

Utilisation d'approches probabilistes basées sur les critères entropiques pour la recherche d'informations sur supports multimédia.

Guilhem Coq

Sous la direction de :
M. Arnaudon (LMA), C. Olivier (XLIM-SIC) et O. Alata (XLIM-SIC).

5 décembre 2008
Université de Poitiers

Modélisation de données par une expérience probabiliste.

- Données :
 - Signaux unidimensionnels : son, mesure physiologique, télécommunication.
 - Signaux bidimensionnels : images.
- Modélisation
 - Description du phénomène.
 - Famille de modèles, paramétriques ou non.
 - Sélection de modèles.
- Probabilités :
 - Mesurent la pertinence du modèle face à l'observation par le maximum de vraisemblance.

Surparamétrisation

Exemple de la régression gaussienne polynomiale


→ pertinence \sim erreur quadratique par rapport aux données.



Surparamétrisation

Exemple de la régression gaussienne polynomiale

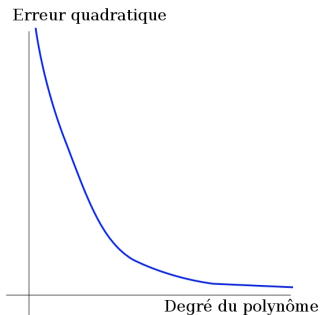

→ pertinence \sim erreur quadratique par rapport aux données.



Surparamétrisation

Exemple de la régression gaussienne polynomiale

→ pertinence \sim erreur quadratique par rapport aux données.



Critères d'information

- $(\Theta_i)_{i \in I}$: les modèles en compétition.
- $-\log \hat{\mathbb{P}}_{\Theta_i}(\mathbf{x})$: mesure d'adéquation, à minimiser.
- Critère d'information :

$$\text{IC}(\Theta_i) = \underbrace{-2 \log \hat{\mathbb{P}}_{\Theta_i}(\mathbf{x})}_{\text{vraisemblance}} + \underbrace{|\Theta_i| \alpha(n)}_{\text{pénalité}}.$$

- Sélection du modèle par :

$$\hat{i} = \text{Argmin}(\text{IC}(\Theta_i), i \in I).$$

→ Comportement inverse, recherche de compromis.

Critères d'information

- $(\Theta_i)_{i \in I}$: les modèles en compétition.
- $-\log \hat{\mathbb{P}}_{\Theta_i}(\mathbf{x})$: mesure d'adéquation, à minimiser.
- Critère d'information :

$$\text{IC}(\Theta_i) = \underbrace{-2 \log \hat{\mathbb{P}}_{\Theta_i}(\mathbf{x})}_{\text{vraisemblance}} + \underbrace{|\Theta_i| \alpha(n)}_{\text{pénalité}}.$$

- Sélection du modèle par :

$$\hat{i} = \text{Argmin}(\text{IC}(\Theta_i), i \in I).$$

→ Comportement inverse, recherche de compromis.

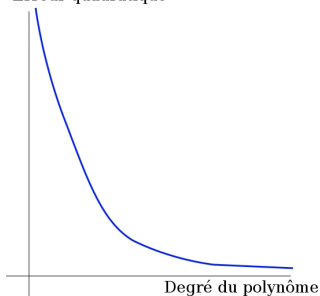
Critères d'information

- Critère d'information :

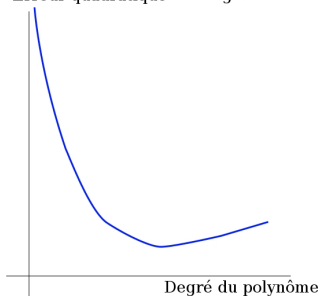
$$IC(\Theta_i) = \underbrace{-2 \log \hat{\mathbb{P}}_{\Theta_i}(\mathbf{x})}_{\text{vraisemblance}} + \underbrace{|\Theta_i| \alpha(n)}_{\text{pénalité}}.$$

→ Comportement inverse, recherche de compromis.

Erreur quadratique



Erreur quadratique + 2.degré



Motivation principale

Comment et pourquoi choisir $\alpha(n)$?

- Akaike 74 AIC : $\alpha(n) = 2$, minimisation d'un risque.
- Schwarz 78 BIC : $\alpha(n) = \log n$, bayésien.
- Hannan-Quinn 79 φ : $\alpha(n) = \log \log n$, consistance.
- Rissanen 86 MDL : $\alpha(n) = \log n$, théorie de l'information
→ Complexité stochastique, inégalité entropique
- Nishii 88 : conditions sur $\alpha(n)$ entraînant consistance.
→ El-Matouat, Hallin 96 φ_β : $\alpha(n) = n^\beta \log \log n$, $\beta \in]0, 1[$
- Rissanen 92 : cadre non-paramétrique, histogrammes.
- Broersen 00 : intérêt pour le non-asymptotique.
- Baraud, Barron, Birgé, Castellan, Massart récemment :
 $\alpha(n) = \text{constante}$, contrôle non-asymptotique du risque, inégalités oracle.

