

Rappel: Loi des grands nombres: Si X_1, X_2, \dots i.i.d.,

$$\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{\text{p.s.}} E[X_1] \quad \text{dès que } E[|X_1|] < \infty$$

Thm central limit: Même setup,

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n (X_i - E[X_1]) \xrightarrow{\text{loi}} \mathcal{N}(0, \text{Var}(X_1))$$

si $E[X_1^2] < \infty$.

Chapitre 4: Intro à la statistique

Motivation: On se donne une suite de résultats d'une même expérience \rightsquigarrow résultat d'une suite de nombres aléatoires, et on veut comprendre la loi de ces nombres.

Def: Soit \mathbb{P} une mesure de proba sur \mathbb{R}^d . Soit $n \geq 1$.

Un n-échantillon de loi \mathbb{P} est une famille indép. de vect. al. $X_1, X_2, \dots, X_n \sim \mathbb{P}$.

Une réalisation d'un n-échantillon X_1, X_2, \dots, X_n , est une suite de vecteurs $(x_1, x_2, \dots, x_n) \in (\mathbb{R}^d)^n$

But: trouver \mathbb{P} à partir de (x_1, \dots, x_n) .

— nous a permis de (x_1, \dots, x_n) .

Déf. Une statistique sur un n -échantillon
 (X_1, \dots, X_n) est une fonction $Y: (\mathbb{R}^d)^n \rightarrow \mathbb{R}$.

↳ • $Y(X_1, X_2, \dots, X_n)$ sera une v.c.

• $Y(x_1, x_2, \dots, x_n)$ est un nombre

Expl. On lance 10 pièces de monnaie et on note 0 pour pile, 1 pour face.

X_i = résultat du i^{em} lancé.

On fait les lancers et on trouve

0, 0, 1, 0, 0, 1, 1, 1, 0, 1

(X_1, \dots, X_{10}) sera un 10-échantillon de Bi
 \mathbb{P} (qu'on ne connaît pas)

$(0, 0, 1, 0, 0, 1, 1, 1, 0, 1)$ est une réalisation du 10-échantillon.

Expl de statistiques: • $\frac{1}{10} \sum_{i=1}^{10} X_i$ est une stat.

• $X_1 + X_2 + X_3$ est une stat

• X_5 est une stat.

Un premier exemple d'estimation paramétrique:

Expérience: lancer de pièce. 0 pour pile

Expérience: lancé de pièce : 0 pour pile
1 pour face.

(X_1, X_2, \dots, X_n) un n -échantillon de loi \mathbb{P}
à déterminer.

Δ \mathbb{P} est une mesure de proba sur \mathbb{R}

a priori $\mathbb{P} \in \{ \mathbb{P} : \mathcal{P}(\mathbb{R}) \rightarrow [0,1] : \text{mesure de proba} \}$.

Idee 1: réduire l'espace : ici on sait que

$$\mathbb{P}(\{0,1\}) = 1 \text{ et donc } \mathbb{P}(\{0\}) + \mathbb{P}(\{1\}) = 1$$

\hookrightarrow pour comprendre \mathbb{P} , il suffit de
calculer $p = \mathbb{P}(\{1\}) = \mathbb{P}(X_i = 1)$.

\rightsquigarrow on fait l'hypothèse qu'il existe $p \in [0,1]$ t.q.

$$\mathbb{P} = \text{Bern}(p). \quad \textcircled{*}$$

Idee 2: On cherche une statistique qui
approxime p .

$$\hat{p}_n = \hat{p}_n(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i$$

Questions:

① est-ce que \hat{p}_n donne la bonne
valeur en moyenne?

② est-ce que augmenter n améliore

② est-ce que augmenter n améliore mon estimation ?

③ à n fixé, quelle est la proba. que mon estimateur soit mauvaise ?

$$\begin{aligned} \textcircled{1} \quad E[\hat{p}_n(X_1, \dots, X_n)] &= E\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n} \sum_{i=1}^n E[X_i] \\ &\stackrel{\text{hyp.}}{=} \frac{1}{n} \sum_{i=1}^n p = p \end{aligned}$$

Rem: vrai pour tout $n \dots$

② la loi forte des grands nombres dit

$$\hat{p}_n = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{\text{p.s.}} E[X_i] = p.$$

↳ augmenter n nous rapproche bien de la valeur voulue.

