

Rappels sur les intégrales multiples

L'outil principal pour calculer des intégrales en plusieurs variables est le théorème de Fubini-Tonelli.

Théorème 1. [Fubini-Tonelli, cas $n=2$] Soit $f: \mathbb{R}^2 \rightarrow \mathbb{R}$ une fonction positive, alors

$$\int_{\mathbb{R}^2} f(x, y) dx dy = \int_{\mathbb{R}} \left(\int_{\mathbb{R}} f(x, y) dx \right) dy = \int_{\mathbb{R}} \left(\int_{\mathbb{R}} f(x, y) dy \right) dx.$$

Où les trois termes sont ou bien fini et égaux ou bien simultanément $+\infty$. Si f est de signe quelconque mais intégrable au sens que $\int_{\mathbb{R}^2} |f(x, y)| dx dy < +\infty$ alors l'égalité des trois intégrales reste vraie.

Exemple 2. $f(x, y) = x e^{-xy} \mathbb{I}_{x \geq 0} \mathbb{I}_{1 < y < 2}$. D'un part

$$\begin{aligned} \int_{\mathbb{R}^2} f(x, y) dx dy &= \int_{\mathbb{R}} \left(\int_{\mathbb{R}} x e^{-xy} \mathbb{I}_{x \geq 0} dx \right) \mathbb{I}_{1 < y < 2} dy \\ &= \int_{\mathbb{R}} \left(\int_{\mathbb{R}} y^2 x e^{-xy} \mathbb{I}_{x \geq 0} dx \right) \frac{\mathbb{I}_{1 < y < 2}}{y^2} dy \\ &= \int_{\mathbb{R}} \left(\int_{\mathbb{R}} x e^{-x} \mathbb{I}_{x \geq 0} dx \right) \frac{\mathbb{I}_{1 < y < 2}}{y^2} dy \\ &= \int_1^2 \frac{dy}{y^2} = \frac{1}{2}. \end{aligned}$$

D'autre part

$$\begin{aligned} \int_{\mathbb{R}^2} f(x, y) dx dy &= \int_0^{+\infty} x \left(\int_1^2 e^{-xy} dy \right) dx \\ &= \int_0^{+\infty} (e^{-x} - e^{-2x}) dx = \frac{1}{2}. \end{aligned}$$

Exemple 3. Voyons un contre-exemple à l'utilisation de Fubini dans un cas où l'intégrale double n'est pas défini. Soit

$$f(x, y) = \frac{x^2 - y^2}{(x^2 + y^2)^2}$$

alors $I = \int_0^1 \int_0^1 f(x, y) dx dy$ n'est pas bien défini car

$$\begin{aligned} \int_0^1 \int_0^1 |f(x, y)| dx dy &= \int_0^1 \left(\int_0^y \frac{y^2 - x^2}{(x^2 + y^2)^2} dx \right) dy + \int_0^1 \left(\int_0^x \frac{x^2 - y^2}{(x^2 + y^2)^2} dy \right) dx \\ &= \int_0^1 \left(\frac{1}{y} - \frac{1}{1 + y^2} \right) dy = +\infty \end{aligned}$$

Or, les intégrales

$$I_1 = \int_0^1 \left(\int_0^1 \frac{x^2 - y^2}{(x^2 + y^2)^2} dx \right) dy, \quad I_2 = \int_0^1 \left(\int_0^1 \frac{x^2 - y^2}{(x^2 + y^2)^2} dy \right) dx$$

sont bien défini et il satisfont $I_1 = -I_2$. En effet:

$$\int_0^1 \frac{x^2 - y^2}{(x^2 + y^2)^2} dy = \int_0^1 \frac{1}{(x^2 + y^2)} dy - 2 \int_0^1 \frac{y^2}{(x^2 + y^2)^2} dy = \frac{1}{1 + x^2}$$

et alors

$$I_2 = \int_0^1 \frac{1}{1 + x^2} dx = [\arctan(x)]_0^1 = \frac{\pi}{4} = -I_1$$

ce qui est in contradiction avec une application naïve de Fubini (car dans ce cas $I_1 = I_2 = I = 0$).

Théorème 4. (CHANGEMENT DES VARIABLES) Soit $h: \mathbb{R}^n \rightarrow \mathbb{R}^n$. On note $h_i(x)$ ses composantes dans la base canonique: $h(x) = (h_1(x), \dots, h_n(x))$ et Jh son Jacobien:

$$Jh(x) = \det \left(\frac{\partial h_i(x)}{\partial x_j} \right)_{i,j=1,\dots,n}.$$

Supposons que

- i. les dérivées partielles de $h_i(x)$ sont continues sur \mathbb{R}^n pour $i = 1, \dots, n$.
- ii. h est une bijection.
- iii. $Jh(x) \neq 0$ pour tout $x \in \mathbb{R}^n$.

Alors pour toute fonction $f: \mathbb{R}^n \rightarrow \mathbb{R}$ et tout ensemble Borelien $K \subseteq \mathbb{R}^n$ tels que $\int_K |f(x)| dx < \infty$

$$\int_K f(x) dx = \int_{h^{-1}(K)} f(h(y)) |Jh(y)| dy.$$

Remarque 5. Par le Théorème de la fonction inverse, sous le condition du Théorème 4 la fonction inverse $g(y) = h^{-1}(y)$ existe partout dans \mathbb{R}^n et

$$Jg(y) = \frac{1}{Jh(g(y))}.$$

On voit donc que h vérifie les conditions i,ii et iii du Theoreme 4 si et seulement si g aussi vérifie ces conditions.

