

◦ RKHS の Rademacher 複雑度

$$\mathcal{F} = \{ f \in H \mid \|f\|_H \leq R \}$$

$$k(x, x) \leq 1 \quad (\forall x \in X) \quad \sigma_i \in \mathcal{E}$$

$$\hat{R}_n(\mathcal{F}) = E_\sigma \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \sigma_i f(x_i) \right| \right]$$

$$= E_\sigma \left[\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \sigma_i \langle k(x_i, \cdot), f \rangle_H \right| \right]$$

$$= E_\sigma \left[\sup_{f \in \mathcal{F}} \left| \langle f, \frac{1}{n} \sum_{i=1}^n \sigma_i k(x_i, \cdot) \rangle_H \right| \right]$$

$$\leq E_\sigma \left[\sup_{f \in \mathcal{F}} \|f\|_H \left| \left\langle \frac{1}{n} \sum_{i=1}^n \sigma_i k(x_i, \cdot), \frac{1}{n} \sum_{i=1}^n \sigma_i k(x_i, \cdot) \right\rangle_H \right| \right]$$

$$\leq R E_\sigma \left[\sqrt{\frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n \sigma_i \sigma_j k(x_i, x_j)} \right]$$

$$\leq R \sqrt{E_\sigma \left[\frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n \sigma_i \sigma_j k(x_i, x_j) \right]}$$

$$= R \sqrt{\frac{1}{n^2} \sum_{i=1}^n k(x_i, x_i)} \leq \frac{R}{\sqrt{n}} //$$

カーネル法の学習効率

モデル: $y_i = f^0(x_i) + \varepsilon_i \quad (i=1, \dots, n)$
 $x_i \sim P_X, \varepsilon_i \sim N(0, \sigma^2) \quad (\text{i.i.d.})$
↑
サンプルサイズ

カーネルリッジ回帰: $\hat{f} = \arg \min_{f \in \mathcal{H}} \frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2 + \lambda \|f\|_{\mathcal{H}}^2$

推定誤差: $\|\hat{f} - f^0\|_{L^2(P_X)}^2 := \mathbb{E}[(\hat{f}(X) - f^0(X))^2]$
↑
テストデータ: $X \sim P_X$ の期待値取る

Q: サンプルサイズ $n \rightarrow \infty$ でどれだけ速く $\|\hat{f} - f^0\|_{L^2}^2 \rightarrow 0$ か?

2乗損失を用いると解が陽に書けるので、
 この形を用いた解析を紹介

$\Sigma: \mathcal{H} \rightarrow \mathcal{H}, \hat{\Sigma}: \mathcal{H} \rightarrow \mathcal{H}$ を次のように定義:

$\Sigma = \mathbb{E}_x [k_x k_x^*], \quad \hat{\Sigma} = \frac{1}{n} \sum_{i=1}^n k_{x_i} k_{x_i}^*$
← $k_x^* f = \langle k_x, f \rangle_{\mathcal{H}}$ とおす

つまり、 $f \in \mathcal{H}$ に対し、
 $\Sigma f = \int k_x k_x^* f \, dP_X(x) = \int k_x f(x) \, dP_X(x)$
 $\hat{\Sigma} f = \frac{1}{n} \sum_{i=1}^n k_{x_i} f(x_i)$

とある。
 $g^0 \in \mathcal{H}, g \in \mathcal{H}$ を次のように定義: ($f^0 \in L^2(P_X)$ は仮定 (2) おく)

$g^0 := \mathbb{E}_x [k_x f^0(x)] = \int k_x f^0(x) \, dP_X(x)$
 $g = \frac{1}{n} \sum_{i=1}^n k_{x_i} y_i$

$\Rightarrow \begin{cases} f_\lambda := (\Sigma + \lambda I)^{-1} g^0 \\ \hat{f} = (\hat{\Sigma} + \lambda I)^{-1} g \end{cases}$ \mathcal{H} 定義上より
↑ f の定義より

以後, 簡単のため $f^0 \in \mathcal{H} \subset \mathcal{L}$. $\mathcal{H} \hookrightarrow L^2(\mathbb{R}^d)$ とする.

