

植物科学の「人工知能」との関わり方を考える

大倉史生^{1,2}, 水谷未耶³, 野下浩司^{1,4}, 戸田陽介^{1,5}

¹JST さきがけ 〒332-0012 埼玉県川口市本町4丁目1-8

²大阪大学情報科学研究所 〒565-0871 大阪府吹田市山田丘1-5

³名古屋大学理学研究科 〒464-8601 愛知県名古屋市千種区不老町

⁴九州大学理学研究院生物科学部門 〒819-0395 福岡県福岡市西区元岡774番地

⁵名古屋大学トランスフォーマティブ生命分子研究所

〒464-8602 愛知県名古屋市千種区不老町

Past and Future of Plant Science with Artificial Intelligence

Fumio Okura^{1,2}, Miya Mizutani³, Koji Noshita^{1,4}, Yosuke Toda^{1,5}

¹Japan Science and Technology Agency, 4-1-8 Honcho, Kawaguchi, Saitama 332-0012, Japan

²Graduate School of Information Science and Technology, Osaka University,
1-5 Yamadaoka, Suita, Osaka, 565-0871, Japan

³Division of Biological Science, Graduate School of Science, Nagoya University,
Chikusa-ku Nagoya 464-8602, Japan

⁴Department of Biology, Faculty of Science, Kyushu University,
744 Motooka, Nishi-ku, Fukuoka 819-0396, Japan

⁵Institute of Transformative Bio-Molecules (WPI-ITbM), Nagoya University,
Chikusa-ku, Nagoya 464-8602, Japan

Keywords: deep learning, machine learning, plant phenotyping

DOI: 10.24480/bsj-review.11c2.00191

1. 「人工知能 (Artificial intelligence)」

1-1. 人工知能分野の歴史と主な技術

人工知能 (artificial intelligence; AI) という言葉の初出は、ジョン・マッカーシー、マービン・ミンスキーラにより開催された 1956 年のダートマス会議 (McCarthy et al. 2006) に遡る。とはいえ、人工知能関連の技術開発や議論は、それ以前から様々な分野で行われてきた。例えば近年様々な分野において活用が進むニューラルネットワークの端緒である形式ニューロン (McCulloch and Pitts 1943) は、1940 年代から神経科学の分野で研究されてきたし、「知能を持つ機械」の判定を

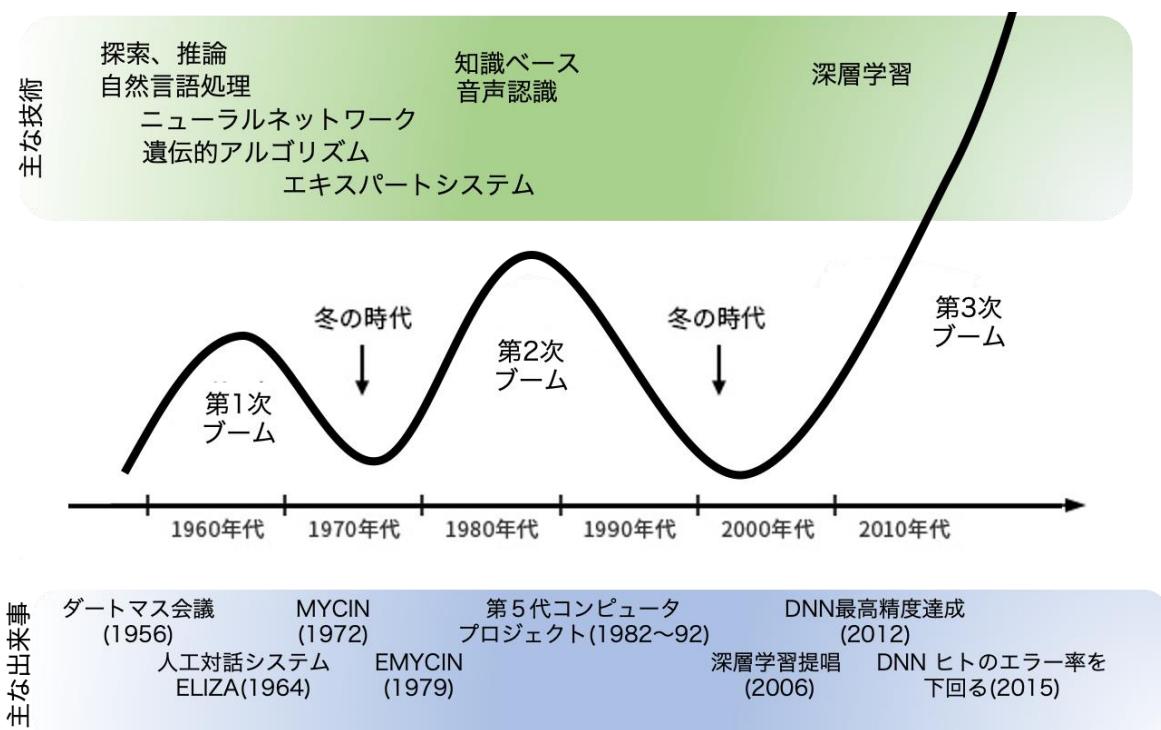


図 1 人工知能の歴史と技術 (平成 26 年版、28 年版 情報通信白書を改変)

行うためのチューリングテスト (Turing 1950) は 1950 年に提案されている¹。以来、図 1 に示すように、人工知能分野で生み出された技術は、人々の過度な期待（あるいはビジネスへの有用性）と技術的困難の狭間で、社会における流行 (AI ブーム) と終焉 (AI 冬の時代) を繰り返してきた。植物科学における活用例を紹介する前に、人工知能分野に関連する主要な歴史や技術を、背景知識としてごく簡単に紹介する。

第一次 AI ブーム：ダートマス会議以降、1960 年代前後に盛んに（多額の資金を投入して）行われた研究群を「第一次 AI ブーム」と呼ぶことがある。数学の定理証明、画像認識、言語理解を含めた様々なタスクに対する研究が行われ、人間と同等の知能を備えた機械の実現も近い、などと楽観視されていた側面もある (Crevier 1993)。しかし、この時点では多くの問題において非常に小規模な例を示せたに過ぎず、実世界の問題は、当時の研究者が考えるほど簡単ではなかった²。

エキスパートシステム（第二次 AI ブーム）：1980 年代を中心に流行したエキスパートシステム (Buchanan and Feigenbaum 1981) は「第二次 AI ブーム」の立役者の一つであり、事前に用意した特定の専門分野に関する知識ベース（もし A ならば B である、などの知識の集合）を用いて推論

¹ チューリングテストは非常に有名である一方、反論もある。例えばサールの「中国語の部屋」。

² 問題を過小評価してしまうのは、どの分野でも研究あるあるだと思う。

を行い、専門家の代わりに問題を解決しようとするものである。知識ベースを準備することは非常に大変な作業であるが、タスクを絞ることにより、産業界においても様々な分野で実用的なシステムが開発された。ルールに基づく推論という点で、ルールベースのシステム（rule-based system）などと呼ばれることがある。

機械学習：一方、事前に用意された明示的なルールの集合からの推論とは異なり、データの集合を入力し、事前に設定した評価尺度を改善するように、モデルを近似させる枠組みを機械学習と呼ぶ (Mackay 2003)。カテゴリ分類などに広く使われる「教師あり学習」と呼ばれる枠組みにおいては、事前に入力データ（例：画像、あるいは画像から計算された特徴）とともに、対応する正答データ（例：撮影された物体の種類や位置）を用意する。これらを「教師データ」と呼び、モデルは、入力データから正答データに近い出力を導き出すように学習される。機械学習の詳細な分類（教師あり学習、教師なし学習、強化学習）についての言及は避けるが、植物科学におけるデータ解析でも馴染みの深い回帰分析³（線形、Lasso、ロジスティック、など）のほか、クラス分類（この物体は「猫」である、など）、類似したデータごとにグループ化するクラスタリング（k 平均法、など）などのタスクは、機械学習の一種といえる。最適化の対象となるモデルの構造や最適化手法は数多く提案されており、深層学習を含むニューラルネットワークはその一例である。その他、サポートベクターマシン（SVM）(Suykens and Vandewalle 1999)、ランダムフォレスト (Breiman 2001)、勾配ブースティング（GBM）による決定木学習 (Chen and Guestrin 2016; Ke et al. 2017)⁴などの手法は、深層学習ブームの現在も、学習データの少ない場面などで日常的に使われている。

