

深層学習と知財

——技術とビジネスの観点から——

丸 山 宏*

抄 録 深層学習は、現在の第3次人工知能ブームの中心となる技術であり、様々な産業応用が既に行われている。深層学習は、訓練済みモデルなどこれまでのシステム開発にはない生成物を含むために、知財に関する新たな議論が必要であり、特に我が国においてその議論が進んでいる。このような議論の現状を鑑み、さらには深層学習をコア技術とするスタートアップ企業において、深層学習をめぐる知財をどのように戦略的に活用するかを考える。

目 次

1. はじめに
2. 深層学習とは
 2. 1 人工知能と深層学習
 2. 2 プログラミングモデルとしての深層学習
 2. 3 深層学習を取り入れたシステムの構成
3. 深層学習における生成物
 3. 1 訓練データセット
 3. 2 訓練済みモデル
 3. 3 生成モデルの出力
4. 我が国における議論
 4. 1 想定された世界
 4. 2 訓練済みモデルの法的保護
 4. 3 ユーザー企業・ベンダー企業間の契約
5. 深層学習ビジネスの現状
 5. 1 自社開発の場合
 5. 2 インフラビジネス
 5. 3 システム構築
 5. 4 データは本当に「21世紀の石油」か？
 5. 5 訓練済みモデルの流通
6. スタートアップ企業の戦略
 6. 1 知財について
 6. 2 技術競争力の維持
 6. 3 人 材
7. おわりに

1. はじめに

人間の脳細胞の働きにヒントを得たニューラルネットワークのアイデアは1950年代からあるが、それが深層学習という形で花開き始めたのは2000年代になってからである。特に、2012年に画像認識の標準問題において圧倒的な精度を達成してからは、機械学習における中心的な技術として期待されていて、画像認識、音声認識、自動運転など多くの領域で実用化が進められている。

本稿では、深層学習の現状とそれを取りまく知財について、技術とビジネスの両面から解説する。2章では深層学習と、その人工知能研究全体の中での位置付けについて俯瞰し、3章では深層学習をめぐる様々な生成物について解説する。4章と5章では世界に先駆けて我が国で起きた知財の議論と、そのビジネスにおける現状について考える。深層学習をコア技術とするスタートアップ企業において、関連する知財を戦略的にどのように考えるか、6章で議論する。

* 株式会社Preferred Networks PFNフェロー
Hiroshi MARUYAMA

2. 深層学習とは

2.1 人工知能と深層学習

「人工知能」とは、知性を計算機で模倣することによって、知性の本質を明らかにしようとする研究分野を指す言葉である。研究分野を指す、という意味では物理学などと同じカテゴリーの言葉であるが、物理学から派生した技術（例えば内燃機関）やその技術を利用した装置（例えば自動車）を「物理学」とは呼ばないのに対して、人工知能研究から派生した技術、たとえば深層学習を用いたシステムを「人工知能」と呼ぶこともある。ここに、「人工知能」という言葉が混乱を招く第1の要因がある。

「人工知能研究から派生した技術を使ったシステム」を人工知能と呼ぶことに合意したとしても、その研究がいつの時代に行われたか、によって指すものが大きく異なる。第1次人工知能ブームで盛んに研究された技術の1つが自然言語による対話技術であり、その技術の一部は今でもチャットボットなどに広く使われている。一方、人間のように意識を持ち、経験したことのない事象にも臨機応変に対応できるような知性（汎用人工知能と呼ばれる）は、将来の人工知能研究から派生するかもしれないが、まだその実現への道のりは見えていない。混乱を招く第2の要因は、過去の技術を使ったチャットボットも、将来可能になるかもしれない想像上のシステム（例えば映画「ターミネーター」に出てくるロボット）も等しく人工知能と呼ばれることにある。

以上2点の要因のため、「人工知能」について議論をしようとする、議論の対象が定まらず意味のない議論になってしまいがちである。現在の人工知能研究の中心的テーマの1つが機械学習、もう少し狭く言えば深層学習と呼ばれる技術である。深層学習はもともと脳の構造に

ヒントを得たもので、既に画像認識などいくつかのタスクで人間の能力を上回っているが、決して人間のように自ら考える知性ではない。本稿では、深層学習に焦点を当て、この技術をめぐる知的財産権の現状を述べ、将来を展望する。

2.2 プログラミングモデルとしての深層学習

深層学習は、入出力の例示に基づく帰納的プログラミングの方法として捉えると、わかりやすい。一つの例として、摂氏を華氏に変換するプログラムを考えてみよう。通常のプログラム開発では、まず「摂氏を入力として取り、それに対応する華氏を出力する」という要求仕様を定義し、その計算方法を我々が持つ先験的な知識（ここでは、 $F = 1.8 \cdot C + 32$ という変換式）に基づいてモデル化する。このモデルに基づいて設計を段階的に詳細化していき、実装を得る。これを、演繹的プログラミングと呼ぼう。

一方、帰納的プログラミングにおいては、入出力の例を作ることから開発が始まる。例えば、摂氏と華氏の2つの温度計を調達して、時々それらの値を同時に読むことで訓練データセットを得る。訓練データセットに対して、機械学習アルゴリズムを適用し、訓練データセットを模倣するモデルを帰納的に求める。このモデルを用いて入出力の変換を行う（図1）。

