

## Optimisation par exploration de code numérique

Victor Picheny

INRA - Mathématiques et Informatique Appliquées  
- Toulouse

Les Houches, le 12 avril 2013

# Optimisation par exploration de code numérique

Victor Picheny

INRA - Mathématiques et Informatique Appliquées - Toulouse

Les Houches, le 12 avril 2013

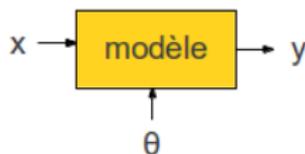
# Plan

- 1 Introduction
- 2 Introduction à l'optimisation globale : l'algorithme DIRECT
- 3 Optimisation sur base de métamodèles
  - Optimisation sur base de modèle polynomial
  - Optimisation sur base de krigeage : l'algorithme EGO
- 4 Extensions
- 5 Conclusion

# Qu'est-ce que l'optimisation de modèles (1/2) ?

## Notations

- Facteurs  $x$
- Paramètres  $\theta$
- Réponse(s)  $y$



Objectif : trouver le jeu de facteurs pour lequel la réponse du système est la meilleure

- $x^* = \arg \min_{x \in D} y(x)$  ou  $x^* = \arg \max_{x \in D} y(x)$
- paramètres  $\theta$  fixes !

# Qu'est-ce que l'optimisation de modèles (2/2) ?

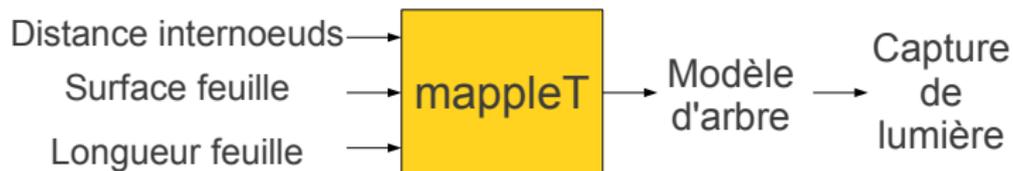
Optimisation = exploitation du modèle par **échantillonnage adaptatif**

- Trouver les décisions (facteurs) qui maximisent la performance (réponse)
- Plan d'expériences... focalisé sur la valeur de la réponse
- Nécessairement adaptatif (séquentiel)

Difficultés inhérentes

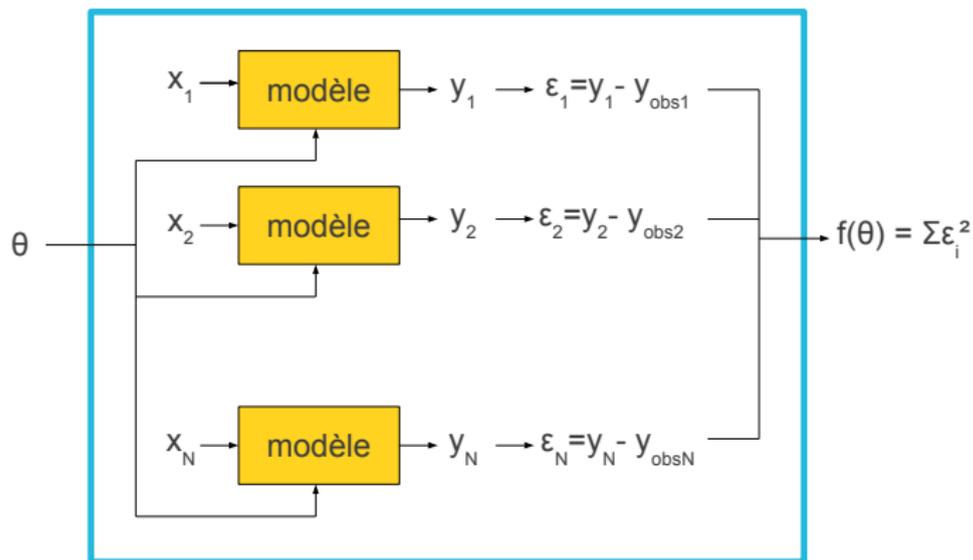
- Modèle = boîte noire : pas de dérivées ; au mieux informations de type régularité, etc.
- Temps de calcul élevé → parcimonie nécessaire

# Un exemple



On peut agir sur certains traits géométriques pour obtenir des arbres avec une architecture optimale.

# Un autre problème d'optimisation : le calage de paramètres



Objectif :  $\theta^* = \arg \min f(\theta)$

# Type de problème abordé dans cette présentation

- Toutes les variables sont des variables de décisions
- Variables continues, bornées
- Petite dimension ( $\leq 20$ )
- Réponse fortement non-linéaire

- 1 Introduction
- 2 Introduction à l'optimisation globale : l'algorithme DIRECT
- 3 Optimisation sur base de métamodèles
  - Optimisation sur base de modèle polynomial
  - Optimisation sur base de krigeage : l'algorithme EGO
- 4 Extensions
- 5 Conclusion

# Optimisation locale vs. globale

## Optimisation locale

- Départ : point initial  $x$
- Direction de descente (plus forte pente : gradient)
- On améliore toujours la situation initiale, mais aucune garantie de trouver le meilleur point !

