

# PROBABILITÉS AVANCÉES

## ING1-GMI 2019-2020

MERCI DE ME SIGNALER TOUTE COQUILLE, YAR@EISTI.EU

CY TECH-EISTI



## *Table des matières*

*Variables aléatoires vectorielles*      5

*Éspérances Conditionnelles*      13

*Bibliographie*      29



# Variables aléatoires vectorielles

## 0.1 Variables aléatoires vectorielles

**Notations :**

- On note, pour  $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ ,  $\|x\| = (x_1^2 + \dots + x_d^2)^{1/2}$ .
- On note  $M'$  la matrice transposée de la matrice  $M$ . On peut représenter  $x \in \mathbb{R}^d$  par un vecteur colonne i.e. une matrice  $d \times 1$  et on écrira indifféremment  $x = (x_1, \dots, x_d)$  ou  $x = (x_1, \dots, x_d)'$ . Pour  $x = (x_1, \dots, x_d)'$  et  $y = (y_1, \dots, y_d)'$ , on a  $x'y = x_1y_1 + \dots + x_dy_d = \langle x, y \rangle$  et  $xy'$  est la matrice de terme générale  $x_iy_j$ .
- On note  $L_d^p(\Omega, \mathcal{F}, \mathbb{P}) = \{X = (X_1, \dots, X_d) : \mathbb{E}[|X|^p] < +\infty\}$ .
- Si  $X \in L_d^1$ , on note  $\mathbb{E}[X] = (\mathbb{E}[X_1], \dots, \mathbb{E}[X_d])$ .

Par définition  $X = (X_1, \dots, X_d)'$  est un vecteur aléatoire si et seulement si, pour tout  $k \in \{1, \dots, d\}$ ,  $X_k$  est une v.a.r. Ceci entraîne :

**Propriété 1 (Doob-Dynkin)** Soient  $X_1, \dots, X_d$   $d$  v.a.r. et  $\mathcal{F}_d = \sigma(X_1, \dots, X_d)$ . Une v.a.r.  $Y$  est  $\mathcal{F}_d$ -mesurable si et seulement si  $Y = f(X_1, \dots, X_d)$  avec  $f$  fonction borélienne sur  $\mathbb{R}^d$ .

*Preuve:* Admise. □

Vous aviez vu la définition de la densité d'une mesure de probabilité  $\mathbb{P}$  définie sur  $(\mathbb{R}^n, \mathcal{B}^n)$  avec  $n = 1$ . Voici la définition lorsque  $n \geq 1$  :

**Définition 1** On dit qu'une mesure de probabilité  $\mathbb{P}$  sur  $(\mathbb{R}^n, \mathcal{B}^n)$  a une densité de probabilité  $f$  si  $f$  est une fonction positive Borel mesurable sur  $\mathbb{R}^n$  vérifiant

$$P(A) = \int_A f(x) dx = \int f(x) \mathbf{1}_A(x) dx \quad (1)$$

$$= \int f(x_1, \dots, x_n) \mathbf{1}_A(x_1, \dots, x_n) dx_1, \dots, dx_n \quad (2)$$

pour tout  $A \in \mathcal{B}^n$ .

En dimension 1 vous aviez vu la définition de l'espérance mathématique d'une variable aléatoire et via le théorème de transfert une

autre formule permettant d'obtenir l'espérance : On considère un espace de probabilité  $(\Omega, \mathcal{F}, \mathbb{P})$ , et une variable aléatoire réelle  $X$  définie sur  $(\Omega, \mathcal{F}, \mathbb{P})$ , de loi  $\mu_X$ .

**Théorème 1 (Théorème de transfert)** Soit  $\phi$  une fonction borélienne définie sur  $\mathbb{R}$ .  $\phi(X)$  est  $\mathbb{P}$ -intégrable si et seulement si  $\phi$  est  $\mu_X$ -intégrable, et l'on a :

$$\int_{\Omega} \phi(X(\omega)) d\mathbb{P}(\omega) = \int_{\mathbb{R}} \phi(x) d\mu_X(x).$$

**Définition 2 (Espérance mathématique)** Si  $X$  est à valeurs positives ou si  $X$  est  $\mathbb{P}$ -intégrable, on appelle espérance mathématique de  $X$ , notée  $\mathbb{E}[X]$ , l'intégrale de  $X$  par rapport à  $\mathbb{P}$  :

$$\mathbb{E}[X] = \int_{\Omega} X(\omega) d\mathbb{P}(\omega) \stackrel{\text{Th. de tr.}}{=} \int_{\mathbb{R}} x d\mu_X(x).$$

Et voici le théorème de transfert en multidimensionnelle :

On considère un vecteur aléatoire  $X$  de dimension  $n$  défini sur  $(\Omega, \mathcal{F}, \mathbb{P})$  de loi conjointe  $\mu_X$ .

**Théorème 2 (Théorème de transfert bis)** Soit  $\phi : \mathbb{R}^n \rightarrow \mathbb{R}$  une fonction borélienne. Alors  $\phi(X)$  est une variable réelle  $\mathbb{P}$ -intégrable si et seulement si  $\phi$  est  $\mu_X$ -intégrable, et l'on a :

$$\mathbb{E}[\phi(X)] = \int_{\Omega} \phi(X(\omega)) d\mathbb{P}(\omega) = \int \cdots \int_{\mathbb{R}^n} \phi(x_1, \dots, x_n) d\mu_X(x_1, \dots, x_n).$$

Soit  $X = (X_1, \dots, X_d)$  un vecteur aléatoire. Les lois  $\mu_{X_1}, \dots, \mu_{X_d}$  s'appellent les lois marginales de  $X$ . On sait que les composants  $X_1, \dots, X_d$  sont indépendantes si et seulement si  $\mu_X = \mu_{X_1} \otimes \cdots \otimes \mu_{X_d}$ . Si  $X$  a une densité  $h$ , on a immédiatement :

**Propriété 2** Soit  $X$  un vecteur aléatoire de densité  $h$ . Les composants  $X_1, \dots, X_d$  sont indépendants si et seulement si  $h(x_1, \dots, x_d) = \prod_{j=1}^d g_j(x_j)$  p.p. et alors  $X_k$  a pour densité  $h_{X_k}(u) = g_k(u) / \int_{\mathbb{R}} g_k(v) dv$ .

Rappelons la formule de changement de variables dans  $\mathbb{R}^d$  (pour une preuve voir le paragraphe IV.3.4 de [p684-p690 Ramis-Warusfel, L2]).

Si  $\phi$  est un  $C^1$ -difféomorphisme de l'ouvert  $U$  sur l'ouvert  $V$ , on a, pour toute fonction  $f \in \mathcal{B}(\mathbb{R}^d)$  intégrable,

$$\int_V f(v) dv = \int_U f(\phi(u)) |\det(J(\phi)(u))| du$$

où  $\det(J(\phi)(u))$  est le déterminant de la matrice Jacobienne de  $\phi$  au point  $u$ , i.e.  $J(\phi)(u) = \frac{\partial \phi_i}{\partial u_j}$ .

**Propriété 3** Soit  $X$  un vecteur aléatoire de densité  $f_X$ . On suppose que  $X \in D$  p.s.,  $D$  ouvert de  $\mathbb{R}^d$ . Soient  $\psi$  un  $C^1$ -difféomorphisme de  $D$  sur un ouvert  $\Delta$  et  $Y = \psi(X)$ , alors

$$f_Y(y) = f_X(\psi^{-1}(y)) |\det(J(\psi^{-1})(y))| \mathbf{1}_{\Delta}(y).$$

Si  $U$  et  $V$  sont deux ouverts de  $\mathbb{R}^n$ , et  $\phi$  une fonction de  $U$  dans  $V$ , on dit que  $\phi$  est un  $C^k$ -difféomorphisme si  $\phi$  est bijective et si  $\phi$  et  $\phi^{-1}$  sont de classe  $C^k$ .

*Preuve:* Soit  $g$  une fonction borélienne bornée. Alors  $\mathbb{E}[g(Y)] < +\infty$ . Or  $g(Y) = g(\psi(X)) = (g \circ \psi)(X)$  avec  $X$  admettant une densité de probabilité, donc  $(g \circ \psi)f_X$  est intégrable, d'où

$$\begin{aligned}\mathbb{E}[g(Y)] &= \mathbb{E}[(g \circ \psi)(X)] = \int_D g(\psi(x))f_X(x) dx \\ &= \int_{\Delta} g(y)f_X(\psi^{-1}(y))|\det(J(\psi^{-1})(y))| dy.\end{aligned}$$

□

Pour les exemples d'applications, voir les exercices des TDs.

### 0.1.1 Covariance

Soient  $X$  et  $Y$  deux v.a.r. de carré intégrable. On appelle covariance de  $X$  et  $Y$  la quantité

$$\text{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])] = \mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y]. \quad (3)$$

$(X, Y) \mapsto \text{Cov}(X, Y)$  est une forme bilinéaire et  $\text{Cov}(X, X) = \text{Var}(X)$ . Si  $X$  et  $Y$  sont indépendantes,  $\text{Cov}(X, Y) = 0$ . On appelle coefficient de corrélation de  $X$  et  $Y$  la quantité

$$\rho_{X,Y} = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}.$$

On a  $|\rho_{X,Y}| \leq 1$  et  $|\rho_{X,Y}| = 1$  si et seulement si  $aX + bY + c = 0$  p.s.

Plus généralement on pose, pour  $X \in L_d^2(\Omega, \mathcal{F}, \mathbb{P})$

$$\text{Cov}(X) = \mathbb{E}[(X - \mathbb{E}[X])(X - \mathbb{E}[X])'] = \mathbb{E}[XX'] - \mathbb{E}[X]\mathbb{E}[X]'$$

$\text{Cov}(X)$  s'appelle la matrice de covariances de  $X$ . On a  $\text{Cov}(X)_{i,j} = \text{Cov}(X_i, X_j)$ . Notons que, si les composantes  $X_1, \dots, X_d$  sont indépendantes,  $\text{Cov}(X)$  est diagonale.

**Propriété 4** Soit  $X \in L_d^2(\Omega, \mathcal{F}, \mathbb{P})$ . On a

- i) 1. Pour tout  $a \in \mathbb{R}$ ,  $\text{Cov}(aX) = a^2 \text{Cov}(X)$
2. Pour tout  $b \in \mathbb{R}^d$ ,  $\text{Cov}(X + b) = \text{Cov}(X)$ .
3.  $\text{Cov}(X)' = \text{Cov}(X)$ .
- ii) Pour tout  $\lambda \in \mathbb{R}^d$ ,  $\lambda' \text{Cov}(X) \lambda \geq 0$ .
- iii) Soit  $M$  une matrice déterministe  $r \times d$ , on a  $\text{Cov}(MX) = M \text{Cov}(X) M'$ .

*Preuve:*

i) Cela résulte de la formule (3) et de la définition de  $\text{Cov}(X)$ .

ii) Vu i), on peut supposer  $\mathbb{E}[X] = 0 \in \mathbb{R}^d$ . Alors

$$\lambda' \text{Cov}(X) \lambda = \lambda' \mathbb{E}[XX'] \lambda = \mathbb{E}[\lambda' XX' \lambda] = \mathbb{E}[(\lambda' X)^2] \geq 0.$$

iii) Vu  $i)$ , on peut supposer que  $\mathbb{E}[X] = 0$ . Alors

$$\text{Cov}(MX) = \mathbb{E}[(MX)(MX)'] = M\mathbb{E}[XX']M' = M\text{Cov}(X)M'.$$

Les points  $i)$  et  $ii)$  montrent que  $\text{Cov}(X)$  est symétrique semi-définie positive.  $\square$

**Théorème 3** Soient  $X, Y \in L_d^2(\Omega, \mathcal{F}, \mathbb{P})$  deux vecteurs aléatoires indépendants, on a  $\text{Cov}(X + Y) = \text{Cov}(X) + \text{Cov}(Y)$ . En particulier, si  $d = 1$ ,  $\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y)$  si les v.a.r.  $X$  et  $Y$  sont indépendantes.

*Preuve:* On peut supposer que  $\mathbb{E}[X] = \mathbb{E}[Y] = 0$ . Alors  $\text{Cov}(X + Y) = \mathbb{E}[(X + Y)(X + Y)'] = \mathbb{E}[XX'] + \mathbb{E}[YY']$  puisque, vu l'indépendance,  $\mathbb{E}[XY'] = \mathbb{E}[X]\mathbb{E}[Y'] = 0$  et de même  $\mathbb{E}[YX'] = 0$ .  $\square$

**Propriété 5** Soit  $X \in L_d^2(\Omega, \mathcal{F}, \mathbb{P})$ . On a  $X - \mathbb{E}[X] \in \text{Im}(\text{Cov}(X))$  p.s.

*Preuve:* Soit  $M = \text{Cov}(X)$ . Comme toujours on peut supposer que  $\mathbb{E}[X] = 0$ . Soit  $V = \text{Im}(M)$ . Si  $\dim(V) = d$ , il n'y a rien à démontrer, en effet  $\dim(\text{Ker}(M)) = 0 \Leftrightarrow M$  est inversible et donc  $MY = X$  avec  $Y = M^{-1}X$  d'où  $X \in \text{Im}(M)$ .

Supposons que  $\dim(V) = \ell < d$ ; d'où  $1 \leq d - \ell = \dim(\text{ker}(M))$ . Comme pour toute matrice  $A$  de taille  $n \times m$  on a  $\text{Im}(A) = (\text{ker}(A'))^\perp$  et que  $M = M'$  (car symétrique) d'où  $(\text{ker}(M))^\perp = \text{Im}(M)$ . De plus, pour tout  $u \in \text{ker}(M)$ , vu la Proposition 4,

$$\mathbb{E}[(u'X)^2] = \text{Var}(u'X) = \text{Cov}(u'X) = u'Mu = 0$$

d'où  $u'X = 0$  p.s. et  $X \in \text{ker}(M)^\perp$  p.s., i.e.  $X \in \text{Im}(M)$ .  $\square$

Rappel : pour une matrice  $M$ ,  $\text{Im}(M) = \{Mx, x \in \mathbb{R}^d\}$ , i.e. l'ensemble des combinaisons linéaires des colonnes de la matrice  $M$ .

