

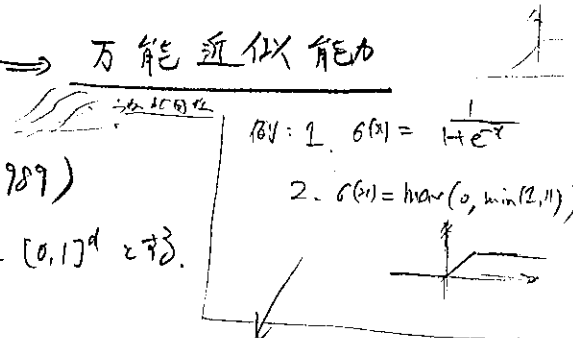
# ユニバーサルアプロクシメーションの近似理論

- ユニバーサルアプロクシメーションは任意の範囲の関数を任意の精度で近似できる。

- しかも最適なレートで近似できることがわかった。

"任意の関数"を"任意の精度"で近似できる能力  $\Rightarrow$  万能近似能力

基本方針 - 調和解析, wavelet, 多項式スプライン近似の併用




## 1. 連続関数 on $[0,1]^d$ の近似定理 (Cybenko, 1989)

$\sigma: \mathbb{R} \rightarrow \mathbb{R}$  を活性化関数とする.  $I^d := [0,1]^d$  とする.

Def

$$\sigma \text{ がシグモイド的} \iff \sigma(x) \rightarrow \begin{cases} 1 & (x \rightarrow \infty) \\ 0 & (x \rightarrow -\infty) \end{cases}$$

( $\sigma$  の単調性は仮定しない)



$$g(x) = \sum_{i=1}^N \alpha_i \sigma(a_i^T x + b_i) \quad (x \in [0,1]^d, \alpha_i \in \mathbb{R}, a_i \in \mathbb{R}^d, b_i \in \mathbb{R})$$

任意形の関数を用いて、連続関数を近似する。

Def

$\sigma$  が識別的  $\iff$   $I^d$  上の任意の有界正値符号付き測度  $\mu$  に対し  $(\mu(I^d) > 0)$  とする。

$$\int_{I^d} \sigma(a^T x + b) d\mu(x) = 0 \quad (\forall a \in \mathbb{R}^d, b \in \mathbb{R})$$

つまり、 $\mu = 0$  とする。

連続関数の集合

LEM

$\sigma$  を連続な識別的関数と仮定すると、 $\forall f \in C(I^d), \forall \epsilon > 0$  とすれば、  
ある  $g(x) = \sum_{i=1}^N \alpha_i \sigma(a_i^T x + b_i)$  が存在して、

$$\sup_{x \in I^d} |f(x) - g(x)| \leq \epsilon$$

が成り立つ。

証明

$f \in g$  の形をすべての関数全体の集合と見なす。これは  $C(I^d)$  の線形部分空間である。その閉包が  $C(I^d)$  であるから、そう仮定してよい。  
すると、Hahn-Banach の定理より  $C(I^d)$  上の有界線形汎関数  $L: C(I^d) \rightarrow \mathbb{R}$  が存在して、 $\forall f \in \overline{S}$  とすれば  $L(f) = 0$  と  $\exists f \in \overline{S}$  と  $L(f) \neq 0$  とする。

また. Rieszの表現定理F'. (Rudin, Thm 6.19')

$$L(h) = \int_{\mathbb{R}^d} h(x) d\mu(x) \quad (\text{ただし } \mu \in M(\mathbb{R}^d) \text{ (} \mu \text{ は } \mathbb{R}^d \text{ 上の有限測度)} \text{)}$$

と書くといい. 特に.  $h(x) = \sigma(a^T x + b)$  を用いると.

$$L(h) = \int_{\mathbb{R}^d} \sigma(a^T x + b) d\mu(x) = 0 \quad (\forall a \in \mathbb{R}^d, b \in \mathbb{R})$$

が成り立つ. 以上. 今  $\sigma$  は識別的であること仮定 (2.3.3 の  $\mu = 0$  である).  
より.  $L(f) = 0$  ( $\forall f \in C(\mathbb{R}^d)$ ) と  $L$  の構造は異なる. よって.  $\bar{S} = C(\mathbb{R}^d)$  である. //

よって. 連続なシグモイド関数は識別的であることを示せばよい.

Lem

任意の連続なシグモイド関数は識別的である.

(有界なシグモイド関数に拡張可能)

Proof

シグモイド関数の定義

$$\sigma(\eta(a^T x + b) + \theta) \xrightarrow{\eta \rightarrow \infty} \begin{cases} 1 & (a^T x + b > 0) \\ 0 & (a^T x + b < 0) \\ \sigma(\theta) & (a^T x + b = 0) \end{cases}$$

である. 今  $\mu \in M(\mathbb{R}^d)$  で  $\int \sigma(a^T x + b) d\mu(x) = 0$  ( $\forall a, b$ ) なる  $\mu \in M(\mathbb{R}^d)$  とおくと.

