

Chapitres 8 - Vecteurs Gaussiens et Conditionnement

Table des matières

1	Vecteurs Gaussiens	1
2	Conditionnement \mathcal{L}^1	4
3	Calculs d'espérance conditionnelle	8

Dans ce chapitre on désigne par (Ω, \mathcal{A}, P) un espace probabilisé, c'est-à-dire, un espace mesurable (Ω, \mathcal{A}) muni d'une probabilité P . Sont écrites en **rouge** les parties hors programme, en **violet** les parties traitées en TD (résultats à connaître pour sa culture).

1 Vecteurs Gaussiens

Définition 1.1. On dit qu'un vecteur aléatoire X à valeurs dans \mathbb{R}^d est gaussien si, pour tout $\eta \in \mathbb{R}^d$, la variable aléatoire réelle $\eta \cdot X = \sum_i \eta_i X_i$ suit une loi gaussienne.

Remarque 1.2.

- (i) En choisissant $\eta := e_i$, où (e_1, \dots, e_d) est la base canonique de \mathbb{R}^d , on voit que les composantes d'un vecteur gaussien sont des var gaussiennes. En général, la réciproque est fautive !
- (ii) Si X est une var gaussienne et $a \in \mathbb{R}$, alors $X + a$ est une var gaussienne, ce que l'on voit à partir de la caractérisation des lois gaussiennes et des propriétés élémentaires de la transformation de Fourier.
- (iii) Plus généralement, si X est un vecteur gaussien, tout vecteur de la forme $Y = MX + a$ où $M \in M_{d,k}(\mathbb{R})$ et $a \in \mathbb{R}^k$ est aussi un vecteur gaussien, puisqu'alors $\eta \cdot Y = ({}^t M \eta) \cdot X + \eta \cdot a$ est une var gaussienne pour tout $\eta \in \mathbb{R}^k$.
- (iv) Si X est un vecteur aléatoire, $a \in \mathbb{R}$ et $M \in M_d(\mathbb{R})$, alors

$$\varphi_{MX+a}(\xi) = e^{-ia \cdot \xi} \varphi_X({}^t M \xi). \quad (1)$$

- (v) On rappelle que si $X \sim \mathcal{N}(\mu, \sigma^2)$, $\sigma \geq 0$, alors

$$\varphi_X(\xi) = \exp\left(i\mu\xi - \frac{\sigma^2}{2}\xi^2\right).$$

Exercice 1.3. Donner un exemple de vecteur aléatoire (X, Y) tel que X et Y sont gaussien mais pas $X + Y$.

Définition 1.4. Soient $\mu \in \mathbb{R}^d$ et $K \in M_d(\mathbb{R})$ symétrique positive. La loi gaussienne $\mathcal{N}_d(\mu, K)$ est l'unique loi sur \mathbb{R}^d dont la transformée de Fourier est la fonction

$$g_{\mu, K}(\xi) := \exp\left(i\mu \cdot \xi - \frac{1}{2} {}^t \xi K \xi\right).$$

Remarque 1.5. *On commence par observer que la mesure de probabilité gaussienne centrée*

$$\gamma(x)dx, \quad \gamma(x) := (2\pi)^{-d/2} \exp(-|x|^2/2),$$

notée plus simplement γ , satisfait $\hat{\gamma} = g_{0,I}$. Cela signifie que $\gamma = \mathcal{N}_d(0, I)$. On note alors Z un vecteur aléatoire de \mathbb{R}^d de loi $\mathcal{N}_d(0, I)$. On observe également qu'il existe des matrices R orthogonale et Δ diagonale positive telles que $K = {}^tR\Delta R$. Comme dans la Remarque 1.2, on montre que le vecteur aléatoire $X := {}^tR\Delta^{1/2}Z$ a pour fonction caractéristique $\varphi_X = g_{0,K}$. Par ailleurs, en introduisant l'application $T : \mathbb{R}^d \rightarrow \mathbb{R}^d$, $T(x) := {}^tR\Delta^{1/2}x$, on observe que X a pour loi $\nu = T\# \gamma$. Cela permet bien d'exhiber une mesure de probabilité ν telle que $\hat{\nu} = g_{0,K}$. Par unicité de la transformation de Fourier, on conclut que $\nu = \mathcal{N}_d(0, K)$.

Théorème 1.6. *Un vecteur aléatoire X à valeurs dans \mathbb{R}^d est gaussien si, et seulement si, sa loi est gaussienne, c'est-à-dire, s'il existe un vecteur $\mu \in \mathbb{R}^d$ et une matrice symétrique $K \in M_d(\mathbb{R})$ tels que*

$$\varphi_X = g_{\mu, K} \tag{2}$$

De plus, μ et K sont l'espérance et la matrice de covariance de X .

