

# Optimisation Séquentielle par Processus Gaussiens

Emile Contal — CMLA, ENS Cachan



# Formulation du Problème

## Modèle

- ▶  $f : \mathcal{X} \rightarrow \mathbb{R}$ , inconnue, non convexe, multimodale
- ▶ on cherche  $f^* = \sup_{x \in \mathcal{X}} f(x)$  via  $f(x_1), f(x_2), \dots$
- ▶  $\mathcal{X}$  peut être  $\subset \mathbb{R}^D$  ou non paramétrique
- ▶ on observe  $y_n = f(x_n) + \varepsilon$  où  $\varepsilon \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \eta^2)$

## Objectifs

- ▶ regret simple :  $S_T = \min_{n \leq T} \{f^* - f(x_n)\}$
- ▶ regret cumulé :  $R_T = \sum_{n \leq T} (f^* - f(x_n))$

# Formulation du Problème

## Modèle


- ▶  $f : \mathcal{X} \rightarrow \mathbb{R}$ , inconnue, non convexe, multimodale
- ▶ on cherche  $f^* = \sup_{x \in \mathcal{X}} f(x)$  via  $f(x_1), f(x_2), \dots$
- ▶  $\mathcal{X}$  peut être  $\subset \mathbb{R}^D$  ou non paramétrique
- ▶ on observe  $y_n = f(x_n) + \varepsilon$  où  $\varepsilon \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \eta^2)$

## Objectifs


- ▶ regret simple :  $S_T = \min_{n \leq T} \{f^* - f(x_n)\}$
- ▶ regret cumulé :  $R_T = \sum_{n \leq T} (f^* - f(x_n))$

Remarque :  $S_T \leq T^{-1}R_T$

# Compromis Exploration/Exploitation



# Compromis Exploration/Exploitation



# Revue de la Littérature

## Bandits Stochastiques

[Lai1985, Bubeck2012]

$$\mathcal{X} = (1, \dots, K), \quad \mathbb{E}[R_T] \approx 2\eta^2 H \log T \text{ avec } H = \sum_{x \in \mathcal{X}: f(x) < f^*} (f^* - f(x))^{-1}$$

# Revue de la Littérature

## Bandits Stochastiques

[Lai1985, Bubeck2012]

$$\mathcal{X} = (1, \dots, K), \quad \mathbb{E}[R_T] \approx 2\eta^2 H \log T \text{ avec } H = \sum_{x \in \mathcal{X}: f(x) < f^*} (f^* - f(x))^{-1}$$

## Algorithmes Evolutionnaires

[Garnier2001, Eiben2003]

garanties de convergence mais peu de résultats sur la vitesse, gourmand en évaluations de  $f$

# Revue de la Littérature

## Bandits Stochastiques

[Lai1985, Bubeck2012]

$$\mathcal{X} = (1, \dots, K), \quad \mathbb{E}[R_T] \approx 2\eta^2 H \log T \text{ avec } H = \sum_{x \in \mathcal{X}: f(x) < f^*} (f^* - f(x))^{-1}$$

## Algorithmes Evolutionnaires

[Garnier2001, Eiben2003]

garanties de convergence mais peu de résultats sur la vitesse, gourmand en évaluations de  $f$

## Optimisation Lipschitzienne

[Bull2015, Grill2015]

$$\mathcal{X} \subset \mathbb{R}^D, \|f\|_{\text{Lip}} < B, \quad \mathbb{E}[R_T] \approx T^{\frac{D+1}{D+2}}$$

# Revue de la Littérature

## Bandits Stochastiques

[Lai1985, Bubeck2012]

$$\mathcal{X} = (1, \dots, K), \quad \mathbb{E}[R_T] \approx 2\eta^2 H \log T \text{ avec } H = \sum_{x \in \mathcal{X}: f(x) < f^*} (f^* - f(x))^{-1}$$

## Algorithmes Evolutionnaires

[Garnier2001, Eiben2003]

garanties de convergence mais peu de résultats sur la vitesse, gourmand en évaluations de  $f$

## Optimisation Lipschitzienne

[Bull2015, Grill2015]

$$\mathcal{X} \subset \mathbb{R}^D, \|f\|_{\text{Lip}} < B, \quad \mathbb{E}[R_T] \approx T^{\frac{D+1}{D+2}}$$

## Optimisation Bayésienne

[deFreitas2012, Srinivas2012]

$$f \sim \mathcal{GP}(0, k), \quad R_T \lesssim \sqrt{T \gamma_T \log(T|\mathcal{X}|)} \text{ avec } \gamma_T \text{ défini plus tard}$$