## Optimisation globale : le **compromis exploration / intensification**

- Exploration : recherche partout dans l'espace pour ne pas rater la zone optimale
- Intensification : une fois une zone identifiée : on recherche le minimum local

# La plus forte pente : une stratégie discutable



# L'algorithme DIRECT

## DIRECT : Dividing RECTangles



D. Jones, C. Perttunen, B. Stuckman (1993)

Lipschitzian optimization without the Lipschitz constant

Journal of Optimization Theory and Applications 79(1), 157-181

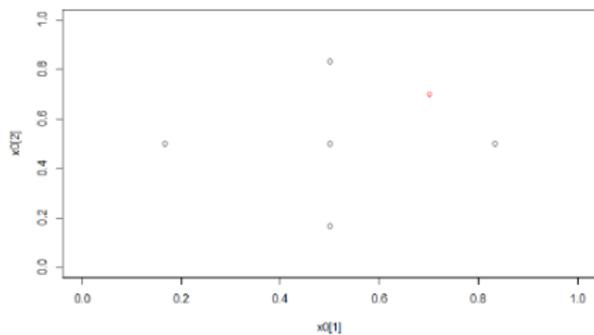
- Découpage de l'espace en (hyper)rectangles
- Un échantillon au centre de chaque rectangle
- On divise les rectangles les plus "intéressants" :
  - soit les plus grands (exploration)
  - soit ceux qui ont une valeur au centre basse (intensification)
- Pour diviser : ajout de 2 points, division en 3

## Quel compromis exploration / intensification ?

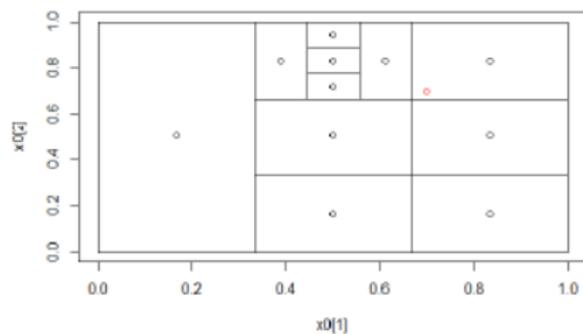
- Pour **chaque** taille de rectangle, on divise celui qui a la meilleure valeur de  $y$
- Valeurs optimales au sens de Pareto !

