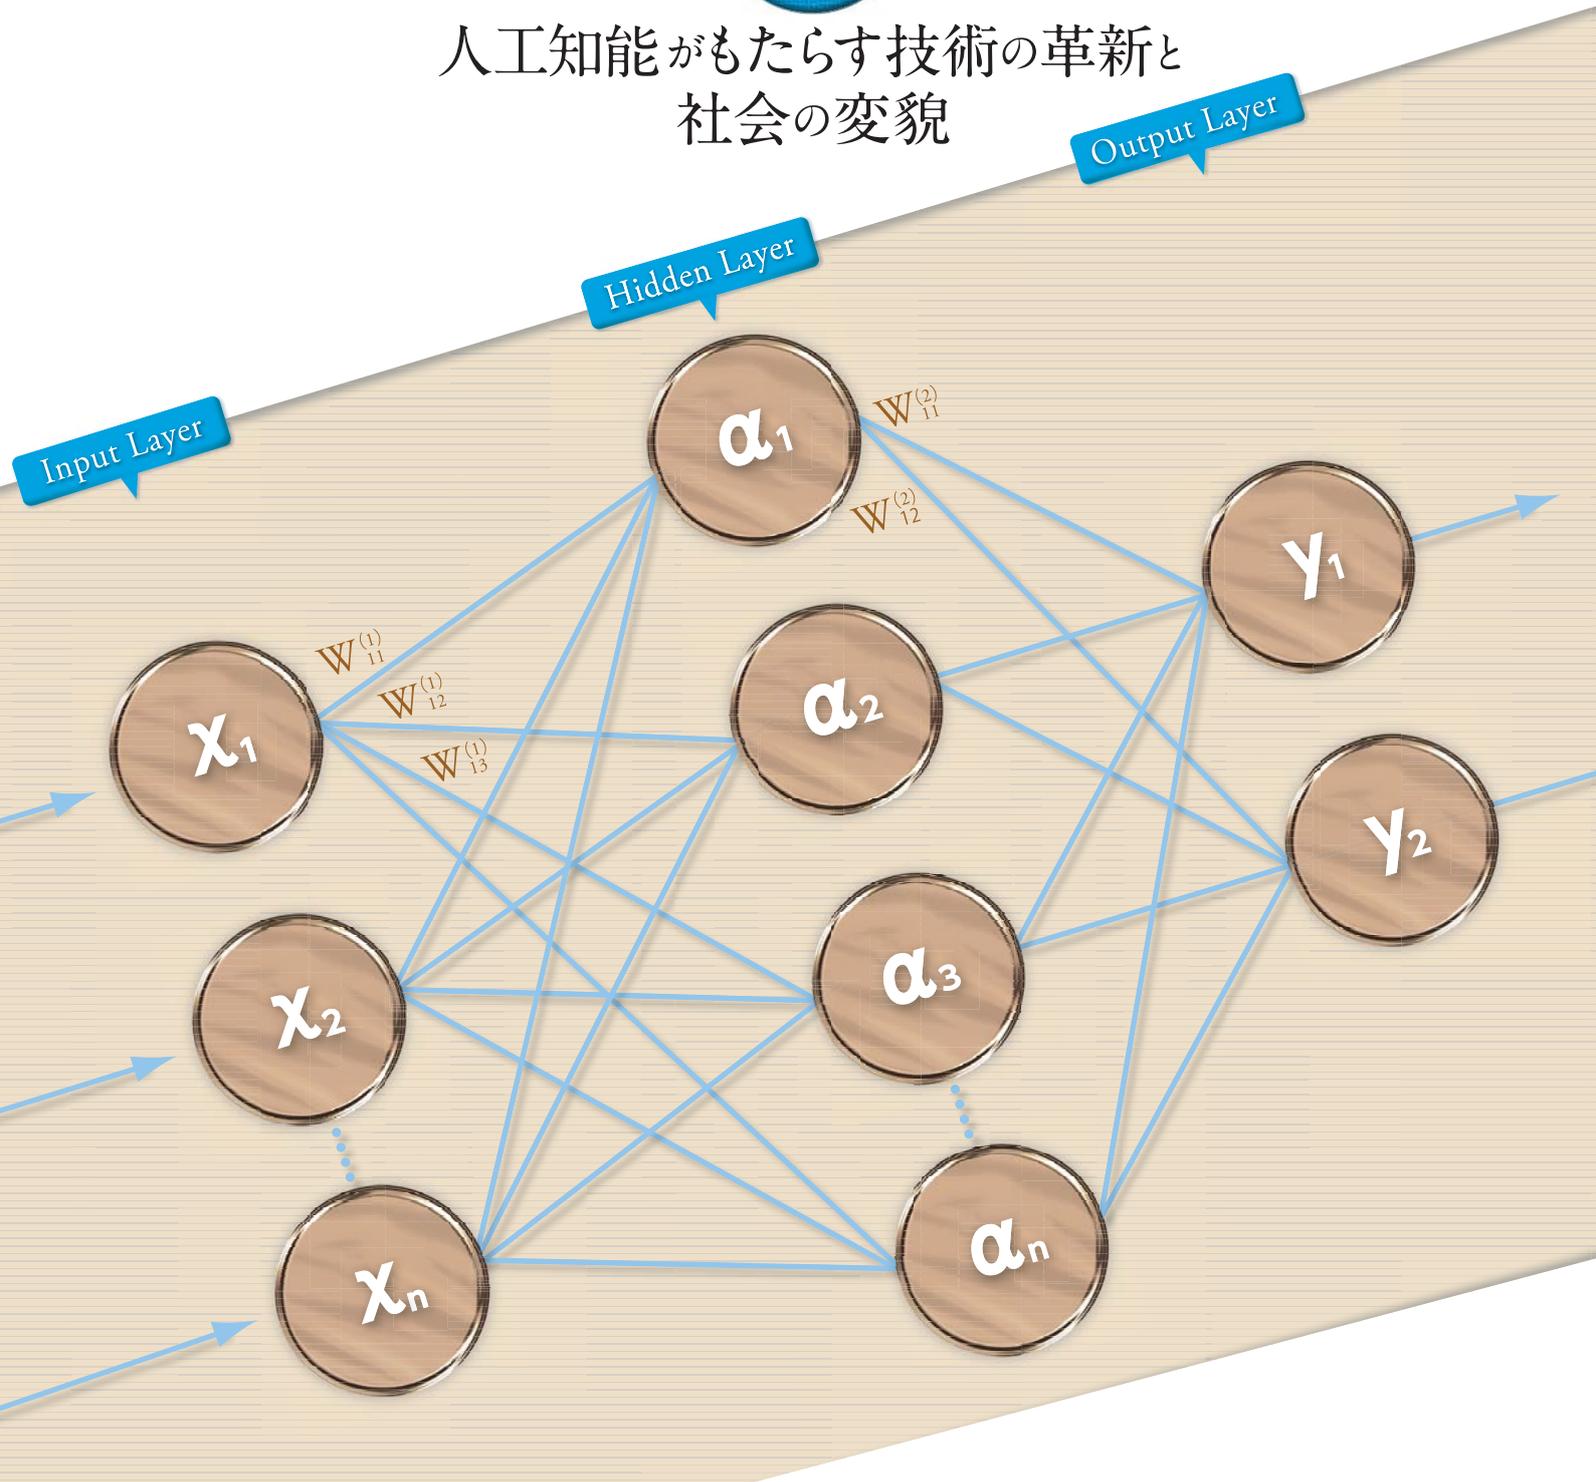


# AI 白書

Artificial Intelligence White Paper

2017

人工知能をもたらす技術の革新と  
社会の変貌



# 刊行にあたって

今、世界は人工知能のブームの只中にあるといっても過言ではない程、メディアを毎日のように賑わせています。人工知能によって世界が大きく変わることが期待されています。

人工知能はこれまでも何回かのブームはありましたが、一時的な流行に終わり、社会に大きな変革をもたらすことはありませんでした。しかし、研究としては続けられ、計算機能力の飛躍的な向上、スマートフォンやセンサの普及による大量データの入手の容易性が加わり、さらにはディープラーニングの登場により大きなブレークスルーが起きたと考えられます。

しかし一方で、ブームにありがちな、技術の正しい理解をしないままの様々な誤解が生じています。人工知能があれば何でも簡単に答えが出せると思っている人もいれば、人工知能によって人間の仕事が奪われると拒否反応を起こす人もいます。こうした多くの誤解や思い込みをそのままにしておくと、安易な利用によりうまくいかないケースや、できることも敬遠して利用が進まない状況に陥ります。そうこうするうちに、海外勢による人工知能を利用した新ビジネスが世の中を席卷してしまうことにもなりかねません。まずは、正しい技術の理解と関連情報について、わかりやすく解説した書物が必要ではないかということになりました。そうした背景のもとで、このたび、人工知能に関わる多くの著名な先生方、関係者のご協力を得て、『AI白書 2017』を刊行する運びとなりました。

本書は技術の専門書ではありません。技術そのものに関心のある方には専門書が今、たくさん出ていますので、そちらを探されることをお勧めします。むしろ、正しい技術理解を踏まえて、歴史的な推移を含めた技術動向の今と未来、人工知能の利用動向、人工知能によってどんな素晴らしいことが可能になるのかの実例紹介、人工知能に関わる制度的基盤や国内海外の政策動向といった、人工知能をとりまく全体像を理解して頂くことを目的としています。本書により、一人でも多くの方が人工知能というものについての正しい理解をされ、人工知能を正しく利用される方が増えていくことで、産業が活性化し、日本発の、社会にイノベーションを起こすようなビジネスが多く生まれていくことを期待しています。

最後に、本白書を取りまとめるにあたって、調査や執筆のご協力をいただいた皆様や、編集委員会において、ご尽力いただいた皆様方に対し、心から敬意を表するとともに、厚くお礼申し上げます。

I P A（独立行政法人情報処理推進機構）

理事長

富田 達夫



# 巻頭言

---

## ディープラーニングが起爆剤となった、三度目のAIブーム

2017年はAIの年と言って良いほど、AIブームの真っ只中である。このブームは深層学習（ディープラーニング）の成功が起爆剤になっている。それまでは10年以上先のことと思われていた、コンピュータ囲碁のプロ棋士に対する勝利が報告された2016年から、この動向は急速に顕著になった。これはAIの三度目のブームと言われている。三度目の正直ではないが、今回は定着すると我々は考えている。

前回のAI白書が作られたのは1994年（『AI白書〈1994〉人工知能の技術と利用』通商産業省機械情報産業局電子政策課 監修、日本情報処理開発協会 編）、ちょうど二度目のAIブームの頃である。このブームは、日本で第五世代コンピュータプロジェクトが走っていた1980年代から1990年代とほぼ一致する。当時、人間の熟練者の知識をAIに移植するエキスパートシステムの研究が盛んであった。しかしながら、実用には至っていない。その最大の理由は、人間は言語化できない知識（暗黙知）を持っているからである。その部分を書き下せないため、コンピュータプログラムに移せなかったのである。

現在、深層学習という手法が実用化され、この暗黙知の部分を学習できる可能性が出て来た。ちょうど、人間が弟子入りして先輩たちの熟練の技を見ながら会得するようなことが、コンピュータにできるようになってきた。プログラムとして明示しなくてよいのである。従来型の記号知識と深層学習を組み合わせることにより、AIの発展の可能性が見えてきた。

---

深層学習の進化は急速である。昨年使った講義資料は、今年は古くてもう使えない。変化は技術だけではない。AIが新しいステージに入ったことで技術革新が加速され、社会の仕組みが急激に変わろうとしている。この時期にAI白書を纏める意義は、大きいと考える。

この白書は時機を逸しないため、約4か月という、通常ではありえないような短期間で仕上げることになった。日本の金融工学の先駆けである今野浩氏による『工学部ヒラノ教授』（新潮文庫）という本に、「工学部の教え7箇条」というのが出ている。「第1条 決められた時間に遅れないこと（納期を守ること）」に始まり、「第7条 拙速を旨とすべきこと」で終わるものであるが、この第7条が特に重要だと考えている。

芸術に限らず、ほとんどの仕事は完成度を追求すればキリがない。本白書もこの方針に則り、拙速を旨とさせていただいた。時機を逃さないことが最重要と考えたからである。言うまでもないことだが「拙」を目指したのではない。「速」を最重視したのである。1年後に白書を編纂すると、今回とはまた異なった風景が見えているに違いない。

AI白書 2017 編集委員会 委員長

中島 秀之



# 目次

|                                 |           |
|---------------------------------|-----------|
| 刊行にあたって                         | 1         |
| 巻頭言                             | 2         |
| 目次                              | 4         |
| 本書のポイント                         | 8         |
| <b>第1章 技術動向</b>                 | <b>15</b> |
| 1.1. “ディープラーニング” がAIを大きく変えた     | 16        |
| 1.1.1. AIの研究動向とディープラーニングの登場     | 16        |
| 1.1.2. ディープラーニングによる生成モデルの可能性    | 18        |
| 1.1.3. 知能の全体像                   | 19        |
| 1.1.4. ロボット研究の難しさとチャンス          | 22        |
| 1.1.5. 産業にとっての重要性               | 24        |
| 1.1.6. ディープラーニングに基づく記号の意味理解に向けて | 25        |
| 1.1.7. 本章の構成                    | 27        |
| 1.2. ディープラーニングによるパターン認識の進展      | 29        |
| 1.2.1. 総論                       | 29        |
| 1.2.2. 機械学習                     | 31        |
| 1.2.3. ディープラーニング                | 33        |
| 1.2.4. 畳み込みニューラルネットワーク          | 35        |
| 1.2.5. リカレントニューラルネットワーク         | 38        |
| 1.2.6. 表現学習                     | 39        |
| 1.2.7. ディープラーニングの画像認識への応用       | 41        |
| 1.2.8. ディープラーニングの音声認識への応用       | 42        |
| 1.2.9. ディープラーニングの芸術への応用         | 44        |
| 1.2.10. ディープラーニングの実現技術          | 46        |
| 1.3. 身体性と知能の発達                  | 48        |
| 1.3.1. 総論                       | 48        |
| 1.3.2. 身体性の意味と役割                | 50        |
| 1.3.3. 知能の発達の設計                 | 52        |
| 1.3.4. 認知発達ロボティクス               | 54        |
| 1.3.5. 構成的発達科学                  | 57        |
| 1.3.6. ロボット学習としてのディープラーニング      | 58        |

|        |                         |     |
|--------|-------------------------|-----|
| 1.3.7. | 歴史的経緯と国内外の研究動向          | 60  |
| 1.4.   | 自然言語を中心とする記号処理          | 64  |
| 1.4.1. | 総論                      | 64  |
| 1.4.2. | 自然言語の構造解析技術             | 65  |
| 1.4.3. | 自然言語の意味・知識理解技術          | 68  |
| 1.4.4. | 自然言語の生成技術               | 74  |
| 1.5.   | ビッグデータ時代の知識処理           | 79  |
| 1.5.1. | 総論                      | 79  |
| 1.5.2. | データと知識ベース               | 80  |
| 1.5.3. | Linked Open Dataとオントロジー | 83  |
| 1.5.4. | 統計モデル                   | 85  |
| 1.6.   | 社会とコミュニティ               | 88  |
| 1.6.1. | 総論                      | 88  |
| 1.6.2. | マルチエージェントシミュレーションの概念    | 89  |
| 1.6.3. | マルチエージェントシステムの応用        | 91  |
| 1.6.4. | ロボカップレスキュー              | 98  |
| 1.6.5. | フィールドでの社会応用             | 102 |
| 1.7.   | 計算インフラを構成するハードウェア       | 105 |
| 1.7.1. | 総論                      | 105 |
| 1.7.2. | ディープラーニングで要求される演算の基本    | 107 |
| 1.7.3. | 学習用のインフラストラクチャと計算デバイス   | 109 |
| 1.7.4. | 推論用のインフラストラクチャと計算デバイス   | 121 |
| 1.7.5. | エッジ、フォグ、クラウドの役割の最適化     | 123 |
| 1.7.6. | 次世代AIインフラストラクチャ・ハードウェア  | 125 |
| 1.8.   | グランドチャレンジによる研究開発の推進     | 136 |
| 1.8.1. | 総論                      | 136 |
| 1.8.2. | ゲームとAIの進化               | 137 |
| 1.8.3. | ロボカップ                   | 141 |
| 1.8.4. | DARPAにおけるグランドチャレンジ      | 143 |
| 1.8.5. | AIによる科学的発見に関するグランドチャレンジ | 145 |
| 1.9.   | 各国の研究開発の現状              | 147 |
| 1.9.1. | 総論                      | 147 |
| 1.9.2. | 各国の政策・プロジェクトの現状         | 148 |
| 1.9.3. | 民間企業の研究開発の現状            | 155 |
| 1.9.4. | 特許・論文の動向                | 157 |

|            |                              |            |
|------------|------------------------------|------------|
| 1.10.      | 今後の展望                        | 160        |
| 1.10.1.    | 総論                           | 160        |
| 1.10.2.    | シンボルグラウンディングの段階的解決へ向けて       | 160        |
| 1.10.3.    | 汎用AIに向けて                     | 163        |
| <b>第2章</b> | <b>利用動向</b>                  | <b>167</b> |
| 2.1.       | 総論                           | 168        |
| 2.1.1.     | AIによって何がかわるか                 | 168        |
| 2.1.2.     | 基盤整備状況                       | 168        |
| 2.1.3.     | 今後の展望                        | 169        |
| 2.2.       | AIによって何がかわるか                 | 170        |
| 2.2.1.     | AIがもたらす産業への影響                | 170        |
| 2.2.2.     | ディープラーニングの産業応用               | 175        |
| 2.2.3.     | 産業別の利用動向                     | 187        |
| 2.3.       | 基盤整備状況                       | 214        |
| 2.3.1.     | 人材                           | 214        |
|            | 【寄稿】「AI×データ時代における人材要件と日本の課題」 | 221        |
| 2.3.2.     | 計算資源                         | 229        |
| 2.3.3.     | 標準化                          | 232        |
| 2.3.4.     | オープンソースソフトウェア                | 234        |
| 2.3.5.     | 共有データセット・共有モデル               | 235        |
| 2.4.       | 企業における利用状況                   | 241        |
| 2.4.1.     | アンケート調査概要                    | 241        |
| 2.4.2.     | アンケート調査結果                    | 242        |
| 2.5.       | 投資規模・市場規模                    | 247        |
| 2.5.1.     | 投資規模                         | 247        |
| 2.5.2.     | 市場規模                         | 249        |
| 2.6.       | 今後の展望                        | 253        |
|            | 【寄稿】「AI経営で会社は甦る」             | 254        |
| <b>第3章</b> | <b>制度的課題への対応動向</b>           | <b>263</b> |
| 3.1.       | 総論                           | 264        |
| 3.1.1.     | 知的財産                         | 264        |
| 3.1.2.     | 倫理                           | 265        |
| 3.1.3.     | 規制緩和・新たなルール形成                | 266        |
| 3.2.       | 知的財産                         | 267        |
| 3.2.1.     | 国内の動向                        | 267        |

|            |                           |            |
|------------|---------------------------|------------|
| 3.2.2.     | 海外の動向                     | 272        |
| 3.2.3.     | 今後の展望                     | 274        |
| 3.3.       | 倫理                        | 276        |
| 3.3.1.     | 背景                        | 276        |
| 3.3.2.     | 取組動向                      | 277        |
| 3.4.       | 規制緩和・新たなルール形成             | 284        |
| 3.4.1.     | 自動運転                      | 284        |
| 3.4.2.     | ドローン                      | 288        |
| 3.4.3.     | 健康・医療・介護                  | 289        |
| 3.4.4.     | 物・サービスへのニーズとのマッチングや効率化    | 292        |
| <b>第4章</b> | <b>政策動向</b>               | <b>295</b> |
| 4.1.       | 総論                        | 296        |
| 4.1.1.     | 国内の政策動向                   | 296        |
| 4.1.2.     | 海外の政策動向                   | 296        |
| 4.2.       | 国内の政策動向                   | 297        |
| 4.2.1.     | 人工知能技術戦略会議による研究開発、産業連携の推進 | 297        |
| 4.2.2.     | 関係府省における政策動向              | 302        |
| 4.3.       | 海外の政策動向                   | 321        |
| 4.3.1.     | 米国                        | 321        |
| 4.3.2.     | EU                        | 324        |
| 4.3.3.     | 英国                        | 326        |
| 4.3.4.     | ドイツ                       | 327        |
| 4.3.5.     | 中国                        | 329        |
| 資料編        |                           | 331        |
| 資料1.       | AIの取組状況に関するアンケート調査結果      | 332        |
| 資料2.       | 情報系教育機関におけるAI分野の教育動向調査    | 349        |
| 委員名簿       |                           | 357        |

# 本書のポイント

『AI白書 2017』は、全部で4つの章で構成される。

第1章でAIの最新技術動向を明らかにしたあと、第2章の利用動向ではその技術をもとにどのような利用が、すでになされているのか／考えられているのかを解説。第3章では知財などの制度面での課題とその対応の状況について、そして第4章では国内はもちろん、海外での政策面での取り組みを紹介する。

各章に記載されている内容のポイントを、以下で解説する。

## 第1章

# 「技術動向」

## ポイント

- 「ディープラーニング」（深層学習）の進展によって、音声・画像認識等のパターン処理では、人間を上回るレベルの認識精度が達成されつつある。
- ディープラーニングによる画像認識は「目」の技術であり、生物が目を得た時と同じく、ロボットや機械の世界でも“カンブリア爆発”的なインパクトになり得る。
- AI及び脳科学等の研究者層の厚みを背景とし、リアル空間のデータを持つ製造業の強みを利用したビジネス開発など、我が国の既存の強みを活かした戦略が求められる。
- ディープラーニングで必要とされる計算インフラの供給によって研究開発・産業応用を加速し、事業開発による利益創出と技術への再投資のサイクルを構築していくことが必要。

## 概要

### ディープラーニングによるAIの進展、ハードウェアの研究開発の活発化

AIの研究開発は、記号的処理の研究からスタートした。言語の発明と使用が、高度な知的社会を人間が構築できた理由であり、記号的処理からAIの研究がスタートしたのは自然な流れだ。だが、こうした方向においてはパターン処理がきわめて弱く、特に視覚的な入力の問題は顕著だった。けれども、ディープラーニングは画像認識や音声認識で大きなブレークスルーを起こした。人間の認識精度とほぼ同等、もしくは超えるという、目覚ましい精度向上が実現された。

このディープラーニングによる精度向上を受けて、機械学習用のハードウェアの研究開発も活発化している。特に、ディープラーニングで、ビッグデータに基づいた学習をさせる際には大規模な計算が必要となり、汎用のCPUとは異なる専用の計算用ハードウェアの開発も活発化している。

### パターン認識と記号的処理の融合に向けて

ディープラーニングを利用したとしても、現状においてすぐに汎用的なAIが実現するという訳ではな



## 囲碁AI「AlphaGo」が 世界最強のプロ棋士に勝利

Google DeepMindが開発したAI囲碁プログラム「AlphaGo」(アルファ碁)は、2017年5月、世界最強とも言われる中国のプロ棋士、柯潔(か けつ)と対戦。3番勝負で3連勝し、中国囲碁協会から名誉九段を贈呈された。(写真提供: Google)



く、継続的な研究開発が必要だ。今後のAIのソフトウェアに関する研究開発の方向性として、ディープラーニングを基盤的なアルゴリズムとして活用する記号的処理と、暗黙知の処理の統合が挙げられる。

ディープラーニングによる機械翻訳をはじめとして、推論や計画作成等、この方向性に沿った研究開発が萌芽的には存在している。AIの研究開発を支えるハードウェアの研究開発の方向性としては、既存のアーキテクチャのデバイスだけでなく、脳の仕組みを模倣することにより、計算速度向上や消費電力低減を図る試みが挙げられる。これらの研究開発の成果が相乗的に効果を発揮し、AIが継続的に発展していくことが期待されている。

今後、AIのどのような応用がどのような順番で実現していくかについては、必要とされる記号の意味がどの程度深いものであるかによって決まる。画像認識に代表されるパターン認識と、ロボットの動きの学習などは、さほど記号の深い意味に踏み込まずに処理できる領域であり、研究開発と社会実装が進むものと考えられる。その後については、記号の意味を実世界の事物へ関連付ける「シンボルグラウンディング」というハードルを乗り越えることが必要となる。

シンボルグラウンディングは、AI分野で長い間困難と認識されてきた課題であるが、ディープラーニングによる新しいアルゴリズムと、実世界や人間とのインターフェースを持つロボティクスの組み合わせにより、解決への糸口が見えて来たところである。

### 我が国の強みを活かした研究開発が期待される

ネット上のビッグデータに基づくディープラーニングへの取組については、米国等のIT企業が先行した。だが、今後必要となるのは、機械学習用のハードウェアやロボティクス等の、我が国が強みを持つ分野が威力を発揮し得る技術である。現在、経済産業省、総務省、文部科学省が連携して研究開発を推進しているところであり、AIの研究開発が大きく前進することが期待されている。

## ポイント

- AIの利用には、質の高い学習用データとそれから生成される優れた学習済みモデルが重要。
- 学習用データセット、学習済みモデル等を公開・共有し、集合知による加速度的な連鎖が生じている一方、それらを独占する、またAIをデータ獲得の武器として利用する動きも生じている。
- 自動運転や医用画像の診断支援等が先進事例。言葉の意味理解に基づく事業創出に向けて、さらなる環境整備（人材、計算資源、標準化等）が必要。
- IoTによって実空間から得られるデータが、AIの今後の競争領域。日本が各産業で保有する強みを活かして、実空間での競争優位を築くことが期待される。

## 概要

ディープラーニングによるAIの非連続的な革新は、様々な領域で高い成果をもたらしている

ビッグデータの増大とディープラーニングに代表される機械学習の革新により、従来は実現困難だった事業領域で、AIは高い成果をもたらしている。先端的なAI活用は、インターネット空間などの特定の分野における画像認識や音声認識の応用で先行していたが、ディープラーニングの機能を備えたクラウドサービスやオープンソースソフトウェア等の実用性の高いツールの登場により、健康・医療・介護、製造業、金融等の様々な産業や業務領域での適用が進行しつつある。

更に、昨今のビッグデータの増大は、統計的アプローチなど従来から利用されてきた手法の性能を飛躍的に向上させ、適用領域を拡大させている。

先行する企業は集合知のプラットフォームを形成、あるいは学習用データを独占

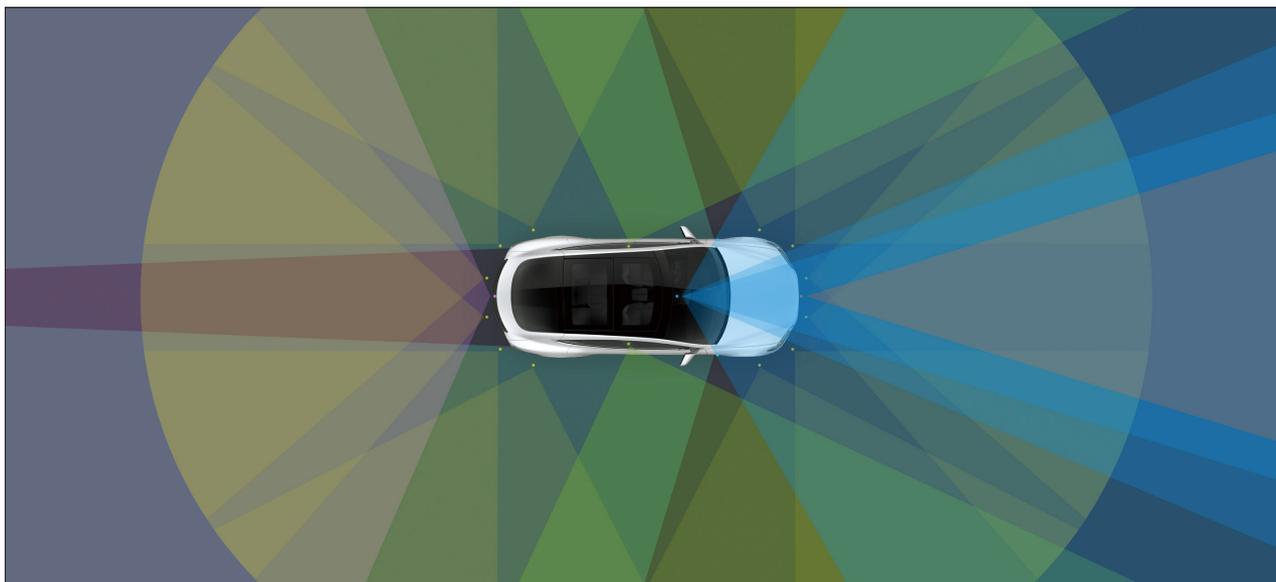
ディープラーニングに関するアルゴリズム、学習済みモデル、学習用データなど、自らが開発した技術やデータ等を公開し、その上に多様な研究者や技術者を集めて技術開発を加速させる集合知のプラットフォーム形成を進めることで、AIを有効に機能させようとする動きが見られる。一方、質の高い学習用データを獲得、独占することで企業の競争力を高める動きも進められている。将来の市場における優位なポジションを築くために、これらの動きは同時並行的に進むと予想される。

AI活用で米国・中国が先行する中、リアル空間でのAI活用が我が国の競争力向上の鍵となる

AIを牽引する企業は、米国のGoogleやAmazon、中国のBaidu、Tencentなど、インターネット空間を中心に勃興してきた企業である。これらの企業は、スピード感を持って市場にサービスを提供し、ユーザーからのフィードバックを受けながら改善を繰り返し、サービスの品質を向上することで競争優位を築いてきた。今後、AIは様々な実空間での産業に応用され、主戦場は自動運転や医療、介護などの人の命に関わる領域に移りつつある。こうした中、品質・安全性の追求や、ソフトウェアとハードウェア

ア間の機能をすり合わせるノウハウなど、日本が各産業領域で保有する強みを活かして競争優位を築く戦略が求められる。

## 自動運転を見据えて、すでに多数のカメラ・センサを装備



Teslaがオプションで提供する、レーダーと8台のカメラ、12個の超音波センサ。得られた情報をリアルタイムに処理できる車載コンピュータと、各所に設置されたこれらのカメラやセンサによって、車の全周をカバーする。将来の自動運転を見据えて、段階的にソフトウェアがアップデートされる予定とのこと。(写真提供：Tesla)

## ポイント

- AIの社会実装の推進にあたって、その存在を想定していなかった既存の法制度等との調和を図る必要がある。
- 「知性」という人間の本質に近いところで、「人間の代替」となる側面を持つAIへの不安や懸念に対して、リスクの整理、明確化と、それらへの対応の検討も課題。
- AIが自律的に生成したものは、多くの国の現行法では著作物として認められないが、人間の「創作意図」や「創作的寄与」があれば、著作物性が認められる。
- 自動走行システムのガイドラインの整備や、健康、医療・介護分野に関しては、匿名化等の加工をしたうえで個人データ共有の検討が行われている。

## 概要

AIの倫理的課題とその制度的対応の議論が、欧米中心に官民挙げて進展

学会やNPOで議論されてきたAIの倫理的課題とその対応について、2016年に入ってから、米国の主要なIT企業（Google、Amazon、Facebook、Apple、Microsoft、IBM等）が中心的な役割を担い、議論を進めている。また、米国、英国は政府や議会でもAIの倫理的課題に関する包括的な検討を実施し、その結果を公表している。更に、IEEEの「ETHICALLY ALIGNED DESIGN」やFLI（Future of Life Institute）の「ASILOMAR AI PRINCIPLES」といった、学界・産業界の幅広いメンバーが参画した団体からAI開発の原則に関する包括的な資料が公表されており、海外では産学官による検討が活発化している。

我が国においても議論は始まっているが、産官学による具体的な検討を加速し、産業応用に即した議論を深めることが求められている。

「AI創作物」や「学習用データセット」「学習済みモデル」の知財面での議論が進行中

AIが創作した音楽や文学作品が出始めている中で、現在の著作権法では保護の対象になっていないこのような「AI創作物」について、「AI創作」の判別可能性や量産性、ビジネス可能性を勘案した保護の在り方について検討が行われている。

機械学習のために、「学習用データ」として他人の著作物等を大量に解析することが著作権侵害か否かが、諸外国において議論されている。我が国の著作権法は平成21年改正によって、コンピュータ等を用いた情報解析のために行われる複製等を許容する、権利制限規定を有している（47条の7）。

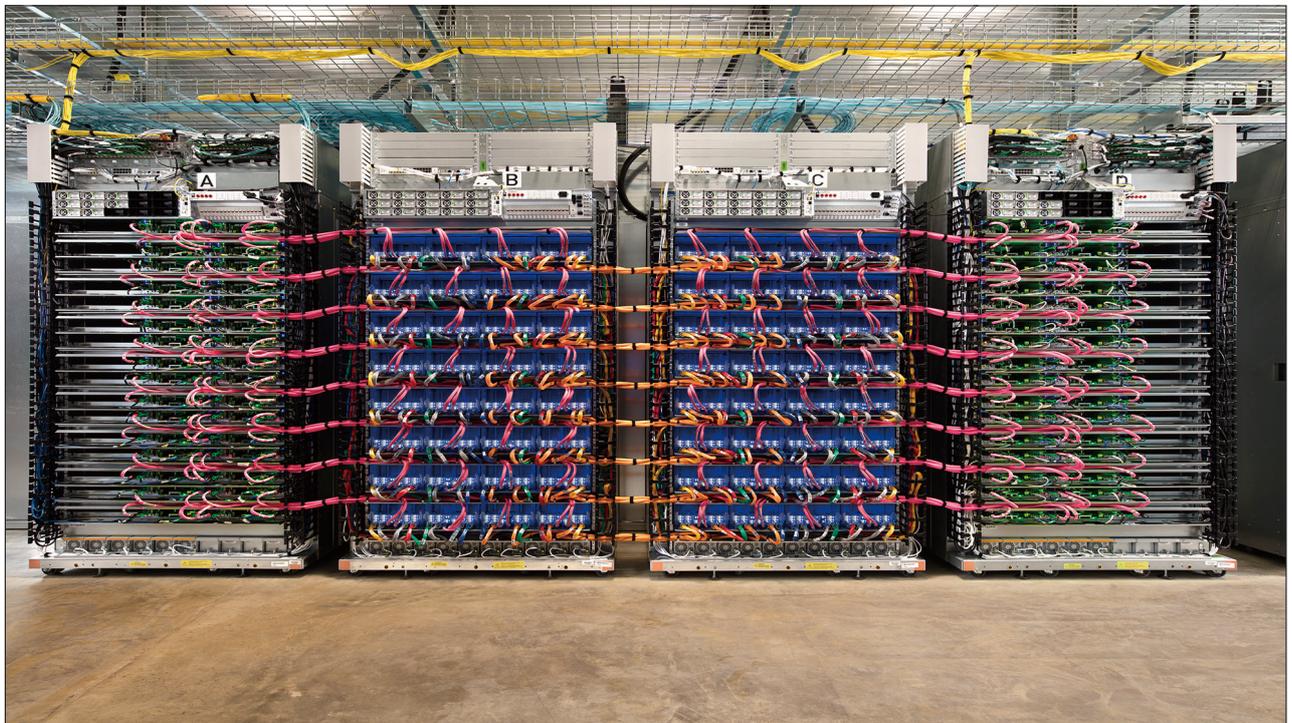
また、「学習済みモデル」の保護の在り方についても、著作権、特許、契約という様々な手段の中で実効性を勘案したビジネス基盤確立に向けた議論が進んでいる。

新たなルール形成が「自動運転」「ドローン」「健康・医療・介護」といった領域で取り組まれている

AIが実現のキーテクノロジーとなっている「自動運転」「ドローン」においては、既存の法体系との整合性を取るべく、法改正や運用ルールの確立に向けた活動が国内外で推進されている。また、健康・医療・介護分野ではAIの機能を十分に発揮できるデータの利活用に向けて、匿名化して活用する仕組みづくりや、パーソナルデータストア（PDS）等の新たな情報活用の仕組みの構築が取り組まれている。

更に、製造業、流通業、サービス業等における物・サービスへのニーズとのマッチングや効率化に向けたAIの活用に関しても、データの匿名化やデータ活用に関するガイドラインづくりが進みつつある。

## 演算回数ではスパコン「京」を超えるディープラーニング専用機



Googleのディープラーニング専用チップ「Cloud TPU」64個を相互接続した「TPUポッド」。演算能力は11.5PFLOPSで、精度は異なるものの、単純に演算回数の比較では、スーパーコンピュータ「京」を上回る。(写真提供：Google)

## ポイント

- AIの研究開発に関して、我が国では「人工知能技術戦略会議」が創設され、研究開発目標と産業化のロードマップの策定等が行われている。
- 米国では2016年に、AIに関わる研究開発戦略、社会的課題の整理・対応、経済的なインパクトの分析・対応の三つの包括的な報告書が発表された。
- EUでは、欧州全体研究開発プログラムである「Horizon2020」の中で、ドイツでは国策である「Industry 4.0」で、それぞれAIが重要な要素として位置づけられている。
- 中国では2016年にAI推進3か年行動計画が策定され、市場創出と研究開発、環境整備がうたわれている。

本白書の記載内容は、原則として2017年4月までの執筆、寄稿、事務局調査に基づく。

# 技術動向

- 1.1 “ディープラーニング”がAIを大きく変えた
- 1.2 ディープラーニングによるパターン認識の進展
- 1.3 身体性と知能の発達
- 1.4 自然言語を中心とする記号処理
- 1.5 ビッグデータ時代の知識処理
- 1.6 社会とコミュニティ
- 1.7 計算インフラを構成するハードウェア
- 1.8 グランドチャレンジによる研究開発の推進
- 1.9 各国の研究開発の現状
- 1.10 今後の展望

# 第1章

## 技術動向

### 1.1 “ディープラーニング”がAIを大きく変えた

#### 1.1.1 AIの研究動向とディープラーニングの登場

人工知能（Artificial Intelligence; AI）分野でのこの数年の大きなブレイクスルーは「ディープラーニング」（深層学習）である。海外のAIに関する会議でも、ディープラーニングに関する話題はここ数年で急激に増えた。ディープラーニングがマサチューセッツ工科大学（MIT）の「10 Breakthrough Technologies」（注目すべき10個の革新的技術）に選ばれたのは2013年であったが、画像認識、音声認識、自然言語処理、ゲームなど、様々な領域に飛ぶ鳥を落とす勢いで広がっている。本節では、ディープラーニングに焦点を当てて議論を進めていく。

ディープラーニングとは、深い層を重ねることで学習精度を上げるように工夫した「ニューラルネットワーク<sup>1</sup>」を用いる機械学習（1.2.2項参照）技術のことである。ディープラーニングについては、2006年にカナダ・トロント大学のジェフリー・ヒントン（Geoffrey Hinton）氏らが精度を上げることに成功して以来、様々な手法が提案され、2011年には音声認識のタスクで優勝、2012年にはILSVRC（ImageNet Large Scale Visual Recognition Challenge）という一般物体認識のコンテストで圧勝するなど、数多くのコンペティションで成果を収めてきた。

2013年には、ヒントン氏とその学生らが立ち上げたベンチャー企業DNNresearch（カナダ）をGoogleが買収。そして2014年初頭には、ディープラーニングの先進的技術を有するDeepMind（現Google DeepMind、英国）も、Googleは4億ドル（約445億円）で買収した。

一方、中国のインターネット検索最大手のBaidu（バイドゥ、百度）は、スタンフォード大学でGPU（Graphics Processing Unit）を使ったディープラーニングの研究を進めていたアンドリュー・エン（Andrew Ng）氏を招き、2013年にディープラーニング研究所を設立した<sup>2</sup>。Facebookは、ディープラーニングの主要な研究者であるニューヨーク大学のヤン・ルカン（Yann LeCun）氏をトップに据えてAI研究所を設立し、その後もニューヨーク、シリコンバレー、パリに拠点を広げている。

なお、ICLR（International Conference on Learning Representations）、NIPS（Neural Information Processing Systems）、ICML（International Conference on Machine Learning）などのディープラーニングと関連する国際会議も、ここ数年は急激にその参加者を増やしている。

ディープラーニングがこのように注目されている状況がこのまま続くかどうかに関し、二つの立場からの見解がある。一つ目の立場から見ると、AIあるいはニューラルネットワークに関するブームは、歴

※1  
脳の神経回路網で見られる特性を計算機上で再現することを目指した数理モデル。

※2  
2017年3月時点でBaiduを退職している。“Opening a new chapter of my work in AI,” Andrew NG Blog Medium.com Website <<https://medium.com/@andrewng/opening-a-new-chapter-of-my-work-in-ai-c6a4d1595d7b>>

史的には何回も繰り返されており[1]、現在用いられている手法も、ほとんどが昔からあるものであるため、その用途も現在のところ画像認識や音声認識などに限定されている。したがって、今回が真の突破口であると信ずる理由はないとするものである。

もう一つの立場は、ディープラーニングが今後起こる大きな変化の突破口であるとする立場である。その理由は、AIの分野で議論されてきた様々な難問において、結局のところは、データを基にして特徴量<sup>3</sup>を抽出するところに最も大きな困難性があり、それが今、「現実的な方法で」「実際に」解けるようになってきているからである。

例えば、情報検索の研究は1970年代からあったが、1990年代後半、インターネットの普及という環境を得て、一気に花開いた。インターネット広告という収益の手段を持つ大手の検索エンジン企業でなければ、その後の検索エンジンの研究はもはや事実上不可能になった。産業界における収益化の手段と一旦結び付いた後の学術研究は、(特に米国においては) 凄まじい発展を見せる。同じように、ディープラーニングの技術も計算機環境の進展とデータの拡大という環境を得て、一気に花開く可能性が高い。

また、後述するように、このディープラーニングの進展は、日本の強みであるものづくり産業にとって非常に相性が良い。したがって、この技術を活かすことによって、大きく産業競争力を強められる可能性がある。産業界における収益化の手段と学術研究を結び付けることができ、技術が収益につながり、また技術に再投資されるというサイクルを作り出すことができれば、情報技術の領域でここ20年、大きく水をあげられてきた日本も、再び世界に伍することができるようになる可能性がある。

ロボット研究者として有名な、カーネギーメロン大学のハンス・モラベック (Hans Moravec) 氏は、著書の中で次のように述べた。

*The main lesson of thirty-five years of AI research is that the hard problems are easy and the easy problems are hard. The mental abilities of a four-year-old that we take for granted - recognizing a face, lifting a pencil, walking across a room, answering a question - in fact solve some of the hardest engineering problems ever conceived... (by Hans Moravec)*

35年におよぶ人工知能研究で学んだことは、人間にとって難しい問題は機械にとってはやさしく、逆に人間にとってやさしい問題は機械にとっては難しいということだ。当然のように思う、4歳児の心的な能力——顔を認識したり、鉛筆を持ち上げたり、部屋を横切ったり、質問に答えたり——は、実際、これまでに直面したことのない最も難しい工学的な問題のいくつかを解いている (ハンス・モラベック)

AIの研究は、大雑把にいうと、1960年代の推論や探索の研究から、1980年代の知識工学・エキスパートシステム<sup>4</sup>、1990年代から2000年代にかけてのオントロジー<sup>5</sup>、セマンティックウェブ (1.5.3項参照) や知識発見、あるいは、マルチエージェント (1.6.1項参照) や社会性、コミュニティといった変遷を経て、2017年現在、機械学習・ディープラーニングの全盛の時代を迎えている。

※3  
学習データがもつ特徴を数値化したもの。

※4  
ある特定分野の専門知識のデータを基に推論を行い、人間の専門家のような判断を下すシステム。

※5  
概念若しくは構成要素の体系化。

これまで、天才ともいえる数多のAI研究者が、知能の問題を考え、そして壁にぶつかってきた。そこで、もっと別のところに答えを見出だそうとする動きが、AIという分野の研究の変遷を生み出してきた。

初期のAIは、記号処理を中心にしたものであり、人間の知能の根源は記号処理にあるだろうというものだった。ところがそれが行き詰まりをみせた。記号処理の中心であったマービン・ミンスキー (Marvin Minsky) 氏はMITでAI研究所の初代所長であったが、3代目の所長になったロドニー・ブルックス (Rodney Brooks) 氏は「表象なき知能」という概念を提唱し、「服属アーキテクチャ」を考案した。要は、知的に見える振る舞いも、環境との簡単な処理の相互作用の結果として得られるということである。

その後、例えばトム・グルーバー (Tom Gruber) 氏は、「オントロジー」という考え方を提唱した。また、知識のもつ社会性に注目した研究が出てきた。複雑性やインタラクションを伴ったマルチエージェントの研究も日本を中心として強い分野となった。

こうした動きは、「群盲象を評す」のように、知能を異なる側面からとらえたものである。ただし、一つだけ足りなかったものが高度なパターン処理であり、それが近年のディープラーニングの進展により解決され始めている。

本節ではまず、AIの分野で、古くから議論されている身体性 (1.3節参照)、あるいはシンボルグラウンディング<sup>6</sup>に焦点をあて、ディープラーニングを基盤に置くことでどのように従来の議論をとらえることができるのかを述べる。そのために、「SHRDLU」(次節参照) や服属アーキテクチャ、述語論理などの概念の再解釈を試みる。特に、ディープラーニングにおける生成モデルが、最も重要な要素技術になり得ることを述べる。

### 1.1.2 ディープラーニングによる生成モデルの可能性

まず、本節での議論を、「SHRDLU」(シュルドゥル) から始める。SHRDLUとは、1968年から1970年にかけてテリー・ウィノグラード (Terry Winograd) 氏が開発したシステムであり、AI研究の初期の有名な研究の一つである。

画面の中の「積み木の世界」に、ブロックや円錐、球などが存在し、ユーザからの様々な質問に自然言語文で答えることができた。例えば、「円錐は何に支えられているか？」などである。また、自然言語文の命令により動かすことができた。ユーザは、「緑色の円錐を赤いブロックの上に置け」と指示した後、「その円錐を取り除け」と指示することができた。

だがウィノグラード氏はこの研究の後、AI研究を辞め、HCI (Human Computer Interaction) の研究を行うようになった。次々と先進的な研究を生み出し、研究室からGoogleの創業者まで輩出したにも関わらず、ウィノグラード氏が自然言語処理の研究を辞めてしまったのは、とんでもないほどの絶望感を感じたためである可能性がある。

積み木の世界は全て人間が設計した世界であり、ありとあらゆるお膳立てをして、ようやくコンピュータは少し知的に見える振る舞いをできるようになる。このような裏の事情を分かっている研究者は、一見華やかに見える研究成果の裏にある膨大なお膳立てと、現実の人間の知能の間には、呆然とするほどの距離があることを思い知らされる。

しかし、このSHRDLUに代表される積み木の世界の研究が、知能の重要な側面をとらえる素晴らしい試みであること自体は、何も間違っていない。そして、それが今、ディープラーニングを突破口に新たな展開を見せつつある。

---

※6

記号システム内のシンボルがどのように実世界の意味と結び付けられるかという問題。

その鍵となるのが、ディープラーニングにおける「生成モデル」である。通常、機械学習においてクラス分類を解くための手法は、「識別モデル」と生成モデルに分けられる。識別モデルとは、データXが与えられたときにXが属するクラスを同定するモデルであり、X自体がどのように生成されたかについては問わない。これに対して、生成モデルはXが生成される過程までを含めてモデル化する。ディープラーニングで良く使われる「畳み込みニューラルネットワーク」(Convolutional Neural Network; CNN)は識別モデルであるが、生成モデルも近年、数多く提案されている。

有名なものには、「VAE」(Variational Auto-Encoder)や、視点を入れた拡張である「DRAW」(Deep Recurrent Attention Writer)がある。また、「GAN」(Generative Adversarial Network)はイアン・グッドフェロー (Ian Goodfellow) 氏らが提案したモデルであり、生成器と識別器から構成され、互いに騙そう、騙されまいとすることによって精度を上げる。これを拡張した「LAPGAN」(Laplacian Pyramid of Generative Adversarial Network)も有名である。これらを使うと、物理世界での動きを「予想」することができるようになる。例えば、ボールがはずむ動きなどを予想することができる。

また、カテリーナ・フラグキアダキ (Katerina Fragkiadaki) 氏らは、ビリヤードの球の動きを、「LSTM」(Long Short-Term Memory) (1.2.3項参照)と「CNN」(1.2.4項参照)で学習させた。これは、ある状況で特定の方向に力を加えると、どのようなことが起こるかを「想像」し、行動の計画を立てることができるというものである。

また、オ・ジュンハク (Junhyuk Oh) 氏らは、ATARI (米国) のゲームを題材に、アクションを挟み込んだオートエンコーダでフレームを学習することにより、特定の行動を行うと次に何ができるかを予測している。それにより、「DQN」(Deep Q-Network)を使ったゲームのスコアが向上する。

これらが示しているのは、明示的に積み木の世界を作らなくても、ディープラーニングの生成モデルを使うことによって、その世界を描くことができるということである。従来のように、人間が細部までお膳立てをすることなく、SHRDLUで目指していたような「どういう行動をすれば何が起きるか」をシミュレートすることができ始めているのである。

「生成モデルで世界をシミュレートする」というのは単純なアイデアだが、これをベースにして、様々な可能性が広がっている。以降では、身体性への拡張（センサ情報だけではなくアクチュエータ<sup>7</sup>の情報も含んだ拡張）を述べ、その上で、自動翻訳（生成モデルで作った世界と言語との結び付きによる言語の意味理解）、更には、述語論理等による推論（生成モデルで作った世界の記号的な要約）について述べる。

### 1.1.3 知能の全体像

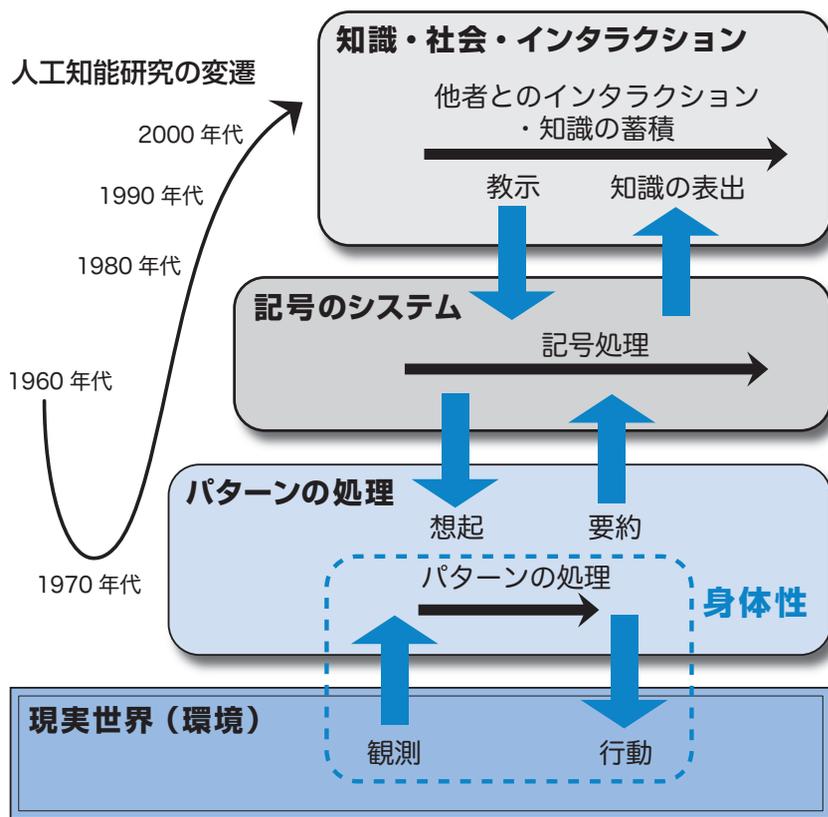
知能の全体像は、**図1**のようになる。まず、人間も動物も、生物は全て環境中に生きているので、環境からのセンシングとそれに応じた行動というループが基本である。それは特定の環境に対してのみ動く、簡単な制御系でも実現できるし、より複雑な環境でロバストに動くようにも設計できる。これは、ブルックス氏が言っていた身体性であり、ロルフ・ファイファー (Rolf Pfeifer) 氏の言う環境における身体性の重要性である。全ての生物は環境に条件付けられた自己保存装置、あるいは再生産装置であるので、環境にその行動は埋め込まれている。

そして、人間の場合は、このシステムの上に記号のシステムを載せている。これはまさに「象はチェスをしない」としてブルックス氏がミンスキー氏を批判したことの裏返しであるが、人間は記号を使っ

---

※7

入力されたエネルギーを物理的運動に変換する機械要素。



■図1 知能の全体像とAI研究の変遷

たチェスというゲームをする。言語の発明と使用は、外部記憶とその共有を可能にした。このことが、人間以外の種がなし得なかった高度な知的社会を人間が構成できた理由であり、また、多くのAI研究者が当初、自然言語や推論の研究を志向した理由でもある。したがって、ここからAIの研究がスタートしたのは、自然な流れといえる。

なお、記号といっても様々なレベルがあり、内的な記号と外的な記号（コミュニケーションに用いる記号）を分ける場合もある。例えば、我々が次の打合せに移動しようという行動計画を立てる場合には、ミクロなレベルの身体の動かし方から、マクロなプランニングまで、異なる階層で行うわけである。だが、少なくとも上の方はかなりの部分、記号を用いた処理を行っているように思える。なぜ記号が、良い行動選択や学習速度の向上につながるのでしょうか。記号はある種の再サンプリングや条件設定の効果、あるいは転移学習<sup>8</sup>の効果があると考えられるが、機械学習の観点から見た記号の意義は、未だに明らかにされていない。

そして、その上に、記号を用いた他者とのコミュニケーションがあり、知識の蓄積がある。この両者はほぼ同じ現象の表裏であり（例えば、オントロジーとコミュニティは同じものであるという議論がある）、知識の取得や蓄積の側に目を向けると、情報検索や知識抽出で研究されてきた分野に当たる。コミュニケーションの側に目を向けると、ソーシャルネットワークやソーシャルメディアの研究ということになる。

ここで述べた全体像は、必ずしも全てのAI研究者が同意するものではないが、大まかにはAI研究者の見方の概観を表すものである。

※8  
新規タスクを効率的に処理するためにほかのタスクで学習した知識を適用することで得られる効果。

ところが、こうした知能の全体像において、これまでの数十年の研究では大きな問題があった。環境中におけるパターンの処理が極めて弱かったことである。ブルックス氏によって昆虫型ロボットが作製されても、それよりも高度なパターン処理をするものは作れなかった。特に視覚的な入力の問題は顕著であった（それが今、ディープラーニングにより画像認識の精度が大きく向上し、大きく進展しようとしている）。

したがって、これまでのAIの研究は、記号の研究からスタートし、それが立脚すべき身体性の重要性に思い至り、そこまで遡ったところまではよかったが、そこで解かれるべきパターン処理が技術的な限界によって解けなかった。このため、答えはほかにあるのかもしれないということで、研究の方向は外へ外へと向かって行った。特にマルチエージェントや社会性といった最近のAIにおける研究は、かなり外に進出しているものである。これを図1における矢印で表している。

ディープラーニングは、様々な問題の根源的な原因を解決するものであり、そこを起点にして、様々なイノベーションが起こっていくはずである。順番としては、認識の問題が解決されれば、次は身体性のはずである。それが動物としての基本機能だからである。その次に、記号の研究が本格化する。今までと違って、きちんと「グラウンドした」記号を使つての研究である。更に、知識の抽出や共有、コミュニケーションといった話題が出て来て、現象のモデル化の能力も研究されるようになるだろう。

グッドフェロー氏やヨシュア・ベンジオ（Yoshua Bengio）氏らの書いた『Deep Learning』という本[2]には次のような一節がある。

*One may wonder why deep learning has only recently become recognized as a crucial technology though the first experiments with artificial neural networks were conducted in the 1950s. ... The learning algorithms reaching human performance on complex tasks today are nearly identical to the learning algorithms that struggled to solve toy problems in the 1980s, though the models we train with these algorithms have undergone changes that simplify the training of very deep architectures. The most important new development is that today we can provide these algorithms with the resources they need to succeed.*

人工ニューラルネットワークの最初の実験が1950年代に行われたのに、なぜ最近になってようやく、ディープラーニングが極めて重要な技術と認識されるようになったかは、不思議に思うかもしれない。（中略）今日、複雑なタスクで人間の性能に到達する学習アルゴリズムは、1980年代におもちゃの問題を解くのに苦労した学習アルゴリズムとほとんど同一である。これらのアルゴリズムで訓練するモデルは、とても深いアーキテクチャでの訓練を簡略化する変化をしてはいるが。最も重要な新しい進歩は、今日ではアルゴリズムが成功するのに必要とするだけのリソースを、アルゴリズムに提供することができることである。

つまり、計算リソースやデータが足りなただけで、アプローチは間違っていなかったのである。ディープラーニングが画像認識や音声認識で大きなブレークスルーを起こした後にくるものは、ブルックス氏やファイファー氏らが間違っていなければ、身体性の研究しかない。そして、その後ようやくミンスキー氏の世界が来る。したがって、今後は、必然的にロボットの研究が重要だということになる。もちろん、これまでのロボットの研究と異なるのは、ディープラーニングの進展とこれまでの研究が融合されるような形で研究の進展が起こってくるはずであるということである。

#### 1.1.4 ロボット研究の難しさとチャンス

もちろん、ロボットを用いた身体性の研究には難しいところが沢山ある。ディープラーニングのロボットにおける研究としては、今、カリフォルニア大学バークレー校 (UCバークレー) のピーター・アビール (Pieter Abbeel) 氏らを中心に、ディープラーニングと強化学習を組み合わせるアプローチが研究されている。実ロボットを使い、様々なマニピュレーション、歩行、飛行などのタスクを行っている。もう一方の雄はGoogle DeepMindで、「AlphaGo」への応用が有名であるが、DQNなどの技術が中心に研究されている。3Dの迷路やシミュレータ上でのロボットの研究も行われている。

ほかにも、カーネギーメロン大学やミシガン大学、国内でも早稲田大学や中部大学、プリファードネットワークス (PFN) など、様々な機関で研究が行われているが、世界的には、UCバークレー系と、DeepMind系とにざっくり大別することができるだろう。

両者の戦略の違いは面白い。DeepMindの戦略は、とにかくオンライン空間上でできることをターゲットにするということだろう。CEOのデミス・ハサビス (Demis Hassabis) 氏の講演や記事から、脳の処理における身体性の重要性は、明確に理解していると思われるが、それを実現するには、オンラインで行くほうが近道であるという戦略であろう。

一方、Facebook AI研究所のルカン氏が最近、「実世界の限界は実時間でしか動かないことである」と度々言っており、ごく当たり前のことであるが、非常に重要な指摘である。例えば、AlphaGoは1秒程度で1局、自己対局をしているが、オンラインのほうが圧倒的に試行錯誤を重ねることができ、結果的に研究が早く進む。

一方で、UCバークレーのアビール氏らは、実世界を対象に研究を進めている。当然、試行回数を減らさなければならず、よい初期値を与えることが重要で、そのための様々な工夫をしている。行動をいかにチャンク化<sup>9</sup>するか、複数の階層のプランニングを行うか、ある行動を別の機会に転移させるかなどの研究課題がいろいろとある。シミュレータを上手に作る、壊れないように行動を制御する、行動結果を予測するなどの研究も進んでいる。

やはり、実世界を対象にした試行錯誤を減らす研究こそが、身体性の獲得においては重要なのだろうか。実世界をいかにシミュレータでモデル化しようが、オンラインのゲームを使おうが、根本的な難しさである実世界の複雑で創造的な非線形性に立ち向かうには、「ほんもの」の実世界を対象にするしかないのではないか。あるいは、「高速に試行錯誤できる」環境で、アルゴリズムを極めた上で、おもむろに実世界を対象にするほうが結局は近道なのではないか。結果的にどちらのアプローチに軍配があがるのか、大変興味深い問題である。

既にその端緒が見て取れるが、こうした研究は次第に記号処理に近づき、その先に、言語との融合があるはずである。言語との融合も、これまでにロボットの研究として様々に行われてきたが、ディープラーニングをベースにした方法に置き換わっていこう (ただし、考え方自体は昔から研究されているものと別段大きく変わるわけではない)。

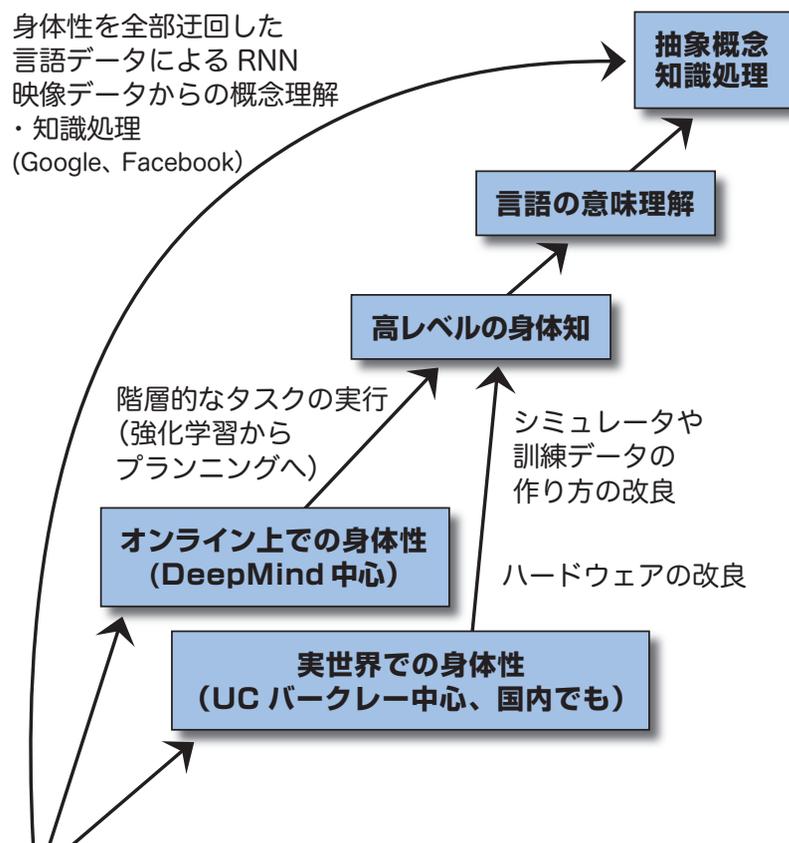
このように、「普通に」考えると、ディープラーニングのブレークスルーから、身体性を介した概念獲得、言語理解というふうに進むはずである。したがって、ロボットの研究をしない限り、AIの研究としては先に進めないはずということになる。

この点においては、日本の研究にもチャンスがある。ディープラーニングの研究を行っているGoogleやFacebookの研究者、あるいはそれを応用しようと目論むシリコンバレーの開発者たちは、実

---

※9

ひとかたまりのデータとしてカテゴリ化すること。



■図2 身体性をめぐるディープラーニング領域の戦況

世界でのロボット技術に対して大きな苦手意識がある（というより別分野だと思っている）。オンラインで完結する対象（例えば音声認識や画像認識や自然言語処理）に対するディープラーニングの研究者の圧倒的な厚みと、その成果のおそるべきスピードに比べると、ディープラーニングとロボットや機械の交わる領域を対象とする研究者は少なく、日本の研究も十分に戦える余地があると感じる。考えてみれば、ロボット研究は、ハードウェアとソフトウェアの知識・ノウハウが必要とされ、一朝一夕にできるものではないので、ディープラーニングが音声・画像・言語処理を席卷してきたようにはいかないものと考えられる。

こうした研究の進展の順序と、その中での日本の（暫時の間の）ロボット研究に基礎を置くAI研究の優位性が信じられてきた。ところが近年、こういった実世界における身体性という話を全部迂回して、大量のデータから概念獲得や意味理解ができてしまう可能性があるのではないかという危惧も生じ始めている。例えば、体を動かさない人でも、大量の動画を見続けるだけで、現象に対する理解に至るのではないだろうか。世界を理解するのに、本当に「実世界の」身体が必要なのだろうか（この議論は、哲学者フランク・ジャクソン（Frank Jackson）氏が提示した「メアリーの部屋」<sup>10</sup>として知られている）。

GoogleやFacebookは、巨大な言語データも映像のデータも持っているので、そこからの学習だけで相当なところまで到達してしまうのではないか。2016年秋には、Google翻訳がディープラーニングバージョンにアップデートされた。8層のLSTMに、意識的な注意のモデルを入れており、まさに現時点でできる限りの最新の技術を全て取り入れた結果、驚くほど精度があがっている。本来は、実世界の認識、身体性なしには、それほど精度はあがらないと考えられていたが、実際にはかなりあがっている。

この路線が、本当の意味理解に到達する可能性はないに等しいが、GoogleやFacebookの持つデータ

※10  
白黒の部屋で生まれ育った女性という設定で行われる哲学的思考実験。

量と、オンラインで完結する対象に対する研究者たちのスピードは凄まじい。こうしたアプローチに、多少なりとも画像や映像などの実世界情報のアラインメント、あるいは獲得した身体性に関する概念とのアラインメントの要素が入ってくれば、大幅にショートカットして、言語理解までたどり着く可能性がある。

その状況を示したのが図2である。普通に身体性から攻めると、UCバークレー路線とDeepMind路線の戦いとなるが、大幅にショートカットするGoogle、Facebook路線もあるかもしれないということである。

### 1.1.5 産業にとっての重要性

こうした状況に対して、日本の研究の立ち位置はどうであろうか。ディープラーニングの研究では日本は相当に遅れている。ICLR、NIPS、ICMLといった主要な会議でも、ディープラーニングに関するテーマで論文を通して日本の研究者はごく僅かである。ただ、身体性という観点から技術を産業と結び付けることにより、その状況を打開することができる可能性はある。

Googleの創業者であるセルゲイ・ブリン (Sergey Brin) 氏やラリー・ページ (Larry Page) 氏はスタンフォード大学の学生であったが、彼らは大学を辞め、Googleを作り、あっという間に時価総額世界一の企業になってしまった。次いで2002年頃には、Facebookが出てきて、あっという間に世界的な企業になってしまった。2017年4月には時価総額で世界5位にまで成長した。

そして、GoogleやFacebookなどの企業は、大量にウェブのエンジニアや研究者、あるいはAIの研究者を雇用している。Googleの年間の研究開発費は1兆円を超える。どう考えても勝ち目が無いほど、GoogleやFacebookの研究者の層は厚い。つまり、事業を作り出し、そこから技術に再投資するサイクルを作ったものが結局は勝つということである。それがここ20年で最も激しかったのがウェブの領域だったのではないかと。そして、それはディープラーニングの研究についてもあてはまる。

したがって、この状況を打開しようと思えば、ディープラーニングをベースに大きく利益を生み出すような事業を作り出し、技術に再投資するしかないわけである。その観点からは、ディープラーニングが破壊的な変化をもたらす領域がどこか。それを見極めることが極めて重要である。まずは画像認識の領域、例えば、医療画像や監視カメラ、写真の分類やユーザの表情の読み取りなどが対象になるだろう。これらは比較的、シリコンバレーのベンチャーでもやりやすいところであり、既に多くの企業が取り組み始めている。

そして、次に起こるのは、身体性の技術の活用である。認識の技術と、ロボット・機械系の技術の融合で新しい付加価値が生み出されるはずである。典型的には、農業、建築、食品加工の領域が考えられる。これまで自動化、機械化するのが難しく、かつ産業として巨大な分野だからである。

産業用ロボットなどの活用もあるが、これまでの工業化はいわば「目の見えない機械」を使って環境を整えることによって自動の処理を実現してきた歴史であった。したがって、今後起こる変化は、環境が整っていないところでの自動化が起こることである。そのなかで産業として大きいのが、農業や建築、食品加工などであろう。それ以外にも、例えば、片付けというのは巨大な市場を構成するのではないかと。認識し、ものをあった場所にしまうというだけだが、それだけで家事労働が非常に楽になるし、生活の質が大きく向上する。

地球ができて46億年だが、5億4200万年前から5億3000万年前という短時間に、現存する全ての生物の門が出揃ったという現象を、「カンブリア爆発」と呼ぶ。これは「眼の誕生」が原因であるとする説を、アンドリュー・パーカー (Andrew Parker) 氏が提唱した。そして、ディープラーニングは「目」の技術であり（視覚野の処理を実現するものであり）、ロボットや機械の世界でこれからカンブリア爆発が

起こるということである。TRI (Toyota Research Institute、米国) のギル・プラット (Gill Pratt) 氏やソフトバンクの孫正義氏も同じ表現をしている。

こうした片付けや調理、あるいは農業や建設などの作業をロボットで実現することは、ロボットの研究コミュニティでは古くから試みられている。しかし、今がそのタイミングなのではないか。ウェブの世界でも、情報検索という技術は昔からあったにもかかわらず、ウェブページを対象とする検索エンジンで一気に商用化した。ソーシャルネットワークの研究は社会学の分野で何十年も行われていたが、SNSは一気に広がった。つまり、昔からあるアイデアが、何らかの現実的な条件が満たされて一気に広がることはよくある。

技術的には、ディープラーニングにより画像認識の精度が非常に上がり、強化学習との連携が使えるようになってきたことが極めて大きな変化である。あとは、ハードウェアの性能の問題と、製造コストがどこまで下がるかである。ここがクリアされれば、大きな事業につながるかもしれない。そして、ハードウェアの問題、コストの問題は、日本の研究者や日本企業が強みを発揮できる部分である。一旦事業として成立し始めれば、更に精度の良い学習を行うことに対して、事業者は強いインセンティブを持つはずである。それが研究の後押しとなり、技術を大きく前に押し進めることになる。

ディープラーニングを起点にした事業化をうまく進めることができれば、インターネットの分野におけるGoogleやFacebookのような地位を日本が取れる可能性があるのが、ロボット・機械の分野である。したがって、AIの研究者という立場からみて、ロボット研究に対する期待は極めて大きい。

### 1.1.6 ディープラーニングに基づく記号の意味理解に向けて

環境世界を知覚する仕組みの上に、世界を予測する生成モデルが築かれ、その上に更に記号の操作が実現されるという知能の全体像を知るという課題に対して、現在のディープラーニングの研究の中で、その解明の端緒に当たるものは二つある。

一つは、画像から文を生成する自動キャプション付けであり、画像中で最も注目すべき点に焦点を当てて、文を生成する手法である。例えば、画像を与えると、「ピンクの服を着た女の子が芝生の上でジャンプしている」などの文を生成する。もう一つは、画像の生成であり、文が入力されると画像を生成するようなモデルを学習するものである。例えば、DRAWを使って、「飛行機が空を飛んでいる」「象が砂漠を歩いている」などの文を入れると、該当する画像を描くことができる。「止まれの標識が空を飛んでいる」などの、普通ならあり得ない文を入れても画像を生成できるところが興味深い。これは、すなわち、自然言語文から画像を生成することができ、更には画像から自然言語文を生成することができるということである。再度、SHRDLUの自然言語による操作と同じことが実現できるわけである。自然言語文の「意味を理解」していると言えるかもしれない。

さて、AIの分野では、意味理解についての議論も古くからある。アラン・チューリング (Alan Turing) 氏は、チューリングテスト<sup>11</sup>を提案し、「計算機は考えることができるか」という問いを、「模倣ゲームをうまく行うことのできるような想像上の計算機は存在するか」という問いに置き換えた。それに対して、ジョン・サール (John Searle) 氏が1980年に示した思考実験が「中国語の部屋」である。仮にチューリングテストに合格する機械ができたとしても、操作している対象の「意味が分かっていない」というものである。

文の意味が分かるとはどういうことだろうか。文の意味を理解するとは、文から画像を生成すること

---

※11  
ある機械がAIであるかどうかを判定するためのテスト。

ができることである。ここで、画像というのは、視覚的な情報を分かりやすく表現した言い方であり、実際には、センサとアクチュエータの複合的な時系列情報であるので、体験という言葉のほうが適切であろう。つまり、意味理解ができるというのは、文から体験を生成し、あるいは体験から文を生成できる相互変換能力のことであると考えられる。

ディープラーニングの生成モデルを使えば、本当の意味での意味理解を行うことができるはずである。例えば、日本語の文から体験を生成し、それを英語の文に変換するということができるかもしれない。すなわち、自動翻訳、しかも意味理解を伴う自動翻訳が可能になるかもしれない。もちろん、本格的な自動翻訳を実現するには、沢山の課題がある。

- 抽象的な概念をどのように扱うのか。人間の意味理解が、視覚情報や視覚的な処理機構をベースにしているのは確かにそうであるとしても（抽象的概念でも空間的な扱いをするものが多い）、映像として再現することは難しい概念も沢山ある。センサ、アクチュエータの高次の特徴量が復元されるということでもいいのだろうか。
- 感情や本能等に関わるものをどのように扱うのか。例えば、美しい、おいしいといった感覚は学習できるにしても、人間と同じような感情が実現されているわけではない。その設計をしなくとも（例えば納豆が嫌いでもほとんど食べたことがない人でも、納豆を食べる人を観察して学習できるように）ある程度何とかできるのだろうか。
- 人間と同じセンサ、アクチュエータがないと、人間に近い（あるいは理解し得る）概念を生成することは難しいのか

もう一つ、考えなければならないのは、記号処理により、見えていないことをいかに予測するかである。AIで長らく研究されてきた命題論理や述語論理、あるいは様相論理などによる推論[3]は、与えられた知識や事実から、最初は見えていない帰結を導き出すための仕組みであった。その点では、最近、注目を集めたAlphaGoの研究も意義深い。過去の棋譜データや自己対戦データを用いながら、CNNを用いた上で、「policy network<sup>12</sup>」、「value network<sup>13</sup>」を構成していく。それによって、先読みを大幅に効率化している。

そもそも、こういった思考ゲームがコンピュータに扱いやすいのは、世界モデルを構築することなく、シンプルなルールを記述しておくだけで、未来の状態を展開することができたところにある（つまり生成モデルによる世界のシミュレーションを「さぼる」ことができたわけである）。ところが囲碁においては、一手一手の操作があまりにもプリミティブすぎて、結局は世界モデルの構築が重要な鍵であった。それに対して、AlphaGoでは、CNNによる盤面の認識に加えて、強化学習によるpolicy networkを構成することで、探索する範囲をかなり絞ることに成功した。

おそらく人間の場合は、視覚的な生成モデルをベースにしながら、こういうときにはこうなるという関係性を記号レベルの接続関係でも学習していく。すると、いちいち重い処理が走らずとも、簡略化して思考を先に走らせることができる。この記号の想起と、視覚的な生成モデルの組合せが、思考の過程であり、それを（生成モデルによる世界のシミュレータがないがゆえに）シンボルの想起だけに限定したものが、従来の述語論理や様相論理による推論ということができるのではないだろうか。

※12  
次の手を選択・評価するための畳み込みニューラルネットワーク  
(Convolutional Neural Network; CNN)。

※13  
局面を評価するためのCNN。

### 1.1.7 本章の構成

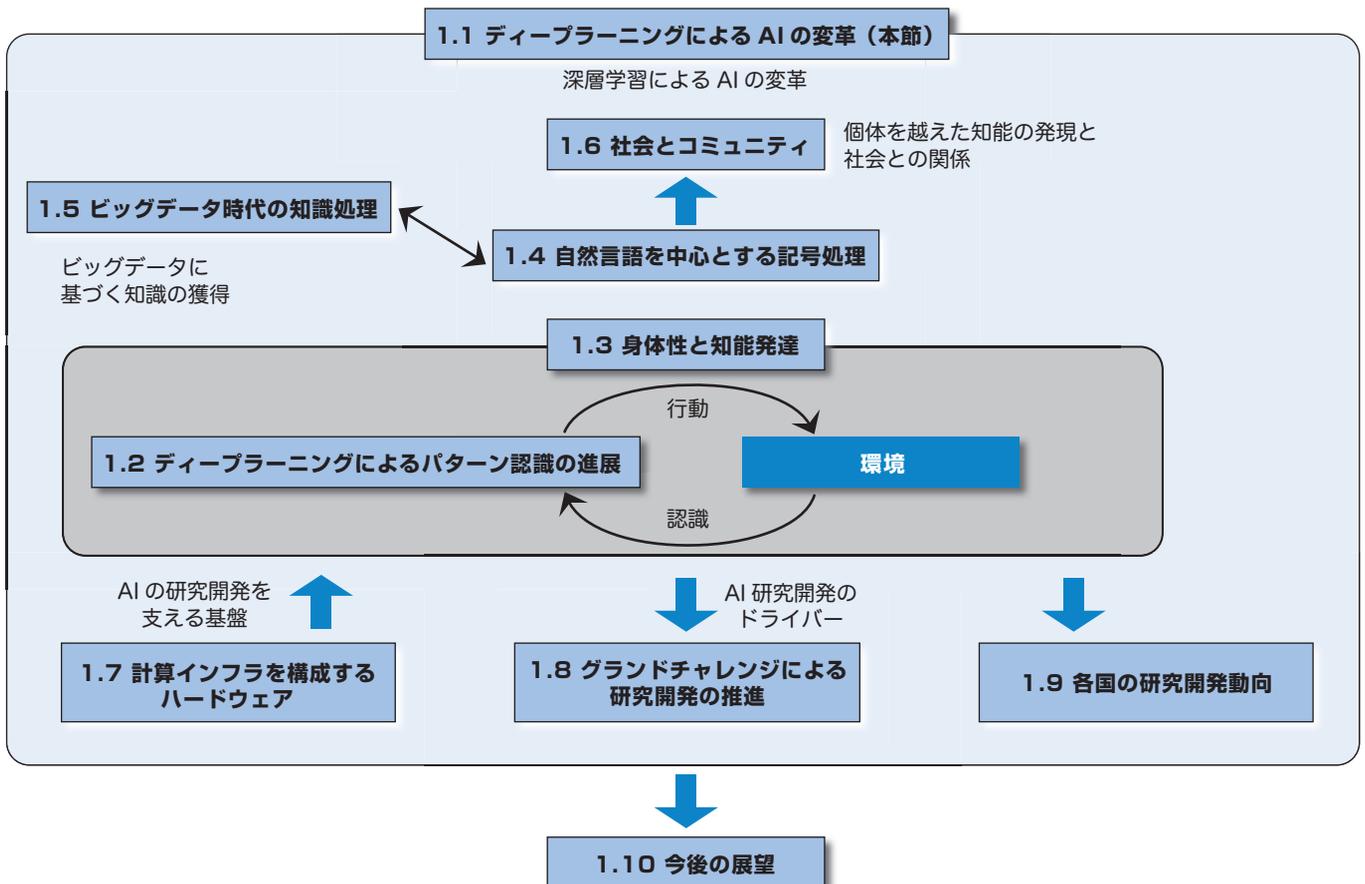
上記の状況認識を踏まえ、本章は次のように構成する。

まず、ディープラーニングを中心とする無意識の処理やパターン認識について、1.2節で述べる。画像認識で多く用いられているCNNや、時系列の処理を行う「リカレントニューラルネットワーク」(Recurrent neural network; RNN) を中心にその理論や応用について述べる。

次に1.3節では、身体性についての研究の動きをまとめる。ディープラーニングの急速な発展をベースに、今後大きく変わっていくであろう技術である。特に、産業的にも日本が強みを発揮する上でこの観点は極めて重要である。

1.4節では、記号・言語についての研究を概観する。記号処理は、まだディープラーニングの影響が大きく及んでいる領域ではないが、機械翻訳を始めとして先進的な動きが進みつつあり、今後、従来からのAI研究と新しい潮流がぶつかる、そして人間の知能を構成する上で大変興味深い部分に研究が突入すると思われる。

1.5節では、こうした進展を支えるビッグデータの技術についてまとめる。ディープラーニングはビッグデータを必要とするが、非常に自由度の高い (capacityの大きな) モデルを学習しており、capacityに比べるとデータ量が少なくてすむような工夫が随所になされている。知能の研究は、できるだけ少ない量で同じモデルを学習する、あるいは、同じデータ量でよりcapacityの大きなモデルを学習するという方向に進んでおり、データの大きさだけで語るのはフェアではない。しかしながら、技術的にはビッグデータの取扱いが大きなイノベーションを起こしてきたのは事実であり、大変重要な技術である。また、ディープラーニングに限らず、ビッグデータによる様々な分析や活用が可能になっており、その流れも今日のAIを特徴付ける一つであろう。



■図3 1章の全体構成

**1.6節**では、社会とコミュニティについて概観する。AI研究では比較的最近進展してきたトピックであり、社会を構成することが人間の知能を大きく高めたことから、その重要性は明らかである。ディープラーニングとの融合はまだ先かもしれないが、AI研究においては重要なトピックの一つである。

**1.7節**では、AIのインフラストラクチャやハードウェアについて述べる。ディープラーニングに用いられるGPUを始めとして、様々なインフラストラクチャやハードウェアがこうしたAIの進化を支えている。省エネの技術や組み込みの技術なども、今後、AIが様々な産業で使われる上では重要であろう。

**1.8節**では、AIのグランドチャレンジを取り上げる。AIの分野では、歴史的にグランドチャレンジが大きな役割を果たしてきた。「ロボカップ」、「DARPA（国防高等研究計画局）Grand Challenge」、「DARPA Robotics Challenge」等である。大きな夢を共有することで、それに向かってコミュニティの力を結集しようというものであり、それによって様々な技術がスピリアウトして出てくる。

**1.9節**では、我が国及び諸外国の政府と民間企業による研究開発の動向を概観する。

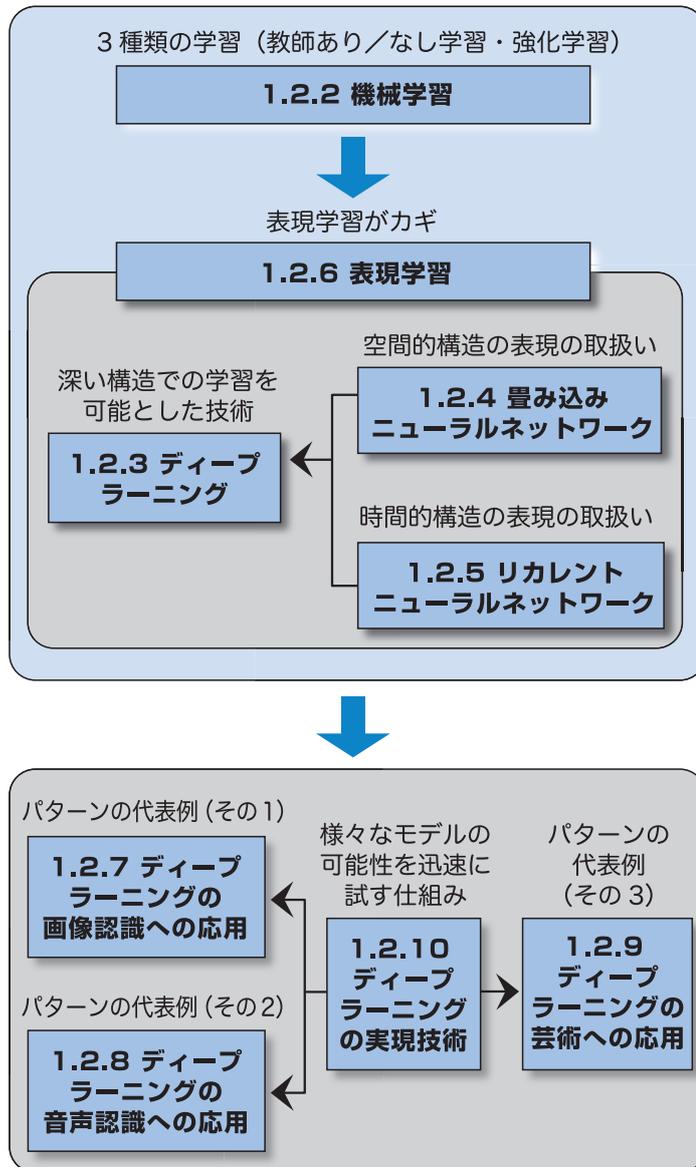
**1.10節**では、AIの今後の展望を述べる。こういった技術の進展はどのようなステップで進むのか、この先に技術はどこまでいくのかなどを述べる。

#### 参考文献

- [1] 麻生英樹ほか『ディープラーニング』近代科学社.
- [2] I. Goodfellow et al., "Deep Learning," *The MIT Press*.
- [3] 石塚満『知識の表現と高速推論』丸善.

# 1.2 ディープラーニングによるパターン認識の進展

## 1.2.1 総論



■図4 本節の構成

1.1節では、ディープラーニングがどのように人工知能（AI）の枠組みを転換し得るのかについて概観した。本節では、そのディープラーニングについての基本的な考え方と応用に関する現状についてより詳しく述べる。

ディープラーニングは、情報処理の単位であるニューロンが層状に接続した構造を模擬した機械学習の一種である。以下では、最初に、機械学習の三つの枠組みについて述べる（1.2.2項参照）。更に、三つの枠組みの中で、特に身体性（1.3節参照）との関係で重要となる強化学習についての課題について詳述する。

ディープラーニングは、ニューロンが多層で接続しているモデル構造（深い構造）を持つことにその名前は由来している（1.2.3項参照）。脳は、ニューロンがネットワーク状に接続しているため、その構造を素直に数理モデルで定式化したものであると言える。ネットワークを多層構造にすれば、基本的な概念から、その組合せで表現される高次の概念まで表現可能なため、アイデアとしては古くから存在

しており、ファジィシステム研究所の福島邦彦氏による「ネオコグニトロン」は、その先駆的な研究とされている。今回のディープラーニングのブレイクスルーは、トロント大学のヒントン氏らによる研究を端緒として、音声認識、一般物体認識を始めとする様々なコンテストで優勝したことによる。一口にディープラーニングと言っても、現在提案されているネットワーク構造は多岐にわたっているが、最も典型的なフィードフォワード<sup>1</sup>の多層ネットワークを例に、その構造と機能を説明する。

現在、データに潜む空間的構造をモデル化する場合と、時間的構造をモデル化する場合で、よく使われるネットワーク構造が分かれており、空間的構造では「畳み込みニューラルネットワーク」(Convolutional Neural Network; CNN)、時間的構造では「リカレントニューラルネットワーク」(Recurrent Neural Network; RNN)が多く使われている。

CNNは、前述の福島氏によるネオコグニトロンを起源とし、脳の視覚野の構造とも類似の機能を持つネットワークであり、現在のディープラーニングによる画像認識に関して、デファクトスタンダードとなっている構造である(1.2.4項参照)。画像中の物体に僅かなずれやゆがみがあっても吸収する仕組みが導入されているため、頑健な認識が可能となっている。

一方、時間的構造の場合には、RNNが利用される場合が多い。ここで言う時間的構造とは、単純な時系列データの構造だけではなく、論理展開や自然言語、音楽など、順序的な構造を含むデータであれば対象となり得る(1.2.5項参照)。

また、AI研究における「表現」(representation)とは、概念に対応したニューラルネットワークの状態のことを指す。ディープラーニングの登場以前には、表現の材料とも言える「特徴量」を、研究者自身が工夫してあらかじめ作成する必要があった。これに対して、ニューラルネットワーク上での「特徴量」の獲得を可能にしたのが、ディープラーニングである。これにより、モデルを構築する際の拠って立つ基盤となる土台が手に入ったことを意味している。

特に、自然言語に代表される「記号」に対応する表現がどのようなものであり、どのように獲得されるのかという問題は「シンボルグラウンディング問題」と呼ばれ、AIの歴史の中で、解決が困難とされてきた課題の一つである。ここでの「記号」とは、静的なイメージ、動的なイメージだけでなく、情報処理の中間的な状態、動機や感情を伴う状態など、脳内の活動のあらゆる側面を含む。シンボルグラウンディングにディープラーニングが重要な役割を果たすのは確かであると考えられるが、必ずしもその構造が必然的なわけでもなく、今後様々な表現学習の手法が出現する可能性が考えられる。

ディープラーニングの応用分野の中で、画像認識の分野は、パターン認識の結果が視覚的に分かりやすく、画像中の物体検出や物体セグメンテーションなど、自動運転、画像診断、防犯画像の認識等の応用にも直結するため、盛んに研究されている分野である(1.2.7項参照)。生成モデルの研究も画像分野が一番進んでおり、キャプションからの画像の生成等が行われている。また、画像的なイメージを伴う概念は多く、シンボルグラウンディングを実現するためにも重要な分野であり続けると考えられる。

音声認識も、画像認識と並んで実用に直結する分野である。スマートフォンやコールセンターでの利用や、今後AIの活用領域の拡大が進むにつれて、機械と人間のインターフェース(マンマシンインターフェース)に音声認識を組み込むケースが増大すると考えられる(1.2.8項参照)。音声分野における生成モデルとしては、テキストから合成音声を生成する研究も既に発表されており、従来に比べて聞き取りやすい音声を得られたとされている。

また、生成モデルを用いた応用として、芸術等の分野でも研究例が増えている(1.2.9項参照)。画像

---

※1

フィードバックの逆。制御を乱す外的要因(外乱)が発生して、それが影響として現れる前に、前もってその影響を極力なくすように必要な修正動作を行う。

の生成、音楽の生成をはじめとして、長期的には小説の生成も目指されている。

本節の最後に、ディープラーニングの開発の際に必要なソフトウェアについて動向を紹介する(1.2.10項参照)。ディープラーニングを実装するためのソフトウェアには、IBMの「Watson」(ワトソン)を始めとする商用のソフトウェアも存在するが、世界のトップクラスの研究開発で使用されているソフトウェアのソースコードの多くは公開されている。その中で、Googleの「TensorFlow」(テンソルフロー)、Berkeley Vision And Learning Centerによる「Caffe」(カフェ)、そして日本のプロフォードネットワーク(Preferred Networks; PFN)が開発した「Chainer」(チェイナー)等が頻繁に利用されているものである。

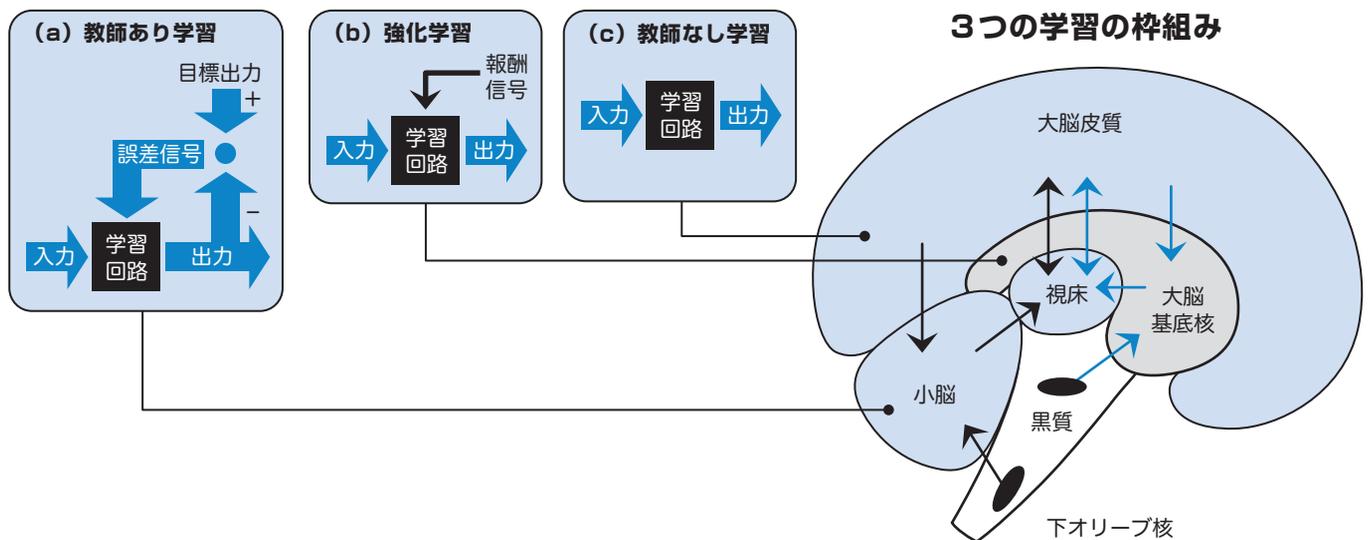
これらのオープンソースソフトウェアには、それぞれに特徴があり、どれか一つでオールマイティというわけではない。GoogleのTensorFlowは大規模なGPU(Graphics Processing Unit)環境での高速化に特徴があるとされている<sup>2</sup>。PFNのChainerは、実行時にも動的にネットワーク構造を変えられる「Define-by-Run」という方式を取っており、ディープラーニングの世界で次々に提案される新しいネットワーク構造やモデルを簡単に取り込むことが可能とあって、人気を集めている。

これらの頻繁に利用されるオープンソースソフトウェアをベースとして、個々の研究者が自身で考案したモデルを実装、公開することで、他の研究者もすぐにそのモデルを試せるといった好循環が生じている。

## 1.2.2 機械学習

### 1.2.2.1 機械学習の構造

脳における学習の枠組み[1]に基づき、機械学習における三つの学習の枠組みを紹介する[2]。



■図5 三つの学習の枠組み

三つの学習とは、「教師あり学習」、「教師なし学習」、そして「強化学習」である(図5)。これらは、脳の部位として、それぞれ小脳、大腦皮質、そして大腦基底核と深く関連がある。

※2

Martin Abadi et al., "TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems."

<<http://download.tensorflow.org/paper/whitepaper2015.pdf>>

- **教師あり学習 (Supervised Learning) :**

主に、小脳が担う。学習者に対し、教示者が明示的に正例を呈示したり、学習者の誤りを指摘したりすることで、学習者が正しい解を得ることを助ける。すなわち、正しい入出力の組合せを与えて学習することで、新規の入力に対し、適切な出力を提示できる。Back Propagation (誤差逆伝播法)<sup>3</sup>が、その代表的手法であろう。また、正例、若しくは負例を入力として、未経験入力に対する意志を決定する決定木 (Decision Tree) の作成などもある。

- **教師なし学習 (Unsupervised Learning) :**

主に、大脳皮質が担う。統計的性質や、ある種の拘束条件により入力パターンを分類したり、抽象化したりする学習。主成分分析、自己組織化マップなどの次元圧縮 (Dimensionality Compression) 手法が代表例である。感覚情報などの入力パターンの分類、同様に出力運動パターンに対して統計的性質を用いて要素行動に分類する学習法などがある。

- **強化学習 (Reinforcement Learning) :**

主に、大脳基底核が担う。最終結果若しくは、途中経過に対して、どの程度良かったかを示す「報酬信号」に基づき、これらの報酬をなるべく大きくするように探索する。

強化学習と教師あり学習の違いは、フィードバックがスカラー (成否) かベクトル (howの情報) かという説明もあるように、明示的な教師ではなく、環境などの非明示的な教師だという解釈もある。

### 1.2.2.2 強化学習の課題と最近の動向

ここでは強化学習の基本課題として、遅延報酬による長期学習時間 (学習時間)、状態行動空間構成 (状態行動空間)、マルチエージェント応用 (スケールアップ) などについて概説し、最近の動向についても触れる。

#### (1) 学習時間

理論的には無限に学習するが、実世界では全てが限られている。ロボットの場合、無限の試行を繰り返すことなどでできず、ロボットが損耗し、実験の続行が困難になる。人間の場合でも、何度も失敗が続けば、それこそ動機を失う。そこで、やさしいタスクからの学習 (Learning from Easy Missions; LEM) を設定することで、理論的に、探索時間を状態行動空間のサイズの指数オーダーから線形オーダーに圧縮可能である。先験的にタスクの「やさしさ」が分かれば問題はないが、そうでない場合、その確信のなさに従い、線形オーダーから遅くなるが、元の学習の収束性が保証されていれば、同様に保証される。

#### (2) 状態行動空間

状態が格子状で行動が格子間の移動などの理想的な状態行動空間は、イベントベースの抽象的な状態行動空間を除き、実世界ではほとんどありえず、セグメンテーション課題と呼ばれる大基本問題の一つである。報酬が与えられる時間も含めて「クレジット割り当て問題」 (Credit Assignment Problem) と呼ばれている (図6)。クレジット割り当て問題とは、状態・行動の空間内での軌跡が与えられたとき、遅延した報酬が与えられたとき、過去のどの時点のどの範囲の行動を強化すれば良いのかという問題である。状態行動空間を再帰的に定義することで、状態行動空間構成の「鶏と卵」問題を解消した手法が

---

※3

正解と実際の出力を比較することで各層間の重み付け等を修正する学習方法。

提案されている。また、初期を一状態とし、連続の状態行動空間を線形関数近似により分割する手法[3]では、線形関数近似に加え、報酬（ゴール到達）の成否による細分化も含まれている。最近では、ベイズ推定の枠組みで、状態・行動空間を自律的に分割する機構を持つ強化学習法が提案されている[4]。

### (3) スケールアップ

より複雑なタスクへの応用として、階層構造化とマルチエージェント化の課題が挙げられる。前者では

「MOSAIC」[6]が有名だが、高橋泰岳氏ら[7]は、均一な強化学習器を多く準備し、階層のレベルを、それらの能力と環境に依存して（事前に指定しない）、自律的に構造化する手法を提案している。マルチエージェント学習では、同時学習による学習過程の不安定化<sup>5</sup>が課題である。

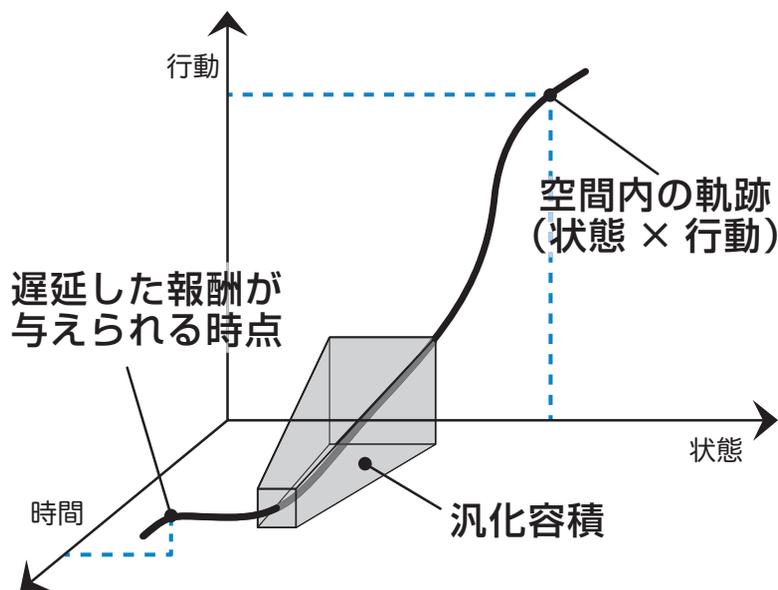
文献[8]は、最近の発展系などに詳しい。ベイズ統計との関連、報酬関数を未知として、人間のエキスパートの行動から報酬関数を推定する逆強化学習、群強化学習、また、強化学習の関数近似にディープラーニングの技術を適用したDQN（Deep Q-Network）などは、1.1節でも紹介されているように、ゲームや実際のロボット応用にも適用され始めている。内発的動機付けとの関連[9]もロボットの自律性などの観点から興味深い。

## 1.2.3 ディープラーニング

ディープラーニング（深層学習）は、狭い意味では、層の数が多い（深い）ニューラルネットワークを用いた機械学習のことである。より広い意味では、低次の局所的特徴から高次の抽象度の高い大域的特徴に至る、深い階層構造を持つ特徴表現（内部表現（internal representation）とも呼ばれる）をデータから獲得する機械学習を指す[10]。

複数の中間層を持つ階層的ニューラルネットワークの、結合の重みをデータから学習させるための方法として、1980年代に誤差逆伝播学習が提案され、様々な問題に適用されて一定の成功を収めた。だが、層の数が多いネットワークをうまく学習させることは難しいとされていた。その理由としては、

- (1) 出力層における誤差を入力層に向けて伝播させる間に、誤差情報が徐々に拡散し、入力層に近い層では勾配の値が小さくなって学習がうまく進まないこと（勾配消失現象）。
- (2) 層の数が多いニューラルネットワークの学習の目的関数は、非常に多くの局所的な極小値（ローカルミニマム）を持ち、適切な結合の重みの初期値の設定が難しいこと。



■図6 クレジット割り当て問題<sup>4</sup>[5]

※4  
文献[5]より作成。

※5  
初心者二人のテニスを連想するとよい。どちらも下手なので、練習もできない。相手がコーチだと定まったボールを初心者に呈示するので、初心者は安心して練習できる。

などが挙げられる。原理的には、中間層が一つのニューラルネットワークによって任意の連続関数が近似可能であるため、層の数が多いニューラルネットワークを学習させる試みはあまり行われなかった。

2006年頃にヒントン氏らのグループは、「深層信念ネットワーク」や、「制限ボルツマンマシン」<sup>6</sup>を多数積み重ねたオートエンコーダ<sup>7</sup>等の手法によって、様々な種類のデータに対して、深い階層を持つ有効な特徴表現が得られることを示した。更に、2011年頃から、不特定話者の連続音声認識や静止画像中の一般物体認識などの難しいパターン認識タスクにおいて、ディープラーニングによって得られる特徴表現を用いて、従来法を大きく上回る性能が得られたことから、ディープラーニングの手法と応用の両方に関する研究が非常に盛んに行われるようになってきている。現在では100層を超える多層のニューラルネットワークも学習可能になっており、特に、一般物体認識や顔の識別などの画像認識系のタスクで、人間と同等以上の認識精度を達成しているものも多い。

画像の認識では、主に入力から出力に向かう結合のみを持つ階層的なニューラルネットワーク、特に、画像などの信号に内在する局所的な特徴が集まって、より大域的な特徴を構成するという構造を反映した、畳み込みネットワークがよく用いられている。一方、自然言語テキストや動画に代表される、構造を持った系列情報を扱うために、RNNも再び研究されるようになった。なかでも、リンツ・ヨハネス・ケプラー大学（オーストリア）のゼップ・ホフレイター（Sepp Hochreiter）氏らの提案した「LSTM」（Long Short-Term Memory）は、必要な文脈情報の長さを適応的に制御することで、時間を遡る誤差逆伝播学習の可能性を向上させる点が再評価された。画像からの説明文の生成や機械翻訳など、多くの課題に適用されている。

パターン認識のための識別モデルとしてのみならず、画像などの観測情報を生成するための生成モデルとして、層の数が多いニューラルネットワークを用いることも研究されている。更に、識別モデルと生成モデルを組み合わせて、相互かつ敵対的に学習させることで、全体の性能を向上させる手法も考案された。

強化学習との組合せや、スタックなどの外部記憶構造との組合せなどによって、ディープラーニングを拡張していく研究も進められている。強化学習とディープラーニングの組合せは、強化学習の性能を大きく左右する状態空間の情報表現を、ディープラーニングによって獲得させられる利点がある。トロント大学のヴォロディームイル・ミン（Volodymyr Mnih）氏らは、古典的テレビゲームに適用して、多くのゲームで人間を超える性能を実現した。カリフォルニア大学バークレー校のセルゲイ・レヴィン（Sergey Levine）氏らは、接触の多い“はめあい”などの動作をロボットに学習させた。ロボットによる物体のピッキングなどへの応用も進められている。

そして、教師ありのディープラーニング、強化学習、モンテカルロ木探索を巧みに組み合わせたコンピュータ囲碁ソフトウェアである「AlphaGo」が、世界トップレベルの棋士に勝利するなど、目覚ましい成果を挙げており（1.8.1項参照）、今後、ロボット制御やシステム最適化などへの適用が更に広がることが期待されている。また、トロント大学のアレックス・グレイヴス（Alex Graves）氏らは、ディープラーニングと外部記憶構造を組み合わせたモデルの全体を学習させることで、指定された回数だけ同じ処理を繰り返すといった複雑な制御構造を持つ情報処理過程を、入出力事例から近似的に学習できることを示している。

こうしたディープラーニングの研究の広がりには、データやタスクに適した特徴表現の学習の重要性を示している。その中で、大規模なネットワークの学習性能を向上させるための様々な工夫が生み出されている。また、Caffe、Chainer、TensorFlowなどの、層の数が多い複雑なニューラルネットワークモ

---

※6  
二層からなる浅いニューラルネットワーク。

※7  
入力を学習データとして、特徴量を抽出するニューラルネットワーク。

デルでも高速な学習と推論を簡単に実装するためのツールも、数多く作られて公開されている。

## 1.2.4 畳み込みニューラルネットワーク

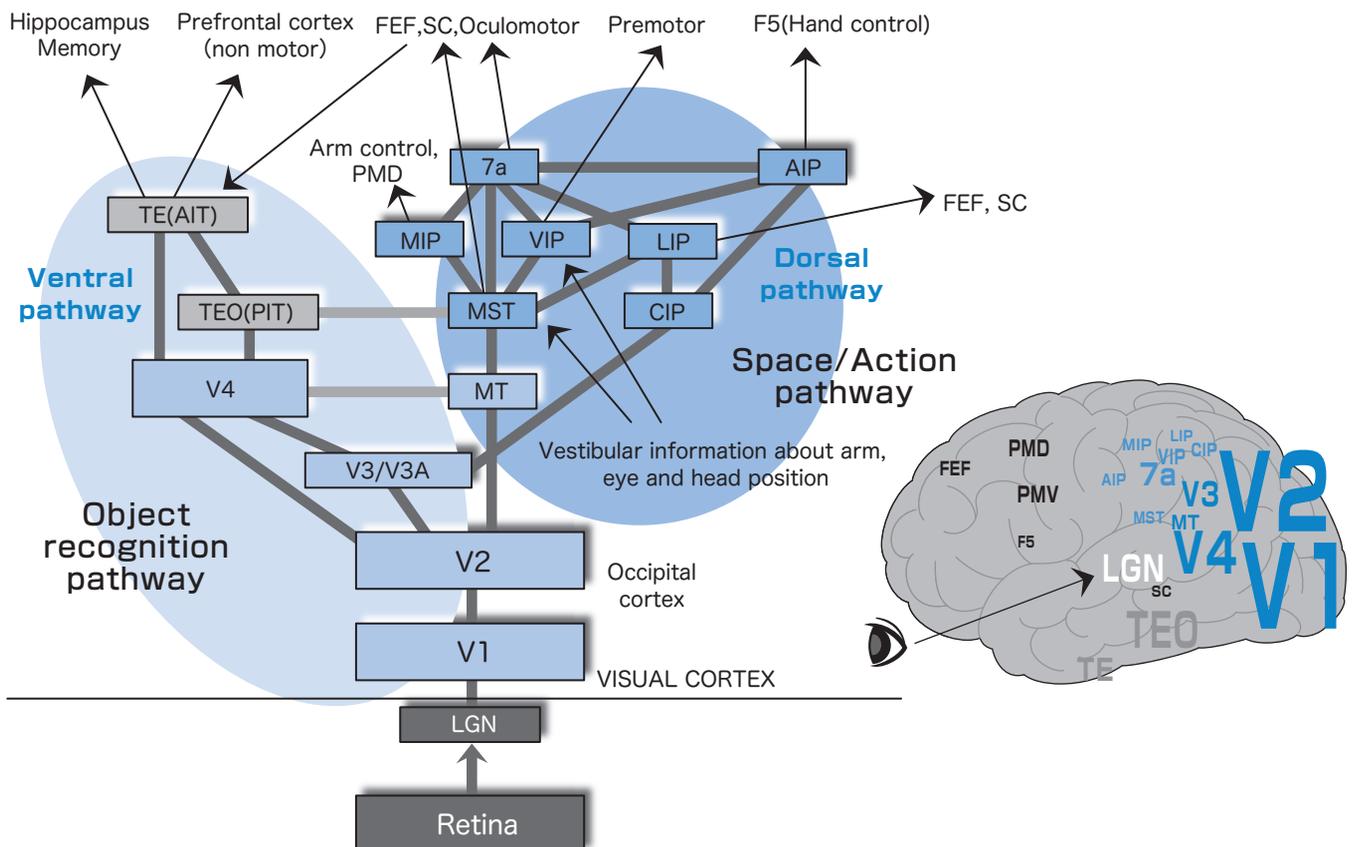
脳は、生理学的な特性によって“領野”（りょうや）と呼ばれる機能単位を有しており、視覚に関連する領野も様々な部位に分類できる。

図7は、脳の視覚野間の分類と関連性を模式的に表した図であり、視野中の形状に関する視覚信号は、腹側経路（V1野→V2野→V4野→IT（TE、TEO）野）と呼ばれる経路で処理される。

これらの領野のうち、比較的良好に知られているのは初期視覚野と呼ばれるV1野の細胞群である。V1野の細胞は、視野中に受容野と呼ばれる情報処理範囲を持ち、一つの細胞の反応する範囲は非常に局所的である。これらの細胞は、受容野に示された入力刺激が、自身の“好み”に適合しないと発火状態にならない。この好みのことを選択特徴などと呼ぶ。

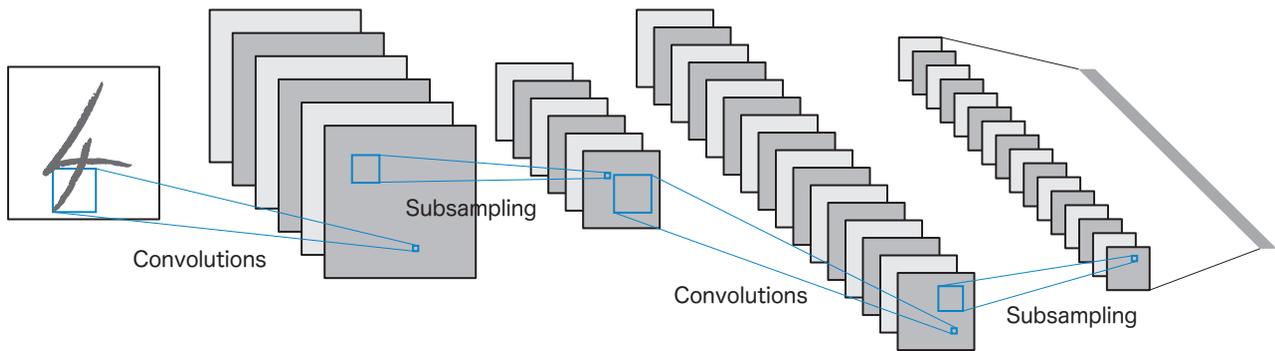
V1野細胞の受容野の大きさはおよそ1度程度の大きさであり、抽出特徴としては、それほど複雑ではなく、画像中の「線分」や「エッジ」といった成分を抽出していると考えられている。更に、この選択特徴の性質の違いによって、初期視覚野の細胞は、単純型細胞と複雑型細胞に分類される。

単純型細胞は、受容野内に提示される選択特徴の位置（位相と呼ぶ）に敏感で、受容野内に位置がずれて提示された選択特徴に対しては反応しない。一方、複雑型細胞も選択特徴を持つが、受容野内の提示位置の位置ずれに関しては寛容で、反応の低下はそれほど起こらない点が、単純型細胞との違いである。デイヴィッド・ヒューベル（David Hubel）氏とトルステン・ウィーセル（Torsten Wiesel）氏は、

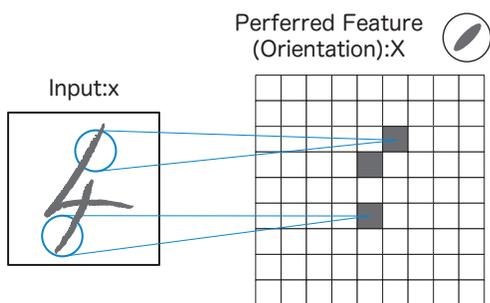


■図7 視覚野のつながり<sup>※8</sup>[11]

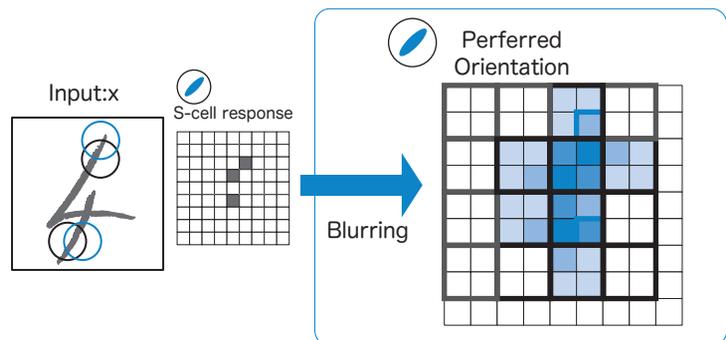
※8  
文献[11]より作成。



### S-cell(Conv.)Layer



### C-cell(Pool)Layer



■図8 ネオコグニトロンアーキテクチャの概要

これらの単純型細胞と複雑型細胞とが、階層的に結合された関係であることを提案し（階層仮説）、現在のところ広く支持されている。

一方、高次視覚野であるV4野からIT野にかけては、耳や鼻といった顔の特徴的な部位に強く反応する細胞や、顔そのものに反応する細胞と抽象的な概念を符号化している細胞が観測される。更には、特定の人々の画像のみならず個人名が書かれたテキスト画像にも同様に反応する、ある種の概念が符号化された細胞の存在も知られている。

これらの細胞では、受容野の大きさはかなり拡大され、IT野に至っては視野中のほぼ全域が受容野となる。すなわち、視野中のどこに物体や写真等を提示しても反応する細胞となっている。

福島邦彦氏は、これらの機能的な事実と生理学的な事実を基に、初期視覚野の細胞群のモデルとして以下のようなものを提案した（図8）。

まず、細胞が局所的な受容野を持つことを前提条件とし、このような細胞群を用いて画像全体を取り扱うために、同じ反応特性の受容野を持つ細胞をずらしながら2次元格子状に並べることとした。このように考えると、これらの細胞の計算は、工学分野で用いられる畳み込み（Convolution）演算として記述できる。この結果、畳み込み演算処理後の出力信号は、視野中のどこに選択特徴があったかを示す特徴マップとして表現される。

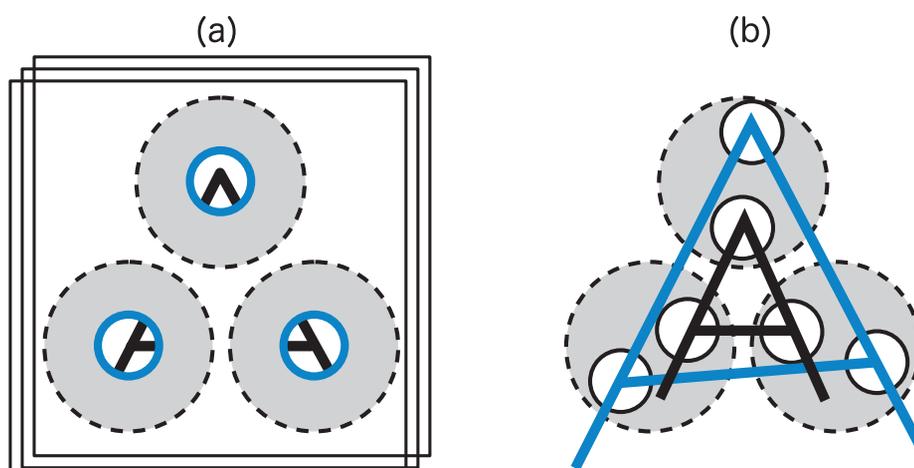
図8の左下の図では“斜め線”の特徴マップを表しており、特徴成分が入力のどこに出現しているのかを黒で示した。このように、単純型細胞は、入力層をいくつかの特徴成分に分解した特徴マップ群として表現する。この操作は視野中に含まれる信号から様々な特徴成分の抽出を行うことを意味する。一方、複雑型細胞は、特徴の位置ずれに寛容な細胞であり、選択特徴の位置（位相）がずれても反応する。位相がずれた位置に受容野を持つ細胞は、特徴マップとして考えた場合、位相ずれしていない位置に受容野を持つ細胞の周辺に存在するはずである。図8の右下の図では、斜め線の位相のずれた入力受容野位置を薄青色の円で示している。すなわち、複雑型細胞の特徴マップは、単純型細胞の特徴マップを

空間的にばかしたような特徴マップとして表現することができる。更に、複雑型細胞の特徴マップは、特徴の出現位置に対して冗長になるため、空間的なりサンプリング（プーリング）を行うことで空間的に情報圧縮を行うことが可能となる。

これらのネットワークアーキテクチャは「ネオコグニトロン」と呼ばれるニューラルネットワークモデルの基本構造となる。福島氏らのグループは、視覚野の高次機能を実現させるために、この基本アーキテクチャを外挿し、繰り返し表現の変換を行うことを提案している。このネオコグニトロンは、局所的な特徴を抽出し、空間プーリング位置ずれを許容しながら情報を圧縮することで、徐々に受容野を拡大し、情報を統合する脳の視覚野モデルとしてとらえることができる。福島氏らは、ネオコグニトロンを手書き文字認識などの問題に適用し、高度な識別器が実現できることを示してきた。また、ネオコグニトロンは、ニコス・ロゴテティス (Nikos Logothetis) 氏らの示したIT野の細胞表現と類似した機能を実現し得ることが示唆されている[12]。

一方、画像処理分野におけるディープラーニングのモデルとして、既にデファクトスタンダードとしての地位を築きつつあるDeep CNN (DCNN) がある。福島氏のネオコグニトロンでは、クラスタリングに代表される教師なし学習を用いて学習することが提案されていたが、ネオコグニトロンの構造自身は、学習手法を限定するものではない。ニューヨーク大学のヤン・ルカン (Yann LeCun) 氏らは、ネットワークアーキテクチャとして、このネオコグニトロンの基本構造を用い、学習手法として機械学習で用いられる誤差逆伝播法を用いたモデルを提案しており、これらの組合せが現在のCNNの基本となっている。2012年に、当時トロント大学 (現在はGoogleに在籍) のアレックス・クリジェフスキー (Alex Krizhevsky) 氏らが発表し、コンピュータビジョン分野に大きな衝撃をもたらした「AlexNet」や、2014年に発表された「VGG」(Visual Geometry Group) といったネットワークも、基本的にはネオコグニトロンのネットワークアーキテクチャを踏襲している。このように、現在のディープラーニングのオリジンの一部は、脳のモデルとしてとらえることができる。

図9にCNNの動作理解を行うための模式図を示す。図中の“A”という線画は、(b) の図に示した複数の“A”のように、異なる大きさと形状を持ち得るが、上端部の尖った形状とT字型の結合部の形状は、共通して持っている特徴ととらえられる。CNNの内部の畳み込み層 (Convolution Layer) は、前述



■図9 CNNの動作原理の概要<sup>9</sup>

※9  
「神経回路モデル「ネオコグニトロン」」『発明と発見のデジタル博物館』国立情報学研究所ウェブサイト <<http://dbnst.nii.ac.jp/pro/detail/498>> より改変 (copyright 電子情報通信学会、許諾番号：17SB0039)

の単純型細胞群に対応し、これらの特徴を別々の特徴マップとして表現する。このため、図9の (a) のように、3種類の特徴マップで表現される。

一方、プーリング層 (Pooling Layer) は複雑型細胞群に対応し、畳み込み層で得られた特徴の位置をぼかしたような特徴マップを出力する。このプーリング層の出力を受ける上位層では、図9の (a) の 'A' という文字に含まれる3種類の特徴のおおよその位置を組み合わせた特徴を、新たな高次特徴としてとらえる。このプーリング層のぼかし操作は、多少特徴の出現位置が変化しても許容する操作となる。

結果としてこれらの三つの特徴の組合せが揃っていれば、同じ特徴としてとらえる動作を行うため、変形などに強い特徴表現を構成できる (図9の (b))。このようにCNNでは、ネットワークが深い階層を取るほど、複雑な組合せ特徴を表現できるような構造になっている。

## 1.2.5 リカレントニューラルネットワーク

2015年の大規模画像認識チャレンジでは、「残渣ネット」(Residual Network; ResNet) (1.2.7項参照) の成績が人間の成績を上回った。2016年の結果も、前年の結果を踏襲しており、ResNetの変形によるショートカット付き多層化CNNモデルで、領域切り出しネットワーク (Region Proposal Network; RPN)、超高速領域CNNを複数合議制 (アンサンブル) で精度向上を実現した。画像認識においてはCNNとそのアンサンブルで精度向上を目指す流れとなっている。このため多層CNNは画像認識、音声認識で一般的な手法となっていると考えられる。

そういったCNN (畳み込みニューラルネットワーク) は、ニューラルネットワークの層を一方通行で処理が行われる。

これに対して、再帰的な繋がりを持つネットワークとして「リカレントニューラルネットワーク」(RNN) に対する研究も進んでおり、自然言語や時系列データなどの連続性のあるデータに対して適用されている。「画素RNN」のように、静止画を右上から走査して系列情報処理モデルであるRNNモデルにより認識させるという手法も提案されている。この手法は時々刻々変化する中間層に何らかの表象が形成されることを仮定したモデルであり、一つの方向と言える。

2015年以降、「生成敵対ネットワーク」(Generative Adversarial Network; GAN) により画像を生成する手法が注目を集めた。この手法を用いれば、未知の画像を生成することができる。2014年以降にCNNの最終畳み込み層の結果をRNNへと接続したニューラルネットワークによる画像脚注生成技術と相まって、画像から言語、言語から画像、言語から音声や音楽など、異なる感覚様式を変換する手法への道が開かれた。このような流れはパターン認識技術の範疇を超え、AIと呼ぶにふさわしい領域へと一歩近づいたとみなして良いだろう。最終畳み込み層の上にソフトマックス層による認識層を使うのではなく、認識層の代わりに領域提案層、言語処理層、音韻処理層などを付け替えて、事前学習とファインチューニングを組み合わせることで学習時間の短縮を行うことが可能であるため、一般のユーザでも手軽に一般画像認識結果の恩恵を享受することができ、今日の熱狂につながったと言えよう。

RNNは系列予測、姿勢制御、自然言語処理への応用などが考えられてきた。近年、RNNの学習に関する勾配消失、勾配爆発問題を回避する手法が一般化したこと、大量のデータをGPUにより高速に処理できるようになったことを受け、性能を向上させてきた。2016年にはGoogleの自動翻訳サービスの精度が向上されたことが話題となったが、従来手法である統計的機械翻訳 (Statistical Machine Translation; SMT) に対して、ニューラルネットワーク機械翻訳 (Neural Machine Translation; NMT) が支配的になりつつある。この分野と画像処理において、任意の場所を選択的に処理する注意機構の導入は、画像と言語と領域は異なるものの数式は同一であり、脳内でも同じような機構が仮定で

きるのではないかと予想される。

アーケードゲームを解くために、認識技術にCNNを用い、高得点を得るために強化学習を用いる手法は、囲碁において世界チャンピオンレベルの強さを有するに至った。この枠組みは更に進歩しているが、かつてのチェスの木探索をブルートフォース<sup>10</sup>に行うのではなく、強化学習による一般的な解法を求めるアルゴリズムを用いている点が、従来からの特化型AIによる人間の専門家への挑戦という枠組みでは取まらない、一般的な解を模索する方法を提供しているように思われる。

以上のように、以前のブームをもたらした技術に比して、汎用性の高いアルゴリズムを用いていることがここでの特徴であり、今後更に発展するものと期待される。

## 1.2.6 表現学習

「表現学習」(representation learning) は、ディープラーニングを抽象化した概念である。機械学習の手法を構成する際に、有用な情報を抽出することができる、すなわちデータの特徴表現 (あるいは、内部表現、素性 (feature)) を学ぶ学習の方法である。機械学習の性能は、データの表現に大きく依存しており、従来は人間の知識や職人技により、素性を構築することが広く行われてきた (素性工学 (feature engineering) と呼ばれる)。それを自動で学習するものが表現学習である。

例えば、曜日と天候から、店の売上を予測したいとする。それには、過去のデータを使って、曜日を表す変数 $x_1$ と天候を表す変数 $x_2$ から、お店の売上 $y$ を回帰する式を見つければよい。ところが、何を変数に置くかというのは、通常は問題の外にある。例えば、安売りをしているかどうかという変数 $x_3$ を入れると、予測精度が大きく上がるかもしれない。

こうした特徴表現は、通常は人間の知識や職人技によって定義されるが、それによって機械学習の性能が大きく異なってしまう。あるいは、別の例では、画像に車が映っているかを判定したいとする。その際、ホイールが映っているか、ハンドルが映っているかななどを素性にすると良さそうであるが、画像から得られた画素の値という観測データ (あるいは生データ、RAWデータ) からそれらの素性をどう構成するのかというのは自明ではない。

特徴表現を学習する方法としては、従来から、様々なクラスタリング法、あるいは主成分分析 (Principal Component Analysis; PCA) や独立成分分析 (Independent Component Analysis; ICA) などの次元圧縮による手法がよく知られている。近年ではディープラーニングに注目が集まっているが、これも表現学習の一つである。ディープラーニングは、層の数が多いニューラルネットワークによって、観測データから本質的な情報を抽出した特徴表現を学習する [13]。

知的な情報処理とその学習における特徴表現の重要性は、AI、認知科学、機械学習、データ解析等の研究において古くから何度も指摘されてきた。デイヴィッド・マー (David Marr) 氏は、いかなる計算機の計算処理も、計算理論、表現とアルゴリズム、ハードウェアという3階層から理解され得ると述べた。情報をどのように表現するかによって、アルゴリズムによる処理が大きく影響を受ける。

よい「表現」とは何かというのは、単純なようで難しい問いである。よい表現とは、何らかの意味で事象を抽象化したものであり、観測データの説明要因をとらえることで、一見自明ではない共通点をとらえることができるものである。ヨシュア・ベンジオ (Yoshua Bengio) 氏は、よい表現に共通するものとして、世界に関する多くの一般的な事前知識 (あるいは事前分布、prior) を挙げている。

代表的な事前知識に該当するものとして、

---

※10

すべての経路を総当たりで探索する。

- (1) 滑らかさ
- (2) 複数の説明要因
- (3) 説明要因の階層的構造
- (4) 半教師あり学習
- (5) タスク間の共通要因
- (6) 多様体
- (7) 自然なクラスタ化
- (8) 時間的空間的一貫性
- (9) スパース性 (データの分布のまばらさ)
- (10) 要因の依存の単純性

などが挙げられる。例えば、よい表現とはスムーズな関数を用いるものであり、また時間的空間的一貫性を持っている。ディープラーニングのアプローチは、なかでも、(3) (5) (10) などに注目していることになる。逆に言えば、こうした事前知識を適切に活用することができるなら、表現学習は必ずしも層の数が多いニューラルネットワークの形をしていなくても良いということになる。

ディープラーニングで特徴的であるのは、簡単な関数の組み合わせで難しい関数を構成することである。通常、浅い構造よりも深い構造のほうがよりコンパクトに関数を表すことができる。そのことにより、素性の再利用と抽象的な概念 (あるいは不変量) の獲得を可能にしている。ディープラーニングによる表現の獲得の例として、「深層信念ネットワーク」(Deep Belief Network) を用いて、インターネット上の動画から切り出した画像を入力し、猫の概念を生成したというGoogleの研究が有名である。また、抽象的な概念を頑健に獲得するには、設定の異なる複数のニューラルネットワークでの共通部分を見つけるとよいという最近の研究もある。

人間の知能においては、得られた抽象的な概念を、言語にマッピングし操作可能にしているところが特筆すべき点であろう。これに関連する有名な問題に、シンボルグラウンディング問題がある。AIにおける難問の一つであり[14]、スティーブン・ハーナッド (Steven Harnad) 氏によって命名された。記号で指し示されるものを計算機がどのように認識するかという問題であり、概念に接続 (グラウンド) されることなしには、記号処理が意味をなさないことを議論している。

更に遡れば、同様の議論は歴史的に古くからあり、スイスの言語哲学者であるフェルディナン・ド・ソシュール (Ferdinand de Saussure) 氏は、記号内容と記号表記を、シニフィエ、シニフィアンと呼んだ[15]。また、イギリスの哲学者ジョン・ロック (John Locke) 氏は、人間知性論のなかで、白紙の心の状態から概念が経験に由来して発生すると考えた[16]。

概念と言語のバインディングは、最近でも活発に研究が行われており[17][18]、またディープラーニングの文脈でも言語表現と画像特徴のアライメントを取るような研究も行われている。ディープラーニングを中心とする表現学習の方法の研究により、人間の持つ知性、特に言語を使った能力についての理解や、その工学的な応用も進んでいくことになるかもしれない。

