

Théorèmes de convergence en probabilité Statistiques inférentielles

1.4.1 Estimation

Définition 1.4.1

Soit X une variable aléatoire admettant une espérance μ et une variance σ^2 .

Pour tout entier $n \in \mathbb{N}^*$, on appelle n -échantillon de X tout n -uplet (X_1, \dots, X_n) de variables aléatoires indépendantes et de même loi* que X .

On appelle alors *estimateur* d'un paramètre θ de X toute suite de variable aléatoire (T_n) , chaque T_n étant une fonction de (X_1, \dots, X_n) .

Le but d'un estimateur est de pouvoir, à partir d'une suite d'observations empiriques d'un phénomène aléatoire, calculer une approximation du paramètre recherché.

EXEMPLE : Soit X une variable aléatoire admettant une espérance μ et une variance σ^2 .

Les deux estimateurs suivants sont à connaître :

- la *moyenne empirique*, notée M_n ou \bar{X}_n , définie par

$$M_n = \frac{1}{n} \sum_{i=1}^n X_i$$

est un estimateur de l'espérance μ de X .

- la *variance empirique*, notée S_n^2 , définie par

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

est un estimateur de la variance σ^2 de X .

*. On parlera souvent de suite de variables *i.i.d.*, pour « indépendantes et identiquement distribuées ».

14.2 Convergence en loi

Les suites de variables aléatoires peuvent converger sous différents sens. On étudie ici le cas de la convergence *en loi*.

Définition 14.2

Soit $(X_n)_{n \in \mathbb{N}}$ une suite de variables aléatoires, et soit X une variable aléatoire.

Pour tout n , on note F_n la fonction de répartition de X_n , et on note F la fonction de répartition de X .

On dit alors que la suite $(X_n)_{n \in \mathbb{N}}$ converge en loi vers X si pour tout réel t où F est continue, la suite $(F_n(t))_{n \in \mathbb{N}}$ converge vers $F(t)$.

On note alors $X_n \xrightarrow{\mathcal{L}} X$.

EXEMPLE : Soient $U_n \hookrightarrow \mathcal{U}([0, 1])$ mutuellement indépendantes. On pose

$$X_n = n(1 - \max(U_1, \dots, U_n)).$$

On commence par chercher la fonction de répartition de X_n : soit $x \in \mathbb{R}$.

$$\begin{aligned} P(X_n \leq x) &= P\left(\max(U_1, \dots, U_n) \geq 1 - \frac{x}{n}\right) \\ &= 1 - P\left(\max(U_1, \dots, U_n) < 1 - \frac{x}{n}\right) \\ &= 1 - \prod_{i=1}^n P\left(U_i < 1 - \frac{x}{n}\right) \\ &= 1 - \left(1 - \frac{x}{n}\right)^n \end{aligned}$$

Or on sait que $\left(1 - \frac{x}{n}\right)^n \xrightarrow[n \rightarrow \infty]{} e^{-x}$, et donc, pour tous n et x

$$F_{X_n}(x) \xrightarrow[n \rightarrow \infty]{} 1 - e^{-x}.$$

On reconnaît alors la fonction de répartition d'une loi exponentielle de paramètre 1.

On peut donc dire, en posant $X \hookrightarrow \mathcal{E}(1)$, que

$$X_n \xrightarrow{\mathcal{L}} X.$$

Proposition 14.3

Soient (X_n) et X des variables aléatoires à valeurs dans \mathbb{Z} . Alors

$$X_n \xrightarrow{\mathcal{L}} X \iff \forall k \in \mathbb{Z}, \lim_{n \rightarrow \infty} P(X_n = k) = P(X = k).$$

Démonstration. La variable X étant à valeurs dans \mathbb{Z} , on note que la fonction F_X est nécessairement continue en tous les points $k \pm \frac{1}{2}$, $k \in \mathbb{Z}$.