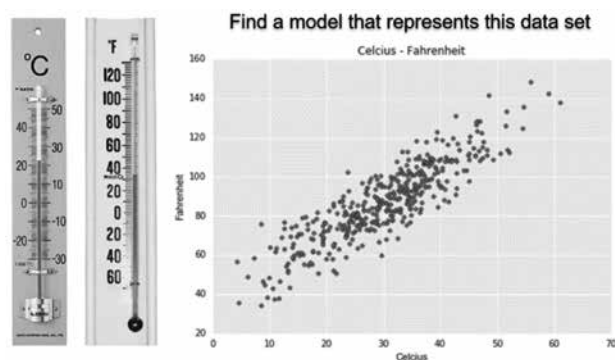


図1 摂氏から華氏へ変換する関数の訓練データ

任意の計算可能関数について、それを十分な精度で近似できるニューラルネットワークが存在することが知られている¹⁾。このため、深層学習は擬似的にチューリング完全と考えることができる。この汎用計算機構は、今までのプログラミングとは異なり、入出力の例示によりプログラミングすることが可能である。

2.3 深層学習を取り入れたシステムの構成

図2に典型的な深層学習応用システムの構成を示す。システムは入力を取り出力を返す。入力・出力はそれぞれ多次元であることが普通である。例えば画像の判別を行うシステムの場合は、ビットマップの各ピクセルの値を入力としてとり、その画像に含まれるオブジェクトのラベル（猫、飛行機など）を出力とする。

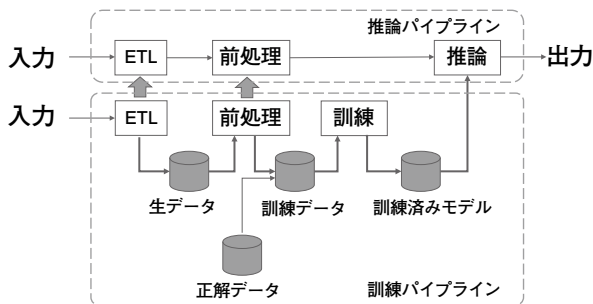


図2 典型的な深層学習応用システム

図の下段は、訓練²⁾を行うパスである。入力データはETL (Extract-Transform-Load) の処理を経た後、前処理が行われる。前処理は欠損データや外れ値の処理、正規化などである。帰納的プログラミングにおいては、各入力データに対してどのような出力が望まれるか、教師信号を付与しなければならない。これには主に4つのアプローチがある。

(1) 教師付き学習

典型的な深層学習では、教師信号は別のデータベースを参照することによって得られる。例

えば、売上予測を行うシステムの場合、過去の実際の売上データが教師信号となる。画像の判別問題などでは、教師信号を手で与えなければならないことがある（アノテーションと呼ばれる）。

(2) 半教師付き学習

すべてのデータ点に対して個別にアノテーションするのはコストが高い。多くのデータ点に対しては教師信号を与えずにその統計的な振舞いだけを学習させておき、比較的少数の教師付きデータを組み合わせることによって高い精度を得られることがあるのが知られている。これを半教師付き学習と呼ぶ。

(3) 教師無し学習

教師信号が全く無くても、機械学習アルゴリズムは入力データの統計的な性質を捉えることができる。これによって、例えば正常時の統計的な性質を用いて、ある入力データが異常値であるかどうかの判定に使うことができる。

(4) 強化学習

教師信号はまた、各データ点に対して、得られた出力を見た後、その出力が望ましいものであったかをフィードバックすることによって、事後に与えることもできる。試行錯誤によって学習するロボットの制御などに使われることがある。

3. 深層学習における生成物

前章で見たように、機械学習応用システムにおいては、通常ソフトウェア開発で得られるソースコードの他に、訓練データセット、訓練済みモデル、システムの出力という大きくわけて3つの生成物がある。これらの生成物は、多くのコストと知見を結集したものであり、多大な価値を持つ知的財産と考えることができる。

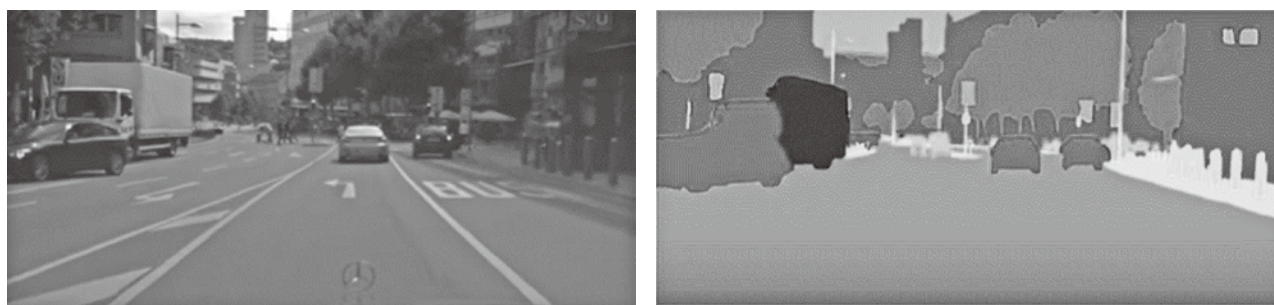


図3 自動運転用の訓練データセットCityscapesに含まれる元画像(左)とアノテーション済みの画像(右)の例

従って、ソースコードや設計の再利用が今までのITの普及に極めて重要だったと同様に、特に上記の最初の2つ、すなわち訓練データセットや訓練済みモデルの再利用が、今後の機械学習応用システムの普及にとって鍵の一つになることは間違いない。

