

## 寄稿 人工知能技術を俯瞰する

鳥海 不二夫

(東京大学大学院工学系研究科准教授)

1. はじめに
2. 人工知能の分類～現在のA I と夢のA I
  - (1) 強いA I ・弱いA I
  - (2) 汎用型A I と特化型A I
  - (3) 現在のA I の根底にあるシステム
3. 人工知能技術の分類
  - (1) 人工知能技術俯瞰図
  - (2) 教師有り学習
4. 深層学習
  - (1) 深層学習の基礎技術
  - (2) 深層学習を用いた技術の研究開発
5. 人工知能の利用の今後
  - (1) 人工知能とビッグデータ
  - (2) 人工知能をどう捉えるか
  - (3) 人工知能技術の開発支援戦略
6. 終わりに

### 1. はじめに

A I すなわち人工知能の発展は目覚ましく、すでにわれわれの日常生活の中でも人工知能と呼ばれる技術が利用された製品やシステムが多数存在している。

その一方で、人工知能という言葉の曖昧さから、「人工知能」と聞いて想像されるものと、実際に使われている技術の間には乖離が存在することも多い。人工知能という言葉の定義は研究者の間でも統一はされておらず、様々な技術を大まかに「人工知能」という言葉で括っているのが現状である。そのため、マスメディアなどで気軽に使われる人工知能という言葉から受ける印象は読者にゆだねられており、実態とはかけ離れたものを想像させてしまうことも少なくない。

本稿は、「人工知能とは何か」を様々な視点から述べ、多彩な意味で使われる「人工知能」がどのような文脈、どのような意味で使われているのかを理解するための一助となることを目指す。また、現在の人工知能がどのようなものと捉えるべきかを述べるとともに、今後我が国で人工知能がどのように扱われるべきかの私見を述べる。

## 2. 人工知能の分類～現在のA Iと夢のA I

### (1) 強いA I・弱いA I

人工知能を表す Artificial Intelligence という言葉が初めて使われたのは「ダートマス会議」であると言われている。これは、世界初のコンピュータ ENIAC が完成した 1946 年からわずか 10 年後にアメリカのダートマス大学で開かれた人工知能に関する世界初の会議である。この会議は当時の人工知能研究を牽引する研究者らによって行われた会議であり、自然言語処理やニューラルネットワークなど現在の人工知能につながる技術について議論が交わされた。

しかしながら、この時代の人工知能はコンピュータの性能が低かったこともあり、一般に普及する製品に搭載されるようなレベルではなかった。一方で、人工知能という言葉の魅力からか SF などでは頻繁に人工知能が登場した。そのため、一般の人々の目に触れるのは長らく夢の人工知能、SF の人工知能のみであった。1968 年に公開された映画「2001 年宇宙の旅」に登場した、人間と会話をし、チェスを楽しむ人工知能 HAL 9000 はその代表であろう。日本においても、鉄腕アトムやドラえもんなど人工知能という名前こそついていないものの、人のようにモノを考える人工知能を搭載したロボットが様々な SF に登場し、親しまれている。

このような SF の存在によって人工知能とは「人のようにモノを考える機械である」という捉え方をされることが多く、現在実際に製品やシステムに搭載されている人工知能との乖離は大きい。

SF に存在する人間のようにモノを考える人工知能と現在の人工知能を区別するために、いくつかの言葉があるが、最も明確にその二つを区別する言葉が「強いA I」「弱いA I」であろう。ここでの強い弱いとは物理的な強弱ではない。人間のように意識を持ったA Iを「強いA I」と呼び、機械的な判別を行うA Iを「弱いA I」(参考文献[1])と呼ぶ。この二つは明確に異なる概念である。

現在人間のように意識をもって自律的に行動する「強い」人工知能は存在しない。自律的に動いているように見える人工知能であっても、その裏にはアルゴリズムが存在しており、そのアルゴリズムに従っているだけである。現在我々が利用する「知的に見える処理を行うA I」は「弱いA I」と呼ばれ同じ人工知能という名前を冠しているが、意識を持ったA Iとは全くの別物である。

では、強いA Iはいつごろ登場するだろうか。また、それについてどの程度考慮する必要があるだろうか。研究者によって意見は異なるが、少なくとも10年程度では強いA Iが実現する可能性はないといってよいだろう。そもそも、現状では「意識」とは何かですら明確ではなく、何ができれば強いA Iであると言えるのかも分かっていない。したがって、

人工知能ブームだからといって意識を持った自律的な「強いA I」についてまで考慮することは、言わば「リニアモーターカーが完成しそうだから、どこでもドアについても考慮しよう」と言うに等しい。たまたま同じ人工知能という名前がついているだけであり、強いA Iは我々が現在目にするA Iとは全く違う存在であると考えべきである。

## (2) 汎用型A Iと特化型A I

強いA Iは意識を持った人間のようなA Iであり、いまだ実現への道は明らかになっていない。一方で、現在の人工知能から一步進んだ人工知能として、汎用型A Iがある。現在の人工知能は特化型A Iと呼ばれ、特定のタスク（仕事）を行うように設計されているものである。例えば、1997年に世界チェスチャンピオンを破ったチェスプログラム、ディープブルーは、チェスについては人間を凌駕しているが、ディープブルーに将棋を指させることはできない。人間であればチェスを学べばある程度将棋も比較的簡単に覚えることができ、指すことができるようになるにもかかわらず、である<sup>1</sup>。