**Théorème du Rang** pour les matrices :

Si  $A$  est une matrice  $m \times n$  sur un corps  $K$ , alors  $\text{rg}(A) + \dim(\text{ker}(A)) = d$  où  $\text{rg}(A) = \dim(\text{Im}(A))$ .

## 0.2 Vecteurs Gaussiens

Rappels : On dit qu'une probabilité  $\mu$  sur  $\mathbb{R}$  est gaussienne si elle a pour densité  $f_{m,\sigma}$  où  $f_{m,\sigma^2}(x) = \frac{1}{\sqrt{2\pi\sigma^2}}e^{-\frac{1}{2\sigma^2}(x-m)^2}$ , i.e.  $\mu(B) = \int_B f_{m,\sigma^2}(x)d\lambda(x)$  avec  $\lambda$  la mesure de Lebesgue sur  $\mathbb{R}$  et  $B \in \mathcal{B}(\mathbb{R})$ ; ou si  $\mu = \delta_m$  (la mesure de Dirac, i.e.  $\delta_m(B) = \mathbf{1}_B(m)$  pour tout  $B \in \mathcal{B}(\mathbb{R})$ ).

### Définition 3

1. Un vecteur aléatoire  $X = (X_1, \dots, X_d)$ , à valeurs dans  $\mathbb{R}^d$  défini sur  $(\Omega, \mathcal{F}, \mathbb{P})$ , est dit gaussien si, pour tout  $a \in \mathbb{R}^d$ ,

$$a'X = a_1X_1 + \dots + a_dX_d \text{ est une v.a.r. gaussienne.}$$

2. On appelle la loi gaussienne sur  $\mathbb{R}^d$  toute loi d'un vecteur gaussien.

Il est normal d'adjoindre les mesures de Dirac aux lois gaussiennes car la mesure  $\mathcal{N}(m, \sigma^2)$  converge étroitement vers  $\delta_m$ .

Rappel : on dit que la suite de mesures de probabilités  $(\mu_n)_n$  converge étroitement vers  $\mu$  si pour tout  $f \in C_b^0(\mathbb{R}^d; \mathbb{R})$   $\lim_n \int_{\mathbb{R}^d} f d\mu_n = \int_{\mathbb{R}^d} f d\mu$ ; par exemple on dit (par définition) que  $(X_n)_n$  converge en loi vers  $X$  ssi  $(\mu_{X_n})_n$  converge étroitement vers  $\mu_X$ . Une v.a.r. est dite gaussienne si sa loi est gaussienne.

Remarques et Exemples :

Pour tout  $k \in \{1, \dots, d\}$ ,  $X_k$  est une v.a.r. gaussienne mais cela ne suffit pas à assurer que le vecteur  $X$  est gaussien ; en effet  $X_k = a'X$  avec  $a = (0, 0, \dots, 1, 0, 0, \dots, 0) \in \mathbb{R}^d$  où  $k$ -ème élément de  $a$  vaut 1. Par exemple  $Y = 2X_3 - \pi X_5$  est aussi une v.a.r. gaussienne, en effet  $Y = a'X$  avec  $a = (0, 0, 2, 0, -\pi, 0, 0, \dots, 0) \in \mathbb{R}^d$ .

Le vecteur aléatoire constant de  $\mathbb{R}^d$ ,  $X = 0$  est un vecteur gaussien ; en effet d'après la remarque sur la convergence étroite 0 est une v.a.r. gaussienne.

**Propriété 6** Soient  $d \in \mathbb{N}^*$  et  $X_1, X_2, \dots, X_d$  une suite de v.a.r. i.i.d. de loi  $\mathcal{N}(0, 1)$  et  $X = (X_1, X_2, \dots, X_d)$ . Alors  $a'X \sim \mathcal{N}(0, a'a)$ , et donc c'est un vecteur gaussien.

*Preuve:* Comme la loi d'une variable aléatoire se caractérise par la détermination de sa fonction caractéristique (ou sa fonction de répartition ou sa fonction de densité) d'où montrons que pour tout  $u \in \mathbb{R}$ ,  $\phi_{a'X}(u) \stackrel{\text{déf}}{=} \mathbb{E}[e^{iu(a'X)}]$  est de la forme  $e^{imu - \frac{1}{2}u^2\sigma^2}$  (i.e. la variable aléatoire est gaussienne d'espérance  $m$  et de variance  $\sigma^2$ ).

Soit  $u \in \mathbb{R}$ . On a

$$\begin{aligned} \phi_{a'X}(u) &= \mathbb{E}[e^{iu(a'X)}] = \mathbb{E}\left[\prod_{j=1}^d e^{iua_j X_j}\right] \\ &= \prod_{j=1}^d \mathbb{E}[e^{iua_j X_j}] \text{ (car les } X_j \text{ sont indépendants)} \\ &= \prod_{j=1}^d \phi_{X_j}(ua_j) = \prod_{j=1}^d e^{-\frac{1}{2}(ua_j)^2} = e^{-\frac{1}{2}u^2 a'a}. \end{aligned}$$

Finalement  $a'X$  est une variable aléatoire réelle gaussienne d'espérance 0 et de variance  $a'a$  ; et donc  $X$  est un vecteur aléatoire gaussien à valeurs dans  $\mathbb{R}^d$ .  $\square$

La notion de vecteurs gaussiens est invariante par transformation linéaire, plus précisément :

**Propriété 7** Soit  $X$  un vecteur gaussien à valeurs dans  $\mathbb{R}^d$  de moyenne  $m \in \mathbb{R}^d$  et de matrice de covariances  $K$ . Pour tous  $b \in \mathbb{R}^r$  et  $M$  matrice  $r \times d$ ,  $Y = b + MX$  est un vecteur gaussien à valeurs dans  $\mathbb{R}^r$  de moyenne  $b + Mm$  et de matrice de covariance  $MKM'$ .

*Preuve:* Soit  $a \in \mathbb{R}^r$ . On sait que pour tout  $\tilde{a} \in \mathbb{R}^d$ ,  $\tilde{a}'X$  est une v.a.r. gaussienne, donc en prenant  $\tilde{a} = M'a \in \mathbb{R}^d$  on obtient que  $\tilde{a}'X = (a'M)X$  est une v.a.r. gaussienne. Comme  $a'b$  est une constante d'où  $a'Y = a'b + (a'M)X$  est une v.a.r. gaussienne. Finalement  $Y$  est un vecteur gaussien à valeurs dans  $\mathbb{R}^r$ , de moyenne  $\mathbb{E}[Y] = b + M\mathbb{E}[X] =$

$b + Mm$  et de matrice de covariances  $\text{Cov}(Y) = \text{Cov}(b + MX) = \text{Cov}(MX) = M\text{Cov}(X)M' = MKM'$ .  $\square$

**Théorème 4** Soit  $X$  un vecteur aléatoire de moyenne  $m$  et de matrice de covariances  $K$ . Le vecteur  $X$  est gaussien ssi sa fonction caractéristique est donnée par

$$\phi_X(t) = e^{it'm - \frac{1}{2}t'Kt}, \forall t. \quad (4)$$

*Preuve:* Supposons que  $X$  est un vecteur gaussien. Alors d'après la Proposition 7 on a  $t'X \sim \mathcal{N}(t'm, t'Kt)$  et  $\phi_{t'X}(1) = \mathbb{E}[e^{it'X}] = e^{it'm - \frac{1}{2}t'Kt}$ , d'où (4).

Supposons (4). Alors  $\phi_{a'X}(u) = \mathbb{E}[e^{iuu'a'X}] = e^{iuu'a'm - \frac{1}{2}u^2a'Ka}$  donc  $a'X$  est une v.a.r. gaussienne et  $X$  est un vecteur gaussien.  $\square$

Toute loi gaussienne sur  $\mathbb{R}^d$  est donc déterminée par sa moyenne  $m$  et sa matrice de covariances  $K$ . On note  $\mathcal{N}_d(m, K)$  une telle loi. On a vu dans la Propriété que  $\mathcal{N}_d(0, I_d)$  existe, en effet on a vu un vecteur aléatoire  $X$  tel que  $\phi_X(a) = e^{ia'0 - \frac{1}{2}a'I_d a}$ , mais on n'a pas établi l'existence dans le cas général. On a,

**Propriété 8** Soit  $K$  une matrice  $d \times d$  symétrique semi-définie positive. Il existe une matrice  $d \times d$  symétrique semi-définie positive  $A$  telle que  $K = AA'$ .

*Preuve:* Soient  $\lambda_1, \dots, \lambda_d$  les valeurs propres de  $K$  qui sont positives. Il existe une matrice orthogonale  $C$  (i.e.  $CC' = C'C = I_d, C^{-1} = C'$ ) telle que  $C'KC = D := \text{diag}(\lambda_1, \dots, \lambda_d)$  où  $\text{diag}(\lambda_1, \dots, \lambda_d)$  désigne la matrice diagonale ayant  $\lambda_1, \dots, \lambda_d$  sur la diagonale. On a alors  $CDC' = K$ . Soit  $\Delta = \text{diag}(\sqrt{\lambda_1}, \dots, \sqrt{\lambda_d})$ . On pose  $A = C\Delta C'$ . On a

$$AA' = C\Delta C'(C\Delta C')' = C\Delta C'C\Delta C' = CDC' = K.$$

$\square$

Appliquant la Propriété 7, on a que, si  $X \sim \mathcal{N}_d(0, I_d)$ ,  $Y = m + AX \sim \mathcal{N}_d(m, K)$ . On a montré

**Théorème 5** Étant donné  $m \in \mathbb{R}^d$  et une matrice  $d \times d$  symétrique semi-définie positive  $K$ , il existe une et une seule loi gaussienne sur  $\mathbb{R}^d$  de moyenne  $m$  et de matrice de covariance  $K$ .

### 0.2.1 Vecteurs gaussiens et Indépendance

**Théorème 6** Soient  $X = (X_1, \dots, X_d)$  un vecteur gaussien. Alors on a,

i) les v.a.r.  $X_1, \dots, X_d$  sont indépendantes si et seulement si la matrice de covariances  $\text{Cov}(X)$  est diagonale.

ii) en posant

$$Y_1 = (X_1, \dots, X_{d_1})', Y_2 = (X_{d_1+1}, \dots, X_{d_2})', \dots, Y_r = (X_{d_{r-1}+1}, \dots, X_d)'$$

les vecteurs aléatoires  $Y_1, Y_2, \dots, Y_r$  sont indépendants si et seulement si  $\text{Cov}(X)_{i,j} = 0$  pour tous  $i, j$  n'appartenant pas au même intervalle  $[1, d_1], [d_1 + 1, d_2], \dots, [d_{r-1} + 1, d]$ .

*Preuve:* Seule la suffisance demande une preuve.

i) Supposons que  $\text{Cov}(X)$  est diagonale. On a  $\text{Cov}(X) = \text{diag}(\sigma_1^2, \dots, \sigma_d^2)$  où  $\sigma_k^2 = \text{Var}(X_k)$ . Alors, notant  $m = \mathbb{E}[X]$ ,

$$\phi_X(t) = e^{i \sum_{k=1}^d m_k t_k - \frac{1}{2} \sum_{k=1}^d \sigma_k^2 t_k^2} = \prod_{k=1}^d e^{i m_k t_k - \frac{1}{2} \sigma_k^2 t_k^2} = \phi_{X_1}(t_1) \cdots \phi_{X_d}(t_d)$$

et donc les  $X_k$  sont indépendants.

ii) Supposons la condition sur les covariances réalisées. Elle implique, pour tous  $u_1 \in \mathbb{R}^{d_1}, u_2 \in \mathbb{R}^{d_2-d_1}, \dots$  et  $p \neq q$ ,  $\text{Cov}(u_p' Y_p, u_q' Y_q) = 0$ . Donc, d'après i), les v.a.r.  $u_1' Y_1, \dots, u_r' Y_r$  sont indépendantes. On a alors

$$\phi_{Y_1, \dots, Y_r}(u_1, \dots, u_r) = \mathbb{E}[e^{i(u_1' Y_1 + \dots + u_r' Y_r)}] = \mathbb{E}[e^{i u_1' Y_1}] \cdots \mathbb{E}[e^{i u_r' Y_r}],$$

i.e.  $\phi_{Y_1, \dots, Y_r}(u_1, \dots, u_r) = \prod_{k=1}^r \phi_{Y_k}(u_k)$  et donc les vecteurs aléatoires  $Y_1, \dots, Y_r$  sont indépendants.  $\square$

**Remarque :** Attention à l'utilisation du Théorème 6. On peut avoir  $X$  et  $Y$  v.a.r. gaussiennes,  $\text{Cov}(X, Y) = 0$  sans que les v.a.  $X$  et  $Y$  soient indépendantes, par exemple prendre  $Y = \varepsilon X$  où  $\varepsilon$  suit une loi de Bernoulli indépendante de  $X$  telle que  $\mathbb{P}(\varepsilon = \pm 1) = 2^{-1}$ ; en effet si  $(X, Y)$  était un vecteur gaussien on aurait, avec  $\alpha = 1$  et  $\beta = 1$ ,  $\alpha X + \beta Y = X + \varepsilon Y$  variable aléatoire gaussienne et donc par continuité de la variable aléatoire gaussienne  $\mathbb{P}(X + \varepsilon Y = 0) = 0$ , alors que  $\mathbb{P}(X + \varepsilon Y) = \mathbb{P}((1 + \varepsilon)X = 0) = \mathbb{P}(1 + \varepsilon = 0) + \mathbb{P}(X = 0) - \mathbb{P}(1 + \varepsilon = 0, X = 0) = \frac{1}{2} + 0 - \mathbb{P}(1 + \varepsilon = 0)\mathbb{P}(X = 0) = \frac{1}{2} + 0 - \frac{1}{2} \times 0 = \frac{1}{2} \neq 0$ .

Rappelons qu'une variable aléatoire  $X$  est continue de densité  $f_X$  si pour tout  $A \in \mathcal{B}(\mathbb{R})$ ,  $\mathbb{P}(X \in A) = \int_A f_X(x) dx$ .