また, $f \in \mathcal{H}$ も自然な埋め込みを用いて $f \in L^2(\mathbb{R}^d)$ とみなす.

$$\| \hat{f} - f^0 \|_{L^2}^2 \leq 2 \left(\underbrace{\| f^0 - f_\lambda \|_{L^2}^2}_{\substack{\text{バイアス} \\ !! \\ A(\lambda)}} + \underbrace{\| f_\lambda - \hat{f} \|_{L^2}^2}_{\substack{\text{バリエーション} \\ !! \\ V(\lambda)}} \right)$$

と, 「バイアス-バリエーション分解」を \mathcal{L} におく.

バリエーションの公平性を示す.

$f_\lambda = (\Sigma + \lambda I)^{-1} \Sigma f^0$ に注意すると.

$$\begin{aligned} f_\lambda - \hat{f} &= f_\lambda - (\hat{\Sigma} + \lambda I)^{-1} \hat{g} \\ &= f_\lambda - (\hat{\Sigma} + \lambda I)^{-1} (\hat{g} - \hat{\Sigma} f^0) - (\hat{\Sigma} + \lambda I)^{-1} \hat{\Sigma} f^0 \\ &= f_\lambda - (\hat{\Sigma} + \lambda I)^{-1} \hat{\Sigma} f^0 - (\hat{\Sigma} + \lambda I)^{-1} (\hat{g} - \hat{\Sigma} f^0) \\ &= (\hat{\Sigma} + \lambda I)^{-1} \left[(\hat{\Sigma} + \lambda I)(f_\lambda - f^0) + \lambda f^0 \right] \\ &\quad - (\hat{\Sigma} + \lambda I)^{-1} (\hat{g} - \hat{\Sigma} f^0) \\ &= (\hat{\Sigma} + \lambda I)^{-1} (\hat{\Sigma} - \Sigma)(f_\lambda - f^0) \quad \leftarrow \lambda \text{ の不確かさ} \\ &\quad - (\hat{\Sigma} + \lambda I)^{-1} (\hat{g} - \hat{\Sigma} f^0) \quad \leftarrow \hat{g} \text{ の不確かさ} \end{aligned}$$

$$\begin{aligned} &= (\Sigma + \lambda I) f^0 \\ &\quad - \Sigma f^0 \\ &= (\Sigma + \lambda I) f^0 \\ &\quad - (\Sigma + \lambda I) f_\lambda \\ &= (\Sigma + \lambda)(f^0 - f_\lambda) \end{aligned}$$

となり,

$$\| f_\lambda - \hat{f} \|_{L^2}^2 \leq 2 \| (\hat{\Sigma} + \lambda I)^{-1} (\hat{\Sigma} - \Sigma)(f_\lambda - f^0) \|_{L^2}^2 + 2 \| (\hat{\Sigma} + \lambda I)^{-1} (\hat{g} - \hat{\Sigma} f^0) \|_{L^2}^2$$

$\leftarrow \tau_1(\lambda)$
 $\leftarrow \tau_2(\lambda)$ とおく

を得る.

つまり,

$$\| \hat{f} - f^0 \|_{L^2}^2 \leq 2 A(\lambda) + 4 \tau_1(\lambda) + 4 \tau_2(\lambda)$$

定義 $B(\lambda) := \| f_\lambda - f^0 \|_{\mathcal{H}}$ (再構成コスト)

自由度 $N(\lambda) := \text{Tr} \left[(\Sigma + \lambda I)^{-1} \Sigma \right]$ (自由度)
degrees of freedom

(以後, $\frac{d}{2}(\lambda, \lambda) \leq 1$ とおす)

$$\sum_{j=0}^{\infty} \frac{\mu_j}{\mu_j + \lambda}$$

$\mu_j = 1 \quad (j=1, \dots, d)$
 $\mu_j = 0 \quad (j > d)$
 $\Rightarrow N(\lambda) = \frac{d}{1+\lambda}$

$\boxed{V_1}$ + 最大主成分の方向

$$V_1(\lambda) \leq c \left[\frac{\lambda^{-1} A(\lambda)}{n} + \frac{\lambda^{-1} B(\lambda)}{n^2} \right] \rho_{\delta}^2\left(\frac{1}{\delta}\right)$$

確率 $1 - \delta$ で成り立つ ($\delta > 0$). なお, c は定数.