表現学習においては、今のところディープラーニングのような深い構造を持ったニューラルネットワークを用いるアプローチが優勢であるが、必ずしもその構造が必然的なわけではない。(かなりいい線をいっているのは確かであるが) 将来的には、今のニューラルネットワークと全く違う形での、より理論的な表現学習の手法が出現する可能性はあるだろう。

## 1.2.7 ディープラーニングの画像認識への応用

2012年に開催された一般物体認識のコンテスト「ILSVRC」(ImageNet Large Scale Visual Recognition Challenge)において、深い構造を持つCNNが、従来手法の分類性能を大幅に上回って以来、ディープラーニングが画像認識に盛んに利用されるようになった。ここでは、ディープラーニングの画像認識への応用として、クラス分類、物体検出、物体セグメンテーション、画像キャプション生成、画像生成について述べる。

### 1.2.7.1 クラス分類

一般に、CNNは、層を沢山重ねて深い構造にすることで、より高い精度で物体を分類できるようになるが、その反面、パラメータ数が膨大となり学習が困難になる。そこで、深い層でも学習がうまくいく枠組みとして、「ResNet」が提案されている。ResNetは、出力を入力と入力からの差分の和でモデル化したネットワークである。この構造によって、上層からの誤差が下層まで伝播するようになり、1000層といったかなり深い構造でも適切に学習が可能となった。

ResNetは、ILSVRC2015の様々な部門において、トップの成績を獲得した。このときの物体クラス分類課題における、上位5位までに正解が含まれないエラー率は、3.57%であった。一方、ILSVRC2016における同部門の1位のエラー率は2.99%、2位が3.03%、3位が3.04%であり、2015年と比較して分類性能はほとんど伸びていない。また、ILSVRC2016のトップの手法は既存技術の組合せであり、物体クラス分類において、この1年間はインパクトのあるトピックが出ていない状況にある。

### 1.2.7.2 物体検出

物体検出とは、画像内の物体を取り囲むボックスを推定するタスクである。物体検出においても、ディープラーニングを利用して検出精度の向上が実現されている。ディープラーニングを利用した物体検出の例として「R-CNN」(Regions with CNN)がある。

R-CNNでは、選択的検索法から得られる物体領域候補内の画像を、事前に学習しておいたCNNに入力し、この領域の画像特徴を抽出する。次に、線形サポートベクトルマシンに抽出された画像特徴を入力し、領域の物体クラスを予測する。R-CNNによって高い検出性能は得られるが、R-CNNは物体領域候補の数だけCNNの順向き伝播の計算が必要である。また、R-CNNは物体検出ネットワークとは別のモジュールで物体領域候補群を計算する必要があった。そこで、物体検出ネットワークと共通の特徴マップから領域候補群を提案するネットワークを作り、この物体検出ネットワークと領域提案ネットワークを統合した「Faster R-CNN」が提案されている。

上記手法では、推定された物体領域候補に物体クラス分類手法を適用することで、画像内の物体の検出を行っていた。物体検出を回帰問題ととらえてモデル化することにより、物体領域を提案するネットワークを不要とし、一つのネットワークで実現できるアルゴリズムも提案されている。また、検出性能を直接的かつEnd to Endで最適化可能であり、検出自体も高速に実行できる。

### 1.2.7.3 物体セグメンテーション

物体セグメンテーションは、物体を取り囲むボックスではなく、対象物体と背景を境界まで詳細に切り分けるタスクである。ディープラーニングを利用した代表的な手法として「FCN」(Fully Convolutional Network)がある。クラス分類のネットワークは前段が畳み込み層、後段が全結合層となっている。カーネルサイズを入力特徴マップのサイズと同じにすれば、全結合層を畳み込み層とみなすことができる。そこで、クラス分類のネットワークの全結合層を畳み込み層に置き換えることで、どの領域に

何がありそうかを表現した分類マップを得ることができる。しかしながら、このままではプーリングの影響で分類マップの解像度が低いため、分類マップを入力画像サイズにアップサンプリングすることで最終的な物体セグメンテーション結果を得る。

上記手法は、ピクセルレベルでセグメンテーションを行うため、意味レベルでの物体セグメンテーションには適切ではない。例えば、複数のリングが隣接して置かれた場合、リング同士を切り分けることは困難である。そこで、各物体を分けつつ物体を背景から切り出す手法として「MNC」(Multi-task Network Cascade)などが提案されている。

#### 1.2.7.4 画像キャプション生成

現在の潮流として、画像と自然言語処理の融合分野がある。この融合分野のタスクとして、画像から「赤い服を着た女性が街中で電話をしている」のような、自然言語で記述された画像キャプションを生成することが挙げられる。基本的なキャプション生成の流れは、画像をCNNに入力し、CNNから得られた画像特徴を、時系列を扱えるネットワークであるLSTMに入力する。LSTMは内部記憶を持っており、事前に生成した単語を考慮しながら、単語を次々と生成していき、最終的な文章を作り出す。

#### 1.2.7.5 画像生成

画像生成も注目を浴びている技術である。2015年にGoogleが「Deep Dream」と呼ばれるシステムを開発し、大きな話題となった。Deep Dreamは、通常の画像を夢に出てくるような神秘的な画像に変換するシステムである。

また、Googleは「Deep Style」と呼ばれる、入力画像の画風（例えば、ゴッホなど）を変換するシステムを開発し、AIが製作する芸術作品としてメディア等で取り上げられている。

いま最も利用されている画像生成手法は、生成敵対ネットワークを利用している。このネットワークは、画像生成器と画像識別器から構成されており、画像生成器は分類器を騙すような画像を生成し、識別器は生成器から生成された画像と本物の画像とを分類するようにそれぞれ学習する。このように競合して学習することで、生成器は適切な画像を生成することが可能となる。

### 1.2.8 ディープラーニングの音声認識への応用

音声認識においてニューラルネットワークを用いる研究は、1990年代初頭に活発に行われたが、その後は混合正規分布 (Gaussian Mixture Model; GMM) に基づく隠れマルコフモデル (Hidden Markov Model; HMM) が一般的となった。大規模なデータを収集して、多数のテンプレート (sum of experts) を用意すれば性能がいくらかでもよくなると考えられていた。これに対して2010年頃にヒントン氏らが、多段のネットワーク (product of experts) を学習するディープラーニングにより、一般的な音素認識タスク (Texas Instruments Massachusetts and Institute of Technology; TIMIT) で驚くべき性能を挙げた。その後MicrosoftやIBM、Googleなどの研究者らにより、種々の大語彙連続音声認識でも大きな改善が得られることが示された。音声認識は、ディープラーニングが最初に成功を収めたタスクの一つである。

現在、世の中で一般的な音声認識システムの構成を図10に示す。この音素状態の認識において、GMMの代わりに深層ニューラルネットワーク (Deep Neural Network; DNN) を用いているのが眼目である。その後の展開を含めて、図10の各要素におけるディープラーニングの導入について以下に述べる。

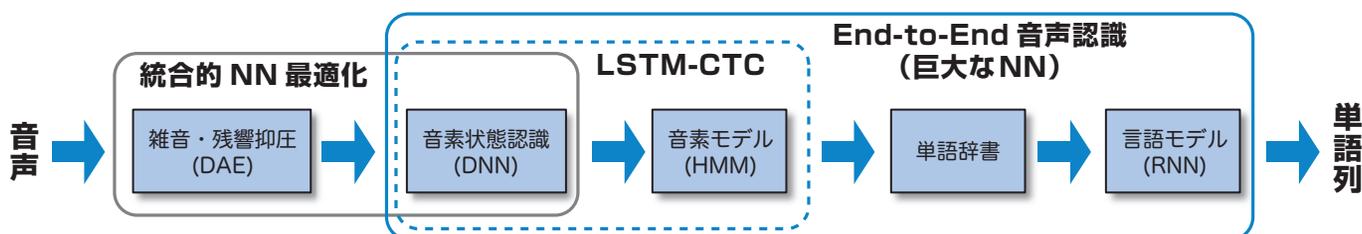
### 1.2.8.1 音素モデルにおけるディープラーニング

前記のとおり、DNNは音響特徴量（音声の周波数スペクトル）を入力として、音素状態（音素を細分化した数千クラス）のカテゴリに分類する。これは基本的には教師付き学習であるが、そのためには事前に音声データを音素状態に区分化する必要がある。これはGMM-HMMなどを用いて自動的に行われる。音素や単語の時系列のモデル化には、HMMが依然として用いられている。

これに対して近年、HMMを一切用いずに、RNNの一種であるLSTMを用いて、音響特徴量の系列から音素や文字などの系列に直接変換するCTC（Connectionist Temporal Classification）という方式が注目を集め、従来のDNN-HMMの性能に近づきつつある。

### 1.2.8.2 言語モデルにおけるディープラーニング

言語モデルは単語系列仮説の尤度（ゆうど）<sup>11</sup>を評価するもので、従来はN-gramモデルが一般的に用いられてきた。これに対して近年、RNNを用いたモデルも導入・併用され、認識率の改善を実現している。



■図10 典型的な音声認識システムの構成とディープラーニングの導入

### 1.2.8.3 雑音・残響抑圧におけるディープラーニング

自動車内や家庭内の機器やロボットの音声認識においては、雑音や残響の影響が大きな問題となり、音響特徴量の計算においてこれらの影響を抑圧する処理が必要となる。従来は、線形フィルタや統計的なモデルが用いられてきたが、近年はデノイジングオートエンコーダ（Denoising Auto Encoder; DAE）などのディープラーニングが用いられている。また、複数のマイクロフォンを用いて音声を強調する場合でも、雑音の分離などにDNNが用いられる。

更に、この雑音・残響抑圧のDNNと音素状態認識のDNNを連結して巨大なニューラルネットワークを構築し、統合的に最適化することも検討されている。

### 1.2.8.4 End to Endのモデル化

前記のCTCを含めて、音響特徴量から音素、文字列、更には単語列に直接変換するアプローチをEnd to Endモデル<sup>12</sup>と呼ぶ。単語辞書や言語モデルも含めて、統合的にディープラーニングの枠組みで構築することも検討されている。ただし、日本語や英語などの主要言語では、テキストのみのデータが圧倒的に多いので、言語モデルを単独に学習したほうがよいのは明らかである。

※11

統計学において、ある条件から結果を得た場合に、結果から逆に条件を推測する際の尤もらしさを表す数値。

※12

End to End Learningは深層学習の重要な方法論の一つ。従来は、入力から出力まで概念的に複数の段階の処理が必要な場合には、個々の処理をステップバイステップで学習した後にそれらを統合するという手順が必要であったが、深層学習により、入力から出力までを一つのネットワークとして表現することで全体のネットワークを一気に学習できるようになった。

### 1.2.8.5 音声合成におけるディープラーニング

音声認識の逆過程である音声合成においても、ディープラーニングの導入が活発に行われている。2016年に発表された「WaveNet」では、階層的に履歴を集積する巧妙なRNNの構造を導入することで、高い品質の音声合成を実現している。

ニューラルネットワークはブラックボックスであるが、可塑性が高いので、複数言語のモデルを統合的に学習したり、画像情報と組み合わせたり、様々な展開が行われている。また、音声認識の典型的な後処理である対話や翻訳においてもディープラーニングが導入されているので、それらとの密な結合も今後考えられる。

### 1.2.9 ディープラーニングの芸術への応用

一般的には極めて人間的な行為と考えられている創造性が必要な絵画や音楽等の芸術分野においてもAIの応用が始まっている。

芸術への応用を目指す研究の端緒の一つは、画像を生成することに関する研究がいくつか発表されたことである。2015年、GoogleがAIを用いた画像処理アルゴリズムとして「Deep Dream」を公開した。Deep Dreamは、学習済みのCNNの内部がどのようになっているかを知るために開発された手法である。学習済みのCNNに対し、指定した画像を入力し、写っている物体を例えば「犬」とであると認識したとする。その場合、「犬」という判定結果を強調するように元の画像を少し変化させる。これを繰り返すことにより、画像全体を変化させていくものである。このように、本来は学習済みのCNNの中を知るために開発されたアルゴリズムであるが、生成されるパターンがサイケデリックな画像となるため、一般にも注目を集めた。

また、同年、Googleはディープラーニングを用いた画像生成手法として「DRAW」(Deep Recurrent Attentive Writer)を発表している。DRAWアルゴリズムは、生成モデルとして「VAE」(Variational Auto Encoder)を用い、さらに画像中の各部分に注意を向けながらRNNで反復的に画像を生



■図11 BEGANにより生成された顔画像の例<sup>13</sup>

※13

David Berthelot et al., "BEGAN: Boundary Equilibrium Generative Adversarial Networks." Cornell University Library Website <<https://arxiv.org/pdf/1703.10717.pdf>>

成するモデルであり、数字の画像を生成することに成功した。更に、2016年には、自然言語で書かれた文に対応した画像を生成する「AlignDRAW」がトロント大学により発表されている。ぼやけた画像ではあるものの、「A stop sign is flying in blue skies」（停止標識が青空を飛んでいる）、「A toilet seat sits open in the grass field」（芝生のなかに便座が開いている）など、通常存在しない状況に対応した画像も生成可能であることを示した。また、Googleは「BEGAN」（Boundary Equilibrium Generative Adversarial Network）という生成モデルを用いて、自然な人物の顔画像の生成に成功している（図11）。

Deep Dreamと同時期に、画像や絵をディープラーニングで生成する技術を芸術の分野で応用しようという研究が出始めた。2015年、ドイツのチュービンゲン大学の研究者らによって、「A Neural Algorithm of Artistic Style」と呼ばれるアルゴリズムが開発された。このアルゴリズムでは、葛飾北斎やゴッホらの画風を特徴量（「スタイル」と呼ばれる）として学習し、任意の画像にスタイルを重ねて出力することで、北斎風やゴッホ風のように変換できるようにしたものである。

2016年には生成モデルの「DCGAN」（Deep Convolutional Generative Adversarial Network）を用いて同様のことが可能であることが示されている<sup>14</sup>。

また、デルフト工科大学（オランダ）とMicrosoftは、17世紀の画家であるレンブラントの絵画の題材や筆づかい、色合いといった作品が持つ特徴をディープラーニングにより分析して、3Dプリンタによって再現するプロジェクト「The Next Rembrandt」を推進しており、2016年にその成果を公開した<sup>15</sup>。レンブラントの全作品を3Dスキャンでデジタル化し、オランダのマウリッツハイス美術館とレンブラントハイス美術館の専門家の協力を得て、ディープラーニングによって作品の特徴が分析された。

音楽分野への応用も始まっている。ソニーコンピュータサイエンス研究所（Sony CSL）は2016年、AIを使ってリードシート<sup>16</sup>を登録したデータベースから音楽スタイルを学習し、学習したスタイルを用いて自動的に作曲することを目指すプロジェクト「Flow Machines」を発表した<sup>17</sup>。このアルゴリズムを用いて、例えばビートルズ風のスタイルを指定すると、実際に作曲が可能であることを示した<sup>18</sup>。また、プリンストン大学のキム・チソン（Ji-Sung Kim）氏が2016年に開発した「deepjazz」<sup>19</sup>は、2層のLSTMを用いてジャズの楽曲を学習し、ジャズを生成できるようにした。

そのほか、カリフォルニア大学サンディエゴ校のクリス・ドナヒュー（Chris Donahue）氏らが、2017年に任意の音楽を入力するとゲームセンターの音楽ダンスゲームである「ダンスダンスレボリューション」のステップを生成するアルゴリズムである「Dance Dance Convolution」を発表した。Dance Dance Convolutionでは、入力された音楽の特徴的なタイミング（ステップを踏むべき点）を音楽のスペクトルから学習し、難易度を指定するとLSTMを用いてステップを生成する。

また、AIで小説を生成しようという試みとして、公立はこだて未来大学の松原仁氏らによる、ショー

※14

「ディープラーニングによる傑作：人工知能の画期的なスタイルを紹介するキャンパスがGTCに登場」NVIDIAウェブサイト <<https://blogs.nvidia.co.jp/2016/04/11/artificial-intelligence/>>

※15

「人工知能が描いた「レンブラントの新作」」WIREDウェブサイト <<http://wired.jp/2016/04/14/new-rembrandt-painting/>>

※16

ポピュラー音楽の歌や、ジャズの曲を楽譜にするときによく使われる、基本的な部分のみを取り出して紙などに書きあらわす記譜法。

※17

Flow Machinesは、欧州研究評議会（European Research Council; ERC）からの資金提供を受けて開発されている。Flow Machines Website <<http://www.flow-machines.com/>>

※18

「世界初の人工知能が作ったポップソング「Daddy's Car」と「Mr Shadow」がYouTubeで公開中」Gigazineウェブサイト <<http://gigazine.net/news/20160924-daddys-car-ai-song/>>

※19

deepjazz Website <<https://deepjazz.io/>>

※20

「きまぐれ人工知能プロジェクト作家ですよ」公立はこだて未来大学ウェブサイト

<[https://www.fun.ac.jp/~kimagure\\_ai/index.html](https://www.fun.ac.jp/~kimagure_ai/index.html)>

トショートを創作させることを目指すプロジェクトがある<sup>20</sup>。2016年に行われたショートショート分野の新人賞である第3回星新一賞<sup>21</sup>では、作成時にAIを利用した2作品が一次審査を突破した。現状では、作品作成時におけるAIの利用割合は部分的であり、近い将来に完全にAIでの執筆が可能になることは困難と考えられる。ただし、その前段階として、人間が小説を執筆する際の支援に利用できるようになる可能性がある<sup>22</sup>。

## 1.2.10 ディープラーニングの実現技術

### 1.2.10.1 ディープラーニングのソフトウェア

ディープラーニングはソフトウェアフレームワークを利用して実装するのが一般的である。多層のニューラルネットワークモデルを定義し、メモリ上に対応する計算グラフを構築し、データを用いて学習・予測を実行するのがフレームワークの役割だが、重要なのはネットワーク記述方法とその柔軟性である。

ネットワークの記述方法の一つ目は、設定ファイルによる記述であり、「Caffe」や「CNTK」(Microsoft Cognitive Toolkit)などがこの方式を採用している。ユーザはデータに適用する関数の種類とその設定を順に並べたテキスト形式の設定ファイルを用意し、これをフレームワークが読み込んでネットワークを構築する。ネットワークの定義自体がテキストデータとなるために可搬性が高く、実システムへの組込みが容易になる一方、ループ構造を持つRNNなどのように、複雑になると人手でネットワーク構造を記述することは難しい。

二つ目はプログラムによる記述であり、「TensorFlow」や「Chainer」など、多くのフレームワークが採用している。ループ構造などもプログラムであれば簡単に記述できる。一方でネットワークの定義がソースコードの形で与えられるため、可搬性はそのプログラミング言語に依存する。

学習を行う際は、ネットワークの定義からモデルをメモリ内に構築したあと、訓練データを入力して順方向計算と誤差逆伝播による勾配計算を行って、パラメータ更新を行うのが一般のフレームワークのアプローチである。この方法では、学習を行う前にモデルが固定化されるため、その際にネットワークの性能面の最適化を行える。ただし、柔軟さに欠けるため、学習時に確率的に構造が変化する動的なニューラルネットワークを扱うのが得意ではなく、特別な計算コンポーネントを導入する必要がある。

一方、プログラム中に直接順伝播の処理を書き、毎回その処理を呼び出すことでネットワークの構築と学習を同時に行う柔軟なアプローチも存在する。これはChainerや「PyTorch」が採用しており、Define by Runや動的計算グラフとも呼ばれる。プログラムのデバッグや性能のプロファイリングは容易であるが、計算上のオーバーヘッドは増える傾向がある。だが、近年アルゴリズム提案が増えている動的なニューラルネットワークを、プログラムとして直感的に記述できるため、その重要性は増している。

### 1.2.10.2 ディープラーニングの実装

#### (1) 行列演算による実装

神経回路のアナロジーでは、多数のユニットを結ぶ重み付き有向辺(矢印の付いた辺)で表現されるニューラルネットワークだが、計算を効率的に行うために、行列演算と非線形関数の組合せで書かれることが多い。行列演算は科学計算一般で用いられるため、高度に最適化された既存の実装が利用可能で

---

※21  
「第3回 日経「星新一賞」日経星新一賞ウェブサイト  
<[http://hoshiaward.nikkei.co.jp/no3\\_result/index.html](http://hoshiaward.nikkei.co.jp/no3_result/index.html)>

※22  
「AI、小説の大海原に乗り出す 作家誕生の日はいつ?」NIKKEI STYLE ウェブサイト  
<<http://style.nikkei.com/article/DGXXZO03732040X10C16A6BC8000>>

ある。画像認識などが応用先にあることを考えると、ベクトルと行列だけでなく三つ以上の軸を持つテンソルも扱えることが望ましい。

## (2) 勾配の計算手法

行列演算と非線形関数で記述されたニューラルネットワークは、それらを合成した巨大な関数と見なせる。これを勾配法によって最適化する場合、各辺の重みやバイアス項に関する勾配を求める必要がある。たとえ巨大なネットワークであっても、合成関数として与えられているので、その微分は連鎖律を用いて各関数のヤコビ行列の積として展開できる。

ディープラーニングで最も一般的な勾配計算法は誤差逆伝播法で、連鎖律によって展開された勾配を、出力に近い関数のヤコビアンから逆順に求めるために、こう呼ばれる。合成関数の勾配計算には自動微分 (automatic differentiation) と呼ばれる数値計算アルゴリズムが用いられる。

CNNなどの単純なフィードフォワードネットワークだけでなく、RNNでも計算手順を時間方向に展開することで、誤差逆伝播法を用いることができる。これを通時的逆伝播 (backpropagation through time) と呼ぶ。途中状態を全て保存しなければならないため、実際には長い系列では逆伝播を打ち切るヒューリスティクスが用いられる。

## (3) 最適化ルーチンと効率化

ニューラルネットワークの勾配を計算したあとは、確率的勾配法に基づく最適化ルーチンを実行することで、パラメータを更新する。最適化アルゴリズムとしては単純なSGD (Stochastic Gradient Descent) に加え、RMSProp、Adamなどがよく用いられる。一般には全てのパラメータについて同一のものを選択する。

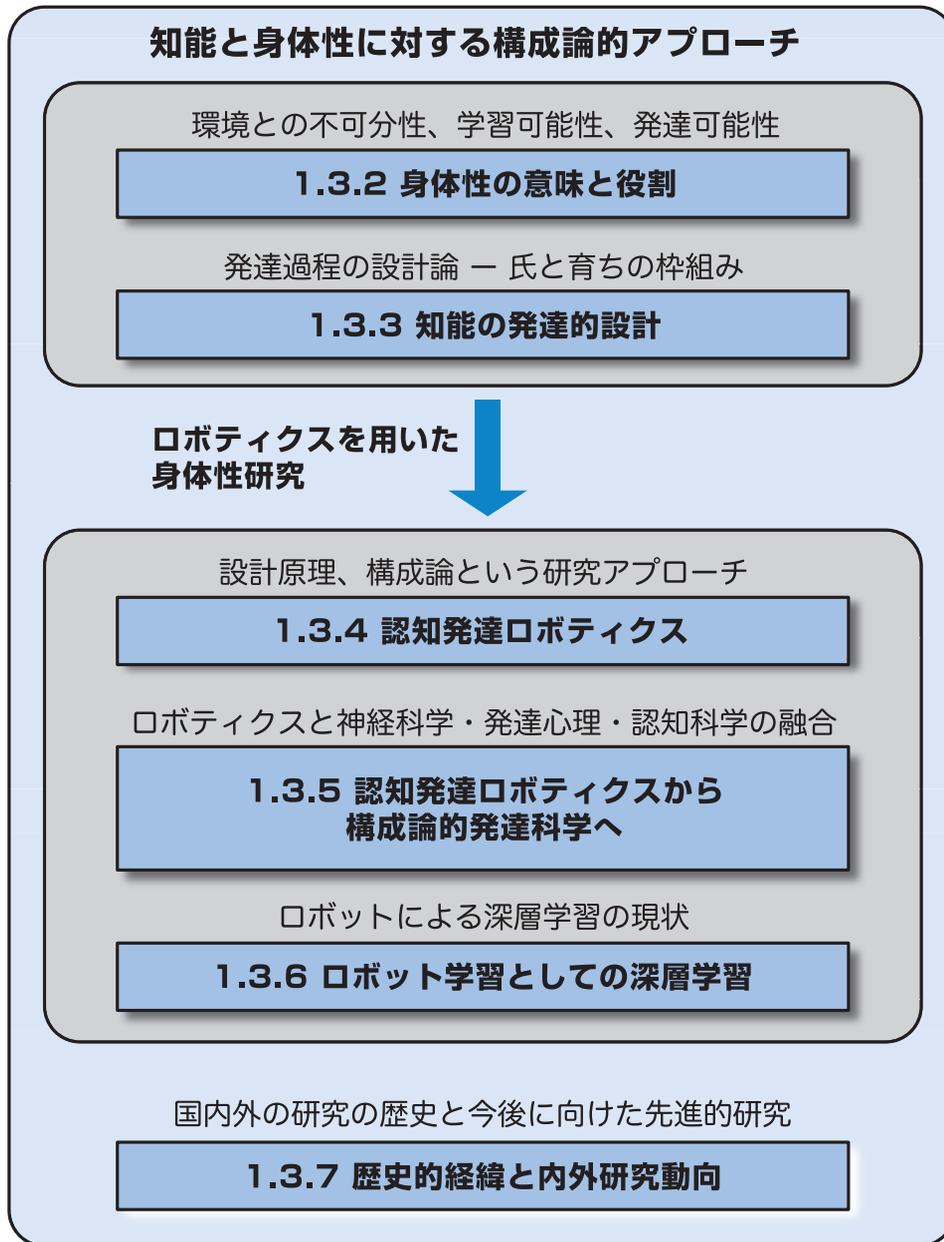
また大量の訓練データを高速に処理するため、オンライン学習で複数の学習サンプルからまとめて勾配を計算するミニバッチと、その並列計算が併用されることが多い。特にNVIDIAの汎用GPUを用いた大幅な高速化は、大規模データセットを用いて複雑なニューラルネットワークを現実的な時間で学習するために必須である。

### 参考文献

- [1] 銅谷賢治ほか「小脳、大脳基底核、大脳皮質の機能分化と統合」『科学』vol.70 No.9, pp.740-749.
- [2] 浅田稔・國吉康夫『ロボットインテリジェンス』岩波書店.
- [3] 高橋泰岳・浅田稔「実ロボットによる行動学習のための状態空間の漸次的構成」『日本ロボット学会誌』vol.17 No.1, pp.118-124.
- [4] 保田俊行・大倉和博「強化学習の最近の発展《第8回》連続空間における強化学習によるマルチロボットシステムの協調行動獲得」『計測と制御』vol.52 No.7, pp.648-655.
- [5] J. H. Connel and S. Mahadevan, "Introduction to robot learning," Robot Learning, Kluwer Academic Publishers, pp1-17.
- [6] 川人光男ほか「多重順逆対モデル(モザイク)その情報処理と可能性」『科学』vol.70 No.11, pp.1009-1018.
- [7] 高橋泰岳・浅田稔「複数の学習器の階層的構築による行動獲得」『日本ロボット学会誌』vol.18 No.7, pp.1040-1046.
- [8] 牧野貴樹ほか『これからの強化学習』森北出版.
- [9] 浅田稔ほか「内発的動機付けによるエージェントの学習と発達」『これからの強化学習』森北出版.
- [10] 麻生英樹ほか『深層学習-Deep Learning-』近代科学社.
- [11] N. Kruger et al., "Deep Hierarchies in the Primate Visual Cortex: What Can We Learn for Computer Vision?" IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.35 No.8, pp.1847-1841.
- [12] 吉塚武治ほか「ネオコグニトロンによる視覚腹側経路のモデル化」『日本神経回路学会誌』vol.14 No.4, pp.266-272.
- [13] 麻生英樹「多層ニューラルネットワークによる深層表現の学習」『人工知能学会誌』vol.28 No.4, pp.649-659.
- [14] 松原仁「一般化フレーム問題の提唱」『人工知能になぜ哲学が必要か』哲学書房.
- [15] フェルディナン・ド・ソシュール(影浦峯・田中久美子訳)『ソシュール一般言語学講義：コンスタンタンのノート』東京大学出版会.
- [16] ジョン・ロック(大槻春彦訳)『人間知性論1』岩波書店.
- [17] 谷口忠大「記号創発ロボティクス 知能のメカニズム入門」講談社.
- [18] 谷淳「ロボットで『科学』する記号の問題」『日本ロボット学会誌』vol.28 No.4, pp.522-531.

# 1.3 身体性と知能の発達

## 1.3.1 総論



■ 図12 本節の構成

人の知能に関する研究は、従来、知能がいかにか動作して、その機能を実現しているかについて、分析のかつ明示的な設計に基づいて構成しようとする方法論で行われてきた。このような方法論は、説明原理に基づく研究と呼ばれる。それに対して、構成論的アプローチでは、比較的単純な身体を構成し、環境と身体との相互作用によって知的な振る舞いがボトムアップに生成されるかどうかを調べる。いわば、知能を創ってみることで研究するという方法論である。知能の設計原理に着目した研究ということもできる。

したがって、構成論的アプローチでは、比較的単純な構成を初期条件として用意し、環境と相互作用しながら、自ら学習して成長していく知能の主体を創ることを目指す。このような知能の見方においては、環境との相互作用の媒体となる身体がクローズアップされ、「身体性」と呼ばれる重要な研究テーマとなる（1.3.2項参照）。

主体から見れば、身体を通してしか環境への働きかけができず、環境からの情報のフィードバックも身体からしか受け取れない。知能の主体は、このような認知的な枠組みの中で多様な行動を行い、学習していくのである。具体的な研究手法としては、身体性について、人間を始めとする生物システムと人工システムに共有可能な性質としての定義を与え、その役割や期待される機能を明示するとともに、脳神経系、筋骨格系、体表面の各部がマイクロレベルからマクロに渡って実現可能かについて考察するという手法が採られる。

また、構成論的アプローチは、知能の時間的な成長を実現しようとするものであるため、知能がどのように発達し得るかという観点が重要となる。赤ちゃんの発達過程の大きな特徴の一つは、創発的であることである。創発とは、形成される秩序の形態を明示的に指定するのではなく、比較的単純な下位の法則から自発的に秩序が形成されることを指すが、赤ちゃんは、環境の中で能動的に探索を行う中で、自律的に概念形成を実現する。

その過程は、外部から教師データを与えられずに、自律的に概念が獲得されるという意味で創発的である。更に、比較的初期の内的世界の発達でキーとなる機構に、「ミラーニューロンシステム」がある。ミラーニューロンシステムは、運動の生成と観測を結ぶことがポイントであり、そのことが、自己と他者の運動の同一性の理解から、他者意図理解などに発展する可能性を持つ（1.3.3項参照）。

以上のような、知能の自律的な発達を可能とする身体を創ってみることによって研究するという構成論的アプローチを、具体的にロボットを用いて研究する手法として、認知発達ロボティクスを導入する（1.3.4項参照）。その基本的な考え方としては、従来の説明原理に基づくロボティクスとは異なり、ロボット自らが、学習過程を通じて知能を発達させる点が挙げられる。この設計過程の中で、脳・神経科学、発達心理、認知科学などの既存分野と連携し、人間の認知発達の未解明の仕組みにも迫る意味や価値を示す。

また、認知発達ロボティクスの枠組みの中で、特に言語を始めとする記号自体がどのように創発したかを問う記号創発ロボティクスを紹介する。ここでの基本的な考え方は、人工知能の設計を記号システムありきで始めずに、記号システムが環境適応を通して形成されるプロセスを機械学習により表現し、言語獲得や社会における言語の形成を、ロボットを用いて構成論的に理解しようとすることである。

記号創発ロボティクスやそれを含む認知発達ロボティクスの考え方を、より発展させたものとして構成的発達科学を紹介する（1.3.5項参照）。知能設計の研究には、機械学習やロボティクスだけでなく、神経科学、発達心理学、認知科学など周辺の幅広い諸科学が深く関係する。これらの諸科学を発達の研究のために総合する学問が構成的発達科学である。例としては、自閉症などの非定型発達の当事者による研究や、共感発達を例に自他認知の課題を扱う研究が、構成論的アプローチをベースとして行われている。

ディープラーニングは、ほとんど同様の枠組みで多様なモダリティ<sup>1</sup>を扱えることから、ロボットの行動学習に対しても非常に有効であると考えられる。また、ディープラーニングのロボットの行動学習への応用例を紹介し、優れた学習結果、並びに今後の課題を示す（1.3.6項参照）。

最後に、歴史的経緯と内外の研究動向を述べ、身体性と知能発達の今後の課題を示す（1.3.7項参照）。

---

※1

視覚、聴覚、触覚等の感覚の種類のこと。

## 1.3.2 身体性の意味と役割

### 1.3.2.1 知能にとっての身体性とは？

前述のように、知能が「経験、学習、発達」するためには、身体を持っているということ、すなわち「身体性」が重要である。身体性は、「行動体と環境との相互作用を身体が規定すること、及びその内容。環境相互作用に構造を与え、認知や行動を形成する基盤となる」と規定される[1]。そのような身体性は、以下のような性質をもたらす。

#### 1. 不可分性：

様々な環境やその変動及び、知能の主体自身の内部状態を感知できる感覚能力、環境に働きかける多様な運動能力、それらを結ぶ情報処理能力は不可分であり、密に結合していること。

#### 2. 学習可能性：

限られた資源（感覚の種類や能力、運動能力）や処理能力の範囲で目的を達成するために、知覚・運動空間の関係の経験（環境との相互作用）を通じて学習できること。

#### 3. 発達可能性：

達成すべき目標や環境の複雑さの増大に対して、適応的に対処できるように、学習結果の経時的発展（発達）を可能にすること。

これらのことを示す興味ある実験として、生後2週間の2匹の仔猫の生理実験がある。1匹は自ら歩行し、もう1匹は自ら歩行できない状態で、同じ視覚入力を与えた場合、前者が正常な奥行き知覚を構成できるのに対し、後者は正しく視覚入力を解釈できず、正常な奥行き知覚が構成されないとされている。このことは、感覚入力を正しく理解するには、自らの能動的な運動入力が不可欠であること（不可分性）、それらの関係を学習できること（学習可能性）が大事であることを示している。更に、自ら歩行していない仔猫でも、歩けるような環境を与えれば、正しい知覚が構成される（発達可能性）。

身体を、感覚・運動・認知を支える物理的基盤と考えると、身体の物理的構造による拘束（形態）だけでなく、感覚器、運動器、内臓など、どのレベルまで生物学的な意味合いで、その内部構造を模擬するかが、議論されている。

以下では、この身体性を構成する各部についての現状と課題について探る。構成的手法に基づく研究でこれまで扱ってきた身体には、脳神経－感覚器－筋骨格－体表面系の一部しか含まれておらず、現状では、消化器系や循環器系、呼吸器系などは、明示的には含まれていない。下記では、脳神経系、筋骨格系、体表面に関する研究の現状を述べる。

### 1.3.2.2 脳神経系

現在までの脳神経系に関する構成的研究では、運動野と感覚野のみのごく一部を扱っているか、他の脳部位を想定していても、明確な対応付けが困難な場合が多い。更に、発達の視点も考慮に入れると、対応問題が難しいというよりも、発達の過程で対応が変化するため、明示的な対応は不適切となる可能性も高い。

例えば、言語発達の初期においては、左脳より右脳の障害のダメージが大きいことが知られている。このことは、成人において最終的な言語野と呼ばれる部分が、最初から中心的な役割を果たしているのではなく、発達の初期段階では、異なる部位が関わっているためと考えられる。また、意識的な注意の機構は、視覚情報の顕著性などによるボトムアップ的なものから、様々なタスクを遂行する上で必要なトップダウンの注意に発達し、関連する脳部位は、後方から前方へ移動することが知られている。

個体発達をメインにしたボトムアップ的なアプローチでは、最小実装から始めて、徐々に機能と構造を複雑化するアプローチに加え、他者を含めた環境、特に養育者との相互作用を主体としたモデル化に準じた脳神経系の設計原理が必要である。さらに、ミラーニューロンシステム（後述）を始めとするメカニズムの獲得も重要な課題となる。

### 1.3.2.3 筋骨格系

筋骨格系は、人間を始めとする動物の運動を生成する身体の基本構造である。これは、従来のロボットではジョイントリンク構造に相当するが、大きな違いは、アクチュエータ<sup>2</sup>として動物では筋肉が、ロボットでは主に電動モータが利用されている点である。電動モータは、制御が容易であるなどの観点から、アクチュエータの代表であり、様々に利用されている。ただし、制御対象と制御手法を区別し、制御手法を駆使することで、様々な動きを実現可能であるが、撃力を伴う衝突やトルクや速度の極めて大きな変化を含む激しい運動は非常に困難である。

これに対して、動物では、筋骨格系身体を効率的に利用して、跳躍・着地、打撃（パンチ、キック）、投擲（ピッチング、砲丸投げ）などの瞬発的な動作を実現可能である。また、動物の筋骨格の構造としては、一つの関節に対し複数の筋肉が、また一つの筋肉が複数の関節にまたがって張りめぐらされ、複雑な構造となっている[2]。そのため個々の関節の個別制御により動きを実現するのではなく、身体全体として、環境と相互作用するなかで動きが自発的に生成され、運動を獲得する。一見、不都合に見えるが、逆に超多自由度ロボットにおける自由度拘束問題<sup>3</sup>の解決策とも言える。

このような生物にならう筋骨格系の人工筋として、「McKibben型空気圧アクチュエータ」<sup>4</sup>が注目されている。これを用いた跳躍ロボットが開発され、すでに動的な運動を実現している[3]。そして、自由度の拘束に関しては、二関節筋構造（一つの筋が二つの関節にまたがって接続されている構造）の脚ロボットでは、一関節筋のみの場合に比べ、運動のコーディネーションが容易であることが実験的に示されている。これらは、制御が身体構造と密接に結び付いていることを示している。すなわち、身体が環境との相互作用を通して、制御計算を担っているとも解釈できる。

その極端な例が、受動歩行<sup>5</sup>であろう。明示的な制御手法もアクチュエータもなしに、坂道で歩行を実現できる。これは、物理的身体のエネルギー消費（資源拘束や疲労）の観点からも重要である。

### 1.3.2.4 体表面

皮膚感覚は、その重要性の認識はありつつも、技術的な実現の限界から、人間型ロボットに、これまであまり採用されてこなかった。しかし、等身大ヒューマノイドの全身に柔軟かつ切り貼り可能な触覚センサを1800個以上実装することにより、ヒューマノイドの様々な身体部位と環境・対象物との接触を活用<sup>6</sup>した動作の実現を行った研究や、ロボットの柔らかい皮膚（シリコン製）の下に触覚センサとして約200個のポリフッ化ビニリデン（PolyVinylidene DiFluoride; PVDF）素子を実装したロボット

---

※2  
入力されたエネルギーを物理的運動に変換する機械要素。

※3  
「超多自由度の運動機構系に対して、どのように運動を構造化するか？」はニコライ・ベルンシュテイン(Nikolai Bernstein)氏が指摘した運動発達の基本問題である。超多自由度の空間内で、適切な運動を探索する際の空間は巨大なものとなり、単純な探索によって最適な運動を獲得するのに必要な計算量が膨大になってしまうことを指す。

※4  
PETなどの繊維を編み込んだチューブに空気を入れると、風船のように膨らむが、一方で全長は収縮して短くなることを利用したアクチュエータ

※5  
アクチュエータなどによるエネルギーの入力や、複雑な制御を行わなくても、きっかけを与えるだけで、脚の機構などにより、坂道などを歩行すること。

※6  
ヒューマノイドの体のどこにいつ触れたのかについての情報を直接得ることにより、ヒューマノイドの動作安定性が増す。

のプラットフォームが開発されている。

また、全身ではないが、プラスチックの骨格にゴム手袋を装着し、PVDF素子とひずみゲージをシリコンと一緒に注入したバイオンックハンドを開発し、触覚センサによる指や掌の触覚と把持運動を利用して、数種の物体を識別する研究も行われている。センサをあらかじめ調整することはせず、創発により校正されることを目指している。人と比べるとセンサは圧倒的に少ないが、受容器の種類として類似の構造を取っており、人の把持スキルの学習発達研究への拡張が期待されている。

体表面の皮膚感覚は、体性感覚と密接に結び付き、自己の身体のイメージを獲得する上で非常に根源的かつ重要な感覚である[4]。高次脳機能がこのような基本的な知覚の上に構成されることを考えれば、知能発達の観点から、何らかの形で実装していることが望ましい。力学的な感覚受容器としての構造化に加え、痛みとしての感覚は、生物の場合、個体の生命維持に必須であるが、その社会的意味としての共感とは、将来、人間と共生するロボットにも望まれる。その際、明示的にプログラムされた物理的インタラクトへの応答ではなく、共感としての情動表現が可能であれば、より深いコミュニケーションが可能と考えられる。これは、以下のミラーニューロンシステムとも深く関連する。

### 1.3.3 知能の発達的设计

#### 1.3.3.1 発達の多様性

発達の様相にはいくつかの視点がある<sup>7</sup>。一つの視点は、赤ちゃんの発達過程を外部から観測した場合、中央制御的ではなく、分散かつ創発的で漸次的過程とみなすことができる点である。

通常的人工的なシステムの場合は、明示的に設計されている構造と制御機構を基盤として上位の構造や機能が作り込まれるが、生物の場合は、不完全で効率の悪い構造と行動表現を基にして、上位の発達段階の構造が構築される点に大きな相違がある。また、乳幼児の生態学的な意味での拘束は、必ずしも不利な点ではなく、むしろ発達を促す。脳、身体、環境の間の共同作用若しくはパターン生成の固有の傾向は、各種「引き込み現象」<sup>8</sup>を引き起こし、更に、能動的探索により自己の身体表象、自由度の拘束などによる運動パターン生成など創発過程が見られる。

発達心理学においては、このような環境に対する能動的な探索と操作の結果として、知覚の範疇の獲得や概念形成が行われると考えられている。感覚やある種の知覚は運動とは無関係に処理されるが、知覚の範疇の獲得は感覚系と運動系の相互作用に依存する。これらの相互作用と創発過程を構成論的にモデル化するため、脳の微視的な構造や機能を参考として、各種の調整を行っている神経修飾物質<sup>9</sup>、神経可塑性<sup>10</sup>、強化学習などを計算モデルに組み込む研究も行われている。

もう一つの視点は、社会性がどのように獲得されるかという点である。巨視的なレベルでは、養育者を始めとする他者の関わりが、赤ちゃんの自律性、適応性、社会性を助長している。養育者による足場作り (scaffolding) は、認知的、社会的、技能的発達に重要な役割を果たす。また、乳幼児は養育者の反応に対する感受性期があり、養育者はこれに合わせて対応を調整する。人工システムにおいても、知能を発達させる観点から、何らかの形で社会的相互作用における養育者による足場作りに相当する環境設計が必要と考えられる。

※7  
詳細は、文献[7]の第7章を参照されたい。

※8  
引き込み現象とは、複数のものの運動が相互作用の中で特定のパターンに収束していく現象を指し、創発に係る一つのメカニズムであると考えられている。

※9  
脳内の神経の振る舞いを制御する神経伝達物質のうち、時間的に持続的な効果を持つものの総称。

※10  
神経系の構造が時間的に変化し得ること。

### 1.3.3.2 ミラーニューロンシステムと社会性発達基盤

社会的相互作用、特に養育者による足場作りにおいて、鍵となる役割を果たしていると考えられるのが「ミラーニューロン」と呼ばれる脳のニューロンである。ミラーニューロンは、ある行動を自分で行う場合と、他者が行う場合の双方に反応するニューロンであり、サル、人等で発見されたものである。人のミラーニューロンは、人の脳内で言語を扱う部位の近くに位置しており、言語能力に至る道筋での重要な役割を果たしていると推察されている。様々な研究から、ミラーニューロンに関わる多くの事柄が明らかになりつつある[5]。

ミラーニューロンシステムには、自己や他者の身体を認識するシステムがそれぞれ存在し、かつ一部を共有している。このことにより、ミラーニューロンシステムが、他者の動作プログラムを自身の脳内で再現すること、すなわち、他者の内部状態を自己の内部状態としてシミュレーションすることが可能となっている。これは、運動主体感、自他弁別、他者の行為認識とも関連すると考えられている。これらに基づき、以下のように考えられている[6]。

- ミラーニューロンはもともと、自他に関わらず、動作そのものを視覚的にコード化し、運動実行中に感覚フィードバックとして働いていたが、発達・進化の過程で、運動情報と統合され、現在のミラーニューロンを構成するようになった。
- 自己身体認知のステップとして、自分自身の運動指令の情報が脳感覚情報を処理する領域に送られ（遠心性コピーと呼ばれる<sup>11)</sup>、感覚からのフィードバック（感覚フィードバック）と一致していれば運動の主体が自己であることを認識する（運動主体感の構成<sup>12)</sup>。
- 遠心性コピーと感覚フィードバックが一致しない場合には、その運動主体感が構成されず、感覚信号は他者の身体による行為の結果と認知される。
- ミラーニューロンは、他者の動作認識とともに、自己の身体や他者の身体の認識にも関与している。

更に、ミラーニューロンシステムは、模倣、共同注意、心の理論、共感、コミュニケーションなどの他者の意識や心理の状態を把握する機能と関連すると考えられている。これらは人に特有の自己と他者の共通性と差異に基づいた自己や他者への気づきの駆動、社会的な行動の学習・発達に寄与しているとみなされている。

実際、サルは模倣しないとされている。また、サルのミラーニューロンシステムの場合、対象が明示された他動詞的な動作にしか反応しないのに対し、ヒトの場合、自動詞的な動作、つまり目的を持たない行動に対しても反応するミラーニューロンシステムが存在する[5]。

サルの場合、人に比べて、個体の生存のための圧力が大きいので、ゴール指向の運動が個別に確立して、いち早く駆動することが可能である。それに対して、人の場合、養育者の庇護を受けるので、その圧力が小さく、ゴール指向のみならず、目的を持たない要素運動的なものにも反応することで、学習による構造化や組織化による汎用性が高まる余裕があり、結果として、より社会的な行動や認知能力へ拡張されたと考えられる。

---

※11  
運動制御においては運動の指令が運動野に送られるだけでなく、その信号のコピーが感覚野に送られていると考えられている。このコピーは、中枢神経から末梢系に送られるので、遠心性コピーと呼ばれる。

※12  
文献[6]では、実際、頭頂葉のニューロンが遠心性コピーと感覚フィードバックの情報の統合に関わることを発見している。

### 1.3.3.3 発達的な知能の設計論

身体性の意味と役割、ロボットの学習を概観してきたが、これらの考え方や既存科学の知識や知見を鑑み、人工システムの知能の発達的な設計論として、より系統的な枠組みが必要と考えられる。そこには、古典的課題である「氏と育ち」の課題と関係が、設計論を通じて浮き彫りにされる。

氏と育ちが対立概念ではなく、育ちを通じて氏が形成される（Nature via Nurture）と主張するマット・リドレー（Matt Ridley）氏に習えば、人工システムも同様に、事前の埋め込みと、それに基づく学習・発達系の設計論が必要である。そのような思想背景から、以降で紹介する認知発達ロボティクスの考え方が生まれ、構成的発達科学へ拡張される。これが、知能の発達の設計の基盤である。

## 1.3.4 認知発達ロボティクス

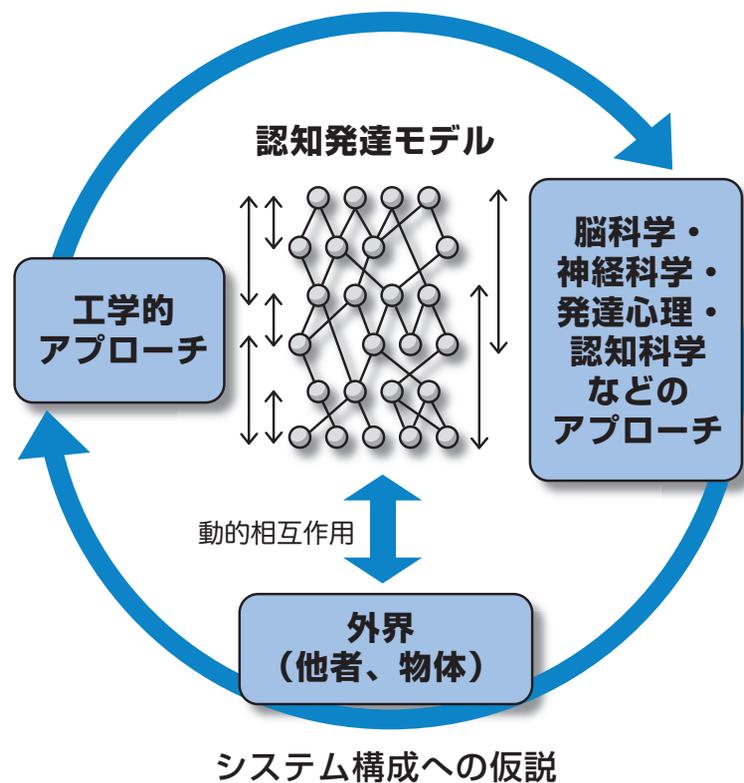
### 1.3.4.1 認知発達ロボティクスの基本的な考え方

認知発達ロボティクスとは、従来、設計者が明示的にロボットの行動を規定してきたことに対し、環境との相互作用から、ロボットが自ら行動を学習し、それらを発達させていく過程に内包される抽象化、概念の獲得を実現するためのロボット設計論である。

認知発達ロボティクスの焦点は、自律的な主体（エージェント）が環境との相互作用を通して、世界をどのように表現し、行動を獲得していくかといった、ロボットの認知発達過程にある。特に、環境因子としてほかのエージェントの行動が自分の行動をどのように規定していくかという過程の中に、ロボットが「自我」を見出していく道筋が解釈できるのではないかという期待がある。このように環境との相互作用をベースとして、その時間的发展に焦点をあて、脳を含む自己身体や環境の設計問題を扱う研究分野が認知発達ロボティクスである。

認知発達ロボティクスの基本的な考え方は、問題自体に対する理解の過程を、ロボット自身が環境との相互作用を通じて経験することにより、様々な状況に対応可能なメカニズムを構成論的アプローチによって構築することである。特に、知的行動を人間のレベルまで求めるのであれば、人間以外の動物にも可能な連合学習<sup>13</sup>のレベルから、人間特有の記号の生成と学習、すなわち言語獲得に至る過程（言語創発）が（1.2節参照）、ロボットの内部構造と外部環境の多様かつ制約的相互作用の中に見出さなければならない。

システム構成による仮説検証  
新たな認知科学的仮説の生成



■図13 認知発達ロボティクスの概念

※13  
2種類の刺激の組合せを学習すること。

従来のロボティクスでは、人間と共生するロボットのコミュニケーション技術として、トップダウン的に言語構造を与えたがために、言語創発過程が内包されていない。それゆえ、表層的な言語コミュニケーションに留まり、限られたコンテキストでの定型的な応答しかできない。その一方で、認知発達ロボティクスでは、言語創発に至る過程そのものを人工的に構成することで、人の認知発達過程の理解とともに新たなロボット設計論を目指す。

このような人の認知に関する研究は、従来、認知科学、神経科学、心理学などの分野で扱わ

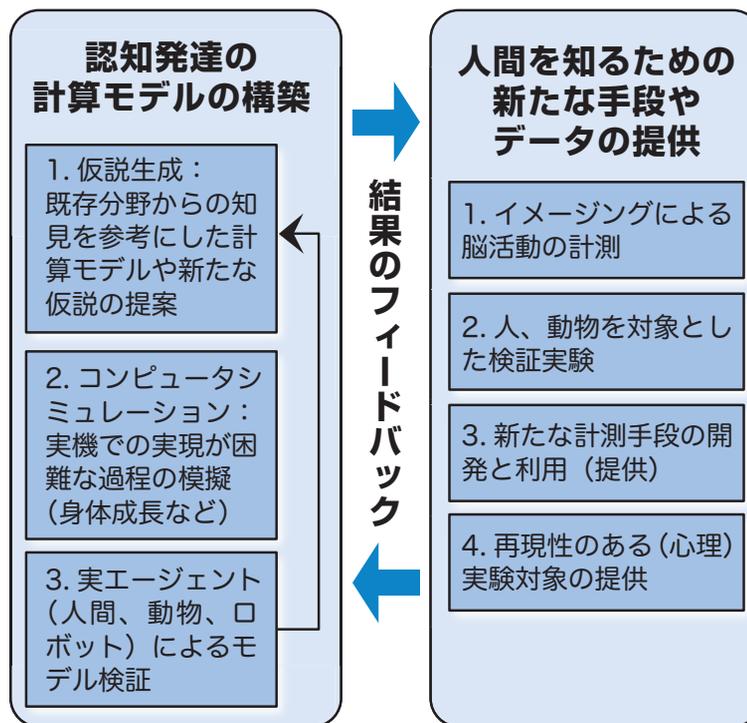
れてきた。そこでは、説明原理による理解を目指しており、認知発達ロボティクスが志向する設計原理に基づくものではない。しかしながら、人間理解という共通基盤を基に、工学的アプローチからは、「システム構成による仮説検証や新たな認知科学的仮説の生成」が、認知科学、神経科学、心理学などの分野に提案され、逆に、これらの分野から、「システム構成への仮説」が工学的アプローチに提案され、相互フィードバックによる認知発達モデルの構成と検証が可能である。それが認知発達ロボティクスの一つの理想形である（図13）。

### 1.3.4.2 認知発達ロボティクスの設計論

認知発達するロボットの設計論は、環境、身体、タスクが一体となって構成されなければならない。ここでは二つに分けて説明する。一つは、身体を通じて行動するための環境表現を構築していくロボットの内部の情報処理の構造をどのように設計するか、もう一つは、そのように設計されたロボットが上手に学習や発達できるような環境、特に教示者を始めとする他者の行動をどのように設計するか、である。両者が密に結合することで、相互の役割である学習・発達が可能である。

重要なポイントは、獲得すべき行動をロボットの脳に直接書き込むのではなく、他者を含む環境を介して（社会性）、ロボット自身が自らの身体を通じて（身体性）情報を取得し解釈していく能力（適応性）と、自らその過程を駆動できることである（自律性）。

認知発達ロボティクスやそれに関連するアプローチ<sup>14</sup>は、まだその事例が少ないが、その方向性は、主に二つに分かれる。一つは、機構の仮説を立て、コンピュータシミュレーションや実際のロボットを使って、実験し、仮説検証と仮説の修正を繰り返すことである。もう一つは、脳活動の計測や人、動物を対象とした検証実験等により人間を知るための実データを提供することである。これらは互いに関連し、相互フィードバックし得る（図14）。



■図14 認知発達ロボティクスやそれに関連するアプローチ

※14

「JST ERATO Asada Project」科学技術振興機構ウェブサイト  
 <<http://www.jst.go.jp/erato/asada/>>

### 1.3.4.3 記号創発ロボティクス

人間の認知発達を考えた際に、言語獲得は特に重要である。それは、言語を人間がコミュニケーションに用いるからという理由だけではなく、思考や推論など様々な高次の認知過程に言語が用いられると考えられているためである。それゆえに、言語は人間と他の動物を分かつ重要な要素であるとみなされてきた。数理論理学を基礎として生まれた初期のAIにおいては、記号処理、つまり記号で表現された述語論理式や変数を操作することが、知能の本質であるとみなされてきた。

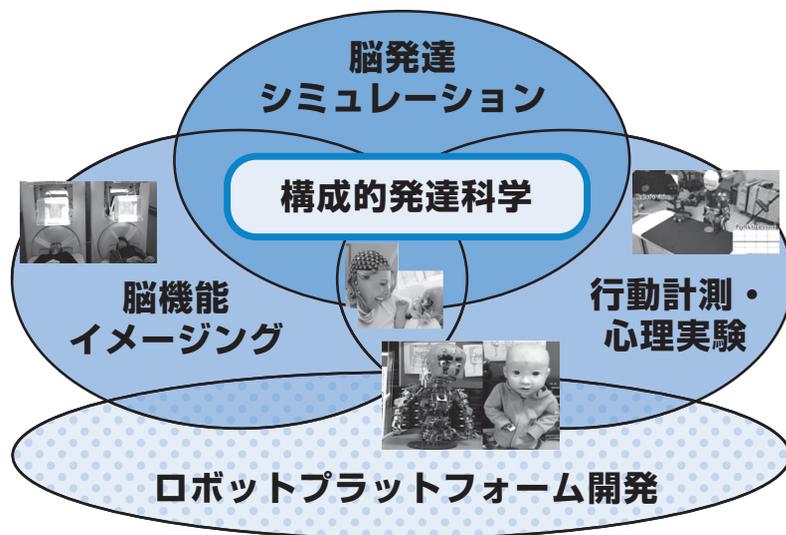
だが、その後、記号操作だけでは実世界の不確実性やダイナミックな環境に対応できないことが指摘された。また、記号の意味をどうやって現実世界に関係付けるのかという問題はシンボルグラウンディング（記号接地）問題と呼ばれ、AIの基本問題の一つに位置付けられる。

しかし、言語の体系に代表される記号システムそれ自身が、身体に基づく経験や社会的相互作用の下で形成されるとするならば<sup>15</sup>、人間がトップダウンにAIに与えた記号システムを絶対的に真な記号システムとして取り扱うことには無理が生じるし、記号システムの適応性を欠いてしまう可能性もある。記号システムはそれ自身が各認知主体の環境適応と、他者とのコミュニケーションを経て、創発的に形成されたと考えるのが妥当であろう。

このような視点から、AIの設計を記号システムありきで始めずに、記号システムが環境適応を通して形成されるプロセスを機械学習により表現し、言語獲得や、社会における言語の形成を、ロボットを用いて構成論的に理解しようとするのが記号創発ロボティクスという研究分野である。

記号創発ロボティクスは、人間のコミュニケーションを支える社会的システムである記号が創発されるシステム（記号創発システム）への構成論的アプローチであると位置付けられている[8]。AIにおいては、身体に近い感覚運動系の低次の認知と言語や論理といった高次の認知をいかに橋渡しするかという問題は、長きに渡って存在してきた。だが、記号創発ロボティクスは、それを感覚運動系からのボトムアップな学習によって、高次の認知まで説明しようとするアプローチであるといえる。

認知発達の一側面である言語獲得を中心に、ロボットを用いて認知発達の過程に構成的に迫るという側面において、記号創発ロボティクスは認知発達ロボティクスの一つの支流である。ただし、人間社会



■図15 神経ダイナミクスから社会的相互作用へ至る過程の理解と構築による構成的発達科学プロジェクトの概要

※15

各人が個別に記号システムを持っている状態では、他者とコミュニケーションを取ることができない。コミュニケーションを行うためには、社会的に共有されている記号の体系が必要となる。ここではそのような体系を指して記号システムと呼んでいる。文献[8]参照。

における記号システムの記号創発のメカニズムを背景とした理解に重きを置きながら、方法論としてはディープラーニングなどの機械学習を駆使して、認知発達における言語獲得の過程を構成的に研究する点に特徴がある。

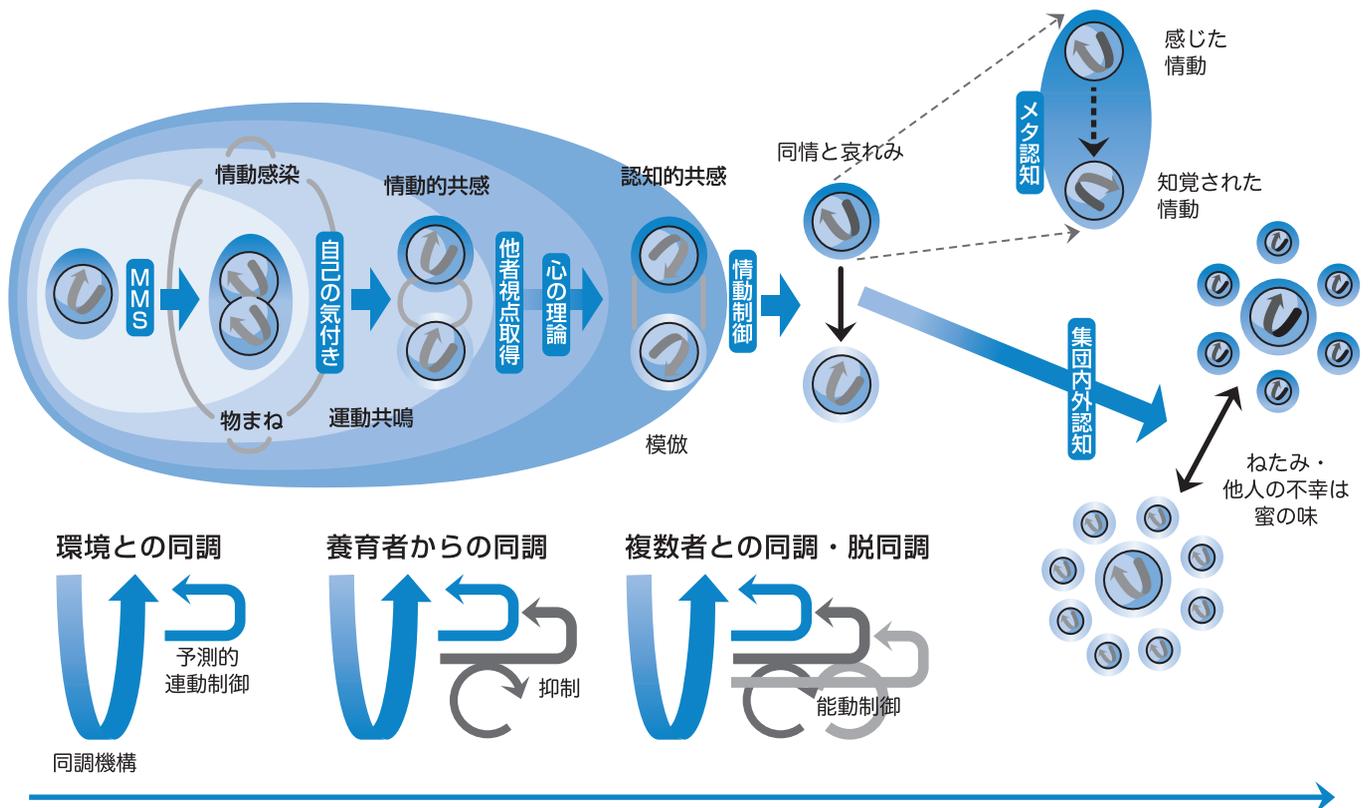
### 1.3.5 構成的発達科学

知能設計の研究には、機械学習やロボティクスだけでなく、神経科学、発達心理学、認知科学など周辺の幅広い諸科学が深く関係する。これらの諸科学を発達の研究のために総合する学問が構成的発達科学であり、記号創発ロボティクスやそれを含む認知発達ロボティクスの考え方をより発展させたものである。

構成的発達科学の主な研究例として、神経ダイナミクスから共感や自他認知の発達などの社会的相互作用へ至る過程の理解と構築を目指した研究と、胎児の発達原理に基づいて発達障害を系統的に理解しようとする研究[9][10]を、以下に紹介する。

前者の研究では、ロボットプラットフォームを用いた自他認知に関わる心理・行動実験を行っている際の、被験者の脳機能イメージングを行うことにより、計算モデルを構築し、自他認知の発達原理を説明することを目指している。研究全体の簡単な概要を図15に示す。

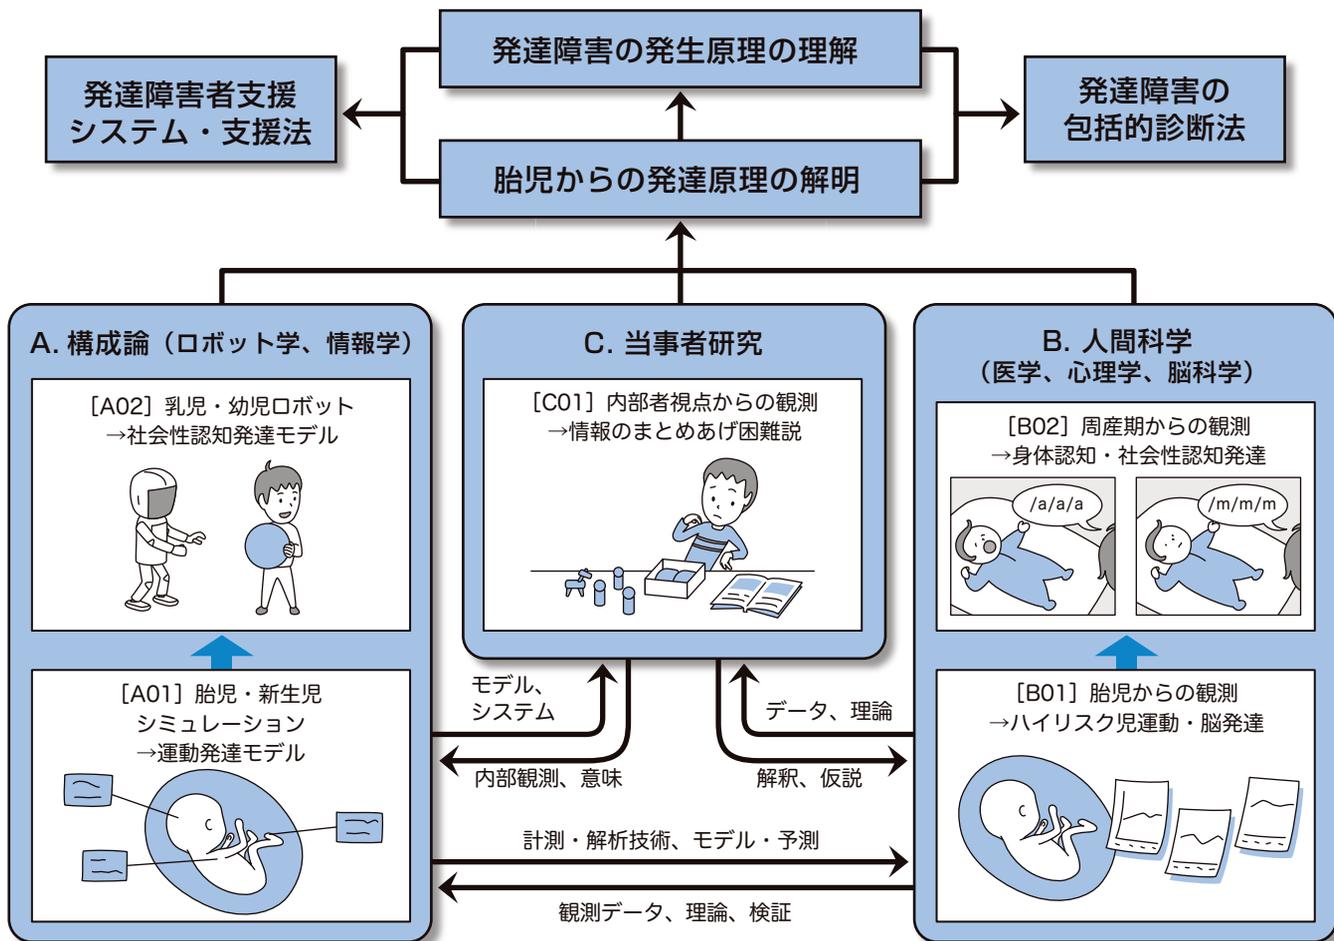
自己認知の発達過程は、人工システムが何をもって、自己の概念を獲得したかの判別が困難である。そこで、共感の発達になぞらえて、人工共感を設計することを想定した模式図に自他認知の発達が組み込まれ、具体的な心的機能が目標として与えられている。図16にその概念図を示す。具体的には、脳



## 自他識別の増強

■図16 共感発達モデルとしての自他認知過程<sup>16</sup>

※16  
文献[7]より作成。



■図17 構成論的発達科学—胎児からの発達原理の解明に基づく発達障害のシステム的理解—プロジェクトの概要

機能イメージングにより、親子ペアが相互に顔を見つめているときと、無関係なビデオを鑑賞しているときの差違が、自閉症軽度と重度の場合で異なることが見出されている。

後者のプロジェクト(図17)では、発達障害者の当事者研究を実施している点が特徴的である[9][10]。当事者研究とは、発達障害者が自らの感覚や経験を観測して体系的に記述することで、モデルの検証や意味付けを行う研究の手法である。例えば、自分が「おなかが空いている」ことを無意識的に感知できない発達障害者がいる。彼らは、複数の下位レベルの状態の集合として意識的に情報をかき集め、自分がどのような状態であるかを推定することにより「おなかが空いている」ことを知覚している。この過程は、先に述べた無意識的過程に相当すると考えられるため、彼らの記述からこの過程をモデル化する際の示唆を得ることができる。

### 1.3.6 ロボット学習としてのディープラーニング

ディープラーニングは、階層的な特徴量<sup>17</sup>の学習により、“ほとんど同様の枠組みで多様なモダリティ<sup>18</sup>を扱える”という特長をもち、ロボット学習への応用が盛んに行われている。実世界で行動するロボットシステムは通常、カメラ、マイクロフォン、接触センサ、アクチュエータなどを備えたマルチモー

※17 特徴量とは、問題の解決に必要な本質的な変数であったり、特定の概念を特徴づける変数のことを指す。複数の種類のセンサ信号やアクチュエータを備えるロボットの場合、それぞれの入出力の特徴量を更に階層的に組み合わせることで、統合的な認識が可能となる。

※18 視覚、聴覚、触覚等の感覚の種類のこと。

ダルシステムであり、ディープラーニングが有効に利用できる。

### 1.3.6.1 ロボットビジョン

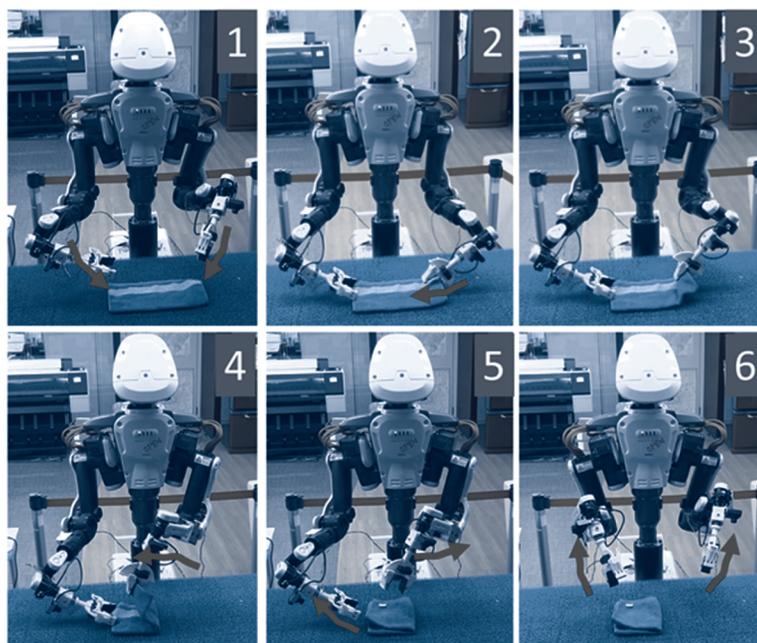
ロボットビジョンはディープラーニングが最初に導入された応用分野である。例えば、ジェヨン・スン (Jaeyong Sung) 氏は、ディープラーニングにより対象物の距離画像から把持ベクトル (ロボットハンドの位置と方向) を出力させる手法を提案している。ジョセフ・レッドモン (Joseph Redmon) 氏とアネリア・アンジェローヴァ (Anelia Angelova) 氏は色 (RGB) と深さ (Depth) データから構成される三次元RGB-D画像から、ディープラーニングモデルの一種である畳み込みニューラルネットワーク (CNN) を利用し、把持ベクトルの予測を行っている。

これらの研究はロボットの把持を対象としてはいるものの、物体画像から把持ベクトル、把持領域などのマッピングのみを問題として扱っている点で、純粋なビジョン研究であると言える。実際の動作自身は、把持ベクトルの情報を受けて、逆運動学<sup>19</sup>などの従来のロボット制御で実行されることを前提としている。

### 1.3.6.2 動作学習(End to End Learning)

把持ベクトルが画像から得られたとしても、実際にどのような動作をすることで把持可能なかが、当然考慮されなければならない。つまり、学習対象には、物体の画像のみならず、動作を生成する身体構造が含まれる必要がある。

ディープラーニングの重要な方法論の一つに、入力から出力までを一つのネットワークとして表現し、全体を学習してしまう「End to End Learning」がある (1.2.8項参照)。従来は、入力から出力まで、概念的に複数の段階の処理が必要な場合には、個々の処理をステップバイステップで学習した後にそれらを統合するという手順が必要であったが、ディープラーニングにより、全体のネットワークが一気に



■図18 Nextageによる柔軟物の折り畳み動作の学習

※19  
ロボットや3Dモデルの関節を制御する方法であり、逆運動学とは指先やつま先の位置から関節の角度が決まることをいう。

※20  
Willow Garage (米国) が開発、販売している双腕ロボット。ハードウェアとソフトウェアがオープンプラットフォームで開発されている。Willow Garage Website <<http://www.willowgarage.com/pages/pr2/overview>>

学習できるようになった。ロボットの動作学習の場合には、入手可能な高次の入力データ（画像や映像）から、必要な高次の出力（複数の関節時系列出力）を直接得るという発想となる。この方法論を適用することで、実際に実行可能な動作の学習が可能となる。

セルゲイ・レヴィン（Sergey Levine）氏は、ロボットPR2<sup>20</sup>にディープラーニングによる行動探索を行わせ、現時刻の一枚の視野画像の入力から次時刻のロボットの複数関節を直接CNNで出力させ、一連の動作を実現する手法を提案している。複数の動作について、物体の位置変化などがあっても、安定的に動作が行えることを示した。

また、同様の手法を14台のロボットアームに導入し、80万回のピッキング動作の学習によって多様な一般物体のハンドリングを実現している。またピンチェ・ヤン（Pin-Che Yang）氏は、「Programming by Demonstration」（動作教示からの動作生成メカニズムの獲得）の視点から、ディープラーニングにより、「Nextage」<sup>21</sup>を用いて画像時系列からの未学習のタオル折り畳み動作生成、及び将来の視野画像の予測などを行っている（図18）。またリカレントニューラルネットワーク（RNN）を利用することで、動作の安定化を実現している。

### 1.3.6.3 言語学習

画像や映像からのキャプション生成など、ディープラーニングによる言語とほかのモダリティとの統合手法はロボットにも応用可能である。この視点から、ディープラーニングモデルによるロボットの動作に関する言語の利用や認識に関する試みもいくつか報告されている。

例えば、イエ Zhou Yang（Yezhou Yang）氏は、人間の調理映像にその状況を説明する言語情報を加えてCNNに与えることで作業シーンの分節化を助け、オブジェクト48種類と6種類の把持タイプを識別し、ロボットの動作に適用している。山田竜朗氏は、ディープラーニングによる自然言語処理に利用されるRNNの「Sequence to Sequence Learning」を応用し、小型ロボット「NAO」の物体操作タスクにおいて、状況依存性（多義性）を持つ未学習の文章指令から運動への変換を実現している。

## 1.3.7 歴史的経緯と国内外の研究動向

### 1.3.7.1 歴史的経緯

認知発達ロボティクスの提唱以前のAIやロボティクスでは、モデルベーストや記号表象に基づく手法が主流であった。これに対し、1984年にヴァレンティノ・ブライテンブルク（Valentino Braitenberg）氏が、簡単な構造を持つ光センサとモータを持つ移動ロボットが、複雑な行動を生成し得ることを示した。また、1986年当時マサチューセッツ工科大学（MIT）にいたロドニー・ブルックス（Rodney Brooks）氏は、知能内部の精巧な推論プロセスを作り込む必要はなく、環境との相互作用により知能が実現されるとする「表象なき知能」という考え方を提唱し、実際に昆虫を模したロボットで障害物回避や不整地歩行が可能であることを示した[11]。

その後ブルックス氏は「Attila」、「Hannibal」など、1990年代にかけて様々な昆虫型のロボットを開発している。元チューリッヒ大学（スイス）のロルフ・ファイファー（Rolf Pfeifer）氏は1987年にAI研究所を設立し、身体性に重きをおいた研究を開始している。

また、1990年代にはロボカップの開催（1997年に第1回大会が開催）、経済産業省の「人間協調・共存ロボットシステムの研究開発」プロジェクトから開始されたHRPシリーズの開発（1998年～）等、

※21

川田工業が開発した人と共存する環境で作業することを念頭に置いた汎用の人型ロボット。

実際のロボットを用いて人間とロボットとの協調動作やロボット同士の協調動作を目指した研究が実施された。これらを背景に、先にも述べた認知発達における身体性や社会性の重要性が認識され始め、「身体性認知科学」や「認知ロボティクス」「認知発達ロボティクス」が勃興し、知の理解と創造が不可分であるとの認識が高まった。

### 1.3.7.2 国内の動向

国内では、2005年秋から科学技術振興機構（JST）の戦略的創造研究推進事業（ERATO）「浅田共創知能システムプロジェクト」が発足した。約5年半に渡り、ヒューマノイドロボットの新たな設計・製作・作動と認知科学や脳科学の手法を用いた構成モデルの検証による、科学と技術の融合した新領域「共創知能システム」を構築することを目標に、研究が展開された。このプロジェクトでは、人工筋肉などの柔軟素材を用いた身体構造と環境と動的結合による運動の創発、身体的行動から対人コミュニケーションまでを発達的につなぐ認知モデルによる認知発達の構成的理解、アンドロイドやマルチロボットシステムを用いたコミュニケーションの理解と実現、脳機能画像計測や動物実験による構成モデルの検証などを中心に行われた。

上記のプロジェクトの動きと並行して、KAIST（韓国）の谷淳氏らがRNNを用い、複雑系科学の分野で、身体性認知科学としてのロボットの神経ダイナミクスの研究を究めている。早稲田大学の尾形哲也氏は、RNNやディープラーニングを駆使したロボットの行動学習に焦点を置いて2014年頃から研究しており、ロボットにマルチモーダル学習をさせ、指示によって行動を切り替えさせることに成功している。立命館大学の谷口忠大氏は、記号創発ロボティクス（1.3.4項参照）を提唱し、認知発達ロボティクスにおける言語創発の課題に焦点をおいた研究を実施している。谷口氏を含め、玉川大学の岡田浩之氏、早稲田大学の尾形氏がメンバーになり、電気通信大学の長井隆行氏が率いる「記号創発ロボティクスによる人間機械コラボレーション基盤創成」プロジェクト<sup>22</sup>が2015年から始まっている。

また、身体性をテーマとした研究は現在も活発に実施されている。体表面（1.3.2項参照）の高度化を目指し、ソフトロボティクスにおける人とのインタラクションを科学としてとらえることを狙ったJSTさきがけプロジェクト「触れ合いデータを収集する子供アンドロイド高機能化」<sup>23</sup>（2016年～）、ミラーニューロンシステム（1.3.3項参照）の予測符合化<sup>24</sup>を基にしたモデル化と発達障害者支援を目標としたJST CRESTプロジェクト「認知ミラーリング：認知過程の自己理解と社会的共有による発達障害者支援」<sup>25</sup>（2016年～）や、アンドロイドの社会的行動の工学的実現を目指したJST ERATO「共生ヒューマンロボットインタラクションプロジェクト」<sup>26</sup>（2016年～）などが継続的に推進されている。

### 1.3.7.3 海外の動向

海外では、1987年にAI研究所を設立したファイファー氏が、身体性に重きをおいた身体性認知科学の多くの研究や思想をまとめて、書籍として著している。柔軟な身体が有する環境との相互作用の豊かさが、いかにして知の創造や理解に繋がるかを説いている。これら、一連の研究は認知発達ロボティク

※22

「記号創発ロボティクスによる人間機械コラボレーション基盤創成」プロジェクト. 科学技術振興機構ウェブサイト <<http://www.jst.go.jp/kisoken/crest/project/1111083/15656632.html>>

※23

【石原 尚】触れ合いデータを収集する子供アンドロイド高機能化」科学技術振興機構ウェブサイト <[http://www.jst.go.jp/kisoken/presto/project/1112079/1112079\\_02.html](http://www.jst.go.jp/kisoken/presto/project/1112079/1112079_02.html)>

※24

脳内で未来の感覚情報の予測が行われていること。

※25

科学技術振興機構 戦略的創造研究推進事業「認知ミラーリング：認知過程の自己理解と社会的共有による発達障害者支援」プロジェクト. 科学技術振興機構ウェブサイト <<http://cognitive-mirroring.org>>

※26

科学技術振興機構ERATO「共生ヒューマンロボットインタラクションプロジェクト」 <<http://www.jst.go.jp/erato/ishiguro>>

スにおけるロボットプラットフォームの重要性、更には、認知過程への本質的な貢献の役割も含めて、現在では、ソフトロボティクスの思想基盤となっている。

イタリアでは、ジェノバ大学のジュリオ・サンディーニ (Giulio Sandini) 氏が、コンピュータビジョンの研究で、当初から生体視覚に着目し、物体の把持や操りなど、行動系と密着したロボットビジョンの研究を行ってきた。そして、発達概念を取り入れた認知発達ロボティクスの考え方を、2003年にファイファー氏らと一緒に著している。彼らは、「iCub」と呼ぶ幼児ロボットプラットフォームを開発し、認知発達研究のプラットフォームとして、世界に送り出している。サンディーニ氏は、その後、イタリア技術研究所 (IIT) のロボット領域の主要メンバーとなり、人間の行動系の研究を中心に多くの研究成果を挙げている<sup>27</sup>。

英国では、プリマス大学のアンジェロ・ケンジェロシ (Angelo Cangelosi) 氏が、iCubを用いた言語発達研究を推し進めている。これは、ヨーロッパのITALK (Integration and Transfer of Action and Language Knowledge in Robots) プロジェクト (2008年3月～2012年2月) の一部であり、IITや後述のビーレフェルト大学 (ドイツ) など、ヨーロッパの主要な研究機関が含まれていた<sup>28</sup>。ケンジェロシ氏は、南イリノイ大学の心理学者マシュー・シュレシンガー (Matthew Schlesinger) 氏とともに、『Developmental Robotics – From Babies to Robots –』と題する書籍を著しており、その中にITALKプロジェクトの成果も含まれている。また、多くのプロジェクトに参画している<sup>29</sup>。

ドイツでは、ビーレフェルト大学のヘルゲ・リッター (Helge Ritter) 氏が、HRI (Human Robot Interaction) を中心とした、工学実利的な側面に重きをおいた多くのプロジェクトを1990年代から現在まで長年に渡って遂行しており、EUにおけるCOEプログラム (Center Of Excellence Program) を獲得し続けている。また、CITEC (the Cluster of Excellence Center in Cognitive Interactive Technology) と呼ばれる研究センターを2007年に設立し、多くの研究者を抱えて活動している<sup>30</sup>。

最近の大きなプロジェクトの一つは、「The Cognitive Service Robotics Apartment as Ambient Host」と呼ばれているもので、2013年10月からの4年プロジェクトで家庭内環境での認知ロボットの活動の実現を目指している。フランクフルト大学のFIAS (Frankfurt Institute of Advanced Studies) のヨッフエン・トリーシュ (Jochen Triesch) 氏は、もともとコンピュータビジョンの研究を行ってきたが、神経科学をベースに認知過程のモデル化を試みている。すなわち、脳のネットワークの創発により知的な感覚と行動が生成される機序を明らかにしようとしている<sup>31</sup>。

フランスでは、国立情報学自動制御研究所 (INRIA) のピエール・イヴ・ウーディユ (Pierre-Yves Oudeyer) 氏率いる研究グループでは、内発的動機付けを情報論の立場から明らかにしようとする発達ロボティクスの研究を行っている<sup>32</sup>。セルジーポントワーズ大学 (フランス) のフィリップ・ゴシエ (Philippe Gaussier) 氏は、脳神経系のモデル化を通じた認知発達過程の解明を目指している。脳の各部の機能とその関係を計算モデルとして具現化し、ロボットによる検証を通じて、新たな理解と洞察を

---

※27  
"Giulio Sandini." Italian Institute of Technology Website  
<<https://www.iit.it/people/giulio-sandini>>

※28  
Integration and Transfer of Action and Language Knowledge in Robots Website <<http://www.italkproject.org>>

※29  
"Angelo Cangelosi: Professor of Artificial Intelligence and Cognition." University of Plymouth Website  
<<http://www.tech.plym.ac.uk/soc/staff/angelo/>>

※30  
The Cluster of Excellence Center in Cognitive Interactive Technology Website <<https://www.cit-ec.de/en/citec>>

※31  
"Research Group of Jochen Triesch." Frankfurt Institute of Advanced Studies Website  
<<http://fiat.uni-frankfurt.de/neuro/triesch/>>

※32  
Pierre-Yves Oudeyer Website <<http://www.pyoudeyer.com>>

※33  
Equipes Traitement de l'Information et Systèmes Website  
<<http://perso-etis.ensea.fr/gaussier/>>

得ることを狙っている<sup>33</sup>。

米国では、1991年にブルックス氏が行動規範型ロボットのアーキテクチャを提唱後、一連の研究が行われてきたが、認知発達ロボティクスに強く関連する研究グループの形成には至らなかった。その後、ブルックス氏は、お掃除ロボット「ルンバ」で有名なiRobotを設立・創業後、Rethink Roboticsを設立し、新たな産業用ロボット「Baxter」の開発・販売に従事している。

認知発達ロボティクスのアプローチの一つは、ロボットを道具として人間研究に利用することである。シアトルにあるワシントン大学で、ILABS (Institute for Learning and Brain Sciences) を率いる心理学者夫妻のアンドリュー・N・メルトゾフ (Andrew N. Meltzoff) 氏とパトリシア・K・クール (Patricia K. Kuhl) 氏は、赤ちゃんの行動実験及び脳磁計 (Magnetoencephalography; MEG) による計測を通じて、発達研究を行っているが、ロボットやモデル研究との連携にも強い関心を示している。そして、フランスのゴシエ氏との共同研究や、大阪大学の浅田稔氏からロボットを譲り受けて、ロボットの学習や社会性に関する研究を行っている。インディアナ大学 (米国) は、発達心理学で著明なリンダ・スミス (Linda Smith) 氏が、計算モデルに関心を持っており、ユ・チェン (Chen Yu) 氏と連携し、赤ちゃんの発達モデル化を試みている。

脳神経系の構造をベースにロボットの感覚行動のマッピングを対象とする研究は、「Neurorobotics」と呼ばれ、ノーベル賞受賞者のジェラルド・モーリス・エデルマン (Gerald M. Edelman) 氏が、1990年代初期から行ってきた。エデルマン氏は、脳のネットワーク構造を明らかにしようとするコネクトーム<sup>34</sup>のオラフ・スポーンズ (Olaf Sporns) 氏や意識の研究で著明なジュリオ・トノーニ (Giulio Tononi) 氏と共同研究を実施している。Neuroroboticsとしての後継者は、ジェフリー・L・クリッチマー (Jeffrey L. Krichmar) 氏である。エデルマン氏のグループ出身のユージン・M・イジケヴィッチ (Eugene M. Izhikevich) 氏 (Brain corp、米国) は、大規模な脳活動シミュレーション研究を行っている。これら一連の研究は、脳研究の派生と見なせるが、既存の脳研究のアプローチの限界を打破する上で、人工物設計を通じたアプローチは、認知発達ロボティクスの理念と通じる。

日本以外のアジア地域では、残念ながら、認知発達ロボティクスの研究はあまり行われていない。先に述べた谷氏らのグループが韓国のKAISTで行っている程度である。

#### 参考文献

- [1] 浅田稔・國吉康夫『ロボットインテリジェンス』岩波書店。
- [2] Donald A. Neumann (嶋田智明・平田総一郎監訳)『筋骨格系のキネシオロジー』医歯薬出版。
- [3] 柿谷慧ほか『筋骨格ロボットを用いた跳躍運動の学習』『ロボティクスシンポジウム予稿集』vol.14, pp.380-385。
- [4] サンドラブレイクスリー・マシューブレイクスリー (小松淳子訳)『脳の中の身体地図—ボディ・マップのおかげで、たいていのことがうまくいくわけ』インターシフト。
- [5] ジャコモ・リゾラッティほか『ミラーニューロン』紀伊国屋書店。
- [6] 村田哲ほか『脳の中にある身体』『ソーシャルブレインズ 自己と他者を認知する脳』東京大学出版会, pp.79-108。
- [7] Minoru Asada, "Towards artificial empathy," International Journal of Social Robotics, vol.7, pp.19-33。
- [8] 谷口忠大『記号創発ロボティクス 知能のメカニズム入門』講談社, 2014。
- [9] 綾屋紗月・熊谷晋一郎『発達障害当事者研究—ゆっくりしていねいにつながりたい』医学書院。
- [10] 綾屋紗月・熊谷晋一郎『つながりの作法—同じでもなく 違うでもなく』NHK出版。
- [11] R.Peifer・J.Bongard (細田耕・石黒章夫訳)『知能の原理 身体性に基づく構成論的アプローチ』共立出版。

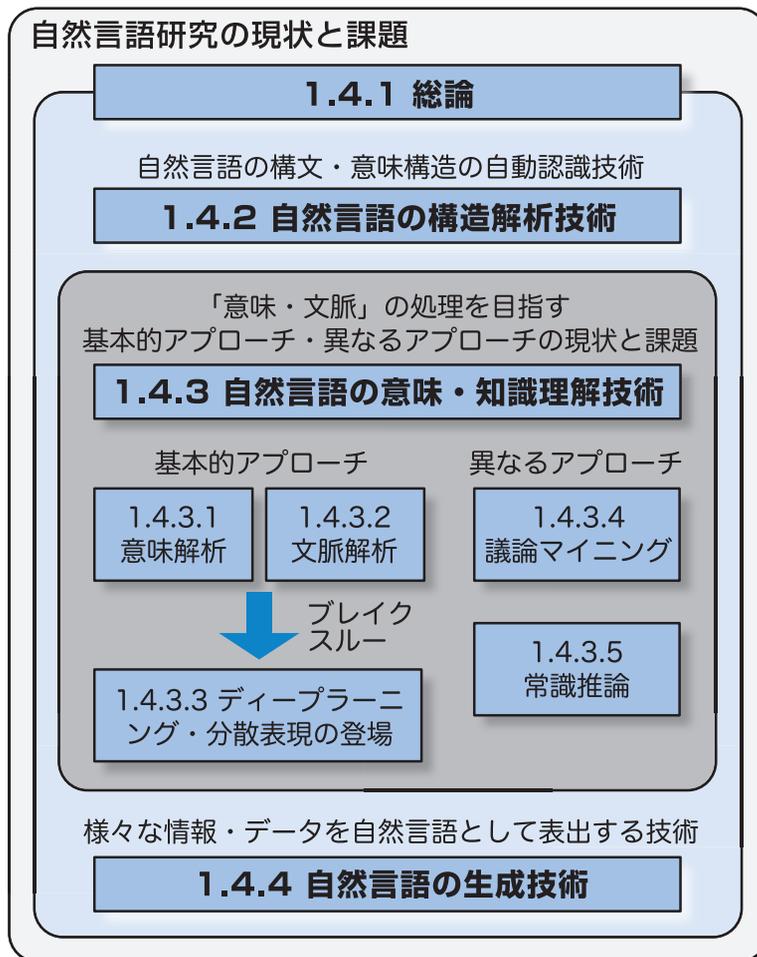
---

※34

ニューロンの間の接続状態を表した神経回路の地図のこと。

# 1.4 自然言語を中心とする記号処理

## 1.4.1 総論



■図19 本節の構成

人間は情報を抽象化・記号化し、更にそれを組み合わせて複雑かつ複合的な情報を表現・理解する能力を持っている。情報の抽象化はおそらく人間以外の生物も行っているだろうが、情報を記号化して組み合わせることで自由自在に加工・利用する能力、つまり自然言語をあやつる能力は、おそらく人間に限られたものであろう。人間であればだれでも当たり前に行っているこの能力をコンピュータ上で再現することが、記号・言語を対象とする人工知能（AI）研究の最終目標である。

自然言語に関する研究では、離散的構造と統計的性質、入力データと背景知識、パターン認識と論理推論など、異なる性質を統合的にモデル化することが求められる。特に最近では、AIの他分野と同様にディープラーニングを利用する研究が目立ち、これまではSVM（Support Vector Machine）やCRF（Conditional Random Field）を用いるのがスタンダードであったものが、フィードフォワードニューラルネットワーク（FFNN）やリカレントニューラルネットワーク（RNN）に置き換わりつつある。

ただし、これは前述の様々な性質の一面について強力な解を提供するものの、自然言語のモデル化の全てを解決するものではない。実際、自然言語処理においてディープラーニングを利用することによる成果は、今のところ様々である。機械翻訳や画像説明文生成のように大幅な性能向上が達成されているもの、構文解析や意味解析のようにインクリメンタルな精度向上は見られるものの基本的な手法はあまり変わらないもの、文脈解析や常識推論など現在のアプローチでは実用的な精度は見込めないもの、などがある。

特に、自然言語の意味・文脈理解や、対話システムにおける対話制御など、タスク設定やモデル化が模索されている段階の研究分野では、課題の多くは、現在も未解決である。

以下では、自然言語に関する研究のうち、自然言語文の内部構造（構文構造、意味構造）を認識する構造解析技術（1.4.2項参照）、自然言語がエンコードしている情報を理解・活用する意味・文脈解析技術（1.4.3項参照）、情報をエンコードして自然言語文として表出する自然言語生成技術（1.4.4項参照）、の三つについて、現在の技術動向と今後の展望について述べる。

## 1.4.2 自然言語の構造解析技術

### 1.4.2.1 構文解析

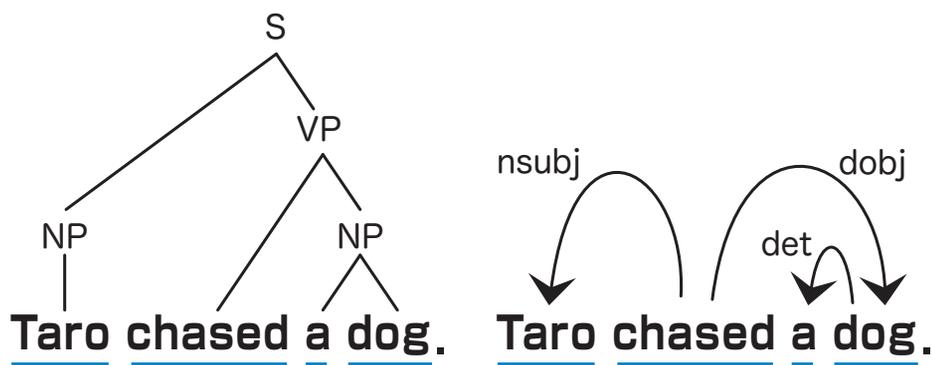
自然言語は、単語を並べることで複雑な情報を表現することができる。しかし、単語の並びが情報をエンコードする方法は自明でない。例えば、「Taro chased a dog.」と「A dog chased Taro.」という二つの文では、使われている単語は同じであるが、だれがだれをchaseするのか、という情報は反対になっている。英語では、主語、目的語といった役割が語順によって決められるため、語順を入れ替えるところのようなことが起きるのだ。

一方、日本語では「が」や「を」といった助詞が主語・目的語を決めるため、「太郎が犬を追いかける」と「犬を太郎が追いかける」は同じ意味を表す。したがって、自然言語データを単なる文字列としてではなく、自然言語を用いて人間が理解している「情報」、すなわち「意味」をコンピュータで扱うためには、自然言語文の背後にある構造を明らかにする必要がある。

自然言語の文の構造を解析する技術は「構文解析」(syntactic parsing)とよばれ、古くから多くの研究がなされてきた。自然言語は再帰的な構造（「花子が飼っている犬が太郎を追いかけた」といった文のように、一つの文の中に更に別の文が入る、という構造）を持つため、文の構造を表現するためには木構造が用いられる。特に、自然言語の構文解析では、図20に示す句構造 (phrase structure) と依存構造 (dependency structure、係り受け構造ともいう) が広く用いられる。句構造は、単語列の構文的なまとまり (S: 文、VP: 動詞句、NP: 名詞句など) を木構造で表す。依存構造は、単語の間の文法関係 (nsubj: 名詞主語、dobj: 直接目的語、det: 限定詞など) を木構造で表す。

構文解析では1990年代半ばから、統計的機械学習を用いる手法が主流である。機械学習の観点からすると、構文解析とは系列データ (単語列) に対して木構造 (句構造あるいは依存構造) を推定する問題である。これには、木構造の「良さ」(正解の木構造との近さ) を定量化する問題と、良い木構造を効率的に探索する問題が含まれる。

前者については、確率文脈自由文法やそれを拡張したものや、SVM、最大エントロピー法、単層パーセプトロン、CRFといった線形分類器がよく使われた。最近では、FFNNやRNNなどのディープラー



■図20 「Taro chased a dog.」に対する句構造(左)と依存構造(右)

ニングを適用することで更に精度が向上している。後者については、CYK (Cocke Younger Kasami) 法やチャート法といった動的計画法、遷移型解析アルゴリズムなど木構造を系列ラベル付け問題に帰着する手法、最良優先探索やA\*探索といったヒューリスティック探索など、AIの基本技術を応用したものが多く。

構文解析の最先端の研究では、機械学習手法と木構造の探索手法のより良い組合せを探求することで、少しずつではあるが解析精度が着実に向上してきている。その結果、英語や日本語といった言語においては、2000年代には90%以上の解析精度が達成された。

現在、構文解析の研究は、構文木の正解データ（「ツリーバンク」という）を学習データとした教師あり学習が主流である。ツリーバンクの開発には多大なコストと時間が必要であり、大きなツリーバンクが利用できる言語は限られている。上述のように英語や日本語において高精度な構文解析が実現されているのは、「Penn Treebank」や「京都大学テキストコーパス」<sup>1</sup>[1]といった大規模ツリーバンクに負うところが大きい。

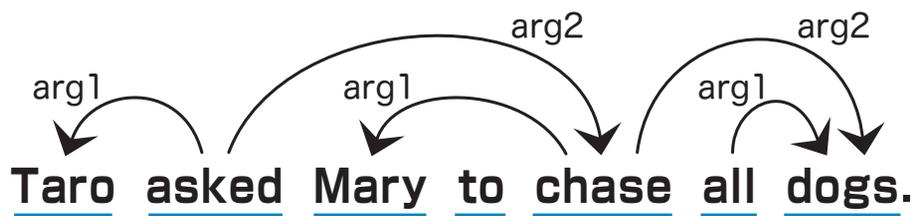
最近では、多数の言語について同じ基準でツリーバンクを開発する「Universal Dependencies」プロジェクトが注目されており、これまでに50言語のツリーバンクが公開されている。高精度な構文解析の実現にはツリーバンクが必要不可欠であることから、今後は大規模かつ高品質なツリーバンクを低コストで構築する技術などが必要となるだろう。

これまでの構文解析技術は、文の表層的な手がかり（品詞、機能語、接頭・接尾辞など）を利用して正しい構文木を選択している。一方、人間は表層的な手がかりに加えて、意味的な手がかり、あるいは意味理解をしながら整合性のある解釈を選択していると考えられる。このような、より人間らしい構文解析を目指す試みはたびたび行われているものの、今のところ全くうまくいっていない。

つまり、現在の構文解析技術は表層的特徴の統計的性質に過度に依存しており、学習データとは統計的性質が異なるテキスト（文のスタイルが大きく変わる、専門的文書で未知語が多いなど）では、解析精度が大幅に低下することが知られている。これまでの構文解析研究は、実用的には成功を収めつつあるものの、人間の言語理解の本質にはまだ迫ることができていないということもできる。

#### 1.4.2.2 意味構造解析

構文解析の次のステップとして、文が表す意味構造を認識する技術を「意味構造解析」(semantic parsing) という。意味構造としては、述語とその意味的な項（意味的な主語や目的語）を表す「述語項構造」(predicate argument structure) や、述語論理などの形式論理を用いて意味を記述する「論



$$\exists x,y,e.(taro(x) \wedge mary(y) \wedge ask(e, x, y, \forall z.\exists f.(dog(z) \supset chase(f, y, z))))$$

■図21 「Taro asked Mary to chase all dogs.」に対する述語項構造(上)と論理表現(下)

※1

コーパスとは、自然言語処理の研究のために大量に集積し、構造を解析した情報も付加された言語資料のこと。

理表現」(logical form) (図21)、汎用的意味表現として提案された「AMR」(Abstract Meaning Representation) が挙げられる。

意味構造解析には二つの流派がある。一つは、構文木(句構造や依存構造)を入力として、意味構造の各要素を推定する機械学習分類器を学習する方法である。例えば、述語項構造は図21に示すように単語間のグラフ構造とみなすことができる。したがって、単語の各ペアについて、述語-項関係が成り立つかどうかを分類すればよい。これは、各単語について述語との関係(意味役割という)を認識する問題に帰着できるので、意味役割付与とも呼ばれる。単純な分類問題なので、SVM、パーセプトロン、CRF、RNNなど、様々な分類器や系列ラベリング手法を応用することができる。

もう一つの方法は、構文木に沿って意味構造を組み立てる方法である。図21に示した論理表現は、グラフ構造ではなく述語論理式であるため、上述のような分類問題に帰着するのは難しい。そこで、各単語に意味表現の断片を割り当て、構文木にそってこれを合成していくことで、文全体の意味表現を計算する。これはモンタギュー文法<sup>2</sup>から続く伝統的なアイデアであるが、文法理論に基づく構文解析が実用レベルに達したことと、形式論理に基づく意味表現の理論的進展から、最近では高精度な意味解析が実現されつつある。

構文解析と同様に、意味構造解析の研究においても言語リソースが重要な役割を果たしている。英語では「Proposition Bank」や「FrameNet」、日本語においては「NAISTテキストコーパス」といった述語項構造コーパスが開発されており、意味構造解析の研究をリードしている。ただし、意味構造のコーパスの開発はツリーバンクより更に困難であるため、このようなリソースが利用できる言語は限られている。

ここで述べた技術は、一つの文の意味構造を認識することを目的としている。しかし、実際の文章では、意味構造に必要な全ての情報が一文で完結することはなく、しばしば先行する文で言及された単語やフレーズが参照される。完全な意味表現を得るためには、文外の情報を適宜参照する必要があり、共参照解析・照応解析として研究が行われている。

### 1.4.2.3 グラウンドされた意味構造解析

これまで述べた意味構造解析は、自然言語文の意味を表す汎用的な表現を求めることを目的としていた。一方、出力すべき表現がアプリケーションから要請されるケースもある。例えば、大規模データベースである「Freebase」<sup>3</sup>に対して自然言語で問い合わせをしたいとする。この場合、Freebaseからデータを取り出すためにはSPARQL言語<sup>4</sup>でクエリ<sup>5</sup>を書かなければならない。したがって、入力 of 自然言語文を、最終的にはSPARQLクエリに変換することが要求される。これは、自然言語の構造解析の立場からすると、SPARQLクエリを意味表現とみなせば、意味構造解析の一種と見ることができる。

このように、自然言語文をデータベースクエリなどのアプリケーション依存の形式言語に翻訳するタスクを、狭義の意味構造解析、あるいはグラウンドされた

■表1 Grounded semantic parsingの代表的なリソース

|              |                   |
|--------------|-------------------|
| GeoQuery     | 米国の地理に関する質問応答     |
| Jobs         | 求職情報に関する質問応答      |
| Free917      | Freebase に対する質問応答 |
| WebQuestions | Freebase に対する質問応答 |

※2

米国の論理学者リチャード・モンタギュー(Richard Montague)氏が1973年の論文で記号理論における意味論と自然言語における意味論には本質的な違いはないとしたことに始まる、自然言語を記号理論の論理式で表現し構造解析を行う意味解析のアプローチ方法。

※3

Google(米国)が提供する知識情報データベース。

※4

SPARQL(SPARQL Protocol and RDF Query Language)言語は、ウェブ上にあるリソースの関係を記述するRDF(Resource Description Framework)に対して検索をする際のクエリ言語。

※5

検索内容を式として表したものの。検索式。

意味構造解析 (grounded semantic parsing) という。表1に示すように、これまでにいくつかのデータセットが開発されている。

基本的なアプローチは、前述の意味構造解析と大きく変わらない。句構造を用いる手法、依存構造を用いる手法、CCG (Combinatory Categorical Grammar) を用いる手法など、様々な手法が提案されている。ただし、このタスクでは、学習データとして入力文と意味表現だけが与えられ、中間の構文構造は与えられないことが多い。したがって、完全な教師あり学習を用いることができず、構文構造を隠れ状態とした弱教師あり学習<sup>6</sup>が適用される。

つまり、正解の意味構造を導く構文構造は分からないため、構文構造を列挙して意味表現への写像を計算し、意味表現が正しいかどうかを判定基準として、構文構造と意味構造の曖昧性解消<sup>7</sup>モデルの学習を行う。更にこの考え方を拡張して、正解の意味構造を与えず、質問に対する答えだけから意味構造解析モデルを学習する手法も提案されている。この場合は意味構造も隠れ状態として扱われ、正しい答えを得られるかどうかという教師信号を利用して学習を行うことになる。構文木や意味構造を教師データとして与える場合より難しい問題設定であるが、高精度な意味構造解析モデルが学習されることが示されている。

### 1.4.3 自然言語の意味・知識理解技術

#### 1.4.3.1 意味解析

1.4.2項で述べた構造解析技術は、文の構造的情報、すなわち単語間の依存関係を明らかにするものである。自然言語処理の分野では、1990年代後半から、更に単語の意味に深く踏み込んだ解析 (意味解析) が行われるようになった。しかし、具体的に「意味」とは何か? どのような「意味」が解析できればよいか? 計算機が扱える形で意味解析の問題を定義するには? 人間にもある程度解けるような問題か? 意味解析の研究では、基礎解析以上に、意味解析の問題をどのように“設計する”かが重要である。

このような問いに答える形で、多くの研究者により多種多様な意味解析問題の設計と評価用データセットの構築が行われた。また、MUC (Message Understanding Conference)、SemEval (Semantic Evaluation)、CoNLL (Conference on Natural Language Learning) Shared Taskといった評価型ワークショップ<sup>8</sup>が開催され、意味解析問題の標準化・データの共有が行われた。その全てを本書で紹介することはできないため、いくつかの重要な問題を紹介する。

「感情極性解析」(Sentiment Polarity Analysis) は、ある文、又は文章が与えられたとき、そこに表明されている意見がポジティブなものか、ネガティブなものかを解析する技術である。例えば、レストランのレビュー記事に書かれた「The atmosphere was good. I really liked the cesar salad.」(雰囲気は良かった。シーザーサラダは本当に気に入った) に対して、「ポジティブ」を出力する。意味解析タスクの評価型ワークショップであるSemEvalにおいても、過去6回共通タスクとして採用されており、実に多くの解析手法が提案されている。

「含意関係認識」(Recognizing Textual Entailment; RTE) は、ある2文、TとHが与えられたとき、TがHを含意するか (Tが真のとき、Hも必然的に真となるか) を解析する問題である。例えば、下記の

※6  
正解の一部が与えられ、残りの正解の推定を含め学習を進める方法。

※7  
一つの文に対して文法的には複数の構文構造が成立可能であり、その中から人が実際に解釈する構文構造を選択すること。

※8  
「評価型ワークショップ」とは参加者に共通のデータを提供し、そのデータの評価(意味解析)を競うコンテスト型のワークショップ。

2文が与えられたとする[2]。

T: Cavern Club sessions paid the Beatles £15 evenings and £5 lunchtime.

H: The Beatles perform at Cavern Club at lunchtime.

一般的に、Cavern Club sessionsがthe Beatlesに対してlunchtimeに£5を支払った (paid) ということから、The BeatlesがCavern Clubで演奏した (perform) ということが推論できる。つまり、この例に対しては、「含意する」を出力する。含意関係認識の問題は、バルイラン大学 (イスラエル) のイド・ダガン (Ido Dagan) 氏らの研究グループの主導により、2006年に「Pascal RTE Challenge」として共通タスク化され[2]、過去7回の評価型ワークショップが行われた。最近では、2文の「含意」関係でなく「類似」関係の判定をタスクとする、STS (Semantic Textual Similarity) というタスクも提案され、2012年からSemEvalのタスクの一つとして採用されている。

意味解析問題の標準化、評価データの整備が行われると、意味解析手法の研究も大きく進展した。多くの意味解析問題は古典的な分類問題・構造予測問題に帰着されるため (例えば、感情極性解析と含意関係認識は二値分類問題である)、解析モデルそのものは、機械学習分野で古くから研究されているSVM、CRFといった基本的なものが用いられた。

前述の2例からも分かるように、意味解析の問題を解く上で重要なのは、人間が持つある種の常識的な知識を解析モデルに取り込むことである。先の例で言えば、「バンドに演奏をしてもらうためにはお金を支払う必要がある」「The Beatlesはバンドである」といった知識である。こうした、人手により書き尽くすことが困難で、小規模な評価用データから学習することも困難な知識を、いかにして解析モデルに組み込むか、といった観点から多くの研究が行われている。

#### 1.4.3.2 文脈解析

1.4.2項で述べた自然言語の基礎解析技術は、一つの文を解析の対象とした技術である。しかし、我々が日常的に目にする本、新聞、ブログなどに存在する自然言語は、文のまとまり、すなわち文章である。一般に、文章全体の意味を考慮した自然言語の処理は「文脈解析」と呼ばれ、多くの研究が行われてきた。

代表的な例として、「照応解析」がある。照応解析は、文章内に存在する照応表現 (代名詞など) について、その指し先を明らかにする解析である。例えば、「John shouted at Bob. He was angry.」という文章が与えられたとき、Heが指し示すものはJohnである、ということと同定する。解析手法については意味解析と同様、基本的な機械学習モデルに基づいて、性別の一致や同義性認識といった意味的な特徴量をいかに設計するか、といった点で多くの研究がなされ、今では解析器がソフトウェアとして公開されて広く使われるなど、限られた場面においては実用段階に達しつつある。

また、省略された代名詞に対する照応解析はゼロ照応解析と呼ばれ、代名詞が頻繁に省略される言語 (中国語、日本語など) では、特に大きな問題となっている。ゼロ照応解析では、代名詞の情報 (性別、物・人の区別など) を解析に用いることができないため、特に難易度の高い問題として広く認識されている。例えば日本語では、その最高性能は3割程度にとどまっている[3]。

談話構造解析は、文章内の文間の意味的構造を明らかにするタスクである。例えば、「John shouted at Bob. He was angry.」という文章では、2文目が1文目の「理由」となっていることを同定する。「構造」の仕様については様々な選択肢が考えられ、実際にこれまでに多くの議論があるが、実際にはRST (Rhetorical Structure Theory) などが多く用いられている。また、今日、談話構造解析の研究において最もよく用いられている評価データとして、ペンシルベニア大学が主導する「Penn Discourse Tree Bank」(PDTB) がある。PDTBは、ニュース記事の2文間に対して、約3万の意味的関係を付与したも

ので、談話構造が付与されたデータセットとしては大規模なものである。2006年のデータ公開を皮切りに、様々な談話構造解析手法の研究がPDTBを用いて盛んに行われている。

### 1.4.3.3 ディープラーニング・分散表現の登場

「Googleの猫」に代表される、2010年代に起こったディープラーニングによるブレイクスルーは、自然言語処理の研究にも大きな影響を与えた。一つの大きなブレイクスルーは、言語の分散表現 (Distributed Representation、又はEmbedding)<sup>9</sup>学習の成功であろう。最も代表的な枠組みは、Googleのトマス・ミコロフ (Tomas Mikolov) 氏によって提案された、通称「Word2Vec」[4]である。文献[4]は、分布仮説 (Distributional Hypothesis) の分散表現版ともいえるアイデアにより、大規模コーパスから単語の表現学習が効果的に行えることを示した。例えば、学習されたベクトルの足し算・引き算により、ある種の意味的な演算が行えることを示した (例えば、 $V(\text{King}) - V(\text{Male}) + V(\text{Female}) \approx V(\text{Queen})$  など)。なお、自然言語処理における分散表現に関する研究については、文献[5]を参照されたい。

このほか、前述した基礎解析技術を含め、意味解析、文脈解析といった、あらゆる自然言語処理の研究においてもディープラーニング化の波が押し寄せた。例えば、畳み込みニューラルネットワーク (CNN) を利用した感情極性解析、RNNに基づく含意関係認識、RNNに基づく共参照解析、FFNNに基づく談話構造解析などが提案されている。しかし、その効果は画像や音声分野ほどのインパクトがなく、性能の向上幅は極めて限定的であり、依然として残された課題は多い。

画像や音声など、意味が詰まった、又は自己完結した“信号の入力”とは異なり、言語は人々が共有している知識を呼び起こすだけの、いわばトリガーのようなものでしかない。つまり、言語はまさに「記号」なのである。ディープラーニングの特徴は特徴量の自動学習であるが、こうした人の知識に依拠した「記号」の列から意味のある特徴量を取り出すことは、画像や音声とは異なる難しさがあると考えられる。それゆえに、人が持つ知識をいかに獲得・モデル化し、それらを解析の中でうまく使いこなせる計算機構をいかに作るかが、依然として本質的で重要、かつ困難な課題であり、未解決な問題として残されている。特に文脈解析といった高次の解析になるほど、この傾向は顕著であると考えられ重要となる。

### 1.4.3.4 議論マイニング

2010年代、議論マイニング (Argumentation Mining) と呼ばれる研究コミュニティに大きな動きがあった。議論マイニングとは、小論文や学術文献などの「議論」に関する文章を主な対象とし、情報抽出・談話構造解析を行う研究分野の一種である。2000年代においては、自然言語処理とは異なる文脈で研究が行われ、2006年に計算機上での議論モデルに関する国際会議 Computational Models of Argument (COMMA) が初めて開催され (隔年開催)、2014年には自然言語処理のトップ会議である ACL (Association for Computational Linguistics) において、その第一回ワークショップ Workshop on Argumentation Mining が開催された (第四回目は2017年、自然言語処理のトップ会議 EMNLP (Conference on Empirical Methods on Natural Language Processing) で開催予定)。

議論マイニングの研究は、意味解析・文脈解析の研究と同様、問題設計に関する議論や、評価用データの構築に関して数多くの議論がなされることから始まり、今まさにこれを解くための計算機モデルの検討が始まったばかりである。代表的な問題設定として、ある議論のトピックに対する著者の立場 (賛成や反対など) を同定するスタンス認識 (Stance Detection)、オンライン掲示板やディベートなどに

---

※9

「言語の分散表現」とは単語を高次元のベクトルで表現する方法。

おける複数の発言者の発言の関係を、支持 (support)、反論 (attack又はrebuttal) に分類する議論関係分類 (Argumentative Relation Detection)、議論の各文をコンポーネント (「背景」「関連研究」など) に分類する議論ゾーニング (Argumentative Zoning) といった問題が提案されている。解析モデルとしては、これまでの意味解析と同様、単語などの表層情報や意味的特徴量に基づく機械学習モデルが用いられているが、その性能は十分なものでなく、検討の余地は多い。

また、現状の議論マイニングで取り組まれている問題は、基本的には古典的な談話構造解析の問題の延長であるが、これは議論の自動評価 (Automated Essay Scoring) などの実際に想定された応用技術を要する入力に対し、少々のギャップがある。例えば、議論の自動評価では、文間が「証拠」の関係にあるということ以上に、書き手がどのような事実や類推を組み合わせで証拠と考えるに至ったのか、といったより深い議論の解析結果が必要とされる。今後の議論マイニングの研究では、こうした深い解析に取り組む研究も登場してくるだろう。

#### 1.4.3.5 常識推論

これまでに紹介した意味解析、文脈解析の研究は、自然言語の解析の上で解消すべき言語現象を駆動力として発展してきた。一方で、近年「言語の理解とは何か」を出発点として、学際的に行われる自然言語処理の研究が一つの大きな流れを作りつつある。本項では、その最新動向を紹介する。

チューリングテストは、「機械が知能を持つか」を判定するテストとして古くから用いられているテストである。審査対象の機械は、審査員から見えない別室に置かれ、審査員はその機械とひととおりの会話を交わす。審査員がその相手を機械だと見破れなければ、その機械は知能を持つと判定されるのである。こうした機械の知能テストを目的として、2000年代後半から今に至るまで、いくつかのテストが提案され、常識推論 (Commonsense Reasoning) タスクとして、大きな注目を浴びつつある。

南カリフォルニア大学のアンドリュー・ゴードン (Andrew Gordon) 氏の研究グループでは、「知能を持つ」ということを事象の因果関係の予測能力になぞらえ、「COPA」 (Choice of Plausible Alternatives) という常識推論問題を提案した。COPAは、前提 (Premise) と二つの文Alternative 1、Alternative 2が与えられたとき、Premiseの結果 (又は原因) として相応しい文を選ぶ問題である。例えば、下記の問題を見てみよう。

Premise: The man broke his toe. What was the CAUSE of this?

Alternative 1: He got a hole in his sock.

Alternative 2: He dropped a hammer on his foot.

前提Premiseにおけるつま先 (toe) を怪我した (broke) ことの原因としては、靴下 (sock) に穴が空いたから (got a hole) ではなく、金づち (hammer) を足 (foot) の上に落とした (dropped) から、ということがより相応しい。つまり、正解はAlternative 2である。このほか、著者のウェブサイト<sup>10</sup>において、データセット1,000問が一般公開されている。

また、2016年、ロチェスター大学 (米国) の研究グループは、COPAを拡張した「ROC Stories」という問題を提案し、10万ストーリーからなるデータセットを一般公開している。ROC Storiesでは、4文からなるストーリーが与えられたとき、そのエンディングとして最も適切な文を二つの選択肢から選ぶことを要求される。2017年1月には、ROC Storiesを対象としたコンペティションが開かれ、2017

---

※10

Choice of Plausible Alternatives (COPA) Website  
<http://people.ict.usc.edu/~gordon/copa.html>

年4月に自然言語処理のトップ会議の一つであるEACL (European Chapter of the Association for Computational Linguistics) のワークショップとして、各種システムと関連研究の発表が行われた。

この種の問題を解くには、計算機も因果関係に関する常識的知識を持っていなければならない。例えば、上の例では、「足にhammerを落とすと、怪我をする」ということを知っていなければならない。現状行われている研究の主な解法は、因果関係を表すキーワード (“because” など) や照応関係などの手がかりを用いて、大規模な文章の集合から常識的な知識を獲得し、これらを基に2文間の因果関係を統計的に計算する手法である。また、獲得した知識をSequence to Sequence学習モデルに投入し、ストーリーの生成器を構築するアプローチもある。COPA、ROC Storiesともに、まだ7割程度の精度でしか解析ができておらず (2017年4月時点)、これからの発展が楽しみな分野である。

また、ニューヨーク大学のアーネスト・デイヴィス (Ernest Davis) 氏とトロント大学 (カナダ) のヘクター・レヴェック (Hector Levesque) 氏の研究グループは、「統語的手がかり (統語的役割や、述語の選択好性など) だけでは解けない照応解析の問題が解けること」を基準として知能テストを定式化した<sup>11</sup>。このテストは、AI研究者テリー・ウィノグラード (Terry Winograd) 氏にちなんで、「WSC」 (Winograd Schema Challenge) と名付けられた。

テストの例を下記に示す。

- (1) The city councilmen refused the demonstrators a permit because they feared violence.
- (2) The city councilmen refused the demonstrators a permit because they advocated violence.

