

再生核希尔伯特空间

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

- 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

高斯过程能近似什么样的函数，需要多少数据，
近似出来的是什麼函数？



再生核希尔伯特空间

再生核希尔伯特空间(Reproducing Kernel Hilbert Spaces)

f 是定义在 R^N 的实值函数， $\mathcal{H}$ 是由这些函数构成的希尔伯特空间(完备(completeness)， $\|f\|_{\mathcal{H}} = \sqrt{\langle f, f \rangle_{\mathcal{H}}}$)， $\mathcal{H}$ 是一个再生核希尔伯特空间，如果存在一个(对称正定核)函数 $\kappa: R^N \times R^N \rightarrow R$ ，满足

- 对任意 $x \in R^N$ ， $\kappa(\cdot, x)$ 属于 $\mathcal{H}$
- κ 有可再生性，即 $\langle f(\cdot), \kappa(\cdot, x) \rangle_{\mathcal{H}} = f(x)$

$f(x)$ 能逐点定义，有“连续性”

$\lim_n \|f_n - f\|_{\mathcal{H}} \rightarrow 0$ ，那么 $\lim_n f_n(x) - f(x) = 0 \quad \forall x$



再生核希尔伯特空间

➤ 练习

希尔伯特空间 $L_2(\Omega)$:

$$\langle f, g \rangle_{\mathcal{H}} = \int f(x)g(x)dx$$

不是再生核希尔伯特空间。



再生核希尔伯特空间

➤ 例子

假设存在一个半正定的核函数，以及对应于测度 μ 的特征值分解

$$\kappa(x, x') = \sum_{i=1}^N \lambda_i \phi_i(x) \phi_i(x')$$

$$\int \phi_i(x) \phi_j(x) d\mu(x) = \delta_{ij}$$

定义由所有 $f(x) = \sum_{i=1}^N f_i \phi_i(x)$ 构成的希尔伯特空间

(其中 N 固定)，内积为 $\langle f, g \rangle_{\mathcal{H}} = \sum_{i=1}^N \frac{f_i g_i}{\lambda_i}$ ，这是一个再生核希尔伯特空间。



再生核希尔伯特空间

Moore-Aronszajn 定理

每一个正定的核函数 $\kappa: R^N \times R^N \rightarrow R$ 都对应唯一的一个再生希尔伯特空间 $\mathcal{H}$ 。

RKHS 范数 $\|\cdot\|_{\mathcal{H}}$ 实际上是仅与核相关的属性，并且在测度的变化下是不变的。



再生核希尔伯特空间

➤ 证明

给定一个半正定的核函数，定义函数空间 $\mathcal{H}_0$

$$\mathcal{H}_0 := \text{span}\{\kappa(\cdot, x): x \in R^N\}$$

$$= \left\{ f = \sum_{i=1}^n c_i \kappa(\cdot, x_i) : n \in N, c_i \in R, x_i \in R^N \right\}$$

对于 $f = \sum_{i=1}^n a_i \kappa(\cdot, x_i) \in \mathcal{H}_0$, $g = \sum_{i=1}^m b_i \kappa(\cdot, y_i) \in \mathcal{H}_0$, 我们定义内积为

$$\langle f, g \rangle_{\mathcal{H}_0} = \sum_{i=1}^n \sum_{j=1}^m a_i b_j \kappa(x_i, y_j)$$

再生核希尔伯特空间 $\mathcal{H}$ 定义为它的闭包。



再生核希尔伯特空间

Wendland [2005, Corollary 10.48]

$\kappa_{\nu,l}$ 是定义在带有 Lipschitz 边界的空间 $\mathcal{X} \subset \mathbb{R}^d$ 上的 Matern 核, $s = \nu + d/2$, 那么再生核希尔伯特空间 $\mathcal{H}_{\kappa_{\nu,l}}$ 和阶数为 s 的 Sobolev 空间

$$W_2^s(\mathcal{X}) := \{f \in L_2(\mathcal{X}) : \|f\|_{W_2^s}^2 := \sum_{\beta \in N_0^d : |\beta| \leq s} \|D^\beta f\|_{L_2}^2 < \infty\}$$

