

創発採択課題 「**深層学習**の原理記述に向けた構造汎化理論スキームの開発」

# AIの原理を解き明かす新理論

2021/12/15 JST

今泉允聡

東京大学 総合文化研究科 先進科学研究機構



東京大学  
THE UNIVERSITY OF TOKYO

# AIと深層学習

新技術の”発見”がもたらしたもの

# 深層学習の”発見”

## 2010年代に実用化されたデータ解析技術

基礎研究

~2000

ブレイクスルー


2012

AIブーム

2016~


技術的  
課題

技術  
発展



高精度を発揮

画像識別精度: 75% → 96%




画像認識




自動運転

発見：ニューラルネットワークの層を増やすと精度向上

(既存法)  
層が少ない  
ネットワーク



(新手法)  
深層学習




# 深層学習はAIの中核技術

## 有名な成功例

### AlphaGo (DeepMind)

- 囲碁で人間超え
  - 世界トップ棋士に勝利



### BERT (Google)

- 言語テストで高得点
  - 人間: 91.2%
  - BERT: 93.2%

#### 文章

In early 2012, NFL Commissioner **Roger Goodell** stated that the league planned to make the 50th Super Bowl "spectacular" and that it would be "an important game for us as a league".

#### 文章に関する問い

Who was the NFL Commissioner in early 2012?

Ground Truth Answers: **Roger Goodell** Roger Goodell Goodell


# 深層学習の謎

その原理はまだ理解されていない

# 性能をめぐる理論の謎

従来理論と深層学習は完全に食い違う

## 従来のデータ解析理論




過剰な  
パラメタは  
**過学習**する  
→性能悪化

誤差は  $\frac{\text{パラメタ数}}{\text{データ数}}$  に比例

深層学習登場前の常識

矛盾

## 巨大深層学習の成功



VGG19 Net  
1億パラメタ



GPT-3  
千億パラメタ

パラメタを増やすほど  
予測精度が向上

→ 理論再考：データ解析理論を再構築する必要性

# 理論がないと何が困る？

深層学習の根本的問題は、原理の不理解に依存

## 問題：膨大な計算コスト



適切な設計が不明  
大量に試験しよう



膨大な計算コスト  
(大手による技術独占)

## 問題: ブラックボックスな挙動



失敗したが  
原因は不明！



信頼できる  
製品が作れない  
(社会への技術浸透の遅れ)

深層学習の原理を説明できる理論がない

➔ 高コスト・非効率な運用が主流に

# 深層学習と基礎理論の関係


“発見”された手法の理解は発展途上

## 実用の世界

- 深層学習の恩恵で発展


## 理論の世界

- 理解・支えるべき
- 実用に追いついていない



# “発見”を理論で記述すること


- 歴史的には共通の現象



蒸気機関の発明  
(1769年)




熱力学の  
成立



飛行機の発明  
(1903年)



航空力学の  
成立



深層学習の発明  
(2012年)



?


**問**：深層学習は記述・理解できる理論は構築できるか？

# 本研究プロジェクト

深層学習を記述する”構造汎化スキーム”

# 近年の理論研究の背景


仮想的・限定的な設定下の理論が多い



# 本研究の枠組み

## 構造汎化スキーム

- 実現象と既存スキームを架橋する理論



深層学習を記述する理論スキームを創出


# これまでの研究

今泉研による理論**成果例** (3点)

# 1/3: データの非滑らかさ

データ構造が**非滑らかな**時、深層学習が優越することを証明


対象：区分上でのみ滑らかな関数



例：物理的相転移現象

$$\mathcal{F}^{PS} := \{f = \sum_m f_m 1_{R_m}\}$$

$f_m$ : ヘルダー級関数,  $1_{R_m}$ : 区分 $R_m$ の指示関数



関数の台を区分に分割

主定理：深層学習の優越 (ミニマックス汎化誤差)

$$\inf_{\hat{f}^{DL}} \sup_{f^* \in \mathcal{F}^{PS}} E \left[ \|f^* - \hat{f}^{DL}\|_{L^2(\mu)}^2 \right] < \inf_{\hat{f}^{lin}} \sup_{f^* \in \mathcal{F}^{PS}} E \left[ \|f^* - \hat{f}^{lin}\|_{L^2(\mu)}^2 \right]$$


深層学習の予測誤差

従来法による予測誤差

# 2/3: データの隠れた低次元性

データの隠れ低次元性が深層学習の性能を向上


対象：隠れた低次元性を持つデータ



例：低次元多様体に集中するデータ

次元の定義：Minkowski 次元

$$\inf \left\{ d > 0 \mid \limsup_{\varepsilon \rightarrow 0} \mathcal{N}_\varepsilon(\Omega) \varepsilon^d = 0 \right\}$$



$\mathcal{N}_\varepsilon(\Omega)$  :  $\Omega$  を  $\|\cdot\|_\infty$  で被覆する  $\varepsilon$  球の数.

主定理：隠れ次元に依存する誤差収束

$D$ 次元データが隠れ次元  $d$  ( $d < D$ )を持つとき：

$$\|\hat{f}^{DL} - f^*\|_{L^2(\mu)}^2 \leq C_1 n^{\frac{-2\beta}{2\beta+d}} (1 + \log n)^4 + \frac{16}{n}$$

深層学習による予測誤差

隠れ次元  $d$  のみに依存する誤差レート


$n$ : データ数

$\beta$ : データの滑らかさ

# 3/3: 複雑なエネルギーの影響


深層学習のエネルギー曲面の複雑性が予測精度を説明

対象：非凸エネルギー曲面を持つ深層学習



図はLi et al. (2018)より

複雑な曲面とパラメタ探索アルゴリズム



主定理：曲面形状による予測誤差

正の確率で以下が成立：

$$R(\hat{f}) \leq \inf_{f \in B_\delta} R(f) + O\left(\frac{\sqrt{d \log K} + SL\delta}{\sqrt{n}}\right)$$

深層学習の予測誤差

曲面形状で決まる誤差 (パラメタ数と独立)

# 本研究の展望


理論のパラダイムと社会の発展

# 新理論のパラダイムを目指して

## AI・データ解析理論の基盤創出

- 試金石としての深層ニューラルネットワーク

理論のパラダイムシフト



- 現在は新しい理論が定着するかの分水嶺

# 社会への影響

- 理論・理解に基づいた新技術開発
  - 深層学習の問題を根底から改善

