

Espérance Conditionnelle

1. Rappels.

- Dans toute ce paragraphe, $(\Omega, \mathcal{F}, \mathbb{P})$ est un espace probabilisé, i.e.
 - ★ Ω est un ensemble non vide.
 - ★ $\mathcal{F} \subset \mathcal{P}(\Omega)$ est une tribu (ou σ -algèbre) sur Ω :
 1. $\emptyset \in \mathcal{F}$;
 2. Si $A \in \mathcal{F}$, alors $A^c \in \mathcal{F}$;
 3. Si $(A_n)_{n \in \mathbf{N}} \subset \mathcal{F}$, alors $\bigcup_{n \in \mathbf{N}} A_n \in \mathcal{F}$.
 - ★ \mathbb{P} est (une mesure de) probabilité sur (Ω, \mathcal{F}) : $\mathbb{P} : \mathcal{F} \longrightarrow \overline{\mathbf{R}}_+ := \mathbf{R}_+ \cup \{+\infty\}$ t.q.
 1. $\mathbb{P}(\emptyset) = 0$;

2. Pour $(A_n)_{n \in \mathbf{N}} \subset \mathcal{F}$ t.q. $A_n \cap A_k = \emptyset$ si $k \neq n$,

$$\mathbb{P} \left(\bigcup_{n \in \mathbf{N}} A_n \right) = \sum_{n \geq 0} \mathbb{P}(A_n) ;$$

3. $\mathbb{P}(\Omega) = 1$.

Remarque(s). Une mesure de probabilité est à valeurs dans $[0, 1]$.

Définition (Tribu engendrée). Soit $\mathcal{C} \subset \mathcal{P}(\Omega)$. On appelle *tribu engendrée par \mathcal{C}* , notée $\sigma(\mathcal{C})$, la plus petite tribu sur Ω , au sens de l'inclusion, contenant \mathcal{C} .

- L'existence de $\sigma(\mathcal{C})$ résulte du fait qu'une intersection quelconque de tribus sur Ω est une tribu sur Ω .
- Si $A \subset \Omega$, $\sigma(\{A\}) = \{\emptyset, \Omega, A, A^c\}$.

Définition (Tribu borélienne). On appelle *tribu borélienne de \mathbf{R}^n* , notée $\mathcal{B}(\mathbf{R}^n)$, la tribu engendrée par les ouverts (pour la topologie usuelle) de \mathbf{R}^n .

- On a $\mathcal{B}(\mathbf{R}) = \sigma(\{]-\infty, a] : a \in \mathbf{R}\}) = \sigma(\{[a, b] : a \in \mathbf{R}, b \in \mathbf{R}\})$

Définition. Soit $X : \Omega \rightarrow \mathbf{R}^n$ une application. On dit que X est une *variable aléatoire* si

$$\forall B \in \mathcal{B}(\mathbf{R}^n), \quad X^{-1}(B) = \{\omega \in \Omega : X(\omega) \in B\} \stackrel{\text{not.}}{=} \{X \in B\} \in \mathcal{F}.$$

Remarque(s). Comme $\mathcal{B}(\mathbf{R}) = \sigma(\{]-\infty, a] : a \in \mathbf{R}\})$, X est une v.a. réelle ssi, pour tout réel a , $\{X \leq a\} \in \mathcal{F}$.

Définition. Soient X une variable aléatoire et \mathcal{G} une sous-tribu de \mathcal{F} . On dit que X est \mathcal{G} -mesurable si

$$\forall B \in \mathcal{B}(\mathbf{R}^n), \quad \{X \in B\} \in \mathcal{G}.$$

Définition (Tribu engendrée par une v.a.). Soit X une variable aléatoire. On appelle *tribu engendrée par X* , notée $\sigma(X)$, la plus petite tribu pour l'inclusion, qui rend X mesurable.

