

## Probabilités discrètes

### Généralités

Espérance mathématique :  $E(X) = \sum_{w \in \Omega} w.P(X = w)$

On notera parmi les propriétés de E :

- E est linéaire
- $E(E(X)) = E(X)$
- la formule de transfert,  $E(f(X)) = \sum_{w \in \Omega} f(w).P(X = w)$
- $E(X) = 0$  pour une variable aléatoire centrée.

Variance :  $Var(X) = E(X^2) - E(X)^2 = E((X - E(X))^2)$

On donne les propriétés suivantes :

- $Var(\lambda X) = \lambda^2 Var(X)$
- X est constante si et seulement si  $Var(X) = 0$ .

Ecart-type :  $\sigma(X) = \sqrt{Var(X)}$

On a :  $\sigma(\lambda X) = |\lambda|\sigma(X)$ .

### Couple (X, Y)

Loi conjointe et Loi marginale :

La loi conjointe de (X, Y) est  $P((X, Y) \in A \times B) = P(X \in A, Y \in B)$ .

Si  $P(X \in A) = P(X \in A, Y \in B)$ , alors on dit que X est une loi marginale.

Variations aléatoires indépendantes :

X et Y sont indépendantes si  $\forall A, B P(X \in A, Y \in B) = P(X \in A) \times P(Y \in B)$ .

Covariance :  $C_{XY} = E(XY) - E(X).E(Y)$ .

En particulier, on trouve  $C_{XX} = Var(X)$ .

Si X et Y sont indépendantes alors  $E(XY) = E(X).E(Y)$ , d'où  $C_{XY} = 0$ .

La matrice des covariances s'écrit :  $C = \begin{pmatrix} C_{XX} & C_{XY} \\ C_{YX} & C_{YY} \end{pmatrix}$ . Elle est symétrique et positive.

Coefficient de corrélation :  $\rho_{XY} = \frac{C_{XY}}{\sigma_X \cdot \sigma_Y}$

On a les propriétés suivantes :

- $\rho_{\alpha X, \beta Y} = \rho_{X, Y}$
- $|\rho_{X, Y}| \leq 1$

Loi de S=X+Y :

$S = w$  peut s'écrire  $\sum_{\alpha} (X = \alpha \text{ et } Y = w - \alpha)$ . Ainsi  $P(S = w) = \sum_{\alpha} P(X = \alpha, Y = w - \alpha)$ .

De plus, si X et Y sont indépendantes alors  $P(S = w) = \sum_{\alpha} P(X = \alpha) \times P(Y = w - \alpha)$ , le produit de convolution des lois X et Y.

Variance d'une somme de variables aléatoires :

$$\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y) + 2.C_{XY}.$$

Si X et Y sont indépendantes, alors on a la formule :  $\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y)$ .

### Fonction génératrice

Considérons une variable aléatoire X entière.

Sa fonction génératrice est définie par :  $G_X(z) = \sum_n p(X = n).z^n$  de rayon  $R \geq 1$ .

Cette fonction caractérise la loi X, et  $P(X = n) = \frac{1}{n!} G_X^{(n)}(0)$ .

On calcule :

$$\begin{aligned} - E(X) &= G'_X(1) \\ - \text{Var}(X) &= G''_X(1) + G'_X(1) - (G'_X(1))^2. \end{aligned}$$

Si X et Y sont indépendantes, alors  $G_{X+Y} = G_X.G_Y$ .

### Loi binomiale et Loi de Poisson

Loi binomiale de paramètre d et d'ordre n :

Considérons une expérience pendant laquelle un événement A peut arriver avec la probabilité d. On répète cette expérience n fois de façon indépendante.

X : nombre de fois où A s'est produit

Y : indicatrice de l'événement A (Y=1 si A s'est produit, 0 sinon).

$Y_1, Y_2, \dots, Y_n$  : échantillon de modèle Y.

On a  $X = \sum Y_i$ .

On montre facilement que  $P(X = k) = \begin{cases} 0, & \text{si } k > n \\ C_n^k d^k (1-d)^{n-k}, & \text{sinon} \end{cases}$ .

