

ディープラーニングとアクティブラーニング ——特徴表現学習から見た LTD 話し合い学習法の特質——

森 邦昭、鈴木有美

将棋、囲碁、お掃除ロボット、自動運転……人工知能と呼ばれるコンピュータのプログラム開発が近年において革新的な勢いで進んでいる。最近までは、人工知能と言っても、たとえば「東ロボくん」のように意味を理解することはできず（森・鈴木，2019）、人間から与えられたプログラムに従った処理しかできない状態にあったが、ディープラーニングという学習方式が導入されるようになってからは、人工知能は大量のデータをもとにみずから学習できるようになった。これにより、いずれ自分より少しだけ賢い人工知能を作り出せるようになるかもしれない。これを無限に繰り返せば、「無限に賢い人工知能」が出現し、カーツワイル（Ray Kurzweil）が予測するように2045年にはコンピュータが人間を超え、開発と進化の主役が人間からコンピュータへ移行する技術的特異点（Singularity）を迎えることになるかもしれない（松尾・塩野，2014）。こうした時代の大転換期のなか、本論文においては、人工知能開発の歴史を踏まえ（第1節）、ディープラーニングのメカニズムをまとめ（第2節）、人間が主体的にかかわることによって成り立つアクティブラーニングとの比較を行って（第3節）、学習の本質へ迫っていきたい。

1 人工知能開発の歴史

意外であるが、日本の人工知能学会に所属する研究者の間では、人工知能とは何かについて明確な定義が定まっていないそうである（松尾，2016a）。なぜ、定まらないのか。それは、人工知能というものに対して、哲学的見方

もあれば物理学的見方もあり、計算科学的アプローチもあれば認知科学的アプローチもあり、立場によって見解や手法が異なるだけでなく、関連する難問も数多く存在するからだと考えられる。たとえば「知能とは何か」「人工知能研究は何をめざすべきか」「人工知能に身体性は必要か」「意識・心とは何か」「知識とは何か」「技術的特異点をどう考えるか」などについては、さまざまな考え方がある。人工知能の定義は研究者の数だけ存在すると言えるほどだとしても、ここではこの研究分野のリーダー的役割を果たしている松尾(2016a)の考え方に従って、「人工知能とは、人間のような知能を、コンピュータを使って実現することを目指した技術あるいは研究分野」だと受け取っておくことにしたい。

人工知能の研究分野は今から約60年前に成立し、その発展にはチューリング (Alan Mathieson Turing)、ミンスキー (Marvin Minsky)、マッカーシー (John McCarthy)、サイモン (Herbert Alexander Simon)、ニューウェル (Allen Newell)、ウィノグラード (Terry Allen Winograd)、ラッセル (Stuart Russell)、ファイゲンバウム (Edward Albert Feigenbaum)、ブルックス (Rodney Allen Brooks)、ミッチェル (Tom Michael Mitchell)、パール (Judea Pearl)、ヒントン (Geoffrey Everest Hinton) などが貢献してきた。人工知能研究においては、これまで「ブーム」と「冬の時代」が交互に到来したが、ちょうど今現在は3回目のブームが訪れているところである。

松尾 (2015) によれば、この3回のブームには、それぞれ次のような特徴がある。第1次ブームは1950年代後半から1960年代に生じた。このときはコンピュータに推論や探索を実行させることにより、特定の問題を解決する研究がなされた。ところが、この方式では迷路問題などのトイ・プロブレムは解けても現実の複雑な問題は解けないことがわかったため、急速に熱が冷めて1970年代に入ると冬の時代となった。しかし、1980年代になるとコンピュータに知識を与えると賢くなるという手法が編み出されて第2次ブームが巻き起こり、数多くの実用的システムが作られた。ところが、当時の技術では知識を記述したり管理したりすることが難しかったため、1995年頃には再び冬の時代となった。しかし、1990年代半ばに検索エンジンが開発されてインターネットが急速に普及し、2000年代になるとウェブから大量のデータを集めることができるようになった。このようなことを背景として第3次ブームが始まり、機械学習 (Machine Learning)^(註1) の手法を中心として今日

では日進月歩の発展が遂げられている。これまでの3回のブームを一言で言えば、第1次は「推論・探索の時代」、第2次は「知識表現の時代」、第3次は「機械学習の時代」だと言える。もちろん、この特徴づけは便宜的なものであり、この3つは相互に重なり合っている。第2次ブームの知識表現も第3次ブームの機械学習も、その発想はすでに第1次ブームのときになされているし、第1次ブームの推論・探索も第2次ブームの知識表現も、依然として今日に至るまで重要な研究課題であり続けている。

では、イメージを膨らませるために、主として松尾（2015）に拠りながら、各時期の特徴をもう少し詳しく辿ってみたい。“Artificial Intelligence”（人工知能）という言葉が初めて登場したのは、1956年の夏にアメリカ北東部ニューハンプシャー州のダートマス大学で開催された伝説的なワークショップ（ダートマス会議）においてである。マッカーシー、ミンスキー、ニューウェル、サイモンといった

「ダートマスの伝説の4人組」も参加し、最新の研究成果が発表された。世界初の人工知能プログラムと言われるニューウェルとサイモンによる「ロジック・セオリスト」（自動的に定理を証明するプログラム）のデモンストレーションも行われた。

第1次ブームでは推論や探索が中心に研究されたが、その処理法の一例として迷路の解法がある。図1のような迷路を




図1 探索木（松尾，2015，p.67）

解く場合、人間は通路を指などでなぞりながらゴールをめざすのが通常である。それはそれでよいのだが、ここで一工夫を加えて、スタートに S、ゴールに G、通路が分かれる分岐点であるノード（頂点、結び目）に A～J の文字を当てて問題を表現すると、迷路の構成パターンが見えやすくなる。これをさらに樹状に描き直して、1 層目に S、2 層目に D と A、3 層目に（D から分岐した）H と I、（A から分岐した）B と C、4 層目に（H から分岐した）E と J、（C から分岐した）F と G を位置づけると、迷路の構成パターンはもっと見えやすくなる。このような樹状の図解は探索木（Search Tree）と呼ばれるが、これを見れば S から G に行ける順路は $S \rightarrow A \rightarrow C \rightarrow G$ だけであることが一目瞭然である。

探索木で問題になっているのは場合分けであり、このような処理はコンピュータの得意とするところである。人工知能の分野では、迷路だけでなく、さまざまなパズルを解く取り組みがなされてきたが、そのなかでもハノイの塔（Tower of Hanoi）が有名である。このパズルは、3 本の杭と中央に穴の開いた大きさの異なる複数の円盤から成り立つ。最初は、すべての円盤が左端の杭に大から小へ積み重ねられている。円盤を 1 回につき 1 枚どれかの杭に移動させることができるが、小さな円盤の上に大きな円盤を乗せることはできない。このルールに従ってすべての円盤を右端の杭に移動させると成功であるが、 n 枚の円盤すべてを移動させるには最低 $2^n - 1$ 回の手数が必要である。そして、このパズルも探索木で解くことができる。

さらに、探索木を使えばロボットの行動計画を作ることでもある。たとえば「部屋の中からバッテリーを持ってきなさい」と部屋の外にいるロボットに命令する場合、「部屋の外にいるときに（前提条件）、ドアを開けると（行動）、ドアが開いた状態になる（結果）」「ドアが開いた状態で（前提条件）、室内に移動すると（行動）、部屋の中にいる状態になる（結果）」のような具合に、前提条件（Preconditions）と行動（Actions）と結果（Postconditions）を記述しておけばプランニングが可能になる。この 3 つを記述して計画を立てる人工知能としては、1971 年に開発された STRIPS（Stanford Research Institute Problem Solver）が知られている。

1946 年に世界初の汎用電子式コンピュータ ENIAC（Electronic Numerical Integrator and Computer）が登場して 10 年ほど経って始まった第 1 次人工知能ブームでは、当時としては圧倒的な計算力が出現したことから、コンピュー

タは人間の能力を超えるとの直感と確信が芽生えた。しかし、現実は厳しかった。この時期の人工知能は、限定された状況における問題しか解けなかった。明確に定義されたルールのなかでの推論・探索はできたが、たとえば「病気になったとき、どんな治療法があるか」「会社が伸びていくには、どういう製品を開発すればよいか」といった本当に解いてほしい現実社会における問題は解けなかった。さらに、1965年に ALPAC (Automatic Language Processing Advisory Committee) が機械翻訳の研究状況に関して厳しい評価を下したため、その後アメリカ政府が投資を引き上げたことなどもあって、人工知能研究は1970年代に冬の時代に入った。

