


カーネル法と学習理論

カーネル法を通じた学習理論の基本的なテクニックを紹介


カーネル法
非線形推論



基本的なアイデア

あるヒルベルト空間 H へ x を非線形にマッピングして、 H 上で線形な操作を行う。

$$x \mapsto \Phi(x) \in H$$



内積係数

$$x^T \beta$$

$$\Downarrow$$

$$\langle \Phi(x), f \rangle_H \quad (\text{ヒルベルト空間内の内積})$$

$$f \in H$$

特に $\langle \Phi(x), \Phi(x') \rangle_H = k(x, x')$ をカーネル関数と呼ぶ。

カーネル法の定式化

ある再生核ヒルベルト空間 H を用いて
(実数値の可変ヒルベルト空間)

$$\hat{f} = \arg \min_{f \in H} \sum_{i=1}^n l(y_i, f(x_i)) + \lambda \|f\|_H^2 \quad \text{--- ①}$$

とす。 $\|f\|_H$ は H における f のノルム。

定義 (正定値カーネル)

$$k: X \times X \rightarrow \mathbb{R} \quad \text{が } k \text{ 次元対称双線形、正定値カーネルと呼ぶ。}$$

- ・ 対称性: $k(x, x') = k(x', x) \quad (\forall x, x' \in X)$
- ・ 正値性: $\sum_{i=1}^m \sum_{j=1}^m a_i a_j k(x_i, x_j) \geq 0$
 $(\forall a_i \in \mathbb{R}, \forall x_i \in X \quad (i=1, \dots, m))$

定義 (再生核ヒルベルト空間)

集合 X 上の再生核ヒルベルト空間 (Reproducing kernel Hilbert Space, RKHS)

とは、 X 上の関数からなるヒルベルト空間 H で、

$\forall x \in X$ に対し、 $k_x \in H$ が存在して (先の $k(x)$ に相当)

②

(再生性) $\langle f, k_x \rangle_H = f(x) \quad (\forall f \in H)$

を H の k の ε という。

特に、 $\langle k_x, k_y \rangle_H = k(x, y)$ は正定値 k -核 (である)、 H は付随した再生核 (Reproducing Kernel, k -核関数) とよぶ。

逆に任意の正定値 k -核 k から RKHS が構成できる。

定理

$k \in$ 正定値 k -核 とする。

$\Rightarrow k \in$ 再生核 k を持つ RKHS が一意的に存在。

証明

$$H_0 := \text{span} \{ k(x, \cdot) \mid x \in X \}$$

$$= \left\{ \sum_{i=1}^m \alpha_i k(x_i, \cdot) \mid \alpha_i \in \mathbb{R}, x_i \in X (i=1, \dots, m), m=1, 2, \dots \right\}$$

$\subset H_0$ に "内積" $\langle \cdot, \cdot \rangle_{H_0}$ を次のように定める:

$$f(x) = \sum_{i=1}^n \alpha_i k(x_i, x), \quad g(x) = \sum_{j=1}^m \beta_j k(y_j, x) \text{ に対し、}$$

$$\langle f, g \rangle_{H_0} = \sum_{i=1}^n \sum_{j=1}^m \alpha_i \beta_j k(x_i, y_j).$$

これは実際に内積であることを示す。

・ 線形性: 自明

・ 対称性: 自明 ($\because k$ は対称)

・ 正値性:

まず $f \in H_0$ に対し、 $\langle f, f \rangle_{H_0} \geq 0$ が k の正値性から示せる。

次に、 $\|f\|_{H_0} = \sqrt{\langle f, f \rangle_{H_0}} = 0$ ならば $f(x) = 0$ ($\forall x \in X$) であることを示す。
 \uparrow 関数 k と 0 。

これは述べた性質より、Cauchy-Schwartz の不等式が成り立ち、

$$|f(x)| = |\langle k(x, \cdot), f \rangle_{H_0}| \leq \sqrt{k(x, x)} \|f\|_{H_0} = 0.$$

さらに、 $\langle \cdot, \cdot \rangle_{H_0}$ は f の表示のしかたによらず well-defined であることを示す。

$$f = \sum_{i=1}^n \alpha_i k(x_i, \cdot) = \sum_{i=1}^{n'} \alpha'_i k(x'_i, \cdot) \text{ のとき、 } f \text{ への } g = \sum_{j=1}^m \beta_j k(y_j, \cdot) \text{ へ}$$

対して、

$$\langle f, g \rangle_{H_0} = \sum_{i=1}^n \sum_{j=1}^m \alpha_i \beta_j k(x_i, y_j) = \sum_{j=1}^m \beta_j f(y_j) \quad \square \text{ 上二行一致}$$
$$\sqsubseteq \sum_{i=1}^{n'} \sum_{j=1}^m \alpha'_i \beta_j k(x'_i, y_j) = \sum_{j=1}^m \beta_j f(y_j) \quad \square$$

$\langle \cdot, \cdot \rangle_{H_0}$ が内積であることを示すための、この定数を $\langle \cdot, \cdot \rangle_H$ とし、 H_0 を完備化する。この H とする。 $f \in H$ に対して、 f に対応するコーシー列 $\{f_n\}_n \in H_0$ を用いて、

$$f(x) := \lim_{n \rightarrow \infty} \langle f_n, k(\cdot, x) \rangle_{H_0}$$

とすれば、 H は実数値関数の集合とみなせる。

このコーシー列の選び方は、実際 $\{f_n\}_n, \{f'_n\}_n \in H_0$ が f と f' に対応するときは、

$$\begin{aligned} & | \langle f_n, k(\cdot, x) \rangle_{H_0} - \langle f'_n, k(\cdot, x) \rangle_{H_0} | \\ & \leq \|k(\cdot, x)\|_{H_0} \|f_n - f'_n\|_{H_0} \rightarrow 0 \end{aligned} \quad \text{である。}$$

