

Rappel. On a démontré à l'aide de la formule d'inversion de Fourier (et de Fubini) la formule suivante (*) qui nous sera utile dans ce cours : si X est une variable aléatoire, si φ_X est sa fonction caractéristique et si f est une fonction de classe C^2 sur \mathbb{R} , à support compact, on a

$$(*) \quad \mathbb{E} f(X) = \frac{1}{2\pi} \int_{\mathbb{R}} \widehat{f}(t) \varphi_X(t) dt.$$

Il en résulte que la fonction caractéristique détermine la loi : pour tous $a < b$, on peut approcher (au sens de la limite simple) l'indicatrice de l'intervalle semi-ouvert $]a, b]$ par une suite (f_n) de fonctions bosse de classe C^2 ,

$$\forall x \in \mathbb{R}, \quad f_n(x) \xrightarrow[n]{} \mathbf{1}_{]a, b]}(x), \quad |f_n(x)| \leq 1;$$

par convergence dominée, on voit que

$$\begin{aligned} F_X(b) - F_X(a) &= \mathbb{P}(\{a < X \leq b\}) = \int_{\Omega} \mathbf{1}_{]a, b]}(X(\omega)) d\mathbb{P}(\omega) \\ &= \lim_n \int_{\Omega} f_n(X(\omega)) d\mathbb{P}(\omega) = \lim_n \mathbb{E} f_n(X) = \lim_n \frac{1}{2\pi} \int_{\mathbb{R}} \widehat{f}_n(t) \varphi_X(t) dt \end{aligned}$$

s'exprime en termes de φ_X .

Exemple. On a vu que si G est une variable aléatoire gaussienne, suivant la loi gaussienne centrée réduite

$$d\gamma(x) = e^{-x^2/2} \frac{dx}{\sqrt{2\pi}},$$

la fonction caractéristique de G est

$$\varphi_G : t \in \mathbb{R} \longrightarrow e^{-t^2/2}.$$

La détermination de la loi au moyen de la fonction caractéristique permet de trouver facilement la loi de combinaisons linéaires de gaussiennes *indépendantes* : si les $(G_j)_{j \geq 1}$ sont des variables aléatoires indépendantes de loi γ et si les coefficients réels (a_j) vérifient l'égalité $\sum_{j=1}^n a_j^2 = 1$, la variable aléatoire $X = \sum_{j=1}^n a_j G_j$ suit aussi la loi γ . En particulier, la loi de

$$\frac{G_1 + G_2 + \dots + G_n}{\sqrt{n}}$$

reste égale à la loi gaussienne γ , pour tout $n \geq 1$: c'est un cas très particulier du *théorème de la limite centrale* qu'on verra un peu plus loin.

Pour montrer que la loi de cette v.a. X est égale à γ , il suffit de montrer que la fonction caractéristique de X est égale à celle des gaussiennes centrées réduites. On a pour tout t réel, en utilisant l'indépendance des (G_j) ,

$$\begin{aligned} \mathbb{E} e^{itX} &= \mathbb{E} e^{i \sum_{j=1}^n ta_j G_j} = \mathbb{E} \left(\prod_{j=1}^n e^{ita_j G_j} \right) = \prod_{j=1}^n \left(\mathbb{E} e^{ita_j G_j} \right) = \\ &= \prod_{j=1}^n \varphi_{G_j}(ta_j) = \prod_{j=1}^n e^{-(ta_j)^2/2} = e^{-t^2 (\sum_{j=1}^n a_j^2)/2} = e^{-t^2/2}, \end{aligned}$$

ce qu'il fallait démontrer.

