

Vitesse de convergence dans le théorème limite central pour des sommes pondérées de champs aléatoires

Davide Giraud

Ruhr-Universität Bochum

Mulhouse, 14 mars 2019

- 1 Introduction
- 2 Champs aléatoires strictement stationnaires
- 3 Obtention d'une vitesse de convergence

Sommes de variables aléatoires

Soit $(\Omega, \mathcal{F}, \mathbb{P})$ un espace de probabilité. Soit $(X_j)_{j \geq 1}$ une suite de variables aléatoires. Ses sommes partielles sont définies par $S_n := \sum_{j=1}^n X_j$ et on s'intéresse à leur comportement asymptotique.

Le cas le plus favorable est celui où la suite $(X_j)_{j \geq 1}$ est indépendante, *i. e.*, pour tout entier n et tous boréliens B_1, \dots, B_n de \mathbb{R} ,

$$\mathbb{P} \left(\bigcap_{j=1}^n \{\omega \in \Omega \mid X_j(\omega) \in B_j\} \right) = \prod_{j=1}^n \mathbb{P}(\{X_j \in B_j\}),$$

et la suite $(X_j)_{j \geq 1}$ est identiquement distribuée, *i. e.*, pour tout entier j et tout borélien B de \mathbb{R} , $\mathbb{P}\{X_j \in B\} = \mathbb{P}\{X_1 \in B\}$.

Même dans ce cas, la suite $(S_n)_{n \geq 1}$ ne converge pas (sauf si $X_j = 0$).

Loi des grands nombres

Lorsque X_1 a une espérance finie, *i. e.*,

$$\mathbb{E}[|X_1|] = \int_{\mathbb{R}} |x| d\mathbb{P}_{X_1}(x)$$

où $\mathbb{P}_{X_1}(B) = \mathbb{P}\{X_1 \in B\}$, alors il existe $\Omega' \subset \Omega$ tel que $\mathbb{P}(\Omega') = 1$ et pour tout $\omega \in \Omega'$,

$$\lim_{n \rightarrow +\infty} \frac{1}{n} S_n(\omega) = \mathbb{E}[X_1] =: \int_{\mathbb{R}} x d\mathbb{P}_{X_1}(x).$$

Théorème limite central

Soit $(X_j)_{j \geq 1}$ une suite de variables aléatoires indépendante et identiquement distribuée. On suppose que $\mathbb{E}[X_1^2] = 1$ et que $\mathbb{E}[X_1] = 0$. Alors pour toute fonction $g: \mathbb{R} \rightarrow \mathbb{R}$ continue et bornée,

$$\lim_{n \rightarrow +\infty} \mathbb{E} \left[g \left(\frac{S_n}{\sqrt{n}} \right) \right] = \mathbb{E} [g(N)],$$

ou, de manière équivalente, pour tout $x \in \mathbb{R}$,

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left\{ \frac{S_n}{\sqrt{n}} \leq x \right\} = \mathbb{P} \{N \leq x\},$$

où N est de loi normale centrée réduite, *i.e.*,

$$\mathbb{P} \{N \leq x\} = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x \exp \left(-\frac{t^2}{2} \right) dt.$$

Mesure de la vitesse de convergence

Il s'avère que sous les conditions précédentes, lorsque $\sigma \neq 0$, la convergence est uniforme sur \mathbb{R} :

$$\delta_n := \sup_{x \in \mathbb{R}} \left| \mathbb{P} \left\{ \frac{S_n}{\sqrt{n}} \leq x \right\} - \mathbb{P} \{ \sigma N \leq x \} \right| \rightarrow 0.$$

Question : à quelle vitesse la suite $(\delta_n)_{n \geq 1}$ tend-elle vers 0 ?

Berry-Esseen (1941-1942) : si $\mathbb{E} [|X_1|^3]$ est finie et $\mathbb{E} [X_1^2] = 1$, alors

$$\delta_n \leq C \mathbb{E} [|X_1|^3] \frac{1}{\sqrt{n}},$$

où C est une constante numérique.

Peut-on améliorer le $n^{-1/2}$?

Soit $(X_j)_{j \geq 1}$ i.i.d. telle que $\mathbb{P}\{X_j = 1\} = \mathbb{P}\{X_j = -1\} = 1/2$. Notons $F_n(x) := \mathbb{P}\left\{\frac{S_n}{\sqrt{n}} \leq x\right\}$. Par symétrie,

$$F_{2n}(0) = \frac{1}{2}(1 + \mathbb{P}(S_{2n} = 0))$$

donc

$$\sup_{x \in \mathbb{R}} |F_{2n}(x) - \mathbb{P}\{N \leq x\}| \geq |F_{2n}(0) - \mathbb{P}\{N \leq 0\}| \geq \frac{1}{2} \cdot \binom{2n}{n} 2^{-2n}.$$

et par la formule de Stirling, le dernier terme se comporte comme du $n^{-1/2}$.

