
CONCENTRATION ET INÉGALITÉS DE MARGE

OLIVIER CATONI

28 mars 2013

1. DÉVIATIONS DES SOMMES DE VARIABLES ALÉATOIRES INDÉPENDANTES

Soit X_i , $1 \leq i \leq n$ un échantillon de variables indépendantes et

$$M \stackrel{\text{def}}{=} \frac{1}{n} \sum_{i=1}^n X_i$$

leur moyenne empirique. On se pose la question des déviations de M par rapport à sa moyenne

$$m \stackrel{\text{def}}{=} \mathbb{E}(M) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i).$$

Considérons les fonctions génératrices des moments

$$\begin{aligned} \psi_i(\lambda) &= \log \left\{ \mathbb{E}[\exp(\lambda X_i)] \right\}, \\ \psi(\lambda) &= \frac{1}{n} \sum_{i=1}^n \psi_i(\lambda). \end{aligned}$$

Ce sont les fonctions convexes, nulles en zéro, à valeurs dans $\mathbb{R}_+ \cup \{+\infty\}$. Considérons la fonction duale

$$\psi^*(x) = \sup_{\lambda \in \mathbb{R}_+} \lambda x - \psi(\lambda) \in \mathbb{R}_+ \cup \{+\infty\}.$$

PROPOSITION 1.1 *Les déviations de la moyennes empirique M vérifient*

$$\mathbb{P}(M \geq x) \leq \exp[-n\psi^*(x)].$$

PREUVE.

CNRS – UMR 8553, Département de Mathématiques et Applications, Ecole Normale Supérieure, 45, rue d’Ulm, F75230 Paris cedex 05, and INRIA Paris-Rocquencourt – CLAS-SIC team.

$$\begin{aligned}
\mathbb{P}(M \geq x) &= \mathbb{E}\left\{\mathbf{1}[\exp(n\lambda(M-x)) \geq 1]\right\} \\
&\leq \mathbb{E}[\exp(n\lambda(M-x))] \\
&= \exp\{n[\psi(\lambda) - \lambda x]\}, \quad \lambda \in \mathbb{R}_+.
\end{aligned}$$

Par conséquent

$$\mathbb{P}(M \geq x) \leq \inf_{\lambda \in \mathbb{R}_+} \exp\{n[\psi(\lambda) - \lambda x]\} = \exp(-n\psi^*(x)).$$

□

PROPOSITION 1.2 *Posons $\Lambda_i = \sup\{\lambda \in \mathbb{R}_+ : \psi_i(\lambda) < +\infty\}$ et $\Lambda = \min\{\Lambda_1, \dots, \Lambda_n\}$. Pour tout $\lambda \in [0, \Lambda_i[$, $\psi_i(\lambda) < +\infty$ et la fonction ψ_i est de classe \mathcal{C}^∞ sur $]0, \Lambda_i[$ lorsque $\Lambda_i > 0$. Si de plus $\mathbb{E}(|X_i|^k) < \infty$, la fonction ψ_i est de classe \mathcal{C}^k sur $[0, \Lambda_i[$.*

PREUVE. Posons $\varphi(\lambda) = \mathbb{E}[\exp(\lambda X_i)]$. Soit $\lambda \in [0, \Lambda_i[$. Par définition de Λ_i , il existe $\beta \in]\lambda, \Lambda_i[$ tel que $\psi_i(\beta) < \infty$, et donc $\varphi(\beta) < \infty$. D'après l'inégalité de Jensen

$$+\infty > \mathbb{E}[\exp(\beta X_i)] = \mathbb{E}\left\{[\exp(\lambda X_i)]^{\beta/\lambda}\right\} \geq \left\{\mathbb{E}[\exp(\lambda X_i)]\right\}^{\beta/\lambda},$$

ce qui prouve que $\varphi_i(\lambda) < \infty$, et donc que $\psi_i(\lambda) < \infty$.

Remarquons que

$$\begin{aligned}
X_i^{j-1} \exp(\beta X_i) &= X_i^{j-1} \exp(\alpha X_i) + \int_{\alpha}^{\beta} X_i^j \exp(\lambda X_i) d\lambda, \\
& \qquad \qquad \qquad 0 < \alpha < \beta < \Lambda_i, \quad j \geq 1.
\end{aligned}$$

De plus

$$\mathbb{E}\left\{\sup_{\lambda \in [\alpha, \beta]} |X_i^j \exp(\lambda X_i)|\right\} < \infty$$