Vecteurs aléatoires

Soit $(\Omega, \mathcal{A}, \mathbb{P})$ un espace probabilisé. Un vecteur aléatoire X de dimension n (ou dans \mathbb{R}^n) est une application $X: \Omega \rightarrow \mathbb{R}^n$ telle que tout les ensembles de la forme $\{X \in B\} = \{\omega \in \Omega: X(\omega) \in B\}$ pour B Borélien de \mathbb{R}^n appartiennent à la tribu \mathcal{A} . En particulier on peut calculer la probabilité $\mathbb{P}(X \in B)$ de l'événement $\{X \in B\}$ (car $\mathbb{P}(A)$ est définie seulement pour $A \in \mathcal{A}$). La loi de X est la l'application $\mu_X: \mathcal{B}(\mathbb{R}^n) \rightarrow [0, 1]$ qui à tout B Borélien de \mathbb{R}^n associe $\mathbb{P}(X \in B)$. On appelle fonction de répartition de X la fonction $F_X: \mathbb{R}^n \rightarrow [0, 1]$ définie par

$$F_X(x_1, \dots, x_n) = \mathbb{P}(X_1 \leq x_1, \dots, X_n \leq x_n)$$

où $(X_i)_{i=1,\dots,n}$ sont les composantes de $X(\omega) = (X_1(\omega), \dots, X_n(\omega))$ (donc des v.a. réelles). La fonction de répartition caractérise la loi de X , i.e. n'importe quel événement $\{X \in B\}$ peut être calculé à l'aide de F_X .

Exemple 6. Soit $n = 2$ et $B =]x_1, y_1] \times]x_2, y_2]$ alors il est facile de vérifier que

$$\mathbb{P}(X \in B) = \mathbb{P}(X_1 \in]x_1, y_1], Y \in]x_2, y_2]) = F_X(y_1, y_2) - F_X(y_1, x_2) - F_X(x_1, y_2) + F_X(x_1, x_2)$$

en utilisant les propriétés élémentaires des probabilités (en particulier $\mathbb{P}(A \cup B) = \mathbb{P}(A) + \mathbb{P}(B) - \mathbb{P}(A \cap B)$):

$$\begin{aligned} \mathbb{P}(X \in B) &= \mathbb{P}(x_1 < X_1 \leq y_1, x_2 < X_2 \leq y_2) \\ &= \mathbb{P}(X_1 \leq y_1, x_2 \leq X_2 \leq y_2) - \mathbb{P}(X_1 \leq x_1, x_2 < X_2 \leq y_2) \\ &= \mathbb{P}(X_1 \leq y_1, X_2 \leq y_2) - (X_1 \leq y_1, X_2 \leq x_2) \\ &\quad - (\mathbb{P}(X_1 \leq x_1, X_2 \leq y_2) - \mathbb{P}(X_1 \leq x_1, X_2 \leq x_2)) \\ &= F_X(y_1, y_2) - F_X(y_1, x_2) - F_X(x_1, y_2) + F_X(x_1, x_2). \end{aligned}$$

Définition 7. Le vecteur X à valeurs dans \mathbb{R}^n est discret si il peut prendre que une quantité d au plus dénombrable des valeurs distinct. Autrement dit si il existent des ensembles au plus dénombrables $\mathcal{X}_1, \dots, \mathcal{X}_n$ tels que $\mathbb{P}(X_1 \in \mathcal{X}_1, \dots, X_n \in \mathcal{X}_n) = 1$. Dans ce cas on appelle la quantité

$$p_X(x) = p_{(X_1, \dots, X_n)}(x_1, \dots, x_n) = \mathbb{P}(X_1 = x_1, \dots, X_n = x_n) \quad x_1 \in \mathcal{X}_1, \dots, x_n \in \mathcal{X}_n$$

la densité discrete de X .

La densité discrete d'un vecteur X satisfait

- a) $p_X(x) \geq 0$;
- b) $\sum_{x_1 \in \mathcal{X}_1} \sum_{x_2 \in \mathcal{X}_2} \dots \sum_{x_n \in \mathcal{X}_n} p_X(x_1, \dots, x_n) = 1$.

Définition 8. On dit que X est un vecteur continu ou que il admet une densité (continue) $f_X: \mathbb{R}^n \rightarrow \mathbb{R}_+$ ssi pour tout Borélien $B \in \mathcal{B}(\mathbb{R}^n)$ (la tribu Borélienne de \mathbb{R}^n) on peut exprimer la probabilité de l'événement $\{X \in B\}$ par une intégrale sur B de f_X :

$$\mathbb{P}(X \in B) = \int_B f_X(x_1, \dots, x_n) dx_1 \dots dx_n.$$

La densité (continue ou discrete), si elle existe, est unique et caractérise la loi de X . On a que

$$\int_{\mathbb{R}^n} f_X(x_1, \dots, x_n) dx_1 \dots dx_n = \mathbb{P}(X \in \mathbb{R}^n) = 1$$

en particulier f_X est intégrable. La fonction de répartition $F_X: \mathbb{R}^n \rightarrow [0, 1]$ de X est donné par

$$F_X(t_1, \dots, t_n) \stackrel{\text{def}}{=} \mathbb{P}(X_1 \leq t_1, \dots, X_n \leq t_n) = \int_{-\infty}^{t_1} \dots \int_{-\infty}^{t_n} f_X(x_1, \dots, x_n) dx_1 \dots dx_n$$

c'est la probabilité de l'événement $\{X \in B\}$ pour $B =]-\infty, t_1] \times \dots \times]-\infty, t_n] \subseteq \mathbb{R}^n$. On peut déterminer la densité en dérivant la fonction de répartition:

$$f_X(t_1, \dots, t_n) = \frac{\partial^n}{\partial t_1 \dots \partial t_n} F_X(t_1, \dots, t_n)$$

formule valable en tout point de continuité de $\partial^n F_X(t_1, \dots, t_n) / \partial t_1 \dots \partial t_n$.

L'interprétation intuitive de la densité f_X est la suivante: si $\Delta x_i \ll 1$ alors la probabilité de l'événement $\{X_i \in [x_i, x_i + \Delta x_i]\}$ pour $i = 1, \dots, n$ est approchable par

$$\begin{aligned} \mathbb{P}(X_i \in [x_i, x_i + \Delta x_i] \text{ pour } i = 1, \dots, n) &= \int_{x_1}^{x_1 + \Delta x_1} \dots \int_{x_n}^{x_n + \Delta x_n} f_X(t_1, \dots, t_n) dt_1 \dots dt_n \\ &\simeq f_X(x_1, \dots, x_n) \Delta x_1 \dots \Delta x_n. \end{aligned}$$

La densité est donc proportionnelle à la mesure de probabilité d'un petit voisinage du point (x_1, \dots, x_n) . Autrement dit, si $B_n(x, \delta) = \{y \in \mathbb{R}^n : |x - y| \leq \delta\} \subseteq \mathbb{R}^n$ est la boule n -dimensionnelle de rayon δ centrée en $x \in \mathbb{R}^n$ et $V_n(\delta) = |B_n(x, \delta)|$ le volume de $B(x, \delta)$, i.e. $V_n(\delta) = \int_{B_n(x, \delta)} d t_1 \dots dt_n$ alors si $\delta \ll 1$ on a l'approximation $\mathbb{P}(X \in B(x, \delta)) \simeq f_X(x) V_n(\delta)$.