さらに、 $f(x) = 0$ ($\forall x \in X$) のとき、 $\langle f, k(x, \cdot) \rangle_H = 0$ ($\forall x \in X$) であり、
 $\forall k \in H_0$ に対し、 $\langle k, f_n \rangle_{H_0} \rightarrow 0$ である ($\{f_n\}$ は f に対応するコーシー列)。

よって、 $\|f\|_H = 0$ である。(弱収束するコーシー列は、強収束する。)

このことから $H \ni f \mapsto (x \mapsto f(x)) \in \mathbb{R}^X$ は単射であり、

H は実数値関数を要素として \mathbb{R}^X の内積空間として well-defined である。

(一意性)

H' を k に対応するもう一つの RKHS であるとすると、

再生核の定義より、 $\text{span}\{k(x, \cdot) \mid x \in X\} \subseteq H'$ (関数の集合として) である。

また、 $\forall f, g \in \text{span}\{k(x, \cdot) \mid x \in X\}$ に対し、

$$\langle f, g \rangle_H = \langle f, g \rangle_{H'}$$

であることは k の再生核性よりわかる。よって、

$$H = \overline{\text{span}\{k(x, \cdot) \mid x \in X\}} \subseteq H' \quad (\text{関数の集合として})$$

であり、 $\forall f, g \in H$ に対し、 $\langle f, g \rangle_H = \langle f, g \rangle_{H'}$ である。

今、 $f \perp k(x, \cdot)$ in H' ($\forall x \in X$) ならば

$$f(x) = \langle f, k(x, \cdot) \rangle_{H'} = 0 \quad (\forall x \in X) \quad \text{なので、} \quad \|f\|_{H'} = 0.$$

よって、 $H = H'$ (関数の集合として) であり、 $f \in H \subseteq H'$ に対し $\langle f, f \rangle_H = \langle f, f \rangle_{H'}$ である。

表現定理

定理

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

は 各 $d_i \in \mathbb{R}$ ($i=1, \dots, n$) に対し、

$$\hat{f}(x) = \sum_{i=1}^n d_i k(x_i, x)$$
 と表現できる。

証明

$f(x_i) = \langle k(\cdot, x_i), f \rangle_{\mathcal{H}}$ 。ロス関数に関する部分は
 $\mathcal{H}_1 = \operatorname{span}(k(\cdot, x_1), \dots, k(\cdot, x_n))$ の射影で決まる。

$$f = f_1 + f_2 \in \mathcal{H}_1 + \mathcal{H}_1^\perp \quad \text{とおく。} \quad f(x_i) = f_1(x_i) + f_2(x_i) = f_1(x_i) \quad \forall i$$

$$\sum_{i=1}^n \ell(y_i, f_1(x_i)) + \lambda \underbrace{\|f_1 + f_2\|_{\mathcal{H}}^2}_{\|f_1\|_{\mathcal{H}}^2 + \|f_2\|_{\mathcal{H}}^2}$$

よって最小化元は $f_2 = 0$ であり $f = \sum_{i=1}^n d_i k(x_i, \cdot)$ と書ける。

※

よって

$$\text{①} \Leftrightarrow \min_{d \in \mathbb{R}^n} \sum_{i=1}^n \ell(y_i, \sum_{j=1}^n k(x_i, x_j) d_j) + \lambda \sum_{i,j} d_i d_j k(x_i, x_j)$$

と有限次元最適化にあたる。

カーネル関数の例

— ガウスカーネル

$$k(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right)$$

— 多項式カーネル

$$k(x, x') = (1 + x^T x')^d$$

- 線形カーネル

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

- ソボレフ空間

$$H^m[a, b] = \{f \in L^2[a, b] \mid f, \dots, f^{(m-1)} \text{ 絶対連続で } f^{(m)} \in L^2[a, b]\}$$

$$k(x, y) = \sum_{l=0}^{m-1} \frac{(x-a)^l (y-a)^l}{l! l!} + \int_a^b \frac{(x-t)_+^{m-1} (y-t)_+^{m-1}}{(m-1)! (m-1)!} dt$$

$$\langle f, g \rangle_H = \sum_{l=0}^{m-1} f^{(l)}(a) g^{(l)}(a) + \int_a^b f^{(m)}(x) g^{(m)}(x) dx$$

- グラフカーネル

- 時系列カーネル

- 多項式カーネル

$x, x' \in \mathbb{R}$ とおくと

$$k(x, x') = 1 + \binom{d}{1} xx' + \binom{d}{2} (xx')^2 + \dots + (xx')^d$$

*) $\Phi(x) = \begin{bmatrix} 1 \\ \sqrt{1} x \\ \sqrt{\binom{d}{2}} x^2 \\ \vdots \\ x^d \end{bmatrix}$

とおけば $k(x, x') = \langle \Phi(x), \Phi(x') \rangle$ となる。

(他のカーネル法)

上記カーネル法における推定量の汎化誤差は本質的に小さくなるのか?
収束レートは? n → ∞

$$L(f) := E_{x, y} [l(y, f(x))]$$

$$\hat{L}(f) := \frac{1}{n} \sum_{i=1}^n l(y_i, f(x_i))$$

$$Pf := E_{x, y} [f(x, y)]$$

$$P_n f := \frac{1}{n} \sum_{i=1}^n f(x_i, y_i)$$

$$(L(f) = P(Q \cdot f), \hat{L}(f) = P_n(Q \cdot f))$$

と置く。

以下、簡単のため $\mathcal{F} := \{f \in H \mid \|f\|_H \leq 1\}$ なる集合を考慮。

$$f^* := \operatorname{argmin}_{f \in \mathcal{F}} L(f)$$

$$\hat{f} := \operatorname{argmin}_{f \in \mathcal{F}} \hat{L}(f)$$

*) 印はこれのこと。

$$\underline{L(\hat{f}) - L(f^*)} \quad (\text{汎化誤差})$$

誤差を減らすための学習理論の基本的問題意識

仮定 1

- $k(x, x) \leq 1 \quad (\forall x \in X)$
- $|\ell(y, f(x)) - \ell(y, f'(x))| \leq |f(x) - f'(x)| \quad (\forall x, y, \forall f \in \mathcal{F})$

