

# Vers une nouvelle validation croisée V-fold

Nelo Magalhães  
(joint work with L. Birgé and P. Massart)

**Journées MAS**  
Toulouse, 29 août 2014

# Introduction

- $\mathbb{X} = \{X_1, \dots, X_n\}$  où  $X_i \in \mathbb{R}$  i.i.d.  $\sim P$ , de densité  $s$ .

# Introduction

- $\mathbb{X} = \{X_1, \dots, X_n\}$  où  $X_i \in \mathbb{R}$  i.i.d.  $\sim P$ , de densité  $s$ .
- **But** : proposer un estimateur  $\tilde{s} = \tilde{s}(\mathbb{X})$  de  $s$ .

# Introduction

- $\mathbb{X} = \{X_1, \dots, X_n\}$  où  $X_i \in \mathbb{R}$  i.i.d.  $\sim P$ , de densité  $s$ .
- **But** : proposer un estimateur  $\tilde{s} = \tilde{s}(\mathbb{X})$  de  $s$ .

**possibilité :**

estimateurs à noyau

- histogrammes
- estimateurs par projection
- ondelettes

# Introduction

- $\mathbb{X} = \{X_1, \dots, X_n\}$  où  $X_i \in \mathbb{R}$  i.i.d.  $\sim P$ , de densité  $s$ .
- **But** : proposer un estimateur  $\tilde{s} = \tilde{s}(\mathbb{X})$  de  $s$ .

possibilité :		problème :
estimateurs à noyau	$\implies$	sélection de la fenêtre
• histogrammes		sélection de partition
estimateurs par projection		sélection de modèle
ondelettes		choix du seuil

# Introduction

- $\mathbb{X} = \{X_1, \dots, X_n\}$  où  $X_i \in \mathbb{R}$  i.i.d.  $\sim P$ , de densité  $s$ .
- **But** : proposer un estimateur  $\tilde{s} = \tilde{s}(\mathbb{X})$  de  $s$ .

- | possibilité :              |            | problème :              |
|----------------------------|------------|-------------------------|
| estimateurs à noyau        | $\implies$ | sélection de la fenêtre |
| • histogrammes             |            | sélection de partition  |
| estimateurs par projection |            | sélection de modèle     |
| ondelettes                 |            | choix du seuil          |
- $\{\text{noyaux, histogrammes, ondelettes, ...}\}$   
 $\implies$  problème du choix d'une **méthode d'estimation**
  - **méthode d'estimation**  $\mathcal{A}_m : \mathbb{Y} \subseteq \mathbb{X} \mapsto \hat{s}_m(\mathbb{Y})$  estimateur de  $s$

# Cadre

$\mathbb{X} = \{X_1, \dots, X_n\}$  où  $X_i \in \mathbb{R}$  i.i.d.  $\sim P$ , de densité  $s$ ,  
 $(\mathcal{A}_m)_{m \in \mathcal{M}}$  collection de méthodes d'estimation.

## Cadre

$\mathbb{X} = \{X_1, \dots, X_n\}$  où  $X_i \in \mathbb{R}$  i.i.d.  $\sim P$ , de densité  $s$ ,  
 $(\mathcal{A}_m)_{m \in \mathcal{M}}$  collection de méthodes d'estimation.

- **Risque de la méthode  $\mathcal{A}_m$**  :  $\mathbb{E}[\ell(s, \hat{s}_m)]$ , où  $\hat{s}_m = \mathcal{A}_m(\mathbb{X})$ ,  
 $\ell$  est une fonction de perte :

**Cas classique** :  $\ell(s, t) = P(\gamma(t, X) - \gamma(s, X)) \geq 0 \forall t$ , avec

- 1  $\gamma(t, x) = \|t\|^2 - 2t(x) \implies \ell(s, t) = \|t - s\|^2$
- 2  $\gamma(t, x) = -\log(t(x)) \implies \ell(s, t) = K(s, t)$

Ou :  $\ell(s, t) = h^2(s, t) = 1/2 \int (\sqrt{s} - \sqrt{t})^2$

## Cadre

$\mathbb{X} = \{X_1, \dots, X_n\}$  où  $X_i \in \mathbb{R}$  i.i.d.  $\sim P$ , de densité  $s$ ,  
 $(\mathcal{A}_m)_{m \in \mathcal{M}}$  collection de méthodes d'estimation.

