

Descente gradient séquentielle
Application aux bandits linéaires combinatoires

I/ Cadre : décisions séquentielles dans un compact convexe de \mathbb{R}^K

C compact convexe de \mathbb{R}^K

Jeu de prédiction :

- L'environnement choisit des f^o convexes sous-diff $l_t: C \rightarrow \mathbb{R}, t \geq 1$.
 - A chaque $t \geq 1$,
 - * Le stat choisit $x_t \in C$ en fonction du passé et essent la perte $l_t(x_t)$
 - * La fonction l_t (ou une partie de cette info) est révélée au statisticien.
- \uparrow info parfaite \uparrow $l_t(x_t)$: bandits

But: minimiser le regret

$$\sum_{t=1}^T l_t(x_t) - \inf_{x \in C} \sum_{t=1}^T l_t(x)$$

Applications :

- pb usuel : choix ^{randomisé} d'une action parmi K actions : (e_1, \dots, e_K) base canonique de \mathbb{R}^K

$C = \text{conv}(\{e_1, \dots, e_K\}) = K\text{-simplexe} = \text{ensemble des probs sur les } K \text{ actions}$

$$l_t(q) = \langle l_t, q \rangle = \sum_{i=1}^K q_i l_{i,t} = \mathbb{E}_{i \sim q} [l_{i,t}]$$

- randomisation sur une partie $G \subset \mathbb{R}^K$ de nature combinatoire



Ex: $G = \{x \in \{0,1\}^K : \sum_{i=1}^K x_i = m\}$ où $m \in \mathbb{N}^+$, puis $C = \text{conv}(G)$.

→ choix simultané de m bras (multiple plays: Uchiya et al. '10)
 Or as: choix de pubs sur une barrière web.

Fonction de gain : $g_t(x) = \langle g_t, x \rangle = \sum_{i=1}^K x_i g_{i,t}$

de sorte que : $\forall x \in G, g_t(x) = \sum_{i \in S_x} g_{i,t}$, où $S_x = \{i : x_i = 1\}$.

= nb de clics total associé au choix de pubs $S_x \subset \{1, \dots, K\}$ si on considère

↳ Ici, le but est de rendre le nb total cumulé de clics $\sum_{t=1}^T \sum_{i \in S_t} g_{i,t}$ le plus grand possible, et notamment proche de $\max_{x \in G} \sum_{t=1}^T \sum_{i \in S_x} g_{i,t}$

$g_{i,t} = 1$ {l'internaute a cliqué sur la pub i à l'instant t }

→ Autre appli : choix d'un chemin de longueur m de A vers B du graphe : Ici, $G \subset \{x \in \{0,1\}^K : \sum_{i=1}^K x_i = m\}$ et



$\forall x \in G, l_t(x) = \langle l_t, x \rangle = \text{tps de trajet total du chemin } x$
 si $l_{i,t} = \text{tps de trajet de l'arête } i$

II - Descente miroir séquentielle en information parfaite

- Refs : Nemirovski '79, Nemirovski & Judin '83, Beck & Teboulle '03 ...
- Online : Herbster & Warmuth '98 ...
 - Stats : Juditsky et al. '05 ...

Def : Soit $\mathcal{D} \subset \mathbb{R}^K$ ouvert convexe et $F: \mathcal{D} \rightarrow \mathbb{R}$.

F est dite "de Legendre" si :

- F strictement convexe sur \mathcal{D}
- $\lim_{n \rightarrow +\infty} \|\nabla f(x_n)\| = +\infty$ pour tout $x \rightarrow \partial \mathcal{D}$.

Algo : descente miroir séquentielle

- Paramètres : C compact convexe de \mathbb{R}^K
 $F: \mathcal{D} \rightarrow \mathbb{R}$ Legendre, avec \mathcal{D} ouvert convexe tq $\mathcal{D} \supset C$ et $C \cap \mathcal{D} \neq \emptyset$
 $\eta > 0$ (paramètre d'apprentissage)

- Initialisation : $x_1 \in C \cap \mathcal{D}$. (typiquement : $x_1 \in \underset{x \in C}{\operatorname{argmin}} F(x)$)

- A chaque ite $t \geq 1$,

(1) Jouer x_t et observer $l_t: C \rightarrow \mathbb{R}$.