ここでは、theyの指し先を、(1) ではthe city councilmen、(2) ではthe demonstratorsと正しく同定する必要がある。このためには、COPAやROC Storiesと同様、「ある人が何かをfearすると、refuseする」といった常識的な因果関係の知識に基づいた予測モデルを構築する必要がある。(1) と同時に (2) のような問題が含まれているため、「主語が先行詞として選択されやすい」といった統語的な手がかりだけでは正しく解析ができないようになっており、常識的な知識を使いこなして初めて解ける問題集となっている点がポイントだ。

2016年には、AIのトップ会議であるIJCAI (International Joint Conference on Artificial Intelligence)<sup>12</sup>のワークショップとして、WSC (World Sudoku Championship) の第一回コンペティションが開かれた。コンペティションにおける最高性能は、大規模ウェブデータから獲得した因果関係知識とニューラルネットワークを組み合わせたモデルであったが、その性能は5割程度であり、まだまだ発展途上の段階である。こうした常識的知識を使いこなす能力は、AI研究の発展には欠かせないものであり、今後の注目分野である。

#### 1.4.3.6 知識獲得

これまで見てきたように、意味解析、文脈解析、常識推論では、基礎解析以上に常識的な知識の活用が重要である。この重要性は古く1980年代から認識されており、知識表現 (Knowledge Representation)、知識ベースの構築、推論の枠組みに関する様々な研究がなされてきた。研究の初期段階は、これらの知識を人手により整備する試み (例えば、プリンストン大学のWordNet、カリフォルニア大学バークレー校のFrameNetが主流であったが、2000年代にいわゆる情報爆発の流れを受け、ウェブ上の

---

※11  
“The Winograd Schema Challenge,” NYU Computer Science Website <<http://www.cs.nyu.edu/faculty/davise/papers/WinogradSchemas/WS.html>>

※12  
米国AI学会が主催している。

大規模な文章集合から常識的知識を獲得する研究が急速に発展した。

獲得された知識は、固有名詞に関する知識 (locateAt)、オントロジ的な知識 (animal-catなどの上位下位関係)、事象間関係知識 (hungry-eatなど) まで多岐に渡る。本項では、近年大きな動きがあった、固有名詞の関係知識の獲得と、事象間関係知識の獲得の研究の最新動向を紹介する。基本的には、1.4.3項で述べた分散表現に基づく知識表現・推論がトレンドである。

「知識グラフ」(Knowledge Graph) とは、主に固有名詞の関係予測問題の文脈で発展してきた知識表現の一種である。その名のとおり、概念 (ここでは固有名詞) をグラフにおけるノード (頂点) に、関係をグラフにおけるノードをつなぐエッジ (辺) としたグラフであり、固有名詞間の関係ネットワークを表現する。

初期 (2000年代) の知識グラフの獲得手法としては、ワシントン大学のオレン・エツィオーニ (Oren Etzioni) 氏の研究グループによって開発されたText Runner、ReVerbに代表されるような、テキスト中に記述された関係知識に対する半教師ありの分類器に基づいて、関係抽出を行うことで知識グラフを構築していた。だが近年は、予測のロバスト性向上のために、分散ベクトル表現を用いた知識グラフの表現が主流である。

もう一つの最近の知識獲得研究のトレンドとして、「スクリプト的知識」(Script Knowledge) に代表される事象間関係知識の研究がある。スクリプト的知識とは、ロジャー・シャンク (Roger Schank) 氏が提唱した概念であり、同時に起こりうる典型的な事象の集合を表す。例えば、「レストラン」のスクリプトには、「椅子に座る」「メニューを見る」「注文する」といった事象の集合が含まれる。典型的なスクリプト的知識の自動獲得の手法は、“and then” などの語彙統語パターンや、照応関係を用いて事象間の関係知識をウェブコーパス<sup>13</sup>から大規模に獲得し、これらに基づいて因果の強さを統計的に推定するものである。

こうした自動獲得のアプローチにおける大きな課題の一つとして、コーパスから大量に獲得した因果関係の事例をどのように一般化し、知識とするか、という問題がある。例えば、「John was fined because he smoked in a non-smoking hotel room.」、「Mary smoked in a non-smoking room, so she was fined 10,000 yen.」といった因果関係の事例からは、“人がnon-smoking roomで喫煙すると、罰金を払わされる (fined)” という一般的な知識が得られる。しかし、これを更に一般化した“人が喫煙すると、罰金を払わされる” というのは (少なくとも相対的に) 不適切に見える。

この問題を解消するために、近年はニューラルネットワークに基づくスクリプト知識のモデル化の研究が盛んに行われている。従来の研究では、一般化の粒度を「動詞のみ」「主語、動詞、目的語」などに固定していたのに対し、分散表現に基づく手法では、できるだけ事象に関する多くの情報を入力し、因果関係の推定が正しく行えるような事象の表現 (すなわち、一般化の粒度ともいえる) を自動的に学習する、ということが期待される。ほかに、Word2Vec[4]を因果関係記述の集合に適用し、因果関係を予測するのに特化した分散表現 (Causal Embedding) を学習する手法、獲得した因果関係を一般化した上で知識グラフ (ノードが事象、エッジが因果関係となる) を構築する手法がある。こうした研究によって、意味解析・文脈解析における長年の課題であった、常識的な知識の効果的な利用方法について、展望が見え始めている。

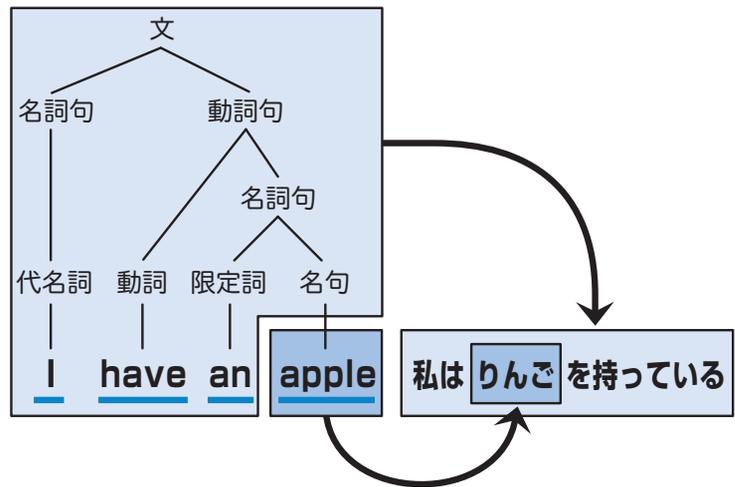
---

※13

ウェブ上から利用できる、言語の文章を大規模に集めたデータベース(コーパス)。

#### 1.4.4 自然言語の生成技術

コンピュータが得た知識を自然言語によって表現し、テキストや音声の形で提示するという考えは、人間をユーザとするAIシステムの出力手段としては極めて自然なものの一つであろう。このような自然言語生成に関する技術は、自然言語処理の主要な目的の一つとして研究されており、様々な手法が提案されてきた。



■図22 構文情報を用いた伝統的な機械翻訳の例(Tree to string統計的機械翻訳)

##### 1.4.4.1 具体的な構造に基づく自然言語生成技術

伝統的には、入力された知識情報と生成対象の自然言語との部分的な対応関係を列挙し、これらの断片的な情報に推論や探索アルゴリズムを適用することで、出力文として最も整合性の高い組合せを探索する手法が長年研究されてきた。これらの手法で特徴的なのは、入出力の具体的な記号同士の対応関係を明確にし、考慮する点である。

例えば、図22に示すのはTree to string統計的機械翻訳と呼ばれる伝統的な機械翻訳システムの動作例であるが、英語と日本語の文の断片「I have an...」と「私は...を持っている」、「apple」と「りんご」といった個別の対応関係をシステムが直接データベース上に保持しており、入力「I have an apple」が与えられた際には、無数に考えられる断片の組合せの中から回答として相応しい選択肢を絞り込むことで出力文「私はりんごを持っている」を生成する。対話システムや質問応答システム等においても、システムによる推論で導き出された情報を、あらかじめ用意したテンプレートやルールの集合に合致するように配置することで出力を生成する手法が用いられてきた。

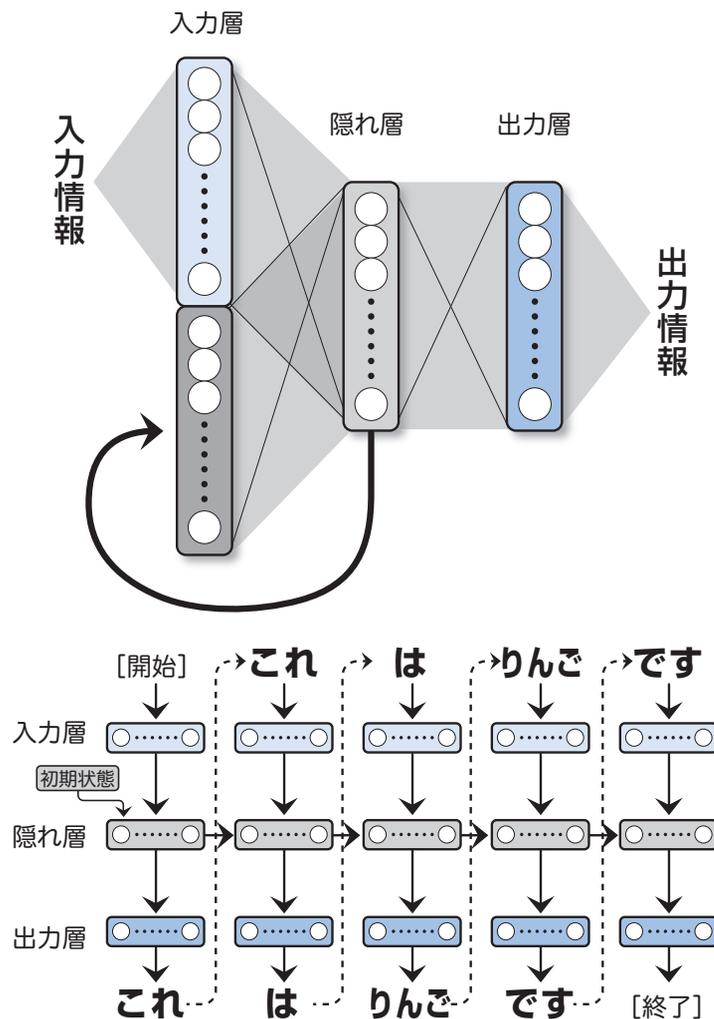
このような手法では入出力言語の統語構造や論理構造を知ることが大きな手がかりとなり、前項で紹介した構文解析技術、及び意味解析技術が重要な役割を担う。また文生成に用いられるデータ構造と実際の文の構造が密接に関連しているため、実際の処理を分解することで、どのような手順で出力文が生成されたのかを人間が明示的に知ることができる。このため、伝統的な文生成システムは技術者によって内部の挙動を直接観測・制御することが可能である。このような特徴は、実際のアプリケーションへ文生成システムを適用する際には利点となる。

一方、システム内部の挙動が複雑なデータ構造に支配されている点が、あるアプリケーションで使用された手法を他のアプリケーションにそのまま移植することを難しくする要因にもなっている。例えば機械翻訳システムの自然言語生成機能を他のアプリケーションに応用したい場合、アプリケーション側では機械翻訳に適したデータ構造を中間データとして出力する等の工夫が必要となり、この作業にしばしば多大な労力を必要とすることとなる。

##### 1.4.4.2 リカレントニューラルネットワーク言語モデル型デコーダによる自然言語生成技術

人間の日常的な会話で発生する自然言語生成では、常に厳密な文の構造を意識しながら単語の選択を行っているとは考えにくい。話者が話そうとする情報に基づいて、前後の単語同士が流暢に接続するよう順に単語を選択しているのとらえるのが妥当であろう。

このような挙動を実際の文生成システムに当てはめて考えると、入力データと初期状態を受け取り、出力文の単語を逐次的に出力するオートマトン<sup>14</sup>の一種としてとらえることができる。このオートマト



■図23 RNNの基本構造(上)  
RNNを使用した自然言語生成の仕組み(RNNLM型デコーダ)(下)

ンに必要となるのは、現在のシステムの状態に基づき、出力単語列の言語としての流暢さを考慮した上で、次回の出力として最も妥当な単語を決定する仕組みである。

このような仕組みは言語モデルと呼ばれ、出力文の流暢性を担保する重要な素性として、様々な自然言語処理システムの構成要素として導入されてきた。言語モデルの本質は「過去の入力系列から次回の出力単語の分布を求める確率モデル」であり、単語の分布の定式化により、大きくn-gram言語モデルとリカレントニューラルネットワーク言語モデル（Recurrent Neural Network Language Model; RNNLM）の2種類に大別される。このうち、後述の理由により、近年の研究ではRNNLMを自然言語生成システムとして採用するものが増えつつある。

RNNLMは、図23のようにRNNを内部状態として採用した言語モデルである。同様のネットワーク構造は1980年代に既に提案されているが、これを言語モデルに応用したミコロフ氏らの研究は、ディープラーニングの手法を自然言語処理に流入させる契機となった点で、自然言語処理研究の転換点として重要な位置にある。

RNNLMの出力単語を入力にフィードバックさせることで、入力としてRNNの初期状態ベクトルの

※14

外部からの入力に対して、内部の状態に応じた処理を行い、結果を出力する処理のこと。同じ入力に対して、内部の状態によって異なる出力を行う場合があることが特徴である。

みを受け取り、文末まで自動的に単語を生成し続ける自然言語生成システム（デコーダ）を構築することができる。このような仕組みを本節ではRNNLM型デコーダと呼ぶこととする。

### 1.4.4.3 エンコーダ・デコーダモデル

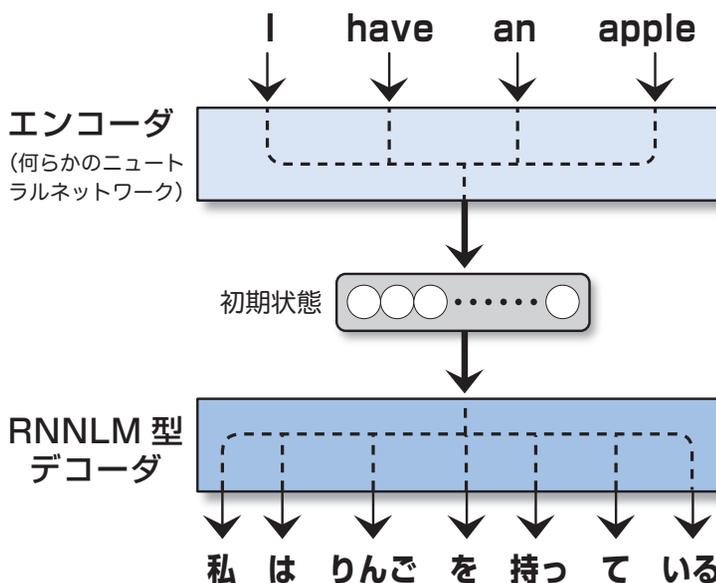
RNNLM型デコーダの初期状態ベクトルは、本質的には単なる実数ベクトルであり、自然言語の生成に必要な情報が格納されていること以外には基本的に値の制約が問われない。

つまり、入力情報を単一の実数ベクトルにエンコードする任意の手法（エンコーダ）を接続することが可能である。この特徴により、従来の具体的なデータ構造を入力データとして使用する自然言語生成システムに比べて、RNNLM型デコーダは様々な入力とモデル的に連携しやすいという特徴がある。

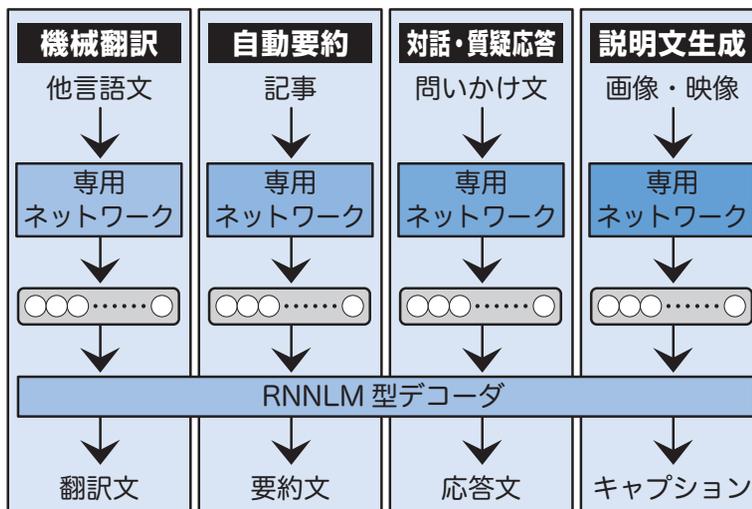
ここで、何らかのニューラルネットワークにより構成されたエンコーダをデコーダに接続することで、エンコーダとデコーダ双方を単一のニューラルネットワークと見なして同時に学習することが可能となる。このように、中間データを介してエンコーダとデコーダが対向する形で構成されたニューラルネットワークは、「エンコーダ・デコーダモデル」と呼ばれる。

最も初期のエンコーダ・デコーダモデルとして、エンコーダにもデコーダとほぼ同様のRNNを備えたエンコーダ・デコーダ機械翻訳モデルが挙げられる。これに注意機構を加えたモデルは、現在の機械翻訳システムの主流の構成法であり、2014年頃から著名な機械翻訳コンペティションにおいて次々と最高精度を達成し続けているのは記憶に新しい。

Googleが2016年に発表した機械翻訳システム「GNMT」（Google Neural Machine Translation）も、本質的にはエンコーダ・デコーダ機械翻訳モデルにいくつかの改良を加えたものである。図24では、エンコーダ・デコーダ機械翻訳モデルで先程の例「I have an apple」を「私はりんごを持っている」に翻訳する例を示している。まずエンコーダが英単語「I」「have」「an」「apple」を順に読み込み、中間データである初期状態ベクトルを生成する。デコーダは初期状態ベクトルを受け取り、自身の状態遷移にしたがって単語列「私」「は」「りんご」「を」「持つ」「て」「いる」を生成する。このモデルの場合、初期状態ベクトルが入力文に関する情報を全て蓄えていることは明らかである。



■図24 エンコーダ・デコーダモデル(機械翻訳の場合)



■図25 様々なタスクで共通して使用可能なRNNLM型デコーダ

エンコーダ・デコーダ機械翻訳モデルは入出力がともに可変長の単語列であることから「Sequence to Sequenceモデル」とも呼ばれる。また、単一のニューラルネットワークで入力から出力までの全てを扱うモデルを「End to Endモデル」と称することがあり、エンコーダ・デコーダモデルはEnd to Endモデルのサブセットであるということもできる。

前述したように、RNNLM型デコーダを使用し、エンコーダ部分を入力データに適したネットワークに変更することで、様々なデータ形式から自然言語を生成するシステムを構築可能である（図25）。例えば、前述のように自然言語を受け付けるエンコーダを使用することで機械翻訳や自動要約システムの基本的な構成を作ることができ、CNN等の画像を認識可能なネットワークをエンコーダとすることで、キャプションや映画の字幕・あらすじの生成等を実現することができる。

実際の人間の脳活動と関連した研究としては、機能的MRI（functional Magnetic Resonance Imaging; fMRI）画像を認識するエンコーダを接続することで、脳活動の情報から自然言語を生成する試みがある。このように、従来モデル的に連携が難しかったデータ構造同士が、エンコーダ・デコーダモデルの枠組みの下で有機的に結合することが可能となった点は特筆に値する。

#### 1.4.4.4 リカレントニューラルネットワーク言語モデル型デコーダによる自然言語生成の課題点

このように、様々な入力に対して有効性が期待されるRNNLM型デコーダ（及びエンコーダ・デコーダモデル）であるが、従来型の自然言語生成システムには存在しなかった特有の問題が複数存在することも報告されている。

特に、単純な構成のRNNLM型デコーダは初期状態を与えれば全自動で動作するため、外部からデコーダの挙動を制御する手段が存在しない点がしばしば問題となる。これにより引き起こされる主な問題として、「過生成」「生成不足」の2点がある。

過生成とはデコーダの状態遷移が何らかの不動点に陥ってしまい、同じ情報を繰り返し（しばしば永遠に）出力し続けることをいう。生成不足とは逆に、本来必要な状態遷移の一部をスキップしてしまったがために、入力として与えられた情報の一部のみが自然言語として出力されてしまうことをいう。表2は機械翻訳における過生成と生成不足の典型例である。このような問題がどのような条件で発生するのは今のところ詳しい解析がなされていない。モデルの構造を工夫することによって間接的に回避するための手法も研究されているが、数理的に解決されたとは言いがたく、今後の更なる解析が待たれる。

また、RNNLM型デコーダは本質的には単なる言語モデルの一種であるため、生成される自然言語の流暢さのみが過剰に追求され、本来の入力データの情報がデコーダにより改変されてしまう場合がある。この問題はGoogleによってGNMTがアプリケーションとして公開された当初から、翻訳結果の統語構造が入力文とは異なっていたり、入力文に全く存在しない名詞が突如として出現したり等、具体的な現象として指摘されている。

特に、言語モデルの効果によって出力文単体としては非常に流暢な文が得られるため、入力された正しい情報を知る手段を持たない者（機械翻訳であれば、入力言語を理解し得ない者）がデコーダの出力に「騙されて」しまう可能性があり、RNNLM型デコーダを使用する上で無視できない問題である。

なお、RNNLM型デコーダ単体としては文の意味合いを明示的に保存するような仕組みはなく、単に入力された情報と統計

■表2 RNNLM型デコーダにおける典型的な誤動作の例

|       |   |
|-------|---|
| 過生成   | 入力：I have an apple and an orange<br>出力：私はりんごとりんごとりんごとオレンジを持っている |
| 生成不足  | 入力：I have an apple and an orange<br>出力：私はりんごを持っている(オレンジを省略)     |
| 原構造無視 | 入力：I have an apple – pen<br>出力：私はりんごとペンを持っている                   |

的に合致する単語列を出力しているだけと考えるのが妥当であろう。このような問題が現状では見逃されている背景として、出力された自然言語文の評価法に問題があると考えられる。自然言語処理研究においてシステムの出力をどのように評価するかは重要な課題だが、現在の主な研究ではテストデータ全体に対する平均的な文の一致を計算する自動評価尺度（代表的な尺度として、機械翻訳ではBLEU (Bilingual Evaluation Understudy)、自動要約ではROUGE (Recall-Oriented Understudy for Gisting Evaluation) など) を使用する傾向が強い。

これらの尺度は文の特定の部分で大きな破綻をきたしているかまでは着目しないため、人間が文を理解するに当たって許容し難い誤りを過小評価してしまう傾向にある。これらの自動評価尺度は開発されて既に10年以上経過しているものが多く、この点でも現在主流の手法を正しく評価できるとは考えづらい。本来、問題解決のための手法とその評価法はともに進歩してゆく必要があるが、手法のみが単独で先行してしまっている状況にある。

対話システムや自動要約にRNNLM型デコーダを用いる場合は、デコーダが出力する情報の可制御性がより重要な問題となる。対話システムの場合、ユーザにシステムが提示する情報は、システムが生成する文に過不足なく表現されている必要がある。これを実現するために、対話制御のための内部状態をRNNの要素として導入することで一定の可制御性を担保する仕組みが提案されている。自動要約では生成される文の単語数が特に重要となるが、これを制御する機構を導入し、出力文の長さをユーザがある程度可能とした手法が提案されている。

一般的にニューラルネットワークの学習には大規模なコーパスが必要となるが、これはRNNLM型デコーダにおいても同様である。言語モデルや機械翻訳といったタスクでは、数百万文～数億文程度のコーパスが比較的容易に入手可能であるため、(種々の問題は残っているが) 実用的なレベルの性能を達成可能なモデルを学習することができる。自然言語処理のなかでも、特にこれらの分野で最初にディープラーニングの応用が始まったのは、このような言語資源による背景も大きく影響していると考えられる。

一方で、話者が少数の言語や、対話システム等の大規模なデータ収集が難しい分野では、言語資源の少なさに起因するニューラルネットワークの適用の困難さが直接支障となる場合がある。このような問題への対処として、異なる言語・ドメイン上の大規模なコーパスで獲得されたモデルの流用や合成によってモデルの頑健性を向上させる試みがある。GNMTにおいて複数の言語を同時に学習させることで、未知の言語対においても翻訳可能なことを示した例はその最たるものであろう。これらは「教師データとして明示的に与えられない表現を学習する」という意味でゼロショット学習と呼ばれる傾向にある。

#### 参考文献

- [1] 黒橋禎夫・長尾眞「京都大学テキストコーパス・プロジェクト」『言語処理学会第3回年次大会予稿集』
- [2] In Machine learning challenges. Evaluating predictive uncertainty, visual object classification, and recognising textual entailment. I. Dagan, O. Glickman, and B. Magnini, "The PASCAL recognising textual entailment challenge," Springer, pp.177-190.
- [3] 大内啓樹ほか「文書全体を考慮したニューラル文間ゼロ照応解析モデル」『言語処理学会第23回年次大会発表論文集』 pp.815-818.
- [4] T. Mikolov et al., "Distributed representations of words and phrases and their compositionality," Neural Information Processing Systems, pp.3111-3119.
- [5] 岡崎直観「<特集>ニューラルネットワーク研究のフロンティア「言語処理における分散表現学習のフロンティア」『人工知能(人工知能学会誌)』 vol.31 No.2, 2016.3, pp.189-201.

# 1.5 ビッグデータ時代の知識処理

## 1.5.1 総論



図26 本節の構成

人工知能（AI）はデータや知識を参照して有意な結論を導くが、データや知識の形態と量、またそれらから結論を導く方法（推論法とも言える）は時代とともに変遷がある。

第2次AIブームであった1980年代の知識処理は、主にルールで記述された知識に基づき、演繹を主体とする推論により結論を導くものであり、多くのエキスパートシステムが作成された。しかし、知識の記述は人手によるものが大半であるために大規模化するのが困難で、データ／知識の量は今日のビッグデータ時代に比べるとはるかに小規模であり、期待には応えられなかった。この人手による知識記述や知識獲得の課題に対処すべく、1980年代後半から機械学習、データマイニングの研究が活発になり、今日に至っている。

1990年代に普及、拡大したウェブは、グローバルな情報共有、情報流通のプラットフォームとして情報環境に革命的な変化をもたらし、今日に至っている。知識の点では、共同執筆のオンライン百科事典である「Wikipedia」は、オンラインの知識源として重要な役割を果たすようになってきている。また2000年代には「SNS」（Social Network Services）の登場等で、各個人の情報発信が増大した。このようなサイバー情報空間の拡大に加え、「IoT」（Internet of Things）による各種センサからのデータもサイバー空間にもたらされ、サイバーフィジカルシステム（Cyber Physical System; CPS）も進捗しつつある。このようにしてデータ／知識量は増大しつつあり、ビッグデータ時代となった。

このビッグデータ時代のデータや知識の形態は、1980年代とは異なるものであり、それらを利用する知識処理も変化してきている。深層ニューラルネットワーク（DNN）によるディープラーニングは、大量データに基づき高性能な識別性能を達成する機械学習法として、2012年以降、広く利用されるようになってきている。

本節ではまず、以上のようなビッグデータ時代のAIが基にするデータや知識とその利用法を概観する（1.5.2項参照）。次いで、「データのウェブ」ともいふべき、知識をコンピュータが意味把握しやすい規格化された形態で表すLOD（Linked Open Data）の動向と、それに関連するオントロジー（基本語彙体系）について紹介する（1.5.3項参照）。最後に、ビッグデータを扱う上で、機械学習とともに実用性の点から多くの場合に必要になる線形モデル（Linear Model; LM）、混合モデル（Mixed Model; MM）、階層ベイズモデル（Bayesian Hierarchical Model; BHM）について紹介する（1.5.4項参照）。

## 1.5.2 データと知識ベース

AIが有意な結果をもたらすには、大量のデータ、大量の知識が必要になる。データを生データとすると、ここでの知識とは、データをある程度、整理・加工・抽象化して形式を整え、推論により組み合わせ、有意な結果を導出する源になるものととらえることができる。しかし、データと知識の境界は必ずしも明確であるわけではなく、特に本節で取り上げるビッグデータ時代には、データと知識の中間的なものも増大してきている（例えば自然言語テキストデータ）。

1970年代後半にAIにおける「知識」の重要性が唱えられ、1980年代には知識ベースに基づく多くのエキスパートシステムが作成された（第2次AIブームの時代）。このときの知識の形式は大部分がルール型であり、一部に階層構造を持つフレーム型や論理型、制約型も用いられた。知識の形式はともかくとして、この1980年代の知識の大半は（専門家へのインタビューや資料参照等を介して）人が書き下したものであり、今日のビッグデータ時代とくらべて小規模であり、スケールアップすることが難しいのが大きな問題であった。

人手による知識獲得の問題に対処すべく、1980年代後半から機械学習、データマイニングの研究が活発になり今日に至っている。データマイニングと言っても、ウェブが普及する以前は関係データベースが主なソースで、そこからの規則性発見の研究が多く行われた。

ウェブは情報共有、情報流通のプラットフォームとして登場し、1990年代半ばからのその普及と拡大は、データや知識のグローバルな流通と共有の主要なプラットフォームとして、検索エンジンを伴うことで情報環境に革命的变化をもたらした。2000年代になるとブログやSNS（代表的なものはTwitter、Facebook）なども登場し、いわゆるCGM（Consumer Generated Media）によって各個人のバラエティに富む情報発信も増大した。

知識の点で特筆すべきは、2001年に始まった共同執筆のウェブオンライン百科事典であるWikipediaである。2016年に英語版は約500万項目、日本語版で約100万項目の規模となっている。内容は中立的観点からの記述にすべきとの方針が採られており、情報の質も2005年に百科事典エンサイクロペディア・ブリタニカとの比較で大差はなかったという調査結果も示された。Wikipediaの情報を、コンピュータによる意味把握を容易にするLOD形式にしたのが「DBpedia」である（1.5.3項参照）。

以上のようにして、1990年代半ばから2000年代にかけては、物理世界とは別の情報のサイバー空間が出現し、拡大した時期であった。これに伴い、アクセス可能なパブリックの情報量は拡大の一途をたどっている。

キーワード検索の検索エンジンはウェブ情報空間利用に不可欠のツールだが、雑多な情報の選別など、アクセスには不十分な点も多い。Googleの「Knowledge Graph」は、ウェブ等から抽出したオブジェクト（事物）間の関係を意味ネットワーク形（オブジェクトをノードとし、ノード間の意味的關係を付したエッジで結んだグラフ）で知識化して表したものである。これにより、単なるキーワードでなくオブジェクトの意味的關係も考慮し、曖昧性を回避するような検索を可能にしている。

2012年の発表時点で57億件以上のオブジェクトと、それらオブジェクト間の180億件以上の意味的關係を有している。2016年に発表があったMicrosoftの「Concept Graph」は、テキスト理解に必要な概念をやはりノードとし、ノード間の確率を伴う関係で結ぶグラフとしている。この概念ノード数は540万程であり、テキスト文の常識に照らした確率的解釈に役立つ。1980年代後半から常識の知識ベース化として主に人手に頼って構築が進められたCYC<sup>1</sup>は、およそ50万概念の規模だが、上記Knowledge

※1

Cycorp Website <<http://www.cyc.com/>>

GraphやConcept Graphは、テキスト・ビッグデータからオブジェクトや概念を自動抽出しており、はるかに大規模の知識ベースとなっている（Concept Graphは一般公開される予定となっているが、Knowledge Graphの一般公開は不明である）。

情報のサイバー空間が拡大する一方で、2000年代にはデータ増大に関して別の動向も顕在化した。IoTやCPSなどと呼ばれる、物理空間とサイバー空間の情報を連携、融合させる動きである。これにより物理空間の多種大量のセンサ計測データがサイバー空間へもたらされ、新サービスに使われるようになってきている。気象データ、人の移動や行動データ、人の健康関連センサデータ、各種交通情報データ、物流データ、カメラなどの監視情報データなど、列挙するのは難しいほど多様多種であり、拡大している。

更に企業では、以前にも増して蓄積するデータ量を増している。ウェブ等のオープン・パブリックデータが注目されることが多いが、世界のデータ総量の70~80%程はこのような企業のプライベートデータであるとも言われている。

知識のソースとして、論文文献データも重要である。医療分野を始めとして公表される論文の情報は、人間が見て判断する量を超えており、コンピュータの助けなしでは十分に利用できなくなっている。その利用も、単なるキーワード検索から、意味的理解に踏み込む利用へと向かっている。

このようにして2000年代半ばにビッグデータ活用の時代になり、今日に至っている。先にも述べたように、AIは大量のデータや知識があって初めて価値を生むことができるのであり、ビッグデータとAIはセットで考える必要がある。

1980年代のルール型知識が主体であった時代の知識の利用法、すなわち推論は、三段論法的な演繹推論が主体であったが、多様なデータや知識のビッグデータ時代はそれらの活用法も多様になってきている。ウェブ上などのテキストデータを活用するには、自然言語理解やテキストマイニングといった手法が主要な役割を果たす。IoTのセンサからの生データの解釈（分類や異常検出など）やデータベース、データの解釈には、従来は統計的手法やパターン認識手法、データマイニング手法が用いられてきたが、ディープラーニングが高性能の成果を達成するようになった2012年以降には、ディープラーニングが注目され、多く用いられるようになった。2016年にニューラル機械翻訳の性能がそれまでのフレーズに基づく統計的機械翻訳の性能を超えるようになり、自然言語処理／理解に関してもDNNは広がる傾向にある。

一方で、ディープラーニングの使用に際して実用面から注意すべき点としては、

- (1) 高性能は達成できるが学習に従来以上の大量訓練データが必要になること。
- (2) 判定の過程がブラックボックス的で人間には理解できず、修正が必要になる場合にどこを修正すればよいか分からないことが多い（訓練データを追加して修正しなければならない）

といった点が指摘されている。またディープラーニングは高い成果を得られる可能性もあるが、特にデータ量が必ずしも十分でない場合などは、無暗にディープラーニングを用いるというのではなく、従来からの統計的アナリティクス、機械学習法なども試みて、見通しをつけることが必要になる場合がある（そういった意味で必要になる統計的手法については1.5.4項参照）。

2010年代の代表的なAIシステム及びプラットフォームとしてIBMの「Watson」を例にとり、データ／知識とその活用法を見てみることにする。IBMは、米国の人気クイズTV番組「Jeopardy!」（ジョパディ!）に挑戦するために、4年間の研究の結果としてWatsonを開発して、2011年2月に人間のチャンピオンに優る成績を挙げた。このIBM WatsonはDeep QA（深い質問応答）の範疇のシステムであり、Wikipediaや文献など大量データや知識を有し（100万冊の本に相当する知識を持つとされる）、幅広い分野の質問に対する回答の確信度を伴って出力する。IBMはこの成果をビジネス（IBMではAIで

なく「コグニティブ・コンピューティング」あるいは「Augmented Intelligence」（拡張知能）と称している）につなげるべく、Watsonのブランド名でツールをセットにしたプラットフォームを提供している。いくつかのツールを挙げると、基礎的なものでは、

- ・ 自然言語分類（文脈、意味も解釈した分類）
- ・ テキストデータの検索及びランク付け（機械学習機能を利用した情報検索精度の向上）
- ・ 性格分析（人のパーソナリティの分類）
- ・ 画像認識
- ・ 音声認識と音声合成

などがある。Jeopardy! に挑戦したWatsonが元になっている経緯から、自然言語テキスト処理や理解関連の機能が目立つ。ディープラーニングツールは当初はユーザ向けに提供されていたが、現在は画像認識、音声認識、自然言語処理関連のツール内で使用される形態となっている。やや応用寄りのツールを挙げると

- ・ Watson Knowledge Studio（テキストの分野ごとのカスタムアノテーション機能を提供）
- ・ Watson for Clinical Trial Matching（患者とガン臨床試験適合性を識別）
- ・ Watson for Oncology（多くの情報（データと専門知識）を得てガン専門医治療の判断を助ける）
- ・ Watson Discovery Advisor（医療や法律などで異質なデータソースを調べて洞察を可能にする。学習機能付き）
- ・ Watson Explore（構造化及び非構造化コンテンツを分析し、傾向、パターン、関係等を見出す）
- ・ Watson Engagement Advisor（顧客と対話して学習して知識を蓄積し、質問を聞き、適切な解決策を提示する）

などがある。健康、医療に力を入れているので、この関連の機能が多くなっている。以上はツールと言えるが、以下の二つは大量データや知識を有する独立してサービスを提供するシステムと言える。

- ・ Watson for Drug Discovery（医療論文データMEDLINEの2000万件程の論文を中心に大量の医療学術論文から抽出した成分と効能の関係などの知識を持ち、創薬やライフサイエンス研究をサポートする）
- ・ Watson Genomic Analytics（遺伝子と薬の効き方の関係などゲノムデータに関する膨大な文献データから抽出した知識を持ち、ゲノム情報を利用した治療法（主にガン）の選択をサポートする）

最後の2システムは、データや知識も含めてシステムとして提供しており、今後のAIビジネスの注目すべき方向である。

AIが価値ある結果を生むには大量のデータや知識が不可欠となり、Google、Amazon、Facebook等では自社サービスを通じて得たビッグデータを活用し、ディープラーニングなどのAIを適用することにより次々と新サービスを生み出している。これに比べると、日本企業は所持する、あるいは活用できるビッグデータの点で弱い。政府や自治体がオンライン情報公開を進めるのは良い傾向で、一層進める必要がある。

民間企業では、購買履歴やクレジットなど個人情報、モバイルデバイスから得られる個人の移動や行動情報を所持する企業もあり、自社内では限定的に利用が図られている。しかし、個人情報保護法によ

るプライバシー保護の観点から、それら個人関連情報を外部企業と共有して利用することは一般には難しい。日本企業のビッグデータ不足を補い、Google、Amazon、Facebookに対抗するような多くのAIシステムやサービスを生み出していくには、ビッグデータ共有の枠組みは取り組まなければならない課題である。情報銀行の構想があるが、一つの可能性として期待したい。

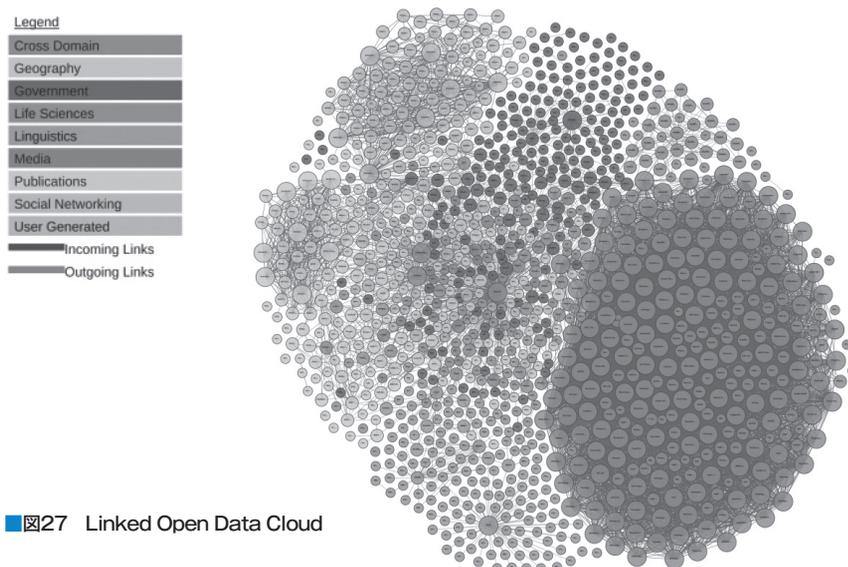
### 1.5.3 Linked Open Dataとオントロジー

ウェブは、我々の情報流通の仕組みを大きく変化させた。このウェブによる情報流通の革命と同じことが今、データの流通に起きつつある。それが「Linked Data」あるいは「Linked Open Data」(LOD)である。これまでのウェブは主に文書的情報を相互にリンクしてネットワークをつくっている。いわば「文書のウェブ」といえる。これに対して、LODは同様のネットワークをデータの間でつくる。このため、LODは「データのウェブ」と呼ばれる。

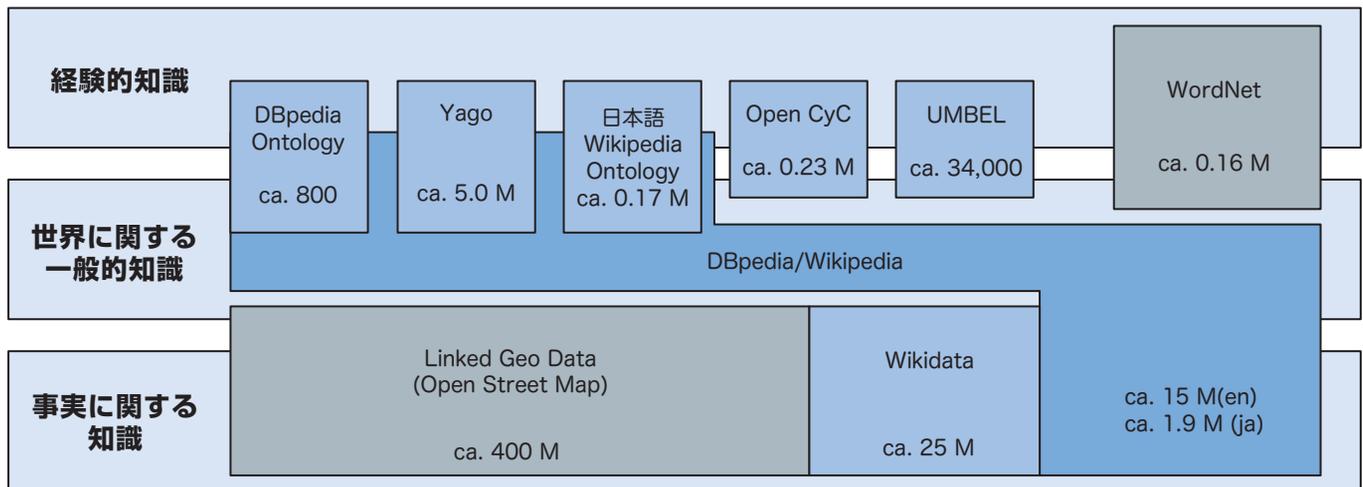
ただし、「文書のウェブ」ではリンクは種類のないものであったのに対して、「データのウェブ」ではデータ間の関係を示すラベルを持つリンクになる。LODはウェブと同じようにグローバルに共有するデータ空間である。すなわち、データが世界のどこのだれが管理しているデータセット(データベース)に含まれているかを意識することなく、アクセスしたり、リンクしたりすることができる。これまでであったデータセットとデータセットの間の障壁は存在しない。個々のデータセットはお互いにリンクし合うことで、一つのグローバルなデータセットの一部となるわけである。

LOD技術とは「セマンティックウェブ」研究でつくられた技術をデータの表現に利用したものである。セマンティックウェブとは、ウェブを作ったティム・バーナーズ・リー(Tim Berners-Lee)氏が提唱した、現行のウェブより高度に知識を記述できるウェブをつくるというビジョンである。そのポイントはウェブのグローバルな情報共有空間はそのままに、その上に標準的なメタデータの記法であるRDF(Resource Description Framework)やそのスキーマを記述する言語(RDFS(RDFS Schema)やOWL(Web Ontology Language))を用意することで、グローバルに知識を共有する仕組みである。

まず、RDFという言語で全てを書く。RDFは「主語」「述語」「目的語」に相当する3語の組み合わせ(三つ組)で全ての情報を書く言語である。このとき、表現したい事物には個別のURI(Uniform Resource Identifier)を与える。ここでは個々の事物にURIを振ることで、URIが世界中でユニークなIDとして使えることが重要である。更にデータを記述する様式が決まっている場合、その様式をスキーマとして別途定義する。RDFを拡張したRDFSという言語では、データ記述の様式をクラスとプロパティの組み合わせで定義する。更にOWLを用いるとクラスやクラスの階層関係などのオントロジーを表現



■ 図27 Linked Open Data Cloud



■図28 知識とオープンなデータセットの関係

することができる。OWLは記述論理（Description Logics）に基づいた知識表現言語であるがRDFを用いて記述される。

現在、上記の原則に基づいたLODが多数公開されている。図27に示すのは、世界中のLODのネットワークで、これを「LOD Cloud」と呼んでいる<sup>2</sup>。2017年2月時点であり、1000以上のデータセットが含まれている。丸が個別のデータセットを示し、データセットとデータセットを結んでいる線は、データセット内のデータ同士にリンクがあることを示している。

LODはこれまでのウェブと同様に、検索サービスを通じてアクセスして使うこともできるし、リンクを順に辿ってみるというブラウジングでアクセスして使うこともできる。しかし、LODの特徴を活かした使い方は、マッシュアップ・アプリケーションを通じての使い方である。

通常のマッシュアップ・アプリケーションでは、複数のウェブサービスのウェブAPI（Application Programming Interface）を利用してアプリケーションを構築する。LODを使ったマッシュアップ・アプリケーションは通常のマッシュアップ・アプリケーションに比べ、より容易に構築できる。LODはデータのアクセスの仕方が統一されているため、ウェブAPIのように個別に対応を変える必要がない。また、記述形式もRDFで統一されているため、アプリケーションのなかでも統一的に扱うことができる。更に、異なるデータセット間でも、リンクがあればそのまま使うことができるため、データ統合の手間を省くことができる。

LOD技術の利用は、データの公開の場面に限定されているわけではない。データモデルをRDFのみとすることで、多種多様なデータを統合的に処理する「ETL」（Extract Transform Load）<sup>3</sup>の仕組みとして使うこともできる。データの収集、洗練、統合、分析、公開、利用といった一連のプロセスを、RDF処理だけで実現できる。その際、データやスキーマはそのまま外部から取り込むことができ、処理結果のほうもそのまま外部へ提供することもできる。また、様々なRDFに関わるツール、ソフトウェアをその間で使うことができる。

これらのデータセットは統一したフォーマット（RDF）で記述され、また一部はデータ間でリンクが貼られている。この中には事実に関するデータからオントロジーといった知識まで含まれている。これらの知識を大まかに図示すると、図28のようになる。

個別の事象、事実に関する汎用的な知識は、Open Street MapのLOD版であるLinked Geo Dataや、

※2  
Andrejs Abele et al, "The Linking Open Data cloud diagram."  
LOD cloud diagram Website <<http://lod-cloud.net/>>

※3  
多様な情報源から必要な情報を抽出し、適切な形式に変換して統合すること。

Wikidataに大量にある。また個別の事象、事実を抽象化した汎用的な知識はDBpediaやWikidataにある。更に知識を構造化したオントロジーがDBpedia Ontology、YAGO (Yet Another Great Ontology)、日本語Wikipedia Ontology[1]、OpenCyc、UMBEL<sup>4</sup>にある。またWordNetもRDF化されている。重要な点はこれらのデータセットが既に結合されているか容易に結合可能であり、一体化した知識として使うことが期待される点である。実際、IBM Watsonの技術であるDeepQAでは知識としては構造的データと非構造的データ両方が用いられているが、構造化データとしてはRDFで記述されたDBpedia、Freebase、YAGOのデータが用いられている。またCognonto (米国) というスタートアップ企業がWikipedia、Wikidata、GeoNames<sup>5</sup>、OpenCyc、DBpedia、UMBELの6個のデータセットを統合したKBpedia<sup>6</sup>という知識ベースを作っている。

このように、LODはデータと知識をシームレスにつなぎ巨大な知識空間を作る仕組みとして機能している。推論や機械学習とこの巨大な知識空間を組み合わせることが知識に基づくAIの新しい在り方となると思われる。

## 1.5.4 統計モデル

人が理解できる情報をデータから引出すためには、何らかの理論的裏付けを持った処理をデータに施す必要がある。これは何もビッグデータに限ったことではなく、100サンプル程度の比較的小規模なデータの解析においても同じである。ただし、データの規模が大きくなると顕現する問題もある。ここでは、古典的な線形モデルを出発点とし、ビッグデータ解析に付随する問題を解決し得る統計モデルを紹介する。

### 1.5.4.1 線形モデル

説明変数を含む項の線形結合で目的変数を記述するモデルで、基本となるモデルは目的変数 ( $y$ ) も説明変数 ( $x$ ) も1次元の場合、すなわち

$$y = b_0 + b_1x$$

である。これは単回帰 (single regression) に等しい。このとき、各項の係数 ( $b_0$ 、 $b_1$ ) をパラメータと呼び、測定したデータから推定する。なお、目的変数が連続値 (連続尺度) の場合は回帰 (regression) だが、離散値 (名義尺度) の場合は分類 (classification) と名称が変わる。

実際にはデータの説明変数が1次元であることは少なく、2次元以上にわたることが多い。この場合、説明変数の次元数 ( $n$ ) に応じて線形結合する項数を増やし

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n$$

とモデルを拡張する。このように、説明変数の次元が2以上の場合を重回帰 (multiple regression) と呼び、各項の係数パラメータを偏回帰係数 (partial regression coefficient) という。

偏回帰係数では目的変数へのある説明変数の影響度を計ることはできない。変数の尺度が変われば、

---

※4  
Umbel Website <<http://umbel.org/>>

※6  
Cognonto Website <<http://cognonto.com/>>

※5  
GeoNames Website <<http://www.geonames.org/>>

偏回帰係数の尺度も変わるからである。目的変数と説明変数をそれぞれ平均0、分散1に標準化した場合の偏回帰係数を標準偏回帰係数 (standardised partial regression coefficient) と呼び、統計モデルのそれぞれの説明変数の影響度を比較することが可能となる。

モデルから得た目的変数の推定値と実際のサンプルの目的変数との誤差を残差 (residual) というが、上記モデルの残差が正規分布に従う場合は一般線形モデル (general linear model) となる。この残差の分布の制限を取り外し、任意の分布と置くと、上記モデルは一般化線形モデル (Generalized Linear Model; GLM) へ拡張される。なお、係数パラメータの推定には、LMでは最小二乗法を用いるが、一般線形モデルやGLMでは最尤推定法を用いる。

#### 1.5.4.2 混合モデル

ここまで紹介してきた統計モデルは、目的変数 ( $y$ ) の中央値 (median) を推定するものである。しかし、データによっては例えば測定誤差が大きく、線形モデルではうまく推定できない、あるいは、推定できても推定値のばらつきが大きくなってモデルの信頼性を担保できない場合がある。そこで、説明変数 ( $x_1 \sim x_n$ ) に新たな概念を導入し、このばらつきをうまく吸収するために考案された統計モデルが混合モデルである。

混合モデルでは、説明変数に固定効果 (fixed effects) と変量効果 (random effects) が混合していると考える。説明変数の固定効果は目的変数の中央値に影響し、説明変数の変量効果は目的変数の分散、すなわちばらつきに影響する。この変量効果は測定誤差に限らず、データを得た場所や時間、個体によって説明変数のばらつきに差がある場合も含まれる。例えば、心血管疾患の罹患 (Cardio Vascular Disease; CVD) を目的変数、健康診断項目の血圧 (Blood Pressure; BP)、体重 (weight; W) と身長 (height; H) を説明変数とそれぞれ置いた重回帰を考える。最も単純な統計モデルは

$$CVD = b_0 + b_1BP + b_2W + b_3H$$

という線形モデルである。ところが、血圧には季節変動があり、冬に高くなることが分かっている。したがって、このデータの説明変数には固定効果 (真の血圧、BP) と変量効果 (季節変動、 $e$ ) が混在しており、混合モデルを採用することが望ましい。

$$CVD = b_0 + b_1BP + b_2W + b_3H + e$$

混合モデルをGLMに当てはめたものが一般化線形混合モデル (Generalized Linear Mixed Model; GLMM) である。変量効果は多くの場合は観測できない潜在変数として現れるので、係数パラメータの最尤推定<sup>7</sup>にはEMアルゴリズム (expectation-maximization algorithm) が利用されることが多い。

#### 1.5.4.3 階層ベイズモデル

GLMMはサンプルの個体差や場所・時間による効果の違いをモデル化できる優れた方法であるが、更に自由に統計モデルを記述したい場合もある。例えば、複数の変量効果をモデルに組み込む場合、あるいは、データの構造が入れ子関係になっている場合などである。具体例を挙げると、ある会社の従業員の健康診断データを解析する際、従業員は事業所や職種で分類されると同時に、更に年齢層や性別で

---

※7

確率分布に含まれるパラメータを、与えられたデータの分布を生み出す確率が最も高くなるように決定する手法。

分類される。このように階層的なデータ構造をモデルに反映し、事業所間での相似や差異、事業所の違いを問わない性差などを検討したい場合である。

階層ベイズモデルは、上記のような複雑なデータ構造を自在に記載し、入れ子関係となっているグループごとに異なる変量効果を設定することができる。また、ベイズモデルは固定効果の係数パラメータの生成も確率過程に従うと仮定し、係数パラメータの分布を推定する。つまり、前式の $b_0 \sim b_3$ はあるパラメータを持った確率分布（例えば平均 $\mu$ と分散 $v$ の正規分布）、すなわち確率変数として推定される。係数パラメータのパラメータをハイパーパラメータと呼ぶ。こうしたパラメータの推定にはマルコフ連鎖モンテカルロ法（Markov Chain Monte Carlo methods; MCMC）を利用することが多い。

#### 1.5.4.4 スパースモデリング

ビッグデータではサンプル数の増大とともに、説明変数の次元数も増大する傾向にある。説明変数の次元数が増えると線形モデルの項数が増え、可能なモデルの個数は直ちに膨大な数になる。多数のモデルから最適なモデルを探索するとき、(1) 多重性、(2) モデル探索の実行可能性の、二つの問題が浮かび上がる。

多重性の問題は、統計モデルに対して検定を繰り返すと、実際には意味のない統計モデルを有意であると誤認してしまう危険性が増すということである。また、膨大な数の統計モデルの全てを試すことは計算時間の爆発的増加を招き、現実的な時間内での実行が困難となる。これが実行可能性の問題である。

これらの問題は、何らかの方法で説明変数の次元数を削減すれば、一定の解決が見込める。説明変数の多くは目的変数の予測に寄与せず、少数の説明変数で組み立てた統計モデルで十分である。そういう寄与しない説明変数の係数パラメータを0と置くことでデータを疎行列化し、データの次元を圧縮する技術がスパースモデリング（sparse modeling）である。コアになる技法はL1正則化と呼ばれ、統計モデルに罰則項を追加して行う推定である。罰則項のハイパーパラメータは正則化の効果を決定し、交差検証（cross validation）で決める。

線形モデルではL1正則化はlasso（least absolute shrinkage and selection operator）と呼ばれ、寄与の低い説明変数の係数パラメータは0となる。いわゆるモデル選択／特徴量選択を行ったこととlassoの使用は同義である。スパースモデリングは特にビッグデータの解析に大きく貢献し、技法が発表されてから20年以上経った現在でも活発に研究が続けられている。

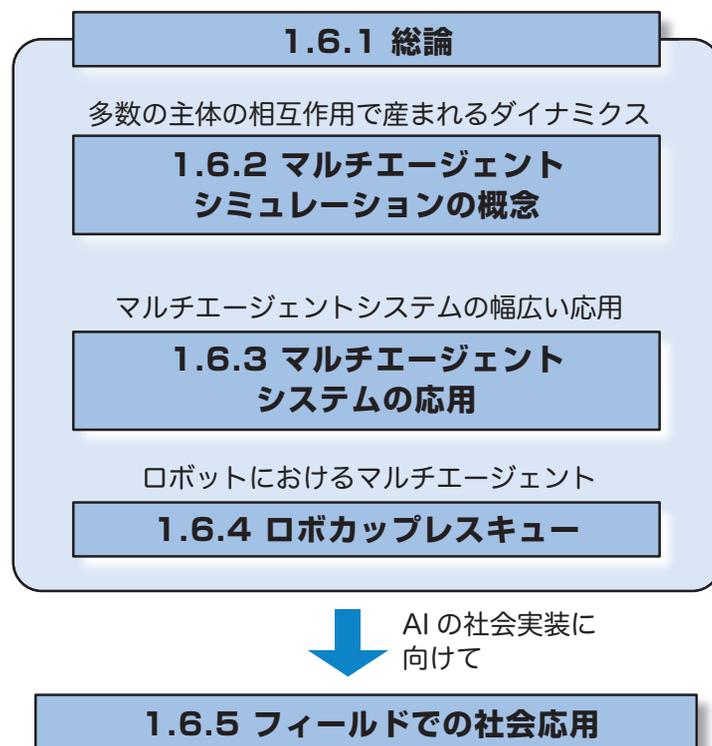
ここで紹介した統計モデルのより詳細な解説や実装は、文献[2][3][4]を参照されたい。

#### 参考文献

- [1] 玉川奨ほか「日本語 Wikipedia からの大規模オントロジー学習」『人工知能学会論文誌』 vol. 25 No. 5, pp.623-636.
- [2] 久保拓弥『データ解析のための統計モデリング入門 一般化線形モデル・階層ベイズモデル・MCMC』岩波書店.
- [3] 岩波データサイエンス刊行委員会『岩波データサイエンス Vol. 1 ベイズ推論とMCMCのフリーソフト』岩波書店.
- [4] 岩波データサイエンス刊行委員会『岩波データサイエンス Vol. 5 スパースモデリングと多変量データ解析』岩波書店.

# 1.6 社会とコミュニティ

## 1.6.1 総論



■図29 本節の構成

本節では人工知能（AI）の社会応用について述べる。実際の応用までを目指した研究においては、AIと他の技術（例えば情報通信技術）などが一体となることが多く、ITの社会応用と呼べる側面が強い。逆に、現在IoT（Internet of Things）やサイバーフィジカルシステム（Cyber Physical System; CPS）の名で呼ばれている分野にも、AI的要素は多い。ここではそれらの中から、特にAI的要素の強いテーマを選んだ。

一般論として技術は基礎研究と応用の間を往復しながら成長する。応用によって基礎技術の不足が判明し、その研究に戻ることもあれば、新しい技術の芽がそれまで不可能だった応用を可能にすることもある。基礎と応用はスパイラル進化をする。

AIに関していえば、一般にAIの夏といわれる時期には基礎研究が盛んになり、その応用がなされる頃には世間的な注目を集めることが少なく、AIの冬といわれる。この理由の一つはAIが応用可能なところまで枯れた技術となる頃には、それはAIとは呼ばれないということに起因する。社会応用がなされる頃には単なる技術であって、AIではないと認識されることが多い。文字認識などが好例であろう。あまり正確に文字認識できない頃にはAIの研究として盛んに新しい手法が試される。しかし郵便番号や宛名の自動読み取りが可能になる頃にはその適用範囲の方に目が向いてしまい、それを可能としている技術自身は語られなくなる。

「マルチエージェントシミュレーション」（Multi-Agent Simulation; MAS）（1.6.2項参照）は実用時にもその技術が認識され得る数少ないものかもしれない。従来は、経済学では人間集団を理想的な行動

を取るものとして理論化してきた。それ以外の分野でも集団を統計的に扱うことしかできなかった。

これに対して、MASでは個々のエージェントの判断を個別にシミュレートできるため、実社会に近いモデルが構築できる。現在のところ、MASは研究ツールとしては経済学に始まる様々な分野でその威力を発揮しているが、主としてシステムの分析あるいはデザイン段階でも用いられることが多く、実用システムに取り入れられた例は少ない。

交通システムや人流シミュレーション（1.6.3項参照）は、実用化されてもシステムの裏でMASが走るという数少ない例かもしれない。前者は公共交通網をITとAI（特にMAS）で管理・運営することにより、現在より飛躍的に効率の良い運行が可能となり、利用者の利便性も増し、自治体の住民サービス向上の一環として住民（特に高齢者）のモビリティ確保の強力な手段となる。

米国では、国防予算の一部がAI研究に投入されている（1.9.2項参照）。これは日本における国費のAI研究投入に比べて1桁から2桁多いと言われている。日本では国防のための研究には反対意見も多い。ならば防災はどうだろうか？ こちらは正義名分があるにもかかわらず、やはり国費投入は限定的である。しかし、研究者の間では防災研究への意欲は大きく、「国際救助隊」設立をスローガンとしてロボカップレスキュー（1.8.3項参照）の枠組みが立ち上がった。

1990年代後半からAIの冬の時代が始まる。その一方でユビキタスコンピューティングや環境知能といった分野が始まり、現在のIoTやCPSへとつながっている。様々な分野名で呼ばれているが、これらは全てコンピュータ上のモデルと実世界を様々なセンサやアクチュエータでつなぐことにより、現実世界での人間活動を支援することを目的としている。この頃に開始されたものに「フィールド情報学」[1]がある（1.6.5項）。様々な現場で情報技術の研究と適用を行う分野である。IT（あるいはAI）をフィールドで活用するときに、最近急激に力をつけているディープラーニングは、環境認識を担う「AIの眼」として大いに期待されているから、この分野は今後違った方向への発展が期待される。様々な社会情報システムから得られる膨大なビッグデータを実時間で解析、学習しながらAIシステムが稼働するようになれば、実用化してもAIの名が残るようになりそうである。

## 1.6.2 マルチエージェントシミュレーションの概念

マルチエージェント社会シミュレーション（Multi-Agent Social Simulation; MASS）は、小さなAIプログラム（エージェントと呼ぶ）を人間とみなし、それが多数集まって相互作用することで生じる現象をもって、人間の社会現象を模倣しようという試みである。人間社会と同じく、個々のエージェントは各々異なる能力や性質、目的を持って独立に意思決定するが、道で出逢えばお互いに避けるなど、互いに影響を受けながら判断するものとされる。シミュレーションの主眼は社会の模倣にあるため、エージェントは非常に賢いものである必要はなく、社会現象を再現する程度に知的であればよい。

シミュレーションの対象となる社会現象としては、人流、物流、交通、情報流通、金融、経済活動など多岐にわたる。またエージェントも、人そのものの場合から、アルゴリズムトレードにおけるプログラムなどの人の代わりとして行動するもの、更には会社組織なども仮想的な「人」エージェントとして扱う場合もある。

MASS技術の出口は、制度設計あるいはサービス設計の支援、なかでも、新規の制度やサービスがシステム全体に与える影響を分析することである。この分析についても、個々の状況における個別の評価よりは、多様な状況下でのシステム全体のマクロな状態について、その挙動の分類や不具合状態に陥る条件の洗い出しが重要なテーマとなる。

例えば、人流シミュレーションを使った避難誘導方法の評価を考えると、ある特定条件における、ある手順での避難の効率を評価したり、あるいはその条件での最適な避難方法を調べたりすることは、原

理的には可能である。しかし、災害という、そもそも状況を詳細に予見することが困難な対象を相手にしていることを考えると、ある特定条件のみにこだわるのではなく、幅広い様々な状況について、安定して機能する誘導方法を見つけ出すこと、あるいは、懸案となっている誘導方法が機能しなくなる条件はどういう場合かを調べることが、一つの大きな応用方法となる。

MASSで問題となるのは、シミュレーションとしてのモデルの精度と結果の信頼度（Validation and Verification）である。エージェントは人の振る舞いをモデル化・模倣するものであるが、人の振る舞いについてはまだ確実なモデルといえるものはほとんどなく、物理法則のように第一原理で全てを精度よく予見できる段階にはない。また、人間は、自分の行動の結果が自分にとって不都合であることを知れば行動を変えてしまうかもしれない、という自律性がある。つまり、シミュレーションを行うこと自体が系に影響を与えてしまうというジレンマを包含しているのが、社会シミュレーションの特徴である。このため、社会シミュレーションを台風の進路を推定するのと同じようなもの、と考えることは現状では危険である。

一方で、シミュレーションの結果をマクロにとらえ、系全体としての性質を分析するツールとみなすことで、MASは非常に有用なツールとなり得る。例えば自動車交通の中でどのような条件で渋滞が生じ、どのように解消していくのか、というマクロな視点で分析すれば、どの条件が渋滞の鍵となっており、どのような方法で軽減するかの方策などについて議論することができる。

これを可能にするためには、多数の異なる条件で対象の系がどのように振る舞うかを網羅的にシミュレーションし、その結果を解析していく方法が大事になってくる。2009年の横断型基幹科学技術研究団体連合の分野横断型科学技術アカデミック・ロードマップ報告書（第4章）<sup>1</sup>でも述べられているように、今後のMASS研究では、複雑系としての分岐理論の確立に向けた取組を進めていく必要がある（図30）。このためには、応用分野や現象を広げていくほか、モデルの精密化につながるセンシングデータとの関連付け、データ同化手法、及び網羅的シミュレーションの知能化・効率化に関する研究及び環境作りが重要となってくる。

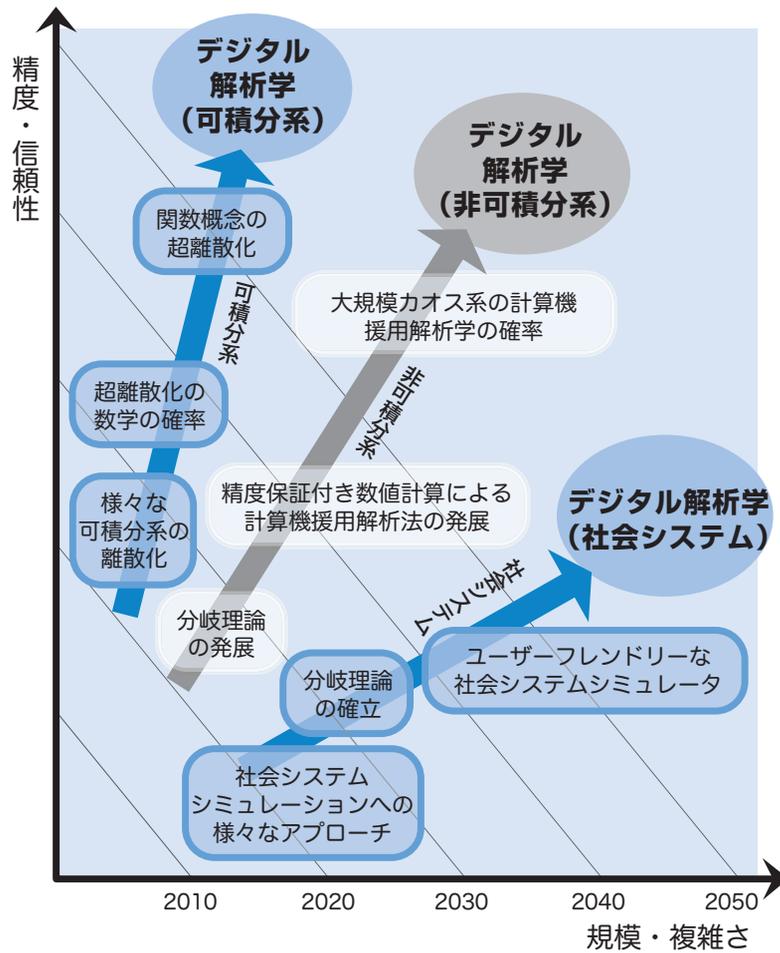
MASの応用分野は幅広いが、特に相性の良い分野の一つとして、経済システムのモデル化がある。なぜなら、現実の経済現象は、様々な思惑を持った個人の行動が互いに影響を及ぼしながら集積した結果現れた現象だからである。まさに、MASが解明しようとしている創発的現象の主な例である。また、経済現象では、各個人の行動基準が比較的明確である。金融市場ならば取引によって利益を出すことであり、購買行動ならば自分にとって価値の高いものをできるだけコストをかけずに購入することである。そのため、エージェントの行動ルールも素直に設計しやすい。

更に、近年の情報通信技術の発達のおかげで、より広範囲で迅速に、詳細で時間分解能力の高い社会経済データが収集できるようになってきた。大量かつ大規模な実データを用いて、経済現象の背後にある個人行動の分析を行い、その結果をエージェントの行動ルールに反映させることによって、エージェントの行動をより現実的にすることができる。

MASの経済への応用は、金融市場、マーケティング、オークション、計算組織理論、製品や技術の普及、電力市場、環境経済など、多くの分野にわたっている。各分野において、実際の経済現象のメカニズムの解明や従来の経済理論の検証、そして現実の経済現象でのルールの設計などに用いられている。

---

※1  
横断型基幹科学技術研究団体連合「分野横断型科学技術アカデミック・ロードマップ報告書」経済産業省ウェブサイト  
<[http://www.meti.go.jp/policy/economy/gijutsu\\_kakushin/kenkyu\\_kaihatu/20fy-pj/oudan2.pdf](http://www.meti.go.jp/policy/economy/gijutsu_kakushin/kenkyu_kaihatu/20fy-pj/oudan2.pdf)>



■図30 複雑系シミュレーション技術のロードマップイメージ<sup>2</sup>

### 1.6.3 マルチエージェントシステムの応用

#### 1.6.3.1 新しい交通システム

MASの社会応用の一つとして、より効率的な都市公共交通のデザインがある。移動の要求を出すユーザやユーザを輸送する車両などをエージェントとして実現。現実の市街地の地理情報の上で、公共交通の時刻表、移動需要の発生、天候などに関する情報を加味することで、現況再現性の高いシミュレーションが可能となってきた。市街地の地理情報に関する標準フォーマットOSM (OpenStreetMap)、オープンでフリーのエージェントベースの交通シミュレータSUMO (Simulation of Urban MObility)<sup>3</sup>、MATSim (Multi-Agent Transport Simulation)<sup>4</sup>などが普及している。

近年、ユーザに移動というサービスを提供する「MaaS」(Mobility as a Service) と呼ばれる概念が提唱されている。移動させることをサービス提供の一種とみなすことで、何かほかのサービスとの共創やハードウェア、ソフトウェアとのパッケージ化を促すことができる。MaaSの導入を進めているフィンランドのヘルシンキでは、タクシー、バス、鉄道、飛行機などの輸送機関が互いに協力、情報交換す

※2  
横断型基幹科学技術研究団体連合「分野横断型科学技術アカデミック・ロードマップ報告書」経済産業省ウェブサイト  
<[http://www.meti.go.jp/policy/economy/gjutsu\\_kakushin/kenkyu\\_kaihatu/20fy-pj/oudan2.pdf](http://www.meti.go.jp/policy/economy/gjutsu_kakushin/kenkyu_kaihatu/20fy-pj/oudan2.pdf)>

※3  
“SUMO - Simulation of Urban MObility” DLR - Institute of Transportation Systems Website <[http://www.dlr.de/ts/en/desktopdefault.aspx/tabid-9883/16931\\_read-41000/](http://www.dlr.de/ts/en/desktopdefault.aspx/tabid-9883/16931_read-41000/)>

※4  
MATSim Website <<http://www.matsim.org/>>

るための情報システムと仕組み作りを行っている。MaaSを社会実装できれば、ユーザは、そのような移動サービスを単一のインターフェースで利用できるようになる。

MaaSの概念を押し進めると、移動サービスのクラウド化という概念に至る[2]。タクシー、バスなどではサービスとそれを提供するハードウェアが分かちがたく結び付いているが、それらを分離して需要に応じて再結合させることができれば、必要な時に必要なだけの移動サービスを生み出すことができる。一般に、クラウドという概念が、CPUや記憶装置を仮想化してネットワーク経由で計算や保存というサービスとして利用できるようにしたシステムを意味するように、移動サービスのクラウド化は、タクシーやバスといった移動手段を仮想化し、需要に応じて同じハードウェアで異なる移動サービスを提供するシステムを意味する。

「Uber」や「Lyft」、「コンビニクル」[3]などが新しい交通システムとして話題に上ることが多い。これらは、移動の要求を持っているユーザがタクシーを呼んだり、自分で選択した公共交通機関を利用したりする行為において、従来のワークフローのデジタル化に留まっている。移動サービスのクラウド化、全体最適という共創のレベルまでは至らず、デジタル化の恩恵は限定的である。

移動サービスのクラウド化は、より効率的な都市公共交通システムを実現する可能性があるが、そのためには、全体最適な車両の運行管理、ユーザからの需要の処理、需要予測に基づく最適化などを解決せねばならない。これらの課題解決には、システム設計→MAS→結果分析→システム改良・設計→…のサイクルが欠かせない。また、現在タクシー会社の熟練オペレータが担当している配車、アクシデント発生時のバス運行緊急対応、個々のタクシー運転手の勤に任されている流し待機エリアなどは、機械学習が得意とする対象でもある。

そういった、乗客のデマンド（呼び出し予約）に応じて、乗降時刻あるいは乗降場所を柔軟に調整しながら走行する公共交通の形態を「デマンド交通」と呼ぶ。バスだけでなく相乗り方式のタクシーや、両者を混在させたデマンド交通の活用例も増えている。デマンド交通は、自由度に応じて大きく以下のような運行方式にカテゴリ分けすることができる[4]。

- ① 迂回路方式：路線バスとして基幹ルートを実行しながら、事前のデマンド受付により迂回ルートを適宜経由、定められた停留所で乗降する方式。
- ② フレックスルート方式：あらかじめ停留所は定めておくが、停留所候補をつなぐルートはデマンドに応じて決める方式。
- ③ ドアトゥドア方式：停留所や路線を定めずに、乗客が指定した任意の乗降場所を実行する方式。
- ④ フルデマンド方式：ドアトゥドア、ダイヤフリー、リアルタイム予約（運行中車両へのデマンドも可能）のデマンド運行が可能。すなわち「いつでも、どこでも、すぐに」を実現する方式。

従来は、自宅や目的地で乗降できる自由度の高さから、③をフルデマンドと呼ぶ場合もあった。だが、現実には「毎時運行」などのダイヤ固定や、「1時間前までの予約」など運行上の制約条件が多く、また運行ルートをオペレータや運転手が経験知で決定していることも多いので、ここではドアトゥドアと呼んだ。更に上記③と④については、予約システムと配車システムがコンピュータで自動制御されているかどうかの違いもある。現状では多くが人力に依存しているために、明確な分類定義がないが、これについても定義しておく。

- (i) 予約・配車いずれのシステム導入もなし
- (ii) 予約支援システムを導入
- (iii) 配車運行自動制御システムを導入

(iv) フル自動制御（予約＋配車運行）システム

運行方式とは別の軸として、運行目的・運行区域による区分も考えられる。

(a) 特定運行型 (Special Transport Services; STS)

過疎地域や高齢化地域、交通空白地域等の、特定区域・特定目的の運行を目的とするもの。

(b) 広範運行型 (General Transport Services; GTS)

中心地域や特定地域という区分を超えてより広範なエリア、広範な目的に対してデマンド交通を導入しようとするもの。

特定運行型は欧米など海外でも使われている定義だが、広範運行型はここで新しく導入した定義である。従来のデマンド交通はほとんどが特定運行型であり、そもそも「広範に運行する」という考え方が存在しなかった。両者の違いは運行エリアの大小ではなく、むしろ都市交通全体の中での位置付けが末端的なのか (a)、中枢的なのか (b) ととらえるほうが適切であろう。

次に国内外の主なデマンド交通の先進事例を取り上げ、実用化の状況を概観する。

まず公共交通へのデマンド交通の導入で、最も成功しているといわれるスウェーデンでは、政府が全土で高齢者・障害者向けの乗合タクシーをコミュニティ単位で運行してきた。ストックホルムやヨーテボリなどの中核都市では、これをフレックスルート方式のデマンドバスへ発展させ、運行地域を急拡大させてきた。

2007年時点でストックホルムでは人口185万人に対して年間利用回数450万回、ヨーテボリでは人口56万人に対して170万回といずれも高利用率だが、位置付けはあくまで中心市街地に対する末端部、誰でも利用可能だが主には高齢者居住者が多い地域での運行である。ヨーテボリの「flexlinjen」(flex line) は、2005年の8路線から2010年には20路線にまで拡大している。予約受付は電話で、オペレータがデマンドのあった停留所をインプットし、運行ルートを運転手に知らせるシステムである。降りる場所はデマンドではなく中心市街地への結節点となる停留所が想定されている。

フィンランドの首都ヘルシンキでは、市街地中心部でフレックスルート方式のデマンドバス「Kut suplus」の導入が試験的に始まっている。ユーザの現在地と目的地に最も近い停留所とマップの提示、バス乗継を含めた複数ルートの提案、ルートや所要時間に応じた価格設定などが、携帯端末から利用可能になっている。フルデマンド方式ではないが、都市中枢部のコミュニティバスをフル自動制御でスマート化することが目指されている。

米国では、シリコンバレーの「RidePal」、ボストンの「Bridj」などが、乗合のデマンドバスサービスに進出しているほか、日本でもタクシー呼出システムの進出が話題となっているUberが、マイカー相乗りサービスも展開している。米国で民間主導のサービスが見られるのは、欧州と異なり政府主導の公共交通の役割が限定されていることが背景にある。そのため、公共の基幹交通と、民間主導のデマンドサービスとの統合が遅れていることが課題といえる。

日本においてもデマンド交通の導入は全国各地で進んでいる[5]。国土交通省の地域交通ネットワーク政策<sup>5</sup>において、基幹ルートは定時路線運行で、結節点から枝分かれする末端部分をデマンド交通とするモデルが描かれているように、実用化事例のほとんどが特定運行型で、迂回路又はフレックスルート方式のコミュニティバスが多勢を占めるが、ドアトゥドア方式やフルデマンド方式のミニバスや乗合

---

※5

「地域公共交通活性化事例集」国土交通省 地域公共交通支援センターウェブサイト <<http://koutsu-shien-center.jp/jirei/>>

タクシーの運行も増えてきている。

国内の数少ない事例の一つとして、ドアトゥドア方式でかつ広範運行型を志向しているのが、北海道ニセコ町「にこっとBUS」、岩手県一戸市「いちのへ いくべ号」、岡山県総社市「雪舟くん」[6]である(表3)。ニセコ町と総社市は、路線バスの存続が厳しくなり、市町全域をデマンド交通でカバーする広範運行に移行した例である。一戸市の場合は既存の路線バスとの共存がなされている。

■表3 国内のデマンド交通：ドアトゥドア方式×広範運行型の事例

| 名称                          | 運行地域            | 運送法上の分類 | 経営主体             | 運行事業者                      | スケジュール                        | 予約方法                        | 料金(おとな)          | 車両                 |
|-----------------------------|-----------------|---------|------------------|----------------------------|-------------------------------|-----------------------------|------------------|--------------------|
| ニセコ町<br>デマンドバス<br>「にこっとBUS」 | 北海道ニセコ町<br>ほぼ全域 | 区域運行    | ニセコ町             | ニセコバス                      | ダイヤなし<br>(午前8時～午後<br>7時/毎日運行) | 一週間前から概<br>ね45分前まで<br>に電話予約 | 1乗車200円          | 10人乗り2台            |
| 「いちのへ<br>いくべ号」              | 岩手県一戸市<br>全域    | 乗合タクシー  | LLP一戸市<br>デマンド交通 | バス1社、<br>タクシー3社<br>(左記出資元) | ダイヤなし<br>(平日7:30～<br>16:30)   | 2日前～1時間<br>前までに予約           | 区域制:<br>300～700円 | ジャンボなど4台           |
| 「雪舟くん」                      | 岡山県総社市<br>全域    | 区域運行    | 総社市              | バス2社、<br>タクシー5社            | 平日8時台～<br>16時台まで<br>往復計16便    | 1時間程度前<br>までに予約             | 1乗車<br>300円      | 10人乗り4台、<br>8人乗り5台 |

ニセコ町では、365日ダイヤなしでドアトゥドアのデマンドに対応するが、要事前予約、運行台数2台と、広範運行とはいえ小規模な運用である。しかしながら、配車運行システムを導入して、どの利用者にも大きな不便を与えることのない経路をシステムで選定し運行している。

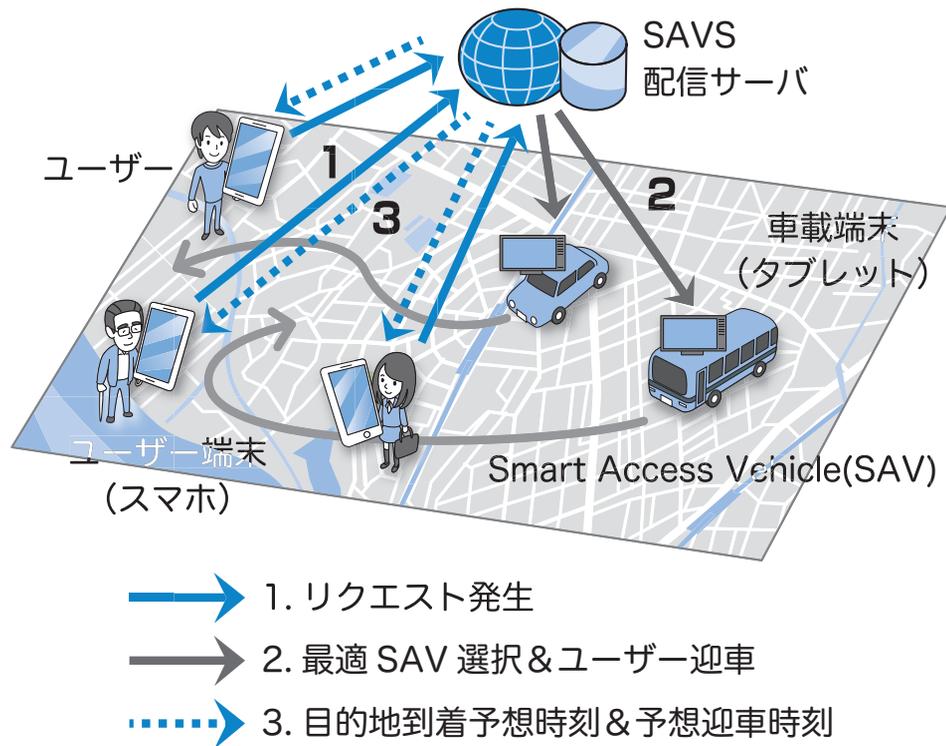
総社市の場合、乗降場所は自由に指定できるものの、出発地域(周辺部)から到着地域(中心市街地)への方向性を持ち、毎時1本運行と本数も決まっているため、実態はフレックスルートのドアトゥドア版という形式になっている。また、土日運行はなく、平日の高齢者用途を主目的としているため、特定運行の拡張版ともいえる。予約も配車運行もオペレータの手作業と経験知で行われている。

一戸市も、平日運行ながらダイヤなしでドアトゥドアのデマンドに対応しているが、要事前予約で台数も4台と少ない。広範運行ではあるものの、町内のほとんどを占める中山間地域から中心部へのアクセス改善を目的として、既存の路線バスを補完する運用となっている。

現在開発が進められているSAV(Smart Access Vehicle) Systemは、④フルデマンド×(b)広範運行型×(iv)フル自動制御を兼ね備えた「デマンド応答型公共交通」(Demand Responsive Transport)の一種であり、固定経路を持たずユーザの呼び出しに応じて即時に配車される[7]。このとき、先に乗車している、しようとしている乗客が乗合いを許容し、その乗客の目的地到着希望時刻が守れるのであれば、乗合いが発生する。つまり、従来のタクシーとバス両方のサービスを兼ね備えたような交通システムである。

ユーザがSAVを呼び出す時の動作を図31に示す。まずステップ(1)にて、ユーザはスマートフォン上のアプリケーションを通じて、SAVS配車サーバにリクエストを上げる。このとき、移動サービスのクラウド化による全体最適化を実現するため、ユーザは事前に移動サービスに関する全ての条件をサーバに通知しなければならない。ユーザのリクエストに対し、配車サーバが最適なSAVを選択し、ステップ(2)にて当該SAVにユーザをピックアップする指令を送る。SAV運転手は、SAVに積んだ車載端末(タブレット)上のアプリケーションでその指令を受信し、ユーザを迎えに移動する。同時に、配車サーバはユーザに対し、目的地到着の予想時刻、迎えに行くSAVの現在位置を通知する。

SAVSには次の三つの特徴がある。一つめは、ユーザからのリクエスト応答処理に、予約ベースでなく即時実行ベースを採用したことである。これにより、SAVSは、例えばバスのような固定路線、固定ダイヤの運行形態をエミュレートできる。つまり、多数のユーザが毎回同時刻に同じ場所間を移動するデマンドを発生し、それをSAVSが即時に処理すると考えれば、バスと等価な運行形態が実現される。同様に、従来タクシーをエミュレートすることも、デマンドバスをエミュレートすることもできる。



■図31 SAVSの呼び出し・配車の基本動作

二つ目は、過疎地域ではなく、少なくとも中規模都市より大きいエリアとユーザ数を想定していることである。シミュレーション結果より、ある規模を超えると現状のタクシーやバスによる乗客輸送システムの効率を上回る領域があることが明らかになっている。ユーザは移動サービスに関する条件を全て事前にSAVSに通知し、計算機がそれを考慮して完全自動で最適な配車を決定するので、原理的にSAVSを展開するサイズが大きくなればなるほど全体最適化の余地が増える。

三つ目は、乗客輸送を制御するパラメータ、例えば移動経路、出発時刻、乗合の可否などを動的かつ連続値として設定できることである。これにより、ユーザの要望、その場の状況や制約に応じて、柔軟かつきめ細かいサービスレベルを実現することができる。一般の交通システムに同じくSAVSでもコストと利便性の間にはトレードオフがあるが、SAV車両ごとに乗客ごとに輸送に関するパラメータを動的に変更してサービスレベルを調整して、そのトレードオフに対処する。また、そのパラメータ変更を受けて全体最適化の制御を変更することになる。

SAVSの本格的な研究開発は2012年から始まり、2017年まで函館市や東京お台場にて実証実験を4回実施した。最大規模で同時に30台のSAV、200人超の乗客からの乗車リクエストを完全自動で遅滞なく処理し、移動サービスを提供することに成功している。

### 1.6.3.2 人流シミュレーション

人流シミュレーションは、群衆が町中や施設の中を歩きまわる状況を再現しようとするものであり、MASSでは特に、群衆を構成する人の多様性や個々人の経験の評価に着目してシミュレーションするものである。人の多様性としては、その場所に関する知識や認識（土地鑑）、歩く速さや分岐点で経路を選ぶ際に重視する要素（目的地までの距離・混雑度・道の雰囲気など）、あるいは出発地・目的地や経由地の違い等が考えられる。経験としては、旅行時間のほか、混雑に巻き込まれていた時間や、目的地・経由地への到着時間などがある。例えば人流シミュレーションの一つ、避難シミュレーションでは、最終的な避難場所やそこへの経路情報、あるいは周辺のエージェントの挙動や混雑度などが情報として

与えられる。これらにより進行する方向を決め、近傍の障害物や他エージェントとの相対距離により実際の歩行速度を求め、移動する。

また、音声や情報機器による情報提供を、行動決定のための情報として与える場合もある。多くの場合、各エージェントは独立して行動するよう設定されるが、シミュレーションによっては、家族などを単位とした集団で行動したり、他のエージェントに追従したりして動くといった性格付けを行う場合もある。

人流で、エージェントが移動する空間については、連続的な2次元平面、平面をグリッド上など小領域に分けたセル空間、廊下や道路を中心とした点と線のネットワークとして扱うモデル、更には、そのネットワーク上の各交差点における待ち行列のみに着目したモデル、という抽象化レベルがあり得る。前者ほどエージェントの細かい挙動を記述でき、スクランブル交差点や広場のある空間での避難現象を正確に扱うことができるが、多くのパラメータ設定と計算量が必要となる。一方、後者は大規模な避難のような移動を比較的簡便に扱うことができるが、人々が入り乱れて移動するような現象を正確には扱えないという問題がある。このため、対象とする避難の規模や求められるシミュレーション速度に応じて、適切な抽象化を選ぶ必要がある。

シミュレーションによる人流解析は、災害時の避難など、まれな状況や新規の状況での人流の分析に強みがある。近年ではモバイル空間統計など、人流に関係するビッグデータの利用が容易になりつつある。これらのビッグデータは平常時に頻繁に繰り返される現象を分析・モデル化する上では有用であるが、災害など滅多に起きない状況や、新しい設備や道路の導入など新規の状況においてはビッグデータそのものでは対処できない。また、災害状況などをリアルに再現した実証実験などは危険性の面から難しいため、実データを実験で揃えることも困難である。

一方、シミュレーションでは、その状況を自由に設定できるため、新規の状況やまれな状況設定に容易に対応できる。更に、そのような分析は災害対策立案やイベントでの全体管理設計において、当事者に全体的な把握を促し、判断する際などにおける有用な情報を提供できる可能性が高い。

AIの研究から見た場合の人流シミュレーションの焦点は、エージェントの行動、特に目標地点や経路の選択である。単純な人流シミュレーションでは、各エージェントが目的地（避難場所など）やそこに至る最短経路を既知とし、エージェントは寄り道せず目的地に向かう。しかし実際の人の挙動は、目的地を特に持たなかったり、経路が分からなかったりする場合があります。経路選択において揺らぎ・混乱が生じる。また、混雑状況や誘導アナウンスなど、ほかから得られる情報を元に行動をするケースも考えられる。人流シミュレーションでは、各エージェントにそのための知的な判断ルーチンを個別にもたせることができるため、混乱の波及や情報提供の効果などを詳細に分析することが可能となる。

### 1.6.3.3 金融分野への応用

「人工市場」とは、金融市場のエージェントモデルである。1990年代後半に、複雑系研究で有名な米国のサンタフェ研究所が、人工市場に学習と創発という観点を初めて導入し、バブルの発生や予測ルールの複雑化を分析した。2000年代に入り、人工市場は、より詳細で現実的になった。国内の人工市場研究プロジェクトの一つである「U-Martプロジェクト」は、多様な取引プログラムが市場サーバに接続する人工市場である。これにより、手数料率や値幅制限などの市場制度のテストを行った。「AGE-DASI TOF」<sup>6</sup>は、現実の経済記事を基にしたデータを人工市場に入力し、現実のある時期のバブル発生・崩壊のメカニズムを解明したり、市場介入政策の決定を支援したりするシステムを構築した。

---

※6

多数の仮想的なディーラーが参加する外国為替市場を模擬した人工市場。A Genetic-algorithmic Double Auction Simulation in Tokyo Foreign exchange market.

金融市場における制度設計や投資手法の変化は、その市場の安定性に大きな影響を与えるが、新たな制度の導入による市場インパクトを事前に知ることは困難である。そこで、人工市場を構築し、制度の効果検証を行う取組が行われている。応用事例は、次の3とおりである。

- (a) 板寄せ（バッチオークション）やザラ場（連続ダブルオークション）などの異なる価格決定方式（市場に出された注文をマッチングし価格を決定する方式）を採用した人工市場により、それぞれの市場効率性や価格変動の性質を比較したもの。
- (b) 空売り制限やサーキットブレーカー、取引税などの市場安定化のための様々な規制の効果を人工市場で検証したもの。
- (c) NASDAQや東京証券取引所に人工市場を適用して、新しい制度（価格変動幅の最小単位の切り下げ）の投資家へのインパクトを検証したもの。

#### 1.6.3.4 マーケティング分野への応用

近年の情報通信技術の発展により、マスメディア、ソーシャルメディア、口コミなど、様々な情報源から膨大な情報を消費者が参照できるようになった。それに伴って、各消費者の選択ルールや消費者間の相互作用がより複雑で多様になり、既存の消費者行動モデルでは説明できない現象が現れている。

そこで、消費者の購買行動とコミュニケーション行動をモデル化したMASにより、消費者行動のミクロな変化と商品売上などのマクロな動態との関係を分析する応用事例が数多く発表された。例えば、市場の動きがエージェントの意思決定過程と製品特性、及び社会ネットワーク構造（社会ネットワーク中のハブのサイズ）の三つの要素間の相互作用に依存することを示した研究がある。他の研究では、消費者の情報チャネルの増加により、各消費者の選択が特定の財に集中する傾向を強める可能性があることが示された。このように、消費者間の新たな相互作用がマーケットに与える影響が、エージェントシミュレーションにより様々な視点から明らかにされている。

消費者側からの視点だけでなく、生産・流通側からの視点によるエージェントシミュレーションの応用事例も数多くある。特に、近年の消費者行動の多様化により、より詳細で高度な生産・在庫管理の手法が提案されている。これらの新たな生産・在庫管理システムを実装したシミュレーションが、複数の市場環境の下でのシステムの有効性（利益、コスト、機会損失）を評価することに使用されている。

#### 1.6.3.5 電力・エネルギー経済分野への応用

近年の世界的な動きとして、電力を含むエネルギー経済分野において様々な規制を緩和し、市場競争の導入による効率化を目指すという自由化の流れが進んでいる。更に、大規模災害の発生により電力網の安定性に大きな関心が集まり、スマートグリッドや分散電源などの、従来よりも柔軟で複雑な新しい電力供給システムが着目されている。

この分野でのMASの主な応用事例は、電力卸売市場と送配電システムに関する新制度を、安定性と効率性の両方の観点から評価するものである。電力市場に関しては、国内外の多くの研究でエージェントシミュレーションが使われ、既に米国ではエージェントベースの大規模な電力市場が構築され、電力市場制度の研究で利用されている。

送配電システムについても、実際の電力需要データや発電データを用いて電力消費エージェントの挙動を決定しスマートグリッドシステムの効率性を評価した研究や、分散した小規模な電力市場により電力価格と配電ネットワークを創発的に構築する新たな電力流通システムの有効性を分析している研究などがある。

### 1.6.3.6 製品や技術の普及過程分析への応用

既存のものとは大きく異なる革新的な製品や技術が、どのような過程で世の中に広まっていくのか、また時には普及せず終わってしまうのかは、経済分野での大きな関心の一つである。イノベーションの普及は、消費者間の相互作用というマーケティングの要素、企業間の競争関係という組織戦略の要素など、複数の要素が関係する創発的現象である。そのため、消費者や企業を対象としたエージェントモデルを利用して、イノベーション普及過程の解明を目指す研究が増加している。

例えば、規模の小さな初期市場から主要市場に発展するまでの溝（ギャップ）の分析、消費者間の複雑ネットワーク構造が与える競合サービス普及への影響分析、企業間競争と社会ネットワークの相互作用の観点からの技術普及の分析などがある。

### 1.6.3.7 環境経済への応用

社会における環境意識の高まりとともに、資源を効率的に利用する循環型社会のための新制度を設計する必要性が高まっている。この分野でのエージェントシミュレーションの応用は、家電リサイクル法など生産者及び消費者にリサイクルや回収に関する何らかの義務を課す制度の有効性を評価するものや、環境に配慮した製品の市場への普及過程を分析したものなど、制度の社会的評価や消費者行動の分析を対象にしたものである。

### 1.6.3.8 マルチエージェントシミュレーションの経済への応用の新しい方向性

エージェントベースの経済シミュレーションのベースとなる個人の行動データの収集については、観察技術の発達によって、より詳細で精緻なデータが、日常の社会的場面でリアルタイムに取得できるようになってきた。今後は、前述の経済現象に関する表面的な行動データだけではなく、脳科学（brain science）の発達により、経済行動の背後にある個人の認知機構や思考過程、行動決定ルールに関する詳細な分析技術の発達も期待される。

特に、2000年代半ばから機能的MRI（fMRI）を始めとする新しい脳観測技術を、経済的選択時の脳活動の分析に用いる神経経済学（ニューロエコノミクス）の発達が目覚ましい。それと同時に、マクロな経済状態についても、より広範囲で高頻度な観測データがリアルタイムに利用可能となった。これらのデータを基にして、複合的な経済シミュレーションモデルをリアルタイムに構築・更新することが可能となり、様々な現実の経済現象の中で、エージェントシミュレーションが現実世界に浸透していく方向に進むと考えられる。

## 1.6.4 ロボカップレスキュー

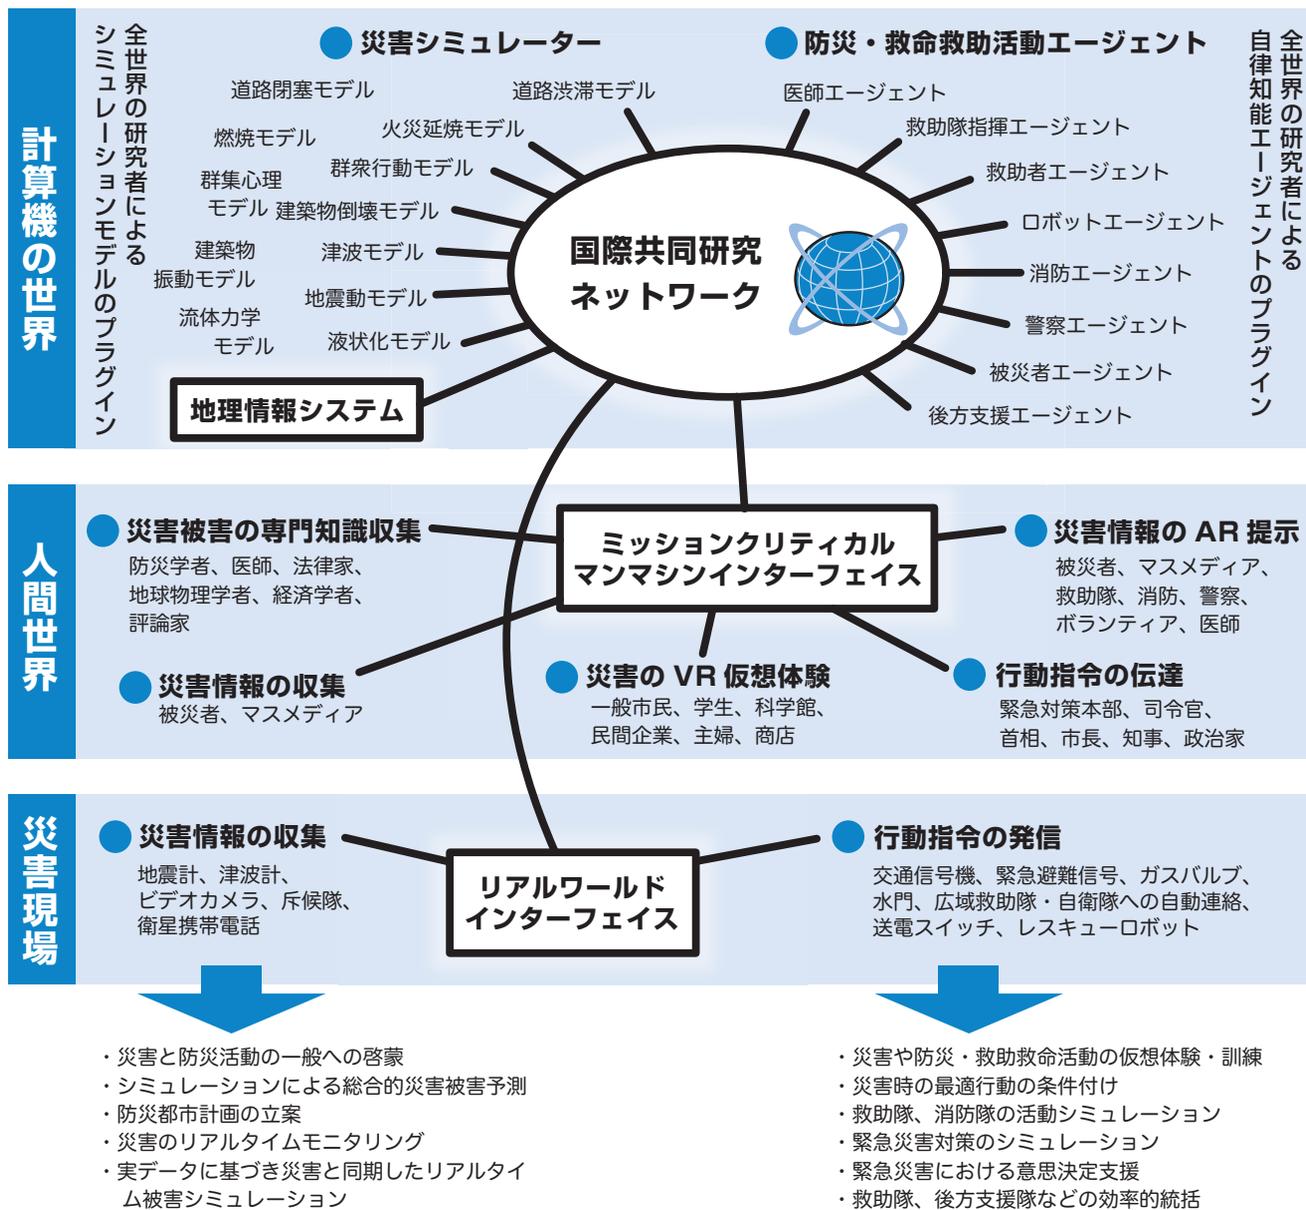
### 1.6.4.1 ロボカップレスキュー構想

ロボカップ（RoboCup、1.8.3項参照）の中に災害救助部門を作ることを目的として、1998年に共同研究コミュニティが立ち上がり、AIやロボットを活用した未来の防災システムの在り方についての議論が行われた。その成果は「ロボカップレスキュー」（RoboCup Rescue）構想として図32のようにまとめられ[8][9]、その一部を競技会として開催すべく、ロボカップレスキューが開始された<sup>7</sup>。

災害事象の分散シミュレータによって作られるサイバー災害空間の中で、災害緊急対応活動を行うエージェントが活動することによって、自然現象と社会現象を合わせた総合的な災害シミュレーション

※7

RoboCup Website <<http://www.robocup.org/>>



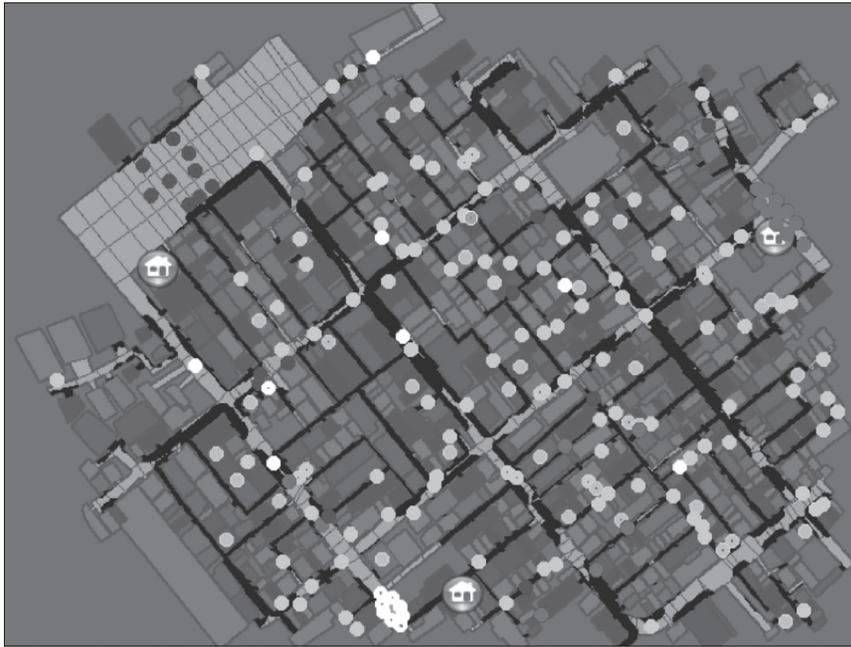
■図32 ロボカップレスキュー構想

を行う。サイバー空間はリアルワールドインターフェースを通じて社会に配備された災害状況センシングシステムからの情報をリアルタイムに収集し、シミュレータの状態量に反映させることによって、仮想空間と現実空間の同期を可能にする。

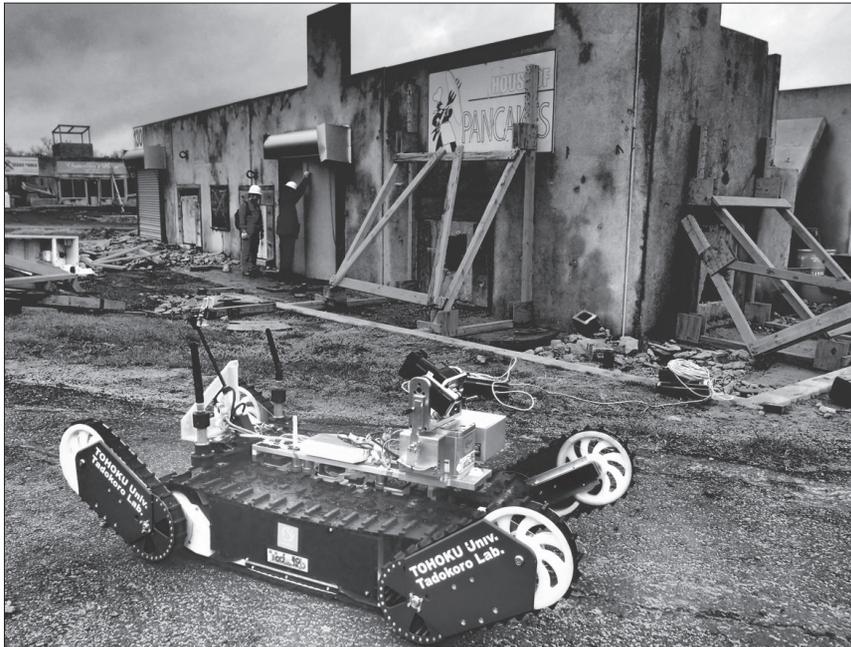
また、行動指令を発信することによって、各種インフラやロボットなどがリアルタイムに能動的な情報収集や災害被害を抑えるための活動を行う。更にミッションクリティカルマンマシンインターフェースによって、災害対応本部の意思決定を支援する。それによって、災害被害軽減のための最適活動を合理的かつ実時間で行うことが可能になる。

#### 1.6.4.2 ロボカップレスキューシミュレーションリーグ

ロボカップレスキューシミュレーションリーグは、阪神淡路大震災における神戸市長田区の被災状況をモデルとし、市街地規模での救助活動を競うシミュレーション競技会であり、ロボカップレスキュー構想に従って2001年に開始された。設定可能なシナリオ（地図及び災害の発生状況）に基づいて被災状況を再現し、消防隊、救急隊、土木工事隊及び各司令所からなる多数の自律型エージェントプログラ



■図33 ロボカップレスキューシミュレーション



■図34 Quince

ムによって災害救助活動を行い、人命や地域の被害などの減災効果で救助エージェント方針の優劣を決定する（図33）。

家屋・道路の被災状況や被災による被害者など多岐にわたる減災効果を指標にし、マルチエージェントアルゴリズム（不完全状況下での資源割当、チームワーク、情報共有等）の競争的發展促進と、その成果に基づく社会貢献を目指した。その間、災害下の救助活動シミュレーションの問題点である対象とする社会問題の複雑さと人の行動規範の定式化、シミュレーション結果の再現性・検証について、シミュレーション対象を明確にするルール及び規模拡大に対するマルチエージェントシステムアーキテクチャの提案、エージェント開発フレームワークの導入による対応が行われてきた。

ロボカップレスキューによるシミュレーションは対象分野の重要性により、大都市大震災軽減化特別プロジェクト（2002～2006年）の震災総合シミュレーションシステム[10]や、英国のALADDIN

(Autonomous Learning Agents for Decentralized Data and Information Networks) プロジェクト [10]、米国でHomeland Security Awardを獲得したARMOR、IRIS、GURADSプロジェクト等に影響を及ぼした。

#### 1.6.4.3 ロボカップレスキューロボットリーグ

ロボカップレスキューロボットリーグは、直接目視できない遠隔から競技用ロボットにより災害現場を模したフィールド内にある被災者を探索し、その数と状態、それらの場所を示した地図作成の精度と速さを競う競技である。災害空間としては不整地、急な階段、複雑な形状の障害物などから構成される迷路が、被災者として穴の開いた箱に隠れた人形が音源や熱源とともに設置され、ロボットに搭載したセンサによって情報を収集する。ロボットは自己位置推定と地図作成を同時に行いながら (Simultaneous Localization and Mapping; SLAM)、被災者の探索を進める [11]。被災者の探索能力の競争に加え、完全自律型ロボットは自律行動や地図生成の能力を、遠隔操縦ロボットは不整地移動性能やヒューマンインターフェースの能力を競う。

競技が開始された2001年にはカメラを搭載したラジコンタンクのレベルに過ぎなかったロボットが、ステップフィールドと呼ばれる高さの異なる角材を組み合わせた不整地や急な階段、障害物の間を自由自在に遠隔あるいは自律で行動できるようになり、自動的に被災者を発見して地図を生成し、入り組んだ場所にある物体を遠隔操作できるようになるなど、被災者探索の技術レベルを高めることに貢献した。

本競技会は災害ロボットの研究分野の創生と活性化に貢献し、それまでは研究テーマとして取り上げられることが皆無であったものが、現在では多くの研究者がロボティクスの活用分野の一つとして取り上げ、その高度化に取り組むこととなった。その成果は、福島第一原発の原子力建屋に国産第一号機として投入された「Quince」の開発につながるなど、実際の災害対応にも一定の成果を上げている [11]。

その競技ルールは、米国国立標準技術研究所 (NIST) によって、災害ロボットの性能評価法として ASTM (American Society for Testing and Materials) 標準となり、災害対応ロボットの調達や隊員の操縦訓練に活用されている<sup>8</sup>。また、DARPA Robotics Challenge、euRAthlon、World Robot Summit (ロボットオリンピック) など、世界中で災害対応を目的とした競技会が開催される基盤となった。

#### 1.6.4.4 残された課題

ロボカップレスキュー構想は、当時リアルタイム防災と呼ばれた自動災害情報収集システムの次世代の形として注目されたが、それを実現するための技術レベルや社会インフラが未熟であり、実際の防災組織や手順との整合性がとれないことから、現実的とはいえなかった。

提案から20年近くを経て、今、構想実現のための技術基盤が整いつつある。地理情報の整備が進み、様々なものが情報化され、災害予測精度は飛躍的に向上し、大規模シミュレーションを可能にする枠組みが整ってきた。無線ネットワーク、IoT、ロボットの発展により、大規模に情報を収集し、行動を指令するための基盤が整備されてきた。あらゆる仕事はネットワーク化され、携帯電話や仮想現実 (Virtual Reality; VR) などのヒューマンインターフェースの普及も著しい。また、自律ロボットが活動できる環境が飛躍的に拡大して生活空間における実用性が確保され、災害のような不定環境においても限定的に作業を実施できる見込みが高まってきた。

ここでの最大の課題は、ほかのAIの問題と同様、シミュレーションのサイバー空間やロボットが持つ

---

※8

"Standard Test Methods for Response Robots." NIST Website  
<<http://RobotTestMethods.nist.gov>>

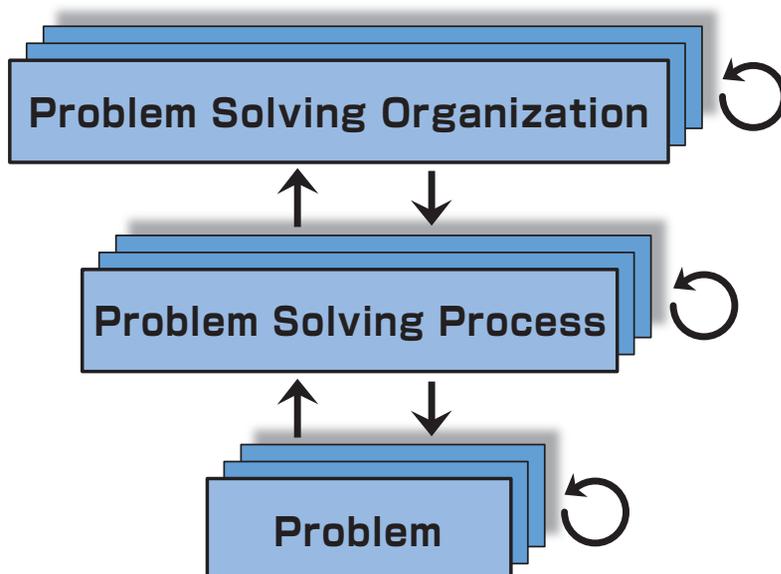
世界モデルと、リアルワールドとの間に存在する、大きな溝を埋めることである。機械学習等の手法によって、実データの解釈の実用性が徐々に高まってきている。人間の組織活動も、ルーチンワークについては少なくとも情報化が進んできている。そのため、10年のスパンで、ある限定された範囲においてロボカップレスキュー構想が実現し、安全で安心して暮らせる社会の実現に貢献すると予測される。

### 1.6.5 フィールドでの社会応用

我が国は少子高齢化を始めとする課題先進国と呼ばれているが、それらの課題はひとときに解決できるものではなく、継続的な問題発見と問題解決を必要とするフィールドととらえたほうがよい[1]。フィールドは「分析的、工学的アプローチが困難で、統制できず、多様なものが共存並立し、予測できない偶発的な出来事が生起し、常に関与することが求められる場（片井修）」である。この定義は、工学的に解決可能な問題を切り出すことが不可能だと言っているわけではないが、様々なステークホルダーが関わる問題の時空間的な広がりや、重層的な問題空間を構成し、仮に切り出したとしても予期せぬ事象によって次々と変容し、いつまでも手を抜くことができないと指摘している。機能分化された社会のなかでも、最も機能分化されたコミュニティに属する研究者や技術者にとって、フィールドは手を焼く存在である。

同様の指摘は、デザインの分野でも古くからいわれている。「Wicked problem」というのは、不完全で変化する要求に対してデザインすることの困難さを示す表現である。問題間の相互依存性が原因となり、一つの問題を解こうとするとその過程で、また別の問題が現れる有様を表している。AIの分野では、フレーム問題が議論されてきた。エージェントの行為の影響を、おそらくは影響を受けないであろう事象を省いて表現するにはどうすればよいかという問題である。先のフィールドの定義は、フィールドにおける問題がWicked problemであり、それに解を与えることはフレーム問題を経験的に解く困難な試みであることを示唆している。

課題を抱えるフィールドで、問題を継続的に切り出し、解決するために、問題、問題解決プロセス、問題解決組織を以下のようにとらえる（図35）。



■図35 問題、問題解決プロセス、問題解決組織

- 問題は、フィールドにおける課題から、解くことを前提として切り出される。
- 問題解決プロセスは、字義どおりには、問題に対して解を与えるプロセスである。しかし、問題は設定された時点で解くことが前提とされるので、実際には、問題解決プロセスは解ける問題を切り出すプロセスであることが多い。そのため、問題発見という言葉が使われることもあるが、解くことを前提とした問題の発見は問題解決と表裏一体である。
- 問題解決組織は、問題解決のためのステークホルダーのネットワークである。言い換えれば、解くことを前提とした問題を継続的に切り出すための組織である。

フィールドにおいて切り出された問題は相互に依存していることが多い。そうであれば、問題を解くプロセスも相互に依存せざるを得ない。その結果、問題解決の主体である問題解決組織も相互に依存することになる。加えて、問題、問題解決プロセス、問題解決組織の依存関係は時間の経過にしたがって変容する。フィールドにおける、問題空間の重層的な関係は、問題を固定し永久的な解を与えることを難しくする。そうであれば、問題の変容に追従できる柔軟な問題解決プロセスをデザインしなければならない。すなわち、眼前の問題を解くことを最終の目標とするのではなく、継続的に問題を解くプロセスのデザインを目標とすべきである。更に、そうしたプロセスを実行する、変化に柔軟な、おそらくはネットワーク型の問題解決組織を維持するべきだろう。

具体的な事例として、途上国支援における多言語コミュニケーションの例を挙げる。途上国支援などで専門家が現地就業者に技術情報を伝える場合は、専門家が現地に赴き、対面で現地就業者に伝える、という方法が一般的であった。しかしながら現地就業者が非識字者であることも多く、伝えた専門知識を将来に向けてそのコミュニティに蓄積させたり、近隣に拡散させたりすることが困難であった。一方、近年では世界的に教育制度が向上していることもあり、途上国の郊外でも児童の就学率が向上し識字率も高くなってきている。そこで、重要で専門的な知識を、ICTを使って国内外の専門家からオンラインで児童を介して非識字の保護者に届ける「YMC」(Youth Mediated Communication) と呼ばれる新しい途上国支援モデルが提案された。

YMCモデルを用いて、ベトナムのメコンデルタ地帯の農家を対象に、日本人専門家による知識提供の支援が行われた。高い精度の翻訳を実現するために、農業分野の辞書や用例対訳が作成され機械翻訳に適用された。しかし、それ以上に努力を要したのは問題解決組織の形成である。ベトナムの農業農村開発省(MARD)、ベトナム・ヴィンロン(Vinh Long)省の農業農村開発局(DARD)、ベトナム国家大学、特定非営利活動法人パンゲア、京都大学の言語グリッドチーム、東京大学や三重大学の農業支援チームがネットワーク型の組織を形成し、2011年から2014年の間にヴィンロン省のTra On地区とBinh Minh地区において4回の実証実験(延べ16か月)が実施された。各回の実証実験には15~30世帯の農家・児童が参加した。日本人農業専門家がベトナム児童を経由して、ベトナムの農民に農業知識を伝えた。要するにこのプロジェクトの中で、機械翻訳技術が、その継続的な利用を実質化する問題解決組織の形成を伴って用いられた。

フィールドと研究者の協働は痛みを伴うこともある。フィールドにしばしば見られる新規技術に対するアレルギーと、研究者の技術的楽観論(情報技術は10年で性能が100倍に向上する)は相容れない。情報システムの人為的複雑さによる説明限界や、情報ビジネスの予測不能性(無料メールがいつの間にかビジネスになる等)が、研究者とフィールドとのコミュニケーションを難しいものにする。フィールドは、研究者にとって活動しやすい場とは限らない。しかしながら、今後、イノベーションの多くはフィールドから生じる。総合的研究領域である情報学においては、研究者のフィールドへのアプローチは必須である。

参考文献

- [1] 京都大学フィールド情報学研究会『フィールド情報学入門—自然観察、社会参加、イノベーションのための情報学—』共立出版.
- [2] 中島秀之ほか「バスとタクシーを融合した新しい公共交通サービスの概念とシステムの実装」『土木学会論文集D3(土木計画学)』vol.71 No.5, pp.1\_875-1\_888.
- [3] 大和裕幸ほか「オンデマンドバス:公共サービスに於けるイノベーション—オペレーションズ・リサーチ」『経営の科学』vol.51 No.9, pp.579-586.
- [4] 鈴木文彦『デマンド交通とタクシー活用』地域科学研究会.
- [5] 中島秀之ほか「新しい交通サービス実践への道程」『サービス学会第3回国内大会講演論文集』
- [6] 田柳恵美子ほか「デマンド応答型公共交通サービスの現状と展望」『人工知能学会全国大会』
- [7] 中島秀之ほか「Smart Access Vehicle System:フルデマンド型公共交通配車システムの実装と評価」『情報処理学会論文誌』vol.57 No.4, pp.1290-1302.
- [8] 田所諭・北野宏明(監修)・ロボカップ日本委員会(編)「RoboCup-Rescue技術委員会・The RoboCup Federation」『ロボカップレスキュー—緊急大規模災害救助への挑戦—』共立出版.
- [9] Hiroaki Kitano and Satoshi Tadokoro, "RoboCup-Rescue: A grand challenge for multi-agent and intelligent systems," *AI Magazine*, vol.22 Issue.1, pp.39-52.
- [10] 後藤洋三「震災総合シミュレーションシステムの開発」『大都市大震災軽減化特別プロジェクト総括成果報告書』文部科学省, p.83.
- [11] Keiji Nagatani et al., "Emergency response to the nuclear accident at the Fukushima Daiichi Nuclear Power Plants using mobile rescue robots," *Journal of Field Robotics*, vol.30 Issue.1, pp.44-63.

