

カーネル関数を構成する.

**Definition 1** (正定値カーネル). 以下を満たす関数  $k : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$  を正定値カーネルという:

1. 対称性:  $k(x, x') = k(x', x), \quad \forall x, x' \in \mathcal{X}$
2. 非負定値性:  $\forall n = 1, 2, 3, \dots, \quad \forall x_1, \dots, x_n \in \mathcal{X}$

$n \times n$  対称行列  $K = \begin{pmatrix} k(x_1, x_1) & \cdots & k(x_1, x_n) \\ \vdots & \ddots & \vdots \\ k(x_n, x_1) & \cdots & k(x_n, x_n) \end{pmatrix}$  は非負定値行列

$$\iff \sum_{i,j=1}^n c_i c_j k(x_i, x_j) \geq 0, \quad \forall n \in \mathbb{N}, \quad \forall c_1, \dots, c_n \in \mathbb{R}.$$

$K$  をグラム行列という.

# Mercerの定理

(大雑把には)  $k(x, x')$  が正定値カーネルなら, 関数  $x \mapsto \phi(x) \in \mathbb{R}^D$  が存在して

$$k(x, x') = \phi(x)^T \phi(x')$$

となる ( $D = \infty$  もありえる).

- $L_2$  収束
- 絶対一様収束

参考文献：赤穂本, 福水本.

**Mercer** の定理の解釈：

$k(x, x')$  が正定値カーネルなら  $k(x, x') = \sum_i \phi_i(x) \phi_i(x')$ .

$\iff$  統計モデル  $\sum_i \phi_i(x) \theta_i$  を仮定して推定.

例 1. 線形, 多項式, ガウシアンカーネルは正定値カーネル.  
多項式  $(1 + x^T x')^k$  はあとで証明

ガウシアン, ラプラス: **Bochner** の定理で証明: 積分表現を与える.

$$e^{-\gamma(x-y)^2} = \frac{1}{2\sqrt{\pi\gamma}} \int_{-\infty}^{\infty} e^{i(x-y)w} e^{-w^2/(4\gamma)} dw$$
$$e^{-\gamma|x-y|} = \frac{\gamma}{\pi} \int_{-\infty}^{\infty} e^{i(x-y)w} \frac{1}{w^2 + \gamma^2} dw$$

- 関数  $g : \mathcal{X} \rightarrow \mathbb{R}$  に対して  $g(x)g(x')$  は正定値カーネル.
- $k(x, x'), k_1(x, x'), k_2(x, x')$  が正定値カーネルのとき
  1. 非負定数  $a, b \geq 0$  に対して  $a + b \cdot k(x, x')$  も正定値カーネル.
  2.  $k_1(x, x') + k_2(x, x')$  も正定値カーネル.
  3.  $k_1(x, x')k_2(x, x')$  も正定値カーネル.  
したがって  $k(x, x')^p, p \in \mathbb{N}$  もカーネル関数.
- $k_1, k_2, \dots, k_n, \dots,$  が全て正定値カーネルのとき

$$k = \lim_{n \rightarrow \infty} k_n \quad (\text{各点収束}) \quad \text{も正定値カーネル}$$

# カーネル関数から定まる統計モデル

正定値カーネル  $k(x, x')$ ,  $x, x' \in \mathcal{X}$  から定義される関数の集合 :

$$\tilde{\mathcal{H}}_k = \left\{ \sum_{i=1}^N k(\cdot, z_i) \beta_i \mid N \in \mathbb{N}, z_i \in \mathbb{R}^d, \beta_i \in \mathbb{R} \right\}.$$

**note:** 線形モデル  $\left\{ \sum_i \phi_i(x) \theta_i \mid \theta_i \in \mathbb{R} \right\}$  の別表現.

$\tilde{\mathcal{H}}_k$  に内積を定義する : 長さや角度 (直交性) を定める.  
推定量の記述, 解釈に役立つ.

## 内積

1. 対称性 :  $\langle f, g \rangle = \langle g, f \rangle$
2. 双線形性 :  $\langle af + bg, h \rangle = a\langle f, h \rangle + b\langle g, h \rangle$
3. 正值性 :  $\langle f, f \rangle \geq 0$
4.  $\langle f, f \rangle = 0 \Leftrightarrow f = 0$ .

