

# Théorèmes de convergence en probabilité

## Statistiques inférentielles

### 14.1 Estimation

#### Définition 14.1

Soit  $X$  une variable aléatoire admettant une espérance  $\mu$  et une variance  $\sigma^2$ .

Pour tout entier  $n \in \mathbb{N}^*$ , on appelle  $n$ -échantillon de  $X$

On appelle alors *estimateur* d'un paramètre  $\theta$  de  $X$



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.

**EXEMPLES (À CONNAÎTRE) :** Soit  $X$  une variable aléatoire admettant une espérance  $\mu$  et une variance  $\sigma^2$ .

Les deux estimateurs suivants sont à connaître :

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

$$M_n =$$

est un estimateur de

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

$$S_n^2 =$$

est un estimateur de

†. 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  $x \in \mathbb{R}$ .

$$P(X_n \leq x) =$$

=

=

=

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

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

On reconnaît alors la fonction de répartition d'une loi

On peut donc dire, en posant  $X \hookrightarrow \text{loi de } e^{-X}$ , que

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

### Proposition 14.3

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

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

#### 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  $X \hookrightarrow$ .

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

On a donc

$$P(X_n = k) =$$

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

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

De plus, on a

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

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

On a donc

$$P(X_n = k) \sim$$

et on reconnaît la loi d'une variable de Poisson de paramètre  $\lambda$ . □

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

### 14.3 Théorèmes limites

Commençons par rappeler que si  $X$  est une variable aléatoire admettant une espérance  $\mu$  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

$$\mathbb{E}(M_n) = \quad \text{et} \quad \mathbb{V}(M_n) =$$

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

$$M_n^* =$$

On rappelle alors l'inégalité de Bienaymé-Tchebychev :

#### Théorème 14.6 – Inégalité de Bienaymé-Tchebytchev

Soit  $X$  une variable aléatoire admettant une variance. Alors

$$\forall \varepsilon > 0,$$

**EXEMPLE :** On souhaite estimer la valeur de  $\frac{\pi}{4}$  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 note de plus  $M_n$  la moyenne empirique des  $X_n$ .

On cherche donc  $n$  tel que

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

Il suffit donc de prendre

On se fixe alors dans la suite une variable aléatoire  $X$  admettant une espérance  $\mu$  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

$$\forall \varepsilon > 0,$$

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  $a < b$ ,

**NOTA :** Le résultat reste vrai en faisant tendre  $a$  ou  $b$  vers  $\pm\infty$ . Par exemple,

Ce théorème nous dit que, en un certain sens, on peut approximer la quantité  $M_n$  par une loi normale de paramètres  $\mu$  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

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  $X_n \sim \mathcal{B}(n, p)$ .

Alors pour tous réels  $a < b$ ,

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

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

Le théorème central limite appliqué à la suite  $(B_n)$  permet d'affirmer que la suite  $(\bar{B}_n^*)$  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 fausse ; 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  $\mu$  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

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

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

- 
- 

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

En prenant 100 comprimés au hasard, on trouve une moyenne de  $M_n = 2,6\text{g}$  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

On peut donc notre hypothèse.

**14.5 Exercices****Exercice 1**

Soit  $(X_n)$  une suite de variables aléatoires identiques et indépendantes, admettant une espérance  $\mu$  et une variance  $\sigma^2$ .

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.

**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  $\lambda$ .

#### 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.

1. Calculer  $\mathbb{E}(S_n)$  et  $\mathbb{V}(S_n)$ .
2. 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%.

#### 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  $\Rightarrow (1)$ .

#### 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  $\Phi$  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  $[-5, 5]$ .

- 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.