

INTRODUCTION AUX PROBABILITES

IX-X-XI-XII

Support du cours donné en 1^{re} année
par Marietta Manolessou
EISTI - Département Mathématiques

Année 2011-2012

Table des matières

	Probabilités	1
9	Indépendance des variables aléatoires	1
1	Variables aléatoires indépendantes	1
2	Variables aléatoires dépendantes	1
1	Covariance de deux variables aléatoires X_1, X_2	2
3	Echantillon	2
10	Inégalités de Tchebycheff	3
1	3
11	Convergence d'une suite de variables aléatoires	5
1	5
1	Convergence en probabilité	5
2	Convergence en moyenne quadratique	5
3	Convergence presque sûre	6
2	Lois des grands nombres	6
1	Loi forte (resp.Loi faible) des grands nombres	6
2	Convergence en loi	7
3	Th. "Limite Centrale"	8
4	Th. de De Moivre- Laplace	8
12	Vecteurs aléatoires	11
1	Vecteurs aléatoires de dimension 2	11
1	Définition	11
2	Mesure de Probabilité - Fonction de répartition conjointe	11
3	Fonction de répartition marginale	12
4	Espérance mathématique (cas général : $h(X, Y)$)	12
5	Indépendance	13
6	Covariance (définition)	13
2	Vecteurs aléatoires à $n > 2$ dimensions	14
1	Fonction de répartition	14
2	Espérance Mathématique (cas général pour une fonction $h(X)$)	15
3	Matrice de covariance (Γ)	15
4	Probabilités Conditionnelles par rapport à un événement	15
5	Indépendance	16
6	Distributions Conditionnelles entre variables et vecteurs aléatoires	16
7	Moments conditionnels (cas général-vectoriel)	17
8	Transformations de vecteurs aléatoires (à densité)	18

Table des figures

Chapitre 9

Indépendance des variables aléatoires

1 Variables aléatoires indépendantes

Définition 1.1

Soient X, Y deux variables aléatoires définies sur $(\Omega, \mathcal{A}, \mathcal{P})$ donc $(X, Y) : (\Omega, \mathcal{A}, \mathcal{P}) \rightarrow (\mathbb{R} \times \mathbb{R}, \mathcal{B})$
On dit que X, Y sont indépendantes si quelque soit le couple de boréliens B_i, B_j , on a :

$$P[\{X \in B_i\} \cap \{Y \in B_j\}] = P[\{X \in B_i\}]P[\{Y \in B_j\}]$$

Autrement : la loi de probabilité P_{XY} du couple (X, Y) est égale au produit des lois P_X et P_Y :

$$P_{XY} = P_X P_Y$$

Définition 1.2 (Généralisation)

Soient $\{X_1, X_2, \dots, X_n\}$ une famille de variables aléatoires définies sur $(\Omega, \mathcal{A}, \mathcal{P})$ donc

$$\{X_1, X_2, \dots, X_n\} : (\Omega, \mathcal{A}, \mathcal{P}) \rightarrow (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n))$$

On dit que ces variables aléatoires sont indépendantes si quelque soient les boréliens B_1, \dots, B_n , on a :

$$P\left[\bigcap_{i=1}^n \{X_i \in B_i\}\right] = \prod_{i=1}^n [P[\{X_i \in B_i\}]]$$

Théorème 1.1

Si deux variables aléatoires X_1 et X_2 sont indépendantes :

$$P[\{X_1 \in A\} \cap \{X_2 \in B\}] = P[\{X_1 \in A\}] P[\{X_2 \in B\}]$$

$$\Rightarrow E(X_1 X_2) = E(X_1) E(X_2)$$

Remarque 1.1

Attention : La réciproque n'est pas toujours vraie !