$\boxed{V_2}$ ← この方が重要項

$$V_2(\lambda) \leq c \left[\frac{\sigma^2 N(\lambda)}{n} + \frac{\lambda^{-1}}{n^2} \right] \rho_{\delta}^2\left(\frac{1}{\delta}\right)$$

確率 $1 - \delta$ で成り立つ.

V_2 を示す方向に解説する.

Σ の定義より,

$$V_2(\lambda) = \left\| \sqrt{\Sigma} (\hat{\Sigma} + \lambda I)^{-1} (\hat{g} - \hat{\Sigma} f^0) \right\|_{\mathcal{H}}^2$$

$$= \left\| \sqrt{\Sigma} (\hat{\Sigma} + \lambda I)^{-1} (\Sigma + \lambda I)^{\frac{1}{2}} (\Sigma + \lambda I)^{-\frac{1}{2}} (\hat{g} - \hat{\Sigma} f^0) \right\|_{\mathcal{H}}^2$$

$$\leq \left\| \sqrt{\Sigma} (\hat{\Sigma} + \lambda I)^{-1} (\Sigma + \lambda I)^{\frac{1}{2}} \right\|_{\mathcal{L}(\mathcal{H})} \left\| (\Sigma + \lambda I)^{-\frac{1}{2}} (\hat{g} - \hat{\Sigma} f^0) \right\|_{\mathcal{H}}^2$$

$$\times \left\| (\Sigma + \lambda I)^{-\frac{1}{2}} (\hat{g} - \hat{\Sigma} f^0) \right\|_{\mathcal{H}}^2$$

• $\left\| \sqrt{\Sigma} (\hat{\Sigma} + \lambda I)^{-1} (\Sigma + \lambda I)^{\frac{1}{2}} \right\|_{\mathcal{L}(\mathcal{H})}$ の Bound

$$\leq \left\| (\Sigma + \lambda I)^{\frac{1}{2}} (\hat{\Sigma} + \lambda I)^{-1} (\Sigma + \lambda I)^{\frac{1}{2}} \right\|_{\mathcal{L}(\mathcal{H})}$$

$$= \left\| (\Sigma + \lambda I)^{\frac{1}{2}} (\hat{\Sigma} - \Sigma + \Sigma + \lambda I)^{-1} (\Sigma + \lambda I)^{\frac{1}{2}} \right\|_{\mathcal{L}(\mathcal{H})}$$

$$= \left\| \left[(\Sigma + \lambda I)^{-\frac{1}{2}} (\hat{\Sigma} - \Sigma) (\Sigma + \lambda I)^{-\frac{1}{2}} + I \right]^{-1} \right\|_{\mathcal{L}(\mathcal{H})}$$

↓
この最大値を具積する
作用素 Bernstein の不等式

定理 (作用素値確率変数の Bernstein の不等式)

- \mathcal{H} : 可分なヒルベルト空間
 - X_1, \dots, X_n : \mathcal{H} 上の自己共役作用素に値を取る i.i.d. 確率変数
 - $E[X_i] = 0$
 - $\|X_i\| \leq M$ (a.s.)
 - $E[X_i^2] \leq S$ (S は 半正定値自己共役作用素)
- 2.9.22. $\forall \delta \in (0, 1)$ に対し.

$$P\left(\left\|\frac{1}{n}\sum_{i=1}^n X_i\right\| \leq \sqrt{\frac{2\|S\|\beta}{n}} + \frac{2M\beta}{n}\right) \geq 1 - \delta,$$

ただし $\beta = \beta_\delta\left(\frac{2\|S\|}{\|S\|\delta}\right)$.