(2) $w_{t+1} = \nabla F^*(\nabla F(x_t) - \eta \nabla l_t(x_t))$ ← descente du gradient sur \mathcal{D}^* ramenée sur \mathcal{D} via ∇F^*

(3) $x_{t+1} = \underset{y \in C}{\operatorname{argmin}} D_F(y, w_{t+1})$ (N.B. : $x_{t+1} \in C \cap \mathcal{D}$ car F Legendre)
 ← projection de Bregman sur C

où $F^*(y) = \sup_{x \in \mathcal{D}} \{ \langle x, y \rangle - F(x) \}$ (transformée de Fenchel-Legendre)

• $\mathcal{D}^* = \nabla F(\mathcal{D})$ (NB : sur \mathcal{D}^* , $\nabla(F^*) = (\nabla F)^{-1}$, cf [Rockafellar])

• $D_F(y, x) = F(y) - F(x) - \langle \nabla F(x), y - x \rangle$ pour tout $(y, x) \in \mathcal{D} \times \mathcal{D}$.

↑ divergence de Bregman
 ≥ 0 et strictement convexe.

[cf illustration page 4]

Rem :

• l'étape (2) n'est bien définie que si $\nabla F(x_t) - \eta \nabla l_t(x_t) \in \mathcal{D}^*$ (hyp)

• l'étape (3) est une projection de $w_{t+1} \in \mathcal{D}$ sur $C \subset \mathcal{D}$.

• Exemples : * $\mathcal{D} = \mathbb{R}^K$, $F(x) = \frac{1}{2} \|x\|_2^2$ m. $\nabla F = \operatorname{id} = \nabla F^*$
 $D_F(y, x) = \frac{1}{2} \|y - x\|_2^2$
 étape (2) : descente de gradient usuelle, étape (3) vide.

* $\mathcal{D} =]0, +\infty[^K$, $F(x) = \sum_{i=1}^K x_i \ln x_i - \sum_{i=1}^K x_i$ (entropie négative)

alors $\nabla F(x) = (\ln x_i)_{1 \leq i \leq K}$ et $\nabla F^*(y) = (\nabla F)^{-1}(y) = (e^{y_i})_{1 \leq i \leq K}$ (2)

$$\text{et } D_F(y, x) = \sum_{i=1}^K \gamma_i \ln \frac{\gamma_i}{x_i} = \sum_{i=1}^K (\gamma_i - x_i)$$

Dans le cas où $C = \Delta(K) := \{y \in \mathbb{R}_+^K : \sum_{i=1}^K \gamma_i = 1\}$, on a: $\forall x \in \mathbb{R}_+^{*K}$,

$$\operatorname{argmin}_{y \in C} D_F(y, x) = \operatorname{argmin}_{y \in \Delta(K)} \left\{ \sum_{i=1}^K \gamma_i \ln \frac{\gamma_i}{x_i / \|x\|_1} \right\} = \operatorname{argmin}_{y \in \Delta(K)} \text{KL}(y, \frac{x}{\|x\|_1}) = \frac{x}{\|x\|_1}$$

D'où :

$$\left. \begin{array}{l} \text{étape (2)} : w_{j,t+1} = w_{j,t} e^{-\eta \nabla_j l_t(x_t)} \\ \text{étape (3)} : x_{t+1} = \frac{w_{t+1}}{\|w_{t+1}\|_1} \end{array} \right\} \begin{array}{l} \text{On retrouve donc les poids} \\ \text{exponentiels :} \\ w_{j,t+1} = \frac{\exp(-\eta \sum_{s=1}^t \nabla_j l_s(x_s))}{\sum_{j=1}^K \exp(-\eta \sum_{s=1}^t \dots)} \end{array}$$

Formulation proximale : l'étape (2) est équivalente à

$$w_{t+1} \in \operatorname{argmin}_{w \in \mathcal{D}} \left\{ \underbrace{l_t(x_t) + \langle \nabla l_t(x_t), w - x_t \rangle}_{\text{approx 1^{ère} ordre de } l_t} + \frac{D_F(w, x_t)}{\eta} \right\}$$

Théorème 1: majoration du regret de l'algo de descente miroir séquentielle

Soit C un compact convexe de \mathbb{R}^k
 $F: \mathcal{D} \rightarrow \mathbb{R}$ \mathcal{L} egendre, avec \mathcal{D} ouvert convexe tq $\mathcal{D} \supset C$ et $C \cap \mathcal{D} \neq \emptyset$.
 $\eta > 0$.

