

Améliorations de la concentration sur les espaces produits

(7)

I/ Entropie et produit

Conventions d'écriture (formel)

Soit X un ensemble produit, $X = X_1 \times \dots \times X_n$ ($n \geq 1$)

Un élément $x \in X$ s'écrit $x = (x_1, \dots, x_n)$ avec $x_i \in X_i$

→ Soit $f: X \rightarrow \mathbb{R}$

On note f_i la fonction définie sur X_i par

$$f_i(t) = f(x_1, \dots, x_{i-1}, t, x_{i+1}, \dots, x_n)$$

les $x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n$ étant fixes.

C'est à dire qu'on s'intéresse à $f(x) = f_i(x_i)$ comme fonction de x_i .

Il peut être utile de noter, pour $i \leq n$, $\hat{X}_i = \prod_{j \neq i} X_j$

(de sorte qu'à l'adresse, on a " $X = X_i \times \hat{X}_i$ ")

De même, pour $x \in X$, $\hat{x}_i = (x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n) \in \hat{X}_i$

Ainsi la fonction $x_i \rightarrow f_i(x_i)$ est définie par $\hat{x}_i \in \hat{X}_i$ donnée:

[$\hat{x}_i = \hat{y}_i \Leftrightarrow x$ et y ne diffèrent (essentiellement) que de la $i^{\text{ème}}$ coordonnée]

Supposons maintenant que l'on munisse X d'une

proba produit $\mu = \mu_1 \otimes \dots \otimes \mu_n$ avec

μ_i proba sur X_i .

On note $\hat{\mu}_i = \mu_1 \otimes \dots \otimes \mu_{i-1} \otimes \mu_{i+1} \otimes \dots \otimes \mu_n$

↳ proba sur \hat{X}_i

Pour un élément de \hat{X}_i fixe (notons le \hat{x}_i) on a

$$\int_{X_i} f_i(t) d\mu_i(t) = \int_{X_i} f(x) d\mu_i(x)$$

i.e. \rightarrow on intègre $f(x)$ par rapport à la variable x_i et la même $d\mu_i(x_i)$

Par Fubini (structure produit) on a :

$$\int_{\hat{X}_i} \left(\int_{X_i} f_i d\mu_i \right) d\hat{\mu}_i = \int_X f d\mu$$

On a mieux, car on travaille avec des proba. (expérience conditionnelle)

En effet, la fonction

$$\begin{array}{l} \hat{X}_i \longrightarrow \mathbb{R} \\ \hat{x}_i \longrightarrow \int_{X_i} f_i(x_i) d\mu_i(x_i) \end{array}$$

peut être vue comme une fonction sur X ne dépend que de \hat{x}_i

$$\begin{array}{l} X \longrightarrow \mathbb{R} \\ x \longrightarrow \int_{X_i} f_i(x_i) d\mu_i(x_i) \end{array}$$

\uparrow fait de \hat{x}_i seulement

et alors on a :

$$\int_X \left(\int_{X_i} f_i d\mu_i \right) = \int_{\hat{X}_i} \left(\int_{X_i} f_i d\mu_i \right) d\hat{\mu}_i = \int_X f d\mu$$

Entropie

Soit (Ω, μ) un espace de proba et

$f: \Omega \rightarrow \mathbb{R}^+$. On définit

$$\text{Ent}_\mu(f) := \int f \log f \, d\mu - \int f \, d\mu \times \log \int f \, d\mu$$

$$\text{Ent}_\mu(f) = \int f \log \left(\frac{f}{\int f \, d\mu} \right) d\mu$$

$$= \int f \log f \, d\mu \quad \text{si} \quad \int f \, d\mu = 1$$

Notez que pour $F: \Omega \rightarrow \mathbb{R}^+$, on a :

$$\text{Ent}_\mu(e^F) = \int F e^F \, d\mu - \int e^F \, d\mu \log \int e^F \, d\mu$$

