

# MAP 433 : Introduction aux méthodes statistiques. Cours 6

21 mars 2014

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher



# Aujourd'hui

- 1 Sélection de variables
  - Backward Stepwise Regression
  - LASSO
- 2 Régression non-linéaire
- 3 Comparaison d'estimateurs
  - Risque et admissibilité
  - Approche asymptotique
- 4 Modèles réguliers et information de Fisher
  - Construction de l'information de Fisher
  - Modèle régulier
  - Cadre général et interprétation géométrique
  - Exemples, applications

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher



# Régression linéaire multiple (= Modèle linéaire)

- La fonction de régression est  $r(\vartheta, \mathbf{x}_i) = \vartheta^T \mathbf{x}_i$ . On observe

$$(\mathbf{x}_1, Y_1), \dots, (\mathbf{x}_n, Y_n)$$

avec

$$Y_i = \vartheta^T \mathbf{x}_i + \xi_i, \quad i = 1, \dots, n$$

où  $\vartheta \in \Theta = \mathbb{R}^k$ ,  $\mathbf{x}_i \in \mathbb{R}^k$ .

- Matriciellement

$$\mathbf{Y} = \mathbb{M}\vartheta + \boldsymbol{\xi}$$

avec  $\mathbf{Y} = (Y_1 \dots Y_n)^T$ ,  $\boldsymbol{\xi} = (\xi_1 \dots \xi_n)^T$  et  $\mathbb{M}$  la matrice  $(n \times k)$  dont les lignes sont les  $\mathbf{x}_i$ .

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher



# EMC en régression linéaire multiple

- Estimateur des moindres carrés en régression linéaire multiple : tout estimateur  $\hat{\vartheta}_n^{\text{mc}}$  satisfaisant

$$\sum_{i=1}^n (Y_i - (\hat{\vartheta}_n^{\text{mc}})^T \mathbf{x}_i)^2 = \min_{\vartheta \in \mathbb{R}^k} \sum_{i=1}^n (Y_i - \vartheta^T \mathbf{x}_i)^2.$$

- En notation matricielle :

$$\begin{aligned} \|\mathbf{Y} - \mathbb{M}\hat{\vartheta}_n^{\text{mc}}\|^2 &= \min_{\vartheta \in \mathbb{R}^k} \|\mathbf{Y} - \mathbb{M}\vartheta\|^2 \\ &= \min_{v \in V} \|\mathbf{Y} - v\|^2 \end{aligned}$$

où  $V = \text{Im}(\mathbb{M}) = \{v \in \mathbb{R}^n : v = \mathbb{M}\vartheta, \vartheta \in \mathbb{R}^k\}$ .  
Projection orthogonale sur  $V$ .

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher



## Géométrie de l'EMC

- L'EMC vérifie

$$\mathbb{M} \hat{\vartheta}_n^{\text{mc}} = P_V \mathbf{Y}$$

où  $P_V$  est le projecteur orthogonal sur  $V$ .

- Mais  $\mathbb{M}^T P_V = \mathbb{M}^T P_V^T = (P_V \mathbb{M})^T = \mathbb{M}^T$ . On en déduit les **équations normales des moindres carrés** :

$$\mathbb{M}^T \mathbb{M} \hat{\vartheta}_n^{\text{mc}} = \mathbb{M}^T \mathbf{Y}.$$

- Remarques.

- L'EMC est un Z-estimateur.
- Pas d'**unicité** de  $\hat{\vartheta}_n^{\text{mc}}$  si la matrice  $\mathbb{M}^T \mathbb{M}$  n'est pas inversible.

◀ ▶ ⏪ ⏩ 🔍 ↺

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

## Géométrie de l'EMC

### Proposition

Si  $\mathbb{M}^T \mathbb{M}$  (matrice  $k \times k$ ) inversible, alors  $\hat{\vartheta}_n^{\text{mc}}$  est **unique** et

$$\hat{\vartheta}_n^{\text{mc}} = (\mathbb{M}^T \mathbb{M})^{-1} \mathbb{M}^T \mathbf{Y}$$

- Contient la droite de régression simple.
- Résultat géométrique, **non stochastique**.

◀ ▶ ⏪ ⏩ 🔍 ↺

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

## Cadre gaussien : loi des estimateurs

- Hyp. 1 :  $\xi \sim \mathcal{N}(0, \sigma^2 \text{Id}_n)$ .
- Hyp. 2 :  $\mathbb{M}^T \mathbb{M} > 0$ .

### Proposition

- (i)  $\hat{\vartheta}_n^{\text{mc}} \sim \mathcal{N}(\vartheta, \sigma^2 (\mathbb{M}^T \mathbb{M})^{-1})$
- (ii)  $\|\mathbf{Y} - \mathbb{M} \hat{\vartheta}_n^{\text{mc}}\|^2 \sim \sigma^2 \chi^2(n - k)$  **loi du Chi 2 à  $n - k$  degrés de liberté**
- (iii)  $\hat{\vartheta}_n^{\text{mc}}$  et  $\mathbf{Y} - \mathbb{M} \hat{\vartheta}_n^{\text{mc}}$  sont **indépendants**.

- Preuve : **Thm. de Cochran** (Poly, page 18). Si  $\xi \sim \mathcal{N}(0, \text{Id}_n)$  et  $A_j$  matrices  $n \times n$  projecteurs t.q.  $A_j A_i = 0$  pour  $i \neq j$ , alors :  $A_j \xi \sim \mathcal{N}(0, A_j)$ , **indépendants**,  $\|A_j \xi\|^2 \sim \chi^2(\text{Rang}(A_j))$ .

◀ ▶ ⏪ ⏩ 🔍 ↺

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

## Propriétés de l'EMC : cadre gaussien

Estimateur de la variance  $\sigma^2$  :

$$\hat{\sigma}_n^2 = \frac{\|\mathbf{Y} - \mathbb{M} \hat{\vartheta}_n^{\text{mc}}\|^2}{n - k} = \frac{1}{n - k} \sum_{i=1}^n (Y_i - (\hat{\vartheta}_n^{\text{mc}})^T \mathbf{x}_i)^2$$

D'après la dernière Proposition :

- $\hat{\sigma}_n^2 / \sigma^2 \sim \chi^2(n - k)$  **loi du Chi 2 à  $n - k$  degrés de liberté**
- C'est un estimateur **sans biais** :

$$\mathbb{E}_\vartheta [\hat{\sigma}_n^2] = \sigma^2.$$

- $\hat{\sigma}_n^2$  est **indépendant** de  $\hat{\vartheta}_n^{\text{mc}}$ .

◀ ▶ ⏪ ⏩ 🔍 ↺

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

## Propriétés de l'EMC : cadre gaussien

- Lois des coordonnées de  $\hat{\vartheta}_n^{mc}$  :

$$(\hat{\vartheta}_n^{mc})_j - \vartheta_j \sim \mathcal{N}(0, \sigma^2 b_j)$$

où  $b_j$  est le  $j$ ème élément diagonal de  $(M^T M)^{-1}$ .

$$\frac{(\hat{\vartheta}_n^{mc})_j - \vartheta_j}{\hat{\sigma}_n \sqrt{b_j}} \sim t_{n-k}$$

loi de Student à  $n - k$  degrés de liberté.

$$t_q = \frac{\xi}{\sqrt{\eta/q}}$$

où  $q \geq 1$  un entier,  $\xi \sim \mathcal{N}(0, 1)$ ,  $\eta \sim \chi^2(q)$  et  $\xi$  indépendant de  $\eta$ .