Alors, l'algorithme de descente miroir séquentielle calibré avec $\eta > 0$ vérifie : $\forall x \in C$,

$$\sum_{t=1}^T l_t(x_t) - \sum_{t=1}^T l_t(x) \leq \frac{D_F(x, x_1)}{\eta} + \frac{1}{\eta} \sum_{t=1}^T D_{F^*}(\nabla F(x_t) - \eta \nabla l_t(x_t), \nabla F(x_t))$$

Preuve : par convexité, (sous-gradient)

$$\sum_{t=1}^T (l_t(x_t) - l_t(x)) \leq \sum_{t=1}^T \langle \nabla l_t(x_t), x_t - x \rangle$$

Or, d'après l'étape (2) et $\nabla F^* = (\nabla F)^{-1}$ sur \mathcal{D}^* , on a

$$\nabla F(w_{t+1}) = \nabla F(x_t) - \eta \nabla l_t(x_t)$$

$$\begin{aligned} \text{d'où } \langle \eta \nabla l_t(x_t), x_t - x \rangle &= \langle \nabla F(x_t) - \nabla F(w_{t+1}), x_t - x \rangle \\ &= D_F(x, x_t) + D_F(x_t, w_{t+1}) - D_F(x, w_{t+1}) \quad (*) \end{aligned}$$

car $\forall (x, y, z) \in \mathcal{D} \times \mathcal{D}^2$, $D_F(x, y) = D_F(x, z) + D_F(z, y) - \langle \nabla F(z) - \nabla F(y), z - x \rangle$

(appliquée avec $z = x_t, y = w_{t+1}$ et $x = x$)

En $\alpha_{t+1} \in \operatorname{argmin}_{y \in C} D_F(y, w_{t+1}) = \text{projeté de Bregman sur } C$

donc (inégalité de Pythagore généralisée) :

$$\forall x \in C, D_F(x, w_{t+1}) \geq D_F(x, \alpha_{t+1}) + D_F(\alpha_{t+1}, w_{t+1})$$

En injectant dans (*), il vient :

$$\langle \eta \nabla \ell_t(x_t), x_t - x \rangle \leq D_F(x, x_t) + D_F(x_t, w_{t+1}) - D_F(x, \alpha_{t+1}) - \underbrace{D_F(\alpha_{t+1}, w_{t+1})}_{\geq 0}$$