- **Risque de la méthode  $\mathcal{A}_m$**  :  $\mathbb{E}[\ell(s, \hat{s}_m)]$ , où  $\hat{s}_m = \mathcal{A}_m(\mathbb{X})$ ,  
 $\ell$  est une fonction de perte :

**Cas classique** :  $\ell(s, t) = P(\gamma(t, X) - \gamma(s, X)) \geq 0 \forall t$ , avec

①  $\gamma(t, x) = \|t\|^2 - 2t(x) \implies \ell(s, t) = \|t - s\|^2$

②  $\gamma(t, x) = -\log(t(x)) \implies \ell(s, t) = K(s, t)$

Ou :  $\ell(s, t) = h^2(s, t) = 1/2 \int (\sqrt{s} - \sqrt{t})^2$

- **But** : proposer  $\hat{m} = \hat{m}(\mathbb{X})$  t.q.  $\tilde{s} = \mathcal{A}_{\hat{m}}(\mathbb{X})$  vérifie

$$\mathbb{E}[\ell(s, \tilde{s})] \sim \inf_{m \in \mathcal{M}} \mathbb{E}[\ell(s, \hat{s}_m)]$$

# Table des Matières

- 1 Validation croisée V-fold
- 2 Nouvelle approche
- 3 Conclusions et perspectives

# Validation simple

- Évaluer la qualité de chaque méthode

# Validation simple

- Évaluer la qualité de chaque méthode
- **Problème** : utiliser les mêmes données pour entraîner les méthodes et pour évaluer la qualité des estimateurs !

## Validation simple

- Évaluer la qualité de chaque méthode
- **Problème** : utiliser les mêmes données pour entraîner les méthodes et pour évaluer la qualité des estimateurs !
- **Idée** :  $\mathbb{X} = \mathbb{X}^t \sqcup \mathbb{X}^v$

# Validation simple

- Évaluer la qualité de chaque méthode
- **Problème** : utiliser les mêmes données pour entraîner les méthodes et pour évaluer la qualité des estimateurs !
- **Idée** :  $\mathbb{X} = \mathbb{X}^t \sqcup \mathbb{X}^v$ 
  - 1  $\mathbb{X}^t \implies (\hat{s}_m^t = \mathcal{A}_m(\mathbb{X}^t))_{m \in \mathcal{M}}$

# Validation simple

- Évaluer la qualité de chaque méthode
- **Problème** : utiliser les mêmes données pour entraîner les méthodes et pour évaluer la qualité des estimateurs !
- **Idée** :  $\mathbb{X} = \mathbb{X}^t \sqcup \mathbb{X}^v$ 
  - 1  $\mathbb{X}^t \implies (\hat{s}_m^t = \mathcal{A}_m(\mathbb{X}^t))_{m \in \mathcal{M}}$
  - 2  $\mathbb{X}^v \implies$  définir  $crit_{HO}(m)$  qui évalue la qualité de  $m$

# Validation simple

- Évaluer la qualité de chaque méthode
- **Problème** : utiliser les mêmes données pour entraîner les méthodes et pour évaluer la qualité des estimateurs !
- **Idée** :  $\mathbb{X} = \mathbb{X}^t \sqcup \mathbb{X}^v$ 
  - 1  $\mathbb{X}^t \implies (\hat{S}_m^t = \mathcal{A}_m(\mathbb{X}^t))_{m \in \mathcal{M}}$
  - 2  $\mathbb{X}^v \implies$  définir  $crit_{HO}(m)$  qui évalue la qualité de  $m$ 
$$\hat{m} \in \arg \min_{m \in \mathcal{M}} crit_{HO}(m)$$

# Validation simple

- Évaluer la qualité de chaque méthode
- **Problème** : utiliser les mêmes données pour entraîner les méthodes et pour évaluer la qualité des estimateurs !