3. 1 訓練データセット

訓練データセットは、整形されたデータであり、さらに多くの場合、多くの労力をかけて人手でアノテーションされたものであり、極めて価値が高い。研究分野においては、訓練データセットの共有は広く行われているプラクティスである(例えば手書き文字認識のデータセットMNIST³⁾や、画像判別のデータセットであるImageNet⁴⁾など)。また、自動運転の技術開発のために作成されたCityscapes⁵⁾データセットは、自動車のカメラで取得した5,000枚の画像に、ピクセル単位でアノテーションをしたもので、自動運転の研究開発に多大な貢献をしている(図3)。

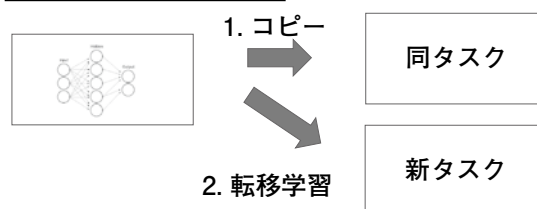
一方、訓練データセットの商業的な再利用については、まだ法律を始め一般的なルールが合意されておらず、なかなか再利用が進まない状況である。しかし、後に述べるが、日本では著作権法の30条の4において、機械学習用訓練データとしての著作物の使用に関し著作権の制限規定が新設されるなど、機械学習応用システムにおけるデータの再利用の促進が期待できる環境

が整いはじめている⁶⁾。

3. 2 訓練済みモデル

機械学習応用システムにおいて、もう一つの重要な再利用可能な生成物は訓練済みモデル⁷⁾である。訓練済みモデルは大まかにいって、ニューラルネットワークの構造と、各重みパラメタ値の組で表現される⁸⁾。訓練済みモデルの再利用には、図4に示すように、いくつかのパターンがある。

ホワイトボックス再利用



ブラックボックス再利用

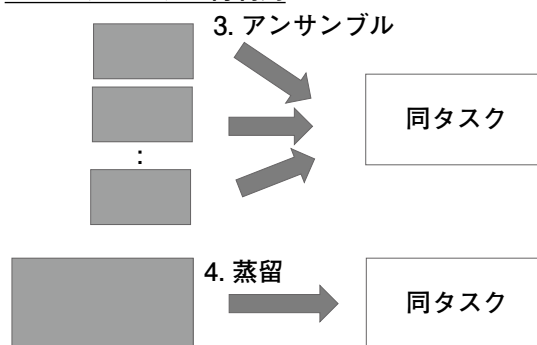


図4 訓練済みモデルの再利用パターン

第1のパターンは、訓練済みモデルをそのままの形でコピーし、同じタスクに再利用するこ

とである。

第2のパターンは、訓練済みモデルに追加の訓練データセットを加えて、似ているが異なる問題に適用することである。これを「転移学習(Transfer Learning)」と呼ぶ。特に画像処理などの場合、新しいモデルを一から学習させることは大きな計算量を必要とする。似た分野の訓練済みモデルから学習をスタートさせることで、低コストで素早く訓練済みモデルを作ることができる。

上記2つのパターンは、訓練済みモデルの詳細までを知って再利用するパターンであり、「ホワイトボックス再利用」であると言える。アカデミアにおいては、訓練済みモデルの共有は進んでいて、例えばCaffe Model Zoo⁹⁾においては画像処理を中心に多くの訓練済みモデルが公開されている。

訓練済みモデルの第3の再利用パターンは、「アンサンブル(Ensemble)」と呼ばれる。同じタスクを解く訓練済みモデルが複数ある場合、これらの訓練済みモデルを同じデータに対して適用し、それらの結果の平均を取ることで精度を向上できることが知られている¹⁰⁾。このパターンにおいては、再利用の際にそれぞれの訓練済みモデルの詳細にアクセスする必要はない。入力を与えると出力を返すというAPIへのアクセスだけで、再利用が可能である。このため、アンサンブルは「ブラックボックス再利用」であると考えられる。

第4の再利用パターンは、「蒸留(Distillation)」¹¹⁾と呼ばれるものである。このパターンにおいては、元の訓練済みモデルは、新たな訓練データセットを作り出すために用いられる。この新しい訓練データセットによって、全く別のニューラルネットワークを学習する。これもAPI呼び出しだけで行えるので、ブラックボックス再利用である。蒸留という行為について、特許法、著作権法上の解釈はまだ共通の理解がない。通

常のソフトウェア開発においては、外部仕様だけから同機能のソフトウェアを作り出す「クリーンルーム開発」が最も近い概念であるかもしれない。いずれにせよ、このあたりについては今後の議論が待たれる。

3.3 生成モデルの出力

深層学習の1つの利用方法として、生成モデルというものがある。これは、教師無し学習の1つであり、大量の訓練データセットから、それらに似た別の出力を生成するものである。生成モデルの典型的な利用方法の1つが、アニメ等におけるキャラクタの生成である。図5は、アニメキャラクタを生成モデルで生成したものである。訓練データセットには、これらに似たキャラクタは存在するが、完全に一致するものは存在しない。このような生成モデルの出力が著作物にあたるかどうかという議論がある。



図5 生成モデルが生成したキャラクタの例

4. 我が国における議論

4.1 想定された世界

深層学習の訓練済みモデルは強力なメカニズムであり、その作成には多大なコストを伴うので知財として保護すべき、という考えも成り立つ。あるドメインの訓練済みモデル、例えば画像認識モデルを、他の領域の画像認識に応用するために、目的領域の比較的小さな訓練デー