Preuve du Théorème 1.6. Etape 1. Montrons que X gaussien implique (2). Soit X un vecteur gaussien. Notons $\tilde{\mu}$ son espérance et \tilde{K} sa matrice de covariance. Pour $\eta \in \mathbb{R}^d$ fixé, nous définissons $Y = \eta \cdot X$ et nous calculons

$$\mathbf{E}(Y) = \eta \cdot \tilde{\mu}, \quad \text{Var}(Y) = \mathbf{E}\left(\sum_{ij} \eta_i(X_i - \tilde{\mu}_i)\eta_j(X_j - \tilde{\mu}_j)\right) = {}^t\eta\tilde{K}\eta.$$

Comme par ailleurs, on sait que Y suit une loi gaussienne, on a nécessairement $Y \sim \mathcal{N}(\eta \cdot \tilde{\mu}, {}^t\eta\tilde{K}\eta)$. D'après le calcul de la fonction caractéristique rappelé en remarque, on a donc

$$\varphi_Y(\xi) = \exp\left(i(\eta \cdot \tilde{\mu})\xi - \frac{1}{2}({}^t\eta\tilde{K}\eta)\xi^2\right).$$

On en déduit

$$\varphi_X(\eta) = \mathbf{E}(e^{iX \cdot \eta}) = \varphi_{\eta \cdot X}(1) = \varphi_Y(1),$$

ce qui donne bien l'expression annoncée.

Etape 2. Montrons que (2) implique X gaussien. Soient $\eta \in \mathbb{R}^d$ et $Y := \eta \cdot X$. D'après la formule (1), pour tout $\xi \in \mathbb{R}$, on a

$$\begin{aligned} \varphi_Y(\xi) &= \varphi_{{}^t\eta X}(\xi) = \varphi_X(\xi\eta) \\ &= \exp\left(-i(\eta \cdot \mu)\xi - \frac{{}^t\eta K \eta}{2}\xi^2\right). \end{aligned}$$

On reconnaît la transformée de Fourier de la loi gaussienne $\mathcal{N}(\eta \cdot \mu, {}^t\eta K \eta)$. Par injectivité de la transformation de Fourier, Y est gaussienne, de loi $\mathcal{N}(\eta \cdot \mu, {}^t\eta K \eta)$. Donc X est gaussien.

D'après l'étape 1, on sait également que φ_X vérifie l'identité (2) associée à $\tilde{\mu}$ l'espérance de X et \tilde{K} la matrice de covariance de X . On en déduit immédiatement que $D\varphi_X(0) = \mu = \tilde{\mu}$ et $D^2\varphi_X(0) = K = \tilde{K}$. Cela prouve bien que dans (2), μ et K correspondent à l'espérance et la matrice de covariance de X . \square

Proposition 1.7. *Si X est un vecteur gaussien, ses composantes sont indépendantes si et seulement si sa matrice de covariance K_X est diagonale.*

Preuve de la Proposition 1.7. Lorsque X_1, \dots, X_d sont indépendantes, c'est un fait général que les covariances

$$\text{cov}(X_j, X_k) = \mathbf{E}(X_j X_k) - \mathbf{E}(X_j)\mathbf{E}(X_k) = 0$$

sont nulles si $j \neq k$.

Réciproquement, si K est diagonale :

$$K = \begin{pmatrix} \sigma_1^2 & & \\ & \ddots & \\ & & \sigma_d^2 \end{pmatrix},$$

la fonction caractéristique de X vérifie

$$\varphi_X(\xi) = \prod_j \varphi_{X_j}(\xi_j).$$

Donc les X_j sont indépendantes. □

Exercice 1.8. Donner un exemple de vecteur aléatoire (X, Y) non indépendant, non gaussien et tel que la matrice de covariance associée est diagonale.

Théorème 1.9. Soit X un vecteur gaussien de loi $\mathcal{N}_d(\mu, K)$. Il existe des réels $\lambda_1, \dots, \lambda_d \geq 0$, des variables gaussiennes Y_1, \dots, Y_d indépendantes de lois respectives $\mathcal{N}_1(0, \lambda_1), \dots, \mathcal{N}_1(0, \lambda_d)$ et une matrice orthogonale $A \in O_d(\mathbb{R})$ tels que

$$X = AY + \mu.$$

Preuve du Théorème 1.9. La matrice K étant une matrice de covariance, elle est symétrique positive (rappelons que ceci se voit par exemple en remarquant que ${}^t \xi K_X \xi = K_{t\xi X} = \text{var}(t\xi \cdot X) \geq 0$). Donc, il existe une matrice orthogonale A et une matrice diagonale Λ telles que

$$K = A\Lambda^t A.$$

Le vecteur

$$Y = {}^t A(X - \mu)$$

est gaussien, centré, et de covariance

$$K_Y = {}^t A K A = A^{-1} K A = \Lambda$$

(rappelons en effet que $K_{MX+a} = M K_X {}^t M$). Comme Λ est diagonale, les Y_j sont indépendantes. De plus, $X = AY + \mu$. □

