

# Procédures adaptatives d'estimation et de tests : sélection de modèles et tests multiples

Béatrice LAURENT

INSA de Toulouse  
Institut de Mathématiques de Toulouse

GdR Mascot-Num, Avignon, 17 Mars 2010

# Plan de l'exposé

## 1 Introduction

# Plan de l'exposé

- 1 Introduction
- 2 Estimation adaptative par sélection de modèles via un critère pénalisé
  - Heuristique de Mallows
  - Sélection de modèles en régression gaussienne (L. Birgé et P. Massart)

# Plan de l'exposé

- 1 Introduction
- 2 Estimation adaptative par sélection de modèles via un critère pénalisé
  - Heuristique de Mallows
  - Sélection de modèles en régression gaussienne (L. Birgé et P. Massart)
- 3 Tests adaptatifs via des procédures de tests multiples
  - Tests d'hypothèses linéaires en régression gaussienne (Y. Baraud, S. Huet, B. L.)

# Plan de l'exposé

- 1 Introduction
- 2 Estimation adaptative par sélection de modèles via un critère pénalisé
  - Heuristique de Mallows
  - Sélection de modèles en régression gaussienne (L. Birgé et P. Massart)
- 3 Tests adaptatifs via des procédures de tests multiples
  - Tests d'hypothèses linéaires en régression gaussienne (Y. Baraud, S. Huet, B. L.)
- 4 Applications en génomique
  - Applications à l'inférence de réseaux de gènes (N. Verzelen et F. Villers)

# INTRODUCTION

- On considère le modèle

$$Y = \mu + \sigma\epsilon$$

$Y$ ,  $\mu$  et  $\epsilon$  sont des vecteurs de  $\mathbb{R}^n$ ,  
 $\epsilon_1, \dots, \epsilon_n$  sont i.i.d. de loi  $\mathcal{N}(0, 1)$ .

# INTRODUCTION

- On considère le modèle

$$Y = \mu + \sigma\epsilon$$

$Y$ ,  $\mu$  et  $\epsilon$  sont des vecteurs de  $\mathbb{R}^n$ ,  
 $\epsilon_1, \dots, \epsilon_n$  sont i.i.d. de loi  $\mathcal{N}(0, 1)$ .

- A partir de l'estimation de  $Y$ , on souhaite
  - Estimer  $\mu$
  - Réaliser des tests d'hypothèses sur  $\mu$ .

# INTRODUCTION

- On considère le modèle

$$Y = \mu + \sigma\epsilon$$

- $Y$ ,  $\mu$  et  $\epsilon$  sont des vecteurs de  $\mathbb{R}^n$ ,  
 $\epsilon_1, \dots, \epsilon_n$  sont i.i.d. de loi  $\mathcal{N}(0, 1)$ .
- A partir de l'estimation de  $Y$ , on souhaite
  - Estimer  $\mu$
  - Réaliser des tests d'hypothèses sur  $\mu$ .
- $\mu$  est de même dimension que le vecteur des observations  $Y$ ,  
il s'agit d'un problème **non paramétrique**.



## Exemples d'applications :

- **Estimation d'une fonction de régression**

$$Y_i = f(x_i) + \sigma\epsilon_i, \quad 1 \leq i \leq n, \quad 0 \leq x_1 < \dots < x_n \leq 1.$$

Dans le cas où  $f$  constante par morceaux, l'estimation de  $\mu$  permet d'estimer les points de ruptures de  $f$ .

## Exemples d'applications :

- **Estimation d'une fonction de régression**

$$Y_i = f(x_i) + \sigma\epsilon_i, \quad 1 \leq i \leq n, \quad 0 \leq x_1 < \dots < x_n \leq 1.$$

Dans le cas où  $f$  constante par morceaux, l'estimation de  $\mu$  permet d'estimer les points de ruptures de  $f$ .

- **Sélection de variables**

$$Y_i = \theta_1 X_i^{(1)} + \dots + \theta_p X_i^{(p)} + \sigma\epsilon_i, \quad 1 \leq i \leq n,$$

où  $X^{(1)}, \dots, X^{(p)}$  sont  $p$  vecteurs de  $\mathbb{R}^n$ .

## Estimation de $\mu$ :

- Pour un estimateur  $\hat{\mu}$  de  $\mu$ , on définit le risque quadratique

$$R(\hat{\mu}, \mu) = E(\|\hat{\mu} - \mu\|_n^2)$$

où  $\|u\|_n^2 = \sum_{i=1}^n u_i^2/n$ .

## Estimation de $\mu$ :

- Pour un estimateur  $\hat{\mu}$  de  $\mu$ , on définit le risque quadratique

$$R(\hat{\mu}, \mu) = E(\|\hat{\mu} - \mu\|_n^2)$$

où  $\|u\|_n^2 = \sum_{i=1}^n u_i^2/n$ .

- L'objectif de la sélection de modèle est de sélectionner parmi une collection d'estimateurs ( $\hat{\mu}_m, m \in \mathcal{M}$ ) de  $\mu$  un estimateur  $\hat{\mu}_{\hat{m}}$  qui minimise le risque quadratique.

## Estimation de $\mu$ :

- Pour un estimateur  $\hat{\mu}$  de  $\mu$ , on définit le risque quadratique

$$R(\hat{\mu}, \mu) = E(\|\hat{\mu} - \mu\|_n^2)$$

où  $\|u\|_n^2 = \sum_{i=1}^n u_i^2/n$ .

- L'objectif de la sélection de modèle est de sélectionner parmi une collection d'estimateurs  $(\hat{\mu}_m, m \in \mathcal{M})$  de  $\mu$  un estimateur  $\hat{\mu}_{\hat{m}}$  qui minimise le risque quadratique.
- Inégalité "oracle" :

$$\forall \mu \in \mathbb{R}^n, R(\hat{\mu}_{\hat{m}}, \mu) \leq \inf_{m \in \mathcal{M}} R(\hat{\mu}_m, \mu)$$

## Estimation de $\mu$ :

- Pour un estimateur  $\hat{\mu}$  de  $\mu$ , on définit le risque quadratique

$$R(\hat{\mu}, \mu) = E(\|\hat{\mu} - \mu\|_n^2)$$

où  $\|u\|_n^2 = \sum_{i=1}^n u_i^2/n$ .

