

# 国立国会図書館 調査及び立法考査局

Research and Legislative Reference Bureau  
National Diet Library

論題 Title	第2章 ロボティクス、AI の発展
他言語論題 Title in other language	Chapter 2 The Evolution of Robotics and AI
著者 / 所属 Author(s)	湯口 彰重 (YUGUCHI Akishige) / 東京理科大学先進工学部助教、早川 智彦 (HAYAKAWA Tomohiko) / 東京理科大学研究推進機構総合研究院准教授、橋本 卓弥 (HASHIMOTO Takuya) / 東京理科大学工学部准教授
書名 Title of Book	AI時代のロボティクス 科学技術に関する調査プロジェクト報告書
シリーズ Series	調査資料 2025-6 (Research Materials 2025-6)
編集 Editor	国立国会図書館 調査及び立法考査局
発行 Publisher	国立国会図書館
刊行日 Issue Date	2026-3-17
ページ Pages	3-25
ISBN	978-4-87582-954-6
本文の言語 Language	日本語 (Japanese)
摘要 Abstract	ロボティクスと人工知能の発展の歴史をたどり、両者がどのように結びついて現在の AI ロボットに至ったのかを説明する。

\* この記事は、調査及び立法考査局内において、国政審議に係る有用性、記述の中立性、客観性及び正確性、論旨の明晰（めいせき）性等の観点からの審査を経たものです。

\* 本文中の意見にわたる部分は、筆者の個人的見解です。

## 第2章 ロボティクス、AIの発展

### 【要旨】

本章では、ロボティクスと人工知能（AI）の発展の歴史をたどり、両者がどのように結びついて現在のAIロボットに至ったのかを説明する。ロボットとAIはそれぞれ別の起源を持ちながら、互いに影響を与え合い、人と協働できる知能的なシステムへと進化してきた。技術の進歩だけでなく、社会や産業の変化もその背景にある。

1950～1970年代の産業用ロボットの誕生を発端に、アメリカのユニメーション社による「ユニメイト」は、世界初の産業用ロボットとして自動車工場に導入され、溶接や塗装などの危険・単調作業を担った。日本でも1970年代に産業ロボットが急速に普及し、現在の製造業の自動化基盤を築いた。この時代のロボットは、人間の操作を忠実に再現する「教示再生型」であり、自ら判断することはできなかった。

1980～2000年代では、AI研究とロボット技術の融合を概観でき、ニューラルネットワークや強化学習の研究が進み、ロボットが環境を「見る」「聞く」「判断する」ための基礎技術が整った。例えば、画像認識や経路計画のアルゴリズムが登場し、ロボットはより複雑な作業や動作選択を行えるようになった。この頃には「自律移動ロボット」や「家庭用ロボット」の試作も始まり、研究レベルから社会応用への転換期を迎えた。

2010年代以降では、深層学習（ディープラーニング）においてブレイクスルーが起き、2012年の画像認識大会でAIが人間を上回る精度を示したことを契機に、上記のロボットの「見る力」「聞く力」「判断する力」は飛躍的に向上し、自動運転車、清掃ロボット、音声アシスタントなど、AIが日常生活の中に浸透していくきっかけとなった。

以上より、ロボット技術とAIが別々の発展を経ながらも互いに補い合い、今日の智能化社会を支える柱となったことが示された。

### I 伝統的なロボティクスの発展（機械制御・自動化）

ロボット技術の黎明期は、オートマタと呼ばれる自動機械や遠隔操作技術に端を発する。特に第二次世界大戦後、放射性物質を扱うために米国アルゴンヌ国立研究所で開発されたマスタースレーブ型マニピュレータ（主操作装置と従属アームによる遠隔操作機械）は、現在の産業用ロボットの原型の一つとされている<sup>(1)</sup>。1950年代には米国でジョージ・デヴォル（George Charles Devol, Jr.）がプログラム可能な機械制御装置を発明し、実業家エンゲルバーガー（Joseph Engelberger）との共同によって世界初の産業用ロボット企業ユニメーション社（Unimation Inc.）が設立された。その成果として1961年頃に工場へ導入された「ユニメイト（Unimate）」は、世界初の実用的産業用ロボットとされる<sup>(2)</sup>。ユニメイトは溶接作業などの単調かつ危険な工程を自動化し、人間に代わって遂行するもので、これ以降ロボットは製造業の自動化・省力化技術の中心的存在となってきた。

1970年代から1980年代にかけて、日本を始め各国で産業用ロボットの開発・導入が急速に

\* 本稿におけるインターネット情報の最終アクセス日は2026（令和8）年2月17日である。

(1) 小菅一弘「ロボット制御の理論とシステムインテグレーション」『日本ロボット学会誌』27(4), 2009.5, pp.375-377. <[https://www.jstage.jst.go.jp/article/jrsj/27/4/27\\_4\\_375/\\_pdf](https://www.jstage.jst.go.jp/article/jrsj/27/4/27_4_375/_pdf)>

(2) 「米国での産業用ロボット誕生から日本上陸まで」Kawasaki Robotics website <[https://robotics.kawasaki.com/ja1/anniversary/history/history\\_01.html](https://robotics.kawasaki.com/ja1/anniversary/history/history_01.html)>

進展した。日本では1970年代後半に川崎重工業株式会社がユニメーション社との技術提携でロボット生産を開始し、1980年は「ロボット元年」と呼ばれるほど産業用ロボットが注目を集めた。産業用ロボットは多関節のアーム型が主流で、自動車産業などで溶接・塗装・組立といった繰り返し動作を高速・高精度に行い生産性を飛躍的に高めた。これら従来型ロボットは基本的にティーチング（教示）によって動作パターンを記憶させ、そのとおりに再生する「プログラム可能な機械」として動作する。センサやコンピュータの発達に伴い細かな改良や性能向上は遂げてきたものの、その本質的な制御原理は黎明期から大きく変わっていない。すなわち、あらかじめ与えられた軌道や動作を高い再現性で実行するという点で、「機械制御・自動化」の枠組みに立脚した技術といえる。

一方で、ロボット研究には古くからもう一つの流れ、すなわち人間型の自動機械（アンドロイドと呼ばれる。）への憧れも存在したため、研究が続けられた。ギリシャ神話のタロスや中世のからくり人形に見られるように、人間や動物を模した自動機械は長らく夢物語だったが、精密機械工学の発達とともに一部は実現に近づいた。しかし実用化された産業用ロボットと、人間のようにふるまうロボットとの間の隔たりは依然大きく、前者は実利的な工場における自動化装置、後者は家庭や福祉など人と接するサービス分野における活用が模索されてきた。こうした背景を受け、20世紀後半のロボティクスは現実の産業ニーズに応える自動化技術としての発展が中心であり、後述する、様々なブレイクスルーを経て処理能力が革新されていたものの、自然言語処理能力やリアルタイム性の不足によりAIとの結びつきは限定的だった。当時のロボットは外界の状況を自ら認識・判断する能力は乏しく、センサ情報に基づく簡単なフィードバック制御は行うものの、基本的には人間がプログラムした手順どおり動く装置だったため、家庭や福祉の現場で用いるには対話能力が不足していた。

従来の産業用ロボット技術は労働生産性の向上や危険作業の自動化に大きく貢献し、現在では世界中の工場で数百万台規模のロボットが稼働するに至っている。国際ロボット連盟（IFR）の統計によれば、2010年代以降も年率二桁台で稼働台数が増加しており、2023年時点で世界の工場では428万台以上の産業用ロボットが稼働している。特に近年は中国や韓国を中心に導入が加速し、アジア地域が新規ロボット設置の過半を占めている<sup>(3)</sup>。このように「機械制御・自動化」の時代から培われたロボット技術は、生産現場に深く浸透し社会基盤の一部となった。一方で、従来型ロボットは囲いの中で人から隔離して使われるのが常であり、人と直接協働する存在ではなかった。21世紀に入りAI技術やセンサ技術が進歩すると、ロボットにも自律的な環境認識や判断能力を持たせ、人と柔軟に協働できるようにする試みが本格化する。

## II AIの進化（機械学習・ディープラーニングの進歩）

AIとは、人間の知的能力、例えば言語の理解、推論、学習、問題解決、認識、意思決定などを、コンピュータによって模倣・実現しようとする技術及び学問分野である。AIは1950年代から研究が始まり、近年では自然言語処理、画像認識、音声認識、自動運転、ロボティクスなど、幅広い応用分野で社会的影響力を強めている。

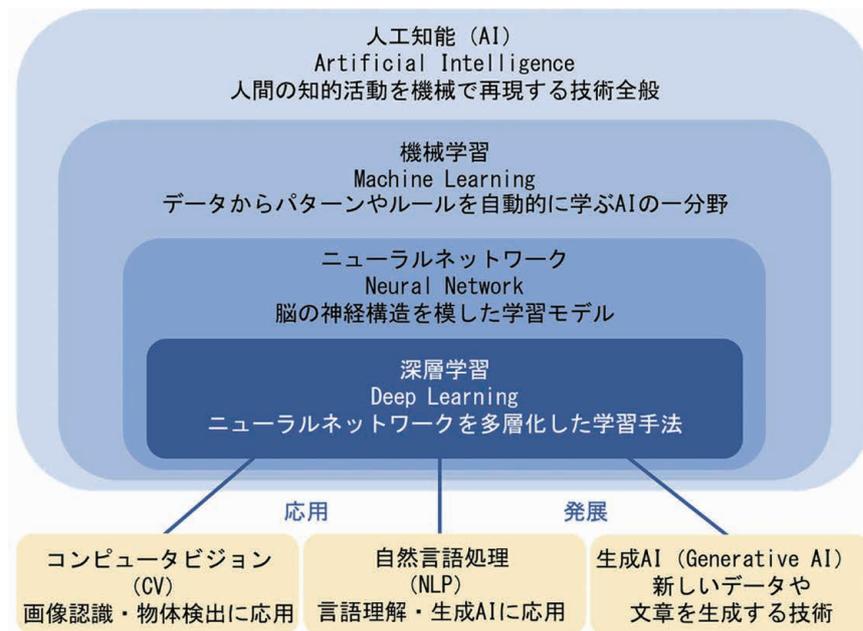
AIの一分野である機械学習とは、明示的なプログラミングによらず、データからパターン

(3) International Federation of Robotics (IFR), "Record of 4 Million Robots in Factories Worldwide," 2024.9.24. <<https://ifr.org/ifr-press-releases/news/record-of-4-million-robots-working-in-factories-worldwide>>

や規則を学習し予測・判断を行うアルゴリズム的手法の総称である。統計学、計算論といった諸分野がAIと融合して生まれた学際的領域であり、現代のAIの中核を成す技術である。従来のロボットは、人間が詳細に手順を教え込む「教示」によって同一動作を正確に再現することを得意としていたが、機械学習によるロボットは、人間が与えたデータから自ら規則性を見だし、未知の状況に応じて行動を最適化できる点で本質的に異なる。

