

Prédiction de suites individuelles
Cours 2 : Prédiction avec experts (suite)

Gilles Stoltz (CNRS – Ecole normale supérieure – HEC Paris)

Jeudi 5 mai 2011

RAPPELS: Jeu répété de prédiction.Paramètres: N experts $j=1, \dots, N$ Ensemble d'observations \mathcal{Y} (arbitraire), ensemble de prédictions \mathcal{X} (convexe)Pour tous les tours $t=1, 2, \dots$

- 1) les experts procurent les conseils $f_{1t}, \dots, f_{Nt} \in \mathcal{X}$, révélés au statisticien;
- 2) l'environnement choisit l'observation $y_t \in \mathcal{Y}$, sans la révéler au statisticien;
- 3) le statisticien forme une prédiction $\hat{p}_t \in \mathcal{X}$, généralement de la forme
$$\hat{p}_t = \sum_{j=1}^N \lambda_{jt} f_{jt} \quad \text{ou} \quad (\lambda_{jt})_{j=1, \dots, N} \text{ est une combinaison convexe;}$$
- 4) y_t est alors révélée au statisticien.

Evaluation: Une fonction de perte $l: \mathcal{X} \times \mathcal{Y} \rightarrow [0, M]$ est donnée.

On veut minimiser la différence entre la perte cumulée du

statisticien $\hat{L}_n = \sum_{t=1}^n l(\hat{p}_t, y_t)$ et celle des experts

$$L_{jn} = \sum_{t=1}^n l(f_{jt}, y_t).$$

Cette différence est appelée le regret

$$R_n = \hat{L}_n - \min_{j=1, \dots, N} L_{jn}.$$

On veut des stratégies telles que

$$\sup R_n \leq o(n)$$

où le supremum est pris sur l'ensemble des suites y_1, \dots, y_n (cas d'un environnement ne réagissant pas aux prédictions du statisticien) ou des stratégies de l'environnement (cas du jeu contre le diable).

Algorithme: L'algorithme de pondération par poids exponentiels des performances

proposé $\mu_1 = (\frac{1}{N}, \dots, \frac{1}{N})$

puis pour $t \geq 2$, μ_t définie par $\mu_{jt} = \frac{\exp(-\eta L_{jt-1})}{\sum_{k=1}^N \exp(-\eta L_{kt-1})}$

Théorème: Si pour tout $y \in Y$, $l(\cdot, y)$ est convexe, alors le choix $\eta = \frac{1}{M} \sqrt{\frac{8 \ln N}{n}}$ assure que

$$\sup R_n \leq M \sqrt{\frac{n}{2} \ln N}.$$

Remarque: Nous avons vu comment nous passer de la connaissance de μ_1 pour calibrer η .

Application: Le lemme de Sion.

Soient X et Y deux ensembles convexes et $f: X \times Y \rightarrow [0, M]$ une fonction telle que

- $\forall x \in X$, $f(x, \cdot)$ est concave,
- $\forall y \in Y$, $f(\cdot, y)$ est convexe.

Alors, sous des hypothèses de régularité (p.ex. X, Y métriques, et f uniformément continue sur $X \times Y$, et X compact),

$$\inf_{x \in X} \sup_{y \in Y} f(x, y) = \sup_{y \in Y} \inf_{x \in X} f(x, y).$$

Optimalité (asymptotique), y compris de la constante :

Théorème: Pour $X = [0, 1]$, $Y = \{0, 1\}$ et $l(x, y) = |x - y|$, toute stratégie de prédiction encourt un regret R_n tel que

$$\liminf_{N \rightarrow +\infty} \sup R_n / \sqrt{\frac{n}{2} \ln N} \geq 1$$

où il suffit de prendre le sup sur des suites individuelles d'observations y_t et de conseils d'experts $f_{jt} \in \{0, 1\}$.

