

RFIDEC — cours 2 : Échantillons, estimations ponctuelles

Christophe Gonzales


LIP6 – Université Paris 6, France

- 1 Lois des grands nombres
- 2 Théorème central-limite
- 3 Estimation ponctuelle à partir d'échantillons
- 4 Biais dans les estimations

Définition

- $(X_n)_{n \in \mathbb{N}}$: suite de variables
- a : constante
- (X_n) **converge en probabilité** vers a si, pour tout $\epsilon > 0$ la probabilité que l'écart absolu entre X_n et a dépasse ϵ tend vers 0 quand $n \rightarrow \infty$:

$$\lim_{n \rightarrow \infty} P(|X_n - a| \geq \epsilon) = 0$$



Aire hachurée tend vers 0 quand $n \rightarrow \infty$

Loi faible

- $(X_n)_{n \in \mathbb{N}}$ est une suite de variables aléatoires :
 - de même loi
 - d'espérance m
 - possédant une variance σ^2
 - **deux à deux** indépendantes
- alors la suite des variables $\bar{X}_n = \frac{\sum_{k=1}^n X_k}{n}$ converge en probabilité vers m

\bar{X}_n est appelée **moyenne empirique**

$$E(\bar{X}_n) = m$$

$$V(\bar{X}_n) = \frac{\sigma^2}{n}$$

conséquence : échantillons de grandes tailles \implies bonne chance d'estimer m

Définition

- $(X_n)_{n \in \mathbb{N}}$: suite de variables
- a : constante
- (X_n) *converge presque sûrement* vers a s'il y a une proba 1 que la suite des réalisations des X_n tende vers a :

$$P \left(\lim_{n \rightarrow \infty} X_n = a \right) = 1$$



Définition plus exigeante que la convergence en probabilité

Loi forte

- $(X_n)_{n \in \mathbb{N}}$: suite de variables aléatoires
 - de même loi
 - d'espérance m
 - possédant une variance σ^2
 - **mutuellement** indépendantes
- alors la suite des variables $\bar{X}_n = \frac{\sum_{k=1}^n X_k}{n}$ converge presque sûrement vers m

Interprétation : échantillon de grande taille
 \implies bonne estimation de m

Définition

- $(X_n)_{n \in \mathbb{N}}$: suite de variables
- F_n : fonction de répartition de X_n
- X : variable de fonction de répartition F
- La suite X_n **converge en loi** vers X lorsque $F_n(x)$ tend vers $F(x)$ en tout point de continuité de F

Notation : $X_n \xrightarrow{\text{loi}} X$

Théorème central-limite

- $(X_n)_{n \in \mathbb{N}}$: suite de variables
 - de même loi
 - d'espérance μ
 - de variance σ^2
 - **mutuellement** indépendantes
- alors la suite des moyennes empiriques centrées réduites

$\frac{\bar{X}_n - \mu}{\sigma / \sqrt{n}}$ tend en loi vers la loi normale centrée réduite :

$$\frac{\bar{X}_n - \mu}{\sigma / \sqrt{n}} \xrightarrow{\text{loi}} \mathcal{N}(0, 1)$$

Illustration du théorème central-limite (1/4)

Lancés de dés à 6 faces



$$\Rightarrow \begin{cases} X_i = \text{résultat du jet du } i\text{ème dé} \\ \bar{X}_n = \text{somme des résultats des dés} \end{cases}$$

distribution de \bar{X}_n pour 1 jet de dé




Illustration du théorème central-limite (2/4)

distribution de \bar{X}_n pour 2 jets de dés




Illustration du théorème central-limite (3/4)

distribution de \bar{X}_n pour 3 jets de dés





Illustration du théorème central-limite (4/4)

distribution de \bar{X}_n pour 4 jets de dés



Statistique inférentielle

Hypothèses :

- les données = les observations
- observations (x_1, \dots, x_n) = réalisation d'une variable aléatoire multidimensionnelle $X = (X_1, \dots, X_n)$
- observations = *échantillon empirique*
- l'échantillon est tiré suivant une loi X_0
- chaque variable X_i suit la même loi que X_0

But :

- déduire des informations sur X_0

Exemples :

- sondages électoraux, études de marché
- tests de fiabilité/qualité
- bases de données \implies diagnostic

Idée force

Dans moult études statistiques :

- population de grande taille
⇒ impossible de la connaître précisément
- possibilité de prélever des échantillons




⇒ étudier l'échantillon et en déduire les caractéristiques de la population

caractéristiques : moyenne μ , variance σ^2 , proportion de succès p

Échantillonnage (1/2)

caractéristique de la population \iff échantillon

\implies **problème** : comment prélever l'échantillon ?