Soit comme précédemment X un espace de proba produit

$$X = X_1 \times \dots \times X_n$$

$$\mu = \mu_1 \otimes \dots \otimes \mu_n, \quad \mu_i \text{ proba sur } X_i$$

Soit $f: X \rightarrow \mathbb{R}$. Pour tout $\hat{x}_i \in X_i$ fixe, on

peut définir $\text{Ent}_{\mu_i}(f_i)$. Plus généralement,

pour $x \in X$,

$$\begin{aligned} \left. \begin{aligned} \text{Ent}_{\mu_i}(f_i)(x) &= \text{Ent}_{\mu_i}(f_i)(\hat{x}_i) \\ &= \int_{X_i} f_i(t) \log f_i(t) \, d\mu_i(t) - \int_{X_i} f_i(t) \, d\mu_i(t) \log \int_{X_i} f_i(t) \, d\mu_i(t) \\ &= \int_{X_i} f(x) \log f(x) \, d\mu_i(x_i) - \int_{X_i} f(x) \, d\mu_i(x_i) \log \int_{X_i} f(x) \, d\mu_i(x_i) \end{aligned} \right\} \end{aligned}$$

→ histoire de notations, uniquement

et avec ces notations

$$\int_X \text{Ent}_{\mu_i}(f_i) d\mu_i = \int_{\widehat{X}_i} \text{Ent}_{\mu_i}(f_i) d\widehat{\mu}_i$$

Theo A (Tensorisation de l'entropie)

Soit (X, μ) le produit des espaces de proba $(X_i, \mu_i), i=1, \dots, n$.

Pour $f: X \rightarrow \mathbb{R}^+$ on a

$$\text{Ent}_{\mu}(f) \leq \sum_{i=1}^n \int_X \text{Ent}_{\mu_i}(f_i) d\mu_i$$

à comprendre

Démo On raisonne par récurrence. Il suffit de le montrer pour $n=2$

$$\mu = \mu_1 \otimes \mu_2$$

$$X = X_1 \times X_2$$

$$\text{Soit } f: X_1 \times X_2 \rightarrow \mathbb{R}^+$$

$$d\mu(x_1, x_2) = d\mu_1(x_1) d\mu_2(x_2)$$

Ecrivons, pour $(x_1, x_2) \in X_1 \times X_2$ $\widehat{x}_1 = x_1$

$$f_{x_2}(\widehat{x}_1) := f^{x_2}(x_1) := f(x_1, x_2)$$

On voit donc f^{x_2} comme une fonction sur X_1 .

$$\text{Ent}_{\mu}(f) = \int_X f \log f d\mu - \int_X f d\mu \cdot \log \int_X f d\mu$$

$$= \int_{X_2} \int_{X_1} f \log f d\mu_1(x_1) d\mu_2(x_2) - \int_{X_2} \left(\int_{X_1} f d\mu_1 \cdot \log \int_{X_1} f d\mu_1 \right) d\mu_2$$

On tente de faire apparaître $\text{Ent}_{\mu_1}(f)$:

$$\begin{aligned}
Ent_{\mu}(f) &= \int_{X_2} \left(\int_{X_1} f^{x_2} \log \frac{f^{x_2}}{\int_{X_1} f^{x_2} d\mu_1} d\mu_2(x_2) \right) d\mu_2(x_2) \\
&\quad + \int_{X_2} \left(\int_{X_1} f^{x_2} d\mu_1 \right) \log \left(\frac{\int_{X_2} \int_{X_1} f^{x_2} d\mu_1 d\mu_2}{\int_{X_2} \left(\int_{X_1} f^{x_2} d\mu_1 \right) d\mu_2} \right) d\mu_2(x_2) \\
&= \int_{X_2} Ent_{\mu_1}(f^{x_2}) d\mu_2(x_2) + Ent_{\mu_2} \left(\int_{X_1} f d\mu_1 \right)
\end{aligned}$$