# 1.7 計算インフラを構成するハードウェア

## 1.7.1 総論

インターネット上のトラフィックは増大し続けており、2020年には40ゼタバイトに到達すると考えられている。我が国のデータ流通量も、2005年の約1.6エクサバイトから2014年の約14.5エクサバイトまで、約9.3倍に伸びており<sup>1</sup>、今後も増大トレンドは変わらないと考えられる。人工知能（AI）の対象領域も今後拡大するものと考えられることから、AIの計算速度、低消費電力、低メモリ等への要求は今後も増大し続けるのは間違いない。そのような要求から、AIの研究開発と実用化を支える基盤として、AIの計算等に係るインフラストラクチャの整備やハードウェアの研究開発が進められている。

AIの研究開発や実用化に際して、HPC（High Performance Computing）技術ベースのクラウド的な共有計算環境を整備していくことが、我が国における新たなプレイヤーの参入ハードルを下げ、AIの今後の普及を支える基盤の一つとなる。AIの学習時には、現状では一般に豊富な計算資源が必要となるが、一部の大企業を除いて大規模な計算環境を整えるのはコストの面から難しいため、共有可能な環境を整備することが望ましい。

CPU、GPU（Graphics Processing Unit）、FPGA（Field Programmable Gate Array）、あるいはディープラーニング用の専用チップなどの計算デバイスに関しても、増大し続ける性能に対する要求に応えるべく研究開発が必要となる。更に、計算を実行するための環境だけでなく、データやモデルの共有など、計算周辺の役割も含めた環境整備も合わせて検討を行うことが必要となると考えられる。

AI、特に機械学習の利用のためには、①データから学習によってモデルを作成するフェーズ、②学習後のモデルを用いて新たなデータに対し推論を行うフェーズがある。学習時には、大量のデータをメモリにロードし、反復しながら精度を高めていく計算が必要であるため、計算性能が重要視される。一方、推論時には、個々の入力データに対し、比較的少数回の演算を行えば結果が得られることから、計算性能に対する要求は学習時ほど高くはないが、データの入出力や格納、転送に関し高い能力が求められる。

したがって、AIの学習、特に大規模な計算環境が必要となるディープラーニングでは、例え大企業であっても個別の会社で計算環境を取得・維持・管理することは一般に困難であり、国が実施する機械学習向けのHPCベースの大規模計算環境の整備や、それらの技術を移転した民間によるクラウドの形態での計算リソースの提供の必要性が今後増していくと思われる。

学習時の計算デバイスに対する性能や性能／電力比の向上への要求は、推論時に比べれば必ずしも高くなく、性能優先で利用されるため、現状ではGPUが広く使用されている。ただし、消費電力低減の要求やメモリ容量に対する要求を無視して良いわけではないため、今後FPGAの利用や、専用チップの開発を推進していくことも求められる。一方でGPU等の汎用チップ自身も機械学習向けの性能や省電力性能を増しており、今後競争の激化が予想される。

しかしながら、現状では学習の速度を上げるのは、応用数値及びHPC由来のアルゴリズム面の進化と、同様のハードウェアでの並列処理に強く依存している。アルゴリズムとしての並列性は、ネットワークのフィードフォワードなどのプロパゲーション（1.7.2項参照）を計算する際の行列の積などのアルゴリズムの低レベルな並列性、プロパゲーション時にネットワークを分割し、分散並列計算するモデル並

※1

「平成27年版 情報通信白書」第2部ICTが拓く未来社会、「我が国におけるビッグデータ流通量の推計」総務省ウェブサイト  
<<http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h27/html/nc254310.html>>

列性、バッチ学習時にバッチ用のデータを分割し、学習勾配を後に統合するデータ並列性、更に一種類のデータセットに対し様々なモデルを組み合わせるアンサンブル学習や、そのほかの探索により学習のパラメータやネットワークの種々の構成を決定するハイパーパラメータチューニングのような上位の並列性がある。

これを実際のマシンに実装する際には、物理的にはチップ内の並列と、複数のチップを組み合わせた計算ノード内での並列、更にはノード間の学習の速度を上げるにはスーパーコンピュータ由来の相互結合網で高速に結合されたノード間の並列を活用する必要がある。つまり数十万～数千万の階層的な並列性を、それを実行可能なマシンに実装するわけであるが、それはまさにHPCであり、スーパーコンピュータの劇的な進化に伴い、ディープラーニングに代表される機械学習が革命的に進化し、新たなAIの隆盛をもたらした由来である。つまり、AIの進化には、単にチップだけでなく、スーパーコンピュータ由来の「システム」や「インフラストラクチャ」の設計・開発・構築・配備が大変重要となる。

推論時には、計算性能への要求よりもむしろ性能/電力比への要求が高まる。特に、実用化の際には、推論の比重が高まる。そのため、クラウド・フォグ・エッジという階層構造の中で、エッジ側に近づくほど、低消費電力、低メモリ、短レイテンシ<sup>2</sup>に対する要求が高まり、機械学習に特化したFPGAや専用チップの開発が有利になる可能性がある。

しかし、ディープラーニングのソフトウェア側の研究は日進月歩であり、ハードウェア構成を設計する際には、積和演算など研究が進んでも不変な部分と、ニューラルネットワークの組み方など現在も様々なモデルが模索されている部分の仕分けが重要であると考えられる。このほか、計算への負荷を軽くするための技術として、計算に用いるビット数の削減の研究がある。ニューラルネットワークの計算には必ずしも通常の数値計算で使用する単精度（32ビット）の精度は必要ないことが分かってきており、8ビットや、極端な場合は1ビットでの計算とすることも研究されている。このような計算は、FPGAで比較的容易に実現可能であるため、FPGAの試験的な利用が短期的には増大するものと考えられる。しかしながら推論では有効なものの、学習時には単精度ぐらいの精度は一般的には要求されるとの研究もあり、このあたりはまだ決着していない。

GPUや高速結合網に代表されるHPCの加速技術が、機械学習の加速にも適用可能であるゆえ、スーパーコンピュータによる加速がまずは期待される。しかしながら、「京」に代表される現状の我が国のスーパーコンピュータ群は、歴史的、技術的な理由などにより機械学習やそれを必要とするビッグデータ処理に最適化されておらず、かつ既存のシミュレーション主体のワークロードで既に容量が手一杯であり、AIに提供できる実際の資源量は乏しい。その中で、東京工業大学学術国際情報センター（GSIC）の「TSUBAME」（Tokyo tech Supercomputer and Ubiquitously Accessible Mass storage Environment）シリーズはAI、ビッグデータに処するハード、ソフトの最適化設計を行っており、2017年8月に稼働する最新のTSUBAME3.0<sup>3</sup>により、従来のスーパーコンピュータの汎用ワークロードと共有ではあるものの、そのディープラーニングの総合性能は単体では47.2ペタフロップス、既設のTSUBAME2.5等との合算では65.8ペタフロップスと、我が国トップの学習能力となる。

産業技術総合研究所人工知能研究センター（AIRC）、理化学研究所革新知能統合研究センター（AIP）、情報通信研究機構（NICT）ユニバーサルコミュニケーション研究所（UCRI）など、各省庁関連のAI関係の研究センターや、主だった企業には数百テラフロップス（TFlops<sup>4</sup>）～数ペタフロップス（PFlops）

※2  
通信における遅延時間。

※3  
「東工大のスパコンTSUBAME3.0が今夏稼働開始—半精度演算性能47.2ペタフロップス、人工知能分野における需要急増へ対応—」  
東京工業大学ウェブサイト <<http://www.titech.ac.jp/news/2017/037500.html>>

の小・中規模の機械学習専用のマシンが近年導入されつつある。

また、国が本格的に実施する計算のための大規模環境の整備計画の例としては、産業技術総合研究所（AIST）の「AI Bridging Cloud Infrastructure（ABCI）」がある<sup>5</sup>。ABCIでは、TSUBAME由来のHPC技術を駆使し、130ペタフロップスの機械学習のための専用クラウド計算環境を構築し、アカデミアと民間企業のオープンイノベーションを推進することが目指されている。ABCIでは、計算環境の提供だけでなく、データや学習後モデルの共有なども含めた総合的なプラットフォームとする計画である。ABCIは専用のデータセンターを構築し、2018年3月頃に稼働が予定されている。

なお、民間によるクラウドの形態での計算リソースの提供に関しては、海外の情報系の企業が先行していたが、国内でもさくらインターネットなどによる「高火力コンピューティング」などのサービスが開始されている。

ディープラーニングの計算には、現状ではGPUを利用することが一般的であるが、中期的には、FPGAの利用、専用チップの開発等を含め、学習時や推論時の要求機能・性能の違い、エッジ、フォグやクラウドの利用環境の違いに合わせて多様な構成のデバイスが求められるようになるであろう。

例えば、Googleは推論に限定されるが、TPU（Tensor Processing Unit）と呼ばれるディープラーニング専用のチップを開発し、既に利用していることを明らかにしている。データセットが大きくなるにつれて、推論と学習に要求される資源量の差が本質的に広がる。そして、推論はエッジ側での組み込みコンピューティングでの利用が中心になる一方、学習はクラウド側でHPC由来の大規模なコンピュータでの処理が中心になるため、そのハードウェア特性の差は広がる可能性が高い。しかしながら、両者において、単にハードウェアだけでなく、推論から学習、更にそのほかのデータ処理の活動で共通かつ広いソフトウェアのエコシステムが提供されていく必要があり、ハードウェア一辺倒の研究開発では実用的な普及はおぼつかないであろう。

更に長期的には、従来のノイマン型コンピュータと異なる計算原理である非ノイマン型コンピュータや、デジタル計算ではなくアナログ計算可能なデバイスを利用するニューロモーフィックコンピューティング、量子計算等の発展も念頭に置いておく必要がある。ニューロモーフィックコンピューティングのデバイス開発では、欧州のHuman Brain Projectでの「SpiNNaker」や「BrainScales」、米国のIBMの「TrueNorth」などが先行している。近年では各国で研究が進み、我が国のメーカーもいくつか開発に乗り出しているが、実用的な学習への適用はまだ基礎研究段階である。

国立情報学研究所（NII）やNTT、富士通などは量子計算の研究開発を実施しており、そのなかでも量子アニーリングは数理最適化の分野においていくつかの成果が報告されているが、実用的な機械学習への適用は未知数である。これらのデバイスでも、基礎研究段階では性能が重要なパラメータであるが、応用段階ではアルゴリズムやソフトウェアのエコシステムの手厚いサポートが重要になってくると考えられる。

## 1.7.2 ディープラーニングで要求される演算の基本

ディープラーニングの学習・推論に使われる演算のうち代表的なものとして、フィードフォワード（feed forward）計算（前向き計算）とバックプロパゲーション（back propagation）計算（後ろ向き計算）のそれぞれについて示す。

※4  
Flops (Floating-point Operations Per Second)。1秒間に実行可能な浮動小数点演算の回数。

※5  
“AI Bridging Cloud Infrastructure (ABCI).” 産業技術総合研究所ウェブサイト <<http://www.itri.aist.go.jp/events/sc2016/pdf/P06-ABCI.pdf>>

### 1.7.2.1 フィードフォワード計算(前向き計算)

#### (1)全結合層

全結合層は、各ニューロンが前のレイヤーの全てのニューロンに、独立したシナプスで接続されているレイヤーである。全結合層のフィードフォワード計算は、本質的に行列（パラメータ・重み）、ベクトル（活性）積である。この計算を効率的に行うためには、複数のサンプルに関する活性ベクトルを方向に連結して行列、行列積として計算する方法が広く用いられており、この計算は線形代数演算のAPIであるBasic Linear Algebra Subprograms (BLAS) のGGeneral Matrix Multiply (GEMM) カーネルを用いて行われることが一般的である。

#### (2)畳み込み層

畳み込み層は、各ニューロンが前のレイヤーの近傍とパラメータを共通するシナプスで接続されているレイヤーであり、主に画像処理（2次元）で用いられる。畳み込み層はレイヤーの境界の扱いやフィルタのスライド幅（stride）に関して様々な変種が存在する。畳み込み層のフィードフォワード計算に関しては、計算内容を変えない範囲で様々な計算アルゴリズムが存在する。

- GEMMを用いる手法：

パラメータと前のレイヤーの活性の畳み込みをベクトル同士の内積と解釈することで、GEMMを用いて畳み込みを行うことができる。行列積計算を行うためには活性を行列の形状にコピーする必要があるが、十分に大きい行列サイズの場合はGEMMの実行時間が支配的となる。一方でこの行列は重複する値を多数含むため、メモリを圧迫する可能性がある。この手法ではよく最適化されたBLAS実装を用いることで高効率な計算を行うことができる。

- ウィノグラードのMinimal filtering algorithm:

「Minimal filtering algorithm」 [1]は、入力サイズ・畳み込みサイズによって定まる定数行列を用いて適切に加減乗除を行うことにより、乗算回数を入力サイズとフィルタサイズの和に比例する計算量で1次元の畳み込みを行うアルゴリズムである。これを2次元に拡張することで、ナイーブな実装と比較して少ない乗算回数で畳み込み層の計算を行うことができる。このアルゴリズムは十分に大きいフィルタサイズが必要なFFT（Fast Fourier Transform）と比較して、フィルタサイズが小さい場合に特に有効である。

- FFTを用いる方法：

二つの関数 $f, g$ について、フーリエ変換を $F$ とすれば $F(f * g) = F(f)F(g)$  が成り立つ（ただし $f * g$ は2関数の畳み込み）。よって畳み込みニューラルネットワーク（CNN）の畳み込みについても入力とフィルタを離散フーリエ変換し、積を逆変換することで畳み込みを行うことができる。

- cuDNNのアルゴリズム：

NVIDIAが開発するディープラーニング向けライブラリであるcuDNN<sup>6</sup>では、前述のアルゴリズムを含めた複数の畳み込みアルゴリズムが実装されており、ユーザが選択できるようになっている。これにより、ユーザが（多大なメモリを使用する）GEMMによるアルゴリズムよりも、高速かつ使用メモリ量が小さいアルゴリズムを使用できる余地があるとしている。

---

※6

GPUに特化したプログラミング言語であるCUDA (Compute Unified Device Architecture) を用いて書かれた深層ニューラルネットワーク (Deep Neural Network; DNN) 用のライブラリ。

### 1.7.2.2 バックプロパゲーション計算(後ろ向き計算)

ディープラーニングは、与えられたデータセットに対して深層ニューラルネットワーク (DNN) のパラメータを最適化する最適化問題に帰着される。パラメータの最適化には確率的勾配降下法 (Stochastic Gradient Descent; SGD) が最も広く用いられる (数式による表現は後述のコラムを参照)。

SGDではパラメータの更新ごとにランダムに選択された少数個のデータを用いるため、1回の更新あたりの計算量を低く抑えることが可能である。大規模なデータを学習 (特に教師あり学習) する場合には、SGDの利用が標準的である。一方、バッチ (データセット全体) を使った最急降下法では、1回の反復に必要な計算量が多大となり、大規模データの学習には現実的ではない。よって、SGDを用いることでほどよい反復あたりの計算量と収束性で学習を行うことができる。

バックプロパゲーションとは、DNNの出力に対する誤差を出力レイヤーから順にフィードフォワードとは逆方向に伝播させることで、各パラメータに対するコスト関数の勾配を計算する手法である。

\* DNNのパラメータ $\theta$ を最適化する最適化問題

$$\theta^* = \operatorname{argmin}_{\theta} \sum_{i \in D} E_{\theta}(z^i, t^i)$$

ただし $D = \{z^i, t^i\}$ はデータセット (データ $z^i$ とラベル $t^i$ の組の集合)、 $E_{\theta}$ はコスト関数であり、DNNの出力 $DNN_{\theta}(z^i)$  とラベル $t^i$ の何らかの距離として定義される。

\* パラメータの最適化に用いられる確率的勾配降下法SGDの反復式

$$\theta^{(t+1)} = \theta^t - \eta \sum_{i \in M^{(t)}} \frac{\partial E_{\theta}(z^i, t^i)}{\partial \theta}$$

ただし $M^{(t)}$ は $t$ ステップ目でデータセットからランダムに選択された部分集合 (ミニバッチ)、 $\eta > 0$ は学習係数である。

## 1.7.3 学習用のインフラストラクチャと計算デバイス

### 1.7.3.1 ディープラーニングによるAIシステムの背景

ディープラーニングによるAIシステムの発展を、画像認識タスクを例に説明する。ILSVRC (ImageNet Large Scale Visual Recognition Competition) [2]は、スタンフォード大学のコンピュータビジョン研究グループを始めとした専門家チームにより2010年に開設された、静止画からの一般物体認識の認識性能を競うコンペティションであり、この目的の為に研究用のデータセットが公開されている。訓練用データセットには1,000クラス、128万点のデータサンプルがあり、この規模は過去に公開された画像の教師ありデータセットの中では、最大規模のものである。

2012年のILSVRCにおいて、当時トロント大学 (カナダ) のアレックス・クリジェフスキー氏 (現在Googleに在籍)、イリヤ・スツケヴェル (Ilya Sutskever、現在OpenAIの研究ディレクターを務める) 氏、ジェフリー・ヒントンの三氏の研究チームが、深層構造を持つニューラルネットワークを用いて認識精度におけるブレークスルーを達成したことは、有名である。1位のトロント大学チームと2位の東京大学チームの認識率の差は10%近くもあり、これがニューラルネットワークの「復活」を印象付ける結果となった。

ブレークスルー以前の典型的な解法は、特徴抽出部と識別部を使ったものであり、前者は経験的に設計され、後者は機械学習により最適化されるものであった。特徴抽出はコンピュータビジョンにおける主要な研究領域の一つであり、アプリケーションドメインにおける事前知識、静止画や動画、処理負荷などの観点から数多くの手法が提案されてきた経緯がある。一方、ニューラルネットワークでは特徴抽

出と識別は統一的に扱われており、特徴抽出部自体がパラメトリックに最適化される点に特色がある。更にDNNでは、特徴抽出部の多層化によってモデルの表現能力が高まり、多くの場合更に認識性能を引出すことが可能となる。[3]

ILSVRCの開設前は、PASCAL<sup>7</sup>と呼ばれるデータセットが一般物体認識の研究で広く使用されていた。このデータセットはILSVRCと比較してサンプル数が2桁少ないが、ここに興味深い研究報告がある。PASCALにおいては、特徴設計型の識別器のほうがDNNに比べて認識性能が良好であると報告されている[4]。つまり、ディープラーニングは小規模データセットにおいてはそれほど認識性能が出ず、大規模データセットが与えられて始めて秀逸な認識性能を獲得することができると考えられる。この意味でILSVRCの登場こそがDNNの“再発見”の最大の要因の一つと言える。

ディープラーニングの研究はブレークスルー以降爆発的な発展を見せ、2016年のILSVRCでは、クリジェフスキー氏らの達成した認識精度を更に10%以上上回るレベルに到達している。近年では特徴抽出過程の学習一般を扱う「表現学習」と呼ばれる分野の国際学会が創設されるなど、分野の発展に拍車がかかっている。

ネットワーク構造は複雑化の一途を辿っており、バイパス構造を持っているものや、ネットワークの途中でコスト関数が定義されているものなど、様々な構造が提案されてきた。現在ではDNNとは「誤差逆伝搬が可能な任意形状の計算グラフ」とのとりえ方が一般的になっており、いくつかのディープラーニングのソフトウェアプラットフォームもこの考えに立脚している。

画像処理だけでなく、人間を超える処理の可能性を強く印象付けたのはDeepMind（英国）が2015年に発表した「AlphaGo」である。それまでは、AIはチェスや将棋では人間のプロに勝利していたが、囲碁はあまりにも対局の場合の数が多くかつ複雑で、従来から用いられていた伝統的なAIの局面の探索手法（ $\alpha$ - $\beta$ 探索法など）では、最新の計算機を用いても計算量が爆発するとみなされていたからである。

しかしながら、DeepMindは、2015年に探索を行う際の判定関数にディープラーニングネットワークとモンテカルロ木を用い、更にプログラムを相互に数千万回対戦させる強化学習を行うことによって、世界最強の棋士の一人であるイ・セドル（Lee Sedol）氏との対局で4-1で圧勝し、人間を上回る囲碁プレイヤーAlphaGoを作り上げた。その技術概要は『Nature』誌にも掲載され[5]、対局のネット配信とともにマスコミが大々的に宣伝し、AIの新時代として大いに注目を浴びることになった。

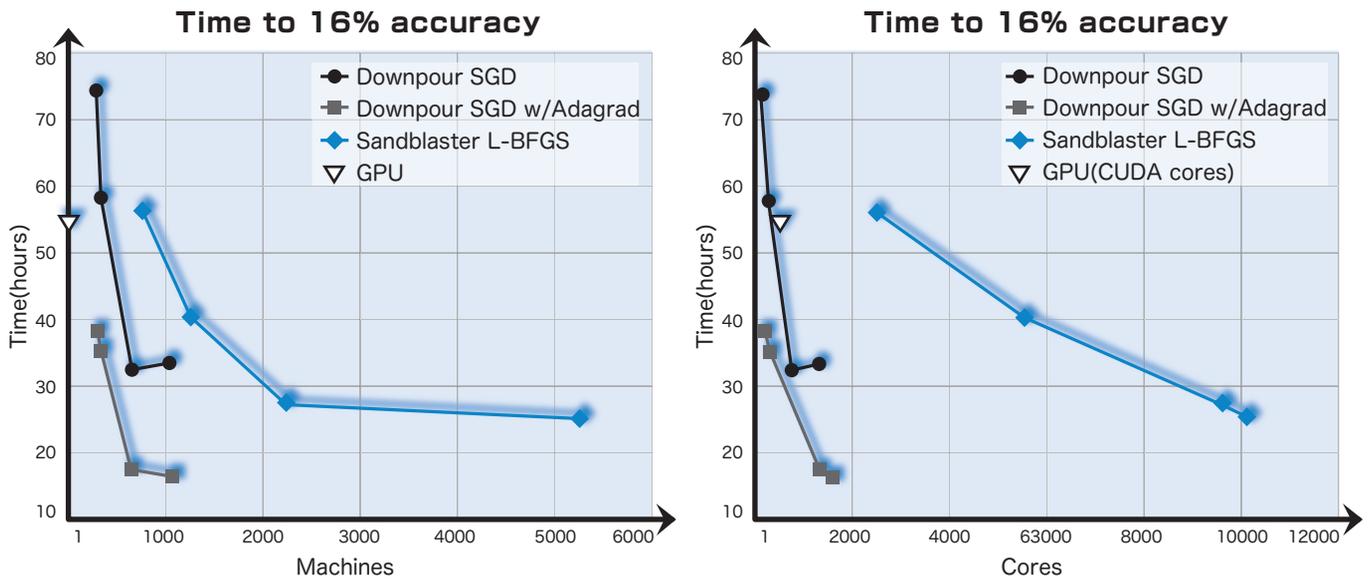
AlphaGoの勝因は二つある。一つは上記のようにディープラーニングの最新技術を適用したことであるが、二つ目は、それを可能にする十分な計算資源を確保し、有効活用したことである。画像処理同様に、Google Cloud Platform上に配備された数百のGPUを潤沢に用いることにより、複雑なディープラーニングネットワークによって駆動されるAIプレイヤーの莫大な対局数による強化学習に成功した。

ILSVRCではGPU中心のHPCによる加速が、それより早くから注目されていた。当初、Googleはディープラーニングの処理プラットフォームとして、自社のCPUファームを用いていたが、図36にみられるように、並列化による強スケーリング<sup>8</sup>時のスケーラビリティの達成が非常に困難であることが判明した。これは後に述べるように、データ並列の手法によって並列加速された学習を行う際に、各ノードで計算された新たな勾配の集約演算（collectives）が相対的かつ急速にオーバーヘッドになるからである。これを解決する一つの方法は、演算密度が高いだけでなく、内部のバンド幅も高いGPUを用いることであった。

このように、ILSVRC及びDeepMindやAlphaGoの成功により、GPUを中心とした高性能計算・スーパーコンピューティング技術によるAIの新たな展開が明らかになった。それとともに、クラウドでは

※7  
“The PASCAL Visual Object Classes Homepage” University of Oxford Website <<http://host.robots.ox.ac.uk/pascal/VOC/>>

※8  
問題のサイズを変えないでプロセッサ数を変えた時の計算時間の評価。



■図36 計算機ノード数・コア数を増減させたときの認識精度16%達成にかかる時間<sup>9</sup>

HPC技術のIDC（Internet Data Center）への導入が急速に始まり、逆にHPCでは計算シミュレーション中心の世界から、ビッグデータやその解析に対する機械学習の適用における数値計算アルゴリズムやシステム技術の適用に関心が高まり、結果として更にディープラーニングを中心としたAIの加速や大規模並列化へ向けたアルゴリズムプロセッサシステム・計算インフラストラクチャ等の研究開発が世界中で盛んになってきている。

このような世界的なトレンドに対し、我が国は遅れを取っていることは否めない。機械学習に関するアルゴリズムの基礎研究や、応用事例は様々あるものの、Google、Amazon、Facebook、Microsoft、Baidu（百度、中国）などの、米中のいわゆる「AI Giants」と比較し、それに匹敵するインフラストラクチャや、システムハードウェアやソフトウェアに対する研究は立ち上がりが遅れ、かつ、HPC分野からの関心も未だ薄い。しかしながら、近年は一部それらを解決する動きが、東京工業大学のTSUB-AMEや産総研のABCI、富士通DLU（Deep Learning Unit）など、産官学でも進められており、これらの努力を更に拡大していくことがAI後進国にならないためにも大変重要である。

### 1.7.3.2 学習向けの高性能インフラストラクチャ・スーパーコンピュータ及びGPUの台頭

元来グラフィックス計算用のプロセッサとして開発されたGPUをHPCに転用するGPGPU（General Purpose computing on GPU）技術はこの10年で一般化した。

グラフィックス処理においては、ピクセル値などの大量のデータ列・パラメータに対して同一の計算を適用することが多く、GPUの設計もそれを実現するために、汎用計算用のCPUと比較してSIMD（Single Instruction Multiple Data）的な処理に特化したものとなっている。そのため、CPUと比して複雑な分岐処理などの性能には劣るが、大量のデータに対して同一の演算を行う並列性の高い処理については、同時代のCPUの5～10倍の性能を示す。

GPUで動作するプログラムを作成するには、従来はCUDA（Compute Unified Device Architecture）やOpenCL（Open Computing Language）などの、GPUに特化したプログラミング言語を用いる必要があったが、近年ではOpenACC（Open Accelerators）などの、C言語プログラムにディレクティブと呼ばれる記述を付加するだけでGPU用の並列化を達成させる言語拡張や、GPUで行わせる

※9  
文献[6]より引用。

■表4 国内外の主なGPUスーパーコンピューター一覧

| 導入年  | コンピュータ名      | GPU 及び搭載数        | 理論性能値<br>(HPC 向け倍精度) | 理論性能値<br>(機械学習向け短縮精度) |
|------|--------------|------------------|----------------------|-----------------------|
| 2010 | TSUBAME2.0   | M2050 × 4224     | 2.4 PFlops           | 4.8 PFlops            |
| 2013 | TSUBAME2.5   | K20X × 4224      | 5.7 PFlops           | 17.1 PFlops           |
| 2013 | Titan        | K20X × 18688     | 27 PFlops            | 80 PFlops             |
| 2016 | Piz Daint    | P100 PCIe × 4500 | 15.99 PFlops         | 82 PFlops             |
| 2016 | DGX Saturn V | P100 SXM2 × 1000 | 4.90 PFlops          | 19 PFlops             |
| 2017 | TSUBAME3.0   | P100 SXM2 × 2160 | 12.15 PFlops         | 47.2 PFlops           |

処理をまとめたライブラリインターフェースを用いて間接的にGPUを利用するなどの、言語習得コストの低いプログラミング方式が実用できるレベルにまで発展している。

GPU技術の一般化はスーパーコンピュータを用いる科学技術計算にも当てはまり、表4に示すとおり日本及び海外のスーパーコンピュータにもGPUを多数搭載したものが現れ、流体力学、分子動力学を始めとした様々なシミュレーションプログラムがGPUを用いて実行されている。国内では、東京工業大学が2010年に運用開始したTSUBAME2.0が導入時からGPUを主たる計算資源として設計されたスーパーコンピュータの先鞭をつけ、2013年にTSUBAME2.5としてGPUのアップグレードを行い、2017年8月からは後継機TSUBAME3.0の運用が開始される予定である。

従来、HPCアプリケーションでは、倍精度浮動小数点数（64bit、double）を用いた演算が行われてきたが、近年では反復法を用いるものなど多くのアプリケーションにおいて、単精度浮動小数点数（32bit、single）でも実用上十分な精度の解が得られることが分かってきた。GPUは機種によるものの、倍精度演算の2倍以上の速度で単精度演算を行うことができ、演算とともにプログラム実行速度のボトルネックとなるメモリ転送速度の面でも、通信量が半分になる単精度浮動小数点数の採用は有利となる。

この傾向は近年更に先鋭化し、2016年に発売された最新世代のGPUであるNVIDIAの「Pascal P100」では半精度浮動小数点数（16bit、half）の演算がサポートされ、倍精度の4倍、単精度の2倍の速度で演算することができるようになったため、ディープラーニングに代表される浮動小数点演算の精度を要求しない機械学習アプリケーションの実行が更に高速化できるようになった。これらの性能向上とともに、Google、Amazon、Facebook、Microsoft、Baiduなどの、いわゆるクラウドの「AI Giants」でもGPUの採用・配備が進んでいる。

このように、主にシミュレーションサイエンスに活用されてきたGPUスーパーコンピュータであるが、AI分野においても、前節に示されるとおり、行列積やFFTなど、GPU処理に向けたアルゴリズムが用いられており、近年複数ノードを用いて大規模なネットワークの学習を並列化して実行する例が多数報告されている。また、ネットワークパラメータの最適化のために、複数のパラメータにおける学習を多数のノードで並行に計算するアンサンブル並列学習や、それらを組み合わせた実行も行われている。これらに関しては後述する。

### 1.7.3.3 ディープラーニング専用プロセッサ

現状では、バックプロパゲーションSGDによるディープラーニングは非常に長い時間と莫大なデータセットの供給が必要であり、かつDNN自身もギガバイト単位の多くのメモリを要求する百以上にも上

※10

エッジデバイスとは、クラウドに、あるいは大規模なサーバのようなネットワークの中心に接続する、末端のデバイスのこと。IoTにおける個々のモノやセンサ類にあたり、処理能力や消費電力は小さい。

る深い層で構成されていて、計算資源や電力の乏しいエッジデバイス<sup>10</sup>における学習は現実的ではない。どちらかと言えば、学習フェーズは先にあるようなHPCから派生してきた大型のチップが装備されている、高性能クラウドやスーパーコンピュータで行うのが主流となっている。

既に述べたように、密行列演算やGEMMの非常に高い加速性能から、ディープラーニングにブレークスルーを最初にもたらしたハードウェアはGPUであった。現状では、ほとんどのディープラーニングのワークロードはGPUによってなされていると言っても過言ではない。しかしながら、いくつかのメーカーがディープラーニングに向けた、あるいはディープラーニングに特化したクラウドスーパーコンピュータ向けの大規模チップを研究開発しており、2017年後半近辺から市場に出回り始める観測である。これらにより、GPUの寡占状態が改まり、競争によって更なる技術革新が起こることが期待されている。

しかし、クラウドやスーパーコンピュータのサーバ向けのチップは、単に性能を上げるだけでは不十分であり、大規模データセンター運用に供するためのRAS (Reliability Availability Serviceability)、安定性やリモート制御、更には長めの製品サイクルや継続性など、様々なエンタープライズ向けの機能が必要であり、そもそもの複雑さと相まって、通常のITと同様、組み込み系と比べて遥かにハードルが高い。

更に、CaffeやTensorFlow等の数多くのディープラーニングのフレームワークや関連ツールが、そのチップで汎用かつ最高性能で動くように、ソフトウェアの開発やチューニングから維持サポートまで、多くの関連開発が必要である。つまり、エンタープライズ系のCPUと同様に、単に「動く」ものでは駄目であり、その開発は、時間・経験・人手が豊富な大手ITベンダーに限られている。

以下、現在アナウンスされているプロセッサをいくつか紹介する。

- ディープラーニング向けGPU:

NVIDIAは2016年に、機械学習に向けたハードウェア特性を備えた大型のGPUである「Pascal P100」を発表・出荷し、現在多くのクラウドやスーパーコンピュータで大規模な採用が始まっている。Pascalの機械学習向けの最大の特徴点は、HPCでは通常用いないFP16という16ビット幅の浮動小数点形式のハードウェアのサポートであり、これによりGEMMの理論ピーク性能が従来用いられていた32ビットの約2倍であるチップあたり21.2 TFlopsと、大変高いものになっている。また、HPCと共用の新たな特徴として、後述の並列化時のチップ間的高速通信を実現するNV Linkが装備され、マルチGPUの学習が従来と比較して大幅に加速される。NVIDIAは更に、Pascal P100を8機装備した機械学習専用サーバであるDGX-1を開発し、多くの研究所や開発の現場で小～中規模の学習プラットフォームとして用いられている。

NVIDIAは、2017年末～2018年初頭に発表する次期GPUの「Volta」では、より機械学習向けの専用機能を発展させ、全体的な高速化とともに、様々な縮退精度 (16 bit、8 bit) のサポート、テンソル演算の高速化命令などを実現すると表明している。また、大規模GPUではライバルとも言えるAMD (米国) も、Vegaシリーズの機械学習向けの「Radeon Instinct」GPUを発表し、そのFP16性能では25 TFlopsと、P100の性能を上回ると主張している。

- Intel Xeon Phi - Knights Mill及びLake Crest:

IntelはHPC向けに高性能メニーコア型CPUである「Xeon Phi-Knights」シリーズを数年来開発しており、最新の「Knights Landing」(KNL) プロセッサは米国エネルギー省サンディア国立研究所の「Trinity」や同ローレンス・バークレー国立研究所の「Cori」、我が国では東京大学「Oak-Forest-PACS」などの最新のトップスーパーコンピュータに採用されている。それをベースに、Intelは機械学習向けに改良した「Knights Mill」(KNM) プロセッサを2016年に発表し、2017年

中に出荷するとしている。KNLと比較して、KNMはHPCでは多用されるが機械学習ではほとんど用いられない倍精度浮動小数点演算性能を縮退し、その代わりに用いられる単精度演算を大幅に強化している。更に、FlexPointという（FP16ではない）新たなディープラーニング用の演算形式を採用し、性能面ではP100を上回る、としている。

また、Intelは2016年にNervana Systems（米国）を4億ドルで買収し、開発されていたディープラーニング専用チップを製品ラインアップに加えるとしている。GPU同様比較的汎用性が高いKNMと比較して、その第一弾である「Lake Crest」はより機械学習向けの縮退精度のテンソル演算に特化していると言われており、その専用化によりKNM比でもより高い学習性能が実現されるとIntelは主張している。

- FPGA:

組み込み系と同様に、FPGAを大規模ディープラーニングに用いる試みも盛んになってきている。特に、Intelに買収されたAltera（米国）や、そのライバルのXilinx（米国）は、サーバプロセッサ並みの巨大なデータセンターやHPC向けのFPGAを開発しており、更に、最新版の「Altera Stratix 10」や「Xilinx Virtex UltraScale+」では、内蔵のハードマクロ演算ユニットであるDSP（Digital Signal Processor）を大量に装備し、ディープラーニングにも効率よく対応できるとしている。

FPGAはDNNで用いられるビット長を任意に調整したり、あるいはハードDSPを使う場合でもデータの流れを最適化したりするなどの手法で、電力性能比でGPUを上回る可能性が学会などで報告されている。しかしながら、FPGAでのプログラミングのツールチェーンは、やはり通常のCPUやGPU程は整備されておらず、かつ、推論と比べて複雑なディープラーニング系のアルゴリズムを有効かつ気軽に載せるのはまだまだチャレンジが大きい。

そのようなソフトウェア上の高いハードルはあるものの、MicrosoftのAzureなどの一部のクラウドIDCでは、後述するようにFPGAを用いた学習を行っており、今後が注目される。

- 富士通DLU:

我が国では富士通が、ディープラーニング専用プロセッサである「DLU」を開発している。詳細はまだあまり明らかにされていないが、京コンピュータで培ったHPC関連の様々な技術を投入し、現状のGPUと比較して10倍の電力効率を得るとしている。その登場は2018年末とされているが、富士通が開発中のAI向けの統合フレームワークである「Zinrai」に統合される予定であり、今後注目である。

- Google TPU:

Googleは2016年に自社開発のディープラーニングASICである「TPU」を発表した。既にGoogleのIDCに相当数が配備され、実際のアプリケーションに供されていると発表している。その内容は、8ビットの行列積を行うハードウェアがシストリックアレイ<sup>11</sup>状に約16,000個並んでいるという、演算エンジンとしては比較的クラシックな構成になっている。その性能は高いものの、精度の低さなどの要因により、TPUは推論専用であり、学習エンジンとして用いるのは困難である。それでも自社IDCで商用向けに大規模運用を行っている点は大変評価でき、今後学習向けのプロセッサも開発してくる可能性はあるであろう。ただし、この論文での性能評価に関し、上記の最新のPascal P100

---

※11

小さい処理を行うプロセッサを多数接続して、近接プロセッサ間において大量のデータ交換ができるようにした構造。

GPUを用いるとそのほうが推論性能は約倍で、かつ学習も可能であるとNVIDIAが声明を発表しており<sup>12</sup>、これらからも専用チップ対GPUの競争の激しさが鑑みられる。

また、上記のほか、NECは大阪大学、情報通信研究機構（NICT）脳情報通信融合研究センター（GiNET）、理化学研究所生命システム研究センター（QBiC）と連携して、脳型コンピューティングシステムの開発を行う研究所を開設したほか<sup>13</sup>、東京大学とも共同研究を開始している<sup>14</sup>。

### 1.7.3.4 ディープラーニングの大規模並列化

#### (1) 大規模システムの背景と並列化

ディープラーニングの加速化は個々のプロセッサの進化だけでは不十分である。実際、新時代の百層以上にもわたる“深い”ネットワークや、データセットの増加や多様化による次元の増加での計算需要の増加は、プロセッサ側のムーアの法則<sup>15</sup>やアーキテクチャ革新による進化を遥かに上回っている。また、ディープラーニングの適用領域の広範化や、高精度化の要求による学習及び推論用のデータの増加や解像度の進化も、ビッグデータ処理能力の大幅な需要増加を意味し、現状でも何ペタバイトにも上るデータを柔軟に扱うには、小規模システムでは困難である。

このような劇的な需要増加に対して、既にGPUの採用が進んでいることは述べたが、総合的に鑑みればハードウェアアーキテクチャとして最適であるものは、現代の超並列アーキテクチャ型のスーパーコンピュータであることは自明であろう。The Top 500<sup>16</sup>やGraph500<sup>17</sup>での世界の上位ランクのトップスーパーコンピュータは、数千～数万個のマルチコアやメニーコア型のプロセッサを数十～数百ビット/秒の超高速ネットワークで密結合し、更にテラバイト/秒の超高性能のI/Oを備えている。AI用クラウドで採用が進むGPU自身も、グラフィックス以外の計算用途への適用はエンジニアリングワークステーションやHPCが最初であり、現在での多くのトップスーパーコンピュータがGPUやその派生型のアーキテクチャを採用している。クラウドもAIへのシフトが起こるにしたがい、基本的にはスーパーコンピュータをそのインフラストラクチャ内に構築しており、我が国のさくらインターネットの高火力コンピューティング<sup>18</sup>もその一種である。

HPCにおける速度向上のテクノロジーの最も基本となるのは処理の並列化である。よって、プロセッサのいかに関わらず、その内部の並列化と、プロセッサ間の並列化を効率よく果たす必要がある。現在のHPCでは、トップスーパーコンピュータにおける全体の並列性は数百万以上に上り、それを効率よく生かせるアルゴリズムやシステムの研究が過去より中心的な課題として盛んに行われてきた。機械学習、特にディープラーニングの学習フェーズでの並列化も例外ではなく、近年のその隆盛により、多くの超並列化による高速化の研究開発が行われている。

---

※12

“AI Drives the Rise of Accelerated Computing in Data Centers.” NVIDIA Website

<<https://blogs.nvidia.com/blog/2017/04/10/ai-drives-rise-accelerated-computing-datacenter/>>

※13

NEC Brain Inspired Computing 協働研究所ウェブサイト

<<http://nbic.ist.osaka-u.ac.jp/index.html>>

※14

[NECと東京大学、日本の競争力強化に向け戦略的パートナーシップに基づく総合的な産学協創を開始 ～第一弾、AIの共同研究・倫理/制度の検討・人材育成を推進～] NEC Website

<[http://jpn.nec.com/press/201609/20160902\\_01.html](http://jpn.nec.com/press/201609/20160902_01.html)>

※15

大規模集積回路（LSI）の将来予測（集積回路上のトランジスタ数が1.5年ごとに倍になる）

※16

“TOP500 Supercomputer Sites.” Top500 Website

<<http://www.top500.org>>

※17

“The Graph 500.” Graph500 Website

<<http://www.graph500.org>>

※18

「高火力コンピューティング」さくらインターネットウェブサイト

<<https://www.sakura.ad.jp/koukaryoku/>>

ただし、いかにスーパーコンピュータといえども、無制限の演算能力とメモリ空間、アクセス速度が得られるわけではなく、むしろ学習の大規模化に伴い、学習の演算自体ではなく、途中経過である学習パラメータの勾配情報等の通信処理が全体の実行時間の過半を占めるようになる。そのため、高性能計算におけるアプリケーション最適化と同様の方法論でアプリケーションのボトルネックを解析し、当該箇所のアルゴリズムの変更を含む最適化を行うことによって、学習全体の速度及びスケラビリティの向上を行うことが必要不可欠である。

これらの中には、SqueezeNetのようにネットワーク中のフィルタやそこに通すチャンネル数（色数）を削減することで演算数を削減する試みや、半精度浮動小数点数やブール値を含む低精度演算を用いることで、演算・メモリ使用量・通信量を大幅に削減する手法も含まれる。

また、スーパーコンピュータを用いて作られた大規模モデルは推論時にも多くの演算を要求するが、同等の推論をより小規模のネットワークで再現させるModel Distillationのような技術も今後重要になると考えられる。

## (2) ディープラーニングの大規模並列化とその課題

ディープラーニングを行う上での課題の一つは、DNNの学習に極めて長い時間を要する点である。DNNの学習は主に計算律速<sup>19</sup>であり、単一GPUを用いた学習では数週間～数か月程度の時間を要する場合がある。また、最適なDNNの構造ハイパーパラメータは一般に自明ではなく、推論性能の良いDNNを得るためには長時間の学習と手動によるDNNの構造・ハイパーパラメータを交互に繰り返すことが必要とされる。この問題を解決するために、スーパーコンピュータ技術を利用した様々な形態の並列化が試みられている。

第一の並列化は、プロセッサ内部の並列化である。既に述べたように、ディープラーニングの計算カーネルは密行列演算、Winograd法、FFT法に大別されるが、それらはHPCの分野では広範囲なアプリケーションにおいて並列化・高性能化の研究や実装が長年行われてきた分野である。ただし、いくつかディープラーニングに特化するべき部分があり、例えばCNNの行列演算では多くのHPCアプリケーションの場合と異なり、幅が狭く長さが長いいわゆるTall and Skinny Matrix同士の密行列演算が畳み込み演算時に頻出し、その効率の良い並列演算アルゴリズムが開発競争の最先端となっているのが現状である。

次に、プロセッサあるいは計算ノードをまたぐディープラーニングの分散並列化手法は、主に「データ並列」と「モデル並列」に分類される。ここでの「データ」とはデータセットに含まれるサンプル（例：画像認識タスクにおける画像）やそれら进行处理することによって得られるデータ（例：フィードフォワード計算で生じる活性等）のことを表し、「モデル」とはDNNそのものを表す。

- データ並列：

複数の計算機が同一のDNNのパラメータを持ち、異なるデータについて並列に計算を行う手法。各データサンプルの処理によって生じるデータは計算モデル上では独立であるため、これらを通信する必要はないが、DNNのパラメータを同期するための通信が必要となる。

- モデル並列：

複数の計算機が同一のデータを分割して持ち、異なるモデルの箇所について並列に計算を行う手法。同一のデータを複数の計算機が使用するため、高頻度な通信が必要となる。一方で、計算機同士でDNNのパラメータを重複して持つ必要がないため、パラメータ数が大きく単一の計算機のメ

---

※19

律速はボトルネックを意味し、つまり計算律速とは計算能力がボトルネックになっていることを表す。

メモリに入らない場合にも有効である。

データ並列とモデル並列のどちらがより有効であるかどうかは、DNNの構造により異なる。一般に、畳み込みレイヤーはパラメータ数が小さいためにデータ並列が適しているのに対し、全結合レイヤーはパラメータ数が大きいためにモデル並列が適しているといわれる。また、GPUクラスタ（スーパーコンピュータ）で学習を行う場合は、GPU内では多数の内蔵コアを用いてモデル並列を利用し、GPU間では後述する集団通信等を用いたデータ並列を用いるなど、これら二つの手法を併用することが一般的である。

これらの並列化手法を応用した学習手法として以下の例が上げられる。

- パラメータサーバ：

パラメータサーバとは、学習途中のDNNのパラメータを専用のサーバ（群）で一元管理する手法、又はそのサーバのことを指す。学習に必要な演算を行う計算機（ワーカー）は更新量を計算してパラメータサーバに送信し、対してパラメータサーバは受信した更新量を用いて内部に持つパラメータを更新してワーカーに返すことにより学習が進行する。後述する集団通信による手法と異なり通信がワーカー、パラメータサーバ間の一対一通信のみで成立することが利点として挙げられる。また、パラメータサーバはパラメータを複数に分割して分散key-valueストアの要領で複数のサーバに分散させることが可能である。パラメータサーバを採用した例としてはGoogleの「Dist Belief」、Microsoftの「Project Adam」が挙げられる。

- 集団通信による手法：

ミニバッチを計算機に分散させてデータ並列で学習を行い、別々に計算された更新量の総和を集団通信によって計算する手法。ミニバッチSGDではコスト関数が各サンプルの総和又は平均として定義されているため、計算機ごとに計算された更新量の総和又は平均を計算することで、ミニバッチSGDの計算モデルに則った更新が可能となる。ここでの通信では主にall-reduce（全プロセスのデータをリダクションし、結果を全プロセスに複製する通信）が用いられる。この手法を採用した例としてはBaiduの「Deep Image」や「Deep Speech 2」が挙げられる。

集団通信の計算精度は通信速度向上のために低く設定されることがある。例えば、Microsoftが開発しているディープラーニングフレームワークであるCNTKでは、一つの通信値（勾配）を1ビットで通信する手法が実装されている。この手法では、通信値を符号によって0又は1で量子化し、復号する際にはパラメータ行列の列ごとの（正值又は負値の）平均値を用いる。また、量子化によって生じる量子化誤差を次の通信に持ち越すことで、量子化誤差が累積しないようにする。このような精度を下げた場合の通信が学習に与える影響は、計算の精度を下げた場合と同様に自明ではない。

パラメータサーバや一部の集団通信による手法では、非同期な学習が用いられている。非同期学習とは、パラメータの更新やそれに伴う通信中にも、古いパラメータを用いてフィードフォワード計算やバックプロパゲーション計算を行うことを指す。非同期学習は厳密にはSGDの更新則にしたがっておらず、同期学習と比較して収束性や学習終了後の推論性能、再現性が悪化することが予想されるが、一方で計算と通信のオーバーラップにより学習が高速化することが期待される。

### (3) 超並列化に向けた課題

ディープラーニングにおいて超並列化を阻害する一番の原因は、SGDが逐次的な計算と更新を必要とする点である。これにより、同期学習での並列数は（ミニバッチサイズ）×（モデルの分割数）以下に

制限される。更にデータ並列、モデル並列、非同期学習（パラメータサーバを含む）のいずれの並列数を増加させる場合でも以下のような問題が発生する。

- データ並列：

多大なミニバッチサイズを用いる場合、収束性及び収束後の推論性能が悪化することが指摘されている。データ並列の利用によりミニバッチサイズが増加するとエポックあたりの学習速度は増加するものの、エポックあたりの収束速度が低下し、結果として学習速度が低下する可能性がある。

- モデル並列：

一般に一つのレイヤーのフィードフォワード、バックプロパゲーション計算では前（後）のレイヤーの全フィルタにまたがるデータを必要とすることから、モデル並列を用いる場合はレイヤーごとに全対全通信が必要となる。近年では100層を超えるDNNの学習手法が確立されていることから、このようなDNNを学習する場合は通信時間の増加が課題となる。

- 非同期学習：

非同期学習ではコスト関数の勾配の計算途中にパラメータが更新されてしまい、勾配が古くなる「staleness」と呼ばれる現象が発生する。非同期学習ではワーカー数が増加すると通信遅延が増加してstalenessが増加することから、収束性能が悪化する。

一方、ディープラーニングの高速化を考える上で重要なことは、ディープラーニングでは厳密・高精度な計算は必ずしも必要とされないという点である。例として非同期学習は厳密には同期学習とは計算内容が異なるものの、特定の条件では同期学習と遜色ない学習がより高速に行えることが報告されている。また、計算精度を単精度よりも低い精度で行う試みも盛んに行われている。

これらの手法は計算性能を向上させる半面、学習性能への影響については以前未知である。よって、ディープラーニングを今後超並列化するためには、古典的な科学技術計算で必要とされてきた計算性能（1エポック<sup>20</sup>の学習を行うために必要な計算時間; time-to-epoch）と同時に学習性能（満足な条件に収束するために必要なエポック; epoch-to-convergence）の両者を同時に考慮する必要がある。これらのような性能と得られる解の精度を総合的に鑑みる枠組みをHPCでは一般的にUQ（Uncertainty Quantification = 不確実性の定量化）と呼ぶが、その適用による適切な性能モデル化も大きな課題である。

### 1.7.3.5 AI向け高性能インフラストラクチャ

HPCと異なり、AI向けの大規模インフラストラクチャの整備はむしろ民間のメジャーなパブリッククラウドベンダーのほうで始まった。スーパーコンピュータにおいてもシミュレーションの結果や観測データのデータ解析は重要なワークロードであり、一般的な統計的なデータ解析手法は多く適用されてきたが、特にAIに対する取組が民間に対して遅れた理由は定かではない。現状では、特に米国や中国において、パブリッククラウドベンダーがGPUや高速ネットワークなどのスーパーコンピュータ技術を取り入れたAI向けのクラウドインフラストラクチャを急速に拡充させていっている。

一方、スーパーコンピュータ側も従来のシミュレーション一辺倒から、データ解析やAIに少しずつ主軸を移し始めている。しかしながら、GPUや汎用のメニーコアのマシンはクラウド同様対応が進んでいるが、専用プロセッサで構成されているマシンでは、汎用のディープラーニングフレームワークが必

---

※20  
データセット全体を使った一回分の学習のこと。

ずしも動作するわけではなく、ハードルが現状ではまだまだ高い。これらが公的なディープラーニング中心のAI研究における阻害要因となっている。

HPCインフラストラクチャのように、世界のトップランクのスーパーコンピュータが1,000万プロセッサコア数を超え、公的な研究に処しているのに比較し、現状ではAI向けのインフラストラクチャは、計算及びデータに関して、民間のインフラストラクチャの方が豊富である。しかしながら、後者のアクセスはコストが非常に高く、すそ野の広い公的研究の阻害要因となっているのが現状である。

2017年3月現在、Google、AmazonなどのGPUの計算ノードのTFlops辺りの単価は月額2万円以上と高額であり、そのほかの付加コストも相まって、我が国の情報基盤センター等の同様の単価と比較すると数倍のコストがかかる。欧米のスーパーコンピュータ全般や、日本でもHPCI (High Performance Computing Infrastructure) などの全国組織から割り当てられるスーパーコンピュータの利用権は、審査ベースで基本は無料である。一方で、基礎研究ですら、商用基盤で競争力のある研究を行うと数千万円単位の金額がかかる状況とは、非常に疎遠であるといえる。いわんや、それらの基盤を所有するゆえに、競争力のある研究が行えているGoogleやBaiduなどの附属研究所は、AIや機械学習などの国際会議やジャーナルに多くの研究成果を発表しているのが現状である。

このような状況を打開するために、公的なインフラストラクチャの整備も行われ出している。特に、我が国では表5に示すとおり、国立のAIの3センターや、その協力機関などにおいて、AI向けの公的インフラストラクチャの整備が急ピッチで進んでいる。

■表5 我が国のAI専用・AI向け公的インフラストラクチャ

| 導入年月        | システム名   | システム概要  | 理論性能値<br>(ディープラーニング向け精度) | 研究機関                  |
|-------------|---|---|--------------------------|-----------------------|
| 2017年4月     | AAIC<br>(AIST AI Cloud)                                     | NVIDIA Pascal P100 × 8<br>GPUサーバ × 50台                    | 8.4 PFlops               | 産業技術総合研究所<br>AI研究センター |
| 2017年4月     | ディープラーニング<br>解析システム   | NVIDIA DGX-1<br>(Pascal P100 × 8 GPU<br>サーバ) × 25台        | 4 PFlops以上               | 理化学研究所<br>革新知能統合研究    |
| 2017年8月     | TSUBAME3.0 + 2.5<br>+KFC (HPC共用)                            | NVIDIA Pascal P100 ×<br>2160 + K20X × 4080 +<br>K80 × 168 | 65.8 PFlops              | 東京工業大学<br>学術国際情報センター  |
| 2018年3月     | ABCI<br>(AI 橋渡しクラウド<br>AI Bridging Cloud<br>Infrastructure) | 未定 (設計調達中)  | 130~200PFlops            | 産業技術総合研究所<br>AI研究センター |
| 参考<br>2017年 | 高火力コンピューテ<br>ィング  | NVIDIA TitanX +<br>Pascal P100                            | 不明                       | さくらインターネット            |

残念ながら、現状では表5に掲載した以外では、日本のスーパーコンピュータセンター並びにパブリッククラウドベンダーにおいて、AI向けのインフラストラクチャの発表を表明しているところは存在しない。公的なスーパーコンピュータセンターでは、新規の設計調達には時間がかかり、かつ既存のユーザベースを蔑ろにすることも困難で、計算とデータサイエンスが両立するようなストラテジーを長期にわたって積み上げてきた東京工業大学学術国際情報センター (GSIC) のような状況でない限り、即時の対応は困難である。

また、パブリッククラウドも同様であり、機械学習に供する大規模なインフラストラクチャは実質的にスーパーコンピュータをIDCに導入する必要があるが、電源供給・冷却・ネットワークの高密度実装、更には運用面において、対応が大変困難である。例えば、AI指向のスーパーコンピュータである東京工業大学TSUBAME3.0は、一ラックあたりの熱密度が最大61KWであるが、これは一般IDCのラック当たりの3~6KWと比較すると10~20倍にも相当し、このようなインフラストラクチャを通常のIDCに入れるのは困難である。

2018年3月稼働を目指して開発・整備が進められている、AIRCのABCI（AI橋渡しクラウド、AI Bridging Cloud Infrastructure）の一つのミッションは、この事態を打開することにある。ABCIの目標としては、①我が国に、ディープラーニングを中心とした計算とデータを両立させた、米国のパブリッククラウドベンダーに匹敵する130ペタフロップス以上の大規模AIインフラストラクチャを整備し、官民のAI研究者に提供すること、②そのようなインフラストラクチャの構築・運用のシステム技術を研究開発すること、③そのインフラストラクチャ技術を速やかかつ継続的に民間移転し、我が国のAI技術の全般的な研究開発のハブとして機能すること、などである。

そのなかでも、AIに向けたデータセンターの構築・運用の研究開発は中心課題であり、スーパーコンピュータで培われた高密度・高信頼・高性能・高効率の計算とデータ処理技術を、いかに安価かつIDCフレンドリーなインフラストラクチャとして技術移転していくかが、大きな目標となる。そのため、ABCIを開発しているAISTは、経済産業省産業技術環境局とともに、東京大学と「(仮称) グローバルAI研究拠点」に関する協定を締結し、東京大学柏キャンパスに新たなAI向けのデータセンターを構築し、日本の民間IDCのAI施設導入の模範的なショールームとする事業を進めている。いわば、TSUBAME3のようなスーパーコンピュータ専用の高密度実装技術を、IDC向けにほとんど性能を犠牲にしない形でコモディティ化し、全国のIDCへの速やかな普及を目指す予定である。

米国でも各研究機関のパブリッククラウドベンダーとの協業が進んでいるが、国立科学財団（NSF）、エネルギー省（DoE）などが2018年以降に向けて、AI・ビッグデータ指向のインフラストラクチャの整備を検討中である。

#### 1.7.3.6 今後：HPCとの融合か離散か

以上、現状のAI向けのハードウェアのインフラストラクチャや技術進展、更には今後のロードマップを俯瞰した。ディープラーニングを中心としたAIの急速な進展は、単に分野内の研究開発だけでなく、HPCのシステム技術が多く転用され、それがAI向けにカスタマイズされ、アルゴリズムとのコ・デザインでもたらされていると言える。HPC向けの「エクサ」(10の18乗) フロップスのスーパーコンピュータが登場するのは2020～21年以降と言われているが、AI向けのスーパーコンピュータは、縮退精度を活用してより早く登場する見込みである。

例えば、米国オークリッジ国立研究所（Oak Ridge National Laboratory）の「Summit」スーパーコンピュータは2018年に稼働するが、最新のNVIDIA Volta GPUを心臓部分としたAI向けの性能は、800ペタフロップス以上と言われており、エクサ級と呼んで差し支えないであろう。更に、それらのマシン上の莫大なAIの能力を生かして、シミュレーションの一部をAIによるデータ予測で補完しよう、といった研究もいくつか始まっていて、AIとHPCの距離はアルゴリズムやアプリケーションレベルでも近づいているとも言える。

一方、今後このようなAIとHPCの協業が続くのか、あるいは分離するのか、という議論も存在する。例えばディープラーニングの精度要求を更に下げて高速化しよう、という研究は多くあるが、これら縮退された数値精度が他のHPCアプリケーションで活用できるかはまだ定かではない。同様に、更にデータフローがAIに特化された場合や、ニューロモーフィック計算のように、通常のHPCワークロードの計算モデルとしての適用性が定かではない技術が台頭してきたときに、それらのHPCとの融合は困難になる可能性もある。今後の高性能アーキテクチャの設計のためには、一般HPCと、よりマーケットが大きくなるAIが、どこが共通で、どこが異なるか、という技術的な探求が早急に求められていくであろう。

## 1.7.4 推論用のインフラストラクチャと計算デバイス

### 1.7.4.1 推論用のインフラストラクチャと計算デバイスのトレンド

推論時のインフラストラクチャや計算デバイスに求められる性能は、学習時とは大きく異なる。特に、ネットワーク上のデータのトラフィックから課せられる制約や、分野によっては処理の時間的遅れ（レイテンシ）に対する制約、使用可能なメモリ量に対する制約、消費電力に対する制約等が、学習時とは異なる形で要請される。

データトラフィックの観点からは、推論のために世の中に流通する全データをクラウド等で集中管理することは、非現実的であり、エッジ、あるいはフォグでのコンピューティングが重要となると考えられる。今後IoTの社会実装が進んだ場合、世の中に流通するデータ量が増大し、2020年には40ゼタバイトに到達すると考えられている。我が国のデータ流通量も、2005年の約1.6エクサバイトから2014年の約14.5エクサバイトまで、約9.3倍に伸びており、今後も増大トレンドは変わらないと考えられる。

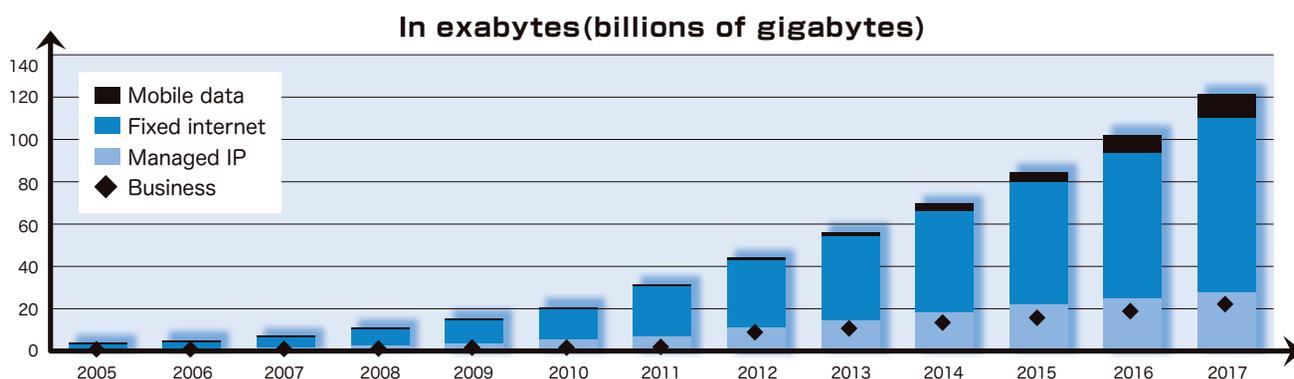


図37 インターネットトラフィックの拡大<sup>21</sup>

ロボット、自動運転等、即時的な応答が求められる応用分野では、情報処理に対するレイテンシに対する要求が厳しくなる場合が多い。例えば、Googleのデータセンターにおける検索時間の要求は7msec、30fps<sup>22</sup>の動画処理では33.3msecである。その場合、推論のためにデータをクラウド等へアップロードすることは時間的遅延が大きくなってしまうため、エッジ、あるいはフォグでの計算処理が必要となる。また、データ送受信の通信コスト、信頼性の観点からも、エッジにおける処理が望ましい。

### 1.7.4.2 組み込み型プロセッサ：推論の高速化・省エネルギー化

現在、ディープラーニングが活躍しているエンドユーザアプリケーションは、多くの場合、推論も学習もデータセンターに存在するバックヤード系の大規模なクラウドやスーパーコンピュータで行うのが主流である。送付するデータ量が少なく、かつある程度の時間が許容できる場合は、セミリアルタイムのアプリケーションですら適用が可能で、代表的にはBaiduのスマートフォンでの「リアルタイム」の音声認識・自動翻訳などが挙げられる。

しかしながら、自動運転やスマートシティ、ロボット制御などのリアルタイム系のIoT系アプリケーションでは、クラウドにデータを送付することなく、学習済みのネットワークを用いた画像や音声の推論・認識をエッジのデバイス側で行うことが求められる。

DNNを用いた推論では、少ない消費電力で学習後のDNNのフィードフォワード計算が必要十分な精

※21  
OECD “Data-Driven Innovation For Growth and Well-Being,”  
Interim Synthesis Report.

※22  
frames per secondの略。

度で行えることが必要となる。このような推論はIoT、ロボット、自動運転車に代表されるハードウェア的に独立した場所での用途が想定されるため、スーパーコンピュータを用いた学習のように大電力を計算に用いることは容易ではない。よって、このような推論を行うために、5~15Wといった組み込み系レベルの低消費電力でフィードフォワード計算を行う用途に最適化された専用チップが開発されている。これらのチップは電力を極限まで削減するために、学習よりも低い精度で計算を行う機能が実装されているものもある。推論は学習と違い反復的な計算ではなく、出力もクラス分類等の計算誤差が無視されやすいことが多いため、このような低精度での計算も依然実用的であると考えられている。

- NVIDIA DRIVE PX (Tegra) :

「Tegra」とはNVIDIAが開発しているモバイル/IoT向けのプロセッサシリーズであり、ARMプロセッサとGPU等がSoC (System on Chip) として搭載され、様々な省電力化の機構が組み込まれている。NVIDIAは自動運転を想定したプラットフォームである「DRIVE PX」シリーズでTegraチップを採用している。最新の「NVIDIA DRIVE PX2」では、一体化されたSoCのTegra (Parker) チップの10W版から、最大4個のPascalアーキテクチャのGPUを搭載している高機能版まで、自動運転の度合いによって複数の種別のものが提供されており、複数のカメラやセンサからの入力を、最大24テラフロップスの性能のDNNを用いて処理できるとしている。

- FPGAによる実現 :

FPGA (Field Programmable Gate Array) は特定の計算を電子回路レベルで実装できるため、同等の計算をGPUで行う場合よりも低消費電力であるといわれる。またディープラーニングは積和演算が主である計算であるために、特に有効である。スヨグ・グプタ (Suyog Gupta) 氏は、固定小数点型を用いたGEMM演算に特化した演算器をXilinx Kintex325T FPGAを用いて実装した。少ないbit数の固定小数点型を用いたディープラーニングでの、過度なアンダーフローによる丸め誤差を防ぐため、確率的に丸め処理を行う機構の擬似乱数生成回路等を用いて導入した。ディープラーニングに必要な計算精度は未だ自明ではなく、このような従来の計算機では計算効率が低下する特殊な計算手法が必要となる場合がある。よってFPGAを用いて加速を行うことは、今後の組み込み型のディープラーニング用アクセラレータとして活躍する可能性がある。

- ディープラーニング用ASIC:

GPUベースのSoCは汎用性が高く、様々なネットワークやアルゴリズムが容易に適用できるが、それらがある程度固定化した場合は、やはり専用のASIC (Application Specific Integrated Circuit) の電力効率はGPUを凌駕する。多くの研究やスタートアップなどが早くから組み込み専用のASICを提案している。一例としてティエンシー・チェン (Tianshi Chen) 氏はディープラーニングに必要な積和演算に特化したアクセラレータ「DianNao」を提案した。DianNaoは485 mWの消費電力で452 GOP/s (ただしOPは16-bit固定小数点数の積和回数) の演算が行え、1Wあたり1Topsと、同世代のTegra K1と比べて約10倍の電力効率を達成している。

全体的に俯瞰すると、IoT向けの推論が汎用性の高いGPU型になるのか、あるいはASICのように専用化するのか、あるいは中間的なものになるのかの決着は付いていない。IoTのエッジデバイスは大量生産される可能性が高いため、通常では他のIT分野同様にASIC化によるコストメリットや省電力化が非常に効果的なはずである。

しかしながら、現状では、後述のディープラーニング専用プロセッサ同様、学習アルゴリズムの高度化・高速化の発展が非常に目覚しく、特定のASICを開発してもそれらの進化に追従できず、早期に陳腐化してしまう可能性も高い。よって、しばらくは主に上記三つのプラットフォームが切磋琢磨する状

況が続くと予想される。

### 1.7.5 エッジ、フォグ、クラウドの役割の最適化

学習と推論の両方を実施する場合には、その双方を考えて、エッジ、フォグ、クラウドのどこで、何を、どの程度の頻度で計算するかについて、最適化が必要となる。基本的には、多くの末端のデバイスからのデータをなるべく統合して学習を行ったほうが精度向上のスピードアップが期待できる。そのため、推論の計算処理を随時行いつつ、学習のためのデータはエッジから見て上層（フォグ、クラウド）にアップロードし、上層で学習を行った後に、学習後のモデルをエッジにダウンロードして推論に利用することが考えられる。

ただし、全データを上層にアップロードするのでは結局トラフィックの問題が生じる。そのためには、学習に利用すべきデータとそうでないデータを峻別する技術が必要となるだろう。その最適化された姿は応用分野に依存するが、例えば、推論精度が悪いデータのみを峻別して学習用データとしてアップロードすること等が仕組みとして考えられる。

上層におけるクラウド側には、学習済みモデルのレポジトリと、モデルのアップデートを行う機能が求められる。民間のクラウドサービスでも、学習のためのインフラ提供機能だけでなく、上記の様な機能も合わせて提供する会社は増えるであろう。

また、エッジやフォグで利用される推論用の計算デバイスには、学習用の計算デバイスに比較して、低消費電力であることが求められる場合が多い。したがって、消費電力の大きいGPUではなく、搭載する計算ロジックを書き換えることができるFPGAや専用チップのニーズが高まると考えられる。Intelは、FPGAを主力製品とするAlteraを買収し、CPUとFPGAを同一パッケージや同一ダイに統合した製品の開発を行っており、Xilinxは画像処理に特化した開発環境reVisionを発表している。これらはFPGAで推論に特化した回路を想定しており、学習までには対応していない。同様なツールはサードパーティーからも発表・リリース予定があり、例えばTERADEEP（米国）、DeePhi Tech（中国）は既にFPGAを採用した推論アクセラレータをリリースしている。日本でも同様のリリースが行われるであろう。

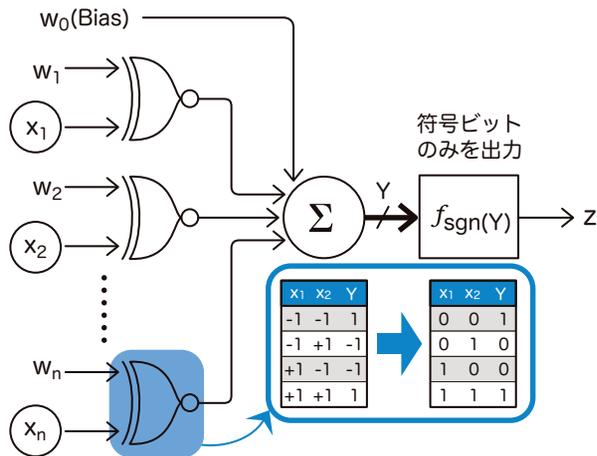
ディープラーニングの学習や推論において、必ずしも倍精度計算は必要なく、8ビット、4ビット、更には1ビット（2値化）／2ビット（3値化）での計算も可能との研究結果が相次いでおり、消費電力や計算性能の観点からFPGAを用いたプロトタイプの研究開発が進んでいる。近年の研究開発動向を表6に示す。興味深いのはIntel、Xilinxがともに1ビット／2ビットの研究開発を進めていることであり、近い将来これらの精度が実用化される可能性は高い。

表6 FPGAにおける2値化/3値化DNNの開発動向<sup>23, 24</sup>

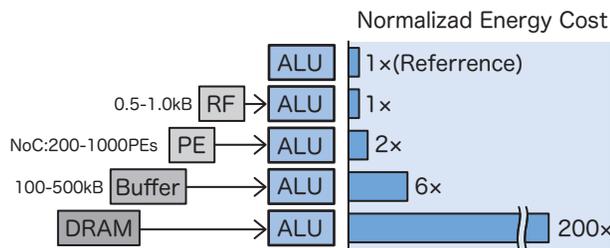
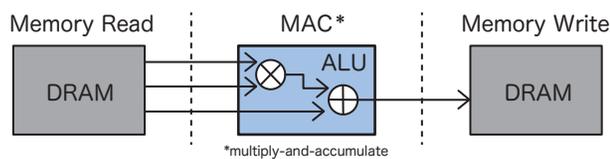
| FPT2016（2016年12月開催）  |
|--|
| E. Nurvitadhi (Intel) et al., "Accelerating Binarized Neural Networks: Comparison of FPGA, CPU, GPU, and ASIC" |
| H. Nakahara et al., "A Memory-Based Realization of a Binarized Deep Convolutional Neural Network"              |
| ISFPGA2017（2017年2月開催）  |
| Ritchie Zhao et al., "Accelerating Binarized Convolutional Neural Networks with Software-Programmable FPGAs"   |
| Y. Umuroglu (Xilinx) et al., "FINN: A Framework for Fast, Scalable Binarized Neural Network Inference"         |
| H. Nakahara, H. Yonekawa, "A Batch Normalization Free Binarized Convolutional Deep Neural Network on an FPGA"  |
| Y. Li et al., "A 7.663-TOPS 8.2-W Energy-efficient FPGA Accelerator for Binary Convolutional Neural Networks"  |
| G. Lemieux, "TinBiNN: Tiny Binarized Neural Network Overlay in Less Than 5,000 4-LUTs"                         |

※23  
"The 2016 International Conference on Field-Programmable Technology (FPT '16)." ICFPT2016 Website  
<<http://www.icfpt2016.org/>>

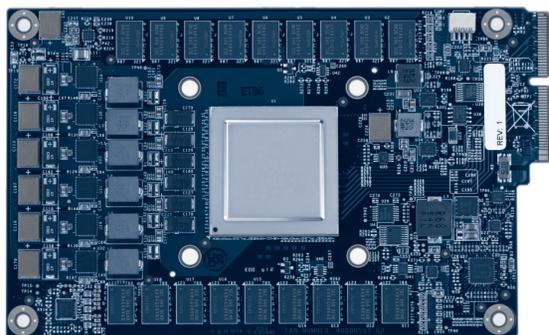
※24  
"25th ACM/SIGDA International Symposium on Field-Programmable Gate Arrays." FPGA2017 Website  
<<http://isfpga.org/>>



■ 図38 2値化ニューラルネットワークの概要



■ 図39 演算器と各種メモリの電力コスト<sup>25</sup>



■ 図40 TPU搭載ボード<sup>26</sup>



■ 図41 TPU搭載サーバ<sup>27</sup>

図38に2値化ニューラルネットワークの概要を示す。通常、GPUやCPUではニューラルネットワークの基本演算である積和演算を8ビットや16ビットの精度で行う。2値化、すなわち1ビット精度でこれを行うと、最も電力・面積を必要とする乗算回路をXNORゲートで実現できる。したがって、大量の積和演算回路を1チップ上に集積することができる。もう一つの利点は、ニューラルネットワークの重みと計算結果を格納するバッファ（メモリ）のサイズを大幅に小さくできることである。ニューラルネットワークの構成によっては全てのバッファを1チップに格納できるので、DRAM（Dynamic Random Access Memory）のようなオフチップは不要になる。

図39に演算器と各種メモリの電力コストを示す。積和演算回路（Arithmetic Logic Unit; ALU）と各種メモリの距離に電力は比例する。2値化により全てをオンチップに格納できればDRAMに要する電力をバッファやレジスタファイル（RF）で必要な電力に抑えることができる。したがって、2値化は電力削減にも貢献する。また、オンチップメモリで格納できれば、演算器チップとオフチップの通信ボトルネックも解消できる。

※25 Massachusetts Institute of Technology, Energy-Efficient Multimedia Systems Group, The Eyeriss Project, “Tutorial on Hardware Architectures for Deep Neural Networks”

※26 「GoogleのTensor Processing Unit (TPU)で機械学習が30倍速くなるメカニズム」 Google Cloud Platform Japan Blog Website <<https://cloudplatform-jp.googleblog.com/2017/05/an-in-depth-look-at-googles-first-tensor-processing-unit-tpu.html>>

※27 同上。

したがって、低精度によるオンチップ化は今後ますます研究開発が進むとみられている。画像の物体認識を行う際、GPU (NVIDIA Tesla K40) では235Wかかるところ、2値化を導入したFPGAでは4.7Wで可能になる。また、モバイルGPU (NVIDIA Jetson TK1) と比較して2値化を導入したFPGAは15倍高速に処理できることが報告されている[7]。

学習時と推論時で必ずしも同じデバイスを利用する必要はなく、むしろそれぞれの用途に特化したデバイスとすることにより高い計算性能や低い消費電力を実現する試みもある。Googleはディープラーニング用チップであるTPU (1.7.1項、図40、図41参照) を開発し、既に利用を開始していることを2016年5月に発表した。消費電力を従来のデバイスに比べて10分の1程度に抑えられたとともに、Googleのディープラーニング向けオープンツールであるTensorFlowとの親和性を高め、開発者はハードウェアの違いを意識せずに利用できるようになっているとしている。また、韓国ではKAISTの(イチョン・ユ) 氏Hoi-Jun Yooらのグループが、CMOS (Complementary MOS) を用いたディープラーニングの推論用のデバイスの開発を行っている。

画像処理などディープラーニングの適用が進んでいる一部の分野については、エッジ側での推論に係るハードウェアとソフトウェアの構成に関して実装例が提案されつつある。実装の方向性として、現状のCNNの枠組みを前提としてハードウェアを最適化してしまう方向と、専用化する部分とGPU、FPGAを一部利用して柔軟性を残しておく方向がある。現状のディープラーニングの研究が日進月歩である状況を考えると、研究の現状を前提とするよりも、今後の発展部分を探り入れる柔軟性を残しておく後者は、最高性能は劣る可能性があるものの、適用分野の幅広さや息の長い開発を見込むことができるだろう。

## 1.7.6 次世代AIインフラストラクチャ・ハードウェア

ディープラーニングによるAIが大きな成功を収めつつあることを背景として、ディープラーニングに向けたアーキテクチャを備えたプロセッサ、あるいは脳型コンピュータと呼ばれるアーキテクチャを構想し、実装しようとする動きが各所で起こっている。この項では、主に、脳を参考にしたモデル<sup>28</sup>に基づいて構築されるディープラーニングのためのニューラルネット計算向きアーキテクチャについて概観する。

### 1.7.6.1 AI向き専用マシンの歴史

コンピュータは、プログラムの入れ替えによってどんな問題にも対処できる万能マシンとしての性能を価値としてきた。しかし、汎用機は大型で高価であることから、特定の問題向きの専用機であれば、より小型で安価な解があるはずだと考えられることはしばしばあった。AIが米国から世界に広がり始めた頃は、AIプログラムとは、Lispなどの記号処理に適した言語で書かれたプログラムのことであり、記号処理に向けたアーキテクチャが構想された。1980年頃には、Lispマシンが商用化された。Lispマシンは、タグ付けされたデータとメモリ管理に適した構造を持つが、その内容は、ノイマン型計算機であり、記号処理向きの命令をマイクロコードで実現していた。

1982~1992年に実施された日本の第5世代コンピュータもAI向きのコンピュータを目指した。AIの本質は論理であるとの考えから、論理型言語Prolog向きのコンピュータが実装されたが、内容はやはりノイマン型計算機にProlog向きのプリミティブをマイクロコードで実装していた。1990年頃からの誤差逆伝播学習の発明に基づく第2期AIブームでは、当時流行していた計算プラットフォームであるワー

※28

Hodgkin-Huxleyのパルス神経伝達モデル、Hebbの学習則、McCulloch-Pittsのニューロンモデル、Hubel-Wieselの神経階層仮説などがある。

クステーションに増設ボードとして付加できるニューラルネットワーク計算のアクセラレータが発売されたが、大きな勢力となることはなかった。

汎用計算機に対抗して開発されたAI専用のコンピュータであるが、AIに限らず、専用計算機が成功するのはまれである。上記のAIコンピュータの中では、Lispマシンは数千台販売されたが、ほかには大きなマーケットを形成していない。大きなマーケットを占めることができた専用プロセッサは、GPGPUだけであろう。専用プロセッサは、その名のとおり、応用領域を限定しているため、汎用計算機に比べて小さな市場にとどまるのは当然である。後述するように、GPGPUはAI向けにも重要な地位を占めているが、GPGPUはその名のとおり、GPUという専用プロセッサをGP=general purposeに適用できるようにしたために利用が進んだ。同様に、FPGAも汎用性の高い専用プロセッサの基材であるために一定の市場を持つことができたといえる。

このように考えると、今盛んに行われているAI向けのニューラルネットワークプロセッサが、成功を収める可能性については未知数である。しかし、今回のAIプロセッサブームは、以前のAIコンピュータブームとは異なる面がいくつもあるので、大成功する可能性も秘めている。それについては後述することにして、まず、現在のニューラルネットワークプロセッサの実例を概観する。

### 1.7.6.2 AIプロセッサの分類

従来型のコンピュータに対するAIコンピュータ、脳型コンピュータの位置付けをノイマン型、非ノイマン型コンピュータの区別とともに図42に示す。AIの情報処理に向けたコンピュータをAIコンピュータとして黒枠で示している。この中には、ニューラルネットワークだけでなく、例えば論理計算に向けたコンピュータも含まれる。現代の計算機を構成する電子回路を論理回路と呼ぶことから分かるように、ノイマン型コンピュータは、論理計算の機能があり、したがって、前述の第5世代コンピュータもノイマン型のAIコンピュータと位置付けられる。

現在注目を浴びているAIコンピュータは、青枠で示したニューラルネットワーク型、あるいはニューロモーフィック型である。現代のコンピュータは、計算論的に万能マシンであるので、ディープラーニング計算をPCやスーパーコンピュータ、あるいはGPGPUで実行させることが可能である。特にGPGPUは、数千を超えるコアを備えて高い並列性を発揮できるので、ノイマン型のなかでも非ノイマン型に近いアーキテクチャを持つ。

脳型コンピュータでは、シナプス結合の強度が、記憶の役割を果たす。その記憶の実現方法には、デジタルコンピュータと同様にDRAM等のメモリを用いるデジタル型と、メモリスタあるいはReRAM<sup>29</sup>のような電気抵抗変化を記憶できるデバイスを用いるアナログ型がある。両者のシナプスとニューロンの細胞体に対応するアナログとデジタルでの実現回路例を図43に示す。

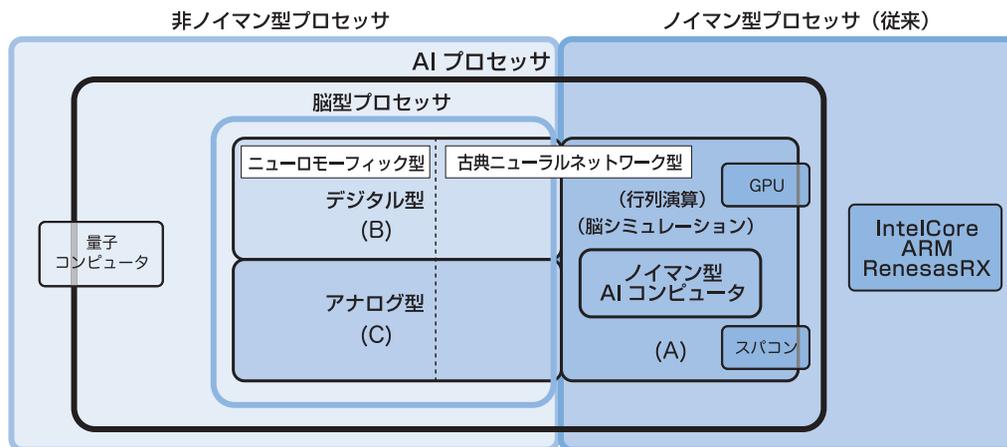
### 1.7.6.3 スーパーコンピュータとGPUによるニューラルネットワーク計算

本格的なニューラルネットワークプロセッサの前に、スーパーコンピュータとGPGPUによるニューラルネットワークのシミュレーションについて述べる。スーパーコンピュータとGPGPUは、PCやウェブサーバなどから見ると特殊なハードウェアであるが、ソフトウェアによってニューラルネットワークシミュレーションを行う点では、PCによる実行と違いがない。現在、機械翻訳やゲームなどで高性能を発揮しているのは、これら通常型のAIプロセッサである。

ニューラルネットワークのシミュレーションには、表7のような種類のソフトウェアがよく使用され

※29

抵抗変化型メモリ (Resistive Random Access Memory)。電気抵抗の変化を利用したメモリ。



【語句定義】

ノイマン型プロセッサ：一つのメモリにデータとプログラムを内蔵、メモリから命令を逐次取り出しプロセッサで実行

非ノイマン型プロセッサ：ノイマン型以外

AIプロセッサ：機械学習、深層学習の演算処理を行うハード（プロセッサ、メモリ等の集合体）

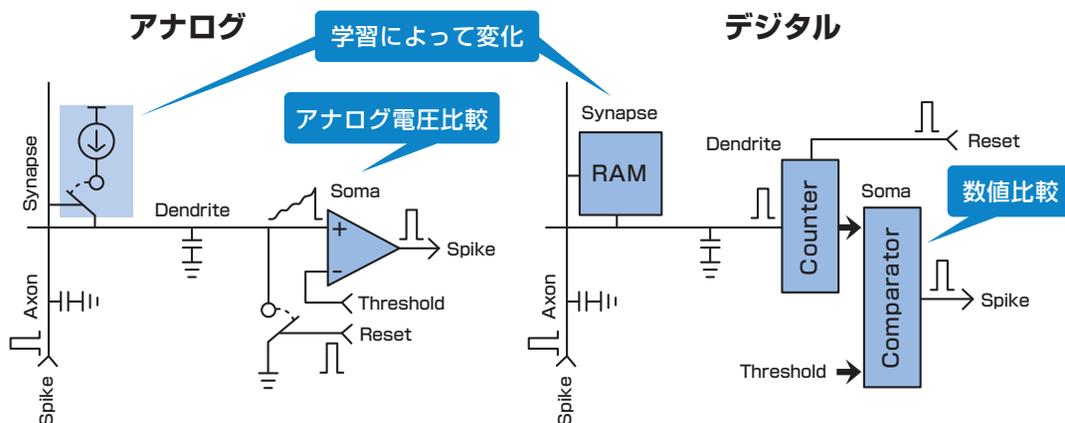
ノイマン型 AI プロセッサ：【図中 (A)】

脳型プロセッサ：AIプロセッサの中で、ニューロン・シナプスのような脳機能を使った演算処理を行う

デジタル型脳型プロセッサ：ニューロン機能をデジタル素子で模擬する脳型プロセッサ【図中 (B)】

アナログ型脳型プロセッサ：ニューロン機能をアナログ素子で模擬する脳型プロセッサ【図中 (C)】

■図42 AIコンピュータ、脳型コンピュータの位置付け<sup>30</sup>



■図43 シナプスとニューロン細胞体の実現回路例<sup>31</sup>

ている。これらの多くはオープンソースである。ソフトウェアとしての実績が蓄積すると、それをLSI化して高速化しようとする動きが出てくる。例えば、GoogleのTensorFlowは、ニューラルネットワークソフトウェアとしても定評があるが、Googleは、TPU (TensorFlow Processing Unit) としてハードウェア化を図っている。テンソル (tensor) というベクタ、マトリクスなどのデータの並べ方を一般化した数学的概念をその名に冠していることから、ニューラルネットワークに限らず非常に汎用的な数学ライブラリをベースにしていることをうかがわせる。

日本では、スーパーコンピュータ「京」を保有する理化学研究所が、2013年8月に、10兆個の結合を持つ神経回路のシミュレーションに成功したことを発表している<sup>32</sup>。ニューロン数は17.3億個であり、小型霊長類の全脳の規模に達している。

※30  
NEDO技術戦略センター作成

※31  
文献[8]より作成。

<[http://www.riken.jp/pr/topics/2013/20130802\\_2/](http://www.riken.jp/pr/topics/2013/20130802_2/)>

※32  
「京(けい)」を使い10兆個の結合の神経回路のシミュレーションに成功ー世界最大の脳神経シミュレーションー」『広報活動』理化学研究所ウェブサイト

■表7 ニューラルネットワークのシミュレーションソフトウェア<sup>34</sup>

| 名称                        | 開発者、頒布                       | 言語、プラットフォーム                                    | 普及状況   |
|---------------------------|------------------------------|--|--|
| Tensorflow                | Google (米)<br>オープンソース        | Linux、MacOS、GPU 可<br>Python、C++                | ベンチマークも含め、標準<br>Google 翻訳などにも使われる  |
| Torch                     | DeepMind (Google)<br>オープンソース | Lua (言語)、Google<br>Cloud Platform              | AlphaGO が使用、並列化が強力   |
| Chainer                   | PFN (日)<br>オープンソース           | Linux、GPU 可、<br>Python                         | コミュニティが、ほぼ国内のみ。<br>画像処理から自然言語処理、ロボット制御<br>(NEDO 「次世代人工知能ロボット中核技術<br>開発事業」で拡張中) |
| Caffe                     | UC Berkeley (米)<br>オープンソース   | Windows、MacOS、<br>Linux、GPU 可、C++、<br>(Python) | 最も古く、コミュニティが大きく、<br>サポート OS が多い。画像認識専用で高速                                      |
| PyLearn2<br>(Theano)      | Montreal 大 (加)<br>オープンソース    | Windows、MacOS、<br>Linux、GPU 可、<br>(Python)     | Caffe に次いで歴史がある  |
| Neural Network<br>Toolbox | Mathworks (米)<br>商用          | Matlab の一部、GPU 可                               | 制御システムや組み込みソフトウェアの<br>開発ツールである Matlab のモジュール<br>と組み合わせられる                      |

■表8 ニューラルネットワーク計算のためのプロセッサチップ(ノイマン型)<sup>34</sup>

| 開発者  | 国        | 名称                            | アーキテクチャ   | 実績・特徴  | 出荷時期                 |
|--|----------|-------------------------------|---|--|----------------------|
| NVIDIA   | 米国       | Pascal                        | 153 億個トランジスタ、16nm<br>FinFET 16GB の DRAM を<br>720GB/s 接続 | AI 研究のスタンダード、産業<br>技術総合研究所 ABCI にも採<br>用予定                                       | 出荷済み                 |
| Google   | 米国       | TPU Tensor<br>Processing Unit | Google 製 NN シミュレータ<br>TensorFlow のハードウェア化               | 低精度の浮動小数点演算で高<br>速化<br>Google 翻訳、AlphaGo、ス<br>トリートビューやクラウドサ<br>ービスで採用中           | 外販しない                |
| Microsoft  | 米国       | Catapult                      | 17 万の ALM と、1,600 の DSP<br>を集積した ALTERA 製 FPGA          | Bing サーチに使用  | 未公表                  |
| デジタルメディア<br>プロフェッショナル<br>産業技術総合研究所 <sup>36</sup> | 日本       | EP1                           | GPU のシェーダプロセッサに<br>DNN 高効率処理 HW を接続                     | 1W 電力により、広く組み込<br>みシステムでの適用を目指す  | 2025 年               |
| 富士通  | 日本       | DLU                           | 京の成果の Tofu インターコネク<br>トで 10 万チップの接続                     | 未公表  | 2018 年               |
| Deep Insights<br>(PEZY グループ)                     | 日本       | DI-1                          | 7nm プロセス、100 万コア  | チップ間の磁界結合、ノード<br>間の Si フォトニクス技術を用<br>いた光通信 100TB/秒、3D<br>積層 DRAM、液浸冷却などの<br>実装技術 | 2018 年               |
| 理化学研究所 <sup>37</sup>                             | 日本       | 未公表                           | 低精度計算と高並列化、NVIDIA<br>T100 の 70 倍が目標、40nm<br>TSMC で製造    | 半精度化により倍精度の<br>16 倍を達成する   | 2017 年度チップ<br>試作     |
| Intel (Nervana)                                  | 米国       | Lake Crest                    | HBM2 独自のインターコネクト、<br>1TB 秒                              | 深層学習フレームワーク<br>“Neon” 用意   | 2017 年 特定顧<br>客向け出荷  |
| Graphcore  | 英国<br>韓国 | IPU                           | 未公表   | DNN モデルをプロセッサ内部<br>に保存   | 2017 年 PCI カ<br>ード出荷 |

GPUは、もともとグラフィックス計算のためのプロセッサであった。画面中のたくさんの頂点に対する座標変換や、ポリゴンへのテクスチャマッピングを高速処理するためにSIMD並列計算する機能を

※33 MMX (Multimedia Extensions)、SSE (Streaming SIMD Extensions)はIntelが開発したCPUの命令セット。

※34 各種公表資料よりNEDO技術戦略研究センター作成。

※35 NEDO「戦略的エネルギー技術革新プログラム」でPEZYグループのPEZY Computing (日本)が開発し、理化学研究所に設置した「Shoubu」(菫蒲)が、2016年にスーパーコンピュータのエネルギー効率ランキングである「Green500」で3期連続の世界1位を獲得した。

備えている。このSIMD計算のことを「NVIDIA」は、Single Instruction Multiple Threadと呼んで、インテルアーキテクチャのMMX、SSE<sup>33</sup>と区別している。GPUの並列計算機能をグラフィックス以外にも応用するために、NVIDIAは、CUDAというC言語を拡張したプログラミング言語、プログラミング環境を提供し、General Purpose GPU、すなわちGPGPUとしての計算モデルを構築した（表8）。

GPGPUは、頂点の座標変換のための積和演算が得意な構造をしている。すなわち、条件分岐が混じらない単精度浮動小数点演算でよい性能を上げる。単精度の積和演算は、ニューラルネットワークの主要な演算であるため、ニューラルネットワークシミュレーションの高速化にも大きな効果を発揮する。x86などのPCやエンタープライズ系CPUでは、2000年頃まで、単精度より遅い倍精度浮動小数点演算を単精度と同じ計算速度にすることに努力が払われたが、グラフィックス計算では、たかだか12~16ビットの計算精度で足りるので、GPUは、32ビット単精度どころか、16ビットの半精度の計算速度を上げることに注力されている。ニューラルネットワークの順方向計算には、16ビットより更に短い8ビット、極端な場合は、1ビットでよいとする説がある。この計算精度の節約は、並列度の引き上げと省電力性の改善のためのキーテクノロジーである。

日本でも理化学研究所、PEZYグループのDeep Insightsなど、複数の機関が短精度化を絡めたプロセッサ開発を進めている<sup>35</sup>。短精度計算は、順方向計算には適用できるが、学習のためには、係数の勾配を計算できなければならないので、精度を落とせないことに注意が必要である。

表7に掲げたニューラルネットワークソフトウェアは、ほとんどが、CPUだけでなくGPGPUで実行するコードを生成する。GPGPUは、ニューラルネットワークの重要な計算プラットフォームとなっている。

#### 1.7.6.4 デジタル型のニューラルネットワークプロセッサ

スーパーコンピュータやGPGPUによるニューラルネットワークは、汎用のコンピュータをニューラルネットワーク計算にも応用しようとする試みであるが、本項で述べるのは、ニューラルネットワーク計算のために設計、試作されたプロセッサチップである（表9）。

■表9 ニューラルネットワーク計算のためのプロセッサチップ(非ノイマン型)<sup>34</sup>

| 開発者                                    | 国  | 名称        | アーキテクチャ   | 実績・特徴                                   | 出荷時期           |
|--|----|-----------|---|---|----------------|
| IBM                                    | 米国 | TrueNorth | データフロー型ニューロン100万個、シナプス結合2.56億個、54億トランジスタ、SRAM   | 順方向認識処理のみチップ当たり70mW、16チップ接続可能           | 2014年発表        |
| Wave Computing                         | 米国 | DPU       | 独自のデータフロー型、16nm FinFET、16,000コア、32GB、512GB DDR4 | TensorFlowを初期状態でサポート                    | 2017年4Q量産      |
| 東芝                                     | 日本 | TDNN      | 神経細胞の興奮、結合係数を1ビットに圧縮し、32kシナプスを1.9mm角に集積         | 興奮レベルをゲート遅延で表現し、可さする信号処理で極端な省電力化        | 2016年11月学会発表   |
| トプスシステムズ <sup>38</sup><br>NEDO 次世代人工知能 | 日本 | SMYLEdeep | データフロー型 8コア 75MHz                               | 低い動作周波数で消費電力を抑えつつ、最大480fpsで超高速画像認識処理が可能 | 2017年2月プレスリリース |

表9の中では、1.7.1項で述べたIBMの「TrueNorth」が傑出している。4,096個のプロセッシングエレメントによって100万個のニューロン、2.56億個のシナプス結合の並列処理を実現し、28nmプロセス<sup>34</sup>

※36  
NEDO「IoT推進のための横断技術開発プロジェクト」で開発中。

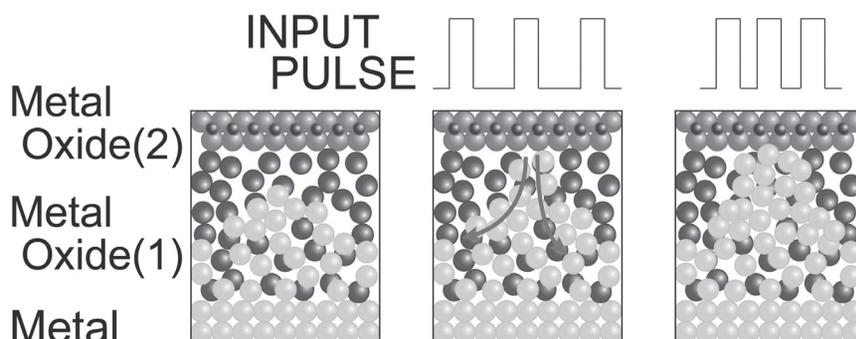
※37  
NEDO「次世代人工知能・ロボット中核技術開発」事業で開発中。

※38  
NEDO「IoT推進のための横断技術開発プロジェクト」で開発中。

で1チップに集積した。16個を組み合わせたことが可能である。省電力性能も高く、400×240のビデオを30fpsで認識するのに要する電力は63mWに過ぎない。

### 1.7.6.5 アナログ型のニューラルネットワークプロセッサ

デジタル型ニューラルネットワークでは、シナプスの結合強度の表現と記憶にDRAM等のデジタルメモリを使用するが、アナログ型ではアナログメモリを使用する。1960年代、アナログコンピュータがデジタルコンピュータに駆逐された主たる理由は、アナログ電圧を記憶するメモリが作れなかったことであるが、2008年にHPが「メモリスト」(memoristor)を発見すると、通過する電荷量に応じて変化する電気抵抗値をメモリに応用する研究が行われた<sup>39</sup>。



■図44 電気抵抗メモリの変化<sup>40</sup>

この電気抵抗メモリは、特に不揮発性に注目されたが、ニューラルネットワークへの応用では、電気抵抗値が連続に変化することに価値がある。産業技術総合研究所で研究が行われているRAND (Resistive Analog Neuro Device) では、電荷が流れることで、物質内に図44に示すような物理的変化が引き起こされ、電気抵抗が変化するとされている。

フラッシュメモリがマルチレベル化で集積度を上げたように、アナログ方式では、一つのメモリ素子にデジタルでいう多ビットを重畳できるので、小型化に適していると考えられる。しかし、アナログ回路は、デジタル回路のように極端な微細化に適していない。デジタル回路は、閾値に幅を持たせてノイズやばらつきを許容することができるが、アナログでは、広い動作範囲での応答の線形性やノイズ耐性を求められるからである。

表10に掲げたアナログ型ニューラルネットワークプロセッサは、シナプス結合強度の表現に、次世代メモリとして研究されていた不揮発メモリ素子を活用している。これらのメモリは、長期間研究が続けられているが、対抗する従来型のメモリであるDRAMとNANDフラッシュメモリも高集積化が続いているので、世代交代を果たせていない。次世代メモリに関する企業や研究者が、ニューラルネットワークプロセッサという新たな可能性を見出して殺到していると解釈できる。

この中で、東芝のTDNN (Time Domain Neural Network) は、シナプス結合強度をバイナリで表現するため、デジタルとアナログの違いよりも、係数を電圧ではなく時間遅れで表現する点に特色がある。これによって従来の試作品の6分の1の消費電力を達成している。一般に、アナログは、デジタルよりも大きな省電力効果が得られる可能性がある。

※39  
DRAMは、コンデンサに蓄えられる電荷、フラッシュはフローティングゲート中の電荷、MRAMや磁気ディスクは磁気によって記憶する。ReRAM、PcRAM、RRAMなどの次世代メモリは、電気抵抗の変化を記録する。STT-MRAMもスピンによって生じる電気抵抗の変化を取り出す。

※40  
[Aidevice] semiconportalウェブサイト  
<[http://www.semiconportal.com/aist\\_aidevice/](http://www.semiconportal.com/aist_aidevice/)>;  
[Aidevice Artificial Neural Network System for Inference]  
Aidevice ウェブサイト <<http://green-innovation.jp/aidevice/>>

■表10 アナログ型ニューラルネットワークプロセッサ<sup>41</sup>

| 開発者  | 国        | 発表時期          | シナプス可塑性の実現素子   | 概要  |
|--|----------|---------------|--|---|
| IBM  | 米国       | 2016年5月       | PCM (GeSbTe)   | シナプスをPCMで構成、integrate-and-fire型ニューロンの挙動を再現1チップ上に400万セルを集積化AIチップと組み込みプロセッサ月のFPGAと実 |
| パナソニック   | 日本       | 2013年6月       | FeMEM  | CMOS型ニューロンの配線層にシナプス   |
| Posteck<br>SK Hynix等                                 | 韓国       | 2015年12月      | メモリスタ<br>(TiN/PCMO)  | ニューロンとシナプスを別々のチップに実装  |
| デンソー<br>University of California,<br>Santa Barbara   | 米国<br>日本 | 2015年12月      | メモリスタ<br>(Al <sub>2</sub> O <sub>3</sub> /TiO <sub>2</sub> ) | CMOSニューロンの上に12x12クロスバー構造のシナプスを形成<br>2030年 車載用実用化目標                                |
| HP,<br>University of Utah,<br>University of Michigan | 米国       | 2016年12月      | メモリスタ  | 32nmプロセスを用いた場合チップ面積85.4mm <sup>2</sup><br>メモリスタを用いた画像認識への取組み                      |
| 東北大学   | 日本       | 2016年12月      | スピントロニクス素子   | スピントロニクス素子36個とFPGAとの組み合わせ   |
| 産業技術総合研究所 他  | 日本       | 2016年6月開発開始   | アナログ型抵抗変化素子  | 対TrueNorth電力効率100倍、チップ面積1/20<br>28nmプロセス、100万個以上のシナプスを集積化する技術を開発                  |
| NEC<br>東京大学  | 日本       | 2016年9月共同開発発表 | 未公表  | ブレインモルフィックAI技術<br>東京大学合原教授が中核   |
| 東芝   | 日本       | 2016年11月に学会発表 | SRAM/ReRAM   | 時間領域アナログ信号処理技術による小型/省電力化、消費電力1/6  |

### 1.7.6.6 次世代ニューラルネットワークプロセッサの方向性

ニューラルネットワーク及びより生物脳に忠実なニューロモルフィックコンピューティングは、専用マシンによらずとも、万能マシンたる現代のコンピュータで実行することが可能である。実際、スーパーコンピューティングにより世界最大規模の脳シミュレーションが実施されたほか、GPGPUには、多数の応用がある。

コンピュータは、プログラムを入れ替えることでどんな情報処理にも適用できる汎用性に大きな強みがあり、応用先を限った専用機は、必ず苦戦することは先に記述した。それにもかかわらず、ニューラルネットワークプロセッサを開発する価値は、ノイマン型アーキテクチャからの脱却と、大規模なニューラルネットワークを構築することにある。半導体産業に陰りの見えた日本にとって、新たなチャンスとなるかもしれない。

ノイマン型アーキテクチャとは、プログラムとデータを同じメモリに内蔵すること、メモリからの命令に従って演算器を逐次的に動作させることでハードウェア量を減らすこと、プログラムをデータのよう操作することができるコンピュータであり<sup>42</sup>、現在主流となっている。このアーキテクチャでは、メモリからのプログラム（命令）の読み出しとデータの読み書きが輻輳し、フォン・ノイマン・ボトルネックと呼ばれる情報伝達の隘路が生じることが問題視されてきた。

※41  
各種公表資料よりNEDO技術戦略研究センター作成。

※42  
プログラム内蔵型のアイデアを出したのは、フォンノイマンではなく、ENIACを開発したエッカートとモークリーである。フォンノイマンは、1946年頃にこのアイデアを聞き及び、軍事機密の禁を破って、フォンノイマンの単独名でレポートを作成した。ENIAC開発予算を工面したゴールドスタイン中尉と成果を宣伝したいペンシルバニア大学は、このレポートを広く公表してしまった。これによってフォンノイマンの名前が知れ渡ったが、エッカートとモークリーはアイデアを公知にされたおかげでUNIVACから獲得していたコンピュータ特許を無効とされた。

その解決は、多数の演算器を用意し、その近傍に専用のメモリを置く方法が考えられるが、ニューラルネットワークアーキテクチャは、まさにそのような構造になっている。現在のコンピュータは、半導体のムーアの法則とスケーリング則を信奉して50年の進歩を続けてきたが、微細化の限界が近づいており、両法則の推進だけでは発展が望めなくなっている。ニューラルネットワーク型アーキテクチャによって、新たな発展軌道に乗れるのではないかと期待がある。

大規模なニューラルネットワークを目指す動きは、人間の脳のニューロン数（大脳皮質で140億個程度、小脳など全ての脳細胞を足すと1,000億個近いとされる）に大きな意味があるのだとする立場から生じている。チンパンジー等、高等な霊長類の大脳皮質のニューロン数は、60～80億個である。チンパンジーは、高度な知的能力を発揮するが、人間が、言語や記憶を駆使して文明社会を形成する能力とは雲泥の差がある。

SRI Internationalのハンス・モラベック（Hans Moravec）氏が2000年頃に発表した計算機の発展と生命体の知能の比較によれば、現在の人工脳の到達レベルは、ネズミのレベルに相当する。その処理能力をあと3桁ほど伸ばすことで、人間レベルに達するのであれば、その努力を続ける価値があろう。いろいろな生物脳のニューロン単体の能力はほとんど一定であると推測されるので、処理能力の差は、ほぼニューロン数とシナプス結合数の違いから生じていると推定される。脳細胞数を増やす重要なアプローチは微細化であるが、前述したようにムーアの法則には陰りが見えており同時に、消費電力の増大が問題となる。

NVIDIAの新しいGPGPUである「Pascal」は、170 テラフロップスという初代の地球シミュレータ<sup>43</sup>を上回る性能を示すが、300Wを消費する。人間の脳は、消費エネルギー20Wであり、大きな差がある。その原因は、PCのCPUに比べれば一つ一つのプロセッサの性能を落としたGPGPUであっても、まだ無駄な計算能力を発揮していることが考えられる。

既に、バイナリ（2値）のニューラルネットワークであっても、ニューロン数をそれに応じて増やせば、より高精度のニューラルネットワークと遜色ない性能を出せることが示されている。IBMの「TrueNorth」は、演算精度と速度を落とすことで、100万ニューロンで70mWという高い性能／電力比を示している。すなわち、人間の脳に近いレベルのニューロン数をリーズナブルなエネルギー性能で実現するには、現在のコンピュータハードウェアは不適當であり、より生物の脳に近い脳型コンピュータに勝機があると推測できる。

現在のニューラルネットワークプロセッサ、あるいはニューロモーフィックプロセッサは、順方向計算の加速には大きな効果を発揮するが、学習能力は持っていない。計算量としては、誤差逆伝播学習は、順方向計算の数倍程度であるが、繰り返し回数が多いため高速性が求められる。また、誤差逆伝播学習では、ニューロンの興奮度から結合係数の変化量を定める際に係数の微分値が必要になり、微分値の計算にある程度の計算精度が必要となる。

順方向計算のように1～16ビットの係数精度では不足するので、現在は、GPU以上のプロセッサでないと実装が難しい。そのため、学習は、データセンターなどのサーバに任せ、エッジ側のプロセッサでは順方向計算に割り切るといった分担ができていく。しかし、人間が作業しながら学習するように、今後はAIも順方向計算と逆伝播学習を同時に並行して進めたいという要求は出てくるであろう。学習機能をハードウェア化できれば、リアルタイム学習のような道も開けるであろう。

ニューラルネットワークプロセッサの実現には、デジタル型とアナログ型があることを述べた。

---

※43

海洋研究開発機構 (Japan Agency for Marine-Earth Science and Technology; JAMSTEC) に設置されているスーパーコンピュータ。2002年に35.86TFlopsで世界1位の性能を記録した。

1970年頃まで、コンピュータにはアナログ方式とデジタル方式があったが、アナログ方式が敗退したのは、誤差が大きく、数値をメモリできないこと、メモリできないからコピーもできず、再現性が低くなるのが原因であった。対するデジタル方式は、ワード長を変えれば精度をいくらでも上げることができ、閾値を設けて値を0、1に分離することにより、ノイズ耐性が向上し、したがって数値の長期記憶が可能となり、記憶をコピーして再現することができた。

ほぼ同じ議論が、アナログ式のニューラルネットワークプロセッサにも成り立つ。シナプス結合強度をアナログの電気抵抗値で表現する方法は、スペース効率と電力効率に優れるが、ノイズによって精度が劣化しやすく、情報を別のプロセッサにコピーして再現することが難しい。コピーするためには、電気抵抗値を計測して送り出す機能が必要となるが、そのための信号線を別途設けることにも困難がある。クラウドで学習した係数データを、多数の末端のアナログAIプロセッサに高速で焼き付けるのも難しい。

コピーが難しく再現性が低いということは、各々のAIプロセッサが個性を持つことを意味する。人間世界では、個性は重要なファクターであるが、機械の個性は必ずしも歓迎されないだろう。例えば、AIが事故を起こした場合に原因をソースプログラムに戻って検証することが困難であり、多数のデバイスに学習データをダウンロードして一律の改善を図ることも困難になる可能性がある。したがって、アナログ方式に特別の意味が見出されるか、アナログ値のコピーの方法が確立するまでは、デジタル式のAIプロセッサが作られ、使用されていくだろう。

#### 1.7.6.7 脳に忠実なモデルと工学的に単純化したモデルとのバランス

脳型コンピュータは、人を超える知的能力を目標に発達していくと想定されるが、現在行われている単純なニューロンモデルでよいのかどうかは議論が分かれる。確かに、ディープラーニングは、特にパターン認識を中心に人間を超える計算能力を発揮しているが、言語、計画、論理、創造など、重要な知的能力の実現は発展途上である。ニューラルネットワークの学習に、大量のデータを何万回も繰り返し与えなければならない点も、生物の学習とは大きく異なる。したがって、ニューラルネットワークの更なる多層化や、ニューロン数を増やすだけで広範な人間的知能を獲得できるとは思われない。

このようなニューラルネットワークの限界を克服すべく、シナプス結合強度を単に積和で計算するのではなく、脳の中の信号の同期性や揺らぎに注目するニューロモーフィックな考え方が注目されている。また、ニューロンのグループがベイジアンネットワークを構成していることなどニューロンの大局的構造に注目した研究や、リカレントニューラルネットワーク (RNN)、LSTM (Long Short-Term Memory)、Reservoirコンピューティング<sup>44</sup>、オートエンコーダのような生物脳由来ではない工学的な情報表現法、学習法の研究の成果が上がりつつある。

米国エネルギー省 (DoE) は、特に生物脳に忠実な再現を目指すのではなく、工学的に効果的であればよいと割り切って研究を進めているが、脳科学者の中には、現在のニューラルネットワークは、1950年代までの脳研究の成果に基づいているだけなので、もっと最近の成果を取り入れるべきだとする研究者も多い。新しい神経・脳モデルができれば、それに基づいて、様々な脳機能が再現される可能性があるが、同時に、忘れやすく、エラーを起こしやすく、疲れやすく、錯覚に陥りやすい脳が再現されてしまう可能性もある。

#### 1.7.6.8 AIコンピュータの今後の研究開発の方向性

AIプロセッサは、ニューラルネットワークの単純なアーキテクチャを活かすことで、従来のロジック

---

※44

力学的な定式化に基づくニューラルネットワークの一種。Echo State NetworkやLiquid-state Machineなどの種類がある。

CPUに比べて集積度を上げやすいこと、ReRAMやメモリスタのようなアナログ素子を使用することにより一つの素子が数ビットの情報量を蓄えることが可能となることから、従来のCPUにおける微細化の壁に打ち勝つことができる可能性を持っている。更に、ノイマン型アーキテクチャから非ノイマン型への変更により、メモリとプロセッサを小さく切り分けて近接した場所に置き、極端な高並列型のアーキテクチャとすることが可能である。これらの考えに基づき、大規模なニューラルネットワークを省電力で実装する試みが続けられている。

ディープラーニングにおける今後の課題の一つであるパターン認識と記号的処理（論理、言語、記号、計画、創造など）の解決に向けた研究開発においても、AIプロセッサの発展が寄与する可能性がある。現在のAIプロセッサは、認識以外の論理、言語、記号、計画、創造などを効率よく実行することができない。その解決の方向性は、脳科学・神経科学の研究からもたらされる示唆を工学的にモデル化した、脳とは異なる構造として実現する可能性もある。海馬、扁桃核、小脳など、大脳皮質とは異なる脳領域を合わせた超構造が必要になるかもしれない。脳の記憶は、海馬から入力されることは分かっているが、その記憶が大脳皮質のほかの領域に運ばれて固定化するメカニズムも解明されていない。

また、今までに作られてきたニューラルネットワークプロセッサは、順方向計算のみで、学習機能を持たない。現在のところ、学習に関してはサーバ側に任せるとする考えが強い。しかし、学習と認識処理を同時進行させられることに生物脳の特徴が隠されている可能性もある。このように、現在のニューラルネットワークを単純に大規模化することのみで良いのかどうかについては、不明なことが多い状況である。

ニューラルネットワークの応用領域は、急速に拡大しつつある。生物脳が学習によって様々な能力を発揮できるのと同様、AIプロセッサは、特に応用を限った発展を考える必要はない。しかし、AIプロセッサの開発を急ぐのであれば、まさにAIプロセッサの設計のための研究を高優先度のテーマとすべきであろう。そのような設計技術が生まれれば、あとは、次々と高性能のAIプロセッサが設計できるようになる。

### 1.7.6.9 量子計算機

更に長期的には、量子計算の動向にも注目しておく必要がある。量子計算の原理には主に三つに分類できる（表11）。

■表11 量子計算原理<sup>45</sup>

|          | 量子コンピュータ               | 量子アニーラ                | 量子ニューラルネットワーク         |          |
|----------|------------------------|-----------------------|-----------------------|----------|
| 計算原理     | 状態ベクトルのユニタリ回転（閉鎖系）     | ハミルトニアン断熱変化（閉鎖系）      | 測定フィードバック系の量子相転移（開放系） |          |
| 開発機関     | IBM / Google           | D-WAVE                | NIJ-Stanford          | NTT      |
| ビット数     | 5～9ビット                 | 1,152ビット              | 100ビット                | 2,048ビット |
| 結線数      | ≦ 10                   | 3,300                 | 1万                    | 400万     |
| 動作温度     | 極低温(10mK)              | 極低温(10mK)             | 室温(300K)              |          |
| 物理系      | 超伝導量子回路                | 超伝導量子回路               | 光パラメトリック発振器ネットワーク     |          |
| 適用先      | 問題に隠れた周期性がある場合（暗号解読など） | NP困難・NP完全問題（組合せ最適化など） | NP困難・NP完全問題（組合せ最適化など） |          |
| 有効ビットの割合 | —                      | 95%                   | 100%                  |          |
| 解ける問題サイズ | —                      | N ≦ 15～17             | N ≦ 2,048             |          |

2011年5月にD-Wave Systems（カナダ）が、世界初の商用量子コンピュータ「D-Wave One」を

※45  
「光を使って難問を解く新しい量子計算原理を実現～量子ニューラルネットワークの開発～」科学技術振興機構ウェブサイト  
<<http://www.jst.go.jp/pr/announce/20161021/>>

※46  
「トポロジカル量子コンピュータ」日経サイエンスウェブサイト  
<<http://www.nikkei-science.com/page/magazine/0607/topology.html>>

発表した。

D-Wave Oneは128量子ビットチップセット上で最適化問題を解くために、量子アニーリングを用いた量子コンピュータである。ただし、D-Waveの実装方法は、極低温を必要とする超伝導状態を用いており、現実性に乏しい。

Microsoftは2016年から、IBMやGoogle、D-waveとは全く違った戦略で量子コンピュータの開発に取り組んでいる。Microsoftは、世界中の共同研究者と一緒に量子コンピュータを構築するための取組を積極的に行っており、研究コンソーシアム的な研究施設Station Qを世界各国に建設し、量子コンピューティング<sup>46</sup>に関する研究を行っている。

対して、我が国の国立情報研究所とNTTで開発している量子ニューラルネットワークは、量子状態の重ね合わせのデバイスとして光を用いており、室温（300K=約27℃）での動作が可能な点が注目されている。現在約2,000ビットでの動作が報告されているが、今後の研究の更なる進展が期待される<sup>47</sup>。量子ニューラルネットワークの開発は、内閣府革新的研究開発推進プログラム（ImPACT）「量子人工脳を量子ネットワークでつなぐ高度知識社会基盤の実現」にて、2014年から2018年の計画で進められている。

海外の動向としては、2016年7月に量子情報科学と高性能コンピューティングの推進についての計画を発表<sup>48</sup>したほか、欧州では欧州委員会から2016年5月にQuantum Technologies Flagshipの立ち上げが発表され、10億ユーロ以上の大規模プロジェクトが立ち上がった<sup>49</sup>。

#### 参考文献

- [1] Shmuel Winograd, "Arithmetic complexity of computations," Siam, vol.33.
- [2] Olga Russakovsky et al., "ImageNet Large Scale Visual Recognition Challenge," IJCV.
- [3] Krizhevsky. A. et al., "ImageNet Classification with Deep Convolutional Neural Networks," *NIPS 2012: Neural Information Processing Systems, Lake Tahoe, Nevada*.
- [4] Maxime Oquab et al., "Learning and transferring mid-level image representations using convolutional neural networks," CVPR2014.
- [5] David Silver et al., "Mastering the game of Go with deep neural networks and tree search", Nature 529, pp.484-489.
- [6] Jeffrey Dean et al., "Large Scale Distributed Deep Networks," *Advances in Neural Information Processing Systems 25 (NIPS 2012)*.
- [7] R. Zhao et al., "Accelerating Binarized Convolutional Neural Networks with Software Programmable FPGAs," ISFPGA2017.
- [8] Ben Varkey Benjamin et al., "Neurogrid: A Mixed-Analog-Digital Multichip System for Large-Scale Neural Simulations," *Proceedings of the IEEE*, Vol.102, No.5, pp.699-716.

---

※47

「光を使って難問を解く新しい量子計算原理を実現～量子ニューラルネットワークの開発～」科学技術振興機構ウェブサイト  
<<http://www.jst.go.jp/pr/announce/20161021/>>

※48

"Realizing the Potential of Quantum Information Science and Advancing High-Performance Computing." White House Website  
<<https://obamawhitehouse.archives.gov/blog/2016/07/26/realizing-potential-quantum-information-science-and-advancing-high-performance>>

※49

"European Commission will launch €1 billion quantum technologies flagship." European Commission Website  
<<https://ec.europa.eu/digital-single-market/en/news/european-commission-will-launch-eu1-billion-quantum-technologies-flagship>>

## 1.8 グランドチャレンジによる研究開発の推進

### 1.8.1 総論

現在までの人工知能 (AI) の歴史の中で、チェス、将棋、囲碁などのゲーム、チューリングテスト (1.4.3 項参照)、ロボットや自動運転など、様々なテーマで「グランドチャレンジ」が長期的な目標として設定されることにより、研究開発を推進する力を産み出してきた。グランドチャレンジは、大きな目標を掲げ、それを達成することで研究開発を加速するプロジェクト推進手法である。米国のアポロ計画に見られるように、「人類を月面に送り込み、安全に帰還させる」という明確かつチャレンジングな目標が設定される。同時に、その達成の過程で、社会的にも産業的にも重要な一連の技術が生み出されることがグランドチャレンジの設定において非常に重要である。

AIの分野では、人間に勝つことのできるチェスコンピュータの開発というチャレンジが、非常に早い段階から掲げられた。このチャレンジは、1997年にIBMの「DeepBlue」が、当時の世界チャンピオンであるガルリ・カスパロフ (Garry Kasparov) 氏に勝利することで達成されたが、その過程において、多くの探索アルゴリズムや並列計算技術など、広く普及している技術が生み出された。

その後、ゲーム題材として、将棋、囲碁、クイズショー、ポーカーなどがチャレンジの課題として設定され、実際に達成されてきた。例えば、将棋に関しては、情報処理学会の「コンピュータ将棋プロジェクト」<sup>1)</sup>によって2015年にトッププロ棋士に追いつき、2017年には第二期電王戦が開催され、佐藤天彦名人と将棋ソフト「Ponanza」の対戦が行われてPonanzaが二局とも勝利した。

更に、我が国の研究者が中心となって1990年代半ばに始まったロボカップは「2050年までに、完全自律型のヒューマノイドロボットで、FIFAワールドカップの優勝チームとFIFAの公式ルールで試合を行い、勝利する」という目標を掲げ、世界45か国で数千人の研究者を巻き込む巨大プロジェクトとなっている。さらにロボカップへの参加者がKIVA Systems (現在のAmazon Robotics)、Aldebaran Robotics (現在のSoftbank Robotics) 等の名だたるロボット企業を創業している [1]。

グランドチャレンジは、目標の達成自体が大きな社会的・産業的意義を持っている場合と、目標自体は、極めて難度が高く、インパクトがあるものの、それ自体には、直接的な社会的・産業的重要性は、必ずしも大きくはない場合とがある。後者の場合は、「ランドマーク型グランドチャレンジ」である。ロボカップを例にとると、サッカーで世界チャンピオンになったとして、それ自体が、直接社会や産業の役に立つわけではない。しかし、その過程で生み出される技術が世の中に大きなインパクトを与えるというものである。

つまり、人類の歴史に残るような目標を掲げるが、それ自体は「記念碑 (ランドマーク)」にすぎない。真の目標は、そこに到達する過程にあるということである。これは同時に、何をランドマークとして設定するかが最も重要であることを意味する。成功するランドマークプロジェクトは、次の三つの要件を満たすものである。

- (1) 社会・産業的に重要になりそうな一群の次世代技術の開発を要求する課題であること。
- (2) その成功や進歩が、一般の人々にも分かる明確な形で示されること。
- (3) 最終目標が、歴史的記念碑となることが明白で、だからこそ困難が予想されるが、すぐに第一歩を踏み出すことは可能であること。

※1

「コンピュータ将棋プロジェクトの終了宣言」情報処理学会ウェブページ <<http://www.ipsj.or.jp/50anv/shogi/20151011.html>>

AIにおけるグランドチャレンジの多くは、ランドマーク型であり、そこからおびただしい技術が出され、世の中に普及している。

グランドチャレンジの成功と、最近のAIの発展を受けて、新たなグランドチャレンジを設定する動きが出てきている。システム・バイオロジー研究機構の北野宏明氏は、2050年までにノーベル賞級の科学的発見を可能とするAIを生命科学分野等で開発するというグランドチャレンジを提唱している[2]。また、公立はこだて未来大学の松原仁氏らは、ショートショートを創作させることを目標としたグランドチャレンジを提唱し、既に開始している。今後、これらの新しいグランドチャレンジが充実していくことにより、AIが加速していくことが期待される。

## 1.8.2 ゲームとAIの進化

ゲームは、ルールが明確である、勝ち負けによって手法の良し悪しが明確に評価できる、目標にできる強い人間が存在する、などAIの研究の題材として優れている。それにより多くのゲームを対象としたグランドチャレンジが行われてきた。

### 1.8.2.1 チェス

チェスは西欧で知性のシンボルとされているので、AIの例題としてのチェス（の世界チャンピオンに勝つコンピュータを開発すること）は、AIの研究が始まって約50年間ずっと中心的な例題となっていた。AIの最初のグランドチャレンジである。ジョン・マッカーシー（John McCarthy）氏は、チェスのことをAIの「ハエ」と称した。遺伝学が「ハエ」を題材として大きな進歩をしたように、AIはチェスを題材として大きな進歩をしたという意味である。チェスの「場合の数」はほぼ $10^{120}$ である。ある局面でルール上指せる合法手の数を分岐数というが、チェスの平均分岐数は約35である。チェスは平均80手で勝負がつくので、35の80乗すなわち $10^{120}$ が場合の数となる。

クロード・シャノン氏とアラン・チューリング氏は、チェスの探索にゲーム理論でジョン・フォン・ノイマンらが開発したミニマックス法<sup>2</sup>を使うことを提案し、このミニマックス法がその後のゲームの探索の基本となった。ゲームのプログラムを強くするには、

- 1) ミニマックス法を基本とした探索手法の改良
- 2) 局面を点数化する（静的）評価関数の精緻化

の2つが求められる。理論的には例外が存在するものの、経験的にほとんどの場合、ゲームはより深く先読みしたほうが強くなるので、同じ時間でできるだけ深く先読みできる探索手法が望ましい。

チェスのプログラムを強くすることを目指して様々な工夫が試みられた。ミニマックス法は探索の末端の局面の全ての評価値をしらみつぶしで求めなくてはならないので、時間がかかってその分深く読めないという欠点がある。そこで、ミニマックス法と探索結果は同じでそれより効率がいい手法が経験的に開発された。それがアルファベータ法である。

チェスのプログラムで経験的に使われているのを、アルゴリズムとしてまとめたのがドナルド・クヌース（Donald Knuth）氏である。クヌース氏は末端の局面の数がN個のとき、アルファベータ法は最も効果が高い場合に $\sqrt{N}$ 個だけ評価値を求めればよいことを明らかにした。

---

※2

何らかの評価関数に基づき、最大の損失が最小になるように行動の意思決定を行う戦略。

アルファベータ法の効果が高くなるのは、展開した探索木が評価関数の値の大きい順番になっているときである。したがって、1手先を読むたびに評価値を計算して、大きい順に並べ替えておくのがいいことになる。チェスのプログラムで経験的にそのことが分かり、それがのちに反復深化 (iterative deepening) という探索手法として定式化された。新しい探索手法の多くは、チェスを例題として開発されたと言ってよい。

例えば、ある指し手の評価値だけが他の評価値とかけ離れているときに、その指し手に注目して、その指し手だけをより深く読むという選択的深化 (selective deepening)、評価値がどの程度信頼できるかを表わす共謀数 (conspiracy number) とそれを拡張した証明数 (proof number)・反証数 (disproof number) などが有名である。

探索を効率的に行うためのハッシュ表<sup>3</sup>、ビットマップなど、データ構造の工夫もチェスを通して確立した。チェスは (アルファベータ法を使って) ルール上指せる全ての手を読むという全数探索が有効だったので、スーパーコンピュータやチェス専用マシンを使うことによって、探索の速度を上げようという試みが盛んになされた。並列に探索するアルゴリズムも、チェスを例題にして盛んに研究された (アルファベータ法は探索全体をアルファ値、ベータ値によって制御するので並列に探索するには困難があった)。

また、チェスは駒の再利用ルールがないので、ゲームの進行に伴って駒の数が単調に減少していく。駒が盤面に数個しか残っていない局面になると、コンピュータは (ほぼ) しらみつぶしの探索によってその局面を解く (双方が最善手を続けたら先手が勝つのか、後手が勝つのか引き分けになるかを求める) ことができる。この探索をあらかじめ行ってデータベース化したものが終盤データベースである。コンピュータはこれを持っていれば、このデータベースに含まれる局面で最善手を指すことができる。1980年代には盤面残り5駒の全ての局面の終盤データベースが作られた。1990年代から2000年代にかけて盤面残り6駒のほとんどの局面の終盤データベースが作られた (その間にコンピュータが世界チャンピオンに勝ってしまったので、終盤データベースを作る意味が薄くなったと言える)。その後も7駒の終盤データベースが作られている。

チェスは何度も人間との対戦を経たのちに1997年に「Deep Blue」が世界チャンピオンのカスパロフ氏に勝利した。6回戦で5回戦が終わった時点では1勝1敗3引き分けのイーブンであったが、最終戦でカスパロフ氏が緊張のあまり序盤で大悪手を指して負けてしまった。これはフロック勝ちで、この時点ではまだカスパロフ氏の実力はDeep Blueに勝っていたと思われる。

これでグランドチャレンジは目標を達成したことになる。その後の進歩によりコンピュータは人間より明らかに強くなっている。Deep Blueはスーパーコンピュータにチェス専用マシンを数百台並べた構成であったが、もはやパソコン1台でも人間が敵わないまでになっている。

### 1.8.2.2 将棋

チェスよりも場合の数が大きいゲームに中国将棋 ( $10^{150}$ )、将棋 ( $10^{220}$ )、囲碁 ( $10^{360}$ ) が存在する。中国将棋は探索問題として見るとチェスに近い (既に人間よりもコンピュータのほうが強くなっている) が、将棋と囲碁はチェスよりはるかに場合の数が大きく、チェスとは異なる手法が必要なので、チェスに続く例題として適切である。将棋はチェスと同じ敵の重要な駒 (キングあるいは玉) を捕まえるゲームであるが、チェスは敵から取った駒が使えないのに対して、将棋では敵から取った駒

が再利用できる (「持ち駒」制度と呼ばれる) ため、終盤は序盤より分岐数が大きくなる。チェスは

---

※3

キーと値をペアで管理するデータ構造。

収束型ゲームであるが、将棋は発散型ゲームなのである。

将棋はチェスよりも場合の数ははるかに大きく、チェスで有効であった探索手法がそのままでは使えないので、チェスの次の探索研究のよい対象になった。将棋は日本固有のゲームなので、将棋を対象とした研究は当然のこととして日本が中心になった。このことが日本におけるゲーム情報学研究を活発にして、世界の中でゲーム情報学において日本が主要な立場を占める原動力になったと思われる。

将棋のプログラムの開発は1970年代に始まったが、当時のコンピュータの能力では将棋はチェスのような全数探索は無理だったので、前向き枝刈り<sup>4</sup>の探索手法が盛んに研究された。ミニマックス法（アルファベータ法）、反復深化などチェスで有効だった手法で将棋でも使える手法はおよそ全て使った。将棋は発散型ゲームなので、チェスで有効だった終盤データベースの手法は使えない。その代わりに詰め将棋という将棋から派生したパズルを解くアルゴリズムの研究が盛んになされた。

詰め将棋の研究は1990年前後から本格的に進められ、その中で様々な探索の手法が試された。有効だったのはチェスで提案された（そしてチェスではあまり有効でないと言われた）証明数・反証数を用いた手法である。詰め将棋のプログラムは2000年前後には既にプロ棋士を超える能力を示した。

評価関数はチェス同様に手作業で作成と改良を行っていたが、チェスの評価関数は駒の損得という明快な基準があったものの、将棋の評価関数は複雑でなかなか強くならなかった。2000年代の半ばに登場した保木邦仁氏（現在、電気通信大学）の「Bonanza」（ボナンザ）によって、コンピュータ将棋は革命的な進歩を果たした。保木氏の工夫は、

- (1) それまで将棋は前向き枝刈りの探索をしていたのをチェスのように全数探索にした。
- (2) それまで評価関数は手作業で作っていたのを棋譜からの機械学習で作るようにした。

の2点である。この工夫をしたボナンザが圧倒的な強さでコンピュータ将棋のトップに立ったので、ほかの研究者・開発者もこぞってこれらの方法を取り入れた。

特に上記の(2)の方法は強豪のプログラム全てが取り入れており、「ボナンザメソッド」と呼ばれている。保木氏はBonanzaのアルゴリズムをすぐに公開し、またプログラムのソースコードも無償で公開した。これはコンピュータチェスの文化を引き継いだものであるが、研究成果を公開するという習慣がこの研究領域の発展を支えているものと思われる。

2010年代になって、コンピュータとプロ棋士が対戦するようになった。2013年、2014年と電王戦と称してプロ棋士5人とプログラム5つが対戦したが、3勝1敗1分け、4勝1敗と、ともにコンピュータが圧勝した。この時点で既にコンピュータはトップクラスのプロ棋士（竜王、名人）のレベルに達した。

現在のトップ棋士のシンボルである羽生善治氏との対戦はすぐに実現しないと思われるので、情報処理学会は2015年10月に将棋で人間とコンピュータの強さを問うことは学問的には結論が出たという終了宣言を行った。事実上グランドチャレンジは2015年をもって目標が達成されたことになる。その後2017年にBonanzaが佐藤天彦名人に圧勝している。

### 1.8.2.3 囲碁

囲碁は中国発祥のゲームであるが、中国では廃れて日本で盛んになった（いま中国で盛んになったのはいわば日本からの逆輸入である）。囲碁は、ほかに似たルールのゲームが存在しない、漢字を使っていないので親しみやすい、などの理由で世界的に普及している。

---

※4

見込みのなさそうな手を試行しないことで、手を読む数を減らす方法。

最初にコンピュータ囲碁の研究がなされたのは1960年代である（チェスよりは遅いが将棋より早い）。囲碁もチェスのように探索によって次の手を決めようとしたが、囲碁の場合の数は $10^{360}$ とチェス（や将棋）よりはるかに大きく、普通の探索によっていい手を見つけるには候補手が多すぎて強くならなかった。2000年代になっても、まだとても弱い状態であった（初心者レベルよりはましでもせいぜい初級者レベルであった）。

囲碁も将棋のボナンザメソッドのような革命的な手法が現れた。それがモンテカルロ木探索である。この元となったモンテカルロ法はフォン・ノイマン氏の命名といわれるシミュレーションによって解を求める方法である。1990年代にこれを囲碁に適用するというアイデアが発表されたものの、そのときは成功しなかった。2000年代になってレミ・クーロン（Remi Coulom）氏が「Crazy Stone」という囲碁プログラムのなかでモンテカルロ法を応用したモンテカルロ木探索を採用し、このCrazy Stoneが圧倒的な強さを示した。

囲碁にモンテカルロ法を適用するということは、ある局面から白と黒が交互にランダムに終局まで打ち進めるというシミュレーションを多数行って、勝つ確率が一番高い手を選ぶということである。そこには囲碁の知識はほとんど何もはっていない。この一見単純な方法で強くなることに驚き、その後の囲碁プログラムはみんなこの方法を取り入れている。それで囲碁プログラムは一気にアマチュアの六段程度の実力に達した<sup>5</sup>。

最近までは日本の「ZEN」（これもモンテカルロ木探索を用いている）が、Crazy Stoneを抜いて最も強い囲碁プログラムであった。これらのプログラムはまだ互先（ハンディなし）で戦うのは無理であるが、トッププロ棋士と4子（初期局面に4個の石をあらかじめ置く）のハンディで勝つまでになっていた。トッププロ棋士に勝つのはまだ10年はかかると思われた。

そこに2016年1月、Googleの「AlphaGo」というプログラムが二段のプロ棋士に互先で5戦5勝の成績を挙げたと発表して大ニュースになった。Alpha-Goは、

- 1) ディープラーニング
- 2) モンテカルロ木探索
- 3) 強化学習

という三つの手法をうまく組み合わせている。大量のプロ棋士の棋譜をデータとしてディープラーニングによってある程度の強さのプログラムを作り、そのプログラム同士の強化学習によって更に強くした。これまでコンピュータ囲碁で成功しなかった評価関数を、実質的に作ったことがAlphaGoの大きな特徴である。手を決める部分では、従来手法であるモンテカルロ木探索を使っている。

その後、2016年3月に、AlphaGoは韓国のトッププロ棋士のイ・セドル（Lee Sedol）氏と対戦して4勝1敗で圧勝した。AlphaGoの改良版である「Master」は2016年末から2017年初めにかけて（持ち時間が短い早碁ではあるが）、世界中のトッププロ棋士相手に60勝で負けなしという成績を収めた。中国の「Fine Art」やZENの改良版である「DeepZenGo」も、ディープラーニングを取り入れてトッププロ棋士といい勝負をするまでになった。囲碁も一気に2016年から2017年に、グランドチャレンジの目標が達成されたことになる。

---

※5  
美添一樹ほか『コンピュータ囲碁-モンテカルロ法の理論と実践-』  
共立出版。

### 1.8.3 ロボカップ

ロボカップは (RoboCup)、「2050年までに、完全自律型のヒューマノイドロボットで、FIFAワールドカップの優勝チームとFIFAの公式ルールで試合を行い、勝利する」という目標を掲げているロボットとAIのグランドチャレンジの一つである。ロボカップは、浅田稔氏、野田五十樹氏、北野宏明氏、松原仁氏ら、日本人研究者が中心となって1990年代初めに構想され、1997年に名古屋で第1回大会が開かれた。運営母体となるThe RoboCup Federationは、スイスに登録されている非営利組織である。

最初は、サッカーに関するリーグから始まったが、すぐに災害救助 (ロボカップレスキュー) や教育 (ロボカップジュニア) に関する活動が加えられた。現在では、家庭用ロボット (ロボカップ@ホーム) や物流など産業用途ロボット (ロボカップインダストリアル) をタスクとしたリーグが増えてきている (表12)。これらのタスクは、理事会で承認され、技術的マイルストーンの検討、研究上と産業上の有用性などから審査され、適切とみなされると追加される。現在、45か国から、数千人の研究者が参加し、教育では数十万人の子供たちが参加する、ロボットとAI分野における世界最大のプロジェクトである。

■表12 ロボカップのリーグ構成(2017)<sup>6</sup>

| ロボカップのリーグ種別       | 概要        |
|-------------------|-----------|
| ロボカップサッカー         | サッカー      |
| ヒューマノイドリーグ        | 人型ロボット    |
| 中型ロボットリーグ         | 車輪中型      |
| 小型ロボットリーグ         | 車輪小型      |
| シミュレーションリーグ       | シミュレーション  |
| ロボカップレスキュー        | 災害救助      |
| レスキュー実機リーグ        | 災害救助ロボット  |
| レスキューシミュレーションリーグ  | シミュレーション  |
| ロボカップジュニア         | 教育        |
| ロボカップ@ホーム         | 家庭内向けロボット |
| ロボカップインダストリアル     | 産業用途ロボット  |
| ロジスティクスリーグ        | 物流ロボット    |
| @ワーク              | オフィス環境向け  |
| アマゾン・ロボティクス・チャレンジ | 倉庫内物流ロボット |

また「リーグ」と呼ばれる各々のカテゴリは、毎年技術要件や競技規則が見直され、最終的にFIFAの正式ルールと一致するようにマイルストーン管理がなされている。例えば、2014年には、図45の様に、フィールドの広さ、周囲の設定なども含め飛躍的に難易度が高い技術要件をクリアする必要がある競技規則となっている。

ロボカップがサッカーを題材とした理由は、ロボット工学とAIの分野で21世紀中頃に、重要な応用領域 (自動走行、物流ロボットなど) を想定して、それらの応用領域の特徴 (不完全



■図45 中型ロボットリーグ

※6

「RoboCup 2017 Nagoya Japan」ロボカップ2017ウェブサイト  
<<http://www.robocup2017.org/index.html>>

情報<sup>7</sup>など)を抽出した。その上で、一連の基幹技術になりそうな項目を同定し(自律エージェント、分散協調システム、実時間システム、不完全情報下での意思決定システムなど)、それらを包含し、誰にでも一言で理解してもらうことが可能で、更に研究者自身が熱くなれるテーマとして選ばれた(図46)。

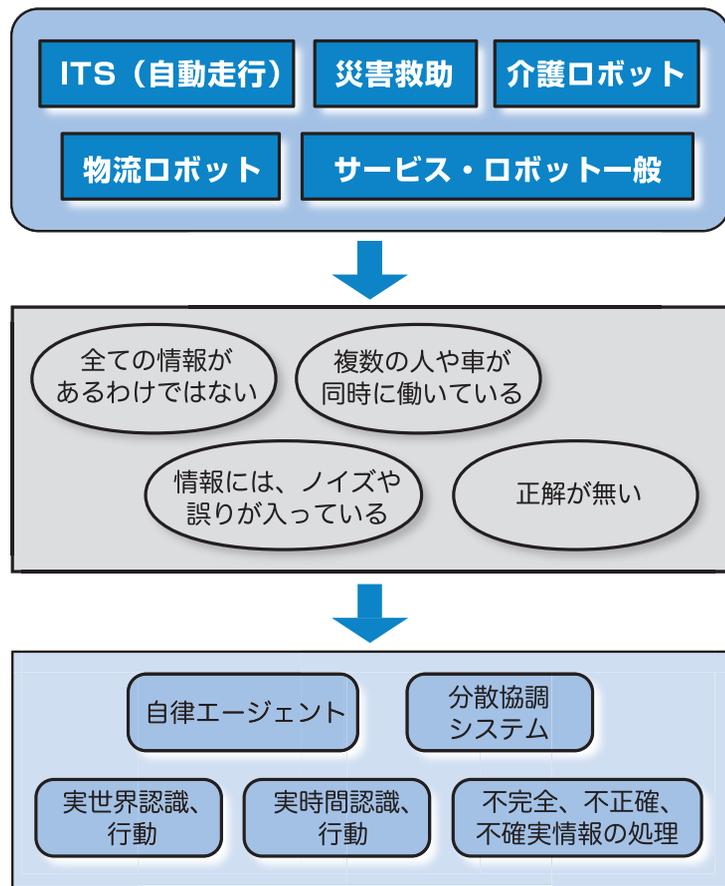
これから必要となる技術は、チェスや将棋のように、全ての状況が理解でき、順番に駒を動かすような問題ではない。不確実な情報を基に刻一刻と変化する状況下で、ベストではないかもしれないがベターな判断を下し、それを実行できる技術体系だろう、という分析であった。いろいろなテーマの候補があったが、最終的に次世代技術の要素を最も含んでいて、世界中で受け入れられるテーマとして、サッカーが選ばれている。

ロボカップを通じて開発された技術を基盤に、起業し、それが大きな成功を収める事例も出てきている。ロボカップの小型リーグを通じて開発された技術を基礎に設立された会社(KIVA Systems、米国)が、2012年に、7億7千万ドル(約800億円)という大きな評価額でAmazonに買収された。更に、ロボカップの標準プラットフォームリーグにワンメイクのヒューマノイドロボットを提供していた、フランスのAldebaran Roboticsが、ソフトバンクに1億ドルの出資を受けるということが起きたのである。

KIVA Systemsは、コーネル大学(米国)のチームを率いたラファエロ・ダンドレア(Raffaello D'Andrea、現在チューリッヒ工科大学)氏らが、ロボカップ向けに開発した技術をベースに、パッケージングから倉庫内の物品移動、発送までも自動化するロボットシステムを開発して事業化した会社である。ちなみに、コーネル大学チームは、ロボカップの小型ロボットリーグに1999年から2003年まで参加し、4回の優勝を飾っている。ダンドレア氏は、そのときのコーネル大学チーム(Cornell Big Reds)のリーダーである。

サッカーロボットでは、複雑でしかも状況が変化する環境下で自律的に目的の場所に移動する、障害物との衝突を回避する、味方のロボットと連携する、といった機能が必須である。これらの機能を大規模オンラインショップ向けに設計し、トータルソリューションを実現したのである。

ロボカップレスキューは、ロボカップの目標がサッカーであり、しかもその達成時期を2050年とかなり先に設定しているため、より早い段階で世の中に還元できる取組も必要であるとの認識から始まっている。



■図46 ロボカップのタスク設定のロジック

※7  
意思決定時において、必要な情報が不完全であること。

災害救助という目的に最適化するため、サッカーロボットと違い、完全自律である必要はない。実際には、操縦者が遠隔操作できる上に、ある程度の自律制御で探索効率を上げる方式が実際的である。ただし、直接ロボットの見えるところから操作することはできない。なぜなら、災害現場では、ロボットからかなり離れた場所から操縦することが想定されるからである。

この背景には、阪神・淡路大震災でロボット工学が無力だったという反省があり、日本のロボット関係者への議論から、計画は急速に動き出した。2001年8月にシアトルで第1回の大会が開催された。

その1か月後、9.11のテロが発生した。米国から参加していた南フロリダ大学のチームは、大会後、レスキューロボットを遠征用にパッキングしたまま休暇に入り、新学期を迎えるところだったが、テロ発生のお知らせに、このロボットを車に積んでニューヨークの現場に入った。ロボカップレスキューは、その構想段階から米国の連邦緊急事態管理局（FEMA）などとも交流を深めていたこともあり、即時に現場の救助活動に統合され、2週間にわたり探索活動の一翼を担い、その有効性は高く評価された。

このような実績が、1999年からロボカップに関心を寄せていた米国防衛先端研究計画局（DARPA）の強い興味を引きつけ、ロボカップのノウハウを利用しながらのDARPA Grand Challenge設立へと結び付いている。

この段階での研究は、阪神・淡路大震災、オクラホマの連邦ビル爆破、9.11同時多発テロ、トルコでの一連の地震などによる被害での救援活動を想定していたため、ビルの倒壊現場などで、瓦礫の間隙から中に入り、被災者を発見するシナリオで開発されている。同時に、新潟県中越地震などで問題となった土砂崩れなどには、無力であることも認識されていた。

東日本大震災においても、津波が被害をもたらした大きな原因であり、レスキューロボットの有効性は限定的になった。もっとも、福島第一原発に投入されている国産ロボット（千葉工業大学未来ロボット技術研究センターが中心に開発）は、ロボカップレスキューの2007年大会に運動性能の部で優勝したシステムをベースに開発されている。ロボカップレスキューは、救助ロボット開発の手法としての有効性は確認されたが、広範かつ複雑な災害現場へのレスキューロボットの有効的な投入には、更に現実的な設定に近づけると同時に、ロボットが最も有効な局面への集中的な課題設定も必要となる。

ロボカップには、このほかにも、各々の目標を設定したリーグが存在し、本来のグランドチャレンジの手法を更に広範に援用した、コンペティション駆動型研究開発のプラットフォームへと変貌を遂げて進化している。

#### 1.8.4 DARPAにおけるグランドチャレンジ

DARPA（アメリカ国防高等研究計画局）とは、米国防総省の研究開発機関であり、インターネットの起源となるARPANETやGPSを開発したことで有名である。DARPAはこれまでに様々なグランドチャレンジと呼べる研究開発プロジェクトを実施しており、なかでも有名なのは「DARPA Grand Challenge」（2004年、2005年）や「DARPA Urban Challenge」（2007年）、「DRC」（DARPA Robotics Challenge）である。

DARPA Grand Challenge、DARPA Urban Challengeはいずれも自動運転技術を競い合う競技会で、DARPA Grand Challengeでは未舗装路を走破する技術、DARPA Urban Challengeでは市街地の交通ルールを守りながら走破する技術が競い合われた。本項では2012年から2015年にかけて行われたDRCを紹介する。

DRCは2011年に発生した東日本大震災をきっかけにして、プログラムマネージャーであるギル・プラット（Gill Pratt）氏が立案・実施した競技会形式の研究開発プログラムであり、その目的は災害発生時に人を支援できるロボットシステムを開発することである。参加者は以下の四つのトラックを選択し

て参加することが可能であった。

トラックA：DARPAからの予算支援を受けて、ハードウェア及びソフトウェアの全てを開発する

トラックB：DARPAから予算支援を受けてソフトウェアを開発し、後述のVRCで勝ち残ればハードウェアプラットフォームの提供を受けて開発を継続する

トラックC：DARPAから予算支援は受けずにソフトウェアを開発し、VRCで勝ち残ればハードウェアプラットフォームの提供を受けて開発を継続する

トラックD：DARPAからの支援は受けずにハードウェア及びソフトウェアの全てを開発する

トラックDのような参加形態が設定されたのは、DARPAが軍関連の組織であり、そこからの支援を受けることに対して抵抗のある組織が多いことが要因であると考えられる。

競技会は以下に示す3度にわたって行われ、ハードウェアプラットフォームとして米Boston Dynamicsが開発したヒューマノイドロボットであるAtlas、シミュレーションプラットフォームとして米OSRF（Open Source Robotics Foundation）が開発したGazeboが提供された。

- (1) ハードウェアプラットフォームの提供を受ける参加者を決定するための、コンピュータシミュレーションによる競技会Virtual Robotics Challenge（VRC、2013年6月）
- (2) 決勝戦へ進むチームを決定するためのDRC Trials（2013年12月）
- (3) 決勝戦であるDRC Finals（2015年6月）

DRC Trialsでは東京大学出身の若手研究者が立ち上げたベンチャーSCHAFTがトラックAで参加し、優勝を収めた。同社はTrialsの直前に上記Boston Dynamics等とともにGoogleによって買収されていたことと合わせて、関係者の間では非常に大きな話題となった。

DRC Finalsの競技の概要は次のとおりであった。

- 8つのタスクを連続して実行し、完了できたタスクの数が多いもの、タスクの数が同じ場合はより短い時間で完了できたものが高成績となる。8つの競技とは（1）車両を運転する、（2）車両から降りる、（3）ドアをあけて室内に入る、（4）バルブを回す、（5）工具を持ち、壁に穴をあける、（6）サプライズタスク、（7）不整地を移動する、又は障害路を通過する、（8）階段を登る、である。
- 競技時間は1時間
- ロボットは無線で動作しなければならない（外部電源なし、転倒防止索なし）

DRCではロボットの自律性を高める研究開発を促進するため、通信制限がルールに盛り込まれた。ロボットとオペレータの間の通信路は2種類あり、一つは通信速度が9,600bpsと非常に遅いが、常につながっており、双方向通信が可能な通信路。もう一つは通信速度が300Mbpsと速いが、屋内エリアに入ると通信が途切れ途切れとなり、最大で30秒の通信遮断が発生し、更に情報はロボットからオペレータへの一方方向でしか送れない通信路である。オペレータが画像を見ながらレスポンスのよい遠隔操作を行うためには、高いバンド幅の通信路が必要であり、これを制限することによってロボットの自律性を高める研究が行われるように誘導している。

DRC Finalsには全世界から23チームが参加し、日本からは5チームがトラックDで参加した。新エネルギー・産業技術総合開発機構（NEDO）の支援を受けて参加したAIST-NEDO（産業技術総合研究所）、NEDO-JSK（東京大学稲葉研究室）、NEDO-Hydra（東京大学中村研究室、千葉工業大学、大阪大学、

神戸大学)の3チームとHRP2-Tokyo(東京大学稲葉研究室)、Aeroである。Finalsの結果は次表(表13)のとおりとなった。

優勝したのは韓国のTeam KAISTであり、使用機体であるDRC-Huboは人型でありながら膝と爪先部分に車輪を持ち、平坦なところでは正座のような姿勢で高速かつ安定に移動し、階段の移動や作業時に立ち上がって作業を行った。日本チームは10位のAIST-NEDOが最高位となった。

■表13 DRC Finalsの競技結果

| 国  | チーム                   | ポイント | 時間       | 移動機構    | ロボットのタイプ |
|----|-----------------------|------|----------|---------|----------|
| 韓  | TEAM KAIST            | 8    | 44:28:00 | 2脚/車輪   | DRC-HUBO |
| 米  | TEAM IHMC ROBOTICS    | 8    | 50:26:00 | 2脚      | ATLAS    |
| 米  | TARTAN REASCUE        | 8    | 55:15:00 | 4脚/クローラ | 独自       |
| 独  | TEAM NIMBRO RESCUE    | 7    | 34:00:00 | 4脚/車輪   | 独自       |
| 米  | TEAM ROBOSIMIAN       | 7    | 47:59:00 | 4脚/車輪   | 独自       |
| 米  | TEAM MIT              | 7    | 50:25:00 | 2脚      | ATLAS    |
| 米  | TEAM WPI-CMU          | 7    | 56:06:00 | 2脚      | ATLAS    |
| 米  | TEAM DRC-HUBO AT UNLV | 6    | 57:41:00 | 2脚/車輪   | DRC-HUBO |
| 米  | TEAM TRAC LABS        | 5    | 49:00:00 | 2脚      | ATLAS    |
| 日  | TEAM AIST-NEDO        | 5    | 52:30:00 | 2脚      | HRP-2    |
| 日  | TEAM NEDO-JSK         | 4    | 58:39:00 | 2脚      | 独自       |
| 韓  | TEAM SNU              | 4    | 59:33:00 | 2脚      | ROBOTIS  |
| 米  | TEAM THOR             | 3    | 27:47:00 | 2脚      | ROBOTIS  |
| 日  | TEAM HRP2-TOKYO       | 3    | 30:06:00 | 2脚      | HRP-2    |
| 韓  | TEAM ROBOTIS          | 3    | 30:23:00 | 2脚      | ROBOTIS  |
| 米  | TEAM VIGIR            | 3    | 48:49:00 | 2脚      | ATLAS    |
| 伊  | TEAM WALK-MAN         | 2    | 36:35:00 | 2脚      | 独自       |
| 米  | TEAM TROOPER          | 2    | 42:32:00 | 2脚      | ATLAS    |
| 独  | TEAM HECTOR           | 1    | 2:44     | 2脚      | ROBOTIS  |
| 米  | TEAM VALOR            | 0    | 0:00     | 2脚      | 独自       |
| 日  | TEAM AERO             | 0    | 0:00     | 4脚      | 独自       |
| 米  | TEAM GRIT             | 0    | 0:00     | 4脚      | 独自       |
| 香港 | TEAM HKU              | 0    | 0:00     | 2脚      | ATLAS    |

DRCは人型ロボットのみを対象とした競技会ではなかったが、Atlasが人型であったこと、階段等脚でなければ移動が困難な環境が含まれていたことから、多くのチームが人型のロボットで競技に臨んだ。しかし結果を見ると、2脚以外の移動機構を採用したチームが上位に集中している。2脚の移動機構を持つロボットのほぼ全てが一度は競技中に転倒したことも合わせて考えると、二足歩行は更なる技術開発が必要である。

DRCは災害時に人に代わって活躍できるロボットを開発することを目的として実施されたが、優勝したTeam KAISTですら8つのタスクを実施するのに45分を要した。仮に同じタスクを人が実施していれば5分程で完了するものと思われ、迅速な対応が求められる災害現場にロボットを投入するには不十分である。自動運転の技術はDARPA Urban Challengeから10年を経て実用化に漕ぎ着けており、災害対応ロボットに関しても実用化に向けて研究開発を継続していくことが重要である。

### 1.8.5 AIによる科学的発見に関するグランドチャレンジ

AIによる科学的発見は、一つの大きな分野である。この分野でのグランドチャレンジとして、ロボカップの提唱者の一人でもあるソニーコンピュータサイエンス研究所(Sony CSL)の北野宏明氏は、「2050年までにノーベル賞級の科学的発見を行うAIシステムを開発する」という目標を掲げたグランドチャレンジを提唱している。特に、医学生理学賞をターゲットとしている。

更に、ノーベル賞は人間に与えられる賞であることから、「Nobel Turing Challenge」として、ノーベル賞級の科学的発見をするAIシステムが、選考委員会からAIであると見破られないで受賞をするというチャレンジを課している。

今までも、AIシステムによる科学法則の発見に関する研究は行われてきた。しかしながら、それらの研究は、既に発見されている法則を、計算機で再発見できるかという試みや、エキスパートシステムの一つであるなど、本当の意味で大きな科学的発見に結び付く展開にはならなかった。

しかし、現在多くの科学分野で大規模データを扱うことが一般化し、膨大な計算を可能とする各種のインフラストラクチャが実現している。同時に、1990年代中頃から登場したシステムバイオロジーの分野では、大規模網羅データを系統的に測定する技術を加速すると同時に、詳細な生命の設計原理や分子機構への洞察を深めた。この状況の変化は、新たにAIによる科学的発見という分野に、再度、グランドチャレンジを設定して、取り組むべき時期にきたと思われる。

この一つの作業仮説は、科学的発見とは、大規模仮説空間の生成・探索と、それらの仮説の高速検証であるというものである。この作業仮説の背景には、今までのグランドチャレンジは、大規模データ、大規模計算、更には機械学習という三つの要因で成り立っていたという分析がある。であるならば、科学的発見も、大規模仮説空間の生成と探索で可能であろうと思える。

このチャレンジを実現するためには、一連のプラットフォームの構築が必要である。このため、まず、各種のデータ並びにモデル表現などに関して標準化を行うコミュニティを成立させている。さらに、解析ソフトウェアなどの相互運用性を実現する必要がある。そこで、「Garuda Platform<sup>8</sup>」を構築し、これらの問題を解決しようとしている。これらの基盤があって初めて、極めて大きな科学的発見を行うAIシステムの開発が可能であると考えている。また、生物実験の精度を向上させ、効率を追求したロボット実験システムの開発も行われている。これらの流れが連動し、このグランドチャレンジを成功に導くと思われる。

このグランドチャレンジは、グローバルな分散協調プロジェクトとなると思われる。仮想的な大規模プロジェクトをどう進行させるのかという新たなマネジメント上のチャレンジでもある。しかし、各々のチャレンジは、極めて重要かつ新規性の大きなものであり、グランドチャレンジ達成への中間段階で、大きな成果の展開も期待できる。

#### 参考文献

- [1] 「ノーベル賞級の発見をするAI 人の限界を超えた科学研究へ」日経エレクトロニクス, 2016.7, pp.97-108.
- [2] Hiroaki Kitano, "Artificial Intelligence to Win the Nobel Prize and Beyond: Creating the Engine for Scientific Discovery," *AI Magazine*, vol.37 No.1, pp.39-49.

