

Statistiques et Sélection de modèles


Sylvain Arlot

20 avril 2007

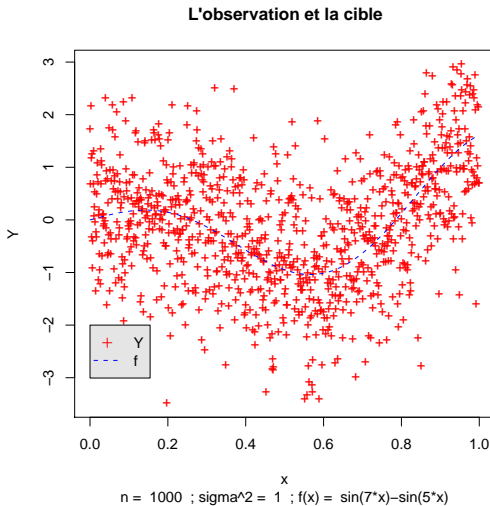
Part I

Introduction


Une observation



But : retrouver le signal d'origine



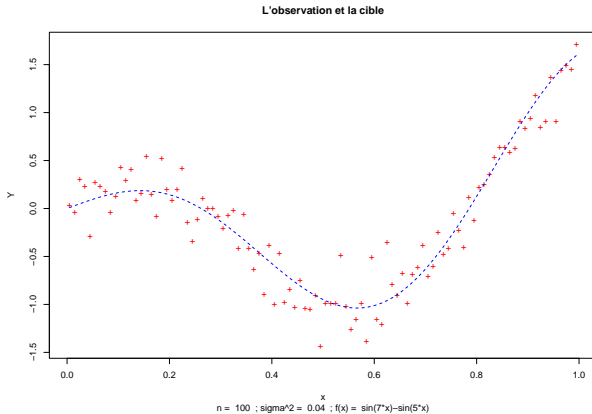
La fonction cible : $f(x) = \sin(7 \cdot x) - \sin(5 \cdot x)$




Comment faire ?

Part II

Estimation par histogrammes



Histogramme à 9 pas



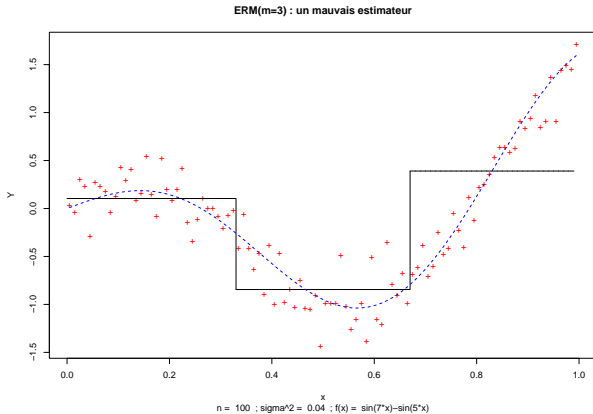
Quel est le “meilleur” histogramme estimant le signal ?

Part III

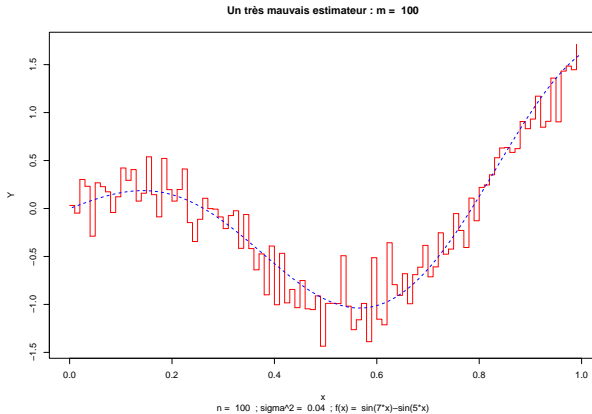
Sélection de modèles

$1 \leq D \leq n \rightarrow \hat{s}_D$ histogramme à D pas


- Quel est le meilleur D ?
- Comment le trouver ?