2 Variables aléatoires dépendantes

Définition 2.1

$$\begin{aligned} P[\{X_i \in A_i\} \cap \{X_j \in A_j\}] &= P[X_i \in A_i | \{X_j \in A_j\}] P[\{X_j \in A_j\}] \\ &\Leftrightarrow P[\{X_i X_j\} \in A] \quad A = "A_i \cap A_j" \end{aligned}$$

1 Covariance de deux variables aléatoires X_1, X_2

Définition 2.2

$$\text{cov}[X_1, X_2] = E[(X_1 - \mu_{X_1})(X_2 - \mu_{X_2})] = E[X_1 X_2] - \mu_{X_1} \mu_{X_2}$$

Remarque 2.1

Quand X_1 et X_2 sont indépendantes, d'après le théorème précédent :

$$E[X_1, X_2] = E[X_1] E[X_2]$$

$$\Rightarrow \text{cov}[X_1, X_2] = 0$$

Théorème 2.1

Soient X_k , avec $k \in \{1, \dots, p\}$, variables aléatoires et, a_k, b_k , avec $k \in \{1 \dots p\}$, une suite de nombres réels alors :

$$\Rightarrow \text{var} \left[\sum_{k=1}^p a_k X_k + b_k \right] = \sum_{k=1}^p a_k^2 \text{var} [X_k] + \sum_{i \neq j} a_i a_j \text{cov} [X_i X_j]$$

Théorème 2.2

Soient X_k , avec $k \in \{1, \dots, p\}$, variables aléatoires indépendantes et, a_k, b_k , avec $k \in \{1 \dots p\}$, une suite de nombres réels alors :

$$E \left[\sum_{k=1}^p a_k X_k + b_k \right] = \sum_{k=1}^p a_k E [X_k] + b_k$$

$$\text{var} \left[\sum_{k=1}^p a_k X_k + b_k \right] = \sum_{k=1}^p a_k^2 \text{var} [X_k]$$

3 Echantillon

Définition 3.1 (échantillon)

On définit un échantillon par les données suivantes.

1. Le n-uplet de variables aléatoires (X_1, \dots, X_n) indépendantes qui suivent la même loi de probabilités avec paramètres (μ, σ^2) .
2. X une variable aléatoire abstraite appelée *variable aléatoire parente*, (qui suit la même loi) avec paramètres (μ, σ^2)
3. $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ la moyenne empirique de l'échantillon, qui vérifie les propriétés :

$$E[\bar{X}] = \mu \quad \text{var}[\bar{X}] = \frac{\sigma^2}{n}.$$

Chapitre 10

Inégalités de Tchebycheff

1

Théorème 1.1 Soient (Ω, \mathcal{A}, P) et X variable aléatoire sur (Ω, \mathcal{A})
Si $h : \mathbb{R} \rightarrow [0, +\infty[$ tel que $h(X)$ variable aléatoire et $E[h(X)]$ existe

$$\Rightarrow \forall k > 0 P[\{h(X)\} \geq k] \leq \frac{E[h]}{k}$$

Théorème 1.2

Soient (Ω, \mathcal{A}, P) et X variable aléatoire sur (Ω, \mathcal{A}) avec (μ_X, σ_X^2) données

\Rightarrow

1. $\forall \delta > 0 P[\{|X - \mu_X| \geq \delta\sigma_X\}] \leq \frac{1}{\delta^2}$
2. $\forall \delta > 0 P[\{|X - \mu_X| < \delta\sigma_X\}] \geq 1 - \frac{1}{\delta^2}$
3. (a) $\forall \epsilon > 0 P[\{|X - \mu_X| \geq \epsilon\}] \leq \frac{\sigma_X^2}{\epsilon^2}$
(b) $\forall \epsilon > 0 P[\{|X - \mu_X| < \epsilon\}] \geq 1 - \frac{\sigma_X^2}{\epsilon^2}$

Chapitre 11

Convergence d'une suite de variables aléatoires

1

1 Convergence en probabilité

Définition 1.1 (Convergence en probabilité)

Soit (Ω, \mathcal{A}, P) . Une suite de variables aléatoires $\{X_1, \dots, X_n, \dots\}$ sur (Ω, \mathcal{A}) converge en probabilité vers X (variable aléatoire : $\Omega \rightarrow \mathbb{R}$)

Si :

$$\forall \epsilon > 0 \quad \lim_{n \rightarrow +\infty} P\{|X_n - X| \geq \epsilon\} = 0$$

notations équivalentes :

$$X_n \xrightarrow{P} X \quad \Leftrightarrow \quad \lim_{n \rightarrow +\infty} X_n = X(P)$$

Théorème 1.1 Soit (Ω, \mathcal{A}, P) . Soient $X, \{X_1, \dots\}$ variables aléatoires définies sur (Ω, \mathcal{A}) , dont le second moment par rapport à l'origine existe et il est tel que : $\lim_{n \rightarrow +\infty} E[(X_n - X)^2] = 0$

\Rightarrow

–

$$\lim_{n \rightarrow +\infty} X_n = X(P)$$

– Cette limite en probabilité est unique.