タセットを用意して再訓練（転移学習）を行うことは、ゼロから訓練を行うよりもはるかに小さなコストで行うことができる。このため、あるドメインで良い訓練済みモデルができれば、その派生モデルが次々と作られていくことが想定できる。

例えば、あるスタートアップ企業が2018年にGoogle AI Open Imagesで2位の精度を達成したモデルは、当時最新のGPUであるV100を512台使って33時間計算させるといって、機械学習の領域としては莫大なコストをかけて訓練したものであった。同年、同社がCEATECでデモしたお片付けロボット（図6）は、このモデルをリビングルームの様々な物体、おもちゃや衣類などを対象に再訓練したものである。このように、多大のコストをかけても良いベースモデルを作ることができれば、そのモデルを他の領域に比較的低コストで利用できる。このため、良いベースモデルからは、派生モデル、2次派生モデル、…のように多くの派生モデルが作られることが想定される。



図6 国内スタートアップ企業が開発したお片付けロボット

派生モデルが価値を生んだときに、ベースモデルあるいは上流の派生モデルの作成者にもなんらかの便益が与えられるべきであるという意見がある。このような仕組みはどのように実現できるだろうか。筆者が2016年に想定した訓練

済みモデルのエコシステムは図7に示すようなものである。すなわち、訓練データセットや訓練済みモデルの市場があり、買い手は、訓練データセットや訓練済みモデルを利用して、新たな派生モデルを作ったり、既にある訓練済みモデルを使って問題を解いたりする。市場の管理者は、どの買い手がどの派生モデルを使っているか、またその派生モデルはどのベースモデルから派生したものであるかを把握しているのだから、買い手の支払った利用料を、上流の作成者に適切に配分することができる。このトレーサビリティを確保するためには、市場のプレイヤーは訓練や推論に、市場運営者が管理する深層学習プラットフォームを利用する必要がある。GoogleやMicrosoftが、深層学習のクラウド上のツールを無料または極めて低額で提供しているのは、このような理由があるのではないかと想像された。

この未来像に基づき、筆者は2016年4月に経済産業省を訪問し、訓練データセットや訓練済みモデルの知財のルール作りと、それに基づく市場形成におけるリーダーシップの重要性を指摘した。その後、同年6月に「IoT, BD, AI時代の知財戦略を考えるシンポジウム¹²⁾」が東京で開催され、そこでこの問題が知財のコミュニティに広く知られ、訓練済みモデルの知財としての可能性が大きくクローズアップされることとなった。

4. 2 訓練済みモデルの法的保護

既存の法的枠組みを利用して訓練済みモデルを知財として保護するには特許、著作権、営業秘密という3つの方法があると考えられた。訓練済みモデルは、ネットワークの構造（アーキテクチャ）と、そのパラメタの値の組で与えられる。パラメタ数はネットワークアーキテクチャによって決まるが、トップレベルの精度を持つ画像認識では、数千万から数億であり、その値は浮動小数点数で与えられる。ある訓練済

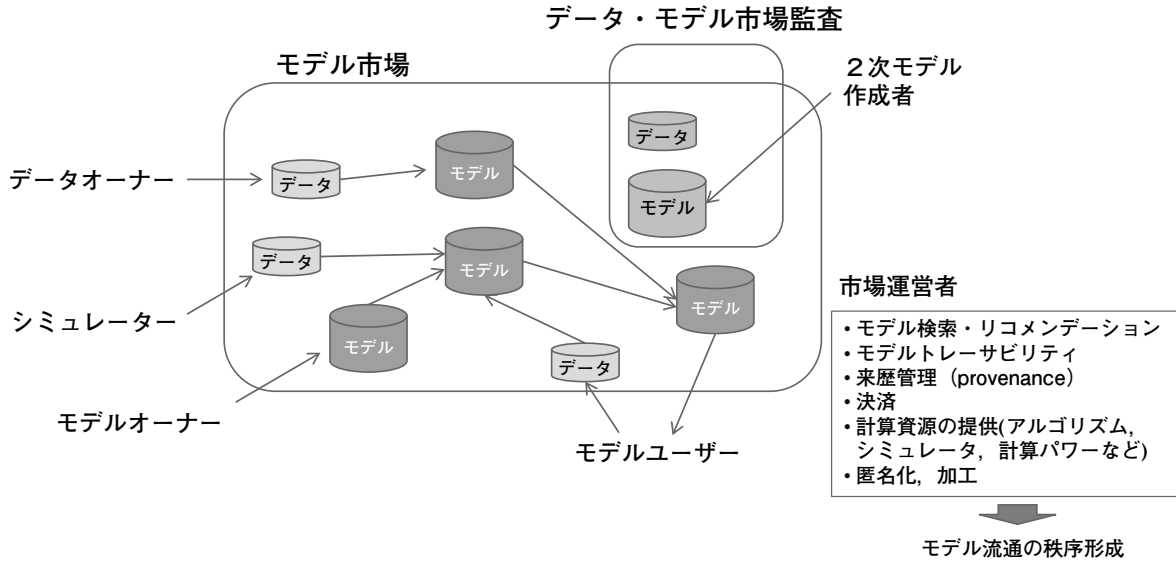


図7 想定された訓練済みモデルの市場

みモデルの数千万のパラメタのうち、1つでも値が異なればその働きは微妙に異なるので、厳密には異なる訓練済みモデルとなる。

訓練済みモデルの知財を特許で保護することを考えた場合、数千万のパラメタの値を個別に指定するわけにはいかないため、パラメタの値を指定した特定の訓練済みモデルを個別の特許として出願することは通常は困難である。従って、ネットワークアーキテクチャをどのように構成するか、そこで使う伝達関数やドロップアウトの仕組みをどのように指定するか、などの構築方法などを出願の対象として検討する。