### 0.2.2 Le cas non dégénéré

On dit que la loi  $\mathcal{N}_d(m, K)$  est non dégénérée si  $\det(K) \neq 0$ . Dans ce cas :

**Théorème 7** Si  $X \sim \mathcal{N}_d(m, K)$  et si  $\det(K) \neq 0$ ,  $X$  admet la densité

$$f_X(x) = (2\pi)^{-\frac{d}{2}} (\det(K))^{-\frac{1}{2}} e^{-\frac{1}{2}(x-m)'K^{-1}(x-m)}.$$

*Preuve:* Soit  $A$  tel que  $K = AA'$ , on a  $\det(A) = (\det(K))^{\frac{1}{2}}$  et  $A$  est inversible. Soit  $Y \sim \mathcal{N}_d(0, I_d)$  un vecteur gaussien de densité

$(2\pi)^{-\frac{d}{2}} e^{-\frac{1}{2}\|y\|^2}$ . On a, d'après la Propriété 7,  $X = m + AY \sim \mathcal{N}_d(m, K)$  et, pour toute fonction  $f \in \mathcal{B}^+(\mathbb{R}^d)$ ,

$$\mathbb{E}[f(X)] = \mathbb{E}[f(m + AY)] = (2\pi)^{-\frac{d}{2}} \int f(m + Ay) e^{-\frac{1}{2}\|y\|^2} dy.$$

On effectue le changement de variable  $y = h^{-1}(x)$  où  $x = h(y) := m + Ay$  qui est bien un  $C^1$ -difféomorphisme, et donc  $y = A^{-1}(x - m)$ , ce qui permet d'obtenir pour tous  $i, j \in \{1, \dots, d\}$ ,  $K_{i,j} := \frac{\partial(h^{-1})^{(i)}}{\partial x_j}(x) = \frac{\partial}{\partial x_j} \sum_{k=1}^d (L_i(A^{-1}))^k x_k = (L_i(A^{-1}))^j = (A^{-1})_{i,j}$ , et donc  $(K_{i,j})_{1 \leq i, j \leq d} = A^{-1}$ , ce qui permet d'écrire  $|\det(K_{i,j})_{1 \leq i, j \leq d}| = \det(A^{-1})$ . D'où

$$\mathbb{E}[f(X)] = (2\pi)^{-\frac{d}{2}} \det(A^{-1}) \int_{\mathbb{R}^d} f(x) e^{-\frac{1}{2}(x-m)'(A^{-1})'A^{-1}(x-m)} dx.$$

Comme  $K^{-1} = (AA')^{-1} = (A^{-1})'A^{-1}$  et donc  $\det(A^{-1}) = (\det(K))^{-\frac{1}{2}}$ , d'où la formule de la densité ci-dessus.  $\square$

# Éspérances Conditionnelles

## 0.3 Rappels sur Probabilité Conditionnelle et Indépendance

**Définition 4 (Probabilité Conditionnelle)** Pour tous événements  $A, B \in \mathcal{F}$  t.q.  $\mathbb{P}(B) \neq 0$ , la **probabilité conditionnelle** de  $A$  sachant  $B$  est définie par

$$\mathbb{P}(A|B) = \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)}. \quad (5)$$

**Exemple 1 (Formule de probabilités totales)** Pour tout événement  $A \in \mathcal{F}$  et toute partition  $(B_i)_{i \in \mathbb{N}^*} \in \mathcal{F}^{\mathbb{N}^*}$  de  $\Omega$  t.q.  $\mathbb{P}(B_i) > 0$  pour tout  $i \in \mathbb{N}^*$ ,

$$\mathbb{P}(A) = \sum_{i \in \mathbb{N}^*} \mathbb{P}(A \cap B_i) = \sum_{i \in \mathbb{N}^*} \mathbb{P}(A|B_i)\mathbb{P}(B_i),$$

où la première égalité et la deuxième égalité viennent respectivement de  $\sigma$ -additivité dénombrable de  $\mathbb{P}$  et de (5).

**Définition 5 (Indépendance des événements)** Soient  $n \geq 2$  et  $(\Omega, \mathcal{F}, \mathbb{P})$  un espace probabilisé. Deux événements  $A$  et  $B$  de  $\mathcal{F}$  sont dits **indépendants** (par rapport à  $\mathbb{P}$ ) si  $\mathbb{P}(A \cap B) = \mathbb{P}(A)\mathbb{P}(B)$ .

Une famille quelconque d'événements  $A_i \in \mathcal{F}$ ,  $i \in I$ , est mutuellement indépendante si pour tout  $J \subset I$  fini

$$\mathbb{P}\left(\bigcap_{j \in J} A_j\right) = \prod_{j \in J} \mathbb{P}(A_j),$$

est une famille d'événements deux à deux indépendants si pour tout  $J \subset I$  fini et pour tous  $i, j \in J$ ,

$$\mathbb{P}(A_i \cap A_j) = \mathbb{P}(A_i)\mathbb{P}(A_j).$$

**Définition 6 (Indépendance de tribus)** Soient  $n \geq 2$  et  $(\Omega, \mathcal{F}, \mathbb{P})$  un espace probabilisé. Une famille quelconque de sous-tribus  $\mathcal{G}_i \subset \mathcal{F}$ ,  $i \in I$ , est mutuellement indépendante si toute famille d'événements  $G_i \in \mathcal{G}_i$ ,  $i \in I$ , est mutuellement indépendante.

**Définition 7 (Indépendance de variables aléatoires)** Soient  $n \geq 2$  et  $(\Omega, \mathcal{F}, \mathbb{P})$  un espace probabilisé. Une famille quelconque de variables

**Exemple 2** On lance un dé à 6 et on note  $A =$  "obtenir un nombre pair" et  $B =$  "obtenir un multiple de 3". On a :  $\mathbb{P}(A) = \frac{1}{2}$ ,  $\mathbb{P}(B) = \frac{1}{3}$  et  $\mathbb{P}(A \cap B) = \frac{1}{6}$ . Les événements  $A$  et  $B$  sont indépendants.

On lance deux dés rouges et verts, et on note  $A =$  "La somme des numéros fait 6" et  $B =$  "Sur le dé rouge, on obtient un nombre pair". Un petit dénombrement de tous les cas possibles montre que  $\mathbb{P}(A) = \frac{5}{36}$ ,  $\mathbb{P}(B) = \frac{18}{36}$  et  $\mathbb{P}(A \cap B) = \frac{2}{36}$ . Les événements  $A$  et  $B$  ne sont pas indépendants.

**Exemple 3** Bien sûr, des événements mutuellement indépendants sont indépendants deux à deux, la réciproque est fautive, en effet en lançant 2 fois une pièce de monnaie et en posant  $A =$  "on obtient pile au premier lancer",  $B =$  "on obtient face au deuxième lancer" et  $C =$  "on obtient la même chose aux deux lancers", il vient très facilement  $\mathbb{P}(A) = \mathbb{P}(B) = \mathbb{P}(C) = \frac{1}{2}$ ,  $\mathbb{P}(A \cap B) = \mathbb{P}(A \cap C) = \mathbb{P}(B \cap C) = \frac{1}{4}$ ,  $\mathbb{P}(A \cap B \cap C) = 0$ ; les événements  $A$ ,  $B$  et  $C$  sont donc deux à deux indépendants, mais ne sont pas mutuellement indépendants.

aléatoires réelles  $X_i, i \in I$ , sur  $(\Omega, \mathcal{F}, \mathbb{P})$  et à valeurs dans  $(E, \mathcal{B})$  est (mutuellement) indépendante si la famille des tribus engendrées par les  $X_i$  est (mutuellement) indépendante, i.e. pour tout  $J \subset I$  fini, et tous les ensembles mesurables  $B_j \in \mathcal{B}, j \in J$ ,

$$\mathbb{P}(\cap_{j \in J} \{X_j \in B_j\}) = \prod_{j \in J} \mathbb{P}(X_j \in B_j).$$

**Exemple 4** Considérons l'exemple du dé, on a  $(\Omega, \mathcal{F}, \mathbb{P})$  où  $\Omega = \{1, 2, 3, 4, 5, 6\}$ ,  $\mathcal{F} = \mathcal{P}(\Omega)$  et  $\mathbb{P}(\{\omega\}) = \frac{1}{6}$  pour tout  $\omega \in \Omega$ . Soient

$$A_1 = \{1, 2, 3\}, A_2 = \{2, 5\}, X_i = \mathbf{1}_{A_i}, \mathcal{F}_i = \sigma(\{A_i\}), i = 1, 2.$$

Indépendance des événements :  $\mathbb{P}(A_1 \cap A_2) = \mathbb{P}(A_1)\mathbb{P}(A_2) = \frac{1}{6}$ , donc  $A_1$  et  $A_2$  sont indépendants.

Indépendance des variables aléatoires : remarquons que  $\sigma(X_1) = \{\emptyset, \Omega, A_1, A_1^c\}$  et  $\sigma(X_2) = \{\emptyset, \Omega, A_2, A_2^c\}$ . Par calculs élémentaires  $\mathbb{P}(B_1)\mathbb{P}(B_2) = \mathbb{P}(B_1 \cap B_2)$  pour tous  $B_1 \in \sigma(X_1), B_2 \in \sigma(X_2)$ , d'où  $X_1$  et  $X_2$  sont indépendants.

Pour montrer que deux sous-tribus  $\mathcal{F}_1$  et  $\mathcal{F}_2$  sont indépendantes, il faut montrer que tous les événements  $B_1, B_2$  tels que  $B_1 \in \mathcal{F}_1$  et  $B_2 \in \mathcal{F}_2$  sont indépendants ; en notons que  $\mathcal{F}_i$  coïncide avec  $\sigma(X_i)$ , pour  $i \in \{1, 2\}$ , le précédent calcul permet donc de dire que  $\mathcal{F}_1$  et  $\mathcal{F}_2$  sont indépendants.

De ce qui précède on voit que si deux tribus  $\mathcal{F}_1$  et  $\mathcal{F}_2$  sont indépendantes, alors toute variable aléatoire  $\mathcal{F}_1$ -mesurable est indépendante de toute autre variable aléatoire  $\mathcal{F}_2$ -mesurable.

## 0.4 Espérance Conditionnelle <sup>1</sup>

### 0.4.1 Conditionnement par rapport à un événement

#### Définition 8 (Espérance conditionnelle par rapport à un événement)

Pour tout variable aléatoire  $X \in L^1$  sur  $(\Omega, \mathcal{F}, \mathbb{P})$  et pour tout événement  $B \in \mathcal{F}$  tel que  $\mathbb{P}(B) > 0$ , l'espérance conditionnelle de  $X$  sachant  $B$ , que l'on note par  $\mathbb{E}[X|B]$ , est défini par

$$\mathbb{E}[X|B] = \frac{\mathbb{E}[X\mathbf{1}_B]}{\mathbb{P}(B)}.$$

### 0.4.2 Conditionnement par rapport à une variable aléatoire discrète

Soit  $(\Omega, \mathcal{F}, \mathbb{P})$  un espace de probabilité. Soient  $X$  une variable aléatoire  $L^1(\Omega)$  (donc l'espérance existe) et  $Z : \Omega \rightarrow \{z_i\}_{i \in I} \subset \mathbb{R}^I$ , où  $I \subset \mathbb{N}^*$ , une variable aléatoire discrète avec  $i \neq j \Rightarrow z_i \neq z_j$ . Sachant que nous avons défini l'espérance conditionnelle de  $X$  par rapport à un événement et que pour tout  $B \in \mathcal{B}(\mathbb{R}), \{Z \in B\}$  est obtenu par

1. M. Capinski and P.E. Kopp. *Measure, Integral and Probability*. Springer Undergraduate Mathematics Series. Springer London, 2013. ISBN 9781447106456. URL <https://books.google.fr/books?id=5d6PBAAAQBAJ>

les  $\{Z = z_i\}, i \in I$ , d'où la définition de l'espérance conditionnelle suivante :

**Définition 9 (Espérance conditionnelle par rapport à une v.a.r. discrète)**

Soient  $I \subset \mathbb{N}^*$  et  $X \in L^1(\Omega)$  et  $Z$  une v.a. discrète prenant valeurs dans  $\{z_i\}_{i \in I} \subset \mathbb{R}^I$  avec  $i \neq j \Rightarrow z_i \neq z_j$ . L'espérance conditionnelle de  $X$  par rapport à  $Z$  est définie par la variable aléatoire discrète  $\mathbb{E}[X|Z] : \Omega \rightarrow \mathbb{R}$  suivante :

$$\mathbb{E}[X|Z] = \sum_{i \in I} \mathbb{E}[X|\{Z = z_i\}] \mathbf{1}_{\{Z=z_i\}}.$$

Notez que  $\mathbb{E}[X|Z] \in L^1(\Omega)$ , en effet  $\mathbb{E}[|\mathbb{E}[X|Z]|] \leq \sum_{i \in I} \mathbb{E}[|X| \mathbf{1}_{\{Z=z_i\}}] = \mathbb{E}[|X|] < +\infty$ .

**Exemple 5** Voir TD1 pour l'exercice.

**Théorème 8** Si  $X \in L^1(\Omega)$  et  $Z$  est une v.a. discrète, alors

- i)  $\mathbb{E}[X|Z]$  est  $\sigma(Z)$ -mesurable.
- ii)  $\mathbb{E}[\mathbb{E}[X|Z] \mathbf{1}_A] = \mathbb{E}[X \mathbf{1}_A], \forall A \in \sigma(Z)$ .

*Preuve:* On pose  $B_i = \{Z = z_i\}$  et donc  $(B_i)_{i \in I}$  est une partition de  $\Omega$ , i.e. les  $B_i$  sont disjoints et  $\Omega = \cup_{i \in I} B_i$ . On pose  $\mathcal{G} = \sigma(Z)$ , et il est clair (montrer le) que  $\sigma(Z) = \sigma(\{B_i, i \in I\})$ , i.e.  $\mathcal{G} = \sigma(\{B_i, i \in I\})$ .