# Bornes de Confiance et UCB

## Intervalles de Confiance

Après  $n$  itérations, connaissant  $y_1, \dots, y_n$  les observations pour  $x_1, \dots, x_n$ , imaginons que l'on peut calculer  $L_n : \mathcal{X} \rightarrow \mathbb{R}$  et  $U_n : \mathcal{X} \rightarrow \mathbb{R}$  tels que :

$$\forall x \in \mathcal{X}, \quad f(x) \in (L_n(x), U_n(x)) \quad \text{avec forte probabilité}$$

# Bornes de Confiance et UCB

## Intervalles de Confiance

Après  $n$  itérations, connaissant  $y_1, \dots, y_n$  les observations pour  $x_1, \dots, x_n$ , imaginons que l'on peut calculer  $L_n : \mathcal{X} \rightarrow \mathbb{R}$  et  $U_n : \mathcal{X} \rightarrow \mathbb{R}$  tels que :


$$\forall x \in \mathcal{X}, \quad f(x) \in (L_n(x), U_n(x)) \quad \text{avec forte probabilité}$$

## Stratégie UCB

Alors, avec  $x_{n+1} = \operatorname{argmax}_{x \in \mathcal{X}} U_n(x)$ , on a :

$$f^* - f(x_{n+1}) \leq U_n(x^*) - L_n(x_{n+1}) \leq U_n(x_{n+1}) - L_n(x_{n+1})$$

# Stratégie UCB pour une Fonction Lipschitzienne sans Bruit



# Optimisation Bayésienne

## Hypothèse de Régularité

- ▶  $f \sim \mathcal{GP}(0, k)$  avec  $k$  connu en théorie
- ▶ en pratique : famille SE ou Matérn et choix empirique des paramètres

# Optimisation Bayésienne

## Hypothèse de Régularité

- ▶  $f \sim \mathcal{GP}(0, k)$  avec  $k$  connu en théorie
- ▶ en pratique : famille SE ou Matérn et choix empirique des paramètres

## Inférence Bayésienne

Sachant les observations  $\mathbf{Y}_n = [y_1, \dots, y_n]$  pour  $\mathbf{X}_n = (x_1, \dots, x_n)$ ,

- ▶  $\mu_n(x) = \mathbb{E}[f(x) \mid \mathbf{X}_n, \mathbf{Y}_n]$
- ▶  $\sigma_n^2(x) = \mathbb{V}[f(x) \mid \mathbf{X}_n, \mathbf{Y}_n]$

# Optimisation Bayésienne

## Hypothèse de Régularité

- ▶  $f \sim \mathcal{GP}(0, k)$  avec  $k$  connu en théorie
- ▶ en pratique : famille SE ou Matérn et choix empirique des paramètres


## Inférence Bayésienne

Sachant les observations  $\mathbf{Y}_n = [y_1, \dots, y_n]$  pour  $X_n = (x_1, \dots, x_n)$ ,

- ▶  $\mu_n(x) = \mathbb{E}[f(x) \mid X_n, \mathbf{Y}_n] = \mathbf{k}_n(x)^\top \mathbf{C}_n^{-1} \mathbf{Y}_n$
- ▶  $\sigma_n^2(x) = \mathbb{V}[f(x) \mid X_n, \mathbf{Y}_n] = k(x, x) - \mathbf{k}_n(x)^\top \mathbf{C}_n^{-1} \mathbf{k}_n(x)$

où  $\mathbf{C}_n = \mathbf{K}_n + \eta^{-2} \mathbf{I}$  et  $\mathbf{K}_n = [k(x_i, x_j)]_{x_i, x_j \in X_n}$ .

# Bornes de Confiance pour un Processus Gaussien



## Cas où $\mathcal{X}$ est fini

Lorsque  $|\mathcal{X}| < \infty$ , avec  $\beta_n \approx \log(n|\mathcal{X}|)$ , avec forte probabilité :

$$\forall n > 0, \forall x \in \mathcal{X}, \quad f(x) \in (L_n(x), U_n(x))$$

- ▶ où  $L_n(x) = \mu_n(x) - \sqrt{\beta_n \sigma_n^2(x)}$
- ▶ et  $U_n(x) = \mu_n(x) + \sqrt{\beta_n \sigma_n^2(x)}$