Corollaire 1.10. Un vecteur gaussien de covariance K_X admet une densité si et seulement si $\det K_X \neq 0$. Sa densité est alors

$$f_X(x) = \frac{1}{(2\pi)^{d/2} \sqrt{\det K_X}} \exp\left(-\frac{1}{2} {}^t(x - \mu) K_X^{-1} (x - \mu)\right).$$

Preuve du Corollaire 1.10. Supposons d'abord $\det K_X \neq 0$. Reprenons les notations du théorème précédent : il existe un vecteur aléatoire gaussien Y de composantes indépendantes $Y_j \sim \mathcal{N}_1(0, \lambda_j)$ et une matrice orthogonale A tels que $X = AY + \mu$.

Comme $Y = A^{-1}(X - \mu)$, $K_Y = A^{-1} K_X A$ donc $\det K_Y = \det K_X \neq 0$ et, puisque $K_Y = \text{Diag}(\lambda_1, \dots, \lambda_d)$, $\lambda_j > 0$ pour tout j . Donc, pour tout j , la loi de Y_j est

$$P_{Y_j} = \frac{1}{\sqrt{2\pi\lambda_j}} \exp\left(-\frac{y_j^2}{2\lambda_j}\right) dy_j.$$

Comme les Y_j sont indépendantes, la loi conjointe de Y est le produit tensoriel de ses lois :

$$\begin{aligned} P_Y &= \bigotimes_j P_{Y_j} = \prod_j \frac{1}{\sqrt{2\pi\lambda_j}} \exp\left(-\frac{y_j^2}{2\lambda_j}\right) dy_j \\ &= \frac{1}{(2\pi)^{d/2} \sqrt{\det K_Y}} \exp(-{}^t y K_Y^{-1} y) dy = f_Y(y) dy, \end{aligned}$$

où l'on a utilisé $K_Y = \text{Diag}(\lambda_1^{-1}, \dots, \lambda_d^{-1})$ et $\det K_Y = \prod_j \lambda_j$. La loi de Y étant connue, celle de $X = AY + \mu$ s'en déduit par un simple changement de variable : pour toute fonction réelle borélienne positive h sur \mathbb{R}^d ,

$$\begin{aligned} \int h(X) dP &= \int h(Ay + \mu) dP \\ &= \int h(Ay + \mu) dP_Y(y) = \int h(Ay + \mu) f_Y(y) dy \\ &= \int h(x) f_Y(A^{-1}(x - \mu)) dx, \end{aligned}$$

où on a effectué le changement de variables $y = \varphi(x) = A^{-1}(x - \mu)$ de sorte que $|J\varphi(x)| = |\det A^{-1}| = 1$. On en déduit que X possède une densité, qui vaut $f_X(x) = f_Y(A^{-1}(X - \mu))$, d'où la formule voulue.

Réciproquement, supposons $\det K_X = 0$. Il existe $a \in \mathbb{R}^d$ tel que $K_X a = 0$. La variable aléatoire $Z = a \cdot X$ a pour espérance $a \cdot \mu_X$ et variance $\sigma_Z^2 = {}^t a K_X a = 0$. Donc $Z = a \cdot \mu$ p.p. Donc $a \cdot (X - \mu) = 0$ p.p. Soit H l'hyperplan

$$H = \mu + a^\perp = \{x \in \mathbb{R}^d, (x - \mu) \cdot a = 0\}.$$

Presque sûrement, $X \in H$ alors que $\lambda_d(H) = 0$. Si X avait une densité, on aurait

$$1 = P(X \in H) = \int_H f_X(x) dx = 0,$$

ce qui est absurde. □

Dans le cas dégénéré, la démonstration précédente montre que, si l'on suppose par exemple que $\sigma_1, \dots, \sigma_r > 0$ tandis que $\sigma_{r+1} = \dots = \sigma_d = 0$, et si V est le sous-espace vectoriel de dimension r image par A des r premiers vecteurs de la base canonique de \mathbb{R}^n , la loi de X est portée par V et X possède une densité relativement à la mesure de Lebesgue associée aux coordonnées d'une base orthogonale quelconque de V .