(\Rightarrow) Supposons que $X_n \xrightarrow{\mathcal{L}} X$. Soit $k \in \mathbb{Z}$. On a alors

$$P(X_n = k) = F_{X_n} \left(k + \frac{1}{2} \right) - F_{X_n} \left(k - \frac{1}{2} \right).$$

Or $F_{X_n} \left(k + \frac{1}{2} \right) \xrightarrow{n \rightarrow \infty} F \left(k + \frac{1}{2} \right)$ et $F_{X_n} \left(k - \frac{1}{2} \right) \xrightarrow{n \rightarrow \infty} F \left(k - \frac{1}{2} \right)$, et donc

$$P(X_n = k) \xrightarrow{n \rightarrow \infty} P(X = k).$$

(\Leftarrow) Supposons maintenant que pour tout $k \in \mathbb{Z}$, $P(X_n = k) \xrightarrow{n \rightarrow \infty} P(X = k)$. Soit $x \in \mathbb{R}$, et soit $\varepsilon > 0$.

Notons que pour tous $a, b \in \mathbb{R}$ avec $|a - b| > 1$, on a

$$F_{X_n}(a) - F_{X_n}(b) = \sum_{k=\lfloor a \rfloor}^{\lfloor b \rfloor} P(X_n = k) \xrightarrow{n \rightarrow \infty} \sum_{k=\lfloor a \rfloor}^{\lfloor b \rfloor} P(X = k) = F_X(a) - F_X(b).$$

Choisissons deux réels A et B de la façon suivante : comme $F_X(t) \xrightarrow{t \rightarrow -\infty} 0$, on peut trouver $A < x$ tel que $F_X(A) < \varepsilon$. De même, on choisit $B > x$ tel que $F_X(B) > 1 - \varepsilon$.

D'après la remarque précédente, on a donc un $n_0 \in \mathbb{N}$ tel que pour $n \geq n_0$,

$$F_{X_n}(x) - F_{X_n}(A) \geq F_X(x) - F_X(A) - \varepsilon.$$

En particulier

$$\begin{aligned} F_{X_n}(x) - F_X(x) &= F_{X_n}(x) - F_{X_n}(A) + F_{X_n}(A) - F_X(x) \\ &\geq F_X(x) - F_X(A) - \varepsilon + F_{X_n}(A) - F_X(x) \\ &\geq -2\varepsilon \end{aligned}$$

De la même façon, il existe $n_1 \in \mathbb{N}$ tel que pour $n \geq n_1$,

$$F_{X_n}(x) - F_{X_n}(B) \leq F_X(x) - F_X(B) + \varepsilon.$$

On en déduit

$$F_{X_n}(x) - F_X(x) \leq F_{X_n}(B) - F_X(B) + \varepsilon \leq 2\varepsilon.$$

In fine, en prenant $n \geq \max(n_0, n_1)$, on obtient bien

$$-2\varepsilon \leq F_{X_n}(x) - F_X(x) \leq 2\varepsilon,$$

et donc le résultat cherché.

□

Proposition 14.4 – Approximation de loi binomiale par la loi de Poisson

Soit (X_n) une suite de variables aléatoires de lois respectives $\mathcal{B}(n, p_n)$, avec $np_n \rightarrow \lambda > 0$.

Alors $X_n \xrightarrow{\mathcal{L}} X$ où $X \hookrightarrow \mathcal{P}(\lambda)$.

Démonstration. Les lois binomiales et de Poisson sont à valeurs entières, et on applique donc le résultat précédent.

On a donc

$$P(X_n = k) = \binom{n}{k} \left(\frac{p_n}{1 - p_n} \right)^k (1 - p_n)^n.$$

On note que la condition $np_n \rightarrow \lambda$ est équivalente à dire que $p_n \sim \frac{\lambda}{n}$, et donc

$$\left(\frac{p_n}{1 - p_n} \right)^k \sim p_n^k \sim \frac{\lambda^k}{n^k}.$$

De plus, on a

$$(1 - p_n)^n = e^{n \ln(1 - p_n)},$$

avec $n \ln(1 - p_n) \sim -np_n \sim -\lambda$. Donc $(1 - p_n)^n \rightarrow e^{-\lambda}$. On peut aussi montrer facilement que $\binom{n}{k} \sim \frac{n^k}{k!}$.

On a donc

$$P(X_n = k) \sim \frac{n^k \lambda^k}{k! n^k} e^{-\lambda} = \frac{\lambda^k}{k!} e^{-\lambda},$$

et on reconnaît la loi d'une variable de Poisson de paramètre λ . □

Dans la pratique, pour n assez grand et certaines conditions, on utilise le résultat d'approximation suivant :

Corollaire 14.5

Si $p \leq 0,1$, $n \geq 30$ et $np \leq 15$, on peut approximer la loi binomiale $\mathcal{B}(n, p)$ par la loi de Poisson $\mathcal{P}(np)$.

