

# Chapitre 3

## Probabilité et espérance conditionnelles

### 3.1 Probabilité conditionnelle

Rappelons que nous comprenons la probabilité d'un événement  $A \subseteq \Omega$  comme une mesure de l'espérance que nous avons que c'est l'évènement  $A$  qui se réalisera et non son contraire  $A^c$ , c'est-à-dire une mesure de l'espérance que nous avons que l'état du monde  $\omega^*$  où l'on se trouve est tel que  $\omega^* \in A$ . Imaginons à présent que nous souhaitons déterminer comment réévaluer cette espérance si nous considérons comme acquis que  $\omega^* \in B$  (soit qu'on a une information qui nous assure de cela, soit qu'on souhaite simplement traiter séparément les deux cas  $\omega^* \in B$  et  $\omega^* \notin B$ ). On appelle cette nouvelle probabilité la *probabilité de  $A$  sachant  $B$* , et on la note  $\mathbb{P}_B(A)$  (ou  $\mathbb{P}(A|B)$ ). Soulignons que  $\mathbb{P}_B$  est bien une probabilité sur (tout)  $\Omega$ , simplement veut-on au-moins que  $\mathbb{P}_B(A) = 0$  si  $A \subseteq B^c$  (puisque si  $\omega^* \in B$ , on est certain que  $\omega^* \notin A$ ); on veut aussi que  $\mathbb{P}_B(B) = 1$  (puisque'on envisage ici que le cas où  $\omega^* \in B$ ). L'idée est alors de poser  $\mathbb{P}_B(A) = c\mathbb{P}(A \cap B)$  ce qui assurera facilement que  $\mathbb{P}_B$  est une probabilité, et comme  $\mathbb{P}_B(B) = 1$ , nous voyons que  $c = 1/\mathbb{P}(B)$ ; bien-entendu ceci impose que  $\mathbb{P}(B) \neq 0$ . Le fait qu'un évènement  $B$  soit de probabilité nulle ou non étant souvent capitale, on dit qu'un évènement est *négligeable* si et seulement si  $\mathbb{P}(B) = 0$ .

D'où finalement la définition

**Définition :** Soit  $B$  un évènement non-négligeable de  $(\Omega, \mathcal{B})$ . On appelle *probabilité conditionnelle sachant  $B$*  la fonction  $\mathbb{P}_B : \mathcal{B} \rightarrow [0, 1]$  définie, pour tout évènement  $A \in \mathcal{B}$ , par 
$$\mathbb{P}_B(A) = \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)}.$$

**Proposition 3.1** Si  $\mathbb{P}$  est une probabilité sur  $(\Omega, \mathcal{B})$ , et si  $B \in \mathcal{B}$  n'est pas négligeable, alors  $\mathbb{P}_B$  est également une probabilité sur  $(\Omega, \mathcal{B})$ .

**Exercice :** Montrer la proposition 3.1 et vérifier que  $\mathbb{P}_B(A) = \mathbb{E}(\mathbb{I}_A \mathbb{I}_B) / \mathbb{E}(\mathbb{I}_B)$ .

On dit qu'une famille d'évènements  $(A_i)_{i=1..n}$  forme un système complet d'évènements (s.c.é) si et seulement si  $^1 \Omega = \bigcup_{i=1..n} A_i$ , c'est-à-dire que chaque  $\omega \in \Omega$  appartient à un  $A_i$  et un seul. Dans ce cas, pour tout évènement  $B \in \mathcal{B}$  on a  $B = \bigcup_{i=1..n} (B \cap A_i)$  et donc  $\mathbb{P}(B) = \sum_{i=1}^n \mathbb{P}(B \cap A_i) = \sum_{i=1}^n \frac{\mathbb{P}(B \cap A_i)}{\mathbb{P}(A_i)} \mathbb{P}(A_i)$ , d'où la *formule de la probabilité totale*

$$\mathbb{P}(B) = \sum_{i=1}^n \mathbb{P}(B|A_i) \mathbb{P}(A_i). \quad (3.1)$$

Imaginons connues les probabilité  $\mathbb{P}(B|A_i)$  et  $\mathbb{P}(A_i)$  pour tout  $i = 1..n$ . La *formule de Bayes*<sup>2</sup> suivante permet d'en déduire les  $\mathbb{P}(A_i|B)$ .