機械学習の中でも深層学習（ディープラーニング）は特に進んだ手法であり、人間の脳神経の仕組みを模して作られた「人工ニューラルネットワーク」を用いて、複数の層を通じて情報を処理し、特徴を自動的に学習する。ニューラルネットワークは、入力層・隠れ層・出力層から構成され、人工ニューロンと呼ばれる演算ユニットが情報を伝達・変換する仕組みとなっている<sup>(4)</sup>。機械学習、深層学習、ニューラルネットワークについて詳しくは後述する。一般に、AI・機械学習・深層学習は包含関係にある（図1）。近年のAI技術の進歩は、主にこの機械学習及び深層学習の発展に支えられている。

図1 AI技術の関係



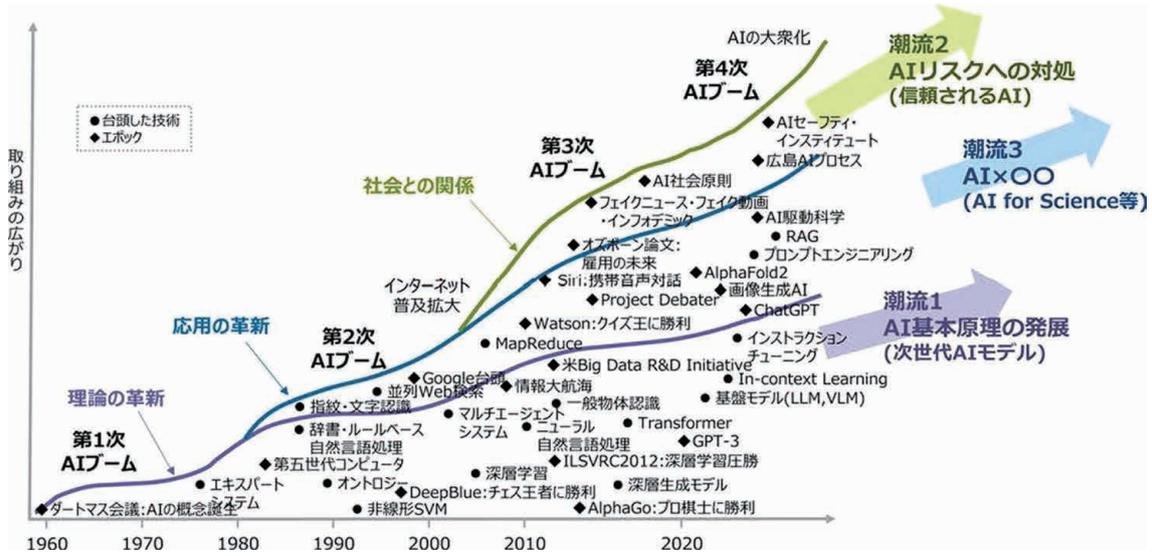
（出典）筆者作成。

## 1 主要な歴史的出来事

AIの発展は、図2で示されるように、技術的なブレイクスルーとともに社会的な期待と停滞を繰り返しながら進展してきた。とりわけ、人工ニューラルネットワークの進化は、ロボティクスにおける知能化の基盤を築いてきた。概要を表1（本節末尾に記載。）として示す。

(4) Volodymyr Mnih et al., “Human-level control through deep reinforcement learning,” *Nature*, Vol.518, 25 February 2015, pp.529-533. <<https://doi.org/10.1038/nature14236>>

図2 AI技術の時系列俯瞰図



(出典) 人工知能 (AI) 技術の時系列俯瞰図 (国立研究開発法人科学技術振興機構研究開発戦略センター『人工知能研究の新潮流 2025～基盤モデル・生成 AI のインパクトと課題～』CRDS-FY2024-RR-07) <[https://www.mext.go.jp/content/240125\\_mxt\\_jyohoka01\\_000033728\\_02.pdf](https://www.mext.go.jp/content/240125_mxt_jyohoka01_000033728_02.pdf)> を基に筆者作成。

その起源は 1943 年、マカロック (Warren Sturgis McCulloch) とピッツ (Walter Pitts) による神経活動の数理モデルに遡る。このモデルは、生物の神経細胞が持つ情報処理の機能を数学的に模倣し、後の人工知能研究に理論的基盤を提供した。1956 年には、米国ニューハンプシャー州のダートマス大学で開催されたダートマス会議において、AI という学問分野名が初めて提唱された。この会議は、人間の学習や推論を機械で再現するという新たな研究分野の誕生を告げるものであった。1958 年には、ローゼンブラット (Frank Rosenblatt) がパーセプトロン<sup>(5)</sup> というモデル<sup>(6)</sup>を開発し、誤り訂正学習則<sup>(7)</sup>を導入したことで、ニューラルネットワークは初めて実用的な学習機構を得た。この成果を契機として、ニューラルネットワーク研究が活発化し、後に第 1 次ニューラルネットワークブームと呼ばれる時期が形成された。これにより第 1 次 AI ブームが始まり、迷路探索や定理証明といった推論・探索アルゴリズムの研究が進められるとともに、初期の対話プログラム「ELIZA」なども開発された。ELIZA は最初期の自然言語対話システムの一つであり、入力文中のキーワードを検出して定型文を返すことで、心理療法士との会話を模倣する仕組みであった。しかし、当時の AI は単純なルールベース処理に依存しており、現実世界の複雑な問題に対応することはできなかった。その後、1969 年にはミンスキー (Marvin Minsky) とパパート (Seymour Papert) が単層パーセプトロンの限界として、原因と結果の関係が複雑な問題<sup>(8)</sup>を扱えない点を指摘し、技術的失望と計算資源<sup>(9)</sup>の制約により「AI の冬」と呼ばれる停滞期が訪れた。

(5) 語源は、英語の perceive (知覚する) に由来し、刺激を受け取って判断する仕組みを表す名称として用いられた。  
 (6) 現実の対象の働きを理解・分析するために、その本質的な要素を抽象化して表現した理論的枠組みのこと。  
 (7) 出力の誤差に基づいて結合の重みを更新する学習方法のこと。例えば、画像を「丸」と「三角」に分類する課題において、誤って「丸」を「三角」と判定した場合、その誤りが減る方向に重みを調整することで、次回以降は正しく判定できるように学習が進む。  
 (8) 線形的に分離できない問題のこと。原因 (入力) と結果 (出力) の関係が単純な比例関係では表せず、条件が絡み合った問題を指す。  
 (9) コンピュータが計算処理を行うために必要とする処理能力や記憶容量などの資源を指す。

1980年代には、専門家の知識をルールとして組み込むエキスパートシステムが登場し、第2次AIブームが起きた。しかし、専門知識を収集・形式化・維持する作業に大きな負担が伴うという知識獲得に伴うボトルネックや、想定外の状況に柔軟に対応しにくいという構造的な制約から限界が顕在化し、研究投資は再び低迷した。

この閉塞状況を打破したのが、1986年にラメルハート（David E. Rumelhart）らが提唱した誤差逆伝播法（バックプロパゲーション）である。これは、出力結果と正解との差として得られる誤差をネットワーク内部に遡って伝え、各結合<sup>(10)</sup>の重み<sup>(11)</sup>を自動的に更新する学習手法である。この手法により、人間が各層や結合ごとに調整方法を設計しなくても多層のネットワークを効率的に学習させられるようにしたものである。この革新により、多層ニューラルネットワーク（図3。II3に記載。）の学習が現実的となり、人工知能研究は再び脚光を浴び、第2次ニューラルネットワークブームが到来した。

さらに1989年には、ルカン（Yann LeCun）らが手書き文字認識用に畳み込みニューラルネットワーク（convolutional neural network: CNN）を開発した。これは、画像の中から線や輪郭などの特徴を自動的に抽出できる仕組みであり、従来は人が設計していた“見るためのルール”をAIが自ら学習できるようにした点で画期的であった。これをきっかけに、画像処理分野への応用が急速に広がっていった。

1990年代後半から2000年代にかけて、インターネットの普及によりビッグデータ<sup>(12)</sup>が蓄積され、計算機の性能向上とあいまって、AI研究は実験室から現実の社会課題へと広がりを見せた。サポートベクターマシン（Support Vector Machine: SVM）は、データを分類・回帰する境界を統計的に学習する手法であり、少量のデータでも高い識別性能を示す特徴を持つ。また、勾配ブースティングは、複数の弱い予測モデルを段階的に組み合わせることで予測精度を高める手法であり、分類や予測タスクで広く用いられている。これらの機械学習手法が多数の分野で成果を挙げ、AIは経験に基づいてパターンを学ぶ「ボトムアップ型」のアプローチへと進化した。

1997年にはホッフライター（Sepp Hochreiter）とシュミットフーバー（Jürgen Schmidhuber）によって長短期記憶（Long Short Term Memory: LSTM）が開発され、音声認識や言語モデルの性能が飛躍的に向上した。LSTMについては後述する。

2006年にはヒントン（Geoffrey Hinton）らが深層信念ネットワーク（Deep Belief Network）を提唱し、深い<sup>(13)</sup>層を一段ずつ学習させる事前学習手法を確立した。これは後の深層学習（ディープラーニング）の時代を切り拓くものであった。そして2012年、クリジェフスキー（Alex Krizhevsky）らによる「AlexNet」が画像認識技術の競技会で圧倒的な精度を達成し、GPU（Graphics Processing Unit）<sup>(14)</sup>を活用した深層学習の有効性が実証された。人間の視覚能力に迫る性能が初めて実現し、第3次AIブームと第3次ニューラルネットワークブームが同時に加速した。画像認識については後述する。

2017年にはヴァスワニ（Ashish Vaswani）らによってトランスフォーマー（Transformer）アーキ

(10) ニューラルネットワークにおいて、ある人工ニューロンから別の人工ニューロンへ信号を伝えるつながりのこと。

(11) 各結合に割り当てられる数値であり、入力信号が出力にどの程度影響を与えるかを表す指標を指す。

(12) 量が非常に多く、種類や生成速度も多様であるため、従来のデータ処理手法では十分に扱うことが困難な大規模データ群。

(13) 本報告書における「深い（深層）」とは、ニューラルネットワークにおいて層の数が多い構造を指す。

(14) 多数の演算を並列に高速処理することに特化した演算装置。一般には、画像処理用のPC部品の名称。

テクチャ<sup>(15)</sup>が発表され、AIが文章を読む仕組みを根本から変えた。これにより、従来よりも長文の文脈を理解し、複雑な関係を捉えることが可能になった。以降、グーグル社のBERTやオープンAI社のGPTシリーズなど、事前学習済みの大規模言語モデル(LLM)が続々と登場し、特に2020年に発表されたGPT-3は1750億パラメータ<sup>(16)</sup>を有し、少量の例示のみで高性能な言語処理を実現したことで、自然言語処理における革新を象徴する存在となった<sup>(17)</sup>。

