

# MIA - Notes de la Séance 7

GABIOT Maxime & PLAS Jean-Pierre

4 Octobre 2022

## Table des matières

<b>1</b>	<b>Statistique inférentielle asymptotique (classique)</b>	<b>2</b>
1.1	Modes de convergence . . . . .	2
1.1.1	Convergence presque sûre ou presque partout . . . . .	2
1.1.2	Convergence en probabilité . . . . .	2
1.1.3	Convergence en loi . . . . .	2
1.1.4	Convergence en moyenne quadratique . . . . .	2
1.2	Applications des modes de convergence . . . . .	3
1.2.1	Loi forte des grands nombres . . . . .	3
1.2.2	Théorème de la limite centrale . . . . .	3
1.2.3	Transformations continues . . . . .	3
1.2.4	Théorème de Slutsky . . . . .	3
1.2.5	Méthode delta . . . . .	4
<b>2</b>	<b>Optimisation</b>	<b>5</b>
2.1	Analyse . . . . .	5
2.1.1	Définition de Limite . . . . .	5
2.1.2	Notions de base de topologie . . . . .	5
2.2	Jacobienne, Gradient . . . . .	6
2.2.1	Gradient . . . . .	6
2.2.2	Jacobienne . . . . .	6
2.3	Optimisation sans contraintes . . . . .	8
2.4	Conditions d'optimalité . . . . .	8

# 1 Statistique inférentielle asymptotique (classique)

## 1.1 Modes de convergence

Il y a quatre modes de convergences différents.

On a  $X_1, \dots, X_n$  une suite de variables aléatoires réelles (v.a.r.) définies sur  $\Omega$ . On va définir la limite  $\lim_{n \rightarrow +\infty} X_n$ . Or, comme il y a plusieurs types de convergences, on note plutôt :

### 1.1.1 Convergence presque sûre ou presque partout

$$\begin{aligned} X_n \rightarrow_{a.e.} X &\sim P, & a.e. &= \text{almost everywhere,} \\ \equiv X_n \rightarrow_{p.s.} X &\sim P, & p.s. &= \text{presque sûr,} \\ \equiv X_n \rightarrow_{a.s.} X &\sim P, & a.s. &= \text{almost sure.} \end{aligned}$$
$$\text{ssi } \exists N \subset \Omega, \text{ tq } P(N) = 0, \forall \omega \in \Omega \setminus N, \lim_{n \rightarrow +\infty} X_n(\omega) = X(\omega).$$
$$\equiv \forall \varepsilon > 0, \lim_{n \rightarrow +\infty} P(\{\omega \mid \omega \in \Omega \text{ et } \exists m \geq n \mid \|X_m(\omega) - X(\omega)\| > \varepsilon\}) = 0$$

Un estimateur  $\theta_n$  de  $\theta$  est fortement consistant de  $\theta$  si et seulement si la suite de var  $(\theta_n)_{n \in \mathbb{N}^*}$  converge presque sûrement vers  $\theta$ .

### 1.1.2 Convergence en probabilité

$$\begin{aligned} X_n \rightarrow_p X &\sim P \\ \text{ssi } \forall \varepsilon > 0, \lim_{n \rightarrow +\infty} P(\|X_n - X\| \geq \varepsilon) &= 0 \end{aligned}$$

Un estimateur  $\theta_n$  de  $\theta$  est faiblement consistant de  $\theta$  si et seulement si la suite de var  $(\theta_n)_{n \in \mathbb{N}^*}$  converge en probabilité vers  $\theta$ .

i.e. son biais tend vers 0 quand n tend vers l'infini.

### 1.1.3 Convergence en loi

$X_1, \dots, X_n$  v.a.r. définies sur  $\Omega$ . On Dit que  $(X_n)$  tend vers  $X \sim P$  en distribution, écrit  $X_n \rightarrow_d X$ , ssi pour tout  $x \in \mathbb{R}$  tel que  $F_x$  la fonction de répartition de  $X$  soit continue en  $x$ , alors  $\lim_{n \rightarrow +\infty} F_{n,X}(x) = F_X(x)$  où  $F_{n,X}$  est la fonction de répartition de  $X_n$ .