- L'objectif de la sélection de modèle est de sélectionner parmi une collection d'estimateurs  $(\hat{\mu}_m, m \in \mathcal{M})$  de  $\mu$  un estimateur  $\hat{\mu}_{\hat{m}}$  qui minimise le risque quadratique.
- Inégalité "oracle" :

$$\forall \mu \in \mathbb{R}^n, R(\hat{\mu}_{\hat{m}}, \mu) \leq C \inf_{m \in \mathcal{M}} R(\hat{\mu}_m, \mu) + \gamma_n$$

## Tests d'hypothèses linéaires :

- On souhaite tester l'hypothèse

$$H_0 : \mu \in V \text{ contre } H_1 : \mu \notin V$$

où  $V$  est un sous-espace vectoriel de  $\mathbb{R}^n$ .

## Tests d'hypothèses linéaires :

- On souhaite tester l'hypothèse

$$H_0 : \mu \in V \text{ contre } H_1 : \mu \notin V$$

où  $V$  est un sous-espace vectoriel de  $\mathbb{R}^n$ .

- Pour tester

$$H_0 : \mu \in V \text{ contre } H_1 : \mu \in W$$

où  $W$  est un s.e.v. de  $\mathbb{R}^n$  de petite dimension devant  $n$  tel que  $V \subset W$ , on réalise un test de Fisher.



## Tests multiples :

- Dans un contexte non paramétrique, on se donne une collection  $(W_m, m \in \mathcal{M})$  de sous-espaces vectoriels de  $\mathbb{R}^n$ , contenant  $V$ . Pour tout  $m \in \mathcal{M}$ , on considère le test de Fisher d'hypothèses :

$$H_0 : \mu \in V \text{ contre } H_1 : \mu \in W_m.$$

## Tests multiples :

- Dans un contexte non paramétrique, on se donne une collection  $(W_m, m \in \mathcal{M})$  de sous-espaces vectoriels de  $\mathbb{R}^n$ , contenant  $V$ . Pour tout  $m \in \mathcal{M}$ , on considère le test de Fisher d'hypothèses :

$$H_0 : \mu \in V \text{ contre } H_1 : \mu \in W_m.$$

- A partir de cette collection de tests, nous allons définir une procédure de tests multiples.

## Tests multiples :

- Dans un contexte non paramétrique, on se donne une collection  $(W_m, m \in \mathcal{M})$  de sous-espaces vectoriels de  $\mathbb{R}^n$ , contenant  $V$ . Pour tout  $m \in \mathcal{M}$ , on considère le test de Fisher d'hypothèses :

$$H_0 : \mu \in V \text{ contre } H_1 : \mu \in W_m.$$

- A partir de cette collection de tests, nous allons définir une procédure de tests multiples.
- L'objectif sera de prouver une inégalité de type "oracle" pour les tests : la puissance du test multiple en tout vecteur  $\mu \notin V$  est "comparable" à la meilleure puissance des tests de la collection en  $\mu$ .

## Application en génomique :

- On considère des réseaux d'interactions entre gènes.
- N. Verzelen et F. Villers ont proposé des tests d'adéquation qui s'appuient sur les procédures de tests multiples.

# ESTIMATION ADAPTATIVE

$$Y = \mu + \sigma\epsilon$$

## Heuristique de Mallows

- Soit  $V$  un s.e.v. de  $\mathbb{R}^n$  de dimension  $D$ , et  $\hat{\mu} = \Pi_V(Y)$ .

$$\begin{aligned} R(\Pi_V(Y), \mu) &= E(\|\Pi_V(Y) - \mu\|_n^2) \\ &= \|\Pi_V(\mu) - \mu\|_n^2 + E(\|\Pi_V(\sigma\epsilon)\|_n^2) \\ &= \|\Pi_V(\mu) - \mu\|_n^2 + \sigma^2 \frac{D}{n}. \end{aligned}$$

# ESTIMATION ADAPTATIVE

$$Y = \mu + \sigma\epsilon$$

## Heuristique de Mallows

- Soit  $V$  un s.e.v. de  $\mathbb{R}^n$  de dimension  $D$ , et  $\hat{\mu} = \Pi_V(Y)$ .

$$\begin{aligned} R(\Pi_V(Y), \mu) &= E(\|\Pi_V(Y) - \mu\|_n^2) \\ &= \|\Pi_V(\mu) - \mu\|_n^2 + E(\|\Pi_V(\sigma\epsilon)\|_n^2) \\ &= \|\Pi_V(\mu) - \mu\|_n^2 + \sigma^2 \frac{D}{n}. \end{aligned}$$

- L'heuristique de Mallows consiste à
  - Estimer sans biais le risque  $R(\Pi_V(Y), \mu)$
  - Sélectionner parmi une collection d'estimateurs un estimateur qui minimise le risque estimé.

## Estimation sans biais du risque

$$R(\Pi_V(Y), \mu) = \|\mu\|_n^2 - \|\Pi_V(\mu)\|_n^2 + \sigma^2 \frac{D}{n}$$

$$R(\Pi_V(Y), \mu) - \|\mu\|_n^2 = -\|\Pi_V(\mu)\|_n^2 + \sigma^2 \frac{D}{n}$$

$$E(\|\Pi_V(Y)\|_n^2) = \|\Pi_V(\mu)\|_n^2 + \sigma^2 \frac{D}{n}$$

$$-\|\Pi_V(Y)\|_n^2 + 2\sigma^2 \frac{D}{n}$$

est un estimateur sans biais de

$$R(\Pi_V(Y), \mu) - \|\mu\|_n^2.$$

## Critère $C_p$ de Mallows (1973)

- On se donne une collection de s.e.v. de  $\mathbb{R}^n$  :  $(S_m, m \in \mathcal{M})$ , avec  $\dim(S_m) = D_m$ .
- On considère

$$\hat{m} = \operatorname{Argmin}_{m \in \mathcal{M}} \left( -\|\Pi_{S_m}(Y)\|_n^2 + 2\sigma^2 \frac{D_m}{n} \right)$$

- On estime  $\mu$  par  $\Pi_{S_{\hat{m}}}(Y)$ .