# Exemple en dim 2

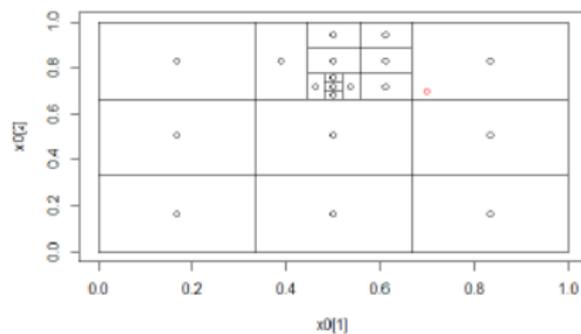
$F_V(t) = \dots$   $f_0(x)$   $dF(x)$



Après 2 itérations

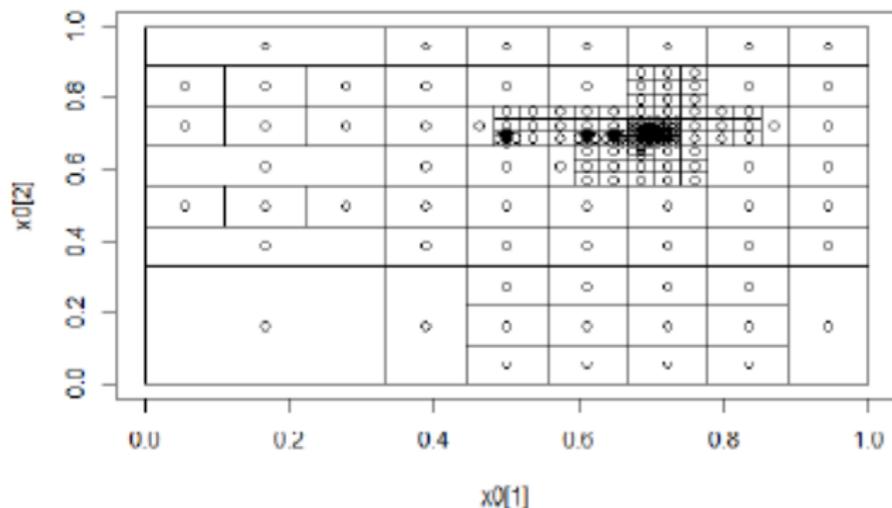


Après 3 itérations

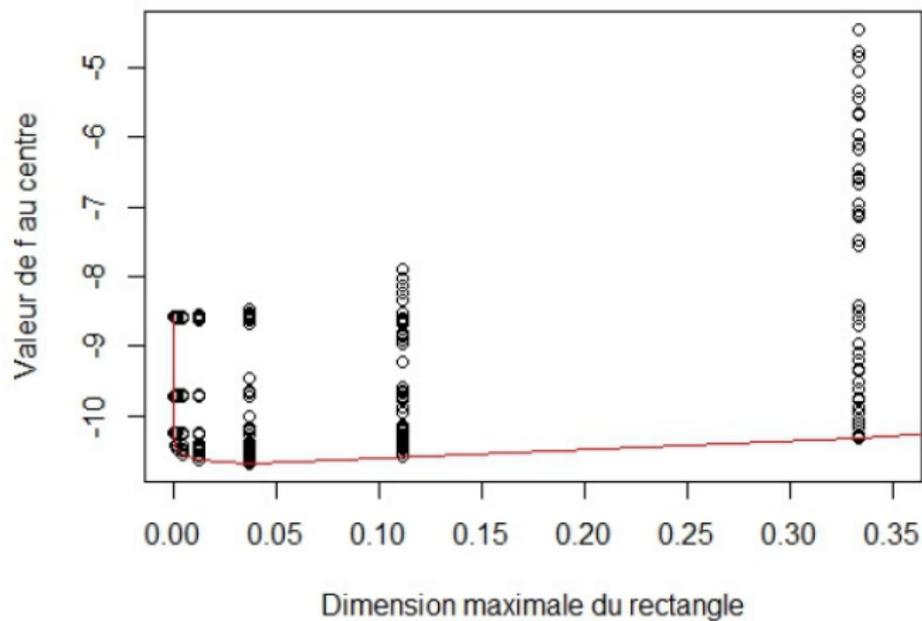


# Après 20 itérations

- Echantillonnage intense dans la zone de l'optimum
- Bonne exploration



# Front de Pareto



# Plan

- 1 Introduction
- 2 Introduction à l'optimisation globale : l'algorithme DIRECT
- 3 Optimisation sur base de métamodèles
  - Optimisation sur base de modèle polynomial
  - Optimisation sur base de krigeage : l'algorithme EGO
- 4 Extensions
- 5 Conclusion

# Optimisation sur base de métamodèles

## Pourquoi faire ?

- Algorithme DIRECT : (presque) sans hypothèse sur  $y$
- Situation d'extrême parcimonie : exploitation maximale de l'information  
→ métamodèle

## Principe général

- Echantillon initial (plan d'expériences)
- Construction d'un métamodèle
- Utilisation du métamodèle pour choisir la prochaine observation

## Approche séquentielle

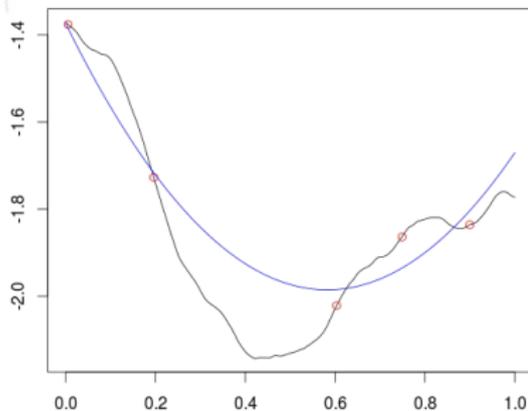
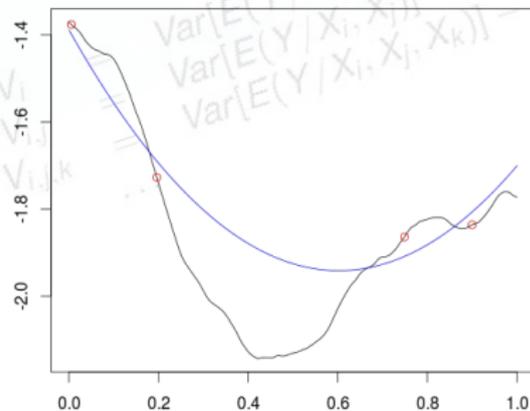
La nouvelle observation enrichit le plan d'expérience et le métamodèle

# Optimisation sur base de modèle polynomial

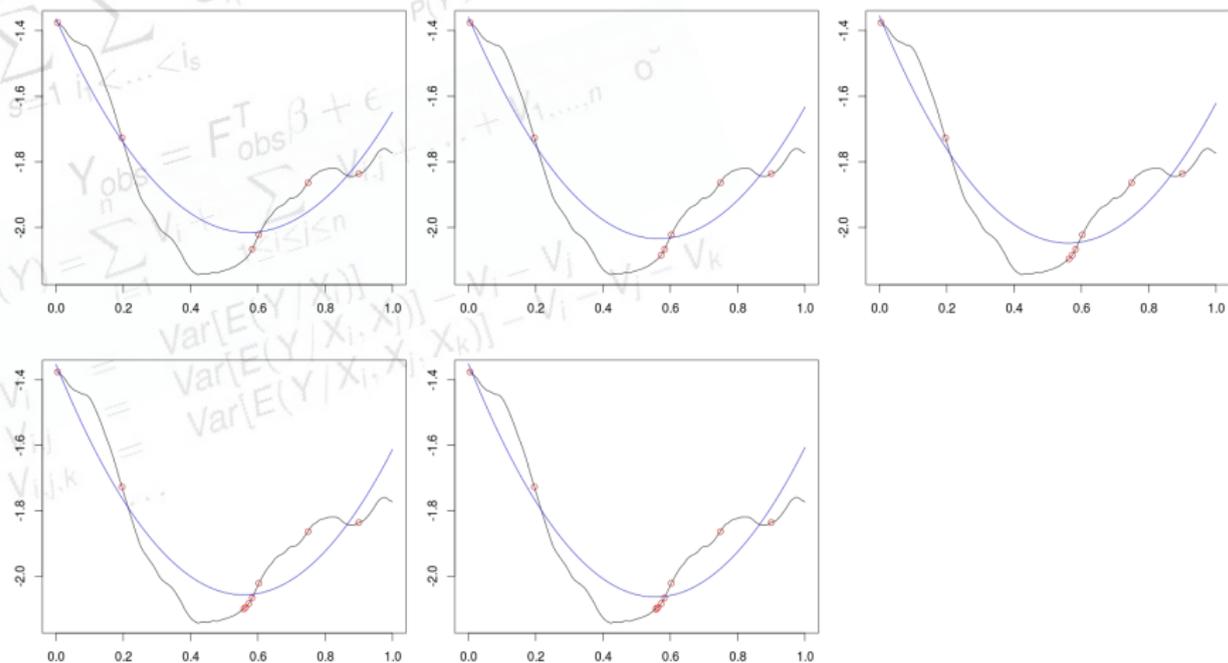
$$F_Y(t) = \dots \\ = 1 \quad E(Y^k) = \int_0^1 (t(x))^k dF(x)$$