Preuve: Randomisation des X_t et des F_{jt} iid $\sim \text{Ber}(1/2)$...

$$\sup_{y_t, f_t} \left\{ \sum_{t=1}^n |\hat{p}_t - y_t| - \min_{j=1, \dots, N} \sum_{t=1}^n |f_{jt} - y_t| \right\} = \sup R_n$$

$$\geq E \left[\sum_{t=1}^n |\hat{p}_t - y_t| - \min_{j=1, \dots, N} \sum_{t=1}^n |f_{jt} - y_t| \right] = E[R_n]$$

y_t tq. f_{jt} et $f_{jt} \sim B(\frac{1}{2})$
 tous id

$$= \dots = \frac{n}{2} - E \left[\min_{j=1, \dots, N} B_{jn} \right]$$

cf. calculs ci-dessous

où les B_{jn} sont id $\sim Bn(n, \frac{1}{2})$

On fait apparaître une quantité du type de celle du TCL :

$$Z_{jn} = 2 \left(\frac{n/2 - B_{jn}}{\sqrt{n}} \right) \xrightarrow{d} \mathcal{N}(0, 1)$$

$$E[R_n] = \frac{\sqrt{n}}{2} E \left[\max_{j \leq N} 2 \left(\frac{n/2 - B_{jn}}{\sqrt{n}} \right) \right] \underset{n \rightarrow \infty}{\sim} \frac{\sqrt{n}}{2} E \left[\max_{j \leq N} G_j \right]$$

où G_j id $\sim \mathcal{N}(0, 1)$

puis on utilisera que :

$$E \left[\max_{j \leq N} G_j \right] \sim \sqrt{2 \ln N}$$

HEURISTIQUE

- 1) Puisque les y_t sont indépendantes de tout le reste et $\sim \text{Ber}(\frac{1}{2})$, notant
- $$E_t = E \left[\cdot \mid F_t \text{ où } j=1, \dots, N \text{ et } s=1, \dots, t \text{ et } y_s \text{ où } s=1, \dots, t \right]$$
- l'espérance conditionnelle par rapport à l'information disponible au statisticien au début du tour t (pour former \hat{p}_t), il vient, \hat{p}_t étant ainsi

fin :

$$E_t [\mathbb{1}(\hat{p}_t = y_t)] = E [|\hat{p}_t - y_t|] = \frac{1}{2} \hat{p}_t + \frac{1}{2} (1 - \hat{p}_t) = \frac{1}{2}$$

soit au final : $E[\hat{L}_n] = \frac{n}{2}$

(Morale : c'est dû à la contrainte de prédiction séquentielle.)

Tandis que : $L_{jt} = \sum_{t=1}^n |F_{jt} - Y_t|$, dont on fait une évaluation rétrospective.

Conditionnellement à Y_1, \dots, Y_n , les $|F_{jt} - Y_t|$ sont iid $\sim \text{Ber}(1/2)$ lorsque j et t varient, de sorte que les L_{jt} sont iid $\sim \text{Bin}(n, 1/2)$ lorsque j varie.

De plus, cette loi commune est indépendante des Y_1, \dots, Y_n .

$$\begin{aligned} \text{Ainsi : } E[R_n] &= E[L_n] - E\left[E\left[\min_{j=1, \dots, N} L_{jn} \mid Y_1, \dots, Y_n \right] \right] \\ &= \frac{n}{2} - E\left[\min_{j=1, \dots, N} B_{jn} \right] \end{aligned}$$

où B_{1n}, \dots, B_{Nn} sont N variables aléatoires iid $\sim \text{Bin}(n, 1/2)$.

$$\begin{aligned} \text{Soit : } E[R_n] &= \sqrt{n} \left(E\left[\max_{j=1, \dots, N} \frac{(n/2 - B_{jn})}{\sqrt{n}} \right] \right) \\ &= \sqrt{\frac{n}{2}} E\left[\max_j Z_{jn} \right] \end{aligned}$$

où :

$$2) \text{ Par TCL, } Z_{jn} = 2 \left(\frac{n/2 - B_{jn}}{\sqrt{n}} \right) \rightarrow \mathcal{N}(0, 1)$$

Les Z_{jn} étant indépendants lorsque j varie, on tire de ces convergences marginales une convergence jointe :

$$\begin{pmatrix} z_{1n} \\ \vdots \\ z_{Nn} \end{pmatrix} \rightarrow \mathcal{U}(\mathbf{0}, \mathbf{I}_N).$$

On veut maintenant prouver la convergence des espérances (attention ! ce n'est pas impliqué en général par la convergence en loi).