第2次人工知能ブームの中心は、エキスパートシステムが演じた。専門分野の知識を取り込んで推論を行うことによって、その分野のエキスパートであるかのように振る舞えるプログラムが登場したのである。たとえば1970年代初めにスタンフォード大学で開発された Mycin (マイシン)^(注2) がそれである。これは伝染性の血液疾患を診断し、抗生物質を処方する人工知能で、500程度の規則から成る知識ベースをもとに、質問に対する答えから感染した細菌を特定し、69%の確率で正しい処方できた。この確率は、細菌感染を専門としていない医師の確率よりは高いが、専門医の確率(80%)よりは低かった。だとしても、今から約半世紀も前にこのようなシステムが開発されていたのは驚異的である。エキスパートシステムと言えば、ファイゲンバウムが開発した Dendral (デンドラル)^(注3) が有名である。これは未知の有機化合物を質量分析法で分析し、有機化学の知識を使って特定するシステムであり、開発は1965年に開始された。この他、生産、会計、人事、金融など、数多くの分野でエキスパートシステムが作り出された。たとえば住宅ローンのエキスパートシステムでは、ローンが組めるかどうかの判断を自動化することによって、人件費削減がめざされた。

しかし、エキスパートシステムには弱点があった。コンピュータに知識を与えるには、その知識を専門家から教えてもらわなければならない、その処理は難しくコストもかさんだ。また、知識やルールの数が膨大になると、これを矛盾なく管理するのも難しかった。皮肉なことに、高度な専門知識が必要とされる限定的分野はまだしも、常識レベルの知識から成り立つ一般的分野では、知識記述はきわめて難しかった。たとえば「お腹が痛い」と言う場合、「お腹とは何か」「痛いとは何か」のようなことを厳密に定義しておく必要が

あった。そのために「知識表現」(Knowledge Representation)の研究が進められ、概念の意味をネットワーク化する試みがなされた。それは、人間は哺乳類に、哺乳類は動物に、動物は生物に属し、2つの手、2つの足をもつが、尾はもたないというように、概念を関係性で記述する試みであった。

あるいは、1984年からはレナート (Douglas Bruce Lenat) が Cyc (サイク)^(注4) というプロジェクトにより、一般常識をデータベース化し、人間と同等に推論するシステムの構築を開始したが、35年経った今でも人手による入力作業が続けられている。こうして、コンピュータで処理できるように知識を記述するのは難しいことが判明したため、オントロジー (Ontology) という名称で知識を記述すること自体に関する研究がなされるようになった。オントロジーとは哲学の用語では「存在するとはどういうことか」を問う存在論のことであるが、人工知能の用語では「概念化の明示的な仕様」と定義されている。つまり、これは知識記述のための仕様書のことである。ここで通常用いられているのが、「is-a 関係」と「part-of 関係」である。

「is-a 関係」は上下関係になっており、人間は哺乳類であるとか、哺乳類は動物であるとかのカテゴリの関係を示している。「part-of 関係」は部分と全体の関係になっており、手は人間の一部であるとか、足は人間の一部であるとかの知識を記述している。たとえば、1より3が大きく、3より7が大きければ、必ず1より7が大きいのように、AとBに関係が成り立ち、BとCにも関係が成り立つならば、AとCにも自動的に関係が成り立つことを推移律と呼ぶが、「is-a 関係」では推移律は成り立つけれども、「part-of 関係」では必ずしもそうだとはかぎらない。たとえば、「親指 part-of 山田太郎」であり、「山田太郎 part-of 取締役会」であれば、「親指 part-of 取締役会」であるとは言にくい。というのも、一方で親指という部分は山田太郎の身体という文脈での全体において記述されており、他方で山田太郎という部分は取締役会のメンバーという文脈での全体において記述されているからである。このような推移律は人間にとっては比較的容易に処理できるが、コンピュータにとってはとても難しい処理であることが明らかになった。

そこで、この事態に対して2つの流派が誕生した。ヘビーウェイト・オントロジーとライトウェイト・オントロジーである。前者は、哲学的考察に基づいて対象世界を適切に把握することを重視して、知識を記述するにはどうしたらよいかを人間が考えようとする立場である。前述の Cyc プロジェクト

は、この一例である。後者は、情報論的効率を重視して、コンピュータにデータを読み込ませて自動的に概念間の関係性を発見させようとする立場である。このうち、後者の方が現実的であった。これは、ウェブデータやビッグデータの分析から知識を抽出するデータマイニングと相性がよかった。そして、この流派の一つの究極形が、IBM の人工知能「ワトソン」である。ワトソンは、2011年にアメリカのクイズ番組「ジョパディ！」で歴代の人間のチャンピオンと対戦して勝った。ワトソンは、ウィキペディアの記述からライトウェイト・オントロジーを生成して解答を導出しているが、質問の意味を理解して答えているわけではない。この点では、東大入試合格をめざして2011年に開発が開始されたが2016年には開発が断念された人工知能「東ロボくん」も同様である。

この時期の人工知能は、知識は豊富になったが、意味を理解することはできなかった。それゆえに、英語から日本語への翻訳は難しかった。たとえば、当時のグーグル翻訳では、“He saw a woman in the garden with a telescope.” は、「彼は望遠鏡で庭で女性を見た」（松尾, 2015, p.102）と訳されたそうである。（今試してみたら、「彼は望遠鏡で庭にいる女性を見ました。」と訳された。当時のグーグル翻訳は統計的機械翻訳だったのだが、2016年11月からはディープラーニングを使った「ニューラル機械翻訳」（瀬谷, 2018b, p.78）という技術を用いるようになったそうである。そのため性能が格段に向上して、人間が言葉を理解するのと同じような構造で訳文を出力し、TOEIC900点以上の人間と同等の訳文生成も可能とされている。）当時のコンピュータは庭にいたのは彼だと受け取っていたが、人間であれば通常、庭にいたのは女性で、その女性を彼が望遠鏡で見たと受け取ると思われる。こうした人間の判断をコンピュータに教えるのは難しい。「望遠鏡で見るのは男性の方が多い」とか、「庭にいるのは女性の方が多い」といったような一般常識をあらかじめコンピュータに入れ込んでおく必要がある。しかし、人間と同様の一般常識をコンピュータが有するようにするためには、途方もない量の知識をあらかじめ書き込んでおかなければならず、この方式での性能向上を図るとすれば、これは際限のない課題（知識獲得のボトルネック）になる。

さらに、「フレーム問題」や「シンボルグラウンディング問題」といった難問もある。フレーム問題というのは、あるタスクを実行する場合に、そのタスクに関係のある知識だけを取り出して用いるにはどうすればよいかという

問題である。これは人間にとっては何ら特別ではない普通の作業であるが、コンピュータにとってはとても難しい作業である。シンボルグラウンディング問題というのは、記号（文字列や言葉）と、それが意味するものを結びつけられるかどうかという問題である。記号の意味を理解していないコンピュータは、記号（シンボル）と、それが意味するものを結びつける（グラウンドする）ことができない。人間であれば、たとえシマウマを見たことがなくても、シマウマとはシマシマのあるウマ（zebra=stripe + horse）だと教えられていたら、初めてシマウマを見たときに「これはシマウマかもしれない」と思う可能性が高い。これができるためには、シマの意味とウマの意味がわかっていなければならない。意味を理解できないコンピュータにとっては、シマもウマも記号の羅列にすぎず、それが何を指しているのかがわからない。結果として、シマウマというシンボルと、それが意味するものを結びつけることができないのである。コンピュータに知識を入れ、その分だけコンピュータを賢くし、実用的にもある程度は使えるエキスパートシステムも作り出したが、そもそもの知識をコンピュータに入れること自体が難しかった。およそ以上のような難点のために第2次人工知能ブームは終焉を迎えてしまい、1995年頃から再び冬の時代に入った。

しかし、前述のとおり、奇しくもこの頃に検索エンジンが開発されてインターネットが急速に普及し、2000年代になるとウェブから大量のデータを集めることができるようになったことを背景として、現在進行中の第3次人工知能ブームが始まった。ここでの中心技術は、機械学習である。機械学習とは、人工知能のプログラム自身が学習する仕組みのことである。そして、ここでの学習ということの根幹を成しているのは、「分ける」という処理である。その方法はさまざまであるが、次の5つが代表的なものである。①最近傍法（Nearest Neighbor）、②ナীবベイズ法（Naive Bayes）、③決定木（Decision Tree）、④サポートベクターマシン（Support Vector Machine）、⑤ニューラルネットワーク（Neural Network）である。このうち、最後のニューラルネットワークだけが異質である。その他の4つがエレガントな方法で分けるという課題に取り組んでいるのに対して、これは人間の脳神経回路を模倣したモデルを用いて分けることに取り組んでいる。そして、このニューラルネットワークを多層化したものがディープラーニング（深層学習）である^(注5)。

