

THÉORÈME DE GLIVENKO CANTELLI

Nourdin plog sauf étape 1
Gaudon (pr Dini)

- Prérequis:
- thm de Dini, $\liminf f$, \limsup
 - fct^o de répartition et ses propriétés.
 - LG-N faibles, cv p-s.
 - fct croissante admet en t point une limite à gch à d.

16 min en allant très vite
16 min 39 normal
14 min

On rappelle le 2^o thm de Dini:

Thm: Soient $a, b \in \mathbb{R}$ avec $a < b$ et (f_n) une suite de fonctions croissantes de $[a, b]$ dans \mathbb{R} qui converge simplement vers f continue. Alors (f_n) converge uniformément vers f sur $[a, b]$.

ne sont pas opposées continues contrairement au Gaudon

Dém: (ne pas faire le jour 5) Gaudon analyse.

Soit $\varepsilon > 0$. f est continue sur $[a, b]$ donc d'après le thm de Heine, elle y est unif ε^0 .
 $\exists \eta > 0 \quad \forall x, y \in [a, b] \quad |x - y| < \eta \Rightarrow |f(x) - f(y)| < \varepsilon. (*)$

On définit une subdivision $a = x_0 < x_1 < \dots < x_p = b$ de $[a, b]$ de pas $< \eta$.

* $f_n(x_i) \rightarrow f(x_i)$: $\exists N_i \quad \forall n \geq N_i \quad |f_n(x_i) - f(x_i)| < \varepsilon. \quad i \in \{0, \dots, p\}. (**)$

On pose $N = \max N_i$: $\forall n \geq N \quad \forall i \text{ si } i \leq p \quad |f_n(x_i) - f(x_i)| < \varepsilon.$

* Soit $x \in [a, b]$. soit $n \geq N$. il existe $i \in \{0, \dots, p\}$ tq $x \in [x_i, x_{i+1}]$

alors $|f(x) - f(x_i)| < \varepsilon$ par (*)

$$\begin{aligned} \text{Donc } |f(x) - f_n(x)| &\leq |f(x) - f(x_i)| + |f(x_i) - f_n(x_i)| + |f_n(x_i) - f_n(x)| \\ &\leq \varepsilon + \varepsilon + (f_n(x) - f_n(x_i)) \quad \text{car } f_n \text{ est croissante} \\ &\leq \varepsilon + \varepsilon + f_n(x_{i+1}) - f_n(x_i) \quad \text{car } f_n \text{ est croissante} \\ &\leq \varepsilon + \varepsilon + |f_n(x_{i+1}) - f(x_{i+1})| + |f(x_{i+1}) - f(x)| + |f(x_i) - f_n(x_i)| \\ &\leq 5\varepsilon. \end{aligned}$$

LA a donc la convergence uniforme

Soit $(\Omega, \mathcal{F}, \mathbb{P})$ un espace probabilisé.

Thm de Glivenko-Cantelli: Soit (X_n) une suite de v.a.-iid de fonction de répartition commune F . Pour tout $t \in \mathbb{R}$ et $n \in \mathbb{N}$ on pose

$$F_n(t) = \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{]-\infty, t]}(X_k) \quad (\text{C'est une v.a. appelée fonction de répartition empirique})$$

Alors $\sup_{t \in \mathbb{R}} |F_n(t) - F(t)| \xrightarrow[n \rightarrow +\infty]{} 0$ p.s.

i.e. $\exists A \in \mathcal{F} \quad \mathbb{P}(A) = 1 \quad \forall \omega \in A \quad \sup_{t \in \mathbb{R}} |F_n(t)(\omega) - F(t)| \xrightarrow[n \rightarrow +\infty]{} 0$

Dém: étape 1: $\sup_{t \in \mathbb{R}} |F_n(t) - F(t)|$ est bien défini et est une v.a.-

* Soit $\omega \in \Omega$. On pose $\mathcal{T} = \sup_{t \in \mathbb{R}} |F_n(t)(\omega) - F(t)|$. Pour tout $x \in \mathbb{R}$, $F_n(x)(\omega)$ et $F(x)$

sont des réels de $[0, 1]$ donc \mathcal{T} est fini. Donc $\sup_{t \in \mathbb{R}} |F_n(t) - F(t)|$ est bien défini.