Motivation principale

Comment et pourquoi choisir $\alpha(n)$?

- Akaike 74 AIC : $\alpha(n) = 2$, minimisation d'un risque.
- Schwarz 78 BIC : $\alpha(n) = \log n$, bayésien.
- Hannan-Quinn 79 φ : $\alpha(n) = \log \log n$, consistance.
- Rissanen 86 MDL : $\alpha(n) = \log n$, théorie de l'information
 - Complexité stochastique, inégalité entropique
- Nishii 88 : conditions sur $\alpha(n)$ entraînant consistance.
 - El-Matouat, Hallin 96 φ_β : $\alpha(n) = n^\beta \log \log n$, $\beta \in]0, 1[$
- Rissanen 92 : cadre non-paramétrique, histogrammes.
- Broersen 00 : intérêt pour le non-asymptotique.
- Baraud, Barron, Birgé, Castellan, Massart récemment :
 $\alpha(n) = \text{constante}$, contrôle non-asymptotique du risque, inégalités oracle.

Codages et inégalité entropique de Rissanen

- Shannon 48 (Jensen) :

$$-\sum_{x \in E} P(x) \log P(x) = H(P) \leq H(P, Q) = -\sum_{x \in E} P(x) \log Q(x)$$

→ le terme de vraisemblance dans IC estime $H(P)$.

- Rissanen : complexité stochastique, notion d'*adaptation* :

$$C_{\Theta}(x) = -\sum_{i=1}^n \log \hat{P}_{\Theta}^{(i-1)}(x_i),$$

$$H_n(P) + |\Theta| \frac{\log n}{2} \leq \mathbb{E} C_{\Theta}(x).$$

→ $\alpha(n) = \log n$, IC(Θ) estime $C_{\Theta}(x)$

→ Adaptation \sim pénalisation.

Codages et inégalité entropique de Rissanen

- Shannon 48 (Jensen) :

$$-\sum_{x \in E} P(x) \log P(x) = H(P) \leq H(P, Q) = -\sum_{x \in E} P(x) \log Q(x)$$

→ le terme de vraisemblance dans IC estime $H(P)$.

- Rissanen : complexité stochastique, notion d'*adaptation* :

$$C_{\Theta}(x) = -\sum_{i=1}^n \log \hat{P}_{\Theta}^{(i-1)}(x_i),$$

$$H_n(P) + |\Theta| \frac{\log n}{2} \leq \mathbb{E} C_{\Theta}(x).$$

→ $\alpha(n) = \log n$, IC(Θ) estime $C_{\Theta}(x)$

→ Adaptation \sim pénalisation.

Codages et inégalité entropique de Rissanen

- Shannon 48 (Jensen) :

$$-\sum_{x \in E} P(x) \log P(x) = H(P) \leq H(P, Q) = -\sum_{x \in E} P(x) \log Q(x)$$

→ le terme de vraisemblance dans IC estime $H(P)$.

- Rissanen : complexité stochastique, notion d'*adaptation* :

$$C_{\Theta}(x) = -\sum_{i=1}^n \log \hat{P}_{\Theta}^{(i-1)}(x_i),$$

$$H_n(P) + |\Theta| \frac{\log n}{2} \leq \mathbb{E} C_{\Theta}(x).$$

- $\alpha(n) = \log n$, IC(Θ) estime $C_{\Theta}(x)$
- Adaptation \sim pénalisation.

Application : estimation de densité par histogramme

- La minimisation d'un codage en deux temps :
 - Codage des données discrétisées sur la partition
 - Codage de précision sans perte

amène le critère


$$\text{CRIT}(\Pi) = - \sum_{j=1}^m n_j \log \frac{n_j}{nL_j} + m \frac{\log n}{2}.$$

- On choisit la partition par :


$$\hat{\Pi} = \text{Argmin}(\text{CRIT}(\Pi), \Pi \in \mathcal{P}).$$

Application : estimation de densité par histogramme

$$\text{CRIT}(\Pi) = - \sum_{j=1}^m n_j \log \frac{n_j}{nL_j} + m \frac{\log n}{2}.$$



$\text{KL}(H, \beta) = 1,2$




$\text{KL}(H, \beta) = 0,89$


→ Application : reconnaissance de loi via Kullback-Leibler sur les histogrammes

Application : estimation de densité par histogramme

- Quantification d'image :



256 classes



39 classes



PSNR = 38,52 dB

→ Application aux domaines transformés.