2022年にはオープンAI社がChatGPTを公開し、自然対話が可能な生成AIとして爆発的な普及を見せた。公開後わずか5日間で100万人、2か月で1億人以上が利用し<sup>(18)</sup>、AI技術が専門領域から一般社会へと急速に浸透する契機となった。さらに2023年にはGPT-4が登場し、画像や音声を含むマルチモーダル<sup>(19)</sup>情報を統合的に処理する能力を持つことで、ロボティクス分野においても人間並みの認識・判断・行動計画が現実味を帯びてきた<sup>(20)</sup>。2025年にはGPT-5が登場し、汎用的な推論能力と複数分野への応用力を兼ね備えた次世代AIとして広く注目を集めている<sup>(21)</sup>。

このように、AIとニューラルネットワークの発展は、ロボティクスの知能化と深く結びつきながら進化してきた。推論・探索から統計学習、深層学習、大規模言語モデルへと至るこの技術的軌跡は、現在のAIロボットやヒューマノイドの認識・制御・学習能力の礎となっている。ロボティクスにとってAIはもはや補助的技術ではなく、その発展を支える中核要素であるといえる。

---

(15) AIモデルを構成する全体的な設計構造や情報処理の枠組み。

(16) AIモデル内部で学習によって調整される数値であり、入力データに対する振る舞いを規定する。一般に、パラメータ数はモデル規模の一つの指標として用いられるが、性能を直接保証するものではない。

(17) T. B. Brown et al., "Language Models are Few-Shot Learners," *Advances in Neural Information Processing Systems*, 2020. <<https://arxiv.org/abs/2005.14165>>

(18) Krystal Hu, "ChatGPT sets record for fastest-growing user base," 2023.2.3. Reuters website <<https://www.reuters.com/technology/chatgpt-sets-record-fastest-growing-user-base-analyst-note-2023-02-01/>>

(19) テキスト、画像、音声など複数の種類(モダリティ)の情報を統合的に扱うこと。

(20) OpenAI et al., "GPT-4 Technical Report," 2023. <<https://arxiv.org/abs/2303.08774>>

(21) OpenAI「GPT 5が登場」2025.8.7. <<https://openai.com/ja-JP/index/introducing-gpt-5/>>

表1 AI進化の主なブレイクスルー

年	主要な出来事	概要
1943	人工ニューラルネットワークの提案	人間の脳を模倣した計算モデルの原型が生まれた
1958	学習可能なモデル（パーセプトロン）の登場	誤りを修正しながら学習できるAIの基礎が築かれた
1969	単層モデルの限界が指摘され、AI研究が停滞	複雑な問題には単純なAIでは対応できないと判明した
1986	誤差逆伝播法により多層ネットワークの学習が可能に	多層構造を持つニューラルネットワークが実用的になった
1989	CNNにより画像認識技術が進展	画像の特徴を自動的に抽出する技術が確立された
1997	LSTMにより時系列処理が向上	文章や音声など、時系列データの処理が向上した
2006	深層学習に向けた事前学習手法が開発される	深層学習モデルの学習効率を高める方法が提案された
2012	AlexNetが深層学習の有効性を実証	GPUを活用し、画像認識の精度が大幅に向上した
2017	トランスフォーマーが自然言語処理に革新をもたらす	重要な部分に注目して情報を処理する仕組みが確立された
2018	BERTの登場	大量の文書から意味を理解する、文脈理解に強い高度な言語モデルが登場した
2020	GPT-3が大規模生成モデルとして注目される	少ない情報から柔軟に回答できるAIとして注目された
2022	ChatGPTの急速な普及	自然対話形式で誰でも使えるAIが一般社会に広まった
2023	GPT-4の登場	画像や音声などのマルチモーダル情報を統合して理解できるAIが登場した
2025	GPT-5の登場	長文理解・推論・マルチモーダル統合性能がさらに向上した高度汎用AIモデルにより、専門分野での応用が進展した

(出典) 筆者作成。

## 2 機械学習とディープラーニング

機械学習は、人工知能の中でも幅広い方法を含む大きな枠組みであり、例えば線形回帰、決定木、サポートベクターマシン（SVM）、k近傍法（k-NN）といった、「データからルールを導き出すための基本的な方法」が含まれる。これらは機械学習でよく使われる手法で、それぞれに得意な場面や用途がある。一方、ディープラーニングは、従来の機械学習では難しかった複雑なパターンや特徴（例えば画像の中の顔や声のニュアンスなど）を、コンピュータが自動で見つけ出すことができるのが大きな特徴である<sup>(22)</sup>。画像を分類するタスクを例にとると、従来の機械学習では、あらかじめ人間が「画像のどこに注目すべきか」を決めておく必要があった。具体的には、「エッジ（輪郭）」「色」「形状」といった情報を手作業で抽出し、入力することで分類を行っていた。これに対し、ディープラーニングでは、大量の画像データを入力するだけで、コンピュータ自身が「どこに注目すればよいか」を学び、より細かく、深いレベルの特徴を自動で見つけ出してくれる。これにより、従来手法よりも高精度かつ柔軟な判断が可能となっている。

## 3 ディープラーニングの発展と主要技術

現代のディープラーニング<sup>(23)</sup>は、図3に示すように入力層と出力層の間に1層以上の隠れ層を持つ多層のニューラルネットワークを用いて、データから特徴表現を学習する技術であり、

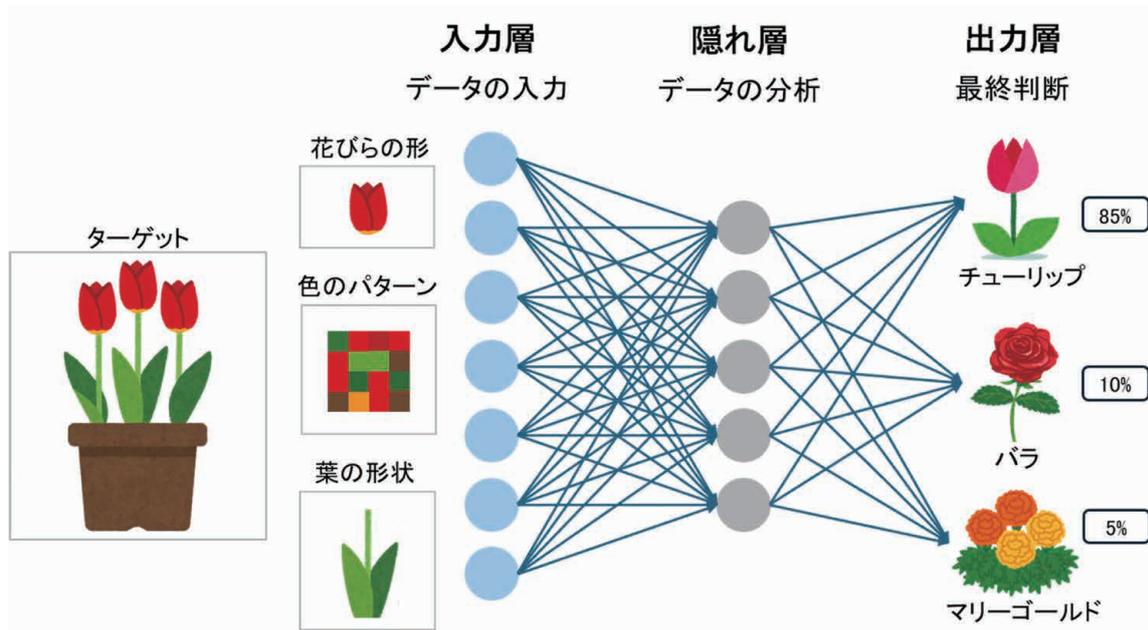
(22) Yann LeCun et al., “Deep learning,” *Nature*, Vol.521, 27 May 2015, pp.436-444. <<https://doi.org/10.1038/nature14539>>

(23) 深層（ディープ）という用語には、何層以上といった厳密な数値基準は存在しない。一般には、隠れ層を多数持ち、階層的に特徴を学習するニューラルネットワーク構造を指して用いられる。例えば、画像認識で広く用いられる ResNet-50 は約 50 層、自然言語処理で用いられる BERT-base は 12 層の変換層を持つ。

画像・音声・言語処理など幅広い分野で高い性能を示す<sup>(24)</sup>。

ニューラルネットワークは機械学習モデルの一種であり、入力層・隠れ層・出力層から成るノード（ニューロン）<sup>(25)</sup>群が入力情報を重み付けして処理し、非線形な変換を加えながら結合される構造を持つ。隠れ層を持たない単層のネットワークと異なり、隠れ層を重ねることで複雑な非線形関係を表現できる点が特徴である。理論的には、隠れ層を1層以上持つニューラルネットワークは、任意の連続関数を近似できることが示されている。一般に教師あり学習（正解付きデータ学習）が多く用いられるが、教師なし学習（特徴抽出）や強化学習（行動試行）の形式でも発展がある。学習には誤差逆伝播法（勾配法に基づくパラメータの更新）<sup>(26)</sup>が広く用いられ、GPU等を活用した大規模並列学習が可能となった。

図3 多層ニューラルネットワークの一例



(出典) 筆者作成。

そこでの主要技術であるCNNは、画像認識タスクに優れた構造を持つニューラルネットワークである<sup>(27)</sup>。入力画像に対して小さな領域（フィルター）を順に適用していくことで、画像の特徴（輪郭や模様など）を検出し、特徴マップを生成する。この処理を「畳み込み」という。その後、重要な部分を残して情報を圧縮する「プーリング」や、複雑なパターンを表現するための「非線形変換（活性化）」を行うことで、画像の中の形や位置が多少変わっても認識できるような階層的特徴が抽出される。CNNは多くの画像認識課題で精度向上に寄与し、以降の主要なアーキテクチャの基盤となった。

その発展を象徴するのが、ImageNet及びその国際競技会であるILSVRC（ImageNet Large Scale Visual Recognition Challenge）である。ImageNetは、米国スタンフォード大学及びプリンストン大学の研究チームによって構築された大規模画像データセットであり、約1400万枚以上の画

(24) 「大規模言語モデル」野村総合研究所ウェブサイト <<https://www.nri.com/jp/knowledge/glossary/llm.html>>  
 (25) ニューラルネットワークを構成する計算単位で、入力を受け取り処理した結果を次の層へ出力する要素。  
 (26) 誤差が小さくなる方向にパラメータを段階的に調整する方法。  
 (27) Keiron O'Shea and Ryan Nash, "An Introduction to Convolutional Neural Networks," 2015. <<https://arxiv.org/abs/1511.08458>>

像に「犬」「車」「りんご」など1,000種類を超えるカテゴリが人手でラベル付けされている。ILSVRCは、このImageNetを用いて2010年から2017年まで毎年開催されていた国際的な性能評価コンテストであり、研究者がAIモデルを訓練し、未知の画像をどれだけ正確に分類できるかを競うものである。これまでの優勝モデルと特徴を表2に示す。ImageNetとILSVRCは、画像認識分野における標準的なベンチマーク（評価基準）として、深層学習技術の性能向上と普及を強く後押しした。画像認識の性能は一般に「誤認率（誤識別率）」によって評価される。誤認率とは、AIモデルが画像を誤って分類した割合を示す指標であり、数値が低いほど性能が高い。

