

Correction du critère EI pour la prise en compte de l'incertitude sur les paramètres d'une covariance


Romain Benassi Julien Bect Emmanuel Vazquez

SUPELEC

4 mai 2010

Atelier optimisation GDR MASCOT-NUM

- Conception de systèmes à l'aide de simulations numériques
- Ici, problème de conception = problème d'optimisation mono-objectif
- Si les simulations prennent beaucoup de temps, le nombre de simulations qu'il est possible d'effectuer est limité (p.ex. < 100)
- Exemple : optimisation de formes



- Comment optimiser une fonction dont l'évaluation est coûteuse ?

- 1 Optimisation bayésienne par EI
- 2 Prise en compte de l'incertitude sur les paramètres
- 3 Exemple
- 4 Conclusions

- 1 Optimisation bayésienne par EI
- 2 Prise en compte de l'incertitude sur les paramètres
- 3 Exemple
- 4 Conclusions

Optimisation bayésienne

- $\mathbb{X} \subset \mathbb{R}^d$ compact : domaine de recherche
- $f : \mathbb{X} \rightarrow \mathbb{R}$ coûteuse à évaluer
- On cherche à **maximiser** f , c.-à-d. construire une suite de points d'évaluations (x_n) de façon à maximiser $M_N = f(x_1) \vee \dots \vee f(x_N)$, avec N le budget d'évaluations de f
- Approche bayésienne : prise en compte d'**informations a priori** sur f
⇒ modélisation de f par un processus aléatoire ξ
- Planification séquentielle des points d'évaluations (x_n)
 - à chaque nouvelle évaluation, utilisation de la loi *a posteriori* de ξ
 - construction d'un critère d'échantillonnage pour choisir les nouveaux points

Processus gaussien et EI [Mockus et al. 1978] 1/3

- Le plus souvent, ξ est pris **gaussien**
 - de moyenne nulle (ici, pour simplifier)
 - de fonction de covariance $k(x, y; \sigma, \underline{\theta}) = \sigma^2 r(x - y; \underline{\theta})$, avec $x, y \in \mathbb{X}$, $\sigma > 0$ et $\underline{\theta} \in \Theta$ vecteur de paramètres inconnus
- Principe d'optimisation à un pas si σ et $\underline{\theta}$ sont connus : choisir

$$x_{n+1} = \operatorname{argmax}_{x \in \mathbb{X}} \mathbb{E}[M_n \vee \xi(x) \mid \underline{\xi}_n, \sigma, \underline{\theta}]$$

avec $M_n = \xi(x_1) \vee \dots \vee \xi(x_n)$ et $\underline{\xi}_n = (\xi(x_1), \dots, \xi(x_n))^T$

Processus gaussien et EI [Mockus et al. 1978] 2/3

- On montre facilement que

$$x_{n+1} = \operatorname{argmax}_{x \in \mathbb{X}} \rho_n(x; \sigma, \underline{\theta}) = \operatorname{argmax}_{x \in \mathbb{X}} \mathbb{E}[(\xi(x) - M_n)_+ \mid \underline{\xi}_n, \sigma, \underline{\theta}]$$

et que l'**amélioration moyenne** (expected improvement)

$$\rho_n(x; \sigma, \underline{\theta}) = s_n(x)[u\Phi(u) + \Phi'(u)]$$

avec

- $u = (\hat{\xi}_n(x) - M_n) / s_n(x)$
- $\hat{\xi}_n(x) = \mathbb{E}[\xi(x) \mid \xi_n(x), \sigma, \underline{\theta}]$ (prédicteur par krigeage de $\xi(x)$)
- $s_n(x)$ l'écart-type *a posteriori* de l'erreur $\hat{\xi}_n(x) - \xi(x)$
- Φ fonction de répartition de $\mathcal{N}(0, 1)$

ρ_n se calcule très facilement !

Processus gaussien et EI [Mockus et al. 1978] 3/3

- EI : critère utilisé par l'algorithme EGO [Jones et al. 1998]
- Problème : σ et $\underline{\theta}$ ne sont pas connus !
- Solution possible : estimer σ et $\underline{\theta}$ à chaque nouvelle évaluation

- 1 Optimisation bayésienne par EI
- 2 **Prise en compte de l'incertitude sur les paramètres**
- 3 Exemple
- 4 Conclusions

