

Def. (Covering number, 被覆数)

$F: \mathbb{R}^d \rightarrow \mathbb{R}$  の関数の集合

$d$ :  $F$  の距離

$F$  の  $\epsilon$ -被覆数 =  $N(\epsilon, F, d) := \min \left\{ m \geq 1 \mid \exists f_1, \dots, f_m \in F \text{ s.t. } \forall f \in F \text{ (2つ) } \exists f_j \text{ s.t. } d(f, f_j) \leq \epsilon \right\}$

$F$  の  $\epsilon$ -被覆と書く

任意の点  $x_1, \dots, x_n \in \mathbb{R}^d$  に対し,  
 $\|f\|_{n,p} := \left( \frac{1}{n} \sum_{i=1}^n |f(x_i)|^p \right)^{1/p} \quad (1 \leq p < \infty)$

とすると

Thm  $f \in F$  の  $\|f\|_0 \leq R$  であるならば、ある  $x_1, \dots, x_n \in \mathbb{R}^d$  が存在して

$$R_n(F) \leq \inf_{d \geq 0} \left\{ d + R \sqrt{\frac{2 \log N(d, F, \|\cdot\|_{n,1})}{n}} \right\}$$

Proof  $f \in F$  に対し、 $v[f] \in \mathbb{R}$  - 値に近い  $\epsilon$ -被覆数の点と選ぶ ( $\|f - v[f]\|_{n,1} \leq \epsilon$ )

$$\begin{aligned} R_n(F) &= E_G \left[ \sup_{f \in F} \frac{1}{n} \sum_{i=1}^n G_i f(x_i) \mid x_1, \dots, x_n \right] \\ &= E_G \left[ \sup_{f \in F} \frac{1}{n} \sum_{i=1}^n G_i (f(x_i) - v[f](x_i)) + \frac{1}{n} \sum_{i=1}^n G_i v[f](x_i) \right] \\ &\leq E_G \left[ \sup_{f \in F} \frac{1}{n} \sum_{i=1}^n G_i (f(x_i) - v[f](x_i)) \right] + E_G \left[ \sup_{f \in F} \frac{1}{n} \sum_{i=1}^n G_i v[f](x_i) \right] \\ &\leq \sup_{f \in F} \frac{1}{n} \sum_{i=1}^n |f(x_i) - v[f](x_i)| + E_G \left[ \max_{1 \leq j \leq n} N(d, F, \|\cdot\|_{n,1}) \frac{1}{n} \sum_{i=1}^n G_i v_j(x_i) \right] \\ &\leq \alpha + R \sqrt{\frac{2 \log N}{n}} \quad (\because \text{Massart の不等式}) \end{aligned}$$

$p \geq 1$  ならば

$N(d, F, \|\cdot\|_{n,p}) \leq N(d, F, \|\cdot\|_{n,1})$  であるから、右辺の各項は  $N(d, F, \|\cdot\|_{n,p})$  ( $p \geq 1$ ) に置き換えられる

Thm (Dudley の不等式)

ある  $x_1, \dots, x_n \in \mathbb{R}^d$  が存在して  $\delta := \sup_{f \in F} \|f\|_{n,2}$  とすると

$$R_n(F) \leq \inf_{d \geq 0} \left\{ 4d + \frac{12}{\sqrt{n}} \int_d^\delta \sqrt{\log N(\epsilon, F, \|\cdot\|_{n,2})} \cdot d\epsilon \right\}$$

成り立つ。

-  $F$  を有限個で近似し、近似精度を粗いものから密なもの  $\lambda$  まで  $2^k$  中  $k$  を  $\lambda$  に  $2^k$  とし、  
 どのように操作すればよいか。  
 - 元の関数  $f$  の性質に依存して  $\lambda$  を決める。  
 (証明は略)

-  $10^9 \times 9 + 10^9 = 10^9 \times 10$

ReLU と BN

$$F_{L,S,B} := \{ (W^{(L)} + b^{(L)}) \circ \eta \circ (W^{(L-1)} + b^{(L-1)}) \circ \dots \circ \eta \circ W^{(1)} x \mid$$

$$\sum_{l=1}^L \|W^{(l)}\|_0 + \sum_{l=1}^L \|b^{(l)}\|_0 \leq \epsilon, \max_l \{ \|W^{(l)}\|_\infty, \|b^{(l)}\|_\infty \} \leq B,$$