Montrons que  $\sigma(\{B_i, i \in I\}) = \{ \cup_{j \in J} B_j, J \subset I \} := K$ . Il est facile de montrer que  $K$  est une tribu contenant les  $B_i, i \in I$ , donc  $\mathcal{G}$  étant la plus petite tribu contenant les  $B_i, i \in I$  on obtient que  $\mathcal{G} \subset K$ . Or  $A \in K$  implique clairement que  $A \in \mathcal{G}$ , d'où  $\mathcal{G} = K$ , i.e. que  $\sigma(\{B_i, i \in I\}) = \{ \cup_{j \in J} B_j, J \subset I \}$ . Finalement

On pose  $\mathbb{E}[X|Z] := \sum_{i \in I} \mathbb{E}[X|B_i] \mathbf{1}_{B_i}$  et donc elle est  $\sigma(Z)$ -mesurable comme étant une somme de v.a.  $\sigma(Z)$ -mesurables. Pour le second point il est aisé de vérifier pour tout les  $A = B_i \in \sigma(Z)$  que  $\mathbb{E}[\mathbb{E}[X|Z] \mathbf{1}_A] = \mathbb{E}[X \mathbf{1}_A]$ , mais comme un  $A \in \sigma(Z)$  s'écrit comme étant  $\cup_{j \in J} B_j$  d'où par union disjoints d'événements  $B_j$  on obtient le second point vérifié.  $\square$

**Exemple 6** Voir l'exercice du TD pour une application numérique du précédent théorème.

## 0.5 Conditionnement par rapport à une variable aléatoire quelconque

Si la v.a.  $Z$  est discrète, nous pouvons définir  $\mathbb{E}[X|Z]$  facilement, mais lorsque  $Z$  est une variable aléatoire quelconque (qui discrète ou continue), il n'est pas facile d'écrire une formule explicite pour  $\mathbb{E}[X|Z]$  en générale.

Une voie naturelle serait d'écrire  $\mathbb{E}[X|Z] = \int x \frac{f_{X,Z}(x,z)}{f_Z(z)} dx$ , mais ce n'est pas utilisable si les densités  $f_{X,Z}$  et  $f_Z$  n'existent pas.

Toutefois **Théorème 8** nous suggère une voie pour définir l'espérance conditionnelle par rapport à une variable aléatoire quelconque :

**Définition 10 (Espérance conditionnelle par rapport à une v.a. quelconque)**

Soient  $X \in L^1(\Omega)$  et  $Z$  une v.a. quelconque. Alors l'espérance conditionnelle de  $X$  par rapport à  $Z$  est définie comme étant une v.a. que l'on note par  $\mathbb{E}[X|Z]$ , telle que :

- i)  $\mathbb{E}[X|Z]$  est  $\sigma(Z)$ -mesurable,
- ii) Pour tout  $A \in \sigma(Z)$ ,

$$\mathbb{E}[\mathbb{E}[X|Z]\mathbf{1}_A] = \mathbb{E}[X\mathbf{1}_A], \forall A \in \sigma(Z) \quad (6)$$

Comme l'espérance conditionnelle est définie implicitement par (6) au lieu d'une formule explicite, nous aurons besoin de justifier une telle définition en montrant que la v.a.  $\mathbb{E}[X|Z]$  est caractérisée de façon unique ; comme il s'agit d'une v.a., cette unicité dépend donc de la mesure de probabilité  $\mathbb{P}$  à travers la notion de  $\mathbb{P}$ -presque sûrement.

**Définition 11 (Égalité  $\mathbb{P}$ -presque sûre)**

1. Deux événements  $A, B \in \mathcal{F}$  sont égaux  $\mathbb{P}$ -presque sûrement ( $\mathbb{P}$ -p.s. ou p.s.) si  $\mathbb{P}((A \setminus B) \cup (B \setminus A)) = 0$ , i.e., la partie non commune de  $A$  et de  $B$  est de probabilité 0.
2. Deux v.a.  $X$  et  $Y$  définies sur  $(\Omega, \mathcal{F}, \mathbb{P})$  sont dites égales  $\mathbb{P}$ -presque sûrement si  $\mathbb{P}(X = Y) = 1$ , ce que l'on note par  $X = Y$ ,  $\mathbb{P}$ -p.s.

**Exemple 7** Notons que deux événements  $A$  et  $B$  sont égaux p.s. n'impliquent pas qu'ils sont les mêmes. On sait seulement que les événements  $A \setminus B$  et  $B \setminus A$  sont de mesures nulles. Par exemple considérons  $A = ]0, 0.5[$  et  $B = ]0, 0.5]$  sur  $([0, 1], \mathcal{B}([0, 1]), \lambda_{[0, 1]})$ . Il est clair que  $A = B$  p.s. mais  $A \neq B$ .

Pour le cas de variables aléatoires, soient  $\Omega = \{\omega_1, \omega_2\}$ ,  $\mathcal{F} = \mathcal{P}(\Omega)$ ,  $\mathbb{P}$  défini sur  $\mathcal{F}$  par  $\mathbb{P}(\{\omega_1\}) = 1$ . Supposons que  $X_i : \Omega \rightarrow \mathbb{R}$  est une v.a. avec  $X_i = \mathbf{1}_{\{\omega_1\}} + (i + 1)\mathbf{1}_{\{\omega_2\}}$ ,  $i \in \{1, 2\}$ ; alors  $X_1 = X_2$  p.s. mais  $X_1 \neq X_2$ .

**Théorème 9 (Unicité de l'espérance conditionnelle)**  $\mathbb{E}[X|Z]$  est unique, c'est-à-dire si  $X = X'$  p.s. alors  $\mathbb{E}[X|Z] = \mathbb{E}[X'|Z]$ .

La preuve repose sur le lemme suivant :

**Lemme 1** Soit  $(\Omega, \mathcal{F}, \mathbb{P})$  un espace de probabilité et  $\sigma(Z) \in \mathcal{F}$ . Si  $Y$  est une v.a.  $\sigma(Z)$ -mesurable et  $\mathbb{E}[Y\mathbf{1}_A] = 0$ , pour tout  $A \in \sigma(Z)$ ; alors  $Y = 0$  p.s. C'est-à-dire,  $\mathbb{P}(Y = 0) = 1$ .

*Preuve:* Soient  $n \geq 1$  et  $A = \{Y \geq \frac{1}{n}\}$ . On a  $A = \{Y \in [\frac{1}{n}, +\infty[) \in \sigma(Z)$  et  $0 \leq \mathbb{E}[\frac{1}{n}\mathbf{1}_A] \leq \mathbb{E}[Y\mathbf{1}_A] = 0$ , d'où  $\mathbb{P}(Y \geq \frac{1}{n}) = 0$ ; de la même façon  $\mathbb{P}(Y \leq -\frac{1}{n}) = 0$  et donc  $\mathbb{P}(A_n) = 1$  où  $A_n = \{-\frac{1}{n} < Y < \frac{1}{n}\}$ . Comme  $(A_n)_{n \in \mathbb{N}^*}$  est une suite d'événements décroissante, i.e.  $A_{n+1} \subset A_n$ , et que  $\{Y = 0\} = \bigcap_{n \in \mathbb{N}^*} A_n$  d'où

$$\mathbb{P}(Y = 0) = \mathbb{P}(\bigcap_{n=1}^{+\infty} A_n) = \lim_{m \rightarrow +\infty} \mathbb{P}(\bigcap_{n=1}^m A_n) = \lim_{m \rightarrow +\infty} \mathbb{P}(A_m) = 1. \quad (7)$$

□

*Preuve:* (Théorème 9) Supposons que  $X = X'$  p.s., i.e.  $\mathbb{P}(X = X') = 1$ . On veut montrer que  $\mathbb{E}[X|Z] = \mathbb{E}[X'|Z]$  p.s. On pose  $Y = \mathbb{E}[X|Z] - \mathbb{E}[X'|Z]$  qui est par  $\sigma(Z)$ -mesurabilité des deux espérances, est  $\sigma(Z)$ -mesurable. Pour tout  $A \in \sigma(Z)$ ,  $\mathbb{E}[Y\mathbf{1}_A] = 0$ , donc grâce au lemme précédent,  $Y = 0$  p.s. i.e.  $\mathbb{E}[X|Z] = \mathbb{E}[X'|Z]$  p.s. □

**Exemple 8** Voir TD2.

## 0.6 Conditionnement par rapport à une tribu

Dans les définitions précédentes nous conditionnions par rapport aux ensembles de  $\sigma(Z)$ , nous pouvons généraliser la définition de l'espérance conditionnelle par rapport à une tribu :

### Définition 12 (Espérance conditionnelle par rapport à une tribu)

Soient  $(\Omega, \mathcal{F}, \mathbb{P})$  un espace de probabilité,  $X \in L^1(\Omega)$  et soit  $\mathcal{G} \subset \mathcal{F}$  une sous-tribu. Alors l'espérance conditionnelle de  $X$  par rapport à  $\mathcal{G}$ , que l'on note par  $\mathbb{E}[X|\mathcal{G}]$ , est définie comme étant une v.a. satisfaisant aux deux conditions suivantes :

- i)  $\mathbb{E}[X|\mathcal{G}]$  est une v.a.  $\mathcal{G}$ -mesurable
- ii) Pour tout  $A \in \mathcal{G}$ ,

$$\mathbb{E}[\mathbb{E}[X|\mathcal{G}]\mathbf{1}_A] = \mathbb{E}[X\mathbf{1}_A]. \quad (8)$$

Notons que différentes variables aléatoires peuvent générer une même tribu. Par exemple, sur l'univers  $\Omega = \{H, T\}$ , soient  $X_1 = \mathbf{1}_{\{H\}}$  et  $X_2 = \mathbf{1}_{\{T\}}$ . Alors  $X_1$  et  $X_2$  génèrent la même tribu  $\mathcal{F} = \{\emptyset, \{H\}, \{T\}, \Omega\}$ . C'est pourquoi l'espérance conditionnelle par rapport à une tribu est plus générale que l'espérance conditionnelle par rapport à une variable aléatoire.

Remarquer que l'unicité de l'espérance conditionnelle se démontre avec le même raisonnement utilisé dans la Preuve du **Théorème 9**.

**Exemple 9** Si  $\mathcal{G} = \{\emptyset, \Omega\}$ , alors  $\mathbb{E}[X|\mathcal{G}] = \mathbb{E}[X]$  p.s.

Pour la preuve, voir les TDs.

**Exemple 10** Pour tout  $B \in \mathcal{G}$ , on a  $\mathbb{E}[\mathbb{E}[X|\mathcal{G}]|B] = \mathbb{E}[X|B]$ .

Pour la preuve voir les TDs.

## 0.7 Dérivé de Radon-Nikodým

Nous allons montrer l'existence de l'espérance conditionnelle, garantie par le Théorème de Radon-Nikodým.

**Définition 13 (Mesure absolument continue)** Soient  $\mu_1$  et  $\mu_2$  deux mesures de probabilité sur  $(\Omega, \mathcal{F})$  t.q.  $\mu_1(A) = 0 \Rightarrow \mu_2(A) = 0$  pour tout  $A \in \mathcal{F}$ . Alors la mesure  $\mu_2$  est dite absolument continue par rapport à  $\mu_1$ , et on note cela par  $\mu_2 \ll \mu_1$ .

**Exemple 11** Considérons l'espace mesurable  $(\Omega, \mathcal{F})$  où  $\Omega = \{1, 2, 3, 4, 5, 6\}$ ,  $\mathcal{F} = \mathcal{P}(\Omega)$ . Pour tout  $\omega \in \Omega$ , soient  $\mu_1(\{\omega\}) = \frac{1}{6}$ ,  $\mu_2(\{\omega\}) = \frac{|\omega-3.5|}{9}$ ,  $\mu_3(\{\omega\}) = \frac{1}{3}\mathbf{1}_{\{\omega \geq 4\}}$  et  $\mu_4(\{\omega\}) = \frac{1}{3}\mathbf{1}_{\{\omega \leq 3\}}$ . Alors vérifier que  $\mu_1 \ll \mu_2$ ,  $\mu_2 \ll \mu_1$ ,  $\mu_3 \ll \mu_i$  et  $\mu_4 \ll \mu_i$  pour  $i \in \{1, 2\}$ .

**Exemple 12** Sur l'espace mesurable  $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$  on définit  $\mathbb{P}_N$  et  $\mathbb{P}_E$  par  $\mathbb{P}_N([a, b]) = F_N(b) - F_N(a)$  et  $\mathbb{P}_E([a, b]) = F_E(b) - F_E(a)$ , où  $F_N$  et  $F_E$  sont les fonctions de répartition respectives des lois normale standard et exponentielle standard. Alors  $\mathbb{P}_E \ll \mathbb{P}_N$  est vraie alors que  $\mathbb{P}_N \ll \mathbb{P}_E$  n'est pas vraie.

**Théorème 10 (Théorème de Radon-Nikodým)** Soit  $(\Omega, \mathcal{F})$  un espace mesurable. Soient  $\mathbb{P}, \mathbb{Q}$  deux mesures de probabilités sur  $(\Omega, \mathcal{F})$  telles que  $\mathbb{Q} \ll \mathbb{P}$ . Alors il existe une unique (au sens presque-sûrement) variable aléatoire strictement positive  $Y \in L^1_+(\mathbb{P})$  telle que

$$\mathbb{Q}(A) = \int_A Y d\mathbb{P}, \quad (9)$$

pour tout  $A \in \mathcal{F}$ . La variable aléatoire  $Y$  est appelée la dérivée Radon-Nikodým de  $\mathbb{Q}$  par rapport à  $\mathbb{P}$ , que l'on note par  $Y = \frac{d\mathbb{Q}}{d\mathbb{P}}$ .