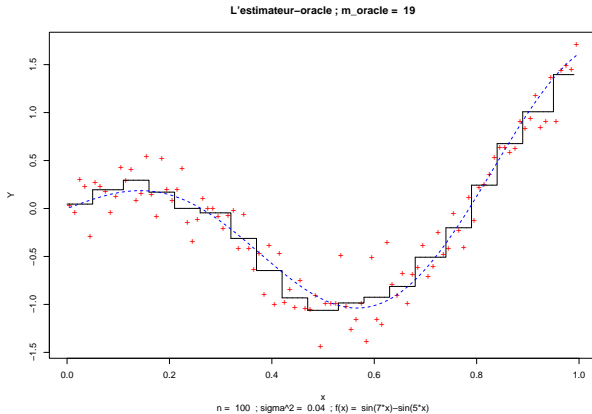
Histogrammes : $D = n = 100$



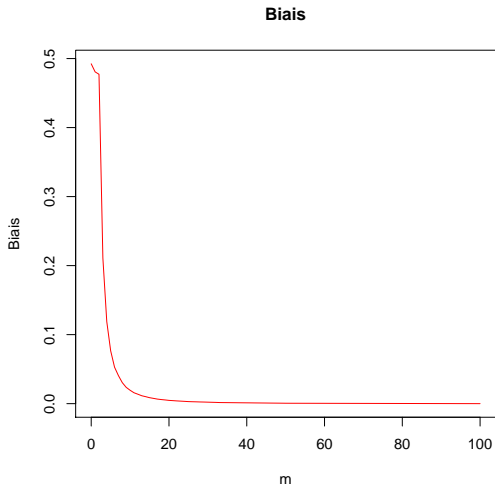
Histogrammes : $D = 16$



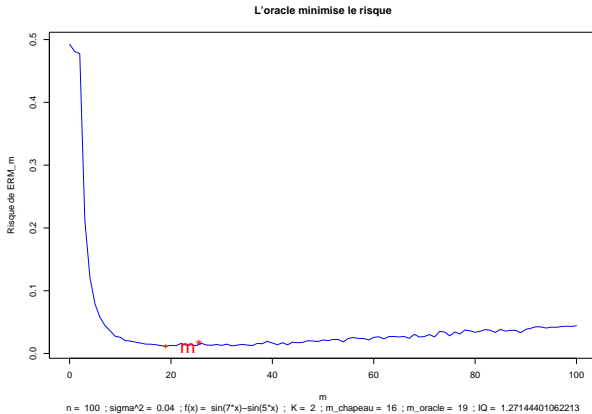
Histogrammes : $D = 19$



Le biais décroît : on ne cherche pas le “vrai” modèle

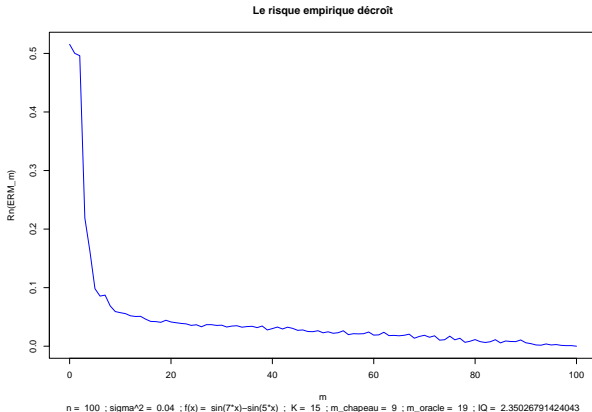


Risque en fonction du nombre D de paramètres



Part IV


Comment choisir le meilleur modèle ?



