

# データセンタリックアプローチによるデータセットとモデルの双最適化とタスク特化型DNNの完全自動構築

大学院生命体工学研究科

客員准教授 鈴木 章央(M人知H28)

教授 田向 権(M生脳H15)



はじめに

世界大会優勝5回<sup>1)</sup>。このロボットの視覚を徹底的に鍛えた発明をロボチームの中で眠らせるのは勿体ない。モノづくり現場での人工知能応用を最初にブロックする大きな壁「データ」に挑戦する研究です。ロボカップ等の競技会で培った技術の社会実装を目指し、この度、明専会の強力なバックアップを受けて、九州工大独自技術シーズのビジネス化を目指します。生命体で博士号取得した鈴木氏を客員准教授に迎え、更なる研究開発からビジネス化まで、オール九州工大体制で進めます。

以下、本稿では、この度、明専会に採択いただいた研究計画の紹介を通して、人工知能応用に関する最新の知見と課題をお伝えします。また、大学発スタートアップで重要といわれる単願特許(九州工大メンバーのみが発明者の特許)をベースにしたビジネス化挑戦への意気込みを述べます。

## 語彙について

この研究に関わる語句や略語、またその定義などは、末尾の付録の章にまとめておきました。随時参照していただければと思います。

## 研究キーワードからみる本研究

研究内容について理解していただくために、タイトルにある『データセンタリック』、『データセットとモデルの双最適化』、『タスク特化型DNNの完全自動構築』の解説をしていきます。また、この解説を通じて、

研究紹介をしていきます。

まずは1つ目のキーワード『データセンタリック』についてです。AIはモデルとデータを掛け合わせて構築されます(図1)。一般的に、AIを改良するために、新しいモデルの構造を提案したり、改良したりします。こうして刷新したモデルを、ベンチマークテスト用のデータセット(学習データとテストデータが提供されている)を使って評価するモデルセンタリックが主流です(図2)

上)。一方で、データセンタリックとは、モデルを固定した状態で、学習するデータを改良し、AIを改良する考え方です(図2下)。つまり、ベンチマークテストとして提供されるデータのうち、テストデータは評価用に使うとして、学習データについて処理を施します。こうして刷新したデータを使って学習をすることで、AIの改良につながります。

2つ目のキーワード『データセットとモデルの双最適化』は文字通り、

## AIはモデルとデータの掛け合わせ



図1 AIの要素：モデルとデータ



図2 モデルセンタリック(上)とデータセンタリック(下)

データセットとモデルの両方を最適化していく、という意味です。一般的にAIの学習パラダイムでは、モ

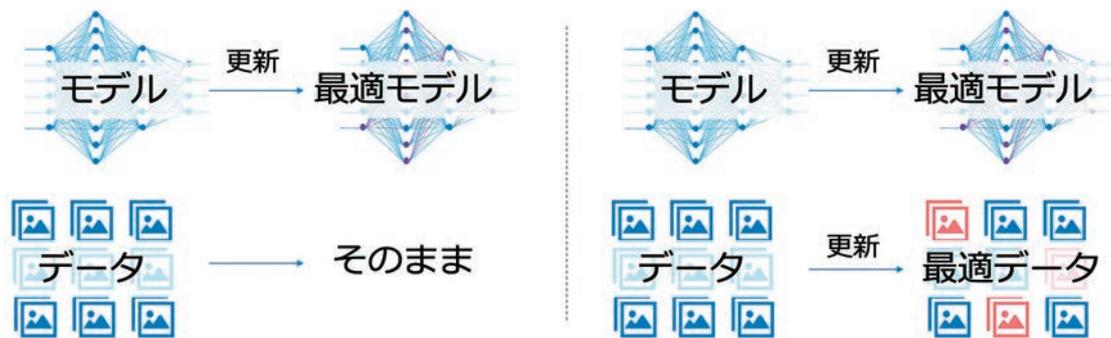
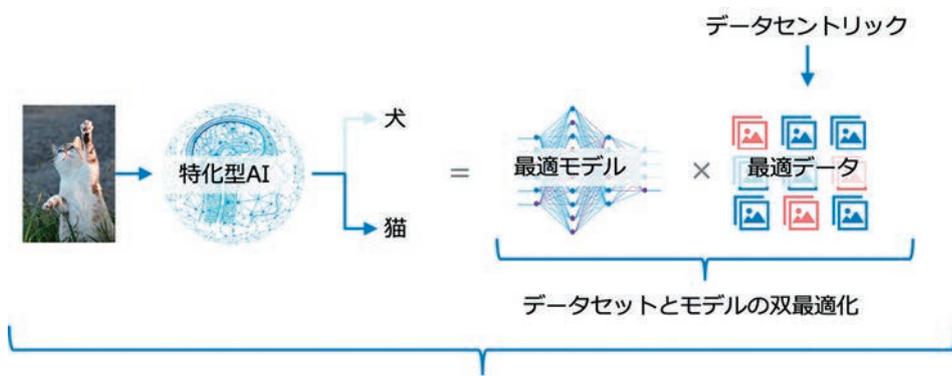


