

1) Variables aléatoires discrètes sur un espace probabilisé

a) Variable aléatoire discrète

Une variable aléatoire discrète X sur un espace probabilisé (Ω, \mathcal{A}, P) est une application définie sur Ω dont l'image $E = X(\Omega)$ est fini ou dénombrable et telle que l'image réciproque de tout élément de E appartient à \mathcal{A} .

Remarque : Alors, pour toute partie $F \subset E$, $X^{-1}(F)$ est un événement de (Ω, \mathcal{A}) .

Notations :

- Pour tout $x \in E$, on pose $P(X = x) = P(X^{-1}(x))$.

- Pour toute partie F de E , on pose $P(X \in F) = P(X^{-1}(F))$.

Par exemple, si X est à valeurs réelles, $(X \geq x)$ désigne l'ensemble A des événements $\omega \in \Omega$ tels que $X(\omega) \geq x$, et $P(X \geq x)$ désigne $P(A)$, c'est-à-dire la probabilité qu'un événement appartienne à A .

Remarque : On a $P(X \in F) = \sum_{x \in F} P(X = x)$ (la somme est bien définie, car $(P(X = x))_{x \in F}$ est sommable).

Par exemple, si X est à valeurs dans \mathbb{N} , $P(X = n) = P(X > n - 1) - P(X > n)$.

b) Loi d'une variable aléatoire

Def : La loi d'une variable aléatoire discrète $X : (\Omega, \mathcal{A}, P) \rightarrow E$ définit une loi sur E par : $x \mapsto P(X = x)$

Def : Deux v.a. à valeurs dans E ont même loi ssi $\forall x \in E, P(X = x) = P(Y = x)$. On note $X \sim Y$.

Remarque : Pour tout $F \subset E$, on a $P(X \in F)$ est bien définie et $P(X \in F) = \sum_{x \in F} P(X = x)$.

2) Tribu associée à une variable aléatoire

a) En pratique, on définit souvent une variable aléatoire X à valeurs dans E par les probabilités $P(X = a)$, où $P(X = a)$ désigne la probabilité que X vaut a .

Les réels $P(X = a)$ appartiennent à $[0, 1]$, et la seule contrainte est d'avoir $\sum_a P(X = a) = 1$.

Exemple : Pour un tirage d'un entier sur $\{0, 1\}$, on définit $P(X = 0)$ et $P(X = 1)$.

Considérons alors X définie sur Ω .

On note $\sigma(X)$ la plus petite tribu engendrée par les atomes $X^{-1}(a)$, où $a \in E$.

On obtient ainsi un espace probabilisé (Ω, \mathcal{A}, P) en définissant P par sa valeur sur les atomes $P(X^{-1}(a)) = P(X = a)$.

La tribu $\sigma(X)$ est formé des réunions (finies ou infinies) de parties de la forme $X^{-1}(a)$, où $a \in E$.

Autrement dit, $\sigma(X)$ est la tribu des $X^{-1}(F)$, où $F \subset E$.

Conséquence : Si $X : \Omega \rightarrow E = \{x_n, n \in \mathbb{N}\}$, où les x_n sont distincts, et si $(p_n)_{n \in \mathbb{N}}$ est une suite de réels positifs vérifiant $\sum_{n=0}^{+\infty} p_n = 1$, alors il existe une probabilité P sur (Ω, \mathcal{A}) telle $\forall n \in \mathbb{N}, P(X = x_n) = p_n$.

b) Considérons un événement A sur un espace probabilisé (Ω, \mathcal{A}, P) .

La fonction caractéristique de A est la v.a. $1_A : \Omega \rightarrow \{0, 1\}$ $\omega \mapsto 1$ si $\omega \in A$ et 0 sinon.

La tribu engendrée par 1_A est la tribu engendrée par A , c'est-à-dire $\{\emptyset, \Omega, A, \bar{A}\}$.