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

## Exemple de données de régression

### Données de diabète

Patient	age	sex	bmi	map	tc	ldl	hdl	tch	ltg	glu	Response
1	59	2	32.1	101	157	93.2	38	4	4.9	87	151
2	48	1	21.6	87	183	103.2	70	3	3.9	69	75
3	72	2	30.5	93	156	93.6	41	4	4.7	85	141
4	24	1	25.3	84	198	131.4	40	5	4.9	89	206
5	50	1	23.0	101	192	125.4	52	4	4.3	80	135
6	23	1	22.6	89	139	64.8	61	2	4.2	68	97
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
441	36	1	30.0	95	201	125.2	42	5	5.1	82	220
442	36	1	19.6	71	250	132.2	97	3	4.6	92	57

$n=442, k=10$

bmi = Body Mass Index

map = Blood Pressure

tc, ldl, tch, ltg, glu = Blood Serum Measurements

Response  $Y$  = a quantitative measure of disease progression 1 year after baseline

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

## Résultats de traitement statistique initial

	Estimate	Std. Error	t value	Pr(>  t )
(Intercept)	152.133	2.576	59.061	< 2e - 16 * **
age	-10.012	59.749	-0.168	0.867000
sex	-239.819	61.222	-3.917	0.000104 * **
bmi	519.840	66.534	7.813	4.30e - 14 * **
map	324.390	65.422	4.958	1.02e - 06 * **
tc	-792.184	416.684	-1.901	0.057947
ldl	476.746	339.035	1.406	0.160389
hdl	101.045	212.533	0.475	0.634721
tch	177.064	161.476	1.097	0.273456
ltg	751.279	171.902	4.370	1.56e - 05 * **
glu	67.625	65.984	1.025	0.305998

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

## Questions statistiques

- Sélection de variables.** Lesquelles parmi les 10 variables :

age, sex, bmi, map, tc, ldl, hdl, tch, ltg, glu

sont significatives ? Formalisation mathématique : trouver (estimer) l'ensemble  $N = \{j : \vartheta_j \neq 0\}$ .

- Prévison.** Un nouveau patient arrive avec son vecteur des 10 variables  $\mathbf{x}_0 \in \mathbb{R}^{10}$ . Donner la prévison de la réponse  $Y$  = état du patient dans 1 an.

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

## Sélection de variables : Backward Stepwise Regression

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Backward  
Stepwise  
Regression  
LASSO

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

- On se donne un critère d'élimination de variables (**plusieurs choix de critère possibles...**).
- On élimine une variable, la moins significative du point de vue du critère choisi.
- On calcule l'EMC  $\hat{\vartheta}_{n,k-1}^{mc}$  dans le nouveau modèle, avec seulement les  $k - 1$  paramètres restants, ainsi que le RSS :
 
$$RSS_{k-1} = \|\mathbf{Y} - \mathbb{M} \hat{\vartheta}_{n,k-1}^{mc}\|^2.$$
- On continue à éliminer des variables, une par une, jusqu'à la **stabilisation de RSS** :  $RSS_m \approx RSS_{m-1}$ .

◀ ▶ ⏪ ⏩ 🔍 🔄

## Données de diabète : Backward Regression

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Backward  
Stepwise  
Regression  
LASSO

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

### Backward Regression : Itération 2.

Critère d'élimination : plus grande valeur de  $\Pr(> |t|)$ .

	Estimate	Std. Error	t value	$\Pr(>  t )$
(Intercept)	152.133	2.573	59.128	$< 2e - 16$
sex	-240.835	60.853	-3.958	0.000104
bmi	519.905	64.156	5.024	$8.85e - 05$
map	322.306	65.422	4.958	$7.43e - 07$
tc	-790.896	416.144	-1.901	0.058
ldl	474.377	338.358	1.402	0.162
<b>hdl</b>	99.718	212.146	0.470	<b>0.639</b>
tch	177.458	161.277	1.100	0.272
ltg	749.506	171.383	4.373	$1.54e - 05$
glu	67.170	65.336	1.013	0.312

◀ ▶ ⏪ ⏩ 🔍 🔄

## RSS (Residual Sum of Squares)

Modèle de régression

$$Y_i = r(\vartheta, \mathbf{x}_i) + \xi_i, \quad i = 1, \dots, n.$$

- **Résidu** : si  $\hat{\vartheta}_n$  est un estimateur de  $\vartheta$ ,

$$\hat{\xi}_i = Y_i - r(\hat{\vartheta}_n, \mathbf{x}_i) \text{ résidu au point } i.$$

- **RSS** : **Residual Sum of Squares**, somme résiduelle des carrés. Caractérise la qualité d'approximation.

$$RSS(= RSS_{\hat{\vartheta}_n}) = \|\hat{\xi}\|^2 = \sum_{i=1}^n (Y_i - r(\hat{\vartheta}_n, \mathbf{x}_i))^2.$$

- En régression **linéaire** :  $RSS = \|\mathbf{Y} - \mathbb{M} \hat{\vartheta}_n\|^2.$

◀ ▶ ⏪ ⏩ 🔍 🔄

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Backward  
Stepwise  
Regression  
LASSO

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

## Données de diabète : Backward Regression

- **Sélection "naïve"** : {sex, bmi, map, ltg}
- **Sélection par Backward Regression** :  
Critère d'élimination : plus grande valeur de  $\Pr(> |t|)$ .

	Estimate	Std. Error	t value	$\Pr(>  t )$
(Intercept)	152.133	2.576	59.061	$< 2e - 16$ ***
<b>age</b>	-10.012	59.749	-0.168	<b>0.867000</b>
sex	-239.819	61.222	-3.917	0.000104 ***
bmi	519.840	66.534	7.813	$4.30e - 14$ ***
map	324.390	65.422	4.958	$1.02e - 06$ ***
tc	-792.184	416.684	-1.901	0.057947
ldl	476.746	339.035	1.406	0.160389
hdl	101.045	212.533	0.475	0.634721
tch	177.064	161.476	1.097	0.273456
ltg	751.279	171.902	4.370	$1.56e - 05$ ***
glu	67.625	65.984	1.025	0.305998

◀ ▶ ⏪ ⏩ 🔍 🔄

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Backward  
Stepwise  
Regression  
LASSO

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

## Données de diabète : Backward Regression

### Backward Regression : Itération 5 (dernière).

Variables sélectionnées :  
 $\{\text{sex}, \text{bmi}, \text{map}, \text{tc}, \text{ldl}, \text{ltg}\}$

	Estimate	Std. Error	t value	Pr(>  t )
(Intercept)	152.133	2.572	59.159	< 2e - 16
sex	-226.511	59.857	-3.784	0.000176
bmi	529.873	65.620	8.075	6.69e - 15
map	327.220	62.693	5.219	2.79e - 07
tc	-757.938	160.435	-4.724	3.12e - 06
ldl	538.586	146.738	3.670	0.000272
ltg	804.192	80.173	10.031	< 2e - 16

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Backward  
Stepwise  
Regression  
LASSO  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher

◀ ▶ ⏪ ⏩ 🔍 🔄

## Sélection de variables : Backward Regression

Discussion de Backward Regression :

- Méthode de sélection purement empirique, pas de justification théorique.
- Application d'autres critères d'élimination en Backward Regression peut amener aux résultats différents.  
Exemple. Critère  $C_p$  de Mallows-Akaike : on élimine la variable  $j$  qui réalise

$$\min_j \left( \text{RSS}_{m,(-j)} + 2\hat{\sigma}_n^2 m \right).$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Backward  
Stepwise  
Regression  
LASSO  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher

◀ ▶ ⏪ ⏩ 🔍 🔄

## Sélection de variables : LASSO

LASSO = Least Absolute Shrinkage and Selection Operator

- **Estimateur LASSO** : tout estimateur  $\hat{\vartheta}_n^L$  vérifiant

$$\hat{\vartheta}_n^L \in \arg \min_{\vartheta \in \mathbb{R}^k} \left( \sum_{i=1}^n (Y_i - \vartheta^T \mathbf{x}_i)^2 + \lambda \sum_{j=1}^k |\vartheta_j| \right) \text{ avec } \lambda > 0.$$

- Si  $\mathbb{M}^T \mathbb{M} > 0$ , l'estimateur LASSO  $\hat{\vartheta}_n^L$  est unique.
- Estimateur des moindres carrés **pénalisé**. Pénalisation par  $\sum_{j=1}^k |\vartheta_j|$ , la norme  $\ell_1$  de  $\vartheta$ .