**Théorème 11 (Existence de l'espérance conditionnelle)** Soit  $(\Omega, \mathcal{F}, \mathbb{P})$  un espace de probabilité et  $\mathcal{G} \subset \mathcal{F}$  une sous-tribu. Alors pour toute v.a.  $X \in L^1(\Omega)$  il existe une v.a. (pas forcément positive, si  $X$  est positive  $X_{\mathcal{G}}$  l'est également (voir la preuve))  $X_{\mathcal{G}}$   $\mathcal{G}$ -mesurable t.q. pour tout  $A \in \mathcal{G}$ ,

$$\mathbb{E}[X\mathbf{1}_A] = \mathbb{E}[X_{\mathcal{G}}\mathbf{1}_A]. \quad (10)$$

$X_{\mathcal{G}}$  est l'espérance conditionnelle  $\mathbb{E}[X|\mathcal{G}]$ .

*Preuve:* 1. via Le Théorème de Radon-Nikodým :

On se donne une v.a. positive  $X \in L^1(\Omega, \mathcal{F})$  telle que  $\mathbb{E}[X] = 1$ . Soit  $\mathbb{Q} : \mathcal{F} \rightarrow [0, +\infty[$  défini par

$$\mathbb{Q}(A) = \int_A X d\mathbb{P},$$

pour tout  $A \in \mathcal{F}$ .

Tout d'abord  $\mathbb{Q}$  est bien une mesure de probabilité sur  $(\Omega, \mathcal{F})$ ; en effet  $\mathbb{Q}(\emptyset) = 0$ ,  $\mathbb{Q}(\Omega) = 1$  et  $\mathbb{Q}$  est  $\sigma$ -additive (c'est-à-dire que  $\mathbb{Q}(\cup_{k=1}^{+\infty} E_k) = \sum_{k=1}^{+\infty} \mathbb{Q}(E_k)$  où  $E_1, E_2, \dots \in \mathcal{F}$  sont deux à deux disjoints).  $\mathbb{Q}$  est telle que  $\mathbb{Q} \ll \mathbb{P}$  sur  $\mathcal{F}$ , c'est-à-dire absolument continu par rapport  $\mathbb{P}$  (voir la question 2 de l'Exercice 2 du TD6 de Probabilités).

Soit  $\mathbb{Q}^{\mathcal{G}}$  la restriction de  $\mathbb{Q}$  à  $\mathcal{G}$ ; elle est trivialement absolument continue par rapport à  $\mathbb{P}^{\mathcal{G}}$ , la restriction de  $\mathbb{P}$  à  $\mathcal{G}$ . Le Théorème 10 de Radon-Nikodým appliqué avec  $\mathbb{P}^{\mathcal{G}}$ ,  $\mathbb{Q}^{\mathcal{G}}$  définies sur  $(\Omega, \mathcal{G})$  et  $\mathbb{Q}^{\mathcal{G}} \ll \mathbb{P}^{\mathcal{G}}$  garantit l'existence d'une variable aléatoire  $X_{\mathcal{G}} = \frac{d\mathbb{Q}^{\mathcal{G}}}{d\mathbb{P}^{\mathcal{G}}} \in L^1_+(\Omega, \mathcal{G}, \mathbb{P}^{\mathcal{G}})$  et  $\mathcal{G}$ -mesurable. Pour tout  $A \in \mathcal{G}$ , on a

$$\mathbb{E}[X\mathbf{1}_A] = \mathbb{Q}[A] = \mathbb{Q}^{\mathcal{G}}(A) = \mathbb{E}_{\mathbb{P}^{\mathcal{G}}}[X_{\mathcal{G}}\mathbf{1}_A] = \mathbb{E}[X_{\mathcal{G}}\mathbf{1}_A]$$

où la dernière égalité vient du fait que  $X_{\mathcal{G}}\mathbf{1}_A$  est  $\mathcal{G}$ -mesurable. Par conséquent,  $X_{\mathcal{G}}$  est l'espérance conditionnelle  $\mathbb{E}[X|\mathcal{G}]$ .

Lorsque  $\mathbb{E}[X] \neq 1$ , il suffit de travailler avec  $\tilde{X} = \frac{1}{\mathbb{E}[X]}X$ , en effet  $\mathbb{E}[\tilde{X}] = 1$ . On obtient donc  $\tilde{X}_{\mathcal{G}} \in L^1_+(\Omega, \mathcal{G}, \mathbb{P})$  et donc  $X_{\mathcal{G}} = \mathbb{E}[X]\tilde{X}_{\mathcal{G}}$ . Mais pour faire toute cette démarche, il faut que  $\mathbb{E}[X] > 0$ ; ce n'est pas grave car on peut s'en passer de ce cas, en effet pour  $X \geq 0$  p.s. avec  $\mathbb{E}[X] = 0$  cela donne  $X = 0$  p.s. et donc  $X_{\mathcal{G}} = 0$  p.s.

Jusqu'à maintenant on avait supposé que  $X \geq 0$  p.s. Lorsque  $X$  n'est pas une v.a. positive, on écrit  $X = X^+ - X^-$  où  $X^+ = X\mathbf{1}_{X>0}$  et  $X^- = -X\mathbf{1}_{X\leq 0}$  qui sont des v.a. positives intégrables; en appliquant le résultat précédent à  $X^+$  et  $X^-$  on prouve l'existence de  $\mathbb{E}[X|\mathcal{G}]$ .  $\square$

## 0.8 Propriétés Générales des Espérances Conditionnelles

**Propriété 9** Soient  $X, Y \in L^1(\Omega, \mathcal{F}, \mathbb{P})$ ,  $(X_n)_{n \in \mathbb{N}^*} \in (L^1(\Omega, \mathcal{F}, \mathbb{P}))^{\mathbb{N}^*}$  et  $\mathcal{H}, \mathcal{G}$  deux sous-tribus de  $\mathcal{F}$ , alors

1.  $\mathbb{E}[aX + bY|\mathcal{G}] = a\mathbb{E}[X|\mathcal{G}] + b\mathbb{E}[Y|\mathcal{G}]$ , p.s. Linéarité.
2.  $\mathbb{E}[XY|\mathcal{G}] = X\mathbb{E}[Y|\mathcal{G}]$  si  $X$  est  $\mathcal{G}$ -mesurable et  $XY \in L^1(\Omega, \mathcal{F}, \mathbb{P})$ .  
Sortir ce qui est connu.
3.  $\mathbb{E}[X|\mathcal{G}] = X$  si  $X$  est  $\mathcal{G}$ -mesurable.
4.  $\mathbb{E}[X|\mathcal{G}] = \mathbb{E}[X]$  si  $X$  est indépendant de  $\mathcal{G}$ .
5.  $\mathbb{E}[\mathbb{E}[X|\mathcal{G}]|\mathcal{H}] = \mathbb{E}[X|\mathcal{H}] = \mathbb{E}[\mathbb{E}[X|\mathcal{H}]|\mathcal{G}]$  si  $\mathcal{H} \subset \mathcal{G}$  Propriété de tour.
6.  $\mathbb{E}[\mathbb{E}[X|\mathcal{G}]] = \mathbb{E}[X]$ .
7.  $\mathbb{E}[X|\mathcal{G}] \in L^1(\Omega, \mathcal{F}, \mathbb{P})$ . Intégrabilité.
8.  $X \geq 0$  p.s.  $\Rightarrow \mathbb{E}[X|\mathcal{G}] \geq 0$  p.s. Positivité.
9.  $X \leq Y$ , p.s.  $\Rightarrow \mathbb{E}[X|\mathcal{G}] \leq \mathbb{E}[Y|\mathcal{G}]$ , p.s. Monotonie.

10.  $\phi$  convexe,  $\phi(X) \in L^1(\Omega) \Rightarrow \phi(\mathbb{E}[X|\mathcal{G}]) \leq \mathbb{E}[\phi(X)|\mathcal{G}]$ , Inégalité de Jensen conditionnelle.

11. Si  $X \in L^p(\Omega)$  pour  $p \in [1, \infty[$ , alors  $\mathbb{E}[X|\mathcal{G}] \in L^p(\Omega)$  et

$$\|\mathbb{E}[X|\mathcal{G}]\|_{L^p(\Omega)} \leq \|X\|_{L^p(\Omega)}$$

où  $\|\cdot\|_{L^p(\Omega)} = (\mathbb{E}[|X|^p])^{1/p}$ .

12. Si  $0 \leq X_n \leq X_{n+1}$ , p.s. pour tout  $n \in \mathbb{N}^*$  et  $X_n \rightarrow X$ , p.s., alors  $\mathbb{E}[X_n|\mathcal{G}] \nearrow \mathbb{E}[X|\mathcal{G}]$ , p.s.. Théorème de Convergence Monotone conditionnelle.

13. Si  $0 \leq X_n$ , p.s., pour tout  $n \in \mathbb{N}^*$ , et  $\liminf_n X_n \in L^1$ , alors  $\mathbb{E}[\liminf_n X_n|\mathcal{G}] \leq \liminf_n \mathbb{E}[X_n|\mathcal{G}]$ , p.s. Lemme de Fatou conditionnel.

14. Si  $|X_n| \leq Z$ , pour tout  $n \in \mathbb{N}^*$  et  $Z \in L^1(\Omega)$ , et si  $X_n \rightarrow X$ , p.s., alors  $L^1(\Omega) \ni \mathbb{E}[X_n|\mathcal{G}] \rightarrow \mathbb{E}[X|\mathcal{G}]$ , p.s. Théorème de Convergence Dominée conditionnelle.

*Preuve:*

1.  $a\mathbb{E}[X|\mathcal{G}] + b\mathbb{E}[Y|\mathcal{G}]$  est  $\mathcal{G}$ -mesurable car combinaison linéaire de variables aléatoires qui sont  $\mathcal{G}$ -mesurables, grâce à la définition de l'espérance conditionnelle. Pour tout  $B \in \mathcal{G}$ ,  $\mathbb{E}[(a\mathbb{E}[X|\mathcal{G}] + b\mathbb{E}[Y|\mathcal{G}])\mathbf{1}_B] = a\mathbb{E}[\mathbb{E}[X|\mathcal{G}]\mathbf{1}_B] + b\mathbb{E}[\mathbb{E}[Y|\mathcal{G}]\mathbf{1}_B] = a\mathbb{E}[X\mathbf{1}_B] + b\mathbb{E}[Y\mathbf{1}_B] = \mathbb{E}[(aX + bY)\mathbf{1}_B]$ .

2. Soit  $Y$  une v.a.  $\mathcal{G}$ -mesurable et  $XY \in L^1(\Omega)$ , on doit montrer que pour tout  $A \in \mathcal{G}$ ,  $\mathbb{E}[XY\mathbf{1}_A] = \mathbb{E}[Y\mathbb{E}[X|\mathcal{G}]\mathbf{1}_A]$ . Pour cela, montrons que  $\mathbb{E}[ZX] = \mathbb{E}[Z\mathbb{E}[X|\mathcal{G}]]$ , pour toute v.a.  $Z$   $\mathcal{G}$ -mesurable t.q.  $ZX \in L^1(\Omega)$ ; en effet après cela il suffit de prendre  $Z = Y\mathbf{1}_A$ .

Pour  $Z$  une v.a. étagée, i.e.  $Z = \sum_{k=1} \alpha_k \mathbf{1}_{A_k}$ , ceci est évident par la définition de l'espérance conditionnelle et la linéarité.

Supposons que  $Z$  et  $X$  sont positives p.s. et  $ZX \in L^1(\Omega)$ . Dans ce cas, il existe toujours une suite croissante de v.a. étagées  $(Z_n)_{n \in \mathbb{N}^*}$  t.q.  $Z_n \nearrow Z$ . Alors  $Z_n X \in L^1(\Omega)$  pour tout  $n \in \mathbb{N}^*$  et le Théorème de Convergence Monotone implique que  $\mathbb{E}[ZX] = \lim_{n \rightarrow \infty} \mathbb{E}[Z_n X] = \lim_{n \rightarrow \infty} \mathbb{E}[Z_n \mathbb{E}[X|\mathcal{G}]] = \mathbb{E}[Z \mathbb{E}[X|\mathcal{G}]]$ . Maintenant que nous nous sommes occupés du cas  $X \in L^1_+(\Omega)$ , il faut s'occuper du cas  $X \in L^1(\Omega)$ . Dans ce cas, en utilisons  $p = 1$  dans la propriété 10. (ou la propriété 9. avec  $-|X| \leq X \leq |X|$ ), on obtient  $|\mathbb{E}[X|\mathcal{G}]| \leq \mathbb{E}[|X||\mathcal{G}]$ , p.s. et donc  $|Z_n \mathbb{E}[X|\mathcal{G}]| \leq Z_n \mathbb{E}[|X||\mathcal{G}] \leq Z_n \mathbb{E}[|X||\mathcal{G}]$ .

Par le cas précédent, on sait que  $\mathbb{E}[Z \mathbb{E}[|X||\mathcal{G}]] = \mathbb{E}[Z|X|]$ , et donc  $Z \mathbb{E}[|X||\mathcal{G}] \in L^1(\omega)$ .

On peut maintenant utiliser le théorème de convergence dominée pour conclure que  $\mathbb{E}[Z \mathbb{E}[X|\mathcal{G}]] = \lim_{n \rightarrow \infty} \mathbb{E}[Z_n \mathbb{E}[X|\mathcal{G}]] = \lim_{n \rightarrow \infty} \mathbb{E}[Z_n X] = \mathbb{E}[ZX]$ .

Finalement, le cas général pour  $Z$  s'obtient par la linéarité avec  $Z = Z^+ - Z^-$ .