---

※8

Sony CSL北野宏明が開発したシステムバイオロジー研究のための統合型データ解析プラットフォーム。

# 1.9 各国の研究開発の現状

## 1.9.1 総論

我が国では、経済産業省、総務省、文部科学省にそれぞれ人工知能（AI）研究のためのセンター（産業技術総合研究所、情報通信研究機構（NICT）、理化学研究所）があり、それぞれAI研究を推進するとともに、連携して研究開発に当たることとなっている。民間企業においても、自動運転や生産ロボットなどの一部の業界において、本格的な研究開発に取り組み始めている状況である。我が国のAIに関わる研究開発の今後の発展に向けて、アルゴリズムの基礎研究、応用研究を更に振興するとともに、ロボティクスや計算用のデバイスなどものづくりの強みを活かした研究開発が有効と考えられる。

海外については、主に米国の情報系企業のディープラーニングに関する取組が早い段階から展開されている。2006年にディープラーニングの研究の発端となった論文を執筆したジェフリー・ヒントン氏は、トロント大学（カナダ）の教授であるが、現在Google（米国）と兼任している。そのほか、ディープラーニング分野の著名な研究者の多くは、Microsoft Research（米国）や、Facebook AI Research（米国）等のいち早く設立された民間情報系企業の研究所に移籍や兼任、アドバイザー等の形で関わっており、情報系企業のAIの研究開発戦略を担っている。また、中国はアカデミックの研究のほか、情報系企業もAIに力を入れており、追い上げが著しい状況である。

米国政府は、「Preparing for the future of artificial intelligence」というレポートを2016年5月に発表し、AIの研究開発の方向性を示した。もともと米国では2015年にイノベーション戦略“A STRATEGY FOR AMERICAN INNOVATION”を策定し、ニューロサイエンス、コネクテッドカーや自動運転車、先進マニファクチャリング、スマートシティといったAIに関連の深いテーマを重点分野として指定しているほか、BRAIN Initiative、Precision Medicine Initiativeや国防高等研究計画局（DARPA）でのSyNAPSEプログラム等、AIと関連の深い分野の研究開発も推進しており、今後も様々な分野でAIへの投資を継続すると予想される。

英国はケンブリッジ大学、オックスフォード大学において従来からAI研究が盛んであるとともに、先端的なディープラーニングの研究開発を行っているGoogle DeepMindの本拠地でもある。ドイツも、ドイツ人工知能研究センター（DFKI）において民間企業との共同研究を多く実施しており、マックスプランク研究所や大学等を含めて、AIや脳科学まで含めれば研究人材が一定数存在している。ディープラーニングへの対応は米国に先を越されたと言わざるを得ないが、従来から「Horizon 2020」<sup>1</sup>において、ヒューマン・ブレイン・プロジェクトを実施しており、脳のシミュレーションから応用まで幅広い範囲で研究を推進してきている実績もある。今後のAI研究に脳科学の知見が取り込まれる過程で重要な寄与をする可能性がある。

中国では、人材の豊富さも手伝って、AIの研究開発が加速している。2016年3月には政府は「インターネットプラス AI3年行動実施法案」を発表し、自動運転、ロボット、スマートホーム等の重点分野において世界トップクラスの企業を育成する目標を掲げている。また、Baidu、Alibaba、Tencent等の情報系企業もAIへの対応を急いでいる。

※1

2014年～2020年まで7年間にわたって、EUの研究開発を促進するためのプログラム。

## 1.9.2 各国の政策・プロジェクトの現状

### 1.9.2.1 我が国のAI研究開発政策

我が国では、「第5期科学技術基本計画」※（平成28年1月22日閣議決定）において、AIを「超スマート社会」を実現するための競争力向上のための基盤技術として位置付け、その強化を推進することとなった。超スマート社会とは、「必要なもの・サービスを、必要な人に、必要な時に、必要なだけ提供し、社会の様々なニーズにきめ細かに対応でき、あらゆる人が質の高いサービスを受けられ、年齢、性別、地域、言語といった様々な違いを乗り越え、生き生きと快適に暮らすことのできる社会」である。ICTを最大限に活用し、サイバー空間とフィジカル空間（現実世界）とを融合させた取組により、人々に豊かさをもたらす「超スマート社会」を未来社会の姿として共有。その実現に向けた一連の取組を更に深化させつつ「Society 5.0」として強力に推進し、世界に先駆けて超スマート社会を実現していくこととされた。

第5回「未来投資に向けた官民対話」（平成28年4月12日）において、安倍総理がAIの研究開発目標と産業化のロードマップを平成28年度中に策定することを表明した。それを受けて、AIの研究開発・イノベーション政策の司令塔となる「人工知能技術戦略会議」が平成28年4月18日に発足し、総務省、文部科学省、経済産業省の3省が連携してAI技術の研究開発と成果の社会実装の加速に当たることとなった。

人工知能技術戦略会議の下には、上記3省のそれぞれが所管するAI研究のためのセンターが存在するため、各センターの研究の総合調整を行う場として研究連携会議が設置されるとともに、人材育成、標準化・ロードマップ作成、技術・知財動向分析、規制改革等のテーマについて研究開発と産業の連携総合調整を図る産業連携会議が設置されて議論が行われている<sup>2</sup>。平成29年3月31日には「人工知能技術戦略」<sup>3</sup>を公表するとともに、「人工知能の研究開発目標と産業化のロードマップ」<sup>4</sup>が策定された。この中では、「生産性」、「健康、医療・介護」、「空間の移動」の3分野及び横断的分野として「情報セキュリティ」が重点分野とされ、3センターが連携して研究開発に取り組むとともに、産学官が有するデータ及びツール群の環境整備を実施することとされた（表14）。

■表14 3センターの連携による研究開発テーマ

| 重点分野     | 研究テーマ概要   |
|----------|---|
| 生産性      | ハイパーカスタマイゼーションの実現を目指し、消費者の需要を反映させた適時適量・多品種少量生産を可能とする次世代生産技術の研究開発。                     |
| 健康、医療・介護 | 予防医療の高度化による病気になるらないヘルスケアの実現を目指し、認知症を含む疾患の早期発見、最適な治療法選択、対処を可能とするシステムの研究開発。             |
| 空間の移動    | SIPにおける自動走行システムと連携しながら、地図データの意味付けやユニバーサルコミュニケーション技術による移動空間の高付加価値化を実現するスマートモビリティの研究開発。 |

※2

人工知能技術戦略会議「資料1 人工知能技術戦略会議について」  
新エネルギー・産業技術総合開発機構ウェブサイト  
<<http://www.nedo.go.jp/content/100790387.pdf>>

※3

人工知能技術戦略会議「人工知能技術戦略（人工知能技術戦略会議とりまとめ）」新エネルギー・産業技術総合開発機構ウェブサイト  
<<http://www.nedo.go.jp/content/100862413.pdf>>

※4

人工知能技術戦略会議「人工知能の研究開発目標と産業化のロードマップ」新エネルギー・産業技術総合開発機構ウェブサイト  
<<http://www.nedo.go.jp/content/100862412.pdf>>

※5

産業構造審議会 産業技術環境分科会 研究開発・イノベーション小委員会「イノベーションを推進するための取組について」経済産業省ウェブサイト <[http://www.meti.go.jp/committee/sankoushin/sangyougijutsu/kenkyu\\_kaihatsu\\_innovation/pdf/report01\\_01.pdf](http://www.meti.go.jp/committee/sankoushin/sangyougijutsu/kenkyu_kaihatsu_innovation/pdf/report01_01.pdf)>

経済産業省の産業構造審議会 産業技術環境分科会 研究開発・イノベーション小委員会ではイノベーションを推進するための取組について議論が行われた。平成28年5月13日に公表した中間とりまとめ<sup>5</sup>では、AIの産業構造を一変させ得る技術として位置付け、国費による国家プロジェクトの研究成果の一部であるデータについて、オープンイノベーションによる利活用を促進するためのデータ戦略を検討することも重要とされた。

新エネルギー・産業技術総合開発機構（NEDO）では、平成27年度から「次世代人工知能・ロボット中核技術開発」をスタートし、次世代AI技術分野として①計算論的神経科学の知見を取り入れた脳型AIやデータ駆動型のAIと知識駆動型のAIの融合を目指した研究開発、②様々な次世代AI技術を統合するフレームワークの研究開発、③標準的ベンチマークやデータセットの整備、革新的ロボット要素技術分野として④革新的なセンシング技術、⑤革新的なアクチュエータ技術、及び⑥ロボットインテグレーション技術の研究開発を実施している。また、平成29年度からは、⑦社会実装に関する研究開発の先導研究を実施する予定としている（表15、表16）。また、「IoT推進のための横断技術開発プロジェクト」では、アナログ型抵抗変化素子を用いた脳型推論集積システムの開発や、革新的アニーリングマシンの研究開発等を実施している<sup>6</sup>。

■表15 次世代人工知能・ロボット中核技術開発」の次世代人工知能技術分野の研究開発項目

| No | 研究開発項目                                    | 概要  |
|----|---|---|
| ①  | 大規模目的基礎研究・先端技術研究開発                        | 最新の計算論的神経科学の知見を取り入れた脳型 AI 及びデータ駆動型の AI と知識駆動型の AI の融合を目指すデータ・知識融合型 AI に関して、大規模なデータを用いた実世界の課題への適用とその結果の評価を前提とした目的基礎研究(大規模目的基礎研究)と、世界トップレベルの性能の達成を目指す先端技術の研究開発を実施する。  |
| ②  | 次世代人工知能フレームワーク研究・先進中核モジュール研究開発            | 広範な AI 応用の研究開発や社会的実用化に資するため、研究開発項目①の成果である脳型 AI 技術、データ・知識融合型 AI 技術、そのほか大学や企業が保有する様々な AI 技術をモジュール化し統合するための次世代 AI フレームワークと、次世代 AI 技術を統合し、多様な応用に迅速につなげるための核となる先進中核モジュールの研究開発を実施する。                              |
| ③  | 次世代人工知能共通基盤技術研究開発                         | 次世代 AI の共通基盤技術として、AI 技術の有効性や信頼性を定量的に評価し、性能を保証するための方法、そのために必要となる標準的問題設定や標準的ベンチマークデータセット等が満たすべき性質と構築の方法に関する研究開発を実施する。また、それらを用いて、研究開発項目①、②の成果の評価を行う。   |
| ⑦  | 次世代人工知能技術の社会実装に関するグローバル研究開発(平成 29 年度より実施) | 次世代 AI 技術の社会実装が求められる領域として、「人工知能の研究開発目標と産業化のロードマップ」における当面の検討課題のうち、(1)生産性、(2)健康、医療・介護、(3)空間の移動の 3 領域において、関連する課題の解決に資するため、次世代 AI 技術の社会実装に関する研究開発を先導研究から実施する。なお、AI 技術とものづくり技術との融合等を国内外の叡智を集集して、グローバルに行うことを考慮する。 |

■表16 次世代人工知能・ロボット中核技術開発」の革新的ロボット要素技術分野の研究開発項目

| No. | 研究開発項目                         | 概要  |
|-----|--------------------------------|---|
| ①   | 革新的なセンシング技術(スーパーセンシング)         | 屋外等の外乱の多い空間でも、的確に信号抽出ができる画期的な視覚・聴覚・力触覚・嗅覚・加速度センシングシステムやセンサと行動を連携させて、検知能力を向上させる行動センシング技術等の研究開発を実施する。 |
| ②   | 革新的なアクチュエーション技術(スマートアクチュエーション) | 人共存型ロボットに活用可能なソフトアクチュエータ(人工筋肉)、高度な位置制御やトルク制御を組み合わせるソフトウェア的に関節の柔軟性を実現する新方式の制御技術や機構等の研究開発を実施する。       |
| ③   | 革新的なロボットインテグレーション技術            | 実環境の変化を瞬時に認知判断し、即座に対応して適応的に行動する技術や個別に開発された要素技術を効果的に連携させ統合動作させるシステム統合化技術等の研究開発を実施する。                 |

※6

「IoT推進のための横断技術開発プロジェクト」新エネルギー・産業技術総合開発機構ウェブサイト  
[http://www.nedo.go.jp/activities/ZZJP\\_100123.html](http://www.nedo.go.jp/activities/ZZJP_100123.html)

表17 AI研究センター(AIRC)のチーム構成

| 研究チーム                   | 研究の概要  |
|-------------------------|--|
| 知能情報研究チーム               | データに内包される意味を理解し、知識を抽出する技術の研究を実施。文章形式のデータのみならず様々な形式のデータを分析し、その中に記述されている出来事の因果関係や、登場する言葉の概念構造、情報の鮮度と客観性、情報間の矛盾などを、AIが認識し、データベース化する技術。  |
| 確率モデリングチーム              | 様々なデバイスから得られる実世界の大量データ(ビッグデータ)と、人が持つ知識の両方を融合し、高度なタスクを実行するAIを学習させる確率モデリング技術の開発。   |
| 脳型人工知能研究チーム             | 大脳皮質に関する神経科学的知見をヒントにした BESOM と呼ぶ機械学習アルゴリズム(ベイジアンネット、自己組織化マップ、独立成分分析などを組み合わせたもの)の実用化を目指した研究。  |
| 機械学習研究チーム               | ベイジアンモデリング、カーネル法、ディープラーニングなどの先端的な機械学習技術の理論基盤、アルゴリズムの研究開発から、リモートセンシングデータ、医療データ、経済データ、ロボットの感覚・運動データ等の実データへの応用まで幅広く研究を実施。   |
| 人工知能クラウド研究チーム           | 実世界から取得される多種多様な大量のデータ(ビッグデータ)を対象とした高度かつ高性能なデータ処理技術の確立と、これを基盤として、AI技術の容易かつ迅速な適用を可能にする次世代AIフレームワークの実現を目指した研究。  |
| 人工知能応用研究チーム             | 機械学習に基づく画像解析や音響データ解析による異常検知などをコア技術とし、社会インフラ診断及び医療診断・ヘルスケア支援に資する技術の実用化に向けた研究。   |
| サービスインテリジェンス研究チーム       | 人々が主体的・共創的にインテリジェンス(観察、判断、行動力)を高める方法論とそれを効率的に実現するAI技術を研究。具体的には介護、看護、健康増進、保育、教育、理美容などの現場に知識工学、設計工学、データ工学、認知科学、バイオメカニクスなどを適用し、横展開可能な技術を開発する。   |
| 計算社会知能研究チーム             | 人と人、人とサービスの相互作用を取り入れたシステム設計を工学的に支援するため、人々の振る舞いを継続的にセンシングする技術と、人を系に組み込んだシミュレーション手法を組み合わせ、サービス導入、変更の影響を都市規模で予測することを目指した研究。   |
| 地理情報科学研究チーム             | 多種多様な膨大な地理空間情報を知的に処理できる基盤を開発し、科学研究だけでなく環境管理、資源開発、防災といった具体的な応用に結び付けた研究。   |
| 生活知能研究チーム               | 多様な生活機能変化者に適合した安全な生活、自立した生活、高度な社会参加のある生活の実現といった社会的インパクトのある具体的課題を設定し、IoT技術、画像処理技術、生活データベース技術、ロボット技術などの研究を推進。また、大規模生活データからニューノーマル化した生活課題をいち早く見つけ、そのソリューションを開発可能にする「生活知識循環エコシステム」の創造も長期的な狙いとしている。 |
| オミクス情報研究チーム             | ライフサイエンスにて生産される大量のオミクス情報から有用な知識を抽出するための情報解析技術及びAI技術の開発。具体的には、ゲノム及びエピゲノム情報解析技術、遺伝子ネットワーク解析技術、タンパク質立体構造シミュレーション技術などの開発を実施。   |
| インテリジェントバイオインフォマティクスチーム | ゲノム情報を始めとする多様な膨大な生命情報に関するデータから生体分子に関する知識発見を行うためのバイオインフォマティクス技術の開発と、疾病因子の推定や生体分子の機能解析などを通じた創薬などへの応用。  |

経済産業省が所管する産業技術総合研究所では、平成27年5月1日にAI研究センター(AIRC)を設立した(表17)。主要な目的基礎研究として、①人間の脳の情報処理原理に関する最新の神経科学の知見を包括的に取り入れた人間の脳に近い脳型AIと、②実世界の大量のデータに基づくデータ駆動型のAIとウェブ上の大規模な知識グラフなどに基づく論理的・形式的な知識駆動型のAIの2つを融合して、大量かつ多様な実世界のデータを深く理解し、人間の意思決定を支援するデータ・知識融合型AIの研究を行うことを目標としている(図47)。

これらの目標のため、AIフレームワーク上で要素技術を統合した先進中核モジュールを実装して、製造業やサービス産業などの幅広い分野での産学連携による実サービスから得られる大規模なデータを使った実証研究、研究用データセットなど、AI技術の研究の基盤となるリソースの整備の実施を通じて、幅広い用途でのAI技術の有用性を提示し、産業競争力の強化と豊かな社会の実現に貢献することを目指している。

具体的には、「人工知能に関するグローバル研究拠点整備事業」<sup>7</sup>では医療・介護現場、住環境、工場等の模擬環境の整備と個別分野のデータの収集・管理、解析、2次提供を行うデータ基盤の構築等を実施するオープンイノベーション・ハブ拠点を構築している。また、「人工知能・IoTの研究開発加速のための環境整備事業」<sup>8</sup>や、「人工知能処理向け大規模・省電力クラウド基盤」(ABCI)などの整備を進めており、ディープラーニングの研究開発の基盤となることが期待されている(1.7.3項参照)。

総務省では、総務大臣の諮問機関である「情報通信審議会情報通信技術分科会技術戦略委員会」において、平成28年7月に「次世代人工知能推進戦略」を取りまとめた<sup>10</sup>。本戦略では、我が国で注力していくべき研究開発分野として、8個のテーマが掲げられている(表18)。

※7  
産業構造審議会 産業技術環境分科会 研究開発・イノベーション  
小委員会「イノベーションを推進するための取組について」  
経済産業省ウェブサイト <[http://www.meti.go.jp/committee/sankoushin/sangyougijutsu/kenkyu\\_kaihatsu\\_innovation/pdf/report01\\_01.pdf](http://www.meti.go.jp/committee/sankoushin/sangyougijutsu/kenkyu_kaihatsu_innovation/pdf/report01_01.pdf)>

※8  
「IoT推進のための横断技術開発プロジェクト」新エネルギー・産業  
技術総合開発機構ウェブサイト  
<[http://www.nedo.go.jp/activities/ZZJP\\_100123.html](http://www.nedo.go.jp/activities/ZZJP_100123.html)>

表18 「次世代人工知能推進戦略」の研究開発テーマ

| No. | 概要  |
|-----|---|
| ①   | 小規模データしか得られない場合に、強化学習やスパースモデリングと呼ばれる技法を用いて学習を実現する AI 技術の開発。   |
| ②   | ディープラーニングの欠点(問題が複雑な場合に汎化能力が欠如するという本質的な課題や、入力と出力の関係がブラックボックスとなってしまう、システムに不具合が生じてもその原因の究明や品質保証が困難になる課題)を克服した機械学習法の研究開発。   |
| ③   | 少量のデータしか得られない場合でも、多数の入力データを活用することによって汎化能力が高められる半教師あり学習など新たな機械学習法の研究開発。  |
| ④   | ロボット等の運動と AI の組合せにより、プランニングを行ったり、シンボルグラウンディングを行う問題に関する研究開発。   |
| ⑤   | 機械翻訳や音声翻訳などの自然言語処理技術と対訳コーパスの開発及び蓄積、並びにウェブや SNS、更には学術論文や公的文書等の多種多様な知識を利用する技術、こうした知識をより効率よく人間に伝え活用するための手段として対話ロボット等の開発。   |
| ⑥   | ネットワーク上のクラウド等と自律的に処理を分担するとともに、システム間での情報共有が可能となる等、相互に通信し連携しながら自律的に判断、行動し、人の意思決定や行動を支援するための、IoT/ビッグデータ、AI を前提としたネットワーク型 AI 社会基盤の実現(例えば、異なる機械学習アルゴリズムの融合に基づいた通信の効率化や、情報のスパース符号化による通信量の削減、更には脳の動的なネットワークの再構成を模倣した効率よいルーティングなど)。 |
| ⑦   | 脳活動計測データ自体の解析への AI の適用。   |
| ⑧   | 人間の脳の情報処理メカニズムを参考にしたディープラーニングの新たなパラダイムの創出など、脳科学の知見の AI への適用。  |

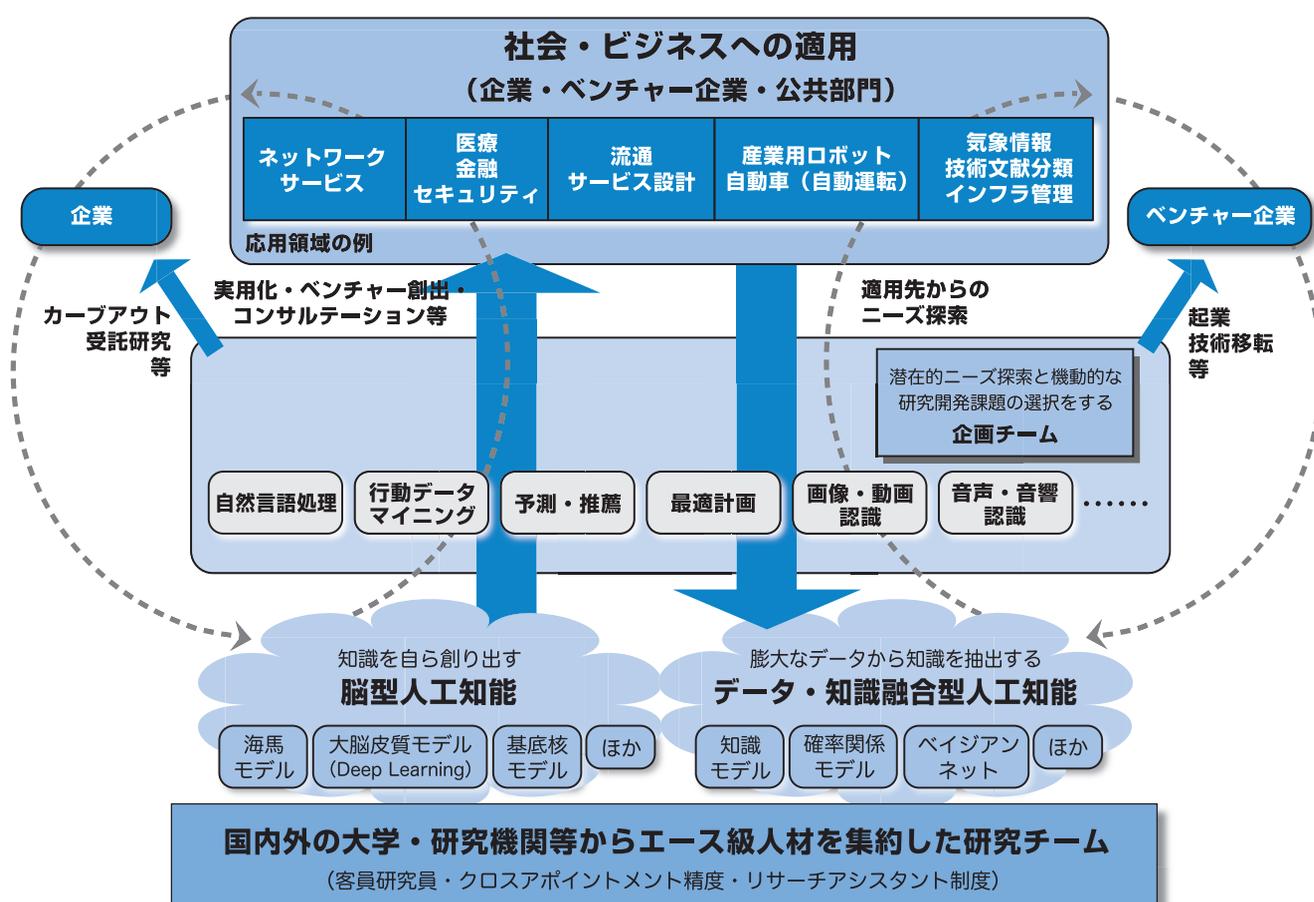


図47 AI研究センター(AIRC)における研究開発の取組<sup>9</sup>

※9 「人工知能研究センター」を設立 -人工知能研究のプラットフォーム形成をめざして- 産業技術総合研究所ウェブサイト <[http://www.aist.go.jp/aist\\_j/news/pr20150507.html](http://www.aist.go.jp/aist_j/news/pr20150507.html)>編集部作成  
 ※10 「次世代人工知能推進戦略」 総務省ウェブサイト <[http://www.soumu.go.jp/main\\_content/000424360.pdf](http://www.soumu.go.jp/main_content/000424360.pdf)>  
 ※11 「ALAGIN 言語資源・音声資源サイト」 ALAGIN 言語資源・音声資源ウェブサイト<<https://alaginrc.nict.go.jp/>>

※12 先進的音声翻訳研究開発推進センターウェブサイト<<http://astrec.nict.go.jp/research/index.html>>  
 ※13 「AIプロジェクト(人工知能/ビッグデータ/IoT/サイバーセキュリティ統合プロジェクト)」に係る平成28年度戦略目標の決定について」文部科学省ウェブサイト <[http://www.mext.go.jp/b\\_menu/houdou/28/05/1371147.htm](http://www.mext.go.jp/b_menu/houdou/28/05/1371147.htm)>

所管のNICTでは、脳情報通信、音声認識、多言語音声翻訳、社会知解析、革新的ネットワーク技術等の研究開発をかねてより進めている。例えば、高度言語情報統合フォーラム（ALAGIN）<sup>11</sup>では、自然言語処理の研究に資する言語資源・音声資源の整備を実施している。また、脳情報通信融合研究センターでは、システム神経科学、情報通信技術、ブレインマシンインターフェース、ニューロイメージング技術及びロボット工学の研究を実施している。更に、先進的音声翻訳研究開発推進センターでは、東京オリンピック・パラリンピック競技大会が開催される2020年までに、国内の鉄道などの交通機関やショッピング施設、観光地、医療の現場などで活用される実用性の高い多言語音声翻訳技術や、企業などにおいて他国の特許を自動で翻訳できる多言語テキスト翻訳技術などを開発している<sup>12</sup>。

次世代人工知能推進戦略では、このようなNICTがこれまで整備を進めてきた言語情報データや脳情報モデルを基盤として、全国規模で利用可能とする「最先端AIデータテストベッド」の整備、脳機能に学び知能を理解・創造する次世代AI技術の研究開発、IoT／ビッグデータ／AI情報通信プラットフォームの開発等を推進することとしている。

文部科学省は「人工知能／ビッグデータ／IoT／サイバーセキュリティ統合プロジェクト」（AIPプロジェクト）を推進しており<sup>13</sup>、その研究開発拠点として、理化学研究所に革新知能統合研究センター（AIP）を平成28年4月に新たに設置した（表19）。

■表19 AIPプロジェクトにおける研究テーマ<sup>14</sup>

| No. | 概要  |
|-----|---|
| ①   | 社会・経済等に貢献するため、多種・膨大な情報を組み合わせ解析する技術開発（カプセル内視鏡やCTなどから取得される膨大な医療画像を診断において高速処理する技術、電子カルテの高度解析による投薬や治療計画最適化をサポートする技術、病気の予兆を発見する技術等）。   |
| ②   | 多種・膨大な情報に基づき、状況に応じ最適化されるシステムのための技術開発（自動運転に関わる膨大な情報から安全走行に必要な情報のみを取捨選択し計算負荷を大幅に低減するデータ処理技術、災害発生時にネットワークを状況に応じ自律的に構成する技術、データの意味を高度に理解してデータの統合分析を可能とするオントロジー、時系列データのリアルタイム分析技術等） |
| ③   | 多種多様な要素で構成される複雑なシステムに適用可能なセキュリティ技術開発（予測型セキュリティ技術、軽量暗号化アルゴリズムの開発・実装、セキュリティ・バイ・デザイン、来歴等のエビデンス情報（プロヴェナンス）によるデータ信頼性検証技術等）。  |

科学技術振興機構（JST）では、戦略的創造研究推進事業（新技術創出）の一環として、AIPに対応した研究領域を設定しプロジェクトを推進している。CRESTの新領域「イノベーション創発に資する人工知能基盤技術の創出と統合化」が平成28年度に新たに設定され、実社会の様々な分野に資するセンサ技術、実時間ビッグデータを扱うデータベース技術、システムセキュリティ技術、機械学習を核とするシステム最適化技術等の高度化と実世界データを総合的に実時間で処理し理解する統合化技術の研究開発が実施されている。

### 1.9.2.2 米国のAI研究開発政策

米国では、全米科学財団（NSF）、国防総省傘下のDARPAや、分野別には国立衛生研究所（NIH）、エネルギー省等により、AIや脳科学の技術開発投資が多く行われてきた。

※14

「急速に高度化・複雑化が進む人工知能基盤技術を用いて多種膨大な情報の利活用を可能とする統合化技術の創出」文部科学省ウェブサイト <[http://www.mext.go.jp/b\\_menu/houdou/28/05/attach/1371148.htm](http://www.mext.go.jp/b_menu/houdou/28/05/attach/1371148.htm)>

※15

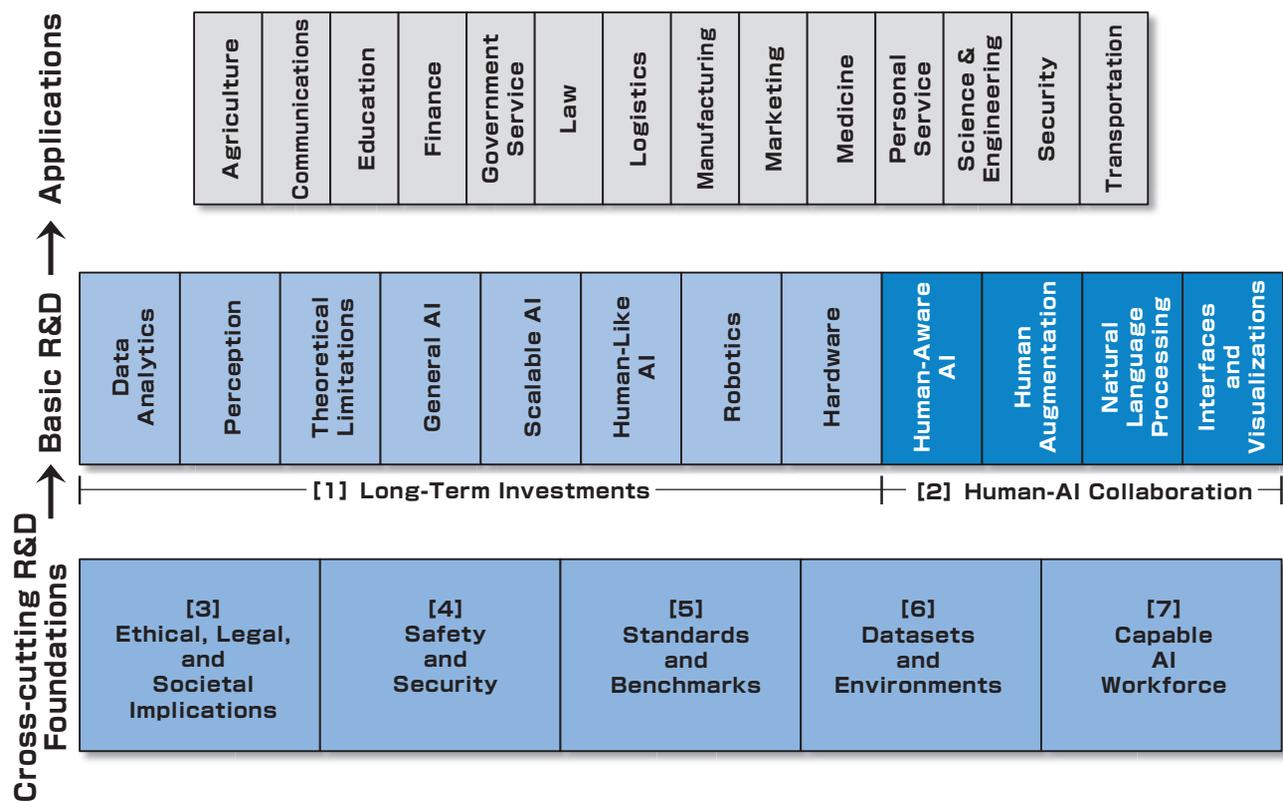
“A STRATEGY FOR AMERICAN INNOVATION.” The white house Website <[https://obamawhitehouse.archives.gov/sites/default/files/strategy\\_for\\_american\\_innovation\\_october\\_2015.pdf](https://obamawhitehouse.archives.gov/sites/default/files/strategy_for_american_innovation_october_2015.pdf)>

※16

「ライフサイエンスのフロンティア研究開発の動向と生命倫理—（平成27年度 科学技術に関する調査プロジェクト）」国立国会図書館ウェブサイト <<http://www.ndl.go.jp/jp/diet/publication/document/2016/index.html>>

※17

“Artificial Intelligence: CALO.” SRI international Website <<https://www.sri.com/work/timeline-innovation/timeline.php?tag=security-and-defense#!&innovation=artificial-intelligence-calo>>



■図48 米国のAIのR&D戦略の構成

2015年に国家経済会議（National Economic Council; NEC）と大統領科学技術政策局（OSTP）により策定された「A STRATEGY FOR AMERICAN INNOVATION」<sup>15</sup>では、ニューロサイエンス、コネクテッドカーや自動運転車、先進マニファクチャリング、スマートシティといったAIに関連の深いテーマを重点分野として指定している。

NSFは、2006年から多種・大容量のデータ処理等関連技術の基盤となる研究開発を継続的に支援しており、2015年からの新たなプログラムでは、基礎研究（3年）、学際研究（3～4年）、大規模研究（4～5年）の募集が数十万～100万ドル規模で実施されている。

2014年に発表されたBRAIN（Brain Research through Advancing Innovative Neurotechnologies）Initiative（BRAINイニシアティブ）では、脳内の神経回路構造を細胞から脳全体のレベルまで全ての階層について調べることで、脳の構造と機能、動作原理の解明を目指した研究が進められている<sup>16</sup>。

米国におけるAI研究では、歴史的にDARPAが果たしてきた役割が大きい。例えば、Appleの音声アシスタント「Siri」に利用されている技術の源流はDARPAの「CALO」（Cognitive Assistant that

※18 “Deputy Secretary of Defense Speech.” U.S. Department of Defense Website <<https://www.defense.gov/News/Speeches/Speech-View/Article/634214/cnas-defense-forum>>

※19 “THE NATIONAL ARTIFICIAL INTELLIGENCE RESEARCH AND DEVELOPMENT STRATEGIC PLAN,H October 2016. The white house Website <[https://obamawhitehouse.archives.gov/sites/default/files/whitehouse\\_files/microsites/ostp/NSTC/national\\_ai\\_rd\\_strategic\\_plan.pdf](https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/national_ai_rd_strategic_plan.pdf)>

※20 「ライフサイエンスのフロンティア—研究開発の動向と生命倫理—（平成27年度 科学技術に関する調査プロジェクト）」国立国会図書館ウェブサイト <<http://www.ndl.go.jp/jp/diet/publication/document/2016/index.html>>

Learns and Organizes)” プロジェクトにおいてSRI Internationalが開発した技術である<sup>17</sup>。近年では、自動運転を目指すアーバンチャレンジや災害用ロボットの実現を目指すロボティクスチャレンジ等のグランドチャレンジや（1.8節参照）、IBMのニューロモーフィックチップであるTrueNorthがDARPAのプロジェクトにより開発されている。

最近では、軍事装備品の諸外国に対する優位性を維持するための「第3のオフセット戦略」の中で、技術的に重要であるビルディングブロックとして、自律的なディープラーニングを用いたシステム、人と機械の協働、人の行動のエンハンスメント、人と機械の協調動作、半自律的な武器、の5点を挙げており、装備品へのAIの活用を目指すプロジェクトを活発化している<sup>18</sup>。

2016年12月にはオバマ政権が「The National Artificial Intelligence Research and Development strategic Plan」を発表しており<sup>19</sup>、長期的な基礎研究の継続性の重要性の指摘している。また、特に重要なテーマとして、人とAIのコラボレーションに資する技術を取り上げている（図48）。

### 1.9.2.3 欧州のAI研究開発政策

EUでは、2013年からの10年間にわたる重点科学プロジェクトとしてヒューマンブレインプロジェクト（HBP）が推進されており、総額12億ユーロが投じられる予定となっている<sup>20</sup>。プロジェクトのスコープは幅広く、脳に関係する遺伝子やたんぱく質の発現情報の取得から人の認知機能のメカニズムの解明、脳のシミュレーション、治療やロボットの研究のためのツール開発まで幅広い範囲の研究開発がなされている。

また、英国では、「UK Digital Strategy」が文化・メディア・スポーツ省により2017年3月に発表され、サイバーセキュリティ、フィンテック、ゲーム、仮想現実、GovTech<sup>21</sup>等におけるAIの活用を推進することにより、関連領域のビジネスを後押しするとしている<sup>22</sup>。

ドイツでは製造業の産業競争力強化を目指して「Industrie 4.0」が推進され、関連したシステム研究開発等を実施している。マックスプランク研究所や大学等を含めて、AIや脳科学まで含めれば研究人材が一定数存在している。ディープラーニングへの対応は米国に先を越されたと言わざるを得ないが、従来からHorizon 2020において、HBPに参画している研究者が多数おり、脳のシミュレーションから応用まで幅広い範囲で研究を推進してきている実績もあり、今後AIに脳科学の知見が取り込まれている過程で重要な寄与をする可能性がある。

また、Horizon 2020の下では、機械翻訳のプロジェクト「Quality Translation21」（QT21）等が実施されている。

### 1.9.2.4 中国のAI研究開発政策

中国では、人材の豊富さも手伝って、AIの研究開発が猛烈な勢いで加速している。2016年3月には政府は「インターネットプラス AI3年行動実施法案」を発表し、自動運転、ロボット、スマートホーム等の重点分野において世界トップクラスの企業を育成し、2018年までに1000億元の市場を創出する目標を掲げている。

---

※21  
政府、行政、公共分野を支援するテクノロジーのこと。

※22  
政府、行政、公共分野を支援するテクノロジーのこと。GOV. UK Website <<https://www.gov.uk/government/publications/uk-digital-strategy>>

※23  
中華人民共和国中央人民政府ウェブサイト<[http://www.gov.cn/xinwen/2017-02/20/content\\_5169236.htm](http://www.gov.cn/xinwen/2017-02/20/content_5169236.htm)>

※24  
Yunhe Pan, “Heading toward Artificial Intelligence 2.0,” Engineering, vol.2 No.4, 2016, pp.409-413. Engineering Website <<http://engineering.org.cn/EN/10.1016/J.ENG.2016.04.018>>

また、「科学技術イノベーション2030」の重点項目に最近「artificial intelligence 2.0 (AI2.0)」が追加された<sup>23</sup>。AI2.0では、今後、ビッグデータに基づくAI、クラウドベースのAI、人と機械をハイブリッドすることにより実現するAI、自律的システムの4点を重視するとしている<sup>24</sup>。

### 1.9.3 民間企業の研究開発の現状

#### 1.9.3.1 我が国の民間企業における研究開発動向

我が国の民間企業においては、特にディープラーニングに対する取組について、米国の情報系企業を中心とする取組に比べ、国内のAI関連の人材不足もあり（2.3節参照）、大手企業において国内外の研究機関と連携することで研究開発を進めている事例が見られる。例えば、Toyota Research Institute（米国）はシリコンバレーに研究所を開設し、スタンフォード大学等との共同研究を実施している。ソニーは、強化学習分野で世界的に著名な研究者であるマーク・リング（Mark Ring）氏がCEOを務めるスタートアップCogitai（米国）に資本参加し、ディープラーニングを用いた強化学習や予測・検知技術の応用に取り組んでいる。また、リクルートホールディングスは、データ分析の自動化技術を開発しているDataRobot（米国）に出資している。パナソニックは、大阪大学と人工知能技術とそのビジネス応用に関する人材開発を共同で行うための人工知能共同講座を開始している。

このほかに、AIの研究を実施している大手企業は、製造業や情報通信業の企業に多く見られる。東芝は、送電線の損傷等の異常画像をディープラーニングで生成し、学習用データの不足を補う仕組みの開発等を実施している。ホンダは、傘下のホンダ・リサーチ・インスティテュート・ジャパンにおいて、脳の計算原理のモデル化に取り組んでいるほか、「人と協調する人工知能技術」等を研究する研究開発組織を新設している。富士通研究所では、手書き文字認識について、教師データが少なくても学習可能なディープラーニング技術の開発を実施している。NECは、顔認証技術にディープラーニングを取り入れ、顔の向きの変化等にも強い、動画を対象とした顔認証を開発した。NTTは、コミュニケーション基礎科学研究所において、ディープラーニングを用いた音声認識技術の研究を実施している。

そして、日立製作所がイジング計算機と呼ばれる組合せ最適化問題に特化したチップを開発しているほか、ディープラーニングを高速かつ高効率に行うチップの開発が、パナソニック、デンソー、NEC、東芝、富士通等によって進められている（1.7.6項参照）。なお、ディープラーニングのオープンソースのフレームワークであるChainerを開発するプリファードネットワークスは、ファナック、DeNA、トヨタ自動車等と協業している（1.2.10項参照）。

#### 1.9.3.2 米国の民間企業における研究開発動向

2006年にディープラーニングの興隆の発端となった論文を執筆したヒントン氏は、トロント大学の教授であるが、現在はGoogleと兼任している。このように、米国の場合、大学と民間企業の研究所間の人材交流が大変活発であることが特徴である。ヒントン氏のほかにも、Facebook AI Researchのヤン・ルカン氏等、AI分野の著名な研究者が多く民間情報系企業の研究所に移籍や兼任、アドバイザー等の形で関わっており、情報系企業のAIの研究開発戦略を担っている。

ジェフリー・ディーン（Jeffrey Dean）氏が率いるGoogle Researchは、1200名程度（2017年4月現在）の研究者を擁する。特にディープラーニングに特化したGoogle Brain Teamは、ディープラーニングの理論的研究から自然言語処理、機械翻訳等の研究を進めており、Neural Turing Machine等、パターンと記号処理の融合を目指す分野で本質的な研究を多く行っている。また、ディープラーニングのフレームワークであるTensorFlowをオープンソースとして公開している。

Vicarious (米国) は、AIのコア技術を開発するベンチャー企業であり、スタンフォード大学のAI Labのディレクターであるフェイ・フェイ・リー (Fei-Fei Li) 氏や、スパースコーディングで有名なカリフォルニア大学バークレー校のブルーノ・オルシャウセン (Bruno Olshausen) 氏が科学アドバイザーを務めている。注力する研究テーマとして、脳科学の知見を取り入れたニューラルネットワーク、少量のデータからの学習や教師なし学習など、今後のAIの研究開発でキーとなり得るものを挙げており、注目に値する (図49)。

### 1.9.3.3. 欧州の民間企業における研究開発動向

英国はケンブリッジ大学、オックスフォード大学において従来からAI研究が盛んであるとともに、Google DeepMindの本拠地でもある。ディープラーニングと強化学習の組合

|                          |  |
|--------------------------|--|
| <b>少量のデータからの学習モデルの開発</b> | <ul style="list-style-type: none"> <li>通常の深層学習では学習に大規模なデータセットが必要であるが、人間は1例で学習することも可能である</li> <li>出来るだけ少ないデータで学習可能なことが知能のコアである</li> </ul> |
| <b>教師なし学習</b>            | <ul style="list-style-type: none"> <li>深層学習の成功例は現在のところ教師あり学習</li> <li>教師なし学習が多くの問題で重要となる</li> </ul>                                      |
| <b>脳科学からの知見</b>          | <ul style="list-style-type: none"> <li>新皮質の構造によりアルゴリズムにもたらされる制約が脳の効率的処理の根本にある</li> <li>脳に関する知見を取り入れたアルゴリズムの開発を実施する</li> </ul>            |
| <b>ネットワーク構造の重要性を強調</b>   | <ul style="list-style-type: none"> <li>現在の主流モデル (CNN) にとらわれず、compositionality を重視したネットワーク構造を採用</li> </ul>                                |
| <b>生成モデル</b>             | <ul style="list-style-type: none"> <li>「想像」することが出来るシステム</li> <li>因果的意味論を取り入れることが可能</li> </ul>  |

■図49 Vicariousが掲げる研究テーマ

|  |   |
|--|---|
| GOTO 1 2<br>HGOTO<br>RGOTO<br>ACT(RIGHT)<br>VGOTO<br>UGOTO<br>ACT(UP)  | 1  2  3    |
| GOTO 1 2<br>HGOTO<br>RGOTO<br>ACT(RIGHT)<br>ACT(RIGHT)<br>ACT(RIGHT)<br>VGOTO<br>DGOTO<br>ACT(DOWN)<br>ACT(DOWN)         | 1  2  3 <br>4  5  6   |
| GOTO 1 2<br>HGOTO<br>LGOTO<br>ACT(LEFT)<br>ACT(LEFT)<br>ACT(LEFT)<br>ACT(LEFT)<br>ACT(LEFT)<br>VGOTO<br>UGOTO<br>ACT(UP) | 1  2  3 <br>4  5  6 <br>7  |
| GOTO 1 2<br>HGOTO<br>LGOTO<br>ACT(LEFT)<br>VGOTO<br>DGOTO<br>ACT(DOWN)   | 1  2  3    |

■図50 仮想3次元空間内に自動車の3Dモデルをランダムな向きで置き、その状態から正面を向く様に回すプログラムを生成する例<sup>26</sup>

※26  
 Scott Reed and Nando de Freitas, "Neural Programmer-Interpreters." Cornell University Library Website <<https://arxiv.org/abs/1511.06279>>

※27  
 "Opening a new chapter of my work in AI." Medium.com Website <<https://medium.com/@andrewng/opening-a-new-chapter-of-my-work-in-ai-c6a4d1595d7b>>

※28  
 "A Chinese Internet Giant Enters the AI Race." MIT Technology Review Website <<https://www.technologyreview.com/s/603070/a-chinese-internet-giant-enters-the-ai-race/>>; Tencent AI Lab Website <<http://ai.tencent.com/ailab/>>

※29  
 検索日は2017年3月27日。

※30  
 欧州特許庁 (European Patent Office, EPO) に出願され発行されたもの。

せで囲碁においてトッププロ棋士に勝利したAlphaGoを作ったGoogle DeepMindの研究開発動向は、仮想的な3次元の迷路を解くエージェントの開発や、リカレントニューラルネットワーク（RNN）でプログラミングを行ってしまう例など、今後のAI開発の方向性を見据えた取組を多く実施している（図50）。

ドイツも、DFKIにおいて、Volkswagen（ドイツ）など民間企業との共同研究を多く実施しており、自然言語処理、知識処理、仮想現実、データマイニング等の研究を実施している。

### 1.9.3.4 中国の民間企業における研究開発動向

中国では、Baidu、Alibaba、Tencent等の情報系企業のAIへの取組が先行している。Baiduでは、1300名程度がAI事業に関わっており、そのうち300名程度が研究者である<sup>27</sup>。

Tencentでは、50人の研究者を擁し、機械学習、コンピュータビジョン、音声認識、自然言語処理の研究を行っている<sup>28</sup>。ソーシャルアプリであるQQのデータを背景として、

高性能なビッグデータ解析のためのプラットフォームであるAngelを2017年の第一四半期にオープンソースとすることを発表している。

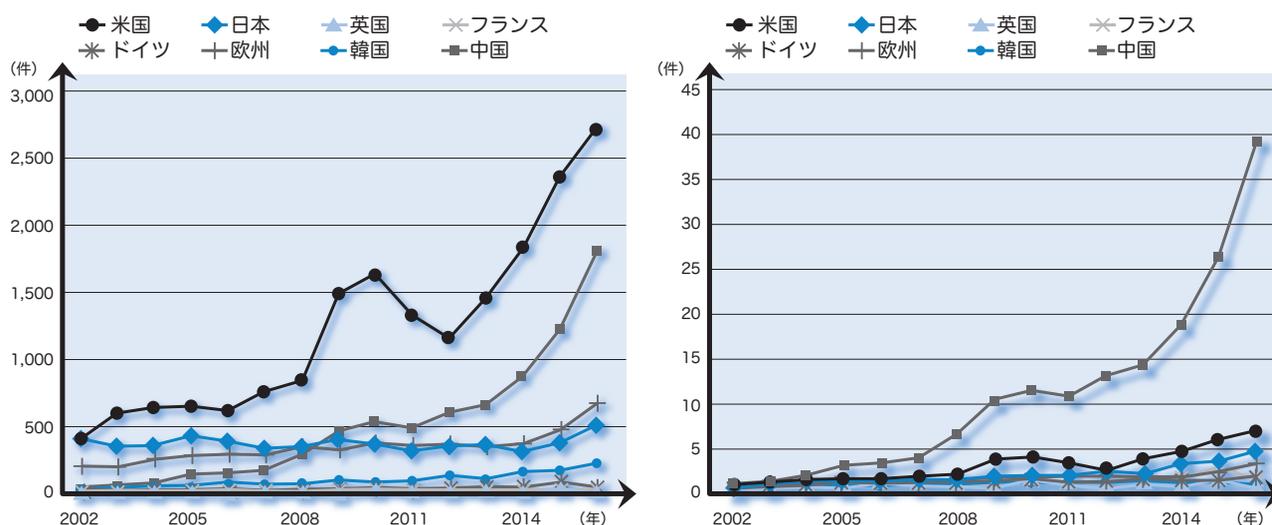
## 1.9.4 特許・論文の動向

### 1.9.4.1 特許動向

AIが様々な領域に影響を与え始めている変革期においては、広い範囲で特許権を取得できるケースは少なくない。また、AIの進展は著しく、自社技術として秘匿しても、優位性を維持できる期間は短い。そのため、国内外の主要企業等では、開発した技術に関わる特許出願を進めている状況にある。

図51に、AIに関わる特許の動向を示す。調査対象は、2002年から2016年の期間に発行された公開特許公報とし、検索にはクラリベイト・アナリティクスのThomson Innovationを使用し、国際特許分類（IPC）の分類コード「G06N」（特定の計算モデルに基づくコンピュータ・システム）を用いた<sup>29</sup>。

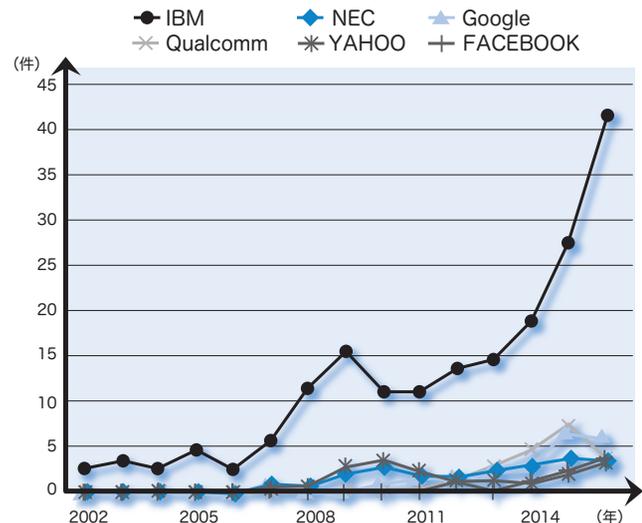
各国の特許文献数を見ると、2002年には日本が399件とトップに位置していたが、米国及び中国における発行数の伸長により、2016年では米国（2,691件）、中国（1,795件）、欧州<sup>30</sup>（664件）、日本（497件）と日本の特許文献数は相対的に低下しつつある。また、2002年の件数を1とした場合の2016年の文献数は、中国（39.0）、米国（6.9）、韓国（4.6）と続き、日本は1.2と横ばい傾向となっている。



■図51 各国の特許文献数(左：2002年～2016年の推移、右：2002年を1としたときの増減)

| 出願人           | 2002～2006年 | 2007～2011年 | 2012～2016年 |
|---------------|------------|------------|------------|
| IBM           | 165        | 550        | 1,166      |
| Mivrosoft     | 170        | 334        | 369        |
| Qualcomm      | 6          | 14         | 209        |
| Google        | 3          | 38         | 202        |
| NEC           | 18         | 82         | 155        |
| SAMSUNG       | 23         | 46         | 111        |
| FUJITSU       | 35         | 56         | 95         |
| SONY          | 134        | 121        | 94         |
| YAHOO         | 4          | 103        | 94         |
| FACEBOOK      | 3          | 6          | 92         |
| HP            | 82         | 63         | 81         |
| Simens        | 24         | 102        | 72         |
| SAP           | 44         | 67         | 62         |
| D-Wave System | 52         | 44         | 55         |
| ORACLE        | 20         | 78         | 39         |

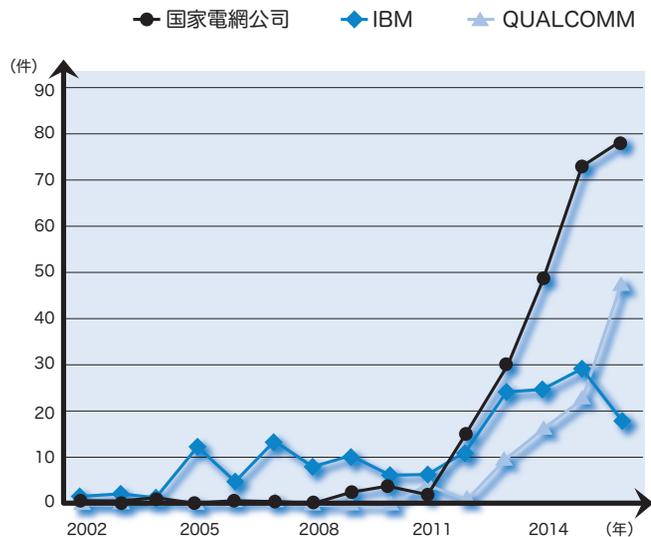
(注) 各機関の上位5機関のセルをハッチングしている



■図52 米国における出願人の動向(左：上位出願人と件数、右：主な出願人の件数推移)

| 出願人       | 2002～2006年 | 2007～2011年 | 2012～2016年 |
|-----------|------------|------------|------------|
| 国家電網公司    | 0          | 8          | 245        |
| IBM       | 21         | 43         | 107        |
| Qualcomm  | 2          | 5          | 98         |
| Microsoft | 54         | 42         | 91         |
| 西安電子科技大学  | 0          | 27         | 82         |
| 浙江大学      | 0          | 47         | 73         |
| 清華大学      | 3          | 30         | 61         |
| 東南大学      | 1          | 18         | 55         |
| 北京航空航天大学  | 1          | 61         | 53         |
| SONY      | 51         | 70         | 53         |
| 天津大学      | 0          | 20         | 51         |
| 北京工業大学    | 2          | 19         | 50         |
| 南京航空航天大学  | 0          | 14         | 42         |
| Siemens   | 8          | 24         | 35         |
| Philips   | 13         | 43         | 16         |

(注) 各機関の上位5機関のセルをハッチングしている



■図53 中国における出願人の動向(左：上位出願人と件数、右：主な出願人の件数推移)

次に、特許文献数の多い米国、中国、日本における国別の出願人の動向を示す。

米国においては、IBMが首位であり、次いでMicrosoftが追従する状況にある。我が国企業は、2002～2011年の期間でソニーが、2012～2016年の期間でNECが上位に位置している。また、近年の件数の伸び率をみてもIBMが他社を圧倒している様子がうかがえるが、近年、Google、Qualcomm、FacebookやNECが、急速に件数を伸ばしている(図52)。

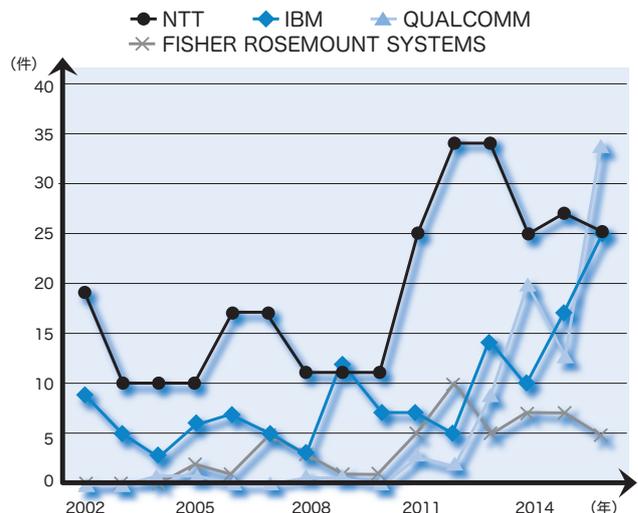
中国においては、中国全土へ送電・変電・配電を行う国家電網会社が首位であり、2012～2016年の

※31

論文の検索にはクラリベイト・アナリティクスのThomson Innovationを使用し、Web of science及び国際会議のプロシーディングスを対象とした。検索キーワードは“deep learning” OR “deep neural network”とし、教育学関係の検索キーワード(“education” OR “education\*” OR “school” OR “student” OR “college” OR “classroom” OR “undergraduate” OR “psychology\*” OR “therapy” OR “personality” OR “gesture”)を含むものを排除した。対象国は特に限定していない。

| 出願人              | 2002～2006年 | 2007～2011年 | 2012～2016年 |
|------------------|------------|------------|------------|
| NTT              | 66         | 75         | 145        |
| FUJITSU          | 81         | 52         | 90         |
| Qualcomm         | 2          | 5          | 78         |
| IBM              | 30         | 34         | 71         |
| SONY             | 104        | 140        | 68         |
| NEC              | 30         | 60         | 58         |
| TOSHIBA          | 71         | 67         | 47         |
| CANON            | 41         | 29         | 40         |
| HITACH           | 42         | 42         | 34         |
| FISHER ROSEMOUNT | 3          | 15         | 34         |
| Microsoft        | 60         | 36         | 22         |
| FUJI XEROX       | 39         | 25         | 17         |
| Philips          | 23         | 40         | 17         |
| HONDA            | 22         | 32         | 16         |

(注) 各機関の上位5機関のセルをハッチングしている



■図54 日本における出願人の動向(左: 上位出願人と件数、右: 主な出願人の件数推移)

期間に245件もの件数となっている。米国のMicrosoftやIBM、Qualcommが、我が国企業では、ソニーが上位に位置している。中国の特徴として、大学からの特許出願が2007年以降増加し、公開される特許の多くを占めるようになってきている (図53)。

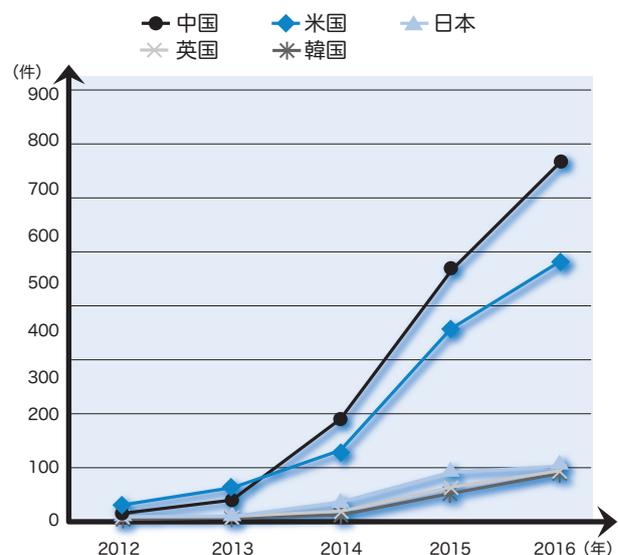
日本においては、ソニーが発行総数312件で首位であり、NTT (286件)、富士通 (223件) と続く。近年の傾向を見ると、IBMやQualcommなどの海外資本企業が件数を伸ばしている (図54)。

#### 1.9.4.2 論文動向

図55に、ディープラーニングの研究論文の2012年～2016年の発表件数の推移を示す<sup>31</sup>。現在のディープラーニングの興隆の嚆矢となるのは、トロント大学のジェフリー・ヒントン氏らの2006年の研究であるが、ディープラーニングの潜在的な能力が2011年から2012年にかけて音声認識や画像認識のコンテストで認識されて以来、ディープラーニングを用いた研究は増加の一途を辿っていることが分かる (図55)。

国別に見ると、2013年の段階で中国が米国を抜いてトップに立っている。また、我が国も英国、韓国とほぼ同等の件数を発表している。

プレプリントサーバである「arXiv<sup>32</sup>」を用いたキーワードトレンド分析<sup>33</sup>では、機械学習分野で2016年に前年よりも使用頻度が大きく増加したキーワードとして、残渣ネット (ResNet) (1.2.7項参照)、生成敵対ネットワーク (GAN) (1.2.5項参照)、RNN (1.2.5項参照)、ニューラル機械翻訳 (1.4.4項参照) 等が挙げられている。



■図55 ディープラーニングに係る論文数の年次推移(上位5ヶ国)

※32

プレプリントとは、研究者が論文原稿を学術誌に発表する前に研究者コミュニティで共有するもの。プレプリントを共有する仕組みとして、コーネル大学(米国)が運営するarXivが有名である。Cornell University Library Website <<https://arxiv.org/>>

※33

“A Peek at Trends in Machine Learning.” Medium Website <<https://medium.com/@karpathy/a-peek-at-trends-in-machine-learning-ab8a1085a106>>

# 1.10 各国の研究開発の現状

## 1.10.1 総論

本章では、人工知能（AI）の体系全体が、ディープラーニングの登場により、パターンの世界での学習が可能になったことにより変革され、従来難しかった記号処理の世界とパターン認識の世界の融合へ向けた端緒が見えてきた状況を記述してきた。本節では改めて、AI技術の今後の発展がどのような順序で実現していくかについて、整理を行う。

短期的には、本章でこれまで記述してきた様に、特徴量の学習を可能としたディープラーニングにより、特に画像認識等のパターン認識の精度が人間並みに向上してきたことを受けて、パターン認識の応用開発が様々な分野で進められるものと考えられる。また、ディープラーニングと、強化学習の仕組みを組み合わせれば、ロボットの動作の学習への応用が可能である。用途をある程度限定した目的であれば、比較的短期に利用されていくものと考えられる。

ディープラーニングによるAIの適用範囲の拡大を目指すには、論理的な推論やプログラムの様な記号的処理をニューラルネットワークで実現することは避けて通れない。理解可能なニューラルネットワークを目指すという意味でも、パターン認識と記号的処理をどのように融合すれば良いかという問題は解決すべき課題である。中期的には、この課題の解決に向けて、脳の持つ様々な機能を模倣したディープラーニングを構成していく試みと、記号を実世界と関連付けるシンボルグラウンディングを段階的に進めていくことが必要である。

更に長期的には、汎用AI（Artificial General Intelligence; AGI）の実現に向けて、自己の認識状態を認識するメタ認知の機能や、他人にも自分と同じ心があることを理解し、心の動きのモデルを自分の中にも構築した上で、他人の動きとそのモデルを同期させ他人の心の状態を推測する心の理論など、現状ではほとんど実現されていないモデルが必要となると考えられる。このような研究開発においては、認知科学、言語学、脳科学、複雑系科学、計算科学等、AIと関連する周辺諸分野の知見も十分に取り入れつつ、最終的にはAGIの実現を目指していくことが必要であろう。

以下では、ディープラーニングに基づくパターン処理と、記号的処理が段階的に融合していくものと考えられる中期的な発展に関する見通しと、長期的観点から、最終的なAIの形態ともいえるAGIへ向けた取組について整理する。

## 1.10.2 シンボルグラウンディングの段階的解決へ向けて

本項では、AI分野の課題の整理をした上で、今後の課題の解決の可能性を整理する。

今後、中期的には、ディープラーニングによるパターン認識と、記号的処理が融合していくものと考えられるが、具体的にどのような課題をどのような順番で実現していくかについては、必要とされる記号の意味がどの程度深いものであるかによって決まるものと考えられる。

短期的に進むと考えられる画像認識に代表されるパターン認識と、ロボットの動きの学習などは、さほど記号の深い意味に踏み込まずに処理できる領域であり、研究開発と社会実装が進むものと考えられる。その後に関しては、記号の意味を実世界の事物へ関連付けるシンボルグラウンディングというハードルを乗り越えることが必要となる。

シンボルグラウンディング問題は、AI分野で古くから課題とされてきた問題の一つである。冒頭～1.3節で述べたように、シンボルグラウンディング問題を解く鍵は、身体性の実現にある。身体性とは、メタ認知や内部的な動機に基づいて、行動（環境への働きかけ）の計画と行動の結果の予測を行い、実

# 何ができるようになるか

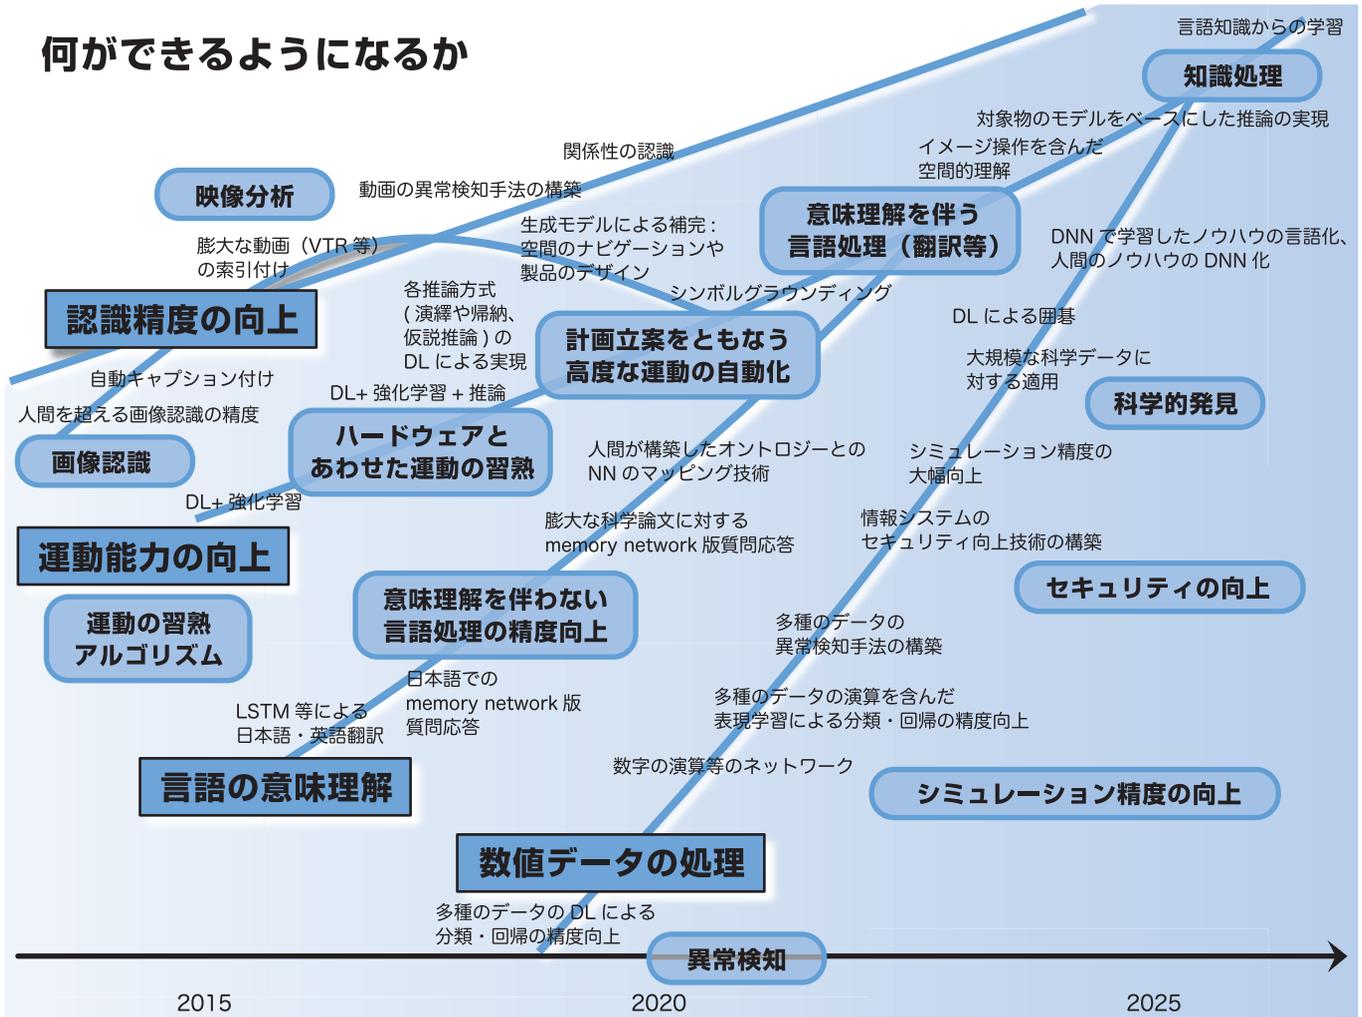


図56 今後のAIの発展の方向性<sup>1)</sup>

行後にその影響の評価を行い、内部のモデルに還元するという認知のループを行う枠組みであり、そのループのイタレーションの中で、記号が自発的に分節されるのが記号創発の仕組みであった。

したがって、外界の事物のパターン、そのパターンの時間的发展を予測するモデルを、内部モデルとして知能の中に持つことが必要となる。外界の事物のパターンを内部モデル化することはディープラーニングで実現されたことであり、その時間的发展を予測することは生成モデルにより実現されたことである。そして、ディープラーニングが登場してから数年経った現在、シンボルグラウンディングに必要であった機能が、現在手元にあるということである。

その結果、今後のAIの技術の発展は、おおよそ次のように進むと考えられる（図56）。まず、既に精度の向上が進んでいる画像処理等のパターンの認識技術と、ロボティクスのハードウェア技術の進化と強化学習に基づく制御の高度化技術が融合。その融合の中で生成モデルが活用されることで、身体性の枠組みがある程度実現し、部分的にかもしないが、シンボルグラウンディングが実現し、記号に対応したパターンとしての表現の高度化が可能となる。そこで獲得される表現を基に、自然言語処理の精度の向上も実現するものと考えられる。最終的には、シンボルグラウンディングにより獲得されたパター

※1  
 松尾豊「人工知能に関する技術動向と産業分野への利用可能性」(第2回 経済産業省 産業構造審議会 新産業構造部会 配布資料5)  
 経済産業省ウェブサイト <[http://www.meti.go.jp/committee/sankoushin/shin\\_sangyoukouzou/pdf/002\\_05\\_00.pdf](http://www.meti.go.jp/committee/sankoushin/shin_sangyoukouzou/pdf/002_05_00.pdf)>

ンの世界と、ビッグデータに基づく記号処理の世界が、完全に近い形で融合するものと考えられる。

実世界へのシンボルグラウンディングではないが、パターンの処理と記号的処理の融合へ向けた萌芽的な研究は進められている。以下に脳の短期記憶に相当する機能をディープラーニングに取り込んだメモリネットワークによる推論の研究と、より原理的にチューリングマシンをディープラーニングで実現したNTM (Neural Turing Machine) を紹介する。

リカレントニューラルネットワーク (RNN) は、原理的にはノイマン型コンピュータで計算可能な計算を全て模倣できることが1995年には知られていた。しかし現実には、記号的処理をニューラルネットワークで実現することは、実現には時間がかかるものと考えられてきた<sup>2</sup>。

ところが、2015年、Facebook AI Research (米国) とGoogle (米国) からこの種の問題にチャレンジする研究が相次いで発表された<sup>3</sup>。Facebook AI Researchのジェイソン・ワトソン (Jason Watson) 氏らによるメモリネットワークは、ディープラーニングのネットワークに、明示的に読み書き可能なメモリ機能を組み込むことで、自然言語による推論の課題の精度をLSTM (Long Short-Term Memory) 等に比べて大幅に向上させた (図57)。

ワトソン氏らは、人工的に生成した様々なタイプの質問と回答を教師データとして学習させ、いくつかのタイプの質問に対し、100%に近い推論精度が得られること示した。

図の例において、「Where is the ring?」の問いに答えるには、指輪 (ring) の動きに関し、人が指輪を持った状態で移動すると、それに伴って指輪も移動するという概念が獲得されている必要がある。このような技術は、質問応答システムや対話インターフェース等、現実的な応用先も多く、ワトソン氏らの研究をきっかけとして多くの改良モデルが提出されている。また、ニュース原稿に関する質問応答など一般的な内容に関しても約80%弱程度まで正解を出せるようになっている。

Bilbo travelled to the cave. Gollum dropped the ring there. Bilbo took the ring.  
Bilbo went back to the Shire. Bilbo left the ring there. Frodo got the ring.  
Frodo journeyed to Mount-Doom. Frodo dropped the ring there. Sauron died.  
Frodo went back to the Shire. Bilbo travelled to the Grey-havens. The End.  
Where is the ring? A: Mount-Doom  
Where is Bilbo now? A: Grey-havens  
Where is Frodo now? A: Shire

■図57 メモリネットワークにより可能になった推論の例

Googleのアレックス・グレイヴス (Alex Graves) 氏らが発表したNTMも、ディープラーニングにメモリ機能を明示的に組み合わせたモデルである。チューリングマシンとは、アラン・チューリング氏が定式化した現在のノイマン型計算機の理論的なモデルであり、演算器とメモリとなるテープ、テープへの読み書きが可能なヘッドから構成されるものである。グレイヴス氏らは、このメモリと読み書きのヘッドをディープラーニングに組み込み、全てが逆誤差伝播法で学習可能な様に定式化を行った。NTMにより、入力出力へのコピー、ソーティングや連想記憶など、比較的簡易なアルゴリズムがニューラルネットワークで実現できることを示した。

※2  
ただし、リカレントニューラルネットワーク (Recurrent Neural Network; RNN) は、原理的にはノイマン型コンピュータで計算可能な計算を全て模倣できることが証明されている。

※3  
Facebook AI ResearchのメモリネットワークのarXivへの投稿の5日後に、GoogleのNeural Turing Machineが同じくarXivへ投稿された。

### 1.10.3 汎用AIに向けて

#### 1.10.3.1 目標としての汎用AI

更に長期的には、上記の様なメモリ機能だけでなく、人間の知能が持つ機能を汎用AIの実現へ向けた研究が必要となる。現在実用化されている対象とするタスク（例えば、囲碁、自動運転など）に特化したAIは特化型AIと呼ばれ、対象とするタスクに応じた事前知識が潤沢に組み込まれている。これに対し、人間のように十分に広範な適用範囲と強力な汎化能力を持ち、多種多様な問題の解決することが可能なAIをAGIと呼んでいる。

AIの登場以来、人間のような知性の実現は究極目標であったが、20世紀の間はあまりにも遠いものと考えられていた。しかし最近のディープラーニング技術の進展などを契機としてその目標は到達可能なものとなってきた。こうした背景において、技術的に定義し得る人間レベルの知能の研究目標として、汎用性が着目されている。AGIが備えるべき特徴としては、経験からの学習を通じて様々な問題に対する多角的な解決能力を獲得できること、人間と同程度に多種多様な知的能力を発揮できること、等が挙げられる。

逆に「AGIは何ではないか」を指摘するなら、以下のようにいえるだろう。

- 単に特化型AIの寄せ集めではない
- 最初から何でもできる知能ではない
- タブラ・ラサ（白紙）から学習するのではない
- 意識の有無は考慮しない（評価が困難）

AGIは任意の人間の知的活動を代替し効率化する技術であることから、経済成長及び生活レベルの向上に大きく資する。そして今世紀半ば頃には、人間個人の知能全般を凌駕し、我々の生活を支える生産者とその管理者の役割をおおむね担う技術と予測されている。一度人間レベルのAIが作られれば、それ自身を使って新たなAIを設計・製造（再帰的自己改修）することが可能になる。その際には生物の進化とは比較にならない速度で自己再帰的に発展し、人類がこれまで行ってきたペースに比べると格段に早い速度で、知を蓄積することができる。この大きな変化は、しばしば「技術的特異点」(Technological Singularity) と呼ばれる。

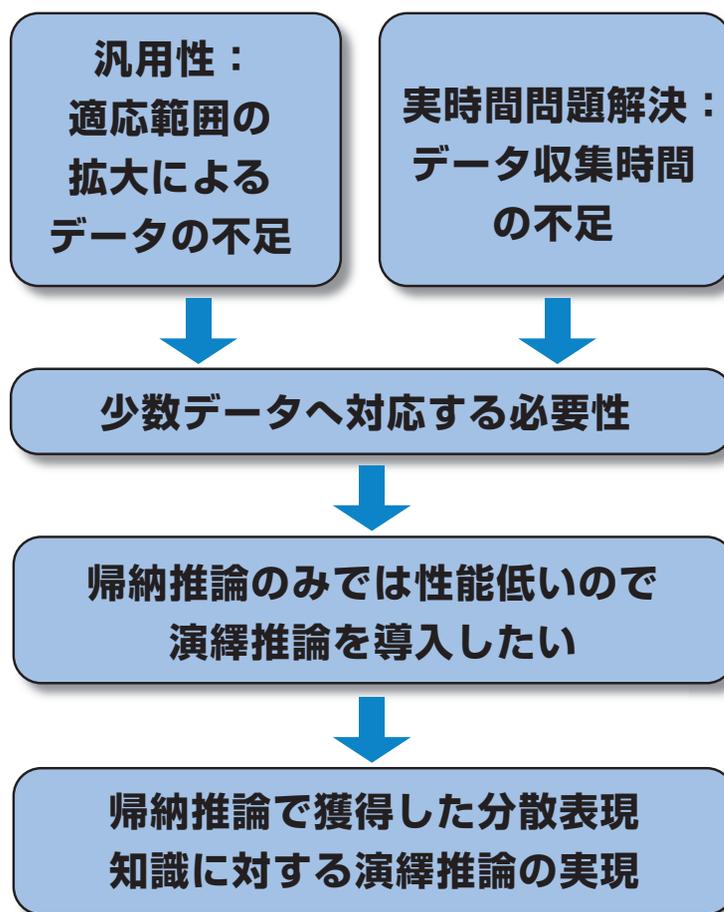
AGIを目指す主要なアプローチとして、外界から情報を取り入れて、何らかの意味で適切な意思決定や行動、制御（若しくはその支援）を行うための認知アーキテクチャの研究がある。認知アーキテクチャでは、人間の総合的な認知機能をモデル化しており、AIの創成期より様々なモデルが研究・開発されてきている。

例えば、カーネギーメロン大学のジョン・アンダーソン (John Anderson) 氏らによって作られた「ACT-R」(Adaptive Control of Thought-Rational) [1]では、人間の認知機能を外界のオブジェクトを認識するための視覚モジュール、目標と意図を記録している意図モジュールなどに分解し、それらが協働することによって、人間と同じような機能を実現する。従来は、心理実験などを通して、認知アーキテクチャの妥当性が測られることが多かったが、近年の脳計測技術の発展により、脳を直接分析することで認知アーキテクチャを構成しようとする、生物からヒントを得た認知アーキテクチャ (BICA) も注目を浴びており、代表的なアーキテクチャとして「LEABRA」、 「Micro PSI」、 「LIDA」 等がある<sup>4</sup>。

※4

“The Biologically Inspired Cognitive Architectures Society.”

BICA Society Website <<http://bicasociety.org/>>



■図58 先鋭化する汎用性をめぐる課題

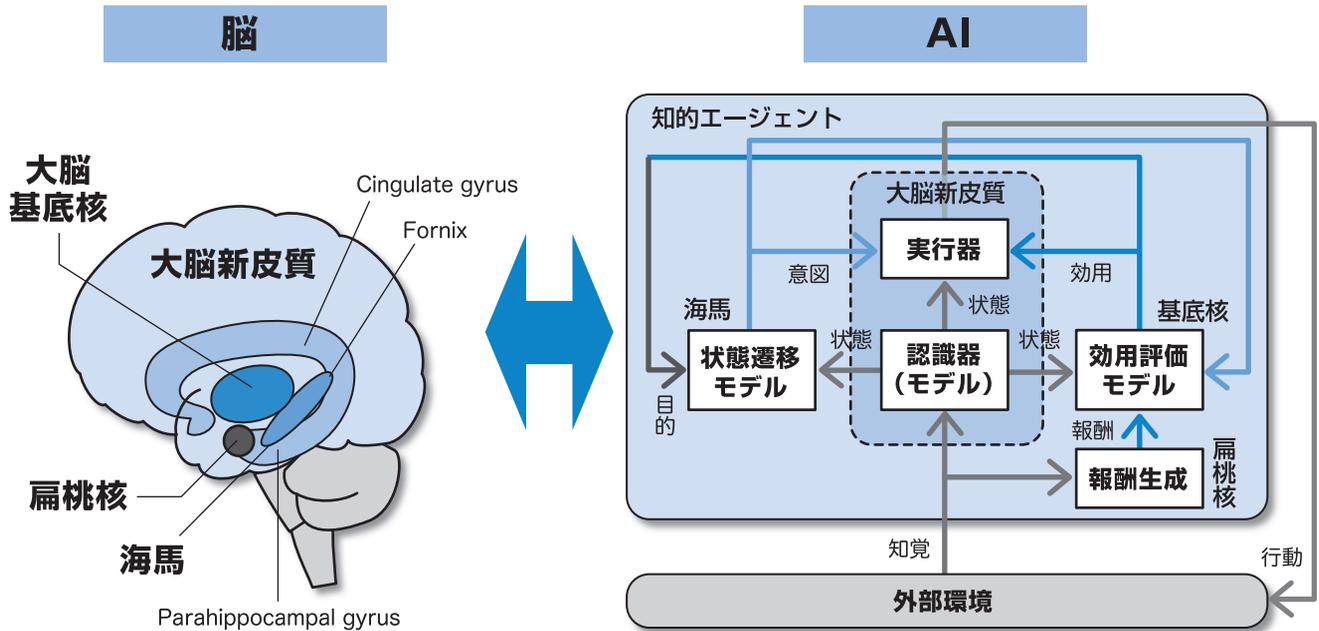
十分にデータを得られるタスクの範囲内であれば、応用価値のある人間並みの性能を持つ学習をすることが可能になった。そこで、最近のAGIの国際会議などにおいて議論されるAIの基本課題は個別のタスクの解決よりも、主に以下のような側面が着目されている。

- 汎用性
- 現実的な時間内での問題解決
- 少数データへの対応
- 演繹推論

実はこの四つの課題は図58に示すように深く関係する。知能の汎用化を目指してタスクの適用範囲を広げていけば、しばしばデータ不足が生ずる。ここで現時的な時間内に問題解決を行おうとすれば、十分なデータを収集するほどの時間的余裕がない。こうしてデータが不足は解消できない状況では帰納推論のみでは良い性能は得られない。そこで、演繹推論を導入することで、データが少ない新たな状況にも対応する必要がある。こうした側面は、以前より繰り返しAI分野で議論されてきたが、ディープラーニングの進展を背景に、AGIという研究の文脈において鮮明化している。

### 1.10.3.2全脳アーキテクチャ・アプローチ

現存するAGIは脳以外には存在しないため、脳の構造と機能を模倣した計算モデルを構築していくことがAGIの研究を進める有力な手段となる。全脳アーキテクチャ(WBA)・アプローチは、「脳全体のアー



■図59 全脳アーキテクチャ・アプローチ

キテクチャに学ぶことで人の様なAGIを創る」という工学的なアプローチである。

こうした脳型AIの研究に資する最新の技術が、ディープラーニングと脳のイメージングである。ディープラーニングは、脳において汎用性を担う大脳新皮質を模倣している計算モデルとみなせる。神経科学においては、光遺伝学等の進歩により、多くのニューロン活動を同時計測し制御できるようになり、脳全体の静的なネットワーク構造や、局所的な詳細なネットワーク構造がコネクトーム研究で明らかにされつつある[2]。こうしてニューロン数個のマイクロな振る舞いと、行動につながる脳全体のマクロな振る舞いとが関連した理解が進んだことで脳をAIとして理解し構築できるようになった。

NPO法人全脳アーキテクチャ・イニシアティブ (WBAI) は、2030年までに公益的な立場から上記アプローチによるAGIの完成を促進することを目的として2015年に創設され、全脳アーキテクチャ (WBA) を進めるための技術基盤として学習環境シミュレータLIS (Life in Silico) 等を構築するとともに、ハッカソンの実施や、さらに勉強会を通じての人材育成、啓蒙活動などをオープンにすすめている。

AI技術では必ずしも人間の脳を参考にする必要はなく、脳の模倣は時として足枷にもなる。しかし、人間のレベルを凌駕するまでは、人間には設計が難しい未解決な計算機能についてのヒント (暫定モデル) が得られるメリットがある。更に理解が進みつつある脳全体に対応する認知アーキテクチャは、分散共同開発において合意しうる技術統合の足場となるため、脳に学んだAGIのオープンな開発が可能になる。

このほか、2016年には国内においても、新学術領域研究 (人工知能と脳科学の対照と融合) や文部科学省 (ポスト「京」萌芽的課題「全脳シミュレーションと脳型人工知能」) の開始、ソニーのCogitai (米国) への資本参加、東京大学の次世代知能科学研究センターの設置、電気通信大学のAI先端研究センターの設置、AIエンジンの開発を進めるベンチャーであるDeep Insightsの設立といったAGIに向けた動きが次第に活発化してきた。

### 1.10.3.3. 海外におけるAGIへの取組

AGIを構築しようとする試みは、2006年頃にベン・ゲーツェル (Ben Goerzel) 氏により提唱され、近年では2015年にDeepMind (英国)、GoodAI (チェコ)、OpenAI (米国) などがAGIの開発を推進していくとの方向性を明確にしている。2016年には、ラットレベルのAGIの開発を宣言したDeep-

Mindが開発成果を続々と発表している。DeepMindは、比較的脳に学ぶ形での研究開発を進めているものと考えられる。

優秀なAI研究者のレベルの創造性を持って更に高度なAIをプログラミングできるAIが造られれば、AI自身による自己再帰的な改良が可能になる。そのレベルに達した最初のAIは、「Seed AI」と呼ばれ、その出現が技術的特異点の起点となる可能性が高い。1980年代頃までに行われたプログラミングを行うAI研究はその後収束していた。しかしDeepMindのチームが2014年10月にディープラーニングにメモリを結合したNTMを提案し、ソートアルゴリズムを自動学習しうることを示すなど、Seed AIに繋がりうる研究成果を示し、2015年にはNPI (Neural Programmer Interpreters) などの成果が公開されている。

GoodAIはAGIを開発することのみを目的に2015年に創設されたチェコของบริษัทであり、できるだけ早く人類を助け世界を理解するためのAGIを完成することをミッションとし、AGI開発のロードマップを公開した上で、5百万ドルのチャレンジを公募している。

この分野ではAGIを育成するためのデータの生成が必要になるため、ゲーム環境を利用した学習環境の公開が進んでいる。WBAIにおいても「LIS」を開発してきたが、OpenAIは、2016年の初頭に主に強化学習のための環境として「OpenAI Gym」を提供し2016年末には「UNIVERS」という環境を公開した。この時期には、「DeepMindはDeepMind Lab」を、Facebookは「TorchCraft」を公開している。

#### 参考文献

- [1] John R. Anderson et al, "An Integrated Theory of the Mind," Psychological Review, vol.111 No.4, pp.1036-1060.
- [2] セバスチャン・スン『コネクトーム:脳の配線はどのように「わたし」をつくり出すのか』草思社.

## 第 2 章

# 利用動向

- 2.1 総論
- 2.2 AIによって何が変わるか
- 2.3 基盤整備状況
- 2.4 企業における利用状況
- 2.5 投資規模・市場規模
- 2.6 今後の展望

# 第2章

## 利用動向

### 2.1 総論

昨今のインターネットサービスやIoT分野におけるビッグデータの増大は、AIの性能を飛躍的に向上させるとともに、AI活用の可能性を高め、産業応用の適用領域を拡大させている。本章では、企業等における最新のAIの利用動向や基盤整備の状況、AIが産業に及ぼす影響や今後の展望について示す。

#### 2.1.1 AIによって何がかわるか

AIの効果を最大化するためには、質の高い学習用データを基に付加価値を生み出す学習済みモデルを生成することが重要となる。先行する企業では、開発した一部の学習済みモデル、学習用データセット、アルゴリズムを公開・共有し、集合知のプラットフォーム形成を進めている。共有された学習済みモデル（共有モデル）や学習用データ（共有データ）を流用するだけでなく、これらを初期状態として再利用することで、比較的少数の学習データから極めて優れた性能を持つ派生モデルを得ることができる。このため、共有モデルや共有データを基に派生モデルを開発し、更にそのモデルを公開・共有することで新たな派生モデルが開発される、といった技術開発の加速度的な連鎖が生じている。

また、質が高く競争の源泉となるデータを独占しようとする動きも見られる。なかでも、サービスのインターフェースにAIを組み込むことで、消費者との接点を押さえて多様なデータの独占を試みるなど、AIをデータ獲得の武器としても利用する企業も現れており、今後もデータ獲得競争が激化する可能性もある。

先行する企業の多くが具体的なビジネスモデルを描けていない中、これらの企業は将来のAI関連市場で競争優位を得るために、プラットフォームの形成やデータの独占を進めている。その一方でアルゴリズム、学習用データ、学習済みモデル等の公開や共有も更に進展する可能性もあり、そうした場合には様々な企業がデータやアルゴリズム等にアクセスできるようになり、学習用データや学習済みモデルは競争優位を得るための差別化領域ではなくなるなど、競争構造が大きく変わる可能性を秘めている。

産業応用の観点では、ディープラーニングは画像認識や音声認識の領域で実用性の高い技術として応用が進められている。画像認識は、自動走行における車外走行環境の認識や医用画像からの疾病等の診断支援で利用が進んでいる。音声や言語の認識は、家庭や自動車内での音声対話や音声アシスタントに応用されているほか、機械翻訳の飛躍的な精度向上も実現している。また、ビッグデータの増大によるAI全般の精度向上により、ものづくり、モビリティ、インフラ、農業、健康・医療・介護、防犯・防災、エネルギー、学習、金融、物流など、多様な産業におけるAIの活用が進展している。

#### 2.1.2 基盤整備状況

AIの利用によるイノベーションを生み出すための、基盤（人材、計算資源、標準化、オープンデータ等）の整備が進んでいる。企業等も、人材や計算資源を確保するために積極的な投資を行っている。例えばト

ヨタ自動車では、中長期的な視点で競争力を高めるために、2016年からの5年間において、研究開発や人材獲得等に対して1,000億円超の投資を行うことを発表している<sup>1</sup>。一方、AI利用に二の足を踏んでいる企業も多く、先行する一部の企業との間に大きなギャップが生じている。また、米国や中国は研究開発投資やスタートアップ企業等への出資を積極的に進めており、日本は先行する米国や積極的に投資を進める中国といった国々と比較して劣後し始めている。

AI利用を支える重要なリソースの一つであり、企業の競争力の源泉である人材の獲得競争が、国内外の企業等で激化している。AIに関わる数学やコンピュータサイエンスの専門性を有する学生や人材の需要は、これまではIT企業が中心であったが、AI関連市場における競争力を高めるために、IT企業のみならず製造業等においても、そういった人材獲得を強化している。その結果、需給のバランスが崩れ、AIに関わる人材に対する給与水準も高まっている。

また、学習のための膨大なデータを管理するストレージや計算処理するためのサーバ資源の整備が進んでおり、AIの研究開発や応用を目的として安価に利用できる基盤の整備も始まっている。学習用データや学習済みモデルの形式や、流通・交換のための規格等に関する国際的な標準化、ディープラーニング・機械学習に関わる機能のオープンソース化が進展しており、基盤を持たない企業等においてもAIを利用する環境が整備されつつある。

企業等のAI利用をより一層促進するために、我が国の言語、風土、文化に適した学習用データセットの共有（共有データ）や、共有データを学習した学習済みモデルの頒布（共有モデル）を進めるための基盤整備が重要となる。

### 2.1.3 今後の展望

日本企業が競争力を高めていくためには、海外企業のAI利用の現状を踏まえた上で、日本企業が将来、優位性を持って発展可能な道筋を見極め、取り組むべき課題や方策を検討する必要がある。

海外のAI利用企業では、検索サービスやSNS、コミュニケーションツールなどのインターネット空間での活動から得られるデータに対して、AIの適用を進めている。特に、ウェブサービスの各分野で圧倒的な世界シェアを誇る海外の大手IT企業は、インターネット空間のビッグデータに実用性の高いAIアルゴリズムを組み合わせてサービス開発を進めている。

先行する企業は、インターネット空間だけにとどまらず、AIの機能を組み込んだ機械やロボットを普及させることで、実空間における消費者との接点も押さえ込みつつある。

海外企業が既に圧倒的なシェアを有する、インターネット空間を中心としたAI利用に、今後日本が対抗して競争優位を築くことは容易ではない。一方、健康情報や自動車から得られる走行データ、工場設備の稼働データ等、個人や企業の実世界における活動から得られる実空間のデータへのAIの適用は、今後の競争領域である。

実空間の産業へのAI適用には、産業領域の深い知識に基づいて獲得されたデータやアルゴリズムが不可欠である。そのため、製造業が保有する実空間のデータと、品質・安全性の追求や全体を把握しながらハードウェアをすり合わせるノウハウなど、日本が各産業領域で保有する強みを活かして、実空間における競争優位を築くための戦略が求められる。

※1

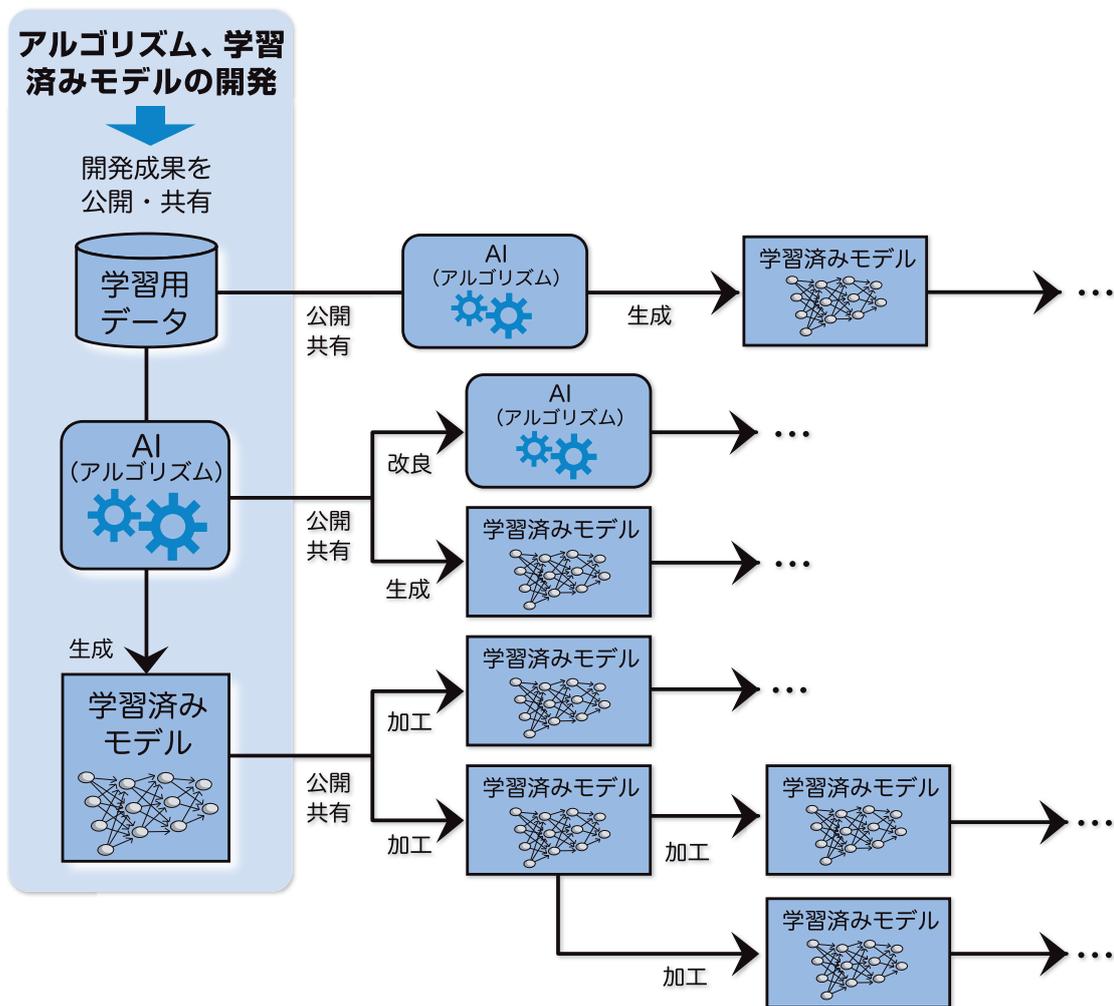
「トヨタ自動車、[人工知能技術]の研究・開発強化に向け新会社を設立」トヨタ自動車ウェブサイト<<http://newsroom.toyota.co.jp/en/detail/10169760>>

## 2.2 AIによって何がかわるか

AIに関わる技術革新に加え、インターネットの浸透やIoTの進展によって、大量のデータが活用できるようになったことで、ディープラーニングや、統計的なアプローチ等の従来手法の精度が高まり、ビジネスプロセスの合理化や付加価値の創出等につながる実用性の高い機能が実現されつつある。

本節では、AI利用の最新動向として、2.2.1項においてAIがもたらす産業への影響に関する動向を示した上で、2.2.2項においてディープラーニングに関する先進的な利用動向、2.2.3項において産業別のAI利用動向を示す。

### 2.2.1 AIがもたらす産業への影響



■図1 アルゴリズム・学習用データ・学習済みモデルの公開・共有による連鎖的な技術開発

※1  
ディープラーニングでは、学習済みモデルに対して、新たに別の課題を学習させる「転移学習」により少量のデータセットかつ少ない計算量で精度の高い学習済みモデルを生成できる。

※2  
ソフトウェア開発プロジェクトのための共有ウェブサービスであり、多くのOSS開発で利用されている。

※3  
査読前論文を投稿・共有可能なインターネット上のサーバ(プレプリントサーバ)。1991年に公開され、現在はコーネル大学(Cornell University、米国)が運営する。

### 2.2.1.1 集合知のプラットフォーム形成

機械学習、特にディープラーニングに関わるアルゴリズムや、学習済みモデル、学習用データ、ソフトウェアコードなど、AIに関して開発した技術やデータ等を公開し、その上に多様な研究者や技術者を集めて技術開発を加速させる、“集合知のプラットフォーム形成”を進める動きが進んでいる。

こうした動きは、Google、Microsoft、Facebook、Baidu（中国）といった先行するIT企業に加え、Google DeepMind（英国）、Preferred Networks（日本）等のスタートアップ企業も積極的に進めている。その背景には、学習用データや学習済みモデルの再利用によって、発展的な研究開発が可能<sup>1</sup>になるというディープラーニングの特徴がある。いったん研究成果が公開、共有されると、図1のように多様な研究者や技術者による成果の再利用、加工（改良）が連鎖的に進み、AIの精度が飛躍的に向上するネットワーク効果が非常に効果的に働く。集合知の活用は、LinuxやAndroid等、これまでのオープンソースソフトウェア（OSS）でも行われ、企業も一定の参加・関与を行ってきたが、ディープラーニングならではの特徴から、従来以上に企業の関与が強まっている。

集合知によるプラットフォーム形成を支えるインフラとして、オープンソースソフトウェア（OSS）、学習用データ、学習済みモデルを共有可能なウェブサービス「GitHub」<sup>2</sup>や査読前論文を投稿・共有可能なウェブサービス「arXiv」<sup>3</sup>などの利用が進んでいる。これらを利用して、大学等研究機関や企業の最新の研究成果が論文、学習用データ、学習済みモデルとして共有され、それを再利用（加工）可能なソフトウェアの機能やツールもOSSとして公開されている。これらのインフラを利用して公開された、共有モデルや共有データを基に派生モデルを開発し、そのモデルを公開・共有することで新たな派生モデルが開発される、といった技術開発の連鎖がAI技術の進化を加速させている。

また、ソフトウェアを中心としたAI市場の形成の動きと並行して、ハードウェアを中心とした市場形成の動きも始まっており、両者が互いに作用し合い、一体となって技術革新が進んでいる点にも注目したい。

例えば、Googleは自社が提供する機械学習フレームワーク「TensorFlow」における、ディープラーニングや機械学習の演算処理に最適化した専用プロセッサ「TPU」（Tensor Processing Units）<sup>4</sup>を独自開発し、AI利用の基盤としている。ある特定のフレームワークで学習した学習済みモデルを使用して推論する場合に、汎用のCPUやGPUを用いるのではなく、ハードウェア側をソフトウェアに特化させていくことで、ソフトウェアの能力を最大限発揮することができるため<sup>5</sup>である。一方、GPUによる汎用計算（GPGPU）の市場普及を進めるNVIDIA（米国）は、ディープラーニングや機械学習の演算に適したGPUの開発、GPUの性能を最大限発揮できる開発環境「CUDA」の提供など、ハードウェアを中心としたプラットフォームの形成を進めている。

今後も、ディープラーニングや機械学習用途のソフトウェアに対してハードウェアを適合させる動きと、ハードウェアを開発・普及させることでソフトウェア側に適合させようとする動きとが、同時並行的に進むことが予想される。

AIに関わる市場は萌芽段階であり、具体的なビジネスモデルを描くことは難しい。ここまで述べてきたように、先行する海外企業等は、必ずしも明確なビジネスモデルを掲げて取組みを進めているわけではない。

---

※4  
TPUの詳細は1.7節を参照されたい。

※5  
「米Googleがディープラーニング専用プロセッサ「TPU」公表、「性能はGPUの10倍」と主張」日経コンピュータDigital ウェブサイト  
<<http://itpro.nikkeibp.co.jp/atcl/ncd/14/457163/052001464/>>

将来の市場における優位なポジションを得るために、一部の技術等をオープンに公開し、参加者を増やしながらAI市場の拡大を牽引するとともに、プラットフォームを形成しようとしている。一方、我が国において先行する一部の企業では、積極的な投資やAI研究者の招聘などを進めている状況にあるが、集合知のプラットフォーム形成において我が国の存在感は必ずしも高いものではない。

#### 2.2.1.2 学習用データの独占

AIを利用して付加価値を創出するためには、質の高い学習データが不可欠である。前項で述べたように集合知のプラットフォーム形成によりオープンな研究開発を進めることでAIを有効に機能させようとする動きがある一方で、質の高い学習用データを獲得、独占することで企業の競争力を高める動きも見られる。

データ獲得の特徴的なものとしては、サービスのインターフェースにAIを組み込むことで、消費者との接点を押さえ、多様なデータを獲得する動きが見られる。例えば、Amazonは音声認識・対話機能を搭載したスピーカー型端末「Echo」の普及を進めるとともに、Echoの基盤となる音声認識・対話機能「Alexa」を様々な製品やサービスと連携させることで、消費者の生活の接点を押さえ、生活に関わる多様なデータへとアクセスできる仕組みを作り上げている。また、Googleにおいても、対話型アシスタント「Google Assistant」、地図・地域検索サービス「Google Map」、翻訳サービス「Google Translate」、写真・動画用クラウドサービス「Google Photo」などの様々なウェブサービスにAIを組み込むことで、利便性を高め、消費者との接点を強化している。

学習用データを獲得することを目的とした買収や、連携の動きも見られる。例えば、Microsoftは2011年にSkypeを買収し、音声データを収集できるようになった。またIBMは、2016年に気象サービスを提供するThe Weather Company（米国）を買収したことで、地球上の20万以上の気象観測所からの気象データを取得できるようになったほか、同年に医療データサービスを提供するTruven Health Analytics（米国）等を買収し、医療保険、治療内容や結果、医療費等に関わるデータを取得するなど、自社が保有しないデータの獲得を進めている。

データの独占は競争力を高める一方で、他のプレイヤーが類似データを公開すると、前述のように連鎖的な技術開発が進み、独占による競争力は低下するだろう。その結果、データの独占から、データや学習済みモデルをオープンにして、集合知のプラットフォーム形成を進める動きへと転換する可能性もある。一方で、データ独占の競争優位性が高まると、集合知のプラットフォーム形成を進めていた企業がデータを独占する動きへと一転する可能性もある。

このように、本項で示した学習用データの独占による事業競争力強化の動きと、前項で示した集合知のプラットフォーム形成による学習用データや学習済みモデル公開での技術開発の連鎖は、同時並行的に進むと予見される。

#### 2.2.1.3 AIを契機とする産業の再構成

2000年代のIT革命においては、社会や産業における不合理な構造や仕組みに対して、ITの適用による合理化が期待されて、業界再編が進められた。それと同様に、AIの実用性の高まりは、社会課題や産業課題解決への期待感を生み出し、AIを契機とした規制緩和や業界再編が進み、新たな市場やビジネス機会が生み出されるだろう。

例えば、AIの技術革新によって、高齢化や都市化による交通空白、交通事故の抑制などの社会的課題解決への期待から自動走行や配車サービスが、また医療費高騰や都市化による医師不足などの課題への対応として、疾患の自動診断に向けた検討等が進みつつある。そういった動きが、従前の産業構造を大きく変えることになるかもしれない。

自動走行をめぐる動向を見ると、自動走行車による移動サービスの普及により、自動車を購入・保有す

るという既存ビジネスモデルが、自動車を保有せずに移動サービスを購入するという市場に代替される可能性がある。また、自動走行車を構成する部品等の要素において、AIの付加価値の比重が高まることで、原価構成が変化することもあり得る。

しかしながら、IT革命の際には海外IT企業のサービスが国内市場を席卷したのと同様に、AI時代においても、先行する海外企業のAIによる製品やサービスで既存産業が代替され、国内産業の空洞化につながる可能性もある。我が国のものづくりでは、熟練技術者の「匠の技」が付加価値を生み出す場合も多く、それが国際的な競争力になっているが、AIやAIを組み込んだ機械・ロボットにそれらの匠の技が代替されることで、ものづくりの機能がモジュール化されるかもしれない。

重要となるのは、産業領域の深い知識に基づいて獲得されたデータやアルゴリズムである。そして品質・安全性を追求し、製品やサービスの全体像を把握しつつ、AI（ソフトウェア）とハードウェアがそれぞれどこまでの機能を担うかをすり合わせるノウハウなど、日本が各産業領域で保有する強みは競争優位を築くための源泉であり、これらを活かす戦略が求められる。

## 事例：Amazonによるユーザ接点の強化とデータ獲得の仕組み

---

Amazonは、「Amazon Echo」や「Alexa」、「Amazon Dash Button」等のAIやIoTを組み込んだサービス等によって、インターネットからリアル空間に至る幅広い顧客との接点を押さえ、データを独占的に獲得する仕組みを構築しつつある。

Echoに搭載された音声認識・対話の機能は、コンピュータやスマートフォンを操作することなく、天気予報、スケジュール、インターネット検索、ショッピング等を音声で確認したり、操作したりできる。日常生活で、より自然な形で利用でき、消費者の利便性を飛躍的に高めている。Echoの販売台数は明らかにされていないが、2016年末までに欧米を中心に500万台以上が販売されたと推定されている。加えて、Echoの基盤となる音声認識・対話機能Alexaを、サービス提供者とハードウェア提供者の両者に公開することで、Alexaの製品搭載やサービスとの連携が急速に進んでいる。

サービス提供者に対しては、「Alexa Skills Kit」(ASK)が提供される。これは、Alexaを搭載した機器から入力される利用者の音声の、どの単語やキーワードに反応して、どのような答え(サービス)を返すかを定義するAPI群だ。これにより、自由にAlexaと自社サービスを関連づけることができ、例えばGeneral Electric (GE)はAlexaを通じて自社の家電製品をコントロールする機能を開発し、Yahoo!はスポーツ情報とAlexaを連携させている。

既に3,000以上の機能(Skill)が開発され、消費者はAlexaを搭載した端末からこれらの機能を利用できるようになっている。一方、ハードウェア側には、Alexaの音声認識を他の製品やサービスに組み込むことができる「Alexa Voice Service」(AVS)が提供される。

これは、Alexaの音声認識を自動車、スマートフォン、冷蔵庫、洗濯機、ロボット、テレビ、照明機器等に搭載することができるサービスであり、2017年1月に開催されたCES 2017では、700社以上がAlexaを搭載した機器を発表している。例えば、Ford等の自動車メーカーの車載システムにAlexaが搭載されたことで、自動車から家庭内の家電を操作し、また家庭からエンジンの起動・停止、ドアの施錠等ができるようになった。このように、AmazonはAlexaを搭載した製品の普及によって、家庭内外の消費者との多様な接点を獲得している。また、日用品の再注文に特化したIoT端末「Amazon Dash Button」を販売し、これも顧客との新たな接点となっている。

このように、多様なハードウェアを通じて多様なサービスを利用できる環境が整備されることで、消費者の生活に密着した多様な情報を獲得する仕組みができつつある。「MIT Technology Review<sup>6</sup>」において、Amazon Echo/Alexaの創設メンバーでシニアリサーチャーのニココ・ストロム(Nikko Strom)は、「既にAlexaが数百万の家庭で活用され、非常に大規模なデータが手に入るようになっている」と述べている。Alexaの普及が進むほど、学習のためのデータが取得・蓄積でき、それをを用いて音声認識の更なる高精度化につなげるほか、マーケティングへの活用など、好循環のエコシステムが生み出される。

---

※6

“Alexa Gives Amazon a Powerful Data Advantage,” MIT Technology Review Website <<https://www.technologyreview.com/s/603380/alex-gives-amazon-a-powerful-data-advantage/>>

## 2.2.2 ディープラーニングの産業応用

ディープラーニングの登場により、多様なデータを対象にパターン認識が比較的容易にできるようになった。画像認識や音声認識等の分野において、ディープラーニングによる自律的な特徴量の抽出が、専門家による特徴量の設計に基づく従来技術の認識精度を凌駕するなど、様々な成果が得られ、産業での応用が進んでいる。1.10節で示したとおり、今後はディープラーニングと強化学習を組み合わせ、ロボットなどの機械の動作の学習（運動の習熟）やパターン認識と記号的処理を融合することで、言葉の意味理解へと発展することが期待されている（図2）。

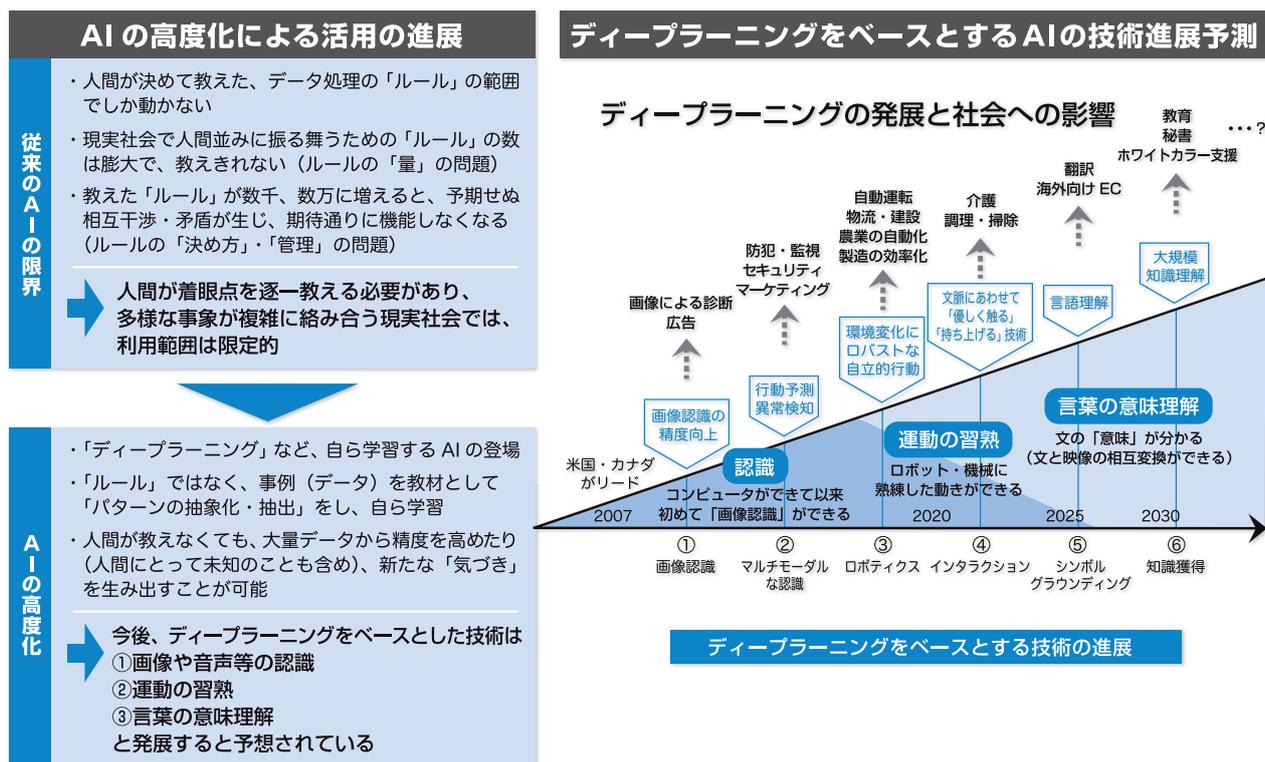


図2 ディープラーニングの登場によるAIの高度化とそれによる産業や社会への影響<sup>7</sup>

認識、運動の習熟、言葉の意味理解の三つの枠組みで産業応用をとらえると、ディープラーニングの実用化は画像や言語等のパターンの認識で先行しており、従来のようなビッグデータに基づく記号処理や知識処理へのアプローチに対して、ディープラーニングが組み込まれる形での実用化が進んでいる。実用化の多くが認識に関わるものであるが、運動の習熟や言葉の意味理解等を産業応用する試みも始まっている。

ディープラーニングに関わる取組は、従前よりデータを収集して大量に保有しているインターネット分野や医学研究、症例データベース等のデータ整備が進んでいる医療分野等で先行している。また、ディープラーニングによる事業への影響が大きい自動走行の領域では、自動車メーカー等が多額の投資を行い、走行環境に関わるデータの取得やアルゴリズムの開発、制御対象である機械（車両）の開発を並行して行っている。

今後もディープラーニングの技術革新は一層進むことが期待され、産業側としての適用領域も拡大する

※7

「DL産業論」経済産業省ウェブサイト <[http://www.meti.go.jp/committee/sankoushin/shin\\_sangyoukouzou/pdf/011\\_s01\\_00.pdf](http://www.meti.go.jp/committee/sankoushin/shin_sangyoukouzou/pdf/011_s01_00.pdf)>より編集部作成

と予見される。しかしながら、ディープラーニングが効果を発揮するためには、学習するためのデータの収集・整備に加え、フィードバックする側の機械等の整備や業務プロセスの改革等を行う必要があり、適用領域によっては多額の投資が必要となる。そのため、ディープラーニングに関わる技術革新のスピードは著しい一方で、実用化の面では、導入効果と投資金額のバランスによって、段階的に導入が進んでいくことが予想される。

### 2.2.2.1 認識

ディープラーニングの産業応用は、画像や音声・言語の認識で先行しており、それらに関わる動向を紹介する。

#### (1)画像認識

ディープラーニングが最も成果を挙げている取組の一つが画像認識である。2012年にGoogleがスタンフォード大学との共同研究により、YouTubeに投稿された大量の動画から「猫」を抽出し、その概念の表示に成功した例などに代表される。産業応用は、自動車の走行環境の認識や、医療分野における画像診断支援等の領域で先行している。以下では、これらの領域を例に、ディープラーニングの利用動向を示す。

##### 1)走行環境の認識

自動車メーカー等のこれまでの研究開発の多くは、運転者がいることを前提としていた。だが、事故防止等の安全性の向上や高齢者や障害者などに対する移動手段の提供を目的として、運転者が不要である「完全自動走行」の実現に向けた取組が進められている。

自動車の走行環境、特に市街地における環境は非常に複雑であり、全てのパターンやルールをあらかじめ設定して、それに基づく制御を行うことは現実的ではない。そのため、現在の自動走行実現へのアプローチの多くは、ディープラーニングを中心とした機械学習によるものが中心となっている。

自動走行は、車両の周辺環境の情報を①認識（走行環境理解）し、今後の②行動を決定（判断）した上で、③走行制御を行うことで実現される。ディープラーニングは、主に車外環境の①認識に利用される。具体的には、GPSや地理空間情報、可視光カメラ、ミリ波レーダー、レーザー測距など、様々なセンサやデータを用いて、車外の移動体や障害物等を検知する取組が行われている。

そういった先進運転システム（Advanced Driver Assistance Systems; ADAS）を開発しているMobileye（イスラエル）は、安価な単眼カメラ単独で先行車との衝突防止、先行車追従、レーンキーピング等の機能を実現できる車載半導体「EyeQ」（アイキュー）を設計・開発。すでにBMWやGM等が販売する自動車向けに、累計で1,500万台を出荷<sup>※8</sup>しており、2017年1月時点の先進運転システムに関わる同社の世界シェアは、80%に達している。

Mobileyeは、そういったカメラやセンサから得られたデータに対して、ディープラーニングを活用することで、製品の付加価値を高めている。具体的には、運転可能な領域や、運転可能エリア内のルート形状、道路の移動オブジェクト、シーンセマンティクス（信号及びその色、交通標識、歩行者の視線方向、路上表示）等を、高精度に認識する機能の開発を進めている。Mobileyeは2016年からIntelと提携していたが、2017年3月、Intelに153億ドル（1.7兆円）で買収された。

NVIDIA（米国）は、GPUを利用した車載用コンピュータと、自律走行のためのソフトウェアの開発を推進している。ディープラーニングによる画像認識も含めた自動走行を、1チップで実現可能なSoC<sup>9</sup>で

※8  
2017年までの累積出荷台数。“Customers,” Mobileye Website  
<<http://www.mobileye.com/about/our-customers/>>

※9  
システムオンチップ(System on a Chip)の略称。

ある「Xavier」(エグゼビア)を、2017年第4四半期からサンプル出荷する。また、ソフトウェアの開発では、最新の研究成果として、物体検出やマッピング、ルートプランニングといったプログラムを行わず、ルートと周辺状況といった限られた情報しか持っていない状態から、ドライバーの反応や周辺の観察により、運転に必要な判断を学習した結果を発表<sup>10</sup>している。

自動走行実現に向けた画像認識への取組は、表1のように自動車部品サプライヤー、スタートアップ企業等でも進んでいる。なお、自動車メーカーの取組は2.2.3項にて紹介する。