Part V


Première méthode : validation

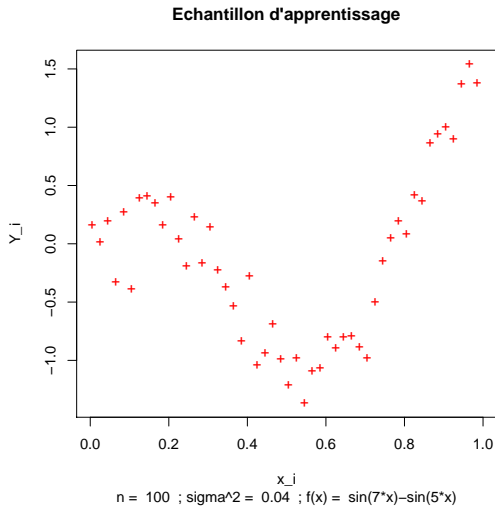
Une observation

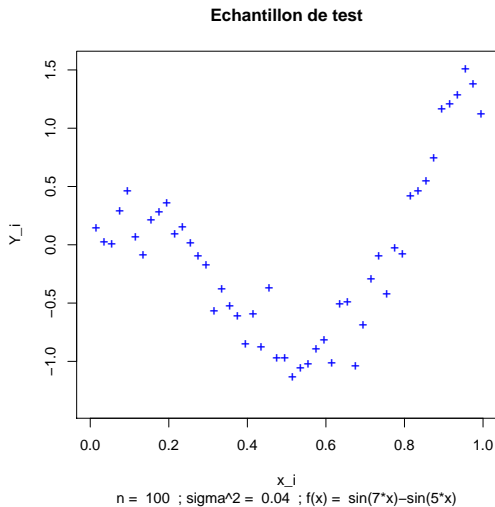


On la découpe en deux parties

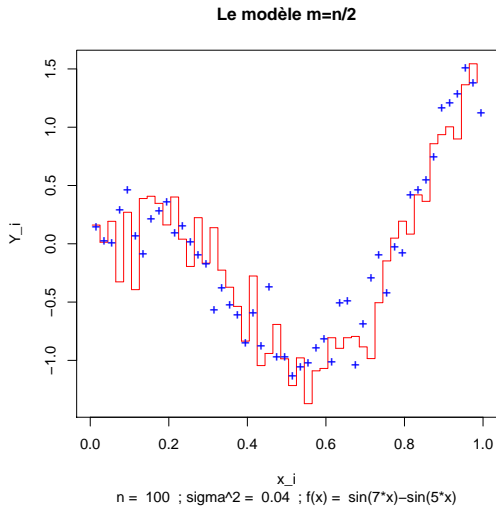
Une observation








Un mauvais choix : $D = 50 = n/2$.




Le modèle sélectionné : $m = 13$




Part VI

Deuxième méthode : pénalisation

Décomposition biais-variance du risque



Risque, biais, risque empirique : pénalité idéale



Part VII

Estimation de la variance


Si l'on connaît les ϵ_j

Si l'on connaît les $\epsilon_j + s_1$

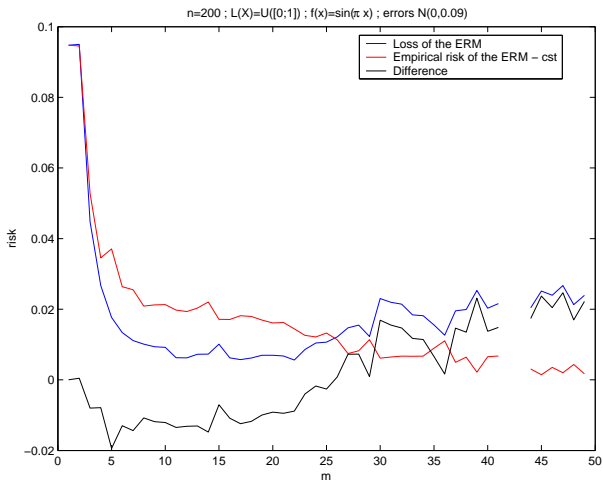
Si l'on ne connaît que $Y_i = \epsilon_i + s(X_i)$

À partir de la courbe $R_n(D)$ du risque empirique

Heuristique de pente : espérances




Heuristique de pente : une réalisation



Heuristique de pente : $\hat{D}(K)$

L'estimateur sélectionné en fonction de K, pour une observation

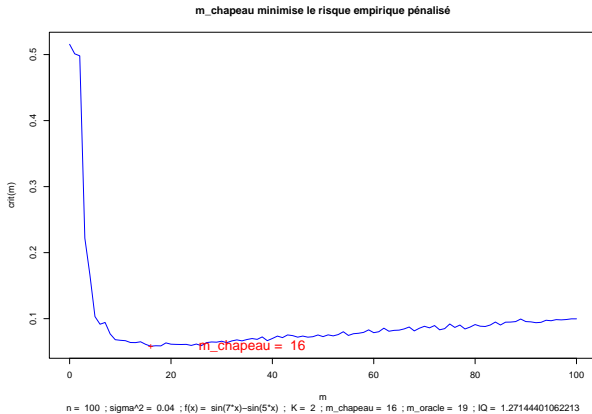


Bilan : sélection de modèles par pénalisation


Part VIII

Pénalisation : simulations numériques

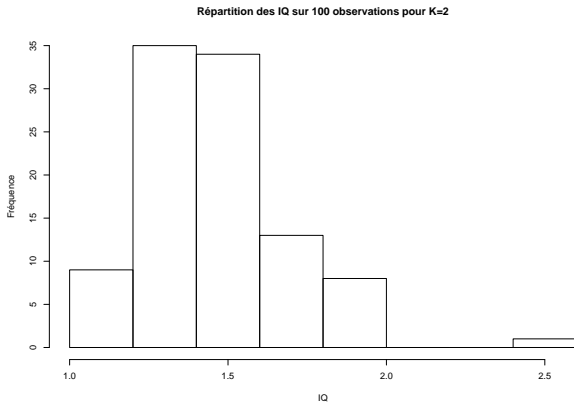
Pénalité de Mallows : $\text{crit}(m)$.