14.3 Théorèmes limites

Commençons par rappeler que si X est une variable aléatoire admettant une espérance μ et une variance $\sigma^2 \neq 0$, alors on note X^* la variable aléatoire $\frac{X - \mu}{\sigma}$. Cette variable aléatoire est alors centrée réduite.

On notera toujours $M_n = \frac{1}{n} \sum_{i=1}^n X_i$ la moyenne empirique, où les variables X_i sont indépendantes et de même loi que X .

On a alors

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

La variable centrée réduite associée à M_n est donc M_n^* définie par :

$$M_n^* = \frac{M_n - \mu}{\frac{\sigma}{\sqrt{n}}}.$$

On rappelle alors l'inégalité de Bienaymé-Tchebychev :

Théorème 14.6 – Inégalité de Bienaymé-Tchebychev

Soit X une variable aléatoire admettant une variance. Alors

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

EXEMPLE : On souhaite estimer la valeur de π à 0,1 près, avec un risque d'erreur inférieur à 1%. Pour cela, on tire au hasard deux valeurs x et y uniformément dans $[0, 1]$. On note que la probabilité que le point de coordonnées (x, y) soit dans le quart de cercle de centre 0 et de rayon 1 est $\frac{\pi}{4}$.

On itère l'expérience : on note X_n la variable aléatoire qui vaut 1 si le n -ième point tiré est dans le cercle, 0 sinon.

On cherche donc n tel que

$$P\left(\left|\overline{X}_n - \frac{\pi}{4}\right| \geq 0,1\right) < 0,01.$$

En notant que pour tout $x \in [0, 1]$, $x(1-x) \leq \frac{1}{4}$, l'inégalité de Bienaymé-Tchebychev nous donne

$$P\left(\left|\overline{X}_n - \frac{\pi}{4}\right| \geq 0,1\right) \leq \frac{1}{4n \times 0,1^2} = \frac{25}{n}.$$

Il suffit donc de prendre $n \geq 2500$.

On se fixe alors dans la suite une variable aléatoire X admettant une espérance μ et une variance $\sigma^2 \neq 0$.

On en déduit alors directement la loi faible des grands nombres :

Théorème 14.7 – Loi faible des grands nombres

Soit (X_n) une suite de variables aléatoires indépendantes de même loi que X . Alors

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

On peut alors raffiner le théorème précédent pour obtenir le célèbre théorème central limite.

Théorème 14.8 – central limite

Soit (X_n) une suite de variables aléatoires indépendantes toutes de même loi que X .

Alors la suite (M_n^*) converge en loi vers une loi normale centrée réduite.

On a donc pour tous réels $a < b$,

$$\mathbb{P}(a < M_n^* < b) \xrightarrow{n \rightarrow \infty} \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{t^2}{2}} dt.$$

Ce théorème nous dit que, en un certain sens, on peut approximer la quantité M_n par une loi normale de paramètres μ et $\frac{\sigma^2}{n}$.

Un inconvénient de ce théorème est qu'il est nécessaire de connaître l'écart-type du phénomène observé. Dans le cas contraire, on peut le remplacer par l'écart-type empirique.

Avec les mêmes hypothèses, posons

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

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

On a alors

Théorème 14.9 – central limite

Dans le contexte précédent, la suite $\left(\frac{M_n - \mu}{\frac{S_n}{\sqrt{n}}}\right)$ converge en loi vers une loi normale centrée réduite.

On a donc

$$\mathbb{P}\left(a < \frac{M_n - \mu}{\frac{S_n}{\sqrt{n}}} < b\right) \xrightarrow{n \rightarrow \infty} \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{t^2}{2}} dt.$$

Dans le cas particulier de la loi binomiale, on obtient le théorème suivant :

Théorème 14.10 – Moivre-Laplace

Soit $p \in]0, 1[$, et soit (X_n) une suite de variables indépendantes telles que $X_n \hookrightarrow \mathcal{B}(n, p)$.