Pour la démonstration de ce théorème on utilise les inégalités de Kolmogorov et Tchebycheff.

2 Convergence en moyenne quadratique

Définition 1.2 (Convergence en moyenne quadratique)

Soient (Ω, \mathcal{A}, P) et $X, (X_1, \dots, X_n, \dots)$ variables aléatoires définies sur (Ω, \mathcal{A}) et dont le second moment μ'_2 existe

On dit que la suite X_1, \dots, X_n converge en moyenne quadratique si

$$\lim_{n \rightarrow +\infty} E[(X_n - X)^2] = 0 \Leftrightarrow \lim_{n \rightarrow +\infty} X_n = X(mq) \Leftrightarrow X_n \xrightarrow{mq} X$$

Proposition 1.1

Si :

$$\lim_{n \rightarrow +\infty} X_n = X(mq) \Rightarrow \lim_{n \rightarrow +\infty} X_n = X(P) \\ \Leftrightarrow$$

Convergence en moyenne quadratique \Rightarrow Convergence en probabilité.**3 Convergence presque sûre****Définition 1.3 (Convergence presque sûre)**

Soient (Ω, \mathcal{A}, P) et $X, (X_1, \dots, X_n, \dots)$ variables aléatoires définies sur (Ω, \mathcal{A}) . On dit que la suite (X_1, \dots, X_n, \dots) converge *presque sûrement* vers la variable aléatoire X si

$$P[\{\lim_{n \rightarrow +\infty} X_n = X\}] = 1 \Leftrightarrow X_n \xrightarrow{p.s} X \Leftrightarrow \lim_{n \rightarrow +\infty} X_n = X(p.s).$$

Remarque : Si $X = C$ (avec $C \in \mathbb{R}$ constante) $\Leftrightarrow X$ var. al. dégénérée en C alors on a convergence presque sûre vers C

Théorème 1.21- $\lim_{n \rightarrow +\infty} X_n = X(p.s)$ si et seulement si

$$\forall \epsilon > 0, \quad \exists N > 0 : \quad \lim_{n \geq N} P[\{\sup |X_n - X| < \epsilon\}] = 1$$

2- Si

$$\lim_{n \rightarrow +\infty} X_n = X(p.s) \quad \Rightarrow \quad \lim_{n \rightarrow +\infty} X_n = X(P)$$

2 Lois des grands nombres**1 Loi forte (resp. Loi faible) des grands nombres****Définition 2.1**

Soit (Ω, \mathcal{A}, P) , et (X_1, \dots, X_n, \dots) une suite de variables aléatoires sur (Ω, \mathcal{A}) pas forcément indépendantes et tel que $\forall i \ E[X_i]$ existe.

Si la variable aléatoire transformée définie par :

$$Y_n = \frac{\sum_{i=1}^n [X_i - E(X_i)]}{n} = \bar{X} - \frac{\sum E[X_i]}{n}$$

converge vers 0 suivant un mode de convergence, alors la suite obéit à la loi des grands nombres :

* Si $\lim_{n \rightarrow +\infty} Y_n = 0(P) \Rightarrow$ la suite obéit à la loi faible des grands nombres.

* Si $\lim_{n \rightarrow +\infty} Y_n = 0(p.s) \Leftrightarrow$ la suite obéit à la loi forte des grands nombres.

Théorème 2.1 (Application à un échantillon)

Soient (Ω, \mathcal{A}, P) , et X_1, X_2, \dots, X_n une suite de variables aléatoires indépendantes sur (Ω, \mathcal{A}) , suivant la même loi de probabilité et telles que :

$$\forall i \in \{1, 2, \dots, n\} \quad E[X_i] = \mu, \quad \text{var}[X_i] = \sigma^2$$

existent, alors la suite $\{X_1, \dots, X_n\}$ obéit à la loi faible et aussi à la loi forte des grands nombres.