En effet, considérons $\gamma \in]\beta, \Lambda_i[$ et

$$\begin{aligned}
C_1 &= \sup_{x \in \mathbb{R}_+} x^j \exp[-(\gamma - \beta)x], \\
C_2 &= \sup_{x \in \mathbb{R}_+} x^j \exp(-\alpha x).
\end{aligned}$$

$$|X_i^j \exp(\lambda X_i)| \leq \begin{cases} C_1 \exp(\gamma X_i), & X_i \geq 0, \\ C_2, & X_i \leq 0. \end{cases}$$

Par conséquent

$$\mathbb{E}\left\{\sup_{\lambda \in [\alpha, \beta]} |X_i^j \exp(\lambda X_i)|\right\} \leq C_1 \mathbb{E}[\exp(\gamma X_i)] + C_2 < \infty.$$

On peut donc employer le théorème de Fubini et écrire

$$\begin{aligned} \mathbb{E}[X_i^{j-1} \exp(\beta X)] &= \mathbb{E}[X_i^{j-1} \exp(\alpha X_i)] + \mathbb{E}\left(\int_{\alpha}^{\beta} X_i^j \exp(\lambda X_i) d\lambda\right) \\ &= \mathbb{E}[X_i^{j-1} \exp(\alpha X_i)] + \int_{\alpha}^{\beta} \mathbb{E}[X_i^j \exp(\lambda X_i)] d\lambda. \end{aligned}$$

D'après le théorème de convergence dominée, $\lambda \mapsto \mathbb{E}(X_i^j \exp(\lambda X_i)) : [\alpha, \beta] \rightarrow \mathbb{R}$ est continue, donc $\beta \mapsto \mathbb{E}[X_i^{j-1} \exp(\beta X_i)]$ est de classe \mathcal{C}^1 , de dérivée $\mathbb{E}[X_i^j \exp(\beta X_i)]$, donc $\beta \mapsto \mathbb{E}[\exp(\beta X_i)]$ est de classe \mathcal{C}^∞ sur $]0, \Lambda_i[$ et il en est de même de ψ_i .

Supposons maintenant de plus que $\mathbb{E}[|X_i|^k] < \infty$. On peut dans ce cas montrer de façon analogue que

$$\mathbb{E}\left\{\sup_{\lambda \in [0, \beta]} |X_i^j \exp(\lambda X_i)|\right\} < \infty, \quad 0 < \beta < \Lambda_i,$$

en déduire que

$$\mathbb{E}[X_i^{j-1} \exp(\beta X_i)] = \mathbb{E}(X_i^{j-1}) + \int_0^{\beta} \mathbb{E}[X_i^j \exp(\lambda X_i)] d\lambda, \quad 0 \leq \beta < \Lambda_i, \quad 1 \leq j \leq k,$$

et enfin que φ_i et ψ_i sont de classe \mathcal{C}^k sur $[0, \Lambda_i[$. \square

PROPOSITION 1.3 *Supposons que $\mathbb{E}(X_i^2) < \infty$ et que $\Lambda_i > 0$. La dérivée seconde de ψ_i prend la forme d'une variance :*

$$\psi_i''(\lambda) = \frac{\mathbb{E}[X_i^2 \exp(\lambda X_i)]}{\mathbb{E}[\exp(\lambda X_i)]} - \left(\frac{\mathbb{E}[X_i \exp(\lambda X_i)]}{\mathbb{E}[\exp(\lambda X_i)]}\right)^2, \quad 0 \leq \lambda < \Lambda_i,$$

de plus

$$\psi_i(\lambda) = \lambda \mathbb{E}(X_i) + \int_0^{\lambda} (\lambda - \alpha) \psi_i''(\alpha) d\alpha, \quad 0 \leq \lambda < \Lambda_i.$$

PREUVE. D'après la proposition précédente, ψ_i est de classe \mathcal{C}^2 sur $[0, \Lambda_i[$ et

$$\psi_i'(\lambda) = \frac{\mathbb{E}[X_i \exp(\lambda X_i)]}{\mathbb{E}[\exp(\lambda X_i)]},$$

en dérivant une fois de plus, on obtient l'expression de ψ_i'' indiquée dans la proposition. Considérons la variable aléatoire Y_i de loi

$$\mathbb{P}(Y_i \in A) = \frac{\mathbb{E}[\mathbf{1}(X_i \in A) \exp(\lambda X_i)]}{\mathbb{E}[\exp(\lambda X_i)]},$$

pour tout borélien A . Elle vérifie pour toute fonction mesurable f telle que $\mathbb{E}[|f(X_i)| \exp(\lambda X_i)] < \infty$

$$\mathbb{E}[f(Y_i)] = \frac{\mathbb{E}[f(X_i) \exp(\lambda X_i)]}{\mathbb{E}[\exp(\lambda X_i)]},$$

ce qui montre que $\psi_i''(\lambda) = \mathbb{E}(Y_i^2) - \mathbb{E}(Y_i)^2$ est bien une variance. La deuxième partie de la proposition s'obtient en écrivant la formule de Taylor $\psi_i(\lambda) = \psi_i(0) + \lambda \psi_i'(0) + \int_0^\lambda (\lambda - \alpha) \psi_i''(\alpha) d\alpha$. \square