このような人間が持つ「ある知識を他へ応用する」といった汎用性を持ったA Iを汎用型A Iと呼ぶ。汎用型A Iの対義語は「特化型A I」であり、これはある特定の問題のみを解くことができるA Iのことを指す。汎用型A Iは言うなれば人間の脳のようなアーキテクチャーを持つ存在である。すなわち、一つのアーキテクチャーを様々な問題に適用できることを意味し、「想定外の事態に対応する」といった機能を有することが期待される。一方、特化型A Iは決められた作業を自動的にこなす存在であり、特定のタスクについては人間以上の能力を発揮するが、それ以外のタスクは解くことができないA Iである。

なお、汎用型A Iと強いA Iはよく混同されるが、この二つも明確に異なるものである。汎用型A Iは様々な問題を解くことが可能な人工知能であり、強いA Iの定義である「意識の有無」は関係がない。

汎用的なアーキテクチャーを持つ人工知能はやはり現在研究中であり、いまだ存在しない。しかしながら、強いA Iが到達への道筋すら見えていない状況なのに対し、汎用型A Iを作ろうという試みは日本を含め世界で行われており<sup>2</sup>、強いA Iよりは近いところにあると言ってよいだろう。

## (3) 現在のA Iの根底にあるシステム

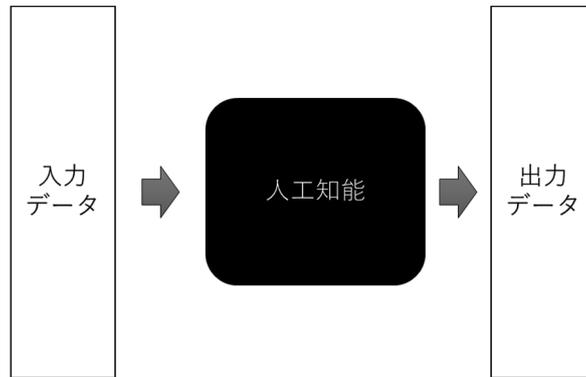
では現在世間をにぎわしているA Iとはなんだろうか。極論を言えば、現在存在するA Iの根幹は入力されたデータに対して適切な出力データを出力するシステム（図1参照）及びそれを利用したシステムである。

---

<sup>1</sup> 例えば、将棋棋士の羽生竜王は、日本有数のチェスプレイヤーでもある。

<sup>2</sup> 例えば、「全脳アーキテクチャーイニシアティブ」<<https://wba-initiative.org/>>など（以下、URLの最終アクセスの日付けはいずれも平成30年9月11日。）

図1 現在の人工知能の基本システム



(出所) 筆者作成

例えば、第3次人工知能ブームの火付け役の一つである Google による「猫の認識」について考えてみよう。深層学習を利用して大量の猫の画像を学習させることによって、ある画像をコンピュータに入力すると、それが猫かどうかを認識できる人工知能を Google が作成した。この猫の認識を図1に照らし合わせて考えてみよう。この場合、入力データは画像データであり、出力データは「猫が含まれている」「猫が含まれていない」の二値となる。入力データは画像であればなんでもよいが、もしそこに「猫」が含まれていれば、出力データとして「猫が含まれている」が出力され、例えば「飛行機」の写真が入力されれば、出力データは「猫が含まれていない」となる。

もちろん、現在人工知能と呼ばれているものはこのような技術が組み込まれたより複雑なシステムである。しかしながら、その根底には入力データから判別を行いデータ出力するシステムが存在する。

例えば、自動運転であれば、入力データとして車載カメラの画像が存在し、それに対してそこに写った物体の種類と位置が出力データとして得られる。これによって、対向車や歩行者の存在や信号の色などを判別させる、言わば「車の目」ができ自動運転が実現した。もともと、周りの状況さえ正確にわかれば、正確な運転を行うことのできるアルゴリズムは従来の技術でも可能であった。それは、例えばすべてがデータ化された環境で運転を行うレーシングゲームなどを考えれば理解できるだろう。しかしながら、そもそもデータ化されていないリアル世界で状況をコンピュータが理解すること自体が難しかったのである。それをディープラーニングが可能にしたところにブレイクスルーがあり、そのディープラーニングはまさに図1に示した判別システムである。

### 3. 人工知能技術の分類

#### (1) 人工知能技術俯瞰図

現在の人工知能を支えるのは入力に対して適切に出力を返すシステムであるが、どのようにして適切な出力を返すシステムを作ればよいだろうか。いかに精度のよい判別システ

ムを作るかが人工知能技術のカギとなる。古くは、人間が判別ルールを作成するエキスパートシステムや、論理演算によって演繹的に解を導く論理推論システムなどが存在したが、現在の主流は学習型の人工知能技術、すなわち機械学習である。

機械学習は基本的には大量のデータを元に学習を繰り返すことによって徐々に判別能力を向上させていく手法である。主な手法として教師有り学習、教師無し学習、そして強化学習が存在する。