$$W^{(l)} \in \mathbb{R}^{m_l \times m_{l-1}}, b^{(l)} \in \mathbb{R}^{m_l} \}$$

また  $\|W\|_0 = w$ ,  $\eta$  は ReLU と  $\eta(x) = \max\{-1, \min\{1, x\}\}$  のとき  $\|W\|_\infty = \max_{i,j} |W_{ij}|$  である。

$$F_{L,S,B} = \{ f(x) = \max\{-1, \min\{1, f(x)\}\} \mid f \in F_{L,S,B} \}$$

clipping  $\pm 1$  の間に挟む。

Len (Schmidt-Hieber, 2017)  
 $\max_x m_L \leq D$  とする。

$$\beta_{\mathcal{F}}(L, F_{L,S,B}, \|\cdot\|_0) \leq 2 \sqrt{L} \beta_{\mathcal{F}}(L(BvI) \cdot D, \epsilon^{-1}) //$$

- VC次元  $\mathcal{O}(\sqrt{L} \beta_{\mathcal{F}}(S))$ : Harvey, Liaw, Mehrabian, 2017.

2nd F1.

$$\hat{R}_n(F_{L,S,B}) \leq \inf_{d>0} \left\{ d + R \sqrt{\frac{2 \beta_{\mathcal{F}}(L, F_{L,S,B}, \|\cdot\|_0)}{n}} \right\} \quad (R = \sup_{f \in \mathcal{F}} \|f\|_\infty)$$
$$\leq 4R \sqrt{\frac{SL \beta_{\mathcal{F}}(L(BvI) \cdot D, \eta)}{n}} \quad (d = \frac{1}{n} \in 16\lambda)$$

$\times$  Rad Bound:  $\forall l, \forall i \|W_{i,:}^{(l)}\|_2 \leq B_1, \|x\|_\infty \leq 1$  の条件下で  $\epsilon$  を満たす。  
 $R \leq B_1^2 \epsilon$  である。

$\hookrightarrow$   $B_1$  は  $L$  に  $\epsilon$  の指数的に増大

$$\text{一応. } \hat{R}_n(F_{L,S,B}) \leq 4 \sqrt{\frac{SL \beta_{\mathcal{F}}(L(BvI) \cdot D, \eta)}{n}} \leftarrow \text{clip する = } \epsilon \text{ を } \epsilon \text{ の } \epsilon \text{ 程度に抑える。}$$

$\downarrow$

Batch-Normalization  
ResNet  
の安定性

- Fast learning rate  $\hookrightarrow$  局所 Rademacher 複雑性

$$L(f) - L(f^*) \leq \sup_{g \in G} (P - P_n)g \quad \text{は R-ス-オ-である。}$$

- 推定量  $f^*$  は  $f^*$  の "近く" に  $L$  は  $f^*$  の  $\alpha$  近傍に存在する。より "局所的" な  $L$  の性質を用いて  
 - モデル  $f$  が  $f^*$  に近ければ、 $L(f) - L(f^*)$  が  $L$  の  $\alpha$  近傍に存在する

仮定

$$\left[ \begin{array}{l} - L \text{ は 強凸} \cdot \text{ある } \alpha > 0 \text{ が存在して } \forall f \in F \text{ に対し } \\ \frac{\alpha}{2} \|f - f^*\|_{L_2(P_n)}^2 \leq L(f) - L(f^*) \end{array} \right. \leftarrow \left[ \begin{array}{l} L(f, f) = (f - f^*)^2 \text{ である} \\ \|f\|_{L_\infty} \leq 1, \|f^*\|_{L_\infty} \leq 1 \\ (f \in F) \text{ が } \beta \text{ である} \end{array} \right]$$

-  $L$  の  $\alpha$  近傍の仮定が満たされている (  $L$  は  $L_1$  ノルムで連続、  $\|f\|_{L_\infty} \leq M$  )

$$G_r := \{ g = f - f^* \in G \mid P_n g = L(f) - L(f^*) \leq r, f \in F \}$$


$R_n(G_r)$  を 局所 Rademacher 複雑性 とする

\*  $L$  の  $\alpha$  連続性と強凸性

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

$$\text{から } P_n g \leq r \text{ なら } \|g\|_{L_2(P_n)} \leq \sqrt{\frac{2r}{\alpha}}$$

$$\|f - f^*\|_{L_2(P_n)} \leq \frac{2r}{\alpha} \quad \leftarrow \text{汎化誤差が } f \text{ が } f^* \text{ に近いほど}$$



Thm (Peeling)