最も基本的な問題設定の話を進めよう。

これらの仮定は緩められることもある。

命題

- $k(x, x) \leq 1 \quad (\forall x \in X)$ ならば
- $\|f\|_\infty \leq \|f\|_{\mathcal{H}} \quad (\forall f \in \mathcal{H})$

証明

$$\begin{aligned} |f(x)| &= |\langle k(x, \cdot), f \rangle_{\mathcal{H}}| \leq \|k(x, \cdot)\|_{\mathcal{H}} \|f\|_{\mathcal{H}} \\ &= \sqrt{\langle k(x, \cdot), k(x, \cdot) \rangle_{\mathcal{H}}} \|f\|_{\mathcal{H}} \\ &= \sqrt{k(x, x)} \|f\|_{\mathcal{H}} \leq \|f\|_{\mathcal{H}} \end{aligned}$$

⇨ $\forall f \in \mathcal{F}$ は $\|f\|_\infty \leq 1$ である。

出発点

\hat{f}, f^* の定義

$$L(\hat{f}) \leq L(f^*)$$

$$\hat{\ell}(\hat{f}) \leq \hat{\ell}(f^*)$$

である。⇨

$$\begin{aligned} 0 \leq L(\hat{f}) - L(f^*) &= L(\hat{f}) - \hat{\ell}(\hat{f}) - L(f^*) + \hat{\ell}(f^*) + \underbrace{\hat{\ell}(\hat{f}) - \hat{\ell}(f^*)}_{\leq 0} \\ &\leq (L(\hat{f}) - \hat{\ell}(\hat{f})) - (L(f^*) - \hat{\ell}(f^*)) \\ &= (P - P_n)(\hat{f} - f^*) \end{aligned}$$

⇨ 右辺を次のように扱う。

$$L(\hat{f}) - L(f^*) \leq \sup_{f \in \mathcal{F}} (P - P_n)(f - f^*)$$

* = = 2.

$$\sup_{f \in \mathcal{F}} P_n(\rho, f) \neq \sup_{f \in \mathcal{F}} \frac{1}{n} \sum_{i=1}^n E_i \rho(y_i, f(x_i))$$

以後可測であるとは定か。可測性がない場合は以下の議論は成り立たない。外測度を用いた議論も使えない。

詳しくは Dudley "Uniform Central Limit Theorems" 等。

c.f. Suslin image admissible.

二二二.

$$g := \rho \circ f - \rho \circ f^*, \quad (z = (x, y), \quad g(z) = \rho(y, f(x)) - \rho(y, f^*(x)))$$

$$\mathcal{G} := \{g \mid g = \rho \circ f - \rho \circ f^*, f \in \mathcal{F}\}$$

とすれば $\sup_{g \in \mathcal{G}} (P - P_n)g$ を押さえる問題になる。

Rademacher 複雑性

定義

$\sigma_i \in \{\pm 1\}$ と $P(\sigma_i = 1) = P(\sigma_i = -1) = \frac{1}{2}$ なる i.i.d. Rademacher 変数とする。

$$\hat{R}_n(\mathcal{G}) := E_{\{\sigma_i\}_{i=1}^n} \left[\sup_{g \in \mathcal{G}} \frac{1}{n} \sum_{i=1}^n \sigma_i g(z_i) \mid z_1, \dots, z_n \right]$$

(経験 Rademacher 複雑性)

$$R_n(\mathcal{G}) := E_{\{z_i\}_{i=1}^n} [\hat{R}_n(\mathcal{G})]$$

(Rademacher 複雑性)

定理 (対称化)

$$E_{\{z_i\}} \left[\sup_{g \in \mathcal{G}} (P - P_n)g \right] \leq 2 R_n(\mathcal{G})$$

証明

$\{z_i\}$ と $\mathcal{A} \subset$ i.i.d. sequence

$$\begin{aligned} \text{左辺} &= E_{\{z_i\}} \left[\sup_{g \in \mathcal{G}} \left\{ E_{\{z'_i\}} \left[\frac{1}{n} \sum_{i=1}^n g(z'_i) \right] - \frac{1}{n} \sum_{i=1}^n g(z_i) \right\} \right] \\ &\leq E_{\{z_i\}, \{z'_i\}} \left[\sup_{g \in \mathcal{G}} \frac{1}{n} \sum_{i=1}^n (g(z'_i) - g(z_i)) \right] \\ &= E_{\sigma_i} \left[E_{\{z_i, z'_i\}} \left[\sup_{g \in \mathcal{G}} \frac{1}{n} \sum_{i=1}^n \sigma_i (g(z'_i) - g(z_i)) \right] \right] \\ &\leq E_{\sigma_i} E_{z'_i} \left[\sup_{g \in \mathcal{G}} \frac{1}{n} \sum_{i=1}^n \sigma_i g(z'_i) \right] + E_{\sigma_i} E_{z_i} \left[\sup_{g \in \mathcal{G}} \frac{1}{n} \sum_{i=1}^n \sigma_i g(z_i) \right] \end{aligned}$$