2 ディープラーニングのメカニズム

ディープラーニングがもたらした衝撃は革命的である。ディープラーニングは他の技術と並ぶ単なる便利な「ツール」ではなく、歴史的変革をもたらす「コア技術」である点がきわめて重要である（多田，2018）。たとえば、AlphaGo がディープラーニングの成果の一つである。この囲碁プログラムは、2015年から2017年にかけて当時の世界チャンピオン級の棋士に次々と勝利した。AlphaGo は棋譜を学習に利用していたが、2017年10月には、棋譜をまったく必要とせず、完全に自己対局だけで学習していく AlphaGo Zero が登場し、従来型を超える強さを実現している（巢籠，2018）。画像認識の精度を競う ILSVRC (Imagenet Large Scale Visual Recognition Challenge) では、コンピュータに1,000万枚の画像データを学習させ、その成果を測定するために15万枚の画像を用いてエラー率を算出する。2012年に優勝したチームは、ヒントンが率いるトロント大学チームで、そのときのエラー率は15.3%だった。この競技会が始まった2010年の優勝チームのエラー率は28%、2011年は26%だったのに比べると長足の進歩である。これもディープラーニングの成果の一つである。2012年以降、ILSVRC の優勝チームはすべてディープラーニングを用いている。エラー率は、2013年に12%、2014年に7%となり、2015年には人間のエラー率4%を下回って3.6%となり、2016年には3%、2017年には2.3%になっている（浅川，2018）。こうした爆発的な力を発揮するディープラーニングのメカニズムはどうなっているのだろうか。主として清水（2016）に拠りながら、まずはディープラーニングの基礎となるニューラルネットワークの原理を明らかにしていきたい。

脳は複雑な働きをすることができるが、それは情報の伝達と処理を行うニューロン（神経細胞）のお蔭である。脳にはたくさんのニューロンが存在し、その数を数えるのは難しいが、人間の脳皮質のニューロンの数は100億から180億くらいだと言われている。さらに、小脳や脊髄にもニューロンは存在し、小脳には1,000億以上のニューロンがあるとも言われている。こうしたことから、中枢神経全体のニューロンの数は1,000億から2,000億の間と推定されている。このニューロンは図2のような姿をしているが、他のニューロンから電氣的刺激を受け、その刺激の合計が一定の値を超えると、自分も興奮して電氣的刺激を他のニューロンに伝える。ここから、こうした生体

ニューロンと同じ性質の仕組みをコンピュータで人工的に作り出すことは可能ではないかというアイディアが生まれ、図3のような人工ニューロンが考え出された。そして、人工ニューロンを組み合わせたニューロンによるネットワークが、図4のような人工ニューラルネットワークである。

最初のニューロンは、単純パーセプトロンと呼ばれ、図5のように単純な構造をしている。入力層から中間層を経由して出力層に情報を出力するニューラルネットワークがパーセプトロンと呼ばれるのだが、中間層が1層のパーセプトロンが単純パーセプトロンと呼ばれる。ところが、この単純パーセプトロンは、とても簡単な問いにすら答えられないことはわかっていた。つまり、線形分離不可能な問題にはまったく役に立たなかったのである。

線形分離不可能というのは、平面上にいろいろなデータをプロットしたときに、直線を1本引いただけではデータを分類できないということである。たとえば、横軸に身長、縦軸に体重をとったグラフに10万人くらいのデータをプロットして、それを10歳未満と10歳以上といった年齢構成で分けようとしたときには、おそらくプロットされたデータは1本の




図2 生体ニューロンと生体ニューラルネットワーク (清水, 2016, p.21)

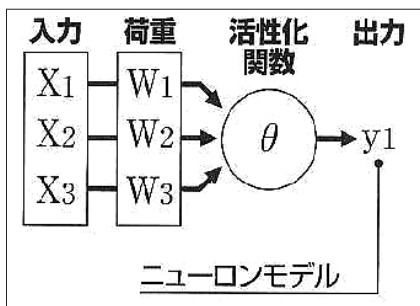


図3 人工ニューロンの構造 (清水, 2016, p.22)




図4 人工ニューラルネットワーク (清水, 2016, p.22)

直線で分けられるようになっているのではないと思われる。ところが、このデータをたとえば収入で分けようとしたときには、おそらく身長体重と収入は相関関係にないことから、1本の直線で分けることは難しく、分けるには2本、3本の直線が必要になるかもしれない。図6では、データ群Aが線形分離可能な問題、データ群Bが線形分離不可能な問題を表している。データ群Aの白マルと黒マルは1本の直線で分離できるが、データ群Bの白マルと黒マルを分離するには2本の直線が必要である。そして、単純パーセプトロンでは、データ群Aは分類できるが、データ群Bは分類できないのである。

このことから、単純パーセプトロンでは、いくつかの学習すべきデータがある場合に、直線を1本引くことによってデータが分類される問題しか学習できないことがわかる。そこで、単純パーセプトロンを多層構

造にすると改善されるのではないかという発想がなされた。この発想は、そもそも本物の脳は1層のパーセプトロンよりもはるかに複雑だから、単純パーセプトロンの層数を増やせば賢くなるのではないかという考え方から由来している。ところが、層数を増やしても賢くならなかった。層数が増えたと、学習すること自体が成り立たなくなったのである。この問題を克服するために、層数が増えても学習できる方法が模索され、誤差逆伝播法（バックプロパゲーション）が発明された。

バックプロパゲーションの仕組みの話に進む前に、人工ニューロンの構造の話に戻ると、図3に示されているように、入力情報には荷重（重み）がか




図5 単純パーセプトロン

(清水, 2016, p.24)




図6 線形分離可能と不可能

(清水, 2016, p.24)

けられる。それと同じように、ニューロンどうしを接続する経路（リンク）にも重みかけられる。仮にAさん、Bさん、Cさんの3人をニューロンだと見立てると、次のような話があるかもしれない。ある映画を見て、Aさんは「おもしろかった」と言い、Bさんは「つまらなかった」と言った。それを聞いたCさんがその映画を見に行ったら「つまらなかった」とすれば、CさんからAさんへの信頼度（重み）は下がらざるをえない。そんなときにAさんがCさんに「この漫画、おもしろいよ」と勧めても、CさんがAさんの言うことを信じるのは難しい。このとき偶然にも同じ漫画をBさんがCさんに「この漫画、そこそこおもしろいよ」と勧めてきた。BさんもAさんも勧めたのでCさんは「もしかして」と思って読んでみたら、その漫画はCさんにとっては大傑作で、Cさんは他の人たちにその漫画を勧めたくなった。Cさんは、Aさんからのリンクにも、Bさんからのリンクにも、それぞれに重みをかけている。Aさんからの情報には話半分くらいの重みづけがなされ、Bさんからの情報は信用に値する重みづけがなされている。

Cさんは映画のときはつまらなかったので興奮しなかったが、漫画のときは大傑作だったので大興奮し、他の人たちに言いたくてたまらないくらいだった。このように興奮することをニューラルネットワークでは、「活性化する」と呼ぶ。そして、与えられた入力に対して当該ニューロンが活性化するかどうかを決定する関数を「活性化関数」^(注6)と呼ぶ。ニューラルネットワークは、このようにして情報をやりとりしているニューロン間の結合がもとになって構成されている。たとえば、図7のような多層構造のパーセプトロンに女性の画像を入力すると、それぞれのニューロンがランダムに反応して情報を伝播していく。このとき、情報は入力側から出力側へ伝播されるので、これはフォワードプロパゲーション（順伝播）である。ニューラルネットワークの初期状態はランダムになっているので、入力情報が複数の中間層を経由して最終結果として出力層に出力されたとき、最初

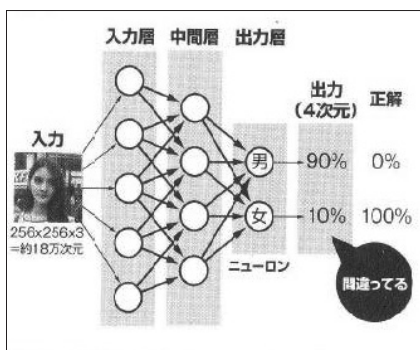


図7 フォワードプロパゲーション
(清水, 2016, p.28)

の答えは必ず間違っている。図7では、女性の画像を見せたのに、「男90%、女10%」という答えになっている。

正解は、言うまでもなく「男0%、女100%」である。そこで、正解と出力結果がどれくらいかけ離れているかの誤差（ロス）を計算して、図8のように、誤差をもとにして、間違った答えを出したニューロンの重みづけを段階的に減らしていくわけである。この方法が、バックプロパゲーション（誤差逆伝播法）である。これを行うと、再び同じ画像を見せたときに、出力結果が多少は改善されていく。図9では、「男40%、女60%」となり、初回よりも正解に近づいている。このようにフォワードプロパゲーション（Forward Propagation）とバックプロパゲーション（Back Propagation）を何度も繰り返して、精度を上げていく。つまり、ニューラルネットワークは、このようにして段階的に学習を積み重ねていくのである。

ところが、バックプロパゲーションを用いても、中間層が3つまでなら学習がうまくいくものの、層がそれ以上に増えてしまうと学習はうまくいかないことがわかった。図10に示されているように、層が多くなると誤差が小さくなりすぎてしまい、

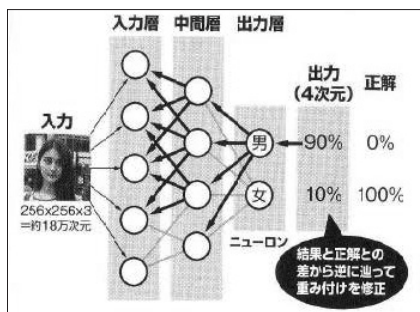


図8 バックプロパゲーション
(清水, 2016, p.28)




