

# 高斯过程求解偏微分方程

黄政宇

北京大学北京国际数学研究中心

北京大学国际机器学习研究中心



# 本堂课大纲

- 求解偏微分方程问题
  - 核岭插值
  - 随机特征方法
- 含参数偏微分方程问题
  - 随机特征方法
  - 高斯回归



# 求解偏微分方程问题

## ➤ 偏微分方程问题


$$\begin{aligned}\mathcal{L}(x, u) &= 0 & x \in \Omega \\ \mathcal{B}(x, u) &= 0 & x \in \partial\Omega\end{aligned}$$

## ➤ 核岭插值

$$\begin{aligned}\hat{u} &= \operatorname{argmin}_{u \in \mathcal{H}_\kappa} \|u\|_{\mathcal{H}_\kappa} \\ \mathcal{L}(x_i, u(x_i)) &= 0 & x_i \in X^{int} \\ \mathcal{B}(x_i, u(x_i)) &= 0 & x_i \in X^{bd}\end{aligned}$$

简单的想法：

基底函数  $\kappa(x, x_i)$   $i = 1, 2, \dots, n$







# 插值问题

## 练习

- 无噪音2维训练数据  $\{(x_i, f(x_i)) | i = 1, 2, \dots, n\}$
- $f(x_i) = \sin(x) \cos(y)$   $x \in [0.5, 3.0], y \in [0.5, 3.0]$
- $x_i$  为  $10 \times 10$  均匀格点





# 插值问题

## ➤ 插值问题

- 无噪音训练数据  $\{(x_i, f(x_i), \nabla_x f(x_i), \Delta f(x_i)) | i = 1, 2, \dots, n\}$

## ➤ 核岭插值

$$\hat{f} = \operatorname{argmin}_{f \in \mathcal{H}_k} \|f\|_{\mathcal{H}_k}$$

使得  $f(x_i) = y_i \quad \nabla_x f(x_i) = y'_i \quad \Delta f(x_i) = y''_i$

$$\hat{f}(x) = \sum_{i=1}^n \alpha_i \kappa(x, x_i) + \sum_{i=1}^n \alpha'_i \nabla_x \kappa(x, x_i) + \sum_{i=1}^n \alpha''_i \Delta_x \kappa(x, x_i)$$

基底函数  $\kappa(x, x_i), \nabla_x \kappa(x, x_i), \Delta_{xx} \kappa(x, x_i), i = 1, 2, \dots, n$



# 插值问题

➤ 对于足够光滑的平稳核函数

$$\frac{\partial^k \kappa(x, y)}{\partial x_{i_1} \partial x_{i_2} \cdots \partial x_{i_k}} \in \mathcal{H}_\kappa$$

且

$$\left\langle \frac{\partial^k \kappa(x, y)}{\partial x_{i_1} \partial x_{i_2} \cdots \partial x_{i_k}}, f(y) \right\rangle = (-1)^k \frac{\partial^k f(x)}{\partial x_{i_1} \partial x_{i_2} \cdots \partial x_{i_k}}$$

基本想法：有限差分逼近

本章后续，我们均考虑足够光滑的平稳核函数



# 核岭插值

## ➤ 线性偏微分方程问题

$$\begin{aligned} -\Delta u &= f(x) & x \in \Omega \\ u &= \bar{u} & x \in \partial\Omega \end{aligned}$$

## ➤ 核岭插值

$$\hat{u} = \operatorname{argmin}_{u \in \mathcal{H}_k} \|u\|_{\mathcal{H}_k}$$

$$\begin{array}{ll} \text{偏微分方程约束} & -\Delta u(x_i) = f(x_i) & x_i \in X^{int} \\ \text{边界条件约束} & u(x_i) = \bar{u}(x_i) & x_i \in X^{bd} \end{array}$$