2 Conditionnement \mathcal{L}^1

Dans cette section, nous définissons la notion d'espérance conditionnelle dans un cadre \mathcal{L}^1 . Une extension possible est de définir cette notion pour des ν positives (sans condition d'intégrabilité). Etant donnée une sous-tribu $\mathcal{C} \subset \mathcal{A}$, on note $L^p(\mathcal{C}) := L^p(\Omega, \mathcal{C}, P)$.

Théorème 2.1. *Soient $\mathcal{B} \subset \mathcal{A}$ une sous-tribu et X une var $\mathcal{L}^1(\mathcal{A})$. Il existe une var $Y \in L^1(\mathcal{B})$ unique, notée $Y = \mathbf{E}(X|\mathcal{B})$ et appelée espérance conditionnelle de X par rapport à \mathcal{B} , telle que*

$$\mathbf{E}(YZ) = \mathbf{E}(XZ) \quad \forall Z = \mathbf{1}_B, B \in \mathcal{B}, \text{ (et donc } \forall Z \in L^\infty(\mathcal{B})). \quad (3)$$

Si $X \in \mathcal{L}^2(\mathcal{A})$ alors $Y \in L^2(\mathcal{B})$ est la solution du problème de minimisation

$$\mathbf{E}((Y - X)^2) = \min_{Z \in L^2(\mathcal{B})} \mathbf{E}((Z - X)^2). \quad (4)$$

Preuve du Théorème 2.1. Commençons par l'unicité. Supposons qu'il existe deux var Y_1 et Y_2 de $L^1(\Omega, \mathcal{B}, P)$ telles que

$$\forall B \in \mathcal{B}, \quad \mathbf{E}(Y_1 \mathbf{1}_B) = \mathbf{E}(Y_2 \mathbf{1}_B) = \mathbf{E}(X \mathbf{1}_B).$$

En prenant $B := \{Y_1 - Y_2 > 0\} \in \mathcal{B}$, on trouve

$$\forall B \in \mathcal{B}, \quad \mathbf{E}((Y_1 - Y_2) \mathbf{1}_{\{Y_1 - Y_2 > 0\}}) = 0,$$

ce qui prouve $Y_1 - Y_2 \leq 0$ p.s.. Et on montre de la même manière $Y_1 - Y_2 \geq 0$ p.s..

Pour l'existence, nous commençons par supposer $X \geq 0$. Soit alors Q la mesure définie sur (Ω, \mathcal{B}) par

$$\forall B \in \mathcal{B}, \quad Q(B) := \int_B X dP.$$

On voit clairement que $Q \ll P$ sur (Ω, \mathcal{B}) . Le Théorème de Radon-Nikodym assure l'existence d'une variable aléatoire positive Y sur (Ω, \mathcal{B}) telle que

$$\forall B \in \mathcal{B}, \quad Q(B) = \int_B Y dP,$$

ce qui est bien le résultat annoncé. Si de plus, $X \in L^1(\mathcal{A})$ alors $Y \in L^1(\mathcal{B})$, ce que l'on voit en prenant $B = \Omega$.

Si maintenant, on suppose juste $X \in \mathcal{L}^1(\mathcal{A})$, on écrit $X = X_+ - X_-$ avec $0 \leq X_{\pm} \in \mathcal{L}^1(\mathcal{A})$ et l'étape précédente nous dit qu'il existe $0 \leq Y_{\pm} \in L^1(\mathcal{B})$ telles que $\mathbf{E}(Y_{\pm} \mathbf{1}_B) = \mathbf{E}(X_{\pm} \mathbf{1}_B)$. On en déduit que $Y := Y_+ - Y_-$ convient.

On suppose enfin $X \in \mathcal{L}^2(\mathcal{A})$. En prenant $Z := Y \mathbf{1}_{|Y| \leq n} \in L^\infty(\mathcal{B})$ dans (3), on obtient

$$\mathbf{E}(Y^2 \mathbf{1}_{|Y| \leq n}) = \mathbf{E}(Y (Y \mathbf{1}_{|Y| \leq n})) = \mathbf{E}(X Y \mathbf{1}_{|Y| \leq n}) \leq \mathbf{E}(X^2)^{1/2} \mathbf{E}(Y^2 \mathbf{1}_{|Y| \leq n})^{1/2},$$

et donc

$$\mathbf{E}(Y^2) = \lim_{n \rightarrow \infty} \mathbf{E}(Y^2 \mathbf{1}_{|Y| \leq n}) \leq \mathbf{E}(X^2).$$

