

Rencontres GDR MascotNum

décembre 2008 – IHP

**Autour des méthodes de régression dans les
RKHS**

J. Bect¹, B. Iooss², L. Pronzato³, E. Vazquez¹

1. SUPELEC, Gif-sur-Yvette

2. CEA, Cadarache

3. CNRS I3S, Sophia Antipolis

Régression dans les RKHS

Trois sujets présentés :

1. Théorie de la pratique du krigeage
2. Planification d'expériences pour codes numériques
3. Optimisation globale bayésienne

Encadrement possible par

- Julien Bect et Emmanuel Vazquez : enseignants - chercheurs à SUPELEC
- Bertrand Iooss : CEA
- Luc Pronzato : DR au CNRS

Contexte et applications visées

- Conception de produit/système via simulations numériques, avec pour objectifs
 - d’optimiser les performances d’un produit (**problème d’optimisation globale**)
 - d’estimer la **probabilité de défaillance** d’un produit
 - d’optimiser les performances en garantissant une probabilité de défaillance donnée (**optimisation sous contrainte**)


Exemple

Conception d'un conduit d'admission
(thèse CIFRE Renault de J. Villemonteix)



- optimisation de la forme du conduit pour réduire les émissions polluantes
- prendre en compte les dispersions de fabrication
- 1 simulation = plusieurs heures

Formalisation




-
- La simulation numérique d'un système est vue comme une fonction

$$f : \mathbb{X} \subseteq \mathbb{R}^d \rightarrow \mathbb{R}^q ,$$


avec d et q des entiers petits (disons $1 \leq d \leq 50$ et $1 \leq q \leq 4$)

- Difficulté spécifique liée à la nature des simulations numériques :
une évaluation de f souvent coûteuse (p. ex. plusieurs minutes/heures) → **budget d'évaluations très réduit en pratique**
- Objectif : établir une relation facile à calculer entre les **sorties** du système et plusieurs **facteurs** (entrées) à partir de simulations déjà effectuées
 - ➔ construire une approximation \hat{f} de f
- Utiliser \hat{f} au lieu de f pour concevoir le système


Données







Approximation



Interpolation



Problème : choisir une bonne approximation



Essentiel :

- choix de l'espace d'approximation
 - contrôle de la régularité
-
- ⇒ classe des **méthodes à noyaux**, *i.e.* approximation par des fonctions dans des **espaces hilbertiens à noyaux reproduisant** (RKHS)
 - ⇒ approche probabiliste, **krigeage**

Espace hilbertien à noyau reproduisant

- \mathcal{F} espace hilbertien de fonctions $\mathbb{X} \subseteq \mathbb{R}^d \rightarrow \mathbb{R}$, avec produit scalaire noté $(\cdot, \cdot)_{\mathcal{F}}$
- $k(x, y) : \mathbb{X} \times \mathbb{X} \rightarrow \mathbb{R}$ **noyau reproduisant** de \mathcal{F} , si pour tout $f \in \mathcal{F}$, tout $x \in \mathbb{X}$,

$$f(x) = (k(x, \cdot), f)_{\mathcal{F}}. \quad (1)$$

- ⇒ \mathcal{F} appelé **espace hilbertien à noyau reproduisant** ou RKHS
(Aronszajn, 1950)

Régression régularisée dans un RKHS

Approximation (Tikhonov et Arsenin 1977)


$$\begin{array}{l} \text{minimiser} \\ \text{régularité} \end{array} \underbrace{\|f\|_{\mathcal{F}}^2}_{\text{régularité}} + C \underbrace{\sum_i l(f(x_i) - f_{x_i}^{\text{obs}})}_{\text{adéquation aux données}}$$

Interpolation

$$\begin{array}{l} \text{minimiser} \\ \text{sous contraintes} \end{array} \begin{array}{l} \|f\|_{\mathcal{F}}^2, \quad f \in \mathcal{F} \\ f(x_i) = f_{x_i}^{\text{obs}}, \quad \forall i = 1, \dots, n. \end{array}$$

Approche probabiliste de l'approximation

- **Point de vue bayésien** \leftrightarrow choix d'un a priori sous la forme d'une mesure de probabilité sur $\mathbb{R}^{\mathbb{X}}$, ce qui revient à choisir la loi d'un processus aléatoire $\xi : \mathbb{X} \rightarrow \mathbb{R}$.