---

<sup>1</sup>Certains auteurs se contentent de demander que les  $A_i$  soient deux-à-deux disjoints et  $\mathbb{P}\left(\bigcup_{i=1..n} A_i\right) = 1$ ; voyez-vous la différence? Que peut-on dire de  $N := \left(\bigcup_{i=1..n} A_i\right)^c$ ?

<sup>2</sup>Thomas Bayes (1702-1761), publication (postume) de *An Essay Toward Solving a Problem of Chances*, en 1754.

**Théorème 3.2 (formule de Bayes)** Soit  $(A_i)_{i=1..n}$  un s.c.é. de  $(\Omega, \mathcal{B})$ . Alors, pour tout évènement  $B$  non-négligeable, et tout  $j = 1..n$ , on a

$$\mathbb{P}(A_j|B) = \frac{\mathbb{P}(B|A_j)\mathbb{P}(A_j)}{\mathbb{P}(B)} \left( = \frac{\mathbb{P}(B|A_j)\mathbb{P}(A_j)}{\sum_{i=1}^n \mathbb{P}(B|A_i)\mathbb{P}(A_i)} \right).$$

**Preuve :** Elle se réduit à l'application de la définition de  $\mathbb{P}(A_j|B)$  et de  $\mathbb{P}(B|A_j)$  :

$$\mathbb{P}(A_j|B) = \frac{\mathbb{P}(A_j \cap B)}{\mathbb{P}(B)} = \frac{\mathbb{P}(B \cap A_j)}{\mathbb{P}(B)} = \frac{\mathbb{P}(B|A_j)\mathbb{P}(A_j)}{\mathbb{P}(B)},$$

et on termine par la formule (3.1). □

**Exercice :** Deux usines se partagent la production mondiale de vistemboirs<sup>3</sup>. Un vistemboir choisi au hasard<sup>4</sup> a la probabilité 0.5 de provenir de l'une comme de l'autre usine. Les vistemboirs de la première usine sont défectueux avec une probabilité de 2% et ceux de la seconde usine sont défectueux avec une probabilité de 6%. On choisit un vistemboir au hasard : qu'elle est la probabilité qu'il provienne de la première usine (Indication : poser  $A_i :=$  "le vistemboir est produit dans l'usine  $i$ ", et  $B :=$  "le vistemboir est défectueux". Cet exemple explique pourquoi cette formule est parfois appelée "formule des probabilités des causes".)

## 3.2 Indépendance

Cette définition assez anodine de probabilité conditionnelle nous conduit à une notion capitale en probabilité : celle d'indépendance. Au chapitre 1 nous avons vu ce qu'est une v.a.  $Y$  qui est  $X$ -mesurable : c'est une simple fonction déterministe de  $X$  dans le sens où  $Y = g(X)$  pour une fonction déterministe  $x \mapsto g(x)$ ; donc  $Y(\omega)$  est entièrement connu dès que  $X(\omega)$  est connu. A l'inverse, nous souhaitons une notion d'indépendance telle la connaissance de  $X(\omega)$  ne nous apprenne rien sur  $Y(\omega)$ . En fait nous allons définir ce que sont deux évènements  $A$  et  $B$  indépendants et demanderons que les évènements  $\{X \leq x\}$  et  $\{Y \leq y\}$  soient (tous) indépendants. L'idée que deux évènements  $A$  et  $B$  sont indépendants est que le fait de supposer, par exemple, que  $B$  a lieu ne change pas la probabilité de  $A$ , c'est-à-dire que  $\mathbb{P}_B(A) = \mathbb{P}(A)$ , ce qu'il n'a de sens que si  $\mathbb{P}(B) \neq 0$ . On veut aussi s'affranchir de l'apparente disymétrie et que  $\mathbb{P}_A(B) = \mathbb{P}(B)$  (sous réserve cette fois que  $\mathbb{P}(A) \neq 0$ ). Explicitons ces deux identités ; nous obtenons

$$\frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)} = \mathbb{P}(A) \text{ et } \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(A)} = \mathbb{P}(B).$$