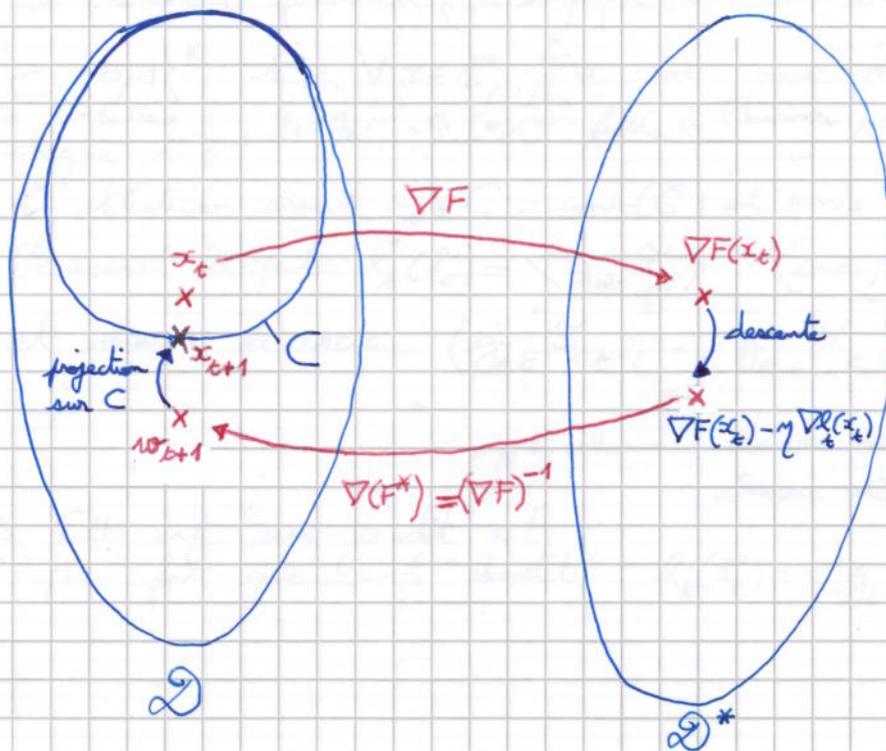
téléscopique

$$\begin{aligned} \text{On a } \sum_{t=1}^T \langle \eta \nabla \ell_t(x_t), x_t - x \rangle &\leq \sum_{t=1}^T (D_F(x, x_t) - D_F(x, x_{t+1})) + \sum_{t=1}^T D_F(x_t, w_{t+1}) \\ &= D_F(x, x_1) - \underbrace{D_F(x, x_{T+1})}_{\geq 0} + \sum_{t=1}^T D_F(x_t, w_{t+1}) \end{aligned}$$

On conclut en remarquant que

$$\begin{aligned} D_F(x_t, w_{t+1}) &= D_{F^*}(\nabla F(w_{t+1}), \nabla F(x_t)) \\ &= D_{F^*}(\nabla F(x_t) - \eta \nabla \ell_t(x_t), \nabla F(x_t)) \text{ d'après étape (2). } \end{aligned}$$

Illustration de la descente miroir séquentielle



III - Application aux bandits linéaires combinatoires

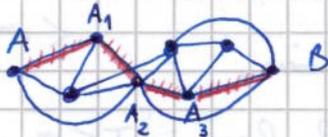
Refs: Cesa-Bianchi & Lugosi (2005), Strehl et al. (2005).

Jeu de prévision:

- Paramètre: $G \subset \{0,1\}^K$ tq $\forall x \in G, \sum_{i=1}^K x_i = m$ avec $m \in \mathbb{N}^*$ connu.
- Initialisation: l'environnement choisit à l'avance des vecteurs de pertes $\underline{l}_t \in [0,1]^K$ (on posera $l_t(x) = \langle \underline{l}_t, x \rangle$ pour tout $x \in \mathbb{R}^K$), $t \geq 1$.
- Et chaque date $t \geq 1$,
 - * Le statisticien choisit $x_t \in C = \text{conv}(G)$ en fonction du passé \mathcal{F}_{t-1} et tire aléatoirement $\tilde{x}_t \in G$ tel que $E[\tilde{x}_t | \mathcal{F}_{t-1}] = x_t$.
 - * Il encourt alors la perte $l_t(\tilde{x}_t) = \langle \underline{l}_t, \tilde{x}_t \rangle$ et observe les valeurs $l_{i,t}$ pour tout i tq $\tilde{x}_{i,t} = 1$ (correspond aux bras joués à l'instant t); autrement dit, le statisticien observe le vecteur $(l_{i,t}, \tilde{x}_{i,t})_{1 \leq i \leq K} \in [0,1]^K$.

Rem: l'observation du vecteur $(l_{i,t}, \tilde{x}_{i,t})_{1 \leq i \leq K}$ est qualifiée d'information "semi-bandits". Cette inf est plus forte que la seule observation de $\sum_{i=1}^K l_{i,t} \tilde{x}_{i,t} = \langle \underline{l}_t, \tilde{x}_t \rangle$ qui correspond au cas des bandits linéaires.

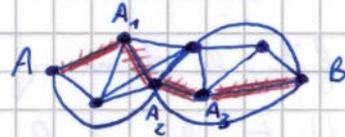
Ex: SEMI-BANDITS



Et chaque date $t \geq 1$, on observe les temps de trajets $l_{i,t}$ des arêtes i parcourues ($\Leftrightarrow \tilde{x}_{i,t} = 1$)
Sur l'ex: durée $(A \rightarrow A_1)$, durée $(A_1 \rightarrow A_2)$, durée $(A_2 \rightarrow A_3)$ et durée $(A_3 \rightarrow B)$

versus

BANDITS



Et chaque date $t \geq 1$, on observe le temps de trajet total $\sum_{i: \tilde{x}_{i,t}=1} l_{i,t}$ du chemin \tilde{x}_t parcouru.
Sur l'ex: durée $(A \rightarrow A_1 \rightarrow A_2 \rightarrow A_3 \rightarrow B)$.

On ne traitera ici que le cas "semi-bandits" linéaires, mais le pb des bandits linéaires est également abordable.

Comment se ramener au cas de l'information parfaite? \Rightarrow On estime le gradient $\nabla l_t(x_t) = \underline{l}_t$.