Estimation avec MLE

- Les paramètres $(\sigma^2, \underline{\theta})$ peuvent être estimés par maximum de vraisemblance


$$\hat{\sigma}_n, \hat{\underline{\theta}}_n = \operatorname{argmax} \frac{1}{(2\pi\sigma^2)^{n/2} |R(\underline{\theta})|^{1/2}} \exp \left[-\frac{\underline{\xi}_n^T R(\underline{\theta})^{-1} \underline{\xi}_n}{2\sigma^2} \right],$$

où $R(\underline{\theta})$ est la matrice de corrélation de $\underline{\xi}_n$

- L'algorithme EGO : $x_{n+1} = \operatorname{argmax}_x \rho_n \left(x; \hat{\sigma}_n, \hat{\underline{\theta}}_n \right)$
- Facile à calculer mais ne fonctionne pas bien pour les *deceptive functions*

Deceptive functions 1/2



- Les points d'évaluation choisis peuvent ne pas être représentatifs des variations de la fonction objectif f



- Ces situations "trompeuses" entraînent une mauvaise estimation de l'erreur de prédiction
- L'estimation des paramètres par MLE y est souvent peu satisfaisante

Deceptive functions 2/2

Prédiction par MLE

Estimation de $\hat{\sigma}^2$ par MLEValeur de $-\log L$ et de $\hat{\sigma}^2$ 

Estimation par approche bayésienne

- Proposition : approche bayésienne pour prendre en compte l'incertitude sur les paramètres de la covariance
- Choix de lois *a priori* sur les paramètres
- La nouvelle expression de l'EI est

$$\tilde{\rho}_n(x) = \mathbb{E} \left[\rho_n(x; \sigma^2, \underline{\theta}) \mid \underline{\xi}_n \right]$$

- Lors du choix d'un nouveau point d'évaluation, l'incertitude associée aux paramètres sera ainsi prise en compte

Choix des lois *a priori* pour les paramètres

- Pour σ^2 : loi inverse gamma
 - Pour $\underline{\theta}$: on fait le choix d'une discrétisation
- ⇒ nombre fini de valeurs $\underline{\theta}_k$ avec des probabilités *a priori* $p(\underline{\theta}_k)$ choisies par l'utilisateur

Correction du critère EI

- 1 Calcul analytique de

$$\rho'_n(x; \underline{\theta}) = \mathbb{E}[(\xi(x) - M_n)_+ | \xi_n, \underline{\theta}]$$

(comme ξ est gaussien, $\xi(x) | \xi_n, \underline{\theta}$ suit une loi de Student)

- 2 Calcul de

$$\begin{aligned} \tilde{\rho}_n(x) &= \mathbb{E}(\rho'_n(x, \underline{\theta}) | \xi_n) \\ &= \int \rho'_n(x, \underline{\theta}) P(d\underline{\theta} | \xi_n) \\ &= \sum_k \rho'_n(x, \underline{\theta}_k) p(\underline{\theta}_k | \xi_n) \end{aligned}$$

avec


$$p(\underline{\theta}_k | \xi_n) \propto p(\xi_n | \underline{\theta}_k) p(\underline{\theta}_k)$$

et $p(\xi_n | \underline{\theta}_k)$ qui suit une loi de Student multivariée

- 1 Optimisation bayésienne par EI
- 2 Prise en compte de l'incertitude sur les paramètres
- 3 Exemple**
- 4 Conclusions

Fonction objectif



La fonction objectif et le design initial choisis (deceptive function)





Conditions de test

- Pour l'approche bayésienne, on suppose que σ^2 suit une loi *a priori* inverse gamma $IG(0.2, 12)$
- On utilise des covariances de Matérn de paramètre $[\sigma^2; \nu; 1/\alpha]$
- La régularité ν est prise égale à 2
- On a $\underline{\theta} = [\alpha]$ (l'inverse de la portée)
- On considère $m = 100$ valeurs possibles pour $\underline{\theta}$ réparties exponentiellement
- Les lois *a priori* sont choisies uniformes


Résultats : itération 1





Résultats : itération 2





Résultats : itération 3





Résultats : itération 4





Résultats : itération 5





Résultats : itération 6



Résultats : itération 7



Résultats : itération 8



- 1 Optimisation bayésienne par EI
- 2 Prise en compte de l'incertitude sur les paramètres
- 3 Exemple
- 4 Conclusions**

- Dans certaines situations (*deceptive functions* mais pas seulement...), estimer les paramètres de la covariance par MLE à chaque itération conduit à des résultats très décevants
- L'approche bayésienne prend en compte l'incertitude sur les paramètres et évite les phénomènes de clustering des points d'évaluations
- Les résultats obtenus montrent que cette nouvelle approche est robuste, même dans des situations très défavorables