

Intégration et Probabilités

S. Nonnenmacher

USTC

28/04/2026



Lois classiques de probabilité.

a) Si E est de cardinal n ($E = \{1, \dots, n\}$),

la loi uniforme sur E est la loi telle que


$$\forall x \in E, \quad P(X=x) = \frac{1}{n}.$$

Tous les points de E ont la même probabilité.

b) Loi de Bernoulli sur $E = \{0, 1\}$ ou $E = \{\text{pile}, \text{face}\}$

paramètre de la loi: $p \in [0, 1]$.

$$P(X=\text{pile}) = P(X=1) = p, \quad P(X=0) = 1-p.$$



C'est la loi uniforme si $p = \frac{1}{2}$, sinon cette loi n'est pas uniforme.

c) Loi binomiale $B(n, p)$, $n \in \mathbb{N}^*$, $p \in [0, 1]$.

$$E = \{0, 1, \dots, n\}$$

$$P(X = k) = \binom{n}{k} p^k (1-p)^{n-k}, \quad 0 \leq k \leq n$$

Cette loi binomiale est reliée à la loi de Bernoulli :

si on tire n fois une loi de Bernoulli avec paramètre p ,

$P(X = k)$ = probabilité d'obtenir k fois "pile".

et donc $(n-k)$ fois "face".

$\Omega = \{0, 1\}^n$ l'espace probabilisé pour n tirage de la pièce.

Parmi les 2^n suites possibles, compter combien de suites contiennent exactement p "pile".

d) Loi géométrique de paramètre $p \in]0, 1[$.

v.a. à valeur dans \mathbb{N} , de loi :

$$P(X=k) = (1-p)p^k, \quad \forall k \in \mathbb{N}.$$

Lien avec la loi de Bernoulli: si on tire une infinité de fois une pièce de Bernoulli- p , la loi géométrique décrit le nombre de "pile" avant le premier "face".

Même question que pour le tirage de dé: combien de tirages faut-il effectuer avant d'obtenir le premier "face"?

"géométrique" car la suite $(C p^k)_{k \geq 0}$ est appelée une suite géométrique de paramètre p .

e) Loi de Poisson de paramètre $\lambda \in \mathbb{R}_+^*$.
v.a. dans \mathbb{N} , de probabilité

$$P(X=k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k \in \mathbb{N}.$$

Cette loi décrit les "événements rares" pendant un grand nombre de tirages (ou pendant une longue période).

Lien avec la loi de Bernoulli: suite de v.a.

X_n de lois binomiales $\mathcal{B}(n, p = \frac{\lambda}{n})$.

Événement rare:

obtenir "pile" à, à chaque fois, la probabilité $\frac{\lambda}{n}$.

$$\lim_{n \rightarrow \infty} P(X_n = k) = \lim_{n \rightarrow \infty} \binom{n}{k} \left(\frac{\lambda}{n}\right)^k \left(1 - \frac{\lambda}{n}\right)^{n-k} \frac{\lambda}{n}.$$

$$\stackrel{\text{Stirling}}{=} \frac{\lambda^k}{k!} e^{-\lambda} \frac{n!}{(n-k)! k!} \frac{\left(\frac{n}{e}\right)^n \sqrt{2\pi n}}{\left(\frac{n-k}{e}\right)^{n-k} \sqrt{2\pi(n-k)}} \frac{1}{k!}$$


$$\sim \frac{1}{e^k} \frac{n^{n-k}}{(n-k)^{n-k}} \frac{\lambda^k}{k!} \frac{(1-\frac{\lambda}{n})^n}{(1-\frac{\lambda}{n})^k}$$

$$\sim \frac{1}{e^k} \frac{(1-\frac{k}{n})^k}{(1-\frac{k}{n})^n}$$

$$\sim \frac{\lambda^k}{k!} e^{-\lambda}$$

Lois de variables continues
(ex: sur \mathbb{R})

a) Loi uniforme sur un intervalle borné $[a, b]$: Loi de densité $p(x) = \frac{1}{b-a} \mathbb{1}_{[a,b]}(x)$.