Exemple 9. Soit $Z = (X, Y): \Omega \rightarrow \mathbb{R}^2$ un couple aléatoire dont la fonction de répartition est donnée par

$$F_Z(x, y) = q(x) q(y)$$

où $q(s) = \max(0, \min(s, 1))$. Alors

$$\frac{\partial^2}{\partial x \partial y} F_Z(x, y) = \begin{cases} \text{non définie} & \text{si } x = 0, 1 \text{ ou } y = 0, 1 \\ 1 & \text{si } (x, y) \in]0, 1[^2 \\ 0 & \text{autrement} \end{cases}$$

et on peut vérifier que

$$F_Z(x, y) = \int_{-\infty}^x \int_{-\infty}^y \mathbb{I}_{]0, 1[}(z_1) \mathbb{I}_{]0, 1[}(z_2) dz_1 dz_2.$$

Donc $f_Z(z_1, z_2) = \mathbb{I}_{]0, 1[}(z_1) \mathbb{I}_{]0, 1[}(z_2)$ est la densité de Z .

Définition 10. Soit $D \subseteq \mathbb{R}^n$ un ensemble mesurable et tel que $\text{Vol}(D) = \int_D dx > 0$ (son volume est positif). On dit que $X: \Omega \rightarrow \mathbb{R}^n$ a une loi uniforme sur D si X admet densité

$$f_X(x) = \frac{\mathbb{I}_D(x)}{\text{Vol}(D)}.$$

Théorème 11. Soit X un vecteur aléatoire continu à valeurs dans \mathbb{R}^n de densité f_X et $h: \mathbb{R}^n \rightarrow \mathbb{R}^n$ une transformation vérifiant les hypothèses du Theoreme 4, alors la v.a. $Y = h(X)$ admet la densité f_Y donnée par

$$f_Y(y) = f_X(h^{-1}(y)) \frac{1}{|Jh(h^{-1}(y))|}$$

pour tout $y \in \mathbb{R}^n$.

Démonstration. Considérons la fonction de repartition de Y :

$$F_Y(t_1, \dots, t_n) = \mathbb{P}(Y_1 \leq t_1, \dots, Y_n \leq t_n) = \int_{A(t)} f_X(x) dx$$

où $A(t) = \{x \in \mathbb{R}^n : h_1(x) \leq t_1, \dots, h_n(x) \leq t_n\}$. Par le Théorème 4 on a que ($y = h(x)$)

$$\int_{A(t)} f_X(x) dx = \int_{h(A(t))} f_X(h^{-1}(y)) \frac{dy}{|Jh(h^{-1}(y))|}$$

or $h(A(t)) = \{y = h(x) : x \in A(t)\} = \{y = h(x) : h_1(x) \leq t_1, \dots, h_n(x) \leq t_n\} = \{y_1 \leq t_1, \dots, y_n \leq t_n\}$.
Donc

$$F_Y(t_1, \dots, t_n) = \int_{-\infty}^{t_1} \dots \int_{-\infty}^{t_n} f_X(h^{-1}(y)) \frac{dy}{|Jh(h^{-1}(y))|}$$

Exercice 1. Montrer que si X est un vecteur aléatoire à valeurs dans \mathbb{R}^n de densité f_X et si A est une matrice $n \times n$ inversible et $b \in \mathbb{R}^n$ alors la v.a. $Y = AX + b$ a densité f_Y donnée par

$$f_Y(y) = f_X(A^{-1}(y - b)) \frac{1}{|\text{Det}(A)|}$$

□

Densités marginales

Définition 12. Si Z est un vecteur aléatoire dans \mathbb{R}^n admettant une densité f_Z alors tout sous-vecteurs Y de Z de dimension $k \leq n$ admettent une densité qu'on obtient en intégrant f_Z par rapport aux composantes qui ne figurent pas dans Y . On appelle cette densité la densité marginale de Y . Explicitement si $Y = (Z_1, \dots, Z_k)$ alors

$$\begin{aligned} \mathbb{P}(Y \in B) &= \mathbb{P}((Z_1, \dots, Z_k) \in B) = \mathbb{P}(Z \in B \times \mathbb{R}^{n-k}) = \int_{(z_1, \dots, z_k) \in B} f_Z(z_1, \dots, z_n) dz_1 \dots dz_n \\ &= \int_B \left(\int_{\mathbb{R}^{n-k}} f_Z(z_1, \dots, z_k, z_{k+1}, \dots, z_n) dz_{k+1} \dots dz_n \right) dz_1 \dots dz_k \end{aligned}$$

donc $f_Y(y_1, \dots, y_k) = \int_{\mathbb{R}^{n-k}} f_Z(y_1, \dots, y_k, z_{k+1}, \dots, z_n) dz_{k+1} \dots dz_n$.

Cas particulier ($n = 2$). Soit $Z = (X, Y)$ un vecteur aléatoire bidimensionnel de densité f_Z . La densité marginale de X est $f_X(x) = \int_{\mathbb{R}} f_Z(x, y) dy$ et la densité marginale de Y est $f_Y(y) = \int_{\mathbb{R}} f_Z(x, y) dx$.

Exemple 13. Considérons le couple (X, Y) de densité

$$f_{(X,Y)}(x, y) = \alpha \frac{e^{-y}}{2\sqrt{x}} \mathbb{I}_{0 < x < y^2} \mathbb{I}_{y > 0}$$

- Déterminer $\alpha > 0$ t.q. $f_{(X,Y)}$ soit correctement normalisée.
- Déterminer les densités marginales f_X et f_Y .
- Calculer $\mathbb{P}(X > 1)$.