- **Idée** :  $\mathbb{X} = \mathbb{X}^t \sqcup \mathbb{X}^v$

- 1  $\mathbb{X}^t \implies (\hat{s}_m^t = \mathcal{A}_m(\mathbb{X}^t))_{m \in \mathcal{M}}$

- 2  $\mathbb{X}^v \implies$  définir  $crit_{HO}(m)$  qui évalue la qualité de  $m$

$$\hat{m} \in \arg \min_{m \in \mathcal{M}} crit_{HO}(m)$$

- **Cas classique** :  $\ell(s, \hat{s}_m) = P(\gamma(\hat{s}_m, X) - \gamma(s, X))$ ,

choix idéal :  $m^* \in \arg \min_{m \in \mathcal{M}} \ell(s, \hat{s}_m) = \arg \min_{m \in \mathcal{M}} P(\gamma(\hat{s}_m, X))$

$$\implies crit_{HO}(m) = P_n^v \gamma(\hat{s}_m^t) := \frac{1}{|\mathbb{X}^v|} \sum_{X_i \in \mathbb{X}^v} \gamma(\hat{s}_m^t, X_i)$$

## Validation croisée V-fold (VCVF)

**Idée :**  $\mathbb{X} = \bigsqcup_{j=1}^V \mathbb{X}_j$  avec  $|\mathbb{X}_j| = n/V \quad \forall j \in \{1, \dots, V\}$ .

Pour chaque découpage  $j$ ,  $\mathbb{X} = \mathbb{X}_j^c \sqcup \mathbb{X}_j$ ,

- 1  $\mathbb{X}_j^c \implies (\hat{s}_{m,j} := \mathcal{A}_m(\mathbb{X}_j^c))_{m \in \mathcal{M}}$
- 2  $\mathbb{X}_j \implies$  définir  $crit_j(m)$  qui évalue la qualité de  $m$

$$\hat{m} \in \arg \min_{m \in \mathcal{M}} \frac{1}{V} \sum_{j=1}^V crit_j(m)$$

## Validation croisée V-fold (VCVF)

**Idée :**  $\mathbb{X} = \bigsqcup_{j=1}^V \mathbb{X}_j$  avec  $|\mathbb{X}_j| = n/V \quad \forall j \in \{1, \dots, V\}$ .

Pour chaque découpage  $j$ ,  $\mathbb{X} = \mathbb{X}_j^c \sqcup \mathbb{X}_j$ ,

- 1  $\mathbb{X}_j^c \implies (\hat{s}_{m,j} := \mathcal{A}_m(\mathbb{X}_j^c))_{m \in \mathcal{M}}$
- 2  $\mathbb{X}_j \implies$  définir  $crit_j(m)$  qui évalue la qualité de  $m$


$$\hat{m} \in \arg \min_{m \in \mathcal{M}} \frac{1}{V} \sum_{j=1}^V crit_j(m)$$

Seule la définition de  $crit_j(m)$  change, l'étape 1 est la même pour toutes les procédures de validation croisée !

# Intuition

Pour chaque  $j \in \{1, \dots, V\}$ , on a  $\mathbb{X} = \mathbb{X}_j^c \sqcup \mathbb{X}_j$ , où


- 1  $\mathbb{X}_j^c \implies (\hat{s}_{m,j} := \mathcal{A}_m(\mathbb{X}_j^c))_{m \in \mathcal{M}}$ .
- 2  $\mathbb{X}_j \implies$  comment choisir parmi une famille de points ?