在范数意义上是等价的。即 $\mathcal{H}_{\kappa_{\nu,l}} = W_2^s(\mathcal{X})$, 且存在常数 $c_1, c_2 > 0$

$$c_1 \|f\|_{W_2^s}^2 \leq \|f\|_{\mathcal{H}_{\kappa_{\nu,l}}}^2 \leq c_2 \|f\|_{W_2^s}^2$$

$\|f\|_{\mathcal{H}}^2$ 不仅蕴含了大小信息, 也蕴含了光滑信息



再生核希尔伯特空间

Wendland [2005, Theorem 10.12]

κ 是定义在 R^N 上的有平移不变性的核 $\kappa(x, y) := \kappa(x - y)$,
 $\kappa \in C(R^d) \cap L_1(R^d)$, 那么再生核希尔伯特空间 $\mathcal{H}_\kappa$ 满足
 $\mathcal{H}_\kappa = \{f \in L_2(R^d) \cap C(R^d):$

$$\|f\|_{\mathcal{H}_\kappa}^2 := \frac{1}{(2\pi)^{d/2}} \int \frac{|\mathcal{F}[f](\omega)|^2}{2\mathcal{F}[\kappa](\omega)} d\omega < \infty\}$$

内积定义为

$$\langle f, g \rangle_{\mathcal{H}_\kappa} := \frac{1}{(2\pi)^{\frac{d}{2}}} \int \frac{\mathcal{F}[f](\omega) \overline{\mathcal{F}[g](\omega)}}{2\mathcal{F}[\kappa](\omega)} d\omega, \quad f, g \in \mathcal{H}_\kappa$$

傅里叶函数 $\mathcal{F}[\kappa]$ 基本决定了这个再生核希尔伯特空间



再生核希尔伯特空间

➤ 正则项

Sobolev 核：考虑 $f: [0,1] \rightarrow R$, $f(0) = f(1) = 0$

$$\|f\|_{\mathcal{H}}^2 = \int_0^1 (f(x))^2 + (f'(x))^2 dx$$

Gaussian 核：

$$\|f\|_{\mathcal{H}}^2 = \int_{-\infty}^{+\infty} |f(\omega)|^2 \exp\left(-\frac{\omega^2 \sigma^2}{2}\right) d\omega$$

$\|f\|_{\mathcal{H}}^2$ 越小，需要函数尽量光滑



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



核岭回归

➤ 核岭回归(Kernel ridge regression)

有噪音训练数据 $\{(x_i, y_i) | i = 1, 2, \dots, n\}$

有限维数据、无限维函数 $\Rightarrow$ 不适定

$$\hat{f} = \operatorname{argmin}_{f \in \mathcal{H}_k} \frac{1}{n} \sum_{i=1}^n L(x_i, y_i, f(x_i)) + \lambda \|f\|_{\mathcal{H}_k}^2$$

当 $L(x, y, y') = (y - y')^2$

$$\hat{f} = \operatorname{argmin}_{f \in \mathcal{H}_k} \frac{1}{n} \sum_{i=1}^n (f(x_i) - y_i)^2 + \lambda \|f\|_{\mathcal{H}_k}^2$$



核岭回归

表示定理(REPRESENTER THEOREM)

$$\hat{f} = \operatorname{argmin}_{f \in \mathcal{H}_k} \frac{1}{n} \sum_{i=1}^n (f(x_i) - y_i)^2 + \lambda \|f\|_{\mathcal{H}_k}^2$$

那么 $\hat{f}(x)$ 能表示为 $\hat{f}(x) = \sum_{i=1}^n \alpha_i \kappa(x, x_i)$ 。

定义 $k_{xX} = [\kappa(x, x_1) \ \kappa(x, x_2) \cdots \kappa(x, x_n)]$, $K_{XX} = [\kappa(x_i, x_j)]_{i,j=1}^n$, $y = [y_1 \ y_2 \cdots y_n]^T$ 。当 $\lambda > 0$ ，一个解为

$$\hat{f}(x) = k_{xX} (K_{XX} + n\lambda I_n)^{-1} y = \sum_{i=1}^n \alpha_i \kappa(x, x_i)$$