Lemme 1. Soit (Z_n) une suite de variables aléatoires réelles sur un espace de probabilité (Ω, \mathcal{F}, P) ; si la fonction caractéristique de Z_n converge simplement sur \mathbb{R} vers celle d'une v.a. Z , alors pour toute fonction bosse f de classe C^2 sur \mathbb{R} on a

$$E f(Z_n) \xrightarrow[n]{} E f(Z).$$

Preuve. — On utilise le théorème de convergence dominée et la formule (*) : pour tout entier n ,

$$E f(Z_n) = \frac{1}{2\pi} \int_{\mathbb{R}} \widehat{f}(t) \varphi_{Z_n}(t) dt ;$$

on a vu que les fonctions caractéristiques sont bornées par 1 en module sur \mathbb{R} ; on voit donc d'après les hypothèses du lemme que

$$\forall t \in \mathbb{R}, \quad \widehat{f}(t) \varphi_{Z_n}(t) \xrightarrow[n]{} \widehat{f}(t) \varphi_Z(t),$$

avec la domination

$$|\widehat{f}(t) \varphi_{Z_n}(t)| \leq |\widehat{f}(t)|$$

par la fonction $|\widehat{f}|$ qui est intégrable sur \mathbb{R} (transformée de Fourier d'une fonction de classe C^2 à support compact). Le résultat découle du théorème de convergence dominée.

Théorème de la limite centrale

Avant d'attaquer le théorème, rappelons que la fonction caractéristique φ_X d'une v.a. X est de classe C^2 sur \mathbb{R} quand $E X^2 < +\infty$. On a vu que dans ce cas, on a

$$\varphi'_X(0) = i E X \quad \text{et} \quad \varphi''_X(0) = - E X^2.$$

Théorème de la limite centrale, version 0. Soit (Y_n) une suite de variables aléatoires indépendantes, centrées, de même loi, et avec un moment d'ordre deux $E Y_n^2$ qui soit tel que $E Y_n^2 = 1$; la suite des variables aléatoires

$$s_n = \frac{Y_1 + \dots + Y_n}{\sqrt{n}}$$

converge en loi vers la loi gaussienne centrée réduite, c'est-à-dire que pour tous $a < b$ on a

$$P(\{a \leq s_n \leq b\}) \xrightarrow[n]{} \int_a^b e^{-x^2/2} \frac{dx}{\sqrt{2\pi}}.$$

Preuve. — Les variables aléatoires (Y_n) ayant toutes la même loi, elles ont la même fonction caractéristique qu'on appellera φ_Y (on a $\varphi_Y = \varphi_{Y_1} = \varphi_{Y_j}$, pour tout $j > 1$). Comme Y_1 est de carré intégrable, la fonction caractéristique φ_Y est de classe C^2 , donc au voisinage de 0 on peut écrire par Taylor-Young

$$\varphi_Y(t) = \varphi_Y(0) + t \varphi'_Y(0) + \frac{t^2}{2} \varphi''_Y(0) + t^2 \varepsilon_1(t),$$

où $\varepsilon_1(t)$ tend vers 0 quand $t \rightarrow 0$. On a ici

$$\varphi'_Y(0) = i E Y = 0, \quad \varphi''_Y(0) = - E Y^2 = -1,$$

donc, en remplaçant, on obtient le développement limité

$$\varphi_Y(t) = 1 - \frac{t^2}{2} + t^2 \varepsilon_1(t).$$

Par l'indépendance des v.a. (Y_j) , pour tout $t \in \mathbb{R}$ fixé, on obtient

$$\begin{aligned} \varphi_{s_n}(t) &= \mathbb{E} e^{its_n} = \mathbb{E} \left(\prod_{j=1}^n e^{itY_j/\sqrt{n}} \right) = \prod_{j=1}^n \left(\mathbb{E} e^{itY_j/\sqrt{n}} \right) = \\ &= \left(\mathbb{E} e^{i(t/\sqrt{n})Y_1} \right)^n = \varphi_Y(t/\sqrt{n})^n. \end{aligned}$$

On a par ailleurs

$$\ln(1 + u) = u + u\varepsilon_2(u)$$

au voisinage de 0, où $\varepsilon_2(u)$ tend vers 0 quand $u \rightarrow 0$. On a donc

$$\ln \varphi_{s_n}(t) = n \ln \varphi_Y(t/\sqrt{n}) = n \ln \left(1 - \frac{t^2}{2n} + \frac{t^2}{n} \varepsilon_1(t/\sqrt{n}) \right).$$