それでは、訓練済みモデルを著作権で保護するのはどうだろうか。数千万のパラメタの値の列を、数値の表現と見ればそれを著作物とみなす考えもあるだろう。しかし、これには問題がある。ある訓練済みモデルに、1つの訓練データ点(例えば新たな1枚の画像)を加えて転移学習を行ったとしよう。この結果、数千万のパラメタのほとんどすべてが微妙に変化する。従って、ほぼ同じ推論を行う2つの訓練済みモデルが、まったく異なる表現になってしまう。これらを同じ著作物とみなせるかの判断は難しい。特に、前章で述べた蒸留が行われた場合には、

ネットワークアーキテクチャを含めて異なる表現になるため、なお判断が難しい。

このため、特定の訓練済みモデルを現行の法体系の中で保護するには、営業秘密として扱うしかなさそうだ。これらのことを、経済産業省の産業構造審議会情報経済小委員会では、表1のようにまとめている(表1中、○は保護対象たりうる、△は一定条件下保護されうる、×は保護対象たりえないことを示す)。

表1 経済産業省がまとめた、深層学習生成物の法的保護の整理¹³⁾

	特許権	著作権	不正競争防止法
データ	×	△	○
訓練データセット	×	○	○
訓練	○	○	○
訓練済みモデル	△	△	○
利用	○	○	○

4.3 ユーザー企業・ベンダー企業間の契約

訓練済みモデルの市場モデルが可能だとしても、我が国のIT業界の主流は委託開発であり、もしユーザー企業がベンダー企業に機械学習応

用システムの開発を委託するのであれば、その成果物の権利関係を明確にしなければならない。このため、経済産業省は東京大学渡部俊也教授を座長とするAI・データ契約ガイドライン検討会を2017年12月に設置した¹⁴⁾。この検討会は、その後検討を重ね、翌年2018年6月に「AI・データの利用に関する契約ガイドライン」を公開した¹⁵⁾。このガイドラインは、全体で350ページを超える大部のものである。ここでいう「AI」は機械学習、主に深層学習を対象にしている、深層学習を利用したシステムをユーザー企業がベンダー企業に発注する際に気をつけるべきこと、またその際の契約書の例を示した。

また、2019年10月には、東京弁護士会主催で行われたAIシンポジウムにおいて、ユーザー企業が発注した深層学習に基づく不良品検出システムについて、従前のIT開発契約を用いるとどのような問題が生じるかを、ユーザー企業とベンダー企業の間で成果物の扱いに関する係争が発生した、という想定で模擬裁判を行った¹⁶⁾。ここでは、例えば訓練済みモデルの所有権がユーザー企業にあるのか、ベンダー企業にあるのか、ということが争われている。従前のIT契約の雛形では、訓練済みモデルという概念がないため、このような係争になる。新しい「AI・データの利用に関する契約ガイドライン」では、このような係争にならないよう、契約の際にどのようなことに気をつけるべきかが明示されている。

深層学習の知財をめぐる以上のような議論は、筆者の知る限り、海外ではほとんど起きていないようだ。このため、筆者らは2017年にはオーストラリアのメルボルンで行われた人工知能の最大国際会議であるIJCAI 2017で、人工知能生成物の共有と再利用に関するワークショップを開催した¹⁷⁾。また、前記の経済産業省「AI・データの利用に関する契約ガイドライン」は英訳され、2019年4月に公開された¹⁸⁾。このよう

に、我々は国際的な発信を行っていて、深層学習の知財に関する議論では世界の中で一定のリーダーシップを示していると認識している。

5. 深層学習ビジネスの現状

5.1 自社開発の場合

本稿執筆時点で深層学習が最も効果的に利用されているのは、自社にデータを生み出すサービスを持っているIT企業であろう。深層学習が実際に価値を生み出すのは、訓練済みモデルを用いて推論を行ったときであるが、Googleが推論用ハードウェアを作成したときの論文によれば、当時Google社内の深層学習における推論ワークロードの調査の結果、CNN、RNN、MLPの合計が99%になったという¹⁹⁾。CNNは画像認識、RNNは音声認識、MLPは検索に使われていると仮定すれば、それらはGoogleフォト、Googleホーム、Google検索に組み込まれているはずであり、Googleの基幹サービスの重要なコンポーネントとして使われていると考えられる。Google、Facebook、Amazon.comなどは、自社内に深層学習の開発チームを持ち、自社で使うシステムを自社で内製している。このような場合、深層学習がどれだけの価値を生んでいるかは、外からは見えにくいですが、大きな価値を生んでいることは間違いないだろう。

5.2 インフラビジネス

深層学習に関する技術で直接売り上げを上げているのが、GPU(Graphics Processing Unit)と呼ばれるハードウェアである。深層学習、特にその訓練においては大きな計算パワーを必要とする。そのほとんどは行列計算であり、従前のCPUでは効率的な計算ができない。GPUは、本来ゲームなどに使われるコンピュータグラフィックス用のハードウェアであったが、そこで使われる計算がやはり行列計算であったため、これが深

層学習に用いられるようになった。GPUのこの用途ではほぼ寡占状態を占めているのがNVIDIAで、NVIDIAのデータセンター向け売り上げのCAGRは2018年までの3年間で85%ということである。