3. Il suffit de prendre  $Y = 1$  dans 2. ou vérifier trivialement que  $X$  satisfait aux deux propriétés de la définition de l'espérance conditionnelle.
4.  $\mathbb{E}[X]$  est constante donc  $\mathcal{G}$ -mesurable et pour tout  $B \in \mathcal{G}$ ,  $\mathbb{E}[X\mathbf{1}_B] = \mathbb{E}[X\mathbf{1}_B]$ .
5. La seconde égalité est triviale car  $\mathbb{E}[X|\mathcal{H}]$  est  $\mathcal{G}$ -mesurable. Pour la première égalité, remarquons que  $\mathbb{E}[\mathbb{E}[X|\mathcal{G}]|\mathcal{H}]$  est  $\mathcal{H}$ -mesurable avec  $\int_A \mathbb{E}[\mathbb{E}[X|\mathcal{G}]|\mathcal{H}] d\mathbb{P} = \int_A \mathbb{E}[X|\mathcal{G}] d\mathbb{P} = \int_A X d\mathbb{P} = \int_A \mathbb{E}[X|\mathcal{H}] d\mathbb{P}$  pour tout  $A \in \mathcal{H}$ .
6. Dans 5. prendre  $\mathcal{H} = \{\emptyset, \Omega\}$  en utilisant  $\mathbb{E}[X|\mathcal{H}] = X$ .
7. Soient  $Y = \mathbb{E}[X|\mathcal{G}]$ ,  $A^+ = \{Y > 0\}$  et  $A^- = \{Y < 0\}$ . Puisque  $A^+ = Y^{-1}(]0, \infty[)$  avec  $]0, \infty[ \in \mathcal{B}(\mathbb{R})$  et  $Y$  est  $\mathcal{G}$ -mesurable, d'où  $A^+ \in \mathcal{G}$  et donc  $0 \leq \mathbb{E}[Y\mathbf{1}_{A^+}] = \mathbb{E}[X\mathbf{1}_{A^+}] \leq \mathbb{E}[|X|\mathbf{1}_{A^+}]$ . De même  $A^- \in \mathcal{G}$  donc  $0 \leq \mathbb{E}[-Y\mathbf{1}_{A^-}] = \mathbb{E}[-X\mathbf{1}_{A^-}] \leq \mathbb{E}[|X|\mathbf{1}_{A^-}]$ . Finalement  $\mathbb{E}[|Y|] = \mathbb{E}[Y\mathbf{1}_{A^+} - Y\mathbf{1}_{A^-}] \leq \mathbb{E}[|X|] < +\infty$ .
8. Soit  $X \geq 0$  p.s. On a  $\mathbb{E}[X\mathbf{1}_{A^-}] = \mathbb{E}[Y\mathbf{1}_{A^-}]$  car  $A^- \in \mathcal{G}$ . Or  $X\mathbf{1}_{A^-} \geq 0$  p.s. par hypothèse, tandis que  $Y\mathbf{1}_{A^-} \leq 0$  p.s. par définition de  $A^-$ . On en déduit que  $Y\mathbf{1}_{A^-} = 0$  p.s., c'est-à-dire que  $Y \geq 0$  p.s.
9. Il suffit de considérer  $Y - X \geq 0$  dans la propriété précédente et d'utiliser la linéarité.
10. 1<sup>ère</sup> preuve : Tout d'abord montrons qu'une fonction convexe  $\phi$  peut s'écrire comme  $\phi(x) = \sup_{n \in \mathbb{N}^*} (a_n + b_n x)$ , pour tout  $x \in \mathbb{R}$  avec  $(a_n)_{n \in \mathbb{N}^*}, (b_n)_{n \in \mathbb{N}^*} \in \mathbb{R}^{\mathbb{N}^*}$  bien choisies.

$\phi$  étant convexe, on a  $\phi(x) \geq \phi(y) + (x - y)\phi'_d(y)$  pour tous  $x, y \in \mathbb{R}$ , où  $\phi'_d$  désigne la dérivée à droite de  $\phi$ . On obtient facilement que  $\phi(x) = \sup_{y \in \mathbb{R}} (\phi(y) + (x - y)\phi'_d(y)) := \sup_{y \in \mathbb{R}} (A_y + B_y x)$  pour tout  $x \in \mathbb{R}$ . Montrons que  $\phi(x) = \sup_{y \in \mathbb{Q}} (A_y + B_y x)$  pour tout  $x \in \mathbb{R}$  :

Le sens  $\geq$  est évident. Soit  $x \in \mathbb{R}$  et soit  $(y_n)_{n \in \mathbb{N}^*} \in \mathbb{Q}^{\mathbb{N}^*}$  tel que  $\lim_{n \rightarrow \infty} y_n = x$ . Alors  $A_{y_n} + B_{y_n} x = \phi(y_n) + (x - y_n)\phi'_d(y_n) \rightarrow \phi(x)$  lorsque  $n \rightarrow \infty$ , en effet  $\phi$  est continue (car convexe) et  $(\phi'_d(y_n))_{n \in \mathbb{N}^*}$  est clairement bornée. D'où le sens  $\leq$  est vrai. Finalement presque-sûrement et pour tout  $n \in \mathbb{N}^*$ , on a  $a_n + b_n \mathbb{E}[X|\mathcal{G}] = \mathbb{E}[a_n + b_n X|\mathcal{G}] \leq \mathbb{E}[\sup_{k \in \mathbb{N}^*} (a_k + b_k X)|\mathcal{G}] = \mathbb{E}[\phi(X)|\mathcal{G}]$ . Cela veut dire que l'inégalité ci-dessus est vrai sur  $\Omega \setminus B_n$  avec  $\mathbb{P}(B_n) = 0$ .

En prenant le supremum sur  $n$ , on obtient que  $\phi(\mathbb{E}[X|\mathcal{G}]) \leq \mathbb{E}[\phi(X)|\mathcal{G}]$  est vrai sur  $\Omega \setminus B$  où  $B = \cup_n B_n$  avec  $\mathbb{P}(B) = 0$ ; ce qui est équivalent à

$$\phi(\mathbb{E}[X|\mathcal{G}]) \leq \mathbb{E}[\phi(X)|\mathcal{G}], \text{ p.s.}$$

2<sup>ème</sup> preuve :  $\phi$  étant convexe, on a  $\phi'_d(y)(x - y) + \phi(y) \leq \phi(x)$ , pour tous  $x, y \in \mathbb{R}$ . En prenant  $x = \mathbb{E}[X|\mathcal{G}]$  et  $y = X$  on obtient  $\phi'_d(\mathbb{E}[X|\mathcal{G}])(X - \mathbb{E}[X|\mathcal{G}]) \leq \phi(X) - \phi(\mathbb{E}[X|\mathcal{G}])$ . Comme dans la preuve de l'inégalité de Jensen avec l'espérance, on a envie de prendre des deux côtés l'espérance conditionnelle par rapport à  $\mathcal{G}$ ; sauf qu'ici  $\phi'_d(\mathbb{E}[X|\mathcal{G}])$  n'est pas constant mais c'est une variable aléatoire et il n'est pas certain que  $\phi'_d(\mathbb{E}[X|\mathcal{G}])(X - \mathbb{E}[X|\mathcal{G}])$  soit intégrable. L'astuce est donc remplacer  $X$  par  $\mathbf{1}_E X$ , où  $E = \{\omega : \mathbb{E}[X|\mathcal{G}](\omega) \leq M\}$  pour  $M < \infty$ .  $\mathbb{E}[X|\mathcal{G}]$  est  $\mathcal{G}$ -mesurable, donc  $E \in \mathcal{G}$ , donc  $\mathbf{1}_E$  est  $\mathcal{G}$ -mesurable, d'où  $\mathbb{E}[\mathbf{1}_E X|\mathcal{G}] = \mathbf{1}_E \mathbb{E}[X|\mathcal{G}]$ , et donc  $\mathbb{E}[\phi(\mathbf{1}_E X)|\mathcal{G}] = \mathbb{E}[\phi(X)\mathbf{1}_E + \phi(0)\mathbf{1}_{E^c}|\mathcal{G}] = \mathbf{1}_E \mathbb{E}[\phi(X)|\mathcal{G}] + (1 - \mathbf{1}_E)\phi(0)$ .

On a l'inégalité  $\phi'_d(\mathbb{E}[\mathbf{1}_E X|\mathcal{G}])(\mathbf{1}_E X - \mathbf{1}_E \mathbb{E}[X|\mathcal{G}]) \leq \phi(\mathbf{1}_E X) - \phi(\mathbf{1}_E \mathbb{E}[X|\mathcal{G}])$  où le membre de droite est intégrable grâce à  $\phi(X) \in L^1(\Omega)$ , donc le membre de gauche est intégrable aussi. D'où en prenant l'espérance conditionnelle par rapport à  $\mathcal{G}$  et en utilisant le fait que  $\phi'_d(\mathbb{E}[\mathbf{1}_E X|\mathcal{G}])$ ,  $\phi(\mathbf{1}_E \mathbb{E}[X|\mathcal{G}])$  ( $\phi'_d$  est croissante et  $\phi$  est continue, donc toutes les deux sont mesurables) sont  $\mathcal{G}$ -mesurables, on obtient  $\phi(\mathbf{1}_E \mathbb{E}[X|\mathcal{G}]) \leq \mathbf{1}_E \mathbb{E}[\phi(X)|\mathcal{G}] + (1 - \mathbf{1}_E)\phi(0)$ , p.s. Finalement, en prenant  $M \rightarrow \infty$ , on a  $\mathbf{1}_E \rightarrow 1$  p.s. et la preuve devient complète.

11. Pour  $p \in [1, \infty[$ , inégalité de Jensen conditionnelle appliquée avec  $\phi(x) = |x|^p$  donne l'inégalité.
12. Par la monotonie, on a  $\mathbb{E}[X_n|\mathcal{G}] \nearrow \zeta \in L^0_+(\Omega)$ , p.s. Le théorème de convergence monotone implique que, pour tout  $A \in \mathcal{G}$ ,

$$\mathbb{E}[\zeta \mathbf{1}_A] = \lim_n \mathbb{E}[\mathbf{1}_A \mathbb{E}[X_n|\mathcal{G}]] = \lim_n \mathbb{E}[\mathbf{1}_A X_n] = \mathbb{E}[\mathbf{1}_A X].$$

13. Soit  $Y_n = \inf_{k \geq n} X_k$ , alors  $Y_n \nearrow Y = \liminf_k X_k$ . Par la monotonie,

$$\mathbb{E}[Y_n|\mathcal{G}] \leq \inf_{k \geq n} \mathbb{E}[X_k|\mathcal{G}] \text{ p.s.,}$$

en effet pour tout  $k \geq n$ ,  $Y_n \leq X_k$  et donc  $\mathbb{E}[Y_n|\mathcal{G}] \leq \mathbb{E}[X_k|\mathcal{G}]$  et l'union dénombrable d'événements négligeables est négligeable; finalement le théorème de convergence monotone conditionnel implique que

$$\begin{aligned} \mathbb{E}[\liminf_n X_n|\mathcal{G}] &= \mathbb{E}[Y|\mathcal{G}] = \mathbb{E}[\lim_n Y_n|\mathcal{G}] = \lim_n \mathbb{E}[Y_n|\mathcal{G}] \\ &\leq \lim_n \inf_{k \geq n} \mathbb{E}[X_k|\mathcal{G}] = \liminf_n \mathbb{E}[X_n|\mathcal{G}]. \end{aligned}$$

14. Comme  $X_n + Z$  et  $Z - X_n$  sont des v.a. positives pour tout  $n \in \mathbb{N}^*$ , le lemme de Fatou conditionnel appliqué donne  $\mathbb{E}[X + Z|\mathcal{G}] = \mathbb{E}[\liminf_n (X_n + Z)|\mathcal{G}] \leq \liminf_n \mathbb{E}[X_n + Z|\mathcal{G}]$  et  $\mathbb{E}[Z - X_n|\mathcal{G}] = \mathbb{E}[\liminf_n (Z - X_n)|\mathcal{G}] \leq \liminf_n \mathbb{E}[Z - X_n|\mathcal{G}]$ . Alors on obtient  $\liminf_n \mathbb{E}[X_n|\mathcal{G}] \geq \mathbb{E}[X|\mathcal{G}]$  et  $\limsup_n \mathbb{E}[X_n|\mathcal{G}] \leq \mathbb{E}[X|\mathcal{G}]$ .

#### Fonctions Convexes :

Pour tous  $x, y \in \mathbb{R}$ , pour tout  $t \in [0, 1]$ ,

$$\phi(tx + (1-t)y) \leq t\phi(x) + (1-t)\phi(y).$$

$$x_1 < x_2 < x_3 \Rightarrow k(x_2, x_1) \leq k(x_3, x_1) \leq k(x_3, x_2)$$

$$\text{où } k(u, v) = \frac{f(u) - f(v)}{u - v}$$

$$\phi'_d(a) = \lim_{t \rightarrow 0^+} k(a + t, a).$$

$\phi$  est dérivable à gauche et à droite.

□

**Propriété 10** Soient  $X$  et  $Y$  deux variables aléatoires réelles telles que  $(X, Y)$  admettent une densité jointe  $f$ . Soit  $g : \mathbb{R} \rightarrow \mathbb{R}$  mesurable (i.e. borélienne) tel que  $g(X) \in L^1(\Omega)$ . Alors

$$\mathbb{E}[g(X)|Y] = h(Y) \text{ où } h(y) = \frac{\int_{\mathbb{R}} g(x)f(x, y) dx}{f_Y(y)} \mathbf{1}_{\{y \in \mathbb{R} : f_Y(y) > 0\}}.$$

*Preuve:* Supposons que  $g \geq 0$  p.p. Comme  $Y$  est  $\sigma(Y)$ -mesurable et  $h$  est positive et borélienne (en effet  $y \mapsto \frac{1}{f_Y(y)} \mathbf{1}_{\{y \in \mathbb{R} : f_Y(y) > 0\}}$  est mesurable et  $g(X) \in L^1(\Omega, \mathcal{F}, \mathbb{P})$  implique que d'après le théorème de Fubini on a  $y \mapsto \int_{\mathbb{R}} g(x)f(x, y) dx$  mesurable), d'où  $h(Y)$  est  $\sigma(Y)$ -mesurable, il nous reste donc à montrer que  $\mathbb{E}[h(Y)\mathbf{1}_A] = \mathbb{E}[g(X)\mathbf{1}_A]$  pour tout  $A \in \sigma(Y)$ .

Soit  $A \in \sigma(Y)$ . Alors il existe  $B \in \mathcal{B}(\mathbb{R})$  tel que  $A = \{Y \in B\}$ . Soit  $C = \{y \in \mathbb{R} : f_Y(y) > 0\}$ .