($\because z'_i$ と z_i 対称) $\sigma_i \leftarrow -\sigma_i$ 同分布

$$= 2 R_n(G) \quad (= \text{Fubini の定理})$$

17

命題

$$\left[P \left(\sup_{g \in G} (R - P_n)g \geq 2 R_n(G) + 4 \sqrt{\frac{g(G)}{2n}} \right) \leq \delta \right]$$

証明 ($|G| \leq 2$ と McDiarmid の不等式)

補題

(McDiarmid の不等式)

X_1, \dots, X_n を X 上の独立な (独立かつ有限) 確率変数とする。

$f: X^n \rightarrow \mathbb{R}$ を可測関数とし、

$$|f(x_1, \dots, x_i, \dots, x_n) - f(x_1, \dots, x'_i, \dots, x_n)| \leq G_i$$

μ_i 任意の $x_1, \dots, x_n, x'_i \in X$ に対し成立する。

$$P \left(f(x_1, \dots, x_n) - E[f(x_1, \dots, x_n)] \geq \varepsilon \right) \leq \exp \left(- \frac{2\varepsilon^2}{\sum_{i=1}^n G_i^2} \right)$$

今、 $f, g \in \mathcal{F}$ かつ $\|f\|_\infty \leq 1$ なる二変数から

$$|g(z)| = |L(g, f(x)) - L(g, f^*(x))| \leq |f(x) - f^*(x)| \leq 2$$

とある。よって

$$h(z_1, \dots, z_n) = \sup_{g \in \mathcal{G}} \left\{ E[g(z)] - \frac{1}{n} \sum_{i=1}^n g(z_i) \right\}$$

は、

$$|h(z_1, \dots, z_i, \dots, z_n) - h(z_1, \dots, z'_i, \dots, z_n)| \leq \frac{4}{n}$$

をみたす。あとは McDiarmid の不等式と先の対称化により、題意を得る。

定理 (Rademacher 複雑性の性質)

(1) $G \subset G'$ なら $R_n(G) \leq R_n(G')$

(2) $\phi_i: \mathbb{R} \rightarrow \mathbb{R}$ かつ $|\phi_i(x) - \phi_i(y)| \leq M|x-y|$ を満たせば、

$$E_{z_i \in G_i} \left[\sup_{g \in G} \frac{1}{n} \sum_{i=1}^n G_i \phi_i(g(z_i)) \right] \leq M R_n(G)$$

(3) G の凸包 $\text{co}G = \left\{ \sum_{i=1}^m \lambda_i g_i \mid \sum_{i=1}^m \lambda_i = 1, \lambda_i \geq 0, g_i \in G, m=1, 2, \dots \right\}$ に対し、

$$R_n(G) = R_n(\text{co}G)$$

証明

(2)の示す. z_1, \dots, z_n 固定して示せば十分.

G_2, \dots, G_n 固定のとき.

$$D = \left\{ (g(z_i), \sum_{i=2}^n G_i \phi_i(g(z_i))) \mid g \in G \right\} \subseteq \mathbb{R}^2$$

とおく.

すると.

$$E_{G_1} \left[\sup_{g \in G} \sum_{i=1}^n G_i \phi_i(g(z_i)) \right]$$

$$= E_{G_2, \dots, G_n} \left[E_{G_1} \left[\sup_{g \in G} \sum_{i=1}^n G_i \phi_i(g(z_i)) \mid G_2, \dots, G_n \right] \right]$$

$$= E_{G_2, \dots, G_n} \left[\underbrace{\frac{1}{2} \sup_{(t_1, s_1) \in D} (\phi_1(t_1) + s_1) + \frac{1}{2} \sup_{(t_2, s_2) \in D} (-\phi_1(t_2) + s_2)} \right]$$

$$= \frac{1}{2} (\phi_1(t_1^*) + s_1^* - \phi_1(t_2^*) + s_2^*) \quad (\exists t_1^*, s_1^*, t_2^*, s_2^* \in \mathbb{R})$$

$$\leq \begin{cases} \frac{M}{2} (t_1^* - t_2^*) + \frac{1}{2} (s_1^* + s_2^*) & (t_1^* \geq t_2^*) \\ \frac{M}{2} (t_1^* - t_1^*) + \frac{1}{2} (s_1^* + s_2^*) & (t_1^* < t_2^*) \end{cases}$$

$$\leq \frac{1}{2} \sup_{(t_1, s_1) \in D} (M t_1 + s_1) + \frac{1}{2} \sup_{(t_2, s_2) \in D} (-M t_2 + s_2)$$

$$= E_{G_1} \left[\sup_{g \in G} G_1 M g(z_1) + \sum_{i=2}^n G_i \phi_i(g(z_i)) \right]$$

以上の議論をくり返せば証明を終了できる.

こゝに $L(g, t)$ の Lipschitz 連続性の仮定を用いることで

$$L(\hat{f}) - L(f^*) \leq \sup_{f \in F} (P - P_n)(L \cdot f - L \cdot f^*)$$

$$\leq 2 R_n(G) + 4 \sqrt{\frac{g(1/\delta)}{2n}} \quad \text{with prob. } 1 - \delta \quad (\delta \in (0, 1))$$

$$\leq 2 R_n(F) + 4 \sqrt{\frac{g(1/\delta)}{2n}}$$

を得る. よって $R_n(F)$ を上からおさめる条件を得る.