Si ξ est un **processus gaussien**,

○ il est très facile d'obtenir les **expressions analytiques**

– de la moyenne a posteriori, ou **krigeage** : $\hat{\xi}(x; \underline{x}_n) := \mathbb{E} [\xi(x) \mid \underline{\xi}_n]$, avec

$$\underline{\xi}_n = \{\xi(x_1), \dots, \xi(x_n)\}$$

– la variance de l'erreur de prédiction, ou **variance de krigeage** :

$$\hat{\sigma}_n^2(x; \underline{x}_n) := \text{var} [\hat{\xi}(x; \underline{x}_n) - \xi(x)]$$

○ il est possible de **simuler des trajectoires** de ξ conditionnellement aux évaluations précédentes

– permet par exemple l'estimation de la **densité a posteriori du**

maximum $M = \max_x \xi(x)$

– ...

○ en pratique, on suppose que ξ est un **processus gaussien**...

Équivalence des méthodes

→ Méthodes à noyaux

- 1960 : splines, (**Schoenberg 1964, Duchon 1976–1979**)
- 1980 : RBF, (**Micchelli 1986, Powel 1987**)
- 1995 : SVM, (**Vapnik 1995**)
- 1997 : SVR, (**Smola 1997**)
- 1999 : SVR semi-paramétrique (**Smola 1999**)

→ Krigeage – prédiction linéaire

- 1950 : prédiction pour la recherche minière (**Krige 1951**)
- 1960 : krigeage, géostatistique (**Matheron 1963**) – École des Mines
- 1970 : krigeage intrinsèque (**Matheron 1971**)
- 1997 : prédiction par « processus gaussiens », (**Williams 1997, Neal 1997**)

Sujet 1. Théorie de la pratique du krigeage

□ Étapes de la modélisation d'un système :

⇒ Choix des facteurs, inclusion d'informations a priori ...

⇒ Choix d'un noyau paramétré

⇒ Estimation des paramètres du noyau

⇒ Régression

Il reste encore beaucoup de travail théorique sur chacune des étapes !


Exemples :

- **Choix des facteurs** : approximation en dimension élevée ?
 - analyse de sensibilité
 - réduction de la dimension : sélection de variables, projections...
- **Choix d'un noyau** \leftrightarrow usuellement, structures classiques (exponentielle, Matérn) + estimation de paramètres
 - structures anisotropes, non stationnaires
 - technique d'estimation des paramètres ?
 - krigeage bayésien ?
- **Régression** : gérer efficacement les grands nombres de données

Objectif : intégrer une réflexion théorique sur ces questions dans un **logiciel libre** proposé à la communauté scientifique et industrielle


Sujet 2. Planification d'expériences

Question : quelles simulations effectuer pour rendre précis le modèle peu coûteux construit à partir des résultats de simulation ?



Ex : X_1 à X_5 fixés puis X_{n+1} au point de variance de krigeage maximale

- - - $f(x)$, — $\eta_n(x)$



II) Un objectif peut en cacher un autre ...

- **Modèle paramétrique : prédire \Leftrightarrow estimer θ**
- **Modèle non paramétrique (krigeage) : on a supposé θ (vecteur des paramètres de la covariance) connu ...**

Estimation de β , σ^2 et θ par maximum de vraisemblance (processus gaussien) :

$$\hat{\beta}^n(\theta) = (\mathbf{1}^\top \mathbf{C}_n^{-1}(\theta) \mathbf{y}_n) / (\mathbf{1}^\top \mathbf{C}_n^{-1}(\theta) \mathbf{1})$$

$$\hat{\sigma}_n^2(\theta) = \frac{1}{n} [\mathbf{y}_n - \hat{\beta}^n(\theta) \mathbf{1}]^\top \mathbf{C}_n^{-1}(\theta) [\mathbf{y}_n - \hat{\beta}^n(\theta) \mathbf{1}]$$

$$\text{et } \hat{\theta}_{MV}^n = \arg \min_{\theta} \det[\hat{\sigma}_n^2(\theta) \mathbf{C}_n(\theta)]$$

→ le plan d'expériences a une influence sur la précision de l'estimation de θ

Posons $\alpha = (\sigma^2, \theta)$, $\nu = (\beta, \alpha) = (\beta, \sigma^2, \theta)$, $\mathbf{C}_{n,\alpha} = \sigma^2 \mathbf{C}_n(\theta)$