Posons

$$u_n = -\frac{t^2}{2n} + \frac{t^2}{n} \varepsilon_1(t/\sqrt{n}),$$

qui tend vers 0 avec n , ce qui entraîne que $\varepsilon_2(u_n)$ tend vers 0 ; de plus

$$nu_n = -t^2/2 + t^2 \varepsilon_1(t/\sqrt{n})$$

tend vers $-t^2/2$ quand $n \rightarrow +\infty$; on en déduit que

$$\ln \varphi_{s_n}(t) = n \ln(1 + u_n) = nu_n + nu_n \varepsilon_2(u_n)$$

tend vers $-t^2/2$. Donc pour tout t réel, $\varphi_{s_n}(t)$ converge vers $e^{-t^2/2} = \varphi_G(t)$, en désignant par G une v.a. gaussienne centrée réduite.

On va conclure grâce au lemme 1. Donnons nous $a < b$, et $\varepsilon > 0$ tel que $2\varepsilon < b - a$, de sorte que $a + \varepsilon < b - \varepsilon$. Considérons deux bosses f_1, f_2 de classe C^2 telles que

$$\mathbf{1}_{(a+\varepsilon, b-\varepsilon)} \leq f_1 \leq \mathbf{1}_{(a, b)} \leq f_2 \leq \mathbf{1}_{(a-\varepsilon, b+\varepsilon)}.$$

D'après le lemme 1, $\mathbb{E} f_i(s_n)$ tend vers $\mathbb{E} f_i(G)$, $i = 1, 2$. Pour $n \geq n_0$, on aura

$$\left| \mathbb{E} f_i(s_n) - \mathbb{E} f_i(G) \right| < \varepsilon, \quad i = 1, 2;$$

en utilisant le fait que la densité $(2\pi)^{-1/2} e^{-x^2/2}$ de la loi gaussienne γ est < 1 , on obtient l'inégalité $\mathbb{P}(x \leq G \leq x + \varepsilon) \leq \varepsilon$ pour tout réel x , donc pour $n \geq n_0$

$$\mathbb{P}(a \leq G \leq b) \leq \mathbb{P}(a + \varepsilon \leq G \leq b - \varepsilon) + 2\varepsilon = \mathbb{E} \mathbf{1}_{(a+\varepsilon, b-\varepsilon)}(G)$$

$$\leq \mathbb{E} f_1(G) + 2\varepsilon < \mathbb{E} f_1(s_n) + 3\varepsilon \leq \mathbb{P}(a \leq s_n \leq b) + 3\varepsilon$$

et de même pour l'autre côté,

$$\mathbb{P}(a \leq G \leq b) \geq \mathbb{P}(a - \varepsilon \leq G \leq b + \varepsilon) - 2\varepsilon$$

$$\geq \mathbb{E} f_2(G) - 2\varepsilon > \mathbb{E} f_2(s_n) - 3\varepsilon \geq \mathbb{P}(a \leq s_n \leq b) - 3\varepsilon.$$

Pour $n \geq n_0$, on a donc

$$\left| \mathbb{P}(a \leq s_n \leq b) - \mathbb{P}(a \leq G \leq b) \right| < 3\varepsilon,$$

ce qui termine la preuve.

Théorème de la limite centrale, version 1. Soit $(X_n)_{n \geq 1}$ une suite de variables aléatoires indépendantes, centrées, de même loi, et avec un moment d'ordre deux $E X_n^2$ fini ; posons $\sigma^2 = E(X_1 - E X_1)^2 = \text{Var}(X_1)$ et supposons $\text{Var}(X_1) > 0$. La suite

$$s_n = \frac{X_1 + \cdots + X_n - n E X_1}{\sigma \sqrt{n}} = \frac{1}{\sqrt{n}} \sum_{j=1}^n \frac{X_j - E X_j}{\sigma}$$

converge en loi vers la loi gaussienne centrée réduite.