Aussi, elle diffère des 2 lois précédentes, car on ne regarde pas événement par événement, mais on regarde directement les fonctions de répartitions.

$$\begin{aligned} \text{Si } X_n \rightarrow_{a.e.} X &\sim P \text{ alors } X_n \rightarrow_p X \sim P. \\ \text{Si } X_n \rightarrow_p X &\sim P \text{ alors } X_n \rightarrow_d X \sim P. \end{aligned}$$

La convergence presque sûre est plus forte que la convergence en probabilité. Cela veut dire que s'il y a convergence presque sûre, alors il y a convergence en probabilité (mais la réciproque n'est pas vraie). Il y a la même relation entre convergence en probabilité et convergence en loi.

### 1.1.4 Convergence en moyenne quadratique

Nous n'avons pas vu ce mode.

## 1.2 Applications des modes de convergence

### 1.2.1 Loi forte des grands nombres

$X_1, X_2, \dots$  variables aléatoires i.i.d.

(The SLLN). Une condition nécessaire et suffisante pour l'existence d'une constante  $c$  telle que

$$\frac{1}{n} \sum_{i=1}^n X_i \rightarrow_{a.s.} c$$

est que  $\mathbb{E}[X_1] < \infty$ , dans ce cas  $c = \mathbb{E}[X_1]$ .

On peut réécrire cette condition comme  $X_1$  a une moyenne ou  $X_1$  a une espérance  $< \infty$ .

#### Remarque :

Il existe aussi la loi faible des grands nombres qui repose sur une convergence en probabilité.

Dans certains cas de figure, la loi faible s'applique, mais pas la forte.

### 1.2.2 Théorème de la limite centrale

(Multivariée) Soit  $X_1, \dots, X_n$  i.i.d. des  $k$ -vecteurs aléatoires avec  $\Sigma = \text{Var}(X_1)$  fini.

Alors

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n (X_i - \mathbb{E}[X_1]) \rightarrow_d N_k(0, \Sigma).$$

où en multipliant par  $\frac{n}{\sqrt{n}}$  on obtient  $\sqrt{n}(\hat{\mu}_n - \mu)$  et où  $\mathbb{E}[X_1]$  peut-être réécrit  $\mu$ .

Pour  $n$  grand,  $\hat{\mu}_n - \mu \sim \text{approx } \mathcal{N}(0, \frac{\Sigma}{n})$

Pour  $n$  grand,  $\hat{\mu}_n \sim \text{approx } \mathcal{N}(\mu, \frac{\Sigma}{n})$

$$\begin{aligned} & \frac{1}{\sqrt{n}} \sum_{i=1}^n (X_i - \mathbb{E}[X_1]) \\ &= \frac{n}{n} * \frac{1}{\sqrt{n}} \sum_{i=1}^n (X_i - \mathbb{E}[X_1]) \\ &= \frac{\sqrt{n}\sqrt{n}}{n\sqrt{n}} \sum_{i=1}^n (X_i - \mathbb{E}[X_1]) \\ &= \frac{\sqrt{n}}{n} \sum_{i=1}^n (X_i - \mathbb{E}[X_1]) \\ &= \sqrt{n} * \frac{1}{n} \sum_{i=1}^n (X_i - \mathbb{E}[X_1]) \\ &= \sqrt{n}(\hat{\mu}_n - \mu) \end{aligned}$$

### 1.2.3 Transformations continues

#### Théorème 1.10.

Soit  $X, X_1, X_2, \dots$  des  $k$ -vecteurs aléatoires définis sur un espace de probabilité

et  $g$  une fonction de  $(\mathcal{R}^k)$  en  $(\mathcal{R}^l)$ .

Supposons que  $g$  est continue.

Alors

(i)  $X_n \rightarrow_{a.s.} X$  implique  $g(X_n) \rightarrow_{a.s.} g(X)$  ;

(ii)  $X_n \rightarrow_p X$  implique  $g(X_n) \rightarrow_p g(X)$  ;

(iii)  $X_n \rightarrow_d X$  implique  $g(X_n) \rightarrow_d g(X)$ .

#### Exemple pour (i) :

$X_1, \dots, X_n$  i.i.d. sur  $P$  avec  $\mu = \mathbb{E}[P]$ .