Pour la preuve de ce théorème on utilise la généralisation de l'inégalité de Tchebycheff \Leftrightarrow inégalité de Kolmogorov.

2 Convergence en loi**Définition 2.2 (Convergence en loi)**

Soient les variables aléatoires $X, \{X_1, \dots, X_n\}$ et les fonctions de répartition correspondantes, $F_X, \{F_{X_1}, \dots, F_{X_n}\}$. On dit que la suite $\{X_1, X_2, \dots, X_n\}$ converge en loi vers X si

$$\lim_{n \rightarrow +\infty} F_{X_n}(x) = F_X(x)$$

en tout point de continuité x de F_X .

\Leftrightarrow

$$X_n \xrightarrow{\mathcal{L}} X \quad \Leftrightarrow \quad \lim_{n \rightarrow +\infty} X_n = X(\mathcal{L})$$

Exemple 2.1

$$F_X(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}t^2} dt$$

$$X_n : \mathcal{N}\left(\frac{1}{n}, 1 + \frac{1}{n}\right)$$

$$\lim_{n \rightarrow +\infty} F_{X_n}(x) = \lim_{n \rightarrow +\infty} \int_{-\infty}^x \frac{1}{\sqrt{2\pi} \left(1 + \frac{1}{n}\right)} e^{-\frac{1}{2} \frac{\left(t - \frac{1}{n}\right)^2}{1 + \frac{1}{n}}} dt = F_X(x)$$

On pose $z = \frac{t - \frac{1}{n}}{\sqrt{1 + \frac{1}{n}}}$

Théorème 2.2 (de Lévy-Cramer-Dugue)

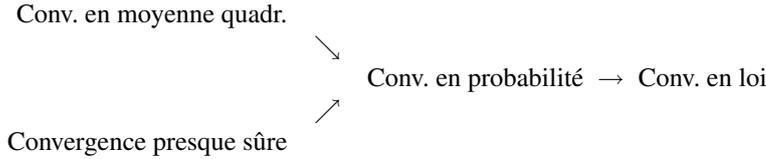
1.

$$X_n \xrightarrow{\mathcal{L}} X \Rightarrow \Phi_{X_n}(\omega) \rightarrow \Phi_X(\omega)$$

uniformément dans tout intervalle fini.

2.

$$\begin{aligned} \text{Si } \Phi_{X_n}(\omega) &\rightarrow \Phi(\omega) \text{ avec } \Re\Phi(\omega) \text{ continue à } \omega = 0 \\ &\Rightarrow \Phi(\omega) \text{ fonction caractéristique d'une variable aléatoire } X \\ \text{et } X_n &\xrightarrow{\mathcal{L}} X \end{aligned}$$

Remarque 2.1 *Tableau de la hiérarchie des convergences***3 Th. "Limite Centrale"****Théorème 2.3 (Théorème de la limite centrale)**

Soient (Ω, \mathcal{A}, P) , et X_1, X_2, \dots, X_n une suite de variables aléatoires indépendantes sur (Ω, \mathcal{A}) , suivant la même loi de probabilité et telles que :

$$\forall i \in \{1, 2, \dots, n\} \quad E[X_i] = \mu, \quad \text{var}[X_i] = \sigma^2$$

existent,

\Rightarrow

la suite $Y_1, Y_2, \dots, Y_n, \dots$ où

$$Y_n = \sqrt{n} \frac{\bar{X} - \mu}{\sigma} = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma} \right)$$

converge en loi vers une variable aléatoire $Y : \mathcal{N}(0, 1)$.

4 Th. de De Moivre- Laplace**Théorème 2.4 (Théorème de De Moivre-Laplace)**

$$\mathcal{B}(n, p) \rightarrow \mathcal{N}(0, 1)$$

Convergence en loi de la loi binomiale vers la loi $\mathcal{N}(0, 1)$.