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Backward  
Stepwise  
Regression  
LASSO  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher

◀ ▶ ⏪ ⏩ 🔍 🔄

## Sélection de variables : LASSO

- Deux utilisations de LASSO :
  - **Estimation de  $\vartheta$**  : alternative à  $\hat{\vartheta}_n^{\text{mc}}$  si  $k > n$ .
  - **Sélection de variables** : on ne retient que les variables qui correspondent aux coordonnées non-nulles du vecteur  $\hat{\vartheta}_n^L$ .
- LASSO admet une **justification théorique** : sous certaines hypothèses sur la matrice  $\mathbb{M}$ ,

$$\lim_{n \rightarrow \infty} \mathbb{P}\{\hat{N}_n = N\} = 1,$$

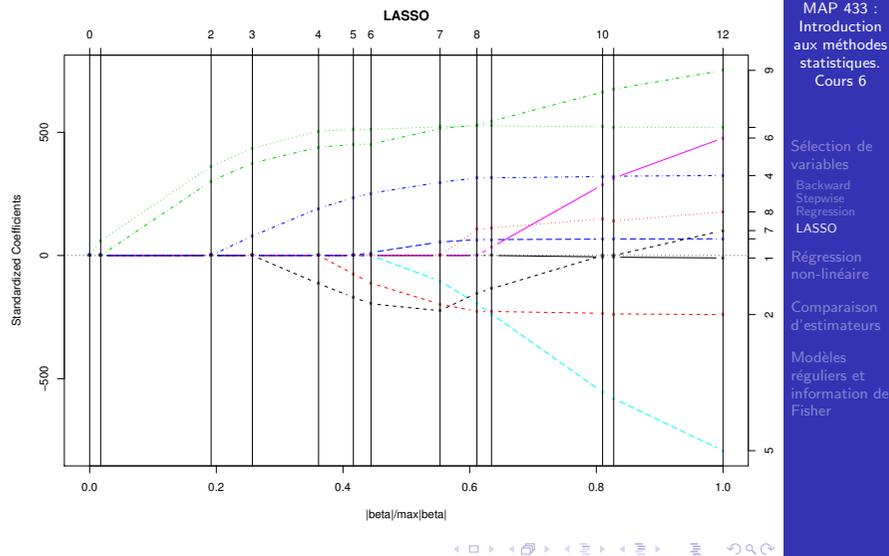
où  $N = \{j : \vartheta_j \neq 0\}$  et  $\hat{N}_n = \{j : \hat{\vartheta}_{n,j}^L \neq 0\}$ .

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Backward  
Stepwise  
Regression  
LASSO  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher

◀ ▶ ⏪ ⏩ 🔍 🔄

## Application de LASSO : "regularization path"



## Données de diabète : LASSO

Application aux données de diabète.

- L'ensemble de variables sélectionné par LASSO :

$\{\text{sex}, \text{bmi}, \text{map}, \text{tc}, \text{hdl}, \text{ltg}, \text{glu}\}$

- Backward Regression :

$\{\text{sex}, \text{bmi}, \text{map}, \text{tc}, \text{ldl}, \text{ltg}\}$

- Sélection naïve :

$\{\text{sex}, \text{bmi}, \text{map}, \text{tc}\}$

## Limites des moindres carrés et du cadre gaussien

- Calcul **explicite** (et efficace) de l'EMC limité à une fonction de régression **linéaire**.
- Modèle linéaire donne un cadre assez général :
  - Modèle polynomial,
  - **Modèles avec interactions...**
- **Hypothèse de gaussianité** = cadre asymptotique implicite.
- Besoin d'outils pour les modèles à réponse **Y discrète**.

## Régression linéaire non-gaussienne

Modèle de régression linéaire

$$Y_i = \vartheta^T \mathbf{x}_i + \xi_i, \quad i = 1, \dots, n.$$

- Hyp. 1' :  $\xi_i$  i.i.d.,  $\mathbb{E}[\xi_i] = 0$ ,  $\mathbb{E}[\xi_i^2] = \sigma^2 > 0$ .
- Hyp. 2' :  $\mathbb{M}^T \mathbb{M} > 0$ ,  $\lim_n \max_{1 \leq i \leq n} \mathbf{x}_i^T (\mathbb{M}^T \mathbb{M})^{-1} \mathbf{x}_i = 0$ .

Proposition (Normalité asymptotique de l'EMC)

$$\sigma^{-1} (\mathbb{M}^T \mathbb{M})^{1/2} (\hat{\vartheta}_n^{\text{mc}} - \vartheta) \xrightarrow{d} \mathcal{N}(0, \text{Id}_k), \quad n \rightarrow \infty.$$

- A comparer avec le cadre gaussien :

$$\sigma^{-1} (\mathbb{M}^T \mathbb{M})^{1/2} (\hat{\vartheta}_n^{\text{mc}} - \vartheta) \sim \mathcal{N}(0, \text{Id}_k) \text{ pour tout } n.$$

## Régression non-linéaire

- On observe

$$(\mathbf{x}_1, Y_1), \dots, (\mathbf{x}_n, Y_n),$$

où

$$Y_i = r(\vartheta, \mathbf{x}_i) + \xi_i, \quad i = 1, \dots, n$$

avec

$$\mathbf{x}_i \in \mathbb{R}^k, \quad \text{et } \vartheta \in \Theta \subset \mathbb{R}^d.$$

- Si  $\xi_i \sim \text{i.i.d. } \mathcal{N}(0, \sigma^2)$ ,

$$\mathcal{L}_n(\vartheta, Y_1, \dots, Y_n) \propto \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (Y_i - r(\vartheta, \mathbf{x}_i))^2\right)$$

et l'estimateur du **maximum de vraisemblance** est obtenu en minimisant la fonction

$$\vartheta \rightsquigarrow \sum_{i=1}^n (Y_i - r(\vartheta, \mathbf{x}_i))^2.$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher



## Moindre carrés non-linéaires

### Définition

- M-estimateur** associé à la **fonction de contraste**  
 $\psi : \Theta \times \mathbb{R}^k \times \mathbb{R} \rightarrow \mathbb{R}$  : tout estimateur  $\hat{\vartheta}_n$  satisfaisant

$$\sum_{i=1}^n \psi(\hat{\vartheta}_n, \mathbf{x}_i, Y_i) = \max_{a \in \Theta} \sum_{i=1}^n \psi(a, \mathbf{x}_i, Y_i).$$

- Estimateur des **moindres carrés non-linéaires** : associé au **contraste**  $\psi(a, \mathbf{x}, y) = -(y - r(a, \mathbf{x}))^2$ .

- Extension** des résultats en densité  $\rightarrow$  théorèmes limites pour des sommes de v.a. indépendantes **non-équidistribuées**.

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher



## Modèle à réponse binaire

- On observe

$$(\mathbf{x}_1, Y_1), \dots, (\mathbf{x}_n, Y_n), \quad Y_i \in \{0, 1\}, \quad \mathbf{x}_i \in \mathbb{R}^k.$$

- Modélisation **via la fonction de régression**

$$\mathbf{x} \rightsquigarrow p_{\mathbf{x}}(\vartheta) = \mathbb{E}_{\vartheta} [Y | \mathbf{X} = \mathbf{x}] = \mathbb{P}_{\vartheta} [Y = 1 | \mathbf{X} = \mathbf{x}]$$

- Représentation**

$$\begin{aligned} Y_i &= p_{\mathbf{x}_i}(\vartheta) + (Y_i - p_{\mathbf{x}_i}(\vartheta)) \\ &= r(\vartheta, \mathbf{x}_i) + \xi_i \end{aligned}$$

avec  $r(\vartheta, \mathbf{x}_i) = p_{\mathbf{x}_i}(\vartheta)$  et  $\xi_i = Y_i - p_{\mathbf{x}_i}(\vartheta)$ .

- $\mathbb{E}_{\vartheta} [\xi_i] = 0$  mais structure des  $\xi_i$  **compliquée** (dépendance en  $\vartheta$ ).