Lemme (Factorisation). *Soit X une variable aléatoire à valeurs dans \mathbf{R}^n . Une variable aléatoire réelle Y est $\sigma(X)$ -mesurable si et seulement si il existe une fonction $h : \mathbf{R}^n \rightarrow \mathbf{R}$ borélienne telle que $Y = h(X)$.*

Remarque(s). Plus généralement, si X_1, \dots, X_n sont des v.a., $\sigma(X_1, \dots, X_n)$ est la plus petite tribu pour l'inclusion qui rend X_1, \dots, X_n mesurables et Y est $\sigma(X_1, \dots, X_n)$ -mesurable ssi $Y = h(X_1, \dots, X_n)$ avec h borélienne.

Définition (Indépendance). Deux variables aléatoires X et Y sont indépendantes si les tribus $\sigma(X)$ et $\sigma(Y)$ le sont c'est à dire si

$$\begin{aligned} \forall B \in \mathcal{B}(\mathbf{R}^n), \forall C \in \mathcal{B}(\mathbf{R}^m), \\ \mathbb{P}(\{X \in B\} \cap \{Y \in C\}) = \mathbb{P}(\{X \in B\}) \mathbb{P}(\{Y \in C\}). \end{aligned}$$

Remarque(s). On peut également donner une définition « fonctionnelle » de l'indépendance : X et Y sont indépendantes si et seulement si, pour toutes fonctions f et g boréliennes et bornées,

$$\mathbb{E}[f(X)g(Y)] = \mathbb{E}[f(X)] \mathbb{E}[g(Y)].$$

Le passage de la définition ensembliste à la définition fonctionnelle se fait via la formule :

$$\forall B \in \mathcal{B}(\mathbf{R}^n), \quad \mathbb{P}(\{X \in B\}) = \mathbb{E}[\mathbf{1}_B(X)].$$

2. Espérance conditionnelle.

- Soient X et Y des variables aléatoires et \mathcal{G} une sous-tribu de \mathcal{F} .
 - ★ Connaissant l'information contenue dans \mathcal{G} , que peut-on dire de plus sur la v.a. X ?
 - ★ Quelle est la meilleure approximation de X connaissant $\sigma(Y)$?
 - ★ La notion d'espérance conditionnelle répond à ces questions

2.1. Exemple introductif.

- Soient X et Y deux v.a.r. ; X de carré intégrable et Y discrète à valeurs $y_1 < y_2 < y_3 < \dots$

- Pour tout borélien B et tout $j \geq 1$, la probabilité conditionnelle

$$\mathbb{P}(\{X \in B\} | \{Y = y_j\}) = \frac{\mathbb{P}(\{X \in B\} \cap \{Y = y_j\})}{\mathbb{P}(\{Y = y_j\})}$$

représente la fréquence de réalisation de $\{X \in B\}$ parmi tous les événements où $Y = y_j$.

- On remarque que

$$\mathbb{P}(\{X \in B\} | \{Y = y_j\}) = \frac{\mathbb{E}[\mathbf{1}_B(X) \mathbf{1}_{\{Y=y_j\}}]}{\mathbb{P}(\{Y = y_j\})},$$

et on définit, pour toute fonction f borélienne (bornée ou positive)

$$\mathbb{E}[f(X) | \{Y = y_j\}] = \frac{\mathbb{E}[f(X) \mathbf{1}_{\{Y=y_j\}}]}{\mathbb{P}(\{Y = y_j\})}.$$

- ★ En fait, la probabilité conditionnelle sachant $\{Y = y_j\}$, $A \mapsto \mathbb{P}(A | \{Y = y_j\})$, est la probabilité de densité $\mathbf{1}_{\{Y=y_j\}}/\mathbb{P}(\{Y = y_j\})$ par rapport à \mathbb{P} .