Preuve. — Comme les X_i sont de carré intégrable par rapport à la mesure finie P sur Ω , elles sont aussi P -intégrables ; comme elles ont la même loi, elles ont la même intégrale $m = E X_i = E X_1$. Posons

$$Y_i = \frac{X_i - m}{\sigma} ;$$

ces variables sont indépendantes comme fonctions $Y_i = g(X_i)$ de variables indépendantes, où

$$g(x) = \frac{x - m}{\sigma},$$

et les (Y_i) ont la même loi (elles sont obtenues par la même fonction g à partir de v.a. de même loi). On a $E Y_i = (E X_i - m)/\sigma = 0$ et

$$E Y_i^2 = \frac{1}{\sigma^2} E(X_i - m)^2 = \frac{1}{E(X_1 - E X_1)^2} E(X_i - E X_i)^2 = 1.$$

Le résultat annoncé découle de la version 0, appliquée aux (Y_i) .

Convergence des lois, topologie étroite

Pour une probabilité μ sur $(\mathbb{R}, \mathcal{B})$, on définit la fonction de répartition F_μ par

$$\forall x \in \mathbb{R}, \quad F_\mu(x) = \mu(]-\infty, x]).$$

On a envie de se servir de la fonction de répartition pour introduire une notion de convergence des lois de probabilité sur \mathbb{R} . Par exemple, si (μ_n) est une suite de probabilités sur \mathbb{R} et si les fonctions de répartition F_{μ_n} convergent uniformément sur \mathbb{R} vers la fonction de répartition F_ν d'une probabilité ν , alors certainement on a envie de dire que (μ_n) tend vers ν . Mais se limiter à ce cas serait trop restrictif. En effet, si la suite (x_n) de réels converge vers x , on veut dire que les mesures de Dirac (δ_{x_n}) convergent vers δ_x , par exemple parce qu'on veut sûrement dire que la loi de la v.a. constante $X_n = x_n$ converge vers la loi de la constante $X = x$, dans la mesure où les v.a. X_n convergent (uniformément) vers la v.a. $X = x$. Or, quand $x_n \neq x$, on a

$$\|F_{\delta_{x_n}} - F_{\delta_x}\|_\infty = 1.$$

Pour s'en sortir, on va accepter de comparer les fonctions de répartition en des points légèrement différents.

Définition. On dit qu'une suite (μ_n) de probabilités sur $(\mathbb{R}, \mathcal{B})$ converge étroitement vers une probabilité ν si pour tout $\varepsilon > 0$, il existe n_0 tel que pour tout $n \geq n_0$ on ait

$$\forall x \in \mathbb{R}, \quad F_\nu(x - \varepsilon) - \varepsilon \leq F_{\mu_n}(x) \leq F_\nu(x + \varepsilon) + \varepsilon.$$

On peut définir une distance sur l'ensemble des probabilités sur $(\mathbb{R}, \mathcal{B})$ qui corresponde à cette notion de convergence ; l'ensemble des $\varepsilon \geq 0$ tels que

$$\forall x \in \mathbb{R}, \quad F_\mu(x) \leq F_\nu(x + \varepsilon) + \varepsilon$$

est fermé parce que F_ν est continue à droite, on peut donc définir le plus petit nombre $\varepsilon(\mu, \nu) \geq 0$ tel que

$$\forall x \in \mathbb{R}, \quad F_\mu(x) \leq F_\nu(x + \varepsilon(\mu, \nu)) + \varepsilon(\mu, \nu)$$

et poser

$$d(\mu, \nu) = \min(\varepsilon(\mu, \nu), \varepsilon(\nu, \mu)).$$

C'est une distance, et la convergence des suites de probabilités sur $(\mathbb{R}, \mathcal{B})$ pour cette distance est la même convergence que celle qui est donnée dans la définition précédente.