③ Proba de ~~se~~ planter : $\varepsilon > 0$ erreur d'approximation

On cherche à calculer

$$\mathbb{P}\left(|\hat{p}_n - p| \geq \varepsilon\right) \underset{E[X_i]=p}{=} \mathbb{P}\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - \frac{1}{n} \sum_{i=1}^n E[X_i]\right| \geq \varepsilon\right)$$

$$= \mathbb{P}\left(\left|\frac{1}{\sqrt{n}} \sum_{i=1}^n (X_i - E[X_i])\right| \geq \sqrt{n} \varepsilon\right)$$

$$= \mathbb{P}\left(\left|\frac{1}{\sqrt{np(1-p)}} \sum_{i=1}^n (X_i - E[X_i])\right| \geq \frac{\sqrt{n} \varepsilon}{\sqrt{p(1-p)}}\right)$$

n grand, $\approx \mathcal{N}(0,1)$ par CLT

n grand, $\approx \mathcal{N}(0,1)$ par CLT

$$\begin{aligned} & \approx \mathbb{P}\left(|\mathcal{N}(0,1)| \geq \frac{\sqrt{n} \varepsilon}{\sqrt{p(1-p)}}\right) \\ & = 2\mathbb{P}\left(\mathcal{N}(0,1) \geq \frac{\sqrt{n} \varepsilon}{\sqrt{p(1-p)}}\right) \quad (***) \end{aligned}$$

On ne connaît pas p , on prend la valeur qui maximise cette proba d'erreur:

$$\begin{aligned} (***) & \leq 2\mathbb{P}\left(\mathcal{N}(0,1) \geq 2\sqrt{n} \varepsilon\right) \quad (p=1/2) \\ & = \frac{2}{\sqrt{2\pi}} \int_{2\sqrt{n} \varepsilon}^{\infty} e^{-x^2/2} dx \leq \frac{1000}{\sqrt{n} \varepsilon} e^{-\varepsilon^2 n/2} \end{aligned}$$

Récap:

- Expérience + mesure \leadsto vect. al. X de loi \mathbb{P} : $\mathbb{P}(A) = \mathbb{P}(X \in A)$.
- On répète n fois l'exp. \leadsto n -échantillon (X_1, \dots, X_n) avec $X_i \sim \mathbb{P}$
- On trouve une réalisation (x_1, \dots, x_n) de (X_1, \dots, X_n) et on cherche à déterminer \mathbb{P} à partir de (x_1, \dots, x_n) .

Estimateurs:

Déf. (estimation paramétrique) On suppose que \mathbb{P} appartient à une famille $(\mathbb{P}_\theta)_{\theta \in \Theta}$ paramétrisée par

à une famille $(\mathbb{P}_\theta)_{\theta \in \Theta}$ paramétrisée par $\theta \in \Theta \subset \mathbb{R}^m$ pour un $m \geq 1$ fixé.

θ est le paramètre et Θ est l'espace des paramètres.

Expl:

1) On tire au hasard un herminet dans la population suisse et on mesure sa masse.

↳ On pourrait se dire que la masse suit une loi $\mathcal{N}(\mu, \sigma^2)$.

↳ $\theta = (\mu, \sigma^2)$, $\Theta = \mathbb{R} \times [0, +\infty)$.

2) Durée de vie d'un ordinateur en salle d'info à l'EPFL.

↳ On pourrait prendre une loi $\text{Exp}(\lambda)$:

$\theta = \lambda$, $\Theta = (0, +\infty)$.

3) Lancer d'un dé à 20 faces (non-équilibré):

$$\Theta = \left\{ p \in [0, 1]^{(1, \dots, 20)} : \sum_{i=1}^{20} p_i = 1 \right\}$$

$$\theta \in \Theta \subset \mathbb{R}^{20}$$

Déf: Soit (X_1, \dots, X_n) un n -échantillon de loi \mathbb{P}_θ ,

$\theta \in \Theta$. Soit $f: \Theta \rightarrow \mathbb{R}$. Un estimateur de $f(\theta)$ est une statistique $\hat{f}: (\mathbb{R}^d)^n \rightarrow \mathbb{R}$ qui ne dépend pas de θ .