* Soit $\omega \in \Omega$ $\sup_{t \in \mathbb{Q}} |F_n(t)(\omega) - F(t)| \leq \sup_{t \in \mathbb{R}} |F_n(t)(\omega) - F(t)|$ car $\mathbb{Q} \subset \mathbb{R}$

* On va montrer l'autre inégalité: Soit $\varepsilon > 0$, par définition du supremum, il existe $x_\varepsilon \in \mathbb{R}$ tq $T - \varepsilon < |F_n(x_\varepsilon)(\omega) - F(x_\varepsilon)| \leq T$ (1)

Comme $x \mapsto F_n(x)(\omega)$ et F sont continues à droite en tout point, en particulier elles le sont en x_ε et la valeur absolue de leur différence aussi:

$$\exists \delta > 0 \forall t \in]x_\varepsilon, x_\varepsilon + \delta[\quad | |F_n(t)(\omega) - F(t)| - |F_n(x_\varepsilon)(\omega) - F(x_\varepsilon)| | \leq \varepsilon$$

d'où $-\varepsilon \leq |F_n(t)(\omega) - F(t)| - |F_n(x_\varepsilon)(\omega) - F(x_\varepsilon)| \leq \varepsilon$

d'où en particulier $|F_n(t)(\omega) - F(t)| \geq |F_n(x_\varepsilon)(\omega) - F(x_\varepsilon)| - \varepsilon$

Ceci est vrai en particulier pour tout $t \in]x_\varepsilon, x_\varepsilon + \delta[\cap \mathbb{Q} \neq \emptyset$ par densité de \mathbb{Q} ds \mathbb{R}

d'où $\sup_{t \in \mathbb{Q}} |F_n(t)(\omega) - F(t)| \geq |F_n(x_\varepsilon)(\omega) - F(x_\varepsilon)| - \varepsilon$

$\geq T - 2\varepsilon$ par (1)

Ceci est vrai pour tout $\varepsilon > 0$ donc $\sup_{t \in \mathbb{Q}} |F_n(t)(\omega) - F(t)| \geq T$

donc $\forall \omega \in \Omega \quad \sup_{t \in \mathbb{Q}} |F_n(t)(\omega) - F(t)| = \sup_{t \in \mathbb{R}} |F_n(t)(\omega) - F(t)|$

* Or pour $t \in \mathbb{Q}$, $(x_1, \dots, x_n) \mapsto \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{x_k \leq t} - F(t) \right|$ est mesurable donc

$\psi: (x_1, \dots, x_n) \mapsto \sup_{t \in \mathbb{Q}} \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{x_k \leq t} - F(t) \right|$ est mesurable comme sup d'un nombre de fonctions mesurables. Donc $\sup_{t \in \mathbb{Q}} |F_n(t) - F(t)| = \psi(X_1, \dots, X_n)$ est une v.a.

Etape 2: Problèmes pour appliquer Dini.

D'après la LGM forte, $\forall t \in \mathbb{R} \exists A_t \in \mathcal{F} \mathbb{P}(A_t) = 1 \forall \omega \in A_t \quad F_n(t)(\omega) \rightarrow F(t)$
De plus pour tout $\omega \in \Omega$, $t \mapsto F_n(t)(\omega)$ est croissante, $n \in \mathbb{N}$. $n \rightarrow +\infty$

On a plusieurs problèmes:

- * F_n n'est pas a priori continue
- * la convergence n'a pas a priori lieu sur un segment $t \in \mathbb{R}$
- * On doit trouver $\#$ de mesure pleine tq $\forall \omega \in A \quad \forall t \in \mathbb{R} \quad F_n(t)(\omega) \rightarrow F(t)$
CS du thm de Dini

Etape 3: On se ramène à des lois uniformes.