$P([a, \beta]) = \frac{\beta - \alpha}{b - a}$ ne dépend que de la longueur de $[\alpha, \beta]$, et non de sa position dans $[a, b]$.

b) Loi exponentielle de paramètre $\lambda \in \mathbb{R}_+^*$: loi de densité $p(x) = \lambda e^{-\lambda x}$ sur \mathbb{R}_+ .

$$= \lambda e^{-\lambda x} \mathbb{1}_{\mathbb{R}_+}(x) \quad \text{sur } \mathbb{R}$$


Propriété intéressante de cette loi : $\forall a, b > 0$,

$$P(X > a+b) = P(X > a) \cdot P(X > b).$$

$$\int_{a+b}^{+\infty} p(x) dx = e^{-\lambda(a+b)} = e^{-\lambda a} \cdot e^{-\lambda b}$$


Interprétation : pour que X dépasse $(a+b)$, il faut d'abord dépasser a , ce qui est fait avec proba $e^{-\lambda a}$, puis il faut en core franchir une distance b pour atteindre $a+b$. Cette 2^e étape, est indépendante de la 1^{ère},

et elle a la même probabilité que pour aller de 0 à b .



Propriété de factorisation reflète l'indépendance des
2 parties du chemin. Absence de mémoire de la particule.

Exemple d'application en physique atomique : processus de
désintégration d'un noyau atomique radioactif.



désintégration au bout d'un
temps aléatoire.

La loi de ce temps de désintégration est une loi exponentielle. Le paramètre λ dépend du type de noyau considéré. $\frac{1}{\lambda}$ = temps de demi-vie de l'atome.


c) Loi gaussienne, ou loi normale $\mathcal{N}(m, \sigma^2)$.

. $m \in \mathbb{R}$ le centre de la gaussienne

. $\sigma \in \mathbb{R}_+$ l'écart-type de la gaussienne.

v.a. sur \mathbb{R} , de densité

$$p(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-m)^2}{2\sigma^2}}$$

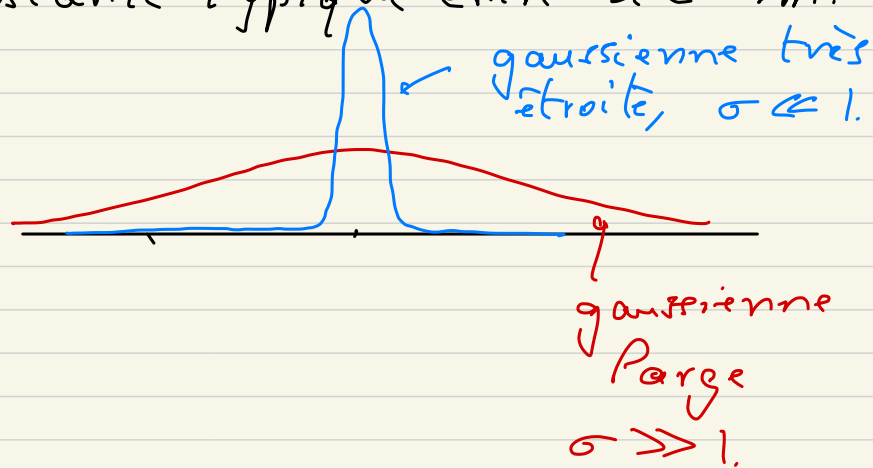


$$\begin{aligned}
 m = \mathbb{E}[X] &= C \int x e^{-\frac{(x-m)^2}{2\sigma^2}} dx = C \int (y+m) e^{-\frac{y^2}{2\sigma^2}} dy \\
 &= \underbrace{C \int y e^{-\frac{y^2}{2\sigma^2}} dy}_{0} + m \underbrace{C \int e^{-\frac{y^2}{2\sigma^2}} dy}_{1}
 \end{aligned}$$

$$\sigma^2 = \mathbb{E}[(X-m)^2] \quad \text{la variance de la loi.}$$


$$\sigma = \sqrt{\mathbb{E}[(X-m)^2]} \quad \text{distance typique entre } x \text{ et } m.$$

= Ecart - type.



Si X suit la loi $\mathcal{N}(m, \sigma^2)$, $(X-m)$ suit la loi centrée $\mathcal{N}(0, \sigma^2)$.

La v.a. $\frac{X-m}{\sigma}$ suit la loi $\mathcal{N}(0, 1)$ = la loi normale centrée réduite



• Si X suit la loi $\mathcal{N}(m, \sigma^2)$, alors la v.a. $Y = \lambda X + \mu$ suit la v.a. normale $\mathcal{N}(\lambda m + \mu, \lambda^2 \sigma^2)$.