其中

$$(\alpha_1, \cdots, \alpha_n)^T := (K_{XX} + n\lambda I_n)^{-1} y \in R^n$$

当 K_{XX} 可逆，该解唯一确定。



高斯回归回顾

➤ 有噪音观测

- 条件概率

$$\begin{bmatrix} y \\ f_* \end{bmatrix} = \mathcal{N} \left(0, \begin{bmatrix} K(X, X) + \sigma^2 I & K(X, X_*) \\ K(X_*, X) & K(X_*, X_*) \end{bmatrix} \right)$$

$$f_* | X_*, X, y \sim \mathcal{N}(K(X_*, X)(K(X, X) + \sigma^2 I)^{-1}y, \\ K(X_*, X_*) - K(X_*, X)(K(X, X) + \sigma^2 I)^{-1}K(X, X_*))$$

- 方差和观测无关
- 预处理计算：Cholesky分解 $(K(X, X) + \sigma^2 I)^{-1}$
- 在线复杂度： $\mathcal{O}(n^2 n_*)$



核岭回归VS高斯回归

等价性

κ 是定义在 R^d 上的正定核，训练数据为 $(x_i, y_i)_{i=1}^n \subset R^d \times R$ ，考虑

- 高斯回归 $f \sim GP(0, \kappa)$ ，假设数据误差服从 $\mathcal{N}(0, \sigma^2)$
- 正则化系数为 λ 的核岭回归，

那么当 $\sigma^2 = n\lambda$ 时，高斯回归的期望函数和核岭回归的函数一致 $\bar{m} = \hat{f}$ 。



核岭回归VS高斯回归

误差估计

先验分布 $f \sim GP(0, \kappa)$ 后验分布 $f \sim GP(\bar{m}, \bar{\kappa})$ ，高斯回归或核岭回归的结果：

$$\begin{aligned}\hat{f}(x) &= \sum_{i=1}^n \alpha_i \kappa(x, x_i) = k_{xX} (K_{XX} + \sigma^2 I_n)^{-1} y \\ &:= w^\sigma(x)^T y\end{aligned}$$

定义核函数

$$\kappa^\sigma(x, y) = \kappa(x, y) + \sigma^2 \delta(x, y)$$

以及相应的再生核希尔伯特空间 $\mathcal{H}_{\kappa^\sigma}$ ，我们有误差估计

$$\sqrt{\bar{\kappa}(x, x) + \sigma^2} = \sup_{f \in \mathcal{H}_{\kappa^\sigma}, \|f\|_{\mathcal{H}_{\kappa^\sigma}} \leq 1} \left(f(x) - \sum_{i=1}^n w_i^\sigma(x) f(x_i) \right)$$



核岭插值

➤ 核岭插值(Kernel interpolation)

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

有限维数据、无限维函数 $\Rightarrow$ 不适定

$$\hat{f} = \operatorname{argmin}_{f \in \mathcal{H}_k} \|f\|_{\mathcal{H}_k} \quad \text{使得} \quad f(x_i) = y_i$$

由表示定理，当 K_{XX} 可逆

$$\hat{f}(x) = k_{xX} K_{XX}^{-1} y = \sum_{i=1}^n \alpha_i \kappa(x, x_i)$$

唯一确定，其中

$$(\alpha_1, \dots, \alpha_n)^T := K_{XX}^{-1} y \in R^n$$



核岭插值VS高斯回归

等价性

κ 是定义在 R^d 上的正定核，训练数据为 $(x_i, y_i)_{i=1}^n \subset R^d \times R$ ，记为 $X := (x_1, \dots, x_n)$ ，假设 K_{XX} 可逆，考虑