ILSVRCでは、各AIモデルが1,000種類の物体カテゴリの中から正しいラベルを選ぶ能力を比較し、主に「Top-5 誤認率（上位5つの予測の中に正解が含まれない割合）」が用いられる。2012年のILSVRCでは、トロント大学チームのAlexNet（深層CNN）が従来手法を大きく引き離して優勝した<sup>(28)</sup>。AlexNetの誤認率は約15%と2位以下より約10%も低く、深層CNNの有効性を示した。これ以降、CNNは層数<sup>(29)</sup>を増やして画像認識性能を向上させる主流アーキテクチャとなり、VGG（16-19層）やGoogLeNet（22層）などもILSVRCで高精度を示した。さらに2015年にはマイクロソフト社の研究者らが提案したResNet（Residual Network）が登場した。深層化が進むと、学習に必要な情報が層を遡る過程で弱まり、初期の層がほとんど更新されなくなることが課題（勾配消失問題）として指摘されていた。勾配消失問題とは、長距離依存（長い文脈や文の後半）を学習することが困難となることであり、逆伝播により誤差を伝える過程で勾配が指数的に小さくなってしまい、初期の情報が無視されてしまう問題である。

ResNetは、途中の層を迂回して情報を直接伝える構造を導入することで、この課題を緩和した<sup>(30)</sup>。ResNetは100層以上の非常に深いネットワークを学習可能とし、それ以降「より深いCNNほど性能が向上する」傾向が加速した。

表2 ILSVRCの代表的画像認識モデルと特徴

年	代表モデル	主な開発機関	Top-5 誤認率	技術的特徴
2010	(従来手法)	—	約28%	手作り特徴量 + SVM分類器が主流
2012	AlexNet	トロント大学	15.3%	GPU学習とReLU*1で精度向上
2014	VGG-16	オックスフォード大学	7.3%	小サイズ畳み込みの多層化*2
2014	GoogLeNet (Inception v1)	Google	6.7%	インセプション構造で高効率化*3
2015	ResNet	Microsoft Research	4.94%	残差学習で152層を実現
2016-2017	ResNeXt / DenseNet	Facebook AI Research 他	約3.5 ~ 4%	層結合の改良で高精度化

(凡例) 本表は各年の全ての優勝モデルを網羅したのではなく、画像認識技術の発展において代表的な転換点となったモデルを抽出して示している。このため、年によっては掲載がない場合や、同一年に複数の代表モデルを示している場合がある。

\*1 入力が正のときはそのまま出力し、負のときは0とする活性化関数。計算が簡単で、深層学習で広く用いられる。

\*2 小さな範囲を順に重ねて処理することで、細かな情報から全体的な特徴までを段階的に捉える方法。

\*3 複数の処理を並列に行い、その結果を統合する構造。

(出典) 筆者作成。

(28) 「深層学習 — Deep Learning」執筆チーム「ニューラルネットワーク・深層学習研究の歴史」2015.10. <<https://jsai-deeplearning.github.io/support/nnhistory.pdf>>

(29) 本文中で示す層数は、入力層や出力層を除き、主に畳み込み層や全結合層などの学習可能なパラメータを持つ層の数を指す。隠れ層のみを単純に数えたものではない。

(30) 「ResNetとは？特徴や構造・メリット・デメリットをわかりやすく解説」2025.10.17. AISmiley ウェブサイト <[https://aismiley.co.jp/ai\\_news/title-resnet-cnn-microsoft-research/](https://aismiley.co.jp/ai_news/title-resnet-cnn-microsoft-research/)>

また、深層学習では転移学習<sup>(31)</sup>も重要なブレイクスルーである。ImageNet等で学習済みの大規模CNNは、一般に初期層でエッジや色彩といった汎用的特徴を学ぶため、異なるタスクへ再利用しやすいことが示されている<sup>(32)</sup>。すなわち、学習済みモデルを出発点に少ないデータで微調整（ファインチューニング）することで、新たな分類や認識タスクを効率よく学習できる。これにより、画像だけでなく音声認識やセンサデータ分析にも深層学習が広く展開されるようになった。

深層学習技術は数々の画期的な成果を生んでいる。画像認識では、システム性能が急激に向上し、医用画像診断（例えば疾患を見分ける）や自動運転（例えばカメラに映った道路標識を読み取る）などで実用化が進んでいる。音声認識・音声合成では、深層ニューラルネットワークを用いた技術が従来技術を大きく上回り、スマートフォンやスマートスピーカーで広く利用されている。自然言語処理では前述のBERTやGPTの登場で翻訳・要約・質問応答性能が飛躍的に向上し、Google翻訳や対話AI（ChatGPTなど）で実用化された。強化学習と深層学習を組み合わせた例として、DeepMind社のAlphaGoは2016年に囲碁で世界チャンピオンに勝利し、AIが複雑な戦略ゲームでも人間を超えられることを示した。この技術はAlphaZeroやMuZeroなど次世代モデルへ発展し、ゲーム以外の複雑問題解決にも応用研究が拡大している<sup>(33)</sup>。

以上のように、深層学習は数十年にわたる技術発展を経て現在の高性能AIを支えている。ニューラルネットワークアーキテクチャや学習手法の革新、大規模データと計算資源の利用が相まって、画像・音声・言語等の多様な領域で人間に匹敵する性能を実現しつつある。今後もアルゴリズムの改良と計算基盤の進化により、さらに高度なAIシステムの実現が期待される。

### Ⅲ AIとロボティクスの融合によるパラダイムシフト

#### 1 コンピュータビジョン分野における認識・判断能力の向上

##### (1) コンピュータビジョンの進化

ロボットにとって周囲の状況を正確に「見て理解する」能力は不可欠である。コンピュータビジョン（Computer Vision: CV）分野では、前節で述べたとおり2012年のCNNモデルの実用化を契機に画像認識精度が飛躍的に向上した。2015年に登場した深いネットワーク構造を持つResNetは、人間の画像認識精度（誤識別率5.1%）を初めて超える4.94%を達成したと報告されている<sup>(34)</sup>。このようにディープラーニングによる視覚認識性能の向上は、ロボットの視覚センサ情報の処理能力を格段に高める要因となった。

特に近年注目すべきは、物体検出やシーン理解のリアルタイム化である。2016年に提案されたYOLO（You Only Look Once）は画像内の複数物体の位置とクラス（カテゴリ）を単一のCNNで高速同時検出できる手法で、45fps（フレーム毎秒、1秒間に画像の情報が出力される回数）を超えるリアルタイム処理を実現した。小型モデルでは155fpsもの高速推論が可能であり、従来の物体検出手法に比べて桁違いの実時間性能を達成している<sup>(35)</sup>。YOLOの登場によりロボット

(31) 別の課題で学んだ知識を流用して学習を行う方法。

(32) Jason Yosinski et al., “How Transferable Are Features in Deep Neural Networks?” 2014. <<https://arxiv.org/abs/1411.1792>>

(33) Google DeepMind, “AlphaGo.” <<https://deepmind.google/research/projects/alphago/>>

(34) K. He et al., “Deep Residual Learning for Image Recognition.” <<https://arxiv.org/abs/1512.03385>>

(35) J. Redmon et al., “You Only Look Once: Unified, Real-Time Object Detection.” <<https://arxiv.org/abs/1506.02640>>

はビデオカメラから得た映像を即座に解析し、移動体や対象物体をその場で認識して対応できるようになった。例えば、自動走行ロボットは走行中に前方の歩行者や障害物を瞬時に検知・回避できるし、産業用ロボットはコンベヤ上の製品をリアルタイムに見分けてピッキング動作を行える。この高速ビジョン処理は、自律移動ロボットやドローン、組立作業ロボットなどにおいて安全性と効率を飛躍的に高めた。

## (2) コンピュータビジョンの実用化

以上のCV技術の発展は、多様な形態のロボットに実装されている。自動運転車はLiDAR (Light detection and ranging)<sup>(36)</sup>などに加えてカメラ画像をCNNで解析し、歩行者検出や信号認識を行う。特にテスラ社はカメラから得られる画像情報を、AI技術の一つであるニューラルネットワークによって解析する視覚処理を中核とし、自動運転・高度運転支援の開発を進めている<sup>(37)</sup>。また、工場の組立ロボットにはマシンビジョン (CV技術を産業用途に応用したもの) が導入され、ベルトコンベヤ上の部品をカメラで見分けて把持するピック & プレースを可能にした。サービス分野でも、清掃ロボットや警備ロボットが内蔵カメラで人や障害物を認識し経路を動的に調整している。さらにヒューマノイド (人型) ロボットの視覚能力も飛躍的に向上しつつある。ボストン・ダイナミクス社のアトラス (Atlas) のような最先端ヒューマノイドでは、深層学習を用いたステレオカメラ画像の認識により不整地や障害物を踏破する高度な歩行が実現されている<sup>(38)</sup>。最近ではテスラ社が開発中のオプティマス (Optimus) でも、マルチカメラ映像をニューラルネットワークで処理して物体の三次元位置推定や把持動作の計画を行っており、公開デモでは人間の指示に従って箱を持ち上げ仕分け作業を行う様子が披露された<sup>(39)</sup>。このように、CNNに始まる現代のCV技術は産業用ロボットから自律移動ロボット、サービスロボット、ヒューマノイドに至るまで幅広いロボットに搭載され、周囲の状況を高精度に認識して適切に判断・行動する礎となっている。

## 2 自然言語処理技術の進化とロボットへの応用

ロボットが人間社会で活躍するためには、「聞く・読む・話す」といった自然言語の理解・生成能力も重要である。自然言語処理 (Natural Language Processing: NLP) は、こうした言語理解と応答を支える基盤技術であり、その進化がロボットの知能化を大きく後押ししている。1990年代から2000年代にかけて、再帰型ニューラルネットワーク (Recurrent Neural Network: RNN) が音声認識や機械翻訳などに応用され始めた。

### (1) 系列処理に基づく自然言語理解 (RNN)

RNNは、過去の入力を踏まえて次の判断を行うことに特化したニューラルネットワークであり、時系列データや系列データの処理に用いられる。例えば文章処理では、直前までに読んだ単語や文脈を内部に保持し、それを踏まえて次の単語の意味を解釈することができる。

RNNは、過去の情報を「隠れ状態 (hidden state)」として内部に引き継ぎながら次の処理を

(36) 光による検知と測距、レーザー光を使って対象物までの距離や位置、形状を把握するセンサ。

(37) 「Tesla Vision アップデート：超音波センサーをTesla Visionへ」2025.9.17. Tesla website <[https://www.tesla.com/ja\\_jp/support/transitioning-tesla-vision](https://www.tesla.com/ja_jp/support/transitioning-tesla-vision)>

(38) “Atlas.” Boston Dynamics website <<https://www.bostondynamics.com/atlas>>

(39) Tesla, “Optimus Robot Demonstration.” YouTube <<https://www.youtube.com/watch?v=D2vj0WcvH5c>>