$$X_i = (\Sigma + \lambda I)^{-\frac{1}{2}} (P_{X_i} P_{X_i}^* - \Sigma) (\Sigma + \lambda I)^{-\frac{1}{2}} \quad \text{と可視化}$$

$$\begin{aligned} E[X_i] &= 0, \quad \|X_i\| \leq \|(\Sigma + \lambda I)^{-\frac{1}{2}} \Sigma (\Sigma + \lambda I)^{-\frac{1}{2}}\| + \\ &\quad \|(\Sigma + \lambda I)^{-\frac{1}{2}} P_{X_i} P_{X_i}^T (\Sigma + \lambda I)^{-\frac{1}{2}}\| \\ &\leq 1 + \sup_{x \in \text{supp}(P_x)} \langle P_x, (\Sigma + \lambda I)^{-1} P_x \rangle_{\mathcal{H}} \\ &\leq 1 + \sup_x \frac{1}{\lambda} \underbrace{\langle P_x, P_x \rangle_{\mathcal{H}}}_{E(1, x)} \leq 1 + \frac{1}{\lambda} =: M \end{aligned}$$

$$\begin{aligned} E[X_i^2] &\leq E_x \left[(\Sigma + \lambda I)^{-\frac{1}{2}} P_x P_x^* (\Sigma + \lambda I)^{-1} P_x P_x^* (\Sigma + \lambda I)^{-\frac{1}{2}} \right] \\ &\leq \sup_x \langle P_x, (\Sigma + \lambda I)^{-1} P_x \rangle_{\mathcal{H}} E_x \left[(\Sigma + \lambda I)^{-\frac{1}{2}} P_x P_x^* (\Sigma + \lambda I)^{-\frac{1}{2}} \right] \\ &\leq \frac{1}{\lambda} (\Sigma + \lambda I)^{-\frac{1}{2}} \Sigma (\Sigma + \lambda I)^{-\frac{1}{2}} = S \end{aligned}$$

つまり $\|S\| \leq \frac{1}{\lambda} \varepsilon(A) \cup \delta \varepsilon$.

$$P \left(\left\| (\Sigma + \lambda I)^{-\frac{1}{2}} (\hat{\Sigma} - \Sigma) (\Sigma + \lambda I)^{-\frac{1}{2}} \right\| \leq \sqrt{\frac{2\beta}{\lambda n}} + \frac{2(1 + \frac{1}{\lambda})\beta}{n} \right)$$

$$\beta = \log \left(\frac{2 \text{Tr}[\Sigma(\Sigma + \lambda I)^{-1}]}{\|\Sigma(\Sigma + \lambda I)^{-1}\| \delta} \right) \geq 1 - \delta,$$

2. ある.

$$\left[\begin{array}{l} \text{十分小さい } \lambda \text{ を選べば, } \|\Sigma(\Sigma + \lambda I)^{-1}\| \geq \frac{1}{2} \text{ である.} \\ (\lambda \leq \|\Sigma\| \text{ とおす}) \\ \Rightarrow \beta = \log \left(\frac{4N(\lambda)}{\delta} \right) \end{array} \right]$$

よ. z. $\frac{1}{n\lambda} \ll 1$ とおす $\ll n$ かつ十分大 $\pm 1 + \frac{1}{n}$ だけ.

$$\left\| (\Sigma + \lambda I)^{-\frac{1}{2}} (\hat{\Sigma} - \Sigma) (\Sigma + \lambda I)^{-\frac{1}{2}} \right\| \leq \frac{1}{2}$$

か高い確率で成り立つ?

$$\Rightarrow \left\| \Sigma (\hat{\Sigma} + \lambda I)^{-1} (\Sigma + \lambda I)^{\frac{1}{2}} \right\|_{L(\mathcal{H})} \leq 2$$

• $\left\| (\Sigma + \lambda I)^{-\frac{1}{2}} (\hat{\theta} - \Sigma f^0) \right\|_{\mathcal{H}}$ の評価

$$\begin{aligned} (\Sigma + \lambda I)^{-\frac{1}{2}} (\hat{\theta} - \Sigma f^0) &= \frac{1}{n} \sum_{i=1}^n (\Sigma + \lambda I)^{-\frac{1}{2}} (\overset{f(x_i) + \varepsilon_i}{\mathbb{P}_{x_i} \hat{y}_i} - \mathbb{P}_{x_i} f^0(x_i)) \\ &= \frac{1}{n} \sum_{i=1}^n \underbrace{(\Sigma + \lambda I)^{-\frac{1}{2}} \mathbb{P}_{x_i}}_{!!} \varepsilon_i \\ &\quad \sum(x_i, \varepsilon_i) \text{ とおす.} \end{aligned}$$

$\rightarrow \left\| \frac{1}{n} \sum_{i=1}^n \sum(x_i, \varepsilon_i) \right\|_{\mathcal{H}}^2 \in \text{Bound}$ だ.