Calculons

$$\begin{aligned} I &= \int_{\mathbb{R}^2} f_{(X,Y)}(x,y) dx dy = \alpha \int_0^\infty \left(\int_0^{y^2} \frac{dx}{2\sqrt{x}} \right) e^{-y} dy \\ &= \alpha \int_0^\infty y e^{-y} dy = \alpha \end{aligned}$$

donc $\alpha = 1$.

$$f_X(x) = \int_{\mathbb{R}} f_{(X,Y)}(x,y) dy = \frac{\mathbb{I}_{x>0}}{2\sqrt{x}} \int_{\sqrt{x}}^\infty e^{-y} dy = \frac{e^{-\sqrt{x}}}{2\sqrt{x}} \mathbb{I}_{x>0}$$

$$f_Y(y) = \int_{\mathbb{R}} f_{(X,Y)}(x,y) dx = \mathbb{I}_{y>0} e^{-y} \int_0^{y^2} \frac{dx}{2\sqrt{x}} = y e^{-y} \mathbb{I}_{y>0}$$

$$\mathbb{P}(X > 1) = \int_1^\infty f_X(x) dx = \int_1^\infty \frac{e^{-\sqrt{x}}}{2\sqrt{x}} dx = \frac{1}{e}$$

Exemple 14. Deux densités $f_{X,Y}(x,y)$ et $g_{X,Y}(x,y)$ peuvent avoir les mêmes marginales. Par exemple il est facile de montrer que les densités

$$f_{X,Y}(x,y) = \frac{1}{2\pi} e^{-(x^2+y^2)/2}, \quad g_{X,Y}(x,y) = \frac{1}{2\pi} e^{-(x^2+y^2)/2} [1 + xy \mathbb{I}_{[-1,1]}(x) \mathbb{I}_{[-1,1]}(y)]$$

ont les mêmes marginales ($f_X = g_X$ et $f_Y = g_Y$). En effet en utilisant l'intégrale remarquable

$$\int_{\mathbb{R}} \frac{1}{\sqrt{2\pi}} e^{-x^2/2} dx = 1$$

on obtient que

$$f_X(x) = \int_{\mathbb{R}} f_{X,Y}(x,y) dy = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$$

et

$$\begin{aligned} g_X(x) &= \int_{\mathbb{R}} g_{X,Y}(x,y) dy = \int_{\mathbb{R}} \frac{1}{2\pi} e^{-(x^2+y^2)/2} [1 + xy \mathbb{I}_{[-1,1]}(x) \mathbb{I}_{[-1,1]}(y)] dy \\ &= \frac{1}{\sqrt{2\pi}} e^{-x^2/2} \int_{\mathbb{R}} \frac{1}{\sqrt{2\pi}} e^{-y^2/2} [1 + xy \mathbb{I}_{[-1,1]}(x) \mathbb{I}_{[-1,1]}(y)] dy = \frac{1}{\sqrt{2\pi}} e^{-x^2/2} \end{aligned}$$

car

$$\int_{\mathbb{R}} \frac{1}{\sqrt{2\pi}} e^{-y^2/2} y \mathbb{I}_{[-1,1]}(y) dy = 0$$

par symétrie.

Densité et espérance conditionnelle

Définition 15. Soit $Z = (X, Y)$ un vecteur aléatoire dans $\mathbb{R}^m \times \mathbb{R}^n$ admettant une densité f_Z . Soient f_X et f_Y les densités marginales des vecteurs X et Y . On appelle densité conditionnelle de X sachant $Y = y$ la densité donnée par

$$f_{X|Y=y}(x) = \frac{f_{(X,Y)}(x,y)}{f_Y(y)} \quad \text{pour tout } y \in \mathbb{R}^n \text{ t.q. } f_Y(y) > 0.$$

Cette définition est motivée par le fait que, si $\delta \ll 1$:

$$\begin{aligned}\mathbb{P}(X \in B_m(x, \delta) | Y \in B_n(y, \delta)) &= \frac{\mathbb{P}(X \in B_m(x, \delta), Y \in B_n(y, \delta))}{\mathbb{P}(Y \in B_n(y, \delta))} \simeq \frac{f_{(X,Y)}(x, y) V_m(\delta) V_n(\delta)}{f_Y(y) V_n(\delta)} \\ &\simeq \frac{f_{(X,Y)}(x, y)}{f_Y(y)} V_m(\delta) = f_{X|Y=y}(x) V_m(\delta)\end{aligned}$$

donc la densité conditionnelle est proportionnelle à la probabilité conditionnelle de trouver X dans une petite boule centrée en x sachant que Y est dans une petite boule centrée en y .

Exemple 16. Considérons $Z = (X, Y)$ de densité $f_Z(x, y) = 2\lambda^2 e^{-\lambda(x+y)} \mathbb{I}_{0 < x < y}$. Quelle est la densité conditionnelle de X sachant $Y = y$?

Calculons d'abord $f_Y(y)$:

$$f_Y(y) = \int_{\mathbb{R}} 2\lambda^2 e^{-\lambda(x+y)} \mathbb{I}_{0 < x < y} dx = 2\lambda e^{-\lambda y} \mathbb{I}_{y > 0} \int_0^y \lambda e^{-\lambda x} dx = 2\lambda e^{-\lambda y} (1 - e^{-\lambda y}) \mathbb{I}_{y > 0}$$

Il vient que

$$f_{X|Y=y}(x) = \frac{2\lambda^2 e^{-\lambda(x+y)} \mathbb{I}_{0 < x < y}}{2\lambda e^{-\lambda y} (1 - e^{-\lambda y}) \mathbb{I}_{y > 0}} = \frac{\lambda e^{-\lambda x} \mathbb{I}_{0 < x < y}}{1 - e^{-\lambda y}} \quad \text{pour tout } y > 0.$$

Définition 17. Une famille $(X_i)_{i=1, \dots, n}$ de v.a. est indépendante ssi pour tout B_i , $i = 1, \dots, n$, on a que les événements $\{X_i \in B_i\}_{i=1, \dots, n}$ sont indépendants, i.e.:

$$\mathbb{P}(X_1 \in B_1, \dots, X_n \in B_n) = \mathbb{P}(X_1 \in B_1) \cdots \mathbb{P}(X_n \in B_n).$$

Dans cette définition les v.a.s X_i peuvent être réelles ou bien des vecteurs aléatoires elles mêmes. Les v.a. X, Y sont indépendantes ssi $F_{(X,Y)}(x, y) = F_X(x) F_Y(y)$. Pour les v.a. avec densité on a la proposition suivante.

