

# カーネル関数の分解と再生核ヒルベルト空間の特徴付け

カーネル関数はある条件のもと

$$k(x, x') = \sum_{i=1}^{\infty} \mu_i e_i(x) e_i(x')$$

の形式に分解できる。ただし、

- $\mu_1 \geq \mu_2 \geq \mu_3 \geq \dots \geq 0$  (固有値)
- $(e_i)_i$  は ある測度  $\nu$  に関する  $L^2(\nu)$  内の ONS.  
 $(\int e_i(x) e_{i'}(x) d\nu(x) = 0) \quad (i \neq i')$  (正規直交系)

今、ある位相空間  $X$  上の (非負) Borel 測度  $\nu$  に対し、  
 $k$  で決まる積分作用素を

$$T_k f(x) = \int f(y) k(y, x) d\nu(y) \quad (f \in L^2(\nu))$$

とする。

作用素  $T_k$  と  $k$  の分解は密接に関係している。

← 作用素のスペクトル理論等  
 が示せる。

## 定理 (Mercer/分解)

$X$  をハウスドルフ位相空間とする。

$\nu$  を  $X$  上の非負 Borel 測度で  $\text{supp}(\nu) = X$  であるとする。

$k: X \times X \rightarrow \mathbb{R}$  は 連続な正定値カーネル で、

$$\int k(x, x) d\nu(x) < \infty$$

とする。

このとき、 $k$  によって決まる RKHS  $H$  は可分で、 $\forall x \in X$  において

$$k(x, x') = \sum_{i=1}^{\infty} \mu_i e_i(x) e_i(x')$$

が  $\forall x' \in X$  で絶対収束し、任意のコmpact集合  $A \subset X$  上の  $x' \in A$  で一様収束する。  $\mu_i \searrow 0$  である。

また、この分解を用いて、 $T_k$  は

$$T_k f(x) = \sum_{i=1}^{\infty} \mu_i e_i(x) \langle e_i, f \rangle_{L^2(\nu)} \quad (\forall x \in X)$$

と書ける。

証明も関連する話題の詳細は

Steinwart & Scovel: Mercer's theorem on general domains:

on the interaction between measures, kernels, and RKHS

Constructive Approximation, 35:363-417, 2012.

を参照してください.

① Mercerの分解を用いて、RKHSは次のようにも書ける.

$$H = \left\{ \sum_{i=1}^{\infty} a_i \mu_i^{\frac{1}{2}} e_i \mid \sum_{i=1}^{\infty} a_i^2 < \infty \right\}$$

$$= \left\{ \sum_{i=1}^{\infty} b_i e_i \mid \sum_{i=1}^{\infty} \frac{b_i^2}{\mu_i} < \infty \right\}$$

( $\frac{0}{0} = 0$  とする)  
 $\sum_{i=1}^{\infty}$  とする  
 $\mu_i = 0 (i \geq M)$  とする  
 $\sum_{i=1}^M$  とする.

②  $f, g \in H$  と  $f(x) = \sum_{i=1}^{\infty} b_i e_i(x), g(x) = \sum_{i=1}^{\infty} b'_i e_i(x)$  と書ける時.

$$\langle f, g \rangle_H = \sum_{i=1}^{\infty} \frac{b_i b'_i}{\mu_i}, \quad \|f\|_H^2 = \sum_{i=1}^{\infty} \frac{b_i^2}{\mu_i}$$

と表現できる.  $\mu_i > 0$ . 再生性も確認できる:

$$\langle f, k(x, \cdot) \rangle_H = \sum_{i=1}^{\infty} \frac{b_i (\mu_i e_i(x))}{\mu_i} = \sum_{i=1}^{\infty} b_i e_i(x) = f(x)$$

$\uparrow k(x, \cdot) = \sum_{i=1}^{\infty} \mu_i e_i(x) e_i(\cdot)$  係数

③  $\mu_i > 0$ .  $(\sqrt{\mu_i} e_i)_{i=1}^{\infty}$  は  $H$  の 正規直交基底 になることを示す.