Exemple. On peut voir que

$$d(\delta_x, \delta_y) = \min(1, |x - y|).$$

Attention ! Si on considère la suite des mesures de Dirac (δ_n) aux points $n \in \mathbb{N}$, la suite des fonctions de répartition F_{δ_n} converge simplement sur \mathbb{R} vers la fonction nulle, mais la fonction nulle n'est pas une fonction de répartition de probabilité. Il n'y a pas convergence étroite dans ce cas. De même on n'a pas que

$$\mu_n = \frac{1}{2}(\delta_0 + \delta_n)$$

converge étroitement vers $\frac{1}{2}\delta_0$, qui n'est pas une probabilité, bien que la suite des fonctions de répartition F_{μ_n} converge simplement vers $\frac{1}{2}F_{\delta_0}$.

En fait, si les (μ_n) sont des probabilités et si on a, sans dire d'avance que ν est une probabilité, que pour tout $\varepsilon > 0$, on a pour n assez grand

$$\forall x \in \mathbb{R}, \quad F_\nu(x - \varepsilon) - \varepsilon \leq F_{\mu_n}(x) \leq F_\nu(x + \varepsilon) + \varepsilon,$$

il en résulte que

$$\limsup_{x \rightarrow +\infty} |1 - F_\nu(x)| \leq \varepsilon,$$

pour tout $\varepsilon > 0$, donc F_ν tend vers 1 en $+\infty$ et ν est une probabilité sur $(\mathbb{R}, \mathcal{B})$.

Remarque. Si (μ_n) tend étroitement vers ν et si x_0 est un réel tel que $\nu(\{x_0\}) = 0$, on a

$$F_{\mu_n}(x_0) \longrightarrow F_\nu(x_0).$$

Preuve. — Sous cette hypothèse sur x_0 , la fonction F_ν est continue au point x_0 ; étant donné $\varepsilon > 0$, il existe α tel que $0 < \alpha < \varepsilon$ et tel que

$$|F_\nu(y) - F_\nu(x_0)| < \varepsilon$$

dès que $|y - x_0| \leq \alpha$. Pour $n \geq n_0$ convenable, n_0 dépendant de $\alpha > 0$, on aura

$$F_{\mu_n}(x_0) \leq F_\nu(x_0 + \alpha) + \alpha \leq F_\nu(x_0) + \varepsilon + \alpha \leq F_\nu(x_0) + 2\varepsilon$$

et de même

$$F_{\mu_n}(x_0) \geq F_\nu(x_0 - \alpha) - \alpha \geq F_\nu(x_0) - \varepsilon - \alpha \geq F_\nu(x_0) - 2\varepsilon,$$

ce qui prouve l'affirmation.

Théorème. Si ν et les (μ_n) sont des probabilités sur $(\mathbb{R}, \mathcal{B})$, les conditions suivantes sont équivalentes :

1. — la suite (μ_n) converge étroitement vers ν ;
2. — pour toute fonction continue bornée f sur \mathbb{R} , réelle ou complexe,

$$\int_{\mathbb{R}} f d\mu_n \xrightarrow[n]{} \int_{\mathbb{R}} f d\nu ;$$

3. — il y a convergence simple sur \mathbb{R} des transformées de Fourier :

$$\forall t \in \mathbb{R}, \quad \widehat{\mu}_n(t) \xrightarrow[n]{} \widehat{\nu}(t).$$