深層学習（第三次 AI ブーム）：現在、我々は新たな、かつてない規模の「AI」ブームの只中にいる。現在の AI ブームは、機械学習、その中でもニューラルネットワークの一種である深層学習の実用化とともに進んでいる。1980～2000 年代にわたる地道な研究の結果、いくつかの技術的ブレイクスルーと計算資源の飛躍的進歩を背景に、大規模なニューラルネットワークの最適化が可能となった (Hinton and Salakhutdinov 2006) ことで、多層のニューラルネットワークを用いた機械学習（＝深層学習）が実用化された⁵。2012 年、畳み込み演算を行うフィルタの学習を伴う畳み

³ 最も単純な例の一つとして、最小二乗法による線形回帰は、データ集合から評価尺度（二乗誤差）を最小にする近似モデル（線形回帰モデル）を求める点で、機械学習の一種であると呼ぶこともできなくはない。

⁴ 近年は、GBM の一つである XGBoost (Chen and Guestrin 2016) や LightGBM (Ke et al. 2017) が、比較的小規模の分類・回帰においてファーストチョイスとされることが多いのではないかと思う。

⁵ ニューラルネットワークの仕組みについては、ここでは解説しない。デモを含む直感的な解説が <https://playground.tensorflow.org/> にある。また、本稿の最後で、学習のためのリソースをいくつか紹介する。

込みニューラルネットワーク（CNN）(Fukushima and Miyake 1982; LeCun et al. 1989)⁶ の一種である AlexNet (Krizhevsky et al. 2017) が従来の機械学習による手法と比較して画像分類精度を圧倒的に改善し、現在の AI ブームの幕開けを告げた。SVM など従来の機械学習手法の適用時には、多くの場合、画像からの特徴抽出（エッジ検出、次元削減など）が事前に必要であり、その際にある種の専門知識が必要であった。しかし、深層学習は、他の機械学習手法と比較し次元数の大きな入力データ・非常にたくさんのパラメータを含むモデル（例えば、AlexNet の最適化対象のパラメータは 6000 万個以上）を比較的うまく最適化できる。そのため、CNN を用いた画像分類などのタスクにおいては、特徴抽出を省略してネットワークに画像を直接入力し、特徴抽出のための畳み込みフィルタを自動学習させるような使い方ができる。あわせて、深層学習の実装がライブラリ化され、容易に使用できるようになり、参入障壁が低くなっている（今では、高性能のマシン・環境構築を必要としないクラウド実行環境もある⁷）。機械学習や特徴抽出の専門性を必要としない深層学習の特性は、ブームの拡大に大きく寄与しており、深層学習を活用した囲碁の世界チャンピオンへの勝利や、コンテンツ生成、実社会への数多くの応用例など、その社会的インパクトは広く知られるところである。

1 – 2. 結局、人工知能ってなに

「人工知能とは何か」、その明確な定義は非常に困難である。一般論として「知的である」と思われるようなタスクを機械が遂行する場合に「人工知能」と呼ばれることが多い。その点で、初期の人工知能分野においては、非常に簡単な問題が扱われ「人工知能」と呼ばれてきた。しかし、コンピュータの進歩により過去に扱われた問題が一般化することにより、それらの問題は「人工知能」であると呼ばれづらくなる（AI 効果）。「知能」あるいは「知的である」ことの定義自体が困難であり、しかも時代とともに変化するのである⁸。

近年流行を見せる深層学習で用いられる深層ニューラルネットワークはニューラルネットワークの 1 カテゴリであり、ニューラルネットワークは機械学習を実現する際に用いるモデルの一つである。さらに、機械学習は人工知能分野で扱われる技術の 1 カテゴリである。たとえば、エキスパートシステムなどのルールベースの手法は人工知能分野で生み出された技術であるが、機械学習とは呼ばれない。「人工知能」という語の定義の難しさや曖昧さは、ビジネス面で（ある意味で）有用であるかもしれないが、ことアカデミックな文脈では、具体的な手法群（こういう特

⁶CNN の初出は Lecun らの LeNet (LeCun et al. 1989) ではなく、福嶋らによるネオコグニトロン (Fukushima and Miyake 1982) だ、と人工知能分野の研究者らはしばしば強調する。

⁷Google Colaboratory などのサービスが無料で利用可能である。本稿を読んで興味を持った読者は、インターネットさえあれば今すぐ活用することができる。<https://colab.research.google.com/>

⁸このあたりの議論は、人工知能学会の「教養知識としての AI」を参照されると良い

https://www.ai-gakkai.or.jp/comic_no1/

徴量設計とこういうラベルで GBM を使って分類するように学習した, など) を挙げて議論されるべきであろう。よって, 以降, これまで人工知能関連の分野に関わる技術や哲学の総称として人工知能 (あるいは AI) という語を用いるが, 個々の議論においてはできる限り具体的な手法を挙げるようとする。

有効活用するにせよ, あえて使わないにせよ, 多くの分野で深層学習をはじめとした人工知能関連の技術と関わりが避けられなくなっている。その意味で, 人工知能が社会や植物科学に何をもたらしたのか (また何をもたらそうとしているのか), その到達点を知っておくことは重要であろう。以降, 本稿では特に画像解析や生命・数理科学・植物科学に関連する話題を通して「AI」の応用可能性の一端を明らかにするとともに, 今後, 植物科学分野が人工知能関連技術にどのように関わるべきかを議論する。

2. 生命科学分野における数理モデル研究と人工知能

「人工知能とは機械を使って知的に推論しようとする試みである」 (Cartwright 1993) とも言われ, その推論の方法開発は数理モデル研究と不可分であった。また, 知能という生物学的な情報処理や抽象化能力を人工的に模倣しようという人工知能研究は生命科学研究と関わりが深い。現在盛んに利用されている深層ニューラルネットワークもその名の通り神経科学的背景を持ち, 特に最初期の研究は, 膜電位のダイナミクスを記述する Hodgkin-Huxley 方程式 (Hodgkin and Huxley 1952) や FitzHugh-Nagumo 方程式 (Fitzhugh 1961; Nagumo et al. 1962) などに代表されるように神經細胞や神經回路の数理モデル的側面が強かった (McCulloch and Pitts 1943)。このように, 人工知能は数理モデルと生命科学と深く結びつきながら発展してきており, 生命科学分野でも様々な人工知能が活用してきた。第 2 章では, 第 1 章で述べた歴史を踏まえ, 数理モデルと生命科学に関わりの深い人工知能について, 「エキスパートシステム」, 「遺伝的アルゴリズム」, 「ニューラルネットワーク」の技術とともに, その応用例も含んで簡単に紹介する。

2-1. エキスパートシステム

前述の第二次 AI ブームの立役者となったエキスパートシステムは, 1970 年代に開発され, 1980 年代には商用化も行われた。専門家の知識やノウハウを人間が「もし〇〇ならば△△である」という規則でルールとして記述し, そのルールに従ってコンピュータに処理させることで問題の解決を目指すものである。特定の領域に限れば, エキスパートシステムは実用で成果を上げた初の人工知能技術といえる。科学の分野においても, 装置の運転制御, 分析手法の開発, 分子モデリング, 画像処理, ロボットによるサンプリング, 診断システムなどで広く用いられ, 一定の成果をあげている。医療分野では 1970 年代にスタンフォード大学で開発された細菌感染症診断を行うエキスパートシステムの“MYCIN”が有名な例として挙げられる (Shortliffe and Buchanan