④  $H = T_{\mathbb{R}^{\frac{1}{2}}} L^2(V)$  である.  $\forall f \in H$  に対し、 $\exists g \in L^2(V)$  と

$$f = T_{\mathbb{R}^{\frac{1}{2}}} g \Leftrightarrow f = \sum_{i=1}^{\infty} \sqrt{\mu_i} \langle g, e_i \rangle_{L^2(V)} e_i$$

と書ける. したがって.

$$\|f\|_H = \inf \{ \|g\|_{L^2(V)} \mid f = T_{\mathbb{R}^{\frac{1}{2}}} g, g \in L^2(V) \}$$

がわかる.

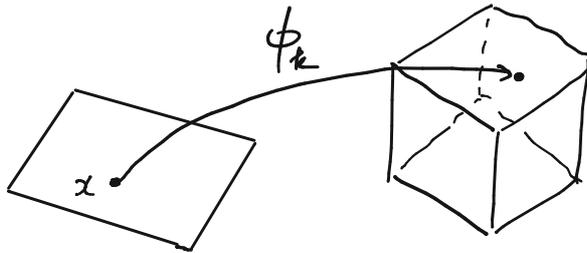
$\mu_i \searrow 0$  であること. 多くの場合  $e_i$  は  $i$  が大きくなるにつれて高周波成分をもつようになる.  $f$  は  $g \in L^2(V)$  に平滑化作用素  $T_{\mathbb{R}^{\frac{1}{2}}}$  を作用させた滑らかな  $f$  となる.

$$\textcircled{5} \quad \phi_R(x) = (\sqrt{\mu_n} e_n(x))_{n=1}^{\infty} \text{ と書くと,}$$

$$k(x, x') = \sum_{n=1}^{\infty} (\sqrt{\mu_n} e_n(x)) (\sqrt{\mu_n} e_n(x'))$$

$$= \langle \phi_R(x), \phi_R(x') \rangle_{\ell^2} \quad \leftarrow \phi_R(x) \text{ と } \phi_R(x') \text{ の内積}$$

と書ける. この  $\phi_R$  は  $x$  の 特徴写像 とみなせる.



Mercer 展開を用いて, カーネル法に於ける学習は次のように書ける:

$$\min_{f \in \mathcal{H}} \frac{1}{n} \sum_{i=1}^n \ell(y_i, f(x_i)) + \lambda \|f\|_{\mathcal{H}}^2$$

$$= \min_{(a_j)_{j=1}^{\infty}} \frac{1}{n} \sum_{i=1}^n \ell(y_i, \sum_{j=1}^{\infty} a_j \sqrt{\mu_j} e_j(x_i)) + \lambda \sum_{j=1}^{\infty} a_j^2$$

$$= \min_{(b_j)_{j=1}^{\infty}} \frac{1}{n} \sum_{i=1}^n \ell(y_i, \sum_{j=1}^{\infty} b_j e_j(x_i)) + \lambda \sum_{j=1}^{\infty} \frac{b_j^2}{\mu_j}$$

このように書くと, カーネル法が (無限次元) 線形モデルを用いた学習法であることがわかる.

また, 正則化項は リッジ正則化 に相当する.

\* Mercer 展開は  $\mathcal{H}$  が 可分なら常に可能.  $(e_i)_i$  を  $\mathcal{H}$  の任意の完全正規直交系 (CONS) とすると,

$$k(x, y) = \sum_i e_i(x) e_i(y) \quad (x, y \in \mathcal{X})$$

が成り立つ. ( $k(x, \cdot) = \sum_i e_i(x) e_i(\cdot)$  が  $\mathcal{H}$  の収束の意味でも成り立つ)

先の分解は  $T_R$  に付随して決まる  $2 \times V$  に依存する.