Alors pour tous réels $a < b$,

$$\mathbb{P}\left(a < \frac{X_n - np}{\sqrt{np(1-p)}} < b\right) \xrightarrow{n \rightarrow \infty} \Phi(b) - \Phi(a).$$

Démonstration. On peut écrire X_n comme la somme de n variables de Bernoulli identiques et indépendantes, de paramètre p : $X_n = \sum_{k=1}^n B_k$.

En notant $\overline{B}_n = \frac{1}{n} \sum_{k=1}^n B_k$, on a donc $\overline{B}_n^* = \frac{\overline{B}_n - p}{\sqrt{\frac{p(1-p)}{n}}} = \frac{X_n - np}{\sqrt{np(1-p)}}$.

Le théorème central limite appliqué à la suite (B_n) permet d'affirmer que la suite (\overline{B}_n^*) converge en loi vers une loi normale centrée réduite. \square

En pratique, on approche la loi binomiale $\mathcal{B}(n, p)$ par une loi normale $\mathcal{N}(np, \sqrt{npq^2})$ si $n \geq 30$, $np \geq 5$ et $n(1-p) \geq 5$.

14.4 Test de conformité de la moyenne

En statistique, un *test d'hypothèse* est une méthode qui nous permettra de choisir s'il est raisonnable d'accepter une hypothèse H_0 .

L'hypothèse H_0 , appelée *hypothèse nulle* est alors faite ; tous les résultats qui suivent supposent donc que cette hypothèse est vraie. L'hypothèse contraire à H_0 est appelée *hypothèse alternative*, notée H_1 .

Le test sera alors une méthode qui nous permettra d'accepter ou de rejeter H_0 , en fonction d'observations empiriques. Il est cependant statistiquement impossible d'être sûr d'avoir eu raison dans notre conclusion. On distingue alors deux types d'erreurs :

- le risque de première espèce, qui est le risque de rejeter l'hypothèse H_0 sachant qu'elle est vraie ; ce risque est choisi à l'avance, souvent 5% ou 1%
- le risque de seconde espèce, qui est le risque d'accepter l'hypothèse sachant qu'elle est fautive ; il est plus difficile à calculer, et son étude dépasse le cadre de ce cours.

On peut alors utiliser le test suivant pour la valeur de la moyenne :

Proposition 14.11

Soit X une variable aléatoire admettant une espérance μ et une variance $\sigma^2 \neq 0$. Soit $\mu_0 \in \mathbb{R}$.

On suppose $H_0 : \mu = \mu_0$, et on définit l'hypothèse alternative $H_1 : \mu \neq \mu_0$.

Alors

$$\mathbb{P} \left(\left| \frac{M_n - \mu_0}{\frac{S_n}{\sqrt{n}}} \right| > u_{1-\frac{\alpha}{2}} \right) \xrightarrow{n \rightarrow \infty} \alpha,$$

où $u_{1-\frac{\alpha}{2}}$ est l'unique réel tel que $\Phi \left(u_{1-\frac{\alpha}{2}} \right) = 1 - \frac{\alpha}{2}$.

En pratique, pour faire un test d'hypothèse de conformité de la moyenne :

- on calcule la moyenne empirique et l'écart type empirique de nos mesures
- on rejette l'hypothèse si la valeur observée de $\frac{M_n - \mu_0}{\frac{S_n}{\sqrt{n}}}$ n'est pas dans l'intervalle $\left[-u_{1-\frac{\alpha}{2}}, u_{1-\frac{\alpha}{2}}\right]$

EXEMPLE : Un médicament doit contenir $\mu_0 = 2,5$ g de substance active.

En prenant 100 comprimés au hasard, on trouve une moyenne de $M_n = 2,6$ g de substance active, avec une variance $S_n^2 = 0.16$.

On utilise un test de conformité à la moyenne, avec un risque de 5%.

On choisit alors $u_{1-\frac{\alpha}{2}} = 1.96$, et on a alors

$$\frac{M_n - \mu_0}{\frac{S_n}{\sqrt{n}}} = 2.5 \notin [-1.96, 1.96].$$

On peut donc rejeter notre hypothèse.

14.5 Exercices

Exercice 1

Soit (X_n) une suite de variables aléatoires identiques et indépendantes, admettant une espérance μ et une variance σ^2 .