1975)。MYCIN は、LISP 言語で記述されたかなり単純な推論（後向きの推論）エンジンと、約 600 のルールからなる知識ベースによって構築され、単純な質問を介して操作する。診断結果として、感染の可能性のある細菌のリストを確率とともに提示し、適した投薬を提案するシステムである。スタンフォード医科大学で行われた研究では、MYCIN は 65% の適切な結果を提示できた。5 人の医師による診断の適切性が 42.5% から 62.5% であったことからも、その成果は人間の専門技術に匹敵しうるとされた (Yu et al. 1979)。しかし、人工知能の誤診に対する責任を誰が負うのかという医療倫理に関する問題や、記述したルール以外の学習はできないという技術的な問題により、実用化には至らなかった。しかし、MYCIN の枠組みは、数年後に実装された E-MYCIN (非医療) がエキスパートシステムを用いる多くのアプリケーションに活用されることで第二次 AI ブームの火付け役になった。このように、知識を入力すれば入力するほど性能が向上するという長所を持ち、人工知能として素晴らしい成果を挙げたエキスパートシステムであるが、①知識を入力する専門家が不可欠、②専門家の持つ知識をすべて入力することが困難（例外や矛盾の存在）、③抽象的な記述や主観的な記述を入力することが困難、という短所が存在する。これらの短所により、エキスパートシステムによる人工知能は人間の専門家を超えない、と捉えられ、第二次 AI ブームは終息に向かっていった。

2-2. 遺伝的アルゴリズム

生命科学研究者にとって、遺伝的アルゴリズム (Genetic algorithm, GA) はなじみ深い人工知能技術の一つではなかろうか。GA は進化的アルゴリズムの一つであり、生物の進化、特に自然選択、のプロセスを模倣し近似解を探索する (Holland 1975)。GA では、ある問題の近似解は数字や文字の配列で表現され、特定の配列（遺伝子型）を持つ個体を多数用意し、解の候補（集団 population）とする。近似解の「良さ」は適応度 (fitness) として計算され、集団から適応度の高いものが優先的に選ばれ（選択 selection），配列の一部を個体間で交換する組み換え（crossover）や配列の一部をランダムに変化させる突然変異（mutation）を経て、次世代集団を作成する。この世代交代を繰り返し、より適応度の高い配列を得ることで近似解が探索できる。解を表現する配列、適応度関数、集団サイズ、選択の方法、交差の種類、突然変異率など様々な設定を検討する必要はあるものの、メタヒューリスティックな方法として多様な分野で活用されている。産業界では、ガスピライライン制御、経路最適化、ロボット制御、プログラム自動生成、工場稼動計画などで広く用いられている。中でも N700 系新幹線の先頭形状設計において、約 5000 パターンのコンピューターシミュレーションの結果、最高速度を維持しつつ乗車人数を最大化する「最適解」を導き出した例として広く知られている。生命科学分野でも、バイオインフォマティクスでの遺伝情報解析やタンパク質の構造決定、物質合成経路の最適化など様々な応用例がある。GA は可能性のある解を並行処理することによって解に至るため、解に至る経路が毎回同じとは限らない。

しかし、何世代ものシミュレーションを繰り返すことで最適解に至るため、ノイズの多いデータやピークが複数ある複雑なデータでの最適解の抽出に対し、特に優れている。その「試行錯誤する」という性質ゆえに、本稿では取り上げないが、GA によって「人工生命」を創出する試みもなされてきた。GA 法は、従来法では解を得ることが難しいほど計算スケールが大きい場合に特に有用であるため、発表当初はコンピュータの処理速度の問題から、アルゴリズムの性能が疑問視されていたが、1990 年代の劇的なコンピュータの性能向上を受けて、再評価された。アルゴリズム上の「集団の大きさ」「適応度」などの変数の決定や方式の決定（確率的余り方式やエリート方式）はユーザーが行うので、生命科学研究においても実験結果などが重要な要素となるモデルといえる。

2-3. ニューラルネットワーク

第1章で述べたように、ニューラルネットワーク（Neural Networks, NN）が第3次 AI ブームを牽引している。前述のようにニューラルネットワークは生物学の数理モデルとして少なくとも 1930 年代から研究が行われ、ノーベル生理学賞を受賞した Hodgkin-Huxley 方程式は、ニューラルネットワークが電気回路によって表現できるとした画期的なモデルであった (Hodgkin and Huxley 1952)。人工知能分野の研究で用いられるニューラルネットワークは、神経細胞を「0」か「1」の値をとるものとしてモデル化し、それをネットワークにしたものである。生物学での「ニューラルネットワーク」と区別し、「人工ニューラルネットワーク」と称される場合があるが、本稿では多くの場合に倣い、単に「ニューラルネットワーク」と呼ぶ。

ニューラルネットワークは、機械が初めて「知識を学習できる」ようになった最初期のモデルの一つでもある。形式ニューロン (McCulloch and Pitts 1943) を応用し、学習可能としたニューラルネットワークのモデルを（単純）パーセプトロン (Rosenblatt 1958) と呼ぶ。単純な構造でありながら学習によってパターン認識を行うことから、「人工知能」の実現を期待させた。しかし、パーセプトロンには①線形分離可能なデータにしか用いることができない、②特徴を人間が（ある程度）教えなければならない、③精度を高めるためには膨大な数のデータを学習する必要がある、という問題があった (松田 2017)。この問題の指摘により一時は下火になったが、1986 年、Rumelhart らによってニューロン間の結合が多層化されたことにより非線形のデータも扱えるようになり①の問題は克服された (Rumelhart et al. 1986)。これにより飛躍的に「人工知能」の研究が進むと期待されたが、当時のコンピュータの計算速度では膨大なデータ量を多層のネットワークに学習させることが困難であった。1990 年代以降にコンピュータの計算能力が劇的に向上したことで問題③は克服され、2006 年に Hinton らによってさらに多層でありながら精度が落ちない深層ニューラルネットワークが提唱され (Hinton and Salakhutdinov 2006)，自動で特徴量抽出が可能になり②の問題も解決された。その結果、近年ニューラルネットワークは再び注目を集めている。

2012 年は、特にニューラルネットワークを用いた技術が世界に衝撃を与えた年である。創薬

分野においては、Merck 社が行った Merck Molecular Activity Challengeにおいてディープラーニングを用いた手法が最高精度を達成した (Ma et al. 2014)。このチームが化合物の活性予測についての専門家でなかったことも、当時注目を集めた。また、画像認識コンペティション ImageNet Large Scale Visual Recognition Competition (ILSVRC)において、AlexNet と呼ばれる CNN を用いた手法が、それまでの画像認識のデファクトスタンダードであった SIFT + Fisher Vector + SVM というアプローチ (Sanchez and Perronnin 2011) に大差をつけて優勝（前年のエラー率 26%に対し 16%と劇的に性能向上）した。さらに 2015 年には Google や Microsoft が人のエラー率である 5%を下回る手法を提案し (He et al. 2016)，「人工知能が人間を超えた」と騒がれた。画像認識において、2012 年のもう一つの有名な出来事といえば「Google の猫」であろう。Google の「Google X Labs」は、YouTube にアップロードされている動画から、ランダムに取り出した 200×200 画素の画像を 1000 万枚用意し、9 つの層からなるネットワークを用い、1000 台のコンピュータで 3 日間かけて学習を行った。その結果、特徴量を人間が教えることなく、猫の特徴に反応するニューロンが自動的に作られた。つまり、コンピュータは猫がどういうものであるか人間に教えられること無く、自力で特徴を抽出することに成功したといえる (Le et al. 2012)。「self-taught learning（自己教示学習）」による高精度の画像認識が可能になったことで、DNN を活用した画像認識は、現在、様々な分野で盛んに活用されている。

植物科学・農学においても、第二次 AI ブーム以降からニューラルネットワークが活用されてきた。藻類における種の自動認識 (Balfoort et al. 1992)、ニューラルネットワークとエキスパートシステムを組み合わせたモルト用大麦の最適な施肥量の提案 (Broner and Comstock 1997)、Hopfield モデルや前述の多層パーセプトロンによる入力画像からの植物形状の特徴量抽出やクラス分類 (Oide and Ninomiya 1998; Oide and Ninomiya 2000) など多岐にわたる。第三次ブームの中にある現在も、他分野の例にもれず植物科学・農学分野でも、ニューラルネットワークを用いた人工知能は注目を集めている。しかし、本章で述べたように、人工知能にはニューラルネットワーク以外にもそれぞれ特徴を持った多彩なアルゴリズムがある。次章以降では、特に画像定量技術に焦点をあて、植物科学・農学での具体的な応用例（ケーススタディ）を紹介しつつ、人工知能とどう付き合っていくべきかを議論する。