En "chassant les dénominateurs", nous voyons que les deux relations se réduisent à l'unique relation  $\mathbb{P}(A \cap B) = \mathbb{P}(A) \cdot \mathbb{P}(B)$  qui a en outre l'avantage d'être définie même si  $\mathbb{P}(A) = 0$  ou  $\mathbb{P}(B) = 0$ . Ceci nous conduit donc tout naturellement à la définition

**Définition :** Soit  $\mathbb{P}$  une probabilité sur  $(\Omega, \mathcal{B})$ , et soient  $A \in \mathcal{B}$  et  $B \in \mathcal{B}$  deux évènements. On dit que les évènements  $A$  et  $B$  sont *indépendants pour la probabilité*  $\mathbb{P}$  si et seulement si  $\boxed{\mathbb{P}(A \cap B) = \mathbb{P}(A) \cdot \mathbb{P}(B)}$ .

Soient  $X$  et  $Y$  deux v.a. sur  $(\Omega, \mathcal{B})$ . On dit que les v.a.  $X$  et  $Y$  sont *indépendantes pour la probabilité*  $\mathbb{P}$  si et seulement si pour tous  $x$  et  $y$  les évènements  $\{X \leq x\}$  et  $\{Y \leq y\}$  sont indépendants.

**Notations :** Il est commode d'écrire  $A \perp\!\!\!\perp B$  pour noter que les évènements  $A$  et  $B$  sont indépendants, et d'écrire  $X \perp\!\!\!\perp Y$  pour noter que les v.a.  $X$  et  $Y$  sont indépendantes.

**Exemple : Pièces de monnaie indépendantes :** Considérons l'ensemble des états du monde  $\Omega$  suivant :

$$\Omega = \{0, 1\}^2 = \{0, 1\} \times \{0, 1\} = \{\omega = (\omega_1, \omega_2), \omega_i = 0..1, i = 1..2\}.$$

Posons  $X_1(\omega_1, \omega_2) = \omega_1$  et  $X_2(\omega_1, \omega_2) = \omega_2$ . Considérons deux pièces de monnaie, et modélisons le fait que la première tombe sur Pile par l'évènement  $\{X_1 = 1\}$ , l'évènement  $\{X_2 = 1\}$  modélisant quant à lui que la seconde pièce tombe sur Pile. Soient  $p := \mathbb{P}(\{X_1 = 1\})$  et  $q := \mathbb{P}(\{X_2 = 1\})$ . Supposons les deux pièces indépendantes. Notons  $A := \{X_1 = 1\}$  et  $B := \{X_2 = 1\}$ ; l'indépendance des deux pièces implique celle de  $A$  et  $B$ , donc  $\mathbb{P}(A \cap B) = \mathbb{P}(A)\mathbb{P}(B) = pq$ , et donc  $\mathbb{P}(\{(X_1, X_2) = (1, 1)\}) = pq$ . En procédant de même pour les autres combinaisons de valeurs de  $X_1$  et  $X_2$ , nous voyons que les deux pièces sont indépendantes si et seulement si on a le tableau des probabilités suivant :

<sup>3</sup> "Vistemboir" : nouvelle de Jacques Perret, La Machin, NRF, Gallimard, 1953.

<sup>4</sup> de "azzahr", le jeu de dés, en arabe ; ne me demandez pas comment on fait pour "choisir au hasard"...

$\downarrow X_1 = *, X_2 = * \longrightarrow$	1	0	$\mathbb{P}(\{X_1 = *\}) \downarrow$
1	$pq$	$p(1-q)$	$p$
0	$(1-p)q$	$(1-p)(1-q)$	$1-p$
$\mathbb{P}(\{X_2 = *\}) \longrightarrow$	$q$	$1-q$	

**Exercice : Pièces indiscernables :** On reprend les notation de l'exemple précédent. Montrer que  $X_1 \perp\!\!\!\perp X_2 \Rightarrow \mathbb{P}(X_1 \neq X_2) = p + q - 2pq$ . On dit que les deux pièces sont *indiscernables* si  $\mathbb{P}(X_1 \neq X_2) = \mathbb{P}(X_1 = X_2 = 1) = \mathbb{P}(X_1 = X_2 = 0) = \frac{1}{3}$ ; montrer que deux pièces indiscernables ne peuvent être indépendantes.