PROPOSITION 1.4 *Supposons que $\Lambda > 0$ et que $\mathbb{E}(X_i^2) < \infty$, $1 \leq i \leq n$. Posons*

$$\bar{V}(\lambda) \stackrel{\text{def}}{=} \frac{2}{\lambda^2} [\psi(\lambda) - \lambda m] = \frac{2}{\lambda^2} \int_0^\lambda (\lambda - \alpha) \psi''(\alpha) d\alpha, \quad 0 \leq \lambda < \Lambda$$

$$V(\lambda) \stackrel{\text{def}}{=} \sup_{\beta \in [0, \lambda]} \bar{V}(\beta),$$

$$v \stackrel{\text{def}}{=} V(0) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}\{[X_i - \mathbb{E}(X_i)]^2\}$$

et remarquons que V est une fonction continue et croissante à valeurs dans $\mathbb{R} + \cup\{+\infty\}$. Sous ces hypothèses

$$\begin{aligned} \mathbb{P}(M \geq m + x) &\leq \exp\left(-\frac{nx^2}{2V(x/v)}\right), \\ \mathbb{P}\left(M \geq m + \sqrt{\frac{2 \log(\epsilon^{-1})}{n}} V\left(\sqrt{\frac{2 \log(\epsilon^{-1})}{nv}}\right)\right) &\leq \epsilon. \end{aligned}$$

PREUVE. Pour tout $0 \leq \beta \leq \lambda$,

$$\psi^*(m + x) \geq \beta x - \frac{\beta^2}{2} V(\lambda),$$

si bien que

$$\mathbb{P}(M \geq m + x) \leq \exp\left[-n\left(\beta x - \frac{\beta^2}{2} V(\lambda)\right)\right].$$

On obtient la première inégalité en choisissant $\lambda = x/v$ et $\beta = x/V(\lambda) \leq \lambda$. Pour obtenir la seconde posons $\epsilon = \exp\left[-n\left(\beta x - \frac{\beta^2}{2}V(\lambda)\right)\right]$, pour obtenir dans un premier temps

$$\mathbb{P}\left(M \geq m + \frac{\beta}{2}V(\lambda) + \frac{\log(\epsilon^{-1})}{n\beta}\right) \leq \epsilon.$$

Choisissons alors $\lambda = \sqrt{\frac{2\log(\epsilon^{-1})}{nv}} \geq \beta = \sqrt{\frac{2\log(\epsilon^{-1})}{nV(\lambda)}}$ pour conclure. \square

PROPOSITION 1.5 (INÉGALITÉ DE BENNETT) *Supposons que $\mathbb{E}(X_i^2) < \infty$ et que $X_i \leq \mathbb{E}(X_i) + b$, $1 \leq i \leq n$. Introduisons la fonction*

$$h(u) = (1+u)\log(1+u) - u \geq \frac{u^2}{2(1+u/3)}, \quad u \in \mathbb{R}_+.$$

Sous ces hypothèses

$$\begin{aligned} \mathbb{P}(M \geq m+x) &\leq \exp\left[-\frac{nv}{b^2}h\left(\frac{bx}{v}\right)\right] \leq \exp\left(-\frac{nx^2}{2v + \frac{2bx}{3}}\right), \\ \mathbb{P}\left(M \geq m + \sqrt{\frac{2v\log(\epsilon^{-1})}{n}}\left(1 - \frac{b}{3v}\sqrt{\frac{2v\log(\epsilon^{-1})}{n}}\right)^{-1/2}\right) &\leq \epsilon. \end{aligned}$$

