

カーネル法によるノンパラメトリックな統計的推論

福水 健次

数理・推論研究系教授 / 統計的機械学習研究センター長

■ カーネル法

正定値カーネルを用いた、データの非線形性、高次モーメントを取り込むための新しい方法論。効率的な計算を重視。

● 定義：正定値カーネル

Ω : 集合. $k: \Omega \times \Omega \rightarrow \mathbf{R}$ が正定値であるとは、 k が対称で、任意の $n \in \mathbf{N}$, $x_1, \dots, x_n \in \Omega$ に対し、

グラム行列 $\begin{pmatrix} k(x_1, x_1) & \dots & k(x_1, x_n) \\ \vdots & \ddots & \vdots \\ k(x_n, x_1) & \dots & k(x_n, x_n) \end{pmatrix}$ が半正定値.

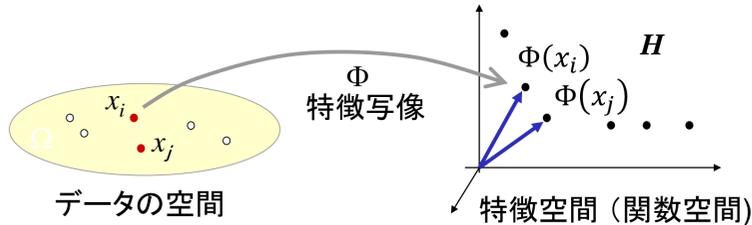
例: ガウスカーネル $\exp(-\|x - y\|^2 / (2\sigma^2))$

● 再生核ヒルベルト空間 (RKHS)

- 正定値カーネルに対しヒルベルト空間が一意に定まる。
- Ω 上の関数からなる関数空間。一般に無限次元。
- 特殊な内積を持つ。

$$\langle k(\cdot, x), f \rangle_{\mathcal{H}} = f(x) \quad \forall f \in \mathcal{H}, x \in \Omega. \quad (\text{再生性})$$

● 正定値カーネルとRKHSを用いたデータ解析



● 特徴写像と特徴ベクトル

$$\Phi: \Omega \rightarrow H, \quad x \mapsto \Phi(x) := k(\cdot, x).$$

● カーネルトリック: 容易な内積計算

$$\langle \Phi(x), \Phi(y) \rangle = \langle k(\cdot, x), k(\cdot, y) \rangle = k(x, y).$$

● 特徴空間上で線形の解析手法を適用 (注: 多くの手法は内積計算が本質的)

- 線形手法の非線形化
- カーネル主成分分析, カーネル判別分析
- サポートベクターマシン

● 非線形カーネル → 非線形 / 高次情報の抽出

■ カーネル平均による分布の表現

● カーネル平均: 特徴ベクトル $\Phi(X)$ の期待値

$$m_X := E[\Phi(X)] = E[k(\cdot, X)] \in H$$

● X の高次モーメントの情報を持つ。

例) $k(u, x) = c_0 + c_1(xu) + c_2(xu)^2 + \dots$ と書ければ

$$E[k(u, X)] = c_0 + c_1 E[X]u + c_2 E[X^2]u^2 + \dots$$

● 特性的なカーネル

$P \mapsto m_P$ が単射, すなわち

$$E_{X \sim P}[k(u, X)] = E_{X \sim Q}[k(u, X)] \Leftrightarrow P = Q.$$

例. ガウスカーネル. c.f. 特性関数 $E[e^{iu^T x}]$.

● カーネル平均による統計的推論

原理: 特性的なカーネルを用いると, 分布に関する推論 → カーネル平均に関する推論

例: 2標本問題 $m_X = m_Y$? (Gretton et al. NIPS'06), 独立性検定 $m_{(X,Y)} = m_X \otimes m_Y$? (Gretton et al. NIPS'07)

■ カーネル平均によるベイズ推論

「行列計算」に基づく新しいノンパラメトリックなベイズ推論法。分布はカーネル平均として、変数間の関係は共分散作用素として表現。

● 共分散作用素 $C_{YX} := E[\Phi_Y(Y)\Phi_X(X)^T] : H_X \rightarrow H_Y$

● 推定量 (標本平均, 標本共分散作用素)

$$\hat{m}_X := \frac{1}{n} \sum_{i=1}^n \Phi_X(X_i), \quad \hat{C}_{YX} := \frac{1}{n} \sum_{i=1}^n \Phi_Y(X_i) \otimes \Phi_X(X_i)^T$$

● ベイズ推論

Bayes' rule: $q(x|y) = \frac{p(y|x)\pi(x)}{\int p(y|x)\pi(x)dx}$

● Kernel Bayes' Rule: 事後確率のカーネル平均

$$m_{Q_{x|y}} = C_{XY}^\pi C_{YY}^{\pi^{-1}} \Phi(y)$$

ただし $C_{YX}^\pi = C_{(YX)X} C_{XX}^{-1} m_\pi$, $C_{YY}^\pi = C_{(YY)X} C_{XX}^{-1} m_\pi$

グラム行列計算により事後確率 (カーネル平均) が得られる

事前確率: $\sum_{i=1}^{\ell} \alpha_i \Phi(\tilde{X}_i)$, $P_{XY}: (X_1, Y_1), \dots, (X_n, Y_n)$ i.i.d.

⇒ 事後確率: $\hat{m}_{Q_{x|y}} = \sum_{i=1}^n w_i(y) \Phi(X_i)$,

$$w(y) = R_{X|Y} \mathbf{k}(y), \quad \mathbf{k}(y) = (k(Y_1, y), \dots, k(Y_n, y))^T$$

$$R_{X|Y} = \Lambda G_{YY} ((\Lambda G_{YY})^2 + \delta_n I_n)^{-1} \Lambda \mathbf{k}(y),$$

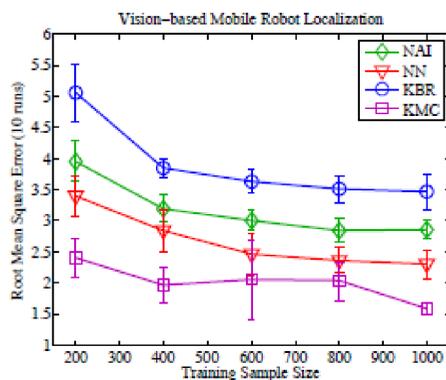
$$\Lambda = \text{Diag}[(G_{XX} + n\varepsilon_n I_n)^{-1} G_{X\tilde{X}} \alpha]$$

● カーネルベイズ推論則の応用

- ノンパラメトリックHMM (Fukumizu et al. NIPS 2011) 遷移則や観測過程をノンパラメトリックにGram行列表現。
- Kernel Approximate Bayesian Computation (Kernel ABC) (Nakagome, Fukumizu, Mano. 2012) 尤度関数が陽に書けない場合
- POMDP: Bellman方程式のカーネル化 (Nishiyama et al UAI2012)
- Monte Carloとの組み合わせ (カーネル Monte Carlo フィルタ, Kanagawa et al AAI 2014)

□ カーネルMonte Carloフィルタの応用: ロボット位置推定

- 状態遷移: モデル化容易 → Monte Carlo Sampling
- 観測過程: モデル化困難 → カーネルベイズ



NAI: naive method (closest image in training data)

NN: Particle Filter + K-近傍 (Vlassis, Terwijn, Kröse 2002)

KBR: KBR + KBR

KMC: KBR + Monte Carlo