

# Théorème de Glivenko - Cantelli

Ref:

- Probabilité 2, J.-Y. Ouyard
- Agrégation de mathématiques, Y. Nourdin

## Théorème (Dini)

Soient  $a, b$  dans  $\mathbb{R}$  tels que  $a < b$ .

Soit  $(f_n)$  une suite de fonctions croissantes de  $[a, b]$  dans  $\mathbb{R}$  convergeant simplement vers une fonction continue  $f$ .

Alors  $(f_n)$  converge uniformément vers  $f$ .

Preuve:

Soit  $\varepsilon \in \mathbb{R}_+^*$ . Comme  $f$  est continue sur le compact  $[a, b]$  le théorème de Heine assure que  $f$  est uniformément continue sur  $[a, b]$ .

Soit  $\delta \in \mathbb{R}_+^*$  tel que

$$\forall (x, y) \in [a, b]^2 \quad |x - y| < \delta \Rightarrow |f(x) - f(y)| < \varepsilon$$

Soit  $(a_i)_{1 \leq i \leq k}$  une subdivision de  $[a, b]$  de pas strictement inférieur à  $\delta$ .

Soit  $n_0 \in \mathbb{N}$  tel que pour tout  $n \in \mathbb{N}$

$$n \geq n_0 \Rightarrow \forall i \in [1, k] \quad |f_n(a_i) - f(a_i)| < \varepsilon$$

Soit  $x \in [a, b]$ . Il existe  $i \in [1, k]$  tel que  $x \in [a_i, a_{i+1}]$ .

Alors on a, pour tout  $n \in \mathbb{N}$  tel que  $n \geq n_0$

$$|f(x) - f_n(x)| \leq |f(x) - f(a_i)| + |f(a_i) - f_n(a_i)| + |f_n(a_i) - f_n(x)|$$

$$\leq \varepsilon + \varepsilon + f_n(x) - f_n(a_i)$$

$$\leq 2\varepsilon + f_n(a_{i+1}) - f_n(a_i) \leq 5\varepsilon. \quad \text{Cela conclut.}$$

## Théorème (Glivenko-Cantelli)

Soient  $(X_n)$  des v.a.i.d de fonction de répartition  $F$ .  
Pour  $t \in \mathbb{R}$  et  $n \in \mathbb{N}^*$ , on note  $F_n(t)$  la somme

$$\frac{1}{n} \sum_{k=1}^n \mathbb{1}_{]-\infty, t]}(X_k)$$

Alors on a presque sûrement

$$\sup_{t \in \mathbb{R}} |F_n(t) - F(t)| \xrightarrow{n \rightarrow +\infty} 0$$

Preuve:

Etape 1: Pour tout  $n \in \mathbb{N}^*$ ,  $\sup_{t \in \mathbb{R}} |F_n(t) - F(t)|$  est une variable aléatoire.

Soit  $n \in \mathbb{N}^*$ . Soit  $\omega \in \Omega$  tel que pour tout  $i \in \llbracket 1, n \rrbracket$   $X_i(\omega)$  soit défini.

Notons  $\tau$  la quantité  $\sup_{t \in \mathbb{R}} |F_n(t)(\omega) - F(t)|$ . Comme les fonctions  $F_n$  et  $F$  sont bornées par 1,  $\tau$  est un réel (positif).

- Montrons que  $\tau = \sup_{t \in \mathbb{Q}} |F_n(t) - F(t)|$  et cela conclura le premier point. (supremum  $t \in \mathbb{Q}$  dénombrable de fonctions mesurables)

↳ Soit  $\varepsilon \in \mathbb{R}_+^*$ . Par définition / propriété du supremum, il existe  $x_\varepsilon \in \mathbb{R}$  tel que  $\tau - \varepsilon < |F_n(x_\varepsilon)(\omega) - F(x_\varepsilon)|$

Comme les applications  $t \mapsto F_n(t)(\omega)$  et  $F$  sont continues à droite, l'application  $g: t \mapsto |F_n(t)(\omega) - F(t)|$  l'est aussi

Soit  $\delta \in \mathbb{R}_+^*$  tel que  $\forall t \in ]x_\varepsilon, x_\varepsilon + \delta[$   $|g(t) - g(x_\varepsilon)| < \varepsilon$ .

On a alors

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

Par densité de  $\mathbb{Q}$  dans  $\mathbb{R}$ , on en déduit

$$\sup_{t \in \mathbb{Q}} |F_n(t)(\omega) - F(t)| \geq |F_n(x_\varepsilon)(\omega) - F(x_\varepsilon)| - \varepsilon \geq \tau - 2\varepsilon.$$

D'où l'égalité annoncée, et la fin de l'étape 1.

3

Etape 2: La loi des grands nombres assure qu'on a

$$\forall t \in \mathbb{R} \quad F_n(t) \xrightarrow[n \rightarrow +\infty]{\text{p.s.}} F(t)$$

et de plus, pour presque tout  $\omega \in \Omega$ , les applications

$$\left( t \longmapsto F_n(t) \right)_{n \in \mathbb{N}^*}$$

sont croissantes.