On estime $l_{i,t}$ par $\tilde{l}_{i,t} = \frac{l_{i,t} \tilde{x}_{i,t}}{x_{i,t}} = \begin{cases} \frac{l_{i,t}}{x_{i,t}} & \text{si } \tilde{x}_{i,t} = 1 \text{ (bras } i \text{ joué à l'instant } t) \\ 0 & \text{sinon} \end{cases}$

On vérifie immédiatement que $E[\tilde{l}_{i,t} | \mathcal{F}_{t-1}] = \frac{l_{i,t}}{x_{i,t}} E[\tilde{x}_{i,t} | \mathcal{F}_{t-1}] = l_{i,t}$
 \Rightarrow estimateur sans biais.

L'algorithme de descente miroir séquentielle vu en section II a été étudié pour toute suite l_1, l_2, l_3, \dots de fonctions de pertes convexes et sous-différentiables.

Pour alors donc pouvoir appliquer trajectorialement (pour tout tirage $\omega \in \Omega$) l'algo de descente miroir séquentielle avec les fonctions de pertes

$$\langle \tilde{l}_1, \cdot \rangle, \langle \tilde{l}_2, \cdot \rangle, \langle \tilde{l}_3, \cdot \rangle, \dots$$

Théorème 2: l'algorithme de descente miroir séquentielle appliqué aux fonctions de pertes $\langle \tilde{l}_t, \cdot \rangle, t \geq 1$, avec $G = \{x \in \{0,1\}^K : \sum_{i=1}^K x_i = m\}$, $x_1 = (\frac{m}{K}, \dots, \frac{m}{K})$ et $F: \mathbb{R}_+^K \rightarrow \mathbb{R}$ vérifie:

$$x \mapsto \sum_{i=1}^K x_i \ln x_i - \sum_{i=1}^K x_i$$

$$\mathbb{E} \left[\sum_{t=1}^T \langle \tilde{l}_t, \tilde{x}_t \rangle \right] - \inf_{x \in G} \sum_{t=1}^T \langle \tilde{l}_t, x \rangle \leq \frac{m}{\eta} \ln \frac{K}{m} + \frac{\eta}{2} \sum_{t=1}^T \sum_{i=1}^K \mathbb{E} [x_{i,t} \tilde{l}_{i,t}^2]$$

$$\leq \sqrt{2TKm \ln \frac{K}{m}}$$

où la $\frac{1}{2}$ -ineégalité est vraie avec $\eta = \sqrt{\frac{2m}{TK} \ln \frac{K}{m}}$.

Rem: on retrouve la borne en $\sqrt{TK \ln K}$ des bandits usuels (correspond à $m=1$ et $G = \{e_1, \dots, e_K\} =$ sommets du simplexe).

Ce terme de complexité $m \ln \frac{K}{m}$ correspond à $\ln \binom{K}{m} \leq \ln \left[\left(\frac{eK}{m} \right)^m \right] \leq m \ln \left(\frac{eK}{m} \right)$.

En fait, le terme $\sqrt{\ln \frac{K}{m}}$ n'est pas nécessaire, car d'autres choix de la fonction F conduisent à la borne \sqrt{TKm} ; cf. le survey de Bubeck et Cesa-Bianchi (p. 73-81).

Preuve: D'après le thm 1 et la remarque qui précède le thm 2, on a: $\forall x \in C,$

$$(*) \text{ p.s. } \sum_{t=1}^T \langle \tilde{l}_t, x_t \rangle \leq \sum_{t=1}^T \langle \tilde{l}_t, x \rangle + \frac{D_F(x, x_1)}{\eta} + \frac{1}{\eta} \sum_{t=1}^T D_{F^*}(\nabla F(x_t) - \eta \tilde{l}_t, \nabla F(x_t))$$

Majorons les deux derniers termes. Après quelques manipulations élémentaires sur

$$F(x) = \sum_{i=1}^K x_i (\ln x_i - 1), \text{ on obtient: } \nabla F(x) = (\ln x_i)_{1 \leq i \leq K}, \nabla(F^*)(y) = (\nabla F)^*(y) = (e^{y_i})_{1 \leq i \leq K}$$

$$\forall y, z \in \mathbb{R}^K, \quad F^*(y) = \sum_{i=1}^K e^{y_i} \text{ et } D_{F^*}(z, y) = \sum_{i=1}^K (e^{z_i} - e^{y_i}) - \sum_{i=1}^K e^{y_i} (z_i - y_i)$$

