

# *Introduction aux Processus Gaussiens*

**Olivier Delalleau**

LISA

19 août 2003

# Contexte

---

- Dataset  $D = \{x_n, t_n\}_{n=1\dots N}$
- $t_n = y(x_n) + \epsilon_n$
- But = prédire la **distribution** de  $t^*$ , étant donné un nouveau point  $x^*$

$$P(t^* | x^*, D)$$

- $\Rightarrow$  perspective **bayésienne**  $\neq$  fréquentiste
- Utilisation typique : régression

$$\hat{y}(x^*) = E[t^* | x^*, D]$$

# Principe

---

- Un GP place une distribution gaussienne *a priori* sur les fonctions :

$$P(y) = \mathcal{N}(f, K) = \frac{1}{Z} \exp \left[ -\frac{1}{2} (y - f)^T K^{-1} (y - f) \right]$$

- Formellement :  $P(y)$  est un GP si pour tous  $x_1, \dots, x_n$ ,  $P(y(x_1), \dots, y(x_n))$  est une gaussienne.
- En pratique :  $f = 0$
- $K(x, x') = Cov[y(x), y(x')]$

# Origine

---

Les GP sont connus depuis longtemps en statistiques, mais ne sont utilisés que depuis peu en machine learning.

[*Bayesian learning for Neural Networks*, Neal, 1996] : un réseau de neurones place une probabilité a priori sur l'espace de fonctions, et lorsque la couche cachée est infinie, il s'agit d'un GP.

# Prédiction

---

- Loi jointe des  $t_n$  :

$$P(y(x_1), \dots, y(x_N)) = \mathcal{N}(0, K_N)$$

et  $P(\epsilon_n) = \mathcal{N}(0, \sigma^2)$

$$\Rightarrow P(t_1, \dots, t_N) = \mathcal{N}(0, K_N + \sigma^2 \cdot I)$$

- Prédiction :

$$\begin{aligned} P(t^* | t_n) &= \frac{P(t^*, t_n)}{P(t_n)} \\ &= \mathcal{N}(\hat{t}^*, \sigma^{*2}) \end{aligned}$$

# La Matrice de Covariance K

---

C'est elle qui définit la solution :

$$(K_N)_{ij} = K(x_i, x_j)$$

⇒ similarité avec les méthodes à noyau comme les SVM. Une fonction de covariance classique est donc bien sûr le noyau gaussien :

$$K(x, x') = \frac{1}{U} \exp \left[ -\frac{1}{2} \frac{\|x - x'\|^2}{\sigma_K^2} \right]$$

# Estimation des Hyperparamètres

---

Hyperparamètres  $\theta = \{\text{bruit } \sigma^2, \text{ variance du noyau } \sigma_K^2\}$

Optimisation "facile" dans un cadre bayésien :

$$P(\theta|t_n) = \frac{P(t_n|\theta)P(\theta)}{P(t_n)}$$

⇒ minimisation de

$$C(\theta) = -\ln(P(t_n|\theta)) - \ln(P(\theta))$$

# Considérations Pratiques

---

- **Entraînement** : il faut calculer  $K_N^{-1} \Rightarrow O(N^3)$
- **Prédiction** en  $O(N)$
- **Bornes de confiance** en  $O(N^2)$
- $\Rightarrow$  **impraticable** pour de grands ensembles de données

# Méthodes d'Accélération

---

Principe = utiliser un sous-ensemble de  $m \ll N$  points : "Sparse"

$\Rightarrow$  entraînement en  $O(m^2 N)$ , prédiction en  $O(m)$ , bornes en  $O(mN)$ .

Exemples :

- Sélection aléatoire
- *Sparse greedy Gaussian Process regression* (Smola, Bartlett, 2001) : critère de sélection des points assez coûteux
- *Fast sparse Gaussian Process Methods: the informative Vector Machine* (Lawrence, Seeger, Herbrich, 2002) : critère basé sur la théorie de l'information, application à la classification  $\Rightarrow$  résultats comparables à une SVM, avec un temps d'entraînement plus rapide
- *Fast forward selection to speed up sparse gaussian process regression* (Seeger, Williams, Lawrence, 2003) : même critère, aussi rapide qu'une sélection aléatoire, mais résultats à peine meilleurs (intérêt = optimisation des hyperparamètres)