \right) \ln N} + \dots$$

$$\begin{aligned} & \text{(cf. } \mathbb{E}[\ell_t^i \tilde{\ell}_t^i] \\ &= \mathbb{E}[\ell_t^i \mathbb{E}_t[\ell_t^i]] \\ &= \mathbb{E}[(\ell_t^i)^2]) \end{aligned}$$

→ Sous l'hyp. (typique des suites individuelles) que les ℓ_t sont bornés par M , on a une borne $\leq \square M \sqrt{nN \ln N}$ sur l'espérance.

→ Juditsky, Nazin, Tsybakov & Vayatis '07 ont été les premiers à remarquer qu'une hyp. du second ordre pouvait être très judicieuse ici : $\mathbb{E}[(\ell_t^i)^2] \leq \sigma^2$ pour tous i et t (c'est une hyp. qui se comprend bien dans un cadre stochastique, pas tellement pour des suites individuelles). On a :

$$\mathbb{E} \left[\sum_{t=1}^n \ell_{I_{t,t}} \right] - \min_{j=1, \dots, N} \mathbb{E} \left[\sum_{t=1}^n \ell_j^t \right] \leq \square \sigma \sqrt{nN \ln N}.$$

Ref: → Dans Aur, Cesa-Bianchi, Freund & Schapire '95 puis '02, l'algo utilise un mélange avec l'uniforme dont on n'a en fait pas besoin (selon une remarque faite postérieurement) pour le cas de l'espérance du regret (mais on en a besoin pour borner le regret avec grande proba). Voir, p.ex., Stoltz '05 (thèse, Th. 2.7 page 40) : c'est le chapitre des rappels, je doute que le résultat soit de moi (mais le moment où je l'ai connu pour la première fois m'échappe). Ça, c'est pour la borne $\square M \sqrt{nN \ln N}$.

→ La borne améliorée en $\sigma \sqrt{nN \ln N}$ n'apparaît pas dans Cesa-Bianchi, Mansour et Stoltz '05, '07, qui donnent en revanche l'ingrédient

essentiel, à savoir l'inég. (2) p. 17; l'application d'une nég. d'info parfaite à des pertes stochastiques est faite p.ex. dans Cesa-Bianchi, Lugosi et Stoltz '05; mais au final, les calculs précis des pages 19-20 sous cette forme sont postérieurs à Juditsky, Nazari, Tsybakov & Vaynshteyn '07 et ont été menés pour cet exposé. (Il restait même dans Cesa-Bianchi, Mansour et Stoltz '05, '07 comme question ouverte non-écrite autre part que dans des emails entre les auteurs à trouver une borne du 2nd ordre pour les bandits à N bras.)

Rq1: Borne avec $\sqrt{N^2 \left(\min_{i=1, \dots, N} E \left[\sum_{t=1}^n \ell_{i,t} \right] \right) \ln N}$ dans Cesa-Bianchi, Mansour et Stoltz '05, version COLT uniquement. Obtenue en revenant à la majoration $\frac{2 \ln N}{\eta_{\min}} + \sum_{t=1}^n \eta_t \Phi(\eta_t, \hat{p}_t, (\tilde{\ell}_{i,t}^+)_i)$ et en traitant les $\Phi(\dots)$ convenablement. Permet d'obtenir des vitesses rapides.

Rq2: Borne sur le regret avec grande proba: Ici, on ne passe plus par \bar{R}_n, \dots On part de l'inég. de la page 19, $\sum_{t=1}^n \ell_{i_t, t} - \min_{i=1, \dots, N} \sum_{t=1}^n \tilde{\ell}_{i,t} \leq \dots$ et il s'agit de montrer (entre autres) que $\sum_{t=1}^n \tilde{\ell}_{i_t, t} \leq \sum_{t=1}^n \ell_{i_t, t} + \Delta_n$ avec grande proba. Δ_n dépend (entre autres) des $\text{Var}_t \tilde{\ell}_{i,t}$ (cf. Bernstein) $\leq E_t (\tilde{\ell}_{i,t})^2 = \frac{(\ell_{i,t})^2}{\hat{p}_t}$