- $\mathcal{F} = \{f \in \mathcal{H} \mid \|f\|_{\mathcal{H}} \leq 1\}$, $\sup_x k(x, x) \leq 1$ のとき.

$$\begin{aligned}
 R_n(\mathcal{F}) &= E_{\{x_i\}} E_{\{G_i\}} \left[\sup_{f \in \mathcal{F}} \frac{1}{n} \sum_{i=1}^n G_i f(x_i) \right] \\
 &= E_{\{x_i\}} E_{\{G_i\}} \left[\sup_{f \in \mathcal{F}} \frac{1}{n} \left\langle \sum_{i=1}^n G_i k(x_i, \cdot), f \right\rangle_{\mathcal{H}} \right] \\
 &\leq E_{\{x_i\}} E_{\{G_i\}} \left[\sup_{f \in \mathcal{F}} \frac{1}{n} \left\| \sum_{i=1}^n G_i k(x_i, \cdot) \right\|_{\mathcal{H}} \cdot \underbrace{\|f\|_{\mathcal{H}}}_{\leq 1} \right] \\
 &= E_{\{x_i\}} E_{\{G_i\}} \left[\frac{1}{n} \sqrt{\sum_{i,j} G_i G_j k(x_i, x_j)} \right] \\
 &\leq \frac{1}{n} \sqrt{E_{\{x_i\}} E_{\{G_i\}} \left[\sum_{i,j} G_i G_j k(x_i, x_j) \right]} = \frac{1}{n} \sqrt{n E_x [k(x, x)]} \\
 &\leq \sqrt{\frac{1}{n}}
 \end{aligned}$$

- \mathcal{F} が有限集合のとき

Th. (Massart の定理)

$\mathcal{F} = \{f_1, \dots, f_M\}$ なら.

$$R_n(\mathcal{F}) \leq E_{\{z_i\}} \left[\max_{1 \leq m \leq M} \sqrt{\frac{1}{n} \sum_{i=1}^n f_m(z_i)^2} \right] \times \sqrt{\frac{2 \log M}{n}}$$

特に $\|f_m\|_{\infty} \leq R$ ($m=1, 2, \dots, M$) なら

$$\leq R \sqrt{\frac{2 \log M}{n}}$$

証明

$A \subset \mathbb{R}^n$ を有限集合とする。このとき $R = \max_{a \in A} \sqrt{\sum_{i=1}^n a_i^2}$ による

$$E_{\{G_i\}} \left[\max_{a \in A} \sum_{i=1}^n G_i a_i \right] \leq R \sqrt{2 \log |A|}$$

を示せば十分.

$$\begin{aligned}
 & \exp \left(E \left[\max_{a \in A} \sum_{i=1}^n G_i a_i \right] \right) \\
 & \leq E \left[\exp \left(\sum_{i=1}^n G_i a_i \right) \right] \leq E \left[\sum_{a \in A} \exp \left(\sum_{i=1}^n G_i a_i \right) \right] \\
 & \leq \sum_{a \in A} \prod_{i=1}^n E \left[\exp \left(G_i a_i \right) \right] \\
 & \leq \sum_{a \in A} \prod_{i=1}^n \exp \left(\frac{G_i^2 a_i^2}{2} \right) \quad (\text{Hoeffding の不等式}) \\
 & \leq \exp \left(\frac{1}{2} \sum_{i=1}^n G_i^2 R^2 \right)
 \end{aligned}$$

$$\frac{1}{2} \sum_{i=1}^n G_i^2 R^2 \leq \frac{2 \log |A|}{n} \quad \text{と } \sum_{i=1}^n G_i^2 \leq n \quad \text{より } R \leq \frac{R \sqrt{2 \log |A|}}{\sqrt{n}}$$

- F が \mathcal{V} の次元有限な集合の時.

F が 2 値関数族 かつ. i.e. $\forall f \in F \forall x \in X \rightarrow f(x) \in \{\pm 1\}$ ($\forall x \in X$)

定義


F の \mathcal{V} 次元

$$dvc(F) := \max \{ n \mid \exists x_1, \dots, x_n \in X \text{ で, } \forall \epsilon \in \{\pm 1\}^n \text{ (対し, } \\ \exists f \in F \text{ で } \epsilon_i = f(x_i) \text{ となる. } \} \\ \uparrow \\ n \text{ の } \epsilon \text{ が } \forall \epsilon \text{ を完全に識別できる.}$$

例: $F = \{ f(x) = \text{sign}(x^T \beta + a) \mid \beta \in \mathbb{R}^d, a \in \mathbb{R} \}$

$\Rightarrow dvc(F) = d + 1$

* \mathcal{V} 次元は分布に依存する.



定理 ($n > dvc(F)$)

$$R_n(F) \leq \frac{2 dvc(F) \log(n) + 2 dvc(F) \log(e/dvc(F))}{n} \\ (\leq c \sqrt{\frac{dvc(F) \log(n)}{n}})$$



定理 (Sauer の定理)

$$F_{X^n} = \{ (f(x_1), \dots, f(x_n)) \in \{\pm 1\}^n \mid f \in F \}$$

かつ.

$$m^F(n) := \max \{ |F_{X^n}| \mid (x_1, \dots, x_n) \in X^n \} \text{ (増大関数)}$$

かつ. ($dvc(F) = \max \{ n \mid |m^F(n)| = 2^n \}$)

つまり.

$n \leq dvc(F)$ ときは


$n > dvc(F)$ ときは

$m^F(n) = 2^n$ ← 指数関数

$m^F(n) \leq \sum_{i=1}^{dvc} \binom{n}{i} \leq \left(\frac{en}{dvc} \right)^{dvc}$

← 多項式!

つまり.



先の定理は Sauer の定理に

Massart の定理の証明と当てはめれば示される.