Objectifs

Nous allons étudier la vitesse de convergence dans le théorème limite central dans le contexte suivant :

$$S_n = \frac{1}{\|b_{n,\cdot}\|_2} \sum_{i \in \mathbb{Z}^d} b_{n,i} X_i,$$

où $b_{n,\cdot} \in \ell^2(\mathbb{Z}^d)$, $d \geq 1$ et $(X_i)_{i \in \mathbb{Z}^d}$ est une collection de variables aléatoires.

Objectifs :

- 1 trouver une condition portant sur la famille des poids $(b_{n,i})_{n \geq 1, i \in \mathbb{Z}^d}$, sur la dépendance et les moments de $(X_i)_{i \in \mathbb{Z}^d}$ qui doit :
 - 1 être facilement vérifiable ;
 - 2 garantir la convergence de S_n vers une loi normale centrée réduite.
- 2 Donner une estimation de la vitesse de convergence.

Motivation des sommes pondérées

Modèle de régression.

On considère le modèle de régression

$$Y_i := g\left(\frac{1}{n}\mathbf{i}\right) + X_i, \quad \mathbf{i} \in \{1, \dots, n\}^d =: \Lambda_n,$$

où $g: [0, 1]^d \rightarrow \mathbb{R}$ est une fonction de classe C^∞ inconnue $(X_i)_{\mathbf{i} \in \mathbb{Z}^d}$ une collection de variables aléatoires.

On estime la fonction g à l'aide de l'estimateur à noyau

$$g_n(\mathbf{x}) := \frac{\sum_{\mathbf{i} \in \Lambda_n} Y_i K\left(\frac{\mathbf{x} - \mathbf{i}/n}{h_n}\right)}{\sum_{\mathbf{i} \in \Lambda_n} K\left(\frac{\mathbf{x} - \mathbf{i}/n}{h_n}\right)}, \quad \mathbf{x} \in [0, 1]^d,$$

où $K: \mathbb{R}^d \rightarrow \mathbb{R}$ est un noyau et $h_n \rightarrow 0$, $nh_n \rightarrow +\infty$ et $nh_n^{d+1} \rightarrow 0$.

Définition

Définition

Un champ aléatoire est une famille de variables aléatoires indexée par \mathbb{Z}^d .

Un champ aléatoire $(X_i)_{i \in \mathbb{Z}^d}$ est dit strictement stationnaire si pour tout N et tous $\mathbf{i}_1, \dots, \mathbf{i}_N, \mathbf{j} \in \mathbb{Z}^d$, les vecteurs $(X_{\mathbf{i}_1}, \dots, X_{\mathbf{i}_N})$ et $(X_{\mathbf{i}_1+\mathbf{j}}, \dots, X_{\mathbf{i}_N+\mathbf{j}})$ ont la même loi.

Exemple : si $(X_i)_{i \in \mathbb{Z}^d}$ est indépendant et identiquement distribué alors $(X_i)_{i \in \mathbb{Z}^d}$ est strictement stationnaire.

Exemples

- ① Processus linéaire : soient $(\varepsilon_i)_{i \in \mathbb{Z}^d}$ un champ aléatoire i.i.d. centré tel que $\mathbb{E} [\varepsilon_{\mathbf{0}}^2] < +\infty$ et $(a_i)_{i \in \mathbb{Z}^d} \in \ell^2(\mathbb{Z}^d)$. On définit

$$X_j := \sum_{i \in \mathbb{Z}^d} a_i \varepsilon_{j-i} = \lim_{N \rightarrow +\infty} \sum_{i \in \mathbb{Z}^d, \|i\|_\infty \leq N} a_i \varepsilon_{j-i}.$$

- ② Champs de Volterra : soient $(\varepsilon_i)_{i \in \mathbb{Z}^d}$ un champ aléatoire i.i.d. centré tel que $\mathbb{E} [\varepsilon_{\mathbf{0}}^2] < +\infty$ et $(a_{i,i'})_{i,i' \in \mathbb{Z}^d} \in \ell^2(\mathbb{Z}^d \times \mathbb{Z}^d)$ tels que $a_{i,i} = 0$ pour tout $i \in \mathbb{Z}^d$. On définit

$$X_j := \sum_{i,i' \in \mathbb{Z}^d} a_{i,i'} \varepsilon_{j-i} \varepsilon_{j-i'} = \lim_{N \rightarrow +\infty} \sum_{i,i' \in \mathbb{Z}^d, \|i\|_\infty, \|i'\|_\infty \leq N} a_{i,i'} \varepsilon_{j-i} \varepsilon_{j-i'}.$$