3. 植物画像解析技術としての「人工知能」の活用例

3-1. 画像解析・植物フェノタイプングと「人工知能」

情報には様々な形態があるが、画像は特に多くの情報を含む形態の一つである。画像に含まれる情報を解析し、必要なものを抽出するという作業は、現象の理解において有益である。そのため、生命科学においても、多くの分野で画像解析技術がこぞって活用されている。生物の画像か

ら取り出される情報の多くは、その生物に表れる性質である「フェノタイプ（表現型）」であり、これを正確に定量し、解析することが生命現象の理解には必須である。植物科学・農学の分野において「フェノタイプ」を正確に把握することは、特に育種や栽培管理などの観点から重要である。

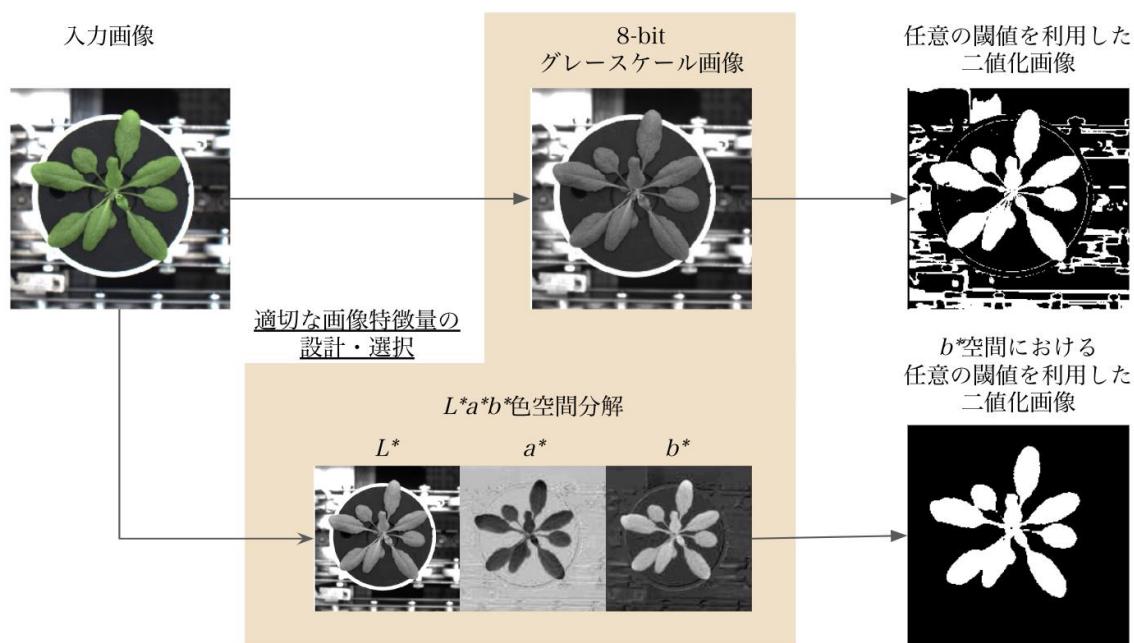
画像に何らかの処理を施し、目的とする表現型を定量的または定性的に抽出する作業は一般的に画像解析と呼ばれるが、植物科学・農学分野においては、（画像を用いるにせよ用いないにせよ）植物の表現型を計測することを「植物フェノタイピング」と称している。画像を用いたフェノタイピング作業は、撮影条件、ノイズ、陰影など様々な要因によって定量が困難を極める場合があり、多くの機器や人的リソースを投じる必要があるため、かつては個人研究者では実現が難しいように思われてきた。しかし、前章までに紹介したように、機器やコンピュータ性能の向上や、画像解析ツール、深層学習を含む機械学習ライブラリの充実により、画像を用いて複雑なフェノタイプを自動・半自動で抽出するような取り組みが広く一般的に行われるようになった。近年は草丈や植物構造などの形状解析 (Minervini et al. 2016; Watanabe et al. 2017; Isokane et al. 2018)，果実や気孔などの器官検出 (Yamamoto et al. 2014; Toda et al. 2018)，ストレス・疾病検出 (Singh et al. 2016; Ghosal et al. 2018; Mohanty et al. 2016) などをはじめとした広い分野で画像解析が用いられており、「画像解析」や「フェノタイピング」といった言葉に、「人工知能」、「AI」といった単語がまるで枕詞のように使われるほど、当該分野に浸透している。しかし、人工知能関連技術の活用の幅が急速に広まるにつれ、各技術の仕組みを正しく理解しないことによる不適切なアルゴリズム設計や、実験条件などにおける問題がしばしば見受けられる。

本節では、人工知能（特に機械学習）の活用による画像解析を用いて「植物フェノタイピング」を行う際、研究者がどのようなアルゴリズムを設計すべきかを、植物の葉面積定量をケーススタディとして議論する。ここでは、特に代表的な画像解析手法を紹介・比較しつつ、いわゆる「人工知能」システムに必要なアルゴリズム設計過程（図2）を解説しながら紹介したい。

3-2. ケーススタディ：画像解析による葉面積定量

定量性の必要なフェノタイピングにおいては、ハイスループットで再現性の高いシステムの構築が求められる。植物においても、機器や撮影技術の進歩に伴って大量の植物を自動で育成し、画像取得により植物生長の経時変化を追うためのシステムを構築する試みがなされている。理化学研究所で開発された全自動植物表現型解析システム RIPPS (Fujita et al. 2018) もその一つである。この RIPPS で被子植物シロイヌナズナを上面から撮影した画像を図 2A に示す。これを入力画像として葉面積を測定する場合、どのような方法が考えられるであろうか。既に述べたように、大量に取得された画像は多くの場合、陰影、ノイズ、微妙な撮影条件の差異などを含み、この中から如何にして必要な情報を定量的に取り出すか、が重要となってくる。以下ではこの点を主眼に置き、代表的な（かつ比較的シンプルな）画像解析の流れを解説する。

A



B

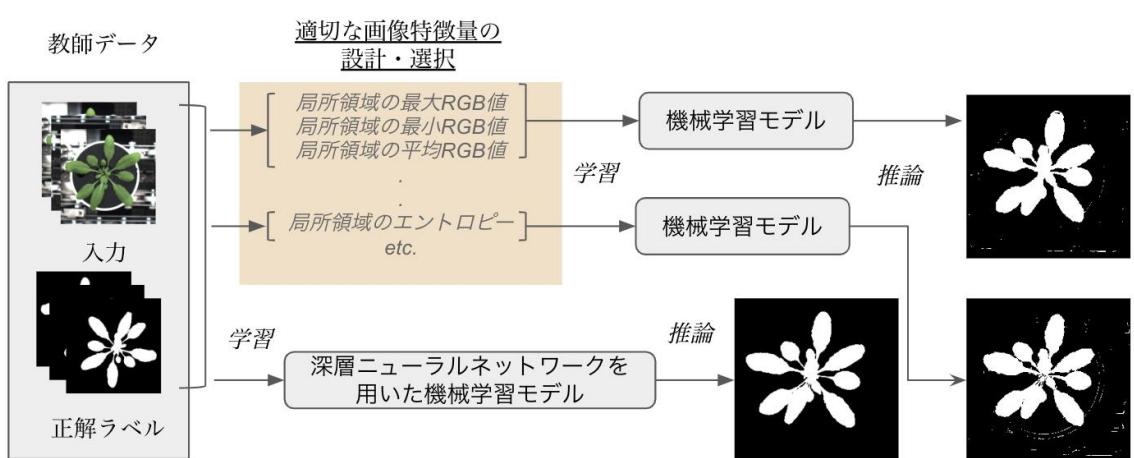


図2 シロイヌナズナの葉面積定量を実現する画像解析技術

3-2-1. 特徴量設計・選択と閾値の手動選択による手法

例えば図2Aのような入力画像をグレースケール変換(8bitに変換)すると、主に明るさの情報から構成されるデータに変換することができる。ここで、「一定の明るさの値を下回るピクセルは葉の領域、上回る領域は背景」と定義し、任意に定めた明るさの閾値に基づき、画像のフィルタリングを行うことで、葉領域のみを抽出することができる(図2A上)。これは、最もシンプルかつ伝統的な画像処理の手法であると考えられる。ここで、グレースケール変換を行う代わりに、入力画像を $L^*a^*b^*$ 色空間に分解し、画像の黄色ー青色成分を構成する b^* 空間の情報を利用する方法も考えられる(図2A下)。ここで利用した明るさ(明度)や色(色調)などのように、画像から情報抽出を行うために用いる情報を一般に特徴量と呼び、最終的に得られる情報の