Esquisse de preuve. — Traitons d'abord **1** \Rightarrow **2** ; supposons que μ_n tende vers ν étroitement ; il existe un ensemble D au plus dénombrable de points y tels que $\nu(\{y\}) > 0$. Alors $\mathbb{R} \setminus D$ est dense dans \mathbb{R} (Cantor). Soit f continue et bornée, disons par 1 pour fixer les idées ; on peut trouver $a < b$ tels que $a, b \notin D$ et que l'intervalle $]a, b[$ soit suffisamment grand pour que

$$F_\nu(b) - F_\nu(a) = \nu(]a, b[) > 1 - \varepsilon.$$

D'après la remarque, pour n assez grand on a $F_{\mu_n}(b) - F_{\mu_n}(a) = \mu_n(]a, b[) > 1 - \varepsilon$. On a donc pour ces valeurs de n

$$\mu_n(\mathbb{R} \setminus]a, b[) < \varepsilon, \quad \nu(\mathbb{R} \setminus]a, b[) < \varepsilon.$$

On a donc aussi pour ces valeurs de n

$$\left| \int_{\mathbb{R}} \mathbf{1}_{\mathbb{R} \setminus]a, b[} f d\mu_n \right| \leq \int_{\mathbb{R}} \mathbf{1}_{\mathbb{R} \setminus]a, b[} |f| d\mu_n \leq \mu_n(\mathbb{R} \setminus]a, b[) < \varepsilon,$$

et de même

$$\left| \int_{\mathbb{R}} \mathbf{1}_{\mathbb{R} \setminus]a, b[} f d\nu \right| \leq \nu(\mathbb{R} \setminus]a, b[) < \varepsilon.$$

La fonction f est uniformément continue sur le compact $[a, b]$, il existe donc $\delta > 0$ tel que $|f(x) - f(y)| < \varepsilon$ dès que $a \leq x, y \leq b$ et $|x - y| \leq \delta$; on peut découper $[a, b]$ en $a = a_0 < a_1 < \dots < a_N = b$ au moyen de points (a_j) qui ne sont pas dans D , et avec un pas de subdivision vérifiant $\max_{0 < j < N} (a_j - a_{j-1}) < \delta$; alors la fonction étagée

$$\varphi = \sum_{j=1}^N f(a_j) \mathbf{1}_{]a_{j-1}, a_j]}$$

est à distance uniforme $\leq \varepsilon$ de $\mathbf{1}_{]a, b[} f$, donc

$$\left| \int_{\mathbb{R}} \mathbf{1}_{]a, b[} f d\mu_n - \int_{\mathbb{R}} \varphi d\mu_n \right| \leq \varepsilon \quad \text{et} \quad \left| \int_{\mathbb{R}} \mathbf{1}_{]a, b[} f d\nu - \int_{\mathbb{R}} \varphi d\nu \right| \leq \varepsilon,$$

alors que

$$\left| \int_{\mathbb{R}} \mathbf{1}_{\mathbb{R} \setminus]a,b]} f \, d\mu_n \right| < \varepsilon, \quad \left| \int_{\mathbb{R}} \mathbf{1}_{\mathbb{R} \setminus]a,b]} f \, d\nu \right| < \varepsilon.$$

on a donc

$$\left| \int_{\mathbb{R}} f \, d\mu_n - \int_{\mathbb{R}} f \, d\nu \right| \leq \left| \int_{\mathbb{R}} \varphi \, d\mu_n - \int_{\mathbb{R}} \varphi \, d\nu \right| + 4\varepsilon.$$

Par ailleurs

$$\int_{\mathbb{R}} \varphi \, d\mu_n = \sum_{j=1}^N f(a_j) \mu_n(]a_{j-1}, a_j]) = \sum_{j=1}^N f(a_j) (F_{\mu_n}(a_j) - F_{\mu_n}(a_{j-1}))$$

converge d'après la remarque vers

$$\sum_{j=1}^N f(a_j) (F_{\nu}(a_j) - F_{\nu}(a_{j-1})) = \int_{\mathbb{R}} \varphi \, d\nu.$$

On en déduit que **1** \Rightarrow **2**.

Comme $x \rightarrow e^{-itx}$ est continue bornée sur \mathbb{R} , on déduit de **2** la convergence simple des transformées de Fourier. Pour terminer avec **3** \Rightarrow **1**, on utilise des bosses de classe C^2 , comme on a fait pour la preuve du TLC.