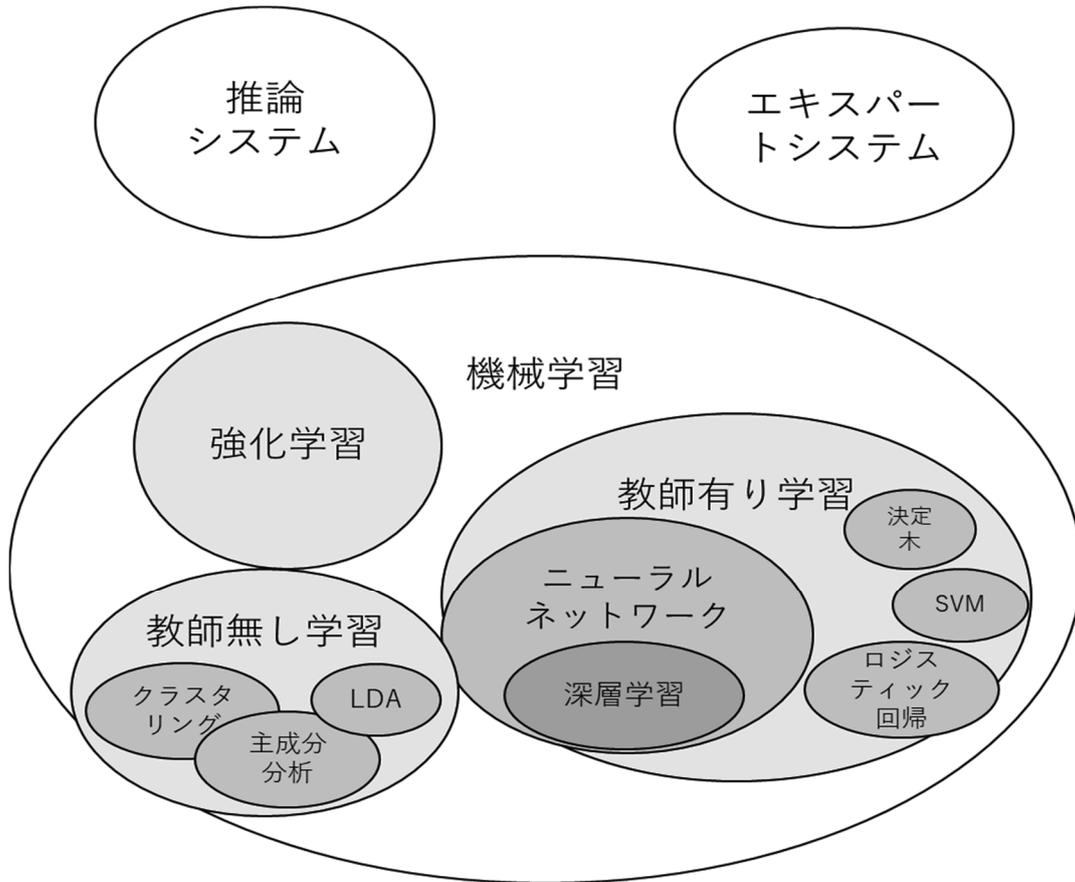
教師有り学習はあらかじめ「正解」のデータを用意しておくことによって、「どのような特徴を持つデータがどのように判別されるべきか」を判別システムに与え、入力データから出力データを算出するアルゴリズムを作る手法である。現在の人工知能ブームを支えるディープラーニングも教師有り学習の一つである。詳しくは3.(2)節にて説明する。

教師無し学習は、正解データが存在しないデータから何らかの出力を得る手法である。基本的にはデータの構造を導出することが目的の学習である。主な教師無し学習として、クラスタリング、LDA、主成分分析等が存在する。クラスタリングは、データを自動的に分類する手法である。データの類似性に着目し、類似したデータは同じグループ、類似していないデータは異なるグループとして分類していくことによって、教師データ無しにデータを複数のグループに分割していくことができる。教師有り学習とは異なり、あらかじめ正解を与えることがないため、計算前には想像もしなかった意外な分類が発見されることもある。

最後に、強化学習は、トライ&エラーを繰り返す学習方法である。強化学習では人工知能を一種のエージェントと捉え、ある環境下に置かれたエージェントが環境情報に基づいて行動を決定し、より良い結果に結び付くような行動を行った場合に報酬を得ることで徐々に環境に適応した行動をとるようにする学習アルゴリズムである。例えば、将棋などのゲームに対して強化学習を応用すると考えれば、ある状態でどのように指せば最終的に勝利に結び付くかを何万回というゲームをプレイすることで学習していく手法である。碁の世界チャンピオンを破ったAlpha-Goでも強化学習が深層学習と併用して用いられていた。

機械学習を含めた人工知能技術の関係を図2に示す。第3次人工知能ブームを支える中心的な技術である深層学習=ディープラーニングは、「人工知能技術の中の機械学習の中の教師有り学習の中のニューラルネットワークの中の一技術」という位置付けになる。このような人工知能技術同士の関係を正しく理解することは、人工知能に関する情報を正しく整理する上で重要である。

図2 人工知能技術の関係図



(出所) 筆者作成

## (2) 教師有り学習

さて、現在の人工知能技術の中心である教師有り学習についてももう少し詳細に見ていこう。

教師有り学習とは、言わばあらかじめ入力 $x_i$ と出力 $y_i$ の組を用意し $y_i = f(x_i)$ となるような関数 $f(x)$ を作り、未知のデータ $x_j$ に対して適切な出力 $y_j$ を求めるための手法と言える。ここで重要となるのは、どのようにして精度の高い関数 $f(x)$ を作るのか、ということになる。

教師有り学習において関数 $f(x)$ を学習する代表的なアルゴリズムとして、ナイーブベイズ、ロジスティック回帰、決定木分析、Support Vector Machine (SVM)、ニューラルネットワーク (深層学習) などがある。