$E_{x, \varepsilon} [\sum(x, \varepsilon)] = 0$ に注意だ.

定理 (Bernsteinの不等式)

- \mathcal{H} : 可分なヒルベルト空間

- ξ_i : \mathcal{H} に値をとり i.i.d. 確率変数,

$$E[\xi_i] = 0 \text{ かつ } E[\|\xi_i\|_{\mathcal{H}}^m] \leq \frac{1}{2} m! \nu M^{m-2} \quad (\forall m \geq 2)$$

$$P \left(\left\| \frac{1}{n} \sum_{i=1}^n \xi_i \right\|_{\mathcal{H}} \leq 2 \left(\sqrt{\frac{\nu}{n}} + \frac{M}{n} \right) \log\left(\frac{2}{\delta}\right) \right) \geq 1 - \delta \quad (\forall \delta \in (0, 1))$$

$\xi_i \in \mathcal{H}$. $\xi(x_i, \varepsilon_i) \in \mathcal{H}$ である。

$$\begin{aligned}
 & E \left[\left\| \xi(x_i, \varepsilon_i) \right\|_{\mathcal{H}}^m \right] \\
 & \leq \sqrt{E \left[\left\| \xi(x_i, \varepsilon_i) \right\|_{\mathcal{H}}^{2m} \right]} \\
 & \leq \sqrt{E_{\varepsilon_i} \left[|\varepsilon_i|^{2m} \right]} \cdot \left(\int \left\| k_x(\Sigma + \lambda I)^{-\frac{1}{2}} \right\|_{\mathcal{H}}^{2m} dP_x(x) \right)^{\frac{1}{2}} \\
 & \leq \sqrt{(2m-1)!! \sigma^{2m}} \cdot \left(\int \langle k_x, (\Sigma + \lambda I)^{-1} k_x \rangle_{\mathcal{H}} dP_x(x) \right)^{\frac{1}{2}} \times \\
 & \quad \left(\sup_x \langle k_x, (\Sigma + \lambda I)^{-1} k_x \rangle_{\mathcal{H}} \right)^{\frac{m-2}{2}} \quad \text{--- } N(\lambda) \\
 & \leq \frac{1}{2} m! \underbrace{\left(\sigma \sqrt{N(\lambda)} \right)^2}_{\sigma^2} \underbrace{\left(\sqrt{\frac{2}{\lambda}} \right)^{m-2}}_{\frac{1}{\lambda}}
 \end{aligned}$$

よって、

$$P \left(\left\| \frac{1}{n} \sum_{i=1}^n \xi(x_i, \varepsilon_i) \right\|_{\mathcal{H}} \leq 2 \left(\sqrt{\frac{\sigma^2 N(\lambda)}{n}} + \frac{1}{n} \sqrt{\frac{2}{\lambda}} \right) \rho_f \left(\frac{2}{\delta} \right) \right) \geq 1 - \delta$$

である。よって、

$$\left\| (\Sigma + \lambda I)^{-\frac{1}{2}} (\hat{g} - \Sigma f^*) \right\|_{\mathcal{H}}^2 \leq \delta \left(\underbrace{\frac{\sigma^2 N(\lambda)}{n}}_{\substack{\uparrow \\ \text{自由度の逆数}}} + \frac{2}{n^2 \lambda} \right) \rho_f^2 \left(\frac{2}{\delta} \right)$$

が確率 $1 - \delta$ で成り立つ。

*** 補足:**

$$\begin{aligned}
 & E \left[\left\| \xi(x_i, \varepsilon_i) \right\|_{\mathcal{H}}^2 \right] \\
 & = \underbrace{E \left[\varepsilon_i^2 \right]}_{\sigma^2} \cdot \underbrace{E_x \left[\left\| k_x (\Sigma + \lambda I)^{-\frac{1}{2}} \right\|_{\mathcal{H}}^2 \right]}_{\substack{\text{---} \\ E_x \left[\langle (\Sigma + \lambda I)^{-\frac{1}{2}} k_x, (\Sigma + \lambda I)^{-\frac{1}{2}} k_x \rangle_{\mathcal{H}} \right] \\ \text{---} \\ E_x \left\{ \text{Tr} \left[k_x k_x^* (\Sigma + \lambda I)^{-1} \right] \right\} \\ \text{---} \\ \text{Tr} \left[\Sigma (\Sigma + \lambda I)^{-1} \right] : \text{自由度}}}
 \end{aligned}$$