## Principe

- On cherche le point qui minimise la surface de réponse
- On ajoute ce point
- On met à jour la surface de réponse
- On recommence...



# Itérations 3 à 7



# Optimisation sur base de modèle polynomial

## Problème : modèle "rigide"

- Sélection des points et de la région de validité  
→ régions de confiance
- Convergence locale : plans localement D-optimaux  
→ algorithme de Kiefer

Où est passé le compromis exploration / intensification ?

Méthodes d'optimisation locale, proche des méthodes de gradient

# Optimisation sur base de krigeage : l'algorithme EGO

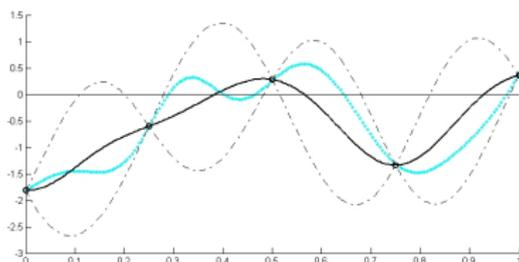
## Atouts du modèle (cf. cours de PG)

- Flexibilité
- Information riche :
  - Meilleur prédicteur  $m(x)$
  - + Information ponctuelle d'erreur : variance  $s^2(x)$

## Compromis exploration / intensification

- Exploration :  $s^2(x)$  grand ( $\sim$  grands rectangles)
- Intensification :  $m(x)$  petit ( $\sim$  faibles valeurs)

## Où se placer sur le front de Pareto ?



# Différents critères

$$F_Y(x) = \int_{-\infty}^x f_Y(x) dx$$



D. Jones (2001)

A taxonomy of global optimization methods based on response surfaces  
[Journal of global optimization 21\(4\), 345-383](#)

- Pure intensification :  $\min m(x)$
- Pure exploration :  $\max s^2(x)$
- Un compromis simple :  $\min m(x) - \alpha s(x)$

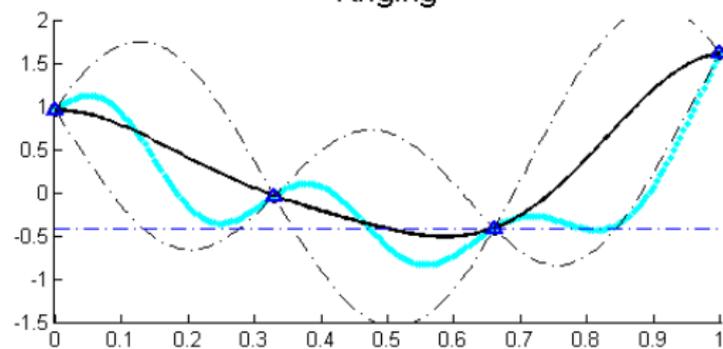
Le meilleur compromis : amélioration espérée (ou *EI: Expected Improvement*)

- Amélioration = gain sur la fonction coût :  $(\min(y_1, \dots, y_n) - Y(x))^+$
- Au temps  $n$  : l'amélioration est une v.a., *mais* on connaît sa loi
- Critère 1 : probabilité d'amélioration
- **Critère 2 : espérance de l'amélioration :**  
$$EI(x) = \mathbb{E} \left[ (\min(y_1, \dots, y_n) - Y(x))^+ \right]$$
- Ecriture analytique en fonction de  $m(x)$  et  $s^2(x)$  !