3) Couple de variables aléatoires

a) Loi conjointe de deux variables aléatoires

Def : Soient $X : \Omega \rightarrow E$ et $Y : \Omega \rightarrow E'$ deux variables aléatoires discrètes sur un univers Ω .

Alors $(X, Y) : \Omega \rightarrow E \times E'$ $\omega \mapsto (X(\omega), Y(\omega))$ est une variable aléatoire sur Ω .

L'application $P_{X,Y} : E \times E' \rightarrow [0, 1]$ $(x, y) \mapsto P(X = x, Y = y)$ est appelée loi conjointe de (X, Y) .

Terminologie : Les lois associées à X et Y sont alors appelées lois marginales de $Z = (X, Y)$.

Remarque : Posons $E = \{x_i, i \in I\}$ et $E' = \{y_j, j \in J\}$.

On représente souvent la loi conjointe par le tableau (p_{ij}) , où $p_{ij} = P(X = x_i, Y = y_j)$.

La somme de tous les p_{ij} vaut 1.

Important :

$$P(X = x_i) = \sum_{j \in J} P(X = x_i, Y = y_j) = \sum_{j \in J} p_{ij} \text{ (somme selon la ligne } i \in I).$$

$$P(Y = y_j) = \sum_{i \in I} P(X = x_i, Y = y_j) = \sum_{i \in I} p_{ij} \text{ (somme selon la colonne } j \in J).$$

b) Loi conditionnelle marginale

$$\text{On a } P(X = x_i | Y = y_j) = \frac{P(X = x_i, Y = y_j)}{P(Y = y_j)} = \frac{p_{ij}}{p_{*j}}, \text{ où } p_{*j} = P(Y = y_j) = \sum_{i \in I} p_{ij}.$$

Elles correspondent aux lois définies par une ligne ou une colonne (renormalisée).

c) Lois marginales d'une variable aléatoire $Z : \Omega \rightarrow E \times E'$

Posons $E = \{x_i, i \in I\}$ et $E' = \{y_j, j \in J\}$. On dispose des probabilités $p_{ij} = P(Z = (x_i, y_j))$.

Les marges (ou lois marginales) sont obtenues en sommant les p_{ij} par ligne ou par colonne.

Plus précisément, les lois marginales $X : \Omega \rightarrow E$ et $Y : \Omega \rightarrow E'$ sont définies par
$$\begin{cases} P(X = x_i) = \sum_{j \in J} p_{ij} \\ P(Y = y_j) = \sum_{i \in I} p_{ij} \end{cases}$$

Remarque : Des variables aléatoires $\Omega \rightarrow E \times E'$ peuvent être distinctes et avoir les mêmes lois marginales.

Par exemple, si $0 \leq p \leq q \leq 1$, $\begin{pmatrix} pq & (1-p)q \\ p(1-q) & (1-p)(1-q) \end{pmatrix}$ et $\begin{pmatrix} p & q-p \\ 0 & 1-q \end{pmatrix}$ ont mêmes marges.

4) Variables aléatoires indépendantes

a) *Def* : Deux variables aléatoires $X : \Omega \rightarrow E$ et $Y : \Omega \rightarrow E'$ sont dites indépendantes si

$$\forall (x, y) \in E \times E', P(X = x, Y = y) = P(X = x)P(Y = y)$$

Remarque : Lorsque X et Y sont indépendantes, $(Y | X = x) = Y$.

Prop : Si X et Y sont des variables aléatoires indépendantes, alors pour toute fonction f et g , les variables aléatoires $f(X)$ et $g(Y)$ sont indépendantes.

Preuve : $P(f(X) = a, g(Y) = b) = P(X \in f^{-1}(a), Y \in g^{-1}(b)) = P(X \in f^{-1}(a))P(Y \in g^{-1}(b))$.

b) Couple de deux variables aléatoires indépendantes

Deux variables aléatoires discrètes sont indépendantes ssi les p_{ij} sont de la forme

$$p_{ij} = p_i q_j$$

On a alors $p_i = P(X = x_i)$ et $q_j = P(Y = y_j)$.