On établit ensuite que :

$$\begin{aligned} - \text{Var}(X) &= nd(1-d) \\ - E(X) &= nd \\ - &\text{en utilisant } G_X(z) = (1 + dz - d)^n. \end{aligned}$$

Loi de Poisson de paramètre a :  $P(X = k) = \frac{a^k}{k!} e^{-a}$

Si l'on pose  $a = nd$ , alors  $C_n^k d^k (1-d)^{n-k} \xrightarrow[n \rightarrow \infty]{} \frac{a^k}{k!} e^{-a}$ .

En pratique, on fait l'approximation de la loi binomiale d'ordre n et de paramètre d par la loi de Poisson de paramètre  $a = nd$ , pour  $n \geq 30$ .

On établit que :

$$\begin{aligned} - \text{Var}(X) &= a \\ - E(X) &= a \\ - &\text{en utilisant } G_X(z) = e^{a(z-1)}. \end{aligned}$$

Théorème : stabilité des lois de Poisson pour la somme

Supposons que  $X$  suit la loi de Poisson de paramètre  $a$  et que  $Y$  suit la loi de Poisson de paramètre  $b$ , alors  $X+Y$  suit la loi de Poisson de paramètre  $a+b$ .

**Probabilités générales**

Note : Seul le cas diffus est développé dans ce chapitre.

**Généralités**

On définit dans le cas diffus la probabilité pour la loi  $X$  :  $P(X \in A) = \int_A f(x)dx$  où  $f$  représente la densité

de la loi  $X$ . La densité vérifie la propriété fondamentale des probabilités :  $P(X \in \Omega) = \int_{\Omega} f(x)dx = 1$ .

L'espérance se définit, dans le cas diffus, comme suit :  $E(X) = \int x dp(x) = \int x \cdot f(x) dx$ .

Les propriétés restent les mêmes que pour les probabilités discrètes.

La formule de transfert s'écrit :  $E(h(X)) = \int h(x) f(x) dx$ .

La variance, la covariance et l'écart-type, ... restent inchangés.

Loi de  $S = X+Y$  :

Soit  $h$  la densité de la loi  $S$ ,  $f$  la densité de la loi  $X$  et  $g$  la densité de la loi  $Y$ .

Pour  $X$  et  $Y$  indépendants, la densité de  $S$  est le produit de convolution des densités de  $X$  et  $Y$ , soit :

$$h(s) = (f * g)(s) = \int_{-\infty}^s f(s-y)g(y)dy.$$

De façon générale, la densité d'une somme de  $n$  variables indépendantes est le produit de convolution des densités.

Loi de  $-X$  :  $F_{-X}(x) = 1 - F_X(-x)$  et  $f_{-X}(x) = f_X(-x)$

**Loi conjointe d'un couple  $(X, Y)$** 

Considérons la densité  $h(x, y)$ , on a  $P((X, Y) \in A \times B) = \iint_{A \times B} h(x, y) dx dy$ . On pourra noter que la densité

de la loi en  $X$  est  $\int_B h(x, y) dy$ , de même pour la densité de la loi en  $Y$ .

Pour des variables aléatoires indépendantes, on a  $P((X, Y) \in A \times B) = P(X \in A) \times P(Y \in B)$ .

Théorème :  $X$  et  $Y$  sont indépendants si  $h(x, y) = f(x)g(y)$ .

**Fonction de répartition**

On définit la fonction répartition comme suit :  $F(x) = \text{Prob}(\text{]}-\infty, x] \cap \Omega) = \text{Prob}(X \leq x)$ .

On a :

- $\lim_{x \rightarrow \infty} F(x) = 1$
- $\lim_{x \rightarrow -\infty} F(x) = 0$

Dans le cas diffus, on a  $F(x) = \int_a^x f$  et  $F'(x) = f(x)$ , où  $f$  représente la densité et  $a = \text{Inf}(\Omega)$ .

Ainsi on peut calculer la probabilité,  $P(x \in A) = \int_A f$ .

## Fonction caractéristique

Soit  $X$  une variable aléatoire de densité  $f$  et  $u$  un réel quelconque.

La fonction caractéristique de  $X$  est définie par  $\Phi_X(u) = E(e^{iuX}) = \int e^{iux} f(x) dx$ .

On a les propriétés suivantes :

- Transformée de Fourier :  $\Phi_X(u) = \hat{f}\left(\frac{-u}{2\pi}\right)$
- $\Phi'_X(0) = iE(X)$
- $Var(X) = -\Phi''_X(0) + (\Phi'_X(0))^2$
- si  $X$  et  $Y$  sont indépendants,  $\Phi_{X+Y} = \Phi_X \times \Phi_Y$ .

