

Dans tout le chapitre,  $(\Omega, \mathcal{T}, \mathbf{P})$  est un espace probabilisé.

On étudie une suite de variables aléatoires réelles  $(X_n)_{n \in \mathbf{N}}$  définies sur  $\Omega$ .

Ces variables aléatoires sont indifféremment finies, dénombrables, ou à densité.

## I Inégalités usuelles

### 1 Inégalité de Markov

PROPOSITION

Soit  $X$  une VAR positive ( $X(\Omega) \subset \mathbf{R}_+$ ), et admettant une espérance  $\mathbf{E}(X)$ . Alors :

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

### 2 Inégalité de Bienaymé-Tchebychev

PROPOSITION

Soit  $X$  une VAR admettant un moment d'ordre 2. Alors :

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

Remarque : ce résultat équivaut à :  $\mathbf{P}(|X - \mathbf{E}(X)| < \varepsilon) \geq 1 - \frac{\mathbf{V}(X)}{\varepsilon^2}$

**Exercice 1 :** Soit  $X$  suivant une loi exponentielle :  $X \hookrightarrow \mathcal{E}(\lambda)$ . Soit  $\varepsilon > 0$ .

1. on suppose ici que  $\varepsilon \leq \frac{1}{\lambda}$ . Que penser dans ce cas de l'inégalité de Bienaymé-Tchebychev ?


2. On suppose dans la suite que  $\varepsilon > \frac{1}{\lambda}$ .

a) Calculer :  $\mathbf{P}(|X - \mathbf{E}(X)| \geq \varepsilon)$ .

b) Le graphique ci-contre montre la représentation graphique des fonctions

$$f(t) = e^{-1-\lambda t} \text{ et } g(t) = \frac{1}{(\lambda t)^2}$$

pour  $\lambda = 1$ . Que penser de la précision de l'inégalité de Bienaymé-Tchebychev ?



## II Loi faible des grands nombres

### 1 Moyenne empirique

DÉFINITION

Soit  $(X_n)_{n \in \mathbf{N}^*}$  une suite de VAR. La suite des **moyennes empiriques** des  $X_n$  est la suite de VAR définie par :

$$\forall n \geq 1, M_n = \frac{1}{n} \sum_{k=1}^n X_k$$

PROPOSITION

Si  $(X_n)_{n \in \mathbf{N}^*}$  est une suite de VAR indépendantes, de même loi, admettant une espérance  $\mu$  et une variance  $\sigma^2$ , alors :  $\mathbf{E}(M_n) = \mu$  et  $\mathbf{V}(M_n) = \frac{\sigma^2}{n}$ .

### 2 Loi faible des grands nombres

THÉORÈME

Soit  $(X_n)_{n \in \mathbf{N}^*}$  une suite de VAR indépendantes, de même loi, admettant une espérance  $\mu$  et une variance  $\sigma^2$ . Alors la suite  $(M_n)_{n \geq 1}$  des moyennes empiriques vérifie :

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

Rq : on dit que la suite  $(M_n)_{n \geq 1}$  converge en probabilité vers une VAR certaine de valeur  $\mu$ .

**Exercice 2 :** Soit  $n \in \mathbf{N}^*$ . On jette  $n$  fois un dé, et on note  $A_n$  l'événement :

$A_n$  : « au cours des  $n$  lancers, on a obtenu 6 moins d'une fois sur dix ».

Utiliser l'inégalité de Bienaymé-Tchebychev pour donner une majoration de  $\mathbf{P}(A_n)$  lorsque :

\*  $n = 10$       \*  $n = 100$       \*  $n = 1000$

### III Convergence en loi

#### 1 Cas de VAR entières

DÉFINITION

Soit  $(X_n)_{n \in \mathbf{N}}$  une suite de VAR entières ( $\forall n \in \mathbf{N}, X_n(\Omega) \subset \mathbf{N}$ ), et soit  $X$  une VAR entière. Alors on dit que  $(X_n)_{n \in \mathbf{N}}$  **converge en loi** vers  $X$  si et seulement si :

$$\forall k \in \mathbf{N}, \lim_{n \rightarrow +\infty} \mathbf{P}(X_n = k) = \mathbf{P}(X = k)$$

PROPRIÉTÉ \*\* **Approximation d'une loi binomiale par une loi de Poisson** \*\*

Soit  $(X_n)_{n \in \mathbf{N}}$  une suite de VAR telle que :  $\forall n \in \mathbf{N}, X_n \hookrightarrow \mathcal{B}(n, p_n)$ .

