

# 'Derivative Free Optimisation: surface response methods


Laurent Dumas

Laboratoire de Mathématiques de Versailles  
Université de Versailles Saint Quentin en Yvelines

Master AMS, V04 course, 2017-18

# Modèles approchés

- De manière générale, l'objectif consiste à construire une fonction approchée  $\tilde{J}$  (*surrogate ou metamodel*) de la fonction exacte  $J$  à partir d'un certain nombre de points  $(X_i, J(X_i))_{1 \leq i \leq N}$  où la fonction exacte est supposée connue.



- Références : *Giannakoglou* (2001), *Jin* (2005), etc...

# Modèles approchés : méthode de krigeage

- La première méthode présentée ici, appelée méthode de krigeage, est une méthode probabiliste basée sur la minimisation de la variance de l'estimation en un point  $X$  donné.
- L'approximation de la fonction coût en un point  $X \in \mathbb{R}^n$  s'écrit :

$$\hat{j}(X) = \sum_{i=1}^N \omega(X_i) j(X_i)$$

où on suppose que  $\hat{j}(X)$  et  $j(X)$  sont des réalisations des variables aléatoires respectives  $\hat{J}(X)$  et  $J(X)$  (*dans cette approche  $J(X)$  n'est plus un réel mais une variable aléatoire*).

- Afin de déterminer  $\hat{j}(X)$ , on suppose que la covariance de  $J$  est connue :

$$\text{cov}(J(X), J(Y)) = c(X, Y)$$

# Modèles approchés : méthode de krigeage

- En cherchant à minimiser  $\text{var}(\hat{J}(X) - J(X))$  tout en imposant  $E(\hat{J}(X) - J(X)) = 0$ , on aboutit à une relation permettant de déterminer  $\hat{j}(X)$  :

$$\hat{j}(X) = K^T C^{-1} z$$

où  $K$  est le vecteur colonne de terme général  $c(X_i, X)$ ,  $C$  est la matrice de terme général  $c(X_i, X_j)$ , et  $z$  le vecteur colonne de terme général  $j(X_i)$ .

- Une estimation de la variance au point  $X$  est également disponible :

$$\text{var}(\hat{J}(X) - J(X)) = c(X, X) - K^T C^{-1} K$$

# Modèles approchés : méthode de krigeage

- La fonction de corrélation est en général choisie comme étant de type exponentielle :

$$c(X, Y) = \theta_1 \exp \left( -\frac{1}{2} \sum_{i=1}^n \frac{(x_i - y_i)^2}{r_i^2} \right) + \theta_2$$

- Les paramètres  $\Theta = (\theta_1, \theta_2, r_1, \dots, r_n)$  sont alors déterminés par le principe du maximum de vraisemblance, c'est à dire en maximisant la fonction :

$$\mathcal{L}(\Theta) = p(j(X_1), \dots, j(X_N)) = \frac{1}{\sqrt{(2\pi)^N \det C}} \exp \left( -\frac{1}{2} z^T C^{-1} z \right)$$

# Modèles approchés : méthode RBF

- Une autre méthode possible, appelée méthode RBF, est construite comme une combinaison linéaire de fonctions radiales centrées en chacun des points  $X_i$ .
- L'approximation de la fonction coût en un point  $X \in \mathbb{R}^n$  s'écrit alors :

$$\tilde{J}(X) = \sum_{i=1}^N w_i h(\|X - X_i\|)$$

où  $h$  désigne une fonction  $r \mapsto h(r)$  dite fonction de base radiale.

# Modèles approchés : méthode RBF

- Les poids  $(w_i)_{1 \leq i \leq N}$  sont calculés par résolution de l'équation matricielle  $Aw = z$  traduisant l'exactitude du réseau sur les points  $(X_i)_{1 \leq i \leq N}$ , où la matrice  $A \in \mathcal{M}_N(\mathbb{R})$  a pour terme général  $a_{i,j} = h(\|X_i - X_j\|)$  et le second membre a pour terme général  $z_i = J(X_i)$ .
- On a donc ici :

$$\tilde{J}(X) = R^T A^{-1} z$$

où  $R$  est le vecteur colonne de terme général  $h(\|X - X_i\|)$ .

- Pour des fonctions  $h$  bien choisies, on peut montrer que la matrice  $A$  est toujours inversible voire définie positive.

# Modèles approchés : méthode RBF

- Une fonction continue  $f$  définie sur  $\mathbb{R}_+^*$  est dite (définie) positive si pour toute famille de points distincts  $X_1, \dots, X_N$  de  $\mathbb{R}^n$ , la forme quadratique

$$q(c_1, \dots, c_N) = \sum_{1 \leq i, j \leq N} c_i c_j f(\|X_i - X_j\|)$$

est (définie) positive.

- **Théorème** (Schoenberg) : Une fonction  $f$  est totalement monotone sur  $\mathbb{R}_+^*$  si et seulement si la fonction  $r \rightarrow f(r^2)$  est positive.
- Ainsi, les fonctions  $r \mapsto e^{-r^2}$  et  $r \mapsto (1 + r^2)^{-\alpha}$  avec  $\alpha > 0$  peuvent être utilisées comme fonctions de base dans les réseaux RBF.

# Modèles approchés : méthode RBF

- **Théorème** (Micchelli) : soit  $h$  une fonction dérivable sur  $\mathbb{R}_+$ , strictement positive sur  $\mathbb{R}_+^*$ . Si la première dérivée de  $h$  est totalement monotone et non constante sur  $\mathbb{R}_+^*$ , alors pour toute famille de points distincts  $X_1, \dots, X_N$  de  $\mathbb{R}^n$  :

$$(-1)^{N-1} \det ([h(\|X_i - X_j\|^2)]) > 0$$

- Ainsi, les fonctions  $r \rightarrow (c^2 + r^2)^\alpha$  avec  $c \in \mathbb{R}$  et  $0 < \alpha < 1$  peuvent être utilisées comme fonction de base radiale dans les réseaux RBF.

# Modèles approchés : méthode RBF

- Afin de déterminer les paramètres optimaux des fonctions de base du modèle RBF, une méthode de type 'leave-one out' peut être utilisée.
- Cette méthode consiste à entraîner le réseau sur tous les points sauf un et à tester l'erreur commise sur ce point. En répétant ce procédé sur tous les points, on aboutit à une erreur globale qu'il s'agit de rendre minimale.
- La méthode RBF rejoint alors la méthode de krigeage si une fonction gaussienne est choisie dans les deux cas. Seule la façon de chercher les paramètres optimaux de cette gaussienne diffèrent.





# Modèles approchés : méthode RBF

- Dans le cas où le nombre de points  $N$  est très grand, la matrice  $A$  peut être mal conditionnée. Afin d'éviter ce problème, deux choix sont possibles.
- Soit un procédé de régularisation de Tychonov est ajouté permettant de réduire le conditionnement de  $A$ . Dans ce cas, la méthode RBF cesse d'être une méthode d'interpolation.
- Soit le nombre de points  $N$  est réduit à  $m$  en ne considérant que les plus proches points du point  $X$  à calculer. Dans ce cas, le réseau construit devient local.

# Modèles approchés : méthode RBF

- Exemple sur la fonction de Rastrigin :

$$Rast(x_1, \dots, x_n) = \sum_{i=1}^n (x_i^2 - \cos(2\pi x_i)) + n$$



- La figure ci-dessus compare les contours de la fonction de Rastrigin et trois modèles approchés, construit à partir d'un réseau RBF avec 40 ou 200 points d'exemples.