- On définit une variable aléatoire Z en posant

$$Z(\omega) = \sum_{j \geq 1} \mathbb{E}[X | \{Y = y_j\}] \mathbf{1}_{Y(\omega)=y_j}, \quad \text{i.e. } Z = \mathbb{E}[X | \{Y = y_j\}] \text{ si } Y = y_j.$$

- ★ Z est $\sigma(Y)$ -mesurable puisque $Z = h(Y)$ avec $h(y) = \sum_{j \geq 1} \mathbb{E}[X | \{Y = y_j\}] \mathbf{1}_{y=y_j}$

★ Par ailleurs, si $G = g(Y)$ est $\sigma(Y)$ -mesurable et de carré intégrable, on a

$$\begin{aligned}
 \mathbb{E}[GZ] &= \mathbb{E} \left[g(Y) \sum_{j \geq 1} \mathbb{E}[X \mid \{Y = y_j\}] \mathbf{1}_{Y=y_j} \right] = \sum_{j \geq 1} \mathbb{E} \left[g(Y) \mathbb{E}[X \mid \{Y = y_j\}] \mathbf{1}_{Y=y_j} \right], \\
 &= \sum_{j \geq 1} \mathbb{E} \left[g(y_j) \mathbb{E}[X \mid \{Y = y_j\}] \mathbf{1}_{Y=y_j} \right] = \sum_{j \geq 1} g(y_j) \mathbb{E}[X \mid \{Y = y_j\}] \mathbb{P}(\{Y = y_j\}), \\
 &= \sum_{j \geq 1} g(y_j) \mathbb{E}[X \mathbf{1}_{Y=y_j}] = \sum_{j \geq 1} \mathbb{E} \left[g(y_j) X \mathbf{1}_{Y=y_j} \right] = \sum_{j \geq 1} \mathbb{E} \left[g(Y) X \mathbf{1}_{Y=y_j} \right], \\
 &= \mathbb{E} \left[X g(Y) \sum_{j \geq 1} \mathbf{1}_{Y=y_j} \right] = \mathbb{E}[X g(Y)], \quad \text{puisque } \sum_{j \geq 1} \mathbf{1}_{Y=y_j} = 1, \\
 &= \mathbb{E}[GX].
 \end{aligned}$$

• La variable aléatoire Z vérifie les deux propriétés suivantes :

★ Z est $\sigma(Y)$ -mesurable ;

★ pour toute v.a. G , $\sigma(Y)$ -mesurable et de carré intégrable,

$$\mathbb{E}[G(X - Z)] = \langle G, X - Z \rangle = 0$$

où $\langle \cdot, \cdot \rangle$ désigne le produit scalaire de L^2 .

• Par conséquent, Z est la projection orthogonale de X sur $L^2(\sigma(Y))$, le sous-espace des v.a. $\sigma(Y)$ -mesurables de carré intégrable

- Z est vérifiée donc

$$\mathbb{E} [|X - Z|^2] = \min \left\{ \mathbb{E} [|X - G|^2] : G \in L^2(\sigma(Y)) \right\}.$$

- Z est la meilleure approximation de X , au sens des moindres carrés, connaissant l'information contenue dans $\sigma(Y)$.

2.2. Définition.

- Soit \mathcal{G} une sous-tribu de \mathcal{F}
- Notons $P_{\mathcal{G}}$ la projection orthogonale sur $L^2(\mathcal{G})$, le sous-espace vectoriel des « variables aléatoires » \mathcal{G} -mesurables et de carré intégrable.
- Si $X \in L^2(\mathcal{F})$, $Z = P_{\mathcal{G}}(X)$ vérifie
 - ★ Z est \mathcal{G} -mesurable ;
 - ★ Z est de carré intégrable ;
 - ★ Pour toute v.a. G , \mathcal{G} -mesurable et de carré intégrable, $\mathbb{E} [XG] = \mathbb{E} [ZG]$
- On a également,

$$\mathbb{E} [|X - Z|^2] = \min \left\{ \mathbb{E} [|X - G|^2] : G \in L^2(\mathcal{G}) \right\}.$$

- Il s'agit d'une généralisation du calcul inductif!
- On peut remarquer que $\mathbb{E}[P_{\mathcal{G}}(X)] = \mathbb{E}[X]$ et que $P_{\mathcal{G}}(X) \geq 0$ p.s. si $X \geq 0$ p.s.
- Cette construction peut être étendue, d'une certaine manière, aux v.a. intégrables