給  $\phi: [0, \infty) \rightarrow [0, \infty)$  単調増加関数  $\phi$ . 各  $r > 0$  に対して  $\phi(4r) \geq 2\phi(r)$

$$\phi(4r) \leq 2\phi(r) \quad \text{なら } \phi(r) \geq \frac{1}{2}\phi(4r) \quad (\text{これはモデルの個数を表す})$$

$$R_n(G_r) \leq \phi(r)$$

ならば  $\forall r > r^*$  に対し

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

Proof

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

両辺期待値をとる

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

$$\text{Excess risk} \leq \epsilon \Rightarrow \|f - f^*\|_{L_2(P_n)} \leq \epsilon + \delta$$

$$\begin{aligned} \|f - f^*\|_{L_2(P_n)}^2 - \|f^* - f^*\|_{L_2(P_n)}^2 &= \|f - f^* + f^* - f^*\|_{L_2(P_n)}^2 - \|f^* - f^*\|_{L_2(P_n)}^2 \\ &= \|f - f^*\|_{L_2(P_n)}^2 + 2\langle f - f^*, f^* - f^* \rangle - \|f^* - f^*\|_{L_2(P_n)}^2 \\ &\leq \|f - f^*\|_{L_2(P_n)}^2 - 2\|f^* - f^*\|_{L_2(P_n)}^2 \end{aligned}$$

Thm (Talagrandの集中不等式)

$(Z, \mathcal{A}, P)$ : 測度空間

$\mathcal{G} = \{g \in \mathcal{G} \mid g \text{ 可測関数の集合, } \|g\|_\infty \leq B, E[g] = 0, E[g^2] \leq \sigma^2\}$

$\mathcal{G}$  は  $\|\cdot\|_\infty$  に関して可分

かつ  $\forall \lambda > 0$  以下

$$P\left[ \sup_{g \in \mathcal{G}} \frac{1}{n} \sum_{i=1}^n g(z_i) \geq 2 E\left[ \sup_{g \in \mathcal{G}} \frac{1}{n} \sum_{i=1}^n g(z_i) \right] + \sqrt{\frac{2\lambda\sigma^2}{n}} + \frac{2\lambda B}{n} \right] \leq e^{-\lambda}$$

この  $\mathcal{G}$  に対し  $\tilde{\mathcal{G}} = \left\{ \frac{Pg - g(z)}{Pg + r} \mid g \in \mathcal{G} \right\}$  とする (  $r > 0$  )

$$\|g\|_\infty = \left\| \frac{Pg - g}{Pg + r} \right\|_\infty \leq \frac{M}{r}, \quad \|g\|_2^2 = \frac{\|Pg - g\|_2^2}{(Pg + r)^2} \leq \frac{P(g^2)}{(Pg + r)^2} \leq \frac{P(g^2)}{2r} = \frac{1}{2r}$$

つまり  $B = \frac{M}{r}, \sigma^2 = \frac{1}{2r}$  とおくと

$$\left( \frac{1}{2} \left( \frac{M}{r} \right)^2 + r \right)^2 \geq \dots$$

さらに Peeling の議論より

$$E\left[ \sup_{g \in \mathcal{G}} (P - P_n)g \right] \leq 2R_n(\tilde{\mathcal{G}}) \leq \frac{\delta\phi(r)}{r}$$

である (  $\delta \in (0, 1)$  )

$$P(g) = L(f) - L(f_0) \leq (P - P_n)(f - f_0) + \underbrace{(P - P_n)(f^* - f_0)}_{O_p\left(\sqrt{\frac{L(f^*) - L(f_0)}{n}}\right)} \leq (Pg + r) \left[ \frac{\delta\phi(r)}{r} + \sqrt{\frac{2\lambda}{2rn}} + \frac{2\lambda M}{rn} \right] + O\left(r^* + \frac{1}{n}\right)$$


よって  $\forall \epsilon > 0$  任意の  $r$  に対し

$$P(g) = L(f) - L(f_0) \leq 2\delta\psi_n(r) + o\left(r^* + \frac{1}{n}\right)$$

を得る  $\psi_n(r) \leq \frac{1}{2}$  かつ

$$\max\left\{ \psi(r), \frac{\lambda}{2n}, \frac{M\lambda}{n}, r^* \right\} \leq r$$

なる  $r$



$\psi$  は凹関数 であるから

$\psi(r) = r$  なる  $r$  が存在する

(Fixed Point)