De plus, pour tout $Z \in L^2(\mathcal{B})$, on a

$$\begin{aligned} \mathbf{E}((X - Z)^2) &= \mathbf{E}((X - Y)^2) + 2\mathbf{E}((X - Y)(Y - Z)) + \mathbf{E}((Y - Z)^2) \\ &= \mathbf{E}((X - Y)^2) + \mathbf{E}((Y - Z)^2), \end{aligned}$$

puisque $Y - Z$ est \mathcal{B} mesurable. On en déduit immédiatement (4). □

Les principales propriétés de l'espérance conditionnelle sont résumées ci-dessous

Théorème 2.2. Soient $\mathcal{B}, \mathcal{C} \subset \mathcal{A}$ deux sous-tribus et X, Y deux var $\mathcal{L}^1(\mathcal{A})$. Alors

$$\bullet \mathbf{E}(\lambda X + Y|\mathcal{B}) = \lambda \mathbf{E}(X|\mathcal{B}) + \mathbf{E}(Y|\mathcal{B}); \quad (5)$$

$$\bullet X \leq Y \Rightarrow \mathbf{E}(X|\mathcal{B}) \leq \mathbf{E}(Y|\mathcal{B}); \quad (6)$$

$$\bullet \mathbf{E}(\mathbf{E}(X|\mathcal{B})) = \mathbf{E}(X), \quad \mathbf{E}(1|\mathcal{B}) = 1; \quad (7)$$

$$\bullet \mathbf{E}(X|\mathcal{B}) = \mathbf{E}(X) \quad \text{si } X \perp \mathcal{B}; \quad (8)$$

$$\bullet \mathbf{E}(XY|\mathcal{B}) = Y \mathbf{E}(X|\mathcal{B}), \quad \mathbf{E}(Y|\mathcal{B}) = Y \quad \text{si } Y \text{ est } \mathcal{B}\text{-mesurable}; \quad (9)$$

$$\bullet \mathbf{E}(\mathbf{E}(X|\mathcal{C})|\mathcal{B}) = \mathbf{E}(X|\mathcal{C}) \quad \text{si } \mathcal{C} \subset \mathcal{B}; \quad (10)$$

$$\bullet \varphi(\mathbf{E}(X|\mathcal{B})) \leq \mathbf{E}(\varphi(X)|\mathcal{B}) \quad \text{si } \varphi \text{ est une fonction convexe,} \quad (11)$$

$$\text{ce qui implique } |\mathbf{E}(X|\mathcal{B})|^p \leq \mathbf{E}(|X|^p|\mathcal{B}) \text{ et } \mathbf{E}(X|\mathcal{B}) \in L^p \text{ si } X \in L^p; \quad (12)$$

$$\bullet \mathbf{E}(X_n|\mathcal{B}) \rightarrow \mathbf{E}(X|\mathcal{B}) \text{ en norme } L^p \text{ si } X_n \rightarrow X \text{ en norme } L^p; \quad (13)$$

$$\bullet \mathbf{E}(X_n|\mathcal{B}) \nearrow \mathbf{E}(X|\mathcal{B}) \text{ si } X_n \nearrow X \text{ p.s.}; \quad (14)$$

$$\bullet \mathbf{E}(\liminf X_n|\mathcal{B}) \leq \liminf \mathbf{E}(X_n|\mathcal{B}) \text{ si } X_n \geq 0; \quad (15)$$

$$\bullet \mathbf{E}(X_n|\mathcal{B}) \rightarrow \mathbf{E}(X|\mathcal{B}) \text{ p.s. et } L^1 \text{ si } X_n \rightarrow X \text{ p.s. et } |X_n| \leq Z \in L^1. \quad (16)$$

Preuve du Théorème 2.2. (5) En notant $X' = \mathbf{E}(X|\mathcal{B})$ et $Y' = \mathbf{E}(Y|\mathcal{B})$, pour tout $Z \in L^\infty(\mathcal{B})$, on a

$$\mathbf{E}((\lambda X' + Y')Z) = \lambda \mathbf{E}(X'Z) + \mathbf{E}(Y'Z) = \lambda \mathbf{E}(XZ) + \mathbf{E}(YZ) = \mathbf{E}((\lambda X + Y)Z).$$

(6) Si $X \geq 0$, en notant $Y := \mathbf{E}(X|\mathcal{B})$ et $B := \{Y \leq 0\}$, on a

$$0 \leq \mathbf{E}(X\mathbf{1}_B) = \mathbf{E}(Y\mathbf{1}_B) \leq 0 \text{ et } Y\mathbf{1}_B \leq 0,$$

de sorte que $Y\mathbf{1}_B = 0$ et donc $Y \geq 0$.

(7) On a $\mathbf{E}(\mathbf{E}(X|\mathcal{B})) = \mathbf{E}(X)$ en prenant $Z = 1$ dans la définition (3) de l'espérance conditionnelle. L'identité $\mathbf{E}(1|\mathcal{B}) = 1$ est immédiate.

