

# Planification d'expériences pour l'optimisation de simulateur numérique

Barry Adama<sup>1 2 3</sup>

Doctorant en Mathématiques Appliquées

<sup>1</sup>Institut Mathématique de Toulouse & <sup>2</sup>INRIA Grenoble & <sup>3</sup>IFP Énergies Nouvelles

RJCAF - Décembre 2022

- 1 Introduction
- 2 Méta-modélisation
- 3 Planification séquentielle
- 4 Application numérique
- 5 Conclusion

# Outline

- 1 Introduction
- 2 Méta-modélisation
- 3 Planification séquentielle
- 4 Application numérique
- 5 Conclusion

- Nom & Prénom : Barry Adama
- Sujet de thèse : Plans d'expériences pour la calibration et la validation de simulateur numérique.
- Un des axes de recherche du Consortium Industrie Recherche pour l'Optimisation et la QUantification d'incertitude pour les données Onéreuses (**CIROQUO**) proposé par l'IFPEN.

- $f : \mathcal{X} \subseteq \mathbf{R}^d \rightarrow \mathbf{R}, d \in \mathbb{N}$
- $f$  coûteuse :  
⇒ nombre d'appel limité
- Forme analytique inconnue et  $\nabla f$  indisponible
- Exemples :
  - 1 Conception d'une voilure d'avion (Forester et al. 2008)
  - 2 Optimisation de la forme des conduits d'un moteur de voiture (Villemonaix et al. 2007)
  - 3 Etc.

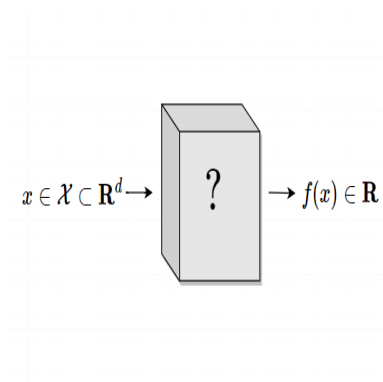


Figure: Simulateur numérique

## Objectif

Estimer  $x^* = \operatorname{argmin}_{x \in \mathcal{X}} f(x)$  et  $m^* = f(x^*)$

- **Cadre statistique:** approche bayésienne

$f$  est considérée comme la réalisation d'un processus aléatoire.

- **Simulation** : évaluation du simulateur.
- **Expérience** : point de simulation.
- **Planification d'expériences** : choix des expériences à réaliser en fonction des précédents.
- **Méta-modèle** : modèle de substitution du simulateur.

# Outline

- 1 Introduction
- 2 Méta-modélisation**
- 3 Planification séquentielle
- 4 Application numérique
- 5 Conclusion



# Processus Gaussiens (1/3)

## Processus Gaussien

Un processus gaussien  $Y$  est une collection de variables aléatoires telle que la distribution conjointe de chaque sous-ensemble fini est gaussienne multivariée, on note :

$$Y \sim \mathbf{GP}(m, k),$$

où  $m(x)$  et  $k(x, x')$  représentent respectivement la fonction moyenne et la fonction de covariance.

## Fonction moyenne et de covariance

- 1 La fonction moyenne  $m : x \mapsto m(x)$
- 2 La fonction de covariance  $k : (x, x') \mapsto k(x, x')$

## Processus Gaussiens (2/3) : Choix de la fonction de covariance

- Un processus gaussien est dit stationnaire si sa fonction moyenne est constante et sa fonction de covariance est telle que :

$$\forall x, x' : k(x, x') = k_{\sigma, l}(\|x - x'\|) = k_{\sigma, l}(d),$$

où  $\sigma$  et  $l$  sont les paramètres de la fonction de covariance.

Nom	Expression
Exponentielle	$\sigma^2 e^{- d /l}$
Gaussienne	$\sigma^2 e^{-d^2/l^2}$
Matern 3/2	$\sigma^2 (1 + \sqrt{6} \frac{ d }{l}) e^{-\sqrt{6} d /l}$
Matern 5/2	$\sigma^2 (1 + \sqrt{10} \frac{ d }{l} + \sqrt{10} \frac{ d ^2}{l^2}) e^{-\sqrt{10} d /l}$

Table: Exemples de fonctions de covariance

# Processus Gaussiens (3/3) : exemples de réalisations

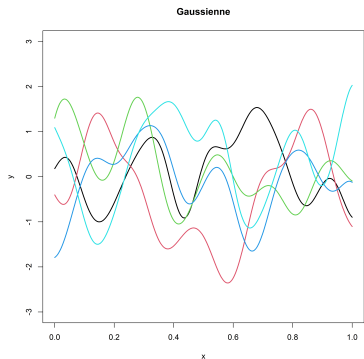


Figure: Fonction de covariance gaussienne avec  $\sigma^2 = 1$  et  $l = 0.1$ .