## Critère Cp de Mallows (1973)

- On se donne une collection de s.e.v. de  $\mathbb{R}^n$  :  $(S_m, m \in \mathcal{M})$ , avec  $\dim(S_m) = D_m$ .
- On considère

$$\hat{m} = \operatorname{Argmin}_{m \in \mathcal{M}} \left( -\|\Pi_{S_m}(Y)\|_n^2 + 2\sigma^2 \frac{D_m}{n} \right)$$

- On estime  $\mu$  par  $\Pi_{S_{\hat{m}}}(Y)$ .
- Quel choix pour la collection de "modèles"  $(S_m, m \in \mathcal{M})$  ?
- Que peut-on dire du risque de cet estimateur ? Est-il possible de prouver une inégalité oracle ?

## Choix de la collection de modèles

$$Y_i = f(x_i) + \sigma\epsilon_i, \quad 1 \leq i \leq n, \quad 0 \leq x_1 < \dots < x_n \leq 1.$$

## Choix de la collection de modèles

$$Y_i = f(x_i) + \sigma \epsilon_i, \quad 1 \leq i \leq n, \quad 0 \leq x_1 < \dots < x_n \leq 1.$$

- On note  $(\phi_j)_{j \geq 1}$  la base Fourier de  $\mathbb{L}^2([0, 1])$ .  
Pour tout  $m = 1, \dots, n$ , on considère l'espace  $S_m$  engendré par les  $m$  vecteurs de  $\mathbb{R}^n$   $(v_1, \dots, v_m)$  où

$$v_j = (\phi_j(x_1), \dots, \phi_j(x_n)), \quad 1 \leq j \leq m.$$

## Choix de la collection de modèles

$$Y_i = f(x_i) + \sigma \epsilon_i, \quad 1 \leq i \leq n, \quad 0 \leq x_1 < \dots < x_n \leq 1.$$

- On note  $(\phi_j)_{j \geq 1}$  la base Fourier de  $\mathbb{L}^2([0, 1])$ .  
Pour tout  $m = 1, \dots, n$ , on considère l'espace  $S_m$  engendré par les  $m$  vecteurs de  $\mathbb{R}^n$   $(v_1, \dots, v_m)$  où

$$v_j = (\phi_j(x_1), \dots, \phi_j(x_n)), \quad 1 \leq j \leq m.$$

- Fonctions constantes par morceaux sur une partition régulière de  $[0, 1]$  en  $m$  intervalles pour  $m = 1, \dots, n$ .

## Choix de la collection de modèles

$$Y_i = f(x_i) + \sigma\epsilon_i, \quad 1 \leq i \leq n, \quad 0 \leq x_1 < \dots < x_n \leq 1.$$

- On note  $(\phi_j)_{j \geq 1}$  la base Fourier de  $\mathbb{L}^2([0, 1])$ .  
Pour tout  $m = 1, \dots, n$ , on considère l'espace  $S_m$  engendré par les  $m$  vecteurs de  $\mathbb{R}^n$   $(v_1, \dots, v_m)$  où

$$v_j = (\phi_j(x_1), \dots, \phi_j(x_n)), \quad 1 \leq j \leq m.$$

- Fonctions constantes par morceaux sur une partition régulière de  $[0, 1]$  en  $m$  intervalles pour  $m = 1, \dots, n$ .
- Fonctions constantes par morceaux sur une partition irrégulière de  $[0, 1]$  en  $m$  intervalles pour  $m = 1, \dots, n$ , obtenue à partir d'une grille fine de pas  $1/n$ .

## Choix de la collection de modèles

$$Y_i = \theta_1 X_i^{(1)} + \dots + \theta_p X_i^{(p)} + \sigma \epsilon_i, \quad 1 \leq i \leq n,$$

## Choix de la collection de modèles

$$Y_i = \theta_1 X_i^{(1)} + \dots + \theta_p X_i^{(p)} + \sigma \epsilon_i, \quad 1 \leq i \leq n,$$

- **Sélection de variables ordonnée**

Pour tout  $m = 1, \dots, p$ , on considère l'espace  $S_m$  engendré par les vecteurs  $(X^{(1)}, X^{(2)}, \dots, X^{(m)})$ .

## Choix de la collection de modèles

$$Y_i = \theta_1 X_i^{(1)} + \dots + \theta_p X_i^{(p)} + \sigma \epsilon_i, \quad 1 \leq i \leq n,$$

- **Sélection de variables ordonnée**

Pour tout  $m = 1, \dots, p$ , on considère l'espace  $S_m$  engendré par les vecteurs  $(X^{(1)}, X^{(2)}, \dots, X^{(m)})$ .

- **Sélection de variables non ordonnée**

Pour tout  $m \subset \{1, 2, \dots, p\}$ , on considère l'espace  $S_m$  engendré par les vecteurs  $(X^{(j)}, j \in m)$ .



# Sélection de modèles en régression gaussienne

L. Birgé et P. Massart *Minimal penalties for Gaussian model selection.*  
*Probab. Theory Related Fields (2007).*

## Théorème

$$Y = \mu + \sigma\epsilon$$

On se donne une collection  $(S_m, m \in \mathcal{M})$  de s.e.v. de  $\mathbb{R}^n$  tels que  $\dim(S_m) = D_m$ .

$$\hat{m} = \operatorname{Argmin}_{m \in \mathcal{M}} (-\|\Pi_{S_m}(Y)\|_n^2 + \operatorname{pen}(m)).$$

# Sélection de modèles en régression gaussienne

L. Birgé et P. Massart *Minimal penalties for Gaussian model selection.*  
*Probab. Theory Related Fields (2007).*

## Théorème

$$Y = \mu + \sigma\epsilon$$

On se donne une collection  $(S_m, m \in \mathcal{M})$  de s.e.v. de  $\mathbb{R}^n$  tels que  $\dim(S_m) = D_m$ .

$$\hat{m} = \operatorname{Argmin}_{m \in \mathcal{M}} (-\|\Pi_{S_m}(Y)\|_n^2 + \operatorname{pen}(m)).$$

Soit  $(L_m, m \in \mathcal{M})$  une collection de nombres  $\geq 0$  tels que

$$\Sigma = \sum_{m \in \mathcal{M}} \exp(-L_m D_m) < +\infty.$$

$$\operatorname{pen}(m) \geq \frac{D_m}{n} \sigma^2 (\kappa + 2(2 - \theta) \sqrt{L_m} + \frac{2}{\theta} L_m), \text{ avec } \theta \in ]0, 1[, \kappa > 2 - \theta,$$