Soient (Ω, \mathcal{A}, P) , et X_1, X_2, \dots, X_n une suite de variables aléatoires indépendantes sur (Ω, \mathcal{A}) , suivant la même loi de probabilité binomiale $\mathcal{B}(n, p)$.

\Rightarrow

La suite $Y_n = \frac{X_n - np}{\sqrt{npq}}$ converge en loi vers la loi Normale centrée réduite :

$$Y_n \xrightarrow[n \rightarrow \infty]{\mathcal{L}} Y : \mathcal{N}(0, 1)$$

Preuve :

La fonction caractéristique de X_n :

$$\Phi_{X_n}(\omega) = [pe^{i\omega} + 1 - p]^n$$

$$\Rightarrow \Phi_{Y_n} = \left[pe^{\frac{i\omega}{\sqrt{npq}}} + 1 - p \right]^n \times e^{\frac{-i\omega np}{\sqrt{npq}}}$$

$$\Rightarrow \ln \Phi_{Y_n} = n \ln \left[p e^{\frac{i\omega}{\sqrt{npq}}} + 1 - p \right] - \frac{i\omega np}{\sqrt{npq}}$$

Développement limité de l'exponentiel à l'ordre 2 :

$$\Rightarrow \ln \Phi_{Y_n} \underset{n \rightarrow \infty}{\simeq} n \ln \left[1 + p \left(\frac{i\omega}{\sqrt{npq}} - \frac{\omega^2}{2npq} \right) \right] - \frac{i\omega np}{\sqrt{npq}}$$

Développement limité du ln à l'ordre 2 :

$$\ln(1+x) \underset{x \rightarrow 0}{\simeq} x - \frac{x^2}{2}$$

$$\Rightarrow \Phi_{Y_n}(\omega) \underset{n \rightarrow \infty}{\simeq} -\frac{\omega^2}{2q} + \frac{1}{2} \frac{p\omega^2}{q}$$

avec $q = 1 - p$

$$\Rightarrow \ln \Phi_{Y_n} \underset{n \rightarrow \infty}{\simeq} -\frac{\omega^2}{2} \text{ et}$$

$$\Phi_{Y_n} \underset{n \rightarrow \infty}{\simeq} e^{-\frac{\omega^2}{2}}$$

On reconnaît la fonction caractéristique de la loi normale $\mathcal{N}(0, 1)$.

Chapitre 12

Vecteurs aléatoires

1 Vecteurs aléatoires de dimension 2

1 Définition

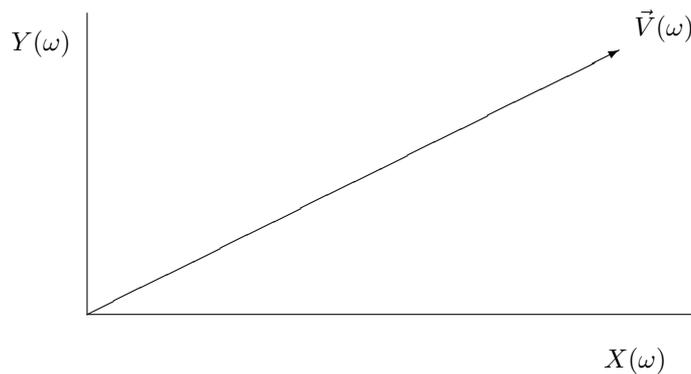
Soit un espace de probabilité (Ω, \mathcal{A}, P) et soient deux variables aléatoires (X, Y) définies sur cet espace. Le vecteur aléatoire $V(X, Y)$ est défini par :

$$\begin{aligned} X &: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R} \\ Y &: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R} \\ V(X, Y) &: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}^2 \\ \forall \omega \in \Omega & \mapsto V(X(\omega), Y(\omega)) \end{aligned}$$

Exemple 1.1

Sur la figure on représente le vecteur aléatoire $\vec{V}(\omega) \in \mathbb{R}^2$. Et pour l'événement : $A(D) \equiv \vec{V} \in D, \quad D \subset \mathbb{R}^2$, on associe l'ensemble des pts ω t.q.