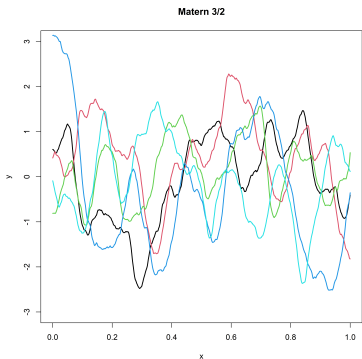


Figure: Fonction de covariance Matern 3/2 avec  $\sigma^2 = 1$  et  $l = 0.1$ .

## Méta-modèle

On suppose que  $f$  est la réalisation d'un processus Gaussien :

$$Y \sim \mathbf{GP}(m_\beta, \sigma^2 C_\psi), \quad (1)$$

où :

- $m_\beta(x) = h(x)^T \beta$ , avec  $h(x) = (h_1(x), \dots, h_s(x))^T$  est le vecteur des fonctions de régression connues,
- $\beta \in \mathbf{R}^s$  est le vecteur des paramètres,
- $C_\psi$  : fonction de corrélation et  $\psi$  est le vecteur d'hyperparamètres.

On dispose de :

- $D_k = \{x_1, \dots, x_k\}$  : le plan d'expériences numériques.
- $f(D_k) = \{f(x_1), \dots, f(x_k)\}$  : les évaluations du simulateur.

A posteriori :

$$Y_k = Y \mid f(D_k) \sim \mathbf{GP}(\mu_{\beta, \psi}^k, V_{\psi, \sigma}^k),$$

où  $\mu_{\beta}^k$  et  $V_{\psi, \sigma}$  représentent la fonction moyenne et la covariance à posteriori.

- La moyenne a posteriori :

$$\mu_{\beta,\psi}^k(x) = m_{\beta}(x) + \Sigma_{\psi}(x, D_k)^T \Sigma_{\psi}(D_k)^{-1} (y(D_k) - m_{\beta}(x))$$

- La covariance a posteriori :

$$V_{\psi,\sigma}^k(x, x') = \sigma^2 \left[ C_{\psi}(x, x') - \Sigma_{\psi}(x, D_k)^T \Sigma_{\psi}(D_k)^{-1} \Sigma_{\psi}(x', D_k) \right],$$

où :

$$\Sigma_{\psi}(D_k) = \left( C_{\psi}(x_i, x_j) \right)_{1 \leq i, j \leq k}, \quad \Sigma_{\psi}(x, D_k) = \left( C_{\psi}(x, x_i) \right)_{1 \leq i \leq k}$$

et  $x, x' \in \mathcal{X}$ .

# Outline

- 1 Introduction
- 2 Méta-modélisation
- 3 Planification séquentielle**
- 4 Application numérique
- 5 Conclusion

# Algorithme général

## Algorithme général

- 1 Choisir le plan initial de taille  $n_0$ : un plan de remplissage de l'espace  $\mathcal{X}$
- 2 Pour  $n$  allant de  $n_0$  à  $n_{budget}$  :
  - ▶ Ajuster un méta-modèle  $\hat{f}$  sur  $\{(x_i, f(x_i))\}_{i=1, \dots, n}$
  - ▶ Utiliser ce méta-modèle pour choisir le prochain point  $x_{n+1}$  selon un critère  $C_n$
- 3 Calculer  $\hat{x}^* = \operatorname{argmin}_{x \in \mathcal{X}} \hat{f}(x)$



$$x_{n+1} = \operatorname{argmax}_{x \in \mathcal{X}} C_n(x)$$

## Quelques critères :

- ① Amélioration moyenne (**Excepted Improvement**) :

$$\mathbf{EI}_n(x) = \mathbf{E}[(m_n - f(x))\mathbf{1}_{f(x) \leq m_n} \mid f(D_n)],$$

où  $m_n = \min_{i=1, \dots, n} f(x_i)$

- ② Borne de confiance (**Upper Confidence Bound**) :

$$\mathbf{UCB}_n(x, \lambda) = \mu_n(x) + \lambda \sigma_n(x),$$

où  $\mu_n(x) = \mathbf{E}(f(x) \mid f(D_n))$ ,  $\sigma_n^2 = \mathbf{Var}(f(x) \mid f(D_n))$  et  $\lambda \in \mathbf{R}$ .