D'où:

$$\bullet D_F(x, x_1) = \sum_{i=1}^K x_i \ln \frac{x_i}{x_{i,1}} - \sum_{i=1}^K (x_i - x_{i,1}) \stackrel{= \frac{m}{K}}{\underset{= m - m = 0}{\leq 0}} = \sum_{i=1}^K x_i (\underbrace{\ln x_i}_{\leq 0} + \ln \frac{K}{m}) \leq m \ln \frac{K}{m}$$

(6)

$$\begin{aligned}
\bullet D_{F^*}(\nabla F(x_t) - \eta \tilde{\underline{l}}_t, \nabla F(x_t)) &= D_{F^*}(\ln x_t - \eta \tilde{\underline{l}}_t, \ln x_t) \\
&= \sum_{i=1}^K (x_{i,t} e^{-\eta \tilde{l}_{i,t}} - x_{i,t}) - \sum_{i=1}^K x_{i,t} (-\eta \tilde{l}_{i,t}) \\
&= \sum_{i=1}^K x_{i,t} \left(e^{-\eta \tilde{l}_{i,t}} - (-\eta \tilde{l}_{i,t}) - 1 \right) \\
&\leq \frac{\eta^2 \tilde{l}_{i,t}^2}{2} \text{ car } e^{-x} - 1 \leq \frac{x^2}{2} \text{ pour tout } x \leq 0.
\end{aligned}$$

En injectant les 2 majorations \uparrow dans $(*)$, puis en prenant l'espérance, il vient: $\forall x \in C$,

$$\sum_{t=1}^T E[\langle \tilde{\underline{l}}_t, x_t \rangle] \leq \sum_{t=1}^T \langle E[\tilde{\underline{l}}_t], x \rangle + \frac{m}{\eta} \ln \frac{K}{m} + \frac{\eta}{2} \sum_{t=1}^T \sum_{i=1}^K E[x_{i,t} \tilde{l}_{i,t}^2].$$

Pour conclure, il suffit de remarquer que

$$\bullet E[\langle \tilde{\underline{l}}_t, x_t \rangle | \mathcal{F}_{t-1}] = \langle E[\tilde{\underline{l}}_t | \mathcal{F}_{t-1}], x_t \rangle = \langle \underline{l}_t, x_t \rangle = \langle \underline{l}_t, E[\tilde{x}_t | \mathcal{F}_{t-1}] \rangle = E[\langle \underline{l}_t, \tilde{x}_t \rangle | \mathcal{F}_{t-1}]$$

$$\bullet E[\tilde{\underline{l}}_t] = E[E[\tilde{\underline{l}}_t | \mathcal{F}_{t-1}]] = \underline{l}_t. \text{ D'où la 1^{ère} inégalité du thm.}$$

$$\text{Car, } E[x_{i,t} \tilde{l}_{i,t}^2 | \mathcal{F}_{t-1}] = E[x_{i,t} \frac{\tilde{l}_{i,t}^2 \tilde{x}_{i,t}^2}{x_{i,t}} | \mathcal{F}_{t-1}] \stackrel{\tilde{x}_{i,t} \leq 1}{\leq} \frac{\tilde{l}_{i,t}^2}{x_{i,t}} E[\tilde{x}_{i,t} | \mathcal{F}_{t-1}] = \tilde{l}_{i,t}^2 \leq 1.$$

D'où:

$$E\left[\sum_{t=1}^T \langle \underline{l}_t, \tilde{x}_t \rangle\right] = \inf_{x \in C} \sum_{t=1}^T \langle \underline{l}_t, x \rangle \leq \frac{m}{\eta} \ln \frac{K}{m} + \frac{\eta TK}{2} = \sqrt{2TK m \ln \frac{K}{m}}$$

$$\text{en posant } \eta = \sqrt{\frac{2m}{TK} \ln \frac{K}{m}} \quad \blacksquare$$

Rem: la même étude est valable si les vecteurs de perte \underline{l}_t sont choisis par un observateur antagoniste (i.e. en fonction du passé $\mathcal{F}_{t-1} = \sigma(\tilde{x}_1, \dots, \tilde{x}_{t-1})$), auquel cas les \underline{l}_t sont aléatoires (il faut ajouter une espérance autour de $\langle \underline{l}_t, x \rangle$ ds le thm \circledast).