En fait, vu l'énoncé du théorème, on veut juste prouver

$$\liminf_{n \rightarrow +\infty} E\left[\max_{j=1, \dots, N} z_{jn}\right] \geq E\left[\max_{j=1, \dots, N} G_j\right].$$

Soit ϕ_L la fonction seuil à L : $\phi_L : x \in \mathbb{R} \mapsto \begin{cases} x & \text{si } x \in [-L, L] \\ -L & \text{si } x < -L \\ L & \text{si } x > L \end{cases}$

$(z_1, \dots, z_N) \mapsto \phi_L(\max_j z_j)$ étant continue bornée :

$$\forall L > 0, \quad E\left[\phi_L(\max_j z_{jn})\right] \rightarrow E\left[\phi_L(\max_j G_j)\right]$$

$$\text{Or,} \quad E\left[\max_j z_{jn}\right] \geq E\left[\phi_L(\max_j z_{jn})\right] + E\left[\underbrace{(L + \max_j z_{jn}) \mathbb{1}_{\{\max_j z_{jn} \leq -L\}}}_{\text{est égal, par théorème de Fubini, à } -\int_{-\infty}^0 \mathbb{P}\{\max_{j=1, \dots, N} z_{jn} \leq u - L\} du.}$$

En effet, pour X variable aléatoire, vu la "positivité" (négativité) :

$$E[X \mathbb{1}_{\{X \leq 0\}}] = \int_{-\infty}^0 x dP^X(x)$$

$$= \int_{(\mathbb{R}^-)^2} (-\mathbb{1}_{\{x \leq u \leq 0\}}) dP^X(x) du$$

$$= -\int_{-\infty}^0 \mathbb{P}\{X \leq u\} du$$

et on applique cela à $X = \max_j z_{jn} + L$

Or (pour $d \leq 0$) $P\{\max_{j \leq N} z_j \leq d\} = (P\{z_n \leq d\})^N$
 (Markov) $\leq \left(\frac{\text{Var } z_n}{d^2}\right)^N = \frac{1}{d^{2N}}$ Par construction, $\text{Var } z_n = 1$

et donc $E[(L + \max_j z_j) \mathbb{1}_{\{\max_j z_j \leq -L\}}] \geq - \int_{-\infty}^0 \frac{1}{(1-L)^{2N}} dx$
 $= - \int_{-\infty}^{-L} \frac{1}{4^{2N}} dx = - \frac{1}{4^{2N}} L \xrightarrow{L \rightarrow +\infty} 0$

Au final,
 $\forall L > 0,$

$$\liminf_{n \rightarrow +\infty} E[\max_j z_j] \geq \liminf_{n \rightarrow +\infty} E[\Phi_L(\max_j z_j)] - r_{L,N}$$

$$= E[\Phi_L(\max_j G_j)] - r_{L,N}$$

par bornitude + cv en loi

Ceci valant pour tout L , et vu $r_{L,N} \xrightarrow{L \rightarrow +\infty} 0$ ($\bar{\alpha}$ N fixé)

et puisque (par convergence dominée par $|G_1| + \dots + |G_N|$)
 $E[\Phi_L(\max_j G_j)] \rightarrow E[\max_j G_j],$

on a prouvé :

$$\liminf E[\max_j z_j] \geq E[\max_j G_j],$$

soit $\liminf_{n \rightarrow +\infty} \frac{2 E[R_n]}{\sqrt{n}} \geq E[\max_{j=1, \dots, N} G_j].$

Pour conclure, il ne reste qu'à voir que $\liminf_{N \rightarrow +\infty} E[\max_{j=1, \dots, N} G_j] / \sqrt{2 \ln N} \geq 1$

$$E\left[\max_{j \in N} G_j\right] = E\left[\underbrace{\left(\max_{j \in N} G_j\right)^+}_{\text{cette espérance est}}\right] - \underbrace{E\left[\left(\max_{j \in N} G_j\right)^-\right]}_{\leq E[G_1^-]} \leq E[G_1^-] < \sqrt{E[G_1^2]} = 1$$

Soit Ψ_N la fonction de répartition de $\left(\max_{j \in N} G_j\right)^+$

Φ celle de la $u(a_1)$

$\Phi_N = \Phi^N$ celle de $\max_{j \in N} G_j$

Alors $\Psi_N(0) = \Phi_N(0) = (\Phi(0))^N = 2^{-N}$

et pour $t > 0$, $\Psi_N(t) = (\Phi(t))^N$; en particulier, Ψ_N est inversible sur \mathbb{R}_+^*