$$A(x, y) = \{\omega | X(\omega) \leq x ; Y(\omega) \leq y\}$$



2 Mesure de Probabilité - Fonction de répartition conjointe

$$F(x, y) \equiv P[\{X \leq x\} \cap \{Y \leq y\}]$$

*** Cas continu :**

La mesure de probabilité définie par :

$$P(x, y) = \frac{\partial^2 F}{\partial x \partial y}$$

si elle existe on l'appelle **fonction de densité conjointe** (notée " $f(x, y)$ ") d'un vecteur aléatoire continu et inversement :

$$F(x, y) = \int_{-\infty}^x \int_{-\infty}^y P(x', y') dx' dy'$$

$$\Downarrow$$

$$(f(x', y'))$$

*** Cas discret - fonction de masse conjointe :**

(i)

$$P[x_i, y_j] \equiv P[\{X = x_i\} \cap \{Y = y_j\}]$$

et $\forall D \in \mathbb{R}^2$ fonction de répartition

$$P[D] = \sum_{(x_i, y_j) \in D} P[x_i, y_j]$$

3 Fonction de répartition marginale*** Cas continu :**

$$F_X(x) = \int_{-\infty}^x \int_{-\infty}^{+\infty} f(x', y') dx' dy'$$

et fonction de densité marginale \Leftrightarrow (dériv. par rapport à x)

$$f_X(x) = \int_{-\infty}^{+\infty} f(x, y) dy$$

*** Cas discret**

Fonction de masse marginale

$$Px_i = \sum_{y_j} P(x_i y_j)$$

Fonction de répartition marginale

$$F_X(x_i) = F[x_i, +\infty]$$

$$\downarrow$$

$$y_j \in]-\infty, +\infty[$$

4 Espérance mathématique (cas général : $h(X, Y)$)***Cas continu :**

$$E[h[X, Y]] = \iint h(x, y) f(x, y) dx dy$$

* Cas discret :

$$E[h[X, Y]] = \sum_{x_i, y_j} h(x_i, y_j) P(x_i, y_j)$$

Propriétés

(a) Si $h(x, y) = x + y$

$$E[h(X, Y)] = E[X] + E[Y]$$

(b) Si $h(x, y) = xy \Rightarrow$ en général

$$E[(X \cdot Y)] \neq E[X]E[Y]$$

5 Indépendance

Théorème 1.1 (Indépendance) Les propriétés suivantes sont équivalentes :

i) Deux variables aléatoires X, Y sont indépendantes

ii) la fonction de répartition conjointe se factorise en produit de fonctions de répartition marginales :

$$\Leftrightarrow F(x, y) = F_X(x)F_Y(y).$$

iii) La fonction de densité (resp. fonction de masse) conjointe se factorise en produit de fonctions de densité (resp. de masse) marginales :

$$f(x, y) = f_X(x)f_Y(y)$$

$$P(x, y) = P_X(x)P_Y(y)$$

Corollaire

Pour deux variables aléatoires (X, Y) indépendantes on a le résultat suivant :

$$E[(X \cdot Y)] = E[X]E[Y]$$

mais : **Remarque importante**

Cette factorisation peut se produire même si X, Y ne sont pas indépendantes (liées).

6 Covariance (définition)

$$\text{Cov}(X, Y) \equiv E[(X - \mu_X)(Y - \mu_Y)]$$

ou \Rightarrow

$$\text{Cov}[X, Y] = E[XY] - \mu_X \mu_Y$$

(i) Corollaire

$$\text{Cov}(X, Y) = 0$$

si X, Y sont non corrélées

(ii) "Inégalité de Schwartz"

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

\Leftrightarrow

$$\text{Cov}(X, Y) \leq \sigma_X \sigma_Y$$

e) **Coefficient de corrélation (de X, Y)** déf.

$$C \equiv \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}$$

en général

$$|C| \leq 1$$

* Si $C = 0 \Leftrightarrow$ var. al. X, Y non corrélées.

* Si $|C| = 1$ (C peut être aussi < 0) $\Leftrightarrow X, Y$ **complètement corrélées**.

