

1 Convergence en loi

Définition 1

Soit $(X_n)_{n \in \mathbb{N}}$ une suite de variables aléatoires réelles définies sur le même espace probabilisé et X une variable aléatoire définie sur le même espace. Pour tout $n \in \mathbb{N}$, on note F_n (respectivement F) la fonction de répartition de X_n (respectivement X). On dit que $(X_n)_{n \in \mathbb{N}}$ **converge en loi** vers X , et on note $X_n \xrightarrow{\mathcal{L}} X$, si, pour tout réel x **point de continuité** de F , $\lim_{n \rightarrow +\infty} F_n(x) = F(x)$.

Proposition 2 (*Caractérisation de la convergence en loi pour les variables à valeurs entières*)

Soit $(X_n)_{n \in \mathbb{N}}$ une suite de variables aléatoires réelles à valeurs entières (i.e. $\forall n \in \mathbb{N}, X_n(\Omega) \subset \mathbb{N}$). Soit X une variable aléatoire à valeurs entières définie sur le même espace probabilisé. La suite de variables aléatoires $(X_n)_{n \in \mathbb{N}}$ converge en loi vers X , si, et seulement si :

$$\forall x \in \mathbb{N}, \lim_{n \rightarrow +\infty} \mathbb{P}(X_n = x) = \mathbb{P}(X = x).$$

Démonstration.

Théorème 3

Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de variables aléatoires telles que, pour tout $n \in \mathbb{N}^*$, $X_n \hookrightarrow \mathcal{B}(n, p_n)$. Si $\lim_{n \rightarrow +\infty} np_n = \lambda \in \mathbb{R}_+^*$, la suite $(X_n)_{n \in \mathbb{N}^*}$ converge en loi vers une variable aléatoire X suivant la loi de $\mathcal{P}(\lambda)$:

$$\forall k \in \mathbb{N}, \lim_{n \rightarrow +\infty} \mathbb{P}(X_n = k) = \frac{\lambda^k}{k!} e^{-\lambda} \quad \left(= \mathbb{P}(X = k) \text{ où } X \hookrightarrow \mathcal{P}(\lambda) \right).$$

Démonstration.

Remarque 4 (*Approximation d'une loi binomiale par une loi de Poisson*)

Le résultat précédent montre que, pour n suffisamment grand et p suffisamment petit, on peut approcher la loi binomiale $\mathcal{B}(n, p)$ par la loi de Poisson $\mathcal{P}(\lambda)$ où $\lambda = np$. *En pratique, on considère que cette approximation est satisfaisante dès que $n \geq 30$ et $p \leq 0,1$ (ces conditions ne sont pas à connaître).*

2 Théorèmes limites

2.1 Inégalités de concentration

Théorème 5 (Inégalité de Markov)

Soit X une variable aléatoire réelle **positive** admettant une espérance. Alors :

$$\forall a > 0, \mathbb{P}(X \geq a) \leq \frac{\mathbb{E}(X)}{a}.$$

Théorème 6 (Inégalité de Bienaymé-Tchebychev)

Soit X une variable aléatoire réelle admettant un moment d'ordre 2. Alors :

$$\forall \varepsilon > 0, \mathbb{P}(|X - \mathbb{E}(X)| \geq \varepsilon) \leq \frac{\mathbb{V}(X)}{\varepsilon^2}.$$

Remarque 7

Ce résultat rappelle que la variance permet de quantifier la dispersion d'une variable aléatoire autour de sa moyenne : la probabilité que X prenne des valeurs éloignées de $\mathbb{E}(X)$ d'au moins ε est d'autant plus faible que $\mathbb{V}(X)$ l'est.

Exemple 8

Soient r un réel strictement plus grand que 1 et X une variable aléatoire suivant la loi géométrique $\mathcal{G}\left(\frac{1}{r}\right)$.

1. Montrer que $\mathbb{P}(X \geq r^2) \leq \frac{1}{r}$.
2. Montrer que $\mathbb{P}(|X - r| \geq r) \leq 1 - \frac{1}{r}$. En déduire que $\mathbb{P}(X \geq 2r) \leq 1 - \frac{1}{r}$.