Proposition 18. Soient X et Y deux v.a. admettant respectivement les densités f_X et f_Y . Alors X et Y sont indépendantes ssi $f_{X|Y=y}$ ne dépend de y . Dans ce cas là $f_{X|Y=y}(x) = f_X(x)$.

Démonstration. Si X, Y sont indépendantes alors $F_{(X,Y)}(x, y) = F_X(x) F_Y(y)$ et donc on a que le couple admet la densité jointe $f_{(X,Y)}(x, y) = f_X(x) f_Y(y)$ car

$$\frac{\partial^2}{\partial x \partial y} F_{(X,Y)}(x, y) = \frac{\partial^2}{\partial x \partial y} F_X(x) F_Y(y) = f_X(x) f_Y(y)$$

et donc $f_{X|Y=y}(x) = f_{(X,Y)}(x, y) / f_Y(y) = f_X(x)$ qui ne dépend pas de y . Réciproquement on a $f_{(X,Y)}(x, y) = f_{X|Y=y}(x) f_Y(y)$ et si la densité conditionnelle ne dépend pas de y

$$f_X(x) = \int_{\mathbb{R}} f_{(X,Y)}(x, y) dy = f_{X|Y=y}(x) \int_{\mathbb{R}} f_Y(y) dy = f_{X|Y=y}(x)$$

et donc $f_{(X,Y)}(x, y) = f_X(x) f_Y(y)$ qui implique l'indépendance de X et Y . \square

Proposition 19. Soient X et Y deux v.a. avec densité jointe $f_{(X,Y)}(x, y)$. Alors X et Y sont indépendantes ssi il existe deux applications g, h telles que $f_{(X,Y)}(x, y) = g(x)h(y)$.

Démonstration. Si X et Y sont indépendantes alors on peut prendre $g = f_X$ et $h = f_Y$. Réciproquement: supposons que $f_{(X,Y)}(x, y) = g(x)h(y)$:

$$f_X(x) = \int_{\mathbb{R}} f_{(X,Y)}(x, y)dy = g(x) \int_{\mathbb{R}} h(y)dy, \quad f_Y(y) = h(y) \int_{\mathbb{R}} g(x)dx$$

$$1 = \int_{\mathbb{R}} f_X(x)dx = \int_{\mathbb{R}} g(x)dx \int_{\mathbb{R}} h(y)dy$$

et donc $f_{(X,Y)}(x, y) = f_X(x) f_Y(y)$. □

Exemple 20. Soit (X, Y) un couple de v.a. dans \mathbb{R}^2 admettant pour densité $f_{(X,Y)}(x, y) = 8xy \mathbb{1}_{0 < x < y < 1}$. X et Y ne sont pas indépendantes car la fonction $\mathbb{1}_{0 < x < y < 1}$ ne peut pas s'écrire sous la forme d'un produit. En effet $f_{(X,Y)}(1/2, 2/3) > 0$ et $f_{(X,Y)}(1/4, 1/3) > 0$. Si $f_{(X,Y)}(x, y) = g(x)h(y)$ alors on doit avoir que $g(1/2) > 0$ et $h(1/3) > 0$ mais alors $f_{(X,Y)}(1/2, 1/3) > 0$ ce qu'est en contradiction avec la définition de $f_{(X,Y)}$ car $f_{(X,Y)}(1/2, 1/3) = 0$.

Espérance et espérance conditionnelle

Si X est un vecteur aléatoire dans \mathbb{R}^n admettant f_X comme densité et $g: \mathbb{R}^n \rightarrow \mathbb{R}$ est une fonction positive alors on définit l'espérance $\mathbb{E}[g(X)]$ de la v.a. $g(X)$ par la formule

$$\mathbb{E}[g(X)] = \int_{\mathbb{R}^n} g(x) f_X(x) dx \tag{1}$$

qui est toujours une quantité positive bien définie même si elle peut prendre la valeur $+\infty$. Si g est de signe quelconque et $\mathbb{E}[|g(X)|] < \infty$ alors on dit que $g(X)$ est intégrable et on peut définir l'espérance de $g(X)$ par la même formule (1). Si $g(X)$ n'est pas intégrable l'intégrale dans la formule (1) n'est pas bien définie.

Théorème 21. Soit X un vecteur aléatoire à valeurs dans \mathbb{R}^n et supposons que pour tout fonction mesurable bornée $g: \mathbb{R}^n \rightarrow \mathbb{R}$

$$\mathbb{E}[g(X)] = \int_{\mathbb{R}^n} g(x) q(x) dx$$

pour une certaine fonction $q: \mathbb{R}^n \rightarrow \mathbb{R}_+$. Alors X admet densité $f_X = q$.

Remarque 22. Ce résultat est assez pratique pour déterminer la densité par changement des variables.

Définition 23. Soit $Z = (X, Y)$ un vecteur aléatoire de $\mathbb{R}^n \times \mathbb{R}^m$. Soit $g: \mathbb{R}^n \times \mathbb{R}^m \rightarrow \mathbb{R}$ une fonction telle que $g(X, Y)$ est intégrable, c-à-d $\mathbb{E}[|g(X, Y)|] < +\infty$. On appellera espérance conditionnelle de $g(X, Y)$ sachant Y et on notera $\mathbb{E}[g(X, Y)|Y]$ la v.a. $\Psi(Y)$ où

$$\Psi(y) = \int_{\mathbb{R}^n} g(x, y) f_{X|Y=y}(x) dx, \quad \forall y \in \mathbb{R}^m : f_Y(y) > 0.$$

Il est importante de remarquer que l'espérance conditionnelle $\mathbb{E}[g(X, Y)|Y]$ est une variable aléatoire.

