

# PLANS D'EXPÉRIENCES ET CODES NUMÉRIQUES

Luc Pronzato

Laboratoire I3S,  
CNRS/Univ. Nice Sophia Antipolis, France

# Plan

- I) Quel objectif ?

# Plan

- I) Quel objectif ?
- II) Non séquentiel ou séquentiel/adaptatif ?

# Plan

- I) Quel objectif ?
- II) Non séquentiel ou séquentiel/adaptatif ?
- III) Quel modèle ?  
(paramétrique/non paramétrique – structure fixe ou variable)

# Plan

- I) Quel objectif ?
- II) Non séquentiel ou séquentiel/adaptatif ?
- III) Quel modèle ?  
(paramétrique/non paramétrique – structure fixe ou variable)
- IV) Quelques problèmes...

# I) Quel objectif ?

$f(x)$  une fonction (inconnue) définie pour  $x \in \mathcal{X} \subset \mathbb{R}^d$

À partir de couples  $X_i, f(X_i)$ ,  $i = 1, 2 \dots$  on va construire un modèle  $\eta(\cdot)$  de  $f(\cdot)$  dans un but

- d'exploration :  $\eta(\cdot)$  doit approximer  $f(\cdot)$  le mieux possible sur  $\mathcal{X}$

# I) Quel objectif ?

$f(x)$  une fonction (inconnue) définie pour  $x \in \mathcal{X} \subset \mathbb{R}^d$

À partir de couples  $X_i, f(X_i)$ ,  $i = 1, 2 \dots$  on va construire un modèle  $\eta(\cdot)$  de  $f(\cdot)$  dans un but

- d'exploration :  $\eta(\cdot)$  doit approximer  $f(\cdot)$  le mieux possible sur  $\mathcal{X}$
- d'optimisation :  
→ utiliser  $\eta(\cdot)$  pour déterminer  $\arg_{x \in \mathcal{X}} f(x)$

# I) Quel objectif ?

$f(x)$  une fonction (inconnue) définie pour  $x \in \mathcal{X} \subset \mathbb{R}^d$

À partir de couples  $X_i, f(X_i)$ ,  $i = 1, 2 \dots$  on va construire un modèle  $\eta(\cdot)$  de  $f(\cdot)$  dans un but

- d'exploration :  $\eta(\cdot)$  doit approximer  $f(\cdot)$  le mieux possible sur  $\mathcal{X}$
- d'optimisation :  
→ utiliser  $\eta(\cdot)$  pour déterminer  $\arg_{x \in \mathcal{X}} f(x)$
- de maximisation de la diversité des réponses :  
→ trouver des  $X_i$  tels que les  $f(X_i)$  soient bien dispersés dans  $\{f(x) : x \in \mathcal{X}\}$

# I) Quel objectif ?

$f(x)$  une fonction (inconnue) définie pour  $x \in \mathcal{X} \subset \mathbb{R}^d$

À partir de couples  $X_i, f(X_i)$ ,  $i = 1, 2 \dots$  on va construire un modèle  $\eta(\cdot)$  de  $f(\cdot)$  dans un but

- d'exploration :  $\eta(\cdot)$  doit approximer  $f(\cdot)$  le mieux possible sur  $\mathcal{X}$
- d'optimisation :  
→ utiliser  $\eta(\cdot)$  pour déterminer  $\arg_{x \in \mathcal{X}} f(x)$
- de maximisation de la diversité des réponses :  
→ trouver des  $X_i$  tels que les  $f(X_i)$  soient bien dispersés dans  $\{f(x) : x \in \mathcal{X}\}$
- on peut avoir  $m$  fonctions  $f_i(\cdot)$ ,  $i = 1, \dots, m$  :  
→ optimisation multicritères, diversité dans  $\mathbb{R}^m \dots$


**Préciser l'objectif est un préalable indispensable à la construction d'un plan "optimal" !**

Préciser l'objectif est un préalable indispensable à la construction d'un plan "optimal" !

## II) Non séquentiel ou séquentiel/adaptatif ?

Non-séquentiel, sans modèle :

propriété de remplissage d'espace ("space filling")  
→ distance maximin ou minimax [Johnson *et al.*, 1990], hypercubes latins [Morris & Mitchell 1995]...