これらの手法はそれぞれに長所短所を持っており、どのアルゴリズムを採用すべきかは問題によって異なる。

ナイーブベイズは、古くは迷惑メールの分類などに利用された手法で、ベイズの定理を利用した比較的シンプルな判別機である。単純なアルゴリズムでありながら強力な判別能力があり、データ量が比較的少なくて学習が可能である。

ロジスティック回帰は回帰の一種であり、目的変数が0か1の場合、すなわち二値分類問題に利用される。理解のしやすさと性能の高さから非常によく使われる手法の一つであ

る。

決定木分析は非線形データの回帰に用いられる手法である。ノンパラメトリックな学習手法であり、どのようなデータに対しても何らかの予測モデルを作ることが可能である。ただし、後述する「過学習」を起こしやすいため、複数の決定木分析を組み合わせるランダムフォレストやBoosted Treeなどのアルゴリズムもよく利用される。

SVMは2クラス判別器であり、マージン最大化を行うことによって未知データを精度よく分類することが可能な手法である。基本的なアルゴリズムでは線形問題しか解くことができなかったが、カーネルトリックと呼ばれる数学的な工夫を行うことで、非線形分類器としても適用可能である。

ニューラルネットワークは、1958年に発表されたパーセプトロンからスタートした生物の脳をモデル化した高い識別能力を持つ判別手法である。しかしながら過学習を起こしやすいという欠点も持つ。ディープラーニング（深層学習）は通常3層からなるニューラルネットワークを多層に拡張したものである。多層に拡張することで表現力が向上し、利用する特徴量の選択が自動化され人手よりも良い特徴を自動で利用することで高い精度で判別が行えるようになった。その一方で、学習には大量のデータと処理時間が必要となる。

ロジスティック回帰や決定木分析などは高い解釈性を持つことが特徴である。解釈性とは「なぜそのような結果になったのか」が明確であるかどうかである。ロジスティック回帰では、データのどこが判別に使われたのかが重みとして表現されるため、「なぜそう判別されたのか」を人間が理解しやすい。一方で、深層学習では判別をつかさどる関数そのものが複雑すぎて、人間には解釈不可能である。そのため、精度は高いがなぜその結果が出たのかはブラックボックスとなる。

また、学習に必要なデータ量もアルゴリズムによって異なる。データが少なくても学習すること自体は可能であるが、学習結果が学習に利用したデータに強く影響を受け、学習に利用していないデータの判別が正しく行われなくなる。このような状態を「過学習」と呼び、教師有り学習では最も避けるべき事態の一つである。逆に学習データに依存しない形で学習ができることを汎化と呼び、汎化能力の高い学習アルゴリズムは良いアルゴリズムと言える。例えば、ニューラルネットワークは過学習を起こしやすいことが知られているが、深層学習はドロップアウトなどを利用して過学習を防いでいる。また、SVMは「マージン最大化」によって高い汎化能力を実現している。

機械学習をそのアルゴリズムが持つ特徴に基づいて、解釈性、精度の二軸で分類したものを図3に示す。

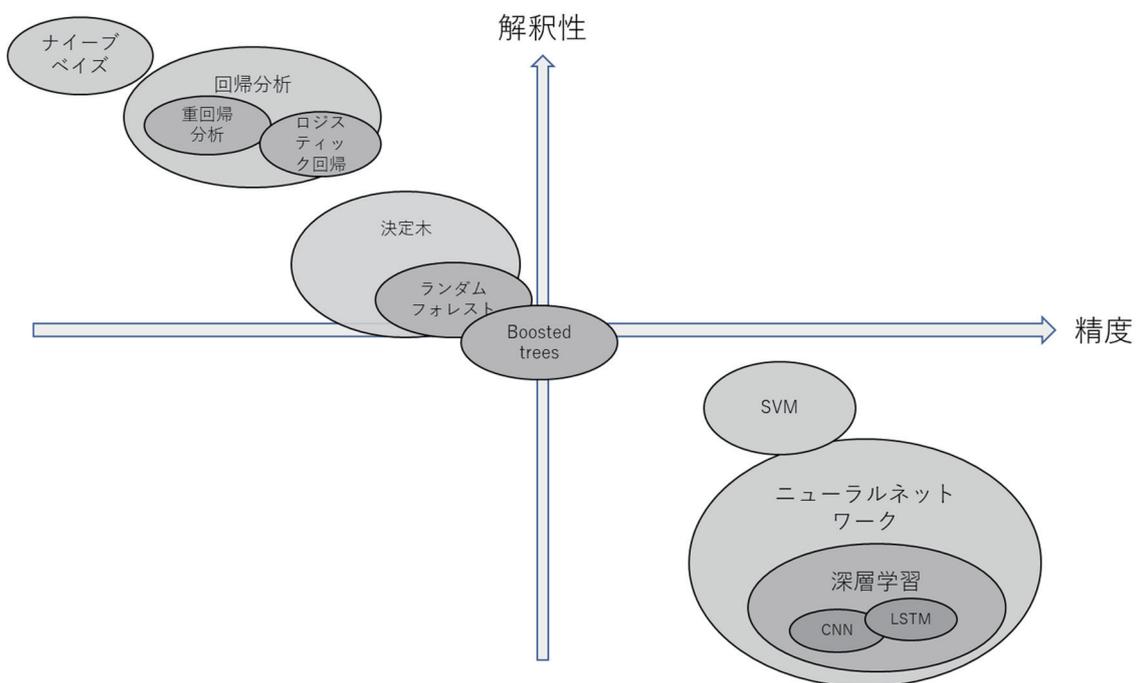
このように機械学習はそれぞれ異なる特徴を持っており、どれが一番良いと言うことはできない。何にでも使える機械学習の手法は存在しないことを「No Free Lunch Theorem」と呼ぶ。現在の人工知能ブームの中心は深層学習であるが、精度の高さと引き換えに大量のデータを学習に必要とし、また解釈性は極めて低い。したがって、例えば人事評価のようなナイーブな判断を行う場合には、解釈性が低い手法は使いづらく、深層学習などはたとえ精度が良かったとしても利用しないほうがよいだろう。