しかし,  $k$  や RKHS 自体は  $V$  に依存しない. つまり, 先の分解は

$(u_i, e_i)_i$  の選ぶ方として  $L^2(V)$  の正規直交系を用いた特殊な例にすぎない

## 。ガウス過程と RKHS

再生核ヒルベルト空間はガウス過程の特徴付けにも有用である。

### 定義

$\mathbb{R}^m$  値確率変数  $(X_1, \dots, X_m)$  が多変量正規分布に従うとは、 $\forall t_1, \dots, t_m \in \mathbb{R} \in \mathbb{A}$  かつ

$$t_1 X_1 + \dots + t_m X_m$$

が  $\mathbb{R}$  上の正規分布に従うことと定義する。

↑ 分散も与える。

平均:  $\mu = (E[X_1], \dots, E[X_m])^T \in \mathbb{R}^m$

共分散:  $\Sigma = (E[X_i X_j] - E[X_i] E[X_j])_{i,j} \in \mathbb{R}^{m \times m}$

を  $\mathbb{A}$  かつ  $N(\mu, \Sigma)$  と書く。 ( $\Sigma$  はランク落ちしてもよい)

### 定義

ある確率過程  $(f_x)_{x \in X}$  を考える。

任意の  $x_1, \dots, x_m \in X$  ( $m$  は任意) に対し、

$$(f_{x_1}, \dots, f_{x_m}) \in \mathbb{R}^m$$

が  $\mathbb{A}$  かつある多変量正規分布に従うとき、 $f = (f_x)_{x \in X}$  は ガウス過程 に従うという。

$m(x) = E[f_x]$  : 平均関数

$k(x, x') = E[(f_x - m(x))(f_{x'} - m(x'))]$  : 共分散関数

を  $\mathbb{A}$  かつ  $GP(m, k)$  と書く。 (正規分布は平均と分散のみで決まる。)

注  $k: X \times X \rightarrow \mathbb{R}$  は正定値対称カーネルに於て  $\mathbb{A}$  かつ。

カーネル関数  $k$  を  $\mathbb{A}$  かつ  $f$  を陽に表した。

⇒ **Karhunen-Loève 展開**

### 定理 (Karhunen-Loève 展開)

$f \sim GP(0, k)$  とする。  
 又は、先の Mercer 展開の定理の条件をみたすとす。  
 先の Mercer 展開を用いて、(f の適当なバージョンが)

$$f_x = \sum_{n=1}^{\infty} \xi_n \sqrt{\mu_n} e_n(x) \quad \leftarrow \text{RKHS の正規直交}$$

$$\xi_n \sim N(0, 1) \quad (\text{i.i.d.}) \quad \leftarrow \begin{array}{l} \text{基底は i.i.d. のから又} \\ \text{係数 } \xi_n \text{ を加けた和} \end{array}$$

と書ける。

### 石倉記

$$\begin{aligned} E[f_x f_{x'}] &= E\left[\sum_{n=1}^{\infty} \sum_{j=1}^{\infty} \xi_n \xi_j \sqrt{\mu_n} e_n(x) \sqrt{\mu_j} e_j(x')\right] \\ &= \sum_{n=1}^{\infty} \sum_{j=1}^{\infty} \underbrace{E[\xi_n \xi_j]}_{\delta_{nj}} \sqrt{\mu_n \mu_j} e_n(x) e_j(x') \\ &= \sum_{n=1}^{\infty} \mu_n e_n(x) e_n(x') = k(x, x') \end{aligned}$$

### 定理 (Driscoll の定理)

$H$  が無限次元

$\Leftrightarrow$  (f の適当なバージョン  $\tilde{f}$  が存在して)