2.2 Loi faible des grands nombres

Définition 9

On appelle **moyenne empirique** du n -uplet de variables aléatoires (X_1, \dots, X_n) la variable $M_n = \frac{1}{n} \sum_{k=1}^n X_k$.

Proposition 10

Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de variables aléatoires indépendantes, admettant une même espérance notée μ et une même variance notée σ^2 .

Pour tout entier $n \in \mathbb{N}^*$, la moyenne empirique $M_n = \frac{X_1 + \dots + X_n}{n}$ admet une espérance et une variance et :

$$\mathbb{E}(M_n) = \mu, \quad \mathbb{V}(M_n) = \frac{\sigma^2}{n} \quad \text{et} \quad \sigma(M_n) = \frac{\sigma}{\sqrt{n}}.$$

Démonstration.

Théorème 11 (*Loi faible des grands nombres*)

Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de variables aléatoires indépendantes admettant une même espérance μ et une même variance σ^2 . Pour tout $n \in \mathbb{N}^*$, la variable aléatoire $M_n = \frac{X_1 + \dots + X_n}{n}$ vérifie :

$$\forall \varepsilon > 0, \quad \lim_{n \rightarrow +\infty} \mathbb{P}(|M_n - \mu| \geq \varepsilon) = 0.$$

Démonstration.

Remarque 12

- La loi faible des grands nombres assure qu'il devient improbable que la moyenne empirique M_n s'écarte de l'espérance d'une valeur fixée ε à mesure que n prenne de grandes valeurs.
- La loi faible des grands nombres fournit une approximations de loi dont on ignore l'espérance (lorsqu'elle existe !) : il suffit de choisir un grand nombre de réalisations et d'en calculer la moyenne empirique.

Exemple 13

On lance un dé à 8 faces, numéroté de 1 à 8. On considère la variable aléatoire X définie par :

$$X = \begin{cases} 1 & \text{si on obtient un nombre divisible par 3} \\ -1 & \text{si on obtient un nombre divisible par 4} \\ 0 & \text{sinon.} \end{cases} .$$

1. Écrire une fonction `simule_X` simulant la réalisation de la variable X .
2. Écrire un script calculant une approximation de l'espérance de X à l'aide de 1000 simulation.

2.3 Théorème central limite**Corollaire 14**

Avec les notation de la proposition 10 et si $\sigma \neq 0$, la variable aléatoire $M_n^* = \frac{M_n - \mu}{\frac{\sigma}{\sqrt{n}}}$ est centrée réduite.

Définition 15

Soit (X_1, \dots, X_n) un n -uplet de variables aléatoires définies sur le même espace probabilisé, de moyenne empirique M_n . On appelle **variance empirique** de (X_1, \dots, X_n) , la variable aléatoire notée S_n^2 définie par :

$$S_n^2 = \frac{1}{n} \sum_{k=1}^n (X_k - M_n)^2.$$

On appelle **écart-type empirique** de (X_1, \dots, X_n) , la variable aléatoire $S_n = \sqrt{S_n^2}$.

Proposition 16 (Hors-programme)

Soit (X_1, \dots, X_n) un n -uplet de variables aléatoires indépendantes, de moyenne empirique M_n et de variance empirique S_n^2 . Alors S_n^2 admet une espérance, égale à :

$$\mathbb{E}(S_n^2) = \frac{n-1}{n} \sigma^2.$$

Démonstration.

Remarque 17 (Correction de la variance empirique)

La variable aléatoire $S_n^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - M_n)^2$, appelée **variance empirique corrigée**, a pour espérance σ^2 .