D'où l'inverse généralisé: $\Psi_N^{(-1)}(u) = \begin{cases} 0 & \text{si } u < 2^{-N} \\ \Phi^{-1}(u^{1/N}) & \text{si } u > 2^{-N} \end{cases}$
 $= \inf\{x : \Psi_N(x) \geq u\}$

Ainsi, $E\left[\left(\max_{j \in N} G_j\right)^+\right] = \int_0^1 \Psi_N^{(-1)}(u) du = \int_{2^{-N}}^1 \underbrace{\Phi^{-1}(u^{1/N})}_{\substack{\text{fonction croissante} \\ \text{et } \geq 0}} du \geq \int_{\delta}^1 \Phi^{-1}(u^{1/N}) du$
 (cf. si X r.a. de f.r.F, d'inverse généralisé $F^{(-1)}$, alors $E[X] = E[F^{(-1)}(U)]$ où $U \sim \mathcal{U}(0,1)$)
 pour tout $\delta > 0$, au moins pour N assez grand

On a donc prouvé:

$$\forall \delta > 0, \lim_{N \rightarrow +\infty} \frac{E\left[\max_{j \in N} G_j\right]}{\sqrt{2 \ln N}} \geq (1-\delta) \frac{\Phi^{-1}(\delta^{1/N})}{\sqrt{2 \ln N}} = \lim_{N \rightarrow +\infty} \frac{E\left[\left(\max_{j \in N} G_j\right)^+\right]}{\sqrt{2 \ln N}} \geq \lim_{N \rightarrow +\infty} \frac{(1-\delta) \Phi^{-1}(\delta^{1/N})}{\sqrt{2 \ln N}}$$

Or (exercice):

$$1 - \Phi(x) \sim \frac{e^{-x^2/2}}{x\sqrt{2\pi}} \text{ quand } x \rightarrow +\infty \text{ d'où } \frac{1}{1-\Phi(x)} \sim e^{x^2/2} x\sqrt{2\pi}$$

Comme $\Phi^{-1}(v) \xrightarrow[v \rightarrow 0]{} +\infty$, il vient: $\frac{1}{1-v} = \frac{1}{1-\Phi(\Phi^{-1}(v))} \sim e^{+\Phi^{-1}(v)^2/2} \times \Phi^{-1}(v) \sqrt{2\pi}$

et en passant aux logarithmes:

$$\ln\left(\frac{1}{1-\delta}\right) \sim + \phi^{-1}(\delta)^2/2 \quad \text{puis} \quad \phi^{-1}(\delta) \sim \sqrt{2 \ln\left(\frac{1}{1-\delta}\right)}$$

quand $\delta \rightarrow 1$

On va réinjecter cet équivalent:

$$(1-\delta) \Phi^{-1}(\delta^{1/N}) \underset{N \rightarrow +\infty}{\sim} (1-\delta) \sqrt{2 \ln\left(\frac{1}{1-\delta^{1/N}}\right)}$$

$$\sim (1-\delta) \sqrt{2 \ln N}$$

car $1-\delta^{1/N} = 1 - \exp\left(\frac{1}{N} \ln \delta\right) \sim \frac{1}{N} \ln \delta$

Au final: $\forall \delta > 0, \quad \lim_{N \rightarrow +\infty} \frac{\mathbb{E}[\max_{j \in N} G_j]}{\sqrt{2 \ln N}} \geq \lim_{N \rightarrow +\infty} \frac{(1-\delta) \Phi^{-1}(\delta^{1/N})}{\sqrt{2 \ln N}} = 1-\delta$

d'où suit le résultat désiré, en faisant $\delta \rightarrow 0$.

Exercice: $\Phi(x) = \int_{-\infty}^x \frac{e^{-t^2/2}}{\sqrt{2\pi}} dt$, abs $1-\Phi(x) \underset{x \rightarrow +\infty}{\sim} \frac{e^{-x^2/2}}{\sqrt{2\pi}}$.