# 核岭插值

## 核岭插值

$$\hat{u} = \operatorname{argmin}_{u \in \mathcal{H}_k} \|u\|_{\mathcal{H}_k}$$

$$\text{使得 } u(x_i) = \bar{u}(x_i) \quad x_i \in X^{bd}, \quad -\Delta u(x_i) = f(x_i) \quad x_i \in X^{int}$$

## 表示定理

$$u(x) = \sum_{x_i \in X^{bd}} \alpha_i \kappa(x, x_i) + \sum_{x_i \in X^{int}} \alpha_i'' \Delta_x \kappa(x, x_i)$$

## 求解

$$k_{xX} = [\kappa(x, X^{bd}) \quad \Delta_y \kappa(x, X^{int})]$$

$$K_{XX} = \begin{bmatrix} \kappa(X^{bd}, X^{bd}) & \Delta_y \kappa(X^{bd}, X^{int}) \\ \Delta_x \kappa(X^{int}, X^{bd}) & \Delta_x \Delta_y \kappa(X^{int}, X^{int}) \end{bmatrix}$$

$$f = [\cdots \bar{u}(x_i) \cdots -f(x_i) \cdots]^T$$

$$u(x) = k_{xX} K_{XX}^{-1} f$$



# 核岭插值

## ➤ 非线性偏微分方程问题

$$\begin{aligned} -\Delta u + \tau(u) &= f(x) & x \in \Omega \\ u &= \bar{u} & x \in \partial\Omega \end{aligned}$$

## ➤ 两层优化

$$\begin{aligned} \hat{u} &= \operatorname{argmin}_{u \in \mathcal{H}_k} \|u\|_{\mathcal{H}_k} \\ \left\{ \begin{array}{l} \text{minimize} \\ z = (z^{bd}, z^{int}, z_{\Delta}^{int}) \end{array} \right. & \left\{ \begin{array}{l} \operatorname{argmin}_{u \in \mathcal{H}_k} \|u\|_{\mathcal{H}_k} \\ u(X^{bd}) = z^{bd}, \\ u(X^{int}) = z^{int}, \\ \Delta u(X^{int}) = z_{\Delta}^{int} \end{array} \right. \\ & \left\{ \begin{array}{l} -z_{\Delta}^{int} + \tau(z^{int}) = f(X^{int}) \\ z^{bd} = \bar{u}(X^{bd}) \end{array} \right. \end{aligned}$$



# 核岭插值

## ➤ 内层优化

$$\hat{u} = \operatorname{argmin}_{u \in \mathcal{H}_k} \|u\|_{\mathcal{H}_k}$$

$$\text{使得 } u(X^{bd}) = z^{bd}, u(X^{int}) = z^{int}, \Delta u(X^{int}) = z_{\Delta}^{int}$$

## ➤ 表示定理

$$u(x) = \sum_{x_i \in X^{bd}, X^{int}} \alpha_i \kappa(x, x_i) + \sum_{x_i \in X^{int}} \alpha_i'' \Delta_x \kappa(x, x_i)$$

## ➤ 求解

$$k_{xX} = [\kappa(x, X^{bd}) \quad \kappa(x, X^{int}) \quad \Delta_y \kappa(x, X^{int})]$$

$$K_{XX} = \begin{bmatrix} \kappa(X^{bd}, X^{bd}) & \kappa(X^{bd}, X^{int}) & \Delta_y \kappa(X^{bd}, X^{int}) \\ \kappa(X^{int}, X^{bd}) & \kappa(X^{int}, X^{int}) & \Delta_y \kappa(X^{int}, X^{int}) \\ \Delta_x \kappa(X^{int}, X^{bd}) & \Delta_y \kappa(X^{int}, X^{int}) & \Delta_x \Delta_y \kappa(X^{int}, X^{int}) \end{bmatrix}$$

$$u(x) = k_{xX} K_{XX}^{-1} z \quad \|u\|_{\mathcal{H}_k} = z^T K_{XX}^{-1} z$$



# 核岭插值

## ➤ 外层优化

$$\begin{aligned} & \underset{z=(z^{bd}, z^{int}, z_{\Delta}^{int})}{\text{minimize}} \quad z^T K_{XX}^{-1} z \\ & -z_{\Delta}^{int} + \tau(z^{int}) = f(X^{int}), \quad z^{bd} = \bar{u}(X^{bd}) \end{aligned}$$