これらのGPUは、一部は深層学習ベンダーのデータセンターで利用される(例えば国内のあるスタートアップ企業では社内のデータセンターに約2,500台のGPUを擁している)が、多くはAWS、Azureなどのクラウドプロバイダに出荷される。深層学習の訓練あるいは推論の計算をする人は、クラウドを使えば自社でデータセンターの管理運営をしなくてすむので、エントリコストを下げるができる。GPUを備えた深層学習向けのインスタンスを提供するクラウドプロバイダは、多くの場合同時に深層学習に必要なソフトウェアスタックも提供していて、PaaS(プラットフォームサービス)としての事業を行っている。

一方、深層学習に使われるソフトウェア、例えばTensorFlow、PyTorchなどの深層学習フレームワークは、きわめて高度な技術だが、それらのほとんどはオープンソースであり、直接的な売り上げを生まない。画像認識や音声認識など、特定の訓練済みモデルをAPIとして提供し、APIコールに対する課金を行うSaaS(ソフトウェアサービス)もあるが、現在のところ大きなビジネスにはなっていないようである。

5.3 システム構築

前章で述べた「AI・データ契約ガイドライン」が想定するのは、ユーザー企業から委託を受けて深層学習応用システムを開発する受託開発型ビジネスである。深層学習応用システムの開発には、現在のところかなりの専門知識を要する。データのクレンジング、前処理、ニューラルネットワークの設計、訓練、評価、運用のいずれもノウハウが必要であり、急速にツール

群が整備されつつあるものの、全体を自動化するようなことは当分できそうにない。このため、自社に専門知識を持たないユーザー企業は開発を外注せざるを得ない。しかし、事前に要件をきちんと書き下すことができるシステム、例えば在庫管理システムの構築と異なり、深層学習を用いたシステムは事前に要件を書き下すことが難しい。手に入る訓練データセットによって、期待する予測精度が実際に得られるかはやってみないとわからない。このため、深層学習応用システムの開発は、多分に試行錯誤的にならざるを得ない。

試行錯誤のループをユーザー企業とベンダー企業で回すとして、その間に契約が入ると大変なことになる。アクセンチュアData Science Center of Excellenceグローバル統括である工藤卓哉氏は、2018年5月の日本ソフトウェア科学会機械学習工学研究会キックオフシンポジウムで、機械学習プロジェクトを最終的に成功させるには、ユーザー企業とベンダー企業の間で合弁事業を立ち上げる必要がある、と述べた²⁰⁾。合弁事業であれば、データを持つ事業チームと技術を持つ開発チームが同一のインセンティブの下で動けるので、データや訓練済みモデルの帰属をめぐる議論を、試行錯誤のループ毎に行う必要はなくなる。

深層学習に関連する新しいビジネスとして、データのアノテーションサービスを専門に行うものもある。

5.4 データは本当に「21世紀の石油」か？

データは21世紀の石油である、と言われることがある²¹⁾。データの重要性を石油になぞらえて強調する言葉である。だが、この言葉はストックとしてのデータ、すなわち過去に生成され記録されている既存データを過剰に評価してしまうことにつながる恐れは否定できない。

ビッグデータがもてはやされた2011年にマッ



図8 深層強化学習による「ぶつからないクルマ」のデモ(左)とその訓練に使われたシミュレータ(右)

キンゼーは、ビッグデータとは「排気データ」、すなわちビジネスの結果として副産物として得られたデータであると定義した²²⁾。だがその後、機械学習、あるいは深層学習が普及してくるにつれ、このような排気データがいくら莫大にあっても、ほとんど役に立たないことがわかってきた。これは、現在の機械学習(深層学習を含む)が、原理的には統計モデリングであることによる。統計モデリングとは、訓練データセットの中の統計的パターンを取り出すことに外ならないのだが、そこでは、訓練データセットにある各データ点が同じ確率分布から独立にサンプリングされたものである、ということを仮定している。残念ながら、ほとんどの排気データは、この仮定を満たさない。例えば、ある工場の工作機械のアラームセンサーから得られた、何十年分ものデータがあったとする。しかし、実際に話を聞いてみると、アラームが多いときには現場の作業員がアラームの設定を変えてアラームが出ないようにしていたという。このようなデータは、条件の違うものが混ざっているので、独立・同分布の仮定を満たさず、結果としてどんなに膨大なデータであったとしても深層学習で利用することはできない²³⁾。

筆者の経験によれば、お客様が持っているストックのデータは多くの場合、深層学習に適さない。深層学習を有効に使いたい場合、むしろ重要なのはどのような入力変数が必要か、またどのような教師信号を与えることができるかを

考えて、データのアーキテクチャを大局的に設計する、あるいは設計しなおすことである。

加えて、深層学習の利用が必ずしもストックのデータを必要としない場面もありうる。碁の世界チャンピオンを破ったAlphaGoは、過去の棋譜を訓練データセットとして使ったが²⁴⁾、その後継のAlphaZeroは、棋譜を使わず、碁のルールを与えただけで自己対戦を通して訓練し、強くなった²⁵⁾。2016年にある国内スタートアップ企業が模型の自動運転車のデモを行ったときには(図8)、シミュレータを使って教師信号を与えることで訓練した。

このように、深層学習の利用には必ずしもデータの存在を前提としない。新たに設計し収集してもよいし、シミュレータなど他のシステムを使ってデータを動的に生成してもよい。もし、企業が手持ちのデータの価値を過大評価するあまり、深層学習の適用領域の可能性を狭く考えたり、データをオープンにすることをためらったりすることがあるとすれば、それは大変もったいないことである。データは石油と異なり、いくらでもコピーができる。より広く使われれば、それだけ大きな価値を生む。「データは石油」「データ主導社会」などの言葉に惑わされて、既存データにこだわってはいならない。データはどんどん生まれる、ということを念頭に、深層学習の利用を考えていくべきである。