図9 再フォワードプロパゲーション
(清水, 2016, p.30)




図10 層数と学習の可能・不可能
(清水, 2016, p.30)

結果として学習できなくなるのがその原因である。

この難問を解決する手法は、2006年にヒントンにより提唱された。この手法がオートエンコーダ（自己符号化器）と呼ばれるものであり、これがディープラーニングの主要な構成要素となったのである。オートエンコーダでは、多数の層を一気に学習させるのではなく、1層ずつ順番に学習させることによって、深層構造のニューラルネットワークを学習

できるようにしている。また、オートエンコーダでは、図11に示されているように、入力されたデータを一旦少ない次元に圧縮してから、その後再びもとの次元に戻すような仕方での学習をさせている。そうすることによって、少なくした次元からもとのデータを再現できるようになったのだが、このことはすなわち、もともとの入力データが有する「特徴表現」(representation)ないし「特徴量」(feature)を少ない次元において獲得したということを意味している。

たとえば図11では、「7」という数字が入力され、入力を再現できるための学習が実行された結果、「7」という数字が出力されている。28ピクセル×28ピクセル=784ピクセルの画像を使用しているので、入力層は784次元、出力層も784次元になっている。そして、この場合は中間層（隠れ層）が400次元になっている。784次元を400次元に圧縮する手法は、たとえば「左下のところが黒くなっていれば、その周辺の10ピクセルをまとめて黒くしても出力への影響はない」ということが判明すると、10ピクセルの情報を1ピクセルで代用させるような手法である。このようにして、同一画像のエンコーディング（圧縮）とデコーディング（復元・再構築）をただひたすらに繰り返していく。そして、この過程において、少ない情報量を経由してもどうすれば復元できるかが学習されているのである。その結果として、入力層と出力層の答え合わせの成績がよいときに隠れ層にできているものが、よい特徴表現だということになる。




図11 オートエンコーダ
(清水, 2016, p.32)

実は、オートエンコーダで行っていることは、データ解析法の一つである主成分分析で行っていることと似ている。線形な重みの関数を用いて、最小二乗誤差を復元エラーの関数にすれば両者は一致する。ただし、オートエンコーダの場合は、非線形な関数を含めて任意の関数を用いることができる点が異なっている。また、主成分分析の場合は、通常、第2主成分は第1主成分の残余から計算されるので第1主成分の影響を強く受け、第3主成分は第1・第2主成分の影響を強く受け、高次の主成分では実質的意味をほとんど喪失してしまう。さらに、オートエンコーダの場合は、さまざまな方法でノイズを与えることによって、きわめて頑強な特徴量を取り出すことができる。それゆえに、よりディープに、より多層において学習することによって、主成分分析では取り出せないような高次の特徴量の獲得に至っている。

人間の赤ちゃんの場合は、目や耳から入ってくる多くの情報をもとにして、何と何が相関し、何が独立成分かという計算を高速で反復していると考えられる。コンピュータ (computer) という言葉の語源については、「ホッブスが、われわれの心の働きはすべて計算 (computatio) であると述べているが、それは正しい」(岡本, 2018, p.85) という言い方をライプニッツ (Gottfried Wilhelm Leibniz) がしている点が注目される。人間も絶えず計算しているわけであるから、人間もその意味ではコンピュータであるとも言えるかもしれない。赤ちゃんは計算と答え合わせの繰り返しからさまざまな特徴量を発見し、たとえば「お母さん」という概念を獲得する。このような作業を通して、世界というものが学習されていくわけである。

図12は、2012年に発表された「グーグルのネコ認識」という研究である。ここでの入力は、ユーチューブの動画から取り出された1,000万枚の画像である。下の方の層では画像によくある模様が認識されるだけであるが、少し上の方の層では丸や三角などの形が認識される。こうした形が組み合わされていくうちに、丸い形をした顔のなかに2つの点としての目があり、その間に縦の線としての鼻があるといった具合で、複雑なパーツが組み合わされた特徴量が獲得される。そして、ついに上の方の層では人間の顔のようなものやネコの顔のようなものが出現している。ユーチューブからの大量の画像をディープラーニングで学習させると、コンピュータはそこから特徴量を取り出して、人間の顔やネコの顔といった概念を自動的に獲得するのである。

スイスの言語哲学者のソシュール (Ferdinand de Saussure) は、概念ない

し記号内容 (signifié) と名前ないし記号表現 (signifiant) が表裏一体の対になったものを記号 (signe) と呼んだ。図12で出現したネコの画像は、まさにシニフィエである。このシニフィエと、日本語では「ネコ」、英語では“cat”というシニフィアンが表裏一体になって対を形成しているのである。このようにしてシーニュ (記号) を獲得すれば、そもそもシンボルグラウンディング問題は発生しない。また、データから現象の特徴量を取り出し、それを用いた概念によって知識を表現すれば、フレーム問題も発生しない。したがって、ディープラーニングが登場するまで人工知能は厳密な意味では実現しなかったと




図12 グーグルのネコ認識

(松尾, 2015, p.163)

言わなければならないのであるが、その理由は、「世界からどの特徴に注目して情報を取り出すべきか」(松尾, 2015, p.139) がコンピュータにはわからず、それに関しては人間が工夫して試行錯誤の上で決定していくしかなかったからである。しかし、コンピュータがデータから特徴量を取り出すことができるになれば、機械学習における特徴量設計 (Feature Engineering) の問題は克服されることになる。

「グーグルのネコ認識」の研究では、コンピュータはディープラーニングを行って、シニフィエとシニフィアンの対としてのシーニュを獲得している。そうなれば、次回からは人間やネコの画像を見れば、即座にこれは人間だと

か、ネコだとかの判断ができるようになる。この研究の当時は、1,000万枚の画像を取り扱うために、ニューロンどうしの結合数が100億個もある巨大ニューラルネットワークを用いて、1,000台のサーバーコンピュータ、つまり16,000個のプロセッサを3日間稼働させた。しかし、その後、CPU (Central Processing Unit) だけでなく GPU (Graphics Processing Unit) を活用することによって、たとえば16台のパソコンでも同様の学習が同程度の時間でできるようになっている。ディープラーニングの発展には、コンピュータのマシンパワーの飛躍的向上も大きく貢献している。

以上において明らかになったように、ディープラーニングはニューラルネットワークを多層化したものであり、特徴表現学習 (Representation Learning) を行う機械学習アルゴリズムの1つである。この特徴表現学習という言葉には、ディープラーニングがオートエンコーダによって情報をよく復元するような表現を生成するというニュアンスが含まれている。オートエンコーダは、入力されたデータを幾層もの隠れ層を通してエンコーディングとデコーディングを繰り返して、入力されたデータそれ自身を予測して出力する。このときフォワードプロパゲーションとバックプロパゲーションが繰り返されているが、それは出力 (正解) に当たる部分にもとのデータを入れることによって可能になる。正解は教師が与えるのが本来の姿であるので、正解ラベルを与える学習のことを機械学習の手法としては「教師あり学習」(Supervised Learning) と呼んでいる。しかし、データから概念を自分自身で生成できるというのであれば教師は不要なので、この場合の学習は「教師なし学習」(Unsupervised Learning) と呼ぶ。したがって、通常のディープラーニングにおいては「教師あり学習的な方法による教師なし学習」(松尾, 2015, p.165) によって特徴量を生成しているわけである。

ディープラーニングによってコンピュータは、人間に特徴量を設計してもらうことなく、自分自身で高次の特徴量を獲得し、それをもとに画像を認識できるようになった。これはまさにブレイクスルーであり、このことによって事態が一変する可能性が高まった。松尾 (2016c) によれば、これはまさに「ディープラーニング革命」であり、「認識」から「運動の習熟」を経て「言語の意味理解」へと進んで行くと考えられている。特徴量設計、シンボルグラウンディング問題、フレーム問題が解決されたことによって、認識の課題は基本的なところではすでに達成されている。運動の習熟においては、人

間以上の認識能力を用いつつ、「強化学習」(Reinforcement Learning)^(注7)によってロボットや機械が練習に練習を重ねて職人と同じ習熟した動きができるようになることがめざされている。言語の意味理解では、ディープラーニングによってコンピュータがついに文の意味を理解できるようになってきている。人間の場合においても、理解できたかできなかったかは、理解できたと思われる事柄を自分自身の言葉で言い表したり図に描いたりすることによって判定されるのだが(山鳥, 2002)、コンピュータも文から画像を生成し、文と画像の相互変換ができるようになってきている。これはちょうど、子どもがお話を聞いてその情景を心のなかに思い浮かべるのと同じことができるようになったということである。この技術を用いれば、たとえば日本語から生成モデルで画像を作り出し、その画像を識別モデルで英語へ翻訳することも可能である。こうした画像を介した翻訳(意識)は、画像の生成モデルと識別モデルが用意されている言語どうしであれば、何語から何語への翻訳も可能になる。