表1 自動走行関連用途にディープラーニングを応用する取組例<sup>11</sup>

| 組織名        | 国     | 概要  |
|------------|-------|---|
| Almotive   | ハンガリー | Almotiveは、距離測定と物体認識を単眼カメラで実現する技術を提案している。ディープラーニングの教師データにステレオカメラの画像を利用し、推論時には単眼カメラからの画像を利用する点が特徴的であり、10ドル程度の安価なカメラで実現可能という。2018年に向けて実用化を進めている。なお、同社はKhronos GroupのメンバーとしてNNEF (Neural Network Exchange Format) <sup>12</sup> を積極的に推進し、自社製品への適用を進めている。                        |
| Comma.ai   | 米国    | Comma.aiは、画像認識等を応用した自動走行向けのソフトウェアプラットフォーム、及び車両制御用のプラットフォームを開発している。また、開発成果であるソフトウェアの機能及び車両制御用のハードウェア設計情報を、それぞれオープンソースとして公開している。前者はOpenPilotと呼ばれ、車間距離を維持しつつ一定速度で走行するアダプティブクルーズコントロールや、走行中の車線逸脱を防止するレーンキーピングアシスタントの機能が含まれる。後者はComma neoと呼ばれ、コンピュータ基盤の回路情報、必要な部品、設計手順等の情報が含まれる。 |
| DeepGlint  | 中国    | DeepGlintは道路交通に関する複雑なシーンで、複数のオブジェクトを同時に検出し、自動車、自転車、歩行者などを識別することができる車両解析システム「Weimu Vehicle Big Data System」を提供している。  |
| Drive.ai   | 米国    | Drive.aiはスタンフォード大学人工知能研究所からスピンアウトして設立され、ディープラーニングを中核とした自動走行用途のソフトウェア開発を進めている。同社はカメラ画像からの歩行者や物体の検知に加えて、交差点停車時の右左折など、運転動作に関わるプランニングや意思決定にもディープラーニングを活用しようと試みている。  |
| Mobileye   | イスラエル | Mobileyeは、単眼カメラから得られる画像にディープラーニングを適用して、衝突の検知、防止・軽減のための警告等を行う先進運転システムを開発している。詳細は本文を参照されたい。   |
| NVIDIA     | 米国    | NVIDIAは、GPU技術を活かした車載用コンピュータとセンサ等から周囲の障害物を認識し、経路プランニング等を行う自動走行向けのソフトウェア開発を推進している。詳細は本文を参照されたい。   |
| Sighthound | 米国    | Sighthoundはディープラーニングにより、車両、人間、顔などを認識する技術を開発している。同社は開発した技術を、ライブカメラから得られる映像に適用することで、車両の製造元、モデル、色、ナンバープレート等を識別したり、走行・飛行する移動体が撮影した画像に適用することで、人や物体等を検知したりするソリューションを提供している。   |
| デンソー       | 日本    | デンソーはAI R&Dプロジェクトを立ち上げ、全社的にAIの研究開発を進めている。具体的には、走行環境の認識、走行シーンの理解、行動予測などを目的としたディープラーニングアルゴリズム、そのアルゴリズムの効果を最大限発揮するための半導体などの実装技術、学習用データや学習済みモデルなどの品質を保証するための基盤の開発を進めている。  |
| モルフォ       | 日本    | モルフォは2015年12月にデンソーと資本業務提携合意し、多様な障害物や標識・標識、車両が走行可能な道路空間、危険が予想されるシーン等を認識するためにディープラーニングを用いた次世代画像認識技術を開発している。   |
| ZMP        | 日本    | ZMPIは道路インフラに極力依存しない自律型の自動走行技術の開発を進めている。ディープラーニングによる画像認識技術、ライダー(LIDAR)による自己位置推定等により、周囲の環境を認識して自律的に走行する技術の開発を行っている。   |

※10  
“ End-to-End Deep Learning for Self-Driving Cars, ” NVIDIA Website <<https://devblogs.nvidia.com/parallelforall/deep-learning-self-driving-cars/>>

※11  
各種公表情報より作成。

※12  
ニューラルネットワークモデルの情報を交換するフォーマット。詳細は2.3.3項を参照されたい。

## 2) 医用画像の認識

医療分野における医用画像の活用の歴史は古く、1839年にルイ・ジャック・マンデ・ダゲール (Louis Jacques Mand. Daguerre) 氏が発明した銀板写真や、ヴィルヘルム・レントゲン (Wilhelm Conrad Röntgen) 氏が1895年に発見したX線によるX線写真で、すでにアナログ画像による診断が始まっている。そしてフィルムカメラからデジタルカメラへと移行したように、診断機器やコンピュータグラフィックスに関わる技術の進歩によって、医用画像もフィルム等のアナログ画像から2次元のデジタル画像や3次元画像の取得が可能となっている。最新の診断機器では1回の検査で千枚を超える医用画像を取得することや、一日当たりの検査件数も増加している<sup>13</sup>ことから、放射線医師らの負担が増加しており、それが疾患の見落としにつながる懸念されている。米国の国立医学研究所 (IOM)<sup>14</sup>によると、診断の見落とし等により、米国だけで毎年1,200万人に影響が及んでいると推定される。

医用画像の診断支援へのAIの活用は、こうした課題の解決や、医師不足等の解決につながると期待されている。特に、医療分野では症例等に関する医用画像の整備が進んでおり、研究機関や企業等はこれらの医用画像に対して、ディープラーニングを適用する取組を進めている。例えば、米国では、肺画像データベースコンソーシアム (Lung Image Database Consortium; LIDC) や画像データベース資源イニシアティブ (Image Database Resource Initiative; IDRI) 等が症例データベースを構築・提供し、スタートアップ企業がこれらを活用してディープラーニングによる医用画像の認識に関わる研究開発を行っている。

Enlitic (米国) は、畳み込みニューラルネットワーク (CNN)<sup>15</sup>を拡張して、X線CT画像からがん画像を検出するシステムの開発を行っている。Enliticの開発したシステムでは、1人の専門家 (放射線技師) よりも約50%高い精度で、医用画像から肺の悪性腫瘍を分類できるという<sup>16</sup>。Enlitic等の医用画像診断への取組は、医師への負担を減らすとともに、診断の高度化にも寄与するとして期待されている。実際にEnliticは2016年12月に開催された北米放射線学会 (RSNA) において、ディープラーニングエンジンを搭載した3次元の肺がんスクリーニングソリューションを公開し、医療機関から高い評価を受けている。

ディープラーニングによる医用画像の認識に関わる取組は、表2のように多様な部位の画像に適用され、がんや骨折などの診断に利用されている。

---

※13  
医用画像は医療に関わるデータの90%以上を占めるまでに増加していると言われている。“IBM Unveils Watson-Powered Imaging Solutions for Healthcare Providers,” IBM Website <<https://www-03.ibm.com/press/us/en/pressrelease/51146.wss>>

※15  
CNNの詳細は1.2.4項を参照されたい。

※16  
“Enlitic,” Enlitic Website <<http://www.enlitic.com/index.html>>

※14  
“IOM Report: Improving Diagnosis in Health Care,” National Patient Safety Foundation Website <<http://www.npsf.org/news/252002/IOM-Report-Improving-Diagnosis-in-Health-Care.htm>>

表2 医用画像認識関連用途にディープラーニングを応用する取組例<sup>17</sup>

| 組織名                  | 国     | 概要   |
|----------------------|-------|--|
| Bay Labs             | 米国    | Bay Labsは超音波診断にディープラーニングを適用し、心臓や血管等の循環器における疾患(心血管疾患等)の治療を支援するソリューションの開発を行っている。   |
| Butterfly Network    | 米国    | Butterfly Networkは低価格で利用できる携帯電話サイズの超音波診断デバイスや、ディープラーニングによる超音波画像の診断機能を開発。具体的には、低コストでインターネットと接続可能なデバイス、ディープラーニングによる腫瘍の認識が可能な学習済みモデル、学習済みモデルを基にクラウド上でリアルタイムに推論を行う機能を開発している。   |
| Enlitic              | 米国    | EnliticはX線CT画像等にディープラーニングを適用し、がんなどの疾患の診断を支援するシステムを開発している。詳細は本文を参照されたい。   |
| Imagia               | カナダ   | Imagiaは早期にがんの変化を検出、定量化することを目的とし、ディープラーニングによる医用画像からの異常検出、腫瘍判定の支援、ゲノム解析のためのソリューションを開発、提供している。  |
| Lunit                | 韓国    | Lunitはディープラーニングによる医用画像や医療データの分析、解釈を行うソフトウェアを開発している。具体的には、胸部X線医用画像から主に肺がんを、乳房X線(マンモグラフィ)医用画像から乳がんを検出するシステムを開発している。同社は国際的な画像認識コンテストILSVRCや乳がんの腫瘍倍増速度を評価する画像認識コンテストTUPAC 2016において評価がなされている。   |
| Mindshare Medical    | 米国    | Mindshare Medicalはディープラーニングにより医用画像から重度の疾患を検出し、効果的な治療計画やフォローアップの手順を含むパーソナライズされた診断とガイダンスを行うシステム臨床意思決定支援システムを開発している。  |
| Zebra Medical Vision | イスラエル | Zebra Medical Visionはディープラーニングによる医用画像の診断により、放射線医師が見逃しやすい症例や兆候など患者の様々なリスクを検出し、病気の検出や予測、予防のためのプログラムの構築などを行うシステムを開発している。具体的には、X線CT画像等を基にディープラーニングを適用して骨(骨密度、骨折リスク、骨折箇所)、肝臓(脂肪肝)、肺(肺気腫の容積)、心臓血管(冠動脈疾患、大動脈瘤)、脳(脳出血)の発症リスク等を解析している。  |
| エルピクセル               | 日本    | エルピクセルはX線CTや磁気共鳴画像診断(MRI)、内視鏡等で取得した医用画像に対してディープラーニングを適用し、がんや脳の疾患等を発見する画像診断支援に関わる研究開発を進めている。  |
| カシオ計算機               | 日本    | カシオ計算機は信州大学と共同でディープラーニングによる皮膚疾患の診断支援システムを開発している。同社の画像変換技術を活かして学習用データ(症例画像)の色や明るさを調整し、学習性能を向上させている点が特徴的である。ISICが主催するメラノーマ(悪性黒色腫)検出のための皮膚病変解析に関わるコンテストのうち、皮膚疾患の自動判別部門で1位を獲得している。   |
| キャノン                 | 日本    | キャノンは大規模症例データベースを活用し、ディープラーニングや機械学習によるがんや神経性疾患の診断支援を行うソフトウェアの開発を進めている。具体的にはX線CT画像から腫瘍の直径や体積を計測することで抗がん剤による治療効果の判定を支援するソフトウェア、過去のX線CT画像と正確に位置合わせを行うことで差分画像を作成するソフトウェア、X線CT画像の肺結節影を分析して良性、原発性、転移性かどうかの判断を支援するソフトウェア、MRI画像から脳の各領域の堆積を定量化して脳疾患による萎縮や肥大化を評価するソフトウェアなどを開発している。           |
| プリファードネットワークス        | 日本    | プリファードネットワークスは国立がん研究センター、産業技術総合研究所と共同でディープラーニングを中心としたAI技術をがん診断システム等に適用するためのプロジェクトを進めている。具体的には、ディープラーニングやAIに関する研究開発を進める同社及び産業技術総合研究所が、国立がん研究センターが保有するがんに関する膨大な罹患者の臨床データや画像データ(X線CT画像、MRI画像)、ゲノムデータ等に対してディープラーニングを中心とした先進的なAI技術を適用することで、より正確ながんの診断や個々のがん患者に適した治療法の選択等を行う技術の研究開発を進める。 |

※17  
各種公表情報より作成。

### 3)その他

これまでに紹介してきた自動走行と医療分野は、ディープラーニングの登場により飛躍的に進歩し、実用化に向けて大きく前進している領域である。ディープラーニングによる画像認識は、これら以外にも幅広い産業用途に広がりを見せつつある。例えば、防犯カメラから取得した動画像に対してディープラーニングを適用することで、都市や施設の安全性を高める取組や事故画像を解析することで損害調査の効率化を高める取組などが進んでいる。これらの領域におけるディープラーニングを含めたAIの活用については、2.2.3項において紹介する。

## (2)音声・言語認識

スマートフォンに搭載された音声アシスタントシステムや自動で質問に対応するチャットボットシステムなど、ディープラーニングの登場により音声認識や文章認識・生成等に関する技術の実用が一層進み、市場での利用が始まっている。

ここでは、ディープラーニングの適用が先行する音声認識・対話、機械翻訳、文章生成の領域における利用動向を紹介する。

### 1)音声認識・対話

音声認識はAIに関わる主要なテーマとして従前より研究開発が行われてきたが、1990年代後半から米国国防高等研究計画局（DARPA）が進めた共通の大規模コーパス<sup>18</sup>の整備及びそれらを用いて音声認識の評価を行うプロジェクトによりその精度は大幅に向上した。音声認識精度の一般的な評価尺度である単語誤り率（Word Error Rate; WER）を見るとIBMが1995年に43%のWERを達成した後、DARPAのプロジェクトが推進剤となり、段階的に精度を高め、2005年にはIBMが15.2%のWERを達成した。その後、ディープラーニングの登場により音声認識の精度は飛躍的に向上し、2015年にIBMが8%<sup>19</sup>、2016年9月にMicrosoftが6.3%<sup>20</sup>、同年10月にMicrosoftが更に精度を高め、プロの口述筆記者と同レベルの5.9%<sup>21</sup>を達成するなど米国の大手IT企業による競争が加速している。最新の成果では、IBMが2017年3月7日に5.5%のWERを達成<sup>22</sup>している。

音声認識を組み込んだ製品は、Appleの「Siri」、Googleの「Google Assistant」、NTTドコモの「しゃべってコンシェル」のように、音声でモバイル端末を操作する機能として生活の中で利用されている。こうした機能は、ディープラーニングの登場に加え、複数のマイクを利用したビームフォーミングや雑音抑制技術の向上等により、今まで以上に実用性の高い機能として様々な環境で実用化が進みつつある。

---

※18  
発話を大規模に集めたデータベース(Switchboard Corpus)。

※19  
“IBM Watson announces breakthrough in Conversational Speech Transcription,” IBM Website <<https://developer.ibm.com/watson/blog/2015/05/26/ibm-watson-announces-breakthrough-in-conversational-speech-transcription/>>

※20  
“Microsoft researchers achieve speech recognition milestone,” Microsoft Website <<https://blogs.microsoft.com/next/2016/09/13/microsoft-researchers-achieve-speech-recognition-milestone/#sm.00001npc74lkeds4xz22819vdlhwj>>

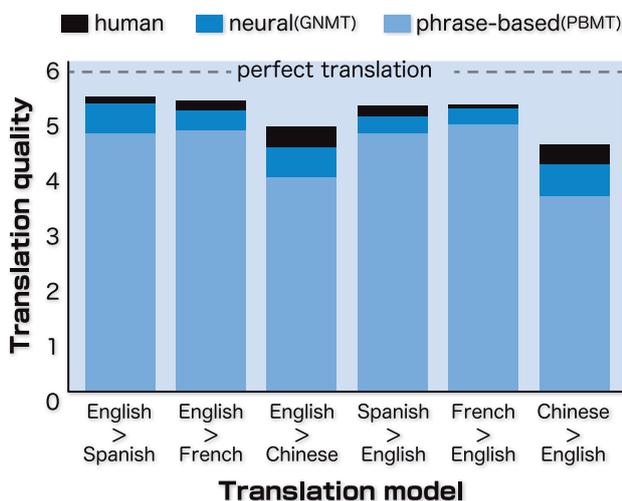
※21  
“Historic Achievement: Microsoft researchers reach human parity in conversational speech recognition,” Microsoft Website <<https://blogs.microsoft.com/next/2016/10/18/historic-achievement-microsoft-researchers-reach-human-parity-conversational-speech-recognition/#sm.00001npc74lkeds4xz22819vdlhwj>>

※22  
“Reaching new records in speech recognition,” IBM Website <<https://www.ibm.com/blogs/watson/2017/03/reaching-new-records-in-speech-recognition/>>

Amazonはディープラーニングを用いて音声を変換する自動音声認識機能（ASR）とテキストを認識する自然言語理解機能（NLU）等を搭載したスピーカー型端末「Amazon Echo」（2.2.1項参照）を販売している。EchoとEchoが搭載する音声認識・対話機能は、ディープラーニングによりテレビの音声、音楽、家族の会話等ノイズの多い家庭空間において高い音声認識精度を達成し、数メートル離れた距離からも音声の認識を可能としている。ASRとNLUは、クラウドサービスAmazon Lexとしても提供され、企業等は容易に対話型の機能を自社の製品やサービスに組み込むことができる。例えば、米航空宇宙局（NASA）は、火星探査用ロボットを模したミニローバー「Rov-E」を学校、地域団体、公共イベント用に開発している。Rov-EはAmazon Lexの機能を用いて、学生や地域住民等との会話を可能とし、言葉で操作したり、火星探査の情報を引出したりすることができるという。

Microsoftは前述のようにディープラーニングにより高い精度の音声認識を実現している。CNNとLSTM<sup>23</sup>を組み合わせ、音響のコンテキストを理解する学習モデルを構築して認識精度を高めている。開発した音声認識は、Windowsのパーソナルアシスタント「Cortana」や同社のクラウドサービス「Azure」の音声認識機能（Bing Speech API、Custom Speech Service）として組み込まれる予定である。

表3のようにクラウドサービスを提供する海外の大手IT企業等を中心に音声認識・対話に関わるサービスの開発が進んでいる。



|                   | PBMT  | GNMT  | Human | Relative Improvement |
|-------------------|-------|-------|-------|----------------------|
| English → Spanish | 4.885 | 5.428 | 5.504 | 87%                  |
| English → French  | 4.932 | 5.295 | 5.496 | 64%                  |
| English → Chinese | 4.035 | 4.594 | 4.987 | 58%                  |
| Spanish → English | 4.872 | 5.187 | 5.372 | 63%                  |
| French → English  | 5.046 | 5.343 | 5.404 | 83%                  |
| Chinese → English | 3.694 | 4.263 | 4.636 | 60%                  |

■ 図3 Google Neural Machine Translationの翻訳精度<sup>25</sup>

## 2) 機械翻訳<sup>24</sup>

ディープラーニングを用いた言語・音声への取組として機械翻訳が大きな成果を挙げている。その代表的な例は、2016年9月にGoogleが発表した翻訳システム「Google Neural Machine Translation」（GNMT）である。

Googleは翻訳サービス開始当初からフレーズ単位で翻訳する統計的機械翻訳（PBMT）を採用していたが、新たな翻訳システムGNMTにおいてディープラーニングにより文章全体を翻訳単位としてとらえることで、従来のアプローチ（PBMT）から翻訳の誤りを55.85%低減する等、性能を大幅に向上させている。Googleによると、GNMTは英語→スペイン語、フランス→英語等の一部のケースにおいて、人間が行う翻訳に近い精度に達しているという。実際に、図3のように、GNMTの翻訳精度はPBMTに比べて飛躍的に向

※23  
時系列データを扱えるモデルとして再起型ニューラルネットワーク（Recurrent Neural Network; RNN）を拡張した手法。詳細は1.2.8項を参照されたい。

※24  
“Samsung goes after Google, Apple, Amazon and your home with new voice assistant Bixby,” CNBC Website <<http://www.cnbc.com/2017/03/29/samsung-galaxy-s8-bixby-voice-assistant-apple-siri-amazon-alexa.html>>

※25  
“Google’s Neural Machine Translation System : Bridging the Gap between Human and Machine Translation,” GoogleResearchBlog <<https://research.googleblog.com/2016/09/a-neural-network-for-machine.html>>; <<https://research.google.com/pubs/pub45610.html>>

上している。Googleが開発したGNMTは同社の翻訳サービス「Google Translation」に採用されているほか、クラウドサービス「Google Cloud Platform」の機能の一部として提供されている。

Microsoftは、LSTMを導入して高品質かつ人間に近い文章表現を実現したことで注目を集めている。Microsoftの機械翻訳は、ニューラルネットワークを導入して動詞や名詞等の品詞、性別、礼儀正しさ（スラング、カジュアル、書面、フォーマルなど）といった概念を、500次元の特徴ベクトルとして学習する

■表3 音声認識・対話関連用途にディープラーニングを応用する取組例<sup>26</sup>

| 組織名       | 国    | 概要   |
|-----------|------|--|
| Amazon    | 米国   | Amazonは、ディープラーニングによる音声認識機能と自然言語理解機能を搭載した家庭用アシスタント端末Echoを販売するとともに、それに搭載されている音声認識機能等を利用可能なAmazon Alexa (2.2.1項参照) やクラウドサービスAmazon Lexを提供している。詳細は本文を参照されたい。   |
| Baidu     | 中国   | Baiduは、シリコンバレーAI研究所(SVAIL)を設置して、ディープラーニングによる音声認識の研究開発を進めているほか、開発した音声認識機能を組み込んだ製品やサービスを提供している。Baiduのスマートフォン向け検索アプリ(Mobile Baidu)に音声検索機能として組み込まれているほか、音声認識機能をプラットフォーム(Baidu Voice)として開発者向けに公開している。このプラットフォームを利用して、Haier(中国)が音声検索機能付きの家電製品を開発したり、Szime(中国)が車載器を開発している。                                |
| DeepGram  | 米国   | DeepGramはディープラーニングによるオーディオデータの分析により、分類やキーワード抽出・発言箇所の特定等を行う技術を開発している。同社の技術は電話、ビデオ映像、オンラインメディア等の多様なオーディオデータを対象に分析が可能である。また、2017年1月に画像認識や音声分析等を実装可能なディープラーニングのツールKurをOSSとして公開している。  |
| Google    | 米国   | Googleはディープラーニングにより音声認識の精度を高め、スマートフォン向けのパーソナルアシスタントGoogle Assistantや家庭向けのパーソナルアシスタントGoogle Homeを提供している。また、AmazonやMicrosoftと同様に、クラウドサービスとして音声認識機能を提供している。具体的には、Google Cloud Platformにおいてディープラーニングによる音声認識機能Cloud Speech APIを提供している。  |
| Gridspace | 米国   | Gridspaceはディープラーニングにより複雑な会話を認識するソフトウェアGridspaceを開発している。会話の重要箇所の識別や会話のカテゴリ化が可能であり、会議録の作成支援等への応用が期待されている。なお、同社はSiriを開発した研究者やスタンフォード大学のエンジニアが参加している。  |
| Microsoft | 米国   | MicrosoftはCNNとLSTM等のディープラーニングにより音声認識の精度を飛躍的に高め、自社の製品やサービスに組み込んでいる。詳細は本文を参照されたい。  |
| Mobvoi    | 中国   | Mobvoiはディープラーニング等による中国語の音声認識・検索技術の開発とその機能を組み込んだスマートウォッチ、車載器、車載スマートフォンアプリの開発を行っている。   |
| Viv       | フランス | Vivはディープラーニング等により音声を認識・理解し、実行するパーソナルアシスタントを開発している。ほかの開発者が作成したアプリケーションや製品に組み込むことが可能な拡張性や複雑な問いかけを認識し、理解した上で回答する等の実用性を有する機能の実現を目指して開発されている。同社はSamsung(韓国)に2016年に買収され、SamsungのスマートフォンGalaxyへの搭載が進められている。最新のスマートフォンGalaxyS8はBixbyと呼ぶ音声アシスタントを搭載しており、今後BixbyにVivの技術が組み込まれていく予定であると言われている <sup>27</sup> 。 |

※26  
各種公表情報より作成。

※27  
“Samsung goes after Google, Apple, Amazon and your home with new voice assistant Bixby,” CNBC Website <<http://www.cnbc.com/2017/03/29/samsung-galaxy-s8-bixby-voice-assistant-apple-siri-amazon-alexa.html>>

ことで、単語ごとに特定の言語対（例えば英語⇄中国語）内の固有の特性をモデル化し、翻訳精度を向上させている。Microsoftも、Googleと同様に、開発した技術を翻訳サービス「Microsoft Translation」に採用したほか、クラウドサービス「Microsoft Azure」の機能の一部として提供している。また、インターネット通話サービス「Skype」における会話を翻訳する、Skype翻訳の高精度化等にも寄与している。

表4に機械翻訳用途にディープラーニングを応用する取組例を示す。

表4 機械翻訳用途にディープラーニングを応用する取組例<sup>※28</sup>

| 組織名       | 国  | 概要  |
|-----------|----|---|
| Baidu     | 中国 | Baiduは機械翻訳にディープラーニングを採用し、統計的な機械翻訳と組み合わせることでその精度を高めている。20以上の言語間の翻訳を可能とするほか、伝統的な中国の詩や方言、広東語等にも対応している。                     |
| Google    | 米国 | Googleは機械翻訳にディープラーニングのアプローチを採用することで、従前のフレーズ単位で翻訳する統計的機械翻訳から大幅に翻訳精度を高めている。これらの翻訳機能をウェブサービスやクラウドサービスに採用している。詳細は本文を参照されたい。 |
| Microsoft | 米国 | Microsoftは機械翻訳にLSTMを採用してその性能を飛躍的に向上させている。Googleと同様にこれらの翻訳機能をウェブサービスやクラウドサービスに採用している。詳細は本文を参照されたい。                       |
| KDDI      | 日本 | KDDIは音声認識や機械翻訳の過程にディープラーニング等のAIを適用し、音声や文字を英語、中国語、韓国語間で翻訳可能なアプリケーションKDDI AI翻訳を提供している。AI翻訳はスマートフォンアプリとして提供されている。          |

### 3)文章生成

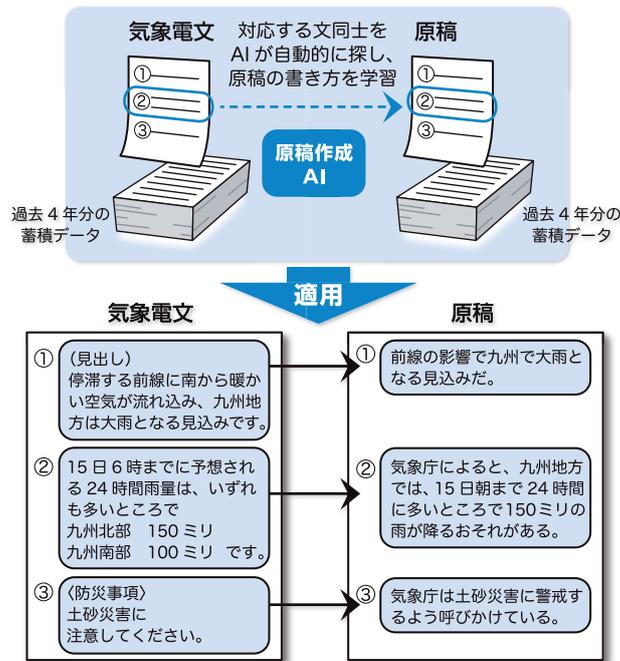
画像、テキスト、数値から自然な文章やメッセージ性の高いキーワードを生成する等の技術開発も進んでいる。こうした技術は、報道記事の生成やウェブサービスのコンテンツ管理等に利用され始めている。

Automated Insights (米国) は、数値データから自動的に記事や文章を生成するサービス「Wordsmith」を提供している。このサービスを利用することで、データから報道記事を自動的に生成したり、Eコマースサイトにおけるコンテンツ作成を自動化したりできる。例えば、Associated Press (米国) はWordsmithを利用して企業の四半期決算のレポート生成や米国メジャーリーグの下部組織であるマイナーリーグ<sup>※29</sup>の試合記事の配信を行っている。マイナーリーグの記事生成では、MLB Advanced Media (米国) のデータに基づき主に試合経過の生成・配信を行っている。Wordsmithの導入により、誤字・誤記などのヒューマンエラーが無くなることで記事品質が向上しているほか、記事生成の高速化によるコンテンツのリアルタイム性の向上、人件費削減等の効果が得られているという。

NTTデータは、ディープラーニングを活用して気象ニュースの原稿を自動生成する実証実験を実施し、人が読んでも違和感のないレベルのニュース原稿の生成に成功している。具体的には、図4のように気象庁が過去に公開した気象電文とアナウンサーが読んだニュース原稿をそれぞれ4年分用意し、原稿作成の規則性をディープラーニングで学習することで、新たに与えられたデータに対してニュース原稿を生成する仕組みである。

※28  
各種公表情報より作成。

※29  
3A、2A、1Aの13のリーグを対象とする。142の球団を対象とし、年間総試合数は1万近くに達するという。



■図4 ディープラーニングを用いた気象ニュース原稿の生成イメージ<sup>30</sup>

ほかにも画像や数値データ等から言語を生成する多様な取組が行われている。表5にディープラーニングによる文章生成の取組例を示す。

■表5 文章生成関連用途にディープラーニングを応用する取組例<sup>31</sup>

| 組織名                | 国  | 概要  |
|--------------------|----|---|
| Automated Insights | 米国 | Automated Insightsはディープラーニングにより数値データ等から記事や文章を自動的に生成するシステムを開発している。詳細は本文を参照されたい。  |
| Narrative Science  | 米国 | Narrative Scienceはディープラーニングにより生データを解釈し、理解しやすい自然な文章を生成するプラットフォームQuillを提供している。ビッグデータが増大する中、人間が扱わなければならないデータ量も増加し、その分析と解釈にかかるコストや時間を抑えるためのソリューションとして期待されている。 |
| Persado            | 米国 | Persadoはディープラーニングにより消費者に行動を促すための適切なコピーライティングやフレーズを自動で生成するプラットフォームを開発している。現在は消費者向けのマーケティング等が主要領域であるが、今後は医療健康の促進等に広げる予定としている。                               |
| NTTデータ             | 日本 | NTTデータはディープラーニングにより気象電文とアナウンサーが読み上げた原稿の内容から原稿作成の規則性を学習し、新たに与えられたデータに対してニュース原稿を生成する技術を開発している。詳細は本文を参照されたい。   |

### 2.2.2.2 運動の習熟

強化学習とディープラーニングを組み合わせた深層強化学習と呼ばれる手法により、ロボットや機械の動作（運動）を習熟させる研究開発が始まっている。深層強化学習は、Google DeepMind（英国）が開発したAlphaGoやゲームをプレイするAIなどに利用されている技術であり、現在の状態から次の行動を

※30  
「人工知能を用いたニュース原稿の自動生成に関する実証実験を実施」NTTデータウェブサイト <<http://www.nttdata.com/jp/ja/news/release/2017/012702.html>>

※31  
各種公表情報より作成。

決める方策 (Policy)、状態や行動の価値を予測する価値関数 (V-function、Q-function) をニューラル ネットで表現してパラメータを学習する手法である。深層強化学習を実空間で応用する試みも始まっているが、多くが実証実験や研究開発段階にとどまっている。特に先進的な取組を表6に紹介する。

表6 運動の習熟関連用途にディープラーニングを応用する取組例<sup>32</sup>

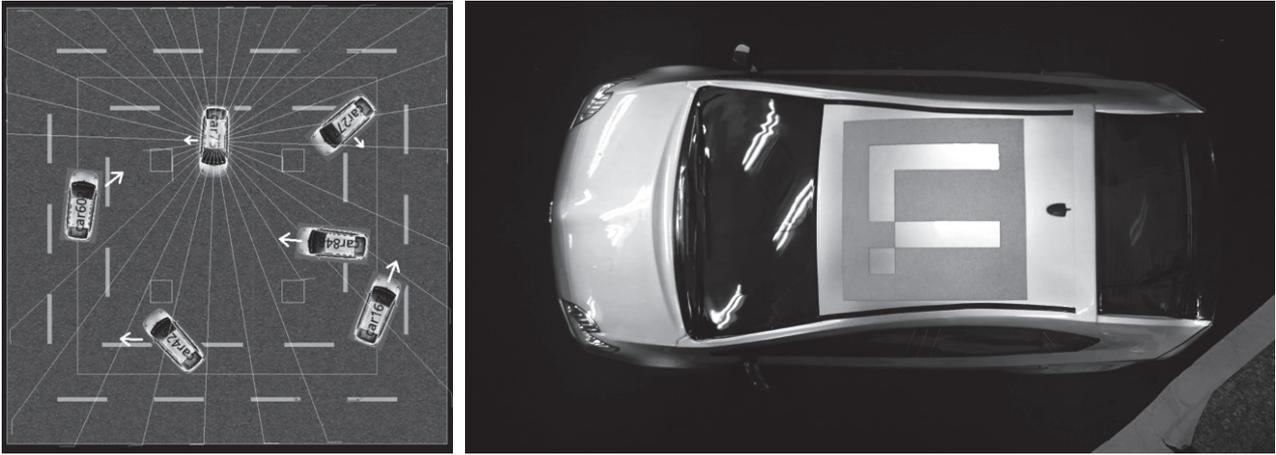
| 組織名    | 国  | 概要   |
|--------|----|--|
| Amazon | 米国 | Amazonは倉庫でのピッキングを完全自動化するために、技術開発コンテスト Amazon Picking Challengeを開催している。同コンテストには深層強化学習等の手法によりピッキングロボットの動作を習熟させる取組が見られた。詳細は本文を参照されたい。 |
| Google | 米国 | Googleはロボットがオフィスや医療機関等の複雑な現場業務を支援する機能を身につけるために、ロボットによる汎用的なスキル獲得を行うための研究開発を進めている。詳細は本文を参照されたい。                                      |
| トヨタ自動車 | 日本 | トヨタ自動車、Preferred Networks、NTTは2016年1月に開催されたCES 2016において、深層強化学習により自ら動作を学ぶロボットカーを展示した。詳細は本文を参照されたい。                                  |

Googleは、ロボットがオフィスや医療機関等の複雑な現場業務を支援する機能を身につけるためには“経験から学ぶ”ことが重要であるとして、ロボットによる汎用的なスキル獲得を行うための研究開発を進めている。2016年10月にGoogleが発表した研究成果<sup>33</sup>では、産業用ロボット（ロボットアーム）が、物体を押して移動させる方法とドアを開ける方法を学習するために、複数台のロボットにより同時に学習し、その結果を共有して精度を高めていく映像が公開されている。この研究には、モデルのない実経験から試行錯誤を行って学習する深層強化学習と、ネットワークを介してほかのロボットに瞬時に経験を伝える分散学習が用いられている。

Amazonは、倉庫でのピッキングを完全自動化するために、技術開発コンテスト Amazon Picking Challengeを開催している。同コンテストには深層強化学習によりピッキングロボットを学習させる試みも見られ、優れた成績を得ている。だが、対象となる荷や稼動範囲などが限定され、機械に任せる作業自体が単純化されていたにも関わらず、最も優れたロボットであっても1時間に30個程度の商品処理しかできないなど、実用化には課題が残っている。また、16%程度のミスが発生しているなど、人が容易に行っている作業の実現が難しいという課題も示された。ディープラーニングにより認識精度が向上したものの、多様な物体を認識することは現状困難なことも課題に挙げられている。具体的には、隠れた物体の検出や状態推定、形状が可変や不定な物体を検出することが実現できていないことなどがある。また、複数のアクチュエータ（例えばロボットハンド等）の精緻な制御など、ハードウェア側の制約も実現に向けた大きな課題とされている。

※32  
各種公表情報より作成。

※33  
“ How Robots Can Acquire New Skills from Their Shared Experience, ” Google Research Blog <<https://research.googleblog.com/2016/10/how-robots-can-acquire-new-skills-from.html>>



■図5 CES2016におけるロボットカーのデモ<sup>34</sup>

トヨタ自動車、Preferred Networks、NTTは2016年1月に開催された国際的な家電見本市CES 2016においてロボットカーの展示を行った（図5）。

この展示は、自動走行実現のための基礎研究の成果として公開されたもので、32方向360度のライダー（LIDAR、レーザーによる物体との距離検知センサ）から得られる障害物や他車両の情報を基に深層強化学習を利用して、「コースにそってなるべく速く移動する」、「ほかの車両や壁、障害物にぶつからない」ことを価値（報酬）として学習が行われている。展示ではロボットカー自らが徐々に運転を習熟していき、最終的にはぶつからずにスムーズに自律的に移動する様子が見られた。シミュレータという実社会とは異なる条件下ではあるが、自動走行の学習に深層強化学習による運動の習熟が効果的であることが示された。

本項で紹介したように、ディープラーニングにより、機械やロボット等の動作を習熟させる取組が進んでいるが、多くは限定された空間やタスクでの検証段階である。無限の事象が存在する実空間の課題に適応した高度な技術に至るには、更なる研究開発が必要と考えられる。

### 2.2.2.3 言語の意味理解

運動の習熟の次のステップとして言語の意味理解の実現が期待されている。第1章で示したとおり、ディープラーニングにより抽出した高次の特徴量を言語と紐付けることで、言語理解や自動翻訳、更には言語からの知識獲得までへと発展することが期待される。言語の意味理解の実用化には至っていないが、意味理解につながる基礎的な研究開発が進められており、着実に成果をあげている状況にある。今後、言語の意味理解の高度化やそれによる知識獲得への発展も期待されており、産業応用が進むことが予想される。

Googleの研究チーム（Google Brainチーム）は、ディープラーニングにより文意を理解して文章を要約することを目的としたテキスト要約（Text summarization）の研究開発を進めている。これは、言語の意味理解につながる基礎研究の一例である。Googleは文章要約の最新研究成果として、2016年8月にジョンズ・ホプキンス大学で作成された英語のニュース記事1万件からなるデータセット Annotated English Gigawordに基づく試行結果を発表している<sup>35</sup>。GoogleのText summarizationは本文から単語を抜粋して要約する「抜粋による要約」（extractive summarization）ではなく、内容をある程度書き換えた上で要約する「抽象的な要約」（abstractive summarization）の手法を採用している。

※34  
「CES2016でロボットカーのデモを展示してきました」 Preferred Research ウェブサイト <<https://research.preferred.jp/2016/01/ces2016/>>

※35  
“Text summarization with TensorFlow,” Google Research Blog <<https://research.googleblog.com/2016/08/text-summarization-with-tensorflow.html>>

例えば、抜粋による要約では「アリスとボブは列車に乗って動物園を訪れました。彼らは、赤ん坊のキリンとライオン、カラフルな熱帯鳥の群れを見ました」という文章を「アリスとボブは動物園を訪れました。彼らは鳥の群れを見ました」といった形で、元の文章から単語を抜粋・連結して要約を生成する。一方、抽象的な要約では「アリスとボブは動物園を訪れ、動物や鳥を見ました。」といった形で文意を別の表現として変換した上で要約する。これらの学習結果はText Summarization Modelとして、TensorFlow上に公開されており、開発者等は自由に学習済みモデルを利用することができる。

文章の意味理解に関わる取組は緒についたばかりであるが、昨今のディープラーニングの進化のスピードに鑑みると、そう遠くない未来に産業等での応用が始まることが期待される。

### 2.2.3 産業別の利用動向

ディープラーニングの登場に加え、昨今のインターネットサービスやIoT分野でのビッグデータの増大は、従前から利用されてきた統計的なアプローチ等の性能を飛躍的に向上させ、AIの産業応用の実用性と適用領域を拡大させている。本項では、AIの利用動向を産業別に示す。

#### 2.2.3.1 ものづくり

製造業は日本のGDPの2割弱を占める基幹産業であり、他産業への高い波及効果を持つ。米国やドイツ等も次世代型製造業への転換政策を打ち出し、製造業の重要性を見直しつつある。具体的には、Industry 4.0やIndustrial Internet に代表されるAI・IoTによる生産性向上、品質管理・向上、在庫削減、不良品の削減等を目的とした生産革新を進める動きが進んでいる。

##### (1)開発設計

ものづくり分野ではCAD、3次元CAD、CAE（Computer Aided Engineering）等により、2次元や3次元での製図やシミュレーションなど、材料開発や設計のプロセスのデジタル化が進んでいる。このデジタル化されたデータに対してAIを適用することで設計コストの抑制、品質やスピードの向上につなげようとする動きが見られる（表7）。

Autodesk（米国）は、軽量化などの設計意図と設計仕様、制約条件を与えると、それらを満足するような形状をAIにより自動的に導出するAdditive Manufacturing技術を3D-CADに組み込む「Dreamcatcher」プロジェクトを進めている。Dreamcatcherは機械学習等によりクラウド上で形状やパラメータ等を変えながら多数の設計案を提示することを目指している。

Citrine Informatics（米国）は、機械学習を中心としたAIにより材料の開発設計を支援する「Citrination」プラットフォームを提供している。Citrinationプラットフォームはクラウドサービスとして提供され、特許、論文、技術レポート、各種データベース等の大規模データに機械学習を適用することで様々な材料や化学物質の特性を予測し、毎年数億円規模のコスト削減や材料の開発設計プロセスの高速化を可能としている。

表7 開発設計にAIを利用する取組例<sup>※6</sup>

| 組織名                 | 国    | 概要   |
|---------------------|------|--|
| Autodesk            | 米国   | Autodeskは機械学習等のAI技術により製品の形状を自動的に導出するシステムを開発している。詳細は本文を参照されたい。  |
| Citrine Informatics | 米国   | Citrine Informaticsは機械学習等のAI技術により材料の開発設計を支援するクラウドベースのプラットフォームを提供している。詳細は本文を参照されたい。   |
| Dassault Systems    | フランス | Dassault SystemsはAIをCADに応用し設計案を自動的に生成したり、部品同士の最適な組み付けを提案する機能を開発している。例えば設計者が性能や設計思想を与えるとコンピュータが自動的に形状案を提示する機能を今後販売予定のSOLIDWORKS 2018に搭載する予定としている。             |
| 富士通                 | 日本   | 富士通は設計・生産現場の様々な業務に対してAIを適用するものづくりAIフレームワークを提供している。顧客の製品特性に応じて収集するデータの選別、予測等精度向上のためのチューニング等を行うことで、効果を高めている。例えば機械学習によりプリント基板の基板層数を予測することで、設計工程を短縮する等の取組が進んでいる。 |

## (2)生産工程

設計や生産プロセスで収集したデータに基づく生産の効率化や、AIを組み込んだ製造ロボット等による生産の自動化が進んでいる。また、これらの機能をプラットフォームとして提供するサービスも現れている。

GEは、AIやIoT等を駆使して製造現場のリアルタイムなデータから自社の生産オペレーションを最適化するプロジェクト「Brilliant Factory」を進めている。現在はセンサから得られたデータを基に、工場内の生産プロセスのリアルタイムの可視化や故障予知等を行っている。今後は製品の設計から製造、サプライチェーンの最適化など、製造に関わる全てのプロセスでデジタル化されたデータを活用して効率化を図る警句である。

Rethink Robotics（米国）は、製造現場で人間のように働く協働ロボットを開発している。同社のロボットは専門的なプログラミング知識なしに、ユーザ自身がロボットにさせたい作業を直接教えることで設定が可能であるほか、人と接触した場合に瞬時に停止するなど、共同作業の安全性を担保する機能を備えている。

ファナックはNTT、Preferred Networks、Cisco Systems（米国）、Rockwell Automation（米国）と共同で、製造プロセスを効率化するプラットフォーム「FIELD System」を開発している。FIELD Systemは製造現場での使用を目的としたIoTプラットフォームであり、製造現場に近いネットワーク内でデータを処理するエッジヘビー思想の仕組みである。エッジで取得したデータとAIによる加工時間の予測や不良品検知・異常検知等を可能とするほか、パートナー企業<sup>37</sup>が登録したアプリケーションの利用も可能になる。

ブリヂストンは熟練技術者の匠の技をAIに学ばせることで、生産工程や品質保証の判断・動作を自動化する取組を進めている。具体的には、複数のセンサからタイヤ1本当たり480項目の品質データを取得し、AIにより最適条件で組立できるようリアルタイムで制御する機能を実現した。これにより、技術者の能力によるばらつきが極小化され、品質向上、高生産性、自動化によるスキルレス化が可能となることで、従前以上の高精度な生産が可能となっている。

生産工程にAIを適用する取組例を表8に示す。

※36  
各種公表情報より作成。

※37  
提供前にもかかわらず200社以上がパートナーとして登録している。

表8 生産工程にAIを利用する取組例<sup>38</sup>

| 組織名              | 国  | 概要   |
|------------------|----|--|
| GE               | 米国 | GEはAIやIoTにより自社工場における生産革新を行うBrilliant Factoryを進めている。詳細は本文を参照されたい。   |
| Sight Machine    | 米国 | SightMachineは製造プロセス全体であらゆる部品、機械、ライン、プラントに対してリアルタイムで可視化を行い、実行可能な洞察を与えるプラットフォームを提供している。具体的には、製造プロセスで発生する非構造データを含む様々な形式のデータを取得し、独自のエキスパートシステムと機械学習アルゴリズムによりデータをリアルタイムで分類・意味付けすることで、製造プロセスの可視化、最適化、予測、異常検知等の機能を提供する。 |
| Rethink Robotics | 米国 | Rethink RoboticsはAIにより製造現場で人間のように働く協働ロボットを開発している。詳細は本文を参照されたい。   |
| ファナック            | 日本 | ファナックはPreferred Networks、Cisco Systems、Rockwell Automationと共同で製造プロセスを効率化するプラットフォームFIELD Systemを開発している。詳細は本文を参照されたい。  |
| ブリヂストン           | 日本 | ブリヂストンはタイヤの成形工程にAIを導入しリアルタイムで最適な組立制御を行う機能を実装している。詳細は本文を参照されたい。   |

### 2.2.3.2 モビリティ

モビリティ分野におけるAIの適用は、自動車に関わる取組が先行している。特に、1.2.1章でも取り上げた自動走行は、今後の競争領域として自動車メーカー各社が研究開発投資を積極的に進めている状況にある。また、自動走行車を組み込んだロボットタクシー等のモビリティサービスの提供や自動走行等を支える地図基盤の開発なども進められている。

#### (1)自動走行

自動走行には、表9のようにドライバーが全ての運転操作を行う状態（レベル0）から、運転支援システムが一部の運転操作を行う状態（レベル1や2）、システムが全ての運転タスクを実施する状態（レベル3.5）など、自動車の運転へのドライバーの関与度合の観点から、レベルが定義されている。

自動走行実現へのアプローチとして、運転支援（レベル1）から段階的に自動化を進める自動車メーカーやサプライヤー、一足飛びに完全自動運転（レベル3～5）を実現しようとするWaymo（Google）等のIT企業やスタートアップ企業の二つの立場がある。

Waymo（Google）は2009年から先駆的に取り組む企業として注目されており、これまでの7年間に、約300万マイル<sup>39</sup>の路上走行試験、10億マイルを超える走行シミュレーションを重ね、技術開発を進めてきた。開発した技術を商用化する目的で、2016年12月にWaymoが設立され、自動走行用センサパッケージを開発している。このパッケージには、360度レーダーと8個のビジョンモジュール、3種類の独自開発のライダーが搭載され、AIにより高速走行時にも遠方の建設コーンのような小さな物体を検出可能としている。2017年1月8日には、Fiat（イタリア）との共同開発によるビジョンシステムを搭載した完全自動走行車が公開され、100台の車両にWaymoのシステムを統合し、走行実験を始めている。本田技研工業もWaymoとの協同研究を発表しているように、自動車メーカーを巻き込んだ動きへと広がりを見せている。

※38  
各種公表情報より作成。

※39  
約482万8千km。

また、自動車メーカー各社は、表10のように2020年以降に完全な自動走行を実現するために、段階的に実用化を進めている。

表9 自動走行システムの定義<sup>40</sup>

| レベル                   | 概要   | 安全運転に係る監視、対応主体 <sup>a)</sup>           |
|-----------------------|--|--|
| 運転者が全てあるいは一部の運転タスクを実施 |  |  |
| SAE レベル0<br>運転自動化なし   | ・運転者が全ての運転タスクを実施   | 運転者                                    |
| SAE レベル1<br>運転支援      | ・システムが前後・左右のいずれかの車両制御に係る運転タスクのサブタスクを実施                                       | 運転者                                    |
| SAE レベル2<br>部分運転自動化   | ・システムが前後・左右の両方の車両制御に係る運転タスクのサブタスクを実施   | 運転者                                    |
| 運転者が全てあるいは一部の運転タスクを実施 |  |  |
| SAE レベル3<br>条件付運転自動化  | ・システムが全ての運転タスクを実施(限定領域内※)<br>・作動継続が困難な場合の運転者は、システムの介入要求等に対して、適切に応答することが期待される | システム<br>(作動継続が困難な場合は運転者) <sup>b)</sup> |
| SAE レベル4<br>高度運転自動化   | ・システムが全ての運転タスクを実施(限定領域内※)<br>・作動継続が困難な場合、利用者が応答することは期待されない                   | システム                                   |
| SAE レベル5<br>完全運転自動化   | ・システムが全ての運転タスクを実施(限定領域内※ではない)<br>・作動継続が困難な場合、利用者が応答することは期待されない               | システム                                   |

※ここでの「領域」は、必ずしも地理的な領域に限らず、環境、交通状況、速度、時間的な条件などを含む。

## (2) ロボットタクシー

自動走行車を前提とした移動サービス（ロボットタクシー）の開発が進められ、先行する企業では市街地等での実証実験が行われている。表11に企業等による取組例を示す。

Uber（米国）はAI研究所を設立して経路検索エンジンの開発や自動走行の開発を進めている。2016年8月に、自動走行タクシーの試験運用を行っているほか、2016年12月には、AIスタートアップ企業であるGeometric Intelligence（米国）を買収するなど、実用化に向けて取組を加速させている。

nuTonomy（米国）は、2016年4月にUberに先んじて自動走行によるタクシーサービスの公道実験をシンガポールで実施している。利用者（住民）はスマートフォンアプリを利用して車両を呼び、目的地まで移動することができるという。

Zoox Labs（米国）では、自動走行車を開発するスタートアップ企業である。単に自動走行により自動車の付加価値を高めるのではなく、利用者がどのように移動したいか、どのように車内で過ごしたいかなどを理解するためにAIを活用し、それに合わせた最適な移動サービスを提供しようとしている。同社に関わる技術的な情報は十分に公開されていないが、市場からは非常に高い評価がなされており、2016年に5000万ドルの資金調達に成功し、設立後の調達額が合計2億4,000万ドルに達している。

ディー・エヌ・エー（DeNA）は2015年5月、ZMP（日本）とロボットタクシーを合弁で設立し、神奈川県藤沢市、千葉市イオンモール幕張新都心等で走行実験を行っている。その後、ZMPとの合弁を解

※40

「戦略的イノベーション創造プログラム(SIP)自動走行システム研究開発計画」内閣府ウェブサイト <[http://www8.cao.go.jp/cstp/gaiyo/sip/keikaku/6\\_jidousoukou.pdf](http://www8.cao.go.jp/cstp/gaiyo/sip/keikaku/6_jidousoukou.pdf)>

表10 自動走行の取組例<sup>41</sup>

| 組織名                      | 国      | 概要   |
|--------------------------|--------|--|
| Audi                     | ドイツ    | Audiは人が運転にまったく関わらないロボットカーではなく、ドライバーを守り助けるための技術として自動走行を位置付けている。2017年に発売する新型車両A8において、量産車として世界初となるレベル3に相当するTrafficjam Pilot機能を搭載する計画である。Trafficjam Pilotは時速60km以下の渋滞時の高速道路等限定された環境でドライバーが監視義務のない同一車線内の自動走行を行う機能である。   |
| BMW                      | ドイツ    | BMWは2016年7月に完全自動走行車の開発促進のために、Intel及びMobileyeとの提携を発表している。2021年までに複数の完全自動走行車が連携して稼動するシステムの実現を目指している。   |
| Daimler                  | ドイツ    | Daimlerは2020年以降の自動走行実現を目指して研究開発を進めている。2016年7月にオランダ・アムステルダムで自動走行バスの実証実験を実施している。   |
| Fiat Chrysler Automobile | イタリア   | Fiat Chrysler Automobile は2016年5月にWaymo (Google) と自動走行車の開発で提携すると発表し、共同開発を進めている。  |
| Ford                     | 米国     | Fordは2016年9月に2025年までに完全自動走行車の一般販売を開始すると発表している。また、2021年までにカーシェアリングや配車サービス向けに完全自律走行車を投入する計画である。  |
| GM                       | 米国     | GMは2016年3月に自動走行システムを開発するスタートアップ企業 Cruise Automation (米国) を買収している。2016年5月にはLyftと連携して自動走行による配車サービスの公道実証実験を開始すると発表している。   |
| Mercedes                 | ドイツ    | Mercedesは2016年7月に発売開始した新型車両Class Eに多くの先進機能 (高速道路の渋滞時に先行車を追従する機能、自動車線変更機能等) を搭載している。  |
| Tesla Motors             | 米国     | Tesla Motorsは自動走行技術を搭載したモデルSを販売している。最新のモデルでは自動レーンチェンジや定速走行・車間距離制御を行うアダプティブクルーズコントロール等の機能が搭載されている。2016年10月に、生産中の全車種に「完全自動走行(エンハンスドオートパイロット)」に対応したハードウェアを搭載すると発表している。具体的には8つのカメラを搭載し、Teslaが開発したディープラーニング等により自車の周囲約250mを認識することを可能とする。また、12台の超音波センサ、前方ミリ波レーダーを搭載することで、従来の約2倍の距離までの物体を検知し、物体の性質 (柔らかい・硬い) や物体の種類 (建物、自動車、人、動物等) を識別できるという。なお、完全自動走行機能のソフトウェアは開発中であり、今後ソフトウェアアップデートを行う計画である。 |
| Volvo                    | スウェーデン | Volvoは2016年8月にUberと自動走行車を共同開発すると発表し、開発プロジェクトにUberと合わせて3億米ドルを投資する計画である。   |
| Waymo                    | 米国     | Waymoは自動走行用センサパッケージを開発し、自動車メーカーと連携して自動走行の実現を目指している。詳細は本文を参照されたい。   |
| トヨタ自動車                   | 日本     | トヨタ自動車は2020年頃の東京オリンピックの開催時期にレベル2又はレベル3の機能を搭載した自動走行車両の販売時期を目指している。  |
| 日産自動車                    | 日本     | 日産自動車は2016年8月に発売開始したセレナに、高速道路の単一レーンにおける自動走行技術を搭載している。また、2018年には高速道路の複数レーンへの対応、2020年には、一般道路や交差点にも対応する技術の商品化を目指している。   |
| 本田技研工業                   | 日本     | 本田技研工業は2020年頃をめどに高速道路における自動走行の実用化を目指したロードマップを公開している。2016年12月にはWaymoとの共同研究開発を発表している。  |

※41  
各種公表情報より作成。

消し、現在は通信技術をNTTドコモ、車体をEasymile（フランス）と提携し、遠隔管制による自動走行バスの開発を進めている。具体的には、第5世代移動通信方式により自動走行車両の周辺環境情報（映像等）を瞬時に伝送し、遠隔地にいるオペレータが高精細な映像を基に遠隔管制を行う仕組みである。

SBドライブは、地域公共交通の確保を目的として小型バスの自動走行化を進めている。ドライバー不足や赤字路線など、地域公共交通の課題を解決するために、1人当たり複数台の自動走行車を遠隔監視し、緊急時等に遠隔から即時停止させたり、路肩への停車・避難を誘導する。自動走行は車両自身が自律的に行うあるいはインフラ協調によって行うことを想定している。

ZMPは、2020年の東京オリンピック・パラリンピックにおいて完全自動走行が可能なロボットタクシーによる移動サービスを提供することを目標に、交通量も多く市街地である東京お台場を中心に公道での走行実験を継続して実施している。これまでの走行実験では、前車両の追従、レーンキーピング、レーンチェンジ、交差点での右左折等をドライバーの操作なしに行う（レベル3に相当<sup>42</sup>する）機能を実装し、検証している。同社は2017年度中にレベル4の機能をもつ車両を開発し、走行実験を行う予定としている。

表11 ロボットタクシーの取組例<sup>43</sup>

| 組織名       | 国  | 概要  |
|-----------|----|---|
| nuTonomy  | 米国 | nuTonomyは自動走行によるタクシーサービスを開発し、公道実験を世界で初めて実施した。詳細は本文を参照されたい。  |
| Uber      | 米国 | UberはAI研究所を設置し、自動車メーカー等と連携しながら自動走行車によるロボットタクシーの開発を進めている。詳細は本文を参照されたい。   |
| Zoox Labs | 米国 | Zoox Labsは自動走行車による移動サービスの開発を進めている。具体的には、移動者の感情等をAIで認識し、それに合わせた最適な移動サービスを提供する狙いがある。詳細は本文を参照されたい。                       |
| DeNA      | 日本 | DeNAは遠隔管制による自動走行バスの開発を行っている。詳細は本文を参照されたい。   |
| SBドライブ    | 日本 | SBドライブは地域公共交通の確保のために自動走行車を用いた移動サービスの開発を進めている。詳細は本文を参照されたい。  |
| ZMP       | 日本 | ZMPはお台場を中心とした地域で東京オリンピック・パラリンピックが開催される2020年に完全自動走行が可能なロボットタクシーによる移動サービスを提供することを目標に走行試験及び周辺システムの開発を進めている。詳細は本文を参照されたい。 |

### (3)その他

自動走行やそれを前提としたロボットタクシー等の実用化には、高度な地図基盤が不可欠である。具体的には、走行する道路等の静的な情報だけでなく、走行エリアの交通規制や混雑情報などの動的な情報も必要となる。こうした動的な道路情報を走行車両に提供するために、インターネットを通じて走行車両のセンサ情報をリアルタイムに収集し、クラウド上で分析することで各地域の交通状況、規制状況を整備する取組が進んでいる。

HERE（ドイツ）は、自動走行実験用の高精度地図データを提供するサービスを世界に先駆けて提供している。自ら車両を走行させて高精度地図データを収集しているほか、ドイツの自動車メーカー等と連携し、データ収集源を拡大し、高精度地図データのプラットフォームの形成を進めている。

ゼンリンは、自動走行用の高精度地図を作成するために、全国の高速道路等で計測車両を走行させている。2020年までに、自動走行用の地図を作成することを目指しており、レーザーセンサで取得した点群デー

※42  
自動走行システムのレベルについては表9を参照されたい。

※43  
各種公表情報より作成。

タとカメラ画像、高精度位置測位情報から、高精度な3Dの空間データベースの作成を進めている。

### 2.2.3.3 インフラ

道路、鉄道、空港・港湾、治水、生活インフラ等の長寿命化や維持管理の効率化を目的として、異常等の検知や設備運用の高度化にAIの適用が期待されている。

#### (1)異常検知

インフラや設備の故障・異常検知にAIを利用する取組が始まっている。AIによる異常検知に取り組む企業の例を表12に示す。

福田道路とNECは、ディープラーニングを用いて路面の映像からわだちとひび割れを同時に検出する舗装損傷診断システムを開発した。このシステムは、NECが保有するディープラーニング技術を活用して開発されたもので、一般的なビデオカメラを搭載した自動車から撮影した路面の映像を分析し、わだち掘れとひび割れを同時に検出して劣化レベルを評価できる。目視点検や専用機器による調査と比較して、安価かつ容易に路面の健全度を可視化することが期待される。

■表12 異常検知にAIを利用する取組例<sup>44</sup>

| 組織名         | 国  | 概要  |
|-------------|----|---|
| 首都高速道路      | 日本 | 首都高速道路は設計、施工、維持管理までの全データを管理し、転換や補修工事などを効率化するインフラ管理システムi-DREAMsを開発し、2017年度から運用を開始する。収集したデータはAIによる損傷推定エンジンが分析し、構造物の健全度や劣化度を予測する。具体的には、三次元レーザースキャナーとGPSを搭載した車両などが走行しながら計測した構造物などの形状をあらゆる座標値(三次元点群データ)を基に、経年変化等を分析することで、浮きや剥離等の形状変化を定量的に分析することができる。 |
| 千葉市         | 日本 | 千葉市と東京大学等は自動車にスマートフォンを搭載して路面を撮影することで損傷度を自動判定する機能を開発している。  |
| 日本国土開発      | 日本 | 日本国土開発と科学情報システムズは、建造物のコンクリートの表層品質を自動評価するシステムを開発している。モバイル端末のカメラでコンクリート表面を撮影するとAIが表面にできた気泡の状態を定量的に採点する。   |
| 東日本高速道路     | 日本 | 東日本高速道路は高速道路における路面凍結防止剤の効率的な散布を行うために、AIにより路面状態を自動で判別し、防止剤の散布量を計算するシステムを開発している。  |
| 福田道路<br>NEC | 日本 | 福田道路とNECはディープラーニングを用いて路面の映像からわだちとひび割れを同時に検出するシステムを開発している。詳細は本文を参照されたい。  |
| NTTコムウェア    | 日本 | NTTコムウェアと総合警備保障(ALSOK)は市販のカメラで撮影した道路の映像を基にひび割れやポットホールの有無を検出する技術を開発している。   |

#### (2)設備運用

インフラ等の設備運用の高度化を目的として、AIを活用する取組も見られる。表13に設備運用にAIを利用する取組例を示す。

香港鐵路有限公司(香港)が運営する香港最大の鉄道路線MTR(Mass Transit Railway)は、1日当たり約520万人の乗客を輸送する世界最大規模の鉄道であり、特別な祝祭日には24時間運行している。また、99.9%の定時運行を行うなど、ニューヨークやロンドン等の大都市と比較して非常に高い品質水準でサービスが提供されている。高い品質を維持するために、MTRでは鉄道の様々な工学的な作業を計画・スケ

※44  
各種公表情報より作成。

ジュール・最適化するためのAIエンジンを開発し、利用している。

具体的には、AIエンジンのスケジューリングに合わせた最適なりソース割り当てを行い、世界最大規模の鉄道システムを高い品質水準で管理を行っている。例えば、広大な地下鉄網における修繕ポイントがAIが見極め、毎週1万人ものエンジニアの修繕作業・整備を効率的に割り当てることができるという。MTRの取組は、米国人工知能協会（AAAI）より革新的アプリケーション（2014 Innovative Applications of AI Award）として表彰されている。

KONUX（ドイツ）は鉄道設備の予兆保全・保守を実施するためにAIを活用している。具体的には、分岐器にセンサを搭載し、分岐器の状態をリアルタイムでモニタリングするとともに、機械学習による予測アルゴリズムにより過去の振動や圧力等から潜在的な障害を検出することを可能とする。

■表13 設備運用にAIを利用する取組例<sup>45</sup>

| 組織名      | 国   | 概要   |
|----------|-----|--|
| KONUX    | ドイツ | KONUXは鉄道設備の予兆保全・保守を実施するためにAIを活用している。詳細は本文を参照されたい。                  |
| 香港鐵路有限公司 | 香港  | 香港鐵路有限公司は24時間利用可能な地下鉄MTRの運用のためにAI技術を組み込んだシステムを利用している。詳細は本文を参照されたい。 |

#### 2.2.3.4 農業

農業の担い手の減少や高齢化に加え、農業は人手に頼る作業や熟練者でなければできない作業が多いことから、省力化や人手の確保、負担軽減が課題となっている。こうした背景から、農業へのAI適用は生産性向上等の用途で先行している。

##### (1) 農業自動化

GPS等を利用して、高精度で無人走行を行う農機の開発や、収穫作業を自動化するロボット等の開発が進められている。これにより、省力化や農作業の負担軽減が期待されている。また、第4回「未来投資に向けた官民対話」<sup>46</sup>において「2018年までに圃場（ほじょう：作物を栽培する田畑）内での農機の自動走行システムを市販化し、20年までに遠隔監視で無人システムを実現できるよう制度整備などを行う」方針が示されたこともあり、より一層農機の自動化と実用化が進むと期待される。

Blue River Technology（米国）は、農機後方に設置したカメラから取得する画像を基に、農機を走らせながら栽培されているレタスを撮影し、自動的にレタスの間引きや雑草等の除去を行う農機を開発している。具体的には、ディープラーニングにより間引くべきレタスと間引かないレタスを画像から判別し、従業者は農機を走行させるだけで、自動的にレタスの間引きができるほか、圃場内の雑草等もAIが判断し、自動的に除去できる。1分間で5,000本の間引きが可能になるため、人手で間引きや除草にかかるコストが大幅に抑制されるほか、農薬の使用量も減らせるため、環境にも優しい減薬農法にもつながるといえる。

Deepfield Robotics（ドイツ）は、環境センサや慣性センサ、Wheel Odometry（車輪回転数からの移動量計算）、GPSを用いて位置推定と自動航行を行い、カメラや各種センサを用いて作物の識別、作物の測定や健康状態分析、土壌の密度測定、作物への水遣り、草むしりを行う農業用多目的ロボットプラッ

※45  
各種公表情報より作成。

※46  
「平成28年3月4日 未来投資に向けた官民対話」首相官邸ウェブサイト <[http://www.kantei.go.jp/jp/97\\_abe/actions/201603/04kanmin\\_taiwa.html](http://www.kantei.go.jp/jp/97_abe/actions/201603/04kanmin_taiwa.html)>

トフォームBoniRobを開発している。

クボタは圃場の広さや形状などのデータを活用し、有人監視下でトラクター（耕運機）の無人走行に取り組んでおり、2017年度からモニタ販売を開始する予定としている。事前に有人運転で農地を走行し、GPSの位置情報から農地の地図情報を作成した後、最適な作業経路を算出し、農機の位置、方位、傾きを高精度に推定する。これらの情報に基づき機体の制御システムと連携を取りながらエンジン回転数や変速などを自動的にコントロールすることで無人走行を実現する。

AIによる農業自動化に取り組む企業の例を表14に示す。

■表14 農業自動化にAIを利用する取組例<sup>47</sup>

| 組織名                   | 国   | 概要   |
|-----------------------|-----|--|
| Abundant Robotics     | 米国  | Abundant RoboticsはAIによりカメラで撮影したりんごの木や果実の画像から収穫物の状態を判別し、傷つけることなく収穫するロボットを開発している。  |
| Blue River Technology | 米国  | Blue River Technologyはディーラーリングにより画像から間引くべきレタスや雑草を判断し走行させるだけで自動的に除去する農機を開発している。詳細は本文を参照されたい。  |
| Deepfield Robotics    | ドイツ | Deepfield Roboticsは農機の自動走行やセンサ等による作物の識別、土壌状態の検知等を行う農業用多目的ロボットプラットフォームを開発している。詳細は本文を参照されたい。   |
| Harvest Automation    | 米国  | Harvest Automationは農園や温室栽培向けの作業を自動化するロボットHV-100を開発している。HV-100は農園等を自律的に移動し、水やり、農薬・除草剤散布、肥料散布等を自動的に行うことが可能であり、労働力不足の農業を支え、生産性を高めることが期待されている。 |
| クボタ                   | 日本  | クボタは圃場の広さや形状などのデータを活用し、有人監視下でトラクター（耕運機）の無人走行の開発を行っている。詳細は本文を参照されたい。  |
| 須藤物産                  | 日本  | 須藤物産はフルーツトマトを栽培する植物工場にAIを導入している。具体的にはGALCON（イスラエル）の植物工場用のAIにより、天候変化の予測に基づく給水等の制御を自動化し、高品質なトマトの生産を行っている。                                    |
| パナソニック                | 日本  | パナソニックはAIを用いてトマトを収穫するロボットを開発している。この収穫ロボットは、センサとカメラにより果実の色や形、場所を認識し、収穫時期を判定した上で、自動的に収穫を行う。夜間等に自動で収穫することで、昼間の作業負担を軽減することを目的とする。              |

## (2) 熟練農家の巧の技・ノウハウの移転

経験や口伝によって継承されてきた農家の技術・判断を形式知化し、就農者等の学習・指導に活用することが期待されている。農林水産省では、2016年に人工知能未来農業創造プロジェクトを開始。熟練農業者の視線や行動を計測し、作業記録と合わせて形式知化することで、新規就業者の学習、指導に活用する取組として進められている。

JAふくおか八女は、農林水産省のAI（アグリ・インフォマティクス）システム実証において、熟練農家の気づきを記録し、それを基に学習教材として形式知化して、未就農者や経験の少ない生産者の学習を支援するシステムを開発。フィールド実証を行った。実証では、熟練農家の着眼点を記録するアイカメラ、動きを捕捉する位置情報・動作センサ等を活用して、熟練農家のノウハウをデータ化した。これをタブレット端末等で参照して学習することで、高度な栽培技術を身につけることを支援するものであり、エキスパートシステムに類する技術の応用である。

※47  
各種公表情報より作成。

### (3)栽培管理の効率化

センサやドローンからの空撮データを基に、圃場ごとに最適な栽培管理方法を分析するほか、気象データ等よりリスクを予測し、事前の対策を実現する取組も進められている。AIによって栽培管理の効率化に取り組む企業例を、表15に示す。

Descartes Labs（米国）は衛星画像を中心として気象情報、商品価格動向、ウェブクロール、ソーシャルメディア等からの情報を取り込み、分析可能なプラットフォームを提供している。農業向けのソリューションとして衛星画像や気象情報等を基にエリアごとの収穫量等の予測を行う「Descartes Labs Crop Forecast」を提供している。

Mavrx（米国）は、衛星画像やドローンからの空撮画像を用いた作物管理やフィールドデータに基づく農作業支援を行っている。具体的には衛星画像や空撮画像により農地の潜在的な問題等を把握し、アラートを配信する「Guided Scouting and Sampling」、過去5年間の衛星データ及び作物データを基に現在の作物業績を過去と比較する「Crop Performance Benchmarking」、土壌の窒素をモニタリングする「Variable Rate Nitrogen」、設定したエリア内の作物等の変動を分析する「Management Zone Creation」等を提供している。

Prospera Technologies（イスラエル）は、農場全てをAIにより管理させることを目的として、センサ、カメラ等の農場の様々なデータを基に、病気や害虫の検出、作物の状態に適した水分や肥料の設定、採取時期や収穫量の判断等を行うツールを開発している。同社のツールは、既に欧州・北米・イスラエルの屋内栽培を行う中堅・大規模農家に導入されているほか、Walmart（米国）やTesco（英国）等の大手スーパーマーケットの契約農家において利用が進んでいる。

表15 栽培管理の効率化にAIを利用する取組例<sup>※48</sup>

| 組織名                   | 国     | 概要   |
|-----------------------|-------|--|
| Descartes Labs        | 米国    | Descartes Labsは衛星画像、気象情報等を分析して収穫量等の予測を行うサービスを提供している。詳細は本文を参照されたい。  |
| Mavrx                 | 米国    | Mavrxは空撮画像を用いた作物管理やフィールドデータに基づく農作業支援を行っている。詳細は本文を参照されたい。   |
| Prospera Technologies | イスラエル | Prospera Technologiesはセンサ、カメラ等のデータを基に、病気や害虫の検出、作物の状態に適した水分や肥料の設定、採取時期や収穫量の判断等を行うツールを開発している。詳細は本文を参照されたい。 |
| TerrAvion             | 米国    | TerrAvionは専用カメラを搭載した通常の飛行機により、カラー画像、赤外線画像、熱画像、植生分布等を可視化するサービスを提供している。                                    |

※48  
各種公表情報より作成。

### 2.2.3.5 健康・医療・介護

医療分野では、1970年代のAI第一次ブーム期より、エキスパートシステムと呼ばれるAI技術を応用する取組が実施されるなど、古くから活用が期待されてきた分野である。昨今のアルゴリズムの進展により、医療分野での実用化が進み、2.2.2項で紹介したディープラーニングによる診断支援に加え、電子カルテなどの診断データによる診断支援、新薬開発へのAIの適用等が期待されている。

#### (1) 診断支援

医学研究や診断・検査結果等を基に医師の診断を支援する取組が始まっている。診断支援に関する取組例を表16に示す。なお、ディープラーニングによる画像認識を用いた診断支援の取組は2.2.2項を参照されたい。

■表16 診断支援にAIを利用する取組例<sup>49</sup>

| 組織名            | 国  | 概要   |
|----------------|----|--|
| IBM            | 米国 | IBMは電子カルテや医学文献を基に医師の診断支援を行うWatson for Oncologyを提供している。詳細は本文を参照されたい。  |
| Grail          | 米国 | Grailは症状が現れる前に早期にがんを検出するための血液検査を開発している。詳細は本文を参照されたい。   |
| Verily         | 米国 | Verily (Googleのライフサイエンス分野が独立) は医療・健康データを収集・整理し、これらの洞察から治療への介入と総合的なプラットフォームの構築を進めている。   |
| 桶狭間病院藤田こころセンター | 日本 | 桶狭間病院藤田こころセンターは日本IBM、大塚製薬と協同でWatsonを用いた精神科向け電子カルテ解析システムMENTATを開発し、2016年7月から運用している。MENTATはWatsonの自然言語処理技術を活用し、電子カルテにある経過記録や退院サマリ、看護メモなどの文章を解析し、患者ごとに未治療期間、初発時年齢、拒薬傾向といった入院長期化や再発予測に関わる要素を抽出してデータベースを作成する。このデータベースを活用することで、過去の類似症例の検索や治療効果・経過確認が可能としている。 |
| 自治医科大学         | 日本 | 自治医科大学は患者の症状から複数の鑑別疾患をあげ、それぞれの疾患の確率を算出する総合診療支援システムホワイトジャックを開発している。問診や検査結果など新たな情報を追加するたびに最適と考えられる鑑別疾患のリストと必要な検査項目、処方箋をAIが繰り返し検討し、表示できる。   |
| FRONTEOヘルスケア   | 日本 | FRONTEOは電子カルテの解析から問診中の会話の分析、医療情報・論文の中から最新かつ最適な情報の抽出まで、個々に適した医療提供を支援するサービスを提供している。詳細は本文を参照されたい。   |

IBMは診断支援システム「Watson for Oncology」を開発し、医療機関への導入を進めている。Watson for Oncologyはがんの診断支援を行うクラウドサービスであり、肺がんや乳がん、結腸・直腸がんなどを対象としている。電子カルテから年齢、性別、症状、各種検査結果などの患者の属性データを抽出し、それを踏まえて各種ガイドラインなどに基づき最適な治療方針を分析するほか、医学文献から治療方針を支援するための根拠を探索し、その上で医師の専門知識によって訓練されたWatsonの推論モデルを用いて治療方針の優先順位を提示することができる。Watson for Oncologyを利用することで、医師はWatsonが提示した治療方針の優先度を基に、最終的な治療方針を決定することができる。

全米がん学会 (AACR) が2016年に開催したサンアントニオ乳がんシンポジウム (SABCS) において、Watson for Oncologyを導入したインドのManipal総合がんセンター及びManipal病院より、評価結果

※49  
各種公表情報より作成。

が発表された。638名の乳がん患者を対象に同病院の腫瘍医による診断との一致度及び評価までの時間を評価したところ、全体として90%腫瘍医による推奨と一致したが、転移がんでは45%しか一致しなかったなど、得手不得手があり、医師の業務を代替するものではなく補完するものであるとの評価が行われている。また、東京大学の医学研究所の研究によると、8割近くの症例でWatsonが診断や治療に役立つ情報を提示したとの成果が報告された。

Grail (米国) は、血液検査でがんを診断する技術「Guardant360」の開発に取り組んでいる。具体的には、血中に存在する極小のがん遺伝子を特定する方法で、患者の血液中の遺伝子情報を分析し、がん治療に対してがん細胞がどのように反応するかを調査する。2016年に設立された後、ジェフ・ベゾス氏、ビル・ゲイツ氏、Google Ventures (米国) 等から9億ドル超の資金調達を行っている。

FRONTEO (旧UBIC、日本) のヘルスケア子会社FRONTEOヘルスケアは、電子カルテの解析から問診中の会話の分析、医療情報・論文の中からの最新かつ最適な情報の抽出まで、世界中の人々が個々に適した最善の医療を受ける手助けとなるサービスを提供している。同社が開発中のがん個別化医療AIシステムは、医師に対して適切な情報提供を行う情報支援ユニット、患者とのコミュニケーションを支援するインフォームドコンセント支援ユニット、遺伝子分析の結果から診断支援を行う診断支援ユニットにより構成される。

## (2)新薬開発

ライフサイエンス分野では、製薬会社や各種研究所などがAIを用いて新薬開発に向けた取組を進めている。新薬開発は企業の競争力の源泉であり、研究開発などに多額の投資が行われ、表17のとおりスタートアップ企業等も新薬開発を効率化するためのAI技術の開発を進めている。

表17 新薬開発にAIを利用する取組例<sup>50</sup>

| 組織名                             | 国  | 概要  |
|---------------------------------|----|---|
| Atomwise                        | 米国 | Atomwiseはディープラーニングにより新薬候補を従来以上のスピード、精度で発見するソフトウェアAtomNetを開発している。詳細は本文を参照されたい。   |
| Benevolent AI                   | 英国 | Benevolent AIはAIにより医学文献等の大量データから新薬開発を支援するシステムを開発している。具体的には、医学論文、特許、臨床試験情報、そのほか医療に関する多様な構造化・非構造化データに対してAIを適用し、新薬候補の発見や化合物の物性予測を行う。テキストデータ等の非構造化データからコンテキストを分析し理解するためにディープラーニングを利用している。 |
| Recursion Pharmaceuticals       | 米国 | Recursion Pharmaceuticalsは生物科学とディープラーニングを含む機械学習を組み合わせ、希少疾患に効く既存薬を効果的に発見する技術を開発している。特定の病気のメカニズムについて長期間にわたって高額な研究をしなくても治療法の特定が可能になり、これまでに15の有望な希少疾患の治療法を発見している。                         |
| システムバイオロジー研究機構、SBX Technologies | 日本 | システムバイオロジー研究機構とSBX TechnologiesはGaruda PlatformとGandhara AI Frameworkを開発し、生命科学の基礎研究から創薬プロセス全般にわたるサポートを国内外の製薬企業に対して提供している。詳細は本文を参照されたい。  |
| 武田薬品工業、富士フイルム、塩野義製薬等            | 日本 | 武田薬品工業、富士フイルム、塩野義製薬等は富士通やNEC等のIT企業とともに、AIを使った新薬開発を推進している。詳細は本文を参照されたい。  |

Atomwise (米国) は、ディープラーニングにより新薬候補を従来以上のスピード、精度で発見するソフトウェア「AtomNet」を開発している。AtomNetは畳み込みニューラルネットワークにより、生理活

※50  
各種公表情報より作成。

性物質の構造を予測し、新薬設計を行うことができるアルゴリズムを搭載している。創薬のベンチマークDUD-E<sup>51</sup>において、AtomNetがほかのアルゴリズムより優れた成績を納め、実際の創薬実験にも利用されている。

システム・バイオロジー研究機構は同機構の事業会社であるSBX Technologiesとともに、システムバイオロジーとAIを適切に組み合わせた創薬プラットフォーム「Garuda Connectivity Platform、Gandhara AI Framework」を開発し、国内外の製薬企業に提供している。さらにドメイン特化型のテキストマイニングサービスTaxilaを提供するなど、製薬企業等の広範なニーズに対応している。

武田薬品工業、富士フイルム、塩野義製薬などは、富士通やNEC等のIT企業とともに、AIによる新薬開発を推進している。約50社が参加し、理化学研究所や京都大学と協力して創薬用AIエンジンの開発が進められている。

### (3)その他

医療現場にロボット等を導入して手、術の自動化や支援を行う取組や医療情報のプラットフォームを構築する動きも進んでいる。

Verb Surgical（米国）は、GoogleとJohnson & Johnson（米国）により設立された合弁会社であり、機械学習や画像処理を用いて複雑な手術を支援する次世代手術ロボットのプラットフォーム開発を進めている。手術支援ロボットで著名な「da Vinci」のように、人間がアームを操作する手術ロボットは様々な企業が開発しているが、同社はGoogleの機械学習や画像処理技術を活用して、様々な外科手術に適用することを目指している。同プラットフォームは、ロボティクス、可視化、計測、データ分析、ネットワーク等の機能により構成され、2017年1月にはパートナー企業にプロトタイプが提供されている。

東京女子医科大学、日本医療研究開発機構（AMED）、広島大学はスマート治療室SCOT（Smart Cyber Operating Theater）を開発している。SCOTは治療室内の医療機器を機能や役割に応じてパッケージ化し、OpeliNKと呼ぶシステムで治療室全体をネットワーク化する。AIを始めとするコンピュータの支援により治療の安全性と効率性を向上させる。治療室全体がネットワーク化されているため、医療機器のデータや術中画像、器具の位置情報、患者の生体情報などを統合管理することができる。SCOTは、手術中に担当の外科医に有用なデータを提供して意思決定を支援する意思決定ナビゲーションシステムや、外科医の負担を低減する精密誘導手術システムで構成され、機器の接続実証などを進め、2019年3月に完成させて同年夏に治療を開始する計画である。

iCarbonX（中国）はゲノムデータ、医療データ、健康関連データを蓄積管理する医療データプラットフォームの構築を進めている。2015年に設立後1億9,948万ドルもの資金調達を行ったほか、創業6ヶ月で企業評価額が10億ドルを超えたことで注目され、医療健康関連の複数のプレイヤーとコンソーシアムを設立している。今後5年間で100万人のユーザを集め、プラットフォームを強化する方針である。

#### 2.2.3.6 防犯・防災

防犯分野におけるAIの適用は、監視カメラ等の映像を基にした“リアルタイムでの”不審者の特定・追跡や防犯ロボット（ドローン）が中心であり、施設から街・都市全体の防犯へと広がることが期待されている。

我が国では「東京2020オリンピック・パラリンピック競技大会」開催に向けたセキュリティ対策の一環としてAIの利用が検討されており、東京オリンピック・パラリンピックをモデルとして全国規模に展開さ

---

※51

100万以上の予測をさせて過去の結果と照合するテスト。

れる可能性も秘めている。

### (1)サイバーセキュリティ対策

ディープラーニングや機械学習等によりマルウェア等の検知率を高めるだけでなく、未知のマルウェアの予測・検知を行う機能の実用化が始まっている。主要な取組例を表18に示す。

■表18 サイバーセキュリティ対策にAIを利用する取組例<sup>52</sup>

| 組織名           | 国     | 概要   |
|---------------|-------|--|
| Cylance       | 米国    | Cylanceはディープラーニングにより未知のマルウェアを特定・検知するソフトウェアを開発している。既知のマルウェアファイルに加えて正常のファイルも学習対象とし、700万の特徴を学習させている。詳細は本文を参照されたい。             |
| Darktrace     | 英国    | Darktraceは機械学習と数学理論に基づいて企業情報ネットワークの動態を学習し、ネットワークの変化を検知して警告を行う情報セキュリティ対策ソフトを開発している。詳細は本文を参照されたい。                            |
| Deep Instinct | イスラエル | Deep Instinctはディープラーニングによりゼロデイ攻撃やAPT攻撃の予測や攻撃からの保護を行うシステムを開発している。詳細は本文を参照されたい。  |
| SignalSense   | 米国    | SignalSenseはセキュリティの検出のために人間の知識を取り入れた脅威の予測検知機能を行うフレームワークを開発している。具体的には、セキュリティ専門家の知識と思考プロセスを学習させることで、未知の脅威の特定、予測、対応強化につなげている。 |
| Symantec      | 米国    | Symantecは機械学習を活用した学習型AIエンジンSkepticを開発し、サイバー攻撃の検出精度を高めている。詳細は本文を参照されたい。   |
| トレンドマイクロ      | 日本    | トレンドマイクロは機械学習型検索機能を組み込んだ企業向け総合セキュリティソフトであるウィルスバスター コーポレートエディション XGを提供している。詳細は本文を参照されたい。                                    |

Darktrace (英国) は、機械学習と数学理論に基づいて企業情報ネットワークの動態を学習し、ネットワークの変化を検知して警告を行う情報セキュリティ対策ソフトを開発している。既に侵入してしまった悪意あるプログラムの動作や内部不正利用・操作ミス等による動作のほか、未知の攻撃についても検知・可視化することができる。産業用制御システム (ICS) や監視制御システム (SCADA) にも適応可能な Industrial Immune Systemも開発しており、重要インフラ等の制御システムへのセキュリティ対策としても期待されている。

Deep Instinct (イスラエル) はディープラーニングによりゼロデイ攻撃やAPT攻撃の予測や攻撃からの保護を行うシステムを開発している。具体的には、10億以上の既知のマルウェアを対象としてディープラーニングにより学習させることで、未知のサイバー攻撃からの保護を可能としている。

Cylance (米国) はディープラーニングを導入したサイバーセキュリティ対策ソフト「CylancePROTECT」を開発している。ディープラーニングにより正常なファイルやマルウェアなど数億に上るファイルから抽出した700万の特徴を学習させ、マルウェアのパターンファイルがなくとも未知のマルウェアを特定・検知することができるという。

Symantec (米国) は自社開発による学習型AIエンジン「Skeptic」によりサイバー攻撃の検出精度を高めている。機械学習を活用し、エンドポイントとクラウドにおけるセキュリティを確保し、サイバー攻撃の兆候となり得るパターンや特異性を見つけ出すことで、攻撃手段にかかわらず、エンドポイントでの

※52  
各種公表情報より作成。

先進的な脅威の阻止と対応を可能とする。

トレンドマイクロは機械学習型検索機能を組み込んだ企業向け総合セキュリティソフトである「ウィルスバスター コーポレートエディション XG」を2017年1月より提供している。同機能は複雑化する脅威から企業を守るために、EXEやdllなどファイルタイプごとに適した学習モデルを使い分け、プログラムの実行前や実行後に「機械学習型検索機能」を用いることで未知の脅威等を検出できる。

## (2)災害対策・予測

都市化や気候変動により、自然災害等による脅威は増大している。特に、日本を含めたアジア地域では、世界で発生した自然災害の約58%を占めるなど、多くの災害が発生し、犠牲者も出ている。我が国では、ハード（防災基盤）、ソフト（避難態勢、規制）、人的（危険度の認識・リテラシ、対応策等）な対策技術やノウハウを長年かけて培ってきた強みがあり、今後も発生が想定されるアジア地域を中心に、こうした技術を展開することも期待されている。これまでの災害対策において、SNS等の情報を用いた災害推定、気象データに基づく降水量の予測及び危険度の推定、雨量データや河川流量のデータに基づく予測などが行われてきたが、今後AIにより、より精度の高い予測や新たな対策の開発も期待される。主要な取組例を表19に示す。

産業技術総合研究所とNECは「産総研-NEC 人工知能連携研究室」を設立し、シミュレーションとAIを融合させて未知の状況での意思決定支援の実現に向けて開発を進めている。具体的には、シミュレーションによりまれに起こる異常事態などに関するデータを擬似的に生成し、統計的な機械学習や大量データを必要とするディープラーニング等が有効に機能しづらい災害等に対しても、予測や意思決定の支援につながる情報提供を可能とする。

情報通信研究機構は、耐災害ICT研究センター及びユニバーサルコミュニケーション研究所において開発した災害状況要約システム「D-SUMM」(Disaster-information SUMMarizer)をウェブ上に試験公開している。D-SUMMは、Twitterに投稿された災害関連情報をリアルタイムに分析する。都道府県単位又は市区町村単位でエリアを指定すると、指定エリア内の被災報告を瞬時に要約し、そのエリアの被災状況の概要が一目で分かるように、コンパクトかつ、分かりやすい提示。各種救援、避難等を支援できる仕組みである。「火災が発生している」、「火事が起きている」など、意味的に類似する被災報告を分類するために、機械学習や統計処理を用いている。

表19 災害対策・予測にAIを利用する取組例<sup>53</sup>

| 組織名                      | 国  | 概要  |
|--------------------------|----|---|
| 産業技術総合研究所 NEC            | 日本 | NECと産業技術総合研究所はディープラーニング等が有効に機能しづらい災害等に対しても予測や意思決定の支援につながる情報提供を行うための技術を開発している。詳細は本文を参照されたい。                |
| 情報通信研究機構                 | 日本 | 情報通信研究機構はエリアの被災状況の概要が一目で分かる災害状況要約システムD-SUMM(ディーサム)を公開している。詳細は本文を参照されたい。                                   |
| 国土技術政策総合研究所<br>産業技術総合研究所 | 日本 | 国土交通省国土技術政策総合研究所と産業技術総合研究所は、土砂災害の予兆や発生を検知可能な観測・監視情報を検討し、IoTを活用したセンサの検討・開発やAIを活用した災害発生の判別精度向上に関する研究を行っている。 |

※53  
各種公表情報より作成。

### (3)映像監視・犯罪リスク予測

テロの発生等によりセキュリティへの意識が高まる中、大規模商業施設や鉄道等の公共施設等に防犯カメラの新設・増設が進んでいる。防犯カメラの設置による防犯効果の向上が期待される一方で、警備員がこれらの映像を目視で監視することは困難である。こうした課題に対して、表20に示すようにAIを適用して異常検知や物体認識・追従を行う機能の開発が進められている。

表20 映像監視・犯罪リスク予測にAIを利用する取組例<sup>54</sup>

| 組織名       | 国   | 概要   |
|-----------|-----|--|
| Algocian  | カナダ | Algocianは最先端の機械学習を活用し、映像から人を検出可能な監視カメラを開発している。カメラの位置や環境条件、屋内外に関わらず検出できるほか、最新の製品Artemis1では、侵入検知等の機能を搭載して人の存在や動作を検知することで不必要な記録や通信(帯域幅使用率)を抑制することができる。  |
| Canary    | 米国  | Canaryはディープラーニングによる画像認識を搭載した屋外用防犯カメラを販売・提供している。スマートフォンアプリと連携し、スマートフォン保有者が外出すると自動的に監視モードへと移行し、遠隔からリアルタイムで映像を確認できるほか、AIにより動きを自動検出した場合に前後数秒の動画を自動的に編集、保存することができる。   |
| SenseTime | 中国  | SenseTimeはディープラーニングを用いた顔認証のソリューションを防犯用途で提供している。シーンごとに1,000人までを解析できるほか、大規模群衆の過密・対流・混乱など状態監視を行うことができる。同社はILSVRCのビデオ部門で2015年に首位を獲得する等高い技術力を有している。   |
| Megvii    | 中国  | Megviiは顔認識を行うクラウド型のプラットフォームサービスのほか、これらの機能と連携可能な監視カメラ等のハードウェアを開発し、ビデオ監視、侵入警報等の機能により政府の安全保障、公共安全、税関、空港、鉄道などでの利用を進めている。   |
| NEST      | 米国  | NESTは機械学習により映像から自動的にドアを認識し、ドアの周囲をアクティビティエリアとして監視対象に設定する家庭用カメラとアプリケーションを提供している。詳細は本文を参照されたい。  |
| 日立製作所     | 日本  | 日立製作所は防犯カメラなどの映像にディープラーニングを適用することで、人物の特定・抽出を行う技術を開発している。人物の性別・年齢層・服装・髪型などの特徴を複数同時に判定できるほか、「歩く」、「走る」、「しゃがむ」などの10項目の動作に関する特徴も識別できる。また、人物の全身画像を詳細に解析し、同一人物の映像を抽出する高速人物追跡も可能とする。空港や駅などの公共施設などでの警備や防犯用途に活用することを狙い、2019年3月までに実用化を目指している。   |
| 富士通       | 日本  | 富士通は市街地や施設内に設置された監視カメラ映像を富士通のAI技術Human Centric AI Zinraiと高速画像処理技術により分析し防犯等に役立てるFUJITSU Technical Computing Solution GREENAGES Citywide Surveillanceを提供している。大量の画像データに対してディープラーニング等のAIを適用して車両の車種や人物の着衣タイプなどの特長まで認識するサービスである。空港・駅・幹線道路・工業団地・ショッピングモール・駐車場といった施設や、市街地などの公共スペースに幅広く活用でき、全体的な車や人の動きの把握や防犯などに適用できる。 |
| NEC       | 日本  | NECは防犯カメラなどの大量の映像から特定の時間・場所に出現する人物や、特定の動作をしている人物を高速・高精度に検索するAIソフトウェアNeoFace Image data miningを提供している。顔画像に基づいた特定の人物の検索に加え、特定の時間・場所に出現する人物の検索、特定の人物と一緒にいる人物の検索が可能であり、犯罪捜査や迷子の捜索等防犯用途での活用が期待されている。特定の時間・場所に頻繁に出現する人物を100万件の顔データから検索する場合には10秒という非常に短時間で検索可能である。顔認証などAIを使った複合的な監視システムを数年以内に100都市に導入する方針を打ち出している。  |

※54  
各種公表情報より作成。

Nest（米国）は家庭用のカメラNest Cam及びAIを組み込んだNestCam用のアプリケーションNest Awareを提供している。Nest Awareは機械学習により映像から自動的にドアを認識し、ドアの周囲をアクティビティエリアとして監視対象に設定できる。アクティビティエリア内の大きな動きや変化を検出すると、スマートフォンにプッシュ通知することができ、不審者の自動検知等に活用されている。

### 2.2.3.7 エネルギー

計測機器や計測システムの高機能化、スマートメーターの普及等により、電力の発電や送電、使用に関わる様々なデータを取得・蓄積できるようになっている。これらのデータに対して、AIを適用して電力需要予測や運用効率化等を行う取組が進められている。

#### (1)電力需要予測

気象データや過去の電力需給データ等から電力需要等を予測する取組が見られる。主要な取組例を表21に示す。

表21 電力需要予測にAIを利用する取組例<sup>55</sup>

| 組織名                    | 国  | 概要   |
|------------------------|----|--|
| Verdigris Technologies | 米国 | Verdigris Technologiesはエネルギーコストの節約や電力需要の監視・調整を行うためのソフトウェアを開発している。詳細は本文を参照されたい。   |
| グリッド                   | 日本 | グリッドは気象情報等を基に、独自の気象予測プログラムにより対象地点の日射量を予測し、30分ごとの発電量を3日先まで予測するシステムを開発している。詳細は本文を参照されたい。   |
| 安藤ハザマ                  | 日本 | 安藤ハザマはAIによる新たなEMSを含むスマートエネルギーシステムAHSESを開発している。建物の利用や気象の情報を基に、機械学習と数理手法により電力需要予測及び最適運転計画を行い、創エネ設備と蓄エネ設備から最適なタイミングで電力の供給を支援することができる。               |
| 清水建設                   | 日本 | 清水建設は中部大学と共同で建物の電力需要を高精度に予測するシステムを開発している。具体的には、電力の需要、気象データ、設備・施設利用状況等の関係をディープラーニングにより学習し、高精度予測を行う。   |
| 三菱重工業                  | 日本 | 三菱重工業はAI及びIoTによる総合的なエネルギーソリューションサービスENERGY CLOUD Serviceを提供している。同サービスは、AIにより90%を超える高い精度でエネルギー需要を予測するほか、設備稼働状況を把握することでエネルギー調達と生産効率の改善を支援することができる。 |

Verdigris Technologies（米国）はオフィスビルや企業施設、大規模商業ビル向けのクラウドベースの分析ソフトウェア「Smart Building Management」を提供している。AIにより設備運用・保守の最適化を行うことで稼働時間を増やし、エネルギーコストを節約する。また、AIにより電力需要を監視し、平均使用量等の一定の基準を超えた場合に設備の電力需要量を自動調整する機能も有し、月平均30.50%のコストを削減できるという。

グリッドは、気象情報、地理データ、周辺環境情報を基に、独自の気象予測プログラムにより対象地点の日射量を予測し、30分ごとの発電量を3日先まで予測するシステムを開発している。また、得られた予測情報と今後全世帯に設置することになるスマートメーターとの情報を組み合わせることで、消費電力予測や電力需給予測を行うことも可能にする。同社は、需給予測情報を電力会社やPPS事業者へ配信するこ

※55  
各種公表情報より作成。

とで、電力需給の「同時同量義務」をサポートし、それらのデータを最終消費者（エンドユーザー）へ配信することで、月末の電気料金予測等の新たなエネルギーサービスの提供も試みている。

## (2)運用効率化

電力の発電や送電、使用に関わる様々なデータをもとに、発電や送電等の効率化を進める取組が始まっている。運用効率化に取り組む企業の例を表22に示す。

SmartCloud（米国）は、AIによる産業システムの監視プラットフォーム「Crex」を提供している。Crexは、AIにより産業システムから送られる膨大なデータの分析を行い、産業システムに異常が発生した場合のリアルタイムでの異常検知や、欠落しているデータの自動補正などを行う。ほかにも、建物の利用や気象の情報を基に、機械学習と数理手法により電力需要予測及び最適運転計画を行い、創エネ設備と蓄エネ設備から最適なタイミングで電力を補完する取組を行っている。

東京電力フュエル&パワーは、GEのIndustrial IoTプラットフォーム「Predix」を導入し、発電設備等の運用効率化に取り組んでいる。具体的には、火力発電所のガスタービン、蒸気タービン、発電機に取り付けたセンサから温度、圧力、振動等の数千項目に上るデータを収集し、運転状況をリアルタイムでモニタリングしたり、燃料の効率的な使い方や異常な挙動等を分析したりする。同社は、機器だけでなく作業員のデータ（心拍、体温、体調等）、外部データ（気候、市場データ等）も分析対象とし、効率的な発電だけでなく効率的な働き方を実現することで、生産性を高めることを狙っている。

表22 運用効率化にAIを利用する取組例<sup>56</sup>

| 組織名          | 国  | 概要   |
|--------------|----|--|
| SmartCloud   | 米国 | SmartCloudは機械学習と数理手法により、電力需要予測及び最適運転計画を行う技術を開発している。詳細は本文を参照されたい。   |
| 東京電力フュエル&パワー | 日本 | 東京電力フュエル&パワーは、GEが提供するPredixを利用して、発電設備等の運用効率化に取り組んでいる。詳細は本文を参照されたい。 |

### 2.2.3.8 学習

教育分野におけるIT活用が進む中、個人の学習傾向に合わせてプログラムを提供する適応学習（Adaptive learning）、解答の採点、学生からの質問への対応等に利用されている。

#### (1)適応学習

個々の学生の学習状況や嗜好等を踏まえて、パーソナライズされた学習を供給する適応学習の提供が始まっている。適応学習に取り組む企業の例を表23に示す。

※55  
各種公表情報より作成。

■表23 適応学習にAIを利用する取組例<sup>57</sup>

| 組織名     | 国  | 概要  |
|---------|----|---|
| ALEKS   | 米国 | ALEKSはAIにより生徒の理解度を判定し、個々の理解度に応じて問題を出題する教育サービスを提供している。詳細は本文を参照されたい。                              |
| Knewton | 米国 | Knewtonは学習履歴、学習行動に関わるデータ、学習の仕組みに関わる研究等を基に理解度や進度を評価する技術を開発している。詳細は本文を参照されたい。                     |
| サイトビジット | 日本 | サイトビジットはAIを活用して、受講者に応じた学習教材を提供する取組を行っている。具体的には司法試験と行政書士講座の受講者に対して、問題解答の傾向から最適な問題を適切なタイミングで提示する。 |

McGraw-Hill Education（米国）傘下のALEKS（米国）は、AIを用いて生徒の理解度を判定し、それに応じて問題を出題する教育サービスを提供している。具体的には、個々の生徒の解答から理解できていない箇所を判断し、理解のために必要な問題を出題する。出題される問題全てがAIにより生成され、個々の生徒の学習状況、理解度に応じて問題が構成される。AIは、解答の正誤だけでなく、Knowledge Space Theoryと呼ばれる学習理論に基づき、問題を選定する。この理論は、一つの学習分野が様々な概念に基づいて構成されているとするもので、複数ある概念をどのようなステップで学習すると効率的なのかを発見することができる。

Knewton（米国）は本人の学習履歴、ほかの学習者の学習行動データ、人間の学習の仕組みに関する数十年にわたる研究を基に、学習者の理解度や進度を基に次の学習ステップへと導く適応学習を提供する。Knewtonの理論は、心理統計学や項目応答理論、認知学習理論、インテリジェント・チュータリングシステムに関する研究成果に基づくもので、学習者の理解度を学習目的別に測定することで、学習者に最適な学習ステップを提供する。

## (2)採点

テスト等の解答に対してAIを適用することで、教員等の採点を支援する取組も始まっている。採点にAIを利用する取組例を表24に示す。

■表24 採点にAIを利用する取組例<sup>58</sup>

| 組織名                         | 国  | 概要  |
|-----------------------------|----|---|
| Educational Testing Service | 米国 | Educational Testing Serviceは英語能力試験TOEFLにおいて自然言語処理を用いた自動採点技術eRaterを導入している。詳細は本文を参照されたい。              |
| Gradescope                  | 米国 | Gradescope（米国）はAIを利用したオンライン答案採点アプリケーションGradescopeを提供している。Gradescopeは答案の分類をAIで行うことができる。詳細は本文を参照されたい。 |
| EduLab                      | 日本 | EduLabは記述式解答の採点効率化への試みとして、手書きの解答を自動でテキストデータ化する技術を開発している。詳細は本文を参照されたい。                               |

Educational Testing Service（米国）は、英語能力試験TOEFLにおいて自然言語処理を用いた自動採点技術「eRater」を導入している。eRaterにより、解答の内容や意味は人間が判断し、文法の誤り（主語と動詞の対応関係等）、代名詞、所有格、冠詞、前置詞等の用法の誤りなど言語的な特徴は自動採点す

※57  
各種公表情報より作成。

※58  
各種公表情報より作成。

ることで、質の高い採点を可能とする。

Gradescope（米国）はオンライン答案採点アプリケーション「Gradescope」にAIを搭載し、答案の分類を行うサービスを提供している。生徒が手書きで解答した結果を画像認識した上で、複数の解答結果を分類することができる。同様・類似解答を一括して採点できるようにすることで、効率化を図ることが期待される。

EduLabは、記述式解答の採点効率化への試みとして、手書きの解答を自動でテキストデータ化する技術を開発している。手書き文字をディープラーニングにより認識し、認識率98.66%を実現している。これにより、1設問当たり最大83%の採点工数カットを実現できるという。

### 2.2.3.9 金融

金融分野におけるAIの利用は、アルゴリズムによる株式取引から資産運用、個人向けの金融サービス、保険サービスまで幅広く適用されている。

#### (1) 株式取引

AIを用いて高度なアルゴリズムトレーディングを実現する、先端ソリューションを開発するスタートアップ企業が現れており、これらのスタートアップ企業と金融機関・投資機関が連携する動きも進んでいる。株式取引にAIを適用する取組例を表25に示す。

表25 株式取引にAIを利用する取組例<sup>59</sup>

| 組織名                   | 国  | 概要  |
|-----------------------|----|---|
| AlpacaDB              | 米国 | AlpacaDBはディープラーニングを用いて投資アルゴリズムを設計するアルパカアルゴ、米国株式市場向けに何をかうべきかを支援するアルパカスキャンを開発している。アルパカアルゴは普段の取引のタイミングを過去のチャートで指定することで、ディープラーニングによりアルゴリズムを生成することができ、プログラミング等のノウハウが無くとも自動取引の仕組みを利用することができる。 |
| Goldman Sachs         | 米国 | Goldman Sachsは過去の株式投資に関わるデータを基に機械学習等のAIにより最適な取引を行うシステムを導入している。詳細は本文を参照されたい。   |
| Sentient Technologies | 米国 | Sentient Technologiesは大規模並列システムを用いて機械学習等のAIによる投資管理システムを開発している。詳細は本文を参照されたい。   |
| 野村證券                  | 日本 | 野村證券は機関投資家向けのアルゴリズム取引システムModelEXにディープラーニングを導入している。東京証券取引所の市場データを基に5分後の株価の動きを予測する。従前は統計的手法を用いていたが、ディープラーニングを用いることで2倍の精度が得られるケースもあるとしている。   |
| みずほ証券                 | 日本 | みずほ証券はAIを搭載した株式売買システムを機関投資家に提供している。個別銘柄の注文状況、売買量、過去の株価の変動等から30分から1時間後の株価の変動を予測する仕組みである。   |
| 三菱UFJ信託銀行             | 日本 | 三菱UFJ信託銀行は機関投資家向けにAIが銘柄を選択する投資信託AI日本株式オープンを提供している。経済ニュース等に基づく個別銘柄の株価変動予測、為替や各種指標に基づく株価の方向性の予測等を基に運用を行う。   |

Goldman Sachs（米国）は過去の株式投資に関わるデータを基に機械学習等のAIを用いて最適な取引を行うシステムを導入している。同社は2000年には600名のトレーダーを抱えていたが、AIの導入により日々の取引作業は200名のITエンジニアが運用する自動取引プログラムに置き換えられており、2名ま

※59  
各種公表情報より作成。

で減少<sup>60</sup>するなど自動化が急速に進んでいる。

Sentient Technologies（米国）は、大規模並列システムを用いて機械学習等のAIを稼働させる技術を開発するスタートアップ企業であり、投資管理を行う機能「Sentient Investment Management」や、視覚的に類似した商品のレコメンデーション等を行う機能「Sentient Aware」などを開発している。同社はJP Morgan Chase（米国）のヘッジファンド運用会社と共同で、株式取引データを基に銘柄指示や売買指示を自律的に行う取引アルゴリズムを開発し、運用している。

## (2)資産管理・運用

AIにより、自動的に資産管理・運用を行うサービスロボアドバイザー（Robo-Advisor）が提供されている。ロボアドバイザーは、投資家の資産状況や嗜好等を踏まえ、適切な株式投資や投資信託の選定、資産配分の提案を行う。ロボアドバイザーには、資金を投資家から預かり、預かった資金をAIで運用するサービスと、投資家が入力した情報と市況等のデータに基づき運用のアドバイスを行うサービスの2種類が存在する。資産管理・運用にAIを適用する取組例を表26に示す。

表26 資産管理・運用にAIを利用する取組例<sup>61</sup>

| 組織名          | 国  | 概要  |
|--------------|----|---|
| Betterment   | 米国 | Bettermentは資産運用と投資アドバイスの両サービスを提供する。詳細は本文を参照されたい。  |
| Wealthfront  | 米国 | Wealthfrontは投資目的、年齢、収入、家族、金融資産、リスク選考等に回答するだけで資産運用のポートフォリオやリスク許容度を診断する。リスク許容度等を変更した時の運用評価等も可能である。                                      |
| お金のデザイン      | 日本 | お金のデザインは五つの質問に答えるだけで86の国と地域における1万以上の海外上場投資信託から最適な資産運用のポートフォリオを診断するTHEOを運用している。THEOはポートフォリオの構築だけでなく、中長期的なポートフォリオのメンテナンスにより運用の効果を高めている。 |
| ソニー銀行        | 日本 | ソニー銀行は複数の貯蓄に関わる目標ごとに運用スタンスを選択し、それに合わせた資産管理を行うロボアドバイザー ほしいものナビ Betaを提供している。詳細は本文を参照されたい。   |
| 野村アセットマネジメント | 日本 | 野村アセットマネジメントは性別、年齢、リスク選考、収入等の7つの質問に回答するだけで最適な資産運用のポートフォリオを診断するFunds Roboを運用している。  |
| みずほ銀行        | 日本 | みずほ銀行は年齢、収入、金融知識、リスク選考等の簡単な質問に回答するだけで、最適な投資ポートフォリオを提案するSMART FOLIOを提供している。  |
| 三菱UFJ国際投信    | 日本 | 三菱UFJ国際投信は投資期間、リスク選考、運用パターンの嗜好等に関する5つの質問に回答するだけで資産運用のポートフォリオを提案するPORTSTARを提供している。   |
| 楽天証券         | 日本 | 楽天証券は年齢や収入など約15個の質問に回答するだけで最適な資産運用コースを提案する楽ラップを提供している。  |
| WealthNavi   | 日本 | WealthNaviは年代、収入、金融資産、運用目的、リスク選考等の6つの質問に回答するだけで資産運用のポートフォリオを提案するWealthNaviを提供している。詳細は本文を参照されたい。                                       |

※60

“As Goldman Embraces Automation, Even the Masters of the Universe Are Threatened,” MIT Technology Review Website <<https://www.technologyreview.com/s/603431/as-goldman-embraces-automation-even-the-masters-of-the-universe-are-threatened/>>

※61

各種公表情報より作成。

Betterment（米国）は、資産運用と投資アドバイスの両サービスを提供する。利用者はオンライン上で、年齢、収入、投資目的、リスク選考等のいくつかの質問に回答するだけで、運用方針や資産運用のポートフォリオを自動的に作成できる。2016年4月には、投資家から預かる資産が40億ドルを超える米国最大のロボアドバイザー事業者となった。同社はロボアドバイザーサービスをプラットフォームとして、退職までの収入・支出を試算して運用を支援する「RetireGuid」、独立系のアドバイザーが顧客の運用を支援する際のツール「Betterment Institutional」等のサービスの開発を進めている。

ソニー銀行は、ソニーコンピューターサイエンス研究所と共同で、多目標設定型の資産管理ロボアドバイザー「ほしいものナビ Beta」を開発し、2017年4月より提供している。ほしいものナビBetaでは、金融資産の投資比率を決定するポートフォリオ理論と制約充足問題の高度なロジックを組み合わせ、複数の資金需要に関してその金額を望まれる達成確度から最適ポートフォリオをアドバイスすることができる。

WealthNaviは年代、収入、金融資産、運用目的、リスク選考等の6つの質問に回答するだけで資産運用のポートフォリオを提案する「WealthNavi」を提供している。ポートフォリオに基づき発注から運用期間中のメンテナンスまで全てを自動で実行することができる。

### (3) 融資審査

融資業務における審査（Credit Scoring）にAIを利用する取組が進んでいる。これまでの審査では、支払履歴や借入残高等の金融関連情報を基に評価されてきたが、AIの利用によりSNSなど幅広い情報を対象に審査が行われるようになっていく。

Affirm（米国）はAIによる与信審査により、クレジットカードの代わりに独自の分割決済を可能とするサービスを提供している。同サービスは、氏名、電話番号、生年月日、社会保障番号（SSN）の下四桁<sup>62</sup>を入力するだけで、Affirmの支払方法に対応したEコマースサイト等で容易に分割決済を可能とする。2017年4月時点で、ホテルや航空券等のオンライン予約を行うExpedia（米国）、家庭用品を販売するEコマースサイトWayfair（米国）、寝具を販売するCasper（米国）など、10を超える企業が対応している。なお、Affirmの支払履歴は利用者の信用情報の構築を目的として、信用調査機関に提供される。

ZestFinance（米国）は機械学習により与信の審査を行う「Zest Automated Machine Learning：（ZAML）」を開発している。信用リスクのない消費者等のリスクを評価するために、個人の属性や買い物等に関わるデータを機械学習によりクレジットデータに変換し、履歴がない消費者にも融資を可能とする。

表27のように、海外のスタートアップ企業だけでなく我が国の金融機関等も融資審査へのAI活用を始めている。

---

※62

社会保障番号の下四桁は個人を識別するために利用される。

表27 融資審査にAIを利用する取組例<sup>63</sup>

| 組織名                 | 国     | 概要   |
|---------------------|-------|--|
| Affirm              | 米国    | AffirmはAIによる与信審査に基づき独自の分割決済を可能とするサービスを提供している。詳細は本文を参照されたい。   |
| Cape Analytics      | 米国    | Cape AnalyticsはAIにより航空画像や衛星画像から不動産の資産査定を支援するサービスを提供している。具体的には、航空画像等から屋根の形状・素材・状態、土地面積、太陽光パネルの設置状況などを認識して抽出する。  |
| Earnest             | 米国    | EarnestはAIにより優秀な学生や学生の両親などに対して審査を行い、低金利でのローンを提供する。具体的には、学歴(学位や大学名等)、両親の雇用状況、金融資産等の情報を基に、学生や両親へのローンを提供している。   |
| Mirador             | ポーランド | MiradorはAIによるローン審査のためのクラウドプラットフォームを提供している。機械学習を用いてリスク等を評価し、中小企業に融資を行う金融機関等を支援することができ、信用報告書、事業信用報告書、納税申告書、ソーシャルメディア、顧客レビュー、銀行取引及び事業財務を含む多様なデータを対象とすることで、金融機関の伝統的なリスク評価とは異なる観点で借り手を評価している。 |
| Tala                | 米国    | Talaは発展途上国の起業家を対象としたマイクロファイナンスの審査にAIを利用している。申請者のスマートフォン上の支払履歴や移動履歴などを利用し、金融機関との取引履歴など信用情報がない場合でも評価することができる。  |
| Zest Finance        | 米国    | Zest Financeは機械学習により与信の審査を行い、信用リスクのない消費者に対して融資を行っている。詳細は本文を参照されたい。   |
| 住信SBIネット銀行<br>日立製作所 | 日本    | 住信SBIネット銀行と日立製作所は顧客の年齢、収入、口座情報、入出金履歴などの従前より審査に利用されてきたデータに加え、地域別の経済指標や各種データの時系列変化を日立製作所のAI技術Hitachi AI Technology/Hで分析し、AIによる融資可能額を算出する取組を始めている。  |
| 東京センチュリー            | 日本    | 東京センチュリーはAIによるインドネシアの消費者向けの融資サービスを開発している。具体的には、消費者のスマートフォンを介してインターネット通販の利用状況、支払履歴、購入商品などの履歴、SNSの投稿データの分析による仕事や友人関係を把握し、AIによりこれらのデータから個人の信用力を算出する取組を試みる。                                  |
| みずほ銀行<br>ソフトバンク     | 日本    | みずほ銀行とソフトバンクは個人向けにAIを用いた融資を行う合弁会社J.Scoreを設立している。みずほ銀行とソフトバンクが保有するビッグデータを組み合わせ、AIによる分析を行うことで審査応諾範囲の拡大、競争力のある金利水準の実現を目指している。   |

#### (4)セキュリティ・詐欺特定

取引、資産管理・運用、融資審査等へのAIの利用やモバイルペイメントなど決済に代表されるFinTechの進展により、金融分野におけるサイバーセキュリティの重要性は高まっている。金融機関が提供するサービスでは、個人認証に暗証番号やワンタイムパスワード等が利用されてきたが、表28のように、AIの進歩により音声や顔などによる生体認証の利用が始まっている。

ANZ（オーストラリア）はモバイル向けのバンキングプラットフォームのセキュリティを強化するために、Nuance Technology（米国）と連携して音声によるバイオメトリクス認証の検証を始めている。今後、同社のバンキングアプリ「ANZ goMoney」に音声認証の機能を搭載し、ほかのデジタルサービスへも展開する計画である。

※63  
各種公表情報より作成。

Barclays（英国）は事前登録した顧客の音声を認識し、個人認証を行う仕組みを全顧客向けに提供している。顧客の口と喉の物理的特性に基づく100以上のパラメータにより、個人を認識する。従前のパスワード以上に高いセキュリティを有し、パスワード忘れ等によるトラブル等も防ぐことができる。

Master Card（米国）は、AIにより詐欺検出等を支援するシステム「Decision Intelligence」を導入している。顧客の過去の消費パターンを分析し、リアルタイムで異常な消費動向かどうかを判別する。顧客価値セグメンテーション、リスクプロファイル、購入場所、加盟店、デバイスデータ、購入時刻、取引の種類などの多様なデータを活用して詐欺の誤検出を抑制する。Decision Intelligenceの目的は詐欺ではない通常の取引の承認率を高めることである。

表28 セキュリティ・詐欺特定にAIを利用する取組例<sup>64</sup>

| 組織名             | 国       | 概要  |
|-----------------|---------|---|
| ANZ             | オーストラリア | ANZはNuance Technology（米国）と連携して音声によるバイOMETRICS認証の検証を進めている。詳細は本文を参照されたい。  |
| Barclays        | 英国      | Barclaysは顧客の音声に基づき個人認証を行う仕組みを提供している。詳細は本文を参照されたい。   |
| Biocatch        | 米国      | Biocatchは機械学習を用いてオンライン上での振り舞い（行動）をモデル化し、本人以外のアクセスや行動を自動的にリアルタイムで検出するサービスを開発している。このサービスは、不正行為の特定、支払・取引の自動停止等を支援することができ、大手の金融機関での採用が始まっている。   |
| Feedzai         | 米国      | Feedzaiは機械学習により過去の取引データと詐欺被害のデータから決済や取引の詐欺リスクを検出し、支払を停止できるサービスを提供している。  |
| Sift Science    | 米国      | Sift Scienceは電子商取引における詐欺防止のために、機械学習により顧客のサイトトラフィックを監視し、リアルタイムで詐欺行為をモニタリングするサービスを提供している。同サービスでは、不正アカウント、支払詐欺、コンテンツの不正利用、宣伝における等の様々な不正を特定することができる。  |
| Master Card     | 米国      | Master CardはAIにより詐欺検出等を支援するシステムDecision Intelligenceを導入している。詳細は本文を参照されたい。   |
| 三井住友フィナンシャルグループ | 日本      | 三井住友フィナンシャルグループはディープラーニングによりクレジットカード利用の不正検知の検証を行い、検知精度を飛躍的に高めている。利用場所、時間、金額などの人間が設定したパラメータに基づき「正常利用」、「不正利用の懸念有り」、「不正利用」の3段階に判別していたが、ディープラーニングを用いて利用履歴、利用金額、利用場所、店舗属性等から生成した学習済みモデルにより懸念有りの誤検知率が95%から5%に減少したという。 |

### 2.2.3.10 物流

自動走行技術を用いた自動輸送・配送や、AIを用いた倉庫作業の改善などが進められている。前者については、主に高速道路における隊列走行など、長距離輸送を自動化する取組として国内外で活発に研究開発が行われている。後者については、倉庫作業者の支援から始まり、先端的な取組としては知的なピッキングロボットや人と共同するロボットの適用が進んでいる。

#### (1) 調達物流

調達物流等の長距離輸送等の物流現場では、ドライバーの不足、物流コストの上昇、安全性向上、環境負荷低減等を目的として、2台目以降を無人化する隊列走行の導入に期待が集まっている。また、海上を

※64  
各種公表情報より作成。

利用した輸送にAIを利用することで、航行を高度化・自動化する取組も検討されている。調達物流にAIを適用する取組例を表29に示す。

ヤマト運輸は豊田通商などと共同で、東京・名古屋・大阪の幹線区間におけるトラックの無人隊列走行の実用化を進めている。2022年を目標に実用化を進め、技術面に加えて連結台数、車間距離、運転免許制度等の制度面での検討を行うとしている。隊列走行によりドライバー1人当たりの輸送量を向上させ、ドライバー不足の解消や幹線輸送の効率化を狙う。

商船三井は2022年をめどに、衝突を自動回避するシステムを船舶に搭載する。AIが衝突可能性のある他船や障害物を画像で識別し、速度の減速や方向転換を行う。これにより、船員の負担を軽減しつつ、航行の安全性を高めることを狙う。

表29 調達物流にAIを利用する取組例<sup>65</sup>

| 組織名                 | 国   | 概要  |
|---------------------|-----|---|
| ClearMetal          | 米国  | ClearMetalはAIによりコンテナ需要を予測し、船舶の稼働率や輸送効率を向上させる資産管理システムを開発している。具体的には天候や貿易レートなど17の外部データを取得し、まだ予約されていない出荷、顧客のキャンセルや変更等を予測することができる。   |
| DHL                 | ドイツ | DHLはAIにより小包に記載された宛先等の情報から企業宛か個人宛かを判別する技術を開発し、在宅率の高い夕方以降に個人宛の小包を配達するなど効率的な配送計画の立案に応用する。  |
| RollsRoyce Holdings | 英国  | RollsRoyce HoldingsはAIによる自動航行と陸からの遠隔操作を組み合わせたハイブリッド型の操船システムを開発している。多数の船舶が混在し、航路のない湾内等の自動航行による危険性が生じる場合はオペレータが陸から遠隔で操船する。EUが支援する研究開発プロジェクトMUNIN (Maritime Unmanned Navigation through Intelligence in Networks)の取組の一つとして進められている。 |
| 商船三井                | 日本  | 商船三井はAIにより衝突を自動回避するシステムを船舶に搭載する計画を発表している。詳細は本文を参照されたい。  |
| 新日鉄住金               | 日本  | 新日鉄住金はAIにより製鉄所間の配船の最適化に取り組んでいる。製品や原料に関わる輸送船の運航情報をリアルタイムで見える化し、AIによる予測等も踏まえて最適な輸送条件を決定する。  |
| ヤマト運輸               | 日本  | ヤマト運輸は高速道路においてトラックの2台目以降を無人化する隊列走行の開発を進めている。詳細は本文を参照されたい。   |

## (2) 拠点内物流

拠点内や倉庫内で、AIとロボットを組み合わせた物流業務の自動化が進みつつある。また、ウェアラブル端末や各種センサ等により、作業動線や業務のデータの自動入手・分析をAIが担い、作業員の業務効率化や物流業務の生産性向上も進められている。拠点内物流にAIを適用する取組例を表30に示す。

Amazonは、ロボカップの技術を応用して、自律分散制御型の倉庫内物流システムを開発するスタートアップ企業Kiva Systems (現Amazon Robotics<sup>66</sup>、米国)を2012年に買収し、子会社とした。Kiva Systemsが開発する倉庫内物流システムは、商品をピックアップして出荷作業を進める従業員の下に商品が載った棚を運び、Amazonが効率的に顧客に商品を出荷するための重要な役割を担っている。2015年末時点で3万台を超えるロボットが導入され、その導入効果により各倉庫で20%以上のコストカット、面積当たりの在庫量の50%増を実現するなど、非常に大きな効果を発揮している。

※65  
各種公表情報より作成。

※66  
2015年に社名を変更。

表30 拠点内物流にAIを利用する取組例<sup>67</sup>

| 組織名            | 国  | 概要  |
|----------------|----|---|
| Amazon         | 米国 | AmazonはKiva Systemsの買収により倉庫内の出荷作業を支援するロボットを導入し、業務効率化を図っている。詳細は本文を参照されたい。  |
| Fetch Robotics | 米国 | Fetch Roboticsは商業及び産業環境で安全に動作する自律移動ロボットを開発している。同社が開発する倉庫内の材料輸送ロボットVirtual Conveyorは、作業員やフォークリフトなどの移動車を認識し、事故のないように最適な障害物回避を行うことができる。  |
| 日立物流           | 日本 | 日立物流は棚ごと自動で搬送する小型・低床式無人搬送車Racrewを提供している。部品や商品が保管されている棚を、棚ごと指定位置まで自動搬送することで作業員が自ら棚に取りに行く場合と比べて生産性向上を図る。また、利用頻度の高い部品や部品を積載した棚を短い搬送時間で済む位置に配置したり、混雑しない搬送ルートを選択したりするなど、搬送効率を改善させる機能も搭載している。                                     |
| Doog           | 日本 | Doogは屋内外で利用可能な追従運搬ロボットサウザー (THOUZER) を開発している。サウザーはレーザーレーダーを搭載し、人、台車、前方のサウザーを追従したり、再帰反射素材のテープ等でラインを作ることで自律移動したりできる。  |
| GROUND         | 日本 | GROUNDは物流にロボットやAI等の最新技術を融合させ、入荷から出荷に至る物流オペレーションの生産性向上を支援するソリューションの開発を進めている。同社はクラウド型入荷管理ソフトウェア・コラボレーションウェアDigital Inbound Squareを開発・提供するほか、GreyOrange (インド) と業務提携し、GreyOrangeが開発する自動搬送ロボットButlerを活用した倉庫内の物流支援ソリューションを提供している。 |
| ZMP            | 日本 | ZMPは自動で追従するカルガモ機能を備えた物流支援ロボットCarriRoを開発している。CarriRoはビーコンに反応し、作業員や前方のCarriRoに追従する機能を搭載しているほか、指定したエリアにおける経路を設定することで自律的に移動し、モノを運ぶ機能を搭載する予定である。   |

### (3) 販売物流

卸売や店舗などへの配送や購入者への直送個別配送にAIを利用し、荷物データやトラックの走行データ、道路情報等を統合的に分析して効率的な配送を行う取組が進んでいる。また、ラストワンマイルの配達を行うために、ドローンの活用や自動集配車の利用も試行されている。販売物流にAIを適用する取組例を表31に示す。

アスクルは、AIを用いて顧客が便利に荷物を受け取るためのサービス「Happy On Time」を提供している。顧客が指定した受取可能な時間範囲に対して、到着時間を30分単位で知らせるほか、到着10分前にも通知を行うことで、受け取り率を高めている。背景には、トラックの移動時間などから配達予定時間を自動で割り出すAIの機能がある。アスクルのAIは、実績を積むたびに学習し、配達時刻の予測精度を高めることができる。

楽天は、ドローンを利用して配送を行うプロジェクト「そら楽」を推進している。第一弾として、ゴルフ場コース内でゴルフ用品、軽食、飲料等を注文すると受取所まで自律的に配送するサービスを提供している。離陸から着陸して荷物を降ろし、帰還するまでの全てプロセスを自動で行い、着陸には画像認識技術を利用する。

ZMPは倉庫内物流システムCarriRo (表30参照) を発展させ、屋外での配達を可能とする「CarriRo Delivery」を開発している。同社は自律走行技術などを利用し、ラストワンマイルでの配達を支援するソリューションの提供を目指している。なお、2017年5月より実証実験のパートナーを募集し、サービス開始に向けた課題抽出や有効性等の検証を進めることが発表されている。

※67  
各種公表情報より作成。

表31 販売物流にAIを利用する取組例<sup>※68</sup>

| 組織名                   | 国    | 概要  |
|-----------------------|------|---|
| Piaggio Fast Forward  | イタリア | Piaggio Fast Forwardはユーザを追従するロボットカーゴGitaを開発している。Gitaは走行しながら自分の位置と周囲の3次元データを取得し、自律走行できるように学習するため、一度学習させれば追従せずに自律的に走行するAutonomousモードでの動作も可能である。センサから得られたリアルタイムのデータが過去に学んだ3次元地理空間情報との差異を検出し回避行動を取ることがきる。 |
| Starship Technologies | 英国   | Starship Technologiesは9台のカメラなどセンサを搭載し、歩道を自動走行して配送を行うロボットを提供している。搭載したセンサにより周囲を監視し、障害物や歩行者を回避して自律走行を行う。通常時は自律走行を行うが、遠隔監視がなされており、緊急時等にはオペレータによる遠隔操作が行われる。  |
| Marble                | 米国   | Marbleは都市内の配送を行う宅配ロボットの開発を行っている。ロボットは高精度のカメラや超音波センサを搭載し都市部における3次元地図に基づき自律的に歩道を走行し、配送を行うことができる。食料品、雑貨、薬剤等幅広い商品を対象としている。  |
| アスクル                  | 日本   | アスクルはAIを用いて顧客の荷物受取を高度化するHappy On Timeを提供している。詳細は本文を参照されたい。  |
| 楽天                    | 日本   | 楽天はドローンを活用した配送サービス そら楽を提供している。詳細は本文を参照されたい。   |
| ZMP                   | 日本   | ZMPは屋外での配達を可能とするCarriRo Deliveryの開発を進めている。同社は自律走行技術などを利用し、ラストワンマイルでの配達を支援するソリューションの提供を目指している。詳細は本文を参照されたい。  |

### 2.2.3.11 その他

AIの応用先は幅広く、これまでに紹介した以外の領域でも活用が進んでいる。ここでは米国などの海外を中心に利用が進む法律（リーガル）におけるAIの利用事例を紹介する。

Ross Intelligence（米国）は、法律に関わる質問を自然言語処理とAIにより理解し、回答する仕組みを提供している。例えば、「債務者がいつ米国の破産法規に基づく団体交渉協定を拒否することができるのか。」といった複雑な文章から意図を読み取り、適切に回答することができる。弁護士事務所等への導入が進んでおり、同社のサービスを導入することで、これまで弁護士が調査に費やしていた時間を短縮でき、生産性を高めることができる。

弁護士ドットコムは、IBMのWatsonを利用して、企業内の法務相談業務を支援するシステムを開発している。企業の従業員が自然言語で法務関連の相談を入力すると、膨大な判例・法令データベースから適切な回答を探し出して応じるほか、各企業の方針や業界に適した法的アドバイスを行うこともでき、法務部門の業務効率化につなげることができる。

※68  
各種公表情報より作成。

## 2.3 基盤整備状況

本節では、人工知能（AI）の利用を支える基盤整備状況として、人材、計算資源、標準化、オープンソースソフトウェア（OSS）、共有データセット・共有モデルについて述べる。

### 2.3.1 人材

#### 2.3.1.1 人材獲得競争の現状

大手IT企業、製造業、スタートアップ企業の間で人材獲得競争が激化し、人材需給のバランスや給与水準に影響を及ぼしつつある。

人材獲得の一つの方法は企業のM&Aである。AIへの期待の高まりに応じてAI技術を有するスタートアップ企業のM&Aが急増し、M&Aされた企業数は、2011年（年間6社）から2016年（同36社）へと6倍<sup>1</sup>に増加している。これらのスタートアップ企業のM&Aを主導しているのは、表32のとおりIT企業である。

■表32 IT企業によるAI技術を有するスタートアップ企業の買収数<sup>2</sup>

| 順位 | 企業名                      | 買収数 |
|----|--------------------------|-----|
| 1  | Google <sup>3</sup> (米国) | 13社 |
| 2  | Intel (米国)               | 6社  |
| 2  | Apple (米国)               | 6社  |
| 4  | Twitter (米国)             | 5社  |
| 5  | eBay (米国)                | 4社  |
| 5  | AOL (米国)                 | 4社  |
| 7  | Microsoft (米国)           | 3社  |
| 7  | IBM (米国)                 | 3社  |
| 7  | Yahoo! (米国)              | 3社  |
| 7  | Salesforce (米国)          | 3社  |