1. Montrer que $\mathbb{E}(S_n^2) \neq \sigma^2$.
2. On appelle alors *estimateur corrigé de la variance* la suite

$$S_n'^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - M_n)^2.$$

Montrer que $\mathbb{E}(S_n'^2) = \sigma^2$.

Exercice 2

Soit f la fonction définie sur \mathbb{R} par $f(x) = e^{-x-e^{-x}}$.

1. Vérifier que f est une fonction de densité.

On dit qu'une variable admettant f pour densité suit la loi de Gumbel.

2. Soit (X_n) une suite de variables aléatoires indépendantes, suivant toutes la loi exponentielle de paramètre 1.
On pose pour tout $n : M_n = \max(X_1, \dots, X_n)$.
Calculer la fonction de répartition F_n de M_n .
3. Montrer que la suite $(M_n - \ln(n))$ converge en loi vers une loi de Gumbel.

Réponse de l'exercice

Exercice 3

Soit $\lambda > 0$. Pour tout entier $n \geq \lambda$, on définit une suite $(X_{n,i})_{i \in \mathbb{N}^*}$ de variables aléatoires indépendantes suivant toutes une loi de Bernoulli de paramètre $p_n = \frac{\lambda}{n}$.

On définit alors pour tout n :

$$N_n = \frac{1}{n} \min\{i \in \mathbb{N}^* \mid X_{n,i} = 1\}.$$

1. Déterminer la loi de la variable nN_n , et en déduire la fonction de répartition de N_n .
2. Montrer que la suite (N_n) converge en loi vers une variable exponentielle de paramètre λ .

Réponse de l'exercice

1. Il est clair que nN_n suit une loi géométrique de paramètre $\frac{\lambda}{n}$.

On a donc pour tout $t \geq 0$:

$$\begin{aligned}\mathbb{P}(N_n \leq t) &= \mathbb{P}(nN_n \leq tn) \\ &= 1 - \left(1 - \frac{\lambda}{n}\right)^{[nt]}\end{aligned}$$

2. On a pour tous t et n

$$[nt] \ln \left(1 - \frac{\lambda}{n}\right) \sim -\frac{\lambda}{n} [nt],$$

et par définition de la partie entière,

$$-\lambda \frac{nt-1}{n} > -\frac{\lambda}{n} [nt] \geq -\lambda t.$$

Par théorème d'encadrement des limites, on a donc $[nt] \ln \left(1 - \frac{\lambda}{n}\right) \rightarrow -\lambda t$, puis

$$\mathbb{P}(N_n \leq t) \rightarrow 1 - e^{-\lambda t}.$$

On reconnaît alors bien la fonction de répartition d'une loi exponentielle.

Exercice 4

Une compagnie aérienne, disposant de 300 places dans un avion, souhaite optimiser au mieux son remplissage. On estime qu'une personne ayant réservé oublie de se présenter à l'aéroport avec une probabilité de 10%. Les choix des passagers de venir ou non sont supposés indépendants.

Pour un entier n représentant le nombre de réservations faites, on note S_n le nombre de personnes qui se présentent à l'aéroport.

- Calculer $\mathbb{E}(S_n)$ et $\mathbb{V}(S_n)$.
- Déterminer le nombre maximal de réservations que peut proposer la compagnie pour que le risque de ne pas pouvoir embarquer tout le monde soit inférieur à 5%.

Réponse de l'exercice

1. La variable S_n suit une loi binomiale $\mathcal{B}(n, 0.9)$. On a donc $\mathbb{E}(S_n) = 0.9n$ et $\mathbb{V}(S_n) = 0.09n$.

2. On note que $S_n \leq 300$ si et seulement si $\frac{\frac{1}{n}S_n - 0.9}{\frac{\sqrt{0.09}}{\sqrt{n}}} \leq \frac{\frac{1}{n}300 - 0.9}{\frac{\sqrt{0.09}}{\sqrt{n}}}$.