弱い人工知能であっても、人工知能という名前がついていると「自動的にこれまで解け

なかった様々な問題が解けるようになる」と誤解を招くことが多いが、話はそれほど単純ではなく、人工知能技術の何を使うのか、どのように使うのか、そしてデータは十分に存在するのか、そもそも解ける問題なのか、など問題を解く上で人工知能技術者が考えるべきポイントは多い。その意味では、人工知能を使えば魔法のようにどんな問題でも解けるわけではない点に注意が必要である。

また、ロジスティック回帰などで十分解くことができる問題にディープラーニングを用いると、膨大な処理時間が必要になったり、処理に利用する機器が高額になったりする。問題を解く上で必要なコストを正しく見積もることも重要である。

図3 機械学習の分類



(出所) 筆者作成

## 4. 深層学習

### (1) 深層学習の基礎技術

先に述べた通り、機械学習には様々な手法が存在し、適切なものを選択する必要があるが、その中でも従来にない高い精度を実現し、現在の第3次人工知能ブームの中心となっている人工知能技術が、深層学習（ディープラーニング）（参考文献[2][3]）である。特に深層学習がその効果を発揮しているのが画像認識と自然言語処理の分野である。

深層学習が最初に大きく注目された出来事の一つが、2012年に行われた一般画像認識コンテスト ILSVRC2012 であろう。一般画像認識コンテストとは、何らかの画像の中に何が写っているのかを自動的に認識する精度を競うコンテストである。それまでは人間が精度をよくする特徴量を手作業で作成していたのに対し、トロント大学のチーム SuperVision は深層学習を用いて特徴量を自動的に算出し認識を行った結果、他のチームに10%近い差

をつけた高い認識率を実現した。画像認識コンテストには画像処理を専門とした研究者が参加していた中、画像処理を専門としていないチームが好成績を出したことに大きなインパクトがあり、深層学習への注目が一気に広がった。

画像認識は、画像内に存在する物体の認識（一般画像認識）だけでなく、顔認識や、ロボットや自動運転の実現でも欠かせない技術でもある。医療現場においても医療画像分析において深層学習の利用に期待が集まっている。画像処理には、畳み込みニューラルネットワーク（Convolutional Neural Network：CNN）（参考文献[4]）がよく利用され、画像認識におけるデファクトスタンダードと言ってよいであろう。

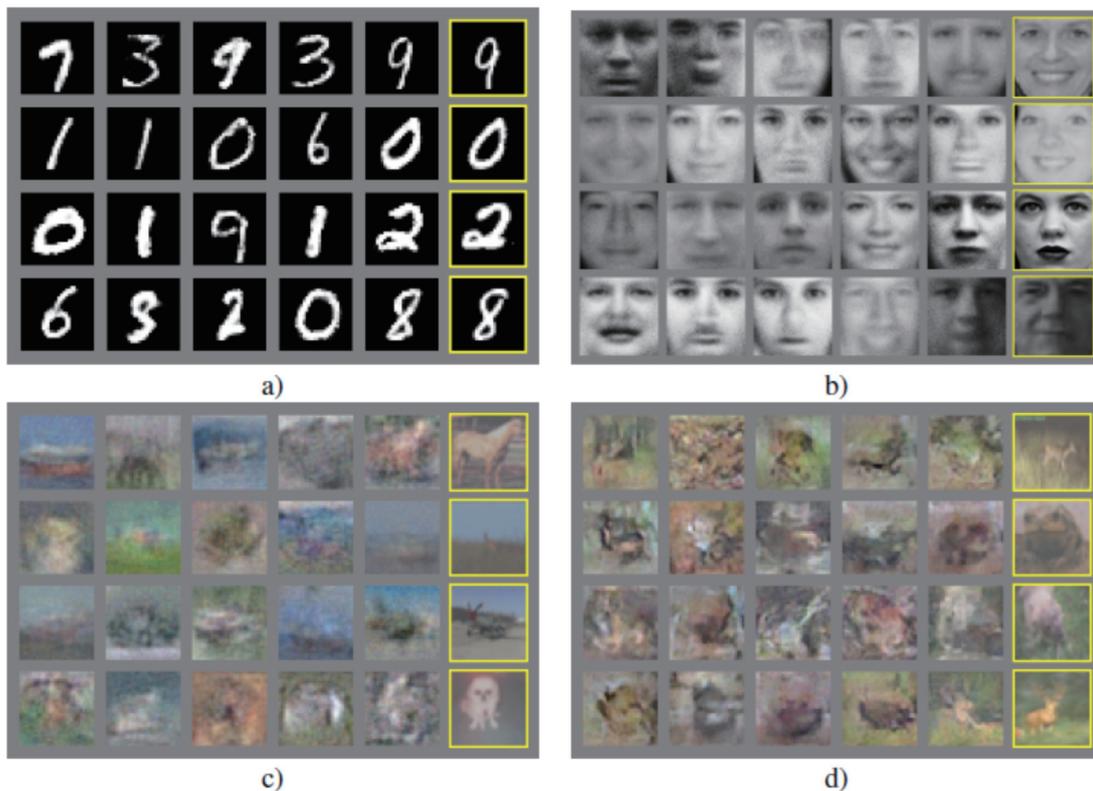
一方自然言語処理では、Long short-term memory（LSTM）（参考文献[5]）がよく用いられる。LSTMでは入力の時系列順を保持しておくことができ、時系列に基づいた出力を行うことが可能なモデルとなる。そのため、ある単語列が入力された場合に適した出力を返すことが可能となる。この性質を利用し成果を上げている事例に、機械翻訳がある。2016年にGoogleが発表したGNMT（Google's Neural Machine Translation system）は、高い精度の翻訳を実現し、世界に衝撃を与えた。