Définition d'un échantillon

Échantillon d'une population = sous-ensemble **représentatif** de la population

\implies composition de l'échantillon due au hasard

Échantillonnage (2/2)

Prélèvement d'un échantillon

2 manières de prélever un échantillon aléatoirement :

① **Échantillonnage avec remise :**

choisir un individu au hasard

noter la valeur de la variable d'intérêt pour celui-ci

remettre l'individu dans la population

réitérer le processus

② **Échantillonnage sans remise :**

même procédé mais sans remettre dans la population

les individus sélectionnés



échantillonnage avec remise \implies un individu peut apparaître plusieurs fois dans l'échantillon



population de grande taille \implies avec remise \approx sans remise



résultats suivants valables uniquement pour des échantillons *avec remise*

⇒ on va travailler avec des échantillons i.i.d :

Échantillon i.i.d

- échantillon de n individus
- X_i = variable aléatoire « valeur du i ème individu tiré »
- les X_i sont mutuellement indépendants
- les X_i ont tous la même distribution

⇒ les X_i sont indépendants et identiquement distribués (i.i.d)

échantillons i.i.d ⇒ bonnes propriétés mathématiques

Estimation de la moyenne d'une population (2/4)

- X variable aléatoire sur l'ensemble de la population
- espérance : μ , variance : σ^2
- échantillon de n individus \implies observation de n valeurs de X
- X_i : variable aléatoire correspondant au i ème individu
- échantillon i.i.d \implies espérance de X_i : μ , variance de X_i : σ^2
- $\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$ = moyenne de l'échantillon

Problèmes : que valent $E(\bar{X})$ et $V(\bar{X})$?

- $$\begin{aligned} E(\bar{X}) &= \frac{1}{n} E(X_1 + X_2 + \cdots + X_n) \\ &= \frac{1}{n} (E(X_1) + E(X_2) + \cdots + E(X_n)) \\ &= \frac{1}{n} (\mu + \mu + \cdots + \mu) = \mu \end{aligned}$$

variables X_i mutuellement indépendantes \implies

- $$\begin{aligned} V(\bar{X}) &= V\left(\frac{X_1 + X_2 + \cdots + X_n}{n}\right) = \frac{1}{n^2} V(X_1 + X_2 + \cdots + X_n) \\ &= \frac{1}{n^2} (V(X_1) + V(X_2) + \cdots + V(X_n)) \\ &= \frac{1}{n^2} (\sigma^2 + \sigma^2 + \cdots + \sigma^2) = \frac{\sigma^2}{n} \end{aligned}$$

Théorème 1

- X : variable aléatoire
- espérance de X : μ , variance de X : σ^2
- échantillon de taille n avec remise sur X
- \bar{X} : variable aléatoire « moyenne de l'échantillon »
- Alors : $E(\bar{X}) = \mu$ et $V(\bar{X}) = \frac{\sigma^2}{n}$

Corollaire

- X : variable aléatoire suivant une loi normale $\mathcal{N}(\mu; \sigma^2)$
- échantillon de taille n avec remise sur X
- \bar{X} : variable aléatoire « moyenne de l'échantillon »
- Alors : $\bar{X} \sim \mathcal{N}(\mu; \frac{\sigma^2}{n})$


Exemple : calcul du handicap au bowling

Compétition en 2 phases :

- 1ère phase : 6 parties
- calcul du handicap :

$$\text{Handicap } H = (215 - \text{moyenne des 6 parties}) \times 60\%$$

- 2ème phase : 6 parties (score + le handicap H)



-
- Calcul du handicap \implies estimation de votre niveau
 - 6 parties de la 1ère phase = échantillon de taille 6
 - X_i = variable aléatoire « score de la i ème partie »

idée : scores de l'échantillon \implies score moyen de la population

Problème : que faire si X ne suit pas une loi normale ?


⇒ sauvé grâce au théorème central-limite :

Théorème 2


- X : variable aléatoire
- espérance de X : μ , variance de X : σ^2
- échantillon de taille n avec remise sur X
- n suffisamment grand ($n \geq 30$ si la distribution de X n'est pas trop dissymétrique, $n \geq 50$ sinon)
- \bar{X} : variable aléatoire « moyenne de l'échantillon »

● Alors :
$$\frac{\bar{X} - E(\bar{X})}{\sqrt{V(\bar{X})}} = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim \mathcal{N}(0; 1)$$

Exemple 1 : la planche de Galton (1/2)



Exemple 1 : la planche de Galton (2/2)



- chaque niveau \implies expérience de Bernoulli

- $\implies X \sim$ loi binomiale

- $\implies X \not\sim$ loi normale

- théorème 2 \implies

$$\frac{\bar{X} - E(\bar{X})}{\sqrt{V(\bar{X})}} = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim \mathcal{N}(0; 1)$$

Exemple 2 : analyse des déchets

- Grenelle de l'environnement
 - ⇒ réduction des déchets
 - ⇒ analyse des déchets
- impossible à réaliser sur toute la population
 - ⇒ échantillon de taille 100 :



450	320	320	390	410	415	380	390
440	350	400	380	430	400	375	...