# Intuition

Pour chaque  $j \in \{1, \dots, V\}$ , on a  $\mathbb{X} = \mathbb{X}_j^c \sqcup \mathbb{X}_j$ , où

- 1  $\mathbb{X}_j^c \implies (\hat{s}_{m,j} := \mathcal{A}_m(\mathbb{X}_j^c))_{m \in \mathcal{M}}$ .
- 2  $\mathbb{X}_j \implies \psi_{l,m}(\mathbb{X}_j) : \text{test "robuste" entre } \hat{s}_{l,j} \text{ et } \hat{s}_{m,j}$



# Test robuste

**Propriété fondamentale :** il existe des constantes  $a > 0$ ,  $\theta \in (0, 1/2)$ , tel que pour deux densités quelconques  $t, u$  et  $\forall z \in \mathbb{R}$ , on peut trouver un test  $\psi_{t,u}(\mathbb{X})$  qui satisfait :

$$\sup_{\{s|h(s,t) \leq \theta h(t,u)\}} \mathbb{P}[\psi_{t,u}(\mathbb{X}) = u] \leq \exp[-an(h^2(t, u) + z)];$$

$$\sup_{\{s|h(s,u) \leq \theta h(t,u)\}} \mathbb{P}[\psi_{t,u}(\mathbb{X}) = t] \leq \exp[-an(h^2(t, u) - z)].$$

# Test robuste

**Propriété fondamentale :** il existe des constantes  $a > 0$ ,  $\theta \in (0, 1/2)$ , tel que pour deux densités quelconques  $t, u$  et  $\forall z \in \mathbb{R}$ , on peut trouver un test  $\psi_{t,u}(\mathbb{X})$  qui satisfait :

$$\sup_{\{s|h(s,t) \leq \theta h(t,u)\}} \mathbb{P}[\psi_{t,u}(\mathbb{X}) = u] \leq \exp[-an(h^2(t, u) + z)];$$

$$\sup_{\{s|h(s,u) \leq \theta h(t,u)\}} \mathbb{P}[\psi_{t,u}(\mathbb{X}) = t] \leq \exp[-an(h^2(t, u) - z)].$$


Le test de rapport de vraisemblance ne vérifie **pas** cette propriété de robustesse !

# Nouvelle VCVF

$$\forall j \in \{1, \dots, V\}, m \in \mathcal{M}$$

$$\text{crit}_j(m) := \sup_{l \in \mathcal{R}_{m,j}} h^2(\hat{S}_{l,j}, \hat{S}_{m,j})$$

$$\text{où } \mathcal{R}_{m,j} = \{l \in \mathcal{M}, l \neq m \mid \psi_{l,m}(\mathbb{X}_j) = l\}.$$




# Nouvelle VCVF

$$\forall j \in \{1, \dots, V\}, m \in \mathcal{M}$$

$$\text{crit}_j(m) := \sup_{l \in \mathcal{R}_{m,j}} h^2(\hat{S}_{l,j}, \hat{S}_{m,j})$$

où  $\mathcal{R}_{m,j} = \{l \in \mathcal{M}, l \neq m \mid \psi_{l,m}(\mathbb{X}_j) = \emptyset\}$ .



# 1ère possibilité : Test de boule (Birgé)

$\hat{s}_{m,j}$



$\hat{s}_{l,j}$

**Cas classique** avec  $\gamma(t, x) = -\log(t(x))$

$\implies$  rapport de vraisemblance entre  $\hat{s}_{m,j}$  et  $\hat{s}_{l,j} : \frac{\hat{s}_{m,j}}{\hat{s}_{l,j}}(\mathbb{X}_j)$

# 1ère possibilité : Test de boule (Birgé)


$$\theta \in (0, 1/2)$$
$$r = \theta h(\tilde{s}_{m,j}, \tilde{s}_{l,j})$$



**Cas classique** avec  $\gamma(t, x) = -\log(t(x))$

$\implies$  rapport de vraisemblance entre  $\hat{s}_{m,j}$  et  $\hat{s}_{l,j}$  :  $\frac{\hat{s}_{m,j}}{\hat{s}_{l,j}}(\mathbb{X}_j)$