Preuve:

$$\frac{1}{\sqrt{2\pi}} \int_x^{+\infty} e^{-t^2/2} dt = \frac{1}{\sqrt{2\pi}} \int_x^{+\infty} t e^{-t^2/2} \cdot \frac{1}{t} dt$$

$$\stackrel{\text{IPP}}{=} \left[-\frac{1}{\sqrt{2\pi}} \frac{e^{-t^2/2}}{t} \right]_x^{+\infty} - \frac{1}{\sqrt{2\pi}} \int_x^{+\infty} \frac{e^{-t^2/2}}{t^2} dt$$

$$= \frac{e^{-x^2/2}}{x \sqrt{2\pi}} \quad \text{or, à nouveau par IPP,}$$

$$0 \leq \frac{1}{\sqrt{2\pi}} \int_x^{+\infty} \frac{t e^{-t^2/2}}{t^2} dt = \left[-\frac{1}{\sqrt{2\pi}} \frac{e^{-t^2/2}}{t^3} \right]_x^{+\infty} - \int_x^{+\infty} \dots$$

de sorte que ce terme est dominant.

donc est $\leq \frac{e^{-x^2/2}}{x^3 \sqrt{2\pi}}$

Rappel: Si $f(x) \sim g(x)$ et que $\begin{cases} f(x) \rightarrow \text{Cste} \neq 1 \\ f(x) \rightarrow +\infty \end{cases}$ alors $\ln f(x) \sim \ln g(x)$
 En effet, $\ln f(x) = \ln f(x)/g(x) + \ln g(x) \sim \ln g(x)$

En fait, le sens difficile était la minoration. On peut montrer que $E[\max_{j \leq N} G_j] \sim \sqrt{2 \ln N}$, via le résultat plus général suivant, qui indique que $E[\max_{j \leq N} G_j] \leq \sqrt{2 \ln N}$.

Lm: Soit $\sigma > 0$ et X_1, \dots, X_N (ni nécessairement indépendantes ni nécessairement identiquement distribués) de fonctions génératrices sous-gaussiennes* :

$$E[e^{dX_i}] \leq e^{d^2 \sigma^2 / 2} \quad \forall d > 0.$$

$$\text{Alors} \quad E[\max_{i=1, \dots, N} X_i] \leq \sigma \sqrt{2 \ln N}.$$

Preuve:

$$\begin{aligned} e^{-d} E[\max_{i=1, \dots, N} X_i] &\leq E[e^{-d \max_i X_i}] \\ &\stackrel{[\text{Jensen}]}{\leq} E[e^{-\max_{i=1, \dots, N} dX_i}] \\ &= E[\max_{i=1, \dots, N} \underbrace{e^{-dX_i}}_{\geq 0}] \\ &\leq \sum_{i=1}^N E[e^{-dX_i}] \\ &\stackrel{[\text{majoration dite "à la Pinsker"}]}{\leq} N e^{d^2 \sigma^2 / 2} \end{aligned}$$

et donc

$$E[\max X_i] \leq \frac{1}{d} \ln(N e^{d^2 \sigma^2 / 2})$$

$$= \underbrace{\frac{\ln N}{d} + d \sigma^2 / 2}$$

est minimal pour d tq. $d^2 = \frac{2 \ln N}{\sigma^2}$,

ie., $d = \sqrt{\frac{2 \ln N}{\sigma^2}}$, ce qui conclut.

* Des exemples de tels variables aléatoires sont celles vérifiant les hypothèses du lemme de Hoeffding par ex., ou, évidemment, les variables gaussiennes.

RÉSUMÉ & NOUVEAUX OBJECTIFS.

[Dans le cas non randomisé,
ou $\ell(\cdot, y)$ est convexe et y_t .