Si  $\lim_{n \rightarrow +\infty} n \times p_n = \lambda \in \mathbf{R}$ , alors  $(X_n)_n$  converge en loi vers une VAR  $X$  telle que :  $X \hookrightarrow \mathcal{P}(\lambda)$ .

**Usage** : on admet communément que lorsque  $n \geq 30$  et  $p \leq 0,1$ , on peut approximer la loi binomiale  $\mathcal{B}(n, p)$  par la loi de Poisson  $\mathcal{P}(np)$ .

**Exercice 3** : Soit  $X \hookrightarrow \mathcal{B}\left(1000, \frac{1}{40}\right)$ . Donner une estimation de :  $\mathbf{P}(X = 25)$ .

#### 2 Cas général

DÉFINITION

Soit  $(X_n)_{n \in \mathbf{N}}$  une suite de VAR, et soit  $X$  une VAR.

On note  $F_{X_n}$  et  $F_X$  respectivement les fonctions de répartition de  $X_n$  et de  $X$ .

Soit  $\mathcal{D}$  l'ensemble des points de discontinuité de  $F_X$ .

Alors on dit que  $(X_n)_{n \in \mathbf{N}}$  **converge en loi** vers  $X$  si et seulement si :

$$\forall x \in \mathbf{R} \setminus \mathcal{D}, \lim_{n \rightarrow +\infty} F_{X_n}(x) = F_X(x)$$

*Rappel* :  $\overline{\mathbf{R}}$  désigne  $\mathbf{R} \cup \{-\infty, +\infty\}$ .

PROPOSITION

Si  $(X_n)_{n \in \mathbf{N}}$  converge en loi vers  $X$ , alors :

$$\forall a, b \in \overline{\mathbf{R}} \setminus \mathcal{D} \text{ (avec } a < b), \lim_{n \rightarrow +\infty} \mathbf{P}(a < X_n \leq b) = \mathbf{P}(a < X \leq b)$$

#### 3 Théorème central-limite première forme

*Rappels* : • Soit  $X$  une VAR admettant une variance non nulle. Alors on note  $X^*$  la VAR centrée réduite

$$\text{associée à } X : X^* = \frac{X - \mathbf{E}(X)}{\sqrt{\mathbf{V}(X)}}.$$

•  $\Phi$  désigne la fonction de répartition de la loi normale centrée réduite  $\mathcal{N}(0, 1)$  :

$$\forall x \in \mathbf{R}, \Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt$$

THÉORÈME

\*\* **TCL<sub>1</sub>** \*\*

Soit  $(X_n)_{n \in \mathbf{N}^*}$  une suite de VAR indépendantes, de même loi, admettant une espérance  $\mu$  et une variance  $\sigma^2 \neq 0$ . Alors la suite  $(M_n^*)_{n \geq 1}$  converge en loi vers une VAR suivant la loi normale centrée réduite  $\mathcal{N}(0, 1)$  :

$$\forall a, b \in \overline{\mathbf{R}} \text{ (avec } a < b), \lim_{n \rightarrow +\infty} \mathbf{P}(a < M_n^* \leq b) = \Phi(b) - \Phi(a) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{t^2}{2}} dt$$

*Remarque* : Soit  $S_n = \sum_{k=1}^n X_k = n \times M_n$ . Alors  $S_n^* = M_n^*$  donc  $(S_n^*)_n$  converge aussi en loi vers  $\mathcal{N}(0, 1)$ .

PROPRIÉTÉ

\*\* **Approximation d'une loi binomiale par une loi normale** \*\*

Soit  $p \in ]0, 1[$  fixé, et soit  $(X_n)_{n \in \mathbf{N}^*}$  une suite de VAR telle que :  $\forall n \in \mathbf{N}^*, X_n \hookrightarrow \mathcal{B}(n, p)$ .

Alors  $(X_n^*)_{n \geq 1}$  converge en loi vers  $\mathcal{N}(0, 1)$  :

$$\forall a, b \in \overline{\mathbf{R}} \text{ (avec } a < b), \lim_{n \rightarrow +\infty} \mathbf{P}\left(a < \frac{X_n - np}{\sqrt{np(1-p)}} \leq b\right) = \Phi(b) - \Phi(a) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{t^2}{2}} dt$$

**Usage** : on admet communément que lorsque  $n \geq 30$ ,  $np \geq 5$  et  $n(1-p) \geq 5$ , on peut approximer la loi  $\mathcal{B}(n, p)$  par la loi normale  $\mathcal{N}(np, npq)$ .