**Définition :** Soit  $(A_i)_{i \in I}$  une famille d'évènements (l'ensemble  $I$  peut être infini). On dit que ces évènements sont indépendants si et seulement si  $I_0 \mathbb{P}(\bigcap_{i \in I_0} A_i) = \prod_{i \in I_0} \mathbb{P}(A_i)$  pour tout sous-ensemble fini. Il est commode de dénoter par  $\prod_{i \in I} A_i$  la propriété que ces évènements sont indépendants.

On dit que les v.a. d'une famille  $(X_i)_{i \in I}$  sont indépendantes si et seulement si pour tous  $x_i \in \mathcal{X}_i := X_i(\Omega)$  les évènements  $(\{X_i \leq x_i\})_{i \in I}$  sont indépendants. Il est commode de dénoter par  $\prod_{i \in I} X_i$  la propriété que ces v.a. sont indépendantes.

**Exercice : Evènements (mutuellement) indépendants :** On reprend les v.a. indépendantes de l'exemple, et on choisit  $p = \frac{1}{2} = q$ ; on pose  $X = X_1$ ,  $Y = X_2$ , et  $Z = |X - Y|$ . Quelles sont les valeurs possibles pour la v.a.  $Z$ ? Les v.a.  $X$  et  $Y$  sont indépendantes par construction; montrer que les v.a.  $X$  et  $Z$  sont indépendantes, et que les v.a.  $Y$  et  $Z$  sont indépendantes. On pose  $A := \{X \leq 0\}$ ,  $B := \{Y \leq 0\}$ , et  $C := \{Z \leq 0\}$ . Calculer  $\mathbb{P}(A)$ ,  $\mathbb{P}(B)$ ,  $\mathbb{P}(C)$ , et  $\mathbb{P}(A \cap B \cap C)$ . Montrer que les v.a.  $X$ ,  $Y$ , et  $Z$  ne sont pas indépendantes. Cet exemple montre que trois v.a. peuvent être indépendantes deux-à-deux sans être indépendantes. C'est pourquoi, pour des v.a. qui sont indépendantes au sens de la définition que nous avons données, on dit parfois qu'elles sont *mutuellement* indépendantes.

**Proposition 3.3** Si les v.a.  $(X_i)_{i \in I}$  ne prennent chacune qu'un ensemble fini ou dénombrable de valeurs  $\mathcal{X}_i := X_i(\Omega) = \{x_j^i, j = 1, 2, \dots\}$ , les v.a.  $(X_i)_{i \in I}$  sont indépendantes si et seulement si pour tous  $x^i \in \mathcal{X}_i$  les évènements  $(\{X_i = x^i\})_{i \in I}$  sont indépendants.

Soient  $(X_i)_{i \in I}$  une famille de v.a. et  $(g_i)_{i \in I}$  une famille de fonctions  $g_i : X_i(\Omega) \rightarrow \mathbb{R}$ . Posons  $Y_i := g_i(X_i)$ . Si les v.a.  $(X_i)_{i \in I}$  sont indépendantes, alors les v.a.  $(Y_i)_{i \in I}$  sont également indépendantes.

**Théorème 3.4** Si les v.a.  $X$  et  $Y$  sont indépendantes, on a  $\mathbb{E}(XY) = \mathbb{E}(X)\mathbb{E}(Y)$ .

**Preuve :** Voir cours; c'est facile. □

**Remarque :** nous avons déjà vu que  $\mathbb{E}$  est linéaire, et qu'on a donc  $\mathbb{E}(aX + bY) = a\mathbb{E}(X) + b\mathbb{E}(Y)$ . Nous voyons ici que si les v.a.  $X$  et  $Y$  sont indépendantes, on a de plus  $\mathbb{E}(XY) = \mathbb{E}(X)\mathbb{E}(Y)$ . Ceci est évidemment très commode pour les calculs d'espérance, mais soulignons bien que si la linéarité est toujours assurée, la relation  $\mathbb{E}(XY) = \mathbb{E}(X)\mathbb{E}(Y)$  est généralement fautive lorsque l'hypothèse d'indépendance n'est pas assurée.