## Loi exponentielle de paramètre $a$ et de début $t_0$

Problème de durée de vie :

Par exemple un appareil est mis en marche à l'instant  $t_0$ . La variable aléatoire  $X$  désigne l'instant où l'appareil tombe en panne. On fait l'hypothèse de non-vieillessement de la machine, c'est à dire  $a(t) = a$ .

Si  $F$  est la fonction de répartition de  $X$ , on démontre que :  $1 - F(t) = e^{-a(t-t_0)}$ ,  $t > t_0$ .

Ensuite, on établit les résultats suivants :

- $E(X) = \frac{1}{a} + t_0$
- $Var(X) = \frac{1}{a^2}$
- densité :  $f(t) = a.e^{-a(t-t_0)}$

## Loi normale (Gauss)

Loi normale réduite  $N(0,1)$  :

La loi est de densité :  $f_{0,1}(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right)$ . On rappelle que  $\int e^{-\left(\frac{1}{2}\right)x^2} dx = \sqrt{2\pi}$ .

Supposons que  $X$  suit  $N(0,1)$ .

Alors il vient :

- $E(X) = 0$
- $Var(X) = 1$  donc  $\sigma_X = 1$
- la fonction caractéristique  $\Phi_X(u) = \exp\left(-\frac{u^2}{2}\right)$

Loi normale générale  $N(m, \sigma)$  :

On suppose que  $X$  suit  $N(0,1)$  et on pose  $Y = \sigma X + m$ , alors  $Y$  suit  $N(m, \sigma)$ .

De même il vient :

- $E(Y) = m$
- $Var(Y) = \sigma^2$  donc  $\sigma_Y = \sigma$
- la densité s'écrit  $f_{m,\sigma}(y) = f_{0,1}\left(\frac{y-m}{\sigma}\right) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{1}{2}\left(\frac{y-m}{\sigma}\right)^2\right)$

Théorème : Stabilité des lois normales

Si  $Y_1$  suit  $N(m_1, \sigma_1)$ , si  $Y_2$  suit  $N(m_2, \sigma_2)$  et si  $Y_1, Y_2$  sont indépendantes, alors  $(Y_1 + Y_2)$  suit  $N(m, \sigma)$

$$\text{avec } \begin{cases} m = m_1 + m_2 \\ \sigma^2 = \sigma_1^2 + \sigma_2^2 \end{cases}$$

Moyenne de lois normales

$Y$  suit  $N(m, \sigma)$ , et  $Y_1, Y_2, \dots, Y_n$  un échantillon.

La moyenne  $\bar{Y} = \frac{1}{n} \sum_i Y_i$  suit  $N\left(m, \frac{\sigma}{\sqrt{n}}\right)$ , car  $\text{Var}(\bar{Y}) = \frac{1}{n} \text{Var}(Y)$ .

Couple Gaussien :  $(X_1, X_2)$ 

Hypothèses :  $X_1$  suit  $N(m_1, \sigma_1)$ ,  $X_2$  suit  $N(m_2, \sigma_2)$ ,  $|r| < 1$ .

La densité de la loi du couple s'exprime :

$$h(x_1, x_2) = \left( \frac{1}{2\pi \cdot \sigma_1 \sigma_2 \cdot \sqrt{1-r^2}} \right) \times \exp \left\{ \frac{-1}{2 \cdot \sqrt{1-r^2}} \left[ \left( \frac{x_1 - m_1}{\sigma_1} \right)^2 + \left( \frac{x_2 - m_2}{\sigma_2} \right)^2 - 2r \left( \frac{x_1 - m_1}{\sigma_1} \right) \left( \frac{x_2 - m_2}{\sigma_2} \right) \right] \right\}$$

avec  $r$  le coefficient de corrélation,  $r = \frac{C_{X_1 X_2}}{\sigma_1 \sigma_2}$ .

Dans le cas d'un couple Gaussien,  $C_{X_1 X_2} = 0$  si et seulement si  $X_1$  et  $X_2$  sont indépendantes. En général, la réciproque est fautive.

Loi conditionnelle :

La loi conditionnelle à une valeur  $y_0$  :  $P(X \in A / Y = y_0) = \frac{\int_A h(x, y_0) dx}{\int_R h(x, y_0) dx}$ .