### Estimation de $P(X_n = k)$ par correction de continuité

Pour  $k \in \llbracket 0, n \rrbracket$ , on veut une approximation de :  $P(X_n = k) = P\left(X_n^* = \frac{k - np}{\sqrt{npq}}\right)$ .

Prendre  $a = b = \frac{k - np}{\sqrt{npq}}$  donnerait 0... On effectue alors une **correction de continuité** :

$$P(X_n = k) = P\left(k - \frac{1}{2} < X_n \leq k + \frac{1}{2}\right) \approx \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{t^2}{2}} dt \quad \text{avec} \quad \begin{cases} a = \frac{k - \frac{1}{2} - np}{\sqrt{npq}} \\ b = \frac{k + \frac{1}{2} - np}{\sqrt{npq}} \end{cases}$$

**Exercice 4** : Soit  $X \hookrightarrow \mathcal{B}\left(1000, \frac{1}{40}\right)$ .

- 1) Estimer la probabilité de l'événement :  $[20 < X \leq 30]$ .
- 2) Estimer la probabilité de l'événement :  $[X = 25]$ . Comparer avec le résultat de l'exercice 3.

## IV Tests statistiques

### 1 Écart-type empirique

DÉFINITION

Soit  $(X_n)_{n \in \mathbf{N}^*}$  une suite de VAR. On définit pour tout  $n \geq 1$  la **variance empirique** de  $X_1, \dots, X_n$  par :

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

L'écart-type empirique de  $X_1, \dots, X_n$  est :  $S_n = \sqrt{S_n^2}$ .

### 2 Théorème central-limite seconde forme

THÉORÈME \*\* TCL<sub>2</sub> \*\*

Soit  $(X_n)_{n \in \mathbf{N}^*}$  une suite de VAR indépendantes, de même loi, d'espérance  $\mu$  et de variance  $\sigma^2 \neq 0$ . Alors la suite  $\left(\frac{M_n - \mu}{\frac{S_n}{\sqrt{n}}}\right)_{n \geq 1}$  converge en loi vers la loi normale centrée réduite.

**Usage** : on se sert de cette deuxième forme lorsqu'on ne connaît pas l'écart-type commun des VAR  $X_n$ .

### 3 Test de conformité à la moyenne

*Situation* : on peut expérimentalement effectuer  $n$  mesures d'un phénomène, et on souhaite tester statistiquement l'hypothèse : «  $H_0$  : la valeur moyenne du phénomène vaut  $\mu_0$  ».

La valeur de  $\mu_0$  peut être obtenue par calcul selon une modélisation mathématique, ou bien être issue d'une bibliographie... On l'appelle ici *moyenne théorique*.

On pose  $H_1$  l'hypothèse alternative : «  $H_1$  : la valeur moyenne du phénomène est différente de  $\mu_0$  ».

On souhaite prendre la décision : accepte-t-on  $H_0$ , ou bien doit-on la rejeter ?

On peut se tromper dans deux cas :

\* on rejette  $H_0$ , alors qu'elle est vraie. C'est le risque de *première espèce*.

\* on accepte  $H_0$ , alors qu'elle est fautive. C'est le risque de *seconde espèce*.

Même en multipliant les expériences, on ne pourra jamais être certain d'avoir pris la bonne décision.

On fixe le *risque d'erreur de première espèce*, noté  $\alpha$ , égal à :  $\alpha = P_{[H_0 \text{ est vraie}]}(\text{on rejette } H_0)$ .

On choisit la plupart du temps  $\alpha = 0,05$  ou  $0,01$  (risque d'erreur à 5% ou à 1%).

Le risque d'erreur de seconde espèce n'est pas étudié ici.

DÉFINITION

Soit  $X$  une VAR admettant une moyenne  $\mu_0$  et un écart-type  $\sigma_0 \neq 0$ . Soient  $n \in \mathbf{N}^*$  et  $\alpha \in ]0, 1[$ .

\* On appelle  $(X_1, \dots, X_n)$  un  **$n$ -échantillon** de  $X$  tout vecteur de VAR indépendantes et suivant la même loi que  $X$ . Sa moyenne empirique est notée  $M_n$ .

\* On appelle **marge d'erreur** au seuil  $1 - \alpha$  le réel :  $\varepsilon = \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \times \frac{S_n}{\sqrt{n}}$   
où  $S_n$  est l'écart-type empirique issu d'un  $n$ -échantillon de  $X$ .