PREUVE. Remarquons tout d'abord que pour tout $\lambda \in \mathbb{R}_+$,

$$\begin{aligned} \psi^*(m+x) &\geq \lambda(x+m) - \frac{1}{n} \sum_{i=1}^n \log[\mathbb{E}(\exp(\lambda X_i))] \\ &= \lambda x - \frac{1}{n} \sum_{i=1}^n \log\left\{\mathbb{E}[\exp(\lambda(X_i - m_i))]\right\}, \end{aligned}$$

où $m_i \stackrel{\text{def}}{=} \mathbb{E}(X_i)$. On peut alors écrire

$$\begin{aligned} \mathbb{E}[\exp(\lambda(X_i - m_i))] - 1 &= \mathbb{E}[\exp(\lambda(X_i - m_i)) - 1 - \lambda(X_i - m_i)] \\ &= \mathbb{E}[\lambda^2(X_i - m_i)^2 g(\lambda(X_i - m_i))] \end{aligned}$$

où $g(y) = y^{-2}(\exp(y) - 1 - y)$. La fonction g est croissante sur \mathbb{R} . En effectuant un développement de Taylor à l'ordre deux de la fonction $z \mapsto \exp(yz)$ entre 0 et 1, on voit en effet qu'elle peut s'écrire

$$g(y) = \int_0^1 (1-z)\exp(yz) dz, \quad y \in \mathbb{R}.$$

On en déduit que

$$\mathbb{E}[\lambda^2(X_i - m_i)^2 g(\lambda(X_i - m_i))] \leq \mathbb{E}[\lambda^2(X_i - m_i)^2 g(\lambda b)], \quad 1 \leq i \leq n,$$

et donc que

$$\log \left\{ \mathbb{E}[\exp(\lambda(X_i - m_i))] \right\} \leq \lambda^2 g(\lambda b) \mathbb{E}[(X_i - m_i)^2].$$

Ainsi

$$\psi^*(m+x) \geq \lambda x - \lambda^2 v g(\lambda b) = \lambda x - \frac{v}{b^2} (\exp(\lambda b) - 1 - \lambda b).$$

Choisissons $\lambda = b^{-1} \log\left(1 + \frac{bx}{v}\right)$ pour obtenir

$$\psi^*(x) \geq \frac{v}{b^2} h\left(\frac{bx}{v}\right).$$

Montrons maintenant que $h(u) \geq \frac{u^2}{2(1+u/3)}$, $u > -1$. Calculons les dérivées de h , $h'(u) = \log(1+u)$, $h''(u) = 1/(1+u)$, puis les dérivées de $f(u) = (1+u/3)h(u) - u^2/2$. On obtient $f'(u) = h'(u)(1+u/3) + h(u)/3 - u$ qui vérifie $f'(0) = 0$ et

$$\begin{aligned} f''(u) &= h''(u)(1+u/3) + 2h'(u)/3 - 1 = \frac{1+u/3}{1+u} + \frac{2}{3} \log(1+u) - 1 \\ &= \frac{2}{3} \log(1+u) - \frac{2u}{3(1+u)} = \frac{2h(u)}{3(1+u)} \geq 0, \quad u > -1. \end{aligned}$$

La fonction f , convexe, nulle en zéro et de dérivée première nulle en zéro est donc positive.

Posons $\epsilon = \exp\left(-\frac{nx^2}{2v + \frac{2bx}{3}}\right)$. On obtient

$$\begin{aligned} x^2 &= \frac{2v \log(\epsilon^{-1})}{n} \left(1 + \frac{bx^2}{3vx}\right) \\ &\leq \frac{2v \log(\epsilon^{-1})}{n} \left(1 + \frac{bx^2}{3v} \left(\frac{2v \log(\epsilon^{-1})}{n}\right)^{-1/2}\right). \end{aligned}$$

On en déduit que

$$x^2 \leq \frac{2v \log(\epsilon^{-1})}{n} \left(1 - \frac{b}{3v} \sqrt{\frac{2v \log(\epsilon^{-1})}{n}}\right)^{-1},$$

ce qui prouve la deuxième inégalité de la proposition. \square

PROPOSITION 1.6 (INÉGALITÉ DE Hoeffding) *Supposons que $a_i \leq X_i \leq b_i$, $1 \leq i \leq n$. Dans ce cas*

$$\mathbb{P}(M \geq m + x) \leq \exp\left(-\frac{2n^2x^2}{\sum_{i=1}^n (b_i - a_i)^2}\right),$$
$$\mathbb{P}\left(M \geq m + \sqrt{\frac{\sum_{i=1}^n (b_i - a_i)^2 \log(\epsilon^{-1})}{2n^2}}\right) \leq \epsilon.$$

PREUVE. La dérivée seconde de ψ_i est la variance d'une variable aléatoire à valeurs dans l'intervalle $[a_i, b_i]$, et ne peut donc excéder $(b_i - a_i)^2/4$. Par conséquent $\psi(\lambda) \leq \lambda m + \frac{\lambda^2}{8} \sum_{i=1}^n (b_i - a_i)^2$ d'où $\psi^*(m + x) \geq \frac{2nx^2}{\sum_{i=1}^n (b_i - a_i)^2}$.

□