- $\tilde{\mathcal{H}}$  上の内積 :

$$\langle k(\cdot, x), k(\cdot, x') \rangle = k(x, x') \quad \& \quad \text{双線形性.}$$

$$\|f\| = \sqrt{\langle f, f \rangle}.$$

- $\langle \cdot, \cdot \rangle$  の定義と正定値カーネルの性質から **1,2,3** 成立.
- **1,2,3**  $\Rightarrow$  シュワルツ不等式  $|\langle f, g \rangle| \leq \|f\| \|g\| \Rightarrow$  **4**
- 上の内積は  $f \in \tilde{\mathcal{H}}$  の表し方に依らない(ことを言う必要がある)

例 2.

$$\langle k(\cdot, x_1) - 2k(\cdot, x_2), k(\cdot, x_3) \rangle = k(x_1, x_3) - 2k(x_2, x_3)$$

$$\|k(\cdot, x) - k(\cdot, x')\|^2 = k(x, x) + k(x', x') - 2k(x, x')$$

# 再生性

$f \in \tilde{\mathcal{H}}_k$ ,  $x \in \mathcal{X}$  に対して以下が成り立つ：

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

*Proof.*  $f(\cdot) = \sum_{i=1}^N k(\cdot, z_i) \beta_i$  とすると

$$\begin{aligned} \langle f, k(\cdot, x) \rangle &= \sum_{i=1}^N \beta_i \langle k(\cdot, z_i), k(\cdot, x) \rangle \\ &= \sum_{i=1}^N \beta_i k(z_i, x) = \sum_{i=1}^N k(x, z_i) \beta_i = f(x) \end{aligned}$$



再生性を使うと  $\langle \cdot, \cdot \rangle$  が内積であることが証明できる.

$\|f\| = 0$  のとき, 任意の  $x \in \mathcal{X}$  に対して

$$|f(x)| = |\langle f, k(\cdot, x) \rangle| \leq \|f\| \|k(\cdot, x)\| = \|f\| \sqrt{k(x, x)} = 0$$

より  $f$  は  $\mathcal{X}$  上の零関数となる. よって  $\|f\| = 0$  なら  $f = 0$  となる.

線形モデルとの対応:

$$\begin{aligned} \boldsymbol{x} &\mapsto k(\boldsymbol{x}, \cdot) \in \tilde{\mathcal{H}}_k, \\ \boldsymbol{w} &\mapsto f \in \tilde{\mathcal{H}}_k, \\ \boldsymbol{w}^T \boldsymbol{x} &\mapsto \langle f, k(\boldsymbol{x}, \cdot) \rangle = f(\boldsymbol{x}) \end{aligned}$$



## § 再生核ヒルベルト空間

**Definition 2** (再生核ヒルベルト空間). 内積空間  $(\tilde{\mathcal{H}}_k, \langle \cdot, \cdot \rangle)$  を完備化  $\implies$  再生核ヒルベルト空間  $(\mathcal{H}_k, \langle \cdot, \cdot \rangle)$ ,  $(\tilde{\mathcal{H}}_k \subset \mathcal{H}_k)$ .

**Reproducing kernel Hilbert space : RKHS** と略す.

完備化 : コーシー列が収束列になるように「穴を埋めた」空間.

(例 :  $\mathbb{Q}$  を完備化  $\implies \mathbb{R}$ )

- $\mathcal{H}_k$  に対しても再生性が成り立つ :  $\forall f \in \mathcal{H}_k, \langle f, k(x, \cdot) \rangle = f(x)$ .  
完備化の定義から証明できる (証明略).
- (完備化しても)  $f \in \mathcal{H}_k$  は  $\mathcal{X}$  から  $\mathbb{R}$  への関数として表現できる (証明略).

# カーネル関数を用いた推定

1. カーネル関数  $k(x, x')$  を定める
2.  $k(x, x')$  から **RKHS**  $\mathcal{H}_k$  が定まる
3. データから回帰関数  $f(x) + b \in \mathcal{H}_k + \mathbb{R}$  を推定する.

カーネル関数  $k$  を用いて推定

$\iff$  統計モデルとして **RKHS**  $\mathcal{H}_k$  を仮定

## 正定値カーネルに対応する関数空間

- $m$  次多項式カーネル :  $k(x, x') = (1 + xx')^m, x, x' \in \mathbb{R}$ .  
 $\mathcal{H}_k$  :  $m$  次以下の多項式のなす線形空間
- ガウシアン・カーネル :  $k(x, x') = \exp\{-\gamma(x - x')^2\}, x, x' \in \mathbb{R}$ .

$$\mathcal{H}_k = \left\{ f \in L_2(\mathbb{R}) \mid \int |\mathcal{F}(f)(w)|^2 e^{w^2/(4\gamma)} dw < \infty \right\}$$

$\mathcal{F}(f)$ :  $f$  のフーリエ変換. 周波数成分が指数的に減衰する関数の集合

# 表現定理

データ  $D = \{(x_1, y_1), \dots, (x_n, y_n)\}$  に対して, 学習アルゴリズム

$$\min_{f, b} L(f(x_1), \dots, f(x_n), b; D) + \Omega(\|f\|^2), \quad f \in \mathcal{H}_k, \quad b \in \mathbb{R}$$

を考える.  $\Omega$  は単調増加関数とする ( $\Omega(\|f\|^2)$  は正則化項に対応).  
このとき  $f$  の最適解は

$$f(\cdot) = \sum_{i=1}^n k(\cdot, x_i) \beta_i, \quad \beta_i \in \mathbb{R}$$

と表せる.