C'est une loi normale  $N(m, \sigma)$ , avec  $m = E(X) + (y_0 - E(Y)) \frac{\sigma_X}{\sigma_Y} r$  et  $\sigma = \sqrt{1-r^2} \cdot \sigma_X$ .

**Loi des grands nombres – Théorème central limite**Convergence en probabilité (CVP)

Soient  $(Y_n)_n$  et un réel  $a$ .

$$\left( Y_n \xrightarrow{\text{CVP}} a \right) \Leftrightarrow \left( \forall \varepsilon > 0, \lim_{n \rightarrow \infty} \text{Prob}(|Y_n - a| > \varepsilon) = 0 \right).$$

Inégalité de Markoff

Hypothèses :  $a > 0$ ,  $X$  à valeurs réelles positives tel que  $m = E(X) < \infty$ .

Alors,  $\text{Prob}(X \geq a \cdot m) \leq \frac{1}{a}$ .

Inégalité de Tchebycheff

Hypothèses :  $b > 0$ ,  $Y$  tel que  $E(Y^2) < \infty$ .

Alors,  $\text{Prob}(|Y - E(Y)| > b \sigma) \leq \frac{1}{b^2}$  ou encore  $\text{Prob}(|Y - E(Y)| > b) \leq \frac{\sigma^2}{b^2}$ .

Loi des grands nombres

Hypothèses :  $X$  tel que  $E(X^2)$  existe, et  $X_1, X_2, \dots, X_n$  un échantillon.

Alors  $\overline{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$  converge en probabilité vers l'espérance  $E(X)$ .

Convergence en loi

$(X_n)_n$  converge en loi vers  $X$  si et seulement si la fonction de répartition  $F_{X_n}$  converge simplement vers  $F_X$ , c'est à dire  $P(X_n \leq x) \xrightarrow{n \rightarrow \infty} P(X \leq x)$ .

Dans le cas d'une variable aléatoire entière, cela signifie aussi  $P(X_n = l) \xrightarrow{n \rightarrow \infty} P(X = l)$ .

Théorème Paul Levy

$(X_n)_n$  converge en loi vers  $X$  si et seulement si la fonction caractéristique  $\Phi_{X_n}$  converge vers  $\Phi_X$ .

Théorème central limite

Soit  $X$  tel que  $E(X^2)$  existe,  $\int |x|^3 f(x) dx < \infty$  et  $X_1, X_2, \dots, X_n$  un échantillon.

On suppose  $E(X) = 0$ ,  $\sigma(X) = \sigma$ .

Soit  $Y_n = \frac{1}{\sqrt{n}} \sum_{i=1}^n X_i$ .

Alors  $(Y_n)_n$  converge vers la loi normale  $N(0, \sigma)$ .

Utilisation pratique du théorème central limite

Soit une variable aléatoire  $X$  et  $X_1, X_2, \dots, X_n$  un échantillon.

- Pour  $n \geq 30$ ,  $Y = \frac{1}{\sqrt{n}} \sum_{i=1}^n X_i$  suit (approximativement) une loi normale  $N(\sqrt{n} \cdot E(X), \sigma_X)$ .
- Pour  $n \geq 30$ ,  $Y = \frac{1}{n} \sum_{i=1}^n X_i$  suit (approximativement) une loi normale  $N\left(E(X), \frac{\sigma_X}{\sqrt{n}}\right)$ .

En conclusion, il est normal de trouver une loi normale !

Loi du chi-deux :  $\mathbb{N}^2$ 

Soit  $X_1, X_2, \dots, X_n$  un échantillon de la loi  $N(0,1)$ .

$$U_n = \sum_{i=1}^n X_i^2.$$

On dit que  $U_n$  suit la loi du  $\mathbb{N}^2$  à  $n$  degrés de liberté et pour  $n \geq 30$ , on considère que  $\frac{1}{\sqrt{n}}(U_n - n)$  suit

(approximativement) la loi  $N(0, \sqrt{2})$ .

**Processus Markoviens discrets en temps et en valeurs****Définitions**

Processus :  $X(t)$  variable aléatoire qui dépend du temps.

Un processus discret en valeurs est tel que  $\forall t$   $X(t)$  est une variable aléatoire discrète.