精度は、利用した特徴量の種類および見出した閾値に大きく依存する。図 2A における二値化結果は、 b^* 空間を利用した方が優れているように見える。これは、今回用いた画像が背景領域に黄緑に近い色成分を含んでいないためである。この種の方法では、如何に閾値を見出しやすい条件で情報を取得できるか（この場合においては背景のノイズをいかに減らして閾値を設定しやすい画像を取得するか）も重要なとなる。適切な閾値を見出すことができれば、高速かつ明快に情報処理を行うことができるため、現在に至るまであらゆる分野で広く用いられるアプローチである。

3－2－2. 機械学習を用いた閾値選択の自動化手法

前述の手法は、人間に処理の流れが理解しやすいことが利点の一つである。他方、ほとんどの過程を人間が行うため、特に、得られた画像が均質でない（色・明るさ・ノイズなどの点で）場合、入力により異なる作業が必要となり作業量が膨大となる。また、一義的な閾値よりも複雑な判断基準により判別・分離が必要な場合、手作業による基準の決定はしばしば困難となる。作業量削減および、複雑な判別基準を見出す観点から、機械学習を用いて一部の過程を代替する方法がある。

以下、伝統的な（深層学習以前の）機械学習手法を用いて画像から葉面の領域を抽出する一例を概説する。まず入力画像とそれに対応する望む出力結果（正解ラベルと呼ぶ；この例の場合では正しい葉面の領域である）の組み合わせ、いわゆる教師データセットを用意する（図 2B）。まず、利用すべき複数の特徴量（この例の場合は局所領域の RGB 値やエントロピー値など）を適切に選択し、機械学習器（例えば SVM や GBM など）を学習させる。機械学習器は、与えられたデータセットに対して目的（本節の場合は葉面の領域抽出）を達成するための適切な閾値、さらには特徴量の重み付けを行うことが可能となるので、教師データセット以外の画像に対しても、葉面の領域を抽出できるようになる（図 2B 上段）。画像解析に用いるのに適した特徴量やモデルに関しては、現在までに多様な画像特徴量と機械学習モデルが提唱されており、それぞれの特徴を理解して、それらを組み合わせることで、画像解析効率が格段に上昇し、利用可能な画像の種類も増加した。

3－2－3. 深層学習を用いた特徴量設計・閾値選択の自動化手法

前章まででも述べた通り、深層学習も機械学習の一種であるが、前節の方法との大きな違いとして、画像解析における応用を考えると、人間が特徴量を設計しなくても良い場面が多くなることが挙げられる。前節の方法では、「葉面積定量を行うためには緑成分が重要かもしれない」というような観点の下、局所領域の RGB 値やエントロピー値を特徴量に選んでいたが、深層学習では、深層学習の過程でニューラルネットワークモデルが能動的に最適な特徴量を学習するような設計が可能である。少し乱暴な言い方をすれば、教師データセットと深層学習のモデルを用意すれば、目的とする一連の過程を一挙に達成する（end-to-end などと呼ばれる）ことが可能と

なる。その極めて高い利便性から、近年多くの研究者が自身の課題を解決するために深層学習を導入しつつあり、近年「人工知能を活用した」画像解析はこのような「深層学習を利用した」画像解析のことを指すことが多い。

3－3. 植物画像解析における「人工知能」をもう一度考える

そもそも画像解析における人工知能とはなんなのか、ここでもう一度考えてみたい。前章まで述べてきたとおり、また、前章までも場合によって表現が異なることからもわかるように、その言葉の定義は極めて曖昧である。本章でもう一度、分野を限って表現するならば、人工知能とは、「人間が従来行ってきた解析作業を大なり小なり代替してくれるアルゴリズム、パイプライン、またはソフトウェア」であると考える。つまり、技術の新旧を問わず、画像解析に携わってきた研究者はブームの前からずっと、人工知能を使い続けてきたのである。繰り返し述べたように、近年注目されている深層学習とは、機械学習の一部であり、「人工知能」のほんの一部である。

近年、多くのシチュエーションで「人工知能」を構成する中心要素として深層学習を利用することができてきた。例えば「圃場中の作物の穂の計測」や「作物の病害虫診断」など、およそ人が設計する特徴量では対応できないような複雑な課題には極めて有効である。しかしながらまだ多くの画像解析タスクでは深層学習を必ずしも使う必要の無いことが多い。図2に示した葉の面積定量なども $L*a*b*$ 空間の利用が適切である場合もある。第2章でも述べたが、各々の「人工知能」には適した使い方がある。各々の特徴を理解し、適切な「人工知能」を最適な方法で利用することが肝要であろう。

また、深層学習特有の問題も多く残る。前章まで述べた開発の歴史を踏まえても、深層学習にはネットワークパラメーターの最適化や、適切なネットワーク構造を選ぶことなどが必要である。このために、実際にはユーザーが必要と予想される特徴量を事前にある程度把握して目的設定を行う必要がある。また、深層学習を行うために必要な教師データ（枚数）は従来の機械学習の手法と比べ数十倍から数百倍必要とされている。これについては、半教師あり/教師なし学習や、転移学習（transfer learning）、データ拡張（data augmentation）など様々なアプローチで改善しつつあるもの、未だ多くの場合にデータの収集やアノテーションが問題となる。また、計算速度の速いコンピュータを用いても、学習にかかる時間が長く、他の手法のほうが効率的である場合も多い。深層学習を中心とした「人工知能」ブームに惑わされず、適切な技術を組み合わせて解析していくのが効率的な結果の取得には重要である。次章では、本章までの内容を踏まえて、我々研究者はどのように「人工知能」と付き合っていくべきか、考えたい。

4. 「人工知能」に振り回されないために

人工知能関連の技術、とりわけ近年は深層学習が容易に使用できるようになり、植物科学をはじめとする様々な分野において応用されている。一方、近視眼的に流行に乗って「とりあえず深層学習を使う」ことや、「AI を使えばなんでもできるんでしょう？」などの発想が増えていることは否めない。また、近年の機械学習手法の仕組みを正しく理解しないことによる過度の恐怖が蔓延していることも事実である。本節では、「AI ブーム」に振り回されず、次世代の植物科学を創っていくためにはどのようなことが必要か、近年の（第3次）AI ブームの中核をなす深層学習によくある問題を踏まえて議論する。

4-1. 深層学習の実際

議論の前提として、深層学習が実際にを行うことを（ネットワーク的な図を使わずに⁹）まとめておく。機械学習の定義に則って説明するなら、深層学習は「たくさんの、かつ高次元（画像など）のデータ集合（学習データ）を入力」し、「事前に設定された評価尺度」を改善するように「（深層ニューラルネットワークで表現された）ものすごく高次元の関数」で近似するように学習するものであるといえる（この学習過程を、学習フェーズと呼ぶ）。学習フェーズで得られたモデルを用いて、任意の新たな入力（テストデータ）に対し、所望の出力に（上記評価尺度の基準で）近い結果を得ること（テストフェーズ、と呼ばれる）が、深層学習の目的である。基本的には、これまでの機械学習（極端に言えば線形回帰分析も含む）の延長線上の技術である¹⁰ため、実装は一般化したとはいえ、一步間違えると科学的に正しくない結果や、本来の意図と異なる結果・結論を導きやすいことに注意が必要である。