Idée: on approxime $f(\theta)$ par $\hat{f}(X_1, \dots, X_n)$.

| Idee: on approxime $f(\theta)$ par $\hat{f}(x_1, \dots, x_n)$.

Pourquoi \hat{f} plutôt que θ ?

expl: $E[X]$ n'est pas forcément $= \theta$.

mais $E[X] = f(\theta)$ pour f bien choisit.

Expl d'estimateur:

$\frac{1}{n} \sum_{i=1}^n X_i$ est un estimateur
de $E[X]$.

Def: Soit $f: \Theta \rightarrow \mathbb{R}$ une quantité à estimer. Pour

$n \geq 1$, on se donne un n -échantillon de loi $\mathbb{P}_\theta, \theta \in \Theta$.

Une suite $\hat{f}_n(x_1, \dots, x_n)$ d'estimateurs de $f(\theta)$ est dite convergente si $\forall \epsilon > 0$,

$$\lim_{n \rightarrow \infty} \mathbb{P}(|\hat{f}_n(x_1, \dots, x_n) - f(\theta)| \geq \epsilon) = 0.$$

(i.e. $\hat{f}_n \xrightarrow{\text{proba}} f(\theta)$).

Def: Soit (X_1, \dots, X_n) un n -échantillon de loi \mathbb{P}_θ .

Soit $f(\theta)$ une quantité à estimer et soit $\hat{f}_n(x_1, \dots, x_n)$ un estimateur de $f(\theta)$. On définit le biais de \hat{f}_n par:

$$E[\hat{f}_n(x_1, \dots, x_n)] - f(\theta) =: \text{Biais}_\theta(\hat{f}_n)$$

$$E[\hat{f}_n(X_1, \dots, X_n)] - f(\theta) =: \text{Biais}_\theta(\hat{f}_n)$$

On dit qu'une suite d'estimateurs $(\hat{f}_n)_{n \geq 1}$ de $f(\theta)$ est asymptotiquement sans biais si

$$\lim_{n \rightarrow \infty} \text{Biais}_\theta(\hat{f}_n) = 0.$$

La variance d'un estimateur \hat{f}_n de $f(\theta)$ est $\text{Var}(\hat{f}_n(X_1, \dots, X_n)) =: \text{Var}_\theta(\hat{f}_n)$.

⚠ La dépendance des quantités en θ est souvent implicite mais elle est bien présente : $X_1, \dots, X_n \sim \mathbb{P}_\theta$.

Lemme: Si $(\hat{f}_n)_{n \geq 1}$ est une suite d'estimateur de $f(\theta)$ telle que:

i) $(\hat{f}_n)_{n \geq 1}$ est asymptotiquement sr. biais,

ii) $\text{Var}_\theta(\hat{f}_n) \xrightarrow{n \rightarrow \infty} 0$,

alors $(\hat{f}_n)_{n \geq 1}$ est une suite convergente d'estimateurs.

* PV: Par Chebyshev, $\forall \varepsilon > 0$

$$\mathbb{P}(|\hat{f}_n - f(\theta)| \geq \varepsilon) \leq \frac{E[(\hat{f}_n - f(\theta))^2]}{\varepsilon^2}$$

$$\begin{aligned}
& \frac{\quad}{\varepsilon^2} \\
& = \frac{E[(\hat{\beta}_n - E[\hat{\beta}_n] + E[\hat{\beta}_n] - \beta(\theta))^2]}{\varepsilon^2} \\
& = \frac{1}{\varepsilon^2} \left(E[(\hat{\beta}_n - E[\hat{\beta}_n])^2] + (E[\hat{\beta}_n] - \beta(\theta))^2 \right. \\
& \quad \left. + 2 \underbrace{E[\hat{\beta}_n - E[\hat{\beta}_n]]}_{=0} (E[\hat{\beta}_n] - \beta(\theta)) \right) \\
& = \frac{1}{\varepsilon^2} \left(\underbrace{\text{Var}_0(\hat{\beta}_n)}_{\substack{\rightarrow 0 \\ \text{ii)}}} + \underbrace{\text{Bias}_0(\hat{\beta}_n)^2}_{\substack{\rightarrow 0 \\ \text{i)}}} \right)
\end{aligned}$$

□