5. 5 訓練済みモデルの流通

一方、我々が想定したような訓練済みモデルの市場はいまだに立ち上がっていない。むしろ、我々が2016年に深層学習の知財の議論を始めてからの世の中の動きを見ていると、そこで起きていることは、データだけでなく訓練済みモデルもどんどん新しい技術を取り入れた、新しいものができているということである。深層学習に関する新しい技術は、プレプリントサーバーarXiv.orgにまず論文投稿されるのが流儀である。2019年現在、毎月約1,000報の深層学習に関する論文が投稿されている。このように動きの速い技術領域では、過去の資産にこだわっていると競争できない。当然、過去の訓練済みモデルは、新しい、より精度の高いものに置き換えられていく。

筆者が訓練済みモデルの知財としての有用性を強調したばかりに、企業がデータや訓練済みモデルの価値を実際以上に過大評価し、その結果新しい技術の導入を阻害している面があるのだとすれば、筆者の不明を恥じたい。

6. スタートアップ企業の戦略

本章では、深層学習をコア技術にしたある仮想的なスタートアップ企業A社があったとして、筆者だったらどのようなビジネス戦略を考えるかを、知財・技術競争力・人材の3点から提案する。なお、この内容は、筆者が所属する組織の現状や戦略とは全く関係がない。

6. 1 知財について

A社は技術力をその競争力の源泉とする会社であり、その意味で、強い特許ポートフォリオを確保しようと努力していなければならない。一方、深層学習のアルゴリズム、ネットワークアーキテクチャについてはGoogleが特許ポートフォリオを保持していると認識している。Google

はOpen Patent Non-Assertion Pledge²⁶⁾によって特定の特許についてその権利を行使しないことを約束しているが、残念ながらこれらには深層学習に関する特許は含まれていない。近い将来にGoogleが権利行使に踏み切る状況は考えにくいだが、もし行使されたとしても対抗できる自社ポートフォリオを維持していく必要がある。

A社はどのような特許を戦略的に取得すべきだろうか。深層学習のアルゴリズムがどうなっているかは、どの入力変数に対してどの出力変数を得るか、という外形的には判断しにくいことから、入力変数と出力変数の形に注目した応用に関する特許の取得に力をいれるべきである。例えば図9に示す発明は、サッカーなどのスポーツの解析に深層学習を用いるアイデアで、ピッチにいる選手の位置をビットマップとして画像処理したデータを入力として、次のプレーの予測を出力するものである。このような発明は、入出力の形がわかりやすいので、より良い特許になると考えられる。

A社では、深層学習の特許ポートフォリオの強化に力をいれるが、その最大の目的は会社の事業の自由度の確保である。自由度の確保のためには、パテントコモズや、LOTネットワーク²⁷⁾への参加等も今後検討するべきだろう。

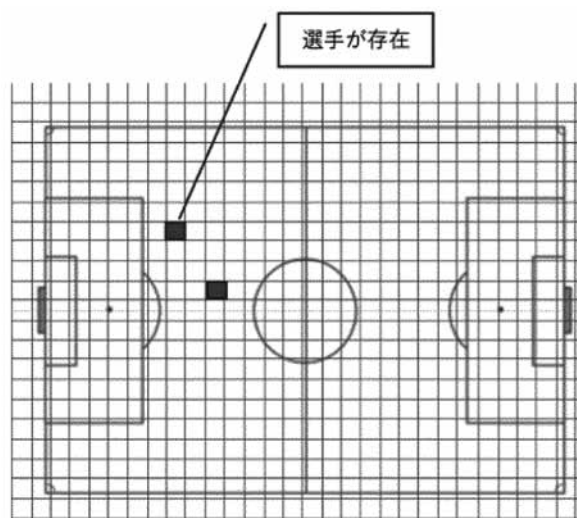


図9 サッカーの解析を深層学習で行う発明の例

6. 2 技術競争力の維持

先にも述べたように、深層学習の領域は進化のスピードが激しく、次々に新しいアイデアが現れる。このようなアイデアに触れるには、最先端の研究を行っている世界中の研究者とのコミュニケーションが大切である。深層学習のトップレベルの研究者のコミュニティは、インフォーマルなコモズのような様相を呈していて、そのメンバーとして認められるのは、高い技術を持ち論文発表やオープンソースで貢献している研究者集団だけだ。貢献がなければコミュニティから相手にされず、コミュニティの一員として認められなければ、新しいアイデアの情報が得られない。

A社ではそのために、深層学習フレームワークなど最先端の技術をオープンソースにし、また学会にも積極的に参加し、最先端の研究発表をする。また、Kaggleなどのコンペティションにも参加し、好成績を収めようとしている。このようにして、世界における深層学習コミュニティで、一目置かれる存在になっていることが、この領域の競争力を維持する上で最も重要である。

また、深層学習には大量の計算力が必要なので、計算資源に投資することも競争力維持の重要な要因である。A社は継続的にスーパーコンピューターに投資すべきである。これらのスーパーコンピューターの主な用途は、顧客の深層学習システムの開発（モデルの訓練）である。訓練のジョブは、長時間（数時間から数日）走ることが多いため、これをクラウド上で行うと大きなコストがかかる。一方、深層学習の推論は、アプリケーションによってはワークロードにはばらつきがあるので、クラウドの利用も考慮するとよい。