Modèles paramétriques

- $\Theta \subset \mathbb{R}^d$ espace des paramètres.

$$\Theta_S = \{\theta \in \Theta \mid \theta_j = 0, j \notin S\}, \quad S \subset \llbracket 1, d \rrbracket.$$

- Nishii 88 : si $\theta^* \in \Theta_{S^*}$ et $\widehat{S} = \text{Argmin}(\text{IC}(\Theta_S), S \subset \llbracket 1, d \rrbracket)$ alors

$$\frac{\log \log n}{\alpha(n)} \longrightarrow 0 \text{ et } \frac{\alpha(n)}{n} \longrightarrow 0 \implies \widehat{S} \xrightarrow{\text{p.s.}} S^*$$

- Introduction du critère φ_β par El-Matouat et Hallin 96 :

$$\alpha(n) = n^\beta \log \log n, \quad \beta \in]0, 1[.$$

Modèles paramétriques

- $\Theta \subset \mathbb{R}^d$ espace des paramètres.

$$\Theta_S = \{\theta \in \Theta \mid \theta_j = 0, j \notin S\}, \quad S \subset \llbracket 1, d \rrbracket.$$

- Nishii 88 : si $\theta^* \in \Theta_{S^*}$ et $\widehat{S} = \text{Argmin}(\text{IC}(\Theta_S), S \subset \llbracket 1, d \rrbracket)$ alors

$$\frac{\log \log n}{\alpha(n)} \longrightarrow 0 \text{ et } \frac{\alpha(n)}{n} \longrightarrow 0 \implies \widehat{S} \xrightarrow{\text{p.s.}} S^*$$

- Introduction du critère φ_β par El-Matouat et Hallin 96 :

$$\alpha(n) = n^\beta \log \log n, \quad \beta \in]0, 1[.$$

Les méthodes comparatives

- Méthode globale : $\hat{S} = \text{Argmin}(\text{IC}(\Theta_S), S \subset \llbracket 1, d \rrbracket)$:
 - 2^d critères à calculer.
 - Introduction des méthodes comparatives.

- Méthode comparative (Nishii 88)

$$\begin{cases} \text{IC}_{\text{ref}} = \text{IC}(\llbracket 1, d \rrbracket) \\ \hat{S} = \{j \in \llbracket 1, d \rrbracket, \text{IC}_{\text{ref}} \leq \text{IC}(\llbracket 1, d \rrbracket \setminus \{j\})\}. \end{cases}$$

- $d + 1$ critères à calculer.
- Méthode comparative inversée
 - $d + 1$ critères à calculer.
- Méthode comparative descendante
 - Au plus $d(d + 1)/2$ critères à calculer.

Résultats concernant la régression

- Avec les méthodes
 - comparative,
 - comparative inversée dans le cas orthonormal,
 - comparative inversée adaptée,
 - comparative descendante,

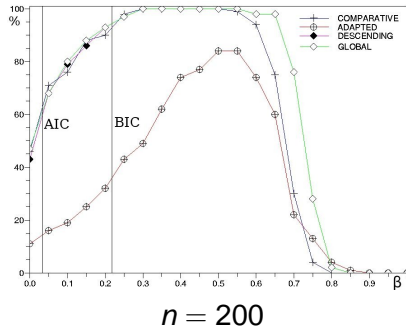
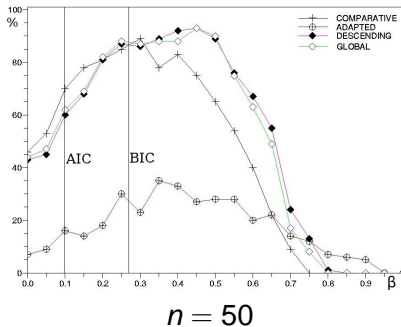
on obtient, sous les conditions de Nishii :

- Consistance forte.
- Equivalence asymptotique du risque avec le risque oracle.

- Lorsque $\alpha(n) = \text{cste}$, la méthode comparative descendante permet l'obtention d'une inégalité oracle non-asymptotique.

Résultats concernant la régression : illustration

- Fonction inconnue : $-x + \cos 2x - \sin 2x$.
- Régression sur $\text{Vect}(x, x^2, \cos x, \cos 2x, \sin x, \sin 2x)$.
- Utilisation de φ_β , $\alpha(n) = n^\beta \log \log n$, pour $\beta \in]0, 1[$.



Conclusions, perspectives

- La pénalité dépend du type de propriété souhaitée
 - Pas de "critère-miracle" mis en évidence
- Les méthodes comparatives permettent une description précise et rapide du modèle :
 - Choix des harmoniques principales d'un signal périodique.
 - Détermination du support d'autorégression d'une image.
- L'estimation par histogramme régulier ou non :
 - Reconnaissance de loi : à partir des densités estimées.
 - Images : quantification des coefficients transformés, élimination de la corrélation résiduelle.

MERCI A TOUS!