(8) Si $X \perp \mathcal{B}$, on a $\mathbf{E}(XZ) = \mathbf{E}(X)\mathbf{E}(Z) = \mathbf{E}(\mathbf{E}(X)Z)$ pour tout $Z \in L^\infty(\mathcal{B})$, ce qui prouve bien $\mathbf{E}(X|\mathcal{B}) = \mathbf{E}(X)$.

(9) Si $Y \in L^\infty(\mathcal{B})$, pour $Z \in L^\infty(\mathcal{B})$, on a

$$\mathbf{E}(\mathbf{E}(X|\mathcal{B})YZ) = \mathbf{E}(XYZ) = \mathbf{E}(\mathbf{E}(XY|\mathcal{B})Z),$$

ce qui prouve $\mathbf{E}(XY|\mathcal{B}) = Y \mathbf{E}(X|\mathcal{B})$. En particulier, en prenant $X = 1$, on a $\mathbf{E}(Y|\mathcal{B}) = Y$.

(10) Si $\mathcal{C} \subset \mathcal{B}$, alors $\mathbf{E}(X|\mathcal{C})$ est \mathcal{B} -mesurable, et donc $\mathbf{E}(\mathbf{E}(X|\mathcal{C})|\mathcal{B}) = \mathbf{E}(X|\mathcal{C})$ d'après (9).

(11) Notons

$$A_\varphi := \{(a, b) \in \mathbb{R}^2; \forall x \in \mathbb{R}, \varphi(x) \geq ax + b\}.$$

Il est clair que

$$\forall x \in \mathbb{R}, \quad \varphi(x) = \sup_{(a,b) \in A_\varphi} (ax + b) = \sup_{(a,b) \in A_\varphi \cap \mathbb{Q}^2} (ax + b).$$

Du fait que $A_\varphi \cap \mathbb{Q}^2$ est dénombrable, on en déduit que p.s.

$$\mathbf{E}[\varphi(X)|\mathcal{B}] = \mathbf{E}\left[\sup_{(a,b) \in A_\varphi \cap \mathbb{Q}^2} (aX + b)|\mathcal{B}\right] \geq \sup_{(a,b) \in A_\varphi \cap \mathbb{Q}^2} \mathbf{E}[aX + b|\mathcal{B}] = \varphi(\mathbf{E}[X|\mathcal{B}]).$$

L'assertion (12) s'en déduit immédiatement.

(13) De (12), on déduit

$$\mathbf{E}(|\mathbf{E}(X_n|\mathcal{B}) - \mathbf{E}(X|\mathcal{B})|^p) = \mathbf{E}(|\mathbf{E}(X_n - X|\mathcal{B})|^p) \leq \mathbf{E}(|X_n - X|^p) \rightarrow 0,$$

si $X_n \rightarrow X$ dans L^p .

(14) Si $X_n \nearrow X$ p.s. on a $Y_n := \mathbf{E}(X_n|\mathcal{B}) \nearrow Y$ p.s. avec Y \mathcal{B} -mesurable. D'après le théorème de convergence monotone, pour tout $B \in \mathcal{B}$, on a

$$\mathbf{E}(Y\mathbf{1}_B) = \lim \mathbf{E}(Y_n\mathbf{1}_B) = \lim \mathbf{E}(X_n\mathbf{1}_B) = \mathbf{E}(X\mathbf{1}_B),$$

ce qui dit bien que $Y = \mathbf{E}(X|\mathcal{B})$. Les assertions (15) et (16) s'en déduisent comme dans le chapitre sur les théorèmes de passage à la limite. \square

Exercice 2.3. *Faire la démonstration détaillée de (15) et (16).*

On peut préciser le point (8).

Théorème 2.4. *Deux sous tribus \mathcal{B}_1 et \mathcal{B}_2 sont indépendantes si, et seulement si,*

$$\mathbf{E}(X|\mathcal{B}_1) = \mathbf{E}(X) \text{ pour toute var } X \text{ } \mathcal{B}_2\text{-mesurable.}$$

Preuve du Théorème 2.4. Le sens direct n'est rien d'autre que (8). Montrons la réciproque et supposons que

$$\mathbf{E}(X|\mathcal{B}_1) = \mathbf{E}(X) \text{ pour toute var } X \text{ } \mathcal{B}_2\text{-mesurable.}$$