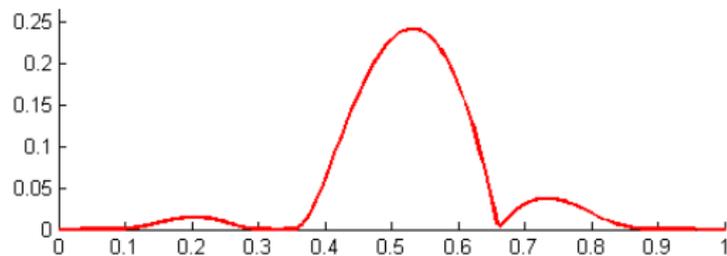
# Illustration

$$F_Y(t) = \int_{-\infty}^t f_Y(x) dx$$

## Kriging



## El criterion



# L'algorithme *Efficient Global Optimization*

## Initialisation

- Réalisation d'un plan initial
- Construction d'un krigeage

## Boucle d'optimisation

- Recherche du point qui maximise l'amélioration espérée
- Calcul du vrai modèle en ce point
- Ajout du point au plan et mise à jour du modèle



D. Jones, M. Schonlau, W. Welch

Efficient global optimization of expensive black-box functions  
*Journal of Global optimization* 13 (4), 455-492 (1998)

# EGO: illustration 1/6

$\sum_{s=1}^n \sum_{i_1 < \dots < i_s} S_{i_1 \dots i_s} = 1$

$F_Y(t) = \dots$

$E(Y^*) = \int_{-\infty}^{\infty} (t(x)) dF(x)$

$n = \int_{-\infty}^{\infty} dF(x)$

$Y_{n,obs} = F^T_{obs}$

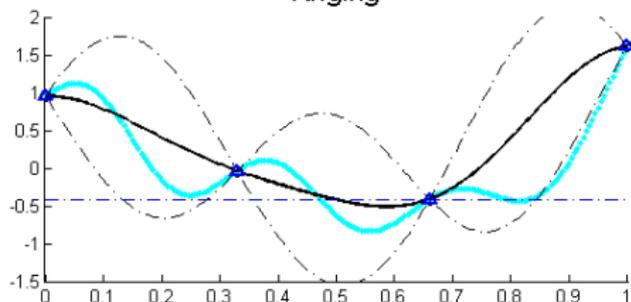
$Var(Y) = \sum_{i=1}^n V_i + \dots$

$V_i = Var[E(\dots)]$

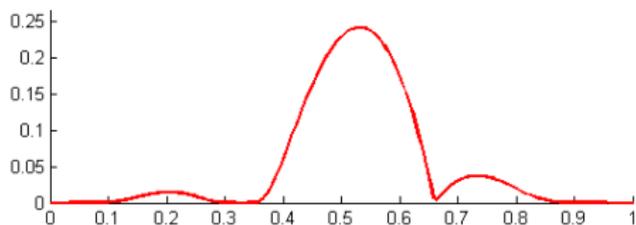
$V_{i,j} = Cov[E(\dots)]$

$V_{i,j,k} = \dots$

Kriging

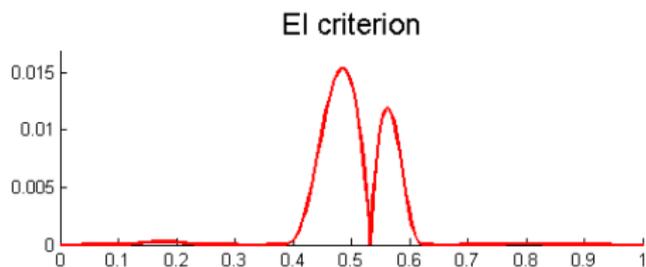
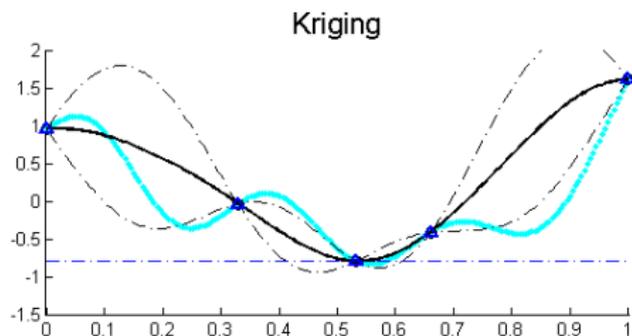


El criterion



# EGO: illustration 2/6

$$\sum_{s=1}^n \sum_{i_1 < \dots < i_s} S_{i_1, \dots, i_s} = 1$$
$$F_Y(t) = \int_{-\infty}^t f_Y(x) dx$$
$$E(Y^*) = \int_{-\infty}^{\infty} x f_Y(x) dx$$
$$Y_{\text{obs}} = F^T \text{obs}$$
$$\text{Var}(Y) = \sum_{i=1}^n v_i + \sum_{1 \leq i < j \leq n} v_{i,j}$$
$$v_i = \text{Var}[E(Y | x_i)]$$
$$v_{i,j} = \text{Cov}[E(Y | x_i), E(Y | x_j)]$$