A noter que la réciproque " $\mathbb{E}(XY) = \mathbb{E}(X)\mathbb{E}(Y) \Rightarrow X \perp\!\!\!\perp Y$ " est fautive également : soit  $X$  une v.a. (élémentaire) symétrique, c'est-à-dire  $\mathbb{P}(\{X \geq +x\}) = \mathbb{P}(\{X \leq -x\})$  pour tout  $x$ , alors  $Z := X^3$  est également symétrique, et donc  $\mathbb{E}(X) = 0 = \mathbb{E}(Z)$ . Posons à présent  $Y := X^2$ ;  $Y$  n'est bien entendu pas indépendant de  $X$  (sauf si  $X = 0$ ), et pourtant  $\mathbb{E}(XY) = \mathbb{E}(X \cdot X^2) = \mathbb{E}(Z) = 0 = 0 \cdot \mathbb{E}(X^2) = \mathbb{E}(X) \cdot \mathbb{E}(X^2) = \mathbb{E}(X)\mathbb{E}(Y)$ .

**Exercice :** Démontrer ce qui vient d'être affirmé ci-dessus : donner un exemple de v.a. élémentaire symétrique  $X$  (choisir  $X(\Omega) = \{-1, +1\}$ ). Montrer que  $\mathbb{P}(X = +1) = \mathbb{P}(X = -1) = \frac{1}{2}$ ; en déduire que  $\mathbb{E}(X) = 0 = \mathbb{E}(X^3)$ . Montrer que  $X$  et  $Y := X^2$  ne sont pas indépendantes.

### 3.3 Espérance conditionnelle

Soit tout d'abord  $Y$  une v.a. sur  $(\Omega, \mathcal{B})$ , et  $A \in \mathcal{B}$  un évènement non-négligeable. Nous pouvons donc considérer la probabilité conditionnelle  $\mathbb{P}_A$  sur  $(\Omega, \mathcal{B})$ . L'espérance de  $Y$  sachant  $A$ , notée  $\mathbb{E}(Y|A)$ , est l'espérance de  $Y$  pour cette probabilité  $\mathbb{P}_A$ , c'est-à-dire le nombre

$$\mathbb{E}(Y|A) := \mathbb{E}^{\mathbb{P}_A}(Y) := \frac{1}{\mathbb{P}(A)} \sum_{y \in Y(\Omega)} y \mathbb{P}(\{Y = y\} \cap A).$$

C'est donc la moyenne des valeurs de  $Y$  pondérée par la probabilité qu'ont ces valeurs lorsque l'évènement  $A$  est supposé assuré.

Si l'on considère le cas où l'évènement  $A$  est la survenue d'une valeur (non négligeable) d'une v.a.  $X$ , l'espérance conditionnelle permet d'associer à la v.a.  $Y$  une nouvelle v.a.  $\bar{Y}_X$  ne dépendant que des valeurs de  $X$ . Voici comment :

Nous supposons que la v.a.  $X$  est élémentaire et notons  $\mathcal{X} := X(\Omega) = \{x_1, \dots, x_n\}$  l'ensemble de ses valeurs prises (avec probabilité non nulle, par définition d'une v.a. élémentaire). Ce qui suit n'est pas restreint à ce cas particulier mais l'exposition du cas général implique des constructions masquant trop facilement le but poursuivi.

Soit  $x \in \mathcal{X}$ ; l'évènement  $B_x := \{X = x\}$  est de probabilité non nulle et on peut considérer la probabilité  $\mathbb{P}_{B_x}$  conditionnellement à cet évènement. Soit à présent  $Y$  une v.a.; notons  $\mathbb{E}_x(Y)$  l'espérance de  $Y$  pour la probabilité  $\mathbb{P}_{B_x}$ . Ce nombre ne prend donc en compte que les valeurs  $Y(\omega)$  que prend  $Y$  lorsque  $X(\omega) = x$ ; en effet

$$\mathbb{E}_x(Y) = \sum_{y \in Y(\Omega)} y \mathbb{P}_{B_x}(\{Y = y\}) = \frac{1}{\mathbb{P}(\{X = x\})} \sum_{y \in Y(\Omega)} y \mathbb{P}(\{Y = y\} \cap \{X = x\}),$$