2 Vecteurs aléatoires à $n > 2$ dimensions

Soit (Ω, \mathcal{A}, P) et $(\mathbb{R}, \mathcal{R})$

$$\vec{X}(\omega) = \{X_1(\omega), X_2(\omega) \dots X_n(\omega)\}$$

avec

$$\begin{aligned} X_i &: \Omega \rightarrow \mathbb{R} \text{ (ou } \mathbb{C}) \\ \omega &\rightarrow X_i(\omega) \\ (\forall i &= 1, 2, \dots, n) \end{aligned}$$

et t.q.

$$\{\omega | X_i(\omega) \in A\} = \mathcal{A}$$

(ou $\forall A \in \mathcal{C} \forall A \in \mathcal{R}$)

Rappel :

$\mathcal{R} \Leftrightarrow$ Tribu de Borel de \mathbb{R}
 $\mathcal{A} \Leftrightarrow$ Tribu de Ω
 ou (\mathcal{C} Tribu de \mathbb{C})

1 Fonction de répartition

$\forall x \in \mathbb{R}$ (ou $x \in \mathbb{C}^n$)

$$F(x) = F(x_1, \dots, x_n) = P[\{X_1 \leq x_1\} \cap \{X_2 \leq x_2\} \cap \dots \cap \{X_n \leq x_n\}]$$

Remarque En général on peut décomposer :

$$\begin{array}{ccccc} F(x) = & F_d(x) + & F_c(x) + & F_s(x) \\ & \uparrow & \uparrow & \downarrow \\ & \text{(cas} & \text{(cas} & \text{(singulière} \\ & \text{discret)} & \text{continu)} & \text{car on ignore..)} \end{array}$$

(i) (Cas continu) fonction de densité

$$f(x) = \frac{\partial^n F}{\partial x_1 \partial x_2 \dots \partial x_n}$$

(ii) (cas discret) fonction de masse

$$P(x^{(i)}) = P[\{\vec{X} = \{x_1^{(i)}, x_2^{(i)} \dots x_n^{(i)}\}\}]$$

Attention

$x^{(i)}$ est un vecteur précis dans \mathbb{R}^n ou dans \mathbb{C}^n .

2 Espérance Mathématique (cas général pour une fonction $h(X)$)

cas continu

$$E[\{h(X)\}] = \int \int_{\mathbb{R}^n} \dots \int h(x)f(x)dx_1 \dots dx_n$$

(ou \mathbb{C}^n)

cas discret

$$E[\{h(X)\}] = \sum_{\substack{x^{(i)} \in \mathbb{R}^n \\ \text{ou } x^{(i)} \in \mathbb{C}^n}} P(x^{(i)})h(x^{(i)})$$

3 Matrice de covariance (Γ)

(i) Si $x \in \mathbb{R}^n$ ($\mu \in \mathbb{R}^n$)

$$\Gamma = E[XX^T] - \mu\mu^T$$

ou

$$\Gamma_{ij} = E[X_i X_j] - \mu_i \mu_j$$

éléments diagonaux

$$\Gamma_{ii} = E[X_i^2] - \mu_i^2 \equiv \sigma_{X_i}^2$$

\Leftrightarrow variances des X_i

ou

$$\Gamma \equiv E[(X - \mu)(X - \mu)^T]$$

Remarque $E[X_i X_j] =$ Matrice de corrélation

(ii) Si $x \in \mathbb{C}^n$

$$\Gamma \stackrel{\text{def}}{=} E[XX^*] - \mu\mu^*$$

ou

$$\Gamma = E[(X - \mu)(X - \mu)^*]$$

et si X centré ($\mu = 0$)

$$\Gamma = E[XX^*]$$

4 Probabilités Conditionnelles par rapport à un événement

Cas scalaire

a) Soit $A \in \mathcal{R}$ (événement) (ex. $A = [a, b]$)
Fonction de répartition conditionnelle

$$F[x|A] = \frac{P[\{X \leq x\} \cap A]}{P[A]}$$

Fonction de densité conditionnelle

$$f[x|A] = \frac{dF[x|A]}{dx}$$

Espérance Conditionnelle

$$E[h(X)|A] = \int f[x|A]h(x)dx$$

b) (def. analogue pour un vecteur de probabilité)

