

Rencontre EMSE/3MI - CEA/LETI

Splines et krigeage

L. Carraro – 12 juin 07

Ecole des mines de Saint-Etienne

carraro@emse.fr
www.emse.fr/~carraro

PLAN

- Approximation et interpolation
- Splines cubiques en 1D
- Krigeage
- Des noyaux
- Éléments de comparaison

Approximation/interpolation

Estimation non paramétrique :

données = couples (x_i, y_i) pour $1 \leq i \leq n$

modèle :

$$y_i = g(x_i) + \varepsilon_i, \text{ où } \varepsilon_i \text{ est un bruit de variance } \sigma^2$$

estimation de g ?

$$-2 \log L(f) \propto (1/\sigma^2) \sum_{i=1}^n (y_i - g(x_i))^2$$

Problème mal posé :

- ◆ Pénaliser
- ◆ Informations a priori

Régularisation

Fonction de coût pénalisée :

critère à minimiser :

$$C(g) = \mathbf{L}(\mathbf{Y}, g(\mathbf{X})) + \lambda J(g)$$

- ♦ J est une fonctionnelle mesurant la régularité de g
- ♦ λ est un paramètre de lissage

$$\mathbf{L}(\mathbf{Y}, g(\mathbf{X})) = \sum_{i=1}^n (y_i - g(x_i))^2$$

Plus généralement,

$$\mathbf{L}(\mathbf{Y}, g(\mathbf{X})) = -2 \log L(g), \text{ ou } \mathbf{L}(\mathbf{Y}, g(\mathbf{X})) = \sum_{i=1}^n D(y_i, g(x_i))$$

D mesure une distance entre y_i et $g(x_i)$

Cas limites

● $\lambda \rightarrow +\infty$ $\text{Min}_{J(g)=0} \sum_{i=1}^n D(y_i, g(x_i))$

Souvent, $\{g, J(g) = 0\}$ est de dim finie

➡ régression linéaire

● $\lambda \rightarrow 0$ $\text{Min}_{g(x_i)=y_i} J(g)$

➡ interpolation

Splines cubiques

$$g : [0, 1] \rightarrow \mathbb{R}$$

$$C(g) = \sum_{i=1}^n (y_i - g(x_i))^2 + \lambda \int_0^1 g''(x)^2 dx$$

Solution de la forme (calcul des variations) :

$$g_\lambda(x) = \beta_\lambda(0) + \beta_\lambda(1)x + \sum_{i=1}^n \alpha_\lambda(i) K(x - x_i)$$

K est la fonction de Green de l'opérateur $\frac{d^4}{dx^4}$

$$K(h) = \frac{h^3}{6} +$$

Solution complète

$$g_\lambda(x) = \beta_\lambda(0) + \beta_\lambda(1)x - \sum_{i=1}^n \alpha_\lambda(i) K(x - x_i)$$

Espace nul

Noyau

En écriture matricielle :

$$g(x) = f(x)\beta + k(x)\alpha, \text{ et } f(x) = (1 \ x), \beta = \begin{pmatrix} \beta(0) \\ \beta(1) \end{pmatrix} \text{ etc...}$$

$$\mathbf{G} = (g(x_1) \dots g(x_n))' = \mathbf{F}\beta + \mathbf{K}\alpha$$

et $\int_0^1 K''(x-x_i)K''(x-x_j)dx = K(x_i-x_j)$ (K fonction de Green)

$$C(g) = C(\alpha, \beta) = (\mathbf{Y} - \mathbf{F}\beta - \mathbf{K}\alpha)'(\mathbf{Y} - \mathbf{F}\beta - \mathbf{K}\alpha) + \lambda \alpha' \mathbf{K} \alpha$$

Un peu de calcul...

β fixé, $\operatorname{argmin} C(\alpha, \beta)$ donne $\alpha(\beta) = (K + \lambda \operatorname{Id})^{-1} (\mathbf{Y} - \mathbf{F} \beta)$

D'où l'expression (Spline) :

$$g_\lambda(x) = f(x) \hat{\beta} + k(x) (K + \lambda \operatorname{Id})^{-1} (\mathbf{Y} - \mathbf{F} \hat{\beta})$$

$$\hat{\beta} = \left\{ \mathbf{F}' \left[\operatorname{Id} - K (K + \lambda \operatorname{Id})^{-1} \right] \mathbf{F} \right\}^{-1} \mathbf{F}' \left[\operatorname{Id} - K (K + \lambda \operatorname{Id})^{-1} \right] \mathbf{Y}$$

Cas limites :

$$\lambda \rightarrow 0, g(x) = f(x) \hat{\beta} + k(x) K^{-1} (\mathbf{Y} - \mathbf{F} \hat{\beta})$$

$$\hat{\beta} = \{ \mathbf{F}' K^{-1} \mathbf{F} \}^{-1} \mathbf{F}' K^{-1} \mathbf{Y}$$

$$\lambda \rightarrow +\infty, g(x) = f(x) \hat{\beta}$$

$$\hat{\beta} = \{ \mathbf{F}' \mathbf{F} \}^{-1} \mathbf{F}' \mathbf{Y}$$

Remarques

● Résultats matriciels généraux

- ◆ Rôle clé du noyau K et de la formule :

$$\langle K(\cdot - x_i) | f \rangle = f(x_i)$$

soit $\langle K(\cdot - x) | f \rangle = f(x)$

↳ Espaces de Hilbert à noyau reproduisant (RKHS)

● Critères pénalisés généraux : solutions de la forme :

$$g(x) = f(x)\beta + k(x)\alpha$$

- ◆ Cas de coûts non quadratiques :
système non linéaire en α et β .