Th.

$$d_{VC}(F) < \infty \text{ ならば } \lim_{n \rightarrow \infty} \sup_{f \in F} |(P_n - P)f| = 0 \text{ P-a.s. } (\leftarrow P: \text{prob. meas.})$$

(Fは image admissible Euclid)

*?

$$\lim_{n \rightarrow \infty} \sup_P E_P \left[\sup_{f \in F} |(P_n - P)f| \right] = 0. \text{ (} d_{VC}(F) < \infty \text{ ならば)}$$

Th. (Assouad)

↑ VC dimension-class

(X, B): 可測空間

$$\sup_P E_P^* \left[\sup_{f \in F} |(P_n - P)f| \right] \rightarrow 0 \text{ (} n \rightarrow \infty \text{)}$$

(X, B) 上の有界関数 \leftarrow 外測度による積分


ならば FはVC-クラス

詳しくは, Dudley の "Uniform Central Limit Theorems" を参照のこと.

仮定 2

- L は強凸: ある $\alpha > 0$ が存在し、 $\forall f \in \mathcal{F}$ に対し、

$$\frac{\alpha}{2} \|f - f^*\|_{L_2(K_2)}^2 \leq L(f) - L(f^*)$$
- 以前の仮定が満たされる



$$L(f) - L(f^*) \leq \sup_{g \in G} (P - P_n)g \quad \text{はルーズすぎる。}$$

$L(f)$ が強凸なら、 f の存在が場所が限定されるはず。


$\sup_{g \in G}$ のかわりに、 f^* の近傍で \sup をおこなうことはできないか？
 → 局所化

Local Rademacher 複雑さ:

$$G_r := \{ g = f - f^* \in G \mid P_n g \leq r \} \text{ とし、}$$

$$R_n(G_r)$$

を local Rademacher 複雑さとする。



(集合を "局所化" したものは $P_n g \leq r$ となる $\|g\|_{L_2} \leq r$ とし、Local Rademacher 複雑さとする)

* $g = f - f^*$ に対し、170 ページ連続性から

$$\frac{\alpha}{2} \|g\|_{L_2}^2 \leq \frac{\alpha}{2} \|f - f^*\|_{L_2}^2 \leq P_n g$$

から、 $P_n g \leq r$ なら $\|g\|_{L_2(K_2)} \leq \sqrt{\frac{2r}{\alpha}}$ 。 ($\|f - f^*\|_{L_2(K_2)} \leq \sqrt{\frac{2r}{\alpha}}$ となる)

定理 (Peeling)

ある $\phi: [0, \infty) \rightarrow [0, \infty)$ なる関数が存在し、

$$\phi(4r) \leq 2\phi(r) \quad \forall r > 0$$

$$R_n(G_r) \leq \phi(r) \quad (r > 0)$$

ならば、 $\forall r > 0$ に対し、

$$E_{G, Z} \left[\sup_{g \in G} \frac{\frac{1}{n} \sum_{i=1}^n \sigma_i g(z_i)}{P_n g + r} \right] \leq \frac{4\phi(r)}{r}$$

である。

証明

$$\sup_{g \in G} \frac{\frac{1}{n} \sum_{i=1}^n \sigma_i g(z_i)}{Pg+r} \leq \sup_{g \in G_r} \frac{\frac{1}{n} \sum \sigma_i g(z_i)}{r} + \sum_{j=0}^{\infty} \sup_{g \in G_{r4^{j+1}} \setminus G_{r4^j}} \frac{\frac{1}{n} \sum \sigma_i g(z_i)}{r4^j+r}$$

両辺期待値をとると、

$$\begin{aligned} E[\text{左辺}] &\leq \frac{R_n(G_r)}{r} + \sum_{j=0}^{\infty} \frac{R_n(G_{r4^{j+1}})}{r4^j+r} \\ &\leq \frac{\phi(r)}{r} + \frac{1}{r} \sum_{j=0}^{\infty} \frac{\phi(4^{j+1}r)}{4^j+1} \\ &\leq \frac{\phi(r)}{r} + \frac{1}{r} \sum_{j=0}^{\infty} \frac{2^{j+1} \phi(r)}{4^j+1} \\ &\leq \frac{4\phi(r)}{r} \end{aligned}$$

$$\begin{aligned} &2 \times \left(\frac{1}{2} + \sum_{j=1}^{\infty} 2^{-j} \right) \\ &= 3 \end{aligned}$$

定理 (Talagrandの測度集中不等式)

(Z, \mathcal{A}, P) : 測度空間.

\tilde{G} : 可測関数の集合 on (Z, \mathcal{A}) s.t. $\forall g \in \tilde{G}, \|g\|_{\infty} \leq B, E[g]=0, E[g^2] \leq \sigma^2, \tilde{G}$ は $\|\cdot\|_{\infty}$ に関して可分.

すると、 $\forall t > 0$ に対し、

$$\begin{aligned} P^n \left(\sup_{g \in \tilde{G}} \frac{1}{n} \sum_{i=1}^n g(z_i) \geq 2 E \left[\sup_{g \in \tilde{G}} \frac{1}{n} \sum_{i=1}^n g(z_i) \right] + \sqrt{\frac{2t\sigma^2}{n}} + \frac{2tB}{n} \right) \\ \leq e^{-t} \end{aligned}$$

(定数は最適ではない)

上の \tilde{G} として、 $\left\{ \frac{Pg - g(z)}{Pg+r} \mid g \in G \right\}$ を代入する。

$$\begin{aligned} \text{すると、} \quad \|g\|_{\infty} &= \left\| \frac{Pg - g}{Pg+r} \right\|_{\infty} \leq \frac{1}{r}, \quad \|g\|_{L_2}^2 = \frac{\|g - Pg\|_{L_2}^2}{(Pg+r)^2} \leq \frac{P(g^2)}{r^2 \frac{1}{2} P(\sigma^2)} \\ &= \frac{2}{\alpha r} \end{aligned}$$