また、M&Aを進める企業は、IT企業だけではない。GEやSamsung（韓国）、Ford（米国）等の製造業を中心とした企業もAI技術を有するスタートアップ企業のM&Aを進めている。

GEは2016年11月に、Industrial IoTで接続された機器やデバイスのデータの統合、解析、予測、自動化を行うプラットフォームを提供するBit Stew Systems（カナダ）と、機械学習により膨大なデータからパターンや傾向を探索するソリューションを開発するWise.io（米国）を買収している。

※1  
“Exit Activity by Year in Artificial Intelligence,” Venture Scanner Website <<https://venturescannerinsights.wordpress.com/category/artificial-intelligence-2/>>

※2  
“The Race For AI: Google, Twitter, Intel, Apple In A Rush To Grab Artificial Intelligence Startups,” CB Insights Website <https://www.cbinsights.com/blog/top-acquirers-ai-startups-ma-timeline/>より作成

※3  
Google DeepMindによるM&Aも含む。

Fordは2016年8月に、ディープラーニングに基づくアルゴリズムの設計、開発、実装を行うSAIPS（イスラエル）を、2017年2月に自律走行車のための機械学習ソフトウェアを開発するArgo AI（米国）を買収している。

また、米国等の海外を中心に大学等の研究者を採用する動きや、企業間での人材の流動化も進んでいる。Fordはシリコンバレーに新たに開発拠点を設置して、260名の人材を確保・採用している。タクシーの配車を手掛けるUberは2015年にカーネギーメロン大学のナショナル・ロボティクス・エンジニアリング・センターで働く140人のスタッフのうち40人の研究者や科学者を引き抜き<sup>4</sup>、自動走行を研究する部門を立ち上げている。

このように企業による人材獲得の取組は加速し、市場からの供給を超える需要が生じる可能性がある。米国の求人情報ウェブサイトIndeedにおける先端技術に関わる求人件数の推移<sup>5,6</sup>をみると、AI・機械学習、IoTに関わる求人は、ほかの先端技術と比較して求人数が多く、また増加傾向にある。具体的には、米国の求人情報全体に占めるAI・機械学習の割合が2016年6月以降飛躍的に増加し、2017年1月には2014年1月の2倍近くに達している。

こうした需要の高まりに応じて人材に対する給与も高い水準が提示されるようになっている。英国、米国、日本の3カ国の給与水準をみると、図6のとおり、ソフトウェアエンジニアと比較してそれぞれ3割程度高い給与水準となっている。特に、米国の給与は他国と比較して非常に高い水準で、約1,500万円の給与が提示されている。その額は、日本のAI人材に提示されている約650万円の2倍以上の金額である。グローバルな人材獲得競争は今後も激化すると想定される中、報酬という観点では、米国水準の人材投資ができない企業はグローバルな人材獲得競争で後塵を拝するおそれがある。

また、大手企業のAI研究開発拠点やスタートアップ企業の拠点となるシリコンバレー（サンフランシスコ）における給与の中央値は約1,640万円と、米国全体の約1,490万円より150万円近く高く、2,820万円を超える水準での求人も行われている<sup>7</sup>。

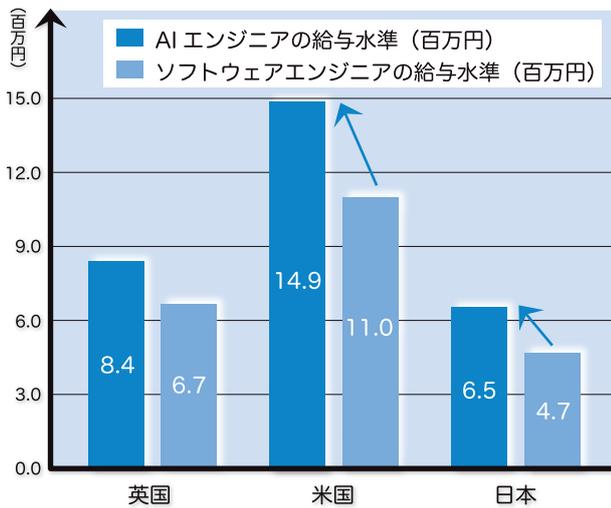
---

※4  
「Uberに人材流出、揺れるカーネギーメロン大学」 The Wall Street Journal <<http://jp.wsj.com/articles/SB12759595096617873597504581020681775312842>>

※5  
“Innovators wanted: Machine learning, IoT jobs on the rise,” InfoWorld Website <<http://www.infoworld.com/article/3155251/it-careers/innovators-wanted-machine-learning-iot-jobs-on-the-rise.html>>

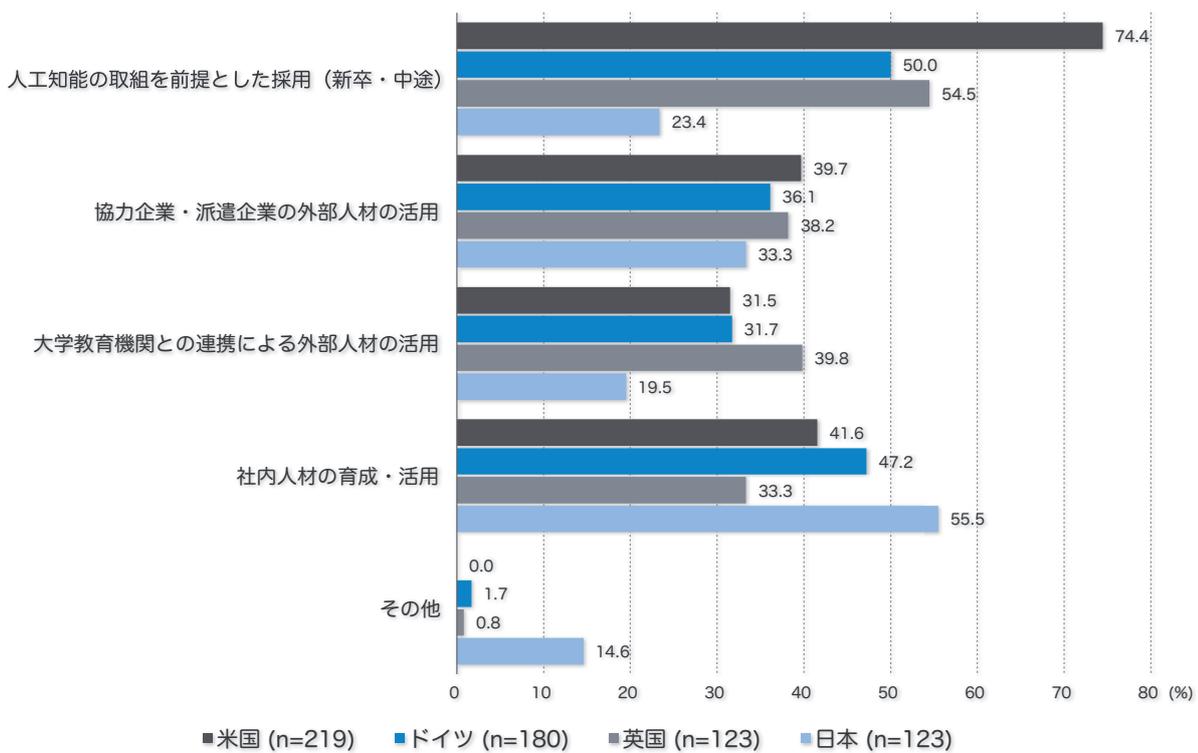
※6  
“Machine Learning Job Trends,” Indeed Website <<https://www.indeed.com/jobtrends/q-Machine-Learning.html>>

※7  
“Machine Learning Engineer Salaries in San Francisco, CA,” Indeed Website <<https://www.indeed.com/salaries/Machine-Learning-Engineer-Salaries,-San-Francisco-CA>>



■図6 AIに関わるエンジニアの給与<sup>8, 9</sup>

国内企業に対するアンケート調査及び海外ウェブアンケート調査（調査概要は2.4.1項を参照）によると、企業内でAIの取組を推進する人材の確保・育成について、図7のとおり米国、ドイツ、英国は、採用あるいは外部企業や大学等の人材活用を進めている一方で、我が国では社内人材の教育・研修が中心となっている。



■図7 人材育成・確保の状況

※8  
下記の公開情報をもとに作成。「平均年収ランキング2016」DODAウェブサイト<<https://doda.jp/guide/heikin/>>;「AI人材の求人、平均年収は約651万円となり社会人の平均を大きく上回る。最も需要が高いプログラミング言語は「Python」」ディップウェブサイト<<http://www.dip-net.co.jp/news/press-release/2016/11/ai651.html>>; “Software Engineer Salaries in the United States,” Indeed Website<<https://www.indeed.com/salaries/Software-Engineer-Salaries>>; Machine Learning Engineer Salaries in the United States,” Indeed Website<<https://www.indeed.com/salaries/Machine-Learning-Engineer-Salaries>>;

“Software Engineering jobs, average salaries and trends for Software Engineering skills,”<<https://www.itjobswatch.co.uk/jobs/uk/software%20engineering.do>>; “Machine Learning jobs, average salaries and trends for Machine Learning skills,”<<https://www.itjobswatch.co.uk/jobs/uk/machine%20learning.do>>

※9  
米国は中央値を参照し、1ドル110円で換算。英国は平均値を参照し、1ポンド140円で換算。

また、我が国の大手IT企業では、社内に点在するAI技術等に知見を持つ人材を配置転換し、体制強化を進める動きが見られる。

- 富士通<sup>10</sup>  
AI事業の推進組織として「AI活用コンサルティング部」を新設し、研究者や技術者等、200名を配置し、2016年10月には人員を3.5倍に拡大する計画を発表している。
- NEC<sup>11</sup>  
AI関連事業・ソリューション展開の強化を進めている。2020年度までにAI関連要員を約1,000人に増強し、AI関連事業で売上累計2,500億円を目指している。
- NTTデータ<sup>12</sup>  
データ分析、AI、組込みソフトウェアなどに強みを持つ人員を集約し、顧客のAIやIoTの活用を支援する専門組織「AI&IoTビジネス部」を2017年3月1日に設置している。設立時点で合計1,700名の人材を抱え、うちコンサルタントやデータ分析を専門とする技術者等が200名、組込みソフトの技術者が1,500名である。

また、社内人材の育成・活用による人材確保の限界もあることから、AIを専門とする人材を外部から採用・獲得する動きも始まっている。国内の先行する企業は、従来の給与とは異なる枠組みの整備等を行うほか、国内のみならず、海外からの人材採用を進める企業も見られる。

- ソニー<sup>13</sup>  
2017年春の新卒採用にAI研究者専用の採用枠を設置し、AI専門の研究者の募集を進めている。
- トヨタ自動車<sup>14</sup>  
2016年1月に米シリコンバレーに「TOYOTA RESEARCH INSTITUTE (TRI)」を設立し、今後5年間で約10億ドルの投入を予定している。同研究所には、DARPAのプログラムマネージャーのギル・プラット (Gill Pratt) 氏が就任している。2017年1月までに100名以上がTRIに参画し、2017年には更に100名程度の新規メンバーが参画する予定<sup>15</sup>である。また、同社は自動走行技術に関するキャリア採用特設サイトを設置<sup>16</sup>し、国内での技術者の採用を積極的に進めている。

---

※10  
「当社が培ったAI技術を「Human Centric AI Zinrai」として体系化」  
富士通ウェブサイト <<http://pr.fujitsu.com/jp/news/2015/11/2.html>>

※11  
「NEC、AI(人工知能)関連事業を強化」 NECウェブサイト <[http://jpn.nec.com/press/201511/20151111\\_01.html](http://jpn.nec.com/press/201511/20151111_01.html)>

※12  
「[AI&IoTビジネス部] の設置について」 NTTデータウェブサイト  
<<http://www.nttdata.com/jp/ja/news/release/2017/030101.html>>

※13  
AI人材、電機も食指 ソニーは新卒採用に専門枠」 日本経済新聞  
2016年6月10日朝刊

※14  
「新会社「TOYOTA RESEARCH INSTITUTE, INC.」設立に関する記者会見」 トヨタ自動車ウェブサイト <<http://newsroom.toyota.co.jp/en/detail/10143272>>

※15  
「トヨタ・リサーチ・インスティテュート ギル・プラットCEOスピーチ参考抄訳(CESプレスカンファレンス)」 トヨタ自動車ウェブサイト <<http://newsroom.toyota.co.jp/en/detail/14644735>>

※16  
「トヨタ自動車 自動運転技術 キャリア採用特設サイト」 トヨタ自動車ウェブサイト <[http://www.toyota-careers.com/automated\\_driving/index.html?padid=ag454\\_crs-170519\\_top\\_to\\_top-bnr](http://www.toyota-careers.com/automated_driving/index.html?padid=ag454_crs-170519_top_to_top-bnr)>

- 日立製作所<sup>17</sup>

米国のカリフォルニア州サンタクララにIoTの基盤技術の開発拠点となるサービス&プラットフォームビジネスユニットのグローバルヘッドクォーターを設置し、2017年3月末までに現地でAIの技術者ら100人を採用する計画を発表している。日本からも100人を送り込み、200人の研究体制とする予定としている。

- 本田技研工業<sup>18</sup>

2016年9月に知能化技術の研究開発を行う新拠点「Honda イノベーションラボ Tokyo」を開設した。新たな人材を幅広く集め、知能化研究開発を行い、当面は数十人を新規採用し、百数十人規模で研究開発を行う計画である。また、優秀な人材確保のために、プロジェクトの掛け持ちを許容するなど柔軟な働き方を採用するだけでなく、同社の給与体系とは違った待遇の検討を進めている<sup>19</sup>。

- 楽天<sup>20</sup>

米国ボストンに、ディープラーニングを含めたAI分野の研究開発拠点を新設。Eコマース企業のチーフサイエンティストであったアンカー・ダッタ（Ankur Datta）氏が研究を主導する。

- リクルートホールディングス<sup>21</sup>

2015年11月4日、AIのグローバル研究開発拠点をシリコンバレーに新設し、トップにはGoogle Research出身でデータマネジメントの著名な研究者であるアロン・ハーヴェイ（Alon Halevy）氏を起用している。

### 2.3.1.2 人材の供給状況

経済産業省は、ビッグデータ、IoT、AIに携わる人材を先端IT人材とした上で、その人材数と不足数を推計<sup>22</sup>している。その結果によれば、2016年の人材数は、約9.7万人、需給ギャップに相当する不足数は1.5万人規模であり、2020年には人材不足数が4.8万人規模に拡大すると推計されている。人工知能戦略会議人材育成TFでは、AIに係る人材の輩出を担う大学における人材養成規模を、AIに関係する研究科・専攻等を対象に修了者数等を基に、暫定的に試算している。

その報告によれば、修士課程は約870名、博士課程は約160名の年間養成規模と試算<sup>23</sup>されている。現在のAIに関わる人材の不足状況を踏まえると、この試算による年間養成規模による人材供給で、現在の需

---

※17

「デジタルソリューション事業の拡大に向けたIoTプラットフォームの開発・構築を強化」日立製作所ウェブサイト <<http://www.hitachi.co.jp/New/cnews/month/2016/04/0414.html>>

※18

「知能化技術研究開発を強化 ～知能化技術の研究開発を行う新拠点「HondaイノベーションラボTokyo」を開設～」本田技研工業ウェブサイト <<http://www.honda.co.jp/news/2016/c160602a.html>>

※19

「ホンダ、AI技術開発を東京・赤坂に集約へ、商品への反映を加速」Bloombergウェブサイト <<https://www.bloomberg.co.jp/news/articles/2016-10-31/OFLMKN6S972B01>>

※20

「楽天、技術研究所をシンガポール及び米国ボストンに開設」楽天ウェブサイト <[https://corp.rakuten.co.jp/news/press/2015/0729\\_02.html](https://corp.rakuten.co.jp/news/press/2015/0729_02.html)>

※21

「Google Research出身でデータマネジメントと人工知能の世界的権威、Alon HalevyがリクルートのAI研究所（RIT：Recruit Institute of Technology）トップに就任。研究本拠も米国シリコンバレーへ。」リクルートホールディングスウェブサイト <[http://www.recruit.jp/news\\_data/release/2015/1104\\_16315.html](http://www.recruit.jp/news_data/release/2015/1104_16315.html)>

※22

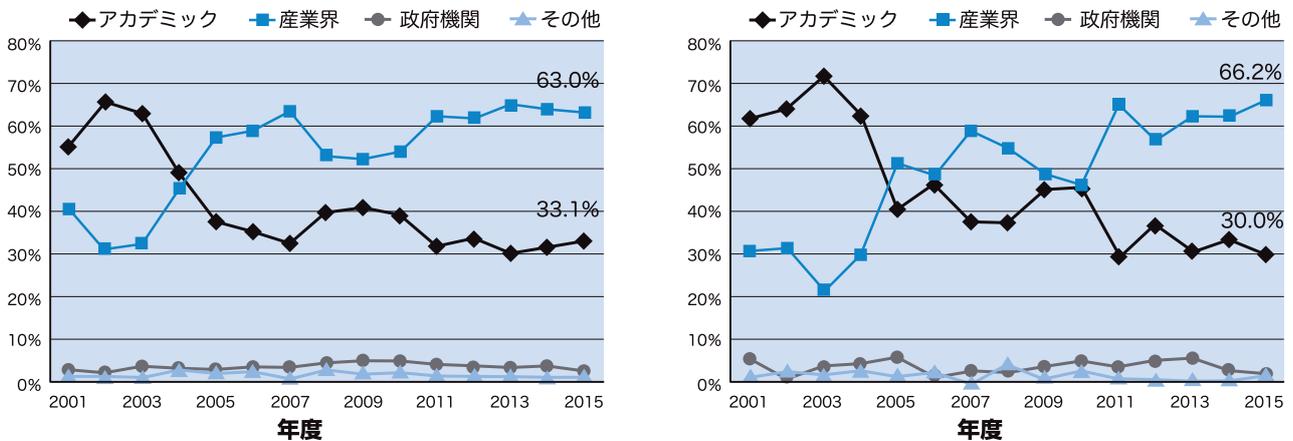
「IT人材の最新動向と将来推計に関する調査結果」経済産業省ウェブサイト <<http://www.meti.go.jp/press/2016/06/20160610002/20160610002.html>>

※23

「人材育成タスクフォース最終取りまとめ」参考資料1 各TF補足資料 新エネルギー・産業技術総合開発機構 人工知能技術戦略会議（第5回）ウェブサイト <<http://www.nedo.go.jp/content/100862415.pdf>>

給ギャップを解消することが難しいと予想され、AIに関わる人材育成の一層の拡充・強化が必要である。

なお、Computing Research Association (CRA) <sup>24</sup>の調査によると、北米（米国・カナダ）における情報系の学位取得者は1,500名であり、AI関連の学位取得者（実数）はそのうち226名である。また、**図8**のとおりAI関連の学位取得者のうち66.2%強の139名が産業界に就職している。



■図8 北米における博士号取得者の就職先<sup>25, 26</sup> (左：情報系学位全体<sup>27</sup>、右：人工知能関連学位)

### 2.3.1.3 人材の育成に関わる動向

#### (1) 産業界と教育機関との連携による人材育成

産業界におけるAIに関わる人材育成の重要性の認識の高まりから、企業と大学等が連携して人材育成を図る取組が実施されている。

- 先端人工知能学教育寄附講座（東京大学、企業8社）

ディープラーニングを含む先端AI技術と、その理論基盤に関する体系的教育プログラムの構築・実施による人材育成を目的として、2016年6月に開設された。2021年5月までの5年間の活動を予定している。トヨタ自動車、ドワンゴ、オムロン、パナソニック、野村総合研究所、DeNA、みずほフィナンシャルグループ、三菱重工業の計8社から合計9億円の寄付により実現した。約50人の大学院生に対して先端AI技術に関する高度な教育を行っている。

- 人工知能共同講座（大阪大学、パナソニック）

AI技術を研究開発やビジネスに活用できる人材を、座学+実プロジェクトによる実学で創出することを旨とした人工知能共同講座を、2016年6月から開始している。まず、試行カリキュラムとして、データマイニング基礎講座及び機械学習基礎講座を、パナソニック内の人工知能研修施設にて、同社の技術者向けに実施している。また、2017年4月からは、大阪大学の学生や本取組に賛同するほかの企業や大学に対しても、カリキュラムを提供する予定である。また、実証実験を通じた、データ利活用における技術課題・社会課題の解決を目指したデータ利活用基盤の構築を共同で実施している。

※24  
“Taulbee Survey,” Computer Research Association Website  
<<http://cra.org/resources/taulbee-survey/>>

※25  
“Taulbee Survey,” Computer Research Association Website  
<<http://cra.org/resources/taulbee-survey/>>より作成。

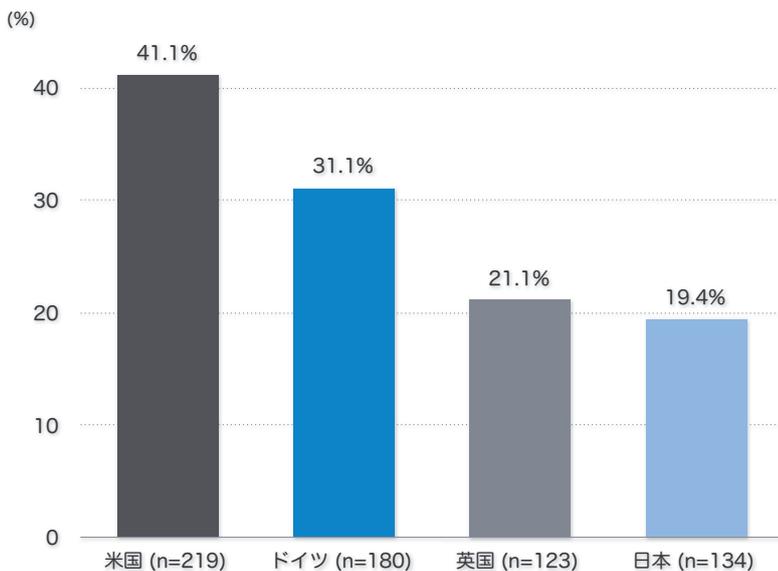
※26  
北米で博士号を取得した学生のうち、北米以外で就職した学生を除く。

※27  
人工知能関連学位を含む。

世界的にAIの研究で先行する大学においても、企業と大学等が連携して人材育成を図る取組が実施されている。

- AIアフィリエイトプログラム（スタンフォード人工知能研究所+企業5社）  
スタンフォード大学内にあるスタンフォード人工知能研究所（SAIL）では、企業がAIに効果的に取り組むための「AIアフィリエイトプログラム」を設置している。このプログラムの参加企業はSAILの全研修・セミナーへの招待、研究トピックの議論のための訪問、客員研究員の育成、学生募集といった機会が与えられる。パナソニック、UST Global（米国）、Tencent（中国）、Samsung（韓国）、Didi（中国）の5社が参加している。
- CSAILアライアンスプログラム（MITコンピュータ科学人工知能研究所）  
マサチューセッツ工科大学（MIT）のコンピュータ科学人工知能研究所（CSAIL）では、企業が同研究所との連携を図るためのCSAILアライアンスプログラムを設置している。このプログラムの参加企業は同研究所の様々な資源にアクセスでき、プロフェッショナル向けの教育コースの受講もその中に含まれている。Google（米国）、Microsoft（米国）、Salesforce（米国）、SAP（ドイツ）、Tencent（中国）、Samsung（韓国）等30以上の企業が参加している。日本からはNECが参加している。

国内企業に対するアンケート調査及び海外ウェブアンケート調査によると、社内の人材を育成するために社外連携している企業は、図9のとおり、米国では40%以上となっている一方、我が国では米国の半数以下の割合にとどまる。今後、AIに係る人材育成において大学等、外部機関との連携強化が求められると考えられる。



■ 図9 社内の人材を育成するために社外連携している企業の割合

## (2)遠隔教育による人材育成

大規模オンライン大学講座として知られている「MOOCs」(Massive Open Online Courses)の初期の実施例として、2011年にスタンフォード大学が試験的に実施した「人工知能入門 (Introduction to AI)」は、世界190カ国から10万人以上の受講者を集め、その後のMOOCs推進の大きなきっかけとなったといわれている。同講座を担当したセバスチアン・スラン (Sebastian Thrun、Googleで画像認識(「猫」の抽出)や自動走行の研究にも参画)氏は、その後MOOCsの有力プラットフォーム「Udacity」を設立している。

また、アンドリュー・エン（Andrew Ng、Googleでディープラーニングの研究開発を主導した後、2014年から2017年3月までBaiduのAI研究所所長）氏も、有力プラットフォーム「Coursera」を設立した。現在でも両プラットフォームではAIの基礎から応用に至る多くの講座が提供されており、AI研究の最先端にある大学等からの提供がされていることから、受講者の教育機会として有用なものになっている。

## 寄稿●AI×データ時代における人材要件と日本の課題

# 安宅和人氏

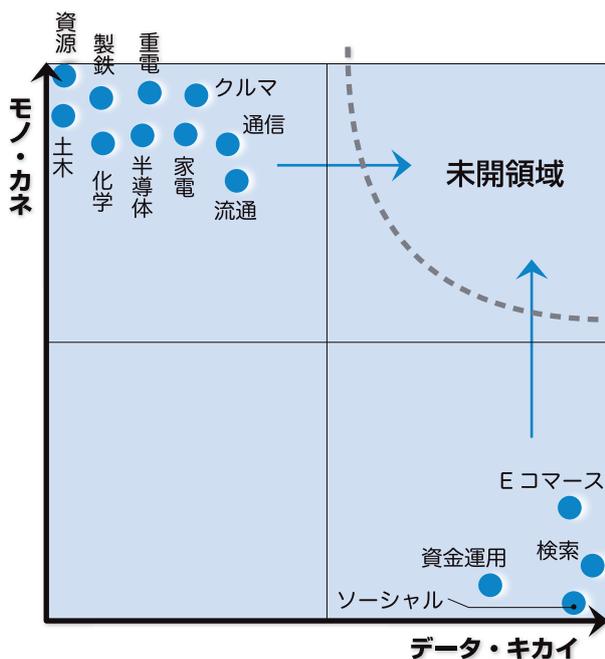
ヤフー株式会社 CSO（チーフストラテジーオフィサー）、  
データサイエンティスト協会 理事・スキル委員長、  
慶應義塾大学SFC特任教授、  
人工知能技術戦略会議 産業化ロードマップタスクフォース副主査

### (1)時代の変曲点

今、我々は歴史的な局面に生きている。利用できるデータ、計算力、情報科学のいずれもが、急激に増大、革新し、これらが重なり合って、指数関数的な変化が至るところで起きているからである。

大きなドライバーは二つある。多様性の高い全量データがリアルタイムで手に入るようになること（ビッグデータ）が一つ、これをさばくための情報処理基盤でもある人工知能（AI）的な機能が計算力、情報科学、データの掛け合わせによって続々と実現していることがもう一つである。

データとAIの持つ力が解き放たれると、情報の識別、予測、暗黙知的なものを取り込んだ実行過程の多く、つまり、現在の我々の労働の多くを占める情報处理的な作業のかなりの部分が自動化する。産業革命までは、人間の労働の大半を占めていた肉体労働、手作業の大半がキカイによって自動化されたのと同様に、再び人間は解放される。人間は使える技術変化は全て使う生き物だからである。



■ 図10 二つの経営資源と今後のトレンド[1]

これまで200年近く続いてきた産業革命的なスキームでは、まず、市場でのプレゼンスを上げ、規模と付

また、情報处理的な活動が殆どの産業で現在の我々の事業活動、そして仕事の中心になった今、この変化はあらゆる産業で起きる。ITとそれ以外という産業の区別自体の意味がなくなる日は近い。今まで、モノ、カネというハード側のリソースで食べてきた産業の大半も、データ、キカイ（AIやロボット）を重要なリソースとして使いこなす産業へと変わっていく。

また今、もう一つ大きな変化が起きている。それは富を生み出す方程式の質的な変化である。

加価値（この総和がGDP）、利益を拡大することが大きな富を生むための基本であった。しかし、これからは、先ほどのAI×データなどの新しい技術革新を活用し、ワクワクを形にし、利益創出以前に事業価値（マーケットキャップ）の形でまずまとまった富が生まれることが基本になる。例えば、先般Teslaの時価総額が、100倍以上のクルマを生産するGMを抜いたように、モビリティの未来がどの事業の向こうに見えるかということで事業価値が生まれる。利益創出はその後、事業が成長するようになってからという逆の流れになる。

既にこの変化は、IT分野の世界的企業の多く（Alphabet/Google、Microsoft、Amazon、Tencentなど）が生み出す利益に比べて比較にならないほど大きなマーケットキャップを持ち、世界の事業価値ランキングの上位を占めていることから明らかである。我々はGDPドリブンな時代から、キャップドリブンエコノミーの時代に突入している。

## (2)これから起きる競争の本質

では、このような時代においてどのようなスキルが必要になるのだろうか？ この問いに答えを出すにはまず、労働環境において、このあと起きる競争の本質をフラットに見極める必要がある。

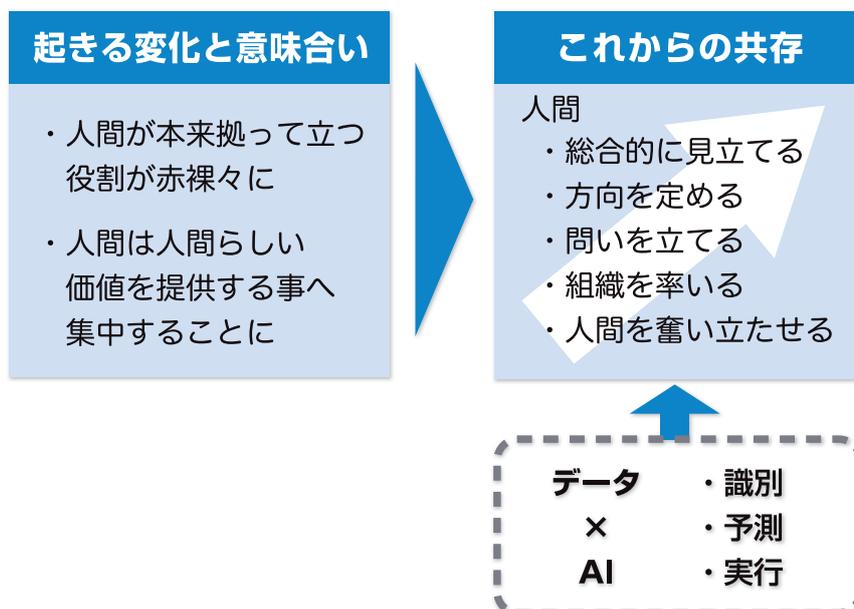
大きく二つのポイントがある。

第一に、これから起きる競争の本質は、よく言われるようなAI vs 人間のような戦いではなく、データやAIの力を使い倒す人と、そうでない人の戦いになるということである。

第二に、キャップドリブンエコノミーの時代においては、これまでのような決まったルールにおけるサバイバルではなく、新しい道を切り開いていくようなジャングルでのサバイバルスキルが重要になるということである。人に言われたこと、「前例があることをきっちりやる」力というよりも、「あったらいいな」を想像し、それを形にする力が大きな富を生むためにより重要になる。

## (3)データ×AIの力を解き放った上で、見る力、決める力、伝える力が重要になる

もう一つ見逃せないのは、ここから先、データやAIの力を使い倒されるようになる結果、情報の識別、予測、実行が自動化していき、人間が本来拠って立つ役割が赤裸々になり、人間は人間らしい価値を提供することに集中することになるということである。具体的には、総合的に見立てる、方向を定める、問い



■図11 起きている変化とこれからの共存<sup>28</sup>

を立てる、組織を率いる、人を奮い立たせるといったことである。

つまり、今後の教育では、まずはデータとAIの力を解き放つ力を身につけることが求められるが、一方で人間の最大の強みである見る力や感じる力、決める力、伝える力を鍛えることが同時に求められるようになる。キカイの得意なことをやっても価値はなくなってしまうからである。

キャップドリブン社会であることを鑑みると、この後者の力を育てていく過程で、若者たちに未来を形作り、リードするためのアントレプレナーシップ的なスキルとマインドを育成していくことが望ましいことも明らかである。これからの人材育成はこのスキルのサンドイッチ構造を念頭に考えることが肝要である。

#### (4)これからの社会を生き抜くための基礎教養

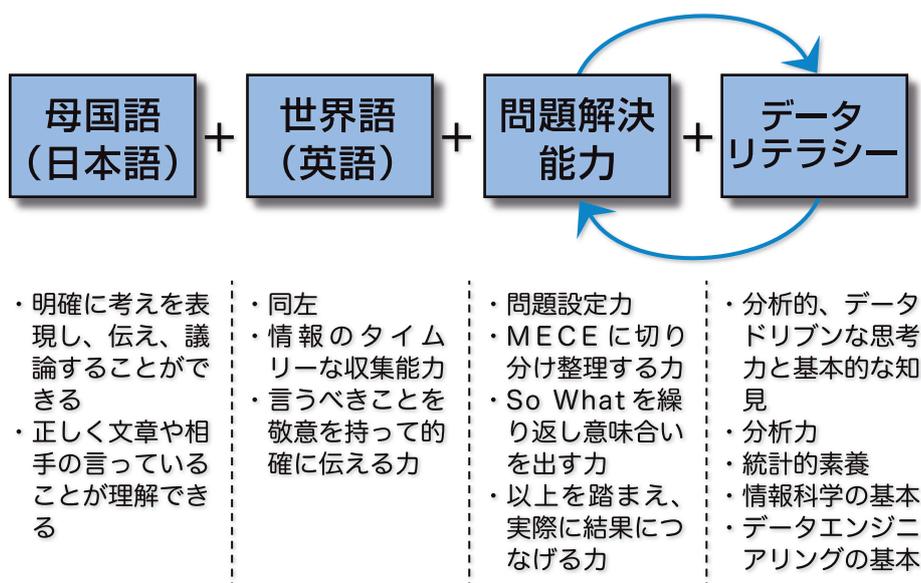
当然のことながら、この大きな変化を受けて今後の時代でのサバイバルにおいて必要になるスキル要件は変わる。

まず、社会を生き抜くための基礎教養、リベラルアーツが変わる。日本ではリベラルアーツというと、古典を学ぶ、文芸に親しむというイメージであるが、本来的にはローマ、ギリシア時代から求められてきた、人に支配されず、自由に生きる人に必要とされるスキルのことである。

その視点で考えると、少なくともこれまでの現代社会のリベラルアーツには大きく三つの要素があった。母国語、世界語、問題解決能力である。

母国語で、明確に考えを表現し、伝え、議論することができ、正しく文章や相手の言っていることが理解できることが第一である。これは言うまでもない。

世界とやり取りする言葉（世界語。現在のところ英語）で同様の能力を持ち、情報のタイムリーな収集能力、言うべきことを敬意を持って的確に伝える力が第二である。特に日本の人口が今後数十年にわたり減ることがほぼ確実であること、主要言語の上で多くの情報がやり取りされることを考えると、少なくと



■図12 社会を生き抜くための基礎教養の変化<sup>30</sup>

※28

「“シン・ニホン” AI×データ時代におけるニホンの再生と人材育成」  
経済産業省ウェブサイト <[http://www.meti.go.jp/committee/sankoushin/shin\\_sangyoukouzou/pdf/013\\_06\\_00.pdf](http://www.meti.go.jp/committee/sankoushin/shin_sangyoukouzou/pdf/013_06_00.pdf)>

※29

Mutually Exclusive and Collectively Exhaustiveの略称。

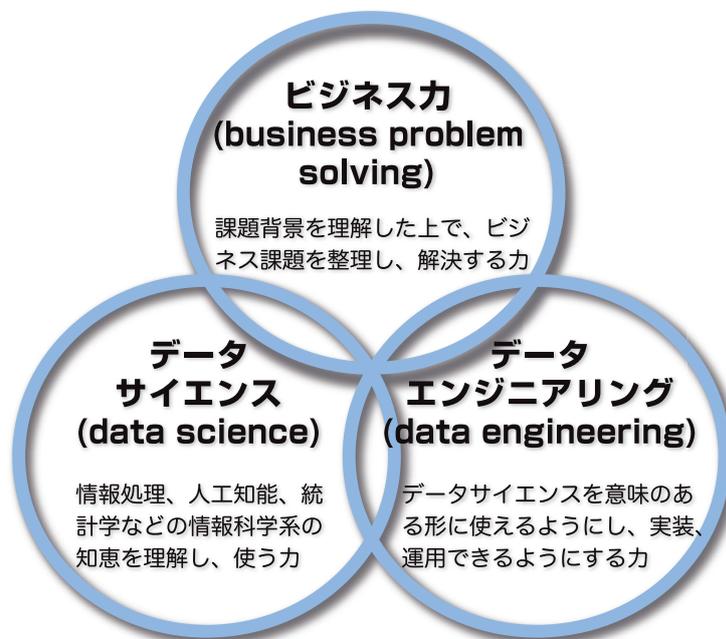
もリーダー層には必須になる。

第三の問題解決能力とは、問題を設定、定義する力であり、対象をダブリもれもなく（MECE<sup>29</sup>に）切り分け、整理する力、またSo Whatを繰り返し意味合いを出す力、これらを踏まえ、実際に結果につながる力である。この重要性を肌身に感じていないホワイトカラーは少ないであろう。

ここにデータの力を解き放つための、データリテラシーが第四の要件として入ってくる。分析的、データドリブンな思考力と基本的な素養のことである。具体的には、分析力、統計的素養、情報科学の基本、データエンジニアリングの基本などからなる。

### (5) データリテラシーとは何か？

この「データの持つ力を解き放つ」ために求められるスキル群を、データサイエンティスト協会（DS協会）では、情報処理、AI、統計学などの情報科学系の知恵を理解し、使う力としてのデータサイエンス力（data science）、データサイエンスを意味のある形に使えるようにし、実装、運用できるようにする力であるデータエンジニアリング力（data engineering）、課題背景を理解した上で、ビジネス課題を整理し、解決する力であるビジネス力（business problem solving）の三つに整理している。



■図13 データの力を解き放つための三つのスキルセット<sup>31</sup>

DS協会のこれまでの発表では、スキルレベルを更にAssistant（見習い）、Associate（一人前）、Full（棟梁）、Senior（業界を代表する）レベルの4段階に整理しているが、当面、一般的に求められるデータリテラシーはここにおける見習いから一人前レベルに相当するというのが現段階での私の見立てである（当然、時代によって内容とも変わる）。

今後はこのデータリテラシーを小中高及び大学教養レベルで理文、専門を問わず身につけることが必要

※30  
「データ時代に向けたビジネス課題とアカデミアに向けた期待」応用統計学フロンティアセミナーウェブサイト <<http://www.applstat.gr.jp/seminar/ataka.pdf>>

※31  
「データサイエンティスト協会、データサイエンティストのミッション、スキルセット、定義、スキルレベルを発表」データサイエンティスト協会ウェブサイト <<https://prtimes.jp/main/html/rd/p/000000005.000007312.html>>

になってくる。なぜなら、これらを持たずにこれからの世の中に出ることはリスクが高すぎるからである。全ての産業がIT化する中、このようなスキルを持たない人を採る会社は急速に減るだろうということが第一、これらのデータリテラシーの多くはほかの先進国では標準となりつつあり、学ばなければ競争力を失ってしまうからということが第二の理由である。

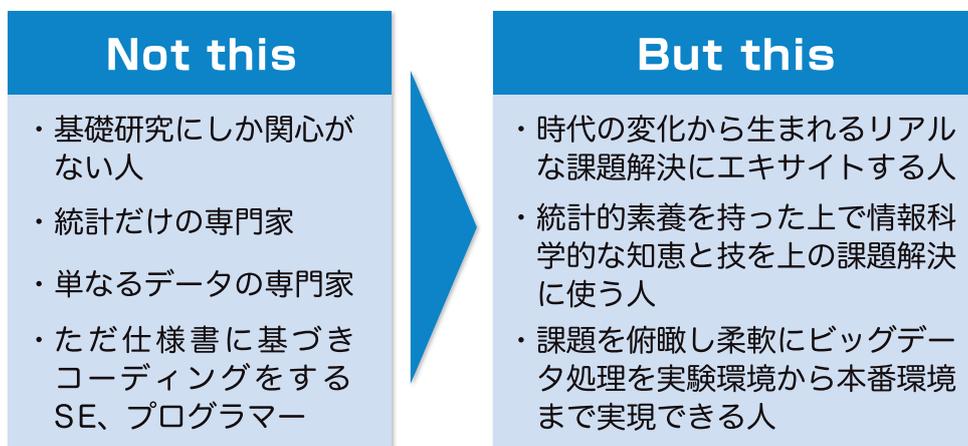
米国の場合、マサチューセッツ工科大学 (MIT)、スタンフォード大学など、トップスクールの学部学生の過半数が、既に学部段階で、計算機科学を少なくとも副専攻 (かなりの数が主専攻) としてとっている。米国ではダブルメジャー、トリプルメジャー (複数専攻) が可能であるからということもあるが、現在、日本の学部生の8割近くが、理数系を入試、若しくは卒業に必要としない文系であり、理系であったとしても、計算機科学やデータサイエンスを体系的に学ぶ人は情報系の学生に偏っている状況で、米国とは対照的である。

実際、日本において深い分析的な訓練を受けた人の数は実数としても大卒に占める割合としてみても、他の先進諸国に比べかなり少ない。我が国の若者たちは持つべき武器を持たずに戦場に出ていっているのである。これからは理文、学部、学科を問わず数学の基礎素養を必須化し、データリテラシーを持たせる必要があるであろう。

#### (6) 必要とされるデータプロフェッショナル

また、これらのスキルが基礎教養化する社会では、必要とされるデータプロフェッショナルも変わる。

これから求められるデータプロフェッショナルは、①時代の変化から生まれるリアルな課題解決にエキサイトする人であり、②統計的素養を持った上で情報科学的な知恵と技を上への課題解決に使う人である。また、システムインテグレーター (SIer) 的なスキルというより、③課題を俯瞰し柔軟にビッグデータ処理を実験環境から本番環境まで実現できる人が求められる。



■図14 これまでとは似て非なるデータプロフェッショナル人材が必要<sup>32</sup>

もちろん、この全てのスキルを一人が体現する必要はないが、求められる人材像がかなり変わることは理解して頂けるであろう。ちなみに①については、我が国の専門家の多くはアカデミアに執着する傾向が強く、シリコンバレーやDeepMindの創業者のような世の中を変えるような産業を起す側に行く人は、

※32

「データ時代に向けたビジネス課題とアカデミアに向けた期待」応用統計学フロンティアセミナーウェブサイト <<http://www.applstat.gr.jp/seminar/ataka.pdf>>

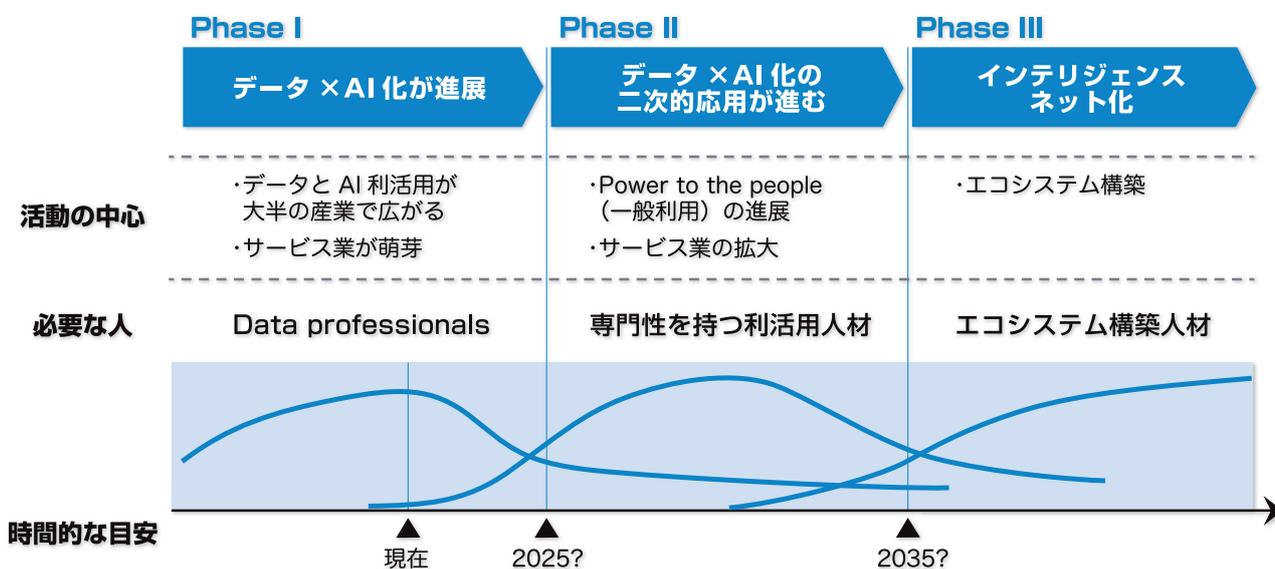
極めて限定的である。②については、これまで統計は個々の学問分野のための付加スキルと考えられてきたこともあり、日本にはそもそも統計学科自体が存在せず、現在ようやく滋賀大学に初めてのデータサイエンス学部ができた状況である。多くの教育機関が、ある種スタート地点にすら立っていない。③については、日本のITエンジニアの大半はSIer的な人材であり、ビッグデータ人材は極めて少ない。我が国の現状は厳しい。

### (7)境界・応用領域こそ専門人材が必要

加えて、全ての産業がIT化し、AI×データの力を必要とする時代になるということは、事業創造の鍵になるのがこれまでのように純粋なデータ×AI領域の専門家だけではなくることを意味している。各産業、あるいは機能における何らかの深いドメイン知識を少なくとも一つは持ち、そこにおいてデータ×AI的な力を解き放てる力が鍵になるということである。

つまり、境界・応用領域こそ人材が必要になる。昨今話題の自動走行のようなものだけではない。例えばある人が今何を知らうとしているのか、また何を欲しているのかを予測するようなマーケティング・広告領域であり、高度な熟練を要する病理診断の自動化、あるいはスターウォーズで出てくる手術ロボット、更には無農薬農業を実現するための雑草カッターのような領域である。

とりわけ、過去20年余りのデータ×AI戦争の第一フェーズで大敗した日本としては、これからやってくるpower to the people的な応用フェーズ（フェーズ2）、そしてこれらのAI的な機能を持つものやサービスがつながり合うintelligence net的なフェーズ3こそがチャンスである。ここでの巻き返しに向けて、これらの人材を相当手厚くする必要がある。大半の出口的な産業を高度に持つ日本には、十分勝機がある。



■図15 データ×AI化における産業化の大局観<sup>33</sup>

※33  
「これから求められる人材について」経済産業省ウェブサイト  
<[http://www.meti.go.jp/committee/sankoushin/shin\\_sangyoukouzou/pdf/005\\_s02\\_00.pdf](http://www.meti.go.jp/committee/sankoushin/shin_sangyoukouzou/pdf/005_s02_00.pdf)>

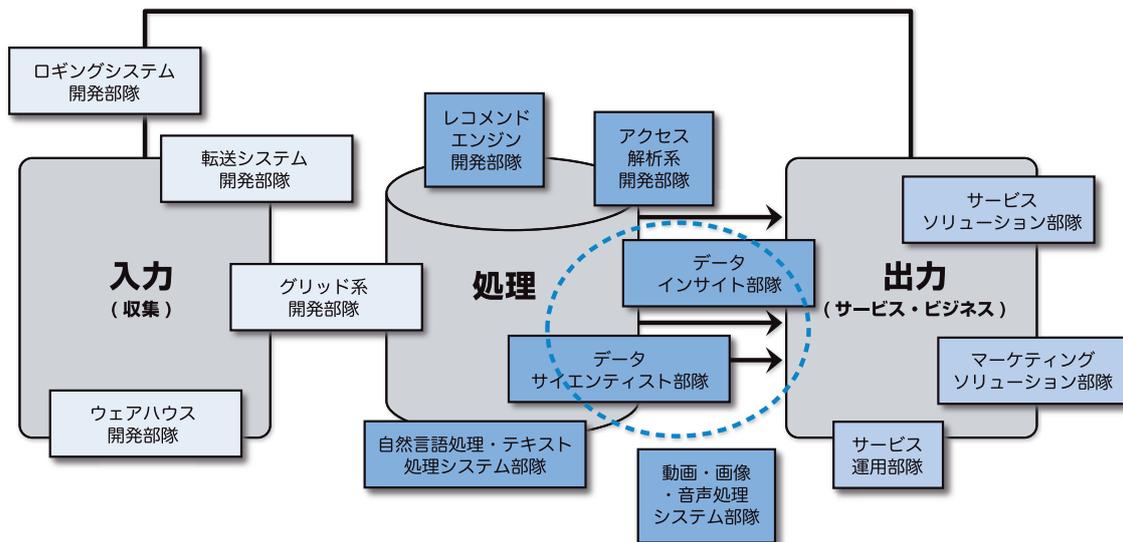
## (8) 必要なのはデータサイエンティストだけではない

この関連で一つ根深い誤解があるのが、データサイエンティストさえいれば、人材課題は解決するかのような考え方である。

データサイエンティストは確かに重要である。情報の収集、処理、出力の三工程で言えば、処理と出力をつなぐ部分に存在し、データウェアハウスや分析用のDBであるデータマートに直接手を突っ込める人であり、自然言語処理や機械学習などの専門家もループに含め、入口と出口をつなぐ人材だからである。

ただ、実際に現在生まれつつあるビッグデータの持つ力を解き放とうと思えば彼らだけでは足りない。処理過程においては自然言語処理や画像処理などの非構造化データ処理の専門家、レコメンデーションエンジン開発の専門家、機械学習の専門家などが必要である。また上流のデータ収集においても、転送システムの開発、ウェアハウスの開発、グリッド型の開発、ロギングシステムの開発など多様なデータインフラの専門家が必要である。

下流の出力工程でもマーケティングソリューション、サービス運用の専門家が川上の収集、処理工程以上に数が必要である。実際このような方々がいないことが、デジタルマーケティングの現場で人不足を招き、労働環境の悪化を引き起こし、社会課題となっている。



■図16 ビッグデータ利活用に必要な専門人材の広がり[2]

## (9) 日本固有の課題

日本固有の課題のうち、ここまで触れられなかった二点についても触れておきたい。

第一にデータ×AI領域におけるそもそもの専門家の層の薄さである。例えば、昨今、革新と応用利用が飛躍的に進むディープラーニング分野において、世界的なリーダーは北米及び英国に集中している。一方、専門誌でのディープラーニング関連の論文数を見ると、中国が更に米国にほぼ並ぶか追い越しつつある。欧米だけをベンチマークとして見ていけばよい時代は終わったのである。単に後追いでは意味がないものの、世界（特に米中）に伍せる情報科学の専門家の数、リーダー層は格段に増やす必要があることは間違いない。

これらのトップ人材は、これまでの先端技術同様、大きなグランドチャレンジを掲げ、ある程度まとまった研究資金の基で、新しい取組を行う中で生まれてくる可能性が高い。特にバブル以降、約15年間に渡ってこれらの大型プロジェクトを行ってこなかったことのツケは大きい。巻き返しのためにも、AI活用の

出口となるモノ・カネ側の国内産業の強みを活かし、国力に見合った取組を何本も行っていく必要があるだろう。

ただし目先の専門家層、リーダー層の人材不足については、このような有機的な人材育成手法では間に合わないことは明らかであり、まったく別のアプローチ、すなわち、明治の開国期に近い世界各国からの才能の広範な募集、取り込みが重要になる。

第二の固有課題は、ミドル・マネジメント層の大半がこのままでは役割を終えてしまう可能性が高いことである。彼らの多くはこのような歴史的な局面において、そもそものチャンスと危機、現代の挑戦の幅と深さを理解していない。また、本来、この層にいるべきビジネス課題とサイエンス、エンジニアリングをつなぐアーキテクト的な人がいない。彼らが生き延びるためにはスキルをrenewしなければいけないが、身につける方法が分からない上、学ぶ場がない。ここには明確な手を打つ必要がある。このままでは革新を阻害するシニア人材（「じゃまオジ」）だらけの社会になってしまうのである。

### **(10)3層+2で育て、加えて世界の才能を取り込むべき**

以上をまとめると、次世代層については、まず①基礎となるデータリテラシーを上げ、未来へのマインドを育てることで基本となる武器を与えることが第一である。具体的には、現代の基礎教養としてのデータリテラシー教育に加え、アントレプレナーシップ、未来を生み出す教育を行い、指数関数的に変わる時代の物の考え方も基本として流し込む（小中高+大学教養）。

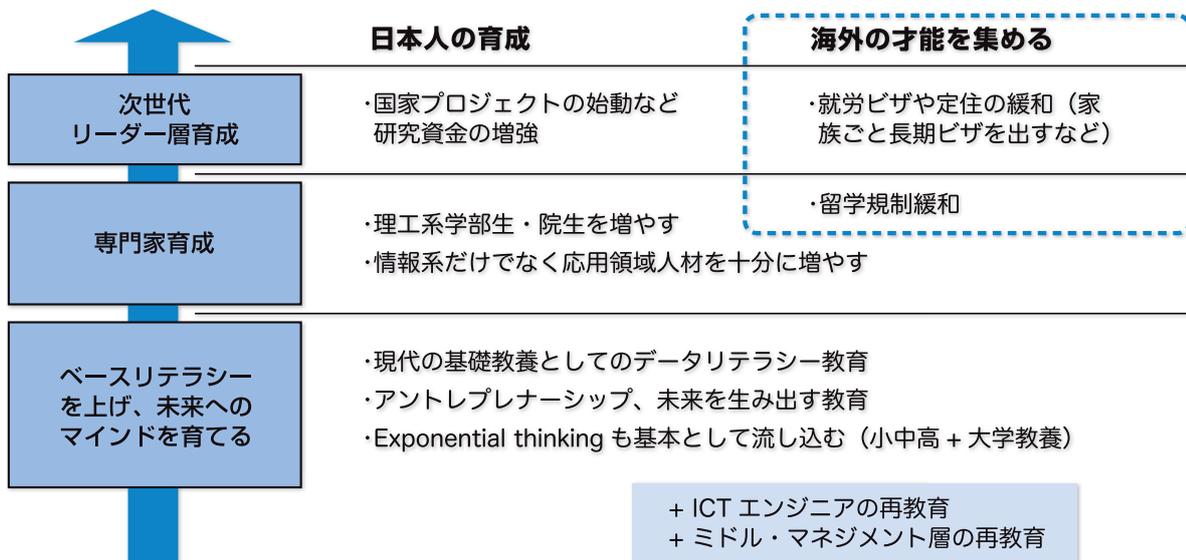
加えて、②専門家層を増やす。理工系学部生・院生を増やすことに加え、情報系だけでなく、理文を問わずあらゆる分野の境界・応用領域人材を十分に増やす。言語×AI=自動翻訳となるように、これらの具体領域と技術の掛算から新しいサービス、産業が生まれてくるからである。③次世代リーダー層を育てる。研究資金の増強を行い、国家プロジェクトの始動などを実施する、という3層構造で未来に向けた人材育成を行うべきである。

既存勤労層については、④ITエンジニア及び、⑤ミドル・マネジメント層をデータ×AI時代に即した形でスキルを刷新するという二枚重ねの取組が必要である。加えて、⑥目先の専門層、リーダー層不足課題については、北米、欧州、中国、インド及びアジア諸国からの才能の取り込みを早急に検討するべきである。

---

※34

「これから求められる人材について」経済産業省ウェブサイト  
<[http://www.meti.go.jp/committee/sankoushin/shin\\_sangyoukouzou/pdf/005\\_s02\\_00.pdf](http://www.meti.go.jp/committee/sankoushin/shin_sangyoukouzou/pdf/005_s02_00.pdf)>



■図17 AI×データ時代に向けた人材の増強イメージ<sup>34</sup>

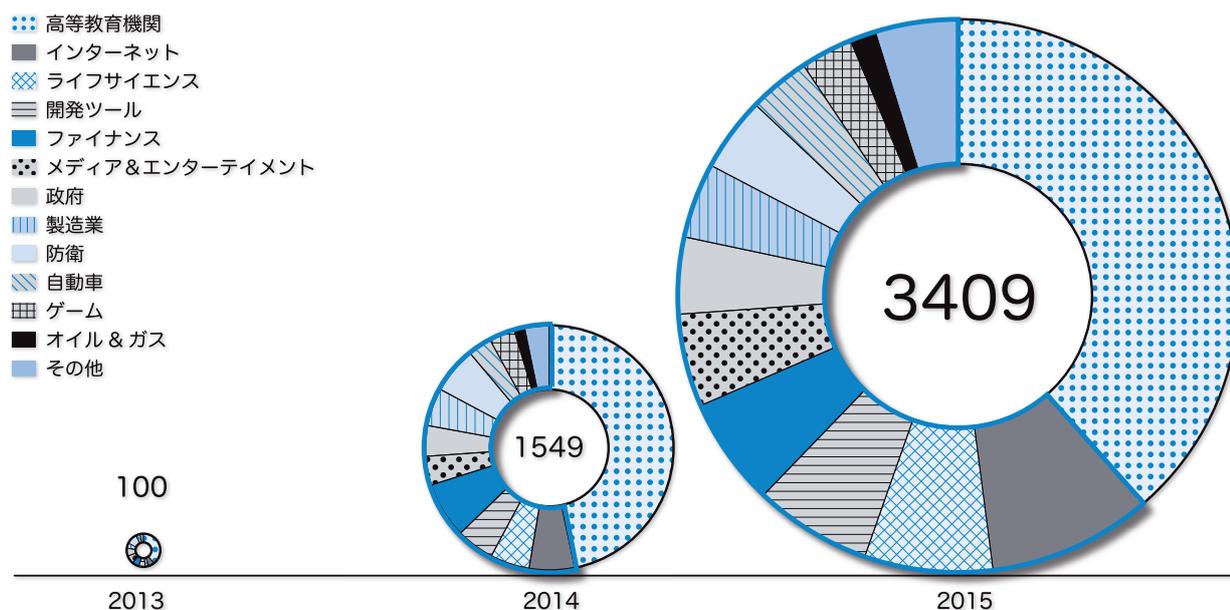
以上見てきたとおり、ここから先はこれまでの日本の産業的な強み領域を十分活かしうる応用フェーズに入る。人材課題への対応については、3層+2+1の施策をいかに迅速に立ち上げ、回していくかが今後の我が国の勝負どころの一つとなる。実にエキサイティングな時代である。

- [1] 安宅和人「人工知能はビジネスをどう変えるか」『DIAMONDハーバード・ビジネス・レビュー』2015.11月号, p.55.
- [2] 安宅和人「Yahoo! JAPANにおけるビッグデータの活用とその舞台裏」『言語処理学会第21回年次大会 (NLP2015) 招待講演』, 2015.3.



### 2.3.2 計算資源

企業等が機械学習やディープラーニングを利用するためには、学習のための膨大なデータを管理するストレージ、その膨大なデータを計算処理するためのサーバ資源等を確保することが必要となる。NVIDIAによるディープラーニング用途のGPUの供給先の組織数を見ると、図18のとおり2013年と比較して2015年に約34倍に増加し、企業等はディープラーニング用途の計算資源の整備を加速させている様子が見えてくる。分野別にみると高等教育機関向けの売上高が4割程度を占める最大の供給先であるが、2014年と2015年を比較すると、高等教育機関の割合が減少していることから産業界への普及が進み、GPUを用いた企業等によるディープラーニングの適用が進んでいる様子が見えてくる。



■図18 ディープラーニングの実装を目的としてNVIDIA社のGPGPUを採用する組織数<sup>35</sup>

一方で、全ての企業がGPU等のAI利用のための計算資源を整備することは難しい。我が国では、産業技術総合研究所によるAI処理向け大規模・省電力クラウド基盤（AI Bridging Cloud Infrastructure; ABCI）やデータセンター事業者によるAI向けのコンピューティングリソースの提供など、企業等がAIを活用するための計算資源の整備が進んでいる。

また、AIを利用する企業には、計算資源のほかに、機械学習やディープラーニング等のミドルウェア（機能）を組み合わせるスキルが求められる。企業におけるAI利用を支援するために、海外のパブリッククラウド事業者を中心に機械学習等のAI機能を搭載したクラウドサービス（クラウドAI）の提供が行われている。

クラウドAIには、音声認識や画像認識、言語翻訳等のディープラーニング等を用いた機能がAPI（Application Program Interface）として搭載されており、利用企業は必要なAPIを通じて必要な機能を扱うことができる。クラウドAIを利用することで、データを保有する一方で計算資源やアルゴリズムに深い知見を持たない利用企業は、比較的容易にAIに関わる機能を試行・実装でき、計算資源への投資やミドルウェア等の構築のコストを抑えることができる。また、クラウドAIの特徴である従量課金の特性から、PoC（Proof of Concept）などスモールスタート用途にも適している。

クラウドAIは、表33のとおり、大手IT企業に加えて米国のData Robot等のスタートアップ企業も提供を始めている。クラウドAIには、学習機能だけでなく、あらかじめ学習した学習済みモデルを利用（推論）できる機能を提供するサービスも現れており、利用する企業側が学習のための十分なデータを持たずとも、データを与えることで推論した結果を得ることができる。特に、音声認識や画像認識等の領域で学習済みモデルを利用する機能の提供が進んでいるが、これらの機能は米国等の主要市場を対象としているため、我が国の環境（言語等）に十分に最適化されない機能となる可能性も高い。2.3.5項で示すとおり、

※35

「拡がるディープラーニングの活用」 NVIDIAウェブサイト  
<https://images.nvidia.com/content/APAC/events/deep-learning-day-2016-jp/NV-DL-User-Cases.pdf>より作成

我が国においてAIを高度に利用するためには、共有データセットや共有モデル等を整備することが重要と考えられる。

■表33 主要なクラウドAI<sup>36</sup>

| 組織名        | サービス名                         | 概要  |
|------------|-------------------------------|---|
| Google     | Google Cloud Machine Learning | <ul style="list-style-type: none"> <li>Googleが提供する機械学習用途のクラウドサービス。事前学習済みモデルも提供されており以下のような用途に対して、独自に学習を行わずに利用することも可能である。 <ul style="list-style-type: none"> <li>Speech API (音声認識)</li> <li>Vision API (画像分析)</li> <li>Translate API (翻訳)</li> <li>Natural Language (テキスト分析)</li> <li>Jobs API (仕事検索機能)</li> </ul> </li> <li>Job APIでは、求職者が求めている事項を予測し、仕事の検索を支援するサービスなど、特徴的な機能も提供されている。</li> <li>従量課金サービスであり、モデルの学習時間による課金と学習済みモデルによる予測回数及び時間単位による課金で収益を得る仕組みである。</li> </ul>  |
| Amazon     | Amazon AI                     | <ul style="list-style-type: none"> <li>AI利用のための以下の機能が提供されている。利用に応じて従量課金が行なわれる。 <ul style="list-style-type: none"> <li>Amazon Rekognition :<br/>ディープラーニングに基づく画像認識サービスであり、画像内の物体やシーン、顔等を検出できる。同サービスでは、学習済みモデルを利用することができる。</li> <li>Amazon Polly :<br/>ディープラーニングを使用した文章から音声への変換サービスである。</li> <li>Amazon Machine Learning :<br/>開発者向けのスケーラブルな機械学習サービスである。</li> <li>ディープラーニング開発者用のリソースとしてAmazon Machine Image、Amazon Cloud Formation等が提供されている。</li> </ul> </li> </ul>  |
| Microsoft  | Azure Machine Learning        | <ul style="list-style-type: none"> <li>「Vision (視覚)」「Speech (音声)」「Language (言語)」「Knowledge (知識)」「Search (検索)」の五つのコグニティブ (認知) 領域における各種APIを、クラウドサービスMicrosoft Azureを通じて提供している。</li> <li>利用に応じて従量課金が行なわれる。</li> </ul>  |
| IBM        | Watson Data Platform          | <ul style="list-style-type: none"> <li>高速なデータ取り込みエンジン (100GB/秒) や機械学習機能を提供するIBM Cloudベースのデータプラットフォームである。</li> <li>データを駆使する専門家 (データサイエンティスト、データエンジニア、ビジネスプロフェッショナル、アプリケーション開発者) が任意の言語やサービス、ツールを使って共同でデータセットの活用に取り組めるようにすることで、高度なコラボレーションを実現する。</li> <li>また、データから得たインサイトをデータ専門家が簡単に可視化し、全社で共有できるようにする。</li> </ul>  |
| GE         | Predix                        | <ul style="list-style-type: none"> <li>PaaS (Platform as a Service) として提供され、アプリケーション開発、ビッグデータの分析機能、データ収集・蓄積機能、デバイス接続機能などを有する。</li> <li>Analytics機能として、予期しない機器のダウンを予測・防止、位置情報を処理、異常値を検出、データ欠損などデータ品質の問題を解決する機能を有する。</li> <li>本業である航空機のエンジン開発、鉄道車両の製造、火力発電所や原子力発電所などの機器製造、医療用機器や各種センサ、産業用ソフトウェアの開発などの知見を生かして、産業ごとのニーズを深く理解した上でクラウドサービスを構築、提供している。</li> <li>GEは自社ソフトウェアのPredix Cloudへの移行を推進し、自らがユーザとなり、Predixプラットフォームの利用は産業界で進みつつある。</li> <li>Boeing (米国) やColumbia Pipeline Group (米国)、BP (英国) などが既に利用している。Predixのクラウドサービスの初期導入企業としては、ANSYS (米国)、Azuqua (米国)、Bsquare (米国)、FogHorn Systems (米国)、FPT Software (ベトナム)、GenPact (米国)、IGATE (米国)、Infosys (インド)、Nurego (米国)、Platine (米国)、SparkBeyond (イスラエル)、Tata Consultancy Services (インド)、ThetaRay (イスラエル) などが挙げられている。</li> </ul> |
| Data Robot | Data Robot                    | <ul style="list-style-type: none"> <li>BtoBの汎用機械学習プラットフォームを開発・提供している。</li> <li>オープンソースライブラリで実装される1,000を超えるモデルを大規模同時並行で学習・評価し、アルゴリズムや前処理、特徴量、パラメータチューニングなどの組み合わせから最適なモデルを導出する。</li> <li>これにより、ビジネスドメインにおける正確な予測モデルの生成・展開を可能としている。</li> </ul>   |

※36  
各種公表情報より作成。

### 2.3.3 標準化

近年、市場に混在する多様で複雑、無秩序な「もの」や「事柄」について、ルールや規則・規定などの取決め（標準）を作成し、利用する標準化が積極的に進められている。企業活動の国際化が進展する中、自社の技術、製品、サービスが市場で際立つような評価・品質の基準、試験方法を標準とするなど、国際的なドミナンスを獲得するためのツールの一つとして標準化が位置付けられているためであり、国内外の政府や企業が積極的に取組を進めている状況にある。

第1章で示したとおり、AIに関わる技術領域は幅広いことから、AIやAIを組み込んだシステム中心の標準化の取組はこれまで十分行われてこなかった。だが、ビッグデータ、IoT、スマートシティなどの産業横断的な枠組みや、交通システム（ITS）、製造システム（Smart Manufacturing）、エネルギー（Smart Energy）、医療システムなど、産業別の枠組みの中で、AIはその一部の機能を担うものとして位置付けられ、標準化が進められてきた。

例えば、国際電気標準会議（IEC）では、オーディオ、ビデオ、マルチメディアシステム等の関連技術の標準化を進めるTechnical Committee（TC）100において、自立生活支援（Active Assisted Living）の標準化<sup>37</sup>の一部として、音声認識を含めた生活支援のためのアクセシビリティやユーザーインターフェースについて議論が進んでいる。民生用分野・業務用分野の機器の性能や測定方法、マルチメディアシステムの応用、システムと機器間のインターオペラビリティなどの標準化を進めている。また、IT分野を取り扱う国際標準化組織として国際標準化機構（ISO）とIECにより設置された協同検討組織ISO/IEC JTC1では、「WG7（センサネットワーク）」、「WG9（ビッグデータ）」、「WG10（IoT）」、「WG11（スマートシティ）」、「SC41（IoT関連技術）」等が設置され、IoT及びスマートシティ等に関わる用語、ルール、データ等の標準化の中でAI、音声認識、機械学習、ニューラルネットワーク等も位置付けられている<sup>38</sup>。

上述したISOやIECのような国際的なデジュール標準を検討・策定する団体のほかに、国家標準を検討・策定する団体においても、従前の標準化の枠組みの中でAIを位置付けている。例えば、米国では、2012年3月に米国ホワイトハウスが5年間で総額2億ドルを超える研究開発政策「ビッグデータ研究開発イニシアティブ」を発表後、国立標準技術研究所（NIST）にビッグデータに関する定義、リファレンスアーキテクチャ、技術ロードマップ等の構築を目的としたパブリックワーキンググループ（BD-PWG）が設置され、標準化が進められている。このBD-PWGが2015年に公開した「ビッグデータ相互運用性フレームワークFinal Version 1<sup>39</sup>」において、ビッグデータユースケースの一部としてディープラーニング及びソーシャルメディア（Deep Learning and Social Media）が位置付けられている。

また、2017年3月に公開された「ビッグデータ相互運用性フレームワークVersion 2（Draft 2）<sup>40</sup>」においても、データサイエンスアプリケーションの重要な領域としてMachine Learningが位置付けられている。

このように、従前の標準化の枠組みや領域の中でAIが位置付けられてきたが、昨今のディープラーニングを中心としたAI技術の発展や実用化の進展等により、AIやAIを組み込んだシステムを前提とした標準

※37  
TA (Technical Area) 16: AAL (Active Assisted Living) において議論がなされている。

※38  
“Hearing lots of voices? AI takes connected devices to the next level,” IEC e-tech Website <<http://iecetech.org/issue/2017-01/Hearing-lots-of-voices>>

※39  
“NIST Big Data interoperability Framework (NBDIF) V1.0 Final Version,” NIST Big Data Public Working Group Website <[https://bigdatawg.nist.gov/V1\\_output\\_docs.php](https://bigdatawg.nist.gov/V1_output_docs.php)>

※40  
“NIST Big Data interoperability Framework (NBDIF) V2.0 Working Drafts,” Nist Big Data Public Working Group Website <[https://bigdatawg.nist.gov/V2\\_output\\_docs.php](https://bigdatawg.nist.gov/V2_output_docs.php)>

化の取組も始まっている。

例えば、ディープラーニングと関連する標準化へ向けた代表的な動きとして、様々なデバイスやソフトウェアの標準化活動を行う非営利団体のクロノスグループ (Khronos Group) により、画像処理のためのオープンなAPI仕様である「OpenVX」が策定されている。OpenVXでは、ディープラーニングを用いた画像処理への対応を各社が個々に開発してしまい、相互運用性が損なわれることを防ぐために、ディープラーニングに基づく推論を実行するための「Open VX Neural Network Extension」と、ニューラルネットワークを規定する情報（構造と重み）の流通を可能とする「Neural Network Exchange Format」(NNEF) を策定している。

OpenVX Neural Network Extensionは、組込みシステムでのリアルタイム処理を意識して、メモリマネジメントや消費電力の観点から、CPU、GPU、DSP、FPGA等の複数のデバイスにわたって処理の分担を細かく調整できるように設計されている。また、NNEFのワーキンググループ<sup>41</sup>では、畳み込みニューラルネットワークを当面の対象としているが、RNN等の幅広いネットワークにも将来的に対応可能な設計とすることを目指している。ワーキンググループは、ディープラーニングフレームワークの開発者に議論への参加を呼びかけており、2017年6月までに議論の詳細化を行う予定となっている。現時点でNNEFのVersion1.0が公開されている。クロノスグループにおけるこれらの議論では、現状ではニューラルネットワークの学習よりも推論に関わる仕様を重視している。そのため、当面は学習済みモデルを固定した上での議論が先行すると想定される。

また、IEEEは、AIや自律システムの論理的配慮に関する国際イニシアティブ (IEEE Global Initiative for Ethical Considerations in Artificial Intelligence and Autonomous Systems) を設置し、全ての技術者がAIや自律システムの設計や開発において倫理的配慮を行うことの優先度を高めるための活動を行っている (3.3.2項参照)。同イニシアティブは、包括的なロードマップ、ホワイトペーパー、教材などの開発・公開、関連団体との協力等の活動に加え、認証や行動規範等に関わる標準化プロジェクトの推進が掲げられている。

具体的には、IEEE P7000 (システム設計における倫理的懸念に対処するモデルプロセス) からP7006 (パーソナライズされたAIエージェントの標準) までの七つのワーキンググループを設立し、設計や開発の倫理的配慮に関わる標準化の議論を進めている。

今後、あらゆる分野でAIの実用化や普及が進むことが期待される中、AIを利用するために必要となる標準の策定を進めることが重要となる。具体的には、学習のためのインターフェース、学習精度の評価・保証制度、データ流通・利用のためのAPI、データ生成から利用における個人情報やセキュリティなどAIに関わるデータの生成、蓄積・流通、加工、利用までのライフサイクルのそれぞれで標準化が進むと想定される。人工知能技術戦略会議がとりまとめた「人工知能技術戦略」<sup>42</sup>においても、AIの協調領域と競争領域を使い分け、戦略的に国際標準や知的財産を押さえ、技術をビジネスにつなげていくことが重要であると示されているとおり、AIに関わる国際的な標準化の議論に我が国企業等も積極的に関与し、競争優位な市場環境を形成・拡大することが重要である。

---

※41  
“ Deep Learning Working Group, ” Khronos Group Website  
<<https://www.khronos.org/assets/uploads/apis/Deep-Learning-SoW.pdf>>

※42  
「人工知能技術戦略」新エネルギー・産業技術総合開発機構ウェブサイト  
<<http://www.nedo.go.jp/content/100862413.pdf>>

## 2.3.4 オープンソースソフトウェア

2.2.1項で示したとおり機械学習やディープラーニングに関わるフレームワークやライブラリをオープンソースソフトウェア（OSS）として公開することで、集合知のプラットフォーム形成を進める動きが見られる。

OSSや2.3.2項で示したクラウドAIを利用することで、利用企業はプログラムを一から記述しなくても機械学習やディープラーニングを用いたシステムの開発が可能となる。代表的なフレームワークは表34のとおりである。

表34 機械学習やディープラーニングに関わる主要なOSS<sup>43, 44</sup>

| ソフト名       | 開発元                                      | 概要  |
|------------|--|---|
| Caffe      | Berkeley Vision And Learning Center (米国) | <ul style="list-style-type: none"> <li>・ Googleに在籍するYangqing Jiaがカリフォルニア大学バークレー校の博士課程に在籍した頃に開発が開始されたディープラーニング用途のフレームワーク</li> <li>・ ディープラーニングの研究が盛んとなった初期に注目され利用が進展</li> <li>・ 対応OSはLinuxOS、MacOS、WindowsOS(非公式)</li> <li>・ GPUに対応</li> <li>・ 操作言語はpython</li> </ul> |
| Chainer    | Preferred Networks                       | <ul style="list-style-type: none"> <li>・ Preferred Networksが2015年6月に公開したディープラーニング用途のフレームワーク</li> <li>・ 国内での利用が進んでいる。対応OSはLinuxOS、MacOS</li> <li>・ GPUに対応</li> <li>・ 操作言語はpython</li> </ul>  |
| CNTK       | Microsoft (米国)                           | <ul style="list-style-type: none"> <li>・ Microsoftが開発・公開したディープラーニングのためのツールキット (Microsoft Cognitive Toolkit; CNTK)</li> <li>・ 対応OSはLinuxOS、WindowsOS</li> <li>・ GPUに対応</li> <li>・ 操作言語はpython、C++</li> </ul>   |
| CSLAIER    | ソニーコンピューターサイエンス研究所、UEI                   | <ul style="list-style-type: none"> <li>・ ソニーコンピューターサイエンス研究所とUEIが共同開発したディープラーニング向けのデザインツール</li> <li>・ ChainerとTensorFlowを手軽に利用できるGUI環境であり、ネットワーク構造などを定義可能</li> <li>・ 対応OSはLinuxOS10</li> <li>・ GPUに対応</li> <li>・ 操作言語はDeelと呼ばれる独自記述言語</li> </ul>                     |
| TensorFlow | Google (米国)                              | <ul style="list-style-type: none"> <li>・ GoogleのMachine Intelligence研究所が開発したディープラーニングや機械学習向けのフレームワーク</li> <li>・ TensorFlowは急速に市場に広まっており、国内外の様々な企業が活用</li> <li>・ 対応OSはLinuxOS、MacOS、WindowsOS</li> <li>・ GPUに対応</li> <li>・ 操作言語はpython、C++</li> </ul>                |
| theano     | University of Montreal (カナダ)             | <ul style="list-style-type: none"> <li>・ ディープラーニングへの応用を強く意識して設計された数値計算ライブラリ</li> <li>・ 対応OSはLinuxOS、MacOS、WindowsOS</li> <li>・ 操作言語はpython</li> <li>・ GPUに対応</li> </ul>   |
| Torch      | Ronan Collobertら                         | <ul style="list-style-type: none"> <li>・ 幅広い機械学習アルゴリズムをサポートするフレームワーク</li> <li>・ Facebook AI ResearchやGoogle DeepMind等が利用</li> <li>・ 対応OSはLinuxOS<sup>44</sup>、MacOS</li> <li>・ GPUに対応</li> <li>・ 操作言語はLua</li> </ul>  |

Googleが提供する機械学習やディープラーニング向けのフレームワーク「TensorFlow」は、同社のMachine Intelligence研究所が機械学習やディープラーニングの研究を行う目的で開発されたものであり、

※43  
「オープンソース」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100861559.pdf>>

※44  
Ubuntu 14.04での動作検証が行われている。WindowsOSなどの他OSでの動作報告も行われている。

その成果がApache 2.0オープンソースライセンスの下で、学生、研究者、エンジニア、開発者等に向けて広く公開されている。TensorFlowは様々な環境で利用でき、複数のGPUへの対応やPCやモバイル端末でも動作する点が特徴的である。企業等への普及が進んでおり、以下の企業等が既に利用を始めている。

- Airbnb (米国)
- Airbus (フランス)
- ARM (英国)
- Dropbox (米国)
- eBay (米国)
- IBM (米国)
- Intel (米国)
- Qualcomm (米国)
- Xiaomi (中国)
- UBER (米国)、等

Microsoftのディープラーニング用途のツールキット「CNTK」(Computational Network Toolkit)も、Google同様自社内の研究向けに開発されたものであった。そのため、公開当初は、C++言語でプログラミングを行う必要があったが、バージョン2.0ではPython等の、AI分野でよく利用されるプログラミング言語への対応を行っている。

表のほかにも企業等によるOSSの公開が盛んに行われている。例えば、2017年1月には、Intelが「BigDL」と称する分散型ディープラーニングライブラリをOSSとして公開している。BigDLは、データの保存、処理とマイニング、フィーチャーエンジニアリング(特徴量設計)、機械学習とディープラーニングワークロードのための統合型データ分析プラットフォームとして機能する。

Amazonは2016年5月にディープラーニング向けのOSSライブラリ「DSSTINE」(Deep Scalable Sparse Tensor Network Engine)を公開している。DSSTINEは、学習及び推論の両方が複数のGPUにスケールアウト可能である。自社でOSSを開発・公開している一方で、自らのクラウドAIの推奨フレームワークとして、CMUなどの研究者が開発するディープラーニング用途のOSSフレームワークMXNetを採用すると発表しており、オープンな開発を進めている。

中国では、Baiduが自社の検索ランキングやターゲット広告、画像検索、翻訳等に搭載されている分散型ディープラーニングのためのフレームワークPaddlePaddle (PArallel Distributed Deep LEarning)を公開している。

このように、大手IT企業、スタートアップ企業等が、自社で開発したフレームワークやライブラリをOSSとして外部に公開している。また、2.2.1項で示したように、学習用データや学習済みモデルなども合わせて公開することで、外部の企業や研究者を巻き込む集合知のプラットフォーム形成が進んでいる。

### 2.3.5 共有データセット・共有モデル

2.2.1項で示したとおり、機械学習、特にディープラーニングはアルゴリズム、学習済みモデル、学習用データ、ソフトウェアコードなど開発した技術やデータ等を公開・共有することで、多様なプレイヤーを巻き込む連鎖的な技術開発が加速度的に進むというネットワーク効果が有効に働く。ディープラーニングの研究開発を進める大学や一部の企業等は、自らが開発した技術やデータを公開・共有する取組を始めている。

本節は、このような学習用データの公開・共有（共有データセット）や学習済みモデルの公開・共有（共有モデル）に関わる動向等について述べる。

### 2.3.5.1 共有データセット

#### (1) 既存の共有データセット

現在、使用可能な共有データセットとしては、画像認識用データセットの「ImageNet」、手書き数字認識用の「MNIST」、画像をピクセル単位で意味づけし、領域を識別する画像セマンティックセグメンテーション用の「MS COCO」などがある。AIの性能を決定づけるのがデータセットであり、そのため世界中の様々な研究機関がデータセットを公開している。表35に、主要な共有データセットを示す。

表35 主要な共有データセット<sup>45</sup>

| データセット名                        | 説明   |
|--------------------------------|--|
| ImageNet                       | スタンフォード大学がインターネット上から画像を集め分類したデータセット。一般画像認識用に用いられる。ImageNetを利用して画像検出・識別精度を競うThe ImageNet Large Scale Visual Recognition Challenge (ILSVRC) などコンテストも開かれる |
| MNIST                          | ニューヨーク大学のYann LeCunらがまとめた手書き数字を集めたデータセット。機械学習の入門用データセットとしてよく用いられる  |
| MS COCO                        | 欧州のAI関連研究コミュニティのPattern Analysis, Statistical Modeling and Computational Learning (PASCAL) がまとめたMicrosoftが作成した画像セマンティックセグメンテーション用データセット                |
| Pascal VOC                     | 画像セマンティックセグメンテーション用データセット  |
| WMT15                          | 機械翻訳に関する国際会議のWorkshop on Statistical Machine Translation (WMT) がまとめた英語と仏語、独語、チェコ語、ロシア語、スペイン語、フィンランド語などの対訳集   |
| Cornell Movie-Dialogs Corpus   | コーネル大学(Cornell University、米国)が600以上の映画の字幕をまとめたデータセット   |
| VGG Face Dataset               | オックスフォード大学Visual Geometry Groupがまとめた顔画像のデータセット   |
| Human Pose Estimate Dataset    | オックスフォード大学Visual Geometry Groupがまとめた人間のポーズ推定を学習するためのデータセット   |
| Oxford Buildings Dataset       | オックスフォード大学Visual Geometry Groupがまとめた建物画像のデータセット  |
| BBC-Oxford Lip Reading Dataset | British Broadcasting Corporation (BBC、英国)とオックスフォード大学がまとめた唇から言葉を読み取るためのデータセット   |
| Text Localisation Dataset      | オックスフォード大学がまとめた、写真の中にある文字の位置を学習させるためのデータセット  |

#### (2) 既存の共有データセットの問題点

現在広く頒布されているデータセットには、問題が二つある。一つは著作権や肖像権の問題である。現在はフェアユース（公正な利用）に近い形で運用されているが、これを企業が用いて学習したものを、業務や製品に使うって良いかという問題への指摘がある。

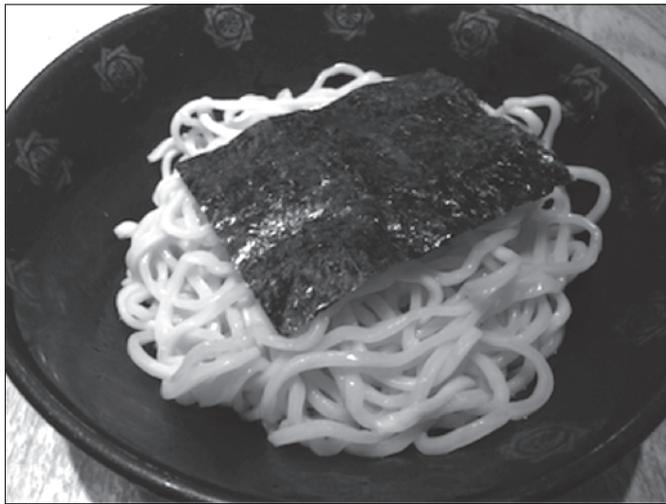
GoogleやMicrosoft、Appleなどは、著作権などの知的財産権の処理をグレーゾーンとして捉え、自社のサービス用AIに共有データセットを学習させた上で、有料のディープラーニングサービスの提供に踏み切っている。他方、我が国では、企業のコンプライアンス部門が厳格な体制や制度を有することから、米国のようにグレーゾーンでの事業展開が難しく、今後、国として何らかの指針を示す必要が出てくるだろう

※45  
各種公表情報より作成。

う。

もう一つの問題が、共有データセットの多くが欧米で作られているということである。例えば、ImageNetは最も良く参照されるデータセットの一つであるが、ImageNetの分類には日本国内ではありふれた「ラーメン」などの料理は無く、国内外で郵便ポストの色も形も違うので、誤認識するという問題がある。

例えば図19のような写真を見せると、ImageNetで学習したAIは図20のように、この写真を「カルボナーラ」又は「マッシュポテト」と解釈する。



■図19 AIに見せた「つけ麺」の画像

```
#1 | n07831146 carbonara | 71.4%
#2 | n07711569 mashed potato | 6.5%
#3 | n04596742 wok | 6.2%
```

■図20 図19を見たAIの出した回答

こうした状況では、我が国でAIに関連するビジネスを立ち上げようとする場合、必要な画像を全て誰かが用意しなければならず、しかもそれは数百万枚に及ぶ膨大な分類となるために大変非効率的であり、早急に解決すべき問題と言える。

### 2.3.5.2 共有モデル

#### (1)既存の学習済みニューラルネットワークモデル

高性能なAIを作り出すもう一つの方法は、学習済みモデルを活用することである。学習済みモデルとは、既に十分な時間、膨大な学習データセットを使用して学習（訓練）させたもので、既に米国ではカリフォルニア大学バークレー校の画像及び学習センター（Berkeley Vision and Learning Center; BVLC）によるモデル動物園（Model Zoo）で、多数の学習済みモデル<sup>46</sup>が公開されている。Model Zooで公開されている主要な学習済みモデルを表36に示す。

※46

43種類が公開されている（2017年3月現在）。

表36 BVLCのModel Zooで公開されている学習済みモデルの例<sup>47</sup>

| モデル名                               | 説明  |
|------------------------------------|---|
| AlexNet                            | 最初期の画像認識用ニューラルネットワークモデル                                 |
| GoogLeNet                          | Googleが開発した画像認識用ニューラルネットワークをBVLCが独自に学習したもの              |
| VGG-19                             | ILSVRC2012のデータにおいて7.5%のTop5エラー率を達成した画像認識用ニューラルネットワークモデル |
| Places CNN                         | マサチューセッツ工科大学が開発・学習した写真から場所を推定するニューラルネットワークモデル           |
| FCNs                               | セマンティックセグメンテーションを行う完全畳み込みネットワーク                         |
| Age and Gender                     | 年齢及び性別を認識するニューラルネットワークモデル                               |
| GoogLeNet_cars                     | GoogLeNetを利用して自動車の種別を認識するニューラルネットワークモデル                 |
| SegNet                             | セマンティックセグメンテーション用のニューラルネットワークモデル                        |
| Holistically-Nested Edge Detection | 輪郭検出用のニューラルネットワークモデル                                    |
| Video2Text_VGG                     | 動画からテキストを自動生成するニューラルネットワークモデル                           |
| VGG Face                           | VGGを使用した顔検出用のニューラルネットワークモデル                             |
| Emotion Recognition                | 顔画像から感情を認識するニューラルネットワークモデル                              |
| ResNets                            | Microsoftが開発した152層に及ぶニューラルネットワークモデル                     |
| Deep Hand                          | 手の形を認識するニューラルネットワークモデル                                  |
| DeepYeast                          | 顕微鏡写真から体内細胞を認識するニューラルネットワークモデル                          |

高性能なAIを作るためには、こうした公開されているモデルを元に、転移学習（ファインチューニングと呼ばれる）を独自のデータセットに対して適用するのが実用上効率的であることが知られている。

BVLCのModel Zooでは、BVLC自身が学習した学習済みモデルも公開しているが、MITやMicrosoftなど、様々な研究機関が独自に学習させた学習済みモデルが多数公開されており、事実上のディープラーニング研究者たちのハブとなる役割を果たしている。

## (2)BVLC Model Zooの問題点

当初、ディープラーニングの研究者にとってBVLCのModel Zooは非常に大きな存在感を示していたが、時間の経過とともに問題が生じてきた。

BVLC Model Zooで公開されている学習済みモデルは、BVLCが開発したディープラーニングツールである「Caffe」用のモデルに限られる。しかしながら、Caffeの設計が必ずしも最新の理論に追いついていないため、標準の状態では高度なモデルを表現することができない。そのため、Model Zooに公開されている学習済みモデルのうちいくつかは、改良版Caffeの実装とセットで公開されている。

この状況は、学習済みモデルの利活用を考える場合に望ましい状態とは言えない。研究者は試したい学習済みモデルに合わせて、それぞれ別個に独自の改良が施されたCaffe実装をインストールする必要があり、運用性が低いという問題がある。また、共有学習済みモデルは共有データセットで学習されたものがほとんどであり、共有データセットが欧米の価値観に依っていることから、共有学習済みモデルもまた、その

※47

“ Model Zoo, ” GitHub Website <<https://github.com/BVLC/caffe/wiki/Model-Zoo>>より作成。

ままでは国内での運用に適さないという問題もある。

### 2.3.5.3 AIが利活用されるためにこれから取り組むべきこと

以上で述べたように、現在流通している共有データセットの多くは海外製であり、日本国内での運用に適さない場合が多いという問題と、それを用いて学習したAIのビジネスへの適用については、その判断が各企業に委ねられているという現状がある。また、共有データセットが欧米向けであるがゆえに、国内での利活用を行うためにはそのままでは共有データセット、共有モデルともに使用しづらいという問題がある。

このような点を踏まえた方策として、知的財産戦略本部「新たな情報財検討委員会」<sup>48</sup>における議論として、公的AI用HPC（High Performance Computer）環境の整備と併せて以下の4点を実現し、民間企業からも一定のルールの下、共有データセットへの自社データの公開が可能で、データを公開した民間企業も利益を得ることができるような仕組みがあると望ましいとの議論がなされている。

- (1) 日本独自の言語、風土や文化を中心とした共有データセットを作り、企業や研究者が利用できる環境の整備
- (2) 上記のデータセットを学習した共有モデルを頒布できる環境の整備
- (3) 分散学習を可能とするような国内で取得されたビッグデータの集積基地としての環境の整備
- (4) 共有モデルや共有データセットにおいて特定のフレームワークに限定されることなく相互運用可能なニューラルネットワークのデータ構造の検討

このような公的AI用HPC環境については、海外に比べてGPU資源への民間投資があまり活発ではない我が国における現状に鑑みて、民間でのAI利活用を後押しすることを目的に、世界最大規模のGPUファームの整備がなされることが望ましいとされている。具体的には次のような点に配慮がなされ、より広く多くの人々が仮説の検証を行うことが可能となるよう、手軽に利用可能な強力な計算資源として整備がなされることが望ましいとされている。具体的には、①グラフィカルユーザーインターフェース（GUI）等でディープラーニングの専門家でなくても仮説検証ができること、②仮説の検証や有望なハイパーパラメータを得られたら、速やかに民間のGPUクラウドへ移行し、業務への活用が可能になること、③日本独自のデータセットや共有モデルを集積・頒布する情報基盤となること、といった点が挙げられている。

また、上記の環境には単に計算資源とそれを活用するためのGUIを用意するだけでなく、優れたAIが育つために国内外の情報やセンサネットワークから得られたビッグデータを集積し、学習する環境を整備することが期待される。実用的かつ優れたAIを学習するには、適切かつ十分なデータが必要となるためである。このような観点からは、次のようなデータの集積がなされると望ましいとされている。具体的には、①公的に配信可能な知財処理済のデータセット、②公的な配信ができない著作物などのデータ（著作権法47条の7項に基づく情報分析のためのデータ）、③センサネットワークから得られたプライバシー情報を含むビッグデータ、といったデータが挙げられている。

これらのデータについて、②と③については著作権やプライバシーに配慮して、書き込み専用とし、直接の読み出しはできないようになっていくことが望ましい。特定の条件を満たすニューラルネットワーク

※48

「新たな情報財検討委員会 報告書」首相官邸ウェブサイト  
<[http://www.kantei.go.jp/jp/singi/titeki2/tyousakai/kensho\\_hyoka\\_kikaku/2017/johozai/houkokusho.pdf](http://www.kantei.go.jp/jp/singi/titeki2/tyousakai/kensho_hyoka_kikaku/2017/johozai/houkokusho.pdf)>

を通した復元不可能な特徴ベクトルの形でのみ利用することができるようにすることで、知的財産や隣接権、プライバシーを守りつつ他に類を見ない強力な学習用データを集積・利活用できることが期待される。これは世界的に見ても類を見ない試みであり、実現すれば我が国のAI開発が他国に比べて大きなアドバンテージを持つことが期待される。

## 2.4 企業における利用状況

国内外の人工知能（AI）に関わる利用実態を把握するために、以下のとおりアンケート調査を実施した。

### 2.4.1 アンケート調査概要

#### 2.4.1.1 国内アンケート調査概要

国内企業におけるAI利用状況及びその変化の動向、取組を進める上での課題の把握等を目的として民間企業宛てにアンケート調査を行った。調査の概要は以下のとおりである。

- 調査方法：郵送調査
- 調査期間：2017年3月
- 調査対象：上場企業 3,787企業
- 業種区分：情報処理実態調査の調査業種26業種
- 回収数：有効回収数 296企業（有効回収率 7.8%）
- 主な調査項目：
  - AIに関する認識
  - AIに関する取組状況
  - AIの推進体制やデータ整備の状況
  - AIに関する投資状況、等

#### 2.4.1.2 海外アンケート調査概要

海外企業に対しても国内企業と同様の目的でアンケート調査を実施した。なお、海外アンケート調査は、ウェブモニタを通じて回答を得た。調査の概要は以下のとおりである。

- 調査方法：ウェブアンケート調査
- 調査時期：2017年3月
- 対象国：米国、英国、ドイツ
- 対象者：民間企業に勤めるマネジメント層
- 回収数：各国311件（日本の上場企業の従業員規模比率をもとに割り付け<sup>1</sup>）
- 主な調査項目：国内企業アンケート調査と同様

---

※1

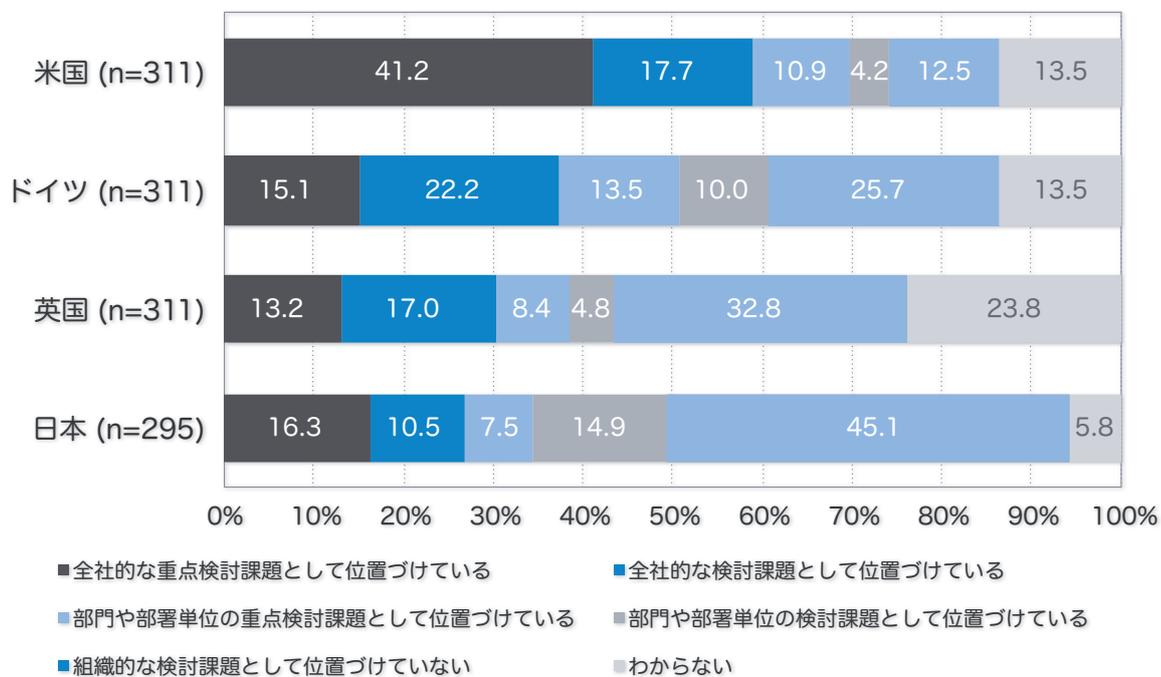
各国の回収数は従業員規模別に、1,000人超：130件／500人～1,000人未満：57件／100～500人未満：94件／100人未満：30件。

## 2.4.2 アンケート調査結果

### 2.4.2.1 AI利用で先行する米国

AIに関する取組を組織的課題として位置付けているかを尋ねたところ、**図21**のとおり我が国では、全社レベルの検討課題（26.8%）又は部署レベルの検討課題（22.4%）との結果となり、合わせて49.2%の企業がAIを自社の課題として認識している。一方で、45.1%の企業が組織的な検討課題として位置付けていないと回答している。一方、米国では全社レベルの検討課題（58.9%）、部署レベルの検討課題（15.1%）とAIへの取組を企業全体に関わる課題として認識しており、合わせて74.0%の企業が組織的な検討課題として位置づけるなど、課題認識に大きな差異が見られた。

また、我が国では、全社的な課題として位置付けたり、取組を進める企業が、ドイツ、英国と同程度存在するが、検討も開始していない企業が多いため、国内における企業間での取組格差が今後拡大することが懸念される。

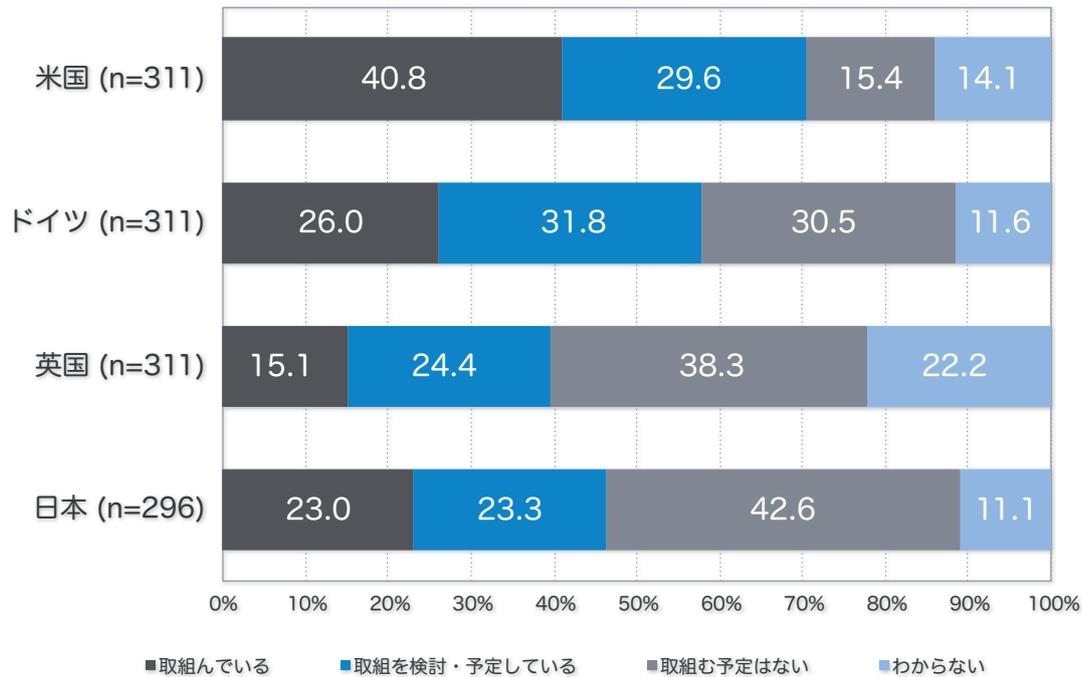


■ 図21 AIに関わる課題認識<sup>2</sup>

※2

日本企業の有効回答数は295件。米、独、英は有効回答数311件。

また、AIの取組状況を尋ねたところ、図22のとおり我が国では、取り組んでいる（23.0%）又は取組を検討・予定している（23.3%）との結果となり、合わせて46.3%の企業がAIへの取組を実施又は予定している。一方で、米国では、取り組んでいる（40.8%）又は取組を検討・予定している（29.6%）との結果となり、合わせて70.4%の企業がAIへの取組を実施又は予定しており、課題認識に加えて取組状況でも差異が見られる。



■図22 AIの取組状況<sup>※3</sup>

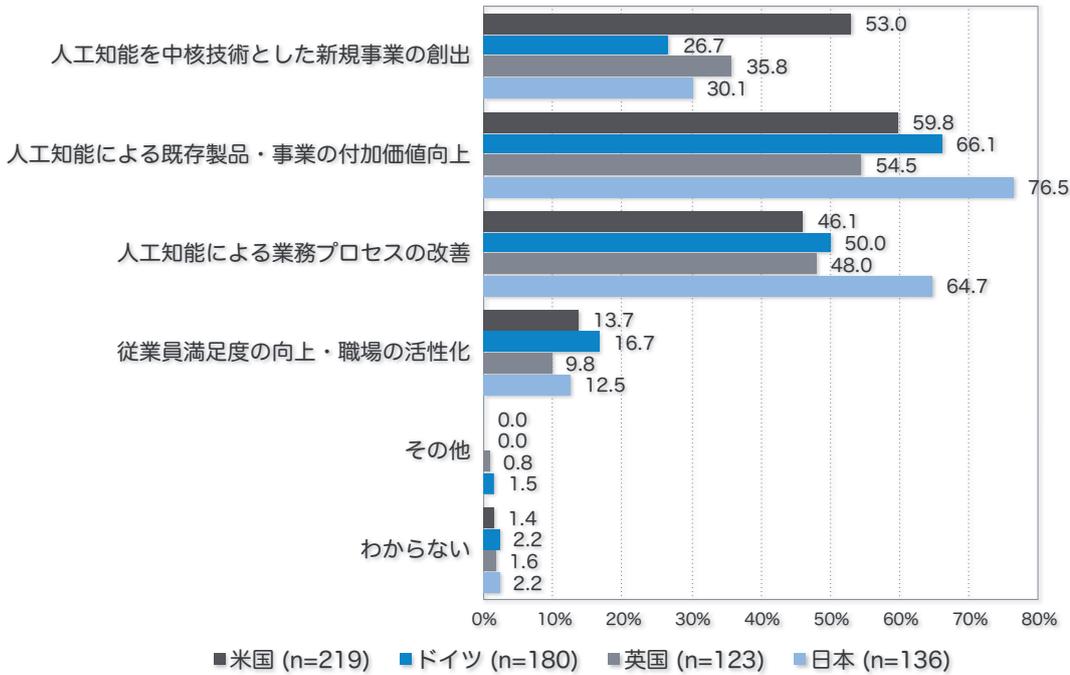
※3

日本企業の有効回答数は296件。米、独、英は有効回答数311件。

### 2.4.2.2 新規事業創出にAIを利用する米国と既存業務への利用を進める日本

AIに取り組んでいる又は取組を検討・予定していると回答した企業に対して取組目的を尋ねたところ、**図23**のとおり、我が国では既存製品・事業の付加価値向上（76.5%）、業務プロセスの改善（64.7%）、新規事業の創出（30.1%）の結果となり、一般的なIT投資の目的と比較しても、新規事業の創出や製品・事業への付加価値向上を目的とする割合が高い結果となった。

一方、米国では新規事業の創出が53.0%と回答企業の半数を占め、日本、ドイツ、英国と比較して、より攻めを目的としたAI利用に注力している様子がうかがえる。



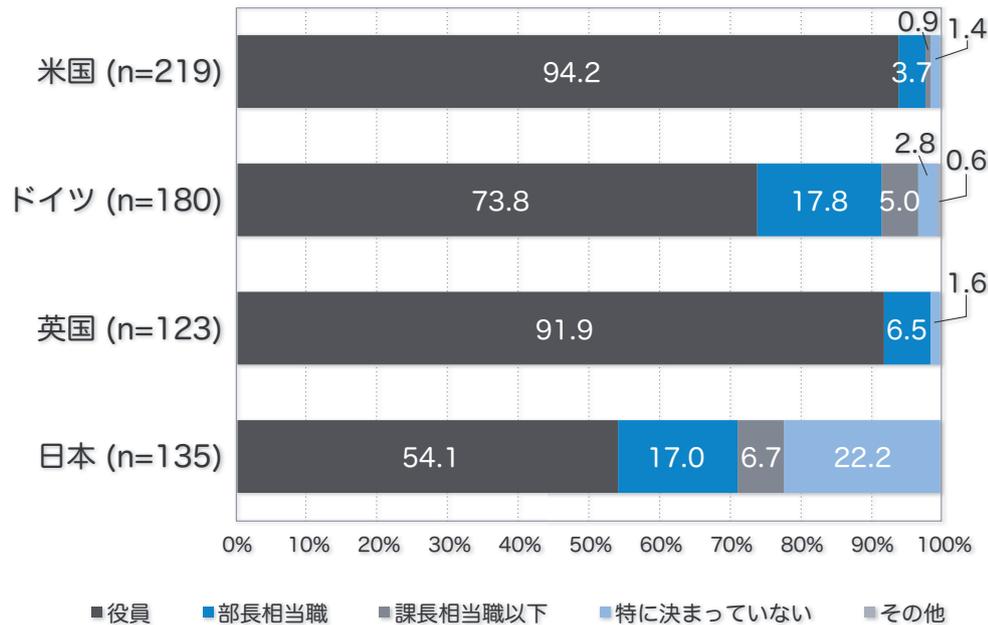
■図23 AIに関する取組目的\*

※4  
AIの取組状況(図22)で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。企業が日本企業の有効回答数は136件。米、独、英の有効回答数はそれぞれ219件、180件、123件。

※5  
AIの取組状況(図22)で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。企業が日本企業の有効回答数は135件。米、独、英の有効回答数はそれぞれ219件、180件、123件。

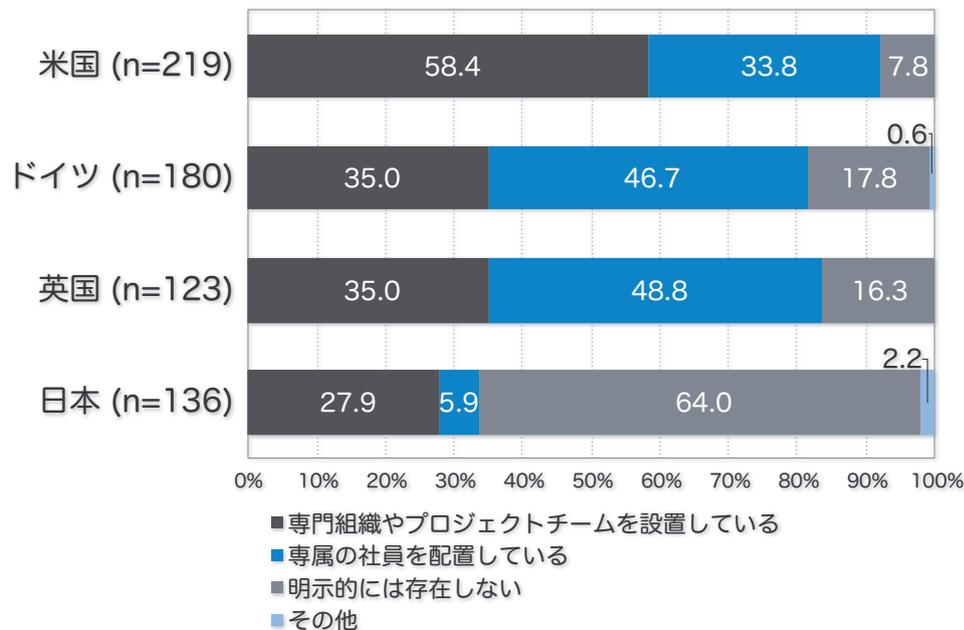
### 2.4.2.3 推進組織・体制整備の遅れ

AIに関する取組を主導する責任者を尋ねたところ、図24のとおり我が国では54.1%の企業において役員が主導している一方で、米国では、94.2%の企業、ドイツでは73.8%の企業、英国では91.9%の企業において役員が主導しているとの結果であった。



■図24 AIに関する取組を主導する責任者<sup>5</sup>

また、AIを推進する専門組織・専属要員を尋ねたところ、図25のとおり、専門組織やプロジェクトチームを設置している企業の割合が、我が国では33.8%であり、米国 (92.2%)、ドイツ (81.7%)、英国 (83.8%) と比較して遅れている状況にある。



■図25 AIに関する専門組織・専属要員の設置状況<sup>6</sup>

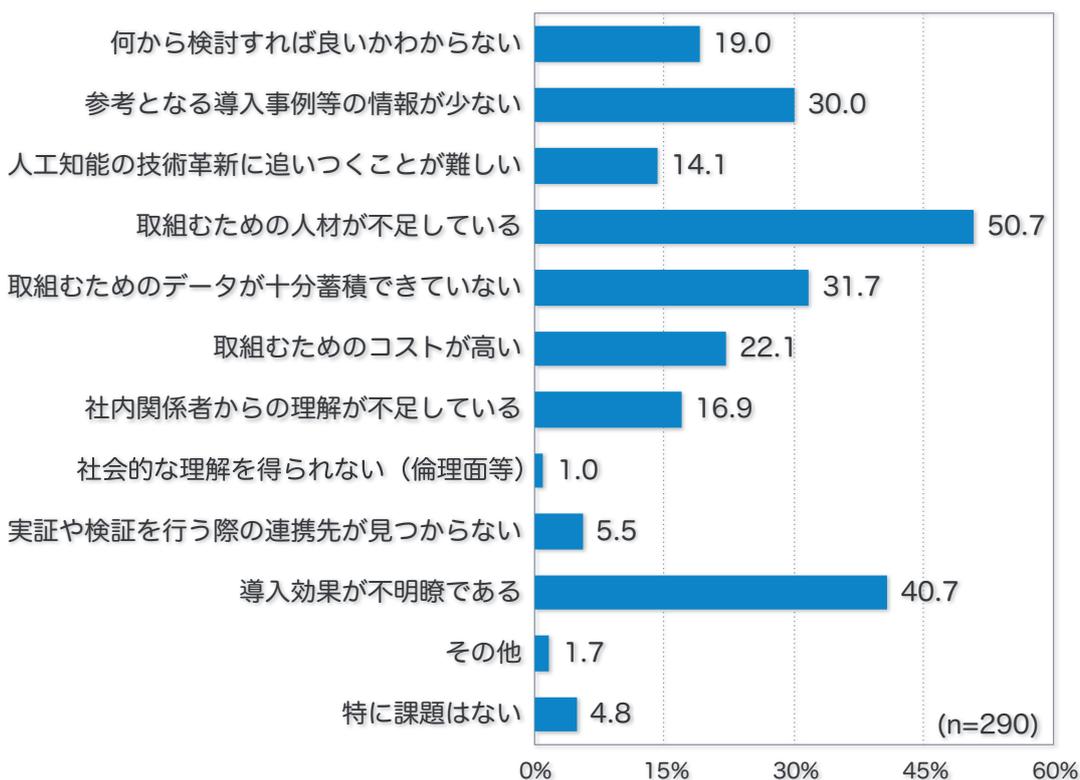
※6

AIの取組状況(図22)で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。企業が日本企業の有効回答数は136件。米、独、英の有効回答数はそれぞれ219件、180件、123件。

#### 2.4.2.4 取組を進める上での課題

AIに関する取組を進める上での課題を尋ねたところ、図26のとおり、日本企業においては、取り組むための人材が不足している（50.7%）が最も多く、次いで導入効果が不明瞭である（40.7%）、取り組むためのデータが十分蓄積できていない（31.7%）、参考となる導入事例等の情報が少ない（30.0%）となった。

2.3.1項で示したとおり、産業界におけるAIに関わる人材育成の重要性の認識の高まりから、企業と大学等が連携して人材育成を図る事例も現れている。だが、50%を超える企業が人材不足を感じている実態を踏まえると、大学でAIやデータサイエンスを学んだ人材の輩出を促すとともに、企業に勤める人材が大学でAIを学び直すリカレント教育等を通じた、企業人材の育成の強化も重要と考えられる。



■ 図26 AIに関する取組を進める上での課題<sup>7</sup>

※7

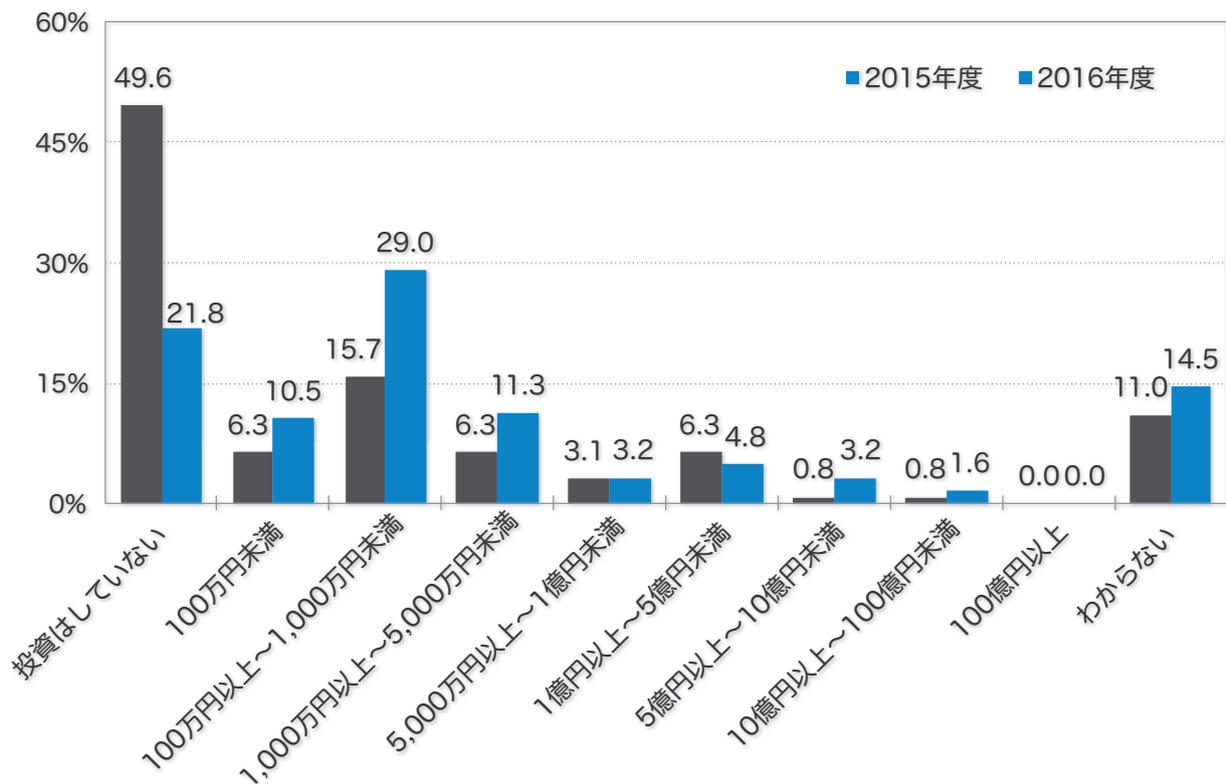
日本企業の有効回答数は290件。

## 2.5 投資規模・市場規模

### 2.5.1 投資規模

国内企業へのアンケート調査結果（概要は2.4.1項参照）において、人工知能（AI）に関する投資金額を尋ねた<sup>1</sup>ところ、我が国では2015年には投資したと回答した企業は50.4%であったが、2016年には78.2%と増加し、投資金額も全体的に増加傾向となっている。

2.4節で示したとおり、AIへの取組で米国、ドイツ、英国に後塵を拝しているものの、投資を開始し、取組を加速させている様子が見えてくる。

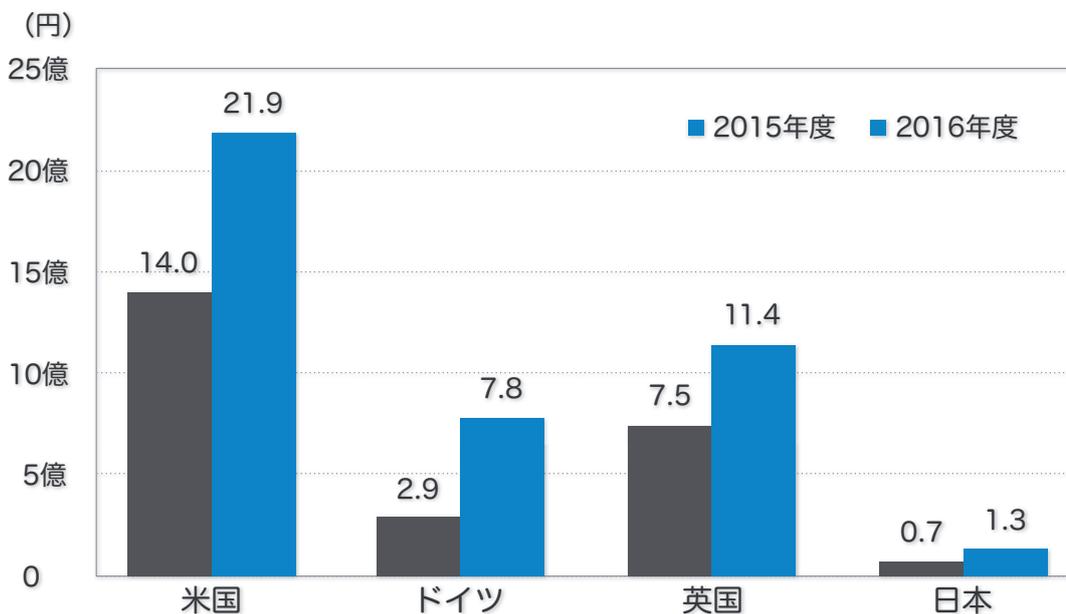


■ 図27 AIに関する投資規模

※1

AIの取組状況(図22)で「取組んでいる」又は「取組を検討・予定している」と回答した企業を対象に、投資金額を尋ねた。2015年度の投資金額は127社、2016年度の投資金額は124社から回答を得た。

また、国内アンケート調査における回答企業の投資総額<sup>2</sup>を推計すると、2015年度で88.9億円、2016年度で約161.2億円であり、一企業当たりの投資金額はそれぞれ約0.7億円、約1.3億円であった<sup>3</sup>。一企業当たりの投資金額を海外と比較すると、図28のとおり米国の投資金額が高く、次いで英国、ドイツの順であり、我が国は比較的小規模な投資を行う企業が多い傾向となった。



■図28 各国の一企業当たりの投資金額の推計<sup>2</sup>

先行する企業においても、現在のAI利用の多くは投資段階であり、今後の実ビジネスへのAIを適用する中で投資を回収していくものと想定され、現在の投資規模の格差が、将来的に企業間の売上や利益に直結するAI利用の格差が生じる懸念もある。

※2  
回答を得た国内企業の投資金額の合計値（2015年度は127社、2016年度は124社の投資金額の合計）。

※3  
投資総額及び一企業当たりの投資金額は、回答された選択肢の中間値を回答企業の投資金額と見なして推計した。  
 ・100万円未満＝50万円  
 ・100万円以上～1,000万円未満＝550万円  
 ・1,000万円以上～5,000万円未満＝3,000万円  
 ・5,000万円以上～1億円未満＝7,500万円  
 ・1億円以上～5億円未満＝3億円  
 ・5億円以上～10億円未満＝7億5,000万円  
 ・10億円以上～100億円未満＝55億円  
 ・100億円以上＝200億円

## 2.5.2 市場規模

AIの技術進展を背景にAIの産業応用が広がりつつある。市場規模に関する既存情報に共通するポイントとして、「AI市場の成長が著しく、様々な産業分野での応用が期待される」、「AIに関わる製品・サービスの供給側の市場と比較して、導入側の経済効果は非常に大きくなる」ことが挙げられる。

### 2.5.2.1 AIに関わる製品・サービス市場

AIに関わる製品やサービス市場推計は多数行われているが、対象とするAIの範囲が多様であるため、市場規模には大きな差異が生じている。

富士キメラ総研[1]によると、2015～2030年までの国内におけるAIのシステムやサービスの売上市場規模は図29のとおり2015年度の約1,500億円から2020年度の約1兆20億円の伸長と見込まれており、2030年度には2兆1,200億円規模に達する見込みである。

システム・サービスの区別の市場規模をみると、2015年度は大手企業における個別受託開発が中心であったため、システム・インテグレーション及びハードウェアが大きな割合を占める（前者の構成比は59.7%、後者は15.0%）一方、市場の伸び率（CAGR）みると、ソフトウェア（77.0%）、IaaS/PaaS（79.0%）、SaaS（52.9%）とAIを搭載したソフトウェアやSaaSの提供やIaaS/PaaSをインフラとしたAI環境の構築が拡大するとみられる。

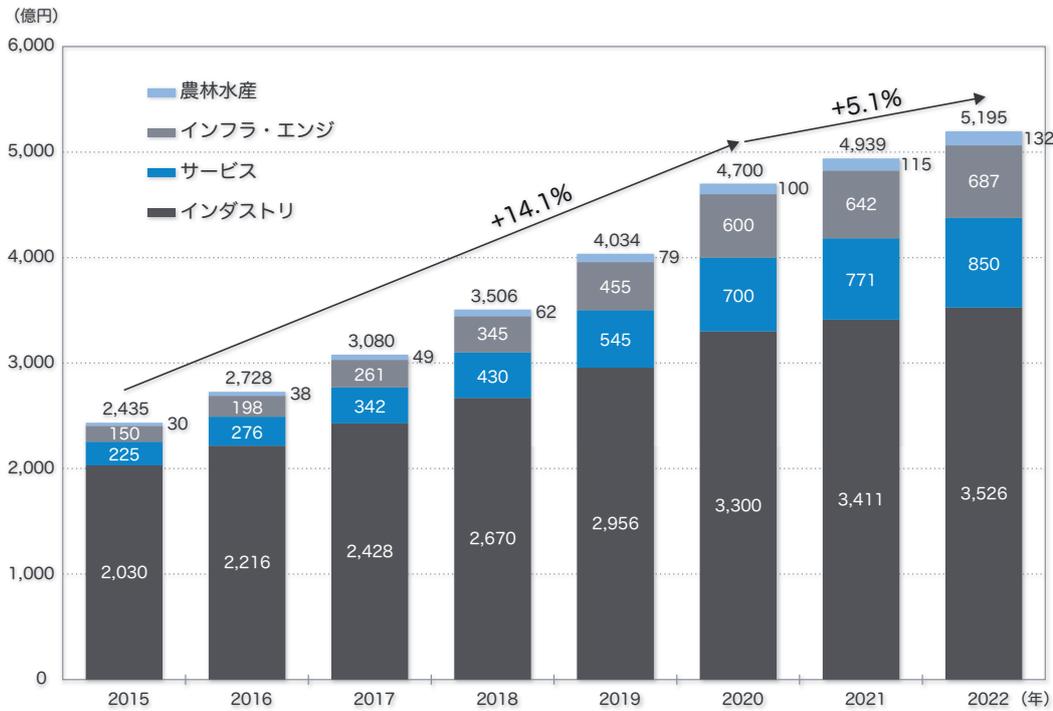
同市場は“直接面接を基本としたヒアリング取材及び同社データベースや関連団体による基礎情報などを活用することにより総合的かつ客観的な調査・分析”により推計し、対象とする市場は図29のとおりAIに関わるシステム/サービスである。



■ 図29 AI市場(左)とシステム別の市場(右)<sup>4</sup>

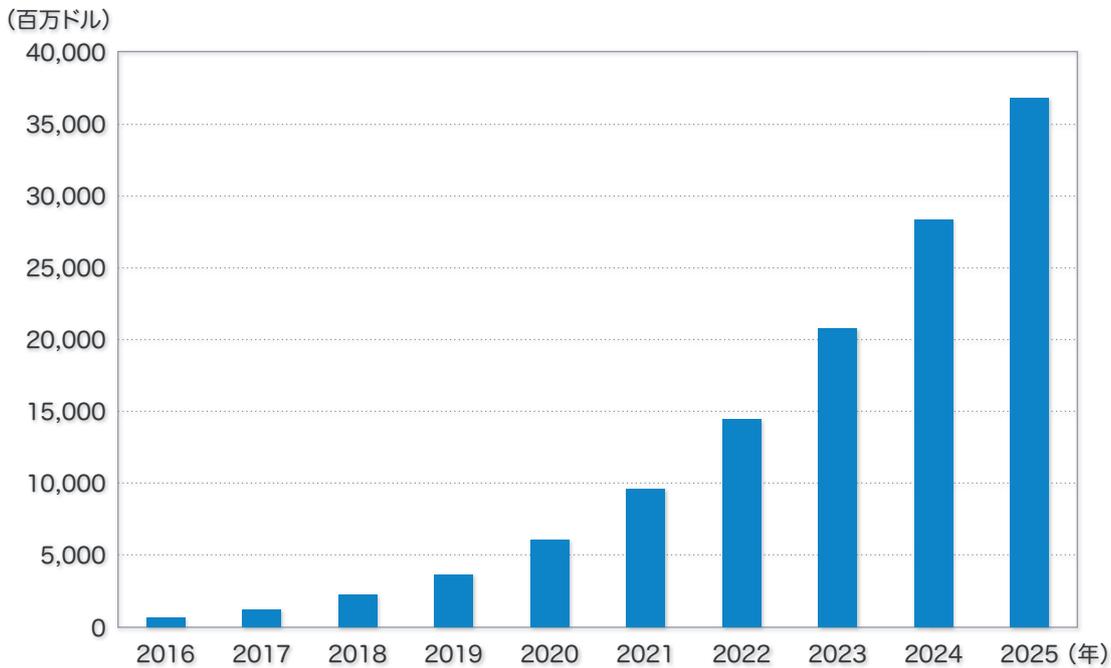
野村総合研究所は「センサ、駆動系、知能・制御系を有した機械装置を含むシステムのうちBtoBに利用されるロボット市場」を対象として、2015年から2022年までの国内市場規模を推計している。図30のとおり2015年には2,435億円の市場が、2022年に5,195億円と倍増する見込みであり、そのうち8割はインダストリ（産業）分野が占める。

※4  
文献[1]より作成。



■図30 BtoBロボット市場<sup>5</sup>

Tractica（米国）は、2016年から2025年までのBtoB及びBtoCのAI製品・サービス世界市場を推計している。図31のとおり2016年の6億4,370万ドルから2025年には368億ドルと約60倍に拡大する見込みである。



■図31 AI製品・サービス世界市場<sup>6</sup>

※5  
 「ITナビゲーター2017年版」これからICT・メディア市場で何が起ころのか.2022年までの市場トレンドを予測」第243回NRIメディアフォーラム <<http://www.nri.com/jp/event/mediaforum/2016/pdf/forum243.pdf>>

※6  
 “ Artificial Intelligence Revenue to Reach \$36.8 Billion Worldwide by 2025, ” Tractica Website <<https://www.tractica.com/newsroom/press-releases/artificial-intelligence-revenue-to-reach-36-8-billion-worldwide-by-2025/>>

IDC（米国）はBtoC及びBtoBの世界ロボット市場の推計を行っている<sup>7</sup>。同推計では、ロボットシステム、システムハードウェア、ソフトウェア、ロボット関連サービス、そしてアフターマーケットに対する支出額を推計の対象としている。2016年の世界史上における支出額は915億ドル規模であり、2020年には1,880億ドルに達する見込みである。国内市場は、2016年に104億ドルであり、2020年には2.3倍に拡大する見込みとしている。

■表37 AIに関わる製品・サービス市場規模に関する既存情報<sup>8</sup>

| 推計内容<br>(実施機関)               | 推計の対象   | 対象国・<br>対象地域 | 市場規模                 |                     |
|------------------------------|---|--------------|----------------------|---------------------|
|                              |   |              | 基準年                  | 予測年                 |
| 2016人工知能ビジネス総調査<br>(富士キメラ総研) | AIのシステムやサービスの売上市場を対象としている。具体的には、AI環境を構築するためのシステムインテグレーション(SI)、AI環境を支えるハードウェア、ソフトウェア、クラウド、AIを搭載したアプリケーションの研究・開発・提供などが含まれる。 | 日本           | 約1,500億円<br>(2015年度) | 約1兆20億円<br>(2020年度) |
| BtoBロボット市場<br>(野村総合研究所)      | センサ、駆動系、知能・制御系を有した機械装置を含むシステムのうちBtoBに利用されるロボット市場を対象としている。   | 日本           | 2,435億円<br>(2015年)   | 5,195億円<br>(2022年)  |
| AI製品・サービス世界市場<br>(Tractica)  | AI製品・サービス世界市場を対象としている。  | 世界           | 約6.4億ドル<br>(2016年)   | 368億ドル<br>(2020年)   |
| BtoC及びBtoBの世界ロボット市場<br>(IDC) | BtoC及びBtoBの世界ロボット市場を対象としている。具体的には、ロボットシステム、システムハードウェア、ソフトウェア、ロボット関連サービス、そしてアフターマーケットに対する支出額が対象である。                        | 世界           | 915億ドル<br>(2016年)    | 1,880億ドル<br>(2020年) |
|                              |   | 日本           | 104億ドル<br>(2016年)    | 約239億ドル<br>(2020年)  |

### 2.5.2.2 AI利用による経済効果

業務効率化や生産性の向上など、AIの利用により生みだされる経済効果の試算や推計も行われている(表38)。前節で示したAIに関わる製品・サービスの供給市場と比較して、AI利用による経済効果は大きい傾向にある。

EY総合研究所は、2015年から2030年までの国内における経済効果を推計<sup>9</sup>している。同推計は、ニーズ(経済的・社会的ニーズの強さ、対象データの性質)・シーズ(技術水準・人材、データの取得可能性)・環境(法令・規制、リスク許容度)を考慮し、統計的・確率的手法を利用したAI(機械学習・ディープラーニングを含む)が今後もたらす効果(市場規模、生産性向上・コスト削減を含む)を対象としている。2015年の国内の経済効果は約3.7兆円であり、2020年には約23.6兆円に達する見込みである。

※7  
「世界ロボティクス関連市場予測を発表」 IDC Japan Website  
<<http://www.idcjapan.co.jp/Press/Current/20170124Apr.html>>。

※8  
各種公表情報より作成。

※9  
「人工知能が経営にもたらす「創造」と「破壊」」 EY総合研究所ウェブサイト  
<<https://eyi.eyjapan.jp/knowledge/future-society-and-industry/pdf/2015-09-15.pdf>>

総務省のAIネットワーク化検討会は、有識者へのヒアリングを基に、生産関数法により産業へのAIネットワークシステムの導入による効率化や製品・サービスの高付加価値化による生産高の増加を推計<sup>10</sup>している。平均ケースでは、2025年に87兆円に、最大ケースでは116兆円に達するとしている。

三菱総合研究所は2017年1月に、AIによる国内総生産（GDP）への効果を発表している。この結果をみると2030年に50兆円GDPを押し上げる見通しであり、AIの進歩に伴う自動走行車の普及や個人の健康状態や行動履歴を活用する新たな産業が原動力になり、経済成長率を年率0.6%押し上げると予測している<sup>11</sup>。同試算は、ものづくりや流通、金融、サービスなど九つの産業分野を対象として試算した結果である。

Bank of America Merrill Lynch（米国）はAI及びロボティクスに関する市場レポート“The global robots & artificial intelligence market”<sup>12</sup>を発表し、世界市場におけるAIソリューションによる潜在的効果を発表している。AIのソリューションの売上、製造業・ヘルスケアのコスト削減効果、雇用削減効果、知的活動の自動化による効果等が含まれ、2016年に約6.38兆円、2020年に約16.83兆円規模に達する見込みである。

■表38 AI利用による経済効果に関する既存情報<sup>13</sup>

| 推計内容<br>(実施機関)  | 推計の対象   | 対象国 | 効果                 |  |
|---|---|-----|--------------------|--|
|   |   |     | 基準年                | 予測年  |
| AIによる産業別の経済効果<br>(EY総合研究所)                                      | 統計的・確率的手法を利用したAI(機械学習・ディープラーニングを含む)が今後もたらす効果(市場規模、生産性向上・コスト削減を含む)を対象としている。              | 日本  | 約3.7兆円<br>(2015年)  | 約23.6兆円<br>(2020年)                             |
| AIネットワーク化による<br>経済効果(総務省)                                       | 産業へのAIネットワークシステムの導入による効率化や、製品・サービスの高付加価値化による生産高の増加を対象としている。                             | 日本  | —                  | [平均ケース]<br>87兆円(2025年)<br>[最大ケース]<br>116兆円(同上) |
| AIによる国内総生産(GDP)<br>押し上げ効果<br>(三菱総合研究所)                          | ものづくり、流通、金融、サービスなど九つの産業分野を対象にAI利用による年率経済成長率の押し上げ効果を推計している。                              | 日本  | —                  | 50兆円<br>(2030年)                                |
| AIソリューションによる<br>潜在的な経済効果<br>( Bank of America Merrill<br>Lynch) | 世界市場において、AIが産業に与える影響を推計している。ソリューションの売上、製造業・ヘルスケアのコスト削減効果、雇用削減効果、知的活動の自動化による効果等を対象としている。 | 世界  | 約6.38兆円<br>(2016年) | 約16.83兆円<br>(2020年)                            |

## 参考文献

[1] 富士キメラ総研『2016 人工知能ビジネス総調査』, 2016.