Définition (Espérance conditionnelle). Soient X une v.a.r. intégrable et \mathcal{G} une sous-tribu de \mathcal{F} . On appelle (*version de l'*)*espérance conditionnelle* de X sachant \mathcal{G} toute variable aléatoire Z vérifiant :

1. Z est \mathcal{G} -mesurable ;
2. Z est intégrable i.e. $\mathbb{E}[|Z|] < +\infty$;
3. Pour toute v.a. G , \mathcal{G} -mesurable et bornée, $\mathbb{E}[XG] = \mathbb{E}[ZG]$.

On note dans ce cas $Z = \mathbb{E}[X | \mathcal{G}]$.

Théorème. Soient X une v.a.r. intégrable et \mathcal{G} une sous-tribu de \mathcal{F} . Il existe une version de l'espérance conditionnelle de X sachant \mathcal{G} .

Si Z et Z' sont deux versions de l'espérance conditionnelle de X sachant \mathcal{G} , alors $Z = Z'$ p.s. i.e. $\mathbb{P}(Z = Z') = 1$.

- Lorsque $\mathcal{G} = \sigma(Y)$ où Y est une v.a. dans \mathbf{R}^m , on note $\mathbb{E}[X | Y]$ au lieu de $\mathbb{E}[X | \sigma(Y)]$
- $\mathbb{E}[X | Y]$ est la meilleure approximation de X connaissant Y

• D'après le lemme de factorisation, $Z = \mathbb{E}[X | Y]$ si

1. $Z = h(Y)$ avec $h : \mathbf{R}^m \rightarrow \mathbf{R}$ borélienne ;
2. $\mathbb{E}[|h(Y)|] < \infty$;
3. Pour toute $g : \mathbf{R}^m \rightarrow \mathbf{R}$ borélienne et bornée, $\mathbb{E}[Xg(Y)] = \mathbb{E}[h(Y)g(Y)]$.

Exemple(s). 1. Soient X et Y indépendantes ; X intégrable. On a $\mathbb{E}[X | Y] = \mathbb{E}[X]$. En effet, notant $Z = \mathbb{E}[X]$:

- (a) $Z = h(Y)$ avec h fonction constante égale à $\mathbb{E}[X]$;
- (b) Z intégrable ;
- (c) Pour g borélienne bornée, puisque X et Y son indépendantes

$$\mathbb{E}[Xg(Y)] = \mathbb{E}[X] \mathbb{E}[g(Y)] = \mathbb{E}[\mathbb{E}[X]g(Y)] = \mathbb{E}[Zg(Y)] .$$

2. Soient X et Y deux v.a. ; X intégrable et $\sigma(Y)$ -mesurable. Alors $\mathbb{E}[X | Y] = X$. En effet,

- (a) X est $\sigma(Y)$ -mesurable ;
- (b) X intégrable ;
- (c) Pour g borélienne bornée,

$$\mathbb{E}[Xg(Y)] = \mathbb{E}[Xg(Y)] .$$

3. Soit Y discrète prenant les valeurs distinctes $(y_j)_{j \geq 1}$. Si X est intégrable

$$\mathbb{E}[X | Y] = \sum_{j \geq 1} \mathbb{E}[X | Y = y_j] \mathbf{1}_{Y=y_j}, \quad \text{où } \mathbb{E}[X | Y = y_j] = \frac{\mathbb{E}[X \mathbf{1}_{Y=y_j}]}{\mathbb{P}(Y = y_j)}.$$

C'est le calcul inductif.