$\sigma$  は有界であることから. Lebesgueの優劣定理F'.

$$\begin{aligned} 0 &= \lim_{\eta \rightarrow \infty} \int_{\mathbb{R}^d} \sigma(\eta(a^T x + b) + \theta) d\mu(x) \\ &= \int_{\mathbb{R}^d} \lim_{\eta \rightarrow \infty} \sigma(\dots) d\mu(x) \\ &= \sigma(\theta) \mu(\Pi_{a,b}) + \mu(H_{a,b}) \quad (\forall \theta, a, b) \end{aligned}$$

である. したがって.  $\Pi_{a,b} = \{x \mid a^T x + b = 0\}$ ,  $H_{a,b} = \{x \mid a^T x + b > 0\}$  である.

$\theta$  は任意である.  $0 = \mu(\Pi_{a,b}) + \mu(H_{a,b})$ ,  $0 = \mu(H_{a,b})$  である.  
( $\theta \rightarrow \infty$ ) (  $\theta \rightarrow -\infty$  )

よって  $a \in \mathbb{R}^d$  を任意に取ると  $\mathbb{R}^d$  上固定. 2つとも. 有界な可測関数に対して.

$$F_a(h) = \int_{\mathbb{R}^d} h(a^T x) d\mu(x).$$

とある.  $h(x) = \mathbb{1}(-b, \infty) + h = \mathbb{1}[-b, \infty)$  をとり替えて

$$F_a(h) = 0$$

が先のギョウキ内である.

定理.  $f_a$  の線形独立性より, 任意の単関数  $f$  に対して  $f_a(x) = 0$  かつ  $f(x) \neq 0$ . 同様に.

また, 優収束定理より.

$$f_a(\cos) = \int_{\mathbb{R}^d} \cos(a^T x) d\mu(x) = 0$$

$$f_a(\sin) = \int_{\mathbb{R}^d} \sin(a^T x) d\mu(x) = 0$$

から, したがって,  $\int_{\mathbb{R}^d} e^{i a^T x} d\mu(x) = 0$  である.  $a \in \mathbb{R}^d$  は任意の  $a$  である.

$\mu = 0$  である. 得られた.

Thm

$G$  が連続な関数  $f$  に対して 任意の  $f \in C(\mathbb{R}^d)$  と任意の  $\epsilon > 0$  に対して.

ある  $g(x) = \sum_{i=1}^n \alpha_i G(a_i^T x + b_i)$  が存在して

$$\|f - g\|_{\infty} \leq \epsilon$$

とできる. (したがって)  $C(\mathbb{R}^d)$  の中で, 万能近似能力をもつ.

\*  $G$  が不連続な  $L_1$  内の稠密性も示せる.

\* ReLU に対して.  $\frac{1}{x} + \frac{1}{x} = \frac{2}{x}$  と  $\frac{1}{x} - \frac{1}{x} = 0$  (したがって  $\frac{1}{x}$  は  $\frac{1}{x}$  の近似として).

## 2. 積分表現

(Ridgelet transform) (Marrate, '96; Sonoda and Murata, '15; Kostadinova et al., '14)

$\eta$ : activation function (e.g. ReLU)  $\eta \in S$  (緩増加関数)

$\exists \eta \in S$  (急減少関数) である.

$$K_{\eta, \eta} = (2\pi)^{d-1} \int_{\mathbb{R}} \frac{\overline{\eta(\xi)} \eta(\xi)}{|\xi|^d} d\xi < \infty \quad (\text{許容条件})$$

とある.

Thm (再構成 formula)

$f \in L^1(\mathbb{R}^d)$ ,  $\hat{f} \in L^1(\mathbb{R}^d)$  かつ  $(\eta, \eta) \in S(\mathbb{R}) \times S'_0(\mathbb{R})$  かつ  $\eta$  が許容条件を満たすならば.

$$R_{\eta}^{\dagger}(a, b) := \int_{\mathbb{R}^d} f(x) \overline{\eta(x^T a - b)} dx$$

$$R_{\eta}^{\dagger} T(x) = \int_{a \in \mathbb{R}^d} \int_{b \in \mathbb{R}} T(a, b) \eta(a^T x - b) da db$$

したがって.