Fonction de répartition conditionnelle

$$F[X_1, X_2 \dots X_n | A] = \frac{P[\{X_1 \leq x\} \cap \{X_2 \leq x_2\} \cap \dots \cap \{X_n \leq x_n\} \cap A]}{P[A]}$$

Espérance conditionnelle

$$E[h(X_1, \dots X_n) | A] = \iint f[x_1 \dots x_n | A] h(x) dx_1 \dots dx_n$$

5 Indépendance

Théorème 2.1 (indépendance (Généralisation à $n > 2$ dimensions))

Les propriétés suivantes sont équivalentes :

- i) *Les variables aléatoires $\{X_1, \dots, X_n\}$ sont indépendantes,*
- ii) *la fonction de répartition conjointe se factorise en produit de fonctions de répartition marginales.*
- iii) *La fonction de densité (resp. fonction de masse) conjointe se factorise en produit de fonctions de densité (resp. de masse) marginales.*

6 Distributions Conditionnelles entre variables et vecteurs aléatoires

Fonction de répartition conditionnelle

$$F[x|Y \leq y] \stackrel{\text{def}}{=} P[\{X \leq x\} | Y \leq y] = \frac{F(x, y)}{F(+\infty, y)}$$

avec, $F(+\infty, y)$, fonction de répartition marginale par rapport à Y .

Fonction de masse conditionnelle

(cas discret)

Définition 2.1

$$P_{x_i | y_j} \stackrel{\text{notation}}{\equiv} P[\{X = x_i\} | \{Y = y_j\}] \stackrel{\text{def}}{\equiv} \frac{P[\{X = x_i\} \cap \{Y = y_j\}]}{P[Y = y_j]}$$

où

$$P[Y = y_j] = \sum_{x_i} P_{x_i y_j}$$

Fonction de densité conditionnelle (cas continu)Cas vectoriel (sur \mathbb{R})**Définition 2.2**

$$f_X[x|y] \stackrel{\text{def}}{=} \frac{f(x, y)}{f_Y(y)}$$

et aussi :

Proposition 2.1

$$\begin{aligned} i) \quad & \int f_X[x|y] dx_1 \dots dx_n = 1 \\ ii) \quad & \int f_X[x|y] f_Y(y) dy_1 \dots dy_n = f_X(x) \end{aligned}$$

Exercice 2.1 Montrer la proposition 2.1**7 Moments conditionnels (cas général-vectoriel)****Espérance Conditionnelle**Soit une fonction - var. aléatoire $h(X)$, avec,

$$\begin{aligned} X \text{ vect. de probabilité ; } X &: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}^n \\ Y \text{ vect. de probabilité ; } Y &: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}^n \end{aligned}$$

Définition 2.3 *Espérance Conditionnelle*

$$E_X[h(X)|y] = \int h(x) f_X[x|y] dx$$

Propriété importante !**Proposition 2.2**

$$E_Y[E_X[h(X)|y]] = E_X[h(X)]$$

Exercice 2.2 Montrer la proposition 2.2**Moments Conditionnels d'ordre p** **Définition 2.4**

$$E_X[X^p|y] = \int x^p f[x|y] dx$$

*(Définition analogue pour le cas discret)***Variance conditionnelle****Définition 2.5**

$$\begin{aligned} E_X[(X - \mu_X)^2|y] &= \int (X - \mu_X)^2 f[x|y] dx \\ &= E[X^2|y] + \mu_X^2 - 2\mu_X E_X[X|y] \end{aligned}$$

8 Transformations de vecteurs aléatoires (à densité)

Théorème 2.2 Soit (Ω, \mathcal{F}, P) un espace de probabilité et soit

$$X = \{X_1, X_2, \dots, X_n\} : (\Omega, \mathcal{F}, P) \rightarrow \mathbb{R}^n$$

un vecteur aléatoire.

Soit $Y = \phi(X)$ un vecteur aléatoire - transformation biunivoque du vecteur aléatoire X .

\Rightarrow

la densité de probabilité du vecteur Y est obtenue par la formule suivante :

$$g(y) = \frac{f((\phi)^{-1}(y))}{|\det J|}$$

où J est la matrice **-Jacobien** de la transformation.