# EGO: illustration 3/6

$\sum_{s=1}^n \sum_{i_1 < \dots < i_s} S_{i_1 \dots i_s} = 1$

$F_Y(t) = \dots$

$E(Y^*) = \int_{(t)(x)} dF(x)$

$n = \int_{(x) > M}$

$Y_{\text{obs}} = F^T \text{obs}$

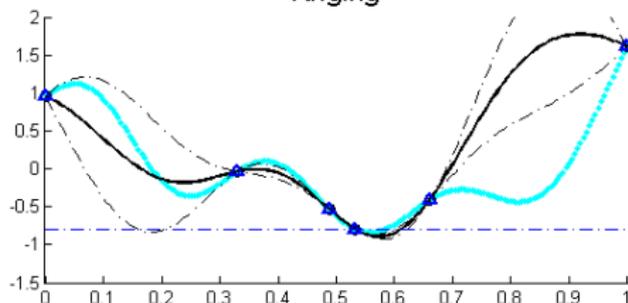
$\text{var}(Y) = \sum_{i=1}^n V_i + \dots$

$V_i = \text{Var}[E(\dots)]$

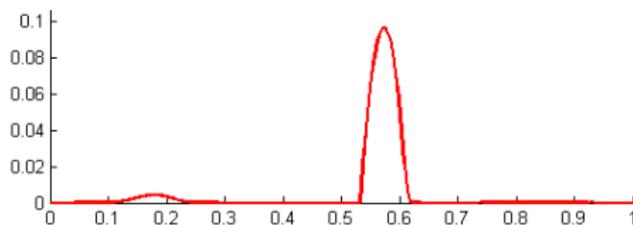
$V_{i,j} = \text{Var}[E(\dots)]$

$V_{i,j,k} = \dots$

Kriging



EI criterion



# EGO: illustration 4/6

$\sum_{s=1}^n \sum_{i_1 < \dots < i_s} S_{i_1 \dots i_s} = 1$

$F_Y(t) = \dots$

$E(Y^*) = \int_{(t(x))} dF(x)$

$n = \int_{(x) > M}$

$Y_{\text{obs}} = F^T \text{obs}$

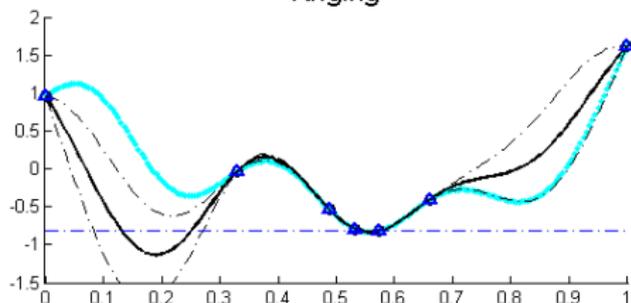
$\text{Var}(Y) = \sum_{i=1}^n v_i + \dots$

$v_i = \text{Var}[E(\dots)]$

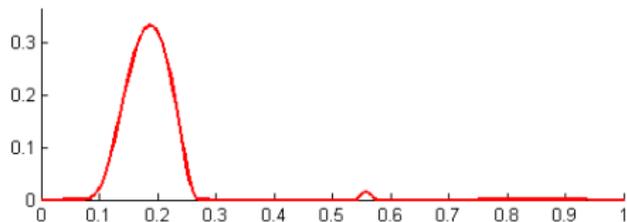
$v_{i,j} = \text{Var}[E(\dots)]$

$v_{i,j,k} = \dots$

Kriging

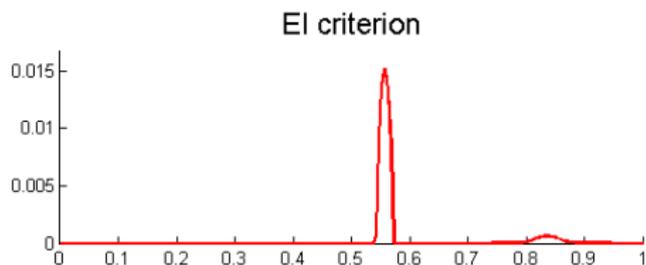
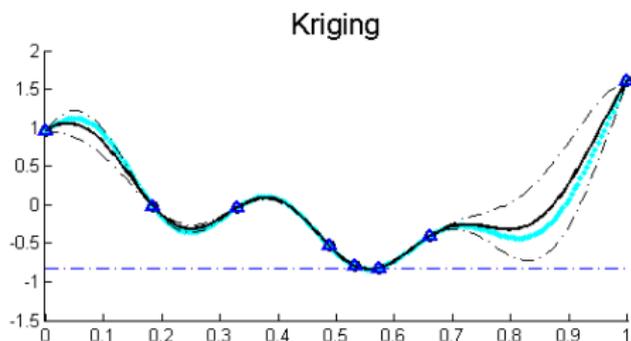


El criterion



# EGO: illustration 5/6

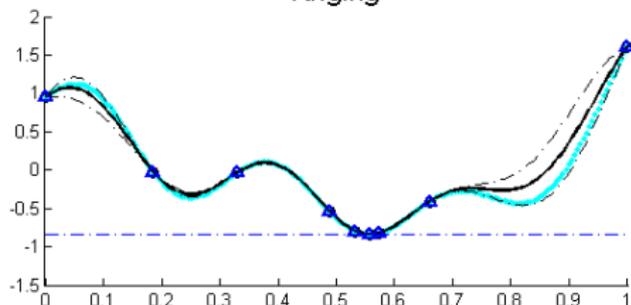
$$\sum_{s=1}^n \sum_{i_1 < \dots < i_s} S_{i_1, \dots, i_s} = 1$$
$$E(Y^*) = \int_{(x)} dF(x)$$
$$Y_{\text{obs}} = F^T \text{obs}$$
$$\text{Var}(Y) = \sum_{i=1}^n v_i + \sum_{1 \leq i < j \leq n} v_{i,j} + \dots$$
$$v_i = \text{Var}[E(Y | x_i)]$$
$$v_{i,j} = \text{Var}[E(Y | x_i, x_j)]$$
$$v_{i,j,k} = \dots$$