Mesure de dépendence

Soit $(X_i)_{i \in \mathbb{Z}^d}$ un champ aléatoire strictement stationnaire de la forme

$$X_i = f((\varepsilon_{i-k})_{k \in \mathbb{Z}^d}), \quad (\text{CB})$$

où $f: \mathbb{R}^{\mathbb{Z}^d} \rightarrow \mathbb{R}$ est mesurable et $(\varepsilon_i)_{i \in \mathbb{Z}^d}$ est i.i.d.. Soit \mathcal{F}_m la tribu engendrée par les variables aléatoires ε_k , $\|k\|_\infty \leq m$. Si $\mathbb{E}[|X_0|^p]$ est finie, on définit

$$\delta_{m,p} := \|\mathbb{E}[X_0 | \mathcal{F}_m] - \mathbb{E}[X_0 | \mathcal{F}_{m-1}]\|_p. \quad m \geq 1, p \geq 2.$$

Remarque

Par le théorème de convergence des martingales,

$\|\mathbb{E}[X_0 | \mathcal{F}_m] - X_0\|_p \rightarrow 0$ donc $\lim_{m \rightarrow +\infty} \delta_{m,p} = 0$ pour tout champ aléatoire de la forme (CB).

Processus linéaire

On considère le champ linéaire

$$X_j := \sum_{i \in \mathbb{Z}^d} a_i \varepsilon_{j-i}.$$

On rappelle que

$$\delta_{m,p} := \|\mathbb{E}[X_0 | \mathcal{F}_m] - \mathbb{E}[X_0 | \mathcal{F}_{m-1}]\|_p, \quad m \geq 1, p \geq 2.$$

où \mathcal{F}_m la tribu engendrée par les variables aléatoires ε_k , $\|k\|_\infty \leq m$.

Alors

$$\mathbb{E}[X_0 | \mathcal{F}_m] = \sum_{i \in \mathbb{Z}^d, \|i\|_\infty \leq m} a_i \varepsilon_{-i}$$

donc

$$\delta_{m,p} = \left\| \sum_{i \in \mathbb{Z}^d, \|i\|_\infty = m} a_i \varepsilon_{-i} \right\|_p.$$

Inégalité de Rosenthal

Rosenthal (1962) : soit $p \geq 2$ et $(Y_i)_{i \geq 1}$ une suite de variables aléatoires indépendante et centrée.

$$\left\| \sum_{i=1}^n Y_i \right\|_p \leq c_p \left(\left(\sum_{i=1}^n \|Y_i\|_2^2 \right)^{1/2} + \left(\sum_{i=1}^n \|Y_i\|_p^p \right)^{1/p} \right),$$

où $\|Y\|_p := (\mathbb{E}[|Y|^p])^{1/p}$ et c_p ne dépend que de p .

Johnson, Schechtman, Zinn (1985) : $c_p = \frac{14.5p}{\log p}$ convient.

On obtient

$$\delta_{m,p} \leq 2c_p \|\varepsilon_0\|_p \left(\sum_{i \in \mathbb{Z}^d, \|i\|_\infty = m} a_i^2 \right)^{1/2}.$$

Cas m -dépendant

Pour une variable aléatoire Z , on définit

$$\delta(Z) := \sup_{t \in \mathbb{R}} |\mathbb{P}\{Z \leq t\} - \mathbb{P}\{N \leq t\}|.$$

On dit que le champ $(X_i)_{i \in \mathbb{Z}^d}$ est m -dépendant si pour tous sous-ensembles A et B de \mathbb{Z}^d tels que $\inf\{\|a - b\|_\infty, a \in A, b \in B\} \geq m$, les collections $(X_i)_{i \in A}$ et $(X_i)_{i \in B}$ sont indépendantes.