Cela suggère qu'il faut minorer les \hat{p}_t uniformément, c'est pourquoi on a recours à un mélange avec la loi uniforme:

$$\hat{p}_t = (1-\gamma) \frac{\exp(-\eta_t \sum_{s=1}^{t-1} \tilde{\ell}_{i_s})}{\sum_{j=1}^N \exp(-\eta_t \sum_{s=1}^{t-1} \tilde{\ell}_{j_s})} + \frac{\gamma}{N}$$

est le compromis entre exploration et exploitation. }
(1-γ) terme d'exploitation + γ/N terme d'exploration

En fait, juste cette modif. conduit à des vitesses $n^{2/3}$ (borne de '95 de Cesa-Bianchi et al.). Plus de travail (conversion parts \rightarrow gains, translation par facteur de variance) donne (Cesa-Bianchi et al. '02, Cesa-Bianchi et Lugosi '06):

Algo Exp3.P (P = proba, Exp3 = exponential-weight algorithm for exploration and exploitation)

Paramètres: β, η, γ ; parts $\underline{l}_t \in [0,1]^N$

Init.: $w_{i0} = 1$ et $\hat{p}_{i1} = 1/N$ pour tout $i=1, \dots, N$

Pour $t = 1, 2, \dots$

1. choisir $I_t \sim \hat{p}_t$;

2. estimer les gains $\tilde{g}_{it} = \frac{1-l_t}{\hat{p}_{it}} \mathbb{1}_{[I_t=i]} + \frac{\beta}{\hat{p}_{it}}$;

3. mettre à jour les poids selon $w_{it} = w_{i,t-1} \cdot e^{-\eta \tilde{g}_{it}}$;

4. définir \hat{p}_{t+1} selon

$$\hat{p}_{i,t+1} = (1-\gamma) \frac{w_{it}}{\sum_{j=1}^N w_{jt}} + \frac{\gamma}{N}, \quad i=1, \dots, N.$$

Borne: Sous l'hyp. que $\underline{l}_t \in [0,1]^N$ pour tout t ,
pour tout $\delta \in]0,1[$, pour tout $n \geq \frac{1}{\delta} \ln \frac{N}{\delta}$,
et pour les choix

$$\beta = \sqrt{\frac{\ln(N/\delta)}{nN}}, \quad \gamma = \frac{6N\beta}{4+\beta}$$

et $\eta = \frac{\gamma}{3N}$, on a avec probab. $1-\delta$

contre toute stratégie du diable:

$$\sum_{t=1}^n l_{I_t, t} - \min_{j=1, \dots, N} \sum_{t=1}^n l_{jt} \leq 6\sqrt{nN \ln \frac{N}{\delta}} + \frac{\ln N}{2}$$

Rq: Evidemment, on peut utiliser $\beta_t, \eta_t, \gamma_t$ pour traiter l'adaptation en les paramètres (y compris M pour $\underline{l}_t \in [0,1]^N$ avec M inconnu); ou rester aux param. fixes à l'intérieur d'un régime et couper le temps en k régimes (comme en page 14).

Optimalité: \sqrt{n} indépassable, même dans le cas stochastique:

pour $l: \mathcal{N} \times [0,1] \rightarrow [0,1]$ définie par $l(j,y) = j^{\text{ème}} \text{ comp. du développement dyadique de } y$, on a: pour toute strat. du statisticien,

$$\forall N \geq 2, \forall n \geq 2, \sup_{y_1, \dots, y_n \in [0,1]} E \left[\sum_{t=1}^n l(I_t, y_t) \right] - \min_{i=1, \dots, N} \sum_{t=1}^n l(i, y_t) \geq \frac{1}{20} \min \{ \sqrt{nN}, n \}$$

preuve: dans le cas où les y_j sont les réalisations de Y_1, Y_2, \dots iid selon une loi bien choisie.

Utilise Pinsker (pas Fano).

↳ facteur $\sqrt{\ln N}$

manquant: améliorer borne inf. ou borne sup. ?