On introduit l'inverse généralisée de F par $\forall u \in]0, 1[\quad F^*(u) = \inf \{ x \in \mathbb{R} \mid F(x) \geq u \}$
 $F^*(u)$ est ps à valeurs dans \mathbb{R} car F admet 0 comme limite en $-\infty$ et 1 en $+\infty$.

alors on a $\forall x \in \mathbb{R} \quad \forall u \in]0, 1[\quad F^*(u) \leq x \Leftrightarrow u \leq F(x)$. (2) (BL p 50)

Si $F^*(u) \leq x$ alors $\forall s > x \exists t < s$ tq $F(t) \geq u$ (ce n'est pas le bon sens) donc par croissance de F , $F(s) \geq F(t) \geq u$ donc $\forall s > x \quad F(s) \geq u$ donc par continuité à droite de F , $F(x) \geq u$.

Réciproquement si $u \leq F(x)$ alors $x \in \{y \in \mathbb{R} \mid F(y) \geq u\}$ donc $x \geq F^*(u) = \inf \{ \dots \}$

* F^* est croissante donc mesurable donc $F^*(U_n)$ est une v.a.

Soit (U_n) une suite de v.a. iid de loi $\mathcal{U}([0, 1])$ alors $F^*(U_n)$ et X_n ont m. loi ptt en \mathbb{N}

$\mathbb{P}(F^*(U_n) \leq t) = \mathbb{P}(U_n \leq F(t)) = F(t)$ car U_n est uniforme

donc $\left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{x_k \leq t} - F(t) \right| \leq \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{F^*(U_k) \leq t} - F(t) \right|$

donc $\sup_{t \in \mathbb{Q}} |F_n(t) - F(t)| = \psi(x_1, \dots, x_n) \sim \psi(F^*(u_1), \dots, F^*(u_n)) = \sup_{t \in \mathbb{Q}} \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{F^*(u_k) \leq t} - F(t) \right|$

D'après l'étape 1 le sup sur \mathbb{Q} ou sur \mathbb{R} c'est pareil.

$\sup_{t \in \mathbb{R}} \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{F^*(u_k) \leq t} - F(t) \right| \stackrel{(2)}{=} \sup_{t \in \mathbb{R}} \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{u_k \leq F(t)} - F(t) \right|$

$\stackrel{s=F(t)}{=} \sup_{s \in F(\mathbb{R})} \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{u_k \leq s} - s \right| \leq \sup_{s \in [0,1]} \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{u_k \leq s} - s \right|$ car $F(\mathbb{R}) \subset [0,1]$.

On pose pour $s \in [0,1]$ $G_n(s) = \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{u_k \leq s}$ et $G(s) = s$.

G est la fonction de répartition de $\mathcal{U}([0,1])$. G_n est la fonction de répartition empirique.

On est donc ramené à étudier des lois $\mathcal{U}([0,1])$ du fait de l'inégalité obtenue.

$\hookrightarrow G$ est continue et on est sur un segment.

Etape 4: Etude pour $\mathcal{U}([0,1])$.

* D'après la LGN faible, $\forall s \in [0,1] \exists A_s \in \mathcal{F} \mathbb{P}(A_s) = 1 \forall \omega \in A_s G_n(s)(\omega) \xrightarrow[n \rightarrow +\infty]{} G(s)$

On pose $A = \bigcap_{s \in [0,1] \cap \mathbb{Q}} A_s$ c'est une intersection dénombrable d'ensembles de mesure pleine

donc $\mathbb{P}(A) = 1$.

donc $\forall \omega \in A \forall s \in [0,1] \cap \mathbb{Q} G_n(s)(\omega) \xrightarrow[n \rightarrow +\infty]{} G(s)$ (3)

* On voudrait que ce soit vrai pour $s \in [0,1]$: Soit $\omega \in A$. Soit $s \in [0,1]$. Soit $\varepsilon > 0$.