$$\int_{a, b} R_{\eta}^{\dagger} f(x) = K_{\eta, \eta} f(x) \quad (\text{a.e.})$$

$$\text{(再構成)} \quad f(x) = \int_{\mathbb{R}^d \times \mathbb{R}} \left[ \int_{\mathbb{R}^d} f(x') \overline{\eta(a^T x' - b)} dx' \right] \eta(a^T x - b) da db$$

$$= \int_{\mathbb{R}^d} f(x') \left[ \int_{\mathbb{R}^d \times \mathbb{R}} \overline{\eta(a^T x' - b)} \eta(a^T x - b) da db \right] dx'$$

$$= \int_{\mathbb{R}^d} f(x') \left[ \int_{\mathbb{R}^d} \overline{\eta} \times \eta(a^T(x-x')) da \right] dx'$$

$$(2\pi)^{-(d-1)} \int_{\mathbb{R}^d} \left( \int_{\mathbb{R}} \frac{\overline{\eta(\xi)} \eta(\xi)}{|\xi|^d} d\xi \right) e^{i a^T (x-x')} da = (2\pi)^{-1} \int_{\mathbb{R}^d} \left( \int_{\mathbb{R}} \frac{\overline{\eta(\xi)} \eta(\xi)}{|\xi|^d} d\xi \right) e^{i a^T (x-x')} da \quad (\text{変換})$$

$$\begin{aligned} &= (2\pi)^{-d} K_{\eta, \eta} \times \\ &= \int_{\mathbb{R}^d} e^{i a^T x} \left( \int_{\mathbb{R}^d} f(x') \overline{e^{i a^T x'}} dx' \right) da \\ &= (2\pi)^{-d} \int_{\mathbb{R}^d} e^{i a^T x} \hat{f}(a) da \quad (\text{Fourier}) \\ &= f(x) \quad (\text{Fourier}) \end{aligned}$$

3.  $\gamma$  空間の近似理論 (無限回微分可能な  $\sigma$ )

$$\Omega = \mathbb{I}^d \subset \mathbb{R}^d$$

$$\|f\|_p := \begin{cases} (\int_{\Omega} |f(x)|^p dx)^{1/p} & (1 \leq p < \infty) \\ \text{ess sup}_{x \in \Omega} |f(x)| & (p = \infty) \end{cases}$$

とある.  $k = (k_1, \dots, k_d) \in \mathbb{Z}^d$  に対し, a.e.  $\gamma$  回微分可能な関数  $f$  に対し

$$\|f\|_{W_p^{\sigma}(\Omega)} := \sum_{0 \leq k \leq \sigma} \|D^k f\|_p \quad (\sigma \in \mathbb{Z}, \sigma \geq 0, 1 \leq p \leq \infty)$$

とある. また  $0 \leq k \leq \sigma$  とは  $0 \leq \sum_{j=1}^d |k_j| \leq \sigma$  を意味し.

$$D^k f = \frac{\partial^{|k|} f}{\partial x_1^{k_1} \dots \partial x_d^{k_d}}$$

とある.

$$\Pi_N := \left\{ \sum_{j=1}^N d_j \sigma(a_j^T x + b_j) \mid d_j \in \mathbb{R}, a_j \in \mathbb{R}^d, b_j \in \mathbb{R} \right\} \quad (\text{二-ラクレットの集合})$$

目標:  $f \in W_p^{\sigma}(\Omega)$  へ  $g \in \Pi_N$  で近似する. その近似精度を求めよ.

Thm

$\sigma$  が ある 開区間  $\gamma$  無限回連続微分可能な  $\sigma$  である. また,  $\gamma$  の 開区間の 端点  $b \in \mathbb{R}$  において

$$\frac{\partial^k \sigma(b)}{\partial x^k} \neq 0 \quad (\forall k \in \mathbb{Z}, k \geq 0)$$

とある. すると,  $\forall f \in W_p^{\sigma}(\Omega)$  に対し,  $\exists g \in \Pi_N$  であり

$$\|f - g\|_p \leq C \cdot \underline{N^{-\frac{\sigma}{d}}} \|f\|_{W_p^{\sigma}}$$

とある.

\* この近似精度は  $O(N)$  個の基底を用いた近似法の中で最適である (非線形を含む)

\*  $\sigma(x) = \frac{1}{1+e^{-x}}$  (シグモイド関数) は条件を満す.

\* 任意の関数は  $\sigma$  で近似できる.

(略証)  $\gamma$  上の多項式  $T_k(x)$  ( $k=0, 1, 2, \dots$ ).  $T_0(x)=1, T_1(x)=x, T_k(x)=2xT_{k-1}(x)-T_{k-2}(x)$  ( $T_k(\cos \theta) = \cos(k\theta)$ ) を用いる.

$$T_k(x) = \prod_{j=1}^k T_{k_j}(x_j) \quad (k=(k_1, \dots, k_d), x=(x_1, \dots, x_d))$$

とすると,  $m \geq 1$  に対し, ある  $P_m(f) = \sum_{0 \leq k \leq m} C_k(f) T_k(f)$  が存在し:

$$\left. \begin{aligned} \|f - P_m(f)\|_p &\leq \frac{C}{m^{\alpha}} \|f\|_{W_p^{\sigma}} \\ \sum_{0 \leq k \leq m} |C_k(f)| &\leq C m^{\alpha} \|f\|_{W_p^{\sigma}} \quad (\alpha = \frac{\sigma}{p \wedge 2}) \end{aligned} \right\} \text{--- } \textcircled{*}$$

とつながると知られる.