→ Agrégation séquentielle convexe de conseils d'experts :

$$\text{Regret } R_n = \hat{L}_n - \min_{j=1, \dots, N} L_{j,n}$$

$$\hat{L}_n = \sum_{t=1}^n \ell(\hat{p}_t, y_t) \quad \text{ou} \quad \hat{p}_t = \sum_{j=1}^N p_{j,t} p_j$$

$$\min_{j=1, \dots, N} L_{j,n} = \sum_{t=1}^n \ell(f_{j,t}, y_t) \stackrel{\text{not.}}{=} L_{j,n}$$

Algorithme :

$$\mu_1 = (\frac{1}{N}, \dots, \frac{1}{N}) \quad \text{et pour } t \geq 2,$$

$$p_{j,t} = \frac{\exp(-\eta_t L_{j,t-1})}{\sum_{k=1}^N \exp(-\eta_t L_{k,t-1})}$$

Th: Pour un choix adaptatif des η_t ,

$$\text{sup } R_n \leq \alpha \| \ell \|_{\infty} \sqrt{n \ln N}$$

où les ordres de grandeur en n et N sont optimaux en général. (On veut de prouver cette optimalité.)

→ Objectifs suivants :

- (1) Améliorer la vitesse avec des hypothèses sur ℓ (exp-concavité / convexité forte)
- (2) Se comparer non pas seulement au meilleur expert j mais à la meilleure combinaison convexe q d'experts

↳ si $q = (q_1, \dots, q_N)$ est une telle combinaison,

$$L_n(q) = \sum_{t=1}^n \ell\left(\sum_{j=1}^N q_j f_{j,t}, y_t\right)$$

et on veut que
soit petit.

$$\text{sup } R_n^{\text{conv}} \hat{=} \text{sup } \left\{ \hat{L}_n - \inf_q L_n(q) \right\}$$

"souvent", cet
inf sera
un min.

EXP-CONCAVITÉ.

Def: l est η -exp-concave (ou η -fortement convexe) si pour tout $y \in Y$,

$$F_{\eta, y} = e^{-\eta l(\cdot, y)} \text{ est concave.}$$

Ex1: Perte-log #1 (marché boursier):
 $X = \mathcal{P}$ simplexe de \mathbb{R}^N (les experts proposent chacun une allocation de capitaux)
 $Y = (\mathbb{R}_+)^N$ (éventuellement infini)
 $l(x, y) = -\log x \cdot y$
 l est 1-exp-concave ($\eta_0 = 1$)

On y revient en détails plus tard

Ex2: Perte-log #2 (liens avec le codage séquentiel → hélas, on n'aura pas le temps de développer ces liens)
 $X = \mathcal{P}$ simplexe de \mathbb{R}^A
 $Y = A = \{1, \dots, m\}$ un alphabet fini
 $l(p, y) = -\log p_y$ (éventuellement infini)
 l est 1-exp-concave ($\eta_0 = 1$)

les experts proposent chacun une probabilité sur A

Ex3: Perte quadratique (prédictions statistiques)

$$X = Y = [0, B]$$

$$l(x, y) = (x - y)^2$$

Les $F_{\eta, y}$ sont deux fois dérivables, avec

$$F'_{\eta, y}(x) = -2\eta(y - x) e^{-\eta(x - y)^2}$$

$$F''_{\eta, y}(x) = [(2\eta(x - y))^2 - 2\eta] e^{-\eta(x - y)^2}$$

et la condition de concavité est que

$$F''_{\eta, y} \leq 0$$

$$\text{soit } \eta \leq \frac{1}{2(x - y)^2} \quad \forall x, y$$

Par exemple, $\eta_0 = \frac{1}{2B^2}$ est tel que

l est η_0 -exp-concave.

Rq: L'exp. concavité entraîne la convexité:

$$l(\cdot, y) = -\frac{1}{\eta} \log F_{\eta, y} \quad \text{où } -\frac{1}{\eta} \log$$

Convexe et
décroissante.

Stratégie 1: Mélange fini sur les experts

$$\text{EWA}(\eta): \begin{cases} t \geq 2, & \mu_{jt} = \exp(-\eta L_{jt-1}) / \sum_{k=1}^N \exp(-\eta L_{kt-1}) \\ \text{et } \hat{P}_t = \sum_{j=1}^N \mu_{jt} f_{jt}. \end{cases}$$

Th1: Si l est η -exp. concave, alors le regret de $\text{EWA}(\eta)$ est borné par

Rq: Pas d'hyp. sur le caractère borné ou non de l !