Théorème 18 (Théorème central limite version variance connue)

Si $(X_n)_{n \in \mathbb{N}^*}$ une suite de variables aléatoires indépendantes **identiquement distribuées** (i.e. de même loi), admettant une espérance notée μ et une variance notée σ^2 , alors la suite de variables aléatoires $\left(\frac{M_n - \mu}{\frac{\sigma}{\sqrt{n}}} \right)_{n \in \mathbb{N}^*}$ converge en loi vers une variable aléatoire Z suivant la loi normale centrée réduite. En particulier, pour tout $(a, b) \in \mathbb{R}^2$ tel que $a < b$, on a :

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left(a < \frac{M_n - \mu}{\frac{\sigma}{\sqrt{n}}} < b \right) = \mathbb{P}(a < Z < b) = \int_a^b \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt = \Phi(b) - \Phi(a).$$

où Φ désigne la fonction de répartition de la loi normale centrée réduite $\mathcal{N}(0, 1)$.

Démonstration admise.

Remarque 19

Chacune des inégalités strictes peut être remplacée par une inégalité large dans le théorème précédent.

Remarque 20

Le théorème central limite permet d'approcher, lorsque n est suffisamment grand, la loi de $\frac{M_n - \mu}{\frac{\sigma}{\sqrt{n}}}$ par la loi normale centrée réduite $\mathcal{N}(0, 1)$, donc la loi de M_n par la loi normale $\mathcal{N} \left(\mu, \frac{\sigma^2}{n} \right)$.

Corollaire 21 (Théorème de Moivre-Laplace)

Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de variables aléatoires indépendantes identiquement distribuées, suivant la loi de Bernoulli de paramètre $p \in]0, 1[$. On note, pour tout $n \in \mathbb{N}^*$, la variable aléatoire $T_n = X_1 + \dots + X_n$.

Alors la suite $\left(\frac{T_n - np}{\sqrt{np(1-p)}} \right)_{n \in \mathbb{N}^*}$ converge en loi vers une variable aléatoire T suivant la loi normale centrée réduite.

En particulier, pour tout $(a, b) \in \mathbb{R}^2$ tel que $a < b$, on a :

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left(a < \frac{T_n - np}{\sqrt{np(1-p)}} < b \right) = \mathbb{P}(a < T < b) = \int_a^b \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt = \Phi(b) - \Phi(a).$$

Démonstration.

Remarque 22

Le théorème de Moivre-Laplace permet d'approcher la loi binomiale $\mathcal{B}(n, p)$ par la loi normale $\mathcal{N}(np, np(1-p))$ lorsque n est suffisamment grand. *En pratique, cette approximation est considérée valide dès $n \geq 30$, $np \geq 5$ et $np(1-p) \geq 5$ (ces conditions ne sont pas à connaître).*

Théorème 23 (Théorème central limite version variance inconnue)

Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de variables aléatoires indépendantes et identiquement distribuées (i.e. de même loi), admettant une espérance notée μ et une variance notée σ^2 .

Alors, les suites de variables aléatoires $\left(\frac{M_n - \mu}{\frac{S_n}{\sqrt{n}}}\right)_{n \in \mathbb{N}^*}$ et $\left(\frac{M_n - \mu}{\frac{S'_n}{\sqrt{n}}}\right)_{n \in \mathbb{N}^*}$ convergent en loi vers une variable aléatoire suivant la loi normale centrée réduite, où S_n et S'_n désignent respectivement l'écart-type empirique et l'écart-type empirique corrigé de (X_1, \dots, X_n) .

Exemple 24

Lors de la construction d'un collège accueillant 500 élèves, il est prévu la construction d'une cantine comprenant deux salles, chacune disposant de N places. On fait l'hypothèse que les élèves qui mangent à la cantine choisissent au hasard et de façon équiprobable l'une des deux salles, indépendamment les uns des autres.

On note X la variable aléatoire correspondant au nombre d'élèves choisissant la première salle.


Montrer qu'il faut et il suffit que $N \geq 279$ pour que la probabilité que chaque élève trouve une place dans la salle qu'il a choisie soit supérieure à 0,99. On donne : $\Phi(2,58) \approx 0,995$.

3 Test de conformité de la moyenne

Remarque 25 (Rappel)

Pour tout $x \in]0, 1[$, on appelle **quantile** d'ordre x de la loi $\mathcal{N}(0, 1)$ et on note u_x l'unique réel tel que $\Phi(u_x) = x$, où Φ désigne la fonction de répartition de la loi $\mathcal{N}(0, 1)$.