以上をまとめると.

$$\|f - f^0\|_{L^2(P_x)}^2 \approx \underbrace{A(\lambda)} + \underbrace{\left(\frac{\sigma^2 N(\lambda)}{n} + \frac{\lambda^{-1} A(\lambda)}{n} + \frac{1}{n^2} (\lambda^{-1} B(\lambda) + \lambda^{-1})\right)}_{\substack{\uparrow \\ \text{この2項が主要項に相当する。}}} B^2(f)$$

with prob. $1 - \delta$.

$A(\lambda), N(\lambda), B(\lambda)$ 等を評価するために、いくつかの仮定を置く。
(カーネル法の理論では標準的)

仮定

1. ある $r \geq \frac{1}{2}$ が存在して、 $f^0 \in T_{K^r} L^2(P_x)$.
つまり、 $\exists h^0 \in L^2(P_x)$ で $f^0 = T_{K^r} h^0$

$$T_{K^r} f(x) := \int K(x, \cdot) f(\cdot) dP_x(x)$$

\uparrow
カーネル関数を使う。

$\leftarrow r \geq \frac{1}{2}$ より $f^0 \in \mathcal{H}$ である。

2. P_x に対する K の Mercer 展開

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

($\mu_1 \geq \mu_2 \geq \dots \geq 0$, $(e_i)_i$ は $L^2(P_x)$ 内の正規直交系)

が可能なと仮定する。このとき、 $\exists \alpha > 1$ で

$$\mu_i \lesssim i^{-\alpha}$$

意味: 1. f^0 の "滑らかさ" を表す。 r が大きいほど滑らか。
 \rightarrow より $RKHS$ の中にいる。

2. $RKHS$ の "複雑さ" を表す。 α が大きいほど単純。
 $\leftarrow \alpha$ は P_x に依存

($\lambda \rightarrow 0$ を参照)

$$\Rightarrow \begin{cases} \cdot A(\lambda) \leq \lambda^{2r} \|h^0\|_{L^2(P_x)}^2 \\ \cdot N(\lambda) \lesssim \lambda^{-\alpha} \end{cases}$$

$\leftarrow r$ が大きいと、バイアスが速く 0 に収束

$\leftarrow \alpha$ が大きいと、バリエーションが速く大きくなる。

$$B(\lambda) \leq \lambda^{2r-1} \|h^0\|_{L^2(P_x)}^2$$

主要項を計算すると.

$$\text{推定誤差} \lesssim \lambda^{2r} + \frac{\lambda^{-\alpha}}{n}$$

バイアス バリエーション

バイアスとバリエーションのバランスを

$$\lambda = n^{-\frac{\alpha}{2r\alpha+1}}$$

とすれば

$$n^{-\frac{2r\alpha}{2r\alpha+1}}$$

(λ 項を無視して)

$$\|\hat{f} - f^0\|_{L^2}^2 \leq n^{-\frac{2rd}{2rd+1}}$$

は mini-max 最適レート と呼ばれる。

定理 (mini-max 最適レート)

$$\inf_{\hat{f}: \text{推定量}} \sup_{\substack{f^0 \in \mathcal{H}: \\ f^0 = T_{\mathbb{R}^d}^{\frac{r}{2}} h^0, \|h^0\|_{L^2(\mathbb{R}^d)} \leq 1}} \mathbb{E} [\|\hat{f} - f^0\|_{L^2(\mathbb{R}^d)}^2] \geq n^{-\frac{2rd}{2rd+1}}$$