重要な補題:

$$\psi(r) \leq \left( \frac{r^2}{2n}, n - \frac{1}{2n} \right) \quad r > 0$$

$$\Rightarrow r^* = o\left(n - \frac{1}{2n}\right)$$

例:  $\psi$  は  $L_2$  の内積,  $r = \frac{1}{2n}, \delta \in (0, 1)$

$$n - \frac{2\lambda}{2n - 1} \quad (\text{丸くおさる})$$

- 深層NNの勾配Rademacher複素値。  
 先作心算をL2ノルムでNNの出力FL, Bを評価。

Thm (informal)

$$\max_{f \in \mathcal{F}} N_{\infty} \leq D \text{ と } \beta.$$

$$\mathcal{F} = \mathcal{F}_{L, \beta, B} \text{ に対して } \mathbb{E} \left[ \int_{\mathcal{F}} L(f) - L(f^0) \right] \leq \beta.$$

$$r > r^* \text{ に対して } \underbrace{\phi(r)}_{R_n(\mathcal{F}_r)} \leq O \left( \sqrt{\frac{\beta L r}{n} \log(L(BV) \cdot D \cdot n)} \right)$$

$$\text{(略証)} \mathbb{E} \left[ \beta_n(\mathcal{F}_r) \right] \leq \mathbb{E} \left[ R_n(\mathcal{F}_r) \right] \quad (\text{対 } \mathcal{L}, \mathcal{F}_r := \{f - f^0 \mid L(f) - L(f^0) \leq 1\})$$

contraction ineq.

$$\leq \mathbb{E} \left[ \int_{\mathcal{D}} \left| \int_{\mathcal{D}} \sqrt{\beta_n(\mathcal{L}, \mathcal{F}_r, \|\cdot\|_{n,2})} d\mathcal{L} \right| \right]$$

$$\text{(対 } \mathcal{L}, \beta = \sup_{f \in \mathcal{F}_r} \|f\|_{n,2} \leq \sqrt{\frac{2r}{\alpha}})$$

これは本質的に処理が必要  
 $\|f\|_{n,2} \leq \|f\|_{L^2(\mathcal{P}_n)}$

$$\leq \int_{\mathcal{D}} \left| \int_{\mathcal{D}} \sqrt{\frac{\beta r}{\alpha}} \cdot \sqrt{2\beta L \log(L(BV) \cdot D \cdot n)} \cdot d\mathcal{L} \right|$$

$$\leq \sqrt{\frac{\beta L r}{n} \log(L(BV) \cdot D \cdot n)} \quad (\alpha = \frac{1}{n} \mathbb{E} \chi^2)$$

ノルム空間上の平均

$$y_i = f^0(x_i) + \epsilon_i$$

$\epsilon_i$  は i.i.d. 雑音, 平均0,  $|\epsilon_i| \leq C$  (d.f.)

$$\hat{f} = \operatorname{argmin}_{f \in \mathcal{F}_{L, \beta, B}} \sum_{i=1}^n (y_i - f(x_i))^2$$

$$\text{Lips. } \ell(y, f) = (y - f)^2 \text{ と } \beta.$$

$$\ast L(f) - L(f^0) = \mathbb{E}[(Y - f(X))^2] - \mathbb{E}[(Y - f^0(X))^2]$$

$$= \mathbb{E}[(f^0(X) + \epsilon - f(X))^2] - \mathbb{E}[\epsilon^2]$$

$$= \mathbb{E}[(f^0(X) - f(X))^2] = \|f^0 - f\|_{L^2(\mathcal{P}_X)}^2$$

に注意.

$\ast \ell$  は  $\mathbb{R}^2 \rightarrow \mathbb{R}$  連続  $\mathbb{R}$ -valued.  $\|f\|_{\infty}, \|g\|_{\infty} \leq M$  と  $|\epsilon| \leq C$  ならば  $\|f\|_{\infty} \leq M$  の範囲で  $\mathbb{R}^2 \rightarrow \mathbb{R}$  連続  
 $m = L(\beta) = \text{ある integer s.t. } m \leq \beta$

Thm. (Yarotsky, 2016; Schmidt-Hieber, 2017)  $C^p([0,1]^d) = \{f \mid \sum_{|\alpha| \leq p} \|D^\alpha f\|_{\infty} + \sum_{|\alpha| \geq p} \int_{[0,1]^d} \frac{|D^\alpha f(x)|}{1 + |x - y|^{|\alpha| + 1}} dx < \infty\}$   
 $f^0 \in C^p([0,1]^d), \|f^0\|_{C^p} \leq 1$  のとき.