$$\sup R_n \leq \frac{\ln N}{\eta}.$$

Preuve: $w_{jt} = \exp(-\eta L_{jt})$ et $W_t = w_{1t} + \dots + w_{Nt}$

$$\ln \frac{w_{jt}}{w_{j0}} \geq -\eta L_{jt} - \ln N$$

$$t=1 \dots n: \quad \ln \frac{W_t}{W_{t-1}} = \ln \sum_{j=1}^N \mu_{jt} e^{-\eta l(f_{jt}, y_t)}$$

$$\leq \ln e^{-\eta l(\sum_{j=1}^N \mu_{jt} f_{jt}, y_t)} \quad [\text{exp. concavité}]$$

$$= -\eta l(\hat{P}_t, y_t).$$

Stratégie 2: Mélange uniforme: $\mu_1 = (\frac{1}{N}, \dots, \frac{1}{N})$ et pour $t \geq 2$,

$$\text{Unif}(\eta): \quad \mu_t = \int_{\mathcal{J}} q e^{-\eta L_{t-1}(q)} d\mu(q) / \int_{\mathcal{J}} e^{-\eta L_{t-1}(q)} d\mu(q)$$

où μ est la mesure uniforme sur \mathcal{J} (dérivée de Lebesgue).

Note: Cette stratégie est reminiscente du mélange de Laplace en codage.

Rq: Comment calculer μ_t en pratique (avec MATLAB)? Un argument de discrétisation (grille de pas ε) est trop coûteux: $\approx 1/\varepsilon^{N-1}$

Par méthode stochastique plutôt :

On utilise que par loi des grands nombres, si Q_1, Q_2, \dots sont tirés au hasard (i.e. selon μ) dans \mathcal{P} , alors pour toute fonction f bornée, éventuellement à valeurs N -dimensionnelles,

$$\text{ lorsque } m \text{ est grand } \int_{\mathcal{P}} f(q) d\mu(q) \approx \frac{1}{m} \sum_{k=1}^m f(Q_k)$$

$$\text{ (en fait, précisément : } \frac{1}{m} \sum_{k=1}^m f(Q_k) \xrightarrow[m \rightarrow \infty]{\text{ps}} \int_{\mathcal{P}} f(q) d\mu(q) \text{)}$$

Mais comment tirer iid selon μ ?

Une méthode est de tirer X_1, \dots, X_{N-1} iid $\sim U_{[0,1]}$

de les réordonner $X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(N-1)}$

puis de considérer les N segments créés :

$$Q = (X_{(1)}, X_{(2)} - X_{(1)}, \dots, X_{(N-1)} - X_{(N-2)}, 1 - X_{(N-1)}).$$

Théorème. Si ℓ est η -exp. concave et prend ses valeurs dans $[0, M]$, alors la stratégie de mélange continu $\text{Mix}(\eta)$ est telle que

$$\sup R_n^{\text{mix}} = \sup \{ \hat{L}_n - \inf_{q \in \mathcal{P}} L_n(q) \} \leq \frac{N-1}{\eta} \max \left\{ 1, \log \frac{e \eta M n}{N-1} \right\}.$$

Rq: On atteint donc une vitesse $\log n \ll \sqrt{n}$ malgré la comparaison à la meilleure combinaison convexe constante. // Note: Il n'y a pas de problème majeur d'homogénéité en M dans la borne, puisque η varie inversement en $1/M$.

Preuve: On note que pour tout t , $\ell(\mu_t \cdot (\frac{f}{\|f\|})_j, y_t) = -\frac{1}{\eta} \log e^{-\eta \ell(\mu_t \cdot (\frac{f}{\|f\|})_j, y_t)}$

où l'on a utilisé $\left. \begin{array}{l} \text{l'inégalité de Jensen} \\ \text{la convexité forte} \end{array} \right\} \leq -\frac{1}{\eta} \log \frac{\int_{\mathcal{P}} e^{-\eta \ell(q \cdot (\frac{f}{\|f\|})_j, y_t) - \eta L_{t-1}(q)} d\mu(q)}{\int_{\mathcal{P}} e^{-\eta L_{t-1}(q)} d\mu(q)}$

et la décroissance de $-\log$

Soit
$$l(\mu \cdot (\frac{f_t}{f_t}), y_t) \leq -\frac{1}{\eta} \log \frac{\int_{\mathcal{P}} e^{-\eta L_t(q)} d\mu(q)}{\int_{\mathcal{P}} e^{-\eta L_{t-1}(q)} d\mu(q)}$$