4-2. 深層学習（あるいは機械学習一般）活用時に直面する問題

ここでは、深層学習（あるいは機械学習一般）活用時に直面する問題について、主要な（？）2点を挙げて議論する。

4-2-1. ブラックボックス性

深層学習が「ブラックボックス」である、という議論が多くなされている。機械学習は、入力データに対応して所望の出力（分類結果など）を得るようにモデルを最適化する。ここで、モ

⁹ モデルがネットワーク状の構造をなすか否かは、ここでは本質ではない。

¹⁰ そのため、現時点で（あるいは近い将来）、AI が意思を持って人類を滅ぼしたり反乱を起こしたりすることはない。深層学習は人間の設計した評価尺度を改善するモデルを推定する最適化器にすぎない。より心配すべきは、人類自身が技術を悪用し、人類を滅ぼす可能性であろう。

モデルが複雑であればあるほど、出力が得られたプロセス（なぜうまくいくのか・うまくいかないのかの判断根拠）を知ることは難しくなる。特に、深層学習は、適切に用いると他の機械学習手法より所望の出力に近い結果を得ることができることが多い一方、非常に多くの（数百万～数億にもなる）パラメータを持つモデルを用いるため、人間が判断根拠を知ることが困難になる。すると、最適化されたモデルを用いて科学的なアプローチで結果を議論することが難しくなり、特に基礎科学や医療応用の分野において深層学習の活用を敬遠する一因となっている。これに対し、近年は深層学習（など）の判断根拠や付随する情報を可視化する説明可能AI（Explainable AI; XAI）という枠組みに関する研究が盛んに行われている。特に、入力のどの部分に注目して判断が行われたかを可視化する GradCAM (Selvaraju et al. 2017) 等の手法や、ネットワーク中の各々のニューロンがどのようなパターンに強く反応するかを可視化する手法 (Olah et al. 2018) が広く使われる¹¹。植物の疾病判別の可視化を対象とした可視化手法の比較研究 (Toda and Okura 2019) も行われており、興味を持った読者は参考にされたい。

4－2－2. バイアス・過学習・データリーク

深層学習（を含む機械学習一般）は本質的に、学習データに含まれる傾向（バイアス・偏り）を判断根拠として抽出し、学習するものである。もし、使用者が意図しない、学習データに特有の傾向が含まれる場合、これらがタスク（分類や回帰など）の判断根拠に含まれることがある。すると、学習済みモデルを他の環境で適用する場合にうまく働くなくなる（＝汎化性が失われる）。このような問題は、文脈により学習データに含まれるバイアス、あるいは過学習（過剰適合）、データリークなどと絡めて議論される。最近は、大手 IT 企業の機械学習を用いたシステムに含まれる差別的なバイアス（学習データ自体にそのようなバイアスが含まれるため、男性を女性より優遇する採用提案システムができた、など）の話題を通じて、一般的に広く知られるようになった。実際、汎化性を毀損するような、使用者の意図しない傾向を判断根拠としてしまう例は数多くある。以下に架空の例を挙げて説明する。これらに類似するケースは様々な場面で発生するため、植物科学分野においても注意が必要であろう。

ケース 1：疾病検出 葉の疾病検出を行うシステムを構築するため、葉の疾病を含む画像を全世界の様々な圃場から収集したが、逆に、正常な葉の画像は持ち合わせていない。そこで、身近な圃場で正常な葉を撮影し、これらを学習データに含めて、疾病かどうかを判別するよう学習した。この場合、もしかすると機械学習モデルは、実際は背景に写った圃場の風景の違い（ある特定の「身近な圃場」かそうでないか）など、撮影設定に特有の特徴を学習している可能性がある。

¹¹ 以下に、直感的なデモを含む解説記事がある。<https://distill.pub/2018/building-blocks/>

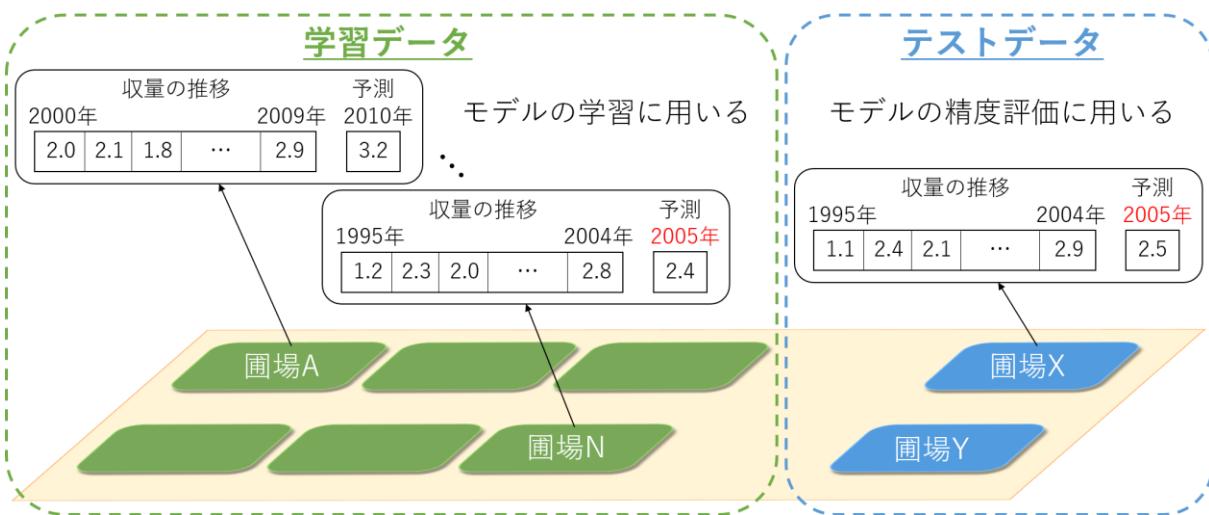


図 3 データリークにより、不当に高い精度が出やすい例（収量予測）：
同一年度の（類似した）データ系列が学習・テスト双方に含まれる。

ケース 2：収量予測 様々な圃場で長期間収集した環境情報・収量の時系列データを使い、収量予測モデルを作りたい（図 3）。例えば、推定対象年度より前 9 年分の環境情報と収量の推移、および推定対象年度の部分的な環境情報から、推定対象年度の収量を予測するようなモデルを学習することを考える。ここで、圃場 A～N の収量・環境情報の推移を学習データ、圃場 X～Y のものをテスト用のデータとし、推定対象年度はランダムに選択した。この場合、異なる圃場の同一年度のデータが学習・テスト双方に含まれ得る。つまり、（もしそれらの圃場が似たような環境にあるならば）テストデータとほとんど同じ系列が学習データに含まれるため、見かけ上高い精度を達成できるだろう。しかし、学習されたモデルは、未知の年度を対象とした予測には使えないものになっているかもしれない。

ケース 3：ハイパーパラメータの設定 機械学習には、学習に際して使用者が決めるべきパラメータ（ハイパーパラメータ）がたくさんある。例えば、深層学習においては学習の繰り返し数（エポック数）などが挙げられる。これらを決めるために、ハイパーパラメータを変えて学習を繰り返し、テストデータで評価尺度が最も改善されるものを採用することがあるが、特定のテストデータにのみ有効なモデルとなる可能性が高く、悪手である。ハイパーパラメータを決める必要があるなら、学習・テストいずれにも使われないデータ（validation データなどと呼ぶ）を使うべきである。機械学習と関わりの深い分野の論文でさえ、このようなミスはしばしば見られる。

ケース 4：手法の選定 多くの場合見逃されることが多いが、本来厳密に言うと、そもそも同じデータセットを使いまわして手法の検討を続けること自体、汎化性を毀損する可能性をはらんでいる。研究に使ったデータセットのみに有効な手法が選ばれる可能性が高くなるからである。本来、可能な限りバリエーションの異なる環境で取得されたデータセット、あるいは環境の異なる