進める構造を持つため、音声認識、文章処理、ロボットの動作など、時間的な連続性を持つデータに対して有効である。

一方で、従来型のRNNは「勾配消失問題」と呼ばれる課題があったが、この課題を解決するために、1997年に提案されたのがLSTMである。LSTMは、情報を「記憶セル」として長期間保持できるように設計された特殊な構造を持ち、「入力ゲート」「出力ゲート」「忘却ゲート」と呼ばれる3つのゲート機構により、重要な情報を選択的に保持・破棄・出力できる。これにより、従来のRNNでは困難だった長文や複雑な時系列パターンの処理が可能となった。この技術革新により、LSTMは音声認識（Google音声検索など）、機械翻訳（Google翻訳の初期モデルなど）、文字列生成（文章やメロディの生成）など、幅広い応用で実用化され、深層学習における時系列処理のスタンダードとなった。その後、LSTMの発想を基に、構造を簡略化しつつ同様の性能を発揮できるGRU（Gated Recurrent Unit）も登場し、軽量のモデルを求める場面で活用されている。このように、RNN及びLSTMは、ニューラルネットワークによる「順序情報の処理」を現実的なものに変え、自然言語処理・音声処理・動画解析など、時系列を重視する多くの分野に深い影響を与えた。

## (2) 文脈理解の高度化（トランスフォーマー）

RNNやLSTMは過去の情報を順に引き継ぎながら処理を行う構造のため、計算を並列化しにくく、大規模データでの学習効率に課題があった。2017年に提案されたトランスフォーマーモデルは、こうした発想を転換し、入力系列の全ての要素同士を一度に参照し合う構造を導入した点に特徴がある。トランスフォーマーは自己注意機構（Self-Attention）により、文章中のどの要素がどの要素と関係しているかを同時に評価できるため、処理の並列化が可能となり、大規模データを用いた高速な学習が実現した。とりわけ、グーグル社の翻訳システムへの適用では従来比で大幅な精度改善を達成し、以降ほとんどの最先端言語モデルはトランスフォーマーに基づいている。

トランスフォーマーの有効性は、大規模事前学習との組合せで最大限に発揮された。2018年以降、インターネット上の膨大なテキストから学習したBERTやGPTシリーズなどのLLMが続々と登場した。2022年には汎用対話型モデルのChatGPTが公開され、人間と遜色ない文章生成や応答能力が社会的関心を集めた。さらに2023年にはGPT-4が登場するなど、トランスフォーマーを基盤とするモデルは急速に発展している。

このトランスフォーマーの考え方は、画像認識分野にも応用されている。2020年には、注意機構（どこを見るべきかを自動的に選ぶ仕組み）を画像領域に適用したVision Transformer（ViT）が提案された。ViTは画像をパッチと呼ばれる小領域に分割し、それらをトークン列として処理することで、従来のCNNを用いずに画像分類を実現した。大規模データによる事前学習を行ったViTは、最先端のCNNと同等の精度を示しつつ、設計の単純化や他分野との統合の容易さといった利点を持つ。このようなトランスフォーマーの視覚分野への応用により、画像と言語や他センサ情報との統合もしやすくなり、ロボットが視覚情報をより高次の文脈で理解する道が開けている<sup>(40)</sup>。

(40) Mariusz Bojarski et al., “End to End Learning for Self-Driving Cars,” 2016. <<https://arxiv.org/abs/1604.07316>>

### (3) 自然言語によるロボット制御 (LLM)

LLMは対話型エージェントや文章生成、翻訳、要約、検索補助など幅広い応用が進んでいるが、ロボットへの自然言語インターフェースの実現にも大きな可能性を与えている。

その一つの方向性は、ロボットに対する対話的命令の理解である。従来、ロボットに動作を指示するにはあらかじめ定められた命令（コマンド）や画面上のボタンなどを用いる画面操作方式（Graphical User Interface: GUI）操作が必要だったが、LLMを組み込むことで人間が日常言語でロボットを操作できるようになりつつある。その代表例がマイクロソフト社及びオープンAI社の研究チームによる「ChatGPT for Robotics」の実験報告である<sup>(41)</sup>。彼らは汎用対話モデルであるChatGPTにロボット制御用の関数ライブラリを与え、適切なプロンプト設計を行うことで、ドローンやロボットアーム、家庭用移動ロボットなど複数のロボットを自然言語指示のみで操作可能にした。例えばユーザが「机の上から青いブロックを取って棚に置いて」と文章で命令すると、ChatGPTはその意図を解析してコード（Pythonスクリプト）の形でロボットアームの動作シーケンスを生成し、実機を動かすことができた。この研究では、言語モデルが自由形式の対話からロボット制御プログラムを合成する能力を示し、今後専門知識のない人でも対話を通じてロボットに高度なタスクを教示できる可能性を示唆している。対話型AIとロボット制御の融合は、サービスロボットや家庭用ロボットの実用化において直感的な操作性を提供する鍵として期待される。

以上は、自然言語による指示をロボットの具体的な動作命令へと変換する方向性である。もう一つの重要な方向性は、ロボットが人間の言葉に含まれる意味や目的を理解し、曖昧な指示であっても自律的に行動計画を立てる能力の獲得である。

LLMは膨大な知識と文脈推論力を持つため、ロボットが物理世界における対象の意味や目的を推論するのに役立つ。例えばグーグル社が開発したPaLM-E<sup>(42)</sup>は、5400億パラメータの言語モデルに220億パラメータの視覚モデルを組み合わせたロボット向けマルチモーダルAIである。PaLM-Eはカメラ映像で捉えた物体と人間の指示文を同時に入力とし、「引き出しからお菓子を持ってきて」という複雑な命令を適切な一連の行動計画に変換できることが実証された。従来のロボット研究では、「お菓子」とは何か、「引き出しを開ける」にはどうすればよいか、といった“人間が常識的に身につけている”知識や推論の取扱いが難しかったが、LLMは過去の膨大な言語知識からそれらを理解し、視覚情報と照合して行動を決定できる。PaLM-Eのような手法により、ロボットが文章による曖昧な指示から具体的な動作を自律的に導き出すことが可能となりつつある。この技術は家庭用ロボットが人間の願いを理解して家事をこなす、といった場面を現実のものに近づけている。

### 3 認識と言語の融合：マルチモーダルAIによる新たな判断力

さらに、CV（視覚）と自然言語処理（言語）の融合は、AIの認識・判断能力に新たなパラダイムシフトをもたらしている。視覚と言語の両方を扱うマルチモーダルAIの代表的タスクにVisual Question Answering (VQA)がある<sup>(43)</sup>。VQAとは、画像を見てその内容についての質問に答える

(41) Sai Vemprala et al., “ChatGPT for Robotics: Design Principles and Model Abilities,” 2023. <<https://arxiv.org/abs/2306.17582>>

(42) D. Driess et al., “PaLM-E: An Embodied Multimodal Language Model,” 2023. <<https://arxiv.org/abs/2303.03378>>

(43) Aishwarya Agrawal et al., “VQA: Visual Question Answering,” 2016. <<https://arxiv.org/abs/1505.00468>>

タスクであり、画像理解と自然言語理解・生成を統合したAI能力が要求される。例えば「この写真の中で赤い帽子を被っているのは誰か?」という質問に対し、AIは写真内から人物を検出し属性を認識し、質問文を解析して正しい回答(人物名など)を生成しなければならない。2015年頃から提唱されたこのタスクを通じて、画像エンコーダ(CNN等)と質問エンコーダ(RNN/トランスフォーマー等)を組み合わせて、双方の情報を注意機構で融合して答えを推論するモデルが多数開発された。VQAはロボットにとって、人間から視覚的状况について問合せを受けた際に的確に答える能力に相当し、例えば「今見えている部屋に飲み物はあるか?」と聞かれてカメラ映像からペットボトルを探し「テーブルの上に水のボトルがあります」と返答するような応用が考えられる。これはロボットの認識結果を人間の理解できる言葉で説明する技術(Explainable AI: XAI)の一種でもあり、人とロボットの円滑なコミュニケーションに寄与する。

また、視覚と言語を統合したAIはロボットの推論力を飛躍的に高める可能性がある。最新の研究では、ウェブ上の画像キャプションや知識から学習した視覚言語モデル(VLM)をロボット制御に取り入れ、見たことのない物体や指示にも対応できるようにする試みが進んでいる。

こうした視覚と言語の統合が進んだ背景には、画像処理においてもトランスフォーマーを用いることで、視覚情報を言語と同様のトークン列として扱えるようになった点がある。グーグル・ディープマインド社が2023年に発表したRobotic Transformer 2(RT-2)は、そのような視覚・言語・行動統合モデルの一例である<sup>(44)</sup>。RT-2はウェブ上の画像と言語の対応データで事前訓練したVLMをロボットの実データで微調整し、カメラ画像から直接ロボットの動作コマンドを出力するend-to-end型のシステムとなっている。特徴的なのは、動作も言葉と同様に記号列で表現し、視覚と言語を同じフォーマットでモデルに学習させた点である。

この結果、RT-2はロボットが訓練で一度も見たことのない新奇な物体に対しても「それが何でありどう扱うべきか」をネット上の知識を応用して推論し、適切な行動を生成できることが示された。例えば「疲れた人に適した飲み物を渡して」と命じられた際、訓練になかったエナジードリンク缶をカメラで見つけ出し、それが疲労回復に良いと理解して手渡す動作を行う、といった意味的(セマンティック)な推論能力が報告されている。

さらにチェーン・オブ・ソート(Chain of Thought: CoT)と呼ばれる段階的推論を組み込むことで、「即席のハンマーとして使える物はどれか?」との問いに対し石を選ぶ、といった段階的な推論・判断も可能になった<sup>(45)</sup>。このような汎用ビジョンと言語モデルをロボットに組み込むアプローチは、ロボットが個別のプログラムなしに人間並みの常識や知識を活用して行動できる未来につながる。研究者はこのカテゴリのモデルをVLA(Vision-Language-Action)モデルとも呼んでおり、今後マルチモーダルAIがロボットの認識・判断・行動を包括的に担う時代が到来しつつある。

さらに広義には、エンボディドAI(Embodied AI)と呼ばれる領域が注目されている<sup>(46)</sup>。エンボディドAIとは、物理世界に身体を持つエージェント(ロボット等)の知能を研究する分野であり、視覚・聴覚などのセンサによる知覚、言語モデルを含む認知的判断、及びモータやアク

(44) Anthony Brohan et al., “RT-2: Vision-Language-Action Models Transfer Web Knowledge to Robotic Control,” 2023. <<https://arxiv.org/abs/2307.15818>>

(45) Yevgen Chebotar and Tianhe Yu, “RT-2: New Model Translates Vision and Language into Action,” 2023.7.28. Google DeepMind website <<https://deepmind.google/discover/blog/rt-2-new-model-translates-vision-and-language-into-action/>>