# 1ère possibilité : Test de boule (Birgé)



**Cas classique** avec  $\gamma(t, x) = -\log(t(x))$

$\implies$  rapport de vraisemblance entre  $\hat{s}_{m,j}$  et  $\hat{s}_{l,j}$  :  $\frac{\hat{s}_{m,j}}{\hat{s}_{l,j}}(\mathbb{X}_j)$

$\implies \psi_{l,m}(\mathbb{X}_j) = \frac{\tilde{s}_{m,j}}{\tilde{s}_{l,j}}(\mathbb{X}_j)$  test robuste

## 2ème possibilité : Formule variationnelle (Baraud)

Soient  $t$  et  $u$  deux densités,  $\ell(s, t) = h^2(s, t) = 1 - \rho(s, t)$ .

- Pour toute densité  $t$  :  $\rho(s, t) = \inf_{\{v \text{ densité}\}} \rho_v(P, t)$ ,  
où  $\rho_v(P, t) = \frac{1}{2} \left( \rho(t, v) + \int \sqrt{\frac{t}{v}} dP \right)$ .
- Soit  $v = \frac{t+u}{2}$  et  $T(P, t, u) = \rho_v(P, t) - \rho_v(P, u)$ .  
On a alors :  $T(P, t, u) \geq 0 \implies h^2(s, t) \leq \frac{\sqrt{2}+1}{\sqrt{2}-1} h^2(s, u)$ .

## 2ème possibilité : Formule variationnelle (Baraud)

Soient  $t$  et  $u$  deux densités,  $\ell(s, t) = h^2(s, t) = 1 - \rho(s, t)$ .

- Pour toute densité  $t$  :  $\rho(s, t) = \inf_{\{v \text{ densité}\}} \rho_v(P, t)$ ,  
où  $\rho_v(P, t) = \frac{1}{2} \left( \rho(t, v) + \int \sqrt{\frac{t}{v}} dP \right)$ .
- Soit  $v = \frac{t+u}{2}$  et  $T(P, t, u) = \rho_v(P, t) - \rho_v(P, u)$ .  
On a alors :  $T(P, t, u) \geq 0 \implies h^2(s, t) \leq \frac{\sqrt{2}+1}{\sqrt{2}-1} h^2(s, u)$ .

**Idée :**  $t$  meilleur que  $u \iff \rho(s, t) - \rho(s, u) \geq 0$   
 $\iff T(P, t, u) \geq 0 \iff T(P_n, t, u) \geq 0$

## 2ème possibilité : Formule variationnelle (Baraud)

Soient  $t$  et  $u$  deux densités,  $\ell(s, t) = h^2(s, t) = 1 - \rho(s, t)$ .

- Pour toute densité  $t$  :  $\rho(s, t) = \inf_{\{v \text{ densité}\}} \rho_v(P, t)$ ,  
 où  $\rho_v(P, t) = \frac{1}{2} \left( \rho(t, v) + \int \sqrt{\frac{t}{v}} dP \right)$ .
- Soit  $v = \frac{t+u}{2}$  et  $T(P, t, u) = \rho_v(P, t) - \rho_v(P, u)$ .  
 On a alors :  $T(P, t, u) \geq 0 \implies h^2(s, t) \leq \frac{\sqrt{2}+1}{\sqrt{2}-1} h^2(s, u)$ .

**Idée :**  $t$  meilleur que  $u \iff \rho(s, t) - \rho(s, u) \geq 0$   
 $\iff T(P, t, u) \geq 0 \iff T(P_n, t, u) \geq 0$

Au découpage  $j$ , on utilise  $\psi_{l,m}(\mathbb{X}_j) = l$  si  $T(\mathbb{X}_j, \hat{s}_{m,j}, \hat{s}_{l,j}) \geq 0$ .