※10  
[[AIネットワーク化検討会議] 中間報告書の公表] 総務省ウェブサイト <[http://www.soumu.go.jp/menu\\_news/s-news/01iicp01\\_02000049.html](http://www.soumu.go.jp/menu_news/s-news/01iicp01_02000049.html)>

※11  
各種報道情報。

※12  
“Robot Revolution . Global Robot & AI Primer” Bank of America Merrill Lynch Website <[https://www.bofam.com/content/dam/boamlimages/documents/PDFs/robotics\\_and\\_ai\\_condensed\\_primer.pdf](https://www.bofam.com/content/dam/boamlimages/documents/PDFs/robotics_and_ai_condensed_primer.pdf)>

※13  
各種公表情報より作成。

## 2.6 今後の展望

海外の先行する人工知能（AI）利用企業では、検索サービスやSNS、コミュニケーションツールなどのインターネット空間での活動から得られるデータに対してAI適用を進めている。特にインターネットサービスの各分野で圧倒的な世界シェアを誇るGoogle、Amazon、Facebook等の米国企業や中国の巨大なインターネット市場を牽引するBaidu、Alibaba、Tencentなどの海外の大手IT企業は、インターネット空間のビッグデータを基にAI技術を磨き上げながらサービス開発を進めている。

これらの企業は、2.2.1項で述べたとおり、研究成果として論文のみならず学習済みモデルや学習用データを合わせて公開することにより、技術開発を急速に進めている。そして、サービスのインターフェースにAIを組み込むことで、消費者との接点を押さえて多様なデータを独占し、AI関連市場における競争優位を築くための取組を加速させている。スピード感を持って市場にサービスを提供し、インターネット空間でのAI利用で高いシェアを獲得しているのだ。

一方で、IoTの進展等により、実空間のデータを容易に入手できるようになった。自動車から得られる走行データ、医療健康データ、工場設備の稼働データ等、個人や企業の実世界における活動から得られるデータの利用へとAIの適用領域が拡大しつつあり、今後の競争領域となると見込まれる。リアル空間の産業へのAI適用は、産業領域の深い知識に基づいて獲得されたデータやアルゴリズムが不可欠である。そのため、製造業等が保有するリアル空間のデータや、品質・安全性の追求、AI（ソフトウェア）がどこまでの機能を担い、ハードウェアがどこまでの機能を担うかなどをすり合わせるノウハウなど、日本が各産業領域で保有する強みを活かして、実空間における競争優位を築くことが期待される。

# 富山和彦氏

株式会社経営共創基盤 代表取締役CEO

## (1) はじめに

人工知能 (AI)、IoT、ビッグデータあるいは第4次産業革命というバズワードが毎日飛び交う今日この頃である。

こうしたバズワードが、産業的、更には経営的に、本当はどのような意味を持っているのであろうか。AI技術そのものの先端性と、ビジネス上の「儲け」の間には、ほとんど相関はない。技術をビジネスの実用に活かすためには、まずはビジネスセンスが重要で、AI技術に関しては、その観点から世の中に存在する様々な技術から必要十分なものを選ぶ選択力、そして当該技術を活用してビジネス化する応用開発力、複合的開発力こそが決め手となる。AIを道具として「経営」できなくては「稼ぐ力」には結びつかないのである。AI、IoT革命期を経営することの本質的な課題、求められる能力とは何かについて論じたい。

## (2) デジタル革命によって「バーチャルの世界」から「リアルの世界」へ

### 1) 最終局面を迎えたデジタル革命

AIやIoTによって、産業構造が大きく変わろうとしている。発電設備や航空機エンジンのビジネスでは、ビッグデータやIoTの活用によって、「モノ売り」ビジネスから安定で高効率なオペレーションを提供する「サービス売り」ビジネスに転換しつつある。建機の世界では、無人運転技術を使って鉱山の採掘サービスを請け負うビジネスモデルを急速に広げている。自動車産業においても、ネット技術を基盤にしたシェアリングサービスの普及と、自動運転技術の発達で、自動車という「モノ」を作って売ることに価値がある産業構造から、人々に安全で便利なモビリティ（移動手段）サービスを提供する「コト」型産業へと構造転換が起きる可能性が生まれている。

今の状況は、1980年代から続く、いわゆる「デジタル革命」の最終段階といえる。「革命」と呼ぶのは、主役が入れ替わり、産業構造、競争構造がドラスティックに変化することを意味し、「最終段階」とは、革命的な影響が及ぶ範囲が非常に広い領域、ほぼ全産業に及ぶ可能性があるということである。

デジタル革命の第1期はコンピュータ産業におけるダウンサイジングと水平分業革命の時代であった。この覇者はMicrosoftとIntelで、IBMなどの伝統的なコンピュータ企業を追い詰めた。第2期が1990年代以降のユビキタス革命、つまりインターネットとモバイル通信革命によって、いつでもどこでも情報にアクセスできるようになったことである。通信機器やオーディオ・ビジュアルの世界で主役交代劇が繰り返された。ソニーに変わりAppleが台頭し、Google、Amazon、Facebookといったベンチャー企業が巨大なグローバル・プラットフォーマーに成長した。従来とは全く異質のプレイヤーたちが時代の覇者となり、BtoCのAV機器・通信関連産業を破壊的に変えたのである。そして、現在、AI、IoT、あるいはビッグデータの利用によって起きているのが、デジタル革命の第3期である。

### 2) バーチャルからリアルへ

今までのデジタル技術によるブレークスルーは、基本的に情報通信や情報処理といった、バーチャルでサイバーな世界で劇的に新たな可能性を生み、生産性を飛躍させた。バーチャルな空間、サイバー空間に新たなビジネス、産業、競争の構図を作り出したのである。その一方で、熱と質量、モノや人間の「現物」

が関わるリアルな世界では、そのインパクトはある特定領域に限られた。

しかし今回、IoT化の進展とAI技術の急速な進化によって、デジタル革命で実現する機能がリアルでリアルな世界に滲み出し、そこでも破壊的な影響を及ぼす可能性がある。主戦場はソフトの世界やネットのバーチャルな世界ではなく、よりリアルでフィジカルな領域、すなわち自動運転や医療、介護のような人の命に関わる「シリアス」なビジネス領域「Sの世界」に移る。つまり破壊的なイノベーションによって、自動車などの製造業はもとより、金融、小売、飲食、運輸、観光、建設、医療、介護、更には農業に至るまで、全ての産業で、産業構造、競争構造が激変し、活躍する企業の顔触れも大きく入れ替わってしまう可能性がある。その影響が従来よりもはるかに広い範囲に及んだ時、そこで活動している既存の企業、そして個人は大きなピンチとチャンスに同時に遭遇することになる。

### 3)「稼ぐ」ビジネスモデルを構築できるか

技術的なブレイクスルーが起き、それが新しいアプリケーションを生み出す場合、人々はそのことに目を奪われ、当該発明・発見自体がビジネスの勝敗を決するかのような錯覚に陥る。しかし、今までのデジタル革命の各ステージで、パソコンにしても、更にはインターネット検索サービスにしても、それを先に発明したプレイヤー、あるいは技術的に最も優れた製品を開発したプレイヤーが勝ってきたわけではない。液晶にしても半導体にしても、ある時点までは、技術、ノウハウ、基礎研究、資金力、国の支援などあらゆる側面で日本勢は圧倒的なポジションを持っていた。Intelはその影響で1985年に、その祖業であるDRAM事業から撤退している。しかしデジタル革命の波の中で産業構造が激変すると、あの時点での敗者Intelこそがその後の圧倒的な勝者となり、日本のDRAM産業は事実上壊滅した。

つまり、革命的なイノベーションの波に飲み込まれた業界において、ビジネスの世界での勝ち負けはあくまでも、急速に変化する環境の中で構造的、持続的に「稼ぐ」ことのできるビジネスモデル、競争モデルを先に構築できたかどうか、他社に代替されにくい唯一無二のポジションを築き上げられたかどうかで決まるのである。

技術的に劣位にあっても、その技術が誰でも買えるものであれば、本質的に競争上のハンディキャップにはならない。パソコン事業であれば、Intelが汎用CPUビジネスモデルで圧倒的なシェアを確立した瞬間に、もはやCPUは競争領域ではなくなる。CPUはパソコンという製品にとっては心臓部そのものであるが、パソコンビジネスとしてはその開発で後れを取ったとして諦める必要はない。また、「革命初期」に一発あてて調子に乗るのも禁物である。例えばAIの応用分野としてロボットが注目されているが、ここで仮にヒット商品を出したとしても、産業構造までもが変わった時には「ロボット製造・販売業」というビジネスモデルが儲かり続ける保証はない。こういう時期に大切なことは、今起きていることの産業的な意味合い、競争上の意味合いを冷徹に洞察することである。

AI技術の世界においても、米国や欧州の企業や研究機関に日本は後れを取っていることを悲観視する声を聞くが、AI研究における優秀な個人は国境や企業の壁を越えて活躍する。その基盤となっている人材の流動性は高い。またアルゴリズムを軸とした要素技術体系もオープンソースになっていく流れを考えると、こうした開発成果は、特定の企業がクロードに囲い込むことは難しくなり、一般に外販される可能性もある。更にはアルゴリズムの数式自体も公開されて、どの企業でもアクセスできるようになると、全く競争領域ではなくなる可能性さえある。IoTはその性格上、本質的に色々なビジネスプロセスのオープンプラットフォーム化を促進するイノベーションであり、乗り遅れば負ける可能性があるが、「勝つ」ため、「稼ぐ」ための差別化領域にはならない可能性が高い。現時点での出遅れ感は経営論的には全く致命的ではない。

他方、こうした状況で一番おそれるべきは、かかる領域で中途半端にキャッチアップ的な自社独自開発に無駄な時間とエネルギーを使い、結果的に世の中の標準となっている格安で手に入るベストプラクティ

スに乗り損ねることである。日本企業の多くが統合基幹業務システム（ERP）ソフトの普及期に犯した過ちである。

また、悲観が過ぎてこうした流れに全く背を向け、無謀な「我が道を行く路線」に凝り固まるパターンも要注意である。イノベーションの波の影響を受けない、時空を超えたダントツのコンピタンスがあれば別だが、たいていは絶滅への道をたどる。

要するに、過度の焦燥感や無用な悲観論に流された情緒的な経営判断の誤りは、確実に「負ける」原因、「稼げなくなる」理由になるといえる。

#### 4) 限界費用ゼロビジネス化による「ネットビジネス」の終焉

デジタル革命第二期にもっとも繁栄を謳歌してきた「バーチャル」で「サイバー」で「カジュアル」な「Cの世界」の産業群、分かりやすく言えば、いわゆるネット系ビジネスモデルは、今、大きな曲がり角を迎えている。かつてほど衝撃的なサービスを生み出すネタが枯渇しつつあるのと、ある程度のヒットを飛ばしても、それがなかなかお金にならない、いわゆるマネタイズが難しくなっているからである。

インターネット革命が生み出したネットビジネスの世界では、ネットワークという巨大なサンクコスト（埋没費用）の上で、ほとんど限界費用を使わずに展開できるビジネスが可能になる。デジタル革命第二期に少数のアイデアから始まった多数のベンチャーが、あっという間にグローバルなメガベンチャーに成長できた経済的な背景の一つは、このフリーライド構造にある。社会的には新たなベンチャーの台頭やイノベーションを巻き起こす可能性が大きくなることは結構なことであるが、個別ビジネスの単位で考えると、限界費用がゼロということは参入障壁が低いことを意味する。その結果、競争激化により価格はほぼ限界費用付近まで低下し、サービスは実質的に無料化しやすい。この構造から抜け出せなくなるといわれる広告モデルに活路を見出そうとするが、テレビのように電波の有限性に基づく独占性がベースになり得ないので、広告の価格も市場原理で決まりやすく、テレビの時代のような超過利潤、レントはとれなくなっていく。コンテンツについても同様で、アーカイブものは配信にほとんど限界コストがかからず、差別化も難しいので、価格競争に陥りやすく、音楽配信にせよ、映像配信にせよ、それが持続的に大きな収益を上げる構造を作ることは難しい。結局新作のドラマなど、限界費用を投じた“生もの”で勝負する、そのコンテンツ制作のためにビッグデータ解析やAI技術を使うという戦略展開にならざるを得ない。

サイバー空間でほぼ完結できる典型的な「ネットビジネス」の時代は黄昏を迎えつつある。デジタル革命第三期は、そのような時期に起きつつあり、これは今までのネットビジネスの常識も通用しない時代の到来をも意味している。

#### 5) ビッグデータは「儲け」につながるのか

現代は膨大な量のデータをインターネットというオープンな世界から集めることが可能になり、高度な解析技術、高性能の解析インフラが、コンピュータ能力の飛躍的な向上と優良ソフトの開発で多くの人々にとって活用可能になった。

その一方で、ビジネスに活用するということは、鉱山資源開発と同じで、資源を掘り出すコストと、それが生み出す収益が釣り合わないと成り立たない。資源探査能力（データ解析能力）が上がり、アクセスできる鉱山の量は増えたが、真の課題は資源含有率、すなわち質の問題である。これはデータそのものの態様（フォーマットや取られ方）と、活用先の商売上の使い道との組み合わせで決まるのだが、現在語られているビッグデータの潜在力の話で、ビジネスの次元でマネタイズできる話はあまり多くない。また、今起きているAI革命の核心的な技術的ブレークスルーであるディープラーニングにおいても、データは量よりも質が圧倒的に重要になる。

IoT、ビッグデータ、AIという三大バズワードの関係性を整理すると、IoTで色々なデータが集まりやすくなり、そのデータを使ってAIが成長・進化する。進化したAIが実装されたIoTネットワークや機器が

進化・普及することで更に有用なデータが集められるようになり、これがAIの進化を促すという、循環構造である。いわゆるインターネットの世界だけでは経済的な価値創造が難しく、ビッグデータもそれだけではあまりマネタイズにならないとなると、結局これからの勝負は、デジタル革命の主戦場となるリアルでシリアスな産業領域、「Sの世界」でこのような循環を起こせるかどうかにかかっている。

## 6)人間の苦手なところから置き換わるのが「道具」の根本法則

AIの作用のなかでも、経済社会的な本格実装という観点、すなわち産業的な活用という観点からは、人間の苦手なところから置き換わっていく展開になる。例えば、もともとアナログにできている人間の脳は一定かつ明確なルールの下に作用することが得意ではない。一方で、例えばAIは都市の雑踏の交差点を人におつからずには渡ることはできない。曖昧さ、揺らぎ、臨機応変、融通無碍なことには弱いのである。ディープラーニングが大きなブレークスルーを起こしつつあるといっても、従来型AIでは人間が行っていたルール（特徴量）の設定について、AI自身が自己学習的に有用なルールを探し当てる能力を手にしたということであり、AIがルールベースで物事を「認識」「判断」することについては同じである。

したがって、ルールそのものがどんどん変わる、あるいは多様かつ曖昧なルールが可変的に出入りするような状況への対応は非常に難しい。ディープラーニングを繰り返してある程度は人間に近づくことはできても、所謂“人間”を超える可能性は小さいように思う。AIとして研究されている「知能」とは、ある問題設定を与えられた時にそれを解決するための知的作用であり、問題設定そのものの背景にある生命体としての「意思」は持ちえない。意思の源にある人間の心的作用の奥底にあるものを「魂」と呼ぶが、ディープラーニングを含めて今のところAI研究は「魂」からは程遠いところにいる。AIは道具という意味で今でも自動車やコンピュータと同じである。

道具の歴史は、馬を移動に使い、牛を力仕事に使い、更には蒸気機関、自動車と、自然界においてか弱い存在の人間が苦手なことを置き換えてきた歴史である。AIも同様に、わざわざ人間の得意な領域、比較優位のある領域を置き換える展開にはならない。まず何より経済的に見合わないのだから、広く普及することはない。

## (3) AI革命は日本に好機

### 1) グローバル化の遅れと人手不足が有利に働く

AIの産業応用というと、欧米では必ず失業問題や移民問題とリンクする。AIの現実的アプリケーションは、それぞれの分野において、本質的に自動化、省力化を促すことになるからだ。AI革命は、「大自動化革命」とも言い換えられる。

欧米では日本と違って、ローカルな産業はもともと人手不足に陥っているわけではない。そこに移民がなだれ込み、ローカルな仕事の奪い合いが生じ失業率が高止まりしている状況である。そのため、AIによって人の仕事が奪われることに対する警戒心が強く、技術レベルでの開発は進んでも、社会実装段階のハードル、特に大規模な商用化段階での政治的、社会的なハードルは極めて高くなる。

なぜ日本の政治が安定しているかと言えば、ローカルな経済圏で働いている人がそこまでのストレスを感じてないからと考えられる。その理由の一つは、残念ながら日本経済がグローバル化の負け組になっており、グローバルで活躍している人の数がそこまで多くないことである。数が少ないから許されるし、むしろハードワーカーということで同情すらされ、うらやましいとは思われない。

もう一点は、少子高齢化と、日本が結果的に移民政策に消極的なことが重なり、サービス産業を中心とするローカル経済圏が人手不足に陥っていることである。日本の雇用の8割を占めるローカル経済圏は、深刻な人手不足の状況にある。日米独をはじめ、グローバル化の進展は先進国の雇用をよりローカル経済圏依存型にする。ローカル経済圏を構成する産業の多くは対面型で、サービスを提供する人間がそこにい

なくてはならない同時同場型のビジネスであるため、グローバル化が進んでも空洞化しにくい。ユーロ安、低い法人税率、労働市場改革で製造業絶好調にみえるドイツでさえ、ほぼ日本と同じで、約8割の労働者はローカルな産業で働いている。

このように今や主要な経済圏となっているローカル経済圏において、少子高齢化の進展は、医療、介護、交通・運輸などの地域密着型産業の主要顧客である高齢者の比率を高める一方で、そこで働くべき生産労働人口の先行的な減少を加速する。この構造的な人手不足により、日本では遠慮なくAIやIoTやロボティクスのテクノロジーを入れて、いっきに生産性を上げていける土壌ができつつある。ローカル経済圏から政治的な突き上げを受けている欧米先進国では考えられない状況であり、新興国では人を使ったほうが安くなり、まだ自動化に対するニーズはそこまで高くない。世界で唯一、日本だけが国の総意としてAIやIoTに積極的にチャレンジできる絶好のチャンスといえる。世界を吹き荒れているG（グローバリズム）からL（ローカリズム）への風向きの変化は、今の日本と日本企業にとっては強烈な追い風になりうる。

また、AI・ロボティクスが、圧倒的に効果があるのは製造業ではなく、対面型、リアル型のサービス産業である。製造業は既に自動化が進んでいるので、生産性はこれ以上劇的には向上しない。他方、サービス産業では、例えば医療や介護サービスではIoT技術を使って遠隔医療が簡単にできるようになれば往診の頻度が下がり、介護ロボットの発達で介護士の負担も減るであろう。交通・運輸サービスや物流サービス産業にとっても、交通事故の90%は人為的なミスが原因ともいわれており、最も重要な生産性指標である「安全性」という観点からは、自動運転技術の発展が生産性を飛躍的に高める可能性が大きい。

## 2) ハードとソフトの融合が焦点

既に示唆してきたように、デジタル技術、ソフトウェアのアルゴリズムがリアルの世界にかかわってくると、必ずハードウェア、つまりモノが関わってくる。アルゴリズムは数式の世界であり、たった一人の天才が世界を一変してしまうことがあるのに対して、ハードウェアの技術は連続的で蓄積的な技術だという特性がある。

そして同じアルゴリズムでも、ハードと融合してリアルな世界で使うためのアルゴリズムは、経験蓄積的ノウハウの塊であり、すり合わせ型のソフト技術になる。同じソフト系技術でもこの種の技術領域は、後述するオープンイノベーションとの関連では、むしろ競争領域として内製化すべき領域となってくる。

AIそのものはアルゴリズムであっても、AIが制御するロボットを実用化するには、ハードの耐久性が求められる。AIやロボット、IoT時代のモノづくりでは、どこまでをソフトが解決し、どの部分をハードで解決するか、両者をどう連動させるかという、ある種のすり合わせが発生する。まさにモノの復権で、両者が揃わなければ効果的、かつ社会的に受容可能なソリューションを提供できないのである。

## 3) ハイブリッド経営システムの構築

AIやIoTを梃子に事業展開する場合、どこまでをオープンイノベーションで、既存のプラットフォームを利用し、どこから独自技術としてブラックボックス化していくのか、協調領域と競争領域の的確な峻別勝負の大きな鍵となる。

デジタル革命の第二期までは、バリューチェーンの出口はバーチャルで完結した。その限りであれば比較的簡単にユーザーインターフェースが取れ、それを横展開してユニバーサル化、加えてスピーディーにサービスを展開することで利用者数、サービス種目数の両面で拡大して、メガプラットフォーマーになることが勝負どころとなり、Google、Facebook、Amazonと言ったユニバーサルなグローバルジャイアントが登場した。

バリューチェーンの出口が自動運転、介護、建機を使う建設現場などリアルな領域になると、それぞれの分野に固有の技術やノウハウがあり、共通する技術やノウハウがなく、共通コストもほとんどないため、

個別化する。また、リアル産業のバリューチェーンの末端は現場メンテナンスなどのサービスが必要となり、その地域にメンテナンスのネットワークがあるか、拠点があるかどうか競争障壁になる。そして最も重要な違いとして、リアルな領域は人の命に係わるシリアスな領域、「Sの世界」でもあり、急速に事業領域を広げてユニバーサルなメガプラットフォームを展開することは難しくなる。デジタル革命第三期においては、相対的に業界ごとに個別化し、今までよりクローズドな要素も残り、色々な形でブラックボックス化できる産業的進化が進む確率が高い。そこが競争領域になりうるのである。

AI、IoTのデジタル革命第三期は、オープンで不連続なイノベーションの世界（ソフトウェア）と、クローズドで連続的・蓄積的なイノベーション（ハードウェア）をどうすればうまくインテグレート（統合）できるかというゲームに変わる。会社のかたち、組織の在り方、働き方などの根幹的な部分で、オープンシステムとクローズシステムが持続的に共存するハイブリッドな経営システムを確立する必要がある。

#### 4)「Sの世界」はものづくり日本にチャンス

ソフトとハードのすり合わせが必要なフェーズになり、日本企業に対する注目度が高まっている。米国のロボット技術のコアはアルゴリズム系で、ハードウェアの部分は弱い。ロボットを実用化するには、ソフト的解決とハード的解決のすり合わせ、デュアル・インテグレートド・ソリューションが不可欠だということが分かってくると、日本企業のきわめて洗練され、かつ実用的で頑健なハードウェアテクノロジーが魅力的に映る。

ハードウェア技術に関しては、クローズド型組織の方が有利である。連続的で、かつ集合知的な技術であるので、比較的同質な集団が長期間にわたって連続的に働いている職場の方が蓄積しやすい。これは開発技術、生産技術のいずれも当てはまる。そのような特性があるので、日本の機械系メーカーや自動車メーカー、材料系メーカー等には十分勝機がある。

#### 5)「Sの世界」のビジネスの流儀、自動運転はどう進むか

自動車は安全性や耐久性を備えたハードが欠かせない。自動運転の実用化を巡っては、現在二つのアプローチが存在する。一つは既存の自動車の安全装置、自動ブレーキや自動ハンドルなどのレベルを上げ、交通事故の90%を占めるといわれる人為的ミスによる事故を減少させながら、自動運転の技術を段階的に上げていき、結果的に可能であれば「レベル4（完全自動運転。ドライバーのいない無人運転をも含む）」に近づけていく「連続的アプローチ」である。トヨタ自動車、Daimlerをはじめ、主要な自動車メーカーはこのアプローチをとっている。

もう一つは、Googleなどのネット系企業やベンチャー企業が挑戦している、いきなりレベル4の完全自動運転をめざす「不連続アプローチ」である。

現実論として、どちらが主流になるであろうか。私は一般公道での自動運転という、人の命がリアルに関わるシリアスな世界、「Sの世界」の極致の領域では、連続的アプローチに軍配が上がると思う。連続的アプローチは「安全性の向上」を前面に立てており、技術力の向上は「死亡事故の減少」という、誰もが称賛する成果として消費者、社会に対してアピールしながら開発を進められる。また世界中に販売される車から膨大な量のデータフィードバックも働く。これに対し、不連続アプローチは一般公道上の完全自動運転という、社会的に受容されないサービスモデルをいきなり狙っているために、実験段階から安全性（人命）とのトレードオフという極めて困難な問題に対峙する。完全自動運転による事故は、たった一人の死亡事故でも社会的には容認されない。これが「Sの世界」のビジネスである。また、技術的にも、AIがスクランブル交差点を渡れるようになる見込みがなかなか立たないことから分かるように、自動運転技術が非常に高度化しても、我が国の大都市部に多い、歩車分離されていない狭い道路を歩行者がランダムに歩き回る雑踏状況のような場所を完全自動運転で乗り切るハードルは極めて高い。

自動運転も「レベル2」や「レベル3」では技術力で差別化が可能であろうが、もし「レベル4」が実現すると、おそらくどの車も同じ地図で、同じCPUにしなければ事故が起きやすくなるであろうから、カギとなるコンポーネントはオープンソース化し、デファクトスタンダードとなるのではないだろうか。そこまでいくと自動車そのものは差別化ポイントではなくなり、Uberのような配車サービス、カーシェアリングサービス、あるいは駐車場をどれだけ確保しているかということの勝負になるかもしれない。ロケーションは先に抑えた方が勝ちであり、これはローカルビジネス型の勝ちパターンである。ディフェンシス的には非常に堅固な競争モデルである。

#### 6)スマイルカーブ現象が有利に働くバリューチェーンポジション

地域密着型サービス産業群は、その地域にいる生身の顧客とフェースtoフェースで日々、対面しながら営まれている。それはインダストリアル・バリューチェーン上、もともと川下側に位置していることを意味している。川上（企画・設計・部品）と川下（販売・メンテナンス）側の利幅が厚くなる一方、真ん中の製造工程（組み立て）はほとんど利幅がとれなくなる現象がスマイルカーブ現象であり、デジタル革命第二期では真ん中の製造工程を担っていた日本のパソコンメーカーがモジュラー化で苦境に陥り、撤退を余儀なくされた。しかし、この産業領域自体が川下側に位置しており、スマイルカーブ現象が起きても本来あまり被害を受けない。むしろうまくすればプラットフォーマーとして強い立場を確立しより多くの付加価値を取り込める存在になる潜在性を持っている。

その意味で、G型産業であるグローバル製造業からみても、Lの領域は、今後より重要な価値を持ってくる。ここでもスマイルカーブ化の圧力、ビジネスのサービス化のプレッシャーが強まる中で、地域や顧客との関係で密着度と密度を高めること、すなわち「密度の経済性」が効かせることが、特にディフェンスを固める上でより重要になってくる。

#### 7)L型産業こそリアルで「Sの世界」のビジネスの極致

デジタル革命の主戦場がリアルの世界に移るということ、しかもスマイルカーブ現象が起きるということは、L型産業（顧客対面型、労働集約型のサービス産業や農業などの地域密着型産業）に大きなチャンスが到来することを意味している。L型経済を構成する、小売、飲食、宿泊、運輸、物流、建設、医療、介護、農業と言った地域密着型の産業群は、まさにリアルな人間がリアルな現場において対面型で財やサービスを提供する、最もリアルなビジネスばかりである。労働集約度が高いということは、今までのIT技術や自動化技術の恩恵をあまり受けてこなかったともいえ、ディープラーニング技術などによるAIのブレークスルーで、こうした分野の様々なビジネスプロセスが大幅に自動化でき、生産性が大きく向上する可能性は大きい。

また、労働集約的で密度の経済性が効くということは、グローバルな規模はもちろん、ナショナルな規模も追う意味があまりない産業ということである。したがって産業構造は分散的となり、その中心は中堅、中小企業となる。したがって企業規模が大きくないことは、あまり決定的なハンディキャップにはならない。

意志と才覚のあるL型産業の経営者、地域の中堅・中小企業経営には非常に大きなチャンスが到来しつつある。日本経済において、GDPの7割、雇用の8割は、こうしたL型産業に属しており、ローカル経済の主役である中小企業は、デジタル革命第三期における日本経済の主役といえる。

#### 8)グローバル企業とローカル・チャンピオンの共存

デジタル革命最終ステージが生み出す景色として、グローバル企業がローカル・チャンピオンと最強タッグを組んで生き残るといえることが大事になってくる可能性がある。

もちろん相手がいる話であり、資本力をテコにするような買収ゲームがそう簡単にできないとなると、インターネットのサイバー空間とは違って、リアルな世界では、グローバル企業がローカル市場も独占するという単純な図式にはなりにくい。フィジカルな部分で勝負がつくようになると、むしろローカルごとにチャンピオンがいるという構図になるかもしれない。グローバル・チャンピオンとローカル・チャンピオンが共存して、ケース・バイ・ケースで手を組むイメージである。

政策的な観点からも、グローバル・チャンピオンを作りだすことばかりに執着せず、エコシステムとして経済社会全体を捉え、このようなG型企业とL型企业の共存・相互補完モデルはもちろん、デジタル革命の中で更に多様化し、流動化するビジネスモデルや経営モデルが、全体として国民経済の持続的発展に資するよう機能させることが重要となる。

#### (4) 日本企業がとるべき戦略

##### 1) トップの決断力

前項では、AIやIoTではハード的解決とソフト的解決のすり合わせが必要で、両者が共存していくには、受入れ側の日本企業が変わらなければならないと述べた。では、どのように変わる必要があるのだろうか。

右肩上がりの高度経済成長期からバブル崩壊までの30年間は、間違いなくクローズドで連続的なイノベーションとの戦いであった。この戦いの中で、日本の自動車メーカーは世界を席卷し、日本の電気製品も世界中に広がった。

今でも素材産業は連続的イノベーションの世界であるし、機械系も比較的最近まではそうであった。しかし、そうした戦いは多くの産業で終焉を迎えつつある。デジタル革命第三期で求められる戦略行動は、オープンな経営資源とクローズドな経営資源を統合するハイブリッド経営であることは先に述べた。しかしこれを持続的、システムティックに行うことは、経営論的にそう簡単なことではない。

オープンな技術は自社開発にこだわらず、よりよいものを外部から調達する。今、日本企業に問われているのは、割り切れるかどうか、日本企業が伝統的に最も苦手としてきた「捨てる」経営ができるかということになる。

クローズドな組織文化の弊害を乗り越えるためには、経営陣がいい意味で割り切って、トップダウンでオープン領域とクローズド領域の間をさばかなければならない。さばけていないと、現場で同じような技術開発を頑張っている仲間の情にほだされて、そちらを優先したくなる。したがって第三者を使って評価するか、トップ自らが直感で決めるしかない。

##### 2) 流動的な優秀な人材が楽しんで働ける環境を用意できるか

ソフトウェアやアルゴリズムの世界では、一人の天才の能力に負う部分が大いなので、人材はどうしてもオープンで流動化する。一部の優秀な人にとっては、特定の企業のためだけに自分の才能を使う合理性はない。そういう才能を、日本的な「カイシャ」という極端にクローズドな世界に囲い込めるかということ、無理がある。日本企業の組織体系そのものをオープンにしなければ、そのような才能は集まらない。

M&Aがうまくいかないのは、買収した企業に対する社内の反応ややっかみを抑えきれず、自分たちと同じ土俵に乗せようとするからである。もともとオープンで自由な文化が橋梁力を支えていたのに、親会社の流儀を無理に押し通せば、ベンチャー特有の熱気が失われ、人材の流失に歯止めがかからなくなる。それができないのは、自分たちのクローズドな組織体制とそこでの生き方、働き方を変えられないからである。オープン型にすると割り切れれば、買収した会社はたまたま資本関係があるだけで割り切るべきである。

変わることができた会社にはチャンスが広がるが、できなかった会社は消えていく運命にある。米国企業はもともと個人契約が基本であり、一番ゲゼルシャフト的（機能的組織、利益集団）で、日本が一番ゲ

マインシャフト的（共同体組織・ムラ社会）であるが、どちらがいいというわけではない。ゲゼルシャフト的な要素が強い分野とゲマインシャフト的な要素が強い分野、プロフェッショナル型のオープンで入れ替え可能な方が向いている分野とサラリーマン型のクローズドで同質な方が向いている分野がある。つまり経営として考えなければならないのは、異質なものを一つの企業体、コーポレーションという名の法的フィクションの上にどうやってうまくのせるかということである。

従来クローズドな体制でやってきた日本企業にとってはかなりハードルの高いチャレンジになるが、うまくやれば、競争力が一気に高まる可能性がある。

## (5)おわりに

今から5億年以上の昔、古生代カンブリア紀に生物の種類が爆発的に増え、現存する多くの生物の原型がこの時期に出そろったといわれている。この現象は「カンブリア爆発」と呼ばれているが、その有力な原因仮説はこの時期に生物は「目」を獲得し、それが捕食方法の進歩と戦略性を高め、また同時に捕食者からの回避能力を高めたことが生物の高度化と多角化を一気に進めたと考えられている。

自動運転やロボティクスの世界では、画像認識・処理技術の発達はAIアルゴリズムのソフトサイド、センサやカメラなどのハードサイドの両面で急激であり、そこで認識されたデータが更にAIアルゴリズムを進化させ、ハードを進化させる循環が始まっている。今、幅広い産業で「カンブリア爆発」的なパラダイムシフトが起きる可能性が高まっていることは間違いない。

デジタル革命最終章の到来は、日本企業の多く、G型企业にもL型企业にも、大企業にも中小企業にも、そしてそこで働く人々にも千載一遇のチャンスをもたらしつつある。しかしその一方で、今のままの経営の在り方、会社の在り方では、そのチャンスをもものにできる確率は非常に低いといわざるを得ない。「Lの風」「Sの風」が吹いてきたといっても、この20年間吹き荒れたデジタル革命の風はこれからも吹き続けるし、グローバル化の風も弱まったとしても止むとは思えない。世界的に見て、「同質性」と「連続性」にあまりに偏ってしまった日本企業の組織特性、経済特性が、デジタル革命の破壊性、グローバル経営が抱え込む多様性と相性が悪いのは自明である。この問題に抜本的なメスを入れない限り、新しい風をつかむことは不可能である。

目の前の現象の本質をとらえ、多少の痛みを伴ってもやるべき自己改革を断行すれば、日本企業は今回こそ、この千載一遇のチャンスをもものにできると信じている。

## 第 3 章

# 制度的課題 への対応動向

- 3.1 総論
- 3.2 知的財産
- 3.3 倫理
- 3.4 規制緩和・新たなルール形成

# 第3章

## 制度的課題への対応動向

### 3.1 総論

人工知能（AI）は、将来に向けて高い機能を有するものと期待されることから、その普及による社会へのインパクトや対応について、学会等により議論がされてきた。昨今、現実社会への実装が本格化しつつあることを背景に、政府や民間企業等、社会政策や実ビジネスの実行機関による検討が本格化している。

そうした検討においては、AI社会実装の推進にあたって、その存在を想定していなかった既存の法制度等との調和（ハーモナイズ）を図る必要が指摘されている。また、従来の技術に比べて、「知性」という人間の本質に近いところで「人間の代替」になるという側面を持つAIに対しては、不安や社会における位置づけの難しさへの懸念が、漠然としたものから具体的なものまで様々にあると想定されている。このようなリスクの整理、明確化とそれに対する対応の検討も、AIの社会への実装を推進する際の大きな課題であると指摘されている。

本章ではこのような課題に対応する制度的基盤としての「知的財産」、「倫理」、「規制緩和・新たなルール形成」に関する社会的議論や対応の動向を述べる。

#### 3.1.1 知的財産

知財に関わる動向については、国内では知的財産戦略本部等における議論が進行しており、2017年3月には「新たな情報財検討委員会 報告書」としてとりまとめられている。

この中では①AIが創作に関わる「AI生成物」の知財制度上の扱い、②「学習済みモデル」「学習用データ」の活用と保護に向けた議論等がされている。

AI生成物の知財制度上の扱いについては、学習済みモデルの利用者の創作的寄与が認められないような簡単な指示に留まる場合は、AIが自律的に生成した「AI創作物」と整理され、現行の著作権法上は著作物と認められないとされている。一方、AI生成物を生み出す過程において、学習済みモデルの利用者に創作意図とAI生成物を得るための創作的寄与があれば、当該AI生成物には著作物性が認められるとされている。

ただし、実際にはどこからが「創作的寄与」があり、どこからがそれが無い「簡単な指示」かは様々な場合があることが想定されるため、今後のAIによる創作事例の積み重ねの中で、社会的な合意が図られていくものと考えられる。

「学習済みモデル」については、既存の学習済みモデルにデータの入出力を繰り返すことで得られる結果を基に学習することにより、同様のタスクを処理する別の学習済みモデルが効率的に作成できるいわゆる「蒸留モデル」は元のモデルへの依拠性の認定及び立証が難しく著作権による保護は困難であるため、特許権や契約による保護等の在り方について議論がされている。

「学習用データ」については、インターネット上のデータ等の著作物を元に学習用データを作成・解析することは、営利目的の場合も含めて著作権法47条の7に基づいて著作権侵害には当たらないとされてい

る。この条項は機械学習の活用にとって有用な我が国独特のものであるが、そのように作成された学習用データの一般への提供は難しいとの扱いとなっている。一方で、米国ではインターネット上の画像データを元に作成した学習用データの公開サイト等（共有データセット）があり、我が国でもAIの研究開発推進に向けて同様のインフラ整備の必要性が指摘されているが、その法的扱いについて議論がされている。今後は著作権法の権利制限規定に関する制度設計や運用の中で検討が行われる見込みである。

諸外国においても、AI生成物の知財制度上の扱いは我が国と同様であるが、英国著作権法では「コンピュータ創作物」（computer-generated work）について「著作権」（copyright）による保護が認められている。また、機械学習のために他人の著作物等を大量に解析することが著作権侵害に当たらないかという問題について、我が国の著作権法47条の7の権利制限規定に類似した法制度が、2014年以降英国、ドイツ、EUで整備されつつある。だが、対象が非営利目的や研究機関に限られており、商用利用が可能な我が国に比べると狭くなっている。

### 3.1.2 倫理

制度的基盤のうち倫理に関わる動向については、AIの社会実装に伴って想定されうるリスクとして、「AI自身のリスク」、「人間がAIを利用して引き起こすリスク」、「既存の社会秩序への負の影響」、「法律・社会の在り方」が挙げられており、海外で数多くの議論がされている。特に米国では、政府や大学、NPOのほかAmazon、Google、Facebook、IBM、Microsoft、Appleという競合する企業群が、AIが人々と社会に与える影響に関する議論等を共同で行うためのNPOとしてPartnership on AIを創立。AIへの取組を推進しているIT関連企業が自ら、あるいは、中心的な役割となって倫理に関する議論を進めている。

一方、欧州では、オックスフォード大学内に設立されたFuture of Humanity Institute（FHI）やケンブリッジ大学に設置されたCentre for the Study of Existential Risks（CSER）など、学術機関がGoogle DeepMind（英国）等のベンチャー企業などと連携しつつ先導して議論を進めている様子が見える。

また、政府によるAIの研究開発・利活用への指針・開発原則の策定等の課題に対する制度的対応、政策的対応が各所で検討されており、より幅広い産業に波及することが期待される。例えば、米国政府は、2016年10月、12月に続けてAIの社会実装に関する文書を発表しており、AIによるリスクや社会の在り方などに関する言及がなされている。

更に、2016年12月にIEEEが公開した倫理的価値を踏まえたAI設計に関する文書“ETHICALLY ALIGNED DESIGN：A Vision for Prioritizing Human Wellbeing with Artificial Intelligence and Autonomous Systems”では、AIの産業応用・実用化の観点から、学習モデルの説明性の担保（ホワイトボックス化）、性能保証について記した指針として注目されている。こうした取組は、日本では具体的な取組が不足しているとの懸念の声も聞かれるが、産業界におけるAI応用を促進する上で必要となるAI活用の信頼性や社会的受容性の醸成にもつながると期待される。

我が国においてもAIによるリスクの整理やそれに対する対応方針について、多様な主体が議論を行っている。例えば、民間では、人工知能学会倫理委員会が2017年2月に「人工知能学会 倫理指針」を発表しており、今後の議論のベースとなることが期待される。また、政府の動向としては、総合科学技術・イノベーション会議の「人工知能と人間社会に関する懇談会」や総務省「AIネットワーク社会検討会議」による検討が行われている。

### 3.1.3 規制緩和・新たなルール形成

AIの活用には、既存の規制が障壁となり、その活用を十分に実現することができないため、規制緩和が必要になる場合がある。また、既存のルールがなくAI活用の拠り所が十分でないために活用が進まない場合がある。この場合には新たなルール作りが必要となる。

AIの活用分野の一つである自動車の自動走行に関しては、既存の国際道路交通条約との関係について国連での議論が続けられ、一部条約改正も実施され整合性が図られている。各国レベルでも、英国では積極的に制度に関する議論が進められており、保険制度の改正、商用化が想定されるシステムの製造・使用規定、交通規範の改正の検討が見込まれる。

米国では先進的な州において公道実験の許可に関する制度が整備されてきており、民間企業による公道での実証等のバックボーンとなっている。こうした動きを受けて、2016年には運輸省道路安全交通局（NHTSA）が自動運転車の安全評価基準を挙げており、今後の具体化が注目される。

我が国においても、警察庁の「自動走行システムに関する公道実証実験のためのガイドライン」の発表、経済産業省・国土交通省共同設置の「自動走行ビジネス検討会」での検討等が進められている。

ドローンの飛行については、2015年12月に改正航空法が施行され、飛行させる空域及び飛行方法の基本的な飛行ルールが定められた。それを受けて、「小型無人機に係る環境整備に向けた官民協議会」が立ち上げられ、詳細な議論が実施されてきた。また、改正航空法の運用を通じ、機体、操縦者及び運航管理体制といった要件の具体化が進み、ガイドラインや民間団体等の取組も含め包括的なルール形成が進展している。

健康、医療・介護分野に関しては、複数の個人データを必要に応じて機関をまたいで連携・活用することで、効果的なデータ分析やサービス提供が可能になる場合が多いと想定されるが、個人情報保護制度の制約条件や機関間の制度の違いによりデータ活用が困難なことが多くなっている。このような中で、制度的な制約を超えてデータ利活用を図る取組が始まっている。

次世代医療ICT基盤協議会 医療情報取扱制度調整ワーキンググループでは、高い情報セキュリティを確保し、十分な匿名加工技術を有する等の一定の基準をみたす組織を公的に認定。認定された組織は複数の医療機関等から医療情報の提供を受けて、匿名化等の加工をして一元的に研究機関や製薬会社等に提供をする「医療情報匿名加工・提供機関（仮称）」の制度化の検討が進められた。匿名化して情報提供をする機能については、「認定匿名加工医療情報作成事業者」との呼称で、2017年3月に「医療分野の研究開発に資するための匿名加工医療情報に関する法律案」（次世代医療基盤法案）として国会に提出されている。そのほか、医療情報等の個人データの安全なデータ流通の仕組みづくりの取組としてパーソナルデータストア（PDS）などの具体的な検討が進められている。

また、製造業、流通業、サービス業等においては、AIを活用して事業者や業種を超えて個人属性や行動特性に応じた商品・サービス提供がされることで高度なカスタマイゼーションが実現し、社会全体としての生産性を高めることが期待されている。そのため、事業者間や業種間で、プライバシー保護や個人情報保護を配慮した形でのデータの利活用を適切に行うための新たな制度的な検討が進められている。

データの匿名化については、改正個人情報保護法で創設された「匿名加工情報」制度のビジネスにおける運用を視野に入れて、「匿名加工情報及び匿名加工情報作成マニュアル」が公表されている。

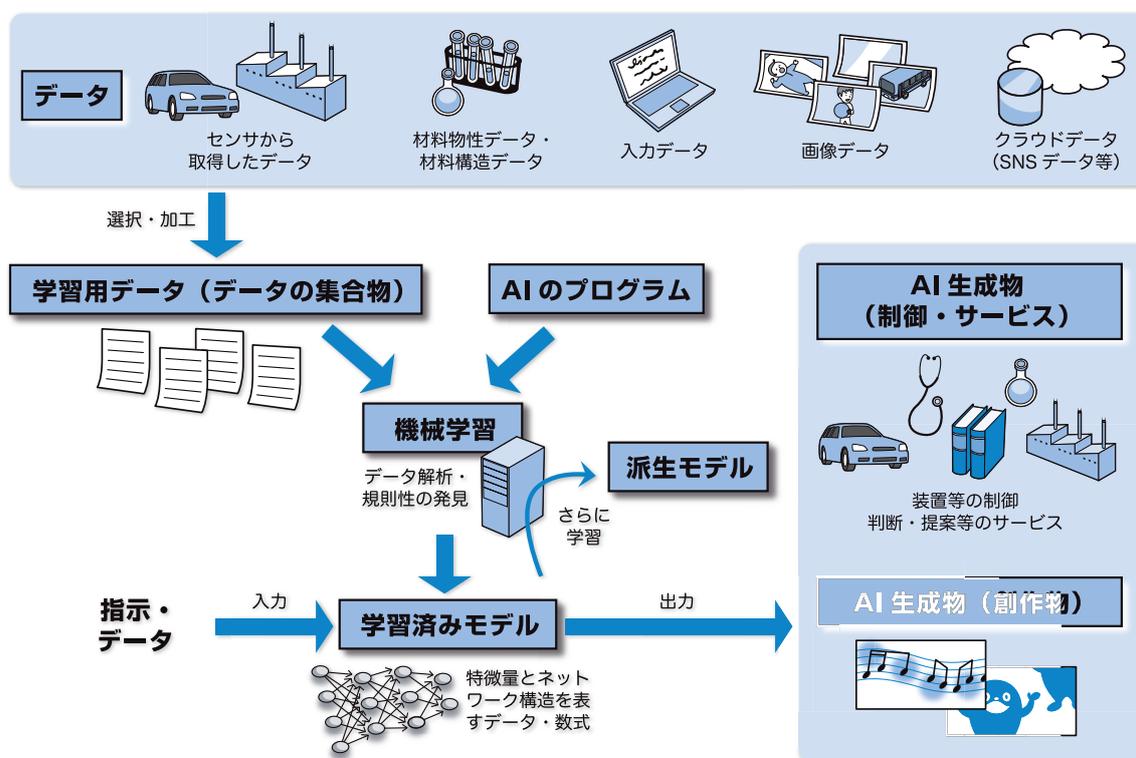
また、ディープラーニングの発展に伴いますます利用が進むことが想定されるカメラ画像について「カメラ画像利活用ガイドブック」が策定されている。

## 3.2 知的財産

### 3.2.1 国内の動向

政府の知的財産戦略本部では、機械学習を用いた人工知能（AI）によるAI生成物の生成過程を図1のようにイメージした上で、AIに関わる知的財産の扱いに関し、以下のような議論・整理がされている。一つはAI自身の創作の可能性が出てきたため、AIが制作した音楽、美術、文学作品などの扱いについて、議論が始まっている。また、「学習用データ」、「学習済みモデル」についても現在活発になっている機械学習を中心としたAI活用の核となる要素であるため、その知的財産上の扱いについて議論が行われている。

本項では、知的財産戦略本部、特許庁での議論を中心にAI生成物の著作権保護、AI生成物の特許保護、学習済みモデルの保護、情報解析の確保について、議論の内容を紹介する。



■図1 機械学習を用いたAIの生成過程のイメージ<sup>1</sup>

#### 3.2.1.1 AI生成物の著作権保護

##### (1) 試行からビジネスに向かう「AIによる創作」

AIの技術進歩に伴い、例えば音楽や文学作品などのコンテンツの特徴を抽出し、学習することで、AIによる新たな創作が可能になりつつある。

例えば、マラガ大学（スペイン）が開発した自動作曲プログラム「Iamus」は、AIによって自律的に現

※1

「新たな情報財検討委員会報告書」知的財産戦略本部ウェブサイトより  
編集部作成<[http://www.kanteigo.jp/jp/singi/titeki2/tyousakai/ken-sho\\_hyoka\\_kikaku/2017/jhonzai/houkokusho.pdf](http://www.kanteigo.jp/jp/singi/titeki2/tyousakai/ken-sho_hyoka_kikaku/2017/jhonzai/houkokusho.pdf)>

代クラシック音楽を作曲することができる。Iamusが作曲した作品は、専門家にも人間が作ったものと判別ができず、演奏会での演奏やCD販売がされるほどのことである。

ポップミュージックの世界でも、ソニーコンピュータサイエンス研究所が2016年9月に、AIを使って作曲したビートルズ風のポップソング「Daddy's Car」を発表している。機械学習で多くの楽曲を読み込んだ「Flow Machines」というツールを使うことで、「〇〇風」の作曲が容易にできるようになっている。

文学においても「AIによる創作」の事例が出てきている。例えば、公立はこだて未来大学では作家・星新一のショートショートを解析して、AIがショートショートを創作するプロジェクトを実施して作品が公表されている。

また、AIベンチャー企業であるクエリーアイは、AIが記した日本初の商用出版書籍『賢人降臨』を、2016年8月にNTTドコモの電子書籍販売サイト「dブック」から800円で発売した。クエリーアイが開発したAIシステム「零」に福沢諭吉『学問のすゝめ』、新渡戸稲造『自警録』をディープラーニング（リカレントニューラルネットワーク）で学習させた上で、「若者」「学問を修め立身」「世界を制する」「成功とは」「人とは何を示すもの」の五つのテーマを与えて零が記したものである。

このように、AIによる創作は実験・試行の段階から、実ビジネスや実サービスの段階へと踏み出されようとしている。

## (2) 「AI生成物」に関わる知財制度上の整理状況

1993年11月に公表された「著作権審議会第9小委員会報告書<sup>2</sup>」においては、「人の「創作意図」及び「創作的寄与」があればコンピュータを道具として使用して創作したと評価できる」と整理されている。これを敷衍すると、AIをツールとして人が作成した創作物については、通常の著作物と同様の著作権が認められるものと考えられる。

2016年4月に知的財産戦略本部から公表された「次世代知財システム検討委員会報告書」<sup>3</sup>においては、**図2**に示されたように、「AI生成物を生み出す過程において、学習済みモデルの利用者に創作意図があり、同時に、具体的な出力であるAI生成物を得るための創作的寄与があれば、利用者が思想感情を創作的に表現するための「道具」としてAIを使用して当該AI生成物を生み出したものと考えられることから、当該AI生成物には著作物性が認められその著作者は利用者となる」とされている。

他方で、同報告書では「利用者の寄与が、創作的寄与が認められないような簡単な指示に留まる場合（AIのプログラムや学習済みモデルの作成者が著作者となる例外的な場合を除く）、当該AI生成物は、AIが自律的に生成した「AI創作物」と整理され、現行の著作権法上は著作物と認められないこととなる」とされている。

すなわち、現行法制度上、AIが自律的に生成した生成物は、「思想又は感情を創作的に表現したもの（著作権法2条の1）」ではないため著作物に該当せず、著作権も発生しないと考えられる。

前項で事例として述べたソニーコンピュータサイエンス研究所の「Daddy's Car」は、作曲家ブノワ・カレ（Benoit Carre）氏がFlow Machinesで、「ビートルズ風」というスタイルと曲の長さを指定して出力された曲に対して作詞・編曲をして発表されている。この場合は、カレ氏が編曲等により、創作的寄与をしていると考えられている。

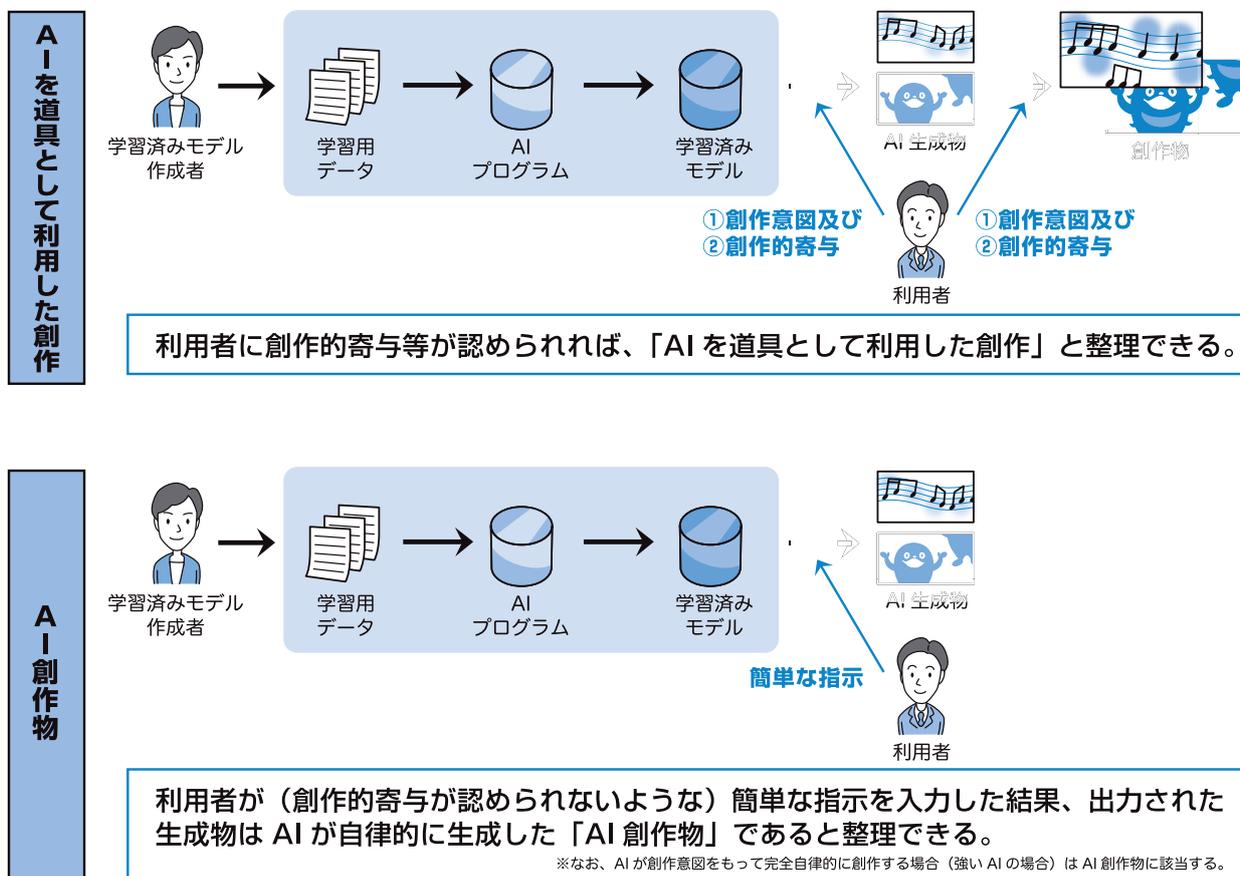
一方でマラガ大学が開発した作曲をするIamusによる楽曲は、AIのみで自律的に制作されている。その

※2  
「著作権審議会第9小委員会（コンピュータ創作物関係）報告書」著作権情報センターウェブサイト <[http://www.cric.or.jp/db/report/h5\\_11\\_2/h5\\_11\\_2\\_main.html](http://www.cric.or.jp/db/report/h5_11_2/h5_11_2_main.html)>

※3  
「次世代知財システム検討委員会報告書」知的財産戦略本部ウェブサイト <[http://www.kantei.go.jp/jp/singi/titeki2/tyousakai/kensho\\_hyoka\\_kikaku/2016/jisedai\\_tizai/hokokusho.pdf](http://www.kantei.go.jp/jp/singi/titeki2/tyousakai/kensho_hyoka_kikaku/2016/jisedai_tizai/hokokusho.pdf)>

ため、その楽曲はAI創作物として著作権は認められないと考えられる。

これらの事例は人の「創作的寄与」の有無が明確であるが、実際にはどこからが「創作的寄与」があり、どこからがそれがない「簡単な指示」かは様々な場合があることが想定される。今後のAIによる創作事例の積み重ねの中で、社会的な合意が図られていくものと考えられる。



■図2「AI生成物」の分類イメージ<sup>4</sup>

### (3) ビジネス活用に向けた「AIによる創作」の保護の在り方

Iamusの楽曲の例をみても分かるように、AI創作物と人間の創作物は、外見から判別することはできないという前提で考えることが妥当である。Iamusは僅か数分で作曲をするといわれているように、AIは人間に比べると極めて効率的に「創作物」を作成することが想定される。そのため、実際には「人間が作った」と見なされるAI創作物が大量に出てくる可能性がある。したがって、AI創作物全体に「著作権」を認めることは、保護過剰になるとの議論がある。一方で、大量供給により価格が大幅に下落することから、たとえ著作権保護をしたところでそこから得られる経済的な利益は大きくならないので問題はないとの指摘もある。

このような大量供給による市場価格の下落もありうる中で、创作者の「創造性」とは何かを改めて問われるなど、人間の創作活動に影響を与える可能性がある。

※4

「新たな情報財検討委員会報告書」知的財産戦略本部ウェブサイトより  
編集部作成<[http://www.kantei.go.jp/jp/singi/titeki2/tyousakai/ken sho\\_hyoka\\_kikaku/2017/johozai/houkokusho.pdf](http://www.kantei.go.jp/jp/singi/titeki2/tyousakai/ken sho_hyoka_kikaku/2017/johozai/houkokusho.pdf)>

これらのことから、今後は「価値ある」AI創作物の峻別方法や、大量生産の意味が大きい市場の探索等のビジネスモデルの検討と、それに即した知財制度の検討が進むものと考えられる。

### 3.2.1.2 AI生成物の特許保護

特許庁の調査<sup>5</sup>では、AIによる自律的な創作が行われた場合については、現行の特許法は発明者が自然人であることが前提であることから、その創作物は保護の対象とならないとしている。その上で、「創作」を①課題設定、②解決手段候補選択、③実効性評価の3ステップからなると考え、アンケート調査<sup>6</sup>の結果からこの3ステップのいずれかを人が行うことが「自然人の創作」である条件と考えられていると整理している。

また、法学者等の専門家のヒアリングから、自然人が発明を着想したか否かといった観点も考慮する必要があるとしている。だが、上記の3ステップいずれかの人による実行という条件と、この観点との両方を満たす必要があるか否かについては、さらなる議論が必要としている。

以上のような整理をした上で、今後、AI技術の進歩とともに変化し得る創作への人の寄与を継続的に調査し、保護すべき創作と、それに必要な人の関与について、改めて検討する必要があると考えられるとしている。

### 3.2.1.3 学習済みモデルの保護

精度の高い学習済みモデルはAI適用の効果を高めることから、モデルを作成した企業はその権利保護を指向することが多いと考えられる。具体的には、学習自体がマシンパワーと時間を要するものであり、多大な投資と労力を投じることが必要であることに加えて、機械学習の手法（①学習用データの選択と学習順序（データの入力の仕方など）、②学習の回数、③学習の組合せ（機械学習と強化学習の組合せなど）、④パラメータの調整など）により、作成される学習済みモデルの出力結果の精度が変わるため、そのノウハウに価値があると指摘されている。

学習済みモデルはプログラム（アルゴリズム）<sup>7</sup>とパラメータで構成されているが、それは著作権法上の「プログラムの著作物」に該当するかの議論がされている。また、仮に「AIのプログラムとパラメータの組合せ」が著作権法上のプログラムに該当しないとしても、特許法上では「プログラム等」に該当するならば、特許法の要件（進歩性など）を満たす場合には保護されるとされている。加えて、仮に著作物や発明に該当しない場合でも、不正競争防止法上の秘密管理性、有用性、非公知性といった要件を満たす場合には、「営業秘密」として保護されるとされている。

また、図3に示されたように、ネットワークの構造とパラメータが外から見えない状況（ブラックボックス化された状況）でも、学習済みモデルにデータの入出力を繰り返すことで得られる結果を基に学習すれば、一から学習済みモデルを作成するよりも効率的に同様のタスクを処理する別の学習済みモデルを作成できる。だが、この「蒸留モデル」は元のモデルへの依拠性の認定及び立証が難しいため、著作権による保護は困難である。そのため、学習済みモデルの特許権や契約による保護等の在り方について、議論が

※5  
「AIを活用した創作や3Dプリンティング用データの産業財産権法上の保護の在り方」特許庁ウェブサイト<[http://www.jpo.go.jp/shiryoutoushin/chousa/pdf/zaisanken/2016\\_10.pdf](http://www.jpo.go.jp/shiryoutoushin/chousa/pdf/zaisanken/2016_10.pdf)>

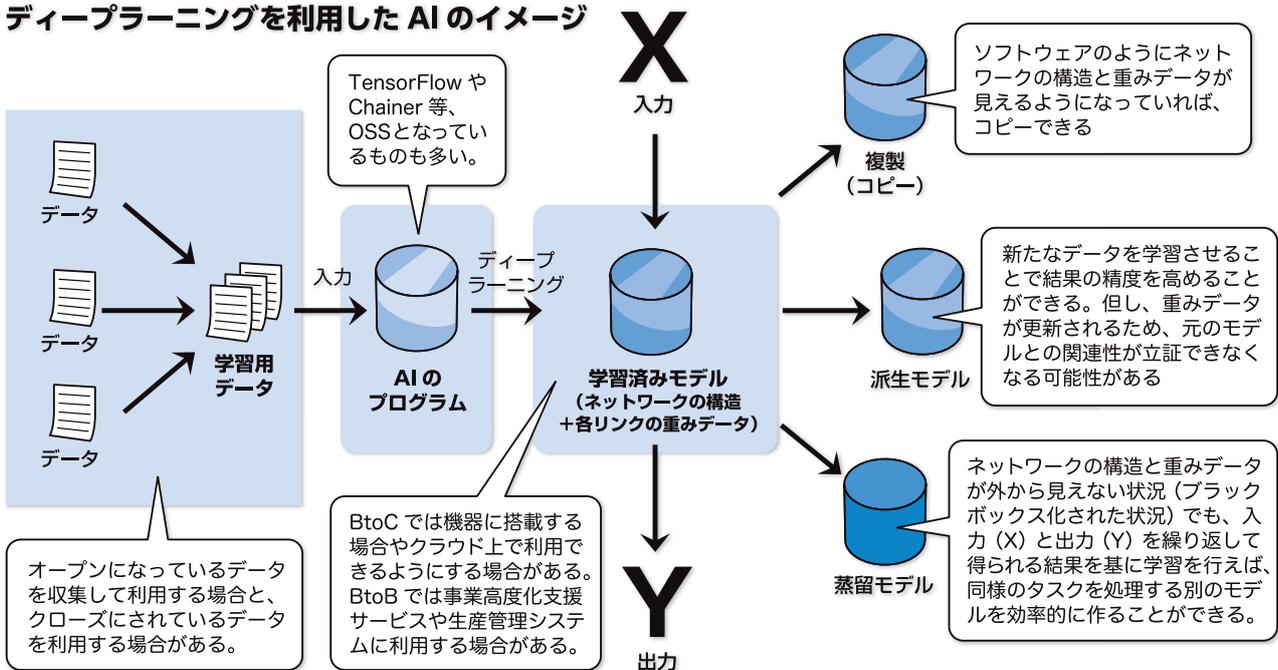
※6  
人工知能学会賛助会員企業とAIを活用したビジネスの実施を公表している企業を対象として実施されている。

※7  
著作権の議論では「アルゴリズム」は著作権法上の保護が及ばない「解法」を指すため、それと区別して「プログラム」と呼んでいる。

されている。特許権による保護は、依拠性の立証がなくとも与えられるため、学習済みモデルの発明が当該特許発明の技術的範囲の内容に応じて保護を受けられる可能性があり、その範囲について検討を進めるとされている。

なお、学習済みモデルの利用規約により、蒸留モデルを禁止する等の契約による保護については、契約の効力は契約当事者以外の第三者には及ばないなどの限界があるものの、柔軟な対応が可能であり、国内外で活用できると考えられている。これを踏まえ、学習済みモデルに関する契約に盛り込むべき事項を明らかにして整理するなど、契約による適切な保護の在り方を検討することがうたわれている。

### ディープラーニングを利用した AI のイメージ



■図3「学習済みモデル」に関わる課題の状況<sup>8</sup>

#### 3.2.1.4 情報解析の確保

学習用データについては国内における利用促進に向けて、知財としての扱いに関して議論がされている。

インターネット上のデータ等の著作物を元に学習用データを作成・解析することは、営利目的の場合も含めて、著作権法47条の7に基づいて著作権侵害には当たらないとされており、機械学習活用の促進にとって我が国特有の有用な制度となっている。しかしながら、現状では学習用データの一般への提供（公衆への送信）は難しいとの扱いになっている。

一方で、米国ではインターネット上の画像データを元に作成した学習用データの公開サイト<sup>9</sup>等（共有データセット）があり、我が国でもAIの研究開発推進に向けて同様のインフラ整備の必要性が指摘されており、その法的扱いについて議論中である。例えば、公衆への送信を認めることについては、「学習用データ」と称して著作物がそのまま提供されることが懸念されている。

今後はこれらの議論を踏まえて、著作権法の権利制限規定に関する制度設計や運用の中で検討が行われる見込みである。

※8  
「新たな情報財検討委員会報告書」知的財産戦略本部ウェブサイトより  
編集部作成 <[http://www.kantei.go.jp/jp/singi/titeki2/tyousakai/kensho\\_hyoka\\_kikaku/2017/johozai/houkokusho.pdf](http://www.kantei.go.jp/jp/singi/titeki2/tyousakai/kensho_hyoka_kikaku/2017/johozai/houkokusho.pdf)>

※9  
代表例としてImagenetがある。Imagenet Website <<http://www.image-net.org/>>

## 3.2.2 海外の動向

AIと知的財産法制度をめぐっては、昨今、日本国内で盛んな議論が展開されているが、諸外国においては、我が国のように大きな政策課題として論じられている国は見当たらない<sup>10, 11</sup>。ただ、諸外国においても、AIと知的財産法について以下のような状況がある。

### 3.2.2.1 AI生成物の著作権保護

第一に、AI生成物と著作権法に関しては、AI生成物が著作権保護を受ける著作物といえるかが問題となるが、諸外国においても、著作権保護を受ける著作物とは、あくまで人間によって創作されたものであることが前提とされている。AIによって自動的に生成された作品は、たとえ客観的な価値が高いとしても、人間によって創作されたといえない以上、著作物として著作権保護を受けることはないとの考えが一般的である。

ただし、英国著作権法（Copyright, Designs and Patents Act; CDPA）は、同法制定時（1988年）から、人間が関与しない「コンピュータ創作物」（computer-generated work）について「著作権」（copyright）による保護を認めている<sup>12, 13</sup>。ここにいう「コンピュータ生成」（computer-generated）とは、「著作物の人間の著作者が存在しない状況において著作物がコンピュータにより生成されることをいう」と定義され（178条）、「コンピュータにより生成される（computer-generated）文芸、演劇、音楽又は美術の著作物の場合には、著作者は、著作物の創作に必要な手筈（the arrangements necessary）を引き受ける者であるとみなされる」と規定されている（9条3項）<sup>14</sup>。そして、「コンピュータにより生成される著作物の場合には……、著作権は、著作物が生成された暦年の終わりから50年の期間の終わりに消滅する」と規定されている（12条7項）。なお、コンピュータ生成物に著作者人格権は適用されない（79条2項c号、81条2項）。

### 3.2.2.2 AI生成物の特許保護

第二に、AIと特許法に関しては、AIを用いて生成された新しい技術が特許法上の「発明」として特許を取得できるかという点が問題である。だが、最近の調査研究によれば、諸外国（米国、欧州、英国、ドイツ、フランス、中国、韓国）においても、AIによる自律的な創作は、AIが自然人でないために「発明者」

※10

知的財産戦略本部・新たな情報財検討委員会においても、2017年1月30日・2月3日にかけて、欧州委員会、マックスプランク研究所及びミュンヘン大学の有識者に対する欧州調査が行われたが、「AIの行った行為の責任に関する議論はされているが、知財に関する議論はほとんど行われていない」とされている（知的財産戦略本部 検証・評価・企画委員会 新たな情報財検討委員会「新たな情報財検討委員会報告書」別添参考資料集p.10「(参考7) 欧州におけるデータ・AIを巡る議論の状況」参照）。

※11

なお、欧州議会の法務委員会における問題提起として、“Draft Report with recommendations to the Commission on Civil Law Rules on Robotics (2015/2103(INL)), ” European Parliament Website <<http://www.europarl.europa.eu/sides/getDoc.do?pubRef=-//EP//NONSGML%2BCOMPARL%2BPE-582.443%2B01%2BDOC%2BPDF%2BV0//EN>>参照。また、ごく最近の議論として文献[1]等も参照。

※12

なお、同様の立法例は、アイルランド著作権法(21条 f 号、30条等)、ニュージーランド著作権法(5条2項 a 号、22条2項等)、インド著作権法(2条 d 項6号)、南アフリカ著作権法(1条1項5号)、バルバドス著作権法(10条4項等)、香港著作権条例(11条3項、17条6項、91条2項c号、93条2項、198条)にも見られる。これらは英国法の影響を受けたものであるが、規定の内容はそれぞれ微妙に異なるものがある。

※13

裁判例として、Nova Productions Ltd v Mazooma Games Ltd, [2006] EWHC 24 (Ch)参照。また、文献[2]も参照。

※14

英国著作権法の和訳については、「外国著作権法 イギリス編」著作権情報センターウェブサイト <<http://www.cric.or.jp/db/world/england.html>>参照。

の要件を満たさず、また権利主体を特定できないことから、権利の客体になり得ないと考えられている。ただし、AIを道具として人が創作を行ったと評価できる場合は、発明として特許法の保護対象となり得るとされ、この場合は、創作への貢献を個別具体的に評価することによって、自然人である発明者が認定されるとのことである<sup>15</sup>。

### 3.2.2.3 学習済みモデルの保護

第三に、学習済みモデル自体が、著作権法上の著作物や特許法上の発明として法的保護を受けるかどうかの問題になる。最近の調査研究によれば、諸外国においても、学習済みモデルが少なくともプログラム及びパラメータと評価できる場合には、一般のプログラムと同様に特許法上の保護を受け得るとされることである<sup>16</sup>。しかしながら、様々なタイプの学習済みモデルが考えられ、また将来も発生する中で、それらの法的な位置づけに関して理解や問題意識が共有されているかどうかについては、今後も注視する必要があると考えられる。

### 3.2.2.4 情報解析の確保

第四に、機械学習のために他人の著作物等を大量に解析することが著作権侵害に当たらないかどうかの問題となるが、諸外国においても、テキスト及びデータ解析 (text and data mining) に関する著作権の制限規定をめぐって議論が行われている。

既に、英国著作権法には、2014年改正によって、テキスト及びデータ解析 (text and data analysis) に関する権利制限規定 (29A条) が設けられている。同条によれば、非商業的な目的による調査を唯一の目的として (for the sole purpose of research for a non-commercial purpose) 行うコンピュータによる解析 (computational analysis) に伴う複製は、十分な出所明示を行うことを条件として、著作権侵害に当たらないとされる<sup>17</sup>。このように、同条の規定は、解析が非商業的目的 (non-commercial purpose) で行われることを要件としているが、解析自体が非営利の目的で行われていれば、その成果を営利目的で公開したり、商業利用したりすることは妨げられないと解釈されている<sup>18</sup>。

また、ドイツにおいても、2017年2月1日に公表された著作権法改正法案に、60d条 [Text und Data Mining] の規定が見られる<sup>19</sup>。同条によれば、学術的な研究のために多数の著作物を自動的に解析する場合であれば、著作物を複製及び一定の公衆提供することが許容される。ただ、非商業的な目的 (nicht-kommerzielle Zwecke) で行うことが条件とされる。

---

※15

「AIを活用した創作や3Dプリンティング用データの産業財産権法上の保護の在り方」特許庁ウェブサイト<[http://www.jpo.go.jp/shiryoutoushin/chousa/pdf/zaisanken/2016\\_10.pdf](http://www.jpo.go.jp/shiryoutoushin/chousa/pdf/zaisanken/2016_10.pdf)> p.40 以下参照。

※16

知的財産研究所・前掲注(15)p.40以下参照。

※17

和訳については、著作権情報センターウェブサイト・前掲注(14)も参照。

※18

“ Exceptions to copyright: Research, ” GOV.UK. Website <[https://www.gov.uk/government/uploads/system/uploads/attachment\\_data/file/375954/Research.pdf](https://www.gov.uk/government/uploads/system/uploads/attachment_data/file/375954/Research.pdf)>

※19

“ Referentenentwurf: Entwurf eines Gesetzes zur Angleichung des Urheberrechts an die aktuellen Erfordernisse der Wissensgesellschaft (Urheberrechts-Wissensgesellschafts-Gesetz . UrhWissG), ” Bundesministerium der Justiz und für Verbraucherschutz Website <[https://www.bmju.de/SharedDocs/Gesetzgebungsverfahren/Dokumente/RefE\\_UrhWissG.pdf?\\_\\_blob=publicationFile&v=1](https://www.bmju.de/SharedDocs/Gesetzgebungsverfahren/Dokumente/RefE_UrhWissG.pdf?__blob=publicationFile&v=1)>

更に、2016年9月14日に公表された欧州指令案<sup>20</sup>においても、テキスト及びデータ解析に関する権利制限規定が見られる（3条）。同条によれば、適法にアクセスできる著作物等を、科学的調査のためにテキスト及びデータ解析を行う目的で、研究機関（research organisations）によって行われる複製及び抽出に関する権利制限規定を定めることが、加盟国の義務とされる。これに反する契約も無効とされる（同条2項）。ただ、権利者は、著作物等が蔵置されるネットワークやデータベースの、セキュリティが確保されるための措置を請求できる（同条3項）などともされている。

なお、我が国著作権法は、既に平成21年改正〔平成21年法律第53号〕によって、コンピュータ等を用いた情報解析のために行われる複製等を許容する権利制限規定を有している（47条の7）。これは国際的に見て非常に早い段階で導入されたものであるとともに、同条によれば、情報解析が非営利である場合にとどまらず、情報解析が営利目的であっても適用される点で、諸外国の規定よりも適用範囲が広いといえる。

### 3.2.3 今後の展望

#### 3.2.3.1 AI生成物に関する新たな法的保護についての議論

上記のように、我が国及び諸外国においては、人間が創作したと評価できないAI生成物は、著作物として著作権保護を受けられない。しかし、そうすると、AI生成物に投下された資本や労力が他人によってフリーライドされてよいかという課題がある。そのため、AI生成物について、何らかの法的保護を与えるべきではないかという議論がある。

具体的には、AI生成物について、著作隣接権等の特別な権利（Sui generis）を新たに付与することや、不正競争防止法による保護を与えることなどが考えられる。ただ、情報について新たな法的保護を設けることは、情報について新たな独占を認めることであるため、そのような法的保護を与える必要性があるのかどうか、また、法的保護を与えた場合に弊害が生じないかどうかは問題となる。

更に、仮にAI生成物について新たな法的保護を付与するとしても、その保護が著作権による保護より弱いということになると、AI生成物を生み出した者は、それがAI生成物であることを秘匿して、自らが創作したものと僭称することによって著作権保護を主張するようになるのではないかという問題が指摘されている。そのような観点から、AI生成物について著作権保護を認める法改正をすべきとの見解も見られる<sup>21</sup>。今後の議論が注目されるところである。

#### 3.2.3.2 機械学習を促進する権利制限規定の見直しについての議論

我が国著作権法47条の7は、機械学習の促進にとって極めて有用な規定といえる。ただ、同条の規定は、もともと機械学習を想定した規定ではないため、より機械学習の促進に資するよう見直すべきではないかとの議論がある。具体的には、同条における「統計的」という文言を削除すべきではないかという点や、同条の規定が、自ら解析を行わずに情報解析を行う他人のために学習用データセットの作成だけを行う者に適用できることを明確にすべきではないかといった点が問題となる。こうした点は、昨今の著作権法改

※20  
“ Proposal for a Directive of the European Parliament and of the Council on Copyright in the Digital Single Market, ”  
European Commission Website <<https://ec.europa.eu/digital-single-market/en/news/proposal-directive-european-parliament-and-council-copyright-digital-single-market>>

※21  
文献[3]参照。

正に向けた審議においても議論されており<sup>22</sup>、今後の動向が注目される。

### 3.2.3.3 さらなる展望

AIと知的財産法に関する従来の議論においては、①AI生成物の法的保護（著作権法及び特許法関係）、②機械学習のための生データ利用（著作権法47条の7関係）、③AIそれ自体の法的保護（著作権法、特許法、不正競争防止法等関係）といった課題が取り上げられているが、今後更に議論が拡大し、そこでは現在想定されていないような課題が登場する可能性もある。他方、AIというものが、知的財産法に大きな影響をもたらすような「新しい」技術ないし現象なのかという点について、懐疑的な見方もあり得よう。今後とも、AIに関する技術発展を継続的にフォローするとともに、将来を見据えた法的対応について、冷静かつ先進的な取組が有用となろう。

### 参考文献

- [1] Andres Guadamuz, “Do androids dream of electric copyright? Comparative analysis of originality in artificial intelligence generated works,” *Intellectual Property Quarterly*, 2017(2).
- [2] Mark Perry and Thomas Margoni, “From Music Tracks to Google Maps: Who Owns Computer Generated Works,” *Computer Law and Security Review*, 2010, p.621.
- [3] 奥邨弘司「人工知能が生み出したコンテンツと著作権.著作物性を中心に.」『パテント』70巻2号, 2017.2, pp16-19.

---

※22

「新たな時代のニーズに的確に対応した権利制限規定の在り方等に関する報告書」文化庁ウェブサイト<[http://www.bunka.go.jp/seisaku/bunkashingikai/chosakuken/needs\\_working\\_team/h28\\_06/pdf/shiryo\\_1.pdf](http://www.bunka.go.jp/seisaku/bunkashingikai/chosakuken/needs_working_team/h28_06/pdf/shiryo_1.pdf)>の p.30注59も、「47条の7について、『統計的』要件がAIによる深層学習に対応できていないのではない

かといった指摘や複数の主体が協業で情報解析用データベースの作成と情報解析を分担して行う場合に権利制限が適用されないとの疑義がある旨の指摘がある。これらの行為については、権利者の利益を害するものでないことから権利制限の対象となるべき行為である旨の意見が示された。なお、後者の指摘については現行法の解釈によっても対応可能であるとの意見もあった」とする。

## 3.3 倫理

### 3.3.1 背景

従来の技術に比べて、「知性」という人間の本質に近いところについても「人間の代替」になるという、従来の技術にはない側面を持つ人工知能（AI）に対しては、不安や社会における位置づけの難しさへの懸念が、漠然としたものから具体的なものまで、様々にあると想定されている。

このような不安や懸念を想起させるAIの社会実装のリスクについては、AI自身のリスク、人間がAIを利用して引き起こすリスク、既存の社会秩序への負の影響、法律・社会の在り方のリスクが議論されている。具体的なリスクとそれに対する対応の例を以下に示す（表1）。

表1 AIの社会実装に伴って想定されるリスクの内容と対応<sup>1</sup>

| リスク分類         | 具体的なリスクの例   | リスクに対する対応例   |
|---------------|---|--|
| ①AI自身のリスク     | <ul style="list-style-type: none"> <li>・ AIが自らを改変して人間の制御を超える(AIの「暴走」、人間の自律性の喪失)。</li> <li>・ AIのアルゴリズムが不透明化し、人間の制御が困難になる。</li> <li>・ 設計者が間違った目的関数を設計したためAIが想定外のリスクを引き起こす。</li> <li>・ AIが過度に機能してしまう。</li> <li>・ データやモデルが不十分なためにAIが想定外のリスクを起こす。</li> </ul> | <ul style="list-style-type: none"> <li>・ AIへの理解の促進。</li> <li>・ AI技術の品質保証の確立。</li> </ul>                                      |
| ②AIに関わる人間のリスク | <ul style="list-style-type: none"> <li>・ 人間が悪意を持った目的でAIを利用する(例：自律兵器による無差別殺人)。</li> <li>・ 人間がAIに過適応してしまう／それを利用した犯罪(例：AIに恋して盲目的にそれに従ってしまう)。</li> </ul>  | <ul style="list-style-type: none"> <li>・ AI関係者の倫理教育。</li> </ul>  |
| ③社会的負のインパクト   | <ul style="list-style-type: none"> <li>・ AIが人間の雇用を奪ってしまう。</li> <li>・ 人間の知識、スキルの陳腐化が早くなってしまう。</li> <li>・ AIによる個人情報の不透明な収集・利活用がされ管理が不備になる。</li> <li>・ AIが人間の信念・健康等の機微な情報を推論してプライバシーが侵害されたり差別的な不利益を被る。</li> </ul>  | <ul style="list-style-type: none"> <li>・ AIでは対応できないスキルの整理とそれに関する教育・訓練の充実。</li> <li>・ 安全なデータ流通技術/プライバシー保護技術の開発・普及。</li> </ul> |
| ④法律・社会の在り方    | <ul style="list-style-type: none"> <li>・ AIが社会規範上の問題を顕在化させる(例：トロツコ問題)。</li> <li>・ 自律運動するAIが引き起こした事故の責任の所在が曖昧になる。</li> <li>・ AIにより人間が評価されることにより、人間の尊厳が喪失される。</li> <li>・ AIを利用した政治や経営における意思決定を行う際に、責任の所在が不透明になる。</li> </ul>                               | <ul style="list-style-type: none"> <li>・ AIの実装時の法的問題に関する整理・議論・社会的合意形成。</li> <li>・ AIの役割の明確化、プロセスの透明性担保のルールづくり・普及。</li> </ul> |

※1

文献[1]及び「AIネットワーク化が拓く智連社会(WINS) 第四次産業革命を超えた社会に向けて」総務省ウェブサイト<[http://www.soumu.go.jp/main\\_content/000414122.pdf](http://www.soumu.go.jp/main_content/000414122.pdf)>等より作成。

AIの社会実装が現実のものになりつつある中で、このような不安については専門家のみならず、一般の話題になることも増えてきている。

こうした中で、不安について冷静に整理し、対応について検討することが重要であると認識され、2016年以降、主要なAIのプレーヤーや政府機関等で盛んに議論が進められ、報告書、提言、ガイドラインが数多く公表されている。

### 3.3.2 取組動向

#### 3.3.2.1 国内における取組

##### (1) 政府における取組

総合科学技術・イノベーション会議の「人工知能と人間社会に関する懇談会」が2016年から2017年1月に設置された。倫理、法、制度、経済、社会的影響など幅広い観点から、AIが進展する未来の社会を見据えて、国内外の動向を俯瞰した上で、AIと人間社会の関わりについて今後取り組むべき課題や方向性の検討が行われた（表2）。

表2「人工知能と人間社会に関する懇談会」論点整理の概要<sup>※2</sup>

| 論点分類    | 内容  |
|---------|---|
| 倫理的論点   | 人工知能技術の進展に伴って生じる、人と人工知能・機械の関係性の変化と倫理観の変化                    |
|         | 人工知能に知らぬ間に感情や信条、行動が操作されたり、順位づけ・選別されたりすることへの懸念。感情を含む人間観の捉え直し |
|         | 人工知能が関与する行為・創造に対する価値の検討、価値観やビジョンの多様性の確保                     |
| 法的論点    | 人工知能による事故等の責任分配の明確化。人工知能を使うリスク、使わないリスクの考慮                   |
|         | ビッグデータを活用した人工知能の利便性確保と個人情報保護の両立                             |
|         | 人工知能を活用した創作物の権利とインセンティブの検討                                  |
| 経済的論点   | 人工知能による働き方の変化：個人対象  |
|         | 人工知能の利活用による雇用形態と企業の変化：企業対象                                  |
|         | 人工知能の利活用を促進するための政策：国対象                                      |
| 社会的論点   | 人工知能との関わり方の自由、忘れられる権利                                       |
|         | 人工知能による格差、デバインド。人工知能に関連する社会的コストの不均衡                         |
| 教育的論点   | 人工知能を利活用するための個人の能力の育成                                       |
|         | 人にしかできない能力の育成   |
| 研究開発的論点 | 倫理観、アカウントビリティ、セキュリティ確保、プライバシー保護                             |
|         | 制御可能性、透明性   |
|         | 人工知能に関する適切な情報公開と、それに基づく責任ある使用判断                             |

※2

「人工知能と人間社会に関する懇談会」報告書] 総合科学技術会議ウェブサイト<[http://www8.cao.go.jp/cstp/tyousakai/ai/summary/aisociety\\_jp.pdf](http://www8.cao.go.jp/cstp/tyousakai/ai/summary/aisociety_jp.pdf)>より作成。

総務省では、AIネットワーク化検討会議を設置し「AIネットワーク化」が社会・経済にもたらす影響とリスクの基礎的な評価を行った上で、AIの開発原則・指針の策定等今後の課題を整理している。

## (2) 民間における取組

人工知能学会倫理委員会では、2016年6月に「人工知能研究者の倫理綱領（案）」を公開して議論を続けてきたが、2017年2月に「人工知能学会 倫理指針」として正式に発表した（表3）。学会からは「今後

表3 人工知能学会 倫理指針の内容<sup>※3</sup>

| 項目              | 内容  |
|-----------------|---|
| 1 人類への貢献        | 人工知能学会会員は、人類の平和、安全、福祉、公共の利益に貢献し、基本的人権と尊厳を守り、文化の多様性を尊重する。人工知能学会会員は人工知能を設計、開発、運用する際には専門家として人類の安全への脅威を排除するように努める。  |
| 2 法規制の遵守        | 人工知能学会会員は専門家として、研究開発に関わる法規制、知的財産、他者との契約や合意を尊重しなければならない。人工知能学会会員は他者の情報や財産の侵害や損失といった危害を加えてはならず、直接的のみならず間接的にも他者に危害を加えるような意図をもって人工知能を利用しない。   |
| 3 他者のプライバシーの尊重  | 人工知能学会会員は、人工知能の利用および開発において、他者のプライバシーを尊重し、関連する法規に則って個人情報の適正な取扱いを行う義務を負う。   |
| 4 公正性           | 人工知能学会会員は、人工知能の開発と利用において常に公正さを持ち、人工知能が人間社会において不公平や格差をもたらす可能性があることを認識し、開発にあたって差別を行わないよう留意する。人工知能学会会員は人類が公平、平等に人工知能を利用できるように努める。  |
| 5 安全性           | 人工知能学会会員は専門家として、人工知能の安全性及びその制御における責任を認識し、人工知能の開発と利用において常に安全性と制御可能性、必要とされる機密性について留意し、同時に人工知能を利用する者に対し適切な情報提供と注意喚起を行うように努める。  |
| 6 誠実な振る舞い       | 人工知能学会会員は、人工知能が社会へ与える影響が大きいことを認識し、社会に対して誠実に信頼されるように振る舞う。人工知能学会会員は専門家として虚偽や不明瞭な主張を行わず、研究開発を行った人工知能の技術的限界や問題点について科学的に真摯に説明を行う。  |
| 7 社会に対する責任      | 人工知能学会会員は、研究開発を行った人工知能がもたらす結果について検証し、潜在的な危険性については社会に対して警鐘を鳴らさなければならない。人工知能学会会員は意図に反して研究開発が他者に危害を加える用途に利用される可能性があることを認識し、悪用されることを防止する措置を講じるように努める。また、同時に人工知能が悪用されることを発見した者や告発した者が不利益を被るようなことがないように努める。 |
| 8 社会との対話と自己研鑽   | 人工知能学会会員は、人工知能に関する社会的な理解が深まるよう努める。人工知能学会会員は、社会には様々な声があることを理解し、社会から真摯に学び、理解を深め、社会との不断の対話を通じて専門家として人間社会の平和と幸福に貢献することとする。人工知能学会会員は高度な専門家として絶え間ない自己研鑽に努め自己の能力の向上を行うと同時にそれを望む者を支援することとする。                  |
| 9 人工知能への倫理遵守の要請 | 人工知能が社会の構成員またはそれに準じるものとなるためには、上に定めた人工知能学会会員と同等に倫理指針を遵守できなければならない。   |

※3

人工知能学会 倫理委員会 ウェブサイト <<http://ai-elsi.org/wp-content/uploads/2017/02/%E4%BA%BA%E5%B7%A5%E7%9F%A5%E8%83BD%E5%AD%A6%E4%BC%9A%E5%80%A8%E7%90%86%E6%8C%87%E9%87%9D.pdf>>より作成。

の人工知能学会と社会との対話に向けた大まかな方針になるものをまず掲げることにある」という趣旨が表明されており、今後の議論のベースになることが期待される。

### 3.3.2.2 海外における取組

#### (1) 政府における取組

米国政府は、2016年10月発行の“PREPARING FOR THE FUTURE OF ARTIFICIAL INTELLIGENCE”<sup>4</sup>では、AIが人間の意思決定を代替するようになっていく際には正義・公正・アカウントビリティに留意が必要であること、AIの実務家や学生に対して倫理教育が必要であることを論じている。

同じく2016年10月発行の“THE NATIONAL ARTIFICIAL INTELLIGENCE RESEARCH AND DEVELOPMENT STRATEGIC PLAN”<sup>5</sup>では「研究者は、透明性があり、利用者に対して判断結果の理由を実質的に説明することのできるAIシステムを開発することが必要である」として透明性の確保が言及されている。

また、2016年12月の“ARTIFICIAL INTELLIGENCE, AUTOMATION, AND THE ECONOMY”<sup>6</sup>では、AIの普及が最大300万人超の雇用に影響を与える可能性があり、それに対応した労働人口の育成の必要性に言及している。

さらに、英国では下院議会がロボティクス及びAIのプログラミング及び利用に起因する倫理的・法的問題について検討・考察している。

EUではAIを含むロボット技術が進展した場合の法律の在り方や、人々の価値観や社会行動の変化を議論することを目的として、2012年から2年間に渡り「RoboLaw.欧州における新興技術規制：ロボット技術に対する法と倫理」(Regulating Emerging Technologies in Europe: Robotics Facing Law and Ethics) と呼ばれるプロジェクトが行われた。<sup>7</sup>

#### (2) 民間における取組

政府による取組に加え、民間においても学会や大学で議論が進められてきた。先駆的な取組の事例としては以下のようなものが挙げられる。

##### 1) AAAI [Presidential Panel on Long-Term AI Futures:2008-2009 Study]<sup>8</sup>

米人工知能学会 (AAAI) では、“Presidential Panel on Long-Term AI Futures:2008-2009 Study” (2008-2009年) として23名の研究者が集まって、AIの社会的な課題等について三つのサブグループで議論を行った。この中には「倫理・法的課題」サブグループがあり、AIの予期せぬ行動に関連した責任割り当ての問題、ロボットへの感情的な問題等について議論が行われた。

---

※4

“ PREPARING FOR THE FUTURE OF ARTIFICIAL INTELLIGENCE,” obamawhitehouse.archives.gov Website <[https://obamawhitehouse.archives.gov/sites/default/files/whitehouse\\_files/microsites/ostp/NSTC/preparing\\_for\\_the\\_future\\_of\\_ai.pdf](https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/preparing_for_the_future_of_ai.pdf)>

※5

“ THE NATIONAL ARTIFICIAL INTELLIGENCE RESEARCH AND DEVELOPMENT STRATEGIC PLAN, ” obamawhitehouse.archives.gov Website <[https://obamawhitehouse.archives.gov/sites/default/files/whitehouse\\_files/microsites/ostp/NSTC/national\\_ai\\_rd\\_strategic\\_plan.pdf](https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/national_ai_rd_strategic_plan.pdf)>

※6

The White House Website <<https://www.whitehouse.gov/sites/whitehouse.gov/files/images/EMBARGOED%20AI%20Economy%20Report.pdf>>

※7

RoboLaw Website <<http://www.robotlaw.eu/>>

※8

Association for the Advancement of Artificial Intelligence ( AAAI ) Website <<http://www.aaai.org/Organization/presidential-panel.php>>

## 2) スタンフォード大学「AI100」<sup>9</sup>

AAAIでの議論を受けて、スタンフォード大学ではAI100 (One Hundred Year Study on Artificial Intelligence) が2014年に立ち上げられた。2016年には“Artificial Intelligence and Life in 2030”が公表され、プライバシー、AIが関わる民事責任／刑事責任、AIの人間に対する代理性、AIの能力の認証等の観点から法的・政策的な問題を整理している。

## 3) オックスフォード大学「The Future of Humanity Institute」<sup>10</sup>

オックスフォード大学のThe Future of Humanity Institute (FHI) は、学際的なアプローチでAIの安全性に関する研究や啓蒙活動を2005年から行ってきた。Google DeepMind (英国) やAIを研究する非営利団体OpenAI<sup>11</sup>等と連携をしており、2016年にはGoogle DeepMindとの週次のミーティングと月次のセミナーを開催した。

また、2016年以降は議論が盛んに行われており、メジャープレイヤーの個別の取組、また競合関係を越えた企業連合やNPOを通じた取組がなされている。

Microsoftは2016年6月に、AI開発原則を発表している。「AIに求められるもの」として①人間の「置き換え」でなく「拡張するもの」、②透明性の確保、③多様性の確保、④プライバシーの保護、⑤説明責任の義務、⑥偏見の排除を提唱。AI時代に「人間に求められるもの」として①共感力、②教育、③創造力、④結果に対する責任が挙げられている。他社に先行した取組は、AIのメインプレイヤー入りの宣言とも受け取れる。

Facebook、Amazon、Alphabet (Google)、IBM、Microsoftが2016年9月に設立したPartnership on Artificial Intelligence to Benefit People and Society<sup>12</sup>も、このような問題にも取り組んでおり、競合関係を越えてAIのメジャープレイヤーの大部分が参画したことで注目される(2017年5月には、ソニーの参加が認められた)。設立時にTenets (信条) として、AIに関して自分たちの取り組むべき原則を発表しており、その中では例えば「AIシステムの動作は、その技術を説明するため、人々の理解と解釈が可能なものであることが重要である。」と言及されている。また、官民連携の取組として、ホワイトハウスの“PREPARING FOR THE FUTURE OF ARTIFICIAL INTELLIGENCE”の作成の支援も行っている。

Tesla Motors (米国) のCEOとして知られるイーロン・マスク (Elon Musk) 氏等が2015年に非営利団体として設立したOpenAIは、技術的な取組以外にAIの安全性に関する具体的な課題の対応として「失敗モデルへの五つの対応」として整理している。

2017年1月の世界経済フォーラムで、IBMのバージニア・ロメッティ (Virginia M. Rometty) 会長は、AIの技術を導入する際に従うべき基本的な原則についてプレゼンテーションを行った。これは、AI実装先駆者としてのポジション維持に向けて、倫理的課題への取組をアピールしたとも受け取れる。

また、2017年1月にはLinkedIn (米国) 共同創業者のリード・ホフマン (Reid Hoffman) 氏等が、「AIの倫理とガバナンスのための基金」(Ethics and Governance of Artificial Intelligence Fund) を創設した<sup>13</sup>。

---

※9  
One Hundred Year Study on Artificial Intelligence (AI100)  
Website <<https://ai100.stanford.edu/>>

※10  
The Future of Humanity Institute Website <<https://www.fhi.ox.ac.uk/>>

※11  
OpenAI Website <<https://openai.com/>>

※12  
Partnership on AI to Benefit People and Society Website  
<<https://www.partnershiponai.org/>>

※13  
Knightfoundation Website <<https://www.knightfoundation.org/press/releases/knight-foundation-omidyar-network-and-linkedin-founder-reid-hoffman-create-27-million-fund-to-research-artificial-intelligence-for-the-public-interest>>

そして2017年2月にはFLI（Future of Life Institute）が、“ASILOMAR AI PRINCIPLES”として23の開発原則を発表した（表4）。これには2,000名以上の研究者・実務者が賛同を表明しており、学会・産業界を通じた議論の土台となることが期待される。

■表4 ASILOMAR AI PRINCIPLESの内容<sup>14</sup>

| カテゴリ    | 内容  |
|---------|---|
| 研究      | 1) AI研究の目標は、無秩序な知能ではなく有益な知能の開発である。  |
|         | 2) AIへの投資は、コンピュータ科学、経済、法律、倫理、社会学の観点から有益と考えられる研究に向ける。                      |
|         | 3) AI研究者と政治家の間で、建設的で健全な対話を行う。   |
|         | 4) 研究者や開発者の間には協力、信頼、透明性の文化を育くむ。   |
|         | 5) AIの開発チーム同士での競争により安全基準を軽視することがないように、チーム同士で協力しあう。                        |
| 倫理と価値基準 | 6) AIシステムはその一生を通して、できる限り検証可能な形で安全、堅牢である。                                  |
|         | 7) AIシステムが害をなした場合、原因を確認できるようにする。  |
|         | 8) 自動システムが司法判断に関わる場合、権限を持つ人間が監査し、納得のいく説明を提供できるようにする。                      |
|         | 9) AIシステムの開発者は、システムの使用、悪用、結果に倫理的な関わりがありどう使用されるかを形作る責任と機会がある。              |
|         | 10) 自動的なAIシステムは、目標と行動が倫理的に人間の価値観と一致するようデザインする。                            |
|         | 11) AIシステムは、人間の尊厳、権利、自由そして文化的多様性と矛盾しないようデザイン、運営しなければならない。                 |
|         | 12) AIには人間のデータを分析し、利用する力があるため、データを提供する人間は自分のデータを閲覧、管理、コントロールする権利が与えられる。   |
|         | 13) AIによる個人情報の利用は、人間が持つ、あるいは持つと思われる自由を理不尽に侵害してはならない。                      |
|         | 14) AI技術は可能な限り多くの人間にとって有益で力を与えるべきだ。                                       |
|         | 15) AIによる経済的利益は広く共有され、人類全てにとって有益であるべきだ。                                   |
|         | 16) 人間によって生まれた目標に関して、AIシステムにどのように決定を委ねるのか、そもそも委ねるのかどうかを人間が判断すべきだ。         |
|         | 17) 高度なAIシステムによって授かる力は、社会の健全に不可欠な社会過程や都市過程を阻害するのではなく、尊重、改善させるものであるべきだ。    |
|         | 18) 危険な自動兵器の軍拡競争が起きてはならない。  |
| 長期的な問題  | 19) 一致する意見がない以上、未来のAIの可能性に上限があると決めてかかるべきではない。                             |
|         | 20) 発達したAIは地球生命の歴史に重大な変化を及ぼすかもしれないため、相応の配慮と資源を用意して計画、管理しなければならない。         |
|         | 21) AIシステムによるリスク、特に壊滅的なものや存亡の危機に関わるものは、相応の計画と緩和対策の対象にならなければならない。          |
|         | 22) あまりに急速な進歩や増殖を行うような自己改善、又は自己複製するようにデザインされたAIは、厳格な安全管理対策の対象にならなければならない。 |
|         | 23) 超知能は、広く認知されている倫理的な理想や、人類全ての利益のためにのみ開発されるべきである。                        |

※14

Future of Life Institute Website <<https://futureoflife.org/ai-principles/>>より作成。

### (3) 国際的な枠組みでの議論

2016年12月には、IEEEがAIを人間の倫理的価値に沿ったものにするための指針を包括的に検討・公開し、2017年3月までパブリックコメントを募集した。業界標準となりうる取組であり、原則論と技術的対応を包括したものとして注目される。

具体的には“ETHICALLY ALIGNED DESIGN : A Vision for Prioritizing Human Wellbeing with Artificial Intelligence and Autonomous Systems”<sup>15</sup>のドラフト案を公開している。

その趣旨は、AIの倫理的、法的及び社会的含意を理解し、それらに対処するAI技術は人間が拘束される公式及び非公式の規範に従って行動することが期待されるため、AIの倫理的、法的及び社会的含意を理解し、倫理的、法的及び社会的目標に合致するAIシステムを設計する方法を開発するための研究が必要となっているというものである。

その一例として、航空分野における「フライトレコーダー」のように、コンピュータが異常な、あるいは危険な振る舞いをした際のアルゴリズムのトレーサビリティが、原因の特定の考察に寄与することが述べられている。また、このようなプロセスがやや不透明な場合は、検証する間接的な手段を探索し、害を及ぼすものを検知。更に、ブラックボックスのソフトウェアを採用する際には、特別な注意と倫理的配慮をすべきであることも言及されている。

一方、OECDではデジタル化によって生じる便益と課題洗い出しのプロジェクトを“OECD Seizing the benefits of digitalization for growth and well - being”として組成し、以下の課題の検討を予定している。

- 経済と社会の非中央化・中枢化への対応
- デジタル化によって生じる職業の変化
- 将来必要となるスキル・知識
- デジタルイノベーション、規制、政治経済の変革
- 生産性と包括的成長
- デジタル化で生じる社会的・環境的課題
- 実証的で評価の伴う政策への移行

---

※15

IEEE Website <[http://standards.ieee.org/develop/indconn/ec/ead\\_v1.pdf](http://standards.ieee.org/develop/indconn/ec/ead_v1.pdf)>

表5 欧米におけるAIに関わる倫理をめぐる官民の動き

| 時期         | 事項  |
|------------|---|
| 2005年      | ・オックスフォード大学が“The Future of Humanity Institute”を創設。  |
| 2008-2009年 | ・AAAI Presidential Panel on Long-Term AI Futures:2008-2009 Studyを実施。  |
| 2012年      | ・ケンブリッジ大学がCentre for the Study of Existential Risk (CSER)を創設。   |
| 2012-2013年 | ・EUが“Regulating Emerging Technologies in Europe: Robotics Facing Law and Ethics”プロジェクトを実施。  |
| 2014年      | ・スタンフォード大学が“AI100” (One Hundred Year Study on Artificial Intelligence)を立ち上げ。  |
| 2015年      | ・イーロン・マスク氏等が非営利団体OpenAIを創設し、議論を開始。  |
| 2016年6月    | ・Microsoftが「AI開発原則」を発表。   |
| 2016年9月    | ・Facebook、Amazon、Alphabet(Google)、IBM、Microsoftが“Partnership on Artificial Intelligence to Benefit People and Society”(いわゆる5社連合)を創設し、議論を開始。 |
| 2016年9月    | ・英国下院科学技術委員会が“Robotics and artificial intelligence”を発表。   |
| 2016年10月   | ・米国政府が“PREPARING FOR THE FUTURE OF ARTIFICIAL INTELLIGENCE”を発表。   |
| 2016年10月   | ・米国政府が“THE NATIONAL ARTIFICIAL INTELLIGENCE RESEARCH AND DEVELOPMENT STRATEGIC PLAN”を発表。  |
| 2016年12月   | ・米国政府が“ARTIFICIAL INTELLIGENCE, AUTOMATION, AND THE ECONOMY”を発表。  |
| 2016年12月   | ・IEEEが“ETHICALLY ALIGNED DESIGN : A Vision for Prioritizing Human Wellbeing with Artificial Intelligence and Autonomous Systems”のドラフト案を公開。  |
| 2017年1月    | ・世界経済フォーラムでIBMのバージニア・ロメッティ会長がAIの技術を導入する際に従うべき基本的な原則についてプレゼンテーションを実施。  |
| 2017年1月    | ・LinkedIn共同創業者のリード・ホフマン氏等が“Ethics and Governance of Artificial Intelligence Fund”を創設。   |
| 2017年1月    | ・欧州議会が「ロボティクスにかかる民法規則に関する欧州委員会への提言に関する報告書案」を採択。   |
| 2017年2月    | ・FLI(Future of Life Institute)が“ASILOMAR AI PRINCIPLES”として23の開発原則を発表。   |
| 2017-2018年 | ・OECD “Seizing the benefits of digitalization for growth and well - being”プロジェクトを実施予定。  |

## 参考文献

[1] 松尾豊「人工知能と倫理」『情報処理学会誌』 Vol.57 No.10, 2016.9.

## 3.4 規制緩和・新たなルール形成

人工知能（AI）によって従来は考えられなかった自動化、無人化が可能になった場合、従来は人間が行うことを前提として形成されていた、当該分野の制度の見直しが必要になる可能性がある。

一つは既存の規制が障壁となり、AIの活用を十分に実現することができないため、規制緩和が必要になる場合がある。もう一つは、既存のルールがなく、AI活用の拠り所が十分でないために活用が進まない場合がある。この場合には新たなルール作りが必要となる。

本節では、このような規制緩和と新たなルール形成の典型事例として、自動運転、ドローン、健康・医療・介護、物・サービスへのニーズとのマッチングや効率化の4分野を取り上げる。

### 3.4.1 自動運転

AIの発展に伴い自動車の自動運転が現実のものになりつつある中で、関連制度との関係の整理、規制緩和が各所で始まっている。

自動運転はまず、現在の法規上許されるのかという観点からは、ジュネーブ道路交通条約やウィーン道路交通条約との関係が議論されてきた。両条約では「車両における運転者の存在」「運転者による車両の操縦」「運転者による車両の制御」が規定されており、自動運転との整合性が取れない懸念があった。しかし、道路交通条約に関する議論を進めている国際連合欧州経済委員会の道路交通安全作業部会（以下「WP 1」）では、自動運転の急速な進展に合わせて条約の改正作業を行ってきた。その結果、国際基準に適合している場合又は運転者によるオーバーライド又はスイッチオフが可能な場合は、その運転自動化システムを許容することを認めるものという改正案が、2014年から2015年にかけて採択されている。

更に、2016年にはWP 1の会議において、公道実証実験に関して、自動車を制御する運転者は、自動車内にいるか否かを問わないという解釈上の合意がなされた（表6）。

このような国際的な合意を受けて、例えば、ウィーン道路交通条約を批准しているドイツでは上記の条約改正内容に対応した国内法の改正作業が行われ、2016年9月に連邦議会で可決された。

自動運転に関わる制度検討が活発に行われている国としては英国が挙げられる。英国運輸省では2015年2月に“The Pathway to Driverless Cars . A detailed review of regulations for automated vehicle technologies”を公表し、英国の現行の法制度上で公道における自動運転の実証実験は可能である旨の見解を示した。更に、2015年7月には公道実験のガイドラインとして“The Pathway to Driverless Cars . A Code of Practice for testing”を発行し、実証実験の実施環境を整えた。そして、2016年7月には“The Pathway to Driverless Cars: Proposals to support advanced driver assistance systems and automated vehicle technologies”を発行し、自動運転に関する技術進歩を将来まで見通すことが困難なため、段階的な法改正を継続的に繰り返す漸進的なアプローチをとるという姿勢を示している。同文書では保険制度の改正、商用化が想定されるシステムの製造・使用規定、交通規範の改正の検討がうたわれており、それに対するパブリックコメントを踏まえた制度改正の具体化が見込まれている。

米国では、交通法規の制定は州政府が行っていることから、自動運転に関する規制緩和やルール形成は先進的な州において推進されてきた。2011年にネバダ州で、自動運転車の走行や運転免許が許可制として定められたのを皮切りに、2012年にはカリフォルニア州における自動運転車の公道走行に必要な安全基準・性能基準の制定、2013年にはミシガン州で条件付きの自動運転の公道実験の許可とベースとなる車の製造者責任の規定等、各州での取組が進み、民間企業による公道での実証等（例：Google Car）のバックボーンとなった。こうした動きを受けて、2016年には運輸省道路安全交通局（NHTSA）が“Federal Automated Vehicles Policy”を公表し、自動運転車の15項目の安全評価基準を挙げている。今後これ

■表6 自動運転に関わる国際道路交通条約の概要と改正内容<sup>1</sup>

|       | 1949年ジュネーブ道路交通条約   | 1968年ウィーン道路交通条約  |
|-------|--|--|
| 主な批准国 | 米国、日本、英国、スペイン、カナダ、オーストラリア  | 欧州諸国、ブラジル  |
| 従前の条文 | 第8.1条<br>一単位として運行されている車両又は連結車両にはそれぞれ運転者がいなければならない。   | 第8.1条<br>あらゆる走行中の車両が連結車両には、運転者がいなければならない。  |
|       | 第8.5条<br>運転者は、常に、車両を適正に操縦し、又は動物を誘導することができなければならない。運転者は、他の道路使用者に接近するときは、当該他の道路使用者の安全のために必要な注意を払わなければならない。             | 第8.5条<br>あらゆる運転者は、常に、車両を制御するか、又は動物を誘導しなければならない。  |
|       | 第10条<br>車両の運転者は、常に車両の速度を制御していなければならない。また、適切かつ慎重な方法で運転しなければならない。運転者は、状況により必要とされるとき、特に見とおしがきかないときは、徐行し、または停止しなければならない。 | 第13.1条<br>車両のあらゆる運転者は、いかなる状況においても、当然かつ適切な注意をして、運転者に必要であるすべての操作を実行する立場にいつもいることができるよう車両を制御下におかななければならない。(後略)       |
| 改正案   | 第8.6条第1文<br>車両の運転方法に影響を及ぼす車両のシステムは、国際基準に適合しているときは、第8.5条及び第10条に適合するものとみなす。  | 第8.5条第1文<br>車両の運転方法に影響を及ぼす車両のシステムは、国際基準に適合しているときは、第8.5条及び第13.1条に適合するものとみなす。                                      |
|       | 第8.6条第2文<br>車両の運転方法に影響を及ぼす車両のシステムは、国際基準に適合していない場合であっても、運転者によるオーバーライドまたはスイッチオフが可能であるときは、第8.5条及び第10条に適合するものとみなす。       | 第8.5条第2文<br>車両の運転方法に影響を及ぼす車両のシステムは、国際基準に適合していない場合であっても、運転者によるオーバーライドまたはスイッチオフが可能であるときは、第8.5条及び第13.1条に適合するものとみなす。 |
| 採択    | 2015年3月  | 2014年3月  |
| 施行    | 未施行  | 2016年3月  |

をベースに制度検討が進展するものと考えられる。

我が国では、道路交通法を所轄する警察庁が、2016年5月に「自動走行システムに関する公道実証実験のためのガイドライン」を発表した。更に、2016年6月から2017年3月まで「自動運転の段階的実現に向けた調査検討委員会」を開催して、高速道路での準自動パイロットの実用化に向けた運用上の課題、限定地域での遠隔型自動走行システムによる無人自動走行移動サービスの公道実証実験の実施に向けた制度的課題等の検討を行った。

このうち、実用化が近いと考えられる高速道路での準自動パイロットについて、①本線車道における速度の在り方、②本線車道への入り方等、③渋滞時の本線車道への合流方法、④流出のための渋滞がある場合における路側帯通行・停車、⑤緊急時における路側帯通行・停車といったそれぞれの課題を抽出し、表7のように対応方針を整理している。

自動車損害賠償保障法を所管している国土交通省は、「自動運転における損害賠償責任に関する研究会」を開催している。民間ベースでは一般社団法人日本損害保険協会が、自動運転の実現に伴う法的課題を整

※1  
各種公表資料より作成。

理している。この中では、自動運転車による事故が発生した場合の損害賠償責任について、自動車損害賠償保障法に基づき考え方を整理するとともに、今後の課題の検討がされている（表8）。

■表7 高速道路での準自動パイロットの実用化に向けた運用上の課題<sup>2</sup>

凡例（図1～5）： 自動運転車 一般車 課題

| 課題                             | 指摘概要・対応方針  | イメージ図             |
|--------------------------------|--|-------------------|
| ①本線車道における速度の在り方について            | <p>◇本線車道において、最高速度規制を遵守していない車両が多い場合があるが、自動運転車が速度規制を遵守することにより、速度規制を超えて実勢速度に合わせて通行する他の車両との速度差が生じ、追突事故や渋滞発生の原因となる可能性。</p> <p>➡</p> <ul style="list-style-type: none"> <li>・道路利用者は速度規制を遵守すべき。</li> <li>・平成22年以降速度規制の見直しを随時実施。</li> </ul>  | <p>&lt;図1&gt;</p> |
| ②本線車道への入り方等について                | <p>◇加速車線（規制速度60km/hと解釈できる。）において、本線車道を通行している車両の速度に近い速度にまで加速して合流することが一般的に行われているが、当該行為が法令に違反しないのが不明確。</p> <p>◇法令違反であるとする、自動運転車が規制速度を遵守することにより、実勢速度に合わせて通行する他の車両との速度差が生じ、追突事故の原因となる可能性。</p> <p>➡ 本線車道への入り方等について、関係法令上の位置付けを含めて可及的速やかに検討する必要。</p>   | <p>&lt;図2&gt;</p> |
| ③渋滞時の本線車道への合流方法について            | <p>◇本線車道が渋滞している場合に、自動運転車が本線車道に合流するために、渋滞中の車両の前方に自車のフロント部分を差し込む行為が、禁止行為である進行妨害に該当するのかが不明確。</p> <p>◇禁止行為に該当するのであれば、法令を遵守する自動運転車が渋滞時に本線車道に合流することは極めて困難。</p> <p>➡ 渋滞時の本線車道への合流方法について、関係法令上の位置付けを含めて検討する必要。</p>   | <p>&lt;図3&gt;</p> |
| ④流出のための渋滞がある場合における路側帯通行・停車について | <p>◇本線車道から出ようとするための車両の渋滞が高速道路の出口から本線車道まで続いており、渋滞の列が本線車道の路側帯に形成されているときに、路側帯を走行しながら渋滞に追従又は路側帯で停車する行為が通行区分の原則に違反しないのか、路側帯における停車等が認められる場合に該当するのかが不明確。</p> <p>◇当該行為が法令に違反するか又は停車等が認められる場合に該当しないのであれば、法令を遵守して走行する自動運転車は、本線車道から出するために、減速車線又は流出路の渋滞の列の途中に強引に割り込むなどの行為を行わざるを得ない。</p> <p>➡ 流出のための渋滞がある場合における路側帯通行・停車について、関係法令上の位置付けを含めて検討する必要。</p> | <p>&lt;図4&gt;</p> |
| ⑤緊急時における路側帯通行・停車について           | <p>◇緊急時に、自動運転によって路側帯に停車する行為が通行区分の原則に違反しないのか、停車等が認められる場合に該当するのかが不明確。</p> <p>◇当該行為が法令に違反するか又は停車等が認められる場合に該当しないのであれば、当該行為を行うような機能を自動運転車両に備えることはできず、例えば、自動走行システムの故障により自動運転を継続できなくなった場合には、本線車道上で、運転者に操作を委譲する必要があり、危険を伴う。</p> <p>➡ 自動走行システムの故障時等、緊急時における路側帯通行・停車について、関係法令上の位置付けを含めて検討する必要。</p>   | <p>&lt;図5&gt;</p> |

※2  
「自動運転の段階的実現に向けた調査研究報告書(概要)」警察庁ウェブサイト<<https://www.npa.go.jp/bureau/traffic/council/jido unten/28houkokusyogaiyou.pdf>>

■表8 自動運転（レベル4）導入に伴い想定される損害保険制度に関わる課題例<sup>3</sup>

| 視点           | 課題   |
|--------------|--|
| ①事故原因の分析     | ドライバーに起因する事故は減少すると期待される。一方で、従来にはない事故として、システムの欠陥・故障を原因とする事故、道路・信号等の交通インフラの欠陥・故障を原因とする事故、サイバー攻撃を原因とする事故などが考えられる。これら事故原因の多様化に対応した事故分析の仕組みを構築する必要が出てくる。具体的には、事後的に事故時の自動車の制動状況、交通インフラの状況等を調査し、事故との因果関係を明らかにするために、ドライブレコーダーやイベント・データ・レコーダー（EDR）による分析を可能にする必要がある。 |
| ②サイバーリスクへの対応 | 対人事故については、サイバー攻撃により事故が発生したとしても、「誰」が行ったのかを特定することができない場合は、「第三者の故意があったこと」を立証したことにはならないと判断される可能性がある。その場合、自賠責保険の免責要件が成立しないことになり、運行供用者が損害賠償責任を負う可能性も考えられる。   |
| ③保有者・運転者の補償  | 自賠法では、自動車事故により保有者や運転者がケガをした場合、同法第3条の「他人」に該当しないため、救済対象からは除かれるが、レベル4における法的枠組みの検討においては、誰が被害者であるかとの観点から、救済すべき範囲を検討する必要がある。   |
| ④過失割合の複雑化    | 事故の原因として、当事者の過失以外にも、システムの欠陥、道路等インフラの欠陥といったことが関係してくる可能性があり、それらを考慮すると責任関係が複雑化し、過失割合の決定が困難になることも考えられる。  |

なお、2016年11月には東京海上日動火災保険が、自動運転中の事故を対象にした自動車保険の特約を2017年4月から無料で契約者に提供すると発表している。

経済産業省は国土交通省と共同で「自動走行ビジネス検討会」を設置し2015年から活動を行ってきた。この報告の中で、自動運転導入に伴い想定される法的責任についてもとりまとめているが、多くの法制度との関係が示唆されており、今後検討が進むことが想定される（表9）。

■表9 自動運転導入に伴い想定される法的責任<sup>4</sup>

| 責任を負う個人／法人 |                 | 製品等   | 責任                     | 責任根拠                        |
|------------|-----------------|---|------------------------|-----------------------------|
| 運転者        |                 |  | 刑事責任                   | 自動車運転死傷行為処罰法<br>刑法<br>道路交通法 |
|            |                 |   | 行政処分                   | 道路交通法                       |
| 運行供用者      |                 | —   | 不法行為責任                 | 民法                          |
| 使用者        |                 | —   | 運転供用者責任                | 自動車損害賠償保障法                  |
| 事業者        | 損害保険会社          | 自動車損害賠償責任保険   | 使用者責任                  | 民法                          |
|            | 完成車メーカー         | 自動車   | 補填責任                   | 自動車損害賠償保障法／契約               |
|            | 部品メーカー          |   | 製造物責任                  | 製造物責任法                      |
|            | ソフトウェア等サービス事業者等 |   | 不法行為責任<br>(製造物責任法の対象外) | 民法                          |
|            | 販売事業者           |   | 瑕疵担保責任                 |                             |
|            | 整備事業者           | 債務不履行   |                        |                             |
|            | 民間設備管理者         | 整備・修理   | 不法行為責任・使用者責任・工作物責任     |                             |
|            | 高速道路会社          | 設備・管理   | 当造物責任に準ずる責任            | 道路整備特別措置法等                  |
| 行政         |                 | 当造物責任   | 国家賠償法                  |                             |

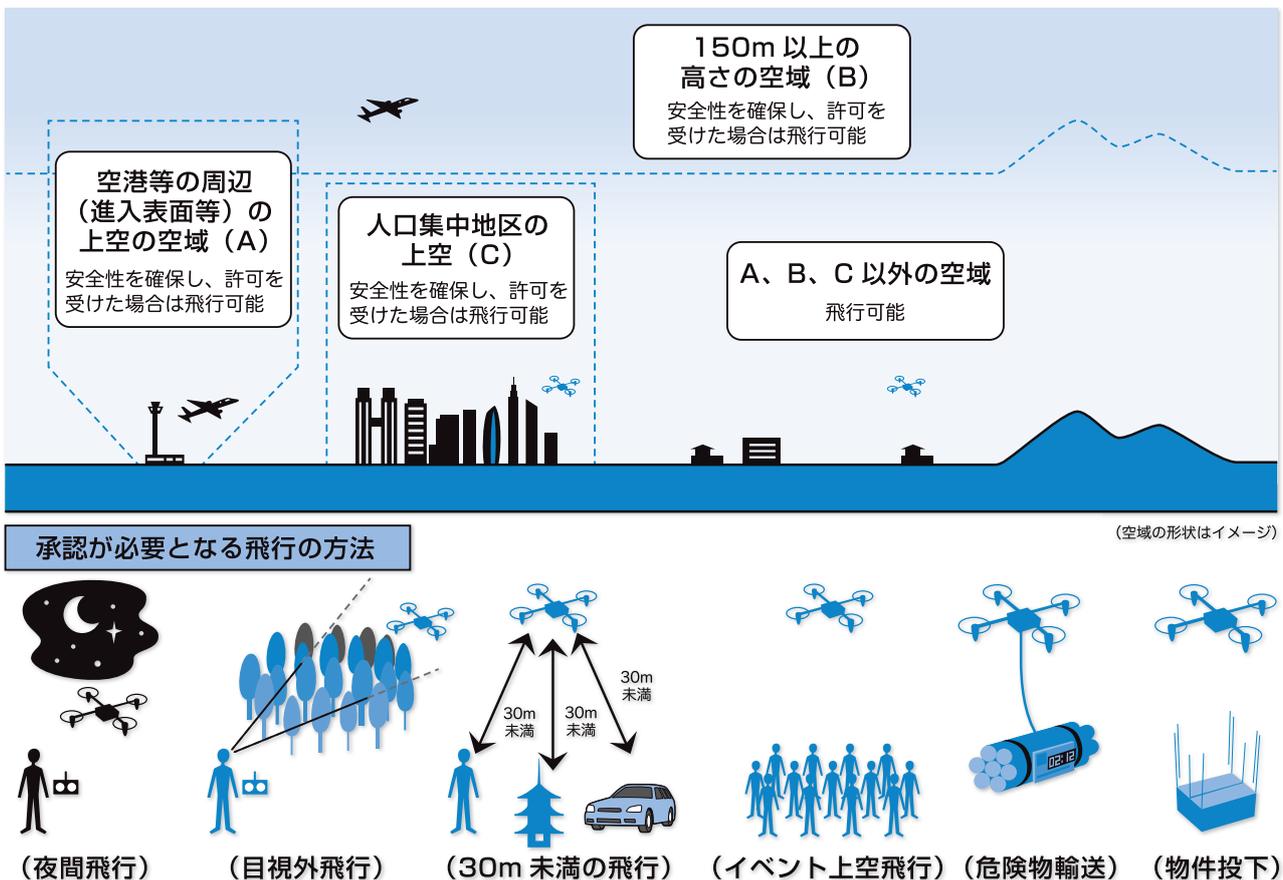
※3 「自動運転の法的課題について」日本損害保険協会ウェブサイト  
[http://www.sonpo.or.jp/news/file/jidou\\_houkoku.pdf](http://www.sonpo.or.jp/news/file/jidou_houkoku.pdf) より作成。

※4 「自動走行の実現に向けた取組方針」経済産業省ウェブサイト  
<http://www.meti.go.jp/press/2016/03/20170314002/20170314002-2.pdf>

なお、国際的な検討の枠組みにおける日本の取組としては、自動車の国際基準に関する議論を進めている国際連合欧州経済委員会の自動車基準調和世界フォーラム（WP29）において自動運転分科会の共同議長（英国と）、ブレーキと走行装置（GRRF）専門分科会の副議長、自動操舵専門家会議の共同議長（ドイツと）を務めており、議論を主導している。

### 3.4.2 ドローン

AI技術の発展は小型無人機（ドローン）の自動操縦や安定飛行を可能にする等、その活用を促進している。ドローンの活用においては、航空法による空域制限等との整合性が課題となってきたが、2015年