Pour $Z \in L^\infty(\mathcal{B}_1)$ on a donc

$$\mathbf{E}(XZ) = \mathbf{E}(\mathbf{E}(X|\mathcal{B}_1)Z) = \mathbf{E}(\mathbf{E}(X)Z) = \mathbf{E}(X)\mathbf{E}(Z),$$

ce qui est bien dire que \mathcal{B}_1 et \mathcal{B}_2 sont indépendantes. \square

Définition 2.5. *Soit X, Y deux var. On appelle espérance conditionnelle de Y sachant X , la var $\mathbf{E}(Y|X) := \mathbf{E}(Y|\sigma(X))$.*

D'après le Théorème I.4.10, il existe une fonction φ telle que $\mathbf{E}(Y|X) = \varphi(X)$. On peut donc voir l'espérance conditionnelle comme une façon de définir une "meilleure fonction" φ de sorte que $\varphi(X)$ "soit proche" de Y .

Corollaire 2.6. *Deux variables aléatoires X et Y sont indépendantes si, et seulement si,*

$$\mathbf{E}(h(X)|Y) = \mathbf{E}(h(X)), \quad \forall h \text{ mesurables.}$$

Théorème 2.7. *Soit \mathcal{B} une sous-tribu et soient X et Y deux variables aléatoires telles que X est indépendante de \mathcal{B} et Y est \mathcal{B} -mesurable. Pour toute fonction mesurable et bornée φ , on a*

$$\mathbf{E}(\varphi(X, Y)|\mathcal{B}) = \Phi(Y), \quad \Phi(y) := \int \varphi(x, y)P_X(dx),$$

où P_X désigne la loi de X .

Preuve du Théorème 2.7. Soit $Z \in \mathcal{L}^\infty(\mathcal{B})$ et notons $P_{(X, Y, Z)}$ la loi du triplet (X, Y, Z) . Comme X est indépendante de (Y, Z) , on a $P_{(X, Y, Z)} = P_X \otimes P_{(Y, Z)}$. Grâce au théorème de Fubini, on a

$$\begin{aligned} \mathbf{E}(\varphi(X, Y)Z) &= \int \varphi(x, y)z P_X \otimes P_{(Y, Z)}(dx, dy, dz) \\ &= \int z \left(\int \varphi(x, y)P_X(dx) \right) P_{(Y, Z)}(dy, dz) \\ &= \int z \Phi(Y)P_{(Y, Z)}(dy, dz) = \mathbf{E}(\Phi(Y)Z). \end{aligned}$$

Cela démontre bien le résultat annoncé. \square

Exercice 2.8. *Soient \mathcal{B} et \mathcal{C} deux sous-tribus et X une var \mathcal{L}^1 . On suppose $\mathcal{C} \perp \sigma(\sigma(X), \mathcal{B})$.*

a) *Montrer que $\mathbf{E}(X\mathbf{1}_{B \cap C}) = \mathbf{E}(X\mathbf{1}_B)\mathbf{P}(C)$, pour tout $B \in \mathcal{B}$ et $C \in \mathcal{C}$.*

b) *Montrer que $\mathcal{D} := \{B \cap C; B \in \mathcal{B}, C \in \mathcal{C}\}$ est une algèbre et que $\sigma(\mathcal{D}) = \sigma(\mathcal{B}, \mathcal{C})$.*

c) *En déduire que $\mathbf{E}(X|\sigma(\mathcal{B}, \mathcal{C})) = \mathbf{E}(X|\sigma(\mathcal{B}))$.*

3 Calculs d'espérance conditionnelle

• *Le cas discret.* Soit X une va à valeurs dans un espace dénombrable E et soit $Y \in \mathcal{L}^1(\mathcal{A})$. On introduit l'ensemble

$$E' := \{x \in E; P(X = x) > 0\},$$

la fonction

$$\varphi(x) := \frac{\mathbf{E}(Y \mathbf{1}_{X=x})}{P(X=x)} \text{ si } x \in E', \quad := 0 \text{ sinon,}$$

et enfin la var $\varphi(X)$. Pour $Z := \mathbf{1}_{X=a}$, $a \in E'$, on calcule

$$\begin{aligned} \mathbf{E}(\varphi(X)Z) &= \mathbf{E}\left(\sum_{x \in E'} \varphi(x) \mathbf{1}_{X=x} \mathbf{1}_{X=a}\right) \\ &= \varphi(a) \mathbf{E}(\mathbf{1}_{X=a}) = \mathbf{E}(Y \mathbf{1}_{X=a}) = \mathbf{E}(YZ). \end{aligned}$$

Comme E est discret, cela suffit pour dire que cette identité est vraie pour tout Z qui est $\sigma(X)$ -mesurable. On vient donc de démontrer que $E(Y|X) = \varphi(X)$.