(46) “What Is Embodied AI?” NVIDIA website <<https://www.nvidia.com/en-us/glossary/embodied-ai/>>

チューエータ<sup>(47)</sup>による行動までを一貫して扱う。この分野では、物理シミュレータ（力学など現実世界の物理法則に基づいて、現象・挙動をコンピュータ上で再現する。）の上でロボットが試行錯誤しながらタスクを習得する強化学習、模倣学習といった技術と、大規模事前学習で得たビジョン・言語知識を統合する試みが行われている。例えばフェイスブック（現メタ）社のHabitatやマイクロソフト社のAirSimといった物理シミュレーション環境上で、家庭内ナビゲーションや物体操作タスクをロボットに学習させ、そこで得たデータを実機に移転する研究が活発である。エンボディドAIの究極的な目標は、人間と同程度に環境を認識・理解し、自律的に計画・行動できるロボットの実現であり、その過程でCVとNLPの更なる融合と高機能化が重要な鍵となる<sup>(48)</sup>。

なお、近年はエンボディドAIと関連して、「フィジカルAI (Physical AI)」という用語も産業界や国際機関を中心に用いられるようになってきている<sup>(49)</sup>。フィジカルAIは、必ずしも身体（ロボットの形態）を持つことを前提とせず、現実の物理世界を直接の対象として知覚・判断・行動を行うAIシステムを指す概念であり、ロボットに加えて、自動運転車、ドローン、スマートファクトリー等に用いられる自律システムを広く含むと整理されている。

このような観点から、エンボディドAIが「身体性を通じた知能の獲得」に焦点を当てる概念であるのに対し、フィジカルAIは「物理世界における自律的な知覚・意思決定・行動」を重視する、より包括的な枠組みとして位置付けられる。近年は、製造業や物流分野における自動化・高度化を背景として、このフィジカルAIの概念が注目を集めている。

#### 4 身体性と運動制御（柔軟な操作、バイオミメティクス）

身体性 (embodiment) とは、ロボットなど自律システムの知能や行動がその物理的身体によって規定・影響されるという概念である<sup>(50)</sup>。もともとは認知科学で提唱された考え方だが、ロボティクスにおいても近年重要性が認識されている。伝統的な産業用ロボットのように硬い機構を持ち、決められた環境で定型動作を行う場合には、ロボットの「身体」が果たす役割を意識することは少ない。しかし、未知の環境で多様なタスクに対応しようとするとき、ロボットの形状・質量・剛性（硬さに相当）など身体の特徴が動作結果に大きな影響を与える。例えば、関節の剛性が高く柔軟性の低いロボットは高速・高精度な動作が得意な一方で、環境からの外力に対してもろく、人や物に衝突すると大きな危害を及ぼす可能性がある。逆に、いわゆるソフトロボットと呼ばれる、柔軟な素材や関節で構成されたロボットは外力に対してしなやかに順応でき、安全な接触や変形を伴う動作が可能である。このようにロボットの身体的性質そのものが一種の制御系として機能し得るということは、身体が計算（情報処理）を担っていると捉えることができる。ロボットの制御ソフトだけでなくロボットの身体構造に役割を担わせることで、より適応的で効率的なシステム設計が可能になると期待されている。

ロボットの運動制御に柔軟性を持たせる技術として、1980年代以降に発展したのが力制御

(47) 電気や圧力などのエネルギーを機械的な動きに変換する装置であり、ロボットや機械において人間の筋肉に相当する役割を担う。

(48) 「ムーンショット目標3 2050年までに、AIとロボットの共進化により、自ら学習・行動し人と共生するロボットを実現」内閣府ウェブサイト <<https://www8.cao.go.jp/cstp/moonshot/sub3.html>>

(49) “Generative Physical AI.” NVIDIA website <<https://www.nvidia.com/en-us/glossary/generative-physical-ai/>>

(50) 新山龍馬「ソフトロボットの身体性」『計測と制御』59(11), 2020.11, pp.796-799. <[https://www.jstage.jst.go.jp/article/sicej/59/11/59\\_796/\\_article/-char/ja](https://www.jstage.jst.go.jp/article/sicej/59/11/59_796/_article/-char/ja)>

やインピーダンス制御と呼ばれる手法である。これはロボットアームが環境や対象物に触れて作業する際、力に対してたわむ、「柔らかさ」と呼ばれる性質をあえて持たせ、安全かつ安定的に接触作業を行う制御方法である。従来の目標位置に移動させる位置制御型ロボットは剛直に動作し、予期せぬ接触があると大きな力を発生させていた。インピーダンス制御では振動を制御するために用いられるバネやダンパの要素を仮想的に導入し、ロボットが環境から受ける力に応じて位置を微調整することで、衝突時の衝撃を和らげたり必要な押し付け力を加減したりできる。この技術は人と直接接触れ合う介護・福祉ロボットなどにとって必須のものとなり、ロボットが周囲に与える力を制御することで、安全性と作業性の両立が図られている。近年ではAIを用いてロボット自身が学習することで適切な柔軟動作を生成する研究も進み、環境への適応能力を高めた柔軟マニピュレーションが実現されつつある<sup>(51)</sup>。

バイオミメティクス（生体模倣技術）も、ロボティクスにおける重要な潮流である。これは生物の持つ優れた構造や仕組みを模倣し、工学システムに応用するアプローチを指す。ロボティクスでは、動物の運動機構や筋骨格構造を模した設計、あるいは生物の持つ素材や表面構造の機能を取り入れた研究が盛んである<sup>(52)</sup>。生物由来のアイデアは、従来の機械にはない柔軟性や適応性をロボットにもたらしている。さらに、生体の筋肉のように伸縮特性を持つ人工筋肉と呼ばれるアクチュエータを用いれば、人間の関節のように剛性を状況によって変化させることも可能である。研究例として、人工筋の配置によって関節剛性を制御することで、歩行と走行を切り替えられる二足ロボットの開発報告もある。このような可変剛性機構は、生物が状況に応じて関節の硬さを調節し安定性と機動性を両立していることをヒントにしたものである。

近年のロボティクス研究においては、柔軟素材によるソフトロボット、AIによる学習制御、生体模倣デザインなどが融合しつつある。柔軟な身体を持つロボットは、未知の環境下で自ら身体を変形・適応させることで、新しいタスク遂行能力を発揮する。例えばタコの腕に着想を得た柔軟アームロボットは、狭い隙間に入り込んで作業したり、壊れやすい物体を優しく包み込んでつかんだりすることができる。また、生物の巧みな運動制御に学び、ロボットに自発的なリズムミカルな運動信号を発生させる中枢パターン発生器（CPG）的なアルゴリズムを組み込むことで、歩行リズムや反射的動作を実現する試みもある。総じて身体性知能とも呼ばれるアプローチにより、ロボットは剛硬な機械からしなやかな「生き物らしさ」を備えた存在へと進化しつつある。この進展は、ロボットが人間や複雑な現実環境と動的に関わり合うための基盤技術として重要であり、サービスロボットやヒューマノイドの発展にも密接に関わっている。

## 5 自律性と学習能力（強化学習、自己進化アルゴリズム）

従来のロボット工学は、あらかじめ定められた手順に従って動作する「自動化」を中心に発展してきた。しかし、ロボットやAIシステムが人間社会で主体的な役割を果たすためには、人間の介入なしに自ら状況を判断し、適切に行動できる能力、すなわち自律性を高い水準で備えることが求められるようになってきている。例えば、日本政府はムーンショット型研究開発制度における目標の一つとして、「2050年までに、AIとロボットの共進化により、自ら学習・行動

(51) Z. Li et al., “Adaptive Impedance Control of Human–Robot Cooperation Using Reinforcement Learning,” *IEEE Transactions on Industrial Electronics*, Vol.64 No.10, 2017.10, pp.8013-8022. <<https://doi.org/10.1109/TIE.2017.2694391>>.

(52) 井上健司「バイオミミクリー×ロボット 最先端研究室に潜入！」『事業構想 PROJECT DESIGN ONLINE』2013.4. <<https://www.projectdesign.jp/201304/mimi-bio-cree/000453.php>>

し人と共生するロボットを実現」を掲げており、人間のように自律的に判断・行動し、さらに自ら学習して成長できる AI ロボットの開発を国家的課題として位置付けている<sup>(53)</sup>。同様の方向性は海外の研究プロジェクトにも見られる。例えば、EU ではロボットが生涯にわたり経験から学ぶことで自律性を高めることを目指す PILLAR-Robots プロジェクトが進行中であり<sup>(54)</sup>、各国においても自律学習型ロボットの実現に向けた取組が加速している。こうした動きの背景には、少子高齢化による労働力不足や、災害現場・宇宙空間などの過酷環境での作業、人類の活動領域拡大といった社会的課題の解決において、自律的に活動できるロボットの存在が不可欠であるという認識の広がりがある。すなわち、人々は、ロボットが自律的に行動し、人間には困難な災害対応や宇宙探査、さらには日常生活支援において、人間に代わって柔軟かつ安全に任務を遂行し、人間の負担軽減と社会全体の効率化を実現することを期待していると言える。

一方で、ロボットが高い自律性を獲得するためには、未知の環境においても自ら学習し、状況に応じて柔軟に適應できる能力が不可欠である。従来のように、あらかじめ定められたルールやシナリオに基づいて全ての状況に対応させることは現実的ではない。そのため、ロボット自身が環境との相互作用を通じて経験を蓄積し、最適な行動方針を自律的に学習する仕組みが必要とされている。このような学習能力を実現するための有力な方法として、機械学習の分野では強化学習及び進化的アルゴリズムが注目を集めている(図4)。強化学習(Reinforcement Learning)は、試行錯誤を通じて「報酬」を最大化する最適な行動戦略を獲得する学習手法である。ロボットは、環境に対して様々な行動を試み、その結果として得られる報酬を手掛かりにして、次第に望ましい行動を学んでいく。近年では、ディープラーニングとの統合によって、複雑な状況認識や高度な意思決定を実現する手法として急速に発展している。進化的アルゴリズム(Evolutionary Algorithm)とは、生物が進化する様子をまねた計算方法である。始めに多くの解の候補を作り、それらを試しながらうまくいったものを次に残すことを繰り返す。このような試行錯誤を続けることで、複雑な問題に対しても少しずつより良い答えを見つけていくことができ、ロボット工学のみならず、設計の最適化などにも応用されている。これら二つの学習手法を組み合わせた AI システムは、従来のルールベース型システムを超え、未知の環境や予期せぬ事象に対しても柔軟に対応できる可能性を持つ。そこで本節では、自律性及び学習能力の観点から、強化学習及び進化的アルゴリズムの技術的展開とその応用動向について概説する。

### (1) 自律性の定義と発展

自律性とは、外部(他者)からの指示や制約を最小限に抑え、自ら設定した目標やルールに基づいて主体的に行動し、目的を達成する能力又は性質であると言える。ロボット工学の文脈では、日本機械学会が「作業環境や状況に適應し、自らの判断によって行動を決定・実行するロボットシステム」を自律ロボットと定義している<sup>(55)</sup>。1980年代までは、プログラムに従ってあらかじめ決められた動作を繰り返す自動ロボットが主流であったが、1990年代以降、セ

(53) 「ムーンショット目標3 AIとロボットの共進化により、自ら学習・行動し人と共生するロボットを実現」前掲注(48)

(54) “Purposeful Intrinsically Motivated Lifelong Learning Autonomous Robots: Fact Sheet (PILLAR-Robots プロジェクトファクトシート (Project ID: 101070381, 開始 2022 年 10 月)),” 2022. European Commission website <<https://cordis.europa.eu/project/id/101070381>>

(55) 「自律ロボット」日本機械学会編『機械工学事典』日本機械学会, 2017.