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher



## Modèle à réponse discrète

- $Y_i$  v.a. de Bernoulli de paramètre  $p_{\mathbf{x}_i}(\vartheta)$ .  
**Vraisemblance**

$$\mathcal{L}_n(\vartheta, Y_1, \dots, Y_n) = \prod_{i=1}^n p_{\mathbf{x}_i}(\vartheta)^{Y_i} (1 - p_{\mathbf{x}_i}(\vartheta))^{1 - Y_i}$$

$\rightarrow$  méthodes de résolution numérique.

- Régression logistique** (très utile dans les applications)

$$p_{\mathbf{x}}(\vartheta) = \psi(\mathbf{x}^T \vartheta),$$

$$\psi(t) = \frac{e^t}{1 + e^t}, \quad t \in \mathbb{R} \quad \text{fonction logistique.}$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher



## Régression logistique et modèles latents

- **Représentation équivalente de la régression logistique** : on observe

$$Y_i = 1_{\{Y_i^* > 0\}}, \quad i = 1, \dots, n$$

(les  $\mathbf{x}_i$  sont donnés), et  $Y_i^*$  est une **variable latente** ou cachée,

$$Y_i^* = \vartheta^T \mathbf{x}_i + U_i, \quad i = 1, \dots, n$$

avec  $U_i \sim \text{i.i.d. } F$ , où

$$F(t) = \frac{1}{1 + e^{-t}}, \quad t \in \mathbb{R}.$$

- $$\begin{aligned} \mathbb{P}_\vartheta [Y_i^* > 0] &= \mathbb{P}_\vartheta [\mathbf{x}_i^T \vartheta + U_i > 0] \\ &= 1 - \mathbb{P}_\vartheta [U_i \leq -\mathbf{x}_i^T \vartheta] \\ &= 1 - (1 + \exp(-\mathbf{x}_i^T \vartheta))^{-1} = \psi(\mathbf{x}_i^T \vartheta). \end{aligned}$$

MAP 433 :  
Introduction aux méthodes statistiques.  
Cours 6

Sélection de variables

Régression non-linéaire

Comparaison d'estimateurs

Modèles réguliers et information de Fisher

## Bilan provisoire : modèles paramétriques dominés

- **Modèle de densité** : on observe

$$X_1, \dots, X_n \sim \text{i.i.d. } \mathbb{P}_\vartheta, \quad \vartheta \in \Theta \subset \mathbb{R}^d.$$

**Estimateurs** : moments, Z- et M-estimateurs, **EMV**.

- **Modèle de régression** : on observe

$$Y_i = r(\vartheta, \mathbf{x}_i) + \xi_i, \quad i = 1, \dots, n, \quad \xi_i \text{ i.i.d.}, \quad \vartheta \in \Theta \subset \mathbb{R}^d.$$

**Estimateurs** :

- Si  $r(\vartheta, \mathbf{x}) = \mathbf{x} \vartheta^T$ , EMC (coincide avec l'**EMV** si les  $\xi_i$  gaussiens)
- Sinon, M-estimateurs, **EMV**...
- Autres méthodes selon des **hypothèses** sur le « design »...

MAP 433 :  
Introduction aux méthodes statistiques.  
Cours 6

Sélection de variables

Régression non-linéaire

Comparaison d'estimateurs

Risque et admissibilité  
Approche asymptotique

Modèles réguliers et information de Fisher

$\hat{\vartheta}_n$  estimateur de  $\vartheta$  : **précision, qualité** de  $\hat{\vartheta}_n$ ? En pratique, on a « souvent »

- une information **non-asymptotique** de type

$$\mathbb{E} [\|\hat{\vartheta}_n - \vartheta\|^2] \leq c_n(\vartheta)^2,$$

- ou bien **asymptotique** de type

$$v_n(\hat{\vartheta}_n - \vartheta) \xrightarrow{d} Z_\vartheta, \quad v_n \rightarrow \infty.$$

Permet « souvent » de construire un(e) région-intervalle de confiance...

MAP 433 :  
Introduction aux méthodes statistiques.  
Cours 6

Sélection de variables

Régression non-linéaire

Comparaison d'estimateurs

Risque et admissibilité  
Approche asymptotique

Modèles réguliers et information de Fisher

## Région-intervalle de confiance : définition formelle

$\{\mathbb{P}_\vartheta^n, \vartheta \in \Theta\}$ ,  $\Theta \subset \mathbb{R}^d$ , engendrée par l'observation  $Z^{(n)}$ .

- **Densité** :  $Z^{(n)} = (X_1, \dots, X_n)$ ,  $\mathbb{P}_\vartheta^n = \mathbb{P}_\vartheta \otimes \dots \otimes \mathbb{P}_\vartheta$
- **Régression** (à design déterministe) :  $Z^{(n)} = (Y_1, \dots, Y_n)$ ,  $\mathbb{P}_\vartheta^n = \mathbb{P}_{\vartheta, \mathbf{x}_1} \otimes \dots \otimes \mathbb{P}_{\vartheta, \mathbf{x}_n}$ , où  $\mathbb{P}_{\vartheta, \mathbf{x}_i}$  loi de  $Y_i = r(\vartheta, \mathbf{x}_i) + \xi_i$ .

### Définition

**Région de confiance** de niveau  $1 - \alpha$ ,  $\alpha \in (0, 1)$ , (resp. **asymptotiquement de niveau  $\alpha$** ) : sous-ensemble **observable**  $\mathcal{C}_{n, \alpha}(Z^{(n)})$  de  $\mathbb{R}^d$  t.q.

$$\forall \vartheta \in \Theta : \mathbb{P}_\vartheta^n [\vartheta \in \mathcal{C}_{n, \alpha}(Z^{(n)})] \geq 1 - \alpha$$

resp.

$$\forall \vartheta \in \Theta : \liminf_{n \rightarrow \infty} \mathbb{P}_\vartheta^n [\vartheta \in \mathcal{C}_{n, \alpha}(Z^{(n)})] \geq 1 - \alpha.$$

MAP 433 :  
Introduction aux méthodes statistiques.  
Cours 6

Sélection de variables

Régression non-linéaire

Comparaison d'estimateurs

Risque et admissibilité  
Approche asymptotique

Modèles réguliers et information de Fisher

## Comparaison d'estimateurs

Etant donné  $\{\mathbb{P}_{\vartheta}^n, \vartheta \in \Theta\}$  comment **construire** le **meilleur** estimateur ? Dans quel sens ?

- **Intuitivement** :  $\hat{\vartheta}_n$  fournit une précision optimale si on peut lui associer une région de confiance de longueur (moyenne) minimale.
- Différence entre point de vue **asymptotique** et **non-asymptotique**.
- **Dans ce cours**, nous étudions les deux points de vue sous un angle –un peu réducteur– particulier :
  - **Non-asymptotique** : contrôle du **risque quadratique**
  - **Asymptotique** : comparaison des estimateurs **asymptotiquement normaux**.

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Risque et  
admissibilité  
Approche  
asymptotique  
Modèles  
réguliers et  
information de  
Fisher



## Risque quadratique, admissibilité

**Situation** :  $\hat{\vartheta}_{n,i} = \hat{\vartheta}_{n,i}(Z^{(n)})$ ,  $i = 1, 2$  deux estimateurs basés sur l'observation  $Z^{(n)}$  qui engendre l'expérience  $\{\mathbb{P}_{\vartheta}^n, \vartheta \in \Theta\}$ ,  $\Theta \subset \mathbb{R}^1$ .