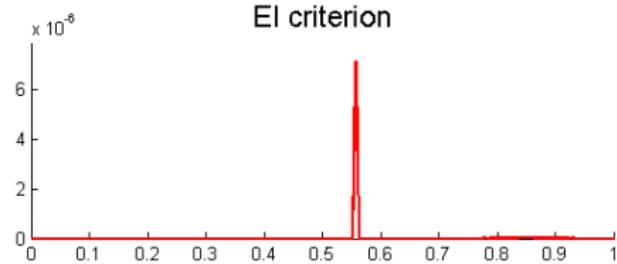
# EGO: illustration 6/6

$$\sum_{s=1}^n \sum_{i_1 < \dots < i_s} S_{i_1, \dots, i_s} = 1$$
$$F_Y(t) = \int_{-\infty}^t f_Y(x) dx$$
$$E(Y^k) = \int_{-\infty}^{\infty} x^k dF(x)$$
$$Y_{\text{obs}} = F^T \text{obs}$$
$$\text{var}(Y) = \sum_{i=1}^n v_i + \sum_{1 \leq i < j \leq n} v_{i,j} + \dots$$
$$v_i = \text{Var}[E(Y | x_i)]$$
$$v_{i,j} = \text{Var}[E(Y | x_i, x_j)]$$
$$v_{i,j,k} = \dots$$

Kriging



EI criterion



# EGO en pratique

## Maximisation de l'amélioration espérée

- Sous-problème d'optimisation (globale) !
- *EI* "gratuit" → méthodes intensives
- De plus : gradients et hessiens analytiques

cf. R package `DiceOptim`



O. Roustant, D. Ginsbourger, Y. Deville (2010)

DiceKriging, DiceOptim: Two R packages for the analysis of computer experiments by kriging-based metamodeling and optimization



V. Picheny, D. Ginsbourger (2013)

Noisy kriging-based optimization methods: A unified implementation within the DiceOptim package  
[Computational Statistics & Data Analysis](#)

## Limites

- Dimension
- Capacité du métamodèle à représenter le système

# Deux propriétés d'EGO

Maximiseur de l'amélioration espérée : stratégie optimale

Donne le meilleur gain (en espérance) sur  $y$

EGO : stratégie myope

Optimale... pour une itération



J. Mockus (1989)

Bayesian approach to global optimization: theory and applications

# Plan

- 1 Introduction
- 2 Introduction à l'optimisation globale : l'algorithme DIRECT
- 3 Optimisation sur base de métamodèles
  - Optimisation sur base de modèle polynomial
  - Optimisation sur base de krigeage : l'algorithme EGO
- 4 Extensions
- 5 Conclusion

# Extensions du principe d'EGO à différents contextes

## Principe général

- Critère traduisant notre objectif
- Recherche du maximisateur du critère
- Ajout séquentiel de points

## Un domaine foisonnant

- Parallélisation
- Modèles stochastiques, optimisation avec paramètres incertains
- Optimisation sous contraintes, multi-objectif, multi-fidélité
- Alternatives à l'EI
- Autres modèles : par ex. Bayesian additive regression trees



Chipman et al. (2009)

Sequential Design for Computer Experiments with a Flexible Bayesian Additive Model

# Parallélisation

Ajout de plusieurs points simultanément au lieu d'un seul

L'amélioration est apportée par le meilleur des points :

$$EI(x_1, \dots, x_p) = \mathbb{E} \left[ (y_{min} - \min(Y(x_1), \dots, Y(x_p)))^+ \right]$$

## Difficultés

Pas de forme analytique !

## Quelques références

 M. Taddy, H. Lee, G. Gray, J. Griffin (2009)  
Bayesian guided pattern search for robust local optimization  
Technometrics, 51(4), 389-401

 D. Ginsbourger, R. Le Riche, L. Carraro (2010)  
Kriging is well-suited to parallelize optimization  
Computational intelligence in expensive optimization problems, 131-162

 C. Chevalier, D. Ginsbourger (2013)  
Fast computation of the multipoint Expected Improvement with applications in batch selection

# Optimisation de modèles stochastiques

## Définition

- On veut optimiser :  $y(x)$
- On a accès seulement à :  $y(x) + \varepsilon$

## Difficultés avec EGO

- $y_{min}$  est inconnu
- La future valeur  $Y(x)$  ne sera pas observée
- Il faut définir une “amélioration” adaptée