Comme $\mathbb{Q} \cap [0,1]$ est dense dans $[0,1]$, il existe $p, q \in \mathbb{Q} \cap [0,1]$ + q

$s - \varepsilon \leq p \leq s \leq q \leq s + \varepsilon$

Or $s \mapsto G_n(s)(\omega)$ est croissante donc $G_n(p)(\omega) \leq G_n(s)(\omega) \leq G_n(q)(\omega)$.
d'où $s - \varepsilon \leq p \stackrel{(3)}{=} \lim_{n \rightarrow +\infty} G_n(p)(\omega) \leq \liminf_{n \rightarrow +\infty} G_n(s)(\omega) \leq \limsup_{n \rightarrow +\infty} G_n(s)(\omega) \leq \lim_{n \rightarrow +\infty} G_n(q)(\omega) \stackrel{(3)}{=} q \leq s + \varepsilon$

C'est vrai pour tout $\varepsilon > 0$. donc $\liminf_{n \rightarrow +\infty} G_n(s)(\omega) = \limsup_{n \rightarrow +\infty} G_n(s)(\omega) = s = G(s)$

donc $\forall \omega \in A \forall s \in [0,1] G_n(s)(\omega) \xrightarrow[n \rightarrow +\infty]{} G(s)$

CS dans le thm de Dini


donc d'après le thm de Dini, $\forall \omega \in A \sup_{s \in [0,1]} |G_n(s)(\omega) - G(s)| \xrightarrow[n \rightarrow +\infty]{} 0$

donc d'après l'étape 3), $\forall \omega \in A \sup_{t \in \mathbb{R}} |F_n(t)(\omega) - F(t)| \xrightarrow[n \rightarrow +\infty]{} 0$.

Soit $\omega \in A$. $s \mapsto F_n(s)(\omega)$ est continue à droite = ~~de t_n à t_0~~ donc
the indicatrice $\mathbb{1}_{x \leq t}$ est continue à droite.

Si $t_n \rightarrow t$ en décroissant $\mathbb{1}_{x \leq t} = \mathbb{1}_{\forall n, x \leq t_n} \stackrel{(3)}{=} \lim_{n \rightarrow +\infty} \mathbb{1}_{x \leq t_n}$

ou $\mathbb{1}_{x \leq t} = \mathbb{1}_{\bigcap_{n \rightarrow +\infty} (x \leq t_n)}$



c'est bien continue à droite!

donc $\sup_{t \in \mathbb{Q}} |F_n(t) - F(t)| = \psi(X_1, \dots, X_n) \sim \psi(F^*(U_1), \dots, F^*(U_n)) = \sup_{t \in \mathbb{Q}} \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{F^*(U_k) \leq t} - F(t) \right|$

D'après l'étape 1 le sup sur \mathbb{Q} ou sur \mathbb{R} c'est pareil.

$\sup_{t \in \mathbb{R}} \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{F^*(U_k) \leq t} - F(t) \right| \stackrel{(2)}{=} \sup_{t \in \mathbb{R}} \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{U_k \leq F(t)} - F(t) \right|$

$s = F(t) \Rightarrow \sup_{s \in F(\mathbb{R})} \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{U_k \leq s} - s \right| \leq \sup_{s \in [0,1]} \left| \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{U_k \leq s} - s \right|$ car $F(\mathbb{R}) \subset [0,1]$.

On pose pour $s \in [0,1]$ $G_n(s) = \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{U_k \leq s}$ et $G(s) = s$.

G est la fonction de répartition de $\mathcal{U}([0,1])$. G_n est la fonction de répartition empirique.

On est donc ramené à étudier des lois $\mathcal{U}([0,1])$ du fait de l'inégalité obtenue.

$\hookrightarrow G$ est continue et on est sur un segment.

Etape 4: Etude pour $\mathcal{U}([0,1])$.