On conclut en remarquant que l'entropie est une fonctionnelle convexe, i.e. $\forall \mu$ proba
 $f \rightarrow Ent_{\mu}(f)$ est convexe sur l'ensemble des $f \geq 0$
 (↓ voir + bas)

On a donc :

$$Ent_{\mu_2} \left(\int_{X_1} f d\mu_1 \right) \leq \int_{X_1} Ent_{\mu_2}(f) d\mu_1$$

On a donc bien

$$\begin{aligned}
Ent_{\mu}(f) &\leq \int_{X_2} Ent_{\mu_1}(f^{x_2}) d\mu_2 + \int_{X_1} Ent_{\mu_2}(f^{x_1}) d\mu_1 \\
&= \int_X Ent_{\mu_2}(f) d\mu + \int_X Ent_{\mu_1}(f) d\mu
\end{aligned}$$



Pour la convexité de la fonctionnelle entropie, traitez l' ⑥

Exercice 5.1

Soit (Ω, μ) un espace de proba et $f: \Omega \rightarrow \mathbb{R}^+$

Montrez que

$$\text{Ent}_\mu(f) = \sup \left\{ \int f g d\mu ; g: \Omega \rightarrow \mathbb{R} \text{ avec } \int e^g d\mu \leq 1 \right\}$$

En déduire la convexité de l'entropie.

La tensorisation de l'entropie est très utile. En voici une première conséquence, utile également.

Theo B

Soit (X, μ) le produit de n espaces de proba (X_i, μ_i) , $i = 1, \dots, n$.

Pour $F: X \rightarrow \mathbb{R}$, on a :

$$\text{Ent}_\mu(e^F) \leq \sum_{i=1}^n \int R_i(e^{F_i}) d\mu$$

où, pour $i = 1, \dots, n$ et $x \in X$

$$R_i(e^{F_i})(x) = R_i(e^{F_i})(\hat{x}_i)$$

$$= \iint_{\{F_i(x_i) \geq F_i(y_i)\}} [F_i(x_i) - F_i(y_i)]^2 e^{F_i(x_i)} d\mu_i(x_i) d\mu_i(y_i)$$

Rq: $\triangle F_i(y_i) = F(x_1, \dots, x_{i-1}, y_i, x_{i+1}, \dots, x_n)$ $d\mu_i(x_i) d\mu_i(y_i)$

Rq: Evidemment $R_i(e^{F_i})(x) \leq \iint_{x_i \times x_i} [F_i(x_i) - F_i(y_i)]^2 e^{F_i(x_i)} d\mu_i(x_i) d\mu_i(y_i)$

Rq :

(7)

Démo

Si on a montré l'inégalité pour $n=1$ (un seul espace), alors l'inégalité sur le produit découle immédiatement du theo A

Notas $X = X_1$ $\mu = \mu_1$

On doit montrer que

$$(*) \quad \text{Ent}_{\mu}(e^F) \leq \iint (x-y)^2 \left(\frac{\partial F}{\partial x}\right)^2 e^{-F(x)} d\mu(x) d\mu(y)$$

Par Jensen on a :

$$\begin{aligned} \text{Ent}_{\mu}(e^F) &= \int F e^F d\mu - \int e^F d\mu \log \int e^F d\mu \\ &\leq \int F e^F d\mu - \int e^F d\mu \int F d\mu \end{aligned}$$

On remarque que

$$\int F e^F d\mu - \int e^F d\mu \int F d\mu = \frac{1}{2} \iint [F(x) - F(y)] [e^{F(x)} - e^{F(y)}] d\mu(x) d\mu(y)$$

symétrique
en x, y

$$= \frac{1}{2} \iint_{\{F(x) \geq F(y)\}} + \frac{1}{2} \iint_{\{F(y) \geq F(x)\}}$$

identique ($x \leftrightarrow y$)

$$= \iint_{\{F(x) \geq F(y)\}} [F(x) - F(y)] [e^{F(x)} - e^{F(y)}] d\mu(x) d\mu(y)$$

On conclut en remarquant que (exo)

| Pour $s, t \in \mathbb{R}$ avec $s \geq t$:

$$(s-t)(e^s - e^t) \leq \frac{1}{2} (s-t)^2 (e^s + e^t) \leq (s-t)^2 e^s$$



II/ Entropie et concentration sur les espaces produit

Notre but est de montrer une concentration gaussienne pour les fonctions convexes et lip. sur $[0, 1]^n$ (comme le résultat obtenu par la propriété (1) - convexe).