6. 3 人材

計算資源以上に重要なのが人材であり、全世界からトップタレントを集めることが至上命題となる。上に述べたオープンソース、論文発表、コンテスト参加、世界レベルの計算環境は、これらの人材を惹きつけるためにも必須であろう。

一方、我が国では「AI人材が不足している」という議論もよく聞く。実際に不足しているのかもしれないが、筆者の私見によれば、優秀な人材はいるのだが、日本の伝統的な企業には見えていないのではないかと。筆者は複数の大企業や国立の研究所で勤務したが、スタートアップ企業に勤務してみると、GitHub, Qiita, conncpassなどのサービスの利用を通じて技術者コミュニティに触れて、実は今まで自分に見えなかったところに多くの人材がいるのだということを知った。近年、スタートアップ企業に転職する優秀な技術者・研究者の多くは、大手企業では顧客のレガシーシステムの保守などを担当していて、最先端の研究開発ができなかったようである。よい技術者がいても、活かすことができないのではないのと同じである。人材不足論を述べる前に、自組織にいる人材をよく理解すべきなのではないかと思う。

7. おわりに

本稿では、深層学習とそれをめぐる知財を、技術とビジネスの観点から議論した。深層学習技術はまだまだこれから大きく発展するものであり、その動きをいかに先取りするかが差別化の要因となる。また、深層学習そのものではないが、深層学習の周辺技術としてベイズ最適化などブラックボックス最適化の技術の動向も目が離せない。

現在の特許や著作権などの仕組みは、深層学習に比べると比較的動きの遅い技術領域を対象として発展してきた。深層学習のように、非常

に動きの激しい技術領域における知財のあり方は、今後議論されてよいかもしれない。

注 記

- 1) Cybenko, G.: Approximation by superpositions of sigmoidal functions. *Mathematics of Control, Signals, and Systems*, Vol.2, No.4 (1989).
- 2) 英語ではtraining。これを「学習」と訳す場合もあるが、本稿ではtrainingに相当する語は「訓練」と訳す。
- 3) <http://yann.lecun.com/exdb/mnist/>
- 4) <http://www.image-net.org/>
- 5) <https://www.cityscapes-dataset.com/>
- 6) Ueno, T.: Copyright Issues on Artificial Intelligence and Machine Learning. *The First International Workshop on Sharing and Reuse of AI Work Products*, 2017.
- 7) 英語では“pretrained model”（事前に訓練されたモデル）と呼ぶ。訓練が利用の前に起きることからこのように呼ばれるが、本稿では訳語として「訓練済みモデル」を使う。
- 8) Chainerなどの深層学習フレームワークでは、ニューラルネットワークの構造が入力データによって動的に構成されることを許している。このような場合は、ニューラルネットワークの構造はプログラムコード片で表現される。
- 9) <https://modelzoo.co/>
- 10) Dietterich, T. G., et al.: Ensemble Methods in Machine Learning. *Multiple classifier systems*, Vol.1857 (2000).
- 11) Hinton, G., Vinyals, O., and Dean, J.: Distilling the Knowledge in a Neural Network. *arXiv preprint arXiv : 1503.02531*, (2015).
- 12) <https://www.rieti.go.jp/jp/events/16062001/info.html>
- 13) 産業構造審議会情報経済小委員会 分散戦略WG (第6回) 事務局資料, 40ページ, 2016.
https://www.meti.go.jp/shingikai/sankoshin/shomu_ryutsu/joho_keizai/bunsan_senryaku/pdf/006_02_00.pdf
- 14) https://www.meti.go.jp/committee/kenkyukai/data_keiyaku/001_haifu.html
- 15) <https://www.meti.go.jp/press/2018/06/20180615001/20180615001.html>
- 16) 詳細は、この模擬裁判で陪席裁判官役を務めた柿沼氏のブログにある。
https://storialaw.jp/blog/6453?fbclid=IwAR1mYVJXFJ-JL0VViL5LwqWZiXTvn_ynnSny-NuA8OSeoGvk11EV0KdS6aM
- 17) <https://sites.google.com/view/srai-2017/>
- 18) <https://www.meti.go.jp/press/2019/04/20190404001/20190404001.html>
- 19) Jouppi, Norman P., et al. In-Datacenter Performance Analysis of a Tensor Processing Unit. *2017 ACM/IEEE 44th Annual International Symposium on Computer Architecture (ISCA)*. IEEE, 2017.
- 20) 日本ソフトウェア科学会機械学習工学研究会 (MLSE)キックオフシンポジウム 基調講演1資料. 24ページ.
<https://www.slideshare.net/MLSE/ss-98345458>
- 21) 例えば、2014年の日本IBM社長のコメント。
<https://www.sbbi.jp/article/cont1/28284>
- 22) McKinsey Global Institute: “Big data: The next frontier for innovation, competition, and productivity.” 2011.
- 23) この場合、アラームの設定がすべて記録されていれば、それを入力変数に含めることで分布は独立・同分布とみなせるかもしれない。
- 24) Silver, David, et al.: Mastering the game of Go with deep neural networks and tree search. *Nature* 529, 7587 (2016): 484.
- 25) Silver, David, et al.: Mastering the game of Go without human knowledge. *Nature* 550, 7676 (2017).
- 26) <https://www.google.com/patents/opnpledge/pledge/>
- 27) <https://lotnet.com/>
(URL参照日は全て2020年1月16日)

(原稿受領日 2019年12月10日)