2. Prédiction économique en observations.

(Référence = Cesa-Bianchi, Lugosi, et Stoltz '05)

Jeu de prédiction:

Paramètres:

décisions $\{1, 2, \dots, N\}$ pour le statisticien
le diable prend des vecteurs de pertes dans \mathbb{R}^N
fonction $\mu: \mathcal{N} \rightarrow \mathcal{N}$ donnant le nombre max. d'observations
(croissante)

Pour $t=1, 2, \dots$

1. le statisticien choisit $\hat{p}_t \in \mathcal{X}$ (proba. sur $\{1, \dots, N\}$, en fonction des infos des tours passés)
2. le diable choisit \underline{l}_t (en fonction des infos des tours passés, à savoir $(I_s, \hat{p}_s)_{s \leq t-1}$ et de \hat{p}_t)
($\underline{l}_t \in [0,1]^N$ pas simplifier)
3. le statisticien tire $I_t \sim \hat{p}_t$ et subit $l_{I_t, t}$ comme perte (non obs.)
4. si strictement moins de $\mu(t)$ vecteurs \underline{l}_s ont été observés jusque là, le statisticien peut choisir de voir \underline{l}_t ; sans quoi, il en demeure dans l'ignorance.

But:

regret $R_n = \sum_{t=1}^n l_{I_t, t} - \min_{j=1, \dots, N} \sum_{t=1}^n l_{j, t}$ à minimiser

Cas simple.

Horizon n fixé, parts $\underline{l}_t \in [0,1]^N$ et budget μ tq.
pour un m fixé et connu: $\mu(1) = \dots = \mu(n) = m.$

Algo:

Paramètres: $\eta > 0$ et $\varepsilon \in]0,1[$ (valeurs données ci-dessous).

Initialisation: $w_1 = (1, \dots, 1)$

Pour $t = 1, 2, \dots, n$:

1. choisir $I_t \sim \hat{p}_t$ ou

$$\hat{p}_t^j = \frac{w_{jt}}{\sum_{i=1, \dots, N} w_{it}} \quad \text{pour } j=1, \dots, N;$$

2. tirer $Z_t \sim \text{Ber}(\varepsilon)$;

3. si $Z_t = 1$, demander à voir \underline{l}_t (si c'est possible!)
et mettre à jour $w_{i,t+1} = w_{it} e^{-\eta l_{it}/\varepsilon}$ pour tout i ;
sinon, lorsque $Z_t = 0$, $w_{i,t+1} = w_{it}$ pour tout i .

Analyse: * Z_1, \dots, Z_n sont des randomisations auxiliaires indépendantes de tout le reste; E_t est l'espérance conditionnelle par rapport aux tours passés (fixe \hat{p}_t et \underline{l}_t , les seuls aléas sont dans $I_t \sim \hat{p}_t$ et $Z_t \sim \text{Ber}(\varepsilon)$).

On note $\tilde{l}_{jt} = \frac{l_{jt}}{\varepsilon} Z_t$; ce sont des estimateurs conditionnellement sans biais:

$$E_t[\tilde{l}_{jt}] = l_{jt}$$

et même (on en aura besoin):

$$E_t\left[\sum_{j=1, \dots, N} \hat{p}_t^j \tilde{l}_{jt}\right] = \hat{p}_t \cdot \underline{l}_t$$

* On veut contrôler $Z_1 + \dots + Z_n$ ($\leq m$?): par inégalité de Bernstein.

Lm (Bernstein - Freedman): X_1, \dots, X_n suite d'accroissements de martingale, par rapport à $(\mathcal{F}_t)_{1 \leq t \leq n}$, bornés supérieurement: $X_j \leq K$ ps.

V_n somme des variances conditionnelles : $V_n = \sum_{t=1}^n E[X_t^2 | \mathcal{F}_t]$.

Alors $P\left(\max_{t=1, \dots, n} X_1 + \dots + X_t > \sqrt{2vx} + \frac{\sqrt{2}}{3} Kx \text{ et } V_n \leq v\right) \leq e^{-x}$.