よ2. 本心は多項式  $P_n(f) \in \Pi_N$  の元を近似するものは  $\mathbb{R}^n$ .

実は、 $\forall \epsilon > 0$  に対し、 $\exists g_{k,\epsilon} \in \Pi_{(2m+1)d}$  として  $\|T_k - g_{k,\epsilon}\|_\infty \leq \epsilon$  とできる。<sup>( $|k| \leq 2m$ )</sup>  
 この系は  $\epsilon$  を任意に小さくできる。

よ3.  $G_N$  は  $[b-\delta, b+\delta]$  上で無限回連続微分可能である。

すなわち、 $G_k(a, x) := \frac{\partial^{|k|}}{\partial a_1^{k_1} \dots \partial a_d^{k_d}} \sigma(a^T x + b) = x^k \sigma^{(|k|)}(a^T x + b)$  ( $k = k_1, \dots, k_d$ )

である。よ2.  $x^k = \frac{1}{\sigma^{(|k|)}(b)} G_k(a, x)$  と得る。<sup>( $x^k = x_1^{k_1} \dots x_d^{k_d}$  とする)</sup>

よ4.  $P_{k,r}(x) := h^{-|k|} \sum_{0 \leq r \leq k} (-1)^{|r|} \binom{k}{r} \sigma^{(|k|-|r|)}(a^T x + b)$  ( $r, k \in \mathbb{Z}^d$ )  
<sup>( $0 < h, k \in \mathbb{R}$ )</sup>  
 とする。

$\|P_{k,x} - G_k(a, x)\|_\infty \leq M_k \cdot h^2$

を示す。すなわち、 $\|x^k - \frac{P_{k,r}}{\sigma^{(|k|)}(b)}\|_\infty \leq \frac{M_k}{\sigma^{(|k|)}(b)} h^2$

よ5.  $\epsilon > 0$  に対し  $h \in \mathbb{R}^d$  かつ  $0 < h < \epsilon$  かつ  $T_k(x) = \sum_{0 \leq r \leq k} T_{k,r} x^r \in \mathbb{R}^d$

$g_{k,\epsilon}(x) = \sum_{0 \leq r \leq k} \frac{T_{k,r}}{\sigma^{(|k|)}(b)} P_{k,r} \in \Pi_{(2m+1)d}$ 、誤差  $\epsilon$  以内で近似できる。

よ6.  $g_{k,\epsilon} \in \Pi_{(2m+1)d}$  とする。

よ7.  $\mathbb{R}^d$  かつ  $(2m+1)d \leq N$  とし、 $\epsilon > 0$  かつ  $\delta < \epsilon$  とする。

$G_N(x) = \sum_{0 \leq k \leq 2m} C_k(f) g_{k,\epsilon}(x)$ ,  $G_N \in \Pi_N$  とする。

$\|P_m(f) - G_N\|_\infty \leq C \cdot m^{-\delta} \|f\|_{W_p^s}$

よ8.  $\mathbb{R}^d$  かつ  $\forall f \in W_p^s$   $\|f - P_m(f)\|_p \leq O(m^{-\delta})$  かつ 全体で

$\|f - G_N\|_p \leq \|f - P_m(f)\|_p + \|P_m(f) - G_N\|_\infty$  ( $\because \mathbb{R}^d = [0, 1]^d$ )

$\leq m^{-\delta} \|f\|_{W_p^s}$

$\leq N^{-\frac{\delta}{2d}} \|f\|_{W_p^s}$  ( $N \approx m^d$  とする)


→ 解析では  $\delta$  UZ 滑らかな関数を用いた。

よ、現在主流の ReLU 活性化関数  $\sigma(x) = \max(x, 0)$  は含まれない。

しかし、 $\sigma$  の  $\delta$  UZ 滑らかな関数を用いた: ReLU を用いた。

$$\|f - G_N\|_{(p)} \leq N^{-\frac{1}{p}} \log(N) \rightarrow \text{スライスネットワーク}$$

と対応する  $\delta$  UZ (幅:  $O(N)$ , 深:  $O(\log(N))$ ) → 浅層化 → 深層化 (ただし  $S \gg 2 \times 4 \times 2$ )  
→ sub-optimal とある。



$\Rightarrow (x+y)^2 - x^2 - y^2 = 2xy \Rightarrow$  全般的多項式  $\wedge$  近似可能  $\wedge$  近似可能

$\Rightarrow$  ヲホレフ空間の元を好く近似できる。