$(x, y) \mapsto g(x)\mathbf{1}_B(y)f(x, y)$  est mesurable et  $g(X) \in L^1(\Omega) \Rightarrow g(X)\mathbf{1}_A = g(X)\mathbf{1}_B(Y) \in L^1(\Omega)$ , d'où d'après le théorème de Fubini  $\mathbb{E}[g(X)\mathbf{1}_A] = \int_B (\int_{\mathbb{R}} g(x)f(x, y) dx) dy = \int_{B \cap C} (\int_{\mathbb{R}} g(x)f(x, y) dx) dy + \int_{B \cap C^c} (\int_{\mathbb{R}} g(x)f(x, y) dx) dy$ . Comme pour tout  $y \in C$ ,  $h(y)f_Y(y) = \int_{\mathbb{R}} g(x)f(x, y) dx$  et pour tout  $y \in C^c$ ,  $f(\cdot, y) = 0$   $\lambda$ -p.p.,  $\lambda$  étant la mesure de Lebesgue; ce qui implique que pour tout  $y \in C^c$ ,  $\int_{\mathbb{R}} g(x)f(x, y) dx = 0$ . Par conséquent,  $\mathbb{E}[g(X)\mathbf{1}_A] = \int_{B \cap C} h(y)f_Y(y) dy = \int_{\mathbb{R}} \int_{\mathbb{R}} h(y)\mathbf{1}_A(y)f(x, y) dx dy$ , comme  $y \mapsto h(y)\mathbf{1}_A(y)f(x, y)$  est une fonction positive et mesurable d'où d'après le Théorème de Tonelli, la dernière double intégrale vaut  $\int_{\mathbb{R} \times \mathbb{R}} h(y)\mathbf{1}_A(y)f(x, y) d\lambda_2(x, y)$  et elle est finie et donc  $\mathbb{E}[g(X)\mathbf{1}_A] = \mathbb{E}[h(Y)\mathbf{1}_A]$ . Finalement  $\mathbb{E}[g(X)|Y] = h(Y)$ .

Pour le cas où  $g$  n'est pas forcément positive p.p., on écrit  $g = g^+ - g^-$  où  $x^+ = x\mathbf{1}_{x>0}$  et  $x^- = -x\mathbf{1}_{x \geq 0}$  et on pose

$$h(y) = \frac{\int_{\mathbb{R}} g(x)f(x, y) dx}{f_Y(y)} \mathbf{1}_{\{y \in \mathbb{R} : f_Y(y) > 0\}}$$

qui est bien mesurable d'après le théorème de Fubini. Comme  $g(X) \in L^1(\Omega, \mathcal{F}, \mathbb{P})$  on a l'existence de  $\mathbb{E}[g(x)|Y]$ . En utilisant les résultats précédents et la linéarité de l'espérance conditionnelle, on obtient donc

$$\begin{aligned} \mathbb{E}[g(X)|Y] &= \mathbb{E}[g^+(X) - g^-(X)|Y] \\ &= \mathbb{E}[g^+(X)|Y] - \mathbb{E}[g^-(X)|Y] \\ &= h^{s^+}(Y) - h^{s^-}(Y) = h(Y) \end{aligned}$$

où  $h^{s^\pm} = (\int_{\mathbb{R}} g^\pm(x)f(x, y) dx) (f_Y(y))^{-1} \mathbf{1}_{\{y \in \mathbb{R} : f_Y(y) > 0\}}$ . □

c'est-à-dire que  $f : \mathbb{R}^2 \rightarrow \mathbb{R}_+$  est mesurable et

$$f \in L^1(\mathbb{R}^2), \forall B \in \mathcal{B}(\mathbb{R}^2), \mathbb{P}((X, Y) \in B) = \int_B f(z) dz.$$

Rappelons que

$$(x, y) \mapsto \frac{f(x, y)}{f_Y(y)} \mathbf{1}_{\{y \in \mathbb{R} : f_Y(y) > 0\}}$$

est appelée la fonction de densité conditionnelle de  $X$  par rapport à  $Y$

**Propriété 11** Soient  $X$  et  $Y$  deux variables aléatoires réelles indépendantes sur  $(\Omega, \mathcal{F}, \mathbb{P})$ . Soit  $\mathcal{G} \subset \mathcal{F}$  une sous-tribu. Alors, pour toute fonction  $h : \mathbb{R}^2 \rightarrow \mathbb{R}$  borélienne, positive ou telle que  $h(X, Y) \in L^1(\Omega)$  (par exemple  $h$  bornée) on a

$$\mathbb{E}[h(X, Y)|X] = g(X), \text{ où } g(x) = \mathbb{E}[h(x, Y)].$$

*Preuve:* On doit prouver que  $g(X)$  est une version de l'espérance conditionnelle de  $h(X, Y)$ . On a, par le théorème de Transfert (en effet  $h(x, \cdot)$  satisfait aux conditions du théorème)  $g(x) = \int_{\mathbb{R}} h(x, y) d\mathbb{P}_Y(y)$  et par le théorème de Fubini on obtient que  $g$  est borélienne d'où  $g(Y)$  est  $\sigma(Y)$ -mesurable.

Soit  $A \in \sigma(X)$ , donc il existe  $B \in \mathcal{B}(\mathbb{R})$  tel que  $A = \{X \in B\}$ . On a  $\int_A h(X, Y) d\mathbb{P} = \int_{B \times \mathbb{R}} h(x, y) d\mathbb{P}_{(X, Y)}(x, y)$  et donc par le théorème de Fubini et du fait que  $\mathbb{P}_{(X, Y)} = \mu_X \otimes \mathbb{P}_Y$ , on obtient

$$\begin{aligned} \int_{B \times \mathbb{R}} h(x, y) d\mathbb{P}_{(X, Y)}(x, y) &= \int_B \int_{\mathbb{R}} h(x, y) d\mathbb{P}_Y(y) d\mu_X(x) \\ &= \int_B g(x) d\mu_X(x) = \mathbb{E}[g(X)\mathbf{1}_A]. \end{aligned}$$

Ce qui donne

$$\int_A h(X, Y) d\mathbb{P} = \int_A g(X) d\mathbb{P}.$$

□

## 0.9 Petite étude de l'espace $L^2(\Omega, \mathcal{F}, \mathbb{P})$

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

On définit l'espace  $\mathcal{L}^2(\Omega, \mathcal{F}, \mathbb{P})$  par  $\mathcal{L}^2(\Omega, \mathcal{F}, \mathbb{P}) = \{X : \Omega \rightarrow \mathbb{R}, \mathcal{F}\text{-mesurable} : \mathbb{E}_{\mathbb{P}}[X^2] < \infty\}$  que l'on note par  $\mathcal{L}^2(\mathcal{F})$ . On utilise l'application  $\|\cdot\|_2$  définie de  $\mathcal{L}^2(\mathcal{F})$  dans  $\mathbb{R}_+$  par  $\|\cdot\|_2 : X \rightarrow \mathbb{E}[X^2]^{1/2}$  pour définir une norme. Nous devrions identifier les variables aléatoires  $\mathbb{P}$ -presque-sûrement égales, comme  $\|X - Y\|_2 = 0 \Leftrightarrow X = Y \text{ } \mathbb{P}\text{-p.s.}$

Pour cela on définit  $X \sim Y$  si et seulement si  $X = Y \text{ } \mathbb{P}\text{-p.s.}$ ; cela est une relation d'équivalence sur  $\mathcal{L}^2(\mathcal{F})$  et donc on peut définir l'espace quotient  $\mathcal{L}^2(\mathcal{F}) / \sim$  que l'on note par  $L^2(\mathcal{F})$ .

Remarquons  $L^2(\mathcal{F})$  est un espace préhilbertien, c'est-à-dire que cet espace vectoriel (voir le paragraphe ci-dessous) de dimension infinie est muni d'un produit scalaire. Le produit scalaire dans cet espace n'est autre que  $\langle X, Y \rangle := \mathbb{E}[XY]$

On a que  $(L^2(\mathcal{F}), \|\cdot\|_2)$  est un espace vectoriel normé, en effet si  $X$  et  $Y$  sont des variables aléatoires, alors  $X + Y$  et  $cX$  le sont également, pour tout réel  $c$ ; comme  $(cX)^2 = c^2X^2$  et  $(X + Y)^2 \leq 2(X^2 + Y^2)$ , il s'ensuit que  $L^2(\mathcal{F})$  est un espace vectoriel et  $\|cX\|_2 = |c|\|X\|_2$ .

cette application  $\langle \cdot, \cdot \rangle$  est bien un produit scalaire, en effet elle est

- symétrique :  $\langle X, Y \rangle = \langle Y, X \rangle$ ,
- linéaire par rapport à l'une des deux variables (donc avec la symétrie elle devient bilinéaire),
- définie :  $\langle X, X \rangle = 0 \Rightarrow X = 0$ ,
- positive :  $\langle X, X \rangle \geq 0$ .

Maintenant  $\|X\|_2 = 0$  si et seulement si  $X = 0$  (comme un élément de  $L^2(\mathcal{F})$ ). Donc tout ce qui reste est de prouver qu'on a l'inégalité triangulaire pour cette application  $\|\cdot\|_2$ .

Premièrement, on a besoin d'une conséquence importante de l'inégalité de Jensen :

**Propriété 12 (Inégalité de Hölder)** Soit  $p > 1$ ,  $\frac{1}{p} + \frac{1}{q} = 1$ . Si  $X \in L^p(\mathcal{F})$  et  $Y \in L^q(\mathcal{F})$ , alors  $XY \in L^1(\mathcal{F})$  et

$$\|XY\|_1 \leq \|X\|_p \|Y\|_q.$$

On obtient un cas spécial et familier lorsque  $p = q = 2$  :

**Corollaire 1 (Inégalité de Schwarz)** Soient  $X, Y \in L^2(\mathcal{F})$ , alors  $XY \in L^1(\mathcal{F})$  et

$$\|XY\|_1 \leq \|X\|_2 \|Y\|_2.$$

On peut donc prouver l'inégalité triangulaire pour  $X \rightarrow \|X\|_p$  sur  $L^p(\mathcal{F})$  pour tout  $p \geq 1$ .

**Corollaire 2 (Inégalité de Minkowski)** Si  $p \geq 1$  et  $X, Y \in L^p(\mathcal{F})$ , alors

$$\|X + Y\|_p \leq \|X\|_p + \|Y\|_p.$$

*Preuve:* Le cas  $p = 1$  est trivial, donc supposons  $p > 1$ . On a

$$|X + Y|^p \leq |X| |X + Y|^{p-1} + |Y| |X + Y|^{p-1}$$

et avec  $\frac{1}{p} + \frac{1}{q} = 1$  on obtient  $|X + Y|^{(p-1)q} = |X + Y|^p$ , et donc  $|X + Y|^{p-1} \in L^q(\Omega)$ . En appliquant l'inégalité de Hölder à chacun des produits on obtient

$$\int_{\Omega} |X| |X + Y|^{p-1} d\mathbb{P} \leq C \|X\|_p,$$

où  $C = (\int_{\Omega} (|X + Y|^{p-1})^q d\mathbb{P})^{1/q} = \|X + Y\|_p^{p/q}$ , et la même inégalité s'obtient en intervertissant  $X$  et  $Y$ . D'où

$$\|X + Y\|_p^p \leq C(\|X\|_p + \|Y\|_p).$$

En divisant les deux membres de cette dernière inégalité par  $C$  (se rappeler de  $p - p/q = 1$ ), on a bien l'inégalité de Minkowski.  $\square$

**Propriété 13** La norme  $L^p(\mathcal{F})$  précédente est croissante en  $p$  si  $\mathbb{P}(\Omega)$  est fini (c'est le cas ici car  $\mathbb{P}$  est une probabilité!), c'est-à-dire que

$$1 \leq p \leq q < \infty \Rightarrow L^q(\mathcal{F}) \subset L^p(\mathcal{F}).$$

Remarque importante : Une fois que vous avez une v.a. telle que  $\mathbb{E}[|X|^n] < \infty$  alors pour tout entier  $k < n$  on a  $\mathbb{E}[|X|^k] < \infty$ .

**Théorème 12**  $L^2(\mathcal{F})$  est un espace vectoriel complet.

Note : on aurait pu tout simplement définir directement  $L^p(\mathcal{F})$  et donc  $L^p(\mathcal{F})$  pour tout  $p \geq 1$ .

$L^2(\mathcal{F})$  est donc un espace préhilbertien complet, d'où l'appellation espace hilbertien (ou espace de Hilbert) par définition. C'est aussi un espace Banach (espace vectoriel normé complet pour la distance issue de sa norme) dont la norme découle du produit scalaire.

*Preuve:* La vérification sur le fait qu'il est bien un espace vectoriel est facile à faire et presque déjà faite auparavant.

Montrons qu'il est complet pour la topologie induite par la norme. Soit  $(X_n)_{n \in \mathbb{N}^*} \in (L^2(\mathcal{F}))^{\mathbb{N}^*}$  une suite de Cauchy, montrons donc qu'elle converge.

On a  $\sup_{m,n > k} \|X_m - X_n\|_2 \rightarrow 0$  pour  $k \rightarrow \infty$ . On veut montrer qu'il existe  $X \in L^2(\mathcal{F})$  (unique au sens de p.s.) tel que  $\lim_{n \rightarrow \infty} \|X_n - X\|_2 = 0$ . Soit  $(k_n)_{n \in \mathbb{N}^*}$  une suite croissante telle que  $\lim_{n \rightarrow \infty} k_n = +\infty$  et  $\|X_s - X_m\|_2 \leq 2^{-n}$  pour tous  $s, m \geq k_n$ .

Alors par le théorème de convergence monotone sur la suite croissante de v.a. mesurables et positives puis par le théorème de Jensen ( $\mathbb{E}[|X|^2] \leq \mathbb{E}[|X|^2]$ ) on obtient  $(\sum_{n=1}^m |X_{k_{n+1}} - X_{k_n}|)_{m \in \mathbb{N}^*}$ , on obtient

$$\mathbb{E} \left[ \sum_{n \in \mathbb{N}^*} |X_{k_{n+1}} - X_{k_n}| \right] \leq \sum_{n \in \mathbb{N}^*} \|X_{k_{n+1}} - X_{k_n}\|_2 \leq \sum_{n \in \mathbb{N}^*} 2^{-n} < \infty$$

et donc pour presque tout  $\omega \in \Omega$  la série  $S(\omega) = \sum_{n \in \mathbb{N}^*} (X_{k_{n+1}} - X_{k_n})$  est absolument convergente et donc  $\lim_{n \rightarrow \infty} X_{k_n}(\omega) < \infty$  p.s.