Proposition (Propriétés élémentaires). *Soit \mathcal{G} une sous-tribu de \mathcal{F} .*

1. *Pour toute constante réelle c , $\mathbb{E}[c | \mathcal{G}] = c$;*

2. *Si a et b sont deux réels, U et V deux v.a. intégrables*

$$\mathbb{E}[aU + bV | \mathcal{G}] = a \mathbb{E}[U | \mathcal{G}] + b \mathbb{E}[V | \mathcal{G}] ;$$

3. *Pour toute v.a. intégrable $\mathbb{E}[\mathbb{E}[X | \mathcal{G}]] = \mathbb{E}[X]$;*

4. *Si X est positive, $\mathbb{E}[X | \mathcal{G}]$ est positive ; en particulier, si X est intégrable*

$$|\mathbb{E}[X | \mathcal{G}]| \leq \mathbb{E}[|X| | \mathcal{G}].$$

Démonstration. La preuve est laissée en exercice. □

Exemple(s). 1. Si X et Y sont indépendantes, alors

$$\begin{aligned}\mathbb{E}[(X + Y)^2 | Y] &= \mathbb{E}[X^2 | Y] + 2\mathbb{E}[XY | Y] + \mathbb{E}[Y^2 | Y] = \mathbb{E}[X^2] + 2Y\mathbb{E}[X | Y] + Y^2, \\ &= \mathbb{E}[X^2] + 2Y\mathbb{E}[X] + Y^2 = \mathbb{V}(X) + (Y - \mathbb{E}[X])^2.\end{aligned}$$

2. Soient X une v.a. de loi uniforme sur $[0, 1]$ et Y une v.a. à valeurs dans \mathbf{N}^* telle que

$$\forall k \in \mathbf{N}^*, \quad \mathbb{P}(Y = k | X) = \mathbb{E}[\mathbf{1}_{Y=k} | X] = (1 - X)X^{k-1}.$$

On obtient facilement la loi de Y : pour $k \in \mathbf{N}^*$,

$$\mathbb{P}(Y = k) = \mathbb{E}[\mathbb{P}(Y = k | X)] = \mathbb{E}[(1 - X)X^{k-1}] = \int_0^1 (1 - x)x^{k-1} dx = \frac{1}{k(k+1)}.$$

Par ailleurs, Y étant discrète à valeurs dans \mathbf{N}^* , on a

$$\mathbb{E}[X | Y] = \sum_{k \geq 1} \mathbb{E}[X | Y = k] \mathbf{1}_{Y=k} = \sum_{k \geq 1} \mathbb{E}[X \mathbf{1}_{Y=k}] \mathbb{P}(Y = k)^{-1} \mathbf{1}_{Y=k},$$

et, pour tout $k \in \mathbf{N}^*$,

$$\mathbb{E}[X \mathbf{1}_{Y=k}] = \mathbb{E}[\mathbb{E}[X \mathbf{1}_{Y=k} | X]] = \mathbb{E}[X \mathbb{E}[\mathbf{1}_{Y=k} | X]] = \mathbb{E}[(1 - X)X^k] = \frac{1}{(k+1)(k+2)}.$$

Par conséquent,

$$\mathbb{E}[X | Y] = \sum_{k \geq 1} \frac{k(k+1)}{(k+1)(k+2)} \mathbf{1}_{Y=k} = \sum_{k \geq 1} \frac{k}{k+2} \mathbf{1}_{Y=k} = \frac{Y}{Y+2}.$$

Calculer $\mathbb{E}[X | Y]$.

2.3. Propriétés.

Proposition (Projections emboîtées). *Soient X une variable aléatoire intégrable, $\mathcal{H} \subset \mathcal{G}$ des sous-tribus de \mathcal{F} . Alors,*

$$\mathbb{E}[\mathbb{E}[X | \mathcal{G}] | \mathcal{H}] = \mathbb{E}[X | \mathcal{H}].$$

- Cette propriété généralise $\mathbb{E}[\mathbb{E}[X | \mathcal{G}]] = \mathbb{E}[X]$.