$$N \gg 1 \text{ ならば 整数 } h \geq 1, \exists L = O(\beta(N)), \exists S = O(H \log(H)), \exists \gamma = O(N), \exists \beta = O(1) \text{ と}$$

$$\inf_{f \in \mathcal{F}_{L, \beta, S}} \|f^0 - f\|_{L^2(\mathcal{P}_X)}^2 \leq O(N^{-\frac{2\beta}{\alpha}})$$

深層NN  $O(\beta(N))$  を用いて  $\beta$  を連続的に増やせる。

$N \gg 2$  に対し,  $L, S, B, D \in \mathbb{R}$  の  $\text{Thm 9.5.3}$  の設定で

$$\|L(\hat{f}) - L(f^0)\| \leq O(N^{-\frac{s}{d}}) \quad \text{2-2.3}$$

$\left\{ \phi(N), \frac{1}{h}, r \right\} \leq r$   $\varepsilon$  に対して  $\frac{1}{h} \in \mathbb{Z}$  かつ  $L \in \mathbb{Z}$  かつ  $r \in \mathbb{C}$ .

$$\|\hat{f} - f^0\|_{L^2(\mathbb{R}^d)}^2 \leq O\left( \frac{N \rho_j(N)^2 (\log(N) + \log(m))}{n} + N^{-\frac{2s}{d}} \right)$$

よって  $N = n^{-\frac{2s+d}{d}}$  に対して (constant)

$$\leq O\left( n^{-\frac{2s}{2s+d}} \rho_j(m)^3 \right)$$

- = - 3 1 2 -> 7 - 7 7 救通代 12 2 2 .

• Over-parametrization 2 大球 的 最近 解 A- 找到 也可 存在

[Du et al. 2018; Allen-Zhu, Li & Song 2018; Li & Liang, 2018; Du et al. 2019]

Du, Zhai, Póczos, and Singh (2018) 4 个 - 2 个 组合 招

4 个 组合 招  
清 楚 是 否 可 以 存 在 解

$$f(w, a, x) = \frac{1}{\sum_{r=1}^m a_r} \sum_{r=1}^m a_r \sigma(w^T x) \quad (m \text{ 个 } + \text{ 个 } x)$$
  
( $a_r \in \mathbb{R}, w_r \in \mathbb{R}^d$ )  
overparametrize.

基 本 的 招  
$$F(w) - F(w^*) \leq \|\nabla F(w)\|^2$$
  
这 招 了

$$L(w) = \frac{1}{2} \sum_{i=1}^n (y_i - f(w, a, x_i))^2$$

$$w_{k+1} = w_k - \eta \frac{\partial L(f)}{\partial w} \Big|_{w=w_k} \quad (\text{Gradient descent})$$

初 始 化:  $w_r \sim N(0, I)$   $a_r \sim p(a_r=1) = p(a_r=-1) = \frac{1}{2}$  (i.i.d.)

$w$  和  $a$  互 新,  $a$  是 正 负

• 时 间 在 进 行 化 化 考 虑

$$\frac{d w(t)}{dt} = - \frac{\partial L(w(t))}{\partial w(t)}$$

$$u(t) = (f(w(t), a, x_i))_{i=1}^n \in \mathbb{R}^n$$
 个 个 在 个 个

$$\frac{d u(t)}{dt} = \sum_{i=1}^n (y_i - u_i(t)) \cdot H_{ij}(t)$$

这 招 了  $H_{ij}(t) = \frac{1}{m} x_i^T x_j \sum_{r=1}^m \{ x_i^T w_r(t) \geq 0, x_j^T w_r(t) \geq 0 \}$

$$\frac{d}{dt} \|Y - u(t)\|^2 = -2(Y - u(t))^T H(t) (Y - u(t))$$

Fact

• 实 在  $m$  个 个 个 大 是 个 个 个 个  $H(0) \geq \lambda_0 I$  ( $\lambda_0 > 2$ ) 个 个 个 个

[ $(\lambda_0)_{m \times m}$  is degenerate (2 个 个 个 个)]

•  $\|w_r(t) - w_r(0)\|_2 \leq \frac{\|Y - u(0)\|_2}{\sum_{r=1}^m \lambda_0}$  ( $w_r(t)$  个 个 个 个) 个 个 个 个

•  $H(t) \geq \frac{\lambda_0}{2}$  (个 个 个 个 个 个)

$$\Rightarrow \|Y - u(t)\|^2 \leq \exp(-\lambda_0 t) \|Y - u(0)\|^2$$

exponential convergence