Soit donc  $X(\omega) = \limsup_n X_{k_n}(\omega)$ , on a que  $X$  est  $\mathcal{F}$ -mesurable et que  $\lim_{n \rightarrow \infty} X_{k_n} = X$  p.s. (en effet lorsque qu'une suite  $(a_n)_n$  est convergente on a  $\lim_n a_n = \limsup_n a_n = \liminf_n a_n$ ). Maintenant on observe que si  $\ell \geq n$ ,  $\mathbb{E}[|X_r - X_\ell|^2] \leq 2^{-2n}$  pour tout  $r \geq k_n$ , donc une application du Lemme de Fatou donne

$$\mathbb{E}[|X_r - X|^2] = \mathbb{E}[\lim_{n \rightarrow \infty} |X_r - X_{k_n}|^2] \leq \lim_{\ell \rightarrow +\infty} \mathbb{E}[|X_r - X_{k_\ell}|^2] \leq 2^{-2n}$$

pour tout  $r \geq k_n$ , qui montre que  $X \in L^2(\mathcal{F})$  et que  $X_n \xrightarrow[n \rightarrow \infty]{} X$  dans  $L^2(\mathcal{F})$ .  $\square$

**Corollaire 3 (Projection Orthogonale)** Si  $\mathcal{B} \subset \mathcal{F}$  est une sous-tribu de  $\mathcal{F}$ , alors  $L^2(\mathcal{B})$  est un sous-espace vectoriel fermé de  $L^2(\mathcal{F})$  et pour tout  $X \in L^2(\mathcal{F})$  il existe une v.a.  $Y \in L^2(\mathcal{B})$  (unique au sens p.s.) qui satisfait à l'une des deux propriétés suivantes, qui sont équivalentes :

- $\|X - Y\|_2^2 = \inf_{Z \in L^2(\mathcal{B})} \|X - Z\|_2^2$
- $X - Y \perp L^2(\mathcal{B})$ , i.e.  $\mathbb{E}[(X - Y)Z] = 0$  pour tout  $Z \in L^2(\mathcal{B})$ .

*Preuve:* Par le Théorème 12, l'ensemble  $L^2(\mathcal{B})$  est complet par la norme  $L^2$  et donc fermé de  $L^2(\mathcal{F})$ ; en effet  $(L^2(\mathcal{F}), \|\cdot\|_2)$  est un espace vectoriel normé donc un espace métrique (on peut définir par exemple la distance  $d$  définie par  $d(X, Y) = \|X - Y\|_2$ ), et  $L^2(\mathcal{B}) \subset L^2(\mathcal{F})$ , d'où le sous-espace métrique  $(L^2(\mathcal{B}), d)$  est complet, et donc  $L^2(\mathcal{B})$  est un fermé de  $L^2(\mathcal{F})$ .

Soit  $\delta = \inf_{Z \in L^2(\mathcal{B})} \|X - Z\|_2^2 < \infty$  et  $(Y_n)_{n \in \mathbb{N}^*} \in (L^2(\mathcal{B}))^{\mathbb{N}^*}$  une suite minimisante :  $\|X - Y_n\|_2^2 \rightarrow \delta$  lorsque  $n \rightarrow \infty$ . On a donc

Ce corollaire est une application du Théorème de la projection orthogonale avec  $H = L^2(\mathcal{F})$  espace de Hilbert et  $E = L^2(\mathcal{B})$  un sous-espace de  $E$  fermé. Alors pour tout  $x \in H$

- $\exists! P(x) \in E$  t.q.  $\|x - P(x)\| = \inf_{y \in E} \|x - y\|$
- $P(x)$  est l'unique vecteur  $y \in E$  t.q.  $x - y$  soit orthogonal à  $E$ .
- $H = E \oplus E^\perp$
- $\|x\|^2 = \|P(x)\|^2 + \|x - P(x)\|^2$

cette suite minimisante  $(Y_n)_{n \in \mathbb{N}^*}$  existe toujours par construction qui vient de la définition de inf; en effet par définition on a  $\delta \leq \|X - Z\|_2^2$  pour tout  $Z \in L^2(\mathcal{B})$ , donc pour tout  $n \in \mathbb{N}^*$ , il existe  $Y_n \in L^2(\mathcal{B})$  tel que  $\delta \leq \|X - Y_n\|_2^2 \leq \delta + \frac{1}{n}$ , car sinon on aurait  $\delta + \frac{1}{n} \leq \|X - Z\|_2^2$  pour tout  $Z \in L^2(\mathcal{B})$ , ce qui contredit  $\inf_{Z \in L^2(\mathcal{B})} \|X - Z\|_2^2$ .

$$\mathbb{E}[|X - Y_n|^2] + \mathbb{E}[|X - Y_m|^2] = 2\mathbb{E}[|X - (Y_n + Y_m)/2|^2] + \mathbb{E}[|Y_n - Y_m|^2]/2,$$

en effet  $\mathbb{E}[|A + B|^2] + \mathbb{E}[|A - B|^2] = 2\mathbb{E}[|A|^2] + 2\mathbb{E}[|B|^2]$  avec  $A = X - (Y_n + Y_m)/2$  et  $B = (Y_n - Y_m)/2$  donne cela. Mais  $(Y_n + Y_m)/2 \in L^2(\mathcal{B})$  ce qui donne que

$$\mathbb{E}[|Y_n - Y_m|^2]/2 \leq \mathbb{E}[|X - Y_n|^2] + \mathbb{E}[|X - Y_m|^2] - 2\sqrt{\delta} \xrightarrow{n,m \rightarrow \infty} 0$$

et donc  $(Y_n)_{n \in \mathbb{N}^*}$  est une suite de Cauchy. D'où avec  $L^2(\mathcal{B})$  complet et fermé on a  $Y := \lim_{n \rightarrow \infty} Y_n \in L^2(\mathcal{B})$ . On a que  $\|X - Y\|_2 \leq \|X - Y_n\|_2 + \|Y_n - Y\|_2$  (inégalité triangulaire) et donc que

$$\|X - Y\|_2 \leq \sqrt{\delta} = \inf_{Z \in L^2(\mathcal{B})} \|X - Z\|_2 \leq \|X - Y\|_2$$

(on a utilisé le fait que  $\|Y_n - Y\|_2 \rightarrow 0$  lorsque  $n \rightarrow \infty$ ), d'où  $\|X - Y\|_2 = \sqrt{\delta}$ .

Pour tous  $t \in \mathbb{R}$  et  $Z \in L^2(\mathcal{B})$  on a que  $Y + tZ \in L^2(\mathcal{B})$  et

$$0 \leq \mathbb{E}[|X - Y - tZ|^2] - \mathbb{E}[|X - Y|^2] = -2t\mathbb{E}[(X - Y)Z] + t^2\mathbb{E}[Z^2].$$

Le polynôme  $P(t) = at^2 + bt$  satisfait à  $P(t) \geq 0$  pour tout  $t \geq 0$ , où  $a = \mathbb{E}[Z^2] \geq 0$  et  $b = \mathbb{E}[(X - Y)Z]$ , donc on doit avoir  $b = 0$ , c'est-à-dire  $\mathbb{E}[(X - Y)Z] = 0$ . L'implication réciproque est facile à établir également. Pour montrer l'unicité presque sûre de  $Y$ , on suppose que  $Y'$  est un autre projection orthogonale. On a  $\mathbb{E}[(Y - Y')Z] = 0$  pour tout  $Z \in L^2(\mathcal{B})$  et donc aussi pour  $Z = Y - Y' \in L^2(\mathcal{B})$ , mais alors  $\mathbb{E}[(Y - Y')^2] = 0$ , i.e.  $Y - Y' = 0$  p.s.  $\square$

**Exemple 13 (Théorème de Pythagore)** Soient  $\mathcal{G} \subset \mathcal{F}$ ,  $X \in L^2(\mathcal{F})$ ,  $Z \in L^2(\mathcal{G})$  et  $Y = \mathbb{E}[X|\mathcal{G}]$  ( $Y$  existe car  $L^1(\mathcal{F}) \subset L^2(\mathcal{F})$ ). Montrer que  $\mathbb{E}[|X - Z|^2] = \mathbb{E}[|X - Y|^2] + \mathbb{E}[|Y - Z|^2]$  et en déduire que  $\mathbb{E}[|X - Y|^2] = \inf_{Z \in L^2(\mathcal{G})} \mathbb{E}[|X - Z|^2]$ .

Cet exercice montre que l'espérance conditionnelle  $\mathbb{E}[X|\mathcal{G}]$  dans  $L^2(\mathcal{F})$  est le meilleur estimateur  $\mathcal{G}$ -mesurable de  $X$  selon le risque quadratique, à savoir :

$$\mathbb{E}[|X - \mathbb{E}[X|\mathcal{G}]|^2] \leq \mathbb{E}[|X - Z|^2], \forall Z \in L^2(\mathcal{G}).$$

En effet cette interprétation géométrique est à la base d'une stratégie pour montrer l'existence de l'espérance conditionnelle dans  $L^2(\mathcal{G})$  :

Soit  $X \in L^2(\mathcal{F})$  et  $\mathcal{B}$  une sous-tribu de  $\mathcal{F}$ . Alors la projection orthogonale  $Y$  de  $X$  sur  $L^2(\mathcal{B})$  satisfait à  $\mathbb{E}[(X - Y)Z] = 0$  pour tout  $Z \in L^2(\mathcal{B})$ . On a donc, en prenant  $A \in \mathcal{B}$ ,  $Z = \mathbf{1}_A \in L^2(\mathcal{B})$  et  $\mathbb{E}[X\mathbf{1}_A] = \mathbb{E}[Y\mathbf{1}_A]$ . Comme  $Y$  est  $\mathcal{G}$ -mesurable d'où  $Y = \mathbb{E}[X|\mathcal{B}]$  ce qui montre l'existence de l'espérance conditionnelle pour  $X \in L^2(\mathcal{F})$ .

Finalement lorsque  $X \in L^2(\mathcal{F})$ , la projection orthogonale de  $X$  sur  $L^2(\mathcal{B})$  est exactement l'espérance conditionnelle de  $X$  par rapport à la tribu  $\mathcal{B}$ . Voici donc une autre version de l'existence de l'espérance conditionnelle d'une variable aléatoire intégrable, en utilisant le résultat précédent :

**Théorème 13** *Pour tout  $X \in L^1(\mathcal{F})$  l'espérance conditionnelle  $\mathbb{E}[X|\mathcal{B}]$  existe et appartient à  $L^1(\mathcal{B})$ .*

*Preuve:* Pour étendre l'existence précédente (lorsque  $X \in L^2(\mathcal{F})$ ) à toute variable aléatoire  $X \in L^1(\mathcal{F})$  on procède par approximation. Soit  $X \geq 0$  p.s. et dans  $L^1(\mathcal{F})$ .

On pose  $X_n(\omega) = \min(X(\omega), n)$ , d'où  $X_n \in L^2(\mathcal{B})$  et  $Y_n$  la projection orthogonale correspondante sur  $L^2(\mathcal{B})$  i.e.  $Y_n = \mathbb{E}[X_n|\mathcal{B}]$ . Alors pour tout  $n \geq m$  on a que  $0 \leq \mathbb{E}[\mathbf{1}_A(X_n - X_m)] = \mathbb{E}[\mathbf{1}_A(Y_n - Y_m)]$  pour tout  $A \in \mathcal{B}$ , ce qu'implique que  $Y_n \geq Y_m$  p.s. (vérifier) et qu'il existe un ensemble de mesure nulle  $N \in \mathcal{B}$  en dehors duquel la suite  $(Y_n(\omega))_n$  est croissante pour tout  $\omega \in N^c$ .

Soit  $Y = \lim_n Y_n$ . On a que  $\mathbb{E}[\mathbf{1}_A Y] = \lim_n \mathbb{E}[\mathbf{1}_A Y_n] = \lim_n \mathbb{E}[\mathbf{1}_A X_n] = \mathbb{E}[\mathbf{1}_A X]$  par convergence monotone et donc que  $Y \in L^1(\mathcal{B})$  et que  $Y = \mathbb{E}[X|\mathcal{B}]$ .

- La première égalité vient du théorème de la convergence monotone (en effet  $(\mathbf{1}_A Y_n)_n$  est une suite croissante p.s. de variables aléatoires positives.)
- La deuxième égalité vient de l'espérance conditionnelle (rappelons que  $Y_n = \mathbb{E}[X_n|\mathcal{B}]$ ).
- La première égalité vient du théorème de la convergence monotone (en effet  $(\mathbf{1}_A X_n)_n$  est une suite croissante p.s. de variables aléatoires positives et  $\lim_n X_n = \lim_n \min(X, n) = X$  p.s.)

Pour une v.a.  $X$  tel que  $X \in L^1$  : soit  $X = X_+ - X_-$  avec  $X_+, X_- \geq 0$  et dans  $L^1$ . On pose  $Y_\pm = \mathbb{E}[X_\pm|\mathcal{B}]$  et  $Y = Y_+ - Y_-$ . On obtient que  $Y \in L^1(\mathcal{B})$  et que  $\mathbb{E}[\mathbf{1}_A X] = \mathbb{E}[\mathbf{1}_A Y]$  pour tout  $A \in \mathcal{B}$ .

Rappel : L'unicité au sens presque sûre de l'espérance conditionnelle a été démontrée en cours, voir la preuve qui est juste après le Lemme 1. □

## *Bibliographie*

M. Capinski and P.E. Kopp. *Measure, Integral and Probability*. Springer Undergraduate Mathematics Series. Springer London, 2013. ISBN 9781447106456. URL <https://books.google.fr/books?id=5d6PBAAAQBAJ>.