# Optimisation de modèles stochastiques

## Définition

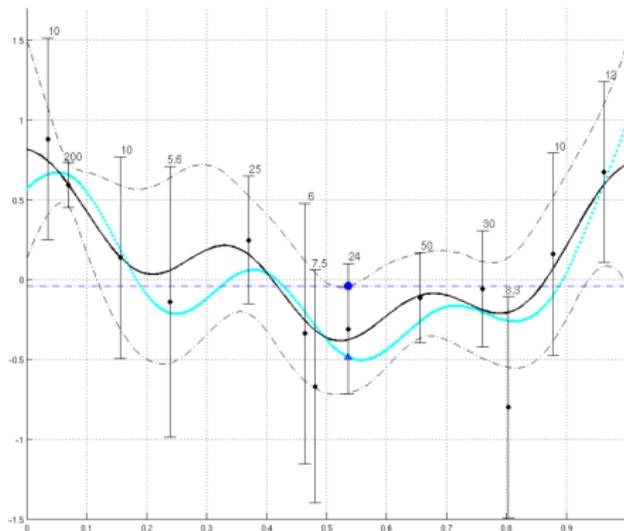
- On veut optimiser :  $y(x)$
- On a accès seulement à :  $y(x) + \varepsilon$

## Difficultés avec EGO

- $y_{min}$  est inconnu
- La future valeur  $Y(x)$  ne sera pas observée
- Il faut définir une “amélioration” adaptée

# Prise de décisions sur données bruitées

Relations d'ordre non garanties à cause du bruit → comment choisir le meilleur point ?

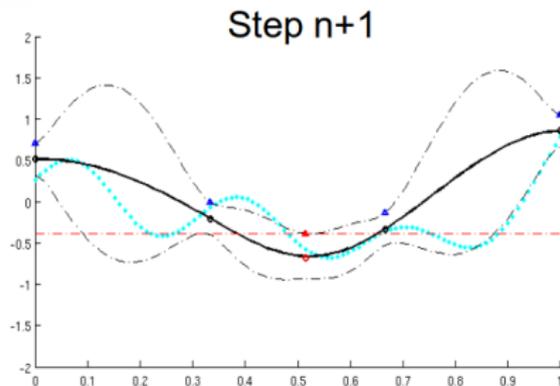
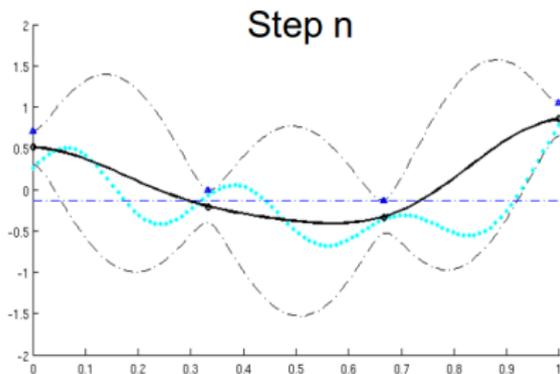


Proposition : utiliser le krigeage comme un filtre → : quantile de krigeage

# Un critère séquentiel d'échantillonnage

## D'une décision statique à un critère séquentiel

- Performance : plus petit quantile
- Amélioration : diminution du plus petit quantile
- $EQI = \mathbb{E}[q_{min} - Q(x)]$



V. Picheny, D. Ginsbourger, Y. Richet, G. Caplin (2013)

Quantile-based optimization of noisy computer experiments with tunable precision

*Technometrics* 55, 2-13

# Alternatives à l'EI : critères spatialisés

Prise en compte de toute l'information  
fournie par une observation

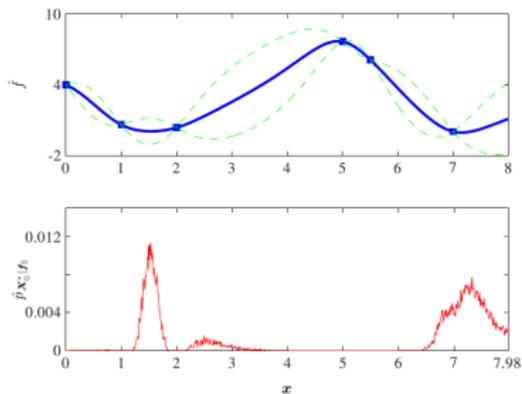
IAGO : Informal approach to Global  
Optimization

Réduction de l'entropie du minimum

IECI : Integrated Expected Conditional  
Improvement

Gain estimé sur tout l'espace

Distribution du minimum (IAGO) :



J. Villemonteix, E. Vazquez, E. Walter (2009)  
An informational approach to the global  
optimization of expensive-to-evaluate functions  
*Journal of Global Optimization*, 44(4), 509-534



R. Gramacy, H. Lee (2011)  
Optimization under unknown constraints  
*Bayesian Statistics* 9

# Plan

- 1 Introduction
- 2 Introduction à l'optimisation globale : l'algorithme DIRECT
- 3 Optimisation sur base de métamodèles
  - Optimisation sur base de modèle polynomial
  - Optimisation sur base de krigeage : l'algorithme EGO
- 4 Extensions
- 5 Conclusion

# Conclusion

## Optimisation sur base de métamodèle

- Nécessité d'un compromis exploration / intensification
- Métamodèle : outil pertinent pour piloter les observations
- Une stratégie de référence : EGO

## Applications à différents contextes

- Soit en adaptant le modèle (cf. présentation de D. Ginsbourger par ex.)
- Soit en adaptant le critère