↑
version maximale à nouveau

Application à $X_t = Z_t - \varepsilon$: $V_n \leq n\varepsilon = v$, $K=1$,
soit avec probab. au moins $1-\delta'$ pour tout $t=1, \dots, n$:

$$Z_1 + \dots + Z_t \leq n\varepsilon + \underbrace{\sqrt{2n\varepsilon \ln 1/\delta'}}_{\leq m} + \frac{\sqrt{2}}{3} \ln 1/\delta'$$

p.ex. pour :

$$\varepsilon = \left(\frac{m}{n} - \left(\frac{\sqrt{2m \ln 1/\delta'}}{n} + \frac{\sqrt{2}}{3n} \ln 1/\delta' \right) \right)^+ \leq \frac{m}{n}$$

* Contrôle du regret maintenant : on revient à la borne la plus simple (voir p.6)

$$\sum_{t=1}^n \sum_{j=1}^N \hat{p}_{jt} \tilde{\ell}_{jt} - \min_{i=1, \dots, N} \sum_{t=1}^n \tilde{\ell}_{it} \leq \frac{\ln N}{\eta} + \eta \sum_{t=1}^n \sum_{j=1}^N \hat{p}_{jt} (\tilde{\ell}_{jt}^2)$$

(voir p.6)

et on concentre : $X_t = \tilde{\ell}_t - \ell_t$ $K = 1/\varepsilon$

$$\text{Var}_t X_t \leq E_t[(\tilde{\ell}_t)^2] \leq \frac{(\ell_t)^2}{\varepsilon^2} \varepsilon \leq 1/\varepsilon$$

soit $\sigma \leq 1/\varepsilon$

cf. $\ell_t \in [0,1]^N$
par simplification
voir p.23

et au final, avec probab. δ' :

$$\sum_{t=1}^n \tilde{\ell}_t \leq \sum_{t=1}^n \ell_t + \sqrt{\frac{2n}{\varepsilon} \ln 1/\delta'} + \frac{\sqrt{2}}{3\varepsilon} \ln 1/\delta'$$

de même pour $\sum_{j=1}^N \hat{p}_{jt} \ell_{jt} - \sum_{j=1}^N \hat{p}_{jt} \tilde{\ell}_{jt}$ (et même une borne plus petite, ici $K=1$)

et pour le membre de droite :

$$\sum_{t=1}^n \sum_{j=1}^m \beta_{jt} (\tilde{\ell}_{jt})^2 \leq \frac{n}{\varepsilon} + \sqrt{2(n/\varepsilon^3) \ln 1/\delta'} + \frac{\sqrt{2}}{3} \varepsilon^2 \ln 1/\delta'$$

f. $E_t (\tilde{\ell}_{jt})^2 \leq \frac{1}{\varepsilon}$ et $\left\{ \begin{array}{l} (\tilde{\ell}_{jt})^2 \leq \frac{1}{\varepsilon^2} \\ \text{Var}_t (\tilde{\ell}_{jt})^2 \leq \frac{1}{\varepsilon^3} \end{array} \right.$

• Au final :

Avec proba. $1 - 3\delta'$,

$$R_n = \sum_{t=1}^n \sum_{j=1}^m \beta_{jt} \ell_{jt} - \min_{i=1, \dots, N} \sum_{t=1}^n \ell_{it}$$

$$\leq \square \left(\sqrt{\frac{n}{\varepsilon} \ln 1/\delta'} + \frac{\ln 1/\delta'}{\varepsilon} \right) + \frac{\ln N}{\eta}$$

$$+ \square \eta \left(\frac{n}{\varepsilon} + \sqrt{\frac{n}{\varepsilon^3} \ln 1/\delta'} + \frac{\ln 1/\delta'}{\varepsilon^2} \right)$$

$(\varepsilon \sim \frac{m}{n})$

$$\sim \square \frac{\eta}{\sqrt{m}} \sqrt{\ln 1/\delta'} + \square \frac{\eta}{m} \ln 1/\delta'$$

$$+ \frac{\ln N}{\eta} + \square \eta \left(\frac{n^2}{m} + \frac{n^2}{\sqrt{m^3}} \sqrt{\ln 1/\delta'} + \frac{n^2}{m^2} \sqrt{\ln 1/\delta'} \right)$$

$\left(\eta \sim \frac{1}{m} \sqrt{m \ln N} \right) \bar{R}_n \leq \square \left(\frac{n}{\sqrt{m}} \sqrt{\ln 1/\delta'} + \square \frac{\eta}{m} \ln 1/\delta' \right) \leq \frac{n^2}{m}$ pour $m \geq \ln 1/\delta'$

ce terme nous permet de supposer $m \geq \square \ln 1/\delta'$ sinon, borne triviale n est meilleure !

et celui-là est abs plus petit!