Chen, Shao (2004) : si $I \subset \mathbb{Z}^d$ est fini, $(Y_i)_{i \in I}$ est un champ aléatoire m -dépendant tel que $\mathbb{E}[|Y_i|^p] < +\infty$, $p \in (2, 3]$ et $\text{Var}(\sum_{i \in I} Y_i) = 1$, alors

$$\delta\left(\sum_{i \in I} Y_i\right) \leq 75(10m + 1)^{(p-1)d} \sum_{i \in I} \mathbb{E}[|Y_i|^p].$$

Idée globales

$$\delta(Z) := \sup_{t \in \mathbb{R}} |\mathbb{P}\{Z \leq t\} - \mathbb{P}\{N \leq t\}|.$$

El Machkouri, Ouchti (2007) : pour toutes variables aléatoires Z et Z' et tout $p \geq 1$,

$$\delta(Z + Z') \leq 2\delta(Z) + \|Z'\|_p^{\frac{p}{p+1}}.$$

- 1 On applique le résultat du cas m -dépendant à $\sum_{i \in \mathbb{Z}^d} b_{n,i} X_{i,m}$ où $X_{i,m} = \mathbb{E}[X_i \mid \sigma(\varepsilon_{\mathbf{u}}, \mathbf{u} \in \mathbb{Z}^d, \|\mathbf{i} - \mathbf{u}\| \leq m)]$.
- 2 On contrôle la contribution de $\sum_{i \in \mathbb{Z}^d} b_{n,i} (X_i - X_{i,m})$ à l'aide d'une inégalité de moments.
- 3 On choisit m adéquatement.

Inégalité de moments pour les sommes pondérées

Théorème (G., 2018)

Soit $\{\varepsilon_i, i \in \mathbb{Z}^d\}$ un champ i.i.d. et $X_j := f\left(\left(\varepsilon_{j-i}\right)_{i \in \mathbb{Z}^d}\right)$ où $\mathbb{E}[|X_0|^p]$ est finie, $\mathbb{E}[X_0] = 0$ et $(a_i)_{i \in \mathbb{Z}^d} \in \ell^2(\mathbb{Z}^d)$, $p \geq 2$,

$$\left\| \sum_{i \in \mathbb{Z}^d} a_i X_i \right\|_p \leq \frac{14.5p}{\log p} \left(\sum_{i \in \mathbb{Z}^d} a_i^2 \right)^{1/2} \sum_{j=0}^{+\infty} (4j+4)^{d/2} \delta_{j,2} \\ + \frac{14.5p}{\log p} \left(\sum_{i \in \mathbb{Z}^d} |a_i|^p \right)^{1/p} \sum_{j=0}^{+\infty} (4j+4)^{d(1-1/p)} \delta_{j,p},$$

où pour $j \geq 1$,

$$\delta_{j,p} = \left\| \mathbb{E}[X_0 \mid \sigma\{\varepsilon_u, \|\mathbf{u}\|_\infty \leq j\}] - \mathbb{E}[X_0 \mid \sigma\{\varepsilon_u, \|\mathbf{u}\|_\infty \leq j-1\}] \right\|_p$$

et $\delta_{0,p} = \left\| \mathbb{E}[X_0 \mid \sigma\{\varepsilon_0\}] \right\|_p$.

Vitesse de convergence, modèle de regression

Modèle :

$$Y_i = g\left(\frac{\mathbf{i}}{n}\right) + X_i, \quad \mathbf{i} \in \Lambda_n := \{1, \dots, n\}^d,$$

où $g: [0, 1]^d \rightarrow \mathbb{R}$ est une fonction inconnue de classe C^∞ , $(X_i)_{i \in \mathbb{Z}^d}$ est un champ aléatoire centré s'exprimant comme une fonctionnelle d'un champ i.i.d.

On utilise l'estimateur g_n défini par

$$g_n(\mathbf{x}) = \frac{\sum_{i \in \Lambda_n} Y_i K\left(\frac{\mathbf{x} - \mathbf{i}/n}{h_n}\right)}{\sum_{i \in \Lambda_n} K\left(\frac{\mathbf{x} - \mathbf{i}/n}{h_n}\right)}, \quad \mathbf{x} \in [0, 1]^d,$$

où $K: \mathbb{R}^d \rightarrow \mathbb{R}$ est un noyau et $(h_n)_{n \geq 1}$ une suite convergent vers 0 et vérifiant

$$\lim_{n \rightarrow +\infty} nh_n = +\infty \text{ et } \lim_{n \rightarrow +\infty} nh_n^{d+1} = 0.$$

Hypothèses sur K

- $\int_{\mathbb{R}^d} K(\mathbf{u}) d\mathbf{u} = 1$;
- K est symétrique, $K(\mathbf{x}) \geq 0$ pour tout \mathbf{x} ;
- le support de K est $[-1, 1]^d$;
- il existe des constantes r , c et C telles que pour tous $\mathbf{x}, \mathbf{y} \in [-1, 1]^d$, $|K(\mathbf{x}) - K(\mathbf{y})| \leq r \|\mathbf{x} - \mathbf{y}\|_\infty$ et $c \leq K(\mathbf{x}) \leq C$.