$\tilde{f} \in H$  が確率 1 で成り立つ

(石倉記) KL-展開を用いて。

$$\|f\|_H^2 = \sum_{n=1}^{\infty} \xi_n^2 \mathbb{1}(\mu_n \neq 0)$$

と書ける。

無限次元:  $\forall n \geq 1, \mu_n \neq 0$  なら

$$\sum_{n=1}^{\infty} \xi_n^2 = \infty \quad (\text{a.s.})$$

無限  
↓

有限次元:  $\exists I \in \mathbb{N}$  で  $\mu_n = 0 \quad (\forall n > I)$  なら

$$\sum_{n=1}^I \xi_n^2 < \infty \quad (\text{a.s.})$$

有限

例  $[0,1]$  上の Wiener 過程  $(W_t)_{t \in [0,1]}$  
 $E[W_t] = 0$   
 $W_0 = 0$  (a.s.)  
 $W_t - W_s \sim N(0, t-s)$

$$k(t,s) = E[W_t W_s] = \min(t,s) \quad (t,s \in [0,1]) \quad (W_t) \text{ の加法過程}$$

$$\int_0^1 k(t,s) e(t) dt = \mu e(s)$$

を解く。

$$\begin{cases} \mu_n = \frac{4}{(2n-1)^2 \pi^2} \\ e_n(t) = \sqrt{2} \sin\left(\frac{(2n-1)\pi}{2} t\right) \end{cases}$$

( $n=1, 2, \dots$ )

が固有値, 固有関数 (基底)。

よって, KL-展開 (1)。Wiener 過程は

$$\begin{aligned} W_t &= \sum_{n=1}^{\infty} \sqrt{\mu_n} e_n(t) \cdot \xi_n \\ &= \sum_{n=1}^{\infty} \frac{2\sqrt{2}}{\pi(2n-1)} \sin\left(\frac{(2n-1)\pi}{2} t\right) \xi_n \end{aligned}$$

for  $\xi_n \sim N(0,1)$  (i.i.d.)

基底表現を持つ。

◦ 加うス過程 回帰

$$y_i = f^*(x_i) + \varepsilon_i$$

$$(\varepsilon_i \sim N(0, \sigma^2))$$

なるモデルを考える.  $D_n = (x_i, y_i)_{i=1}^n \in \mathbb{A} \cup \mathbb{Z}$   $f^*$  を推定した  $u$ .

ベイズ事前分布  $\pi(df)$ : 加うス過程  $\mathcal{G}P(0, k)$

f の尤度 :  $\prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2\sigma^2} (y_i - f(x_i))^2\right)$

⇒ ベイズ事後分布

$$\pi(df | D_n) \propto \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2\sigma^2} (y_i - f(x_i))^2\right) \pi(df)$$

ある  $x \in \mathcal{X}$  に対し.

$$k_{x, D_n} := (k(x, x_1), \dots, k(x, x_n))^T \in \mathbb{R}^n$$

$$K := (k(x_i, x_j))_{i,j} \in \mathbb{R}^{n \times n}$$

とすると, f の事後分布は

$$Y = (y_1, \dots, y_n)^T \in \mathbb{R}^n$$

- 平均:  $\hat{m}(x) = k_{x, D_n}^T (K + \sigma^2 I)^{-1} Y$
- 共分散:  $\hat{k}(x, x') = k(x, x') - k_{x, D_n}^T (K + \sigma^2 I)^{-1} k_{x', D_n}$

なる 加うス過程 で与えられる. (全く加うス分布の条件付き確率等の計算を求めず.)

平均に注目すると, これはカーネルリッジ回帰の解と一致する.

$$\left[ \begin{aligned} \hat{d} &= \underset{d \in \mathbb{R}^n}{\operatorname{argmin}} \sum_{i=1}^n (y_i - k_{x_i, D_n} d)^2 + \lambda d^T K d \\ \Rightarrow \hat{d} &= (K + \lambda I)^{-1} Y \quad \text{f)}. \quad \hat{f}(x) = \sum_{i=1}^n k(x, x_i) \hat{d}_i \\ &= k_{x, D_n}^T (K + \lambda I)^{-1} Y \\ &= \hat{m}(x) \\ \text{if } \lambda &= \sigma^2 \end{aligned} \right]$$