Un dernier coup d'Hoeffding-Azuma pour relier R_n à \bar{R}_n (à $\sqrt{n \ln 1/\delta'}$ près) et on a (avec $\delta' = \delta/5$):

Th: $\left\{ \begin{array}{l} R_n \leq \square \frac{n}{\sqrt{m}} \sqrt{\ln \frac{5}{\delta}} \\ Z_1, \dots, Z_n \leq \frac{n}{m} \end{array} \right\}$ avec proba $1 - \delta$

Rq: Pour $m = n$, on retrouve la borne habituelle.

Rq: Hoeffding-Azuma ne suffit pas pour cette preuve; si on l'utilise on a de plus mauvaises vitesses. (Ex: $\sum \tilde{\ell}_{it} \leq \sum \ell_{it} + \square \varepsilon \sqrt{n \ln 1/\delta'}$...)

Cas d'une fonction μ générale $\mathbb{N} \rightarrow \mathbb{N}$:

Cor: si μ est croissante tq. $\lim_{n \rightarrow +\infty} \frac{\mu(n)}{(\log n) \log \log n} = +\infty$

alors il existe une stratégie pour le statisticien tq.

$$\overline{\lim} \frac{R_n}{n} \leq 0 \text{ ps.}$$

tout en respectant les contraintes données par μ .

Preuve (éléments): Cette stratégie découpe le temps en régimes $r=1,2,\dots$ et choisit dans chaque régime sa longueur n_r , le nombre max. d'obs. m_r (ainsi qu'un niveau de confiance δ_r , tq. $\sum \delta_r < +\infty$ pour appliquer Borel-C.)
Détails dans Cesa-Bianchi, Lugosi & Stoltz '05.

Optimalité (\bar{a} n et m fixés).

Th: Pour $l: \mathbb{N} \times [0,1] \rightarrow \{0,1\}$ (définie comme d'habitude selon et pour $c > 0$ (qu'on peut calculer précisément), $l(i,y) =$ jème élément du dvpt dyadique de $y \in [0,1]$)

pour tout $N \geq 2$ et $n \geq m \geq \lceil \ln N \rceil$,

toute stratégie du statisticien utilisant au plus m observations a un regret tq.

$$\sup_{y_1, \dots, y_n \in [0,1]} E \left[\sum_{t=1}^n l(I_t, y_t) \right] - \min_{i=1, \dots, N} \sum_{t=1}^n l(i, y_t) \geq c \cdot m \sqrt{\frac{\ln N}{m}}.$$

preuve: on remplace le $\sup_{y_1, \dots, y_n \in [0,1]}$ par N probabilités-produits sur $[0,1]^n$, chacune favorisant une action i

à ε près :

Q_i est la loi de $\text{Ber}(\frac{1}{2}-\varepsilon) \times 2^{-i} + \sum_{\substack{k=1, \dots, N \\ k \neq i}} 2^{-k} \text{Ber}(\frac{1}{2}) + 2^{-(N+1)} \mathbb{1}_{[0,1]}$

Sous $Q_i^{\otimes n}$, les

$l(k, Y_t)$, $k=1, \dots, N$, $t=1, \dots, n$ sont

indépendantes, avec $l(k, Y_t) \sim \text{Ber}(\frac{1}{2})$ si $k \neq i$

$l(i, Y_t) \sim \text{Ber}(\frac{1}{2}-\varepsilon)$

puis $\sup_{y_1, \dots, y_n \in [0,1]} \max_{i=1, \dots, N} E \left[\sum_{t=1}^n l(I_t, y_t) \right] - \sum_{t=1}^n l(i, y_t)$

$\geq \max_{i=1, \dots, N} E_{Q_i^{\otimes n}} \left[\underbrace{E_A \left[\sum_{t=1}^n l(I_t, Y_t) \right]}_{\text{random. auxiliaire}} - \underbrace{\sum_{t=1}^n l(i, Y_t)}_{= n/2 - n\varepsilon} \right]$

$= \frac{n}{2} - \varepsilon \sum_{t=1}^n Q_i^{\otimes n} \otimes P_A (I_t = i)$

$= \max_{i=1, \dots, N} n\varepsilon \left(1 - \frac{1}{n} \sum_{t=1}^n Q_i^{\otimes n} \otimes P_A (I_t = i) \right)$