Le théorème central limite nous affirme, les variables admettant une variance non nulle, que

$$\mathbb{P}\left(\frac{\frac{1}{n}S_n - 0.9}{\frac{\sqrt{0.09}}{\sqrt{n}}} \leq \frac{\frac{1}{n}300 - 0.9}{\frac{\sqrt{0.09}}{\sqrt{n}}}\right) \approx \Phi\left(\frac{\frac{1}{n}300 - 0.9}{\frac{\sqrt{0.09}}{\sqrt{n}}}\right).$$

On cherche donc n tel que $\Phi\left(\frac{\frac{1}{n}300-0.9}{\frac{\sqrt{0.09}}{\sqrt{n}}}\right) \geq 0.95 \approx \Phi(1,65)$.

Par croissance de Φ , on a alors

$$\begin{aligned} \Phi\left(\frac{\frac{1}{n}300-0.9}{\frac{\sqrt{0.09}}{\sqrt{n}}}\right) &\geq 0.95 \approx \Phi(1,65) \\ \Leftrightarrow \frac{\frac{1}{n}300-0.9}{\frac{\sqrt{0.09}}{\sqrt{n}}} &\geq 1.65 \\ \Leftrightarrow n &\leq 323 \end{aligned}$$

Exercice 5

Montrer que

$$\lim_{n \rightarrow \infty} e^{-n} \sum_{k=0}^n \frac{n^k}{k!} = \frac{1}{2}.$$

On pourra utiliser des variables aléatoires X_i indépendantes, suivant toutes une loi de Poisson $\rightsquigarrow (1)$.

Réponse de l'exercice

Par stabilité des lois de Poisson par somme, on a donc $S_n \xrightarrow{d} \rightsquigarrow (n)$. Le théorème central limite nous affirme alors

$$\mathbb{P}\left(\frac{\frac{1}{n}S_n - 1}{\frac{1}{\sqrt{n}}} \leq 0\right) \rightarrow \Phi(0) = \frac{1}{2}.$$

D'autre part, on a

$$\mathbb{P}\left(\frac{\frac{1}{n}S_n - 1}{\frac{1}{\sqrt{n}}} \leq 0\right) = \mathbb{P}(S_n \leq n) = \sum_{k=0}^n \mathbb{P}(S_n = k) = e^{-n} \sum_{k=0}^n \frac{n^k}{k!}.$$

Exercice 6

On pourra utiliser pour les programmes Python la fonction `linalg.matrix_rank()` du module `numpy`, qui permet de déterminer le rang d'une matrice, comme le montre l'exemple suivant :

```
1 import numpy as np
2 A = np.array([ [1, 2, 1], [2, 3, 2], [3, 5, 3] ])
3 print(np.linalg.matrix_rank(A))
4
```

La dernière ligne affiche le rang de la matrice $\begin{pmatrix} 1 & 2 & 1 \\ 2 & 3 & 2 \\ 3 & 5 & 3 \end{pmatrix}$, c'est-à-dire 2.

On pourra aussi utiliser la fonction `randint()` du module `random`. Pour a et b deux entiers `randint(a, b)` retourne un entier équiprobablement entre a et b (a et b étant inclus).

On considère la matrice :

$$A = \begin{pmatrix} 3 & 1 & 1 \\ 1 & 0 & 1 \\ -3 & 0 & -1 \end{pmatrix}.$$

1. a) Écrire une fonction Python prenant en arguments deux vecteurs de taille 3 et renvoyant un booléen (True ou False) indiquant s'ils sont colinéaires. (On pourra représenter les vecteurs par des listes).
- b) Écrire une fonction Python vecteurs_propres(u) prenant en argument un vecteur de taille 3 et renvoyant un booléen (True ou False) indiquant s'il est un vecteur propre de A.
2. a) Vérifier que $-1, 1, 2$ sont valeurs propres de A et préciser pour chacune un vecteur propre associé.
- b) La matrice A est-elle diagonalisable ?
3. Soient X_1, \dots, X_n , n variables aléatoires indépendantes suivant la loi de Bernoulli de paramètre $p \in]0; 1[$. On note : $M_n = \frac{1}{n} \sum_{k=1}^n X_k$ et $M_n^* = \frac{M_n - p}{\sqrt{\frac{p(1-p)}{n}}}$.
 - a) Donner, pour $\alpha \in \mathbb{R}_+$, l'approximation de la probabilité $P([-\alpha < M_n^* < \alpha])$ donnée par le théorème central limite.
 - b) En déduire que $\mathbb{P}\left(p \in \left[M_n - \frac{1}{\sqrt{n}}, M_n + \frac{1}{\sqrt{n}}\right]\right) \geq 0.95$.
On pourra admettre que, $\forall x \in [0; 1]$, $x(1-x) \leq \frac{1}{4}$ et si Φ désigne la fonction de répartition d'une variable suivant une loi normale centrée réduite, alors $\Phi(1; 96) \approx 0,975$.
4. On note N_V le nombre de vecteurs propres de A dont les coefficients sont des entiers de $\llbracket -5, 5 \rrbracket$.
 - a) Expliquer comment le programme suivant permet d'estimer la valeur de N_V :

```

1 def simul () :
2     u = [ randint ( -5 ,5) for k in range (3) ]
3     return vecteurs_propres (u)
4 n = 10000          # Valeur de n a definir.
5 nb = 0
6 for k in range (n):
7     if simul () :
8         nb += 1
9 print ( round (nb/n *11*3)) # round (x) = l'entier le plus proche de x.
10