Important : Pour toutes parties $A \subset E$ et $B \subset E'$, on a $P(X \in A, Y \in B) = P(X \in A)P(Y \in B)$.

En effet, $\sum_{(i,j) \in A \times B} p_i q_j = (\sum_{i \in A} p_i) (\sum_{j \in B} q_j)$.

c) Variables aléatoires mutuellement indépendantes

Def : Des variables aléatoires X_1, X_2, \dots, X_n sont mutuellement indépendantes ssi

$$P(X_1 = x_1, \dots, X_n = x_n) = P(X_1 = x_1) P(X_2 = x_2) \dots P(X_n = x_n)$$

Remarque : Si X, Y et Z sont des variables aléatoires mutuellement indépendantes, alors (X, Y) et Z sont des variables aléatoires indépendantes. En particulier, pour toute fonction f définie $E \times E' \rightarrow E''$, $f(X, Y)$ et Z sont indépendants.

Par exemple, si X_1, \dots, X_n sont mutuellement indépendants, X_n est indépendant de $X_1 + \dots + X_{n-1}$.

Remarque : Des variables aléatoires (avec $n \geq 3$) deux à deux indépendantes ne sont pas nécessairement mutuellement indépendantes.

d) Espace probabilisé portant une suite de variables aléatoires mutuellement indépendantes

Prop (admis) : Soit une suite $(X_n)_{n \in \mathbb{N}}$ de variables aléatoires mutuellement indépendantes. Alors il existe un espace probabilisé Ω et une suite $(Y_n)_{n \in \mathbb{N}}$ de v.a. (mutuellement indépendantes) sur cet espace Ω telle que $\forall n \in \mathbb{N}, X_n \sim Y_n$.

Exemple : Modélisation d'un jeu de pile ou face infini par une suite $(X_n)_{n \in \mathbb{N}}$ de variables aléatoires de Bernoulli mutuellement indépendantes. On a $X_n : \{0, 1\} \rightarrow \{0, 1\}$ définie par $P(X_n = 0) = p$ et $P(X_n = 1) = 1 - p$.

On considère alors $\Omega = \{0, 1\}^{\mathbb{N}}$ l'ensemble des suites à valeurs dans $\{0, 1\}$ et $Y_n : \Omega \rightarrow \{0, 1\}$ $(u_k)_{k \in \mathbb{N}} \mapsto u_n$ est la variable aléatoire correspondant au n -ième tirage.

Par exemple, on a $P(Y_0 = 1, Y_0 = 1, \dots, Y_{n-1} = 1) = p^n$. Si $p < 1$, on a $P((Y_n)_{n \in \mathbb{N}} = (1)_{n \in \mathbb{N}}) = \lim_{n \rightarrow +\infty} p^n = 0$.

5) Espérance et variance d'une variable aléatoire discrète à valeurs réelles

Soit $X : \Omega \rightarrow E = \{x_n, n \in \mathbb{N}\}$ une variable aléatoire discrète à valeurs réelles, c'est-à-dire $E \subset \mathbb{R}$.

a) Opérations sur les variables aléatoires discrètes à valeurs réelles

- Soit $f : \mathbb{R} \rightarrow \mathbb{R}$ une application.

Si X est une v.a.d. à valeurs réelles, il en est de même de la variable aléatoire $f(X) : x \mapsto f(X(x))$.

- Plus généralement, si $f : \mathbb{R}^n \rightarrow \mathbb{R}$ et si X_1, \dots, X_n sont des v.a.d. à valeurs réelles, il en est de même de $f(X_1, \dots, X_n)$.

Exemple : Si X et Y sont des v.a.d. à valeurs réelles, (X, Y) est une v.a.d à valeurs dans \mathbb{R}^2 .

Et λX , $X + Y$ et XY sont des v.a.d. à valeurs réelles (où $\lambda \in \mathbb{R}$).