- ③ Probabilité d'amélioration (**Probability of Improvement**):

$$\mathbf{PI}_n(x) = \mathbf{E}[\mathbf{1}_{f(x) \leq m_k} \mid f(D_n)]$$

# Algorithme d'optimisation globale

Les étapes de l'algorithme sont les suivantes :

① Initialisation :

- ▶ Choisir un plan initial  $D_0 = \{x_1, \dots, x_{n_0}\}$  de taille  $n_0$
- ▶ Évaluer le simulateur en  $D_0$  et calculer  $m_0 = \min\{f(x_1), \dots, f(x_{n_0})\}$
- ▶ Entraîner le méta-modèle sur  $(D_0, f(D_0))$ .

② Pour  $k = n_0 + 1, \dots, n_{budget}$ , faire :

- ▶ Déterminer

$$x_k = \operatorname{argmax}_{x \in \mathcal{X}} EI_k(x) = \mathbf{E}[(m_k - f(x))\mathbf{1}_{f(x) \leq m_k} \mid f(D_k)]$$

- ▶ Enrichir le plan d'expériences  $D_k = D_{k-1} \cup \{x_k\}$  et calculer  $f(x_k)$
- ▶ Mettre à jour le méta-modèle sur  $(D_k, f(D_k))$
- ▶ Mettre à jour  $m_k = \min\{f(x_1), \dots, f(x_k)\}$

③ Retourner  $\hat{x}^* = \operatorname{argmin}_{x \in \mathcal{X}} \hat{f}(x)$ ;  $\hat{f}(\cdot)$  est le prédicteur donné par le méta-modèle.



# Outline

- 1 Introduction
- 2 Méta-modélisation
- 3 Planification séquentielle
- 4 Application numérique**
- 5 Conclusion


# Application

- Fonction de test :  $f : x \in [3, 20] \mapsto \sin(x) + \sin(\frac{2}{3}x) \in \mathbf{R}$
- Taille budget  $n_{budget} = 20$  et taille du plan initiale  $n_0 = 5$
- Fonction de covariance : *Matern* 5/2
- $D_0$  : Plan de remplissage Latin Hypercube maximin de taille  $n_0$
- Critère utilisé : **Excepted Improvement**


# Application : illustration




# Application : illustration



# Application : illustration




# Application : illustration







# Application : illustration




# Application : illustration




# Application : illustration




# Application : illustration




# Application : illustration




# Application : illustration



# Application : illustration




# Application : illustration






# Application : illustration




# Application : illustration



# Application : illustration

Finalement :  $\hat{x}^* = 17.039 = x^*$  et  $\hat{f}(x^*) = -1.9059 = f(x^*)$







# Outline

- 1 Introduction
- 2 Méta-modélisation
- 3 Planification séquentielle
- 4 Application numérique
- 5 Conclusion**

## Synthèse :

- La modélisation par Processus Gaussien offre un cadre propice à la planification d'expériences.
- La stratégie basée sur le critère d'acquisition **EI** améliore au fur et à mesure la connaissance du minimum en choisissant les expériences qui apporte le plus d'informations pour son estimation.
- Pour chaque objectif particulier des critères adaptés peuvent être définis à l'aide du méta-modèle de Processus Gaussien.

*Merci pour votre attention !!!*

-  Peter I. Frazier, *A tutorial on bayesian optimization*, 2018.
-  D. Krige, *A statistical approach to some basic mine valuation problems on the witwatersrand, by d.g. krige, published in the journal, december 1951 : introduction by the author*, Journal of The South African Institute of Mining and Metallurgy **52** (1951), 201–203.
-  Carl Edward Rasmussen and Christopher K. I. Williams, *Gaussian processes for machine learning.*, Adaptive computation and machine learning, MIT Press, 2006.
-  Jerome Sacks, Susannah Schiller, and William Welch, *Designs for computer experiments*, Technometrics **31** (1989), 41–47.



Julien Villemonteix, Emmanuel Vazquez, and Eric Walter, *Identification of expensive-to-simulate parametric models using kriging and stepwise uncertainty reduction*, 2007 46th IEEE Conference on Decision and Control, IEEE, 2007, pp. 5505–5510.