\* On appelle **intervalle de confiance** au seuil  $1 - \alpha$  l'intervalle réel :  $C_n = [M_n - \varepsilon, M_n + \varepsilon]$ .

PROPOSITION

$$\lim_{n \rightarrow +\infty} P(\mu_0 \in C_n) = 1 - \alpha$$

### Conduite du test :

1. on fixe arbitrairement  $\alpha \in ]0, 1[$ .
2. on détermine  $u_\alpha = \Phi^{-1}\left(1 - \frac{\alpha}{2}\right)$  grâce à une table de la loi normale.
3. On effectue  $n$  simulations de  $X$  et on calcule moyenne et écart-type empiriques  $M_n$  et  $S_n$ .
4. On explicite l'intervalle de confiance  $C_n = \left[ M_n - u_\alpha \times \frac{S_n}{\sqrt{n}}, M_n + u_\alpha \times \frac{S_n}{\sqrt{n}} \right]$ .
5. On décide de rejeter  $H_0$  si  $\mu_0 \notin C_n$ . Sinon, on conclut que le test ne permet pas de rejeter  $H_0$  au seuil d'erreur  $\alpha$ .

On a alors asymptotiquement (si  $n$  est grand) un risque d'erreur  $\alpha$ .

En pratique, on admet la validité du test lorsque  $n \geq 30$ .

**Exercice 5 :** Une usine agro-alimentaire conditionne des barquettes de framboises de 250 grammes. En pratique, les barquettes ne font bien sûr pas toutes exactement 250 g : cette valeur doit être comprise comme une masse moyenne. Un contrôle est effectué pour savoir si l'usine respecte cette moyenne de 250 g. On prélève au hasard  $n = 100$  barquettes issues de cette usine, et on calcule la masse moyenne  $M_n$  et l'écart-type  $S_n$  de cet échantillon. On trouve :  $M_n = 247$  g et  $S_n = 5$  g.

Au risque d'erreur de 5%, peut-on considérer que l'usine respecte la moyenne de 250 g ?

## 4 Test de conformité sur une proportion

*Situation :* on connaît la moyenne théorique  $\mu$  d'un phénomène, et on souhaite tester si des valeurs peuvent être issues de ce phénomène, en comparant la moyenne empirique  $M_n$  à la moyenne théorique  $\mu$ .

### DÉFINITION

Soit un phénomène apparaissant avec une fréquence  $\mu$  dans une population.

Soit  $\alpha \in ]0, 1[$ . On appelle **intervalle de fluctuation** au seuil  $1 - \alpha$  l'intervalle réel :

$$F_n = \left[ \mu - \frac{a}{\sqrt{n}}, \mu + \frac{a}{\sqrt{n}} \right]$$

où  $a = \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \times \sqrt{\mu(1 - \mu)}$ .

DÉFINITION SIMPLIFIÉE : pour  $\alpha = 0,05$  et en majorant  $\mu(1 - \mu)$  par  $\frac{1}{4}$ , on obtient :  $F_n \approx \left[ \mu - \frac{1}{\sqrt{n}}, \mu + \frac{1}{\sqrt{n}} \right]$ .

### PROPOSITION

On choisit au hasard et indépendamment  $n \geq 1$  éléments de cette population, et on note  $M_n$  la moyenne empirique obtenue. Alors :  $\lim_{n \rightarrow +\infty} \mathbf{P}(M_n \in F_n) = 1 - \alpha$ .

### Conduite du test au risque d'erreur de 5% :

1. on pose  $\alpha = 0,05$  (si autre choix, adapter les valeurs suivantes).
2. On explicite l'intervalle de fluctuation simplifié  $F_n = \left[ \mu - \frac{1}{\sqrt{n}}, \mu + \frac{1}{\sqrt{n}} \right]$ .
3. On calcule  $M_n$ .
4. On décide que les valeurs ne sont pas issues du phénomène étudié (elles ne sont pas représentatives de ce phénomène) si  $M_n \notin F_n$ . Sinon, on conclut que le test ne permet pas d'exclure que ces valeurs soient issues du phénomène.

Comme précédemment, on convient que  $n \geq 30$  est suffisant pour assurer la validité du test.

**Exercice 6 :** En 2024, on compte 51,5% de femmes en France. Une étude montre que parmi les 80 postes de direction (président ou directeur général) des entreprises du CAC40, on compte 5 femmes.

Peut-on affirmer au risque d'erreur de 5%, que les femmes sont bien représentées dans les directions des plus grandes entreprises françaises ?