# Sélection de modèles en régression gaussienne

L. Birgé et P. Massart *Minimal penalties for Gaussian model selection.*  
*Probab. Theory Related Fields (2007).*

## Théorème

$$Y = \mu + \sigma\epsilon$$

On se donne une collection  $(S_m, m \in \mathcal{M})$  de s.e.v. de  $\mathbb{R}^n$  tels que  $\dim(S_m) = D_m$ .

$$\hat{m} = \operatorname{Argmin}_{m \in \mathcal{M}} (-\|\Pi_{S_m}(Y)\|_n^2 + \operatorname{pen}(m)).$$

Soit  $(L_m, m \in \mathcal{M})$  une collection de nombres  $\geq 0$  tels que

$$\Sigma = \sum_{m \in \mathcal{M}} \exp(-L_m D_m) < +\infty.$$

$$\operatorname{pen}(m) \geq \frac{D_m}{n} \sigma^2 (\kappa + 2(2 - \theta) \sqrt{L_m} + \frac{2}{\theta} L_m), \text{ avec } \theta \in ]0, 1[, \kappa > 2 - \theta,$$

$$E(\|\Pi_{S_{\hat{m}}}(Y) - \mu\|_n^2) \leq \frac{1}{1 - \theta} \inf_{m \in \mathcal{M}} \left( \|\Pi_{S_m}(\mu) - \mu\|_n^2 + \operatorname{pen}(m) - \sigma^2 \frac{D_m}{n} \right) + C_2(\theta) \frac{\Sigma}{n}.$$

## Applications

On se donne une collection  $(S_m, m \in \mathcal{M})$  de s.e.v. de  $\mathbb{R}^n$ .

Pour tout  $D \geq 1$ , on note  $N(D)$  le nombre d'éléments de la collection de dimension  $D$ .

## Applications

On se donne une collection  $(S_m, m \in \mathcal{M})$  de s.e.v. de  $\mathbb{R}^n$ .  
Pour tout  $D \geq 1$ , on note  $N(D)$  le nombre d'éléments de la collection de dimension  $D$ .

- Si  $N(D) \leq 1$  (partition régulière, sélection de variable ordonnée), on peut prendre  $L_m = \delta > 0$

$$\Sigma = \sum_{m \in \mathcal{M}} \exp(-L_m D_m) \leq \sum_{D \geq 1} \exp(-\delta D) < +\infty.$$

## Applications

On se donne une collection  $(S_m, m \in \mathcal{M})$  de s.e.v. de  $\mathbb{R}^n$ .  
Pour tout  $D \geq 1$ , on note  $N(D)$  le nombre d'éléments de la collection de dimension  $D$ .

- Si  $N(D) \leq 1$  (partition régulière, sélection de variable ordonnée), on peut prendre  $L_m = \delta > 0$

$$\Sigma = \sum_{m \in \mathcal{M}} \exp(-L_m D_m) \leq \sum_{D \geq 1} \exp(-\delta D) < +\infty.$$

- Le théorème s'applique pour

$$\text{pen}(m) \geq \frac{D_m}{n} \sigma^2 \left( \kappa + 2(2 - \theta) \sqrt{\delta} + \frac{2}{\theta} \delta \right), \text{ avec } \theta \in ]0, 1[, \kappa > 2 - \theta.$$

- L'heuristique de Mallows est justifiée dans ce cas.

## Applications

- $N(D) = C_n^D$  (partition irrégulière, sélection de variable non ordonnée avec  $p = n$ ).
- En posant  $L_m = L(D_m)$ ,

$$\sum_{m \in \mathcal{M}} \exp(-L_m D_m) \leq \sum_{D=1}^n C_n^D \exp(-DL(D)) \leq \sum_{D=1}^n \exp(D + D \ln(\frac{n}{D}) - DL(D))$$

## Applications

- $N(D) = C_n^D$  (partition irrégulière, sélection de variable non ordonnée avec  $p = n$ ).
- En posant  $L_m = L(D_m)$ ,

$$\sum_{m \in \mathcal{M}} \exp(-L_m D_m) \leq \sum_{D=1}^n C_n^D \exp(-DL(D)) \leq \sum_{D=1}^n \exp(D + D \ln(\frac{n}{D}) - DL(D))$$

- On peut prendre  $L(D) = L + \ln(\frac{n}{D})$ ,  $L > 1$

$$\text{pen}(m) \geq \frac{D_m}{n} \sigma^2 \left( \kappa + C(\theta) \ln \left( \frac{n}{D_m} \right) \right).$$



## Applications

- $N(D) = C_n^D$  (partition irrégulière, sélection de variable non ordonnée avec  $p = n$ ).
- En posant  $L_m = L(D_m)$ ,

$$\sum_{m \in \mathcal{M}} \exp(-L_m D_m) \leq \sum_{D=1}^n C_n^D \exp(-DL(D)) \leq \sum_{D=1}^n \exp(D + D \ln(\frac{n}{D}) - DL(D))$$

- On peut prendre  $L(D) = L + \ln(\frac{n}{D})$ ,  $L > 1$

$$\text{pen}(m) \geq \frac{D_m}{n} \sigma^2 \left( \kappa + C(\theta) \ln \left( \frac{n}{D_m} \right) \right).$$

- Le théorème ne permet pas de justifier l'heuristique de Mallows dans ce cas.

## Applications

- $N(D) = C_n^D$  (partition irrégulière, sélection de variable non ordonnée avec  $p = n$ ).
- En posant  $L_m = L(D_m)$ ,

$$\sum_{m \in \mathcal{M}} \exp(-L_m D_m) \leq \sum_{D=1}^n C_n^D \exp(-DL(D)) \leq \sum_{D=1}^n \exp(D + D \ln\left(\frac{n}{D}\right) - DL(D))$$

- On peut prendre  $L(D) = L + \ln\left(\frac{n}{D}\right)$ ,  $L > 1$

$$\text{pen}(m) \geq \frac{D_m}{n} \sigma^2 \left( \kappa + C(\theta) \ln \left( \frac{n}{D_m} \right) \right).$$

- Le théorème ne permet pas de justifier l'heuristique de Mallows dans ce cas.
- L. Birgé et P. Massart montrent que, pour des collection de modèles complexes, le  $C_p$  de Mallows ne fonctionne pas.