ンサ技術の高度化や人工知能（AI）による行動計画アルゴリズムの発展により、環境に応じて柔軟に行動を変える自律ロボットが登場した。

機械システムにおける自律性の分類には幾つかの枠組みが存在する。その代表例が、自動運転車の自律度を定めたSAEレベル（SAE J3016 SEP2016に準拠）<sup>(56)</sup>である。これは、自動車工学分野において国際的に広く参照されている工業規格の一つであり、レベル0（完全な手動運転）からレベル5（完全な自動運転）までの6段階が定義されている。また、近年ではAIエージェントの自律レベルについても議論が進められており、レベル0（人間が直接操作）からレベル5（人間は監視のみ）までの段階が提案されている<sup>(57)</sup>。これらの枠組みに共通するのは、「人間がどの程度関与するか」と「システムがどの程度自律的に判断・行動できるか」という二つの観点から自律性を整理している点である。この観点からすれば、以降で扱う学習能力は自律性を規定する鍵となる要素であり、より高い自律性を持つシステムほど、自ら環境から学んで適応する能力が不可欠であると言える。

## (2) 強化学習の概要

強化学習は、学習者（エージェント、例えばロボット）が環境との相互作用を通じて報酬を最大化する行動方策を学習する枠組みである<sup>(58)</sup>。エージェントは環境に対して行動を選択し、その結果として報酬と新たな状態を受け取り、この過程を繰り返すことで環境に適応した行動戦略を獲得していく（図4(a)）。このような特徴から、強化学習は未知環境におけるロボットの自律行動学習手法として注目されている。

強化学習の特徴は、教師データ（あらかじめ与えられた正解）が存在せず、報酬という評価のみを手掛かりに学習が進む点にある。エージェントは短期的な報酬にとらわれず、長期的な累積報酬を最大化するように行動を選択し、成功や失敗の経験を基に方策を改善する。この「試行錯誤による学習」は、動物の学習になぞらえることができ、人間の学習過程にも近い直感的なモデルである。例えば、子どもが自転車の練習を通じてバランスの取り方を覚える過程や、動物が報酬（エサ）を得るために行動を調整する過程は、強化学習の原理と対応している。数理的に見ると、強化学習はマルコフ決定過程（Markov Decision Process: MDP）の枠組みに基づいて定式化される。MDPでは、現在の状態と行動が次の状態を確率的に決定し、将来の報酬を割引因子（未来の報酬を現在よりも低く評価する係数）を用いて評価する。エージェントの目的は、この報酬の総和（累積報酬）を最大化するような行動方策、すなわち「どの状態でどの行動をとるか」を定めるルールを見つけることである。

強化学習の発想は、20世紀初頭の動物行動学における報酬に基づく学習の考え方にまで遡ることができる。その代表的な理論の一つとして、後にオペラント条件付けが体系化された。一方、計算機科学の文脈では、1950～60年代に発展した最適制御理論や動的計画法がその源流に位置付けられる。これら二つの系譜は当初独立して発展していたが、1970年代後半から1980年代にかけて、動的計画法の枠組みを学習に結びつける研究が進展した。特に、リチャー

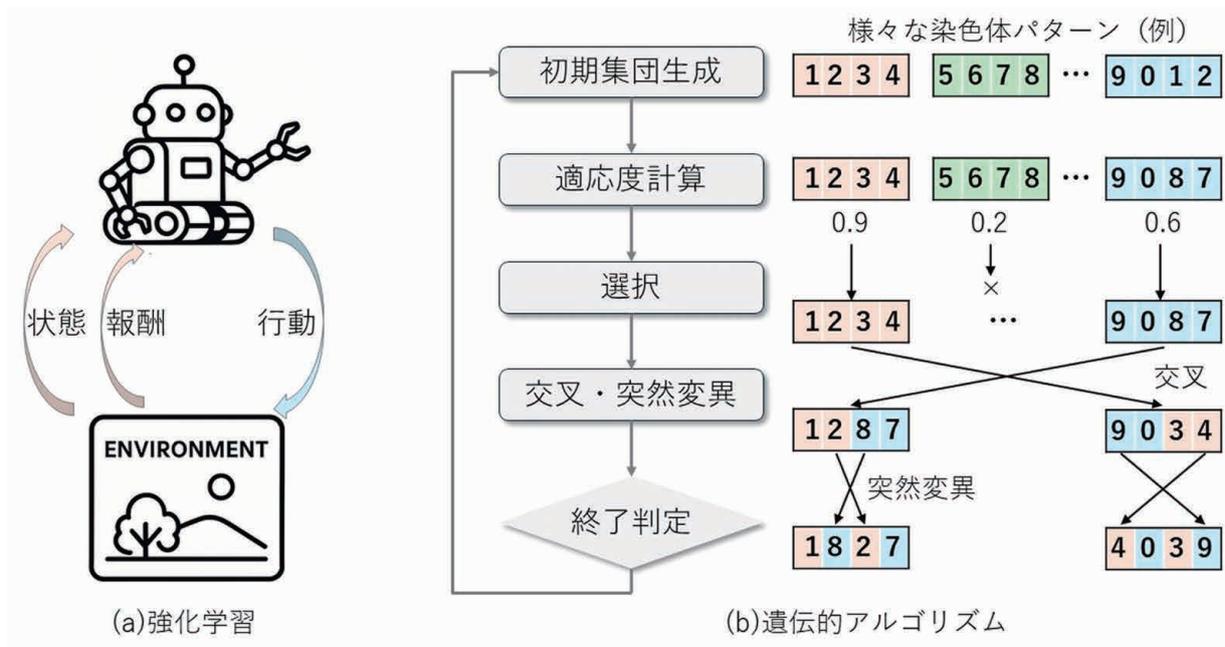
(56) SAE International, *Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles (J3016)*, 2021.4.30. <[https://www.sae.org/standards/content/j3016\\_202104/](https://www.sae.org/standards/content/j3016_202104/)>

(57) K. J. Kevin Feng et al., "Levels of Autonomy for AI Agents," 2025. <<https://arxiv.org/abs/2506.12469>>

(58) 森村哲郎「強化学習一般」『人工知能』37(4), 2022.7, pp.455-463. <[https://www.jstage.jst.go.jp/article/jjsai/37/4/37\\_455/\\_article/-char/ja](https://www.jstage.jst.go.jp/article/jjsai/37/4/37_455/_article/-char/ja)>

ド・サットン (Richard Sutton) による時系列差分 (Temporal Difference: TD) 学習や、ポール・ワーボス (Paul Werbos) のヒューリスティック動的計画法などが、報酬に基づく学習と最適制御を理論的に接続する契機となった。さらに1989年には、クリストファー・ワトキンス (Christopher Watkins) が環境モデルを用いずに状態と行動の価値を学習する Q 学習 (Q-Learning) を提案し、これにより報酬による学習と最適制御理論の統合が本格的に達成された<sup>(59)</sup>。その後、2010年代には DeepMind による Deep Q Network (DQN) の成功を契機として、深層学習と組み合わせた深層強化学習が急速に発展し、ゲームやロボット制御など多様な分野で人間を凌駕 (りょうが) する性能を示す AI が登場した。特に、2016年、DeepMind が開発した AlphaGo が囲碁の世界チャンピオンに勝利したことは、強化学習の歴史的転換点であった<sup>(60)</sup>。従来の囲碁 AI が大量の棋譜データに基づく教師あり学習に依存していたのに対し、AlphaGo は自己対戦による強化学習を通じて、人間の知識を超える戦略を自ら獲得した。この成果は、「AI が自己学習によって人間トップを超えた」初めての事例として、強化学習の潜在力を世界に示したと言える出来事となった。

図4 強化学習と遺伝的アルゴリズムのイメージ



(出典) 筆者作成。

### (3) 強化学習の自律ロボットへの応用

2016年のAlphaGo以降、強化学習はゲーム領域を超え、ロボットや産業システムなどの実世界タスクへの応用が急速に進展している。特にロボット制御分野では、物理シミュレータ上でエージェントに運動方策を学習させ、その知識を実機ロボットに転移する Sim-to-Real (シ

(59) Richard S. Sutton and Andrew G. Barto, *Reinforcement Learning: An Introduction*, 2nd ed., Cambridge, Massachusetts: MIT Press, 2018. <<https://web.stanford.edu/class/psych209/Readings/SuttonBartoIPRLBook2ndEd.pdf>>

(60) *ibid.*

ミュレータから実機への転移) 技術が注目されている<sup>(61)</sup>。DeepMind は仮想環境内で二足歩行ロボットや多脚ロボットの運動を強化学習によって獲得させる研究を行い、高速歩行や障害物回避などの高度な運動制御を実現した<sup>(62)</sup>。また、強化学習のためのオープンソース開発環境の整備が進んだことで、研究者が容易に仮想ロボットを用いた実験を行える基盤が確立し、分野全体の発展を後押ししている。一方で、実機ロボットへの応用においては、物理シミュレータと現実環境のわずかな差異（摩擦係数やセンサノイズなど）が方策の破綻を招くパフォーマンスギャップが存在する。これに対処するため、学習時に環境パラメータをランダムに変化させて汎化性能を高める方法や、複数環境への転移を考慮した学習手法が提案されている。

強化学習は、「自らの経験から学ぶ AI」を実現する中核技術として、ゲームやロボットのみならず、工業や金融、医療などの幅広い領域への応用が進められている。しかし同時に、サンプル効率の低さ（膨大な試行回数の必要性）や安全性・説明可能性の不足、ハイパーパラメータ調整の困難さといった課題も依然として残されている。これらの課題に対処するためのアプローチの一つとして、以降で紹介する進化的アルゴリズムとの統合が注目されており、探索効率や学習安定性の向上を目指した研究が活発に行われている。