### Définition

**Risque quadratique de l'estimateur**  $\hat{\vartheta}_n$  au point  $\vartheta \in \Theta$  :

$$\mathcal{R}(\hat{\vartheta}_n, \vartheta) = \mathbb{E}_{\vartheta}^n [(\hat{\vartheta}_n - \vartheta)^2].$$

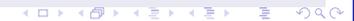
### Définition

L'estimateur  $\hat{\vartheta}_{n,1}$  est **préférable** – au sens du risque quadratique – à l'estimateur  $\hat{\vartheta}_{n,2}$  si

$$\forall \vartheta \in \Theta, \mathcal{R}(\hat{\vartheta}_{n,1}, \vartheta) \leq \mathcal{R}(\hat{\vartheta}_{n,2}, \vartheta).$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Risque et  
admissibilité  
Approche  
asymptotique  
Modèles  
réguliers et  
information de  
Fisher



## Absence d'optimalité

- Existe-t-il un estimateur **optimal**  $\vartheta_n^*$  au sens où

$$\forall \vartheta \in \Theta, \mathcal{R}(\vartheta_n^*, \vartheta) \leq \inf_{\hat{\vartheta}_n} \mathcal{R}(\hat{\vartheta}_n, \vartheta) ?$$

- Si  $\Theta = \{\vartheta_1, \vartheta_2\}$  et **s'il n'existe pas d'événement** observable  $A$  tel que, **simultanément** :

$$\mathbb{P}_{\vartheta_1}^n [A] = 0 \text{ et } \mathbb{P}_{\vartheta_2}^n [A] = 1,$$

(on dit que  $\mathbb{P}_{\vartheta_1}^n$  et  $\mathbb{P}_{\vartheta_2}^n$  ne sont **pas étrangères**), alors **il n'existe pas d'estimateur optimal**.

- Condition suffisante pour que  $\mathbb{P}_{\vartheta_1}^n$  et  $\mathbb{P}_{\vartheta_2}^n$  ne soient pas étrangères :  $\mathbb{P}_{\vartheta_1}^n \ll \mathbb{P}_{\vartheta_2}^n$  et  $\mathbb{P}_{\vartheta_2}^n \ll \mathbb{P}_{\vartheta_1}^n$ .

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Risque et  
admissibilité  
Approche  
asymptotique  
Modèles  
réguliers et  
information de  
Fisher



## Absence d'optimalité (cont.)

- **Preuve** : Pour tout estimateur  $\vartheta_n^*$ , on a

$$\max \{ \mathcal{R}(\vartheta_n^*, \vartheta_1), \mathcal{R}(\vartheta_n^*, \vartheta_2) \} > 0 \quad (*)$$

- Supposons  $\vartheta_n^*$  estimateur optimal et  $\mathcal{R}(\vartheta_n^*, \vartheta_1) > 0$ . Alors  $\hat{\vartheta}_n^{\text{trivial}} := \vartheta_1$  vérifie

$$0 = \mathcal{R}(\hat{\vartheta}_n^{\text{trivial}}, \vartheta_1) < \mathcal{R}(\vartheta_n^*, \vartheta_1) \quad \text{contradiction !}$$

et contredit l'optimalité de  $\vartheta_n^*$ .

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Risque et  
admissibilité  
Approche  
asymptotique  
Modèles  
réguliers et  
information de  
Fisher



## Notions d'optimalité

- **Différentes notions existent.** Deux exemples extrêmes :

### Définition (Admissibilité et critère minimax)

- Un estimateur  $\vartheta_n^*$  est **admissible** s'il n'existe pas d'estimateur  $\hat{\vartheta}_n$  **préférable** à  $\vartheta_n^*$  tel que, pour un point  $\vartheta_0 \in \Theta$

$$\mathcal{R}(\hat{\vartheta}_n, \vartheta_0) < \mathcal{R}(\vartheta_n^*, \vartheta_0).$$

- Un estimateur  $\vartheta_n^*$  est **minimax** si

$$\sup_{\vartheta \in \Theta} \mathcal{R}(\vartheta_n^*, \vartheta) = \inf_{\hat{\vartheta}_n} \sup_{\vartheta \in \Theta} \mathcal{R}(\hat{\vartheta}_n, \vartheta).$$

- **Admissibilité** : permet d'éliminer des estimateurs absurdes (mais pas tous).
- **Minimaxité** : notion très **robuste mais conservatrice**, à suivre...

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Risque et  
admissibilité  
Approche  
asymptotique  
Modèles  
réguliers et  
information de  
Fisher

## Absence d'optimalité (fin.)

- Preuve de (\*) : si  $\mathcal{R}(\vartheta_n^*, \vartheta_1) = \mathcal{R}(\vartheta_n^*, \vartheta_2) = 0$ , alors

$$\vartheta_n^* = \vartheta_1 \mathbb{P}_{\vartheta_1}^n - \text{p.s.} \quad \text{et} \quad \vartheta_n^* = \vartheta_2 \mathbb{P}_{\vartheta_2}^n - \text{p.s.}$$

Soient  $A = \{\omega, \vartheta_n^*(\omega) = \vartheta_1\}$  et  $B = \{\omega, \vartheta_n^*(\omega) = \vartheta_2\}$ .  
Alors  $\mathbb{P}_{\vartheta_1}^n[A] = 1$  et donc  $\mathbb{P}_{\vartheta_2}^n[A] > 0$ . Aussi,  $\mathbb{P}_{\vartheta_2}^n[B] = 1$ .  
Donc  $A \cap B \neq \emptyset$ . Il existe  $\omega_0$  tel que  $\vartheta_1 = \vartheta_n^*(\omega_0) = \vartheta_2$   
**contradiction !**

- **Attention !** La propriété  $\mathbb{P}_{\vartheta_1}^n$  et  $\mathbb{P}_{\vartheta_2}^n$  non étrangères est **minimale**. Mais elle disparaît en général lorsque  $n \rightarrow \infty$ .

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Risque et  
admissibilité  
Approche  
asymptotique  
Modèles  
réguliers et  
information de  
Fisher

## Comparaison d'estimateurs : cas asymptotique

- Si  $v_1(\vartheta) < v_2(\vartheta)$ , et si  $\vartheta \rightsquigarrow v_i(\vartheta)$  est continue, on pose

$$\mathcal{C}_{n,\alpha}(\hat{\vartheta}_{n,i}) = \left[ \hat{\vartheta}_{n,i} \pm \sqrt{\frac{v_i(\hat{\vartheta}_{n,i})}{n}} \Phi^{-1}(1 - \alpha/2) \right], \quad i = 1, 2$$

où  $\alpha \in (0, 1)$  et  $\Phi(\cdot)$  est la fonction de répartition de la loi normale standard.

- $\mathcal{C}_{n,\alpha}(\hat{\vartheta}_{n,i})$ ,  $i = 1, 2$  sont deux **intervalles de confiance asymptotiquement de niveau  $1 - \alpha$**  et on a

$$\frac{|\mathcal{C}_{n,\alpha}(\hat{\vartheta}_{n,1})|}{|\mathcal{C}_{n,\alpha}(\hat{\vartheta}_{n,2})|} \xrightarrow{\mathbb{P}_{\vartheta}^n} \sqrt{\frac{v_1(\vartheta)}{v_2(\vartheta)}} < 1.$$

- La notion de **longueur minimale possible d'un intervalle de confiance** est en général difficile à manipuler.

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Risque et  
admissibilité  
Approche  
asymptotique  
Modèles  
réguliers et  
information de  
Fisher

## Approche asymptotique

- Hypothèse simplificatrice :  $\vartheta \in \Theta \subset \mathbb{R}$ . On se restreint aux **estimateurs asymptotiquement normaux** c'est-à-dire vérifiant

$$\sqrt{n}(\hat{\vartheta}_n - \vartheta) \xrightarrow{d} \mathcal{N}(0, v(\vartheta))$$

cf. théorèmes limites obtenus pour les  $Z$ -,  $M$ -estimateurs.

- Si  $\hat{\vartheta}_{n,1}$  et  $\hat{\vartheta}_{n,2}$  as. normaux de variance asymptotique  $v_1(\vartheta) \leq v_2(\vartheta)$ , alors la précision de  $\hat{\vartheta}_{n,1}$  est **asymptotiquement meilleure** que celle de  $\hat{\vartheta}_{n,2}$  au point  $\vartheta$  :

$$\hat{\vartheta}_{n,1} = \vartheta + \sqrt{\frac{v_1(\vartheta)}{n}} \xi^{(n)}$$

$$\hat{\vartheta}_{n,2} = \vartheta + \sqrt{\frac{v_2(\vartheta)}{n}} \zeta^{(n)}$$

où  $\xi^{(n)}$  et  $\zeta^{(n)} \xrightarrow{d} \mathcal{N}(0, 1)$ .