On commence par l'observation suivante

Prop C

Soit P une proba produit sur \mathbb{R}^n et $f: \mathbb{R}^n \rightarrow \mathbb{R}$ une fonction séparément convexe (càd que chaque f_i est convexe sur \mathbb{R} , ce qui est moins demander que f convexe, bien sûr)

Alors

$$\text{Ent}_P (e^f) \leq \iint \sum_{i=1}^n (x_i - y_i)^2 \left(\frac{\partial f}{\partial x_i}(x) \right)^2 e^{f(x)}$$

Rq: On rappelle qu'une fonction convexe est localement lip et que donc elle admet presque partout un gradient ∇f .
Cela dit, comme la mesure P est ici générale, il est prudent de supposer que f est C^1 dans et énoncé (ce n'est pas gênant pour la suite)

Démo: Écrivons $P = \mu_2 \otimes \dots \otimes \mu_n$ avec μ_i proba sur \mathbb{R} .

D'après le theo B, il est suffisant de montrer (et Fabrice, encore)

Evidemment, d est beaucoup plus petit que le diamètre de $[a, b]^n$ (ici, d est vraiment une constante)

Dans ce theo, on gagne par rapport à la concentration produit car on est en mesure d'utiliser que F est 1-lip % la métrique euclidienne. Le prix à payer pour pouvoir utiliser cette hypothèse forte est qu'on doit imposer F séparément convexe

[Notez que la concentration produit donnerait un terme en n , $\forall \epsilon > 0 \quad P(\int F \geq \int F dP + \epsilon) \leq e^{-\epsilon^2 / 4d^2 n}$ ← mauvais]

Démo (méthode de Herbst)

OPS que $d = 1$, i.e. : on travaille sur $[0, 1]^n$

Par ailleurs, il suffit de modifier le theo dans le cas où f est C^2

[En effet, pour f 1-lip générale, on peut convoler avec un noyau Gaussien (g_ϵ) , $f_\epsilon = f * g_\epsilon$. On a alors $f_\epsilon \in C^\infty$ avec $|\nabla f_\epsilon| \leq 1$. On applique le résultat à f_ϵ et on passe à la limite par convergence ~~uniforme~~ sur $[0, 1]^n$.

On a donc $|\nabla f| \leq 1$ sur \mathbb{R}^n i.e. : $\sum_{i=1}^n \left(\frac{\partial f}{\partial x_i}\right)^2(x) \leq 1, \forall x$

Soit $H(\lambda) = \int e^{\lambda F} dP$ On veut majorer $H(\lambda)$.

On applique la Prop C à la fonction λP -convexe λF et on trouve

$$\begin{aligned} \text{Ent}_P(e^{\lambda F}) &\leq \iint \sum_{\substack{\leq 1 \text{ sur le} \\ \text{support de } P \otimes P}} \frac{(x_i - y_i)^2}{\lambda^2} \lambda^2 \left(\frac{\partial F}{\partial x_i}\right)^2 e^{\lambda F(x)} dP(x) dP(y) \\ &\leq \lambda^2 \int e^{\lambda F(x)} dP(x) \end{aligned}$$

Par ailleurs

$$H'(\lambda) = \frac{dH(\lambda)}{d\lambda} = \int F e^{\lambda F} dP$$

Donc $Ent_P(e^{\lambda F}) = \lambda H'(\lambda) - H(\lambda) \log H(\lambda)$

On a donc

$$\lambda H'(\lambda) - H(\lambda) \log H(\lambda) \leq \lambda^2 H(\lambda)$$

On conclut à une majoration de H' par un argument à la Croftwell.