En particulier, l'ensemble des v.a.d. $X : \Omega \rightarrow \mathbb{R}$ est un sev (et même une sous-algèbre) de $\mathcal{F}(\Omega, \mathbb{R})$.

b) Espérance

Def : On dit que $X : \Omega \rightarrow E = \{x_n, n \in \mathbb{N}\}$ est d'espérance finie si $\sum_{x \in E} |x| P(X = x)$ converge.

Dans ce cas, on pose $E(X) = \sum_{x \in E} x P(X = x) = \sum_{n=0}^{+\infty} x_n P(X = x_n)$.

Remarque : Comme les termes sont positifs, la valeur de la somme (finie ou infinie) ne dépend pas de l'ordre des termes. Autrement dit, X est d'espérance finie ssi la famille $(x P(X = x))_{x \in E}$ est sommable.

Propriété : Soient X et $Y : \Omega \rightarrow \mathbb{R}$ des v.a.d. d'espérance finie.

- Linéarité de l'espérance : $E(X + Y) = E(X) + E(Y)$, $E(\lambda X) = \lambda E(X)$

En particulier, en posant $m = E(X)$, la v.a. $X - m$ (qu'on devrait noter $X - \tilde{m}$) est d'espérance nulle.

- Positivité : Si $X \geq \tilde{0}$, alors $E(X) \geq 0$, avec égalité ssi X est nulle presque partout, c'est-à-dire $P(X \neq 0) = 0$.

- Croissance de l'espérance : Si $X \leq Y$, alors $E(X) \leq E(Y)$.

Théorème de comparaison :

Si $|X| \leq Y$ et Y d'espérance finie, alors X est d'espérance finie et $|E(X)| \leq E(Y)$.

Ainsi, $\mathcal{L}^1(\Omega, \mathbb{R})$ des v.a. d'espérance finie (= de moment d'ordre 1 fini) est un sev de $\mathcal{F}(\Omega, \mathbb{R})$.

Et $X \mapsto E(X)$ est une forme linéaire sur cet espace. De plus, elle est définie positive, au sens où $X \geq 0$ implique

$E(X) \geq 0$, avec égalité ssi $X = 0$ presque sûrement, c'est-à-dire ssi $P(X = 0) = 1$.

Terminologie : $X - \mu$ est d'espérance nulle (variable centrée) ssi $\mu = E(X)$.

On dit que $X - \mu$ est la variable centrée associée à X .

c) Théorème du transfert : Soit $X : \Omega \rightarrow \mathbb{Z} \subset \mathbb{E} = \{x_n, n \in \mathbb{N}\}$ et $f : \mathbb{Z} \rightarrow \mathbb{R}$.

Th : La v.a. $f(X) : \Omega \rightarrow \mathbb{R}$ est d'espérance finie ssi $\sum_{x \in E} |f(x)| P(X = x)$ converge, et dans ce cas

$$E(f(X)) = \sum_{x \in E} f(x) P(X = x)$$

Preuve : L'idée est de regrouper dans la somme $\sum_{x \in E} f(x)P(X = x)$ les termes selon la valeur de $f(x)$.

Par sommation par paquets, on a

$$\sum_{x \in E} |f(x)| P(X = x) = \sum_{y \in f(E)} \sum_{f(x)=y} |f(x)| P(X = x) = \sum_{y \in f(E)} |y| P(f(X) = y)$$

La première somme converge ssi les deux autres convergent. On obtient alors :

$$\sum_{x \in E} f(x)P(X = x) = \sum_{y \in f(E)} \sum_{f(x)=y} f(x)P(X = x) = \sum_{y \in f(E)} yP(f(X) = y) = E(f(X))$$

Exemple d'utilisation : Preuve de la linéarité de l'espérance :

On considère $Z = (X, Y)$, et $f : \mathbb{R}^2 \rightarrow \mathbb{R} (x, y) \mapsto x + y$.