Si $X \hookrightarrow \mathcal{N}(0, 1)$ alors, pour tout $\alpha \in]0, 1[$, $\mathbb{P}\left(-u_{1-\frac{\alpha}{2}} \leq X \leq u_{1-\frac{\alpha}{2}}\right) = 1 - \alpha$.



Proposition-Définition 26

Soit X_1, \dots, X_n des variables indépendantes identiquement distribuées, d'espérance μ et d'écart-type σ^2 . Alors, pour tout $\alpha \in]0, 1[$, on a :

$$\lim_{n \rightarrow +\infty} \mathbb{P}\left(\mu \in \left[M_n - u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}, M_n + u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}\right]\right) = 1 - \alpha.$$

$$\lim_{n \rightarrow +\infty} \mathbb{P}\left(\mu \in \left[M_n - u_{1-\frac{\alpha}{2}} \frac{S_n}{\sqrt{n}}, M_n + u_{1-\frac{\alpha}{2}} \frac{S_n}{\sqrt{n}}\right]\right) = 1 - \alpha.$$

$$\lim_{n \rightarrow +\infty} \mathbb{P}\left(\mu \in \left[M_n - u_{1-\frac{\alpha}{2}} \frac{S'_n}{\sqrt{n}}, M_n + u_{1-\frac{\alpha}{2}} \frac{S'_n}{\sqrt{n}}\right]\right) = 1 - \alpha.$$

où $u_{1-\frac{\alpha}{2}}$ désigne le quantile d'ordre $1 - \frac{\alpha}{2}$ de la loi normale $\mathcal{N}(0, 1)$, i.e. l'unique réel u tel que $\Phi(u) = 1 - \frac{\alpha}{2}$.

On appelle **intervalles (asymptotiques) de confiance** au niveau $1 - \alpha$ les intervalles :

$$\left[M_n - u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}, M_n + u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}\right], \left[M_n - u_{1-\frac{\alpha}{2}} \frac{S_n}{\sqrt{n}}, M_n + u_{1-\frac{\alpha}{2}} \frac{S_n}{\sqrt{n}}\right] \text{ et } \left[M_n - u_{1-\frac{\alpha}{2}} \frac{S'_n}{\sqrt{n}}, M_n + u_{1-\frac{\alpha}{2}} \frac{S'_n}{\sqrt{n}}\right].$$

Démonstration.

Remarque 27

Cette propriété n'est pas à connaître, il faut la retrouver systématiquement d'après le programme.

Remarque 28

On considère que l'approximation est satisfaisante dès que $n \geq 30$.

On présente ci-dessous le contexte du test de conformité à la moyenne :

- On considère une population dans laquelle les individus possèdent un certain caractère X et dont l'espérance μ est inconnue. Une hypothèse est formulée sur la valeur de ce paramètre $\mu = \mu_0$.
- On étudie un échantillon de la population et, à partir des résultats obtenus, rejeter ou non l'hypothèse formulée.
- L'hypothèse selon laquelle on fixe a priori un paramètre de la population à une valeur particulière s'appelle l'**hypothèse nulle** et est notée $(H_0) : \mu = \mu_0$. On définit l'**hypothèse alternative** $(H_1) : \mu \neq \mu_0$.
- Un **test statistique** est une démarche qui a pour but de fournir une règle permettant, à partir des résultats obtenus sur l'échantillon, de faire un choix entre ces deux hypothèses. C'est l'hypothèse H_0 qui est soumise au test et toute la démarche du test s'effectue en supposant cette hypothèse validée.
- On peut alors établir des règles de décision qui nous permettent d'accepter ou de rejeter l'hypothèse H_0 . Toutefois, il est statistiquement impossible de prendre, à coup sûr, la bonne décision. Le risque, consenti à l'avance et que nous notons α , de rejeter l'hypothèse H_0 alors qu'elle est vraie, s'appelle le **risque de première espèce** ; ainsi :

$$P_{[H_0 \text{ est vrai}]}(\text{rejeter } H_0) = \alpha$$

On choisit en général $\alpha = 0,05$, voire $\alpha = 0,01$.