Démonstration. Notons $Z = \mathbb{E}[\mathbb{E}[X | \mathcal{G}] | \mathcal{H}]$ et montrons que $Z = \mathbb{E}[X | \mathcal{H}]$. Il s'agit de montrer que :

1. Z est \mathcal{H} -mesurable ;
2. Z est intégrable ;
3. Pour toute v.a. H bornée et \mathcal{H} -mesurable,

$$\mathbb{E}[ZH] = \mathbb{E}[ZX].$$

Pour le premier point, comme $Z = \mathbb{E}[TRUC | \mathcal{H}]$, Z est \mathcal{H} -mesurable. Par construction de l'espérance conditionnelle, X étant intégrable, $\mathbb{E}[X | \mathcal{G}]$ est intégrable et $Z = \mathbb{E}[\mathbb{E}[X | \mathcal{G}] | \mathcal{H}]$ aussi. Soit H bornée et \mathcal{H} -mesurable. Comme $\mathcal{H} \subset \mathcal{G}$, H est aussi \mathcal{G} -mesurable et donc

$$\mathbb{E}[ZH] = \mathbb{E}[\mathbb{E}[\mathbb{E}[X | \mathcal{G}] | \mathcal{H}]H] = \mathbb{E}[\mathbb{E}[X | \mathcal{G}]H] = \mathbb{E}[XH].$$

□

Proposition. *Soient X et Y deux v.a. et \mathcal{G} une sous-tribu. On suppose que X et XY sont intégrables et que Y est \mathcal{G} -mesurable. Alors*

$$\mathbb{E}[XY | \mathcal{G}] = Y \mathbb{E}[X | \mathcal{G}].$$

- Il s'agit d'une propriété d'usage très fréquent.

Démonstration. Faisons la preuve dans le cas où Y est bornée. Notons $Z = Y \mathbb{E}[X | \mathcal{G}]$ et montrons que $Z = \mathbb{E}[XY | \mathcal{G}]$. Les deux premiers points de la définition sont évidents. Pour le 3^e, soit G une va \mathcal{G} -mesurable et bornée. Comme YG est \mathcal{G} -mesurable et bornée, on a, par définition de $\mathbb{E}[X | \mathcal{G}]$,

$$\mathbb{E}[GYX] = \mathbb{E}[GY\mathbb{E}[X | \mathcal{G}]] = \mathbb{E}[GZ].$$

□

Proposition. *Soient X et Y deux variables aléatoires indépendantes à valeurs dans \mathbf{R}^n et \mathbf{R}^m et $h : \mathbf{R}^n \times \mathbf{R}^m \rightarrow \mathbf{R}$ une fonction borélienne telle que $\mathbb{E}[|h(X, Y)|] < \infty$. Alors*

$$\mathbb{E}[h(X, Y) | Y] = H(Y), \quad \text{avec} \quad H(y) = \mathbb{E}[h(X, y)].$$

- La preuve sera vue en TD dans le cas où (X, Y) possède une densité.

Exemple(s). Si X et Y sont des v.a. indépendantes, X de loi de Poisson de paramètre $\lambda > 0$, Y de loi exponentielle de paramètre 2λ , on a, Y^X étant positive,

$$\mathbb{E}[Y^X | Y] = H(Y) \quad \text{avec} \quad H(a) = \mathbb{E}[a^X] = e^{\lambda(a-1)}; \quad \mathbb{E}[Y^X | Y] = e^{\lambda(Y-1)}.$$

Par conséquent,

$$\mathbb{E}[Y^X] = \mathbb{E}[\mathbb{E}[Y^X | Y]] = e^{-\lambda} \mathbb{E}[e^{\lambda Y}] = e^{-\lambda} \int_0^{+\infty} e^{\lambda y} (2\lambda)e^{-2\lambda y} dy = 2e^{-\lambda}.$$

Proposition. Soient X une v.a. intégrable, \mathcal{G} et \mathcal{H} deux sous-tribus de \mathcal{F} . On suppose que \mathcal{H} est indépendante de la sous-tribu $\sigma(\sigma(X), \mathcal{G})$. Alors

$$\mathbb{E}[X | \sigma(\mathcal{G}, \mathcal{H})] = \mathbb{E}[X | \mathcal{G}].$$

Remarque(s). Attention, il ne suffit pas que \mathcal{H} et X soient indépendantes pour appliquer ce résultat ! \mathcal{G} peut amener un couplage. Par exemple, si X et Y sont indépendantes, notant $\mathcal{H} = \sigma(Y)$ et $\mathcal{G} = \sigma(X + Y)$

$$\mathbb{E}[X | \sigma(\mathcal{G}, \mathcal{H})] = X, \quad \mathbb{E}[X | \mathcal{G}] = \frac{X + Y}{2}.$$

Proposition (Intégrabilité). Soient $(X_n)_{n \geq 1}$ et X des v.a. intégrables.