On mesure la vitesse de convergence en loi de

$\left((nh_n)^{d/2} (g_n(\mathbf{x}) - \mathbb{E}[g_n(\mathbf{x})]) \right)_{n \geq 1}$ vers une loi normale par la quantité suivante :

$$\Delta_n := \sup_{t \in \mathbb{R}} \left| \mathbb{P} \left\{ (nh_n)^{d/2} (g_n(\mathbf{x}) - \mathbb{E}[g_n(\mathbf{x})]) \leq t \right\} - \Phi \left(\frac{t}{\sigma \|K\|_2} \right) \right|,$$

où $\Phi(t) = \mathbb{P}\{N \leq t\}$, N de loi normale centrée réduite.

Afin d'exprimer g_n sous la forme de sommes $\sum_{i \in \mathbb{Z}^d} b_{n,i} X_i / \|b_{n,\cdot}\|_2$, nous aurons besoin de définir

$$A_n := (nh_n)^{d/2} \left(\sum_{i \in \Lambda_n} K^2 \left(\frac{\mathbf{x} - i/n}{h_n} \right) \right)^{1/2} \|K\|_2^{-1} \left(\sum_{i \in \Lambda_n} K \left(\frac{\mathbf{x} - i/n}{h_n} \right) \right)^{-1/2}$$

Sous les hypothèses mentionnées sur K , $A_n \rightarrow 1$.

Nous aurons également besoin de contrôler

$$\varepsilon_n := \sum_{j \in \mathbb{Z}^d} |\mathbb{E} [X_0 X_j]| \left(\sum_{i \in \Lambda_n \cap (\Lambda_n - j)} \frac{K \left(\frac{\mathbf{x} - i/n}{h_n} \right) K \left(\frac{\mathbf{x} - (i-j)/n}{h_n} \right)}{\sum_{\mathbf{k} \in \Lambda_n} K^2 \left(\frac{\mathbf{x} - \mathbf{k}/n}{h_n} \right)} - 1 \right).$$

Pour chaque j fixé,

$$\lim_{n \rightarrow +\infty} \sum_{i \in \Lambda_n \cap (\Lambda_n - j)} \frac{K \left(\frac{\mathbf{x} - i/n}{h_n} \right) K \left(\frac{\mathbf{x} - (i-j)/n}{h_n} \right)}{\sum_{\mathbf{k} \in \Lambda_n} K^2 \left(\frac{\mathbf{x} - \mathbf{k}/n}{h_n} \right)} = 1,$$

donc la finitude de $\sum_{j \in \mathbb{Z}^d} |\mathbb{E} [X_0 X_j]|$ garantit la convergence de $(\varepsilon_n)_{n \geq 1}$ vers 0.

Théorème (G., 2018)

Soit $p > 2$, $p' := \min \{p, 3\}$ et $(X_j)_{j \in \mathbb{Z}^d} = \left(f \left((\varepsilon_{j-i})_{i \in \mathbb{Z}^d} \right) \right)_{j \in \mathbb{Z}^d}$ un champ aléatoire centré, s'exprimant comme une fonctionnelle d'i.i.d.. On suppose qu'il existe $\alpha, \beta > 0$ tels que les quantités suivantes soient finies

$$C_2(\alpha) := \sum_{j=0}^{+\infty} (j+1)^{d/2+\alpha} \delta_{j,2} \text{ et } C_p(\beta) := \sum_{j=0}^{+\infty} (j+1)^{d(1-1/p)+\beta} \delta_{j,p}.$$

Supposons que $\sum_{i \in \mathbb{Z}^d} |\text{Cov}(X_0, X_i)| < +\infty$ et que $\sigma^2 := \sum_{j \in \mathbb{Z}^d} \text{Cov}(X_0, X_j) > 0$.

Pour tout $\gamma > 0$, il existe n_0 et une constante κ tels que pour tout $n \geq n_0$,

$$\Delta_n \leq \kappa |A_n - 1|^{\frac{p}{p+1}} + |\varepsilon_n| + \kappa (nh_n)^{\frac{d}{2}(\gamma(p'-1)d-p'+2)} + (nh_n)^{-\frac{d}{2}\gamma\alpha\frac{p}{p+1}} + (nh_n)^{\frac{2d-p(\gamma\beta+1)}{2(p+1)}}.$$

Perspectives

- 1 Autre mesure de la vitesse de convergence.
- 2 Bornes non uniformes : on cherche à contrôler

$$\left| \mathbb{P} \left\{ \sum_{i \in \mathbb{Z}^d} b_{n,i} X_i / \|b_n\|_2 \leq x \right\} - \mathbb{P} \{N \leq x\} \right| (1 + |x|)^p.$$