**Non-séquentiel, avec modèle** : si objectif = exploration,  
critère = maximum ou moyenne sur  $\mathcal{X}$  de l'erreur  
quadratique moyenne de prédiction (EQM) ...

**Non-séquentiel, avec modèle** : si objectif = exploration,  
critère = maximum ou moyenne sur  $\mathcal{X}$  de l'erreur  
quadratique moyenne de prédiction (EQM) ...

Disposer d'une EQM suppose un modèle  $\eta(\cdot)$

... et si on dispose d'un modèle, on peut utiliser un plan  
adaptatif (construit pas à pas)

**Problème central : comment prédire l'incertitude en un  
point  $x$  non encore exploré ?**

**Non-séquentiel, avec modèle** : si objectif = exploration,  
critère = maximum ou moyenne sur  $\mathcal{X}$  de l'erreur  
quadratique moyenne de prédiction (EQM) ...

Disposer d'une EQM suppose un modèle  $\eta(\cdot)$

... et si on dispose d'un modèle, on peut utiliser un plan  
adaptatif (construit pas à pas)

**Problème central : comment prédire l'incertitude en un  
point  $x$  non encore exploré ?**

### III) Quel modèle ?

**Éviter une approche paramétrique dans un contexte non-  
paramétrique !**

## Modèle paramétrique :

$f(X_i) = \eta(X_i, \theta) + \varepsilon_i$ ,  $\theta$  estimé par MC

$$\hat{\theta}^N = \arg \min \frac{1}{N} \sum_{i=1}^N [f(X_i) - \eta(X_i, \theta)]^2$$

## Modèle paramétrique :

$f(X_i) = \eta(X_i, \theta) + \varepsilon_i$ ,  $\theta$  estimé par MC

$$\hat{\theta}^N = \arg \min \frac{1}{N} \sum_{i=1}^N [f(X_i) - \eta(X_i, \theta)]^2$$

Dans un contexte stochastique, avec  $(\varepsilon_i)$  i.i.d. de moyenne 0 et variance  $\sigma^2$  et  $(X_i)$  i.i.d. avec mesure de probabilité  $\xi$  sur  $\mathcal{X}$ , alors  $\hat{\theta}^N \xrightarrow{\text{p.s.}} \bar{\theta}$  et

$$\sqrt{N}(\hat{\theta}^N - \bar{\theta}) \xrightarrow{d} \zeta \sim \mathcal{N}(0, \sigma^2 \mathbf{M}^{-1}(\xi, \bar{\theta}))$$

avec  $\mathbf{M}(\xi, \theta) = \int_{\mathcal{X}} \frac{\partial \eta(x, \theta)}{\partial \theta} \frac{\partial \eta(x, \theta)}{\partial \theta^\top} \xi(dx)$

Soient  $\theta$  fixé et  $X_1, \dots, X_n$  fixés (tels que  $\mathbf{M}(\xi_n, \theta)$  de rang plein). Choisir

$$X_{k+1} = \arg \max_{x \in \mathcal{X}} \frac{\partial \eta(x, \theta)}{\partial \theta^\top} \mathbf{M}^{-1}(\xi_k, \theta) \frac{\partial \eta(x, \theta)}{\partial \theta}, \quad k \geq n$$

assure  $\xi_k \rightarrow \xi^*(\theta) = \arg \max_{\xi} \det \mathbf{M}(\xi, \theta)$  ( $D$ -optimalité)  
quand  $k \rightarrow \infty$ , avec  $\xi_k =$  mesure empirique de  $X_1, \dots, X_k$

Soient  $\theta$  fixé et  $X_1, \dots, X_n$  fixés (tels que  $\mathbf{M}(\xi_n, \theta)$  de rang plein). Choisir

$$X_{k+1} = \arg \max_{x \in \mathcal{X}} \frac{\partial \eta(x, \theta)}{\partial \theta^\top} \mathbf{M}^{-1}(\xi_k, \theta) \frac{\partial \eta(x, \theta)}{\partial \theta}, \quad k \geq n$$

assure  $\xi_k \rightarrow \xi^*(\theta) = \arg \max_{\xi} \det \mathbf{M}(\xi, \theta)$  ( $D$ -optimalité)  
quand  $k \rightarrow \infty$ , avec  $\xi_k =$  mesure empirique de  $X_1, \dots, X_k$