• La loi normale est très importante : le théorème central Limite décrit la somme de N variables

aléatoires indépendantes et identiques.

• Fonction de répartition d'1 v.a. réelle X

$$F_x(t) = P(X \leq t) = P_x(\left] -\infty, t \right]), \quad \forall t \in \mathbb{R}.$$

$$F_x(t) \xrightarrow[t \rightarrow +\infty]{} 1, \quad \text{cf. loi de probabilité.}$$

• F fonction $F \xrightarrow[t \rightarrow -\infty]{} 0$, \uparrow , continue à droite

$$F \xrightarrow[t \rightarrow +\infty]{} 1$$

\rightarrow correspond une unique loi de probab. sur \mathbb{R} .

$$P(a \leq X \leq b) = F_x(b) - F_x(a-)$$

$$P(a < X < b) = F_x(b-) - F_x(a).$$

Points de discontinuité de $F_x =$ atomes de P_x .

• Tribu engendrée par une v. a.

Ω , $\mathcal{A} = ?$

Pour choisir la tribu \mathcal{A} , on demande que certaines fonctions $f: \Omega \rightarrow \mathbb{R}$ soient mesurables.

Si $X: \Omega \rightarrow (E, \mathcal{E})$, la tribu engendrée par X , notée $\sigma(X)$, est la plus petite tribu telle que X soit mesurable entre $(\Omega, \sigma(X))$ et (E, \mathcal{E}) .

On trouve que

$$\sigma(X) = \underbrace{\left\{ A = X^{-1}(B), B \in \mathcal{E} \right\}}_{\text{une tribu.}}$$

• $(X_i)_{i \in I}$ famille de fonctions $\Omega \rightarrow (E_i, \mathcal{E}_i)$,

alors on peut définir la tribu engendrée par la famille de ces fonctions:

$$\mathcal{I} = \sigma((X_i)_{i \in I}) = \sigma\left(\bigcap_{\Omega} \left\{ X_i^{-1}(B) ; B \in \mathcal{E}_i, \forall i \in I \right\}\right)$$


La plus petite tribu telle que tous les X_i soient mesurables $\mathcal{I} \rightarrow \mathcal{E}_i$.

• Proposition Soit X une v.a. à valeur dans (E, \mathcal{E}) , et soit Y une v.a. réelle. On a alors équivalence entre:

i) la v.a. Y est $\sigma(X)$ -mesurable.

$\Leftrightarrow \sigma(Y)$ est une sous-tribu de $\sigma(X)$.

ii) il existe une fonction $f: (E, \mathcal{E}) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mesurable, telle que $Y = f(X)$.



On dit alors que Y est totalement dépendante de X .

" si je connais la valeur de X , alors la valeur de Y est fixée.

Preuve: ii) \Rightarrow i) si $Y = f \circ X$, alors, $\forall A \in \mathcal{B}(\mathbb{R})$,
 $\sigma(Y) \ni Y^{-1}(A) = (f \circ X)^{-1}(A) = X^{-1}(\underbrace{f^{-1}(A)}_{\in \mathcal{E}}) \in \sigma(X)$.

i) \Rightarrow ii) Supposons que Y est $\sigma(X)$ -mesurable.

1^{er} cas: si γ est étagée: $\gamma = \sum_{i=1}^n \lambda_i \mathbb{1}_{A_i}$, avec
 $A_i \in \sigma(X)$ disjoints 2 à 2.

$\Rightarrow \exists B_i \in \mathcal{E}$ tq $A_i = X^{-1}(B_i)$, B_i disjoints 2 à 2

$$\Rightarrow \gamma = \sum_{i=1}^n \lambda_i \mathbb{1}_{X^{-1}(B_i)} = \sum_{i=1}^n \lambda_i \mathbb{1}_{B_i} \circ X$$

$$= \underbrace{\left(\sum_{i=1}^n \lambda_i \mathbb{1}_{B_i} \right)}_{f} \circ X$$

$f: \mathcal{E} \rightarrow \mathbb{R}$ mesurable.
 $\mathcal{B}(\mathbb{R})$

• γ une fonction quelconque, $\sigma(X)$ -mesurable.

$$\gamma = \gamma^+ - \gamma^-$$

$\gamma^+ = \lim_{n \rightarrow \infty} \gamma_n \rightarrow$ fonctions étagées ≥ 0
 $\sigma(X)$ -mesurables

Chaque $\gamma_n = f_n \circ X$ pour une fonction étagée ≥ 0 f_n ,
 mesurable $\mathcal{E} \rightarrow \mathcal{B}(\mathbb{R})$.