Remarque 24. Par convenance on note $\mathbb{E}[g(X)|Y=y] = \int_{\mathbb{R}^n} g(x, y) f_{X|Y=y}(x) dx$ l'espérance par rapport à la loi conditionnelle de X sachant $Y = y$. Cette espérance est une fonction réelle de y .

Exemple 25. Revenons à l'exemple 16 et calculons $\mathbb{E}[XY|Y]$ (il faut donc prendre $g(x, y) = xy$). Vérifions d'abord la condition d'intégrabilité (qui donne sens au calcul de l'espérance conditionnelle):

$$\begin{aligned} \mathbb{E}[|XY|] &= \int_{\mathbb{R}^2} |xy| f_{(X,Y)}(x, y) dx dy = 2\lambda^2 \int \int xy e^{-\lambda(x+y)} \mathbb{I}_{0 < x < y} dx dy \\ &\leq 2\lambda^2 \int_0^\infty \int_0^\infty xy e^{-\lambda(x+y)} dx dy = 2\lambda^2 \left(\int_0^\infty x e^{-\lambda x} dx \right)^2 < \infty \end{aligned}$$

donc XY est bien intégrable.

$$\begin{aligned} \Psi(y) &= \int_{\mathbb{R}} xy f_{X|Y=y}(x) dx = y \mathbb{I}_{y>0} \int_{\mathbb{R}} x \frac{\lambda e^{-\lambda x} \mathbb{I}_{0 < x < y}}{1 - e^{-\lambda y}} dx = \frac{\lambda y}{1 - e^{-\lambda y}} \mathbb{I}_{y>0} \int_0^y x e^{-\lambda x} dx \\ \Psi(y) &= \frac{y}{1 - e^{-\lambda y}} \mathbb{I}_{y>0} \frac{1 - e^{-\lambda y} - \lambda y e^{-\lambda y}}{\lambda} \end{aligned}$$

et donc

$$\mathbb{E}[XY|Y] = \frac{Y}{1 - e^{-\lambda Y}} \frac{1 - e^{-\lambda Y} - \lambda Y e^{-\lambda Y}}{\lambda}$$

Proposition 26. Soit h une application de $\mathbb{R}^n \times \mathbb{R}^m \rightarrow \mathbb{R}$ telle que $g(X, Y)h(Y)$ est intégrable. Alors

1. $\mathbb{E}[g(X, Y)|Y]h(Y) = \mathbb{E}[g(X, Y)h(Y)|Y]$
2. $\mathbb{E}[\mathbb{E}[g(X, Y)|Y]h(Y)] = \mathbb{E}[g(X, Y)h(Y)]$

Démonstration. Soit $\Phi(Y) = \mathbb{E}[g(X, Y)|Y]$ et $\Psi(Y) = \mathbb{E}[g(X, Y)h(Y)|Y]$ où

$$\Phi(y) = \int_{\mathbb{R}^n} g(x, y) f_{X|Y=y}(x) dx, \quad \Psi(y) = \int_{\mathbb{R}^n} g(x, y) h(y) f_{X|Y=y}(x) dx$$

alors $\Psi(y) = h(y)\Phi(y)$ qui donne la première égalité. Pour la deuxième on remarque que

$$\begin{aligned} \mathbb{E}[\mathbb{E}[g(X, Y)|Y]h(Y)] &= \mathbb{E}[\Phi(Y)h(Y)] = \mathbb{E}[\Psi(Y)] = \int_{\mathbb{R}^m} \Psi(y) f_Y(y) dy \\ &= \int_{\mathbb{R}^n \times \mathbb{R}^m} g(x, y) h(y) f_{X|Y=y}(x) f_Y(y) dx dy = \int_{\mathbb{R}^n \times \mathbb{R}^m} g(x, y) h(y) f_{(X,Y)}(x, y) dx dy \\ &= \mathbb{E}[g(X, Y)h(Y)] \end{aligned}$$

par la définition de la densité conditionnelle et d'espérance. □

Cas particuliers:

- $g(x, y) = x$ et $h(y) = 1$: $\mathbb{E}[\mathbb{E}[X|Y]] = \mathbb{E}[X]$
- $g(x, y) = 1$, $h(Y)$ intégrable: $\mathbb{E}[h(Y)|Y] = h(Y)$.

Exemple 27. Soient X et Y deux v.a. indépendantes de loi exponentielle de densité $f(x) = \lambda e^{-\lambda x} \mathbb{1}_{x>0}$ avec $\lambda > 0$. Calculons la densité conditionnelle $f_{X|X+Y}$ et l'espérance conditionnelle $\mathbb{E}[X|X+Y]$. Si $z < x$

$$\mathbb{P}(X+Y < z, X < x) = \mathbb{P}(X+Y < z, X < z) = \int_0^z \int_0^{z-u} f(u)f(v)du dv$$

et si $z \geq x$

$$\mathbb{P}(X+Y < z, X < x) = \int_0^x \int_0^{z-u} f(u)f(v)du dv.$$

Par conséquent, pour $z \geq x$ la densité jointe du couple $(X+Y, X)$ est

$$f_{(X+Y, X)}(z, x) = \frac{\partial^2}{\partial u \partial v} \mathbb{P}(X+Y < z, X < x) = f(z-x)f(x) = \lambda^2 e^{-\lambda z}$$

et $f_{(X+Y, X)}(z, x) = 0$ si $z < x$. Par ailleurs, la densité de $X+Y$ est la convolution de deux densités exponentielles, i.e. $f_{X+Y}(z) = \lambda^2 z e^{-\lambda z} \mathbb{1}_{z>0}$. Donc la densité conditionnelle de X sachant $X+Y$ est

$$f_{X|X+Y}(x|z) = \frac{f_{(X+Y, X)}(z, x)}{f_{X+Y}(z)} = \frac{1}{z} \mathbb{1}_{0 \leq x \leq z}$$

qui est la densité uniforme sur l'intervalle $[0, z]$. Donc on calcule facilement que $\mathbb{E}[X|X+Y = z] = \frac{z}{2}$ et finalement que

$$\mathbb{E}[X|X+Y] = \frac{X+Y}{2}.$$

Une application de cet exemple est la suivante. Soit X l'instant où la première demande arrive à un système de service et Y l'intervalle de temps entre l'arrivée de la première et la deuxième demandes. Si on sait que la deuxième arrive au temps z (donc $X+Y = z$) alors on vient de déterminer que la loi du temps d'arrivée de la première est donnée par la densité $1/z$ sur l'intervalle $[0, z]$. En particulier, la moyenne du temps d'arrivée de la première est $z/2$.