## Références Sélection de modèles

- Y. Baraud, C. Giraud, S. Huet (2009) *Gaussian model selection with an unknown variance*, Ann. Statist.
  - L. Birgé, P. Massart (2007) *Minimal penalties for Gaussian model selection*, Probab. Theory Related Fields.
  - X. Gendre (2008) *Simultaneous estimation of the mean and the variance in heteroscedastic Gaussian regression*, EJS.
  - B. L., C. Ludena, C. Prieur (2008) *Adaptive estimation of a linear functionals by model selection*, EJS.
  - P. Massart (2007) *Concentration inequalities and model selection*. Cours de l'école d'été de St Flour 2003, Springer.
- 
- S. Arlot, P. Massart (2009). *Data-driven calibration of penalties for least squares regression*, Journal of Machine Learning Research.
  - M. Lerasle (2009) *Optimal model selection in density estimation*, Preprint. Hal.

# TESTS ADAPTATIFS

## Tests d'hypothèses linéaires

Y. Baraud , S. Huet, B.L. (2003), Ann. Statist.

$$Y = \mu + \sigma\epsilon$$

avec  $\epsilon_1, \dots, \epsilon_n$  i.i.d. de la  $\mathcal{N}(0, 1)$ .

- On souhaite tester l'hypothèse  $H_0 : \mu \in V$  contre  $H_1 : \mu \notin V$  où  $V$  est un sous-espace vectoriel de  $\mathbb{R}^n$ .

# TESTS ADAPTATIFS

## Tests d'hypothèses linéaires

Y. Baraud , S. Huet, B.L. (2003), Ann. Statist.

$$Y = \mu + \sigma \epsilon$$

avec  $\epsilon_1, \dots, \epsilon_n$  i.i.d. de la  $\mathcal{N}(0, 1)$ .

- On souhaite tester l'hypothèse  $H_0 : \mu \in V$  contre  $H_1 : \mu \notin V$  où  $V$  est un sous-espace vectoriel de  $\mathbb{R}^n$ .
- On se donne un niveau  $\alpha \in ]0, 1[$  et une fonction de test  $\Phi_\alpha(Y) \in \{0, 1\}$ .
- On accepte  $H_0$  si  $\Phi_\alpha(Y) = 0$ , on rejette  $H_0$  si  $\Phi_\alpha(Y) = 1$ .

# TESTS ADAPTATIFS

## Tests d'hypothèses linéaires

Y. Baraud , S. Huet, B.L. (2003), Ann. Statist.

$$Y = \mu + \sigma \epsilon$$

avec  $\epsilon_1, \dots, \epsilon_n$  i.i.d. de la  $\mathcal{N}(0, 1)$ .

- On souhaite tester l'hypothèse  $H_0 : \mu \in V$  contre  $H_1 : \mu \notin V$  où  $V$  est un sous-espace vectoriel de  $\mathbb{R}^n$ .
- On se donne un niveau  $\alpha \in ]0, 1[$  et une fonction de test  $\Phi_\alpha(Y) \in \{0, 1\}$ .
- On accepte  $H_0$  si  $\Phi_\alpha(Y) = 0$ , on rejette  $H_0$  si  $\Phi_\alpha(Y) = 1$ .
- **Test de niveau  $\alpha$  :**

$$\mathbb{P}_{H_0}(\Phi_\alpha(Y) = 1) \leq \alpha.$$

- **Puissance du test :**

$$\mu \mapsto \mathbb{P}_\mu(\Phi_\alpha(Y) = 1).$$

## Test de Fisher

Pour tester

$$H_0 : \mu \in V \text{ contre } H_1 : \mu \in W$$

où  $W$  est un s.e.v. strict de  $\mathbb{R}^n$  tel que  $V \subset W$ , on réalise un test de Fisher.  $\dim(V) = q$ ,  $\dim(W) = p$ .

$$F(Y) = \frac{\|\Pi_W(Y) - \Pi_V(Y)\|^2 / (p - q)}{\|Y - \Pi_W(Y)\|^2 / (n - p)}$$

On rejette  $H_0$  si

$$F(Y) > \bar{F}_{p-q, n-p}^{-1}(\alpha)$$

où  $\bar{F}_{p-q, n-p}^{-1}(\alpha)$  désigne le  $1 - \alpha$  quantile de la loi de Fisher de paramètres  $(p - q, n - p)$ .

$$\Phi_\alpha(Y) = \mathbb{1}_{F(Y) > \bar{F}_{p-q, n-p}^{-1}(\alpha)}.$$

## Puissance du test

- A quelle distance de l'hypothèse  $H_0$ , peut-on garantir que le test est puissant ?



## Puissance du test

- A quelle distance de l'hypothèse  $H_0$ , peut-on garantir que le test est puissant ?
- Soit  $\beta \in ]0, 1[$ , on peut montrer que  $\mathbb{P}_\mu(\Phi_\alpha(Y) = 1) \geq 1 - \beta$  si

$$d_n^2(\mu, V) = \|\mu - \Pi_V(\mu)\|_n^2 \geq C_1 \|\mu - \Pi_W(\mu)\|_n^2 + C_2 \frac{\sigma^2}{n} \sqrt{(p - q) \ln \left( \frac{2}{\alpha\beta} \right)}.$$

## Puissance du test

- A quelle distance de l'hypothèse  $H_0$ , peut-on garantir que le test est puissant ?
- Soit  $\beta \in ]0, 1[$ , on peut montrer que  $\mathbb{P}_\mu(\Phi_\alpha(Y) = 1) \geq 1 - \beta$  si

$$d_n^2(\mu, V) = \|\mu - \Pi_V(\mu)\|_n^2 \geq C_1 \|\mu - \Pi_W(\mu)\|_n^2 + C_2 \frac{\sigma^2}{n} \sqrt{(p - q) \ln \left( \frac{2}{\alpha\beta} \right)}.$$

- En pratique, comment choisir  $W$  ?
- Si on choisit  $W$ , le test sera peu puissant si  $d_n(\mu, W)$  est grande.