最後に、松尾(2016c)が考える日本のとるべき戦略は、およそ次のとおりである。予選リーグA(情報路線)、予選リーグB(運動路線)、決勝リーグの3つがあるとして、A(メール、スケジュール管理、対話、質問応答などのプラットフォームを作る分野で、便利であるということが付加価値)では欧米が圧倒的に強く、日本が勝ち上がる可能性は低い。しかし、B(ものを動かす、加工する、調理するなどの分野で、信頼できるということが付加価値)では日本が強い。来るべき決勝リーグでは、それぞれのリーグの勝者が競い合って、人工知能や機械が高度にモジュール化して組み込まれた社会を実現していくことになるであろうが、その際、主な手法となるのは、畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)系、リカレントニューラルネットワーク(Recurrent Neural Network: RNN)系、オートエンコーダ系の技術であり、これに関する大量の人材育成が急務である。

3 アクティブラーニングの特質

ディープラーニングとは、特徴表現学習を行う機械学習アルゴリズムの1つで、人間の脳神経回路をモデルにしたニューラルネットワークを多層化することにより、データに含まれる潜在的な特徴量をコンピュータが自分自身

の力（学習能力）によって取り出し、より正確で効率的な判断を実現させる技術や手法のことであった。換言すれば、ディープラーニングのお陰でコンピュータはいわば自立的・主体的に学習を行って、自分自身で独自の成果を生み出すことができるようになったと言えるのではないと思われる。それでは、こうしたディープラーニングの立場から、人間が主体的にかかわることによって成り立つアクティブラーニングの考え方や手法を見たら、どのように見えるのだろうか。

今日、日本の大学においてはアクティブラーニングの導入が必要だと言われるが、その理由としては次の5点がよく指摘される（アクティブラーニング実践プロジェクト、2015）。①テクノロジーの急速な発達により社会の変化が激しくなり、社会が求める能力が変化したこと、②ユニバーサルアクセス段階が到来し、従来なら大学へ進学しなかった層が大量に大学教育を受けるようになったこと、③自分の解釈や理解を言語化し相手に伝えるというソーシャルな学びが、より高度なコミュニケーション能力形成の点でも効果的だと見なされるようになったこと、④新知識を既有知識と関連づけ、一生剥がれ落ちない知識と理解を得る深い学びが要請されるようになったこと、⑤ラーニングピラミッドという模式図で示されるように、他者に教えるという行為が知識の定着をもたらし実感されていることの5点である。

最後の5点目のラーニングピラミッドとは、図13で描かれているように、知識の定着率は、講義を聴いただけだと5%、読解をすれば10%、視聴覚教材を用いれば20%、デモンストレーションをすれば30%、グループディスカッションをすれば50%、活動や体験をすれば75%、他者に教えれば90%になるというように、一人よりも

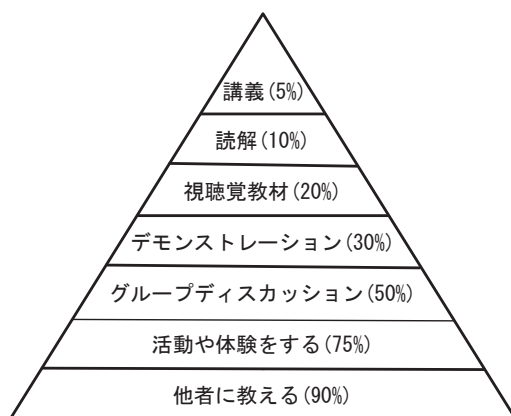


図13 知識の定着率を表すラーニング
ピラミッド（溝上, 2014, p.148）

グループで学習した方が、グループでも認知的負荷がより高い活動を行った方が、知識の定着率は高くなると主張する模式図である。アクティブラーニングという言葉は、2000年代に入ってから主として高等教育においてカタカナ表記で使用されるようになった。それ以前は、英語からの訳語として「能動的学習」「積極的学習」「主体的学習」などが当てられていた。そして、こうした言葉は、1970～80年代から徐々に、90年代以降は本格的に、主として初等中等教育においてであるが高等教育においても幅広く使用されている。

ところが、アクティブラーニングの定義の方は、厳密になされないままの状態が続いていた。あらゆる分野の専門家や実践家が納得できるような定義を作り上げることは不可能に近いという事情も関係しているが、このことを前提にした上で、アクティブラーニングとは「一方的な知識伝達型講義を聴くという（受動的）学習を乗り越える意味での、あらゆる能動的な学習のこと。能動的な学習には、書く・話す・発表するなどの活動への関与と、そこで生じる認知プロセスの外化を伴う」（溝上，2014，p.7）という定義がなされている。この定義に従えば、受動的な学習は効果的ではない。このことは、人工知能の例を用いて言えば、独力で意味を理解できないコンピュータは有用ではないということと同じことではないだろうか。つまり、教えられるばかりでは意味を理解できるようにはならず、意味が理解できなければ知識は定着しないことになると考えられる。

では、能動的な学習とは、どのような学習のことなのだろうか。書く・話す・発表するなどの活動がアクティブラーニングの必須条件である。では、何を書き・話し・発表するのだろうか。それは、学習課題から学習者が学んだ成果だと言える。このことをディープラーニングに置き換えるなら、入力データに対してフォワードプロパゲーションとバックプロパゲーションを何度も繰り返すことによって、そして層が深くなればエンコーディングとデコーディングを何度も繰り返すことによって、もとの入力データが有する特徴表現ないし特徴量を取り出すこと（特徴表現学習）に相当していると言えるのではないだろうか。そうだとしたら、アクティブラーニングで要求されている手法は、ディープラーニングを可能にした手法ときわめて親和的ではないかと考えられる。そこで、このことをもう少し詳しく明らかにするために、アクティブラーニング型授業の戦略の一つである LTD 話し合い学習法（Learning through Discussion）における学習過程をディープラーニング、つ

まり特徴表現学習の立場から見てみたい。その前に、LTD 話し合い学習法（以下、「LTD」と略記）の概要について若干の説明をしておきたい。

LTD は、アメリカ・アイダホ大学のヒル（William Fawcett Hill）によって 1962 年に開発され、その名称のとおり、学習者が小グループに分かれて議論することを通して学習を進めていく協同学習の一つである。このような手法を用いることにより、LTD は「教授者中心の教育」から「学習者中心の教育」への転換を図りながらも、「這いまわる経験主義」を克服していると考えられる（森・鈴木，2016）。しかも、LTD による学びの効果は顕著に出現することが明らかにされている（鈴木・森，2017）。LTD では、協同学習（集団思考）により実施される授業（ミーティング）に先立って、個人学習（個人思考）により予習を行わなければならない。そして、この予習においては、テキスト（課題文）の徹底的な読解が要求される（森・鈴木，2018）。

LTD の目的は、学習教材である課題文をできるだけ深く読み解いていくことにある。（これはまさに、ディープラーニングの目的が入力データからできるだけ有効な特徴量を取り出すことに置かれているのと同じだと考えられる。）LTD の読解手法は、予習の際もミーティングの際も「LTD 過程プラン」に基づいている。この過程プランは、グループ・ダイナミクスやブルーム（Benjamin Samuel Bloom）の教育理論、さらに認知心理学や学習心理学などの知見に基づいて編み出され、「予習用」と「ミーティング用」がある。

表 1 が予習用の、表 2 がミーティング用の過程プランである。この 2 つは基本的に同じである。ステップ 1 と 8 が異なっているが、これは個人作業かグループ作業かの違いで、本質的な違いではない。ただし、ミーティング用には時間制限があるが、予習用にはそれがなく大きく違っている。一般に予習をすればするほどミーティングで得られる成果が大きくなるため、学習者は自発的な努力で予習ノートの作成にますます勤しむようになることが報告されている。そもそも予習なしのミーティングを LTD と呼ぶことはないし、ミーティングの成否は学習者の予習にかかっている。ミーティングでは、小グループにおいて予習の成果を発表して討論するが、このときに他のメンバーとの議論を通してきわめて多くの新たな視点や刺激を受け取ることにより自分自身の見解をより明確に・より堅固にしていきながら、課題文の理解を深めるだけでなく、次の予習へ向けて大いに動機づけられる。こうしたことをディープラーニング（特徴表現学習）の立場から見れば、どのよう

表1 LTD 過程プラン (予習用)

段 階	ステップ	予習内容 (ノート作成)	
理 解	St. 1 課題を読む	全体像の把握	低次の学習 (収束的学習)
	St. 2 語彙の理解	言葉調べ	
	St. 3 主張の理解	主張のまとめ	
	St. 4 話題の理解	話題のまとめ	
関連づけ	St. 5 知識の統合	既有知識との関連づけ	高次の学習 (拡散的学習)
	St. 6 知識の適用	自己との関連づけ	
評 価	St. 7 課題の評価	学習課題の評価	
準 備	St. 8 リハーサル	ミーティングの準備	

安永 (2006)・溝上 (2014) をもとに作成

表2 LTD 過程プラン (ミーティング用)