## Cas où $\mathcal{X}$ est fini

Lorsque  $|\mathcal{X}| < \infty$ , avec  $\beta_n \approx \log(n|\mathcal{X}|)$ , avec forte probabilité :

$$\forall n > 0, \forall x \in \mathcal{X}, \quad f(x) \in (L_n(x), U_n(x))$$

▶ où  $L_n(x) = \mu_n(x) - \sqrt{\beta_n \sigma_n^2(x)}$

▶ et  $U_n(x) = \mu_n(x) + \sqrt{\beta_n \sigma_n^2(x)}$

pour la stratégie UCB : 
$$R_T \leq \sum_{n=1}^T 2\sqrt{\beta_n \sigma_n^2(x_{n+1})}$$

## Cas où $\mathcal{X}$ est fini

Lorsque  $|\mathcal{X}| < \infty$ , avec  $\beta_n \approx \log(n|\mathcal{X}|)$ , avec forte probabilité :

$$\forall n > 0, \forall x \in \mathcal{X}, \quad f(x) \in (L_n(x), U_n(x))$$

▶ où  $L_n(x) = \mu_n(x) - \sqrt{\beta_n \sigma_n^2(x)}$

▶ et  $U_n(x) = \mu_n(x) + \sqrt{\beta_n \sigma_n^2(x)}$

pour la stratégie UCB :  $R_T \leq \sum_{n=1}^T 2\sqrt{\beta_n \sigma_n^2(x_{n+1})}$

or  $\sum_{n=1}^T \sigma_n^2(x_{n+1}) \lesssim \gamma_T$  avec  $\gamma_T = \max_{\substack{S \subset \mathcal{X} \\ |S|=T}} H(f) - H(f | Y_S)$

## Cas où $\mathcal{X}$ est fini

Lorsque  $|\mathcal{X}| < \infty$ , avec  $\beta_n \approx \log(n|\mathcal{X}|)$ , avec forte probabilité :

$$\forall n > 0, \forall x \in \mathcal{X}, \quad f(x) \in (L_n(x), U_n(x))$$

▶ où  $L_n(x) = \mu_n(x) - \sqrt{\beta_n \sigma_n^2(x)}$

▶ et  $U_n(x) = \mu_n(x) + \sqrt{\beta_n \sigma_n^2(x)}$

pour la stratégie UCB :  $R_T \leq \sum_{n=1}^T 2\sqrt{\beta_n \sigma_n^2(x_{n+1})}$

or  $\sum_{n=1}^T \sigma_n^2(x_{n+1}) \lesssim \gamma_T$  avec  $\gamma_T = \max_{\substack{S \subset \mathcal{X} \\ |S|=T}} H(f) - H(f | Y_S)$

ainsi,  $R_T \lesssim \sqrt{T \gamma_T \log(T|\mathcal{X}|)}$

# Cas où $\mathcal{X}$ est Continu : Préliminaires

## Pseudo-Métrique Canonique

$$\begin{aligned}\text{Soit } d^2(x, x') &= \mathbb{V}[f(x) - f(x')] \\ &= k(x, x) - 2k(x, x') + k(x', x')\end{aligned}$$

# Cas où $\mathcal{X}$ est Continu : Préliminaires

## Pseudo-Métrique Canonique

$$\begin{aligned}\text{Soit } d^2(x, x') &= \mathbb{V}[f(x) - f(x')] \\ &= k(x, x) - 2k(x, x') + k(x', x')\end{aligned}$$

Fixons  $x, x' \in \mathcal{X}$ , avec forte probabilité :

$$|f(x) - f(x')| \lesssim d(x, x')$$

# Cas où $\mathcal{X}$ est Continu : Préliminaires

## Pseudo-Métrique Canonique

$$\begin{aligned}\text{Soit } d^2(x, x') &= \mathbb{V}[f(x) - f(x')] \\ &= k(x, x) - 2k(x, x') + k(x', x')\end{aligned}$$

Fixons  $x, x' \in \mathcal{X}$ , avec forte probabilité :

$$|f(x) - f(x')| \lesssim d(x, x')$$

## Borne pour un sous-ensemble fini $S \subset \mathcal{X}$

Pour  $|S| = m$ , on a avec forte probabilité :

$$\sup_{x \in S} f(x) - f(x_n) \lesssim \sqrt{\log m} \sup_{x \in S} d(x, x_n)$$

## Cas où $\mathcal{X}$ est Continu : Discrétisation

### $\varepsilon$ -Recouvrement de $\mathcal{X}$

$S \subset \mathcal{X}$  est un  $\varepsilon$ -recouvrement de  $\mathcal{X}$  pour  $d$  ssi :


$$\forall x \in \mathcal{X}, \exists x' \in S \text{ t.q. } d(x, x') \leq \varepsilon$$