- moyenne de l'échantillon = 390 kg/an/habitant
- \bar{X} : variable aléatoire « moyenne de l'échantillon »
- $\sigma = 20$ supposé connu
- $\bar{X} \sim \mathcal{N}(\mu, \frac{\sigma^2}{n}) \implies$ écart-type de $\bar{X} = 20/10 = 2$

Problème :



v.s.



- lancement de la Wii \implies étude de marché
- échantillon de taille $n \implies$ succès = Wii, échec = PS3
- p = proportion de succès dans toute la population
- P_i : variable aléatoire « succès du i ème individu »

Question : peut-on déduire p en observant les p_i ?

Question : peut-on déduire p en observant les p_i ?

- p = proportion de succès dans la population (p pas trop petit)
 - échantillon i.i.d de taille n assez grand
 - P_i = variable aléatoire « succès du i ème individu »
 - $P_i \sim$ loi binomiale $\mathcal{B}(1, p)$
 - \bar{P} = moyenne de l'échantillon
-

Théorème central-limite $\implies \frac{\bar{P} - E(\bar{P})}{\sqrt{V(\bar{P})}} \sim \mathcal{N}(0; 1)$

Or $\bar{P} \sim \frac{1}{n}\mathcal{B}(n; p) \implies E(\bar{P}) = \frac{np}{n}$ et $V(\bar{P}) = \frac{p(1-p)}{n}$

Théorème 3

- échantillon i.i.d de taille n assez grand
- p = proportion de succès dans la population (p pas trop petit)
- \bar{P} = moyenne de l'échantillon

● Alors :
$$\frac{\bar{P} - E(\bar{P})}{\sqrt{V(\bar{P})}} = \frac{\bar{P} - p}{\sqrt{\frac{p(1-p)}{n}}} \sim \mathcal{N}(0; 1)$$

\implies on peut estimer p en observant la valeur de \bar{P}

Application du théorème précédent

Expert : 80%



v.s. 20%



● échantillon de 100 personnes \implies 70 Wii et 30 PS3

● Doit-on croire l'expert ?

si $p = 80\%$ alors Théorème 3 $\implies \frac{\bar{P} - 0,8}{\sqrt{\frac{0,8 \times 0,2}{100}}} = 25(\bar{P} - 0,8) \sim \mathcal{N}(0; 1)$

$$\begin{aligned}\text{Prob}(\bar{P} \leq 0.7) &= \text{Prob}(25(\bar{P} - 0.8) \leq 25 \times (0.7 - 0.8)) \\ &= \text{Prob}(25(\bar{P} - 0.8) \leq -2,5) \approx 0,62\%\end{aligned}$$

Application au réchauffement climatique

- Avril 2007 : étude tms-sofres / CNRS :
opinion des gens sur le réchauffement climatique
- 1000 personnes de 15 ans et + interrogées
⇒ échantillon i.i.d
- 790 pensent qu'il y a un changement climatique
- 210 ne le pensent pas
- \bar{P} : proportion de succès moyenne de l'échantillon
- p : proportion de personnes pensant qu'il y a dérèglement climatique dans la population française



$$\frac{\bar{P} - p}{\sqrt{\frac{p(1-p)}{n}}} \sim \mathcal{N}(0; 1)$$

⇒ estimation de $p = 79\%$, écart-type de $\bar{P} \leq \sqrt{\frac{0.25}{1000}} \approx 0,015$

Caractéristiques des estimateurs

Transparents précédents \implies si échantillon de grande taille
alors $\bar{X} \approx \mu \implies$ estimer μ par \bar{X}

Estimateur non biaisé

- Estimateur T d'un paramètre $\theta \implies$ valeur estimée $\hat{\theta}$
- T non biaisé si $E(T) = \theta$



estimateur biaisé \implies on surévalue ou sous-évalue θ

Estimateur convergent

- Estimateur T d'un paramètre θ
- T convergent si $E[(T - \theta)^2] \rightarrow 0$ lorsque la taille de l'échantillon \nearrow

moyenne \bar{X} et proportion de succès \bar{P} :
estimateurs non biaisés et convergents

Biais : estimation ponctuelle d'une variance (1/5)

- population = 4 nombres $\{1, 2, 3, 4\}$
- $\mu = \frac{5}{2}$ et $\sigma^2 = \frac{5}{4}$
- échantillon de taille 2 avec remise :