複数のデータセットを使うべきであるが、データ収集の制約から、実際は難しいことが多い。

以上のように、機械学習において汎化性能があがらないことは永遠の課題であり、機械学習を専門とする分野の論文であっても、再現性の低さ、異なるデータセットにおける精度の低下（汎化性の低さ）が度々議論される。機械学習がうまく行えるのは、基本的に「モデルのパラメータを作る空間に分布するデータ点」の内挿である。学習データの分布に含まれない¹²ような入力に対するモデルの出力はあてにならない。つまり、機械学習を用いる場合は常に、「そのデータセット（あるいは検証方法）を使った場合、実際に活用したい場面で通用する（=汎化する）モデルを学習できるのかどうか」を、データ取得の計画段階から慎重に考え続けることが重要である。様々な落とし穴があるため、「とりあえず」深層学習を適用し、驚くほど良い精度が出たとしても、その結果を鵜呑みにしてはならず、深く考察することを心がけたい。特に、データ取得や実装、実験設定が適切か、今一度確認することが重要であろう。あるいは、上述のような可視化手法を用いることで、意図しない部分に着目するようなモデルが学習されていないかどうかを（ある程度）確認することができる。

4－3. 「人工知能」時代の植物科学

深層学習は、非常にパワフルかつ参入障壁の低い技術であり、機械学習の専門知識を持たずして、利用することができる。そして、これこそが現在の AI ブームの礎をなす。であるからこそ、植物科学は「AI」ブームに踊らされず、あくまで植物科学を発展させるべく、効果的に活用していくことが（あるいはあえて活用しないことも）必要であろう。

深層学習は、植物科学、なかでも植物フェノタイピングや遺伝子解析などにおいて強力なツールとなる。たとえば CRISPR を用いたゲノム編集が遺伝子解析の自由度を劇的に向上するツールであるように、深層学習をはじめとした技術群は、植物科学におけるデータ解析を効率化し、かつ人間にも見つけられないような特徴を抽出することを可能とするかもしれない。幸い、近年は初学者でも簡単に深層学習（あるいは他の機械学習も）を使い始める事ができるため、必要に応じて、身近な問題から取り入れていくことができるだろう。

一方、上述のように機械学習（深層学習はとくに）には、ある意味でのブラックボックス性があることに注意したい。生理的・物理的・数学的にルールが自明であるタスクについて、機械学習的アプローチを取ることは、基本的にはおすすめできない¹³。特に解釈性が重視されるべき基礎科学分野において、ルールが既知である部分を、ブラックボックスに置き換えることには問題

¹² 一方、モデルのパラメータを作る高次元空間は人間に理解し難いため、何をもって「学習データの分布に含まれない」とするかは、非常に難しい議論である。

¹³ 工学的な目的においては、ルールが自明な対象であっても、高速に推論できる深層学習の適用を選択することがある。

がある。近年、「AI」を使ったこと自体をアピールする研究や製品が数多く見られるが、「AI」を使うこと自体は、（技術的な）アドバンテージにはならない。深層学習（あるいは機械学習一般）はあくまでツールであり、実現したいことに適した手法を（それが「AI」と呼べるかどうかに関わらず）選択することこそが重要である。

「AIが仕事を奪う」という言説がある¹⁴。この真偽についてここでは議論しないが、科学研究の分野において、専門知識を持った研究者の重要性は、「AI時代」においてより高まることが予想される。深層学習の解釈性の向上について、XAIなどの研究がなされているものの、それらが行うのはあくまでモデルが注目した領域の可視化などにとどまる。モデルが学習した特徴の学術的（植物学的）な意味合いを説明し得るのは、専門知識を持った研究者である。今後、深層学習により、人間にはこれまで見つけられなかつた詳細な特徴が（人間には理解し難い高次元のパラメータ空間内で）得られるかもしれない。しかし、これを植物科学に還元するためには、これらの特徴の可視化等を通じて、植物科学的な考察を付与できる研究者こそが欠かせないのである。

機械学習はデータに基づく最適化を行うものである。人工知能関連の技術の中で、人間が持つ知識（ヒューリスティクス）を扱う技術はエキスパートシステムなどのルールベースの手法に強みがある。近い将来、機械学習ベースの手法も、ヒューリスティクスを積極的に活用するような方向に進むべきであろう。例えば、「植物の発生ルール」を深層学習による植物の構造推定を行うモデルに組み込むことは、現時点では容易ではない。その点において、基礎科学分野における専門性は、AI分野における新たな手法の構築にも寄与し得る。

「AI時代」のいまこそ、植物科学研究者、および当分野に長年蓄積されてきた知識が重要である。「AI」に振り回され、植物科学を捨ててはならない。人工知能分野とともに歩んできた植物科学分野は、これからも人工知能分野とともに歩んでゆく。人工知能分野の劇的な進展を、植物科学の発展に活かすような使い方をすること（あるいはあえて活かさないことを選択すること）が最も重要である。

4-4. やりたくなった・勉強したくなつた

本稿を読んで、機械学習・深層学習に興味を持った読者は、ぜひ触ってみることをお勧めする。多くのライブラリがPythonで記述されており、最新の深層学習手法（モデル）の多くは実装が公開されているため、ツールとしての活用が比較的容易である。ここ数年、特に深層学習の研究は日進月歩どころか秒進分歩で進んでいるため、本稿では特定の手法を紹介することはしない（本稿が掲載される頃には陳腐化しているかもしれない）。代わりに、ここでは学習に活用できるリソースをいくつか紹介する。

¹⁴著者の一人は、もし本当にAIが仕事を奪ってくれるなら奪ってほしい、悠々自適に暮らしたい、と考える。しかし現実には、研究者の仕事は増える一方である。

深層学習の初心者向けチュートリアルを含む記事は、インターネット上に多く存在する。一方、それらの多くが MNIST と呼ばれる文字認識データセットを用いたものであり、植物科学分野の研究者にとっては馴染みが薄く、応用との隔たりがある。本稿著者の戸田が制作した生物学者のための深層学習チュートリアル¹⁵では、深層学習の基礎的な活用方法を、植物を題材として進めることができる。比較的可読性の高い深層学習ライブラリである Keras と、オンラインでコードを実行できる環境である Google Colaboratory を用い、実行しながら学習をすすめることができる。深層学習に関するモデルは、日々より良いものが提案されており、専門家でも追いかけることが難しくなっている。Paper with Code¹⁶では、タスクごとに各種モデルの精度をランク化している。これから挑戦するタスクに近いランキングを参照し、手法選択の参考とすることができる。

機械学習・深層学習の技術解説については、インターネット上に非常に多くのリソースがあり、特定のライブラリに特化した実装方法についても、インターネット・書籍ともに多数存在する。そのため、ツールとして機械学習・深層学習を使うための情報には事欠かない時代となった。一方、実装に特化しない、体系化された理論を学習したい場合には、以下のような本が多くの大学や研究室で講義・輪講の題材に挙げられているようである。ただし、いずれの本も、読みすすめるためには基礎的な解析・線形代数・統計の知識が必要である。

深層学習関連

- 導入編：ゼロから作る Deep Learning—Python で学ぶディープラーニングの理論と実装 (斎藤 2016)
- 学部レベル：深層学習（機械学習プロフェッショナルシリーズ）(岡谷 2015)
- 大学院レベル：深層学習（原題：Deep Learning）(Goodfellow et al. 2016)

機械学習一般

- 学部・大学院レベル：はじめてのパターン認識（通称：はじパタ）(平井 2012)
- 学部・大学院レベル：わかりやすいパターン認識（通称：わかパタ）(石井 et al. 2019) 続・わかりやすいパターン認識(石井 and 上田 2014)
- 研究者レベル：パターン認識と機械学習（原題：Pattern Recognition and Machine Learning, 通称 PRML）(Bishop 2006)

謝辞

本総説で紹介した研究の一部は、JST さきがけ「情報科学との協働による革新的な農産物栽培手法を実現するための技術基盤の創出」JPMJPR17O5（戸田），JPMJPR17O3（大倉），