図3 一般的な学習パラダイム(左)と本研究の学習パラダイム(右)



図4 汎用型AIと特化型AI

デルだけを最適化します。学習の結果にに応じて原因の調査を行い、モデルを改良するか、データセットを改良するか、というのがモデル・データセントリックの違いで、モデルセントリックでもデータセントリックでも1回の学習を行う間にデータセットを変更することはありません(図3左)。本研究では、このパラダイムを崩して、学習中にデータセットも最適化していきます(図3右)。これを可能としているのがデータ生成する技術です。データセントリックなアプローチであっても、データを生成することは想定されていません。分量を調整したり、教師



タスク特化型DNNの完全自動構築

図5 本研究の全体像

データを見直したりする程度です。自由自在にデータを増減させることができるからこそ、学習中にデータセットも最適化するというアプローチが取れるのです。3つ目のキーワードは『タスク特化型DNNの完全自動構築』です。

AIはタスクの設計次第で、人のようになんでもやらせる汎用型と特定の処理に特化させる特化型に分けられます。例えば、画像領域でいえば、物体認識・画像生成・異常検知、文章領域で言えば文章執筆・文章翻訳・文章要約などのタスクをすべて一つのDNNでこなすのが汎用型で、物体認識だけ、文章要約だけをこなすのが特化型です(図4)。

これらのキーワードを踏まえて本研究で目指す全体像を図5に示します。本研究では、『データセントリック』の考え方で、データセットを生成・改良できるようにして、学習においては『データセットとモデルの双最適化』を行い、最終的に『タスク特化型DNNの完全自動構築』を目指します。

### 研究の全体像

ここまで、キーワードを使ってこの研究で取り組む内容について述べてきました。ここからは、研究の最終目的から取り組む内容にどう帰着するのかについて述べていきます。

この研究の最終目的は、画像処理タスクとデータセットを関連づけることで、画像処理タスクからデータ

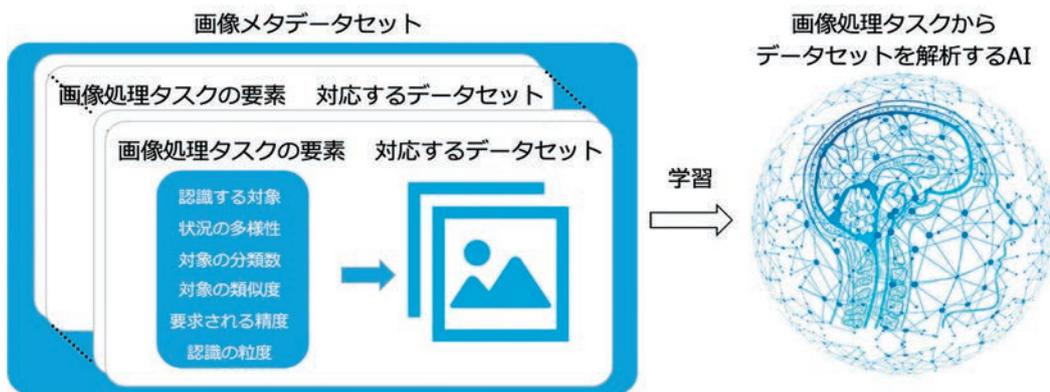


図6 本研究の最終目的

セットを解析するAIを開発することで(図6)。この技術が完成した未来では、画像処理のタスクを入力すると、対応するデータセットが自動で生成されます。生成された

データセットを学習することで、タスク特化型のAIが出来上がります。タスクの要素(認識する対象や認識対象の分類数など)を入力するだけでAIが出来上がるので、データセットの準備やモデルの設計・学習などの要素をスキップすることができ、ユーザーからすると超効率的にAIを構築することができます。さて、この最終目的を達成するための最初のステップとして2つの目標を立てました。目的を達成するためにはまず、画像メタデータセットを構築する必要があります。もっと言えば『画像処理タスクと、それに対して、どのモデルを使っても精度の向上限界(≒学習限界)を向かえる高精度なデータセットの組み合わせ』が必要です。一般的なデータセットでさえ、人手で作成するのは(自動生成の技術が開発されるくらい)困難です。よって、画像メタデータセットに対して、人力でデータセットを作成・収集する方法は現実的ではなく、機械で自動生成する方が適していると考えられます。そこで、データセットを自動で生成する手法と、任意のタスクに対してAIのモデルとデータセットの両方を同時に

最適化する手法を研究することになりました。さらに、これらの手法を組み合わせることで、任意のタスクに対して特化したAIモデルを自動構築できるようにします。モデルとデータセットの両方が最適化されているので、同時に『あるモデルの学習限界を達成可能な高精度なデータセット』も取得することができます。つまり、図5に示すシステム完成には、画像メタデータセットを構築する要素を得るといふ狙いがあります。