ここで、 $\forall t > 0, B = \frac{1}{r}, \sigma^2 = \frac{2}{\alpha r}$ とおくと、 $\forall t > 0$ に対し、

$$\sup_{g \in G} \frac{(P-P_n)g}{Pg+r} \leq 2 E \left[\sup_{g \in G} (P-P_n)g \right] + \sqrt{\frac{4t}{\alpha r n}} + \frac{2t}{r n} \quad \text{w.p. } 1 - e^{-t}$$

こゝで、前の定理 (peeling) F'.

$$\begin{aligned} E \left[\sup_{\hat{\theta} \in \hat{\Theta}} (P - P_n) \hat{\theta} \right] &\leq 2 R_n(\hat{\Theta}) \\ &\leq \frac{8 \phi(r)}{r}. \end{aligned}$$

である。以上より、

$$\begin{aligned} L(\hat{f}) - L(f^*) &\leq (P - P_n) \overbrace{(\hat{f} - f^*)}^{\hat{\theta}} \\ &\leq (P \hat{\theta} + r) \underbrace{\left(\frac{16 \phi(r)}{r} + \sqrt{\frac{4r}{dn}} + \frac{2r}{rn} \right)}_{\psi_n(r)} \end{aligned}$$

よゝ $\psi_n(r) \leq \frac{1}{2}$ なる任意の r に対し、 $(L(\hat{f}) - L(f^*) = P \hat{\theta})$ であること
に注意せよ。


$$L(\hat{f}) - L(f^*) \leq 2r \psi_n(r) \leq r$$

が成り立つ。

$$\max \left\{ 84 \phi(r), \frac{72r}{dn}, \frac{12r}{n} \right\} \leq r$$

なる r を。

$\phi(r)$ は \square 関数になることが多い。



$\phi(r)$ と r の交点を求めたい

(Fixed Point)

これは $\phi(r)$ はどのような形になるだろうか？


Dudley の定理

定義 (イントロノ数)

(T, d) を距離空間とする。

$$e_n(T, d) := \inf \{ \varepsilon > 0 \mid \exists s_1, \dots, s_{2^n} \in T \text{ s.t. } T \subset \bigcup_{j=1}^{2^n} B_d(s_j, \varepsilon) \}$$

* 半径 ε を指定したときのボールの個数はカリリノフナンバー といい、
そちらを使うことも多い ($N(\varepsilon, T, d)$ と書く)



2^n 個のボールで
おおうために必要な
最小の半径 ε

定理 (Dudley の定理) 一般の G を成り立つ

z_1, \dots, z_n を固定する。

$$\hat{R}_n(G) \leq \frac{2}{\sqrt{n}} \left(\sum_{i=1}^{\infty} 2^{i/2} e_{2^i}(G \cup \{0\}, L_2(P_n)) + \sup_{g \in G} \|g\|_{L_2(P_n)} \right)$$

* 直感的には G を有限個の代表点で近似し、


その近似精度を粗いものから密なものまで上げ、 ε 中 $< (\varepsilon$ 中 $<$)
という操作に対応。

* カリリノフナンバー ε を用いた場合は、 $\hat{R}_n(G) \leq \frac{C}{\sqrt{n}} \int_0^{\sup_{g \in G} \|g\|_{L_2(P_n)}} \sqrt{\log N(\varepsilon, G \cup \{0\}, \| \cdot \|_{L_2(P_n)})} d\varepsilon$
である。

証明


$$T = \{ (g(z_1), \dots, g(z_n)) \mid g \in G \} \cup \{ (0, \dots, 0) \} \in \mathbb{R}^n$$

$$d(x, x') = \frac{1}{\sqrt{n}} \sum_{i=1}^n (x_i - x'_i)^2 \quad \text{とすると、} (T, d) \text{ は可分な距離空間。}$$



以後、 $\forall n \in \mathbb{N}$ $e_n(T, d)$ は有限だとし一般性を失わない。 $e_n(T, d) < \infty$

特に T は有界で、 $n \rightarrow \infty$ で $e_n(T, d) \rightarrow 0$ である。



$\Rightarrow T$ は有界


任意の $\varepsilon > 0$ に対し、

$$\rho_1 := \sup_{t \in T} d(t, 0)$$

$$\rho_{2^i} := (1/\varepsilon) \rho_{2^i}(T, d) \quad (i=1, 2, \dots)$$

とある。また、 $\forall i \geq 1$ に対し、 $\rho_{2^i} - \varepsilon$ に対し $T_i \in \mathcal{T}$ を $|T_i| \leq 2^{2^i - 1}$ なるものとして取り来る。
(インターポレーションの定義より可能)

$$\bigcup_{t \in T_i} \overline{B}d(t, \rho_{2^i}) \supseteq T \text{ なる } \mathcal{C} \text{ の}$$



$T_0 = \{0\}$ とする。また、 $\rho_j(T, d) \rightarrow 0$ ($j \rightarrow \infty$) かつ $\rho := \bigcup_{j=0}^{\infty} T_j$ に対し、

$$\sup_{t \in \rho} \frac{1}{n} \sum_{i=1}^n \rho_{2^i} \chi_{T_i}(t) = \sup_{t \in T} \frac{1}{n} \sum_{i=1}^n \rho_{2^i} \chi_{T_i}(t)$$

が成り立つ。まず、 T の外側は ρ を考慮しなす。

$j \geq 1$, $t \in T$ に対し、 $\pi_j(t) \in T_j$ を、 $d(t, \pi_j(t)) \leq \rho_{2^j}$ なるものとして取り来る。