¹⁵ https://github.com/totti0223/deep_learning_for_biologists_with_keras

¹⁶ <https://paperswithcode.com/sota>

JPMJPR16O5 (野下) および、JSPS 若手研究 19K16163 (水谷) の支援を得て遂行した。

参考文献

- Bishop, C.M. 2006. Pattern Recognition And Machine Learning. New York: Springer.
- Breiman, L. 2001. Random Forests. Springer Science and Business Media LLC.
- Broner, I., & Comstock, C.R. 1997. Combining expert systems and neural networks for learning site-specific conditions. *Computers and Electronics in Agriculture* 19(1), pp. 37–53.
- Buchanan, B.G., & Feigenbaum, E.A. 1981. Dendral and Meta-Dendral. In: *Readings in Artificial Intelligence*. Elsevier, pp. 313–322.
- Cartwright, H.M. 1993. Applications Of Artificial Intelligence In Chemistry. Oxford: Oxford University Press.
- Chen, T., & Guestrin, C. 2016. XGBoost: A Scalable Tree Boosting System. In: *Proceedings of ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD)*, pp. 785–794.
- Crevier, D. ed. 1993. AI: The tumultuous history of the search for artificial intelligence, Basic Books.
- Fitzhugh, R. 1961. Impulses and Physiological States in Theoretical Models of Nerve Membrane. *Biophysical Journal* 1(6), pp. 445–466.
- Fujita, M., Tanabata, T., Urano, K., Kikuchi, S., & Shinozaki, K. 2018. RIPPS: A Plant Phenotyping System for Quantitative Evaluation of Growth under Controlled Environmental Stress Conditions. *Plant & Cell Physiology* 59(10), pp. 2030–2038.
- Fukushima, K., & Miyake, S. 1982. Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. In: Amari, S. and Arbib, M. A. eds. *Competition and Cooperation in Neural Nets*. Lecture notes in biomathematics. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 267–285.
- Ghosal, S., Blystone, D., Singh, A.K., Ganapathysubramanian, B., Singh, A., & Sarkar, S. 2018. An explainable deep machine vision framework for plant stress phenotyping. *Proceedings of the National Academy of Sciences of the United States of America* 115(18), pp. 4613–4618.
- Goodfellow, I., Bengio, Y., & Courville, A. 2016. Deep Learning. The MIT Press.
- He, K., Zhang, X., Ren, S., & Sun, J. 2016. Deep residual learning for image recognition. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, pp. 770–778.
- Hinton, G.E., & Salakhutdinov, R.R. 2006. Reducing the dimensionality of data with neural networks. *Science* 313(5786), pp. 504–507.

平井有三 2012. はじめてのパターン認識, 森北出版.

Hodgkin, A.L. & Huxley, A.F. 1952. A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of Physiology* 117(4), pp. 500–544.

Holland, J.H. 1975. Adaptation In Natural And Artificial Systems: An Introductory Analysis With Applications To Biology, Control, And Artificial Intelligence. U Michigan Press.

石井健一郎 & 上田修功 2014. 続・わかりやすいパターン認識—教師なし学習入門—, オーム社.

石井健一郎, 上田修功, 前田英作 & 村瀬洋 2019. わかりやすいパターン認識(第2版), オーム社.

Isokane, T., Okura, F., Ide, A., Matsushita, Y. & Yagi, Y. 2018. Probabilistic Plant Modeling via Multi-view Image-to-Image Translation. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2906–2915.

Ke, G., Meng, Q., Finley, T., et al. 2017. Lightgbm: A highly efficient gradient boosting decision tree. In: *Proceedings of Advances in Neural Information Processing Systems (NeurIPS)*. pp. 3146–3154.

Krizhevsky, A., Sutskever, I. & Hinton, G.E. 2017. AlexNet 2012 ImageNet classification with deep convolutional neural networks. *Communications of the ACM* 60(6), pp. 84–90.

LeCun, Y., Boser, B., Denker, J.S., et al. 1989. Backpropagation applied to handwritten zip code recognition. *Neural Computation* 1(4), pp. 541–551.

Le, Q.V., Ranzato, M., Monga, R., et al. 2012. Building high-level features using large scale unsupervised learning. In: *Proceedings of International Conference on Machine Learning (ICML)*.

Ma, J., Sheridan, R. P., Liaw, A., Dahl, G. E. and Svetnik, V. 2014. Deep neural nets as a method for quantitative structure-activity relationships. *J. Chem. Inf. Model* 55(2), pp. 263–274.

Mackay, D.J.C. 2003. Information Theory, Inference And Learning Algorithms. 1st ed. Cambridge, UK: Cambridge University Press.

McCarthy, J., Minsky, M.L., Rochester, N. and Shannon, C.E. 2006. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine* 27(4).

McCulloch, W.S. & Pitts, W. 1943. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics* 5(4), pp. 115–133.

Minervini, M., Fischbach, A., Scharr, H. & Tsafaris, S.A. 2016. Finely-grained annotated datasets for image-based plant phenotyping. *Pattern Recognition Letters* 81, pp. 80–89.

Mohanty, S.P., Hughes, D.P. & Salathé, M. 2016. Using deep learning for image-based plant disease detection. *Frontiers in Plant Science* 7, p. 1419.

- Nagumo, J., Arimoto, S. & Yoshizawa, S. 1962. An active pulse transmission line simulating nerve axon. *Proceedings of the IRE* 50(10), pp. 2061–2070.
- Oide, M. & Ninomiya, S. 2000. Discrimination of soybean leaflet shape by neural networks with image input. *Computers and Electronics in Agriculture* 29(1–2), pp. 59–72.
- Oide, M. & Ninomiya, S. 1998. Evaluation of Soybean Plant Shape by Multilayer Perceptron with Direct Image Input. *Ikushugaku Zasshi* 48(3), pp. 257–262.
- 岡谷貴之 2015. 深層学習 (機械学習プロフェッショナルシリーズ), 講談社.
- Olah, C., Satyanarayan, A., Johnson, I., et al. 2018. The building blocks of interpretability. *Distill* 3(3).
- Rosenblatt, F. 1958. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review* 65(6), pp. 386–408.
- Rumelhart, D.E., Hinton, G.E. & Williams, R.J. 1986. Learning representations by back-propagating errors. *Nature* 323(6088), pp. 533–536.
- 斎藤康毅 2016. ゼロから作る Deep Learning—Pythonで学ぶディープラーニングの理論と実装, オライリージャパン.
- Sanchez, J. & Perronnin, F. 2011. High-dimensional signature compression for large-scale image classification. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1665–1672.
- Selvaraju, R.R., Cogswell, M., Das, A., Vedantam, R., Parikh, D. & Batra, D. 2017. Grad-CAM: Visual explanations from deep networks via gradient-based localization. In: *Proceedings of IEEE International Conference on Computer Vision (ICCV)*. IEEE, pp. 618–626.
- Shortliffe, E.H. & Buchanan, B.G. 1975. A model of inexact reasoning in medicine. *Mathematical Biosciences* 23(3–4), pp. 351–379.
- Singh, A., Ganapathysubramanian, B., Singh, A.K. & Sarkar, S. 2016. Machine learning for high-throughput stress phenotyping in plants. *Trends in Plant Science* 21(2), pp. 110–124.
- Suykens, J.A. & Vandewalle, J. 1999. Least squares support vector machine classifiers. *Neural Processing Letters* 9(3), pp. 293–300.
- Toda, Y. & Okura, F. 2019. How convolutional neural networks diagnose plant disease. *Plant Phenomics*, Article ID 9237136.
- Toda, Y., Toh, S., Bourdais, G., Robatzek, S., Maclean, D. & Kinoshita, T. 2018. Deepstomata: facial recognition technology for automated stomatal aperture measurement. *BioRxiv* 365098.
- Turing, A.M. 1950. Computing machinery and intelligence. *Mind* 49, pp. 433–460.

Watanabe, K., Guo, W., Arai, K., et al. 2017. High-Throughput Phenotyping of Sorghum Plant Height Using an Unmanned Aerial Vehicle and Its Application to Genomic Prediction Modeling. *Frontiers in Plant Science* 8, p. 421.

Yamamoto, K., Guo, W., Yoshioka, Y. & Ninomiya, S. 2014. On plant detection of intact tomato fruits using image analysis and machine learning methods. *Sensors* 14(7), pp. 12191–12206.

Yu, V.L., Buchanan, B.G., Shortliffe, E.H., et al. 1979. Evaluating the performance of a computer-based consultant. *Computer Programs in Biomedicine* 9(1), pp. 95–102.