## Procédure de tests multiples

On se donne une collection  $(S_m, m \in \mathcal{M})$  de s.e.v. de  $V^\perp$ , tels que  $\dim(S_m) = D_m$ .

- On pose pour tout  $m \in \mathcal{M}$ ,  $W_m = V + S_m$ , on note  $N_m = n - \dim(W_m)$ .

## Procédure de tests multiples

On se donne une collection  $(S_m, m \in \mathcal{M})$  de s.e.v. de  $V^\perp$ , tels que  $\dim(S_m) = D_m$ .

- On pose pour tout  $m \in \mathcal{M}$ ,  $W_m = V + S_m$ , on note  $N_m = n - \dim(W_m)$ .
- On considère la statistique de test de Fisher pour tester

$$H_0 : \mu \in V \text{ contre } H_1 : \mu \in W_m$$

$$F_m(Y) = \frac{\|\Pi_{S_m}(Y)\|^2 / D_m}{\|Y - \Pi_{W_m}(Y)\|^2 / N_m}.$$

## Procédure de tests multiples

On se donne une collection  $(S_m, m \in \mathcal{M})$  de s.e.v. de  $V^\perp$ , tels que  $\dim(S_m) = D_m$ .

- On pose pour tout  $m \in \mathcal{M}$ ,  $W_m = V + S_m$ , on note  $N_m = n - \dim(W_m)$ .
- On considère la statistique de test de Fisher pour tester

$$H_0 : \mu \in V \text{ contre } H_1 : \mu \in W_m$$

$$F_m(Y) = \frac{\|\Pi_{S_m}(Y)\|^2 / D_m}{\|Y - \Pi_{W_m}(Y)\|^2 / N_m}.$$

- On rejette  $H_0$  si  $\exists m \in \mathcal{M}, F_m(Y) > \bar{F}_{D_m, N_m}^{-1}(\alpha_n)$  où  $\alpha_n$  vérifie :

$$\mathbb{P} \left( \sup_{m \in \mathcal{M}} \left\{ F_m(\epsilon) - \bar{F}_{D_m, N_m}^{-1}(\alpha_n) \right\} > 0 \right) = \alpha.$$

- $\alpha/|\mathcal{M}| \leq \alpha_n \leq \alpha$ .

# Puissance de la procédure de tests multiples

## Théorème

$$Y = \mu + \sigma\epsilon$$

$$H_0 : \mu \in V \text{ contre } H_1 : \mu \notin V$$

$$\begin{aligned}\Phi_\alpha(Y) &= 1 \text{ si } \exists m \in \mathcal{M}, F_m > \bar{F}_{D_m, N_m}^{-1}(\alpha_n) \\ &= 0 \text{ sinon}\end{aligned}$$

Soit  $\beta \in ]0, 1[$ ,  $\mathbb{P}_\mu(\Phi_\alpha(Y) = 1) \geq 1 - \beta$  si

$$d_n^2(\mu, V) \geq \inf_{m \in \mathcal{M}} \left\{ C_1 \|\mu - \Pi_{W_m}(\mu)\|_n^2 + C_2 \frac{\sigma^2}{n} \sqrt{D_m \ln\left(\frac{2}{\alpha_n \beta}\right)} \right\}$$

# Vitesse de détection de signal

## Corollaire

$$Y_i = f(x_i) + \sigma \epsilon_i, \dots, 1 \leq i \leq n.$$

$$\mu = E(Y) = (f(x_1), \dots, f(x_n))'.$$

$$H_0 : \mu = 0 \text{ contre } H_1 : \mu \neq 0$$

$$V = \{0\} \quad , \quad W_m = S_m.$$

# Vitesse de détection de signal

## Corollaire

$$Y_i = f(x_i) + \sigma \epsilon_i, \dots, 1 \leq i \leq n.$$

$$\mu = E(Y) = (f(x_1), \dots, f(x_n))'.$$

$$H_0 : \mu = 0 \text{ contre } H_1 : \mu \neq 0$$

$$V = \{0\}, \quad W_m = S_m.$$

Pour tout  $m \in \mathcal{M} = \{2^j, j \geq 0\} \cap \{1, \dots, [n/2]\}$

$$S_m = \text{Vect} \left\{ \left( \mathbb{1}_{\lfloor \frac{j-1}{m}, \frac{j}{m} \rfloor}(x_1), \dots, \mathbb{1}_{\lfloor \frac{j-1}{m}, \frac{j}{m} \rfloor}(x_n) \right)', j = 1, \dots, m \right\}.$$



# Vitesse de détection de signal

## Corollaire

$$Y_i = f(x_i) + \sigma \epsilon_i, \dots, 1 \leq i \leq n.$$

$$\mu = E(Y) = (f(x_1), \dots, f(x_n))'.$$

$$H_0 : \mu = 0 \text{ contre } H_1 : \mu \neq 0$$

$$V = \{0\} \quad , \quad W_m = S_m.$$

Pour tout  $m \in \mathcal{M} = \{2^j, j \geq 0\} \cap \{1, \dots, [n/2]\}$

$$S_m = \text{Vect} \left\{ \left( \mathbb{1}_{\lfloor \frac{j-1}{m}, \frac{j}{m} \rfloor}(x_1), \dots, \mathbb{1}_{\lfloor \frac{j-1}{m}, \frac{j}{m} \rfloor}(x_n) \right)', j = 1, \dots, m \right\}.$$

$$\forall R > 0, s \in ]0, 1], \quad \mathcal{H}_s(R) = \{f, \forall (x, y) \in [0, 1]^2, |f(x) - f(y)| \leq R|x - y|^s\}.$$