## ➤ 两层优化

$$\begin{aligned} & \underset{z=(z^{bd}, z^{int}, z_{\Delta}^{int})}{\text{minimize}} \quad z^T K_{XX}^{-1} z \\ & \quad \quad \quad F(z) = y \end{aligned}$$

Newton法 :  $z^k \rightarrow z^{k+1}$

$$\begin{aligned} & \underset{z=(z^{bd}, z^{int}, z_{\Delta}^{int})}{\text{minimize}} \quad z^T K_{XX}^{-1} z \\ & \quad \quad \quad F(z^k) + F'(z^k)(z - z^k) = y \end{aligned}$$



# 随机特征方法

## Bochner定理

一个定义在 $R^N$ 中的有平移不变性的实值核函数，那么当 $\kappa$ 能表示为

$$\kappa(\tau) = \int_{R^N} e^{2\pi i \omega \cdot \tau} p(\omega) d\omega$$

其中 $\mu(\omega)$ 是有限正测度，我们考虑特殊情况 $d\mu(\omega) = p(\omega) d\omega$ 。

定义 $\psi(x, \omega) = e^{2\pi i \omega \cdot x}$ ，那么

$$\begin{aligned} \kappa(x - x') &= \int_{R^N} e^{2\pi i \omega \cdot (x - x')} p(\omega) d\omega \\ &= \mathbb{E}_{\omega \sim p(\omega)} [\psi(x, \omega) \psi^*(x', \omega)] \end{aligned}$$



# 随机特征方法

## ➤ 偏微分方程问题

$$\begin{aligned}\mathcal{L}(x, u) &= 0 & x \in \Omega \\ \mathcal{B}(x, u) &= 0 & x \in \partial\Omega\end{aligned}$$

## ➤ 随机特征方法

$$\hat{u}(x) = \sum_{i=1}^D c_i \psi(x, \omega_i)$$

$$\min \sum_{x_i \in X^{int}} \lambda_{Li} \|\mathcal{L}(x_i, u(x_i))\|^2 + \sum_{x_i \in X^{bd}} \lambda_{Bi} \|\mathcal{B}(x_i, u(x_i))\|^2 + \lambda \|c\|_2^2$$

二次优化问题



# 求解偏微分方程问题

## ➤ 传统方法(有限体积、有限元方法)

- 需要有网格
- 局部基底函数
- 能保持守恒律

## ➤ 基于高斯回归的方法 (核岭回归、随机特征方法)

- 不需要有网格、只需要采样点
- 全局基底函数
- 对足够光滑的问题，能达到指数收敛 (谱方法)
- 超参选取、可能有数值不稳定



# 本堂课大纲

- 求解偏微分方程问题
  - 核岭插值
  - 随机特征方法
  
- 含参数偏微分方程问题
  - 随机特征方法
  - 高斯回归



# 含参数偏微分方程问题

## ➤ 偏微分方程问题

$$\begin{aligned} \mathcal{L}(x, u, a) &= 0 & x \in \Omega \\ \mathcal{B}(x, u) &= 0 & x \in \partial\Omega \end{aligned}$$

$$\mathcal{G}^\dagger: a \rightarrow u$$

## ➤ 代理模型 (surrogate model)

两个函数空间  $\mathcal{A} = \{a: \Omega \mapsto \mathbb{R}\}$   $\mathcal{U} = \{u: \Omega \mapsto \mathbb{R}\}$ ，求解偏

微分方程给出映射  $\mathcal{G}^\dagger: \mathcal{A} \mapsto \mathcal{U}$

降阶模型  $\mathcal{G}_\theta \approx \mathcal{G}^\dagger$  是一个这样的映射的近似



# 算子学习 (OPERATOR LEARNING)

## ➤ 偏微分方程问题

$$\begin{aligned} \mathcal{L}(x, u, a) &= 0 & x \in \Omega \\ \mathcal{B}(x, u) &= 0 & x \in \partial\Omega \end{aligned}$$

$$\mathcal{G}^\dagger: a \rightarrow u$$

## ➤ 代理模型 (surrogate model)

两个函数空间  $\mathcal{A} = \{a: \Omega \mapsto \mathbb{R}\}$   $\mathcal{U} = \{u: \Omega \mapsto \mathbb{R}\}$ ，求解偏

微分方程给出映射  $\mathcal{G}^\dagger: \mathcal{A} \mapsto \mathcal{U}$

给定数据  $\{a_i, u_i = \mathcal{G}^\dagger(a_i)\}$

寻找近似  $\mathcal{G}_\theta \approx \mathcal{G}^\dagger$ ，比如降阶模型。



# 再生核希尔伯特空间

## ➤ 核函数

函数  $f: R^N \rightarrow R$

核函数  $\kappa: R^N \times R^N \rightarrow R$

再生核希尔伯特空间  $\mathcal{H}_\kappa$ :

$$\mathcal{H}_\kappa = \overline{\text{span}\{\kappa(\cdot, x_i)c_i\}}$$

表示定理:

$$f = \sum_{i=1} \kappa(\cdot, x_i)c_i \quad (c_i \in R)$$

$\kappa(\cdot, x): \mathcal{H}_\kappa \rightarrow R$  定义了有界线性映射

$$f \rightarrow \langle \kappa(\cdot, x), f \rangle_{\mathcal{H}_\kappa} = f(x)$$



# 再生核希尔伯特空间

## ➤ 算子值(Operator valued)核函数

算子  $G^\dagger : \mathcal{A} \rightarrow \mathcal{U}$ ,  $\mathcal{A}$ 和 $\mathcal{U}$ 是两个实希尔伯特空间

核函数  $\kappa : \mathcal{A} \times \mathcal{A} \mapsto \mathcal{L}(\mathcal{U}, \mathcal{U})$  其中  $\mathcal{L}(\mathcal{U}, \mathcal{U})$  表示在空间  $\mathcal{U}$  上的所有有界线性算子构成的 Banach 空间

正定性 :

$$\sum_{i,j=1}^n \langle u_i, \kappa(a_i, a_j) u_j \rangle_{\mathcal{U}} \geq 0$$

再生性 :

$$\langle u, f(a) \rangle_{\mathcal{U}} = \langle \kappa(\cdot, a) u, f(\cdot) \rangle_{\mathcal{H}_\kappa} \quad \forall a \in \mathcal{A}, u \in \mathcal{U}, f : \mathcal{A} \rightarrow \mathcal{U}$$

表示定理 :  $f = \sum_{i=1} \kappa(\cdot, a_i) u_i$

再生核希尔伯特空间 :

$$\mathcal{H}_\kappa = \overline{\text{span}\{\kappa(\cdot, a_i) u_i\}}$$



# 再生核希尔伯特空间

## ➤ 代理模型: 算子学习

给定数据  $\{a_i, u_i = g^\dagger(a_i)\}$ ，以及再生核希尔伯特空间  $\mathcal{H}_\kappa$ ，求解核岭回归（插值）

$$\hat{g} = \operatorname{argmin}_{g \in \mathcal{H}_\kappa} \|g\|_{\mathcal{H}_\kappa} \text{ 使得 } g(a_i) = u_i$$

## ➤ 表示定理：

$$\hat{g}(\cdot) = \sum_{i=1} \kappa(\cdot, a_i) y_i : \mathcal{A} \rightarrow \mathcal{U}$$

$\kappa(\cdot, a_i)$ : 难以构造



# 随机特征方法

## ➤ 算子值(Operator valued)核函数

假设

$$\kappa(a, a') = \int \varphi(a, \omega) \otimes \varphi(a', \omega) \rho(\omega) d\omega$$

其中

$$\begin{aligned} \varphi(a, \omega) &: \mathcal{A} \times \Theta \rightarrow \mathcal{U} \\ (u_1 \otimes u_2)u_3 &= \langle u_2, u_3 \rangle_{\mathcal{U}} u_1 \end{aligned}$$

我们有

$$\kappa(a, a')u = \int \langle \varphi(a', \omega), u \rangle_{\mathcal{U}} \varphi(a, \omega) \rho(\omega) d\omega \in \mathcal{U}$$



# 随机特征方法

## ➤ 算子值(Operator valued)核函数

再生性：

$$\begin{aligned}\langle \mathcal{G}(a), u \rangle_u &= \langle \mathcal{G}(\cdot), \kappa(\cdot, a)u \rangle_{\mathcal{H}_\kappa} \\ &= \left\langle \mathcal{G}(\cdot), \int \varphi(\cdot, \omega) \otimes \varphi(a, \omega) \rho(\omega) d\omega u \right\rangle_{\mathcal{H}_\kappa} \\ &= \int \langle \varphi(a, \omega), u \rangle_u \langle \varphi(\cdot, \omega), \mathcal{G}(\cdot) \rangle_{\mathcal{H}_\kappa} \rho(\omega) d\omega \\ &= \left\langle \int c_f(\omega) \varphi(a, \omega) \rho(\omega) d\omega, u \right\rangle_u\end{aligned}$$

其中  $c(\omega) = \langle \varphi(\cdot, \omega), \mathcal{G}(\cdot) \rangle_{\mathcal{H}_\kappa}$ ，我们有

$$\mathcal{G}(a) = \int c(\omega) \varphi(a, \omega) \rho(\omega) d\omega \approx \frac{1}{D} \sum_{i=1}^D c_i \varphi(a, \omega_i)$$



# 随机特征方法

## ➤ 核岭回归

$$\hat{G} = \operatorname{argmin}_{G \in \mathcal{H}_\kappa} \frac{1}{n} \sum_{i=1}^n (G(a_i) - u_i)^2 + \lambda \|G\|_{\mathcal{H}_\kappa}^2$$

## ➤ 随机特征方法

$$G(a) = \frac{1}{D} \sum_{i=1}^D c_i \varphi(a, \omega_i)$$


$$c = \operatorname{argmin}_{c \in \mathbb{R}^D} \sum_{i=1}^n \frac{1}{n} \left\| \frac{1}{D} \sum_{l=1}^D c_l \varphi(a_i, \omega_l) - u_i \right\|_u^2 + \frac{\lambda}{D} \|c\|_2^2$$




# 例子

## ➤ Darcy 流方程

$$\begin{aligned} -\nabla \cdot (a(x)\nabla u) &= f(x), & x \in D \\ u(x) &= 0 & x \in \partial D \end{aligned}$$
$$\mathcal{G}^\dagger : a \mapsto u$$



$a$



$u$

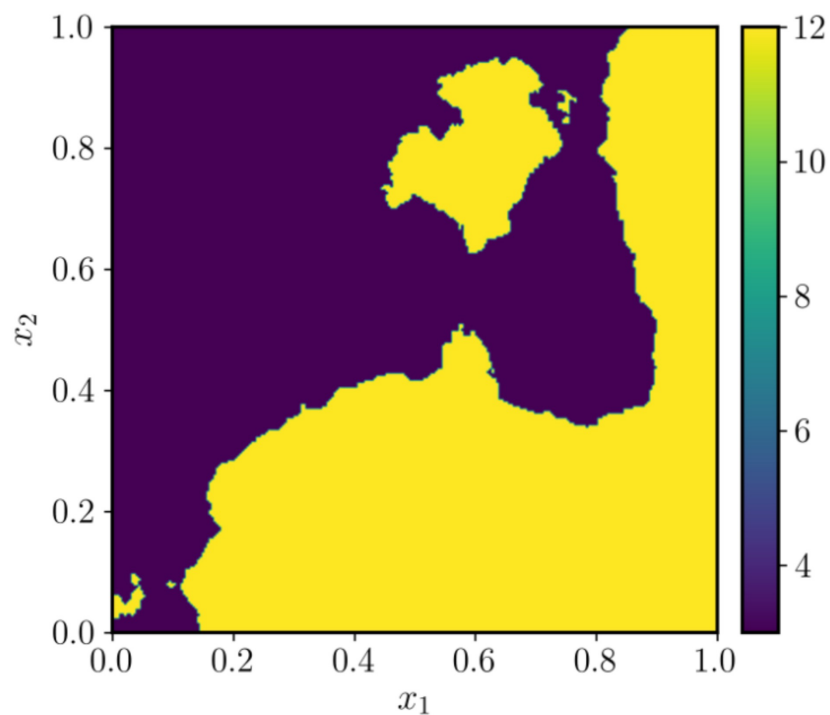


# 随机特征方法


## Fourier随机特征

$$\varphi(a, \omega): \mathcal{A} \times \Theta \rightarrow \mathcal{U}$$

$$\varphi(a, \omega) = \sigma(\mathcal{F}^{-1} \text{filter}(\mathcal{F}a \mathcal{F}\omega))$$



$a$




$\varphi(a, \omega)$




# 例子


## ➤ Darcy 流方程




(a) Truth



(b) Approximation



(c) Input




(d) Pointwise Error



# 高斯回归

## 算子学习



训练数据:

$$\begin{aligned} \phi(a) &= \{a(x_1), a(x_2), \dots, a(x_n)\} \in \mathbb{R}^n \\ \varphi(u) &= \{u(y_1), u(y_2), \dots, u(y_m)\} \in \mathbb{R}^m \end{aligned}$$


目标:

$$G^\dagger = \chi \circ f^\dagger \circ \phi: \mathcal{A} \mapsto \mathcal{U}$$



# 高斯过程

## 算子学习



$$\hat{f} := \operatorname{argmin} \|f\|_{\mathcal{H}_k} \quad \text{满足} \quad f(\phi(a_i)) = \varphi(u_i)$$

$$\hat{u} := \operatorname{argmin} \|u\|_{\mathcal{H}_k} \quad \text{满足} \quad \varphi(u) = \hat{f}(\phi(a)) \in R^m$$



# 含参数偏微分方程问题

- 传统方法(有限体积、有限元方法)
  - 准确但耗时
  
- 基于高斯回归的方法 (随机特征方法、高斯过程)
  - 模型训练、预测均很高效但不精确
  - 需要大量数据训练
  - 超参选取
  - 预测仅限于内插 (分布内数据)



# 参考文献

## ➤ 高斯过程求解偏微分方程

高斯回归 : Zhang, Xiong, Kang Zhu Song, Ming Wan Lu, and X. Liu. "Meshless methods based on collocation with radial basis functions." *Computational mechanics* 26 (2000): 333-343.

高斯回归 : Chen, Yifan, Bamdad Hosseini, Houman Owhadi, and Andrew M. Stuart. "Solving and learning nonlinear PDEs with Gaussian processes." *Journal of Computational Physics* 447 (2021): 110668.

随机特征方法 : Chen, Jingrun, Xurong Chi, and Zhouwang Yang. "Bridging traditional and machine learning-based algorithms for solving PDEs: the random feature method." *J Mach Learn* 1 (2022): 268-98.

随机特征方法 (算子学习) : Nelsen, Nicholas H., and Andrew M. Stuart. "The random feature model for input-output maps between banach spaces." *SIAM Journal on Scientific Computing* 43, no. 5 (2021): A3212-A3243.

高斯回归 (算子学习) : Batlle, Pau, Matthieu Darcy, Bamdad Hosseini, and Houman Owhadi. "Kernel methods are competitive for operator learning." *Journal of Computational Physics* 496 (2024): 112549.