段 階	ステップ	討論内容	配分時間 (60分)
準 備	St. 1 導入	雰囲気づくり	3分
理 解	St. 2 語彙の理解	言葉の定義と説明	3分
	St. 3 主張の理解	全体的な主張の討論	6分
	St. 4 話題の理解	話題の選定と討論	12分
関連づけ	St. 5 知識の統合	既有知識との関連づけ	15分
	St. 6 知識の適用	自己との関連づけ	12分
評 価	St. 7 課題の評価	学習課題の評価	3分
	St. 8 活動の評価	ミーティングの評価	6分

安永 (2006)・溝上 (2014) をもとに作成

に見えるのだろうか。成果発表は予習の出力であるがミーティングの入力であり、討論はオートエンコーダにおいて意図的にノイズを与えて特徴量に頑強性 (ロバスト性) をもたせることであり、理解を深めることは特徴量を最適化することであり、次回への動機づけはまさに強化学習そのものであると受け取ることができるのではないかと考えられる。以上のことは LTD 過程プランの全ステップにおいて共通に当てはまるとして、各ステップではどのような処理作業が行われることになるのかについて見ていきたい。

ステップ1 全体像の把握

予習では、わからない言葉や内容があっても、まず課題文の全体を一読し、課題文の全体像が把握できるまで繰り返し読むことが求められる。これは途方もない要求である。全体は部分からしか理解されないし、部分は全体からしか理解されない。あらゆる解釈術のなかで最も困難な「解釈学的循環」の問題に最初に直面させられる。しかし、次の段階へ進むためには、この山は何としても乗り越えなければならない。身も蓋もない結論を言えば、課題文の全体像を把握するためには、それができるまで繰り返し読むしかない。

通常、文は単語の羅列ではなく、文章は文の羅列ではなく、文章の全体が一貫した意味を有するように単語や文が構成されている。この「意味」に気づくことがポイントではないかと思われる。そして、この「意味」が「特徴量」になっていると考えられる。特徴量とは、対象を認識する際に注目すべき特徴を定量的に表したものであるが、要するに「どこに目をつけたらよいか」「重要なのはどこか」「何が有効か」「コツは何か」などのことである。認知心理学の情報処理アプローチでは、トップダウン処理とボトムアップ処理の区別をしながらも、この2つは対極的であるが排他的ではなく、並行して処理が進められると想定している（柏崎, 2010）。この想定に基づけば、トップダウン処理（全体から部分を理解する）とボトムアップ処理（部分から全体を理解する）を並行化することが重要になる。

このことは実際、ディープラーニングが行っていることだと考えられる。ニューラルネットワークの初期状態はランダムになっているので、最初は入力情報を理解することはできない。そこで、フォワードプロパゲーションとバックプロパゲーションを何度も繰り返して、理解の精度を上げていく。行ったり来たりを何度も繰り返しながら、徐々に全体像（全体構造）を明瞭にしていかなければならないというのは、人間でもコンピュータでも共通である。なお、ミーティングでは、教授者が協同学習のさまざまな技法を用いながら、学習者に仲間の心身の状態をお互いに把握させつつ授業への参加意欲を一層高めることが重要だとされているが、この他にも、今から取り組むタスクの意義を確認し合い、それを明確にするということもありえると思われる。コンピュータにタスクの意義をあらかじめ理解させることは困難だとしても、タスクの内容を明確にして情報を入力するのは必須だと思われる。

ステップ2 言葉の理解

予習では、課題文を読んで気になった言葉の意味を調べてノートにまとめ、ミーティングで仲間に説明できるように準備する。ミーティングでは、よくわからないものや重要なものの意味を教え合って理解する。このとき人間にとって不可欠なのは、「意味がわからないと、わかりたいと思う心」ではないかと思われる。この心は、認識の脳科学では人間の心の根本傾向だと考えられるが（山鳥，2002）、その程度に応じて学習の様態は異なるのではないかと思われる。AlphaGo は囲碁のルールを事前に棋譜で学習していたが、AlphaGo Zero は完全に自己対局だけで学習していく。前者は「教師あり学習」を、後者は「教師なし学習」をしていると言える。なお、この場合の「教師」とは「出力データ」（正解データ）のことを指している。

ディープラーニングの場合、「教師あり学習」がよいのか、「教師なし学習」がよいのか、はたまた「強化学習」がよいのかは、優劣の問題ではない。与えられたタスクや目的に応じて、どの手法が適しているかだけが問題なのである。人間の場合、わからない言葉の意味を調べることなく、課題文の文脈だけから推測することも不可能ではないかもしれないが、それはかなり困難ではないかと思われる。通常のディープラーニングの場合は、「教師あり学習的な方法による教師なし学習」によって特徴量を生成しているように、人間の場合も、必要に応じて事前学習を完了させておくのが重要だと考えられる。

ステップ3 主張の理解

課題文の著者の主張を著者の立場から客観的に理解したうえで、それを学習者が自分自身の言葉でまとめることがこのステップの処理作業である。これはすなわち、入力データが有する最も本質的な特徴量を見つけ出す処理作業に他ならないと考えられる。しかし、特徴量を抽出することはコンピュータにとってはとても難しい処理作業で、ディープラーニングの登場以前は人間が特徴量の選択を行わなければならなかった。ところが、現在ではディープラーニングによって入力データを読み込んで特徴量を抽出することが実現されている。これが特徴表現学習であり、特徴量を機械学習それ自体に発見させるアプローチである。

課題文における著者の主張を学習者自身の言葉でまとめるという処理作業は、オートエンコーダによってできるだけよい特徴表現を作り出すことに相

当すると考えられる。図11で見たように、オートエンコーダは入力と出力が同じになるニューラルネットワークである。入力と出力が同じになるような学習をするのがオートエンコーダだと言われても、それにどんな意味があるのかはそれだけではわかりにくい。この学習の特色は、入力情報のエンコーディング（圧縮）とデコーディング（復元・再構築）を繰り返しているうちに、入力情報の特徴がうまく圧縮表現された特徴表現が隠れ層にできあがってくるという点にある。入力層と出力層の答え合わせの成績がよいときほど隠れ層によりよい特徴表現ができていくわけであるから、このような方式によって課題文の圧縮と復元を繰り返していけば著者の主張を学習者自身の言葉で特徴づけるに至るのではないかと考えられる。

ステップ4 話題の理解

このステップの目的は、著者の主張を支持する話題を見つけて、話題ごとに内容を理解するとともに、逆に話題を手がかりにすることによって著者の主張をより深く理解することに置かれている。ここで「話題」と呼ばれているのは英語の topic を訳したものであり、たとえば「根拠」「理由」「背景」「状況」などがある。主張が成り立つことができるためには、そうした話題がどうしても必要である。ということは、著者は主張を成立させるために話題を用いているわけであるから、話題を見つけようとする場合は、著者の立場に立って「文章作成における主張と話題の取り上げ方」を意識しながら課題文を読むと効果的ではないかと考えられる。

こうした考え方は、第2次人工知能ブームにおける知識表現研究の考え方に類似していると思われる。つまり、概念の意味をネットワーク化し、概念を関係性で記述しようとする考え方である。たとえばIBMのワトソンはこの方式で傑出した成果を挙げたが、そこにはオントロジーの難しさやフレーム問題、シンボルグラウンディング問題が付随している。しかし、こうした問題はディープラーニングの登場によって一挙に解消された。たとえば図12の「グーグルのネコ認識」で明らかに示されるように、ディープラーニングで学習させると、コンピュータは特徴量を取り出して、人間の顔のようなものやネコの顔のようなものを出現させる。こうした「人間の顔」や「ネコの顔」は、ニューラルネットワーク上の「ノード」として出現する。そして、このノードが課題文で言えば話題に相当するのではないかとと思われる。したがっ

て、意味ネットワーク的方法だけではなく深層ニューラルネットワーク的方法で話題を見つけ出すこともありえるのではないかと思われる。

ステップ5 既有知識との関連づけ

このステップでは、課題文から学んだ学習内容（新知識）を、すでに知っていたこと（既有知識）と関連づけて、課題文の理解をさらに深めることをめざす。新知識はいくつあってもよいが、これを「ベース」と呼ぶ。そして、そのベースごとに関連していることを思い出す。これを「ターゲット」と呼ぶ。ターゲットは同じ授業の内容からでも、他の授業の内容からでも、個人的な経験からでも、つまりどこから選んでもよい。仲間が思いつかないようなターゲットを選んだり、ベースとターゲットの関連づけ方が意外だったりすると、仲間が驚いてミーティングが盛り上がる。驚きを伴う理解は記憶に残りやすい。こうした関連づけにより、学習内容が学習者自身の知識構造のなかに組み込まれて、理解が深まり記憶が促進されるとともに、知識の断片化が防止されて体系化され、より広い文脈での知識活用力が向上する。

唐突の感は免れないが、ここで行っていることは、機械学習が対象にする3つの学習（教師あり学習、教師なし学習、強化学習）のうち、強化学習に相当するのではないかと思われる。強化学習においては、一連の行動を遂行していく過程で、どのような行動をとればそこからより多くの報酬が得られるかを基準にして学習が進められていく。この学習メカニズムについて、2013年に DeepMind 社が動画 (<https://www.youtube.com/watch?v=TmPfTptdgg>) で公開しているゲームの「ブロック崩し」を行うプログラムを例にして考えてみたい（2019年9月10日閲覧）。