また、深層学習を利用して新しいデータを作り出すGenerative Adversarial Network（GAN）（参考文献[6]）にも注目が集まっている。GANは画像生成などで用いられる。GANでは二つのディープニューラルネットワークを用意し、片方で学習を行い（discriminator）、もう片方で生成を行う（generator）。ここで、discriminatorは入力されたデータが本物かどうかを見極めるよう学習を行い、generatorはdiscriminatorを騙すようなデータを出力するように学習を行う。これによって、discriminatorはよりgeneratorが生成したデータを見破りやすくなるが、generatorがその上をいけば、discriminatorにも見破られない偽データを作ることができる。このようにして生成された画像の例が図4である。数字であれば精度よく作成できているほか、人物の顔なども自動生成が可能となっている。

もう一つ、深層学習を利用した技術で様々な分野で利用が進みつつあるものに、データの特徴空間への埋め込み（Embedding）がある。この技術で特に有名なものに単語をベクトル化したWord2Vecがある。本来単語は英単語であればアルファベット、日本語であれば平仮名や漢字で表現されるものであるが、Word2Vecでは単語の周辺に出てくる単語に基づいて、単語自体をある空間上のベクトルとして表現し、コンピュータにも扱いやすくする手法である。ベクトルは数学的に扱えるため、「王様－男性＋女性＝女王」や「パリ－フランス＋日本＝東京」のように単語の足し算や引き算、単語同士の近さの比較などを行うことができるようになる。単語の埋め込み技術の発展によって、言語処理の技術が飛躍的に向上した。

このように、深層学習はその高い判別能力を生かして様々な場面に応用可能な基礎技術として利用されている。

図4 GANによる画像生成。黄色い枠が生成された画像。



(出所) Goodfellow, Ian, et al. "Generative adversarial nets." Advances in neural information processing systems. pp. 2672-2680 (2014)

## (2) 深層学習を用いた技術の研究開発

深層学習を利用したシステム開発にはいくつかのレイヤーが存在する。それぞれのレイヤーを図5に示す。

まず、基礎技術としてCNN、RNN、LSTMなど深層学習を発展させる技術が研究されている。さらに、それらの基礎的な技術を利用するためのライブラリも多数開発されている。現在のデファクトスタンダードはGoogleが開発したTensorflow<sup>3</sup>及びKeras<sup>4</sup>である。日本においてもPreferred Network社がニューラルネットワークのライブラリChainer<sup>5</sup>を開発している。また、SONYがグラフィカルにニューラルネットワークを構築できるNeural Network Console<sup>6</sup>を無料開放し、話題となった。

次に、これらのライブラリを使い、一般物体認識や自然言語処理、異常値検知など基礎的な人工知能技術を開発するレイヤーが存在する。さらに、それらの人工知能技術を使い、対話システムや自動運転などの応用的なAIシステムが構築される。

<sup>3</sup> <<https://www.tensorflow.org/>>

<sup>4</sup> <<https://keras.io/>>

<sup>5</sup> <<https://chainer.org/>>

<sup>6</sup> <<https://dl.sony.com/>>

図5 AIシステム開発のレイヤー



(出所) 筆者作成

どのレイヤーにおいても現在技術の研究開発が日進月歩で行われている。ここで言う日進月歩というのは比喩ではない。1年前の情報ではもう古いといわれ、従来研究開発の発表の場であった論文は掲載されるまでに年単位の時間がかかることから忌避され、数か月で発表の場が得られる国際会議であっても時間がかかりすぎると考えられている節もある。

深層学習の最新情報は今やプレプリントサーバで得ることが常識となりつつある。最もよく使われるプレプリントサーバは arXiv.org<sup>7</sup>であり、ここに掲載された技術情報は早いものであれば数日中に実装され、ソフトウェア開発プラットフォームの GitHub<sup>8</sup>にオープンソースとして掲載され、数か月で利用や改良が行われる。

このように、現在の人工知能周りの開発スピードは数か月単位で動いており、従来の研究開発の考え方では世界の最先端に行くことは難しい。

## 5. 人工知能の利用の今後

### (1) 人工知能とビッグデータ

人工知能は今後の社会の発展には欠かせない存在である。すでに世界は先進的な人工知能技術を持った企業が他の企業を圧倒する時代が訪れている。人工知能技術を単なるソフトウェアと捉えて過小評価すると、我が国は他国に対して大きく後れを取ることになるだろう。