On voudrait appliquer le théorème de Dini énoncé précédemment, mais il y a trois "problèmes":

- \* la régularité de  $F$ ;
- \* la convergence ne se fait pas sur un segment;
- \* Il faut "p.s.  $\forall t \in \mathbb{R} \lim_{n \rightarrow +\infty} F_n(t) = F(t)$ ".

Etape 3: On se ramène à des lois uniformes.

Rappel: Inverse généralisée

$$\hookrightarrow \text{on note } \forall u \in [0, 1] \quad F^*(u) = \inf \left\{ x \in \mathbb{R} / F(x) \geq u \right\}$$

L'application  $F^*$  vérifie

$$\forall x \in \mathbb{R} \quad \forall u \in [0, 1] \quad F^*(u) \leq x \iff u \leq F(x)$$

et si  $U \sim \mathcal{U}[0, 1]$  alors  $F^*(U)$  a pour fonction de répartition  $F$ .

Alors  $\Psi(X_1, \dots, X_n) := \sup_{t \in \mathbb{Q}} |F_n(t) - F(t)|$  suit la même loi que  $\Psi(F^*(U_1), \dots, F^*(U_n))$  où  $(U_n)$  sont des v.a.i.i.d. de loi  $\mathcal{U}[0, 1]$ .

On a:

$$\Psi(F^*(U_1), \dots, F^*(U_n)) \stackrel{\text{étape 1}}{=} \sup_{t \in \mathbb{R}} \left| \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{F^*(U_i) \leq t\}} - F(t) \right|$$

$$= \sup_{s \in F(\mathbb{R})} \left| \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i \leq s\}} - s \right|$$

$$\leq \sup_{s \in [0,1]} \left| \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i \leq s\}} - s \right|$$

Notons  $G_n(s) := \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i \leq s\}}$  et  $G(s) := s$ .

Alors  $G$  est la fonction de répartition de la loi  $\mathcal{U}[0,1]$  et  $G_n$  est sa fonction de répartition empirique.

Par l'inégalité précédente nous ramène donc à montrer le théorème dans le cas  $\mathcal{U}([0,1])$  (qui élimine 2 problèmes)

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

Par la loi des grands nombres, pour tout  $s \in [0,1]$ , il existe un ensemble mesurable  $A_s$  tel que  $\mathbb{P}(A_s) = 1$  et tel que

$$\forall \omega \in A_s \quad \lim_{n \rightarrow +\infty} G_n(s)(\omega) = G(s)$$

Notons  $A$  l'ensemble  $\bigcap_{t \in [0,1] \cap \mathbb{Q}} A_t$ , qui est de proba 1.

Par caractère dénombrable, on a

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

Montrons que cela reste vrai pour  $s \in [0,1]$ .

↳ Soit  $s \in [0,1]$  et  $\varepsilon \in \mathbb{R}_+^*$ . Par densité de  $\mathbb{Q} \cap [0,1]$  dans  $[0,1]$  il existe  $p, q$  dans  $[0,1] \cap \mathbb{Q}$  tels que  $s - \varepsilon \leq p \leq s \leq q \leq s + \varepsilon$ .

Par croissance de  $s \mapsto \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i(\omega) \leq s\}}$ , on obtient

$$\frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i(\omega) \leq p\}} \leq \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i(\omega) \leq s\}} \leq \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i(\omega) \leq q\}}$$

pour tout  $\omega \in A$ .

On en déduit

$$p = \liminf \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i(\omega) \leq p\}} \leq \liminf \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i(\omega) \leq s\}}$$

$$q = \limsup \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i(\omega) \leq q\}} \geq \limsup \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i(\omega) \leq s\}}$$

et donc  $s - \varepsilon \leq \liminf \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i(\omega) \leq s\}} \leq \limsup \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i(\omega) \leq s\}} \leq s + \varepsilon$ .  
(pour tout  $\omega \in A$ )

D'où

$$\forall \omega \in A \quad \forall s \in [0, 1] \quad \lim_{n \rightarrow +\infty} G_n(s)(\omega) = s$$

Le théorème de Dini énoncé conclut. ■

Rmq:

(1) on utilise le fait que si  $(X_n), (Y_n)$  sont deux suites de v.a. telles que

$$\forall n \in \mathbb{N} \quad X_n \sim Y_n$$

sur le même espace de proba.

et  $X_n \xrightarrow[n \rightarrow +\infty]{p.s.} 0$ , alors  $Y_n \xrightarrow[n \rightarrow +\infty]{p.s.} 0$ . le 0 est important!

(2) On pourrait montrer que l'on a

$$\|F_n - F\|_\infty = \max \left( \max_{1 \leq k \leq n} \left| \frac{k}{n} - F(X_{(k)}) \right|, \max_{1 \leq k \leq n} \left| \frac{k-1}{n} - F(X_{(k)}) \right| \right)$$

(3) 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

Soit  $(X_n)$  une suite de v.a.i.i.d de fonction de répartition  $F$  continue.

Alors on a

$$\sqrt{n} \|F_n - F\|_{\infty} \xrightarrow[n \rightarrow +\infty]{\text{Loi}} \mu_{KS}$$

où  $\mu_{KS}$  est la loi de fonction de répartition

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

ne dépend pas de  $F$

pour  $t \in \mathbb{R}_+^*$ .