従来のプログラムは、人間がルールを定義して教えていたため、上達に限界があった。ところが、ディープラーニングと強化学習を組み合わせたプログラムにしたら、画像を入れただけで、最初は下手だが試行錯誤しているうちにだんだん上達し、ついに人間を上回る記録を残した。ここではスコアが報酬で、スコアが上がると、その前の行動が強化される。そのようにして練習を重ねているうちに、コンピュータが自分でコツを発見していくようになる。つまり、画像から特徴量を取り出して、どのようにプレイすればよい成績が出せるかに気づくようになるのである。しかも、同一のプログラムで、「インベーダーゲーム」を学習させることもできる（松尾, 2016c）。

このプログラムは、何度も練習しているうちに、独力でコツを発見し続けている。コツは発見された時点では新知識だが、次のコツが発見されると既有知識になる。そのようにして、新知識と既有知識が次から次へと生み出されていく。それを理解して関連づけることにより、知識を体系化して知識活用力を獲得している。ディープラーニングと強化学習を組み合わせた学習は「深層強化学習」(Deep Reinforcement Learning) と呼ばれるが、AlphaGo もこれを用いている。人間以上の能力を形成する可能性を有する深層強化学習は、自動運転やロボティクスの分野で活用され始めている (巢籠, 2018)。

ステップ6 自己との関連づけ

このステップでは、課題文から学んだ学習内容(ベース)を、自分自身に關すること(ターゲット)と関連づけて、自分自身のことを振り返る。思い浮かべるターゲットとしては、自分自身のこと、自分を中心とした人間関係、自分が所属している集団などがある。ステップ5と6の作業は同様の手順で行うため、最初のうちは両者を区別するのは難しい。区別の基準は、思い浮かべたターゲットが知識それ自体に関連するものであればステップ5、自分自身の生き方(人生観)や考え方(価値観)に関連するものであればステップ6という点に置けばわかりやすいかもしれない。

機械学習やディープラーニングといえば、文字や物体を認識するためのものというイメージが強いが、そのような識別タスクだけではなく、生成タスクにも応用されることができるようになってきている。生成タスクには、「データをもとにして、新しく別の何かを生成する」と「データそのものを生成する」の2種類があり、これを遂行する手法は「生成モデル」と呼ばれる。生成モデルにおいてもディープラーニングを組み合わせると、これまで以上の成果が得られることがわかったので、この2つを組み合わせた「深層生成モデル」(Deep Generative Model)の研究も進められている(巢籠, 2018)。自己との関連づけで求められているのは、たとえば「今回このようなことを学んだので(ベース)、今まではこのようにしていたけれども(ターゲット)、今後はこのようにしてみたい(関連づけ)」というようなかたちでの「新たな思考行動の創造」であると受け取るならば、これはまさに生成モデルの問題ではないかと思われる。

ステップ7 課題文の評価

これまでのステップでは課題文を批判したり評価したりすることは禁じられているが、このステップでは課題文の評価を行う。ここでの評価とは、当該課題文の改善に役立つ建設的な評価を行うということである。現代社会においても、的確な評価ができるというのは、価値ある能力である。この能力を向上させるには、観察力や分析力、論理的で柔軟な思考力が必要とされるが、ステップ7ではこうした能力養成も重要な目的になっている。このことは、ディープラーニングの場合で言えば、出力データと照合しながら入力データを評価することに相当すると思われる。

ステップ8 リハーサル／ミーティングの評価

予習では、ミーティングの仲間や場面を想像し、ステップの流れに沿ってミーティングの展開を予想しながら一人で予行演習を行う。その結果、予習不足が判明したら、予習をもっと行う。ミーティングでは、ミーティング自体を振り返って評価し、今後の改善点を出し合い、対応策を話し合ってから授業を終える。このことは、ディープラーニングの場合で言えば、処理作業の目的と照合しながら出力データを評価することに相当すると思われる。

ところで、「アクティブラーニング」という用語は、日本では2012年8月28日の中央教育審議会答申「新たな未来を築くための大学教育の質的転換に向けて～生涯学び続け、主体的に考える力を育成する大学へ～」以降にますます注目を集めるようになった。当時は、文部科学省はアクティブラーニングを推進していくと思われていたが、2017年の学習指導要領改訂案においてその文言が消え、「主体的・対話的で深い学び」という表現に変更された。その理由について、文部科学省は次のように説明している。

「アクティブ・ラーニング」という用語については、文脈等により様々な定義で用いられることから、法規としての性格を有する学習指導要領ではこれを用いずに、「主体的・対話的で深い学びの実現に向けた授業改善」としてお示ししています。これは、平成28年12月の中央教育審議会答申「幼稚園、小学校、中学校、高等学校及び特別支援学校の学習指導要領等の改善及び必要な方策等について」における「平成26年11月の諮問において提示され

た『アクティブ・ラーニング』については、子供たちの『主体的・対話的で深い学び』を実現するために共有すべき授業改善の視点として、その位置付けを明確にすることとした」との提言を踏まえたものであり、児童生徒の資質・能力の育成に向けて、主体的・対話的で深い学びの視点（アクティブ・ラーニングの視点）からの授業改善を図ることが重要であるという認識は変わっていません。（文部科学省、2018）

では、「主体的・対話的で深い学び」とは、どのような学びなのだろうか。上の文科省の説明に登場する平成28年12月の中央教育審議会答申では、次のように説明している。

○「主体的・対話的で深い学び」の実現とは、特定の指導方法のことでも、学校教育における教員の意図性を否定することでもない。人間の生涯にわたって続く「学び」という営みの本質を捉えながら、教員が教えることにしっかりと関わり、子供たちに求められる資質・能力を育むために必要な学びの在り方を絶え間なく考え、授業の工夫・改善を重ねていくことである。

○「主体的・対話的で深い学び」の具体的な内容については、以下のように整理することができる。

「主体的・対話的で深い学び」の実現とは、以下の視点に立った授業改善を行うことで、学校教育における質の高い学びを実現し、学習内容を深く理解し、資質・能力を身に付け、生涯にわたって能動的（アクティブ）に学び続けるようにすることである。

① 学ぶことに興味や関心を持ち、自己のキャリア形成の方向性と関連付けながら、見通しを持って粘り強く取り組み、自己の学習活動を振り返って次につなげる「主体的な学び」が実現できているか。

子供自身が興味を持って積極的に取り組むとともに、学習活動を自ら振り返り意味付けたり、身に付いた資質・能力を自覚したり、共有したりすることが重要である。

② 子供同士の協働、教職員や地域の人との対話、先哲の考え方を手掛かりに考えること等を通じ、自己の考えを広げ深める「対話的な学び」が実現できているか。

身に付けた知識や技能を定着させるとともに、物事の多面的で深い理解

に至るためには、多様な表現を通じて、教職員と子供や、子供同士が対話し、それによって思考を広げ深めていくことが求められる。

③ 習得・活用・探究という学びの過程の中で、各教科等の特質に応じた「見方・考え方」を働かせながら、知識を相互に関連付けてより深く理解したり、情報を精査して考えを形成したり、問題を見いだして解決策を考えたり、思いや考えを基に創造したりすることに向かう「深い学び」が実現できているか。

子供たちが、各教科等の学びの過程の中で、身に付けた資質・能力の三つの柱を活用・発揮しながら物事を捉え思考することを通じて、資質・能力がさらに伸ばされたり、新たな資質・能力が育まれたりしていくことが重要である。教員はこの中で、教える場面と、子供たちに思考・判断・表現させる場면을効果的に設計し関連させながら指導していくことが求められる。(中央教育審議会, 2016)

政策的諸事情があるにしても、「アクティブラーニング」は「主体的・対話的で深い学び」という装いになった。ここに来て、学習の深さへの関心が急速に強まっている感がある。上の中央教育審議会の説明では、結局のところ、知識の習得・活用・探究が重要で、これを高い次元で実現させるものが「深い学び」であると言っているのではないかと思われる。深さの系譜には、少なくとも「深い学習」「深い理解」「深い関与」があるとされるが(松下, 2015)、田村(2018)は、深い学びとは、知識を関連づけることであり、それは知識をネットワーク化して構造化したり、パターン化して身体化したりして高度化することであり、そのためには知識を活用することが重要だと捉えている。

そもそも人間というものは、知情意のすべてを駆使して理解することによって生きていく存在であり(Dilthey, 1883)、体験＝表現＝理解の解釈学的循環のなかで理解を絶えず深めていく存在であり(Dilthey, ca. 1910)、実存に基づいて理解することによって生きていく存在であり(Heidegger, 1927)、それゆえにまさにアクティブラーニングを行うことによって生きていく存在である(森, 2016)。そうだとすれば、ディープラーニングがアクティブラーニングから生み出され、アクティブラーニングがディープラーニングへ行き着くことになったとしても、それは自然な流れだと考えられる。アクティブ