Ainsi, $f(Z) = X + Y$. On a donc $E(X + Y) = \sum_{(x,y) \in E \times F} (x + y)P(X = x, Y = y)$.

Avec $g(Z) = X$, on a de même $E(X) = \sum_{(x,y) \in E \times F} xP(X = x, Y = y)$. De même pour $E(Y)$.

Donc $E(X + Y) = E(X) + E(Y)$.

Exemple d'utilisation :

On prend $f : \mathbb{R}^2 \rightarrow \mathbb{R} (x, y) \mapsto xy$ pour prouver $E(XY) = E(X)E(Y)$ pour X et Y indépendantes.

d) Moments d'ordre 2, sev $\mathcal{L}^2(\Omega, \mathbb{R})$

Def : $E(X^2) = \sum_{n=0}^{+\infty} x_n^2 P(X = x_n)$ est appelé le moment d'ordre 2 de X .

On dit que X admet un moment d'ordre 2 ssi $E(X^2) < +\infty$, c'est-à-dire ssi $\sum x_n^2 P(X = x_n)$ converge.

Prop : Si X et $Y : \Omega \rightarrow \mathbb{R}$ admettent un moment d'ordre 2, alors XY est d'espérance finie.

Preuve : $|XY| \leq \frac{1}{2}(X^2 + Y^2)$.

Corollaire : Si $E(X^2) < +\infty$, alors $X = X \cdot 1$ est d'espérance finie, et $|E(X)| \leq E(|X|) \leq \sqrt{E(X^2)}$.

Corollaire : L'ensemble $\mathcal{L}^2(\Omega, \mathbb{R})$ des v.a. de moment d'ordre 2 fini est un sev de $\mathcal{F}(\Omega, \mathbb{R})$.

Remarque : Les fonctions constantes \tilde{m} appartiennent à $\mathcal{L}^2(\Omega)$, car $E(\tilde{m}) = m^2 P(\Omega) = 1$.

Important : L'application $f : \langle X, Y \rangle \mapsto E(XY)$ est bilinéaire, symétrique et positive sur $\mathcal{L}^2(\Omega)$.

En particulier $E(X^2) = \sum_{i=1}^n E(X_i^2) + 2 \sum_{i < j} E(X_i X_j)$.

On a donc l'inégalité de Cauchy-Schwarz : $E(XY)^2 \leq E(X^2)E(Y^2)$.

Complément : On identifie les variables aléatoires X et Y telles que $P(X = Y) = 1$.

On dit que X et Y sont égales presque sûrement. Alors \langle , \rangle est un produit scalaire sur le sev $\mathcal{L}^2(\Omega)$.

e) Variance

Def et prop : Si $E(X^2) < +\infty$, alors X est d'espérance finie.

On pose $V(X) = E((X - \mu)^2)$, où $\mu = E(X)$.

$V(X)$ est appelé variance de X , et on a $V(X) = E(X^2) - m^2$.

Preuve : Si $E(X^2) < +\infty$, alors X est d'espérance finie (car $X = X \cdot \tilde{1}$ et $\tilde{1} \in \mathcal{L}^2(\Omega)$).

Remarque : Réciproquement, si $(X - m) \in \mathcal{L}^2(\Omega)$, alors $X \in \mathcal{L}^2(\Omega, \mathbb{R})$, car $\tilde{m} \in \mathcal{L}^2(\Omega)$.

Def : On définit l'écart type par $\sigma(X) = \sqrt{V(X)}$.

Remarque : Plus la variance est petite et plus la variable aléatoire est concentrée autour de sa moyenne.

Propriétés : Pour λ et μ réels, et $X \in \mathcal{L}^2_P(\Omega)$, on a $V(X + \mu) = V(X)$ et $V(\lambda X) = \lambda^2 V(X)$.

