

Sélection de variables dans les modèles mixtes fonctionnels

Madison Giacomini
Equipe SAM

Sophie Lambert-Lacroix (TIMC - Grenoble)
Franck Picard (LBBE - Lyon)

Journée de rentrée des doctorants en statistique
Mardi 20 novembre 2012

Contexte

- On s'intéresse au problème de sélection de variables
- Considérons le modèle de régression pour $i = 1, \dots, N$:

$$\mathbf{Y}_i = \mathbf{X}_i \boldsymbol{\beta} + \mathbf{E}_i \quad \text{où } \mathbf{E}_i \sim \mathcal{N}(0, \sigma_E^2 \mathbf{I})$$

avec $\boldsymbol{\beta} = (\beta_1, \dots, \beta_M)$ vecteur de variables explicatives

- But de la sélection de variables :
 - Avoir un modèle interprétable
 - Réduire la variance des estimateurs
 - Stabiliser les estimateurs

Régression pénalisée

- Dans les années 90, développement des techniques de régression pénalisée pour la sélection de variables
 - La plus populaire : Régression LASSO basée sur la norme ℓ_1 des paramètres [Tib96]

$$\hat{\beta} = \arg \min \|\bar{\mathbf{Y}} - \mathbf{X}\beta\|^2 + \lambda\|\beta\|_1$$

avec λ paramètre de régularisation à déterminer.

⇒ Sélection de variables grâce à la présence d'une singularité en zéro.

- Dans un cadre de régression non paramétrique fonctionnelle

$$Y_i(t_m) = \mu(t_m) + E_i(t_m)$$

- En projetant sur une base d'ondelettes, le modèle sur les coefficients empiriques devient :

$$d_{ijk} = \beta_{jk} + \varepsilon_{ijk} \quad \text{où } \varepsilon_{ijk} \sim \mathcal{N}(0, \sigma_\varepsilon^2)$$

Seuillage

- Cadre fonctionnel : design orthogonal
⇒ LASSO est équivalent à un seuillage doux des coefficients [DJ94]
défini par :

$$\widehat{\beta}_{jk} = \text{sign}(d_{\bullet,jk}) (d_{\bullet,jk} - \lambda)_+$$

- Associé avec le seuillage dit dur :

$$\widehat{\beta}_{jk} = d_{\bullet,jk} \mathbf{1}_{\{|d_{\bullet,jk}| > \lambda\}}$$

- Dépendent d'un paramètre de régularisation λ
⇒ Seuil universel : $\lambda = \widehat{\sigma}_\varepsilon \sqrt{2 \log M}$ [DJ94]
- Seuillages near-minimax : vitesse de convergence optimale dans la classe des espaces de Besov à un facteur $\log M$ près.


Seuillage SCAD

- Inconvénients : biais sur les grands coefficients (seuillage doux), instabilité des estimations (seuillage dur)
- Seuillage SCAD [FL01]
 - ⇒ Réalise un compromis entre les seuillages doux et dur

$$\hat{\beta}_{jk} = \begin{cases} \text{sign}(d_{\bullet jk}) (d_{\bullet jk} - \lambda)_+ & \text{si } |d_{\bullet jk}| \leq 2\lambda \\ \frac{1}{a-2} [(a-1)d_{\bullet jk} - a\lambda \text{sign}(d_{\bullet jk})] & \text{si } 2\lambda > |d_{\bullet jk}| \leq a\lambda \\ d_{\bullet jk} & \text{si } |d_{\bullet jk}| > a\lambda \end{cases}$$

avec a et λ paramètres de régularisation (habituellement, $a = 3.7$ par des arguments bayésiens).

Représentation des différents seuillages



Seuillage SCAD [2]

- Equivalent à un problème de régression pénalisée :

$$\text{pen}_{\text{SCAD}}(\beta_{jk}; \lambda) = \lambda |\beta_{jk}| \mathbf{1}_{\{\beta_{jk} \leq \lambda\}} + \frac{(a+1)\lambda^2}{2} \mathbf{1}_{\{\beta_{jk} > a\lambda\}} \\ - \frac{|\beta_{jk}^2| - 2a\lambda|\beta_{jk}^2| + \lambda^2}{2(a-1)} \mathbf{1}_{\{\lambda < \beta_{jk} \leq a\lambda\}}$$

- Utilisé avec le seuil universel
- Bonnes propriétés de convergence (vitesse near-minimax avec le seuil universel)
- Possède des propriétés oraculaires (sélection de variables et normalité asymptotique).