ラーニングからディープラーニングへの方向だけでなく、ディープラーニングからアクティブラーニングへの方向で両者を循環参照的に見るのも一興ではないだろうか。

注

- (1) 機械学習とは、ビッグデータと呼ばれる大量のデータを用いることによって、人工知能プログラムがみずから知識を獲得する学習のことである。このブームが起こった背景は、対象を認識する際に注目すべき特徴を定量的に表した特徴量と呼ばれるものを人工知能プログラムがみずから習得するディープラーニング（深層学習）が登場したことである（瀬谷，2018a）。
- (2) Mycin とは、スタンフォード大学で1970年代初めに開発されたエキスパートシステムのことである。Dendral から派生し、大幅に修正されている。その名称は多くの抗生物質の接尾辞（-mycin）から由来している。
- (3) Dendral とは、世界初と言われるエキスパートシステムのことである。その名称は Dendritic Algorithm（樹枝状アルゴリズム）に由来する混成語である。
- (4) Cyc とは、一般常識をデータベース化し、人間と同等の推論システムを構築することを目的としたプロジェクトのことである。その名称は encyclopedia から由来している。
- (5) 2019年1月12日に公開された Lex Fridman: MIT Deep Learning Basics: Introduction and Overview (youtube.com/watch?v=O5xeyoRL95U) によれば、ディープラーニングのアイディアや画期的な出来事sの歴史として、次のようなものが紹介されている。1943年ニューラルネットワーク。1957年パーセプトロン。1974–86年バックプロパゲーション、RBM、RNN。1989–98年 CNN、MNIST、LSTM、双方向 RNN。2006年「ディープラーニング」、DBN。2009年 ImageNet。2012年 AlexNet、Dropout。2014年 GANs、DeepFace。2016年 AlphaGo。2017年 AlphaGo Zero、Capsule Networks、2018年 BERT。（2019年9月10日閲覧）
- (6) 出力層ではシグモイド関数やソフトマックス関数を用いなければ出力を確率で表すことができないが、隠れ層の活性化関数についてはさまざまな工夫がなされている。たとえば tanh（ハイパボリックタンジェント）関数、ReLU（Rectified Liner Unit）関数、Leaky ReLU 関数、Parametric ReLU 関数、Randomized ReLU などがあるが、どれが一番よいかは一概に言えない（巢籠，2018）。
- (7) ディープラーニングにおける強化学習とは、ある環境のもとで、目的とする報酬（スコア）を最大にするには、どのような行動を選択していけばよいのかを学習していくことである。「教師あり学習」と「強化学習」を混同するケースが多く見られるが、強化学習では、一連の行動系列の結果としての報酬を最大化するように学習する点が、教師あり学習と異なっている。ロボットの歩行制御の例で言えば、歩き方の正解ラベルを与えるのが教師あり学習で、歩けた距離（強化子）を報酬として与えるだけなのが強化学習である（巢籠，2018）。

引用・参考文献

- アクティブラーニング実践プロジェクト (2015)「アクティブラーニングをめぐる起きてきたこと、起こっていること」、小林昭文・鈴木達哉・鈴木映司・アクティブラーニング実践プロジェクト (編)『現場ですぐに使えるアクティブラーニング実践』、産業能率大学出版部、1-23頁。
- 浅川伸一・江間有沙・工藤郁子・巢籠悠輔・瀬谷啓介・松井孝之・松尾豊 (2018)『深層学習教科書ディープラーニング G 検定 (ジェネラリスト) 公式テキスト』、一般社団法人日本ディープラーニング協会監修、株式会社翔泳社。
- 浅川伸一 (2018)「ディープラーニングの研究分野」、浅川他 (2018) 187-220頁。
- 中央教育審議会 (2016)「幼稚園、小学校、中学校、高等学校及び特別支援学校の学習指導要領等の改善及び必要な方策等について (答申)」。
- Dilthey, Wilhelm (1883) *Einleitung in die Geisteswissenschaften. Versuch einer Grundlegung für das Studium der Gesellschaft und der Geschichte. Erster Band.* In: ders.: *Gesammelte Schriften*, Bd. 1, Stuttgart 1959.
- Dilthey, Wilhelm (ca. 1910) *Plan der Fortsetzung zum Aufbau der geschichtlichen Welt in den Geisteswissenschaften. Entwürfe zur Kritik der historischen Vernunft.* In: ders.: *Gesammelte Schriften*, Bd. 7, Stuttgart 1979, S. 189-291.
- グッドフェロー, イアン・ベンジオ, ヨシュア・カービル, アーロン (2018)『深層学習』、岩澤有祐・鈴木雅大・中山浩太郎・松尾豊監訳、株式会社ドワンゴ。
- Heidegger, Martin (1927) *Verstehen und Auslegung.* In: ders.: *Sein und Zeit*, Tübingen 1979, S. 148-153.
- 柏崎秀子 (2010)「文章の理解・産出の認知過程を踏まえた教育へ——伝達目的での読解と作文の実験とともに」、『日本語教育』第146号、34-48頁。
- 松尾豊・塩野誠 (2014)『東大准教授に教わる「人工知能って、そんなことまでできるんですか?」』、株式会社 KADOKAWA。
- 松尾豊 (2015)『人工知能は人間を超えるか——ディープラーニングの先にあるもの』、株式会社 KADOKAWA。
- 松尾豊 (2016a)「はじめに——人工知能とは何か」、人工知能学会監修・松尾豊編著『人工知能とは』、株式会社近代科学社、iii-vii 頁。
- 松尾豊 (2016b)「ディープラーニングで日本のモノづくりは復権する」、DIAMOND ハーバード・ビジネス・レビュー編集部編訳『人工知能——機械といかに向き合うか』、ダイヤモンド社、105-122頁。
- 松尾豊 (2016c)「人工知能は人間を超えるか」、SoftBank World 2016、[youtube.com/watch?v=7bvflM5vPQ](https://www.youtube.com/watch?v=7bvflM5vPQ) (2019年8月17日閲覧)
- 松尾豊・NHK「人間ってナンダ? 超 AI 入門」作成班編著 (2019)『超 AI 入門——ディープラーニングはどこまで進化するのか』、NHK 出版。
- 松下佳代 (2015)「ディープ・アクティブラーニングへの誘い」、松下佳代・京都大学高等教育研究開発センター編著『ディープ・アクティブラーニング——大学授業を深化さ

- せるために』、勁草書房、1-27頁。
- 溝上慎一 (2014) 『アクティブラーニングと教授学習パラダイムの転換』、東信堂。
- 森邦昭 (2016) 『ディルタイから教育実践へ——アクティブラーニングの源流』、九州大学出版会。
- 森邦昭・鈴木有美 (2016) 「対話の害と LTD 話し合い学習法——協同学習の原理的考察」、福岡女子大学国際文理学部紀要『国際社会研究』第5号、1-12頁。
- 森邦昭・鈴木有美 (2018) 「LTD 話し合い学習法の予習方法に関する考察——解釈学、脳科学、教育心理学からの示唆」、福岡女子大学国際文理学部紀要『文藝と思想』第82号、61-90頁。
- 森邦昭・鈴木有美 (2019) 「読解と解釈学的循環——人工知能「東ロボくん」開発断念からの示唆」、福岡女子大学国際文理学部紀要『文藝と思想』第83号、29-46頁。
- 文部科学省 (2018) 「小・中学校新学習指導要領 Q&A」http://www.mext.go.jp/a_menu/shotou/new-cs/qa/_icsFiles/afldfile/2018/05/18/1401386_3.pdf (2019年8月21日閲覧)
- 岡本裕一郎 (2018) 『人工知能に哲学を教えたら』、SBクリエイティブ株式会社。
- 瀬谷啓介 (2018a) 「人工知能 (AI) とは」、浅川他 (2018) 1-16頁。
- 瀬谷啓介 (2018b) 「人工知能分野の問題」、浅川他 (2018) 65-92頁。
- 清水亮 (2016) 『よくわかる人工知能——最先端の人だけが知っているディープラーニングのひみつ』、株式会社 KADOKAWA。
- 巢籠悠輔 (2018) 「ディープラーニングの手法」、浅川他 (2018) 137-186頁。
- 鈴木有美・森邦昭 (2017) 「LTD 話し合い学習法が教職課程履修者に与える学びの効果——アクティブラーニングに対する認識の変化と授業興味及び授業適応感との関連」、福岡女子大学国際文理学部紀要『国際社会研究』第6号、1-14頁。
- 多田和市 (2018) 『AI 後進国——ニッポンが危ない！脱出のカギはディープラーニング人材の育成』、日経 BP 社。
- 田村学 (2018) 『深い学び』、東洋館出版社。
- 塚本邦尊・山田典一・大澤文孝 (2019) 『東京大学のデータサイエンティスト育成講座——Python で手を動かして学ぶデータ解析』、中山浩太郎監修、松尾豊協力、株式会社マイナビ出版。
- 山鳥重 (2002) 『「わかる」とはどういうことか——認識の脳科学』、筑摩書房。
- 安永悟 (2006) 『実践・LTD 話し合い学習法』、ナカニシヤ出版。
- 安永悟・須藤文 (2014) 『LTD 話し合い学習法』、ナカニシヤ出版。