### Entropie métrique

Soit  $N(\mathcal{X}, \varepsilon)$  la taille du plus petit  $\varepsilon$ -recouvrement

$H(\mathcal{X}, \varepsilon) = \log N(\mathcal{X}, \varepsilon)$  est l'entropie métrique de  $\mathcal{X}$

# Un $\varepsilon$ -Recouvrement pour la Distance Euclidienne




## Cas où $\mathcal{X}$ est continu : Recouvrements Hiérarchiques


On suppose que  $d(\cdot, \cdot) \leq 1$ .

- ▶  $\varepsilon_0 = 1, \varepsilon_1 = 1/2, \varepsilon_2 = 1/4, \dots$
- ▶  $S_0 \subset S_1 \subset \dots \subset \mathcal{X}$
- ▶  $S_i$  est un  $\varepsilon_i$ -recouvrement


# Recouvrements Hiérarchiques : $\varepsilon_0 = 1$




# Recouvrements Hiérarchiques : $\varepsilon_1 = \frac{1}{2}$



# Recouvrements Hiérarchiques : $\varepsilon_2 = \frac{1}{4}$



# Recouvrements Hiérarchiques : $\varepsilon_3 = \frac{1}{8}$



## Cas où $\mathcal{X}$ est continu : Chaînage

Soit  $\pi_i : \mathcal{X} \rightarrow S_i$  qui associe à un point de  $\mathcal{X}$  son point le plus proche de  $S_i$

$$\sup_{s \in S_i} f(s) - f(\pi_{i-1}(s)) \lesssim \sqrt{H(\mathcal{X}, \varepsilon_i)} \varepsilon_{i-1}$$

### Théorème : Erreur de Discrétisation

$$\forall i \geq 0, \quad \sup_{x \in \mathcal{X}} f(x) - f(\pi_i(x)) \lesssim \omega_i$$

$$\text{où } \omega_i = \sum_{j>i} \sqrt{H(\mathcal{X}, \varepsilon_j)} \varepsilon_{j-1}$$

# Cas où $\mathcal{X}$ est continu : UCB et Discrétisations Adaptatives

A l'itération  $n$ , on choisit le niveau de discrétisation  $i_n = \lceil 1/2 \log_2 n \rceil$

Alors,  $\omega_{i_n} \lesssim \sqrt{\frac{d \log n}{n}}$



Avec  $x_{n+1} = \operatorname{argmax}_{x \in \mathcal{S}_{i_n}} U_n(x)$  on obtient :

**Théorème : Regret**



$$R_T \lesssim \sqrt{T \gamma_T d \log^2 T}$$

avec forte probabilité




# Expérience 1/4 : Fonction d'Himmelblau




# Expérience 2/4 : Noyau SE



# Expérience 3/4 : Wave Energy Converter



# Expérience 4/4 : Noyaux de Graphes



$$f(\text{Graph 1}) = 1.3$$

$$f(\text{Graph 2}) = 0.2$$

$$f(\text{Graph 3}) = 2.7$$

## Conclusion

### L'Algorithme UCB par Chaînage

- ▶ construit en suivant la théorie
- ▶ calibre automatiquement le compromis exploration/exploitation
- ▶ s'adapte à des cadres divers
- ▶ calculs raisonnables : itération en  $\mathcal{O}(n^2)$

### Code Matlab en Ligne (et bientôt Python)

<http://econtal.perso.math.cnrs.fr/software/>

- Contal, E., Malherbe, C., and Vayatis, N. (2015). Optimization for gaussian processes via chaining. *NIPS Workshop on Bayesian Optimization*.
- Munos, R. (2011). Optimistic optimization of deterministic functions without the knowledge of its smoothness. In *Advances in neural information processing systems 25 (NIPS)*.
- Srinivas, N., Krause, A., Kakade, S., and Seeger, M. (2012). Information-theoretic regret bounds for Gaussian process optimization in the bandit setting. *IEEE Transactions on Information Theory*, 58(5):3250–3265.
- Talagrand, M. (2014). *Upper and Lower Bounds for Stochastic Processes: Modern Methods and Classical Problems*, volume 60. Springer-Verlag Berlin Heidelberg.