Modèle mixte fonctionnel

- Ajout d'effets individuels fonctionnels pour modéliser la variabilité inter-individuelle

$$Y_i(t_m) = \mu(t_m) + U_i(t_m) + E_i(t_m)$$

conduisant sur les coefficients d'ondelettes :

$$d_{ijk} = \beta_{jk} + \theta_{ijk} + \varepsilon_{ijk}$$

avec :

$$\begin{cases} \varepsilon_i & \sim \mathcal{N}(0, \sigma_\varepsilon^2 \mathbf{I}) \\ \theta_i & \sim \mathcal{N}(0, \mathbf{G}_\theta) \end{cases} \quad \text{et} \quad \mathbf{G}_\theta = \text{Diag}(2^{-j\eta} \gamma_{jk}^2).$$

- Représentation parcimonieuse de l'effet fixe μ dans le domaine des ondelettes
 \Rightarrow On peut penser qu'il en est de même pour $U_i(t)$

Vraisemblance pénalisée

- Proposition : Retrouver cette parcimonie par une sélection des effets fixes β et des variances des effets aléatoires γ .
- Idée : basée sur les techniques de vraisemblance pénalisée en utilisant une pénalité de type SCAD.
- Problème d'optimisation

$$q(\lambda_1, \lambda_2) = \log \mathcal{L}(\mathbf{d}; \beta, \mathbf{G}_\theta, \sigma_\varepsilon^2) + \text{pen}_{\text{SCAD}}(\beta; \lambda_1) + \text{pen}_{\text{SCAD}}(\gamma; \lambda_2)$$

⇒ On cherche à minimiser ce critère

Propriétés asymptotiques

- Pour $\Upsilon = (\beta^T, \gamma^T)^T$ et sous certaines hypothèses concernant la vraisemblance et le terme de pénalité

Théorème

On suppose les hypothèses (H1)-(H7) vérifiées. De plus, on suppose que $\sqrt{\frac{N}{M}}\lambda \rightarrow \infty$ si $\lambda \rightarrow 0$ et $\frac{M^5}{N} \rightarrow 0$ quand $N \rightarrow \infty$. Alors, avec une probabilité tendant vers 1, l'estimateur

$\sqrt{N/M}$ -consistant $\hat{\Upsilon} = \begin{bmatrix} \hat{\Upsilon}^1 \\ \hat{\Upsilon}^2 \end{bmatrix}$ vérifie :

- (Parcimonie) $\hat{\Upsilon}_2 = 0$
- (Normalité Asymptotique)

$$\sqrt{N}\mathbf{A}_N\mathcal{I}^{-\frac{1}{2}}(\Upsilon_0^1) [\mathcal{I}(\Upsilon_0^1) + \mathbf{P}_N] \left[\hat{\Upsilon}^1 - \Upsilon_0^1 + (\mathcal{I}(\Upsilon_0^1) + \mathbf{P}_N)^{-1}\mathbf{p}_N \right] \xrightarrow{\mathcal{D}} \mathcal{N}(0, \mathbf{H})$$

où \mathbf{A}_N est une matrice de taille $q \times s_N$ telle que $\mathbf{A}_N\mathbf{A}_N^T \rightarrow \mathbf{H}$, avec \mathbf{H} matrice symétrique positive.

Procédure d'estimation

- Présence de données non-observées (effets individuels)
⇒ Utilisation de l'algorithme EM
- Se déroule en 2 étapes
 - Etape E : Prédiction des effets aléatoires (calcul de l'espérance conditionnelle du critère $q(\lambda_1, \lambda_2)$)
 - Etape M : Maximisation selon les paramètres β , γ et σ_ε^2 séparément (variante ECM)
- Conduit à des seuillages de type SCAD
 - $\beta \rightsquigarrow$ Seuillage des données corrigées des prédictions des effets aléatoires
 - $\gamma \rightsquigarrow$ Seuillage des données centrées et normalisées par les prédictions des effets aléatoires

Prochaines étapes

- Etude de simulation pour évaluer les performances :
 - en terme de sélection de variables sur les effets fixes et aléatoires
 - en terme de précision des estimateurs
 - question subsidiaire : quel est le gain par rapport au seuillage habituel avec estimation robuste de la variance ?

- Applications à des données réelles issues de la biologie moléculaire.



D.L. Donoho and I.M. Johnstone.

Ideal spatial adaptation by wavelet shrinkage.

Biometrika, 81(3) :425–455, 1994.



J. Fan and R. Li.

Variable selection via nonconcave penalized likelihood and its oracle properties.

Journal of the American Statistical Association, 96(456) :1348–1360, 2001.



R. Tibshirani.

Regression shrinkage and selection via the lasso.

Journal of the Royal Statistical Society Series B, 58(1) :267–288, 1996.