Principes du krigeage

● Pénalisation probabiliste

On donne un poids à toutes les fonctions, selon leur régularité.

Utilisation de processus gaussiens → poids déterminé par :

- ◆ Espérance : $E(g(x)) = f(x)\beta$
- ◆ Covariance : $cov(g(x), g(y)) = K(x, y)$

NB :

souvent, $K(x, y) = K(x - y)$ et $\sigma_g^2 = K(0)$

Principes du krigage

- **Modèle probabiliste des observations**

$$y_i = g(x_i) + \varepsilon_i, \text{ où } \varepsilon_i \text{ est un bruit de variance } \sigma_\varepsilon^2$$

- **Estimation de g en connaissant les y_i**

Détermination de la loi conditionnelle du processus $(g(x))_x$ sachant \mathbf{y}

Théorème (Duchon, Matheron, Wahba...)

$E[g(x)/\mathbf{Y}]$ est donnée par l'expression (Spline)
avec $\lambda = \frac{\sigma_\varepsilon^2}{\sigma_g^2}$

Remarques

- Pas de preuve « satisfaisante »
- Le noyau K est le même !
- Outil pivot = RKHS
 - ◆ Cas des splines cubiques :
Le processus associé au noyau K est la primitive du mouvement brownien
 - ◆ Cas général :
Notions de semi-RKHS et de processus intrinsèques

Propriétés du noyau K

- K est défini positif (ou conditionnellement d.p.) :

$$\forall a = (a_x)_x \in \mathbb{R}^{(X)}, \sum_x \sum_y a_x a_y K(x, y) \geq 0$$

et = 0 ssi $\sum_x a_x K_x \equiv 0$

- K détermine :

- les fonctions de base stockées dans k(x)
- vision spline : la pénalisation
- vision krigeage : la régularité du processus

Propriétés du noyau K

- Pénalisations du type :

$$\|g\|_H^2 = \int_{\mathbb{R}^d} [P(x, D)g](x)^2 dx$$

$P(x, \cdot)$ est un polynôme en d variables (à coefficients non constants en général)

D est l'opérateur de différentiation

$P(\cdot, D)$ est un opérateur différentiel

- ◆ Le noyau K est la fonction de Green de l'opérateur :

$$P(\cdot, D)^* P(\cdot, D)$$

Splines

- Splines = vision fonctionnelle
 - ◆ propriétés de convergence
 - ◆ terme $f(x)\beta$ souvent implicite, et négligé
 - ◆ noyau découlant d'une norme
 - ◆ noyau non paramétré car norme « standard »
 - ◆ erreur commise de forme simple (norme)
 - ◆ lien avec krigeage via les RKHS

Krigeage

- **Krigeage = vision probabiliste**
 - ◆ pas de propriétés de convergence
 - ◆ terme $f(x)\beta$ explicite, mais souvent négligé
 - ◆ noyau explicite et paramétré
 - ◆ grand intérêt pratique
 - ◆ difficultés d'estimation
 - ◆ mélange de modèles (approche bayésienne)
 - ◆ erreur commise sous forme de loi de proba
 - ◆ lien avec splines via les RKHS

Bibliographie

- Aronszajn N. (1950), Theory of reproducing kernels, Trans. AMS, 68, p. 337-404
- Amato U., Antoniadis A., Pensky M. (2006), Wavelet kernel penalized estimation for non-equispaced design regression, Statistics and Computing, 16, 1, 37-56, 2006
- Carraro L., Bay X., Roustant O. (2007), Introduction aux RKHS, GDR MASCOT NUM, www.lsp.ups-tlse.fr/Fp/Gamboa/GDR/rencontres_mars2007.html.
- Carraro L., Corre B., Helbert C., Roustant O., Josserand S. (2007), Optimal designs for the propagation of uncertainty in computer experiments, to appear in Chemometrics and Intelligent Laboratory Systems.
- Duchon J. (1980), Fonctions splines homogènes à plusieurs variables, Thèse d'Etat, Université de Grenoble.
- Duchon J. (2007), Modèles intrinsèques et probabilités conditionnelles, en préparation.
- Feuillard V. (2007), Analyse d'une base de données pour la calibration d'un code de calcul, Thèse de doctorat, Univ. Paris VI.
- Girosi F., Jones M., Poggio T. (1995), Regularization theory and neural network architectures, Neural Computation, 7, p. 219-269.

Bibliographie

- Lu F., Keles S., Lin Y., Wright S.J., Wahba G. (2006), Kernel Regularization and Dimension Reduction, Tech. Report n°1119, U. of Wisconsin.
- Vazquez E. (2005), Modélisation comportementale de systèmes non linéaires multivariables par méthodes à noyaux et applications, thèse de doctorat de l'U d'Orsay.
- Wahba G. (1990), Spline models for observational data, SIAM.
- Wahba G. (2000), An Introduction to Model Building with Reproducing Kernel Hilbert Spaces, Tech. Report n°1020, U. of Wisconsin.
- Yue R., Hickernell F.J. (1999), Robust designs for fitting linear models with misspecification, Stat. Sinica, 9, p. 1053-1069.