$= n\varepsilon \left(1 - \min_{i=1, \dots, N} \frac{1}{m} \sum_{t=1}^n Q_i^{\otimes n} \otimes P_A (I_t = i) \right)$

par Fano généralisé (voir plus bas)

ceci est $\leq \max \left\{ \frac{R}{\ln N}, \square \right\}$ où $R = \frac{1}{Nm} \sum_{\substack{t=1, \dots, n \\ i=1, \dots, N}} KL \left(\left(Q_i^{\otimes n} \otimes P_A \right)^{I_t} \left(Q_i^{\otimes n} \otimes P_A \right)^{I_t} \right)$

or le choix de I_t dépend au plus de

m observations : $KL(,) \leq KL(Q_i^{\otimes m}, Q_1^{\otimes m}) \leq m KL(Q_i, Q_1)$

$\leq m (KL(\text{Ber}(\frac{1}{2}), \text{Ber}(\frac{1}{2}-\varepsilon)) + KL(\text{Ber}(\frac{1}{2}-\varepsilon), \text{Ber}(\frac{1}{2})))$

$\leq \square m \varepsilon^2$

Ici il faut en fait

considérer d'abord 1 strat. dét.

et étendre aux strat. randomisées,

voir CB, L, S '05 pour 1 vraie preuve.

Au final,

$$\sup_{y_1, \dots, y_n} \mathbb{E}[R_n] \geq \max_{i=1, \dots, N} \mathbb{E}_{Q_i \in \mathcal{A}} [R_n]$$

$$\geq n \varepsilon \left(1 - \max \left\{ \frac{\sigma m \varepsilon^2}{\ln N}, \sigma \right\} \right)$$

$$\geq \sigma \frac{n}{\sqrt{m}} \sqrt{\ln N} \quad \text{pour le choix } \varepsilon \sim \sqrt{\frac{\ln N}{m}}$$

Reste juste à voir le lemme de Fano pour des combinaisons convexes...

Lm (Fano, version Bregman - Pinsker): $\{A_0, \dots, A_N\}$ partition de Ω ,
 $\mathbb{P}_0, \dots, \mathbb{P}_N$ N probabilités sur Ω ,

alors $\min_{j=0, \dots, N} \mathbb{P}_j(A_j) \leq \max \left\{ \frac{\bar{K}}{\ln(N+1)}, \frac{2e}{2e+1} \right\}$

où $\bar{K} = \frac{1}{N} \sum_{j=1}^N \text{KL}(\mathbb{P}_j, \mathbb{P}_0)$.

preuve (très courte):

• rappels: $\left\{ \begin{array}{l} (\mathbb{P}, \mathbb{Q}) \mapsto \text{KL}(\mathbb{P}, \mathbb{Q}) \text{ est convexe} \\ \text{pour toute v.a. } X, \quad \text{KL}(\mathbb{P}^X, \mathbb{Q}^X) \leq \text{KL}(\mathbb{P}, \mathbb{Q}) \end{array} \right.$

• ainsi, $\forall \mathbb{P}_i, \mathbb{Q}_i, A_i$, sans conditions pour l'instant:

$$\begin{aligned} \text{KL}(\mathbb{P}_i, \mathbb{Q}_i) &\geq \text{KL}(\mathbb{P}_i^{\mathbb{1}_{A_i}}, \mathbb{Q}_i^{\mathbb{1}_{A_i}}) \\ &= \text{KL}(\text{Ber}(\mathbb{P}_i(A_i)), \text{Ber}(\mathbb{Q}_i(A_i))) \end{aligned}$$

Par convexité, $\bar{K} = \frac{1}{N} \sum_{i=1}^N \text{KL}(\mathbb{P}_i, \mathbb{Q}_i) \geq \frac{1}{N} \sum_{i=1}^N \text{KL}(\text{Ber}(\mathbb{P}_i(A_i)), \text{Ber}(\mathbb{Q}_i(A_i)))$

$$\geq \text{KL}(\text{Ber}(p), \text{Ber}(q))$$

où $p = \frac{1}{N} \sum_{i=1}^N \mathbb{P}_i(A_i)$,

$q = \frac{1}{N} \sum_{i=1}^N \mathbb{Q}_i(A_i)$

(***) $= p \log \frac{p}{q} + (1-p) \log \frac{1-p}{1-q}$

$\log \frac{1}{1-q} \geq 0$,

$(1-p) \log(1-p) \geq -\frac{1}{e}$ 29.