$\forall \omega \in \Omega, Y_n(\omega) \rightarrow Y(\omega)$ simplement \Rightarrow

$$f_n(\underbrace{X(\omega)}_{x \in \text{Ran}(X) \subset E}) \rightarrow Y(\omega).$$

$\Rightarrow \forall x \in \text{Ran}(X), f_n(x)$ a une limite.

\Rightarrow définissons la fonction f sur E , tq.

est mesurable $\left\{ \begin{array}{l} f(x) = \lim_{n \rightarrow \infty} f_n(x) \text{ si la limite existe} \\ 0 \text{ sinon.} \end{array} \right.$

On sait que la limite existe si $x \in \text{Ran}(X)$.

$$\Rightarrow \forall \omega \in \Omega, f(X(\omega)) = \lim_{n \rightarrow \infty} f_n(X(\omega)) = Y(\omega).$$

$$\Rightarrow Y = f \circ X.$$

□.

• TCM: $X_n \geq 0$, $X_n \uparrow X \Rightarrow \mathbb{E}[X_n] \uparrow \mathbb{E}[X]$.

Fatou: $X_n \geq 0 \Rightarrow \mathbb{E}[\liminf_n X_n] \leq \liminf_n \mathbb{E}[X_n]$

TCD: $|X_n| \leq Z$ et $\mathbb{E}[Z] < \infty$, $X_n \rightarrow X$ p.p.
 $\Rightarrow \mathbb{E}[X_n] \rightarrow \mathbb{E}[X]$.

• Une v.a. réelle X est centrée si elle est intégrable ($\mathbb{E}[|X|] < \infty$) et $\mathbb{E}[X] = 0$.

• En théorie des probabilités, "presque partout" se dit "presque sûrement" (p.s.) = "avec probabilité 1".

\leq de Hölder : $\mathbb{E}[|XY|] \leq \underbrace{\mathbb{E}[|X|^p]}^{1/p} \underbrace{\mathbb{E}[|Y|^q]}^{1/q}$

q, p conjuguées.

$\|X\|_p$ $\|Y\|_q$

• $\|X\|_r \leq \|X\|_p$ si $p \geq r$

• Cauchy-Schwarz : $\mathbb{E}[|XY|] \leq \mathbb{E}[X^2]^{1/2} \mathbb{E}[Y^2]^{1/2}$

($Y=1$) $\Rightarrow \mathbb{E}[|X|]^2 \leq \mathbb{E}[X^2]$.

Variance et matrice de covariance.

Déf : Soit $X \in L^2(\Omega, \mathcal{P})$ une v.a. réelle. On

définit sa variance par :

$\text{var}(X) = \mathbb{E} \left[\underbrace{(X - \mathbb{E}[X])^2}_{\text{v. a. centrée}} \right] < \infty$

et son écart-type $\sigma_x = \sqrt{\text{var}(X)}$


largeur de la
distribution de X

dispersion de X



Si $\text{Var}(X) = 0 \rightarrow X = \mathbb{E}[X]$ p.s.

Si X suit la loi normale $\mathcal{P}(m, \sigma^2)$, alors $\sigma_x = \sigma$ représente la "largeur à mi-hauteur" de la gaussienne :



$$|x - m| \leq \sigma \Leftrightarrow p(x) \geq \underbrace{e^{-\frac{1}{2}}}_{\frac{1}{\sqrt{2}}} \cdot p_{\max}$$

$\sigma \sqrt{2 \ln 2}$

$0,606 \dots$

Proposition: $X \in L^2(\Omega, \mathbb{R})$. Alors

$$\text{var}(X) = \mathbb{E}[X^2] - (\mathbb{E}[X])^2.$$

↑ moment d'ordre 2 de la v.a. X .

$$\forall a \in \mathbb{R}, \mathbb{E}[(X-a)^2] = \text{var}(X) + \underbrace{(\mathbb{E}[X] - a)^2}_{\geq 0}$$

$$\Rightarrow \text{var}(X) = \inf_{a \in \mathbb{R}} \mathbb{E}[(X-a)^2], \text{ avec } \underset{\text{minimum atteint pour } a = \mathbb{E}[X].}{\geq 0}$$