#### (4) 自己進化アルゴリズムの概論

進化的アルゴリズムとは、生物の進化プロセスを模倣し、適者生存の原理に基づいて解の探索と改良を行うアルゴリズムの総称である。代表的な手法として、遺伝的アルゴリズム (Genetic Algorithm: GA)、遺伝的プログラミング (Genetic Programming: GP)、進化戦略 (Evolution Strategy: ES)、及び差分進化 (Differential Evolution: DE) が挙げられる。基本的な考え方は共通しており、まず複数の解（ポピュレーション）を生成し、その中から評価の高い個体を選択する。次に、それらの組合せ（交叉（こうさ））や変異によって多様化させ、次世代の候補を作り出す（図 4(b)）。この過程を繰り返すことで、世代を重ねるごとに解が洗練され、より良い解へと進化していく<sup>(63)</sup>。1970 年代にジョン・ホランド (John Holland) が提唱したビットストリング GA は、その嚆矢（こうし）とされる。解を 0 と 1 のビット列で表現し、優れた個体同士のビット列を交叉して次世代を生成するもので、「良い解の部分を受け継がせれば、より良い解が得られる」という仮定に基づいている。この考えにより、進化の過程を通じて最適解へと近づくことが期待される。

進化的アルゴリズムは、多くの解の候補を同時に試し、その中からうまくいったものを残すことを繰り返して解を探す方法である。強化学習ではエージェントが環境の中で行動を少しずつ調整しながら学習していくのに対し、進化的アルゴリズムでは解そのものを直接比較・選択する点が大きく異なる。このため、解の良し悪しを判定できさえすれば、問題の内部構造や詳細な数式を与えなくても適用できるという特徴がある。その結果、複雑でルールを明示しにくい問題や、試行錯誤を通じてしか評価できない問題にも柔軟に利用できる。

(61) W. Zhao et al., “Sim-to-Real Transfer in Deep Reinforcement Learning for Robotics: a Survey,” *2020 IEEE Symposium Series on Computational Intelligence (SSCI)*, 2020, pp.737-744. <<https://doi.org/10.1109/SSCI47803.2020.9308468>>

(62) N. Heess et al., “Emergence of Locomotion Behaviours in Rich Environments,” 2017. <<https://arxiv.org/abs/1707.02286>>

(63) 萩原将文ほか編「知識の森 S3 群 4 編 ソフトコンピューティングとニューラルネットワーク」電子情報通信学会ウェブサイト <[https://www.icice-hbkb.org/portal/s03/s03\\_04/](https://www.icice-hbkb.org/portal/s03/s03_04/)>

### (5) 自己進化アルゴリズムの自律型ロボットへの応用

前項で述べた進化的アルゴリズムは、ロボット工学の分野でも独自の応用が進められている。特に「進化ロボティクス (Evolutionary Robotics: ER)」と呼ばれる研究分野<sup>(64)</sup>では、ロボットの動き方 (行動方針) や機体の形を進化計算によって自動的に設計する試みが行われてきた。例えば、ロボットの歩き方を遺伝的アルゴリズムで進化させる研究では、環境や速度の違いに応じて効率よく動く様々な歩行パターンが生まれることが確認されている<sup>(65)</sup>。このように、人間が一つ一つプログラムを書かなくても、ロボット自身が試行錯誤しながら動作を学習することができる。ロボットの構造や制御系の設計に応用した研究では、ロボットアームの関節の長さや配置を進化計算で最適化し、特定の作業に合った形を自動で作る研究<sup>(66)</sup>などがある。また、ドローンの部品の組合せや機体寸法を遺伝的アルゴリズムで調整して推進効率を高める研究<sup>(67)</sup>なども報告されている。さらに、ロボットの形 (構造) と動き (制御) を同時に進化させ、得られた設計を3Dプリンタで実際に作ることで、自動設計・自動製造を実現した研究もある<sup>(68)</sup>。このように、進化計算は「形」と「動き」の両方を同時に進化させる共進化を通じて、ロボットをより自然に進化させる新しい設計手法として発展している。

AIとロボットの融合分野では、ニューラルネットワークそのものを進化させる「神経進化 (Neuroevolution)」という研究も盛んに行われている<sup>(69)</sup>。神経進化では、ネットワークの重みや構造を遺伝的アルゴリズムで自動的に改良し、強化学習では見つけにくい新しい行動パターンや戦略を発見できる場合がある。代表的な手法「NEAT」では、ネットワークの構造を少しずつ複雑にしながら学習を進め、複雑な動作や環境への適応を可能にしている。

一方で、進化的アルゴリズムにも課題がある。強化学習では一体のロボットが何度も練習しながら行動を少しずつ改善していく方法であるのに対し、進化的アルゴリズムでは多くの解の候補を同時に試し、良いものだけを残す方法である。そのため、同時に評価する候補数が多い進化的アルゴリズムでは計算時間が長くなる場合がある。また、多数の候補解を同時に評価するという性質上、実際のロボットで直接試行を行う場合には、安全性やコストの面で問題が生じる。そのため、多くの場合はシミュレータ上で進化を行い、得られた結果を実機ロボットに転移する手法が採られている。さらに、進化的アルゴリズムによって得られた解は、環境条件の変化に対する適応性が限定的となることもあり、その点では環境から継続的に学習できる強化学習の方が有利な場合もある。このような背景から、近年では両者を組み合わせた統合的手法の研究が進められている。

(64) J. A. Meyer et al., "Evolutionary Robotics: A Survey of Applications and Problems," P. Husbands and J.A. Meyer, eds., *Evolutionary Robotics* (Lecture Notes in Computer Science Vol.1468), Berlin, Heidelberg: Springer, 1998. <[https://doi.org/10.1007/3-540-64957-3\\_61](https://doi.org/10.1007/3-540-64957-3_61)>

(65) G. S. Hornby et al., "Autonomous evolution of dynamic gaits with two quadruped robots," *IEEE Transactions on Robotics*, Vol.21 No.3, 2005.6, pp.402-410. <<https://doi.org/10.1109/TRO.2004.839222>>

(66) G. S. Hornby et al., "Generative representations for the automated design of modular physical robots," *IEEE Transactions on Robotics and Automation*, Vol.19 No.4, 2003.8, pp.703-719. <<https://doi.org/10.1109/TRA.2003.814502>>

(67) V. M. Arellano-Quintana et al., "Multirotor design optimization using a genetic algorithm," *2016 International Conference on Unmanned Aircraft Systems (ICUAS)*, 2016, pp.1313-1318. <<https://doi.org/10.1109/ICUAS.2016.7502564>>

(68) J. B. Pollack et al., "First Three Generations of Evolved Robots," T Gomi, ed., *Evolutionary Robotics. From Intelligent Robotics to Artificial Life* (Lecture Notes in Computer Science Vol.2217), Berlin, Heidelberg: Springer, 2001. <[https://doi.org/10.1007/3-540-45502-7\\_3](https://doi.org/10.1007/3-540-45502-7_3)>

(69) K. O. Stanley and R. Miikkulainen, "Evolving Neural Networks through Augmenting Topologies," *Evolutionary Computation*, Vol.10 No.2, 2002.6, pp.99-127. <<https://doi.org/10.1162/106365602320169811>>

## 6 技術的課題

高度に自律的な強化学習エージェントや進化型 AI を実社会に実装するにあたり、幾つかの技術的課題が存在する。

### (1) 安全性と信頼性

自律的に学習・行動するシステムでは、予期せぬ動作や暴走を防ぐ安全対策が最も重要である。強化学習エージェントは報酬を最大化しようとする過程で、意図しない行動をとる可能性がある。これは、報酬の設計に起因する「報酬ハッキング (Reward hacking)」と呼ばれる問題である。例えば、ロボットアームに作業時間の短縮のみを報酬として与えた場合、衝突や過大な力を伴う動作によって、機器や人間を損傷させる行動が選択されることがある。特に物理世界で動作するロボットにおいては、学習中の事故や機器損傷は致命的であり、安全制約の下で学習を行う「安全強化学習 (Safe RL)」や、安全性を優先した方策探索の研究が進められている。また、強化学習や深層学習のモデルは内部構造が複雑で、人間がその判断過程を直接理解しにくいという「ブラックボックス問題」を抱えている。自律システムが社会に受け入れられるためには、行動の根拠をある程度説明できる説明可能性 (Explainability) や、動作の予測可能性 (Predictability) が求められる。この課題に対しては、行動を選択する AI モデルの可視化手法や、記号的ルール (「もし～ならば～する」といった形で表現された人間が理解しやすい規則) を取り入れるハイブリッド AI の一種であるニューロシンボリック AI などが提案されている。

### (2) サンプル効率と計算コスト

強化学習では、エージェントが環境と多数の試行を繰り返して学習を進めるため、膨大な試行回数と多大な計算コストが必要となる。シミュレーション上で数百万回の試行を行ってようやく成果が得られる場合もあり、実世界で同様の試行を行うのは現実的でない。このため、近年ではオフライン強化学習 (既存データからの学習) や模倣学習 (人間の熟練者の行動を模倣する手法) など、データを効率的に活用する研究が進展している。

### (3) 大規模化とスケーラビリティ

ディープラーニング技術の発展に伴い、強化学習エージェントのモデル規模や使用データ量は急速に増大している。複数のエージェントを同時に動作させる分散学習や大規模並列実験が可能になった一方で、膨大な計算資源と複雑なシステム設計が求められるようになった。分散強化学習では、学習の安定化、通信コストの削減、経験データの効率的共有などが技術的課題として挙げられる。また、モデルの巨大化に伴い、一部では LLM と強化学習を統合する試みも進められているが、安定性や汎用性の観点ではまだ課題が残っている。今後は、計算負荷を抑えつつスケールアップを実現するための新しい学習フレームワークの確立が求められている。

## おわりに

本章では、ロボティクスと人工知能 (AI) の発展が互いに歩んできた軌跡と、その融合によってもたらされた知能化のパラダイムシフトを概観した。1950 年代の機械制御・自動化に始ま

るロボティクスは、人間の作業を正確に模倣する技術として発展し、産業の自動化・効率化を支える中核的基盤を形成してきた。一方で、AIは人間の知的活動を数理的に再現しようとする試みから出発し、ニューラルネットワーク、機械学習、そして深層学習の発展を経て、知覚・推論・言語理解の分野で飛躍的な進歩を遂げた。これら二つの技術領域は、当初は独立して進化していたが、21世紀に入りセンサ・計算資源・データ環境の拡充とともに融合を果たし、AIロボットという新たな知的システムを生み出すに至った。

特に、深層学習とコンピュータビジョンによる環境認識、自然言語処理による言語理解、強化学習による行動最適化、さらには進化的アルゴリズムによる自律的適応は、ロボットに「見る」「聞く」「判断する」「学ぶ」「成長する」能力を与えた。さらに、マルチモーダルAIやエンボディドAIの台頭は、視覚・言語・運動を統合的に扱う新たな知能の形を提示しており、人と共生しながら柔軟に行動できるロボット像を現実のものとしつつある。すなわち、ロボットはもはや単なる機械ではなく、学習と身体性を備えた自律的存在へと進化している。

しかし同時に、自律型ロボットの社会実装に向けては、安全性・信頼性・説明可能性など、技術を超えた多面的な課題も浮き彫りとなっている。今後は、AIの汎用知能化とロボットの身体知能の両立を図るとともに、人間側にもそれらを適切に理解し活用する能力（リテラシー）の向上が不可欠となる。

（湯口 彰重、早川 智彦、橋本 卓弥）