* D'après la LGN faible, $\forall s \in [0,1] \exists A_s \in \mathcal{F} P(A_s) = 1 \forall \omega \in A_s G_n(s)(\omega) \xrightarrow[n \rightarrow +\infty]{} G(s)$

On pose $A = \bigcap_{s \in [0,1] \cap \mathbb{Q}} A_s$ c'est une intersection dénombrable d'ensembles de mesure pleine

donc $P(A) = 1$.

donc $\forall \omega \in A \forall s \in [0,1] \cap \mathbb{Q} G_n(s)(\omega) \xrightarrow[n \rightarrow +\infty]{} G(s)$ (3)

* On voudrait que ce soit vrai pour $s \in [0,1]$: Soit $\omega \in A$. Soit $s \in [0,1]$. Soit $\varepsilon > 0$.

Pomme $\mathbb{Q} \cap [0,1]$ est dense dans $[0,1]$, il existe $p, q \in \mathbb{Q} \cap [0,1]$ tq

$s - \varepsilon \leq p \leq s \leq q \leq s + \varepsilon$

Or $s \mapsto G_n(s)(\omega)$ est croissante donc $G_n(p)(\omega) \leq G_n(s)(\omega) \leq G_n(q)(\omega)$.
d'où $s - \varepsilon \leq p \stackrel{(3)}{=} \lim_{n \rightarrow +\infty} G_n(p)(\omega) \leq \liminf_{n \rightarrow +\infty} G_n(s)(\omega) \leq \limsup_{n \rightarrow +\infty} G_n(s)(\omega) \leq \lim_{n \rightarrow +\infty} G_n(q)(\omega) \stackrel{(3)}{=} q \leq s + \varepsilon$

C'est vrai pour tout $\varepsilon > 0$. donc $\lim_{n \rightarrow +\infty} G_n(s)(\omega) = \lim_{n \rightarrow +\infty} G_n(s)(\omega) = s = G(s)$

donc $\forall \omega \in A \forall s \in [0,1] G_n(s)(\omega) \xrightarrow[n \rightarrow +\infty]{} G(s)$

CS dans le thm de Dini

Donc d'après le thm de Dini, $\forall \omega \in A \sup_{s \in [0,1]} |G_n(s)(\omega) - G(s)| \xrightarrow[n \rightarrow +\infty]{} 0$

Donc d'après l'étape 3), $\forall \omega \in A$

Soit $\omega \in A$. $s \mapsto F_n(s)(\omega)$ est continue

et décroissante

Si $t \rightarrow 0$ on dé

ou $\mathbb{1}_{x \leq t} = \mathbb{1}_{x \leq 0}$

- Pour tout n , si $(X_k)_{1 \leq k \leq n}$ est un échantillon de taille n , la fonction F_n est appelée la fonction de répartition empirique de l'échantillon $(X_k)_{1 \leq k \leq n}$.
- Le théorème de Glivenko-Cantelli est parfois appelé théorème fondamental de la statistique, car il exprime en quoi une loi de probabilité peut être révélée par la connaissance d'un échantillon suffisamment grand de ladite loi de probabilité.
- Le théorème de Glivenko-Cantelli est parfois considéré comme une généralisation du deuxième théorème de Dini, car il ne suppose pas en particulier la continuité de F , ni le fait d'être défini sur un compact.
- Le théorème de Kolmogorov-Smirnov précise l'énoncé du théorème de Glivenko-Cantelli dans le cas où F est continue : il donne une estimation de la vitesse de convergence en $\frac{1}{\sqrt{n}}$:

Théorème 4 (de Kolmogorov-Smirnov)

Soit (X_1, \dots, X_n) un échantillon de loi μ sur \mathbb{R} de fonction de répartition F . Si F est continue, alors

$$K_n = \sqrt{n} \sup_{x \in \mathbb{R}} |F_n(x) - F(x)| \xrightarrow{L} \mu_{KS}$$

où μ_{KS} est une loi universelle ne dépendant pas de F . Elle est portée par \mathbb{R}^+ et a pour fonction de répartition pour $t \geq 0$:

$$F_{KS}(t) = 1 + 2 \sum_{k=1}^{+\infty} (-1)^k e^{-2k^2 t^2}$$

- Le théorème de Kolmogorov-Smirnov est à la base du test d'adéquation à une loi de