```

- b) Comment choisir n pour que l'on soit sûr à 95% de la valeur affichée ?
- c) Commenter le résultat obtenu.

Réponse de l'exercice

1. On propose le code

```

1 def colineaires(u,v):
2     mat = np>array([u,v])
3     return np.linalg.matrix_rank(mat) == 2
4
5 A = np.array([3,1,1],[1,0,1],[-3,0,-1])
6
7 def vecteurs_propres(u):

```

```

8   if u == [0,0,0]:
9       return False
10  else:
11      return colineaires(np.dot(A,u),u)
12

```

2. a) On vérifie facilement que $A \begin{pmatrix} 0 \\ 1 \\ -1 \end{pmatrix} = - \begin{pmatrix} 0 \\ 1 \\ -1 \end{pmatrix}$, $A \begin{pmatrix} 2 \\ 1 \\ 3 \end{pmatrix} = \begin{pmatrix} 2 \\ 1 \\ 3 \end{pmatrix}$ et $A \begin{pmatrix} 1 \\ 0 \\ -1 \end{pmatrix} = 2 \begin{pmatrix} 1 \\ 0 \\ -1 \end{pmatrix}$.

b) La matrice $A \in \mathcal{M}_3(\mathbb{R})$ a donc trois valeurs propres distinctes, et donc est diagonalisable.

3. a) Les X_i sont des variables indépendantes, toutes de même loi, et admettent une espérance p et une variance $p(1-p) \neq 0$.

Par le théorème central limite, on a donc

$$\mathbb{P}(-\alpha < M_n^* < \alpha) \approx 2\Phi(\alpha) - 1,$$

où Φ est la fonction de répartition de la loi normale centrée réduite.

b) On a donc

$$\begin{aligned} \mathbb{P}\left(M_n - \frac{1}{\sqrt{n}} \leq p \leq M_n + \frac{1}{\sqrt{n}}\right) &= \mathbb{P}\left(\frac{-1}{\sqrt{p(1-p)}} \leq M_n^* \leq \frac{1}{\sqrt{p(1-p)}}\right) \\ &\geq \mathbb{P}(-2 \leq M_n^* \leq 2) \\ &\approx 0.95 \end{aligned}$$

4. a) La fonction `simul()` teste si un vecteur au hasard est vecteur propre de A .

Ensuite, on applique n fois cette fonction, et on compte la proportion de vecteurs propres.

En multipliant cette proportion par le nombre de vecteurs possibles (11^3), on obtient une estimation de la quantité cherchée.

b) On considère l'expérience de Bernoulli qui est un succès si un vecteur aléatoire de $[-5, 5]^3$ est vecteur propre de A .

L'intervalle de la question 3b est donc intervalle de confiance du nombre cherché à 95%, et il est de largeur $\frac{2}{\sqrt{n}}$. Ainsi, pour être sûr du résultat (entier) à 95%, il suffit d'avoir $\frac{2}{\sqrt{n}}11^3 < 1$ et donc $n > 4 \times 11^6$.

c) En comptant les vecteurs propres, on en a 10 dans E_{-1} , 10 dans E_2 et 2 dans E_1 . Il y a donc 22 vecteurs propres de A à coefficients entiers entre -5 et 5 , ce qui est confirmé par le programme.