Puis en sommant sur $t=1, 2, \dots$ (et en se rappelant la convention $L_0 = 0$)

Si l'inf n'est pas atteint, on prend q_{ε}^* tq. $L_n(q_{\varepsilon}^*)$ soit proche à ε près de $\inf_{q \in \mathcal{P}} L_n(q)$

$$\hat{L}_n \leq -\frac{1}{\eta} \log \int_{\mathcal{P}} e^{-\eta L_n(q)} d\mu(q).$$

On note $q^* \in \operatorname{argmin}_{q \in \mathcal{P}} L_n(q)$; et on utilise que les q qui sont dans un voisinage de q^* ont des performances similaires à lui :

si $q = (1-\alpha)q^* + \alpha r$ pour $\alpha \in [0, 1]$ et $r \in \mathcal{P}$,
alors comme (par composition et somme) L_n est convexe :

$$L_n(q) \leq (1-\alpha)L_n(q^*) + \alpha L_n(r) \leq (1-\alpha)L_n(q^*) + \alpha M_n$$

de sorte que
$$\int_{\mathcal{P}} e^{-\eta L_n(q)} d\mu(q) \geq e^{-\eta((1-\alpha)L_n(q^*) + \alpha M_n)} \times \mu(V(q^*, \alpha))$$

où $V(q^*, \alpha)$ désigne le α -voisinage de q^* :

$$V(q^*, \alpha) = \{ q : \exists r \in \mathcal{P} \mid q = (1-\alpha)q^* + \alpha r \}$$

Or, μ étant uniforme, $\mu(V(q^*, \alpha)) =$ mesure de Lebesgue de $\alpha \mathcal{P}$ dans l'hyperplan affine engendré par \mathcal{P} $= \alpha^{N-1} \mu(\mathcal{P}) = \alpha^{N-1}$

En réinjectant :

$$\begin{aligned} \hat{L}_n &\leq -\frac{1}{\eta} \log \left(e^{-\eta((1-\alpha)L_n(q^*) + \alpha M_n)} \alpha^{N-1} \right) \\ &= \underbrace{(1-\alpha)}_{\leq 1} L_n(q^*) + \alpha M_n + \frac{N-1}{\eta} \log \frac{1}{\alpha} \end{aligned}$$

$$\hat{L}_n - L_n(q^*) \leq \inf_{\alpha \in [0, 1]} \left\{ \alpha M_n + \frac{N-1}{\eta} \log \frac{1}{\alpha} \right\} \stackrel{\text{not.}}{=} \Psi_{M, N, \eta}$$

(Si on avait q_{ε}^* , alors on a prouvé $\hat{L}_n - \inf_{q \in \mathcal{P}} L_n(q) \leq \varepsilon + \hat{L}_n - L_n(q_{\varepsilon}^*) \leq \varepsilon + \Psi_{M, N, \eta}$ et

il suffit de faire $\varepsilon \rightarrow 0$.)

Reste à calculer $\varphi_{M, N, \eta}$:

$$\varphi: \alpha \in \mathbb{R}_+^* \mapsto \alpha M_n + \frac{N-1}{\eta} \log \frac{1}{\alpha}$$

$$\varphi'(\alpha) = M_n - \frac{N-1}{\eta \alpha}, \quad \varphi''(\alpha) = \frac{N-1}{\eta \alpha^2} > 0$$

donc φ atteint son minimum en $\alpha^* = \frac{N-1}{M_n \eta}$.

mais attention! cette valeur de α n'est pas toujours < 1 !

Ce n'est le cas que si $M_n > \frac{N-1}{\eta}$; pour $M_n < \frac{N-1}{\eta}$, on utilise que le regret est plus petit que \hat{L}_n et donc que $M_n < \frac{N-1}{\eta}$.

$$\text{Pour } M_n > \frac{N-1}{\eta}, \text{ on a } \varphi(\alpha^*) = \frac{N-1}{\eta} + \frac{N-1}{\eta} \log \frac{M_n \eta}{N-1}.$$

Ainsi, dans tous les cas: $\varphi_{M, N, \eta} = \frac{N-1}{\eta} + \frac{N-1}{\eta} \left(\log \frac{M_n \eta}{N-1} \right)^+$, ce qui donne la borne proposée.