Convergence monotone. *On suppose que, pour tout $n \geq 1$, $0 \leq X_n \leq X_{n+1}$ presque sûrement.*

Alors,

$$\lim_{n \rightarrow \infty} \mathbb{E}[X_n | \mathcal{G}] = \sup_{n \geq 1} \mathbb{E}[X_n | \mathcal{G}] = \mathbb{E} \left[\lim_{n \rightarrow \infty} X_n | \mathcal{G} \right] = \mathbb{E} \left[\sup_{n \geq 1} X_n | \mathcal{G} \right].$$

Lemme de Fatou. *On suppose que, pour tout $n \geq 1$, $X_n \geq 0$ presque sûrement. Alors,*

$$\mathbb{E} \left[\liminf_{n \rightarrow \infty} X_n | \mathcal{G} \right] \leq \liminf_{n \rightarrow \infty} \mathbb{E}[X_n | \mathcal{G}].$$

Convergence dominée. *On suppose que $(X_n)_{n \geq 1}$ converge vers X presque sûrement et que $\sup_{n \geq 1} |X_n|$ est intégrable. Alors,*

$$\lim_{n \rightarrow \infty} \mathbb{E}[|X_n - X| | \mathcal{G}] = 0 ; \quad \text{en particulier, } \lim_{n \rightarrow \infty} \mathbb{E}[X_n | \mathcal{G}] = \mathbb{E}[X | \mathcal{G}].$$

- Ces propriétés se déduisent facilement de leurs analogues pour l'espérance classique.

Proposition (Inégalité de Jensen). *Soient X une v.a. intégrable et \mathcal{G} une sous-tribu de \mathcal{F} . Soit $g : \mathbf{R} \rightarrow \mathbf{R}$ une fonction convexe telle que $\mathbb{E}[|g(X)|] < \infty$. Alors,*

$$g(\mathbb{E}[X | \mathcal{G}]) \leq \mathbb{E}[g(X) | \mathcal{G}].$$

- Une fonction g est convexe si, pour tous x, y et $\lambda \in [0, 1]$,

$$g(\lambda x + (1 - \lambda)y) \leq \lambda g(x) + (1 - \lambda)g(y).$$

- ★ On a alors $g(y) \geq g(x) + g'(x)(y - x)$
- ★ Si g est dérivable, g est convexe ssi g' est croissante.
- On utilise souvent l'inégalité de Jensen avec les fonctions $x \mapsto |x|^p$ convexe dès que $p \geq 1$ et $x \mapsto e^{ax}$ convexe pour tout réel a .

3. Loi conditionnelle.

Paragraphe non traité en 2019/2020

Définition. On appelle *noyau de transition* toute fonction $K : \mathbf{R}^m \times \mathcal{B}(\mathbf{R}^n) \longrightarrow [0, 1]$ telle que :

1. Pour tout $B \in \mathcal{B}(\mathbf{R}^n)$, $y \mapsto K(y, B)$ est borélienne ;
 2. Pour tout $y \in \mathbf{R}^m$, $B \mapsto K(y, B)$ est une mesure de probabilité notée $K(y, dx)$.
- $K(y, dx)$ est une famille de probabilités sur \mathbf{R}^n indexée par $y \in \mathbf{R}^m$.