人工知能技術をさらに発展させるには何が必要だろうか。人工知能技術が発展した三つの要素として、アルゴリズムの発展、コンピュータ技術の発展、ビッグデータの存在があると考えられる。

<sup>7</sup> <<https://arxiv.org/>>

<sup>8</sup> <<https://github.com/>>

特に、2010年代に騒がれたビッグデータは人工知能技術を下支えする重要な技術である。単なるパスワードとしてビッグデータと人工知能を捉えるとその本質を見失うことになる。現在の人工知能技術のほとんどは大量のデータによって支えられており、データなしに人工知能の実現はあり得ない。

一方で、現在の我が国では大量に存在するはずのデータを適切に扱うことができていない。海外ではGoogle、FacebookなどGAF Aが大量の情報を保持し、それに基づいて機械学習を用いたサービスを次々に開発している。中国ではアリババなどは個人に紐づいた大量データを保有することで、ほぼ社会インフラともいべきレベルで社会に入り込んでいる。それに対して日本ではそこまでの大量のデータを保有した企業は存在するだろうか。あるいは、それを有効に使うことができているだろうか。

これまで大量のデータは主にWEBを介して存在していた。今後はIoTの発展により、リアル社会における大量のデータも利用可能となり、いかにデータを効率よく利用するかが技術の発展の決め手となってくるだろう。

日本ではハードウェア信仰が極めて強く、ソフトウェアやシステム、データに対する考え方が世界の動きに追いついていないように思える。日本においては「職人芸」など極めて属人的な技術がもてはやされるが、それらを人に依存しない形でシステム化しなければ、それはデファクトスタンダードにはなりえず、世界では戦うことができないと考えられる。

そのためにも、大量のデータの確保は人工知能時代に最も重要なミッションの一つとなる。

## (2) 人工知能をどう捉えるか

人工知能技術は過小評価すべき存在でもなく、また、過大評価すべきでもない。「人工知能を使えば〇〇ができる」という妄想は極めて危険である。人工知能技術を売り込もうとする一部の企業では売り込みのために過大に人工知能技術の能力を高く表現するが、実際には人工知能技術が生かされる場面もあれば、そうではない場面も存在する。

特に多い事例として、データが存在しないにもかかわらず人工知能を使えば何とかできるだろうという考え方である。現在の人工知能は基本的に機械学習であるため、十分な学習データがあって初めて力を発揮する。少ないデータから結論を導き出す能力はまだ人間のほうがはるかに優れている。

したがって、人工知能技術を使えば何でもできる、ではなく、自動化できなかった判別ができるようになる、あるいは従来より精度よく自動的に判別が行える、と捉えるべきである。また、そのためにはそれに見合うだけのデータが必要であるということを理解しなければいけない。

現在の情報化社会においては、様々な情報へのアクセスが容易になっている一方で、それらの情報には多数のポジショントークが存在する。人工知能技術のような新しい技術については、特にその傾向が強い。嘘ではないが、ストレートに信じるべきではない情報も数多い。例えば、新聞や雑誌に出ている人工知能技術の中には、マーケティング視点の人工知能であり、技術的な意味での人工知能ではないものも含まれる。すなわち、「売るため

に名前を付けただけ」であったり、必要以上に大げさな書き方をしていたりするわけである。そこには商品売りたい企業の思惑だけではなく、記事にインパクトを与えたいというメディアの思惑もあるだろう。フェイクニュースが今話題となっているが、フェイクニュースとは言わなくても眉唾物の記事も世の中には氾濫している。

もちろんそれはメディアだけではなくあらゆる場所にそのような情報はあふれてしまっている。したがって「人工知能で何ができるのか」「人工知能とは何か」を正しく理解することは極めて難しい。

研究者間でも意見が割れることは多く、それぞれの立場で異なる考え方が存在する。例えば、現在日本の人工知能技術をけん引する一人である松尾豊氏は今後の世界を左右する人工知能技術はディープラーニングであると考え、日本においてもディープラーニングを使った産業を発展させるべきであり、ディープラーニングの技術者を育てるべきであると考えている。一方で「人工知能はディープラーニングだけではない」という考えを持つ研究者もあり、そういった研究者は人工知能＝ディープラーニングではなく、ディープラーニングには限界があることを声高に叫ぶだろう。ではどちらの研究者が正しいことを言っているのだろうか。おそらくどちらも間違っていない。人工知能技術はディープラーニングだけではないが、ディープラーニングが今後の社会を支える技術であることも事実なのである。しかし、どちらかの情報だけを妄信的に信じてしまうと正しく人工知能技術の全体像を理解することはできなくなる。

これはシンプルな事例であるが、同様のことは様々な場面で生じうるだろう。このような状態で、人工知能を専門としていない意思決定者は、どのように人工知能技術を捉え判断を行えばよいだろうか。例えば、強い人工知能や汎用人工知能が実現しているかのような意見があれば、それは明らかに間違っていると判断できる。人工知能をイメージではなく実態に沿って理解することが最も重要である。

### (3) 人工知能技術の開発支援戦略

ディープラーニングなどの人工知能技術によってできることが膨大に存在するため、様々な組織で技術開発を行うことが重要であると考えられる。人工知能技術を開発するためにはある程度の予算は必要ではあるが、ハードウェアの開発に比べはるかに低予算で実現可能である。したがって、多くの企業や研究機関で人工知能技術を利用したサービスやシステムの開発が可能である。