$\hat{\mu}_n(X_1, \dots, X_n) \rightarrow_{a.e.} \mu$

$g : x \mapsto x^2$

$g(\hat{\mu}_n) \rightarrow_{a.s.} g(\mu)$

$\hat{\mu}_n^2 \rightarrow_{a.s.} \mu^2$

### 1.2.4 Théorème de Slutsky

#### Théorème 1.11 (Théorème de Slutsky).

Soit  $X, X_1, X_2, \dots, Y_1, Y_2, \dots$  des variables aléatoires sur un espace de probabilité.

Supposons que  $X_n \rightarrow_d X$  et  $Y_n \rightarrow_p c$ , où  $c$  est une constante réelle.

Alors

(i)  $X_n + Y_n \rightarrow_d X + c$

(ii)  $Y_n X_n \rightarrow_d cX$

(iii)  $X_n/Y_n \rightarrow_d X/c$  si  $c \neq 0$ .

### 1.2.5 Méthode delta

La méthode delta nous permet d'étudier les fluctuations de  $g(X_n)$  autour de  $g(c)$ .

Soit  $X_1, X_2, \dots, Y$  des vecteurs aléatoires de dimension  $k$  tels que :

$$a_n(X_n - c) \rightarrow_d Y$$

pour  $c$  appartenant à  $\mathbb{R}^k$  et  $(a_n)$  une suite de nombres positifs tendant vers  $+\infty$ .

Alors pour toute fonction  $g : \mathbb{R}^k \rightarrow \mathbb{R}$  différentiable en  $c$ , on a :

$$a_n[g(X_n) - g(c)] \rightarrow_d [\nabla g(c)]^T Y$$

## 2 Optimisation

### 2.1 Analyse

#### 2.1.1 Définition de Limite

**Concept central :**

$$\lim_{x \rightarrow a} f(x) = l$$

$\forall \epsilon > 0, \exists \delta > 0$  tel que  
 $\|x - a\|_2 \leq \delta \implies \|f(x) - l\| < \epsilon$

#### 2.1.2 Notions de base de topologie

Dans  $\mathbb{R}^n$ , La boule fermée  $B_f(x, \epsilon)$ , centrée sur  $x$  et de rayon  $\epsilon$  associée à la norme Euclidienne est l'ensemble des points  $y$  de  $\mathbb{R}^n$  tels que  $\|x - y\|_2 \leq \epsilon$ .

Dans  $\mathbb{R}^n$ , La boule ouverte  $B_o(x, \epsilon)$ , centrée sur  $x$  et de rayon  $\epsilon$  associée à la norme Euclidienne est l'ensemble des points  $y$  de  $\mathbb{R}^n$  tels que  $\|x - y\|_2 < \epsilon$ .


$U$  est un ouvert de  $\mathbb{R}^n$  ssi  $U \subset \mathbb{R}^n$  et pour tout  $x$  dans  $U$ , il existe  $\epsilon > 0$ , tel que  $B_f(x, \epsilon) \subset U$ .

On peut dire qu'un ouvert est un ensemble qui n'inclut aucune frontière.

$U$  est un fermé de  $\mathbb{R}^n$  ssi son complément dans  $\mathbb{R}^n$  est un ouvert de  $\mathbb{R}^n$ .

On peut dire qu'un fermé est un ensemble qui inclut toutes ses frontières.

FIGURE 1 – Schéma représentatif d'ensembles ouvert, fermé, et ni ouvert ni fermé.



**Frontière en pointillés  
= frontière non incluse dans l'ensemble**

Exemple :  $[0, 5[$  est un sous-ensemble des Réels

Il n'est ni ouvert ni fermé car on inclut une frontière mais pas l'autre frontière.