- 高斯回归 $f \sim GP(0, \kappa)$ ，假设数据没有误差
- 核岭插值

高斯回归的期望函数和核岭插值的函数一致 $\bar{m} = \hat{f}$



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



数值计算

核岭回归和高斯回归

给定正定核函数 κ

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

$$\hat{f}(x) = k_{xX} (K_{XX} + n\lambda I_n)^{-1} Y = \sum_{i=1}^n \alpha_i \kappa(x, x_i)$$

对于数据量大 $n \gg 0$, 计算量是 $\mathcal{O}(n^3)$



数值计算

➤ 低秩近似

$$K_{XX} = QQ^T \quad Q \in R^{n \times m}$$

那么 (Woodbury 矩阵恒等式)

$$\begin{aligned} (K_{XX} + n\lambda I_n)^{-1} &= (QQ^T + n\lambda I_n)^{-1} \\ &= \frac{I}{n\lambda} - \frac{1}{n\lambda} Q(n\lambda + Q^T Q)^{-1} Q^T \end{aligned}$$

对于数据量大 $n \gg 0$ ，计算量是 $\mathcal{O}(nm^2)$



数值计算

➤ Nyström近似

从原始矩阵中抽取一部分行和列形成一个小的子矩阵，并利用这个子矩阵来构建原矩阵的低秩近似，对于

$$K_{XX} = \begin{bmatrix} K_{mm} & K_{m(n-m)} \\ K_{(n-m)m} & K_{(n-m)(n-m)} \end{bmatrix}$$

作前 m 步(带主元的)-Cholesky分解

$$\begin{aligned} K_{XX} &= \begin{bmatrix} L_m & 0 \\ K_{(n-m)m} L_m^{-T} & I \end{bmatrix} \begin{bmatrix} I & 0 \\ 0 & * \end{bmatrix} \begin{bmatrix} L_m^T & L_m^{-1} K_{m(n-m)} \\ 0 & I \end{bmatrix} \\ &\approx \begin{bmatrix} L_m & \\ K_{(n-m)m} L_m^{-T} \end{bmatrix} \begin{bmatrix} L_m^T & L_m^{-1} K_{m(n-m)} \end{bmatrix} \\ &= K_{(n-m)m} K_{mm}^{-1} K_{m(n-m)} \end{aligned}$$



数值计算

➤ 随机特征方法

$$\kappa(x, x') = \Psi(x)^T \Psi(x')$$

其中

$$\Psi(x) = [\psi_1(x) \ \psi_2(x) \ \cdots \ \psi_m(x)]^T$$

那么：

$$K_{XX} = Q Q^T$$

其中：

$$Q = \begin{bmatrix} \Psi(x_1)^T \\ \Psi(x_2)^T \\ \vdots \\ \Psi(x_n)^T \end{bmatrix} \in R^{n \times m}$$



回顾

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 $\mu(\omega)$ 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

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



数值计算

➤ 随机特征方法

$$\kappa(x, x') = \Psi(x)^T \Psi(x')$$

其中

$$\Psi(x) = [\psi_1(x) \ \psi_2(x) \ \cdots \ \psi_m(x)]^T$$

随机特征：

$$\begin{aligned} \kappa(x, x') &= \mathbb{E}_{\omega \sim p(\omega)} [\psi(x, \omega) \psi(x', \omega)] \\ &= \sum_{i=1}^q \psi(x, \omega_i) \psi(x', \omega_i) \end{aligned}$$

可以定义：

$$\Psi(x) = [\psi(x, \omega_1) \ \psi(x, \omega_2) \ \cdots \ \psi(x, \omega_m)]^T$$



参考文献

➤ 参考文献

C. E. Rasmussen & C. K. I. Williams, Gaussian Processes for Machine Learning, Chapter 6

Wendland, Holger. Scattered data approximation. Vol. 17. Cambridge university press, 2004.

Kanagawa, Motonobu, Philipp Hennig, Dino Sejdinovic, and Bharath K. Sriperumbudur. "Gaussian processes and kernel methods: A review on connections and equivalences." arXiv preprint arXiv:1807.02582 (2018).

Rahimi, Ali, and Benjamin Recht. "Random features for large-scale kernel machines." Advances in neural information processing systems 20 (2007).