Problème :  $\xi^*(\theta)$  a  $p(p+1)/2$  points de support au plus  
(et souvent seulement  $p$ ) avec  $p = \dim(\theta)$

$\Rightarrow \xi_k$  n'est pas "space filling"

Quand on ré-estime  $\theta$  à chaque étape, soit

$$X_{k+1} = \arg \max_{x \in \mathcal{X}} \frac{\partial \eta(x, \theta)}{\partial \theta^\top} \Big|_{\hat{\theta}^k} \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \frac{\partial \eta(x, \theta)}{\partial \theta} \Big|_{\hat{\theta}^k}, \quad k \geq n \quad (1)$$

la convergence de  $\hat{\theta}^k$  vers  $\bar{\theta}$ , et de  $\xi_k$  vers  $\xi^*(\bar{\theta})$ , n'est pas prouvée en général, mais jamais mise en défaut...

Quand on ré-estime  $\theta$  à chaque étape, soit

$$X_{k+1} = \arg \max_{x \in \mathcal{X}} \frac{\partial \eta(x, \theta)}{\partial \theta^\top} \Big|_{\hat{\theta}^k} \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \frac{\partial \eta(x, \theta)}{\partial \theta} \Big|_{\hat{\theta}^k}, \quad k \geq n \quad (1)$$

la convergence de  $\hat{\theta}^k$  vers  $\bar{\theta}$ , et de  $\xi_k$  vers  $\xi^*(\bar{\theta})$ , n'est pas prouvée en général, mais jamais mise en défaut...

On pourrait penser utiliser (1) dans un cadre déterministe avec une fonction d'approximation pour modèle  $\eta(x, \theta)$  (réseau de neurones, RBF...)

**Ex. 1 : RBF**  $\eta(x) = \sum_{j=1}^p \theta_j K(x - N_j)$  (par ex.  $K(\cdot)$  gaussien)

→ modèle linéaire à  $p$  paramètres

$p = 5$  fixé,  $N_1, \dots, N_5$  fixés,  $(X_1, \dots, X_5) =$  plan  $D$ -optimal

puis  $X_i$  là où la variance de la prédiction est maximale


(ce qui suppose  $f(X_i) = \eta(X_i) + \varepsilon_i \dots$ )

**Ex. 1 : RBF**  $\eta(x) = \sum_{j=1}^p \theta_j K(x - N_j)$  (par ex.  $K(\cdot)$  gaussien)

→ modèle linéaire à  $p$  paramètres

$p = 5$  fixé,  $N_1, \dots, N_5$  fixés,  $(X_1, \dots, X_5) =$  plan  $D$ -optimal  
 puis  $X_i$  là où la variance de la prédiction est maximale  
 (ce qui suppose  $f(X_i) = \eta(X_i) + \varepsilon_i \dots$ )

→ pas d'exploration :  
 le plan reste concentré en  
 $p$  points




Prenons  $p$  croissant (structure variable) :

$N_1, \dots, N_5$  et  $(X_1, \dots, X_5)$  comme précédemment  
puis  $N_i$  et  $X_i$  au point de variance de prédiction maximale

Prenons  $p$  croissant (structure variable) :

$N_1, \dots, N_5$  et  $(X_1, \dots, X_5)$  comme précédemment  
puis  $N_i$  et  $X_i$  au point de variance de prédiction maximale

→ pas beaucoup plus  
d'exploration : le plan  
reste concentré



**Le problème n'est pas lié au choix de  $\eta(x, \theta)$  : mêmes difficultés pour polynômes, ou "fonction universelle"**

**Le problème n'est pas lié au choix de  $\eta(x, \theta)$  : mêmes difficultés pour polynômes, ou "fonction universelle"**

**Ex. 2 :** 
$$\eta(x, \theta) = \int_0^{x+\theta_1} \frac{\theta_2 \theta_4}{1 + \theta_4^2 - \cos(\theta_2 t)} \cos[\exp(t)] dt + \theta_3$$


(famille dense dans  $\mathcal{C}(I)$  pour tout  $I = [a, b] \subset \mathbb{R}$ )