一方で、すでに述べたように現在の人工知能技術の中心である機械学習にはデータが欠かせない。いかにデータを収集保存活用するかが人工知能技術開発のカギとなる。そのため、むしろ技術力の有無よりも基盤となるデータの有無に着目して開発力を捉えたほうがよい。その意味では、例えば国が人工知能技術について支援を行おうとする場合は、特定の企業や研究機関にいわゆる「選択と集中」を行うのではなく、多数の企業と研究機関による技術開発を期待する「ばらまき型」のほうが適切であろう。たとえ支援については「選択と集中」ができたとしても、データの「選択と集中」は事実上不可能であるため、支援だけ集中しても人工知能技術に関しては発展が見込めない。できるだけ幅広く裾野を広げ、

大学や研究所とデータを持つ企業を結び付けるような支援を行うことで、その中のいくつかが優れた技術・システムの開発を実現することに期待をするほうが日本の人工知能技術全体の発展には寄与するだろう。

実際、現在世界を席卷しているG A F A (Google、Apple、Facebook、Amazon) は選択と集中によって成長した企業ではない。言ってしまうと無数に存在した企業の中で偶然成長した企業がポジティブフィードバックによって高い成長力を獲得したと捉えたほうがよい。例えばFacebook は、登場した当初は世界中には無数にあるソーシャルメディアの一つに、すぎなかった。しかしながら、偶然ユーザが増えることで多くのデータを集約できるようになり、それを分析利用することでサービスを向上し、現在の地位を確立した。これは狙ってできるようなものではない。

人工知能技術の特性を考えれば、できるだけ多くのデータを保有する企業と技術を持つ研究機関を支援し、人工知能技術を応用したシステム・サービスを開発できる環境を整えることこそが、今後の我が国の人工知能技術の発展に寄与する戦略となるだろう。

## 6. 終わりに

本稿では、人工知能技術を網羅的に理解するため、複数の視点から人工知能技術を説明した。「人工知能」という名前がついているものの中には、いまだ実現への道筋が見えない強いA I から、現在盛んに研究開発が行われ実際に利用されている深層学習まで様々なものが存在する。人工知能という言葉だけを捉えるのではなく、いったいその本質が何なのかを理解しなければならない。

現代の人工知能と呼ばれるものはその基本は機械学習であり、インターネットやI o T の発達によって作られた大量のデータと、高性能コンピュータ及び高度なアルゴリズムの発達によって実現した技術である。

特に、深層学習の発展が目覚ましく、画像処理、言語処理の分野で実利用に耐える精度が実現されたことが、現在の第3次人工知能ブームを支えている。深層学習をはじめとする機械学習は、極めて基礎的な技術であることから、その応用範囲は広い。画像、自然言語、音声などメディア処理はもちろん、異常検知など大量データの処理にも適している。

これらの技術は比喻ではなく日進月歩で進化しており、世界中、特にアメリカと中国での人工知能技術の発達は目覚ましい。人工知能技術で世界に後れを取れば、日本は技術立国としての立場を維持することはできない。人工知能は、インターネット界限や情報通信業だけではなく、運輸、建設、医療、金融などの分野へも利用され始めている。近い将来には、農業や林業など一次産業も人工知能技術無しには成り立たなくなる。特に日本の強みである製造業、モノづくりにおいても人工知能技術は積極的に取り入れなければ今後世界と対等に渡り合うことすら難しくなる。

人工知能に関する国際会議の最高峰N I P S 2018 は、参加チケットがわずか12分で売り切れたと言う。現在世界はそれほどまでに人工知能に注目している。これは、決して一過性のブームなどではない。人工知能を正しく理解せずに「強い人工知能」のようなものを想定し、そこに到達しない現在の人工知能技術に失望した結果訪れたのが第二次人工知

能ブーム後の人工知能の「冬の時代」である。1980年代には日本で現在のディープラーニングにつながるネオコグニトロン（参考文献 [7]）が福島らによって提唱されていた。にもかかわらず、現在人工知能分野で日本が後れを取っている要因の一つが、過度の期待とそれによってもたらされた失望であった。

そのような事態を繰り返さないためにも、今の人工知能技術が一体なんなのか、そしてそれはどのように産業界に応用できるのかを正しく見極めることが重要である。そのためには、日々更新される人工知能技術を俯瞰的な視点で理解していく必要がある。

#### 【参考文献】

- [1] 鳥海不二夫『強いA I 弱いA I —研究者に聞く人工知能の実像』（丸善出版、2017年）
- [2] Hinton, Geoffrey E., and Ruslan R. Salakhutdinov. "Reducing the dimensionality of data with neural networks." *science* 313.5786 (2006) : 504-507.
- [3] Hinton, Geoffrey E., Simon Osindero, and Yee-Whye Teh. "A fast learning algorithm for deep belief nets." *Neural computation* 18.7 (2006) : 1527-1554.
- [4] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." *Advances in neural information processing systems*. 2012.
- [5] Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory." *Neural computation* 9.8 (1997) : 1735-1780.
- [6] Goodfellow, Ian, et al. "Generative adversarial nets." *Advances in neural information processing systems*. pp. 2672-2680 (2014)
- [7] Fukushima, K.; Miyake, S.; Ito, T. "Neocognitron: a neural network model for a mechanism of visual pattern recognition". *IEEE Transactions on Systems, Man, and Cybernetics SMC-13* (3): 826-834. (1983)

（とりうみ ふじお）