Remarque : Ainsi, $V(\lambda X + \mu) = \lambda^2 V(X)$.

f) Covariance, espérance et variance d'une somme

Covariance : $\text{Cov}(X, Y) = E((X - \mu_X)(Y - \mu_Y)) = E(XY) - \mu_X \mu_Y$, où $m_X = E(X)$.

Prop : $E(\sum_{i=1}^n X_i) = \sum_{i=1}^n E(X_i)$ et $V(\sum_{i=1}^n X_i) = \sum_{i=1}^n V(X_i) + 2 \sum_{i < j} \text{Cov}(X_i, X_j)$.

En effet, en notant $X_i = X'_i + m_i$, on a $V(X) = \langle X', X' \rangle$.

f) Corrélation

Def : Le coefficient de corrélation est $\rho_{X,Y} = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}$.

On a l'inégalité de Cauchy-Schwarz : $f : \langle X, Y \rangle^2 \leq \langle X, X \rangle \langle Y, Y \rangle$.

Prop : $|\rho_{X,Y}| \leq 1$, avec égalité ssi X et Y sont égales (presque sûrement)

6) Inégalités de Markov et de Bienaymé-Tchebychev

Soit $X : \Omega \rightarrow E = \{x_n, n \in \mathbb{N}\}$ une variable aléatoire discrète à valeurs réelles.

a) Inégalité de Markov

Prop : $P(X \geq a) \leq \frac{E(X)}{a}$.

Preuve : $E(X) \geq \sum_{x \geq a} x P(X = x) \geq \sum_{x \geq a} a P(X = x) = a P(X \geq a)$.

b) Inégalité de Bienaymé-Tchebychev

Prop : Posons $\mu = E(X)$. Alors $\forall \varepsilon > 0, P(|X - \mu| \geq \varepsilon) \leq \frac{V(X)}{\varepsilon^2}$.

Preuve : $P((X - \mu)^2 \geq \varepsilon^2) \leq \frac{E((X - \mu)^2)}{\varepsilon^2}$.

Remarque : $P(S \geq n\varepsilon) \leq \frac{E(e^{tS})}{e^{nt\varepsilon}}$. Si $S = (X_1 + X_2 + \dots + X_n)$, où X_i i.i.d., alors $P(S \geq n\varepsilon) \leq \frac{E(e^{tX})^n}{e^{nt\varepsilon}}$.

7) Variance de variables aléatoires discrètes indépendantes

a) Prop : $\boxed{\text{Si } X \text{ et } Y \text{ sont deux variables aléatoires discrètes réelles indépendantes, alors } E(XY) = E(X)E(Y)}$

Corollaire : Si les X_i sont mutuellement indépendantes, alors $E(X_1 \dots X_n) = E(X_1) \dots E(X_n)$.

En effet, X_n est indépendant de $X_1 X_2 \dots X_{n-1}$, et on procède par récurrence sur n .

Remarque : Plus généralement, si les $f_i : E \rightarrow D$, et les X_i sont mutuellement indépendantes, alors

$$E \left(\prod_{i=1}^d f_i(X_i) \right) = \prod_{i=1}^d E(f_i(X_i)).$$

En effet, les $f_i(X_i)$ sont mutuellement indépendantes.

b) Prop : $\boxed{\text{Si les } X_i \text{ sont des variables aléatoires deux à deux indépendantes, alors } V(\sum_{i=1}^n X_i) = \sum_{i=1}^n V(X_i)}$.

8) Variables aléatoires identiquement distribuées

Def : On dit que deux v.a. X et Y à valeurs dans E sont identiquement distribuées ssi elles ont même loi, c'est-à-dire si

$$\forall x \in E, P(X = x) = P(Y = x).$$

Prop : Si les X_i sont des v.a. à valeurs réelles et i.d.d (indépendantes et identiquement distribuées), alors

$$E\left(\sum_{i=1}^n X_i\right) = n\mu \text{ et } V\left(\sum_{i=1}^n X_i\right) = nv$$

où μ et v sont l'espérance et la variance de la loi des X_i .