et  $\mathbb{P}(\{Y = y\} \cap \{X = x\}) = 0$  si  $y \notin Y(\{X = x\})$ , puisque  $\{Y = y\} \cap \{X = x\} = \emptyset$  dans ce cas. Cette formule montre que le nombre  $\mathbb{E}_x(Y)$  est la moyenne des valeurs de  $Y$  pondérée par la probabilité de  $\{Y = y\} \cap \{X = x\}$ . Si l'on effectue cette opération pour chaque  $x \in X(\Omega)$  on définit une fonction  $x \mapsto g(x) := \mathbb{E}_x(Y)$ ; nous pouvons alors considérer la nouvelle v.a.  $\bar{Y}_X := g(X)$ ; par construction elle est constante sur les parties de la partition de  $\Omega$  en les  $\{X = x\}$ ,  $x \in \mathcal{X}$ , et cette valeur constante est une moyenne de  $Y$  sur  $\{X = x\}$ ; nous pouvons donc comprendre  $\bar{Y}_X$  comme la v.a.  $X$ -mesurable "ressemblant le plus à  $Y$ "; en particulier, si  $Y$  est (déjà)  $X$ -mesurable, on a  $\bar{Y}_X = Y$ . En revanche, si  $Y$  et  $X$  sont indépendantes, ce traitement dégrade complètement la v.a.  $Y$  en une constante (la constante qui ressemble le plus à  $Y$ , à savoir  $\mathbb{E}(Y)$ ). Encore un mot :  $\bar{Y}_X$  se note  $\mathbb{E}(Y|X)$ , notation commode dans les calculs, mais peut-être pas très évocatrice.

A noter que la v.a.  $X$  n'a été utilisée dans cette construction que pour définir la partition de  $\Omega$  en les atomes de  $\alpha(X)$  que sont les évènements  $\{X = x\}$ , pour  $x \in \mathcal{X}$ . Soit  $\mathcal{A}$  est une algèbre quelconque et supposons que ses atomes  $A_i$  soient de probabilité non nulle. La même construction conduit à la v.a.  $\mathbb{E}(Y|\mathcal{A})$ , appelée "espérance conditionnelle de  $Y$  relativement à l'algèbre  $\mathcal{A}$ ", qui est constante sur les atomes  $A_i$  de  $\mathcal{A}$ , définie par

$$\mathbb{E}(Y|\mathcal{A})(\omega) = \mathbb{E}(Y|A_i) \text{ pour tout } \omega \in A_i.$$

**Exercice :** Soit  $X$  une v.a. élémentaire. Montrer que  $\mathbb{E}(Y|X) = \mathbb{E}(Y|\alpha(X))$ ; en déduire que  $\mathbb{E}(Y|X) = \mathbb{E}(Y|g(X))$  pour toute application injective  $g$ . Ceci montre le rôle réduit des valeurs de la v.a.  $X$  dans  $\mathbb{E}(Y|X)$  : seule l'information révélée par  $X$  (c'est-à-dire  $\alpha(X)$ ) est essentielle.

**Théorème 3.5** Soient  $\mathcal{A}^+ \supseteq \mathcal{A}^-$  deux algèbres, alors  $\mathbb{E}(\mathbb{E}(X|\mathcal{A}^+)|\mathcal{A}^-) = \mathbb{E}(X|\mathcal{A}^-)$ .

Si  $Z$  est  $\mathcal{A}$ -mesurable, alors  $\mathbb{E}(ZX|\mathcal{A}) = Z\mathbb{E}(X|\mathcal{A})$ .

Soit  $Y$  une v.a.  $\mathcal{A}$ -mesurable. Alors  $Y = \mathbb{E}(X|\mathcal{A})$  si et seulement si  $\mathbb{E}(Y\mathbb{1}_A) = \mathbb{E}(X\mathbb{1}_A)$  pour tout  $A \in \mathcal{A}$

**Exercice :** Montrer ce théorème 3.5 dans le cas où les atomes de  $\mathcal{A}$  et  $\mathcal{A}^+$  (et donc ceux de  $\mathcal{A}^-$ ) ne sont pas négligeables et  $Z$  est une v.a. élémentaire.



Thomas Bayes (1702-1761) :