• Si $\mathbb{E}\{Z(x, \omega)Z(u, \omega)\} \searrow 0$ pour $\|x - u\| \rightarrow \infty$ et

les X_i sont dans un domaine de taille croissante

$\hat{\nu}_{MV}^n$ est consistant et $\mathbf{M}_n^{1/2}(\nu)(\nu_{MV}^n - \nu) \xrightarrow{d} \mathcal{N}(0, \mathbf{I})$ avec

$$\mathbf{M}_n(\nu) = \mathbb{E}\{[\partial l_n(\nu)/\partial \nu][\partial l_n(\nu)/\partial \nu]^\top\} = \begin{pmatrix} m_n(\beta) & \mathbf{0}^\top \\ \mathbf{0} & \tilde{\mathbf{M}}_n(\alpha) \end{pmatrix}$$

$$m_n(\beta) = \mathbf{1}^\top \mathbf{C}_{n,\alpha}^{-1} \mathbf{1}, \quad [\tilde{\mathbf{M}}_n(\alpha)]_{i,j} = \frac{1}{2} \text{trace} \left[\mathbf{C}_{n,\alpha}^{-1} \frac{\partial \mathbf{C}_{n,\alpha}}{\partial \theta_i} \mathbf{C}_{n,\alpha}^{-1} \frac{\partial \mathbf{C}_{n,\alpha}}{\partial \theta_j} \right]$$

avec $l_n(\nu)$ la log-vraisemblance


Si on s'intéresse à la précision sur α

→ maximiser $\det \tilde{\mathbf{M}}_n(\alpha)$


Ex [Zimmerman, 2006] : $\mathbb{E}\{Z(x, \omega)Z(u, \omega)\} = \sigma^2\theta^{\|x-u\|}$,
 $\theta = 0.3$ (σ^2 connu), \mathcal{X} grille régulière 5×5

- X_1, \dots, X_4 minimisent $\max_{x \in \mathcal{X}} \rho_4(x)$ (\rightarrow prédiction)
- X_1, \dots, X_4 maximisent $\det \tilde{\mathbf{M}}_4(\theta)$ (\rightarrow estimation de θ)

objectif=prédiction, θ connu




objectif=estimation de θ




Suite de l'exemple de [Zimmerman, 2006] : X_1, \dots, X_4

minimisent $\max_{x \in \mathcal{X}} \rho_n(x) + \text{trace} \left[\tilde{\mathbf{M}}_n^{-1}(\theta) \frac{\partial \mathbf{u}^\top(x)}{\partial \theta} \mathbf{C}_{n,\theta} \frac{\partial \mathbf{u}(x)}{\partial \theta^\top} \right]$


objectif=prédiction, θ connu



objectif=estimation de θ




objectif=prédiction avec θ estimé



Sujet 3. Optimisation bayésienne

Optimisation d'un système avec simulations numériques




- Soit $f : \mathbb{X} \rightarrow \mathbb{R}$, avec $\mathbb{X} \subset \mathbb{R}^d$ borné, une fonction à maximiser
- Soit x^* un maximiseur global :



$$x^* = \arg \max_{x \in \mathbb{X}} f(x)$$

- Intérêt du modèle probabiliste : distribution a posteriori du maximiseur x^* ou du maximum

Exemple : distribution a posteriori de x^* dans le cas d'évaluations sans bruit



... dans le cas d'évaluations bruitées



Comment construire une suite $(x_n)_{n \in \mathbb{N}}$ de manière à ce que x^* soit une valeur d'adhérence ?

L'algorithme EI

- Expected improvement \leftrightarrow excursion moyenne de ξ au dessus du maximum des évaluations précédentes :

$$\rho_n(x) := \mathbb{E} \left[\max(0, \xi(x) - M_n) \mid \underline{\xi}_n \right]$$


avec $M_n = \max\{\xi(x_1), \dots, \xi(x_n)\}$.



- $\rho_n(x)$ peut être calculé analytiquement
- l'algorithme EI :



$$x_{n+1} = \arg \max_{x \in \mathbb{X}} \rho_n(x)$$

\leftrightarrow “stratégie optimiste d'amélioration”

Exemple







[Vazquez, Bect 07] $\rightarrow x^*$ est bien une **valeur d'adhérence** de $(x_n)_{n \in \mathbb{N}}$ produit par l'algorithme EI (sous certaines conditions de régularité)

Questions

- vitesse de convergence ?
- IAGO [Villemonaix et al. 08] :

$$x_{n+1} = \arg \min_{x \in \mathbb{X}_d} \mathbf{E} \left[H(x^*; \underline{\xi}_n, \xi(x)) \mid \underline{\xi}_n \right]$$

- \leftrightarrow **réduction de l'incertitude sur la position du maximiseur**
- \rightarrow convergence et vitesse de convergence ?

Informations pratiques

- Stage M2R souhaité
- Indemnités de stage : 700€
- Thèse financée + monitorat possible
- Lieu : SUPELEC, Gif-sur-Yvette
Grande Ecole de rang A, dans le domaine des sciences de l'information, de l'énergie et des systèmes (1560 élèves ingénieurs, 200 doctorants, 150 permanents)
- Contacts :
 - Emmanuel Vazquez emmanuel.vazquez@supelec.fr
 - Julien Bect julien.bect@supelec.fr