特に、 $t \in T_j$ ならば $\pi_j(t) = t$ としておく。

$j \geq 1$ を 1 つ固定し、 γ_λ ($\lambda \leq j$) を

$$\gamma_\lambda = \pi_\lambda$$

$$\gamma_j = \pi_j$$

$$\gamma_{\lambda-1} = \pi_{\lambda-1} \circ \gamma_\lambda \quad (\lambda=1, \dots, j)$$

としておく。

当然、 $d(\gamma_\lambda(t), \gamma_{\lambda-1}(t)) \leq \rho_{2^{\lambda-1}}$ である。

$$h(t) := \frac{1}{n} \sum_{i=1}^n \rho_{2^i} \chi_{T_i}(t) \quad (t \in T)$$

と置く。


$t \in T_j$ となる。

$$h(t) = h(t) - 0$$

$$= \sum_{\lambda=1}^j (h(\gamma_\lambda(t)) - h(\gamma_{\lambda-1}(t))) \leq \sum_{\lambda=1}^j \max_{t \in T_\lambda} h(t) - h(\pi_{\lambda-1}(t))$$

とある。まず、 $S_k := T_0 \cup \dots \cup T_k$ に対し

$$\max_{t \in S_k} h(t) \leq \sum_{j=1}^k \max_{t \in T_j} \{h(t) - h(\pi_{j-1}(t))\}$$



次に、 T_j とし、有限集合の Rademacher 複雑度 (Massart の定理) [6]

$$E_{G_n} \left[\max_{t \in T_j} h(t) \right] \leq \sum_{j=1}^k E_{G_n} \left[\max_{t \in T_j} |h(t) - h(\pi_{j-1}(t))| \right]$$

$$\leq \sum_{j=1}^k \sqrt{\frac{2 \log(2^{2^j} - 1)}{n}} \nu_{2^j-1}$$

$J = \bigcup_{j=0}^{\infty} T_j$ となる。 $k \rightarrow \infty$ とすると、単調増大性より、

$$E_{G_n} \left[\sup_{t \in J} h(t) \right] \leq \sum_{j=0}^{\infty} \sqrt{\frac{4 \cdot 2^j}{n}} \nu_{2^j}$$

これは、 $\varepsilon \rightarrow 0$ とし、 $\rho_\varepsilon = \sup_t d(t, 0)$ とあること (注意すべし) 題意を ε だけ \parallel

示

$$R_n(\mathcal{F}) \leq \frac{2}{\sqrt{n}} \left(\sum_{j=1}^{\infty} E_{G_n} [e_{2^j}(\mathcal{F}, L_2(P_n))] 2^{j/2} + E \left[\sup_{g \in \mathcal{G}} \|g\|_{L_2(P_n)} \right] \right)$$

± RKH の エンタロピー 数は?

定理

カーネル関数 k の 正定 分解 できる:

$$k(x, x') = \sum_{i=1}^{\infty} \lambda_i \phi_i(x) \phi_i(x') \quad (\text{in } (X \times X, \mathbb{R} \times \mathbb{R}))$$

ただし、 $\lambda_i \geq 0$, $\{\phi_i\}$ は $L_2(P_x)$ 内の 正規直交系。

$$\lambda_i \leq a i^{-\frac{1}{p}} \quad (i \geq 1)$$

ある $0 < p < 1$ と あり、 $\mathcal{F} = \{f \in \mathcal{H} \mid \|f\|_{\mathcal{H}} \leq 1\}$ は、

$$E [e_n(\mathcal{F}, L_2(P_n))] \leq C_p a \min \{ i^{\frac{1}{2p}}, n^{\frac{1}{2p}} \} \cdot i^{-\frac{1}{p}} \leq C_p a i^{-\frac{1}{4}}$$

と あり。

証明は 略: Steinwart, Christmann "SVM" の Cor. 7.3]

定理

$\mathcal{F}_r = \{f \in \mathcal{F} \mid \|f\|_{L_2(P_n)} \leq r\}$ と すると、上の条件のもと、

$$R_n(\mathcal{F}_r) \leq C(p) \max \left\{ \frac{a^p r^{1-p}}{n}, n^{-\frac{1}{4p}} a^{\frac{2p}{4p}} \right\}$$

(略証)

$R = \min \{ i \mid r \geq C_p a i^{-\frac{1}{4p}} \}$ と すると、

$$R_n(\mathcal{F}_r) \leq \sum_{i=1}^R \frac{2^{i/2} \cdot r}{\sqrt{n}} + \sum_{i=R+1}^{\infty} \frac{2^{i/2} \cdot C_p a i^{-\frac{1}{4p}}}{\sqrt{n}} \approx \frac{a^p r^{1-p}}{n} \quad L_2(P_n) \text{ と } L_2(P_n) \text{ の } P_n \text{ に 差 がある}$$

の 2. 2. 2. の 確 率 あり。 \parallel

よ2.

$$G_r \subseteq \{f, f^* \mid f \in F \sqrt{\frac{r}{\alpha}}\} \quad (1)$$

$$R_c(G_r) \subseteq R_c(F \sqrt{\frac{r}{\alpha}}) \subseteq C \max\left(\frac{r^{\frac{1-p}{2}}}{T_n}, n^{-\frac{1}{4p}}\right)$$

よ2. 十分大なる n に対し $r = \eta_n n^{-\frac{1}{4p}}$ とおけば:

$$\phi(r) \subseteq R_c(G_r) \subseteq r$$

よ2. $L(\hat{f}) - L(f^*) \subseteq C \eta_n n^{-\frac{1}{4p}}$ である。

例: γ 核レフ空間 (d 次元, 帯域 $z \leq m$)

$$p = \frac{d}{2m}, \quad \text{収束レート} = n^{-\frac{2m}{2m+d}} \leftarrow \text{ため込存在ほど速い収束}$$

($2m > d$)

→ これは $\epsilon = \epsilon^2$ 最適