Discrets en temps revient à considérer une suite d'instants  $t_0, t_1, \dots, t_n$  au lieu de prendre le temps en continu.

Les  $X(t_i)$  sont notés  $X(i)$ .

### Définitions Markovien

Un processus discret en temps et en valeurs est dit Markovien si et seulement si :  $\forall m, \forall n \geq m + 1, \forall e_i,$

$$P(X_{m+1} = e_{m+1}, \dots, X_n = e_n | X_m = e_m, X_{m+1} = e_{m+1}, \dots, X_n = e_n) = P(X_{m+1} = e_{m+1}, \dots, X_n = e_n | X_m = e_m, X_{m-1} = e_{m-1}, \dots, X_0 = e_0)$$

En d'autres termes, l'état futur ne dépend (directement) que du présent et pas du passé.

### Propriété : Loi des n-uplets

Dans le cas d'un processus Markovien, on a :

$$P(X_0 = e_0, \dots, X_n = e_n) = \prod_{k=1}^n \underbrace{P(X_k = e_k | X_{k-1} = e_{k-1})}_{\text{transition}} \times \underbrace{P(X_0 = e_0)}_{\text{initialisation}}$$

## Les chaînes de Markov

Les chaînes de Markov représentent un cas particuliers important des processus Markoviens.

### Définition : Chaîne de Markov

Ce sont les processus Markoviens vérifiant la propriété suivante :

$$\forall n, k \quad P(X_n = e' | X_0 = e) = P(X_{n+k} = e' | X_k = e)$$

Il y a invariance des transitions, ou autrement les règles ne changent pas au cours du jeu. Il y a non-vieillessement du processus.

On suppose de plus que les valeurs possibles de X sont en nombre finis :  $e_1, \dots, e_n$  encore notées  $1, \dots, n$ .

$$\text{Notons } G_{i,j} = P(X_1 = j | X_0 = i) = \underbrace{P(X_{k+1} = j | X_k = i)}_{\text{transition}}, \text{ pour } i, j = 1, \dots, n.$$

On note G la matrice des transitions,  $G = (G_{i,j})$ .

### Théorème :

$$P(X_k = j | X_0 = i) = (G^k)_{i,j}.$$

Ainsi la matrice de transition pour la k<sup>ème</sup> étape est  $G^k$ .

### Exemple fondamental : La marche aléatoire


On considère un promeneur se déplaçant étape par étape soit à droite soit à gauche de façon équiprobable. Si il se trouve sur un bord, il y restent ( bord absorbant). Les règles n'évoluent pas au cours du temps. Il s'agit d'une chaîne de Markov.

$$\text{La matrice G de transition est : } \begin{pmatrix} 1 & 0 & 0 & 0 \\ 1/2 & 0 & [1/2] & 0 \\ 0 & 1/2 & 0 & 1/2 \\ 0 & 0 & 0 & 1 \end{pmatrix} \begin{array}{l} \rightarrow \text{bord absorbant à droite} \\ \\ \\ \rightarrow \text{bord absorbant à gauche} \end{array}$$

On remarque que cette matrice est *stochastique* car la somme des coefficients de chaque ligne fait 1.

Le coefficient encadré s'écrit  $P(X_1 = 3 | X_0 = 2) = 1/2$  et représente la probabilité d'arriver en position 2, en partant de la position 3.

On peut représenter la marche aléatoire avec le tableau ci-dessous.



On cherche à connaître le comportement asymptotique ou à long terme du promeneur.  
 Pour cela, on calcule  $G^k$  et on prend sa limite en l'infini :

$$G^\infty = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 2/3 & 0 & 0 & 1/3 \\ 1/3 & 0 & 0 & 2/3 \\ 0 & 0 & 0 & 1 \end{pmatrix} \rightarrow \text{proba d'arriver en } j, \text{ en partant de } i = 2$$

Ainsi, on peut résumer le contenu de cette matrice en disant que :

- le promeneur parti de 1 reste en 1 (bord absorbant)
- le promeneur parti de 2 a une probabilité  $2/3$  d'échouer à gauche et  $1/3$  d'échouer à droite
- le promeneur parti de 3 a une probabilité  $1/3$  d'échouer à gauche et  $2/3$  d'échouer à droite
- le promeneur parti de 4 reste en 4 (bord absorbant).