**Le problème n'est pas lié au choix de  $\eta(x, \theta)$  : mêmes difficultés pour polynômes, ou "fonction universelle"**

**Ex. 2 :** 
$$\eta(x, \theta) = \int_0^{x+\theta_1} \frac{\theta_2 \theta_4}{1 + \theta_4^2 - \cos(\theta_2 t)} \cos[\exp(t)] dt + \theta_3$$

(famille dense dans  $\mathcal{C}(I)$  pour tout  $I = [a, b] \subset \mathbb{R}$ )

→ pas vraiment  
d'exploration : le plan  
reste concentré



→ **Changeons la façon de prédire l'incertitude en  $x$  !**

→ **Changeons la façon de prédire l'incertitude en  $x$  !**

**Ex. 1 (suite) : RBF avec Bootstrap et Leave-One-Out**  
**[Gazut, Martinez, Issanchou 2006] :**

$$\eta_i(x, \theta^{(i)}) = \sum_{j=1, j \neq i}^n \theta_j K(x - N_j)$$

→ variance  $V(x)$  des  $n$  prédictions (MC) en  $x$

→ observation en  $X_{n+1} = \arg \max_x V(x)$  et  $N_{n+1} = X_{n+1}$

→ **Changeons la façon de prédire l'incertitude en  $x$  !**


**Ex. 1 (suite) : RBF avec Bootstrap et Leave-One-Out**  
[Gazut, Martinez, Issanchou 2006] :

$$\eta_i(x, \theta^{(i)}) = \sum_{j=1, j \neq i}^n \theta_j K(x - N_j)$$

→ variance  $V(x)$  des  $n$  prédictions (MC) en  $x$

→ observation en  $X_{n+1} = \arg \max_x V(x)$  et  $N_{n+1} = X_{n+1}$

→ exploration




## Ex. 3 : Krigage

Même données que pour Ex. 1, modèle :  $f(x) = \beta + Z(x, \omega)$   
avec  $Z(x, \omega)$  réalisation d'un processus gaussien,


$\mathbb{E}\{Z(x, \omega)\} = 0$ ,  $\mathbb{E}\{Z(x, \omega)Z(u, \omega)\} = \sigma^2 C(|x - u|, \theta)$  (ici,  $\beta$  et  $\sigma^2$  inconnus et  $\theta$  fixé)

$X_{n+1}$  au point de variance de krigage maximale

→ exploration  
(9 points seulement)



→ exploration  
(20 points)



## III) Quelques problèmes...

- algorithmes pour plans non-séquentiels sans modèle (“space-filling”)

## III) Quelques problèmes...

- algorithmes pour plans non-séquentiels sans modèle (“space-filling”)
- plans séquentiels, méthodes d’exploration, apprentissage actif, modèles (Bootstrap et Leave-One-Out, krigeage...)

## III) Quelques problèmes...

- algorithmes pour plans non-séquentiels sans modèle (“space-filling”)
- plans séquentiels, méthodes d’exploration, apprentissage actif, modèles (Bootstrap et Leave-One-Out, krigeage...)
- propriétés théoriques : asymptotique, prise en compte de l’estimation de  $\theta$  dans  $C(\cdot, \theta)$  pour prédiction par krigeage —aspect dual de la construction du plan—

## III) Quelques problèmes...

- algorithmes pour plans non-séquentiels sans modèle (“space-filling”)
- plans séquentiels, méthodes d’exploration, apprentissage actif, modèles (Bootstrap et Leave-One-Out, krigeage...)
- propriétés théoriques : asymptotique, prise en compte de l’estimation de  $\theta$  dans  $C(\cdot, \theta)$  pour prédiction par krigeage —aspect dual de la construction du plan—
- autres problématiques que l’exploration (optimisation...)

## III) Quelques problèmes...

- algorithmes pour plans non-séquentiels sans modèle (“space-filling”)
- plans séquentiels, méthodes d’exploration, apprentissage actif, modèles (Bootstrap et Leave-One-Out, krigeage...)
- propriétés théoriques : asymptotique, prise en compte de l’estimation de  $\theta$  dans  $C(\cdot, \theta)$  pour prédiction par krigeage —aspect dual de la construction du plan—
- autres problématiques que l’exploration (optimisation...)
- problèmes réels, benchmarks...