- Il existe un autre risque, à savoir celui d'accepter l'hypothèse H_0 alors qu'elle est fautive. Ce risque est appelé le **risque de seconde espèce** β . Le risque de première espèce α est fixé au départ; celui de deuxième espèce reste à calculer (quand c'est possible).

Méthode 29. Test de conformité à la moyenne

- (i) On choisit la valeur μ_0 définissant l'hypothèse nulle $(H_0) : \mu = \mu_0$
- (ii) Le réel α étant fixé, on détermine le quantile $u_{1-\frac{\alpha}{2}}$ d'ordre $1 - \frac{\alpha}{2}$.
- (iii) On effectue un nombre $n \geq 30$ de mesures, dont on calcule la moyenne M_n et l'écart-type S_n empiriques.
- (iv) On rejette l'hypothèse nulle (H_0) si (de manière équivalente) :
 - la valeur observée $\frac{M_n - \mu_0}{\frac{S_n}{\sqrt{n}}}$ n'appartient pas à l'intervalle $[-u_{1-\frac{\alpha}{2}}, u_{1-\frac{\alpha}{2}}]$,
 - ou la valeur μ_0 n'appartient pas à l'intervalle de confiance $\left[M_n - u_{1-\frac{\alpha}{2}} \frac{S_n}{\sqrt{n}}, M_n + u_{1-\frac{\alpha}{2}} \frac{S_n}{\sqrt{n}} \right]$.


Le risque de rejeter (H_0) alors que cette hypothèse est vraie est asymptotiquement égal à α .

Remarque 30

Le tableau ci-dessous rassemble ce qu'il faut retenir des risques de première et seconde espèce.

	Hypothèse H_0 vrai	Hypothèse H_1 vraie
Hypothèse H_0 accepté	bonne décision ($1 - \alpha$)	mauvaise décision (risque β)
Hypothèse H_1 accepté	mauvaise décision (risque α)	bonne décision ($1 - \beta$)

On représente ci-dessous un exemple de distribution des lois (ici normales) de la statistique de test selon que l'hypothèse H_0 ou H_1 est vraie, ainsi que le risque β et la valeur μ_{seuil} permettant, une fois le risque α fixé, de décider d'accepter ou de rejeter H_0 .

**Remarque 31**

On présente ci-dessous le tableau des valeurs usuelles de niveau de confiance et quantile correspondant.

niveau de confiance ($1 - \alpha$)	90%	95%	99%
valeur de $\Phi\left(u_{1-\frac{\alpha}{2}}\right)$	0,95	0,975	0,995
quantile $u_{1-\frac{\alpha}{2}}$	1.65	1.96	2.58

Exemple 32

Dans un centre avicole, des études antérieures ont montré que la masse d'un œuf choisi au hasard peut être considérée comme la réalisation d'une variable aléatoire normale X , de moyenne m et de variance σ^2 . On admet que les masses des œufs sont indépendantes les unes des autres. On prend un échantillon de $n = 36$ œufs que l'on pèse. Les mesures (en grammes) sont présentées ci-dessous :

50,34 52,62 53,79 54,99 55,82 57,67 51,41 53,13 53,89 55,04 55,91 57,99
 51,51 53,28 54,63 55,12 55,95 58,10 52,07 53,30 54,76 55,24 57,05 59,30
 52,22 53,32 54,78 55,28 57,18 60,58 52,38 53,39 54,93 55,56 57,31 63,15

- Déterminons un intervalle de confiance au niveau 95% puis 99% de la masse moyenne m d'un œuf.
- Testons si la moyenne de cette variable est égale à 56g.

Exemple 33

Dans une population de renards sauvages d'effectif inconnu, on capture 154 individus dont 14 sont atteints de la rage. Déterminer un intervalle de confiance à 95% de la fréquence de renards atteints de la rage dans la population totale.