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Risque et  
admissibilité  
Approche  
asymptotique  
Modèles  
réguliers et  
information de  
Fisher

## Conclusion provisoire

- Il est **difficile en général** de comparer des estimateurs.
- Cadre asymptotique + normalité asymptotique → comparaison de la **variance asymptotique**  $\vartheta \rightsquigarrow v(\vartheta)$ .
- Sous des hypothèses de régularité du modèle  $\{\mathbb{P}_\vartheta^n, \vartheta \in \Theta\}$  alors
  - Il **existe** une variance asymptotique  $v^*(\vartheta)$  **minimale** parmi les variances de la classe des  $M$ -estimateurs as. normaux.
  - Cette fonction est associée à une **quantité d'information intrinsèque** au modèle.
  - La variance asymptotique de l'**EMV** est  $v^*(\vartheta)$ .
- Ceci règle **partiellement** le problème de l'optimalité.

MAP 433 :  
Introduction aux méthodes statistiques.  
Cours 6

Sélection de variables

Régression non-linéaire

Comparaison d'estimateurs

Risque et admissibilité  
Approche asymptotique

Modèles réguliers et information de Fisher

◀ ▶ ⏪ ⏩ 🔍 🔄

## Régularité d'un modèle statistique et information

- Cadre simplificateur : modèle de densité

$$X_1, \dots, X_n \text{ i.i.d. de loi } \mathbb{P}_\vartheta$$

dans la famille  $\{\mathbb{P}_\vartheta, \vartheta \in \Theta\}$  avec  $\Theta \subset \mathbb{R}$  pour simplifier.

- Notation :

$$f(\vartheta, x) = \frac{d\mathbb{P}_\vartheta}{d\mu}(x), \quad x \in \mathbb{R}, \vartheta \in \Theta.$$

- Hypothèse : la quantité

$$\mathbb{I}(\vartheta) = \mathbb{E}_\vartheta [(\partial_\vartheta \log f(\vartheta, X))^2]$$

est bien définie.

MAP 433 :  
Introduction aux méthodes statistiques.  
Cours 6

Sélection de variables

Régression non-linéaire

Comparaison d'estimateurs

Modèles réguliers et information de Fisher

Construction de l'information de Fisher  
Modèle régulier  
Cadre général et interprétation géométrique  
Exemples, applications

◀ ▶ ⏪ ⏩ 🔍 🔄

## Information de Fisher

### Définition

- $\mathbb{I}(\vartheta) = \mathbb{E}_\vartheta [(\partial_\vartheta \log f(\vartheta, X))^2]$  s'appelle **l'information de Fisher** de la famille  $\{\mathbb{P}_\vartheta, \vartheta \in \Theta\}$  au point  $\vartheta$ . Elle ne dépend pas de la mesure dominante  $\mu$ .
- Le cadre d'intérêt est celui où
$$0 < \mathbb{I}(\vartheta) < +\infty.$$
- $\mathbb{I}(\vartheta)$  quantifie « l'information » qu'apporte chaque observation  $X_i$  sur le paramètre  $\vartheta$ .

Remarque : on a  $\mathbb{P}_\vartheta [f(\vartheta, X) > 0] = 1$ , donc la quantité  $\log f(\vartheta, X)$  est bien définie.

MAP 433 :  
Introduction aux méthodes statistiques.  
Cours 6

Sélection de variables

Régression non-linéaire

Comparaison d'estimateurs

Modèles réguliers et information de Fisher

Construction de l'information de Fisher

Modèle régulier  
Cadre général et interprétation géométrique  
Exemples, applications

◀ ▶ ⏪ ⏩ 🔍 🔄

## Information dans quel sens? Origine de la notion

- Supposons l'EMV  $\hat{\vartheta}_n^{mv}$  bien défini et **convergent**.
- Supposons l'application  $(\vartheta, x) \rightsquigarrow f(\vartheta, x)$  possédant **toutes les propriétés de régularité et d'intégrabilité** voulues.
- Alors

$$\sqrt{n}(\hat{\vartheta}_n^{mv} - \vartheta) \xrightarrow{d} \mathcal{N}\left(0, \frac{1}{\mathbb{I}(\vartheta)}\right)$$

en loi sous  $\mathbb{P}_\vartheta$ , où encore

$$\hat{\vartheta}_n^{mv} \stackrel{d}{\approx} \vartheta + \frac{1}{\sqrt{n\mathbb{I}(\vartheta)}} \mathcal{N}(0, 1)$$

en loi sous  $\mathbb{P}_\vartheta$ .

MAP 433 :  
Introduction aux méthodes statistiques.  
Cours 6

Sélection de variables

Régression non-linéaire

Comparaison d'estimateurs

Modèles réguliers et information de Fisher

Construction de l'information de Fisher

Modèle régulier  
Cadre général et interprétation géométrique  
Exemples, applications

◀ ▶ ⏪ ⏩ 🔍 🔄

## Construction de l'information + jeu d'hypothèses attendant

- Heuristique : on établira un jeu d'hypothèses justifiant **a posteriori** le raisonnement.
- Etape 1 : l'EMV  $\hat{\vartheta}_n^{mv}$  **converge** :

$$\hat{\vartheta}_n^{mv} \xrightarrow{\mathbb{P}_\vartheta} \vartheta$$

via le théorème de convergence des  $M$ -estimateurs.

- Etape 2 : l'EMV  $\hat{\vartheta}_n^{mv}$  est un **Z-estimateur** :

$$0 = \partial_\vartheta \left( \sum_{i=1}^n \log f(\vartheta, X_i) \right)_{\vartheta = \hat{\vartheta}_n^{mv}}.$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher  
Construction de  
l'information de  
Fisher  
Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications



## Construction de $\mathbb{I}(\vartheta)$ cont.

- Etape 3 : développement asymptotique **autour de  $\vartheta$**  :

$$0 \approx \sum_{i=1}^n \partial_\vartheta \log f(\vartheta, X_i) + (\hat{\vartheta}_n^{mv} - \vartheta) \sum_{i=1}^n \partial_\vartheta^2 \log f(\vartheta, X_i),$$

soit

$$\hat{\vartheta}_n^{mv} - \vartheta \approx - \frac{\sum_{i=1}^n \partial_\vartheta \log f(\vartheta, X_i)}{\sum_{i=1}^n \partial_\vartheta^2 \log f(\vartheta, X_i)}$$

- Etape 4 : le numérateur. Normalisation et convergence de  $\frac{\sum_{i=1}^n \partial_\vartheta \log f(\vartheta, X_i)}{\sum_{i=1}^n \partial_\vartheta^2 \log f(\vartheta, X_i)}$  ?