Théorème (Jirina). Soient X et Y deux v.a. à valeurs dans \mathbf{R}^n et \mathbf{R}^m . Il existe un noyau de transition $K(y, dx)$ tel que : pour toute fonction $f : \mathbf{R}^n \longrightarrow \mathbf{R}$ borélienne et bornée,

$$\mathbb{E}[f(X) | Y] = \int_{\mathbf{R}^n} f(x) K(Y, dx) \quad \mathbb{P} - p.s.$$

- Un tel noyau de transition $K(y, dx)$ est appelée (*version de la*) *loi conditionnelle de X sachant Y*.
- On désigne $K(y, dx)$ par $\mathcal{L}(X | Y)$ ou $\mathcal{L}(X | Y = y)$.

Remarque(s). La loi du couple (X, Y) est obtenue à partir de $\mathcal{L}(X | Y)$ et $\mathcal{L}(Y)$. En effet, si f et g sont boréliennes et bornées

$$\begin{aligned} \mathbb{E}[f(X)g(Y)] &= \mathbb{E}[\mathbb{E}[g(Y)f(X) | Y]] = \mathbb{E}[g(Y) \mathbb{E}[f(X) | Y]], \\ &= \mathbb{E}\left[g(Y) \int_{\mathbf{R}^n} f(x)K(Y, dx)\right] = \int_{\mathbf{R}^m} g(y) \int_{\mathbf{R}^n} f(x)K(y, dx) \mathbb{P}_Y(dy), \\ &= \iint_{\mathbf{R}^n \times \mathbf{R}^m} g(y)f(x) K(y, dx) \mathbb{P}_Y(dy). \end{aligned}$$

Plus généralement, si $h : \mathbf{R}^n \times \mathbf{R}^m \rightarrow \mathbf{R}$ est borélienne et bornée

$$\mathbb{E}[h(X, Y)] = \iint_{\mathbf{R}^n \times \mathbf{R}^m} h(x, y) K(y, dx) \mathbb{P}_Y(dy).$$

On retient $\mathbb{P}_{(X, Y)}(dx, dy) = K(y, dx) \mathbb{P}_Y(dy)$.

Exemple(s). 1. Supposons que X et Y sont indépendantes. On a, dans ce cas, pour toute f borélienne bornée

$$\mathbb{E}[f(X) | Y] = \mathbb{E}[f(X)] = \int_{\mathbf{R}^n} f(x) \mathbb{P}_X(dx).$$

Par conséquent, $K(y, dx) = \mathbb{P}_X(dx)$ soit $\mathcal{L}(X | Y = y) = \mathcal{L}(X)$.

2. Supposons que X est $\sigma(Y)$ -mesurable. D'après le lemme de factorisation, $X = h(Y)$ avec $h : \mathbf{R}^m \rightarrow \mathbf{R}^n$ borélienne. On a, pour toute f borélienne bornée,

$$\mathbb{E}[f(X) | Y] = f(X) = f(h(Y)) = \int_{\mathbf{R}^n} f(x) \delta_{h(Y)}(dx).$$

Il s'en suit $K(y, dx) = \delta_{h(y)}(dx)$.

3. On suppose que (X, Y) possède une densité $p(x, y)$. Pour f et g boréliennes bornées,

$$\begin{aligned} \mathbb{E}[f(X)g(Y)] &= \iint_{\mathbf{R}^n \times \mathbf{R}^m} f(x)g(y) p(x, y) dx dy = \int_{\mathbf{R}^m} g(y) \left(\int_{\mathbf{R}^n} f(x) p(x, y) dx \right) dy \\ &= \int_{\mathbf{R}^m} g(y) \left(\frac{\int_{\mathbf{R}^n} f(x) p(x, y) dx}{p_Y(y)} \right) p_Y(y) dy, \end{aligned}$$

où p_Y désigne la densité de Y i.e.

$$p_Y(y) = \int_{\mathbf{R}^n} p(x, y) dx.$$

Par conséquent,

$$\mathbb{E}[f(X) | Y] = \int_{\mathbf{R}^n} f(x) \frac{p(x, Y)}{p_Y(Y)} dx, \quad K(y, dx) = \frac{p(x, y)}{p_Y(y)} dx.$$