## 2.2 Jacobienne, Gradient

$f : U \subset \mathbb{R}^n \rightarrow \mathbb{R}^m$ , de classe  $\mathcal{C}^1$  ( $\mathcal{C}^1$ , qui ont une dérivée continue)  
Dérivée partielle  $f : x \mapsto (f_1(x), f_2(x), \dots, f_m(x))$

$$\frac{\partial f_i}{\partial x_j} : (a_1, \dots, a_n) \mapsto \lim_{h \rightarrow 0} \frac{f_i(a_1, \dots, a_{j-1}, a_j + h, a_{j+1}, \dots, a_n) - f_i(a_1, \dots, a_j, \dots, a_n)}{h}$$

### 2.2.1 Gradient

Gradient de  $f_1 : U \subset \mathbb{R}^n \rightarrow \mathbb{R}$

$$\nabla f_1 : x \mapsto \begin{bmatrix} \frac{\partial f_1(x)}{\partial x_1} \\ \vdots \\ \frac{\partial f_1(x)}{\partial x_n} \end{bmatrix}$$

### 2.2.2 Jacobienne

Matrice Jacobienne (transposée du gradient si  $\mathbf{m} = \mathbf{1}$ )

$$\mathbf{J} = \begin{bmatrix} \frac{\partial \mathbf{f}}{\partial x_1} & \cdots & \frac{\partial \mathbf{f}}{\partial x_n} \end{bmatrix} = \begin{bmatrix} \nabla^T f_1 \\ \vdots \\ \nabla^T f_m \end{bmatrix} = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \cdots & \frac{\partial f_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial f_m}{\partial x_1} & \cdots & \frac{\partial f_m}{\partial x_n} \end{bmatrix}$$

"Chain rule"

$$J_{f \circ g}(\mathbf{a}) = J_f(g(\mathbf{a}))J_g(\mathbf{a})$$

Exemple de gradient / Jacobienne :

$$f : \begin{cases} \mathbb{R}^2 \rightarrow \mathbb{R}^2 \\ x, y \mapsto x + y, x - y \end{cases}$$

$$g : \begin{cases} \mathbb{R}^2 \rightarrow \mathbb{R}^3 \\ x, y \mapsto x^2, y^2, x^2 + y^2 \end{cases}$$

Que vaut  $J_{g \circ f}$  ?

$$g \circ f : \begin{cases} \mathbb{R}^2 \rightarrow \mathbb{R}^3 \\ x, y \mapsto (x + y)^2, (x - y)^2, (x + y)^2 + (x - y)^2 \end{cases}$$

$$J_f(x, y) = \begin{bmatrix} \frac{\partial(x+y)}{\partial x} & \frac{\partial(x+y)}{\partial y} \\ \frac{\partial(x-y)}{\partial x} & \frac{\partial(x-y)}{\partial y} \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}$$

$$J_g(x, y) = \begin{bmatrix} \frac{\partial x^2}{\partial x} & \frac{\partial x^2}{\partial y} \\ \frac{\partial y^2}{\partial x} & \frac{\partial y^2}{\partial y} \\ \frac{\partial(x^2+y^2)}{\partial x} & \frac{\partial(x^2+y^2)}{\partial y} \end{bmatrix} = \begin{bmatrix} 2x & 0 \\ 0 & 2y \\ 2x & 2y \end{bmatrix}$$

$$J_{g \circ f}(x, y) = J_g(f(x, y)) J_f(x, y) = \begin{bmatrix} 2(x+y) & 0 \\ 0 & 2(x-y) \\ 2(x+y) & 2(x-y) \end{bmatrix} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}$$

$$= \begin{bmatrix} 2(x+y) & 2(x+y) \\ 2(x-y) & -2(x-y) \\ 4x & 4y \end{bmatrix}$$

### 2.3 Optimisation sans contraintes

$$f : \mathbb{R}^n \mapsto \mathbb{R}$$
$$\min_x f(x)?$$

$x^*$  est un minimum global de  $f$  ssi pour tout  $x \in \mathbb{R}^n$ ,  $f(x^*) \leq f(x)$   $x^*$  est un minimum local de  $f$  ssi il existe un ensemble ouvert  $U \subset \mathbb{R}^n$  contenant  $x^*$  tel que pour tout  $x \in U$ ,  $f(x^*) \leq f(x)$ .

### 2.4 Conditions d'optimalité

#### Conditions nécessaires, premier ordre

Si  $x^*$  est un minimum local et  $f$  est de classe  $\mathcal{C}^1$  sur un ouvert  $U \subset \mathbb{R}^n$  contenant  $x$ , alors  $\nabla f(x^*) = 0$ .