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher  
Construction de  
l'information de  
Fisher  
Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications



## Numérateur

### Lemme

On a

$$\mathbb{E}_\vartheta [\partial_\vartheta \log f(\vartheta, X)] = 0.$$

### Preuve.

$$\begin{aligned} \mathbb{E}_\vartheta [\partial_\vartheta \log f(\vartheta, X)] &= \int_{\mathbb{R}} \partial_\vartheta \log f(\vartheta, x) f(\vartheta, x) \mu(dx) \\ &= \int_{\mathbb{R}} \frac{\partial_\vartheta f(\vartheta, x)}{f(\vartheta, x)} f(\vartheta, x) \mu(dx) \\ &= \int_{\mathbb{R}} \partial_\vartheta f(\vartheta, x) \mu(dx) \\ &= \partial_\vartheta \int_{\mathbb{R}} f(\vartheta, x) \mu(dx) = \partial_\vartheta 1 = 0. \end{aligned}$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher  
Construction de  
l'information de  
Fisher  
Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications



## Dénominateur

De même  $\int_{\mathbb{R}} \partial_\vartheta^2 f(\vartheta, x) \mu(dx) = 0$ . **Conséquence** :

$$\mathbb{I}(\vartheta) = \mathbb{E}_\vartheta [(\partial_\vartheta \log f(\vartheta, X))^2] = - \mathbb{E}_\vartheta [\partial_\vartheta^2 \log f(\vartheta, X)]$$

En effet

$$\begin{aligned} &\mathbb{E}_\vartheta [\partial_\vartheta^2 \log f(\vartheta, X)] \\ &= \int_{\mathbb{R}} \frac{\partial_\vartheta^2 f(\vartheta, x) f(\vartheta, x) - (\partial_\vartheta f(\vartheta, x))^2}{f(\vartheta, x)^2} f(\vartheta, x) \mu(dx) \\ &= \int_{\mathbb{R}} \partial_\vartheta^2 f(\vartheta, x) \mu(dx) - \int_{\mathbb{R}} \frac{(\partial_\vartheta f(\vartheta, x))^2}{f(\vartheta, x)} \mu(dx) \\ &= 0 - \int_{\mathbb{R}} \left( \frac{\partial_\vartheta f(\vartheta, x)}{f(\vartheta, x)} \right)^2 f(\vartheta, x) \mu(dx) = - \mathbb{E} [(\partial_\vartheta \log f(\vartheta, X))^2]. \end{aligned}$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables  
Régression  
non-linéaire  
Comparaison  
d'estimateurs  
Modèles  
réguliers et  
information de  
Fisher  
Construction de  
l'information de  
Fisher  
Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications



## Conséquences

- Les  $\partial_{\vartheta} \log f(\vartheta, X_i)$  sont i.i.d. et  $\mathbb{E}_{\vartheta} [\partial_{\vartheta} \log f(\vartheta, X)] = 0$ .  
TCL :

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n \partial_{\vartheta} \log f(\vartheta, X_i) \xrightarrow{d} \mathcal{N}(0, \mathbb{E}_{\vartheta} [(\partial_{\vartheta} \log f(\vartheta, X))^2]) \\ = \mathcal{N}(0, \mathbb{I}(\vartheta)).$$

- Les  $\partial_{\vartheta}^2 \log f(\vartheta, X_i)$  sont i.i.d. LGN :

$$\frac{1}{n} \sum_{i=1}^n \partial_{\vartheta}^2 \log f(\vartheta, X_i) \xrightarrow{\mathbb{P}_{\vartheta}} \mathbb{E}_{\vartheta} [\partial_{\vartheta}^2 \log f(\vartheta, X)] \\ \stackrel{\text{conséquence}}{=} -\mathbb{I}(\vartheta).$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications

◀ ▶ ⏪ ⏩ 🔍 ↺

## Conclusion

- En combinant les deux estimations + lemme de Slutsky :

$$\sqrt{n}(\hat{\vartheta}_n^{\text{mv}} - \vartheta) \approx -\frac{\frac{1}{\sqrt{n}} \sum_{i=1}^n \partial_{\vartheta} \log f(\vartheta, X_i)}{\frac{1}{n} \sum_{i=1}^n \partial_{\vartheta}^2 \log f(\vartheta, X_i)} \\ \xrightarrow{d} \frac{\mathcal{N}(0, \mathbb{I}(\vartheta))}{\mathbb{I}(\vartheta)} \\ \stackrel{\text{loi}}{=} \mathcal{N}\left(0, \frac{1}{\mathbb{I}(\vartheta)}\right).$$

- Le raisonnement est **rigoureux dès lors que** : i) on a la convergence de  $\hat{\vartheta}_n^{\text{mv}}$ , ii) on peut justifier le lemme et sa conséquence, iii)  $\mathbb{I}(\vartheta)$  est bien définie et non dégénérée et iv) on sait contrôler le terme de reste dans le développement asymptotique, **partie la plus difficile**.

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications

◀ ▶ ⏪ ⏩ 🔍 ↺

## Modèle régulier

### Définition

La famille de densités  $\{f(\vartheta, \cdot), \vartheta \in \Theta\}$ , par rapport à la mesure dominante  $\mu$ ,  $\Theta \subset \mathbb{R}$ , est **régulière** si

- $\Theta$  ouvert et  $\{f(\vartheta, \cdot) > 0\} = \{f(\vartheta', \cdot) > 0\}$ ,  $\forall \vartheta, \vartheta' \in \Theta$ .
- $\mu$ -p.p.  $\vartheta \rightsquigarrow f(\vartheta, \cdot)$ ,  $\vartheta \rightsquigarrow \log f(\vartheta, \cdot)$  sont  $\mathcal{C}^2$ .
- $\forall \vartheta \in \Theta, \exists \mathcal{V}_{\vartheta} \subset \Theta$  t.q. pour  $a \in \mathcal{V}_{\vartheta}$

$$|\partial_a^2 \log f(a, x)| + |\partial_a \log f(a, x)| + (\partial_a \log f(a, x))^2 \leq g(x)$$

où

$$\int_{\mathbb{R}} g(x) \sup_{a \in \mathcal{V}(\vartheta)} f(a, x) \mu(dx) < +\infty.$$

- L'information de Fisher est non-dégénérée :

$$\forall \vartheta \in \Theta, \mathbb{I}(\vartheta) > 0.$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications

↺

## Résultat principal

### Proposition

- Si l'expérience engendrée par l'observation  $X_1, \dots, X_n \sim \text{i.i.d. } \mathbb{P}_{\vartheta}$  est associée à une famille de probabilités  $\{\mathbb{P}_{\vartheta}, \vartheta \in \Theta\}$  sur  $\mathbb{R}$  **régulière** au sens de la définition précédente, alors

$$\sqrt{n}(\hat{\vartheta}_n^{\text{mv}} - \vartheta) \xrightarrow{d} \mathcal{N}\left(0, \frac{1}{\mathbb{I}(\vartheta)}\right).$$

- Si  $\hat{\vartheta}_n$  est un Z-estimateur **régulier** asymptotiquement normal de variance  $v(\vartheta)$ , alors

$$\forall \vartheta \in \Theta, v(\vartheta) \geq \frac{1}{\mathbb{I}(\vartheta)}.$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications

◀ ▶ ⏪ ⏩ 🔍 ↺

## Preuve de la proposition

- Le premier point consiste à **rendre rigoureux** le raisonnement précédent. **Point délicat** : le contrôle du terme de reste.
- Optimalité de la variance de l'EMV parmi celle des Z-estimateurs** : on a vu que si  $\hat{\vartheta}_n$  est un Z-estimateur régulier associé à la fonction  $\phi$ , alors, sa variance asymptotique  $v(\vartheta) = v_\phi(\vartheta)$  vaut

$$v_\phi(\vartheta) = \frac{\mathbb{E}_\vartheta [\phi(\vartheta, X)^2]}{(\mathbb{E}_\vartheta [\partial_\vartheta \phi(\vartheta, X)])^2}.$$

- A montrer** : pour toute fonction  $\phi$  :

$$\frac{\mathbb{E}_\vartheta [\phi(\vartheta, X)^2]}{(\mathbb{E}_\vartheta [\partial_\vartheta \phi(\vartheta, X)])^2} \geq \frac{1}{\mathbb{I}(\vartheta)}.$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications

◀ ▶ ⏪ ⏩ 🔍

## Preuve de l'inégalité

- Par construction

$$\partial_a \mathbb{E}_\vartheta [\phi(a, X)] \Big|_{a=\vartheta} = 0.$$

- (avec  $\dot{\phi}(\vartheta, x) = \partial_\vartheta \phi(\vartheta, x)$ )

$$\begin{aligned} 0 &= \int_{\mathbb{R}} [\dot{\phi}(\vartheta, x) f(\vartheta, x) + \phi(\vartheta, x) \partial_\vartheta f(\vartheta, x)] \mu(dx) \\ &= \int_{\mathbb{R}} [\dot{\phi}(\vartheta, x) f(\vartheta, x) + \phi(\vartheta, x) \partial_\vartheta \log f(\vartheta, x) f(\vartheta, x)] \mu(dx). \end{aligned}$$