Variance, covariance et corrélation

Définition 28. La covariance $\text{Cov}(X, Y)$ du couple (X, Y) de v.a. réelles est donnée par $\text{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])]$. La variance de X est $\text{Var}(X) = \text{Cov}(X, X) = \mathbb{E}[(X - \mathbb{E}[X])^2] \geq 0$.

Si $\text{Var}(X) = 0$ alors $X = \mathbb{E}[X]$ est une constante. La covariance est une fonction symétrique ($\text{Cov}(X, Y) = \text{Cov}(Y, X)$) et linéaire par rapport à chacun de ses arguments ($\text{Cov}(\alpha X + \beta Y, Z) = \alpha \text{Cov}(X, Z) + \beta \text{Cov}(Y, Z)$). $\text{Var}(\alpha X + c) = \alpha^2 \text{Var}(X)$. On a que

$$\begin{aligned} \text{Var}(X+Y) &= \text{Cov}(X+Y, X+Y) = \text{Cov}(X, X) + 2\text{Cov}(X, Y) + \text{Cov}(Y, Y) \\ &= \text{Var}(X) + 2\text{Cov}(X, Y) + \text{Var}(Y). \end{aligned}$$

Si X, Y sont indépendantes $\text{Cov}(X, Y) = 0$, le réciproque n'est pas vrai en général.

Exemple 29. Soit $X \sim \mathcal{N}(0, 1)$ et $Y = X^2$. Alors $\text{Cov}(X, Y) = \mathbb{E}[XY] = \mathbb{E}[X^3] = 0$ mais évidemment X, Y ne sont pas indépendantes: par exemple $0 = \mathbb{P}(X > 1, Y < 1) \neq \mathbb{P}(X > 1)\mathbb{P}(Y < 1) = \mathbb{P}(X > 1)\mathbb{P}(-1 < X < 1) > 0$.

On a l'inégalité

$$\text{Cov}(X, Y)^2 \leq \text{Var}(X) \text{Var}(Y)$$

[Preuve: considérer le discriminant du polynôme positive $P(t) = \text{Var}(X + tY) \geq 0$].

Le coefficient de corrélation $\rho_{X,Y}$ est défini par

$$\rho_{X,Y} = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X) \text{Var}(Y)}} \in [-1, 1]$$

Exemple 30. Si $\rho_{X,Y} = \pm 1$ et $\text{Var}(Y) > 0$ alors existe $\alpha \in \mathbb{R}$ tel que $\text{Var}(X - \alpha Y) = 0$ et donc $X - \alpha Y = \text{constante}$ qui donne que $\text{Cov}(X, Y) = \text{Cov}(\alpha Y, Y) = \alpha \text{Var}(Y)$, $\text{Var}(X) = \alpha^2 \text{Var}(Y)$ et $\rho_{X,Y} = \text{sgn } \alpha$. Donc on voit bien que le signe de α est celui de $\rho_{X,Y}$.

Pour le prouver, considérer le polynôme quadratique en α défini par $P(\alpha) = \text{Var}(X - \alpha Y) = \text{Var}(X) - 2\alpha \text{Cov}(X, Y) + \alpha^2 \text{Var}(Y)$. Or $P(\alpha) \geq 0$ et donc l'équation $P(\alpha) = 0$ admet au plus une solution et il admet une solution seulement si le discriminant est nul. Ici $\Delta = 4 [\text{Cov}(X, Y)]^2 - 4\text{Var}(X)\text{Var}(Y) = 4 \text{Var}(X) \text{Var}(Y) (\rho_{X,Y}^2 - 1) \leq 0$ et donc $\Delta = 0 \Leftrightarrow |\rho_{X,Y}| = 1$. Après il est clair que si $X = \alpha Y + c$ avec c constant on doit avoir

$$\rho_{X,Y} = \frac{\text{Cov}(\alpha Y + c, Y)}{\sqrt{\text{Var}(\alpha Y + c) \text{Var}(Y)}} = \frac{\alpha \text{Cov}(Y, Y)}{\sqrt{\alpha^2 \text{Var}(Y) \text{Var}(Y)}} = \frac{\alpha}{|\alpha|} = \text{sgn}(\alpha).$$

Exercice 2. Montrer que $\rho_{X,Y} = \text{sgn}(ad) \rho_{aX+b, dY+d}$, c-à-d que le coefficient de corrélation est invariante par des transformation affines des variables elles vérifient $\text{sgn}(ad) = 1$.

Définition 31. On appelle variance conditionnelle de X sachant Y et on notera $\text{Var}(X|Y)$ la v.a.

$$\text{Var}(X|Y) = \mathbb{E}[(X - \mathbb{E}[X|Y])^2|Y]$$

Proposition 32. On a $\text{Var}(X|Y) = \mathbb{E}[X^2|Y] - (\mathbb{E}[X|Y])^2$

Démonstration.

$$\begin{aligned} \text{Var}(X|Y) &= \mathbb{E}[X^2 - 2X\mathbb{E}[X|Y] + (\mathbb{E}[X|Y])^2|Y] \\ &= \mathbb{E}[X^2|Y] - 2(\mathbb{E}[X|Y])^2 + (\mathbb{E}[X|Y])^2 \\ &= \mathbb{E}[X^2|Y] - (\mathbb{E}[X|Y])^2 \end{aligned}$$

car $\mathbb{E}[X \mathbb{E}[X|Y]|Y] = \mathbb{E}[X|Y] \mathbb{E}[X|Y]$ et $\mathbb{E}[(\mathbb{E}[X|Y])^2|Y] = (\mathbb{E}[X|Y])^2$. □