échant.	espérance	variance	échant.	espérance	variance
1 1	$E(\bar{X}) = 1$	$V(\bar{X}) = 0$	1 2	$E(\bar{X}) = \frac{3}{2}$	$V(\bar{X}) = \frac{1}{4}$
1 3	$E(\bar{X}) = 2$	$V(\bar{X}) = 1$	1 4	$E(\bar{X}) = \frac{5}{2}$	$V(\bar{X}) = \frac{9}{4}$
2 1	$E(\bar{X}) = \frac{3}{2}$	$V(\bar{X}) = \frac{1}{4}$	2 2	$E(\bar{X}) = 2$	$V(\bar{X}) = 0$
2 3	$E(\bar{X}) = \frac{5}{2}$	$V(\bar{X}) = \frac{1}{4}$	2 4	$E(\bar{X}) = 3$	$V(\bar{X}) = 1$
3 1	$E(\bar{X}) = 2$	$V(\bar{X}) = 1$	3 2	$E(\bar{X}) = \frac{5}{2}$	$V(\bar{X}) = \frac{1}{4}$
3 3	$E(\bar{X}) = 3$	$V(\bar{X}) = 0$	3 4	$E(\bar{X}) = \frac{7}{2}$	$V(\bar{X}) = \frac{1}{4}$
4 1	$E(\bar{X}) = \frac{5}{2}$	$V(\bar{X}) = \frac{9}{4}$	4 2	$E(\bar{X}) = 3$	$V(\bar{X}) = 1$
4 3	$E(\bar{X}) = \frac{7}{2}$	$V(\bar{X}) = \frac{1}{4}$	4 4	$E(\bar{X}) = 4$	$V(\bar{X}) = 0$

- espérance $\left\{ \begin{array}{l} \text{des moyennes des échantillons} = \mu \\ \text{des variances des échantillons} = \frac{5}{8} \neq \frac{5}{4} \end{array} \right. \Rightarrow \text{biais !}$

Biais : estimation ponctuelle d'une variance (2/5)

- X : variable aléatoire sur l'ensemble de la population
- σ^2 : variance de X
- échantillon i.i.d. de taille n
- X_j : variable aléatoire correspondant au i ème individu
- x_i : valeur observée de X_j
- \bar{X} : variable aléatoire « moyenne sur l'échantillon »
- \bar{x} : valeur observée de \bar{X}
- $s_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \left(\sum_{i=1}^n x_i^2 \right) - \bar{x}^2$
- $s_n^2 =$ variance de l'échantillon

Problème : pourquoi s_n^2 n'est-il pas un bon estimateur de σ^2 ?

Biais : estimation ponctuelle d'une variance (3/5)

$$\bullet S_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \left(\sum_{i=1}^n X_i^2 \right) - \bar{X}^2$$

$\bullet s_n^2$ est une réalisation de S_n^2

$$\bullet E(S_n^2) = E \left(\frac{1}{n} \left(\sum_{i=1}^n X_i^2 \right) - \bar{X}^2 \right) = \frac{1}{n} \left(\sum_{i=1}^n E(X_i^2) \right) - E(\bar{X}^2)$$

\bullet Or échantillon i.i.d $\implies \forall i, E(X_i^2) = E(X^2)$


$$\implies E(S_n^2) = E(X^2) - E(\bar{X}^2)$$

\bullet Or $V(X) = E(X^2) - E(X)^2$ et $V(\bar{X}) = E(\bar{X}^2) - E(\bar{X})^2 = E(\bar{X}^2) - E(X)^2$
 $\implies E(S_n^2) = V(X) + E(X)^2 - V(\bar{X}) - E(X)^2 = V(X) - V(\bar{X})$

\bullet Or échantillon i.i.d $\implies V(X) = \sigma^2$ et $V(\bar{X}) = \frac{\sigma^2}{n}$

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

Biais : estimation ponctuelle d'une variance (4/5)



- courbe verte : la population
- courbes rouges : échantillons
- pts bleus : valeurs observées
- variance S_n^2 sous-estimée : mesurée par rapport à la moyenne de l'échantillon au lieu de la moyenne de la population

Variance corrigée

- X : variable aléatoire sur la population
- σ^2 : variance de X sur cette population
- échantillon de taille n avec remise
- X_i : variable aléatoire correspondant au i ème individu
- \bar{X} : moyenne des X_i
- alors : $E \left(\frac{n}{n-1} \sum_{i=1}^n \frac{(X_i - \bar{X})^2}{n} \right) = \sigma^2$
- **Variance corrigée** : $\frac{n}{n-1}$ fois la variance de l'échantillon S_n^2