- Conclusion**

$$\mathbb{E}_\vartheta [\dot{\phi}(\vartheta, X)] = -\mathbb{E}_\vartheta [\phi(\vartheta, X) \partial_\vartheta \log f(\vartheta, X)]$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications

◀ ▶ ⏪ ⏩ 🔍

## Preuve de l'inégalité (fin)

- On a

$$\mathbb{E}_\vartheta [\dot{\phi}(\vartheta, X)] = -\mathbb{E}_\vartheta [\phi(\vartheta, X) \partial_\vartheta \log f(\vartheta, X)]$$

- Cauchy-Schwarz** :

$$(\mathbb{E}_\vartheta [\dot{\phi}(\vartheta, X)])^2 \leq \mathbb{E}_\vartheta [\phi(\vartheta, X)^2] \mathbb{E}_\vartheta [(\partial_\vartheta \log f(\vartheta, X))^2],$$

c'est-à-dire

$$v_\phi(\vartheta)^{-1} = \frac{(\mathbb{E}_\vartheta [\dot{\phi}(\vartheta, X)])^2}{\mathbb{E}_\vartheta [\phi(\vartheta, X)^2]} \leq \mathbb{I}(\vartheta).$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications

◀ ▶ ⏪ ⏩ 🔍

## Information de Fisher dans un modèle général

### Définition

- Situation** : suite d'expériences statistiques

$$\mathcal{E}^n = (\mathfrak{Z}^n, \mathcal{Z}^n, \{\mathbb{P}_\vartheta^n, \vartheta \in \Theta\})$$

dominées par  $\mu_n$ , associées à l'observation  $Z^{(n)}$ ,

$$f_n(\vartheta, z) = \frac{d\mathbb{P}_\vartheta^n}{d\mu^n}(z), \quad z \in \mathfrak{Z}^n, \vartheta \in \Theta \subset \mathbb{R}.$$

- Information de Fisher** (si elle existe) de l'expérience au point  $\vartheta$  :

$$\mathbb{I}(\vartheta | \mathcal{E}_n) = \mathbb{E}_\vartheta^n [(\partial_\vartheta \log f_n(\vartheta, Z^{(n)}))^2]$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications

◀ ▶ ⏪ ⏩ 🔍

## Le cas multidimensionnel

- **Même contexte** que précédemment, avec  $\Theta \subset \mathbb{R}^d$ , et  $d \geq 1$ .
- **Matrice d'information de Fisher**

$$\mathbb{I}(\vartheta) = \mathbb{E}_{\vartheta} [\nabla_{\vartheta} \log f(\vartheta, Z^n) \nabla_{\vartheta} \log f(\vartheta, Z^n)^T]$$

**matrice symétrique positive.**

- Si  $\mathbb{I}(\vartheta)$  définie et si  $\mathcal{E}^n$  **modèle de densité**, en généralisant à la dimension  $d$  les conditions de régularité, on a

$$\sqrt{n}(\hat{\vartheta}_n^{\text{mv}} - \vartheta) \xrightarrow{d} \mathcal{N}(0, \mathbb{I}(\vartheta)^{-1}).$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications



## Interprétation géométrique

- On pose  $\mathbb{D}(a, \vartheta) = \mathbb{E}_{\vartheta} [\log f(a, X)]$ . On a vu (inégalité d'entropie) que

$$\begin{aligned} \mathbb{D}(a, \vartheta) &= \int_{\mathbb{R}} \log f(a, x) f(\vartheta, x) \mu(dx) \\ &\leq \int_{\mathbb{R}} \log f(\vartheta, x) f(\vartheta, x) \mu(dx) = \mathbb{D}(\vartheta, \vartheta). \end{aligned}$$

- On a

$$\mathbb{I}(\vartheta) = \partial_a^2 \mathbb{D}(a, \vartheta) \Big|_{a=\vartheta}.$$

- Si  $\mathbb{I}(\vartheta)$  est « petite », le **rayon de courbure de  $a \rightsquigarrow \mathbb{D}(a, \vartheta)$  est grand** dans un voisinage de  $\vartheta$  : la stabilisation d'un maximum empirique (l'EMV) est plus difficile, rendant moins précis l'estimation.
- Si  $\mathbb{I}(\vartheta)$  est « grande », le **rayon de courbure est petit** et le maximum de l'EMV est mieux localisé.

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications



## Information de Fisher et régression

- $\mathcal{E}^n$  expérience engendrée par  $(\mathbf{x}_1, Y_1), \dots, (\mathbf{x}_n, Y_n)$  avec

$$Y_i = r(\vartheta, \mathbf{x}_i) + \xi_i,$$

$\xi_i$  : densité  **$g$  par rapport à la mesure de Lebesgue** + « design » déterministe.

- Observation :  $Z^n = (Y_1, \dots, Y_n)$ ,  $\mu^n = dy_1 \dots dy_n$ ,  $z = (y_1, \dots, y_n)$  et

$$f_n(\vartheta, Z^n) = \prod_{i=1}^n g(Y_i - r(\vartheta, \mathbf{x}_i))$$

- **Information de Fisher**

$$\mathbb{I}(\vartheta | \mathcal{E}^n) = \mathbb{E}_{\vartheta} [(\partial_{\vartheta} \log f_n(\vartheta, Z^n))^2]$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications



## Information de Fisher et régression

- **Formule explicite** pour la log-vraisemblance

$$\partial_{\vartheta} \log f_n(\vartheta, Z^n) = \sum_{i=1}^n \partial_{\vartheta} \log g(Y_i - r(\vartheta, \mathbf{x}_i))$$

- **Propriété analogue avec le modèle de densité** :

$$\mathbb{E}_{\vartheta} [\partial_{\vartheta} \log g(Y_i - r(\vartheta, \mathbf{x}_i))] = 0.$$

- **Information de Fisher** par indépendance + centrage :

$$\begin{aligned} \mathbb{I}(\vartheta | \mathcal{E}^n) &= \sum_{i=1}^n \mathbb{E}_{\vartheta}^n [(\partial_{\vartheta} \log g(Y_i - r(\vartheta, \mathbf{x}_i)))^2] \\ &= \dots \end{aligned}$$

MAP 433 :  
Introduction  
aux méthodes  
statistiques.  
Cours 6

Sélection de  
variables

Régression  
non-linéaire

Comparaison  
d'estimateurs

Modèles  
réguliers et  
information de  
Fisher

Construction de  
l'information de  
Fisher

Modèle régulier  
Cadre général et  
interprétation  
géométrique  
Exemples,  
applications



A **titre d'exercice**, savoir calculer l'information de Fisher pour :

- L'estimation du paramètre d'une loi de Poisson dans le modèle de densité.
- L'estimation de la moyenne-variance pour un échantillon gaussien.
- **La régression logistique**
- L'estimation du paramètre d'une loi exponentielle **avec ou sans** censure.

- Dans un modèle régulier, le **calcul numérique** de l'EMV peut être difficile à réaliser.
- Si l'on dispose d'un estimateur  $\hat{\vartheta}_n$  **asymptotiquement normal** et si les évaluations

$$\ell'_n(\vartheta) = \frac{1}{n} \sum_{i=1}^n \partial_{\vartheta} \log f(\vartheta, X_i), \quad \ell''_n(\vartheta) = \frac{1}{n} \sum_{i=1}^n \partial_{\vartheta}^2 \log f(\vartheta, X_i)$$

sont **faciles**, alors on peut **corriger**  $\hat{\vartheta}_n$  de sorte d'avoir le même comportement asymptotique que l'EMV :

$$\tilde{\vartheta}_n = \hat{\vartheta}_n - \frac{\ell'_n(\hat{\vartheta}_n)}{\ell''_n(\hat{\vartheta}_n)} \quad (\text{algorithme de Newton})$$

satisfait

$$\sqrt{n}(\tilde{\vartheta}_n - \vartheta) \xrightarrow{d} \mathcal{N}\left(0, \frac{1}{\mathbb{I}(\vartheta)}\right)$$