Exemple. On prend $\Omega := \{1, \dots, 6\}$ et $P(\{\omega\}) = 1/6$ pour tout $\omega \in \Omega$. On définit

$$X(\omega) := \begin{cases} 1 & \text{si } \omega \text{ est impair,} \\ 0 & \text{si } \omega \text{ est pair,} \end{cases}$$

et $Y(\omega) = \omega$. Alors

$$\mathbf{E}(Y|X)(\omega) = \varphi(X(\omega)) = \begin{cases} 3 & \text{si } \omega \text{ est impair,} \\ 4 & \text{si } \omega \text{ est pair,} \end{cases}$$

puisque par exemple

$$\varphi(1) = \frac{\mathbf{E}(\sum_{\omega} \omega \mathbf{1}_{X(\omega)=1})}{P(X=1)} = \frac{\sum_{\omega \text{ impair}} \omega P(\{\omega\})}{1/2} = \frac{1+3+5}{3}.$$

• *Le cas continu.* Soient X et Y deux v.a.r. telles que le couple (X, Y) a pour densité $f_{X,Y}(x, y)$. On observe en particulier que la var Y a pour densité

$$f_Y(y) := \int_{\mathbb{R}} f_{X,Y}(x, y) dx$$

et on pose

$$f_{X|Y}(x|y) := \frac{f_{X,Y}(x, y)}{f_Y(y)} \mathbf{1}_{f_Y(y) > 0}.$$

Pour tout $\varphi, \psi \in \mathcal{L}^\infty(\mathbb{R})$, on calcule

$$\begin{aligned} \mathbf{E}(\varphi(X)\psi(Y)) &= \int_{\mathbb{R}^2} \varphi(x)\psi(y) f_{X,Y}(x, y) dx dy \\ &= \int_{\mathbb{R}} \int_{\mathbb{R}} \varphi(x) f_{X|Y}(x|y) dx \psi(y) f_Y(y) \mathbf{1}_{f_Y(y) > 0} dy \\ &= \int_{\mathbb{R}} \Phi(y) \psi(y) f_Y(y) dy = \mathbf{E}(\Phi(Y)\psi(Y)), \end{aligned}$$

où on a posé

$$\Psi(y) := \int_{\mathbb{R}} \varphi(x) f_{X,Y}(x, y) dx.$$

On a ainsi démontré que $\mathbf{E}(\varphi(X)|Y) = \Phi(Y)$.

• *Le cas gaussien.* Soit (X, Y_1, \dots, Y_n) un vecteur gaussien centré. Alors $\mathbf{E}(X|Y_1, \dots, Y_n)$ coïncide avec la projection orthogonale de X sur le sous-espace vectoriel engendré par Y_1, \dots, Y_n . Il existe donc $\lambda_1, \dots, \lambda_n$ tels que

$$\mathbf{E}[X|Y_1, \dots, Y_n] = \sum_{j=1}^n \lambda_j Y_j =: m_Y.$$

De plus, pour toute fonction φ mesurable et bornée, on a

$$\mathbf{E}[\varphi(X)|Y_1, \dots, Y_n] = \int \varphi(x) g_{m_Y, \sigma_Y^2}(x) dx$$

avec g_{m, σ^2} la densité de la loi $\mathcal{N}(m, \sigma^2)$ et

$$\sigma_Y^2 := \mathbf{E}[(X - m_Y)^2].$$

Preuve. On note $m_Y := \sum \lambda_j Y_j$ la projection orthogonale de X sur Y_1, \dots, Y_n . Pour tout $j \in \{1, \dots, n\}$, on a

$$\text{cov}(X - m_Y, Y_j) = \mathbf{E}[(X - m_Y)Y_j] = 0,$$

par définition de la projection orthogonale. Puisque le vecteur $(Y_1, \dots, Y_n, X - m_Y)$ est gaussien centré, il en résulte que la va $X - m_Y$ est indépendante des Y_1, \dots, Y_n . On en déduit

$$\mathbf{E}[X|Y_1, \dots, Y_n] = \mathbf{E}[X - m_Y|Y_1, \dots, Y_n] + m_Y = \mathbf{E}[X - m_Y] + m_Y = m_Y,$$

et la première assertion. Pour la dernière assertion, ; notons $Z := X - m_Y$, de sorte que Z est indépendante de (Y_1, \dots, Y_n) et suit la loi $\mathcal{N}(0, \sigma_Y^2)$. D'après le Théorème 2.7, on a alors

$$\mathbf{E}(\varphi(X)|Y_1, \dots, Y_n) = \mathbf{E}(\varphi(m_Y + Z)|Y_1, \dots, Y_n) = \int \varphi(m_Y + z) P_Z(dz).$$

On conclut grâce à un changement de variables. □