# Vitesse de détection de signal

## Corollaire

$$Y_i = f(x_i) + \sigma \epsilon_i, \dots, 1 \leq i \leq n.$$

$$\mu = E(Y) = (f(x_1), \dots, f(x_n))'.$$

$$H_0 : \mu = 0 \text{ contre } H_1 : \mu \neq 0$$

$$V = \{0\}, \quad W_m = S_m.$$

Pour tout  $m \in \mathcal{M} = \{2^j, j \geq 0\} \cap \{1, \dots, [n/2]\}$

$$S_m = \text{Vect} \left\{ \left( \mathbb{1}_{\lfloor \frac{j-1}{m}, \frac{j}{m} \rfloor}(x_1), \dots, \mathbb{1}_{\lfloor \frac{j-1}{m}, \frac{j}{m} \rfloor}(x_n) \right)', j = 1, \dots, m \right\}.$$

$$\forall R > 0, s \in ]0, 1], \quad \mathcal{H}_s(R) = \{f, \forall (x, y) \in [0, 1]^2, |f(x) - f(y)| \leq R|x - y|^s\}.$$

$$\rho_n^2 = R^{\frac{2}{1+4s}} \left( \frac{\sqrt{\ln \ln(n)}}{n} \sigma^2 \right)^{\frac{4s}{1+4s}} + R^2 n^{-2s} + \frac{\ln \ln(n)}{n} \sigma^2$$

$$\forall R > 0, s \in ]0, 1], \text{ si } f \in \mathcal{H}_s(R) \text{ et } \|\mu\|_n^2 \geq C(\alpha, \beta) \rho_n^2, \quad \mathbb{P}_\mu(\Phi_\alpha(Y) = 1) \geq 1 - \beta.$$


# APPLICATIONS EN GENOMIQUE

- **Tests pour les modèles graphiques gaussiens**

Réf. N. Verzelen et F. Villers

- *Tests for Gaussian graphical models*. CSDA, 2009
- *Goodness-of-fit Tests for high-dimensional Gaussian linear models*. à paraître Ann. Statist.

# Réseau de régulation génique d'E. Coli



## Modèle graphique gaussien

On considère  $\mathbf{X} = (X_1, \dots, X_p) \sim \mathcal{N}_p(0, \Sigma)$

$\Sigma$  inversible

$\Gamma := \{1, \dots, p\}$

$G = (\Gamma, E)$  graphe non orienté fini

$ne_G(a)$  : voisins de  $a$  dans  $G$ .

## Modèle graphique gaussien

On considère  $X = (X_1, \dots, X_p) \sim \mathcal{N}_p(0, \Sigma)$

$\Sigma$  inversible


$\Gamma := \{1, \dots, p\}$

$G = (\Gamma, E)$  graphe non orienté fini

$ne_G(a)$  : voisins de  $a$  dans  $G$ .

$X$  vérifie la propriété de **Markov local** en  $a$  par rapport à  $G$  si

$$(X_a \perp\!\!\!\perp X_{-\{a, ne_G(a)\}}) | X_{ne_G(a)}$$



# Modèle graphique gaussien

On considère  $X = (X_1, \dots, X_p) \sim \mathcal{N}_p(0, \Sigma)$

$\Sigma$  inversible


$\Gamma := \{1, \dots, p\}$

$G = (\Gamma, E)$  graphe non orienté fini

$ne_G(a)$  : voisins de  $a$  dans  $G$ .

$X$  vérifie la propriété de **Markov local** en  $a$  par rapport à  $G$  si

$$(X_a \perp\!\!\!\perp X_{-\{a, ne_G(a)\}}) | X_{ne_G(a)}$$



$X$  est un **modèle graphique gaussien** par rapport à  $G$



$X$  vérifie la propriété de Markov local pour tout sommet  $a \in \Gamma$ .

## Tests pour les modèles graphiques gaussiens

- $n$  observations de  $X = (X_1, \dots, X_p)$ , avec  $X \sim \mathcal{N}_p(0, \Sigma)$ .  
 $n$  Microarrays sur lesquels on mesure l'expression de  $p$  gènes ( $n \ll p$ )



## Tests pour les modèles graphiques gaussiens

- $n$  observations de  $X = (X_1, \dots, X_p)$ , avec  $X \sim \mathcal{N}_p(0, \Sigma)$ .  
 $n$  Microarrays sur lesquels on mesure l'expression de  $p$  gènes ( $n \ll p$ )
- **Test de voisinage** : On se donne un noeud  $a$ .

$H_{0,a}$  :  $X$  satisfait la propriété de Markov locale au noeud  $a$  relativement au graphe  $G$ .

$H_{0,a}$  :  $X_a \perp\!\!\!\perp X_{\Gamma \setminus \{a, \text{ne}_G(a)\}} \mid X_{\text{ne}_G(a)}$ .

## Tests pour les modèles graphiques gaussiens

- $n$  observations de  $X = (X_1, \dots, X_p)$ , avec  $X \sim \mathcal{N}_p(0, \Sigma)$ .  
 $n$  Microarrays sur lesquels on mesure l'expression de  $p$  gènes ( $n \ll p$ )
- **Test de voisinage** : On se donne un noeud  $a$ .

$H_{0,a}$  :  $X$  satisfait la propriété de Markov locale au noeud  $a$  relativement au graphe  $G$ .

$H_{0,a}$  :  $X_a \perp\!\!\!\perp X_{\Gamma \setminus \{a, \text{ne}_G(a)\}} \mid X_{\text{ne}_G(a)}$ .

- Propriété des vecteurs gaussiens :

$$X_a = \sum_{b \in \Gamma \setminus \{a\}} \theta_b^a X_b + \epsilon_a$$

- $\sum_{b \in \Gamma \setminus \{a\}} \theta_b^a X_b = E(X_a / X_{-a})$
- $\epsilon_a \perp\!\!\!\perp X_{-a}$  de loi  $\mathcal{N}(0, \sigma_a^2)$ .

## Tests pour les modèles graphiques gaussiens

- $n$  observations de  $X = (X_1, \dots, X_p)$ , avec  $X \sim \mathcal{N}_p(0, \Sigma)$ .  
 $n$  Microarrays sur lesquels on mesure l'expression de  $p$  gènes ( $n \ll p$ )
- **Test de voisinage** : On se donne un noeud  $a$ .

$H_{0,a}$  :  $X$  satisfait la propriété de Markov locale au noeud  $a$  relativement au graphe  $G$ .

$H_{0,a}$  :  $X_a \perp\!\!\!\perp X_{\Gamma \setminus \{a, \text{ne}_G(a)\}} \mid X_{\text{ne}_G(a)}$ .