つまり、最悪誤差はどんな推定量を用いても $n^{-\frac{2rd}{2rd+1}}$ を超えられない。

→ リッジ回帰は (ほぼ) 最適

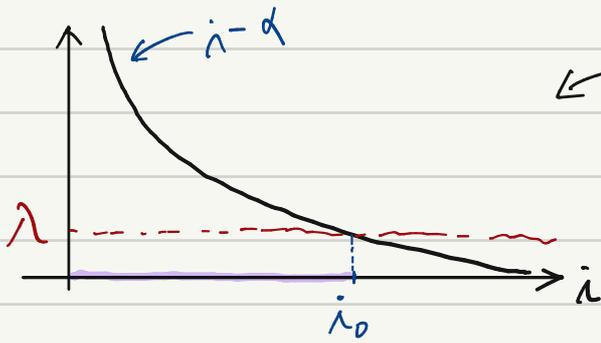
↳ 次ページに続く

◎ 自由度 $N(\lambda)$ の意味について (重要)

$$N(\lambda) = \text{Tr}[\Sigma(\Sigma + \lambda I)^{-1}] = \sum_{i=1}^{\infty} \frac{\mu_i}{\mu_i + \lambda}$$

正定値行列 Σ を考える。今 $\mu_i = O(i^{-\alpha})$ ($\alpha > 1$) ならば

$N(\lambda)$ は おおよそ $\sum_{i=1}^{\infty} \frac{i^{-\alpha}}{i^{-\alpha} + \lambda}$ でおおざらめ。 (これは $O(\lambda^{-\frac{1}{\alpha}})$)



← このように、固有値 λ で切ると、
 λ 以上の固有値の個数 i_0 を数えよと、

$$i_0^{-\alpha} \approx \lambda \Rightarrow \underline{i_0 \approx \lambda^{-\frac{1}{\alpha}}}$$

つまり、 $i_0 \approx N(\lambda)$

自由度は、 λ 以下の固有値に対応する固有ベクトル空間を無視した有限次元空間の次元 \rightarrow カーネルレギュラリゼーションはこの有限次元空間に制限して学習していることに相当する。

$$H \ni f^{\circ} = \sum_{i=1}^{\infty} \alpha_i e_i(x) \xrightarrow{\text{近似}} \sum_{i=1}^{i_0} \alpha_i e_i(x) \quad (i_0 \approx N(\lambda))$$

↑
近似する $A(\lambda): \lambda^{2r}$

自由度 $N(\lambda)$ は λ の選択にも用いられる \rightarrow Mallows' C_p 規準

AIC と同様の効果: AIC はモデル選択における次元の決定に使われる。
 Mallows' C_p 規準では、AIC でおこる次元の λ の代わりに $N(\lambda)$ を用いる。



つまり、 λ の選択もできる。

カーネル法が無限次元モデルにもかかぬらば、過学習せず適切な推定ができるのは、この $N(\lambda)$ が有限になるからである。

↑ つまり、有限次元モデルで近似できる

- RKHS の covering number

$\mathcal{B}(H)$: H の単位球

$$\mu_i \leq c i^{-\alpha} \implies \begin{cases} \log N(\mathcal{B}(H), \varepsilon, \|\cdot\|_{L^2(\mathbb{R}^k)}) \leq \varepsilon^{-\frac{2}{\alpha}} \\ e_n(\mathcal{B}(H), \|\cdot\|_{L^2(\mathbb{R}^k)}) \leq n^{-\frac{\alpha}{2}} \end{cases}$$

$$\lambda = \varepsilon^2 \text{ を代入すれば. } \log N(\dots) \leq \lambda^{-\frac{1}{\alpha}} \cong N(\lambda)$$

$$\longrightarrow \|f\|_{L^2(\mathbb{R}^k)}^2 \leq \lambda \text{ かつ } 0 \text{ と同一視すれば残りの次元は } N(\lambda)$$

先の局所 Rademacher 複雑度を用いた fast rate

$$\implies \underline{n^{-\frac{1}{1+\frac{1}{\alpha}}} = n^{-\frac{\alpha}{\alpha+1}} \quad (r = \frac{1}{\alpha} \text{ の } L(-))$$

$$\begin{aligned} \text{ちなみに. } & \mathbb{E} \left[R_n \left(\{f \in \mathcal{F} \mid Pf^2 \leq r, \|f\|_H \leq 1\} \right) \right] \\ & \leq \left(\frac{2}{n} \sum_{i=1}^{\infty} \min \{r, \mu_i\} \right)^{\frac{1}{2}} \end{aligned}$$

とある. (Mendelson: Geometric parameters of kernel machines. COLT2002. pp. 29-43.)