# Résumé

$$\hat{m}_{VF} = \operatorname{argmin}_{m \in \mathcal{M}} \frac{1}{V} \sum_{j=1}^V \operatorname{crit}_j(m)$$

- Définition classique :  $\operatorname{crit}_j(m) := \frac{1}{|\mathbb{X}_j|} \sum_{X_i \in \mathbb{X}_j} \gamma(\hat{s}_{m,j}, X_i)$ .
- Définition alternative :  $\operatorname{crit}_j(m) := \sup_{l \in \mathcal{R}_{m,j}} h^2(\hat{s}_{l,j}, \hat{s}_{m,j})$ ,  
avec  $\mathcal{R}_{m,j} = \{l \in \mathcal{M} \mid l \neq m \mid \psi_{l,m}(\mathbb{X}_j) = \hat{l}\}$ .
- différence dans l'étape de validation :
  - fonction de contraste (estimation du risque)
  - tests robustes (prend en compte les autres compétiteurs)

## Comparaison au VF classique

### Du point de vue

- pratique : semble performante en terme de risque, sa qualité augmente avec  $V$
- algorithmique : nettement plus lente mais le coût n'est pas prohibitif
- théorique : une borne sur le risque Hellinger est possible sous une hypothèse très faible, **MAIS** les résultats restent insatisfaisants pour expliquer le choix de  $V$

## Perspectives : ne pas conclure !

Une autre procédure V-fold similaire peut être définie à l'aide du test de Baraud en effectuant la procédure V-fold sur le test !

Soit

- $\mathcal{T}(P_n, m, l) = \frac{1}{V} \sum_{j=1}^V T(\mathbb{X}_j, \hat{s}_{m,j}, \hat{s}_{l,j}),$
- $\mathcal{R}_m = \{l \in \mathcal{M}, l \neq m \mid \mathcal{T}(P_n, l, m) \geq 0\},$
- et  $\mathcal{D}(m) = \sup_{l \in \mathcal{R}_m} h^2(\hat{s}_l, \hat{s}_m).$

On choisit alors

$$\hat{m}_{\text{TVF}} \in \underset{m \in \mathcal{M}}{\operatorname{argmin}} \mathcal{D}(m) .$$

## Perspectives : ne pas conclure !

Une autre procédure V-fold similaire peut être définie à l'aide du test de Baraud en effectuant la procédure V-fold sur le test !

Soit

- $\mathcal{T}(P_n, m, l) = \frac{1}{V} \sum_{j=1}^V T(\mathbb{X}_j, \hat{s}_{m,j}, \hat{s}_{l,j}),$
- $\mathcal{R}_m = \{l \in \mathcal{M}, l \neq m \mid \mathcal{T}(P_n, l, m) \geq 0\},$
- et  $\mathcal{D}(m) = \sup_{l \in \mathcal{R}_m} h^2(\hat{s}_l, \hat{s}_m).$

On choisit alors

$$\hat{m}_{\text{TVF}} \in \underset{m \in \mathcal{M}}{\operatorname{argmin}} \mathcal{D}(m) .$$

Avantages : temps de calcul nettement moins lourd et très bon en pratique également !


Espoir : inégalité oracle plus fine grâce aux outils classiques des inégalités de concentration.

Fin


Merci

# Influence de $V$ ; $\ell = h^2$


## Histogrammes réguliers :



## Estimateurs à noyau gaussien :




# Histogrammes réguliers : $\ell = h^2$



La différence

- La différence augmente avec  $V$  pour les 3 procédures
- La différence augmente avec  $n$  pour le KLVF

# Histogrammes réguliers : $\ell = h^2$




La différence

- La différence augmente avec  $V$  pour les 3 procédures
- La différence augmente avec  $n$  pour le KLVF

Même conclusions pour les autres pertes !


# Estimateurs à noyau : $\ell = h^2$

- ucv unbiased cross-validation
- SJ implements the methods of Sheather & Jones (1991) to select the bandwidth using pilot estimation of derivatives



# Histogrammes réguliers, irréguliers et estimateurs à noyau

## LSVF



## KLVF