Efficacité algorithmique?

• Même si $C = \text{conv}(C) = \{q \in [0,1]^K : \sum_{i=1}^K q_i = m\}$ n'est pas un K -simplexe, on peut sûrement vérifier que l'algo de descente miroir séquentielle avec

la fonction entropie $F(x) = \sum_{i=1}^K x_i \ln x_i - \sum_{i=1}^K x_i$ donne lieu aux poids exponentiels:

$$x_{i,t} = m \frac{\exp\left(-\eta \sum_{s=1}^{t-1} \tilde{\ell}_{i,s}\right)}{\sum_{j=1}^K \exp\left(-\eta \sum_{s=1}^{t-1} \tilde{\ell}_{j,s}\right)}, \quad 1 \leq i \leq K, \quad t \geq 1.$$

ou encore:
$$x_{i,t} = m \frac{x_{i,t-1} e^{-\eta \tilde{\ell}_{i,t-1}}}{\sum_{j=1}^K x_{j,t-1} e^{-\eta \tilde{\ell}_{j,t-1}}}$$

donc le calcul itératif des $x_t \in \mathbb{C}$ ne requiert que $O(K)$ opérations élémentaires à chaque itération t .

- Il existe par ailleurs un moyen efficace de tirer aléatoirement $\tilde{x}_t \in \mathbb{C}$ pour que $E[\tilde{x}_t | \mathcal{F}_{t-1}] = x_t$.

(Première idée naïve: puisque $x_t \in \mathbb{C} = \text{conv}(\mathbb{C})$, il existe une proba $q = (q_x)_{x \in \mathbb{C}}$ sur \mathbb{C} telle que $x_t = \sum_{x \in \mathbb{C}} q_x x$. On tire alors $\tilde{x}_t \sim q$. \rightarrow mauvaise complexité algèbre car \mathbb{C} est gros!

Implémentation efficace du tirage de \tilde{x}_t : [cf Vichaya et al '10 et Gandhi et al '06]

- On part de $q_0 = x_t \in \mathbb{C} = \text{conv}(\mathbb{C})$.
- On construit itérativement des vecteurs $q_1, q_2, \dots, q_{k_{\text{final}}} \in \mathbb{C}$ tels que

$$E[q_k | q_0, \dots, q_{k-1}] = q_{k-1} \text{ et } q_{k_{\text{final}}} \in \mathbb{C} \text{ p.s.} \quad \text{Méthode:}$$

(a) $q_i = q_0, i = 0$

(b) TANT QUE $\exists i \in \{1, \dots, K\} : 0 < q_i < 1$ FAIRE

- Choisir $i \neq j$ tq $0 < q_i < 1$ et $0 < q_j < 1$ (existe car $\sum_{a=1}^K q_a = m \in \mathbb{N}$)
- Poser $\alpha = \min\{1 - q_i, q_j\}$ et $\beta = \min\{q_i, 1 - q_j\}$.
- Mettre à jour q_i et q_j de la façon suivante:

$$(q_i, q_j) \leftarrow \begin{cases} (q_i + \alpha, q_j - \alpha) & \text{avec proba } \frac{\beta}{\alpha + \beta} \\ (q_i - \beta, q_j + \beta) & \text{avec proba } \frac{\alpha}{\alpha + \beta} \end{cases}$$

(c) Poser $k \leftarrow k+1$ et $q_k \leftarrow q$

FIN TANT QUE

(c) $k_{\text{final}} \leftarrow k$

- On renvoie $\tilde{x}_t = q_{k_{\text{final}}} \in \mathbb{C}$. Cette randomisation est efficace d'un point de vue algèbre car le nombre d'itérations k_{final} vérifie $k_{\text{final}} \leq K$ (puisque l'une des coordonnées q_i ou q_j devient 0 ou 1 à chaque itération).

||| BILAN: à chaque date $t \geq 1$, l'obtention de x_t et \tilde{x}_t ne requiert que $O(K)$ opérations élémentaires. ⑧

Extensions du problème (cf survey de Bubeck & Cesa-Bianchi)

- information de type "bandits" au lieu de "semi-bandits"
→ algo "John's exploration" for ex
- autres compacts convexes $C \subset \mathbb{R}^K$ (ex: boule euclidienne)
- fonctions de pertes non-linéaires
- etc