Preuve: développer les carrés

$$\begin{aligned} \mathbb{E}[(X-a)^2] &= \mathbb{E}[X^2 - 2aX + a^2] \\ &= \mathbb{E}[X^2] - 2a\mathbb{E}[X] + a^2\mathbb{E}[1] \\ &= \underbrace{\mathbb{E}[X^2] - \mathbb{E}[X]^2}_{\text{var}(X)} + (\mathbb{E}[X] - a)^2 \end{aligned}$$

• Inégalités :

• Inégalité de Markov: X v. a. ≥ 0 , $\forall a > 0$
 $\Rightarrow P(X \geq a) \leq \frac{1}{a} E[X].$

• Inégalité de Bienaymé-Chebyshev :

si $X \in L^2(\Omega, \mathcal{P})$, $a > 0$,

$$P(|X - E[X]| \geq a) \leq \frac{1}{a^2} \text{var}(X).$$

pr: utiliser Markov pour la v.a. $Y = (X - E[X])^2$

Ces \leq permettent de borner les probabilités de grandes déviations en terme d'espérances.

- Covariance entre plusieurs v.a. réelles.

Déf. Soit $X, Y \in L^2(\Omega, \mathbb{P})$. La covariance de X et Y

est définie par :

$$\text{cov}(X, Y) = \mathbb{E} \left[\underbrace{(X - \mathbb{E}[X]) (Y - \mathbb{E}[Y])}_{\text{v.a. centrée}} \right]$$

$$= \mathbb{E} [X (Y - \mathbb{E}[Y])]$$

$$= \mathbb{E} [(X - \mathbb{E}[X]) Y]$$

$$= \mathbb{E} [XY] - \mathbb{E}[X] \mathbb{E}[Y]$$

Soit un vecteur aléatoire $X = (X_1, X_2, \dots, X_d)$
v.a. à valeurs dans \mathbb{R}^d .

On suppose que $X_i \in L^2(\Omega, \mathbb{P})$, $\forall i=1, \dots, d$.

On définit alors la matrice de covariance de X :

$$K_X = \left(\text{cov}(X_i, X_j) \right)_{i,j=1,\dots,d}$$

Propriétés de $\text{cov}(X, Y)$:

1) Si $X = Y$, $\text{cov}(X, Y) = \text{var}(X) \geq 0$.

Par contre, si $X \neq Y$, on peut avoir $\text{cov}(X, Y) \leq 0$.

ex: $Y = -X \Rightarrow \text{cov}(X, -X) = -\text{var}(X) \leq 0$.

2) Cauchy-Schwarz: $|\text{cov}(X, Y)| \leq \sqrt{\text{var}(X)} \sqrt{\text{var}(Y)}$

3) $(X, Y) \mapsto \text{cov}(X, Y)$ est une forme bilinéaire ^{symétrique} sur $L^2(\Omega)$.

4) Pour $X = (X_1, \dots, X_d)$, la matrice de covariance K_X est symétrique positive:

$$(K_X)_{ij} = (K_X)_{ji}$$

$$\forall \lambda = (\lambda_1, \dots, \lambda_d) \in \mathbb{R}^d,$$

$$\langle \lambda, K_X \lambda \rangle = \sum_{i,j=1}^d \lambda_i \lambda_j (K_X)_{ij} = \text{var} \left(\sum_{i=1}^d \lambda_i X_i \right) \geq 0$$

Exercice: si A matrice $n \times d$, et $X' = A X$ une v.a. dans \mathbb{R}^n , alors la matrice sur \mathbb{R}^d

$$\text{de covariance } \underbrace{K_{X'}}_{n \times n} = \underbrace{A}_{n \times d} \underbrace{K_X}_{d \times d} \underbrace{A^t}_{d \times n}$$

La covariance donne une mesure de la dépendance,

ou la corrélation, entre les v.a. X et Y .

$$\text{Si } Y \approx X \Rightarrow \text{cov}(X, Y) \geq 0$$

$$Y \approx -X \Rightarrow \text{cov}(X, Y) \leq 0$$

Si Y et X sont indépendantes $\Rightarrow \text{cov}(X, Y) = 0$.