$$d'au \quad \bar{K} \geq \left(p \log \frac{p}{q} \right) - \frac{1}{e}.$$

On en déduit le lemme: on prend $Q_i = P_i$,

$$a = \min_{j=0, \dots, N} \mathbb{P}_j(A_j) \leq p$$

qu'on utilise l'hyp. de partition! et $q = \frac{1}{N} (1 - \mathbb{P}_0(A_0)) \geq \frac{1}{N} (1-a)$

on peut supposer $a \geq \frac{1}{e}$ (et alors, $p \geq \frac{1}{e}$):

puis: $x \mapsto x \log x$ croissante sur $[\frac{1}{e}, 1]$

$$\text{et donc } p \log p \geq a \log a$$

$$\log q \geq \log \frac{1}{N} (1-a)$$

$$\text{et donc } p \log \left(\frac{p}{q} \right) - \frac{1}{e} \geq a \log \left(\frac{Na}{1-a} \right) - \frac{1}{e}$$

$$\geq a \log \left(\frac{Na}{e(1-a)} \right)$$

(car $a \geq \frac{1}{e}$)

$$\bar{K} \geq a \log \left(\frac{Na}{e(1-a)} \right) \geq a \log (N+1) \quad \text{par } a \geq \frac{2e}{2e+1}.$$

$a \mapsto \frac{a}{e(1-a)}$ fonction croissante de a , $\xrightarrow{a \rightarrow 1} +\infty$

donc pour $a \geq \square$,

$$\text{c'est } \geq 1 + \frac{1}{2} \geq 1 + \frac{1}{N}$$

(P.ex., $\square = \frac{2e}{2e+1}$, proposition de Pascal Passaret,

fait que c'est ≥ 2)

Ref: Birgé 2008 IEEE IT

Massart 2003 St-Flour

plus, notamment par arrivés à l'inég. clé $\bar{K} \geq KL(\mathcal{B}_e(p), \mathcal{B}_e(q))$,

une simplification personnelle (non publiée)... qui d'ailleurs 30.

nous permet d'arriver à un résultat partiel avec des couples (P_i, Q_i) ;
ça pourrait être utile pour ... ?

→ APPEL aux bonnes idées !

Voyons l'extension aux combinaisons convexes :

Suffit de reprendre une couche de combinaisons convexes en $(**)$:

$$\bar{K} = \frac{1}{N} \sum_{i=1}^N \sum_{s=1}^S \alpha_s \text{KL}(P_i^s, Q_i^s)$$

$$\geq \text{KL}(\text{Ber}(p), \text{Ber}(q))$$

$$\text{cà} \quad p = \frac{1}{N} \sum_{i=1}^N \sum_{s=1}^S \alpha_s P_i^s(A_i^s)$$

$$q = \frac{1}{N} \sum_{i=1}^N \sum_{s=1}^S \alpha_s Q_i^s(A_i^s)$$

On conclut comme en p 30 pour peu que pour tout s , (A_0^s, \dots, A_N^s)
soit une partition de Ω . On a obtenu :

Lm (Fano pour des combinaisons convexes) :

$\{A_0^s, \dots, A_N^s\}$ ($s=1, \dots, S$) sont S partitions de Ω ,
 (Q_0^s, \dots, Q_N^s) sont S $(N+1)$ -ups de probabilités de Ω ,

$$\alpha_1, \dots, \alpha_S \geq 0 \quad \text{tq} \quad \alpha_1 + \dots + \alpha_S = 1;$$

$$\text{alors} \quad \min_{j=0, \dots, N} \sum_{s=1}^S \alpha_s Q_j^s(A_j^s) \leq \max \left\{ \frac{2e}{2e+1}, \frac{\bar{K}}{\ln(N+1)} \right\}$$

$$\text{cà} \quad \bar{K} = \frac{1}{N-1} \sum_{j=2}^N \sum_{s=1}^S \alpha_s \text{KL}(Q_j^s, Q_0^s)$$