Pénalité de Mallows : $\hat{D} = 16$.



$K = 2$: répartition de $\mathcal{I}_Q = \frac{d_n(s, \hat{s}_D)^2}{d_n(s, \hat{s}_{D^*})^2}$ (moy. ≈ 1.45)




Part IX

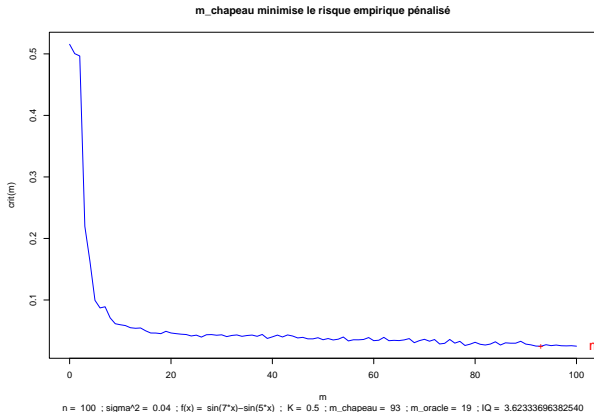
Doit-on sur-pénaliser ou sous-pénaliser ?

Choix de K dans la pénalité $K \times D/n$?

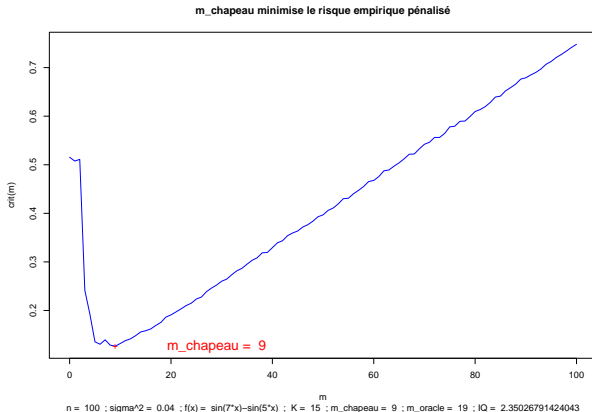
L'estimateur sélectionné en fonction de K , pour une observation



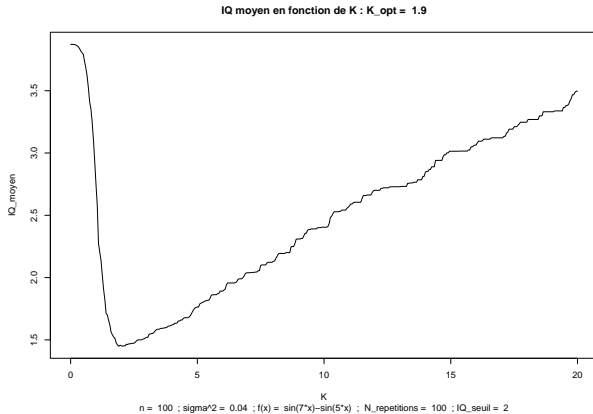
Pourquoi éviter K petit : $\text{crit}(m)$




Pourquoi éviter K grand : crit(m)



Il faut éviter $K \leq 1$ ou $K \gg 1$.




$1,5 \leq K \leq 4$ semble un bon choix.

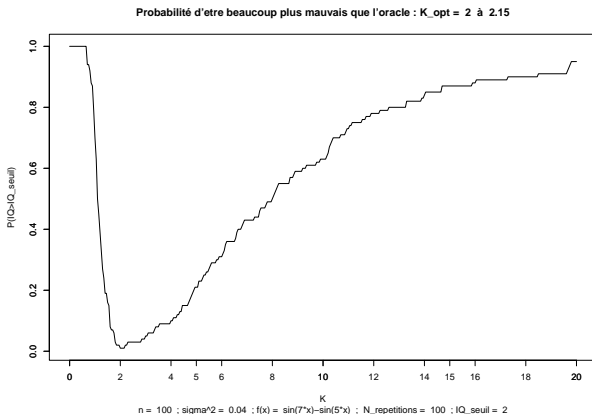


$\frac{\text{Risque}(\widehat{s}_D)}{\text{Risque}(\widehat{s}_{D^*})}$ en fonction de K : $K_{\text{opt}} = 2,15$.

Rapport des risques de l'estimateur et de l'oracle ; $K_{\text{opt}} = 2.15$



$\mathbb{P}(\mathcal{I}_Q > 2)$ en fonction de K : $2 \leq K_{\text{opt}} \leq 2,15$



Part X

Apprentissage