Proposition 33. (Identité de la variance conditionnelle) Soient X et Y 2 v.a. sur le même espace de probabilité et $\mathbb{E}[X^2] < +\infty$. Alors $\text{Var}(X) = \mathbb{E}[\text{Var}(X|Y)] + \text{Var}[\mathbb{E}(X|Y)]$

Démonstration.

$$\begin{aligned} \text{Var}(X) &= \mathbb{E}[X^2] - (\mathbb{E}[X])^2 = \mathbb{E}[\mathbb{E}[X^2|Y] - (\mathbb{E}(X|Y))^2] + \mathbb{E}[(\mathbb{E}(X|Y))^2] - (\mathbb{E}[\mathbb{E}[X|Y]])^2 \\ &= \mathbb{E}[\text{Var}(X|Y)] + \text{Var}[\mathbb{E}(X|Y)] \end{aligned} \quad \square$$

Meilleure prévision et regression

Soit X, Y un couple aléatoire de densité jointe $f_{X,Y}$ et tel que $\mathbb{E}[Y^2] < \infty$. Le problème de la meilleure prévision est de trouver une fonction g telle que l'écart moyen quadratique de Y à $g(X)$ soit le plus petit possible:

$$\mathbb{E}[(Y - g(X))^2] = \inf_h \mathbb{E}[(Y - h(X))^2]$$

Dans le contexte de la meilleure prévision la variable X est appelée *variable explicative* ou *prédicteur* et Y est appelée *variable expliquée*. L'esperance conditionnelle $\Psi(x) = \mathbb{E}[Y|X = x]$ donné l'unique solution de ce problème.

Théorème 34. (MEILLEURE PREVISION) Soit $\Psi(x) = \mathbb{E}[Y|X = x]$ alors

$$\mathbb{E}[(Y - \Psi(X))^2] \leq \mathbb{E}[(Y - h(X))^2]$$

pour tout $h: \mathbb{R} \rightarrow \mathbb{R}$ mesurable et telle que $\mathbb{E}[h(X)^2] < \infty$.

Démonstration. On a que

$$\begin{aligned} \mathbb{E}[(Y - h(X))^2] &= \mathbb{E}[(Y - \Psi(X) + \Psi(X) - h(X))^2] \\ &= \mathbb{E}[(Y - \Psi(X))^2] + \mathbb{E}[(\Psi(X) - h(X))^2] + 2\mathbb{E}[(Y - \Psi(X))(\Psi(X) - h(X))]. \end{aligned}$$

Or

$$\mathbb{E}[(Y - \Psi(X))(\Psi(X) - h(X))] = \mathbb{E}[\mathbb{E}[(Y - \Psi(X))|X](\Psi(X) - h(X))] = 0$$

et donc

$$\mathbb{E}[(Y - h(X))^2] = \mathbb{E}[(Y - \Psi(X))^2] + \mathbb{E}[(\Psi(X) - h(X))^2]$$

ce qu'implique que

$$\mathbb{E}[(Y - h(X))^2] \geq \mathbb{E}[(Y - \Psi(X))^2]$$

avec égalité si et seulement si $\mathbb{E}[(\Psi(X) - h(X))^2] = 0$ c'est à dire si $\Psi(X) = h(X)$.

□

La fonction $g(x) = \mathbb{E}[Y|X = x]$ est dite **fonction de regression de Y sur X** . Dans le cas où X, Y sont des v.a. réelles la regression est dite simple. Si X, Y sont des v.a. à valeurs vectorielles alors la regression est dite multiple ou multivariée.

Exemple 35. Soit (X, Y) un vecteur aléatoire dans \mathbb{R}^2 de densité

$$f_{X,Y}(x, y) = (x + y)\mathbb{I}_{0 < x, y < 1}.$$

Explicitions la fonction de regression de X sur Y : $g(x) = \mathbb{E}[Y|X = x]$. La densité marginale de X est donnée par

$$f_X(x) = \int_{\mathbb{R}} f_{X,Y}(x, y) dy = \left(x + \frac{1}{2}\right)\mathbb{I}_{0 < x < 1}.$$

Alors la densité conditionnelle est donnée par

$$f_{Y|X}(y|x) = \frac{x+y}{x+1/2} \mathbb{I}_{0 < x, y < 1}$$

et

$$g(x) = \int_{\mathbb{R}} y f_{Y|X}(y|x) dy = \int_{\mathbb{R}} y \frac{x+y}{x+1/2} \mathbb{I}_{0 < x, y < 1} dy = \frac{\frac{x}{2} + \frac{1}{3}}{x + \frac{1}{2}}$$

pour tout $x \in]0, 1[$. Soulignons que, en general, g est une fonction non-lineaire de x .

Si g est la fonction de regression de X sur Y alors la v.a. $\xi = Y - g(X) = Y - \mathbb{E}[Y|X]$ represente l'erreur stochastique dans la prevision de Y par $g(X)$. On appelle ξ le residu de regression. Par definition d'esperance conditionnelle

$$\mathbb{E}[\xi|X] = 0$$

et donc aussi $\mathbb{E}[\xi] = 0$. L'erreur quadratique de l'approximation de Y par $g(X)$ est

$$\Delta = \mathbb{E}[(Y - g(X))^2] = \mathbb{E}(\xi^2) = \text{Var}(\xi).$$

On appelle Δ la variance résiduelle. On a que $\Delta \leq \text{Var}(Y)$: par le théorème de meilleur prevision, pour tout $h: \mathbb{R} \rightarrow \mathbb{R}$ mesurable $\Delta \leq \mathbb{E}[(Y - h(X))^2]$. En choisissant $h(x) = \mathbb{E}[Y]$ (constante) on a que

$$\Delta \leq \mathbb{E}[(Y - h(X))^2] = \mathbb{E}[(Y - \mathbb{E}[Y])^2] = \text{Var}(Y).$$

On a aussi que

$$\text{Var}(Y) = \text{Var}(\mathbb{E}[Y|X]) + \mathbb{E}[\text{Var}(Y|X)] = \text{Var}(g(X)) + \Delta$$

car

$$\Delta = \mathbb{E}[Y^2] - \mathbb{E}[\mathbb{E}[Y|X]^2] = \mathbb{E}[\text{Var}(Y|X)].$$