- Propriété des vecteurs gaussiens :

$$X_a = \sum_{b \in \Gamma \setminus \{a\}} \theta_b^a X_b + \epsilon_a$$

- $\sum_{b \in \Gamma \setminus \{a\}} \theta_b^a X_b = E(X_a / X_{-a})$
- $\epsilon_a \perp\!\!\!\perp X_{-a}$  de loi  $\mathcal{N}(0, \sigma_a^2)$ .

$$H_{0,a} : \theta_b^a = 0 \forall b \notin \text{ne}_G(a).$$

## Procédure de tests multiples

- On note  $\mathbf{X}_j$  le vecteur de  $\mathbb{R}^n$  correspondant aux  $n$  observations de  $X_j$  pour tout  $j \in \Gamma$ ,  $\mathbf{X}_{-a} = (\mathbf{X}_b, b \neq a)$

$$H_{0,a} : \theta_b^a = 0 \forall b \notin \text{ne}_G(a).$$

## Procédure de tests multiples

- On note  $\mathbf{X}_j$  le vecteur de  $\mathbb{R}^n$  correspondant aux  $n$  observations de  $X_j$  pour tout  $j \in \Gamma$ ,  $\mathbf{X}_{-a} = (\mathbf{X}_b, b \neq a)$

$$H_{0,a} : \theta_b^a = 0 \forall b \notin \text{ne}_G(a).$$

- On se donne une collection  $\mathcal{M}$  de sous-ensembles de  $\Gamma \setminus \{\text{ne}_G(a), a\}$  Pour tout  $m \in \mathcal{M}$ ,

$$H_{1,a,m} : \theta_b^a = 0 \forall b \notin \text{ne}_G(a) \cup m.$$

## Procédure de tests multiples

- On note  $\mathbf{X}_j$  le vecteur de  $\mathbb{R}^n$  correspondant aux  $n$  observations de  $X_j$  pour tout  $j \in \Gamma$ ,  $\mathbf{X}_{-a} = (\mathbf{X}_b, b \neq a)$

$$H_{0,a} : \theta_b^a = 0 \forall b \notin \text{ne}_G(a).$$

- On se donne une collection  $\mathcal{M}$  de sous-ensembles de  $\Gamma \setminus \{\text{ne}_G(a), a\}$  Pour tout  $m \in \mathcal{M}$ ,

$$H_{1,a,m} : \theta_b^a = 0 \forall b \notin \text{ne}_G(a) \cup m.$$

$$V = \text{Vect}(\mathbf{X}_b, b \in \text{ne}_G(a)), \quad S_m = \text{Vect}(\mathbf{X}_b, b \in m).$$

$$\phi_m(\mathbf{X}_a, \mathbf{X}_{-a}) = \frac{\|\Pi_{V+S_m}(\mathbf{X}_a) - \Pi_V(\mathbf{X}_a)\|^2 / D_m}{\|\mathbf{X}_a - \Pi_{V+S_m}(\mathbf{X}_a)\|^2 / N_m}.$$

## Procédure de tests multiples

- L'hypothèse  $H_{0,a}$  est rejetée si

$$\exists m \in \mathcal{M}, \phi_m(\mathbf{X}_a, \mathbf{X}_{-a}) > \bar{F}_{D_m, N_m}^{-1}(\alpha_n),$$

$$\alpha_n = \sup \left\{ u, P \left( \sup_{m \in \mathcal{M}} \left( \phi_m \left( \frac{\epsilon_a}{\sigma_a}, \mathbf{X}_{-a} \right) - \bar{F}_{D_m, N_m}^{-1}(u) \right) > 0 / \mathbf{X}_{-a} \right) \leq \alpha \right\}$$

## Puissance du test

- Collection de modèles :  $\mathcal{M} = \{\{b\}, b \notin \{\text{ne}(a) \cup a\}\}$ .



## Puissance du test

- Collection de modèles :  $\mathcal{M} = \{\{b\}, b \notin \{\text{ne}(a) \cup a\}\}$ .

### Théorème

(N. Verzelen, F. Villers)

Soit  $\alpha, \beta \in ]0, 1[$ . On note  $d_a = |\text{ne}(a)|$ ,  $p = |\Gamma|$ .

$$\rho^2 = \frac{C_1}{n - d_a} \ln \left( \frac{p - d_a - 1}{\alpha\beta} \right).$$

$P(T_\alpha > 0) \geq 1 - \beta$  dès que :

$$\exists b \in \Gamma \setminus \{\text{ne}(a) \cup a\}, \frac{\text{Var}(X_a/X_{\text{ne}(a)}) - \text{Var}(X_a/X_{\text{ne}(a) \cup \{b\}})}{\text{Var}(X_a/X_{\text{ne}(a) \cup \{b\}})} \geq \rho^2$$

## Puissance du test

- Collection de modèles :  $\mathcal{M} = \{\{b\}, b \notin \{\text{ne}(a) \cup a\}\}$ .

### Théorème

(N. Verzelen, F. Villers)

Soit  $\alpha, \beta \in ]0, 1[$ . On note  $d_a = |\text{ne}(a)|$ ,  $p = |\Gamma|$ .

$$\rho^2 = \frac{C_1}{n - d_a} \ln \left( \frac{p - d_a - 1}{\alpha\beta} \right).$$

$P(T_\alpha > 0) \geq 1 - \beta$  dès que :

$$\exists b \in \Gamma \setminus \{\text{ne}(a) \cup a\}, \frac{\text{Var}(X_a/X_{\text{ne}(a)}) - \text{Var}(X_a/X_{\text{ne}(a) \cup \{b\}})}{\text{Var}(X_a/X_{\text{ne}(a) \cup \{b\}})} \geq \rho^2$$

- Propriétés d'optimalités de la procédure sous certaines hypothèses.
- Application sur des simulations et des données réelles.

## Références Tests adaptatifs

- Y. Baraud, S. Huet, B. L. (2003) *Adaptive tests of linear hypotheses by model selection*, Ann. Statist.
- Y. Baraud, S. Huet, B. L. (2005) *Adaptive tests of qualitative hypotheses* , Ann. Statist.
- M. Fromont, B. L. (2006) *Adaptive goodness-of-fit tests in a density model* , Ann. Statist.
- N. Verzelen, F. Villers (2009) *Tests for Gaussian graphical models*. CSDA .
- N. Verzelen, F. Villers (2010) *Goodness-of-fit Tests for high-dimensional Gaussian linear models*. à paraître Ann. Statist.
- M. Fromont, B. L., P. Reynaud (2010) *Adaptive tests of homogeneity for Poisson processes* Preprint.