Exemple : Si $X \sim \mathcal{B}(n, p)$, alors $E(X) = np$ et $V(X) = np(1-p)$.

9) Variables aléatoires à valeurs dans \mathbb{N}

On considère des v.a.d. définies à valeurs dans $E = \mathbb{N}$. On pose $\boxed{a_n = P(X = n)}$.

a) Espérance

Prop : $\boxed{E(X) = \sum_{n=0}^{+\infty} nP(X = n) = \sum_{n=0}^{+\infty} P(X \geq n+1)}$.

Preuve : En posant $a_n = P(X = n)$ et $A_n = P(X \geq n) = \sum_{k=n}^{+\infty} a_k$, alors la transformée d'Abel donne

$$\sum_{n=0}^{+\infty} na_n = \sum_{n=1}^{+\infty} n(A_n - A_{n+1}) = \sum_{n=1}^{+\infty} A_n$$

b) Série génératrice

On pose $\boxed{G_X(z) = \sum_{n=0}^{+\infty} a_n z^n}$. En particulier, $G_X(1) = 1$. On considère désormais G_X définie sur $[0, 1]$.

Prop : $\boxed{\text{L'espérance est } E(X) = \sum_{n=0}^{+\infty} na_n = G'_X(1)}$.

Remarque : $E(X)$ est finie ssi $G'_X(1)$ existe. En effet, la convergence de $\sum_{n=0}^{+\infty} na_n$ équivaut à la convergence normale de la série des dérivées $\sum na_n x^{n-1}$ sur $[0, 1]$.

Remarque : Plus généralement le moment d'ordre r est $M(r) = \sum_{n=0}^{+\infty} n^r a_n z^n$. Il est fini ssi $G_X^{(r)}(1)$ existe.

En particulier, $M(2) = \sum_{n=0}^{+\infty} n^2 a_n z^n = G_X''(1) + G_X'(1)$.

Prop : $\boxed{\text{La variance est } V(X) = E(X - E(X))^2 = E(X^2) - E(X)^2 = G_X''(1) + G_X'(1) - G_X'(1)^2}$.

c) Série génératrice de $X + Y$, où X et Y sont indépendantes

Prop : On suppose X et Y indépendantes.

Alors $S = X + Y$ suit la loi $P(S = n) = \sum_{k=0}^n P(X = k)P(Y = n - k)$. Donc $\boxed{G_{X+Y}(z) = G_X(z)G_Y(z)}$

Exemples fondamentaux :

- Une v.a. de Bernoulli de paramètre p admet pour série génératrice $G_X(z) = 1 - p + pz$.

Une somme $S = X_1 + X_2 + \dots + X_n$ de v.a. de Bernoulli i.d.d. de paramètre p admet pour série génératrice

$$G_S(z) = G_X(z)^n = (1 - p + pz)^n = \sum_{k=0}^n \binom{n}{k} (1 - p)^{n-k} p^k z^k$$

Autrement dit $S = \sum_{i=1}^n X_i \sim B(n, p)$, c'est-à-dire S suit une loi binomiale de paramètre (n, p) .

- Une v.a. de Poisson de paramètre $\lambda \geq 0$ admet pour série génératrice $G_X(z) = \sum_{n=0}^{+\infty} \frac{\lambda^n e^{-\lambda}}{n!} z^n = e^{\lambda(z-1)}$.

Une somme $S = X_1 + X_2 + \dots + X_n$ de v.a. de Poisson mutuellement indépendantes et de paramètres respectifs p_1, p_2, \dots, p_n admet pour série génératrice $G_S(z) = e^{\lambda(z-1)}$, où $\lambda = \lambda_1 + \lambda_2 + \dots + \lambda_n$.

Donc $S \sim \mathcal{P}(\lambda)$, c'est-à-dire S suit une loi binomiale de paramètre $\lambda = \lambda_1 + \lambda_2 + \dots + \lambda_n$.