Par le voir, posons $\alpha(\lambda) := \frac{1}{\lambda} \log H(\lambda)$

$\alpha(0) = H'(0)$
par que α soit
continue

On a exactement :

$$\alpha'(\lambda) \leq 1$$

• Donc $\alpha(\lambda) \leq \lambda + \alpha(0)$

et donc $H(\lambda) \leq e^{\lambda^2 + \lambda \alpha(0)}$

Par ailleurs: $H(\lambda) = 1 + \lambda \int F dP + o(\lambda)$

donc $\alpha(0) = H'(0) = \int F dP$

On a donc

$$\int e^{\lambda [F - \int F dP]} dP \leq e^{\lambda^2}$$

 $\forall \lambda \geq 0$

la suite est classique.

On a:

$\forall \lambda \geq 0,$

$$P(\{F - \int F dP \geq \lambda\}) \leq e^{\lambda^2 - \lambda}$$

↪ λ optimal
 $\lambda = \frac{\lambda}{2}$

si tenons:

$$P(\{F \geq \int F dP + \lambda\}) \leq e^{-\lambda^2/4}$$



Applications du resultat

Evidement, dans le cas de $f(x) = x \cdot a$
 $= \sum_{i=1}^n a_i x_i$

sur $(\mathcal{D}_n, \sigma_n)$, cela ne donne rien de mieux.

En effet, on a $\|f\|_{\text{lip}} = |a|$ et donc, puisque f est convexe
on retrouve

$$\mathbb{P}\left(\sum_{i=1}^n a_i \epsilon_i \geq r\right) \leq e^{-r^2/4|a|^2}$$

(Rq: on ne retrouve qu'un des vers de la concentration)

Prenez E un Banach, $(E, \|\cdot\|)$ de dual $(E^*, \|\cdot\|_*)$

Soit $v_1, \dots, v_k \in E$ et $\epsilon_1, \dots, \epsilon_k$ des
v.a. de Bernoulli ± 1 independantes.

Posez

$$S = \sum_{i=1}^k \epsilon_i v_i \quad (\text{vecteurs aleatoires de } E)$$

que peut-on dire de $\|S\|$?

1) si on utilise la concentration produit sur $(\mathcal{D}_k, \sigma_k)$

Posez $f(x) = \left\| \sum x_i v_i \right\|$

On a: si x et y varient de la coord. i seulement

$$|f(x) - f(y)| \leq 2 \|v_i\|$$

Donc: $\mathbb{P}(\|S\| \geq \mathbb{E}\|S\| + r) \leq e^{-r^2/8k^2}$

ou $k^2 = \sum_{i=1}^n \|v_i\|^2$

2) Si on utilise le theo D avec le \bar{m}

$$f(x) = \left\| \sum_{i=1}^k x_i \sigma_i \right\|$$

On remarque que f est convexe sur \mathbb{R}^n
 quelle est sa constante de lip?

$$f(x) = \sup_{\substack{\xi \in E^* \\ \|\xi\|_* \leq 1}} \sum_{i=1}^k x_i \xi(\sigma_i)$$

On voit que $\|f\|_{\text{lip}} \leq \sigma$

$$\bar{m} \quad \sigma := \sup_{\|\xi\|_* \leq 1} \sqrt{\sum_{i=1}^k \xi(\sigma_i)^2}$$

~~On~~ On a des

$$\left| \mathbb{P}(\|\xi\| \geq \# \|\xi\| + r) \leq e^{-r^2/4\sigma^2}$$

$$\underline{\text{On}} : \quad \sigma^2 \leq \sum_{i=1}^k \|\sigma_i\|^2$$

en g n ral, il y a une grande diff rence.

[Revoir concentration Gaussienne version Pisier]

Donc le theo D donne la bonne concentration
 Gaussienne pour la norme d'une somme vectarielle
 de v.a. indep.