### 今後の研究の進め方

ここまで目指す内容や着想経緯について説明してきました。ここでは、実際にどのように進めていくのかについて説明してきます。現状、5つの手法の実施を計画しています。

手法1 データセットの自動生成法・田向研の独自技術を使って、複雑かつ多様なデータセットを自動生成します。

手法2 データセット評価法とその応用・フラクタル次元やエントロピーなどの画像特徴を使ってデータセットを評価します。

手法3 データセットを予測、改善しながらモデルを学習するスキ

ム構築・手法1と手法2を合わせて、データセットを評価しながら学習を行なっていくスキームを構築します。

手法4 モデルの学習状況の評価法策定・学習前後のDNNのモデルの変化や学習誤差、精度などを使ってモデルの学習状況を定量評価します。

手法5 学習限界を見定める評価実験・一般的な学習誤差や精度と手法4の内容を組み合わせて、学習限界という状態を定義します。これら5つの手法について、既存の技術や新技術を組み合わせる実現していきます。

### 意気込み

DNNの研究開発をする上で、データセットの量や質がボトルネックになることが多いです。この研究を通じて、そのボトルネックを解消し、今後の画像処理DNNの研究開発におけるインフラ技術としての確立を目指します。一方で、事業化も目指しています。2021年には北九州SDGsイノベーション&アントレプレナーシップ(KIEPS)に、2022年度にはKYUTECにそ

れぞれ採用されており、ビジネスプランの構築を進めてきました。今年度は本格的に展開するための顧客獲得を目指していきます。この研究で提案しているデータセントリックな方法でのタスク特化型DNNの完全自動構築は、世界的にも類似のものはなく、事業化を通じて、九州工大初のユニコーン企業を目指します。

### 期待できる成果

本研究では、画像処理を中心に研究活動を進めていきます。一方で、『データを解析して、DNNの学習効率を改善する技術』の開発につながるため、テールデータ処理や自然言語処理、音声処理などDNNを扱うことができる他の分野への応用を期待することができます。また、『データを用意して↓それを学習して↓モデルを改善していく』というこれまでのDNNのパラダイムを崩す可能性があり、学術的なインパクトは計り知れません。ビジネス化も推進していきますので、学術・社会両方に幅広く浸透させていくことが期待できます。結果として、九州工大の知名度を大きく上げることにつながるかと考えています。

### おわりに

これまで研究内容について述べてきましたが、ここで『研究活動』について、僭越ながら共同研究代表者・鈴木が述べさせていただきます。2022年の後半以降、つまりStable DiffusionやChatGPTといったいわゆる生成AIの発表以来、AIの普及は爆発的に加速しました。特に、最もAIに代替される可能性が低いと言われていたクリエイティブ領域での進歩が目覚ましいです。さらに、この生成AI領域で開発された技術を他のアプリケーションに展開することで、従来の(例えば認識)技術も進歩を遂げています。日々数え切れないほどの発表があり、自分の研究に類似したもの・上位互換のようなものがあります。この奔流に対して、我々に求められるのは自分の世界観を明確にすることだと思います。この研究では、メタデータセットを構築することで、誰も実現してこなかったタスクとデータセットの最適予測を実現するという独自の世界観を掲げています。発表されている研究や技術もそれぞれの研究者が持っている世界観を実現させる

ための要因の一つでしかありません。我々に求められることは、流されることなく着実に自分の世界観を実現する方法を考えていくことだと思います。こう考えると視点は変わり、他者の技術でさえその要因にすることができません。世の流れに対して動じることなく、自分の思う未在像に向けて研究活動をしていければと思います。

### 付録・重要語句と前提知識

読者の皆様に、文脈から判断させてしまうことのないように、この文章内での言葉の定義や前提知識などを示しておこうと思います。

- AI: Artificial Intelligence、人工知能のこと。その実現方法の一つが機械学習であり、機械学習のアルゴリズムの一つがDNNである。
- 機械学習: AIの分野の一つで、入出力関係から挙動を自動的に予測させるもの。学習によって、アルゴリズムが持つパラメータを調整する。
- 学習: 与えられた入出力関係を実現できるように、機械学習アルゴリズムのパラメータを調整すること。
- ニューラルネットワーク: 機械学

習の分野の一つで、複数のニューロン同士がシナプスを通じて結合し、ネットワークを形成している。

- DNN: Deep Neural Network、深層ニューラルネットワークのことで、ニューラルネットワークのアルゴリズムの一つ。3層以上のもの。図1のモデルを指してDNNというのが正確だが、学習というプロセスを通じて、タスクをこなせるようになったAIをタスク特化型DNNと呼ぶことにする。

また、モデルの開発やデータセットの作成や学習を行うことなどを総称してDNNの研究開発と呼ぶことにする。

- タスク: 機械学習アルゴリズムが挙動を予測する対象。人間の挙動。
- データセット: タスクを実現するための入出力関係のまとまり。機械学習アルゴリズムが学習するもの。入出力関係のうち、入力データを、出力を教師データとする。
- モデル: DNNのアーキテクチャ、構成するネットワークの形状のこと。

### 引用

[1] Hhikino-Musashi@Home  
<https://www.brainkyutech.ac.jp/~hma/ja/top/>