*Proof.*  $S = \text{span} \{k(\cdot, x_1), k(\cdot, x_2), \dots, k(\cdot, x_n)\}$  とする.

直交補空間を  $\mathcal{K}^\perp$  とする.  $f = f_1 + f_2$ ,  $f_1 \in \mathcal{S}$ ,  $f_2 \in \mathcal{S}^\perp$ . このとき

$$f(x_i) = \langle f_1 + f_2, k(\cdot, x_i) \rangle = \langle f_1, k(\cdot, x_i) \rangle = f_1(x_i),$$

$$\|f\|^2 = \|f_1\|^2 + \|f_2\|^2 \geq \|f_1\|^2.$$

したがって

$$\begin{aligned} & L(f(x_1), \dots, f(x_n), b; D) + \Omega(\|f\|^2) \\ & \geq L(f_1(x_1), \dots, f_1(x_n), b; D) + \Omega(\|f_1\|^2). \end{aligned}$$

すなわち, 部分空間  $\text{span}\{k(\cdot, x_1), \dots, k(\cdot, x_n)\}$  上に  $f$  の最適解が存在する. ■

$$\min_{f,b} L(f(x_1), \dots, f(x_n), b; D) + \Omega(\|f\|^2), \quad f \in \mathcal{H}_k$$

$$\Leftrightarrow \min_{\beta,b} L\left(\sum_{i=1}^n k(x_1, x_i)\beta_i, \dots, \sum_{i=1}^n k(x_n, x_i)\beta_i, b; D\right) + \Omega(\beta^\top K \beta)$$

ただし  $K_{ij} = k(x_i, x_j)$ .

- 表現定理：  
 $\mathcal{H}_k$  が無限次元でも、有限次元の最適化問題を解くことで、厳密な最適解が得られる。
- さまざまな損失関数で成立

$k(x, x')$  : が正定値カーネルでないとき :

$$\text{統計モデル} : \mathcal{H}' = \left\{ f(x) = \sum_{i=1}^N k(x, z_i) \beta_i \mid N \in \mathbb{N}, \beta_i \in \mathbb{R}, z_i \in \mathcal{X} \right\}.$$

- 正則化 :  $\langle f, f \rangle$  ではなく  $\sum_k \beta_k^2$  など.
- 内積空間と対応せず, 統計的性質を調べにくい.

# カーネルパラメータの選択

カーネルパラメータ：カーネル関数を決めるパラメータ.

- 多項式カーネルの次数  $m \in \mathbb{N}$ .
- ガウシアン・カーネルの幅パラメータ  $\gamma > 0$ .

正則化パラメータ, カーネルパラメータ： **$K$ -fold CV**などで決める.



## カーネルパラメータの選択：ガウシアン・カーネル

- 正則化パラメータの候補： $\lambda_1, \dots, \lambda_p$
- カーネル幅パラメータの候補： $\gamma_1, \dots, \gamma_q$
- $(\lambda_i, \gamma_j)$  を用いて回帰関数を学習する。このときの予測誤差の推定値を **cross validation** で計算： $\hat{e}_{CV}(\lambda_i, \gamma_j)$ .
- $\hat{e}_{CV}(\lambda_i, \gamma_j), i = 1, \dots, p, j = 1, \dots, q.$  のなかで最小値を達成する  $(\lambda, \gamma)$  を用いた回帰関数を推定量とする.

**$K$ -fold CV** を用いるとき  $pqK$  回の推定を行う.

# ヒューリスティクス (発見的解法)

- 交差検証法は一般に計算コストが大きい.
- モデルパラメータが複数ある場合：以下のような工夫をする
  - 並列計算
  - いくつかのパラメータを適当な値に固定,  
残りのパラメータを交差検証法で決める.

## ガウシアンカーネルの $\gamma$ の選び方

ガウシアンカーネルの  $\gamma$  をヒューリスティックに決める.

$$k(\mathbf{x}, \mathbf{x}') = \exp\{-\gamma\|\mathbf{x} - \mathbf{x}'\|^2\}$$

- 計算の安定化のため,  $\gamma\|\mathbf{x}_i - \mathbf{x}_j\|^2$  が「ほどほどの値」を取るようにする.


$$d^2 := \text{median}\{\|\mathbf{x}_i - \mathbf{x}_j\|^2 : i < j\} \quad (\text{中央値})$$

として  $\gamma = \frac{1}{d^2}$  とする


- $\gamma\|\mathbf{x}_i - \mathbf{x}_j\|^2$  は 1 のまわりに分布
- グラム行列の数値計算が安定

# 推定結果


- カーネルパラメータ :  $\sigma = 0.98$  (median-heuristics)
- 正則化パラメータ  $\lambda$  : いろいろ変える.



$(\sigma, \lambda) = (0.98, 0.1^5)$



$(\sigma, \lambda) = (0.98, 0.78)$



$(\sigma, \lambda) = (0.98, 10)$