

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



再生核希尔伯特空间

- 再生核希尔伯特空间(核函数观点)
- 再生核希尔伯特空间(正则化观点)
 - 核岭回归(Kernel ridge regression)
 - 核岭插值(Kernel interpolation)
- 数值计算
 - Nyström近似
 - 随机特征方法



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

$$\mathcal{L}(x, u) = 0 \quad x \in \Omega$$

$$\mathcal{B}(x, u) = 0 \quad x \in \partial\Omega$$

➤ 核岭插值

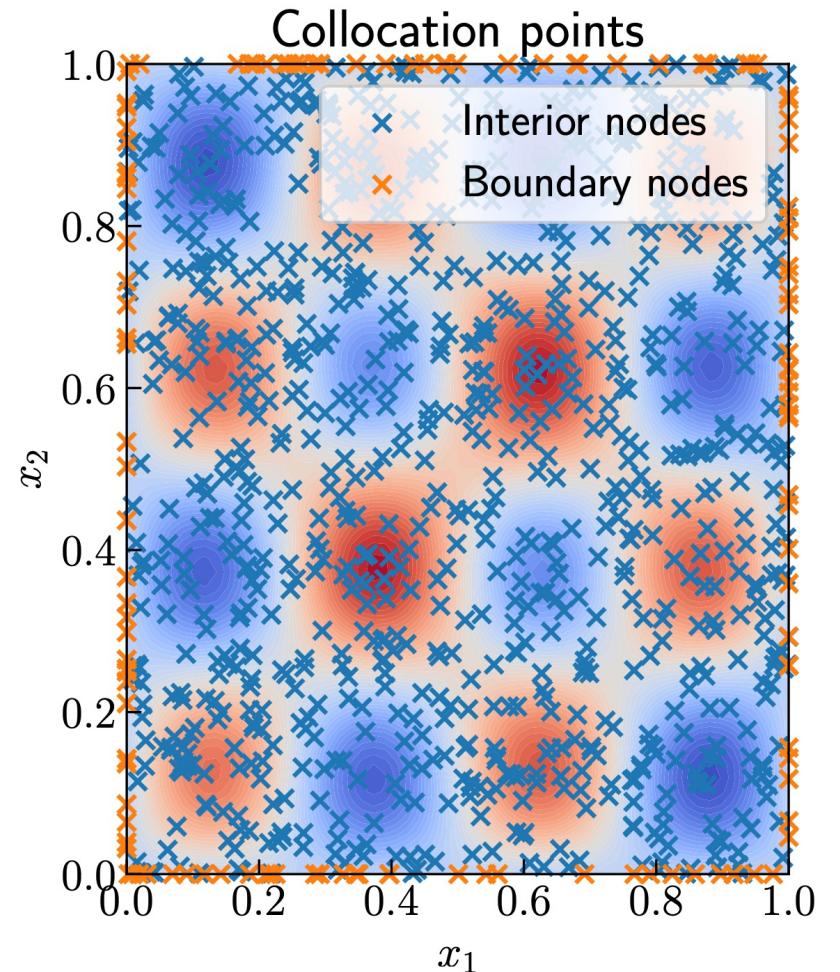
$$\hat{u} = \operatorname{argmin}_{u \in \mathcal{H}_\kappa} \|u\|_{\mathcal{H}_\kappa}$$

$$\mathcal{L}(x_i, u(x_i)) = 0 \quad x_i \in X^{int}$$

$$\mathcal{B}(x_i, u(x_i)) = 0 \quad x_i \in X^{bd}$$

简单的想法：

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

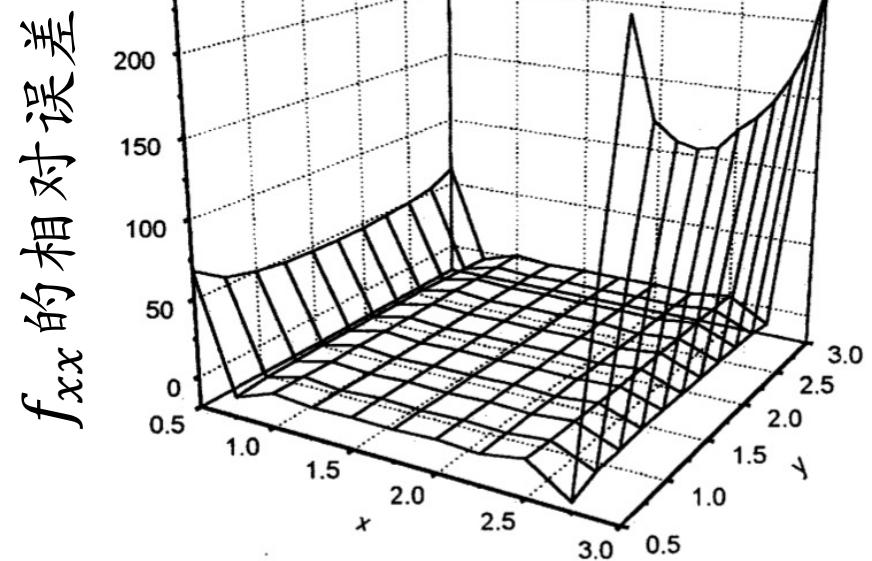
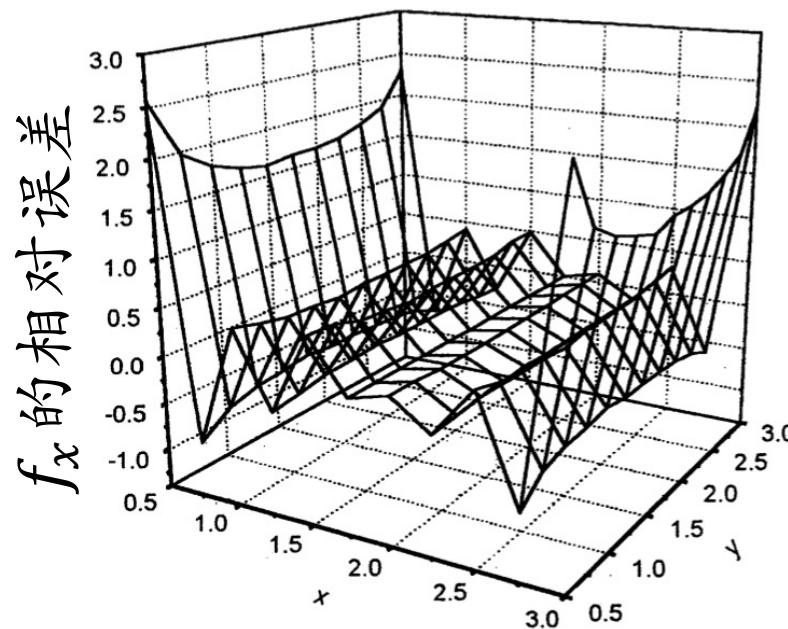




插值问题

➤ 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 10×10 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

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

且

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

基本想法：有限差分逼近



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

$$\begin{aligned}\hat{u} &= \operatorname{argmin}_{u \in \mathcal{H}_k} \|u\|_{\mathcal{H}_k} \\ \text{偏微分方程约束} \quad -\Delta u(x_i) &= f(x_i) \quad x_i \in X^{int} \\ \text{边界条件约束} \quad u(x_i) &= \bar{u}(x_i) \quad x_i \in X^{bd}\end{aligned}$$



核岭插值

➤ 核岭插值

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

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

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

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

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

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



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

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



核岭插值

➤ 内层优化

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

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

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

➤ 两层优化

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

Newton法 : $z^k \rightarrow z^{k+1}$

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



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 κ 能表示为

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

其中 $p(\omega)$ 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

$$\mathcal{L}(x, u) = 0 \quad x \in \Omega$$

$$\mathcal{B}(x, u) = 0 \quad x \in \partial\Omega$$

➤ 随机特征方法

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

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

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

$$\mathcal{L}(x, u, \alpha) = 0 \quad x \in \Omega$$

$$\mathcal{B}(x, u) = 0 \quad x \in \partial\Omega$$

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

➤ 代理模型(surrogate model)

两个实Banach空间 $\mathcal{A} = \{\alpha: \Omega \mapsto \mathbb{R}\}$ $\mathcal{U} = \{u: \Omega \mapsto \mathbb{R}\}$ ，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

$$\mathcal{L}(x, u, a) = 0 \quad x \in \Omega$$

$$\mathcal{B}(x, u) = 0 \quad x \in \partial\Omega$$

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

➤ 代理模型(surrogate model)

两个实Banach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}_κ :

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

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 :

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

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

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 $\{a_i, u_i = \mathcal{G}^\dagger(a_i)\}$ ，以及再生核希尔伯特空间 \mathcal{H}_κ ，求解核岭回归（插值）

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

➤ 表示定理：

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

$\kappa(\cdot, a_i)$: 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

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

➤ 随机特征方法

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

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

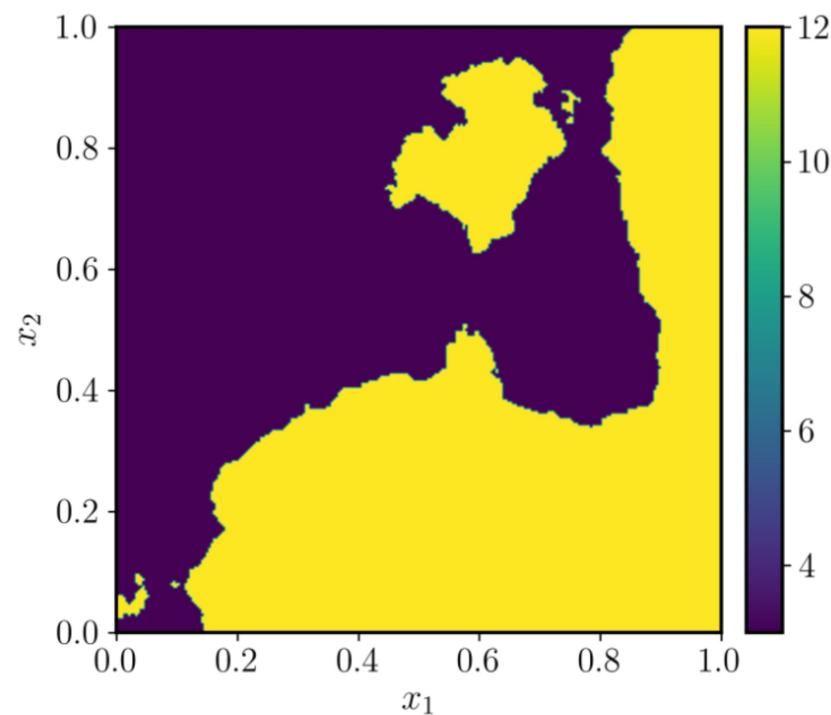


随机特征方法

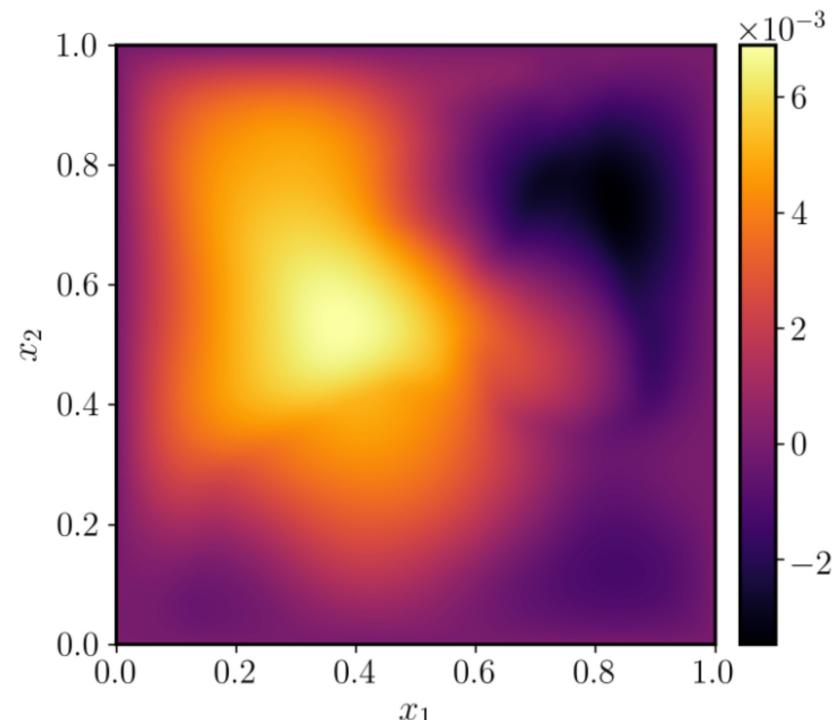
► Fourier随机特征

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

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



a

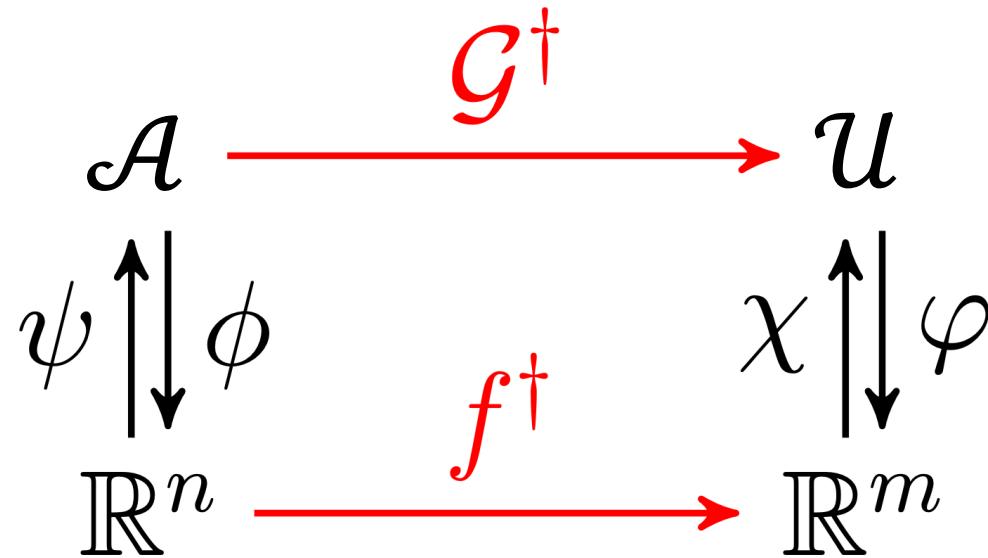


$\varphi(a, \omega)$



高斯回归

➤ 算子学习



训练数据:

$$\phi(a) = \{a(x_1), a(x_2), \dots, a(x_n)\} \in R^n$$

$$\varphi(u) = \{u(y_1), u(y_2), \dots, u(y_m)\} \in R^m$$

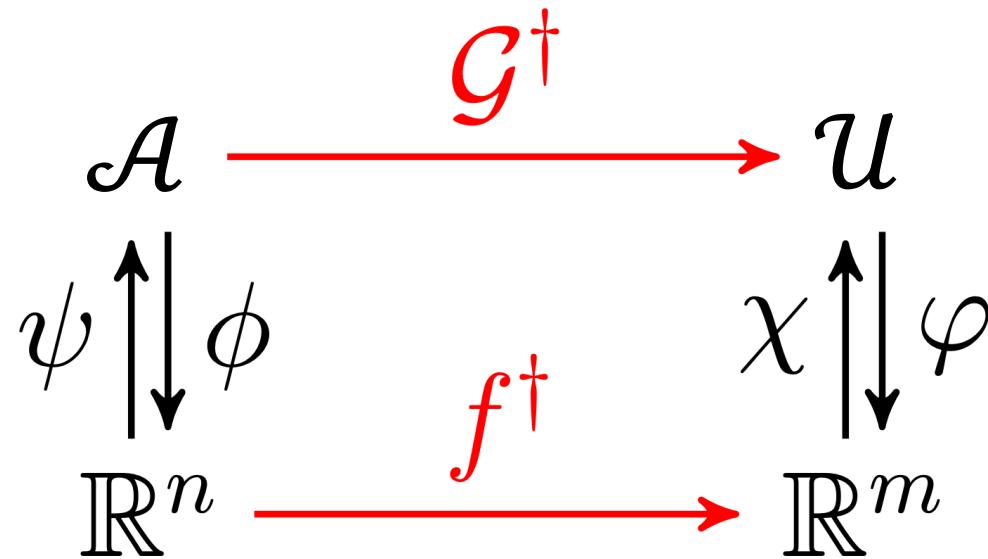
目标:

$$g^\dagger = \chi \circ f^\dagger \circ \phi: \mathcal{A} \rightarrow \mathcal{U}$$



高斯过程

➤ 算子学习



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

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



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.