



Réglage automatique et comparaison de méthodes de diagnostic par krigeage

Julien Marzat, Eric Walter, Hélène Piet-Lahanier, Frédéric Damongeot

4èmes Journées Doctorales / Journées Nationales MACS
Marseille , France, 9-10 juin 2011



retour sur innovation

Position du problème

Méthodologie de réglage

Applications

- Tests statistiques de changement de moyenne

- Schémas complets de diagnostic

Conclusions et perspectives

Position du problème


Hyperparamètres de méthodes de diagnostic

- Gains d'observateur
- Matrices de covariance
- Seuils
- Taille minimale de changement à détecter
- Horizon temporel
- ...


Réglage optimal des hyperparamètres

- Meilleure performance d'une méthode sur un problème complexe ?
- Nécessaire pour la comparaison de méthodes
- Nombreuses simulation d'un cas test pour les ajuster
- Minimisation globale d'indicateurs de performance


Exemple de cas test



Exemple de cas test



Méthode de réglage



Réglage sur un ensemble de cas test = *Computer Experiment*

- Le *krigeage* comme modèle de substitution à la simulation complexe
- *Efficient Global Optimization*, recherche itérative de l'optimum à l'aide du modèle de krigeage (info de gradient pas nécessaire)

Point de départ

Indicateur de performance scalaire $y(\mathbf{x})$ calculé pour un échantillon initial de vecteurs d'hyperparamètres $\mathcal{X}_n = [\mathbf{x}_1, \dots, \mathbf{x}_n]$, $\mathbf{x} \in \mathbb{X} \subset \mathbb{R}^d$

$y(\cdot)$ approximé par $Y(\mathbf{x}) = \mathbf{f}^T(\mathbf{x})\mathbf{b} + Z(\mathbf{x})$


- $\mathbf{f}^T(\mathbf{x})\mathbf{b}$ modèle de régression classique à identifier sur les données
- $Z(\cdot)$ processus gaussien de moyenne nulle et de covariance
 $k(Z(\mathbf{x}), Z(\mathbf{x} + \mathbf{h})) = \sigma^2 R(\mathbf{h})$
- Fonction de corrélation (choisie), par exemple
 $R(\mathbf{h}) = \exp \left\{ - \sum_{k=1}^d |h_k / \theta_k|^{p_k} \right\}$
- Estimation de θ_k , σ^2 , $\mathbf{b}$ au sens du maximum de vraisemblance

Bonnes propriétés du krigeage

- $\hat{Y}(\mathbf{x})$, meilleur prédicteur linéaire non biaisé de $y(\mathbf{x})$, $\forall \mathbf{x} \in \mathbb{X}$
- Variance de l'erreur de prédiction calculée $\hat{\sigma}^2(\mathbf{x})$

[1] G. Matheron : Principles of geostatistics. Economic Geology, 58(8) :1246, 1963.

Illustration du krigage



Algorithme *Efficient Global Optimization*² (EGO)

Objectif: Trouver itérativement le minimiseur global de $y(\cdot)$

- 1 Calculer la valeur de $y(\cdot)$ pour l'échantillonnage initial $\mathcal{X}_n$
- 2 Trouver le minimum empirique dans ces points, $y_{\min}$
- 3 Identifier un prédicteur par krigeage sur ces données
- 4 Trouver un nouveau vecteur $\mathbf{x}$ où évaluer $y(\cdot)$ en maximisant l'*amélioration attendue* (*Expected Improvement*),

$$\text{EI}(\mathbf{x}) = \hat{\sigma}(\mathbf{x}) [u\Phi(u) + \phi(u)]$$

avec



$$u = \frac{(y_{\min} - \hat{Y}(\mathbf{x}))}{\hat{\sigma}(\mathbf{x})}$$

- 5 Aller en 2 jusqu'à $\max \text{EI} < \varepsilon_{\text{EI}}$ ou budget de simulation épuisé



[2] D.R. Jones : A taxonomy of global optimization methods based on response surfaces. *Journal of Global Optimization*, 21(4) :345– 383, 2001.

Illustration d'EGO



Itération 1




Itération 2



Itération 3




Tests statistiques de changement de moyenne d'un résidu




- ❶ Seuillage fixe $\rightarrow$ 1 hp
- ❷ Test de Student sur une fenêtre glissante $\rightarrow$ 1 hp
- ❸ Test du GLR $\rightarrow$ 2 hp
- ❹ Test du SPRT $\rightarrow$ 4 hp
- ❺ CUSUM $\rightarrow$ 2 hp
- ❻ RSS (Randomised SubSampling) $\rightarrow$ 3 hp


Résultats - Meilleures fonctions de décision




(a) 3-sigma




(b) Student




(c) GLR



(d) SPRT (no decision: 0.5)





(e) CUSUM




(f) RSS

Exploration de l'espace et résultats numériques




	3-sigma	Student	GLR	SPRT	CUSUM	RSS
<i>Classement</i>	6	4	5	2	1	3
Taux de fausse alarme	0.2124	0	0	0	0	0
Taux de non détection	0.5473	0.0579	0.07	0.0379	0.024	0.0399
Nombre moyen d'évaluations	32.84	19.71	39.68	51.13	49.5	46.67

Schémas complets de diagnostic



- 1 Observateur de Luenberger (3 poles) + CUSUM (2 hp) → 5 hp
- 2 Filtre de Kalman (4 valeurs non nulles covariances) + CUSUM (2 hp) → 6 hp

Résultats



	Observateur et CUSUM	Kalman et CUSUM
<i>Classement</i>	<i>2</i>	<i>1</i>
Taux de fausse alarme	0	0
Taux de non détection	0.0455	0.0184
Nombre moyen d'évaluations	102.21	136.14

Conclusions et perspectives

Résumé

- Réglage automatique de méthodes, par simulations de cas test
- Modèle de substitution (*krigeage*) + optimisation globale (*EGO*)
- Applications traitées (dimension 1 à 6) :
 - six méthodes de détection de changement de moyenne
 - deux schémas avec générateur de résidus + test statistique
- Résultats robustes à l'échantillonnage initial
- Peu de lancements de la simulation nécessaires (≈ 20 par dimension)
- Applicable au réglage de nombreux algorithmes en automatique

En cours

- Prise en compte des variables environnementales (niveau de bruit, incertitudes de la simulation, ...) au sens du minimax continu
→ J. Marzat, E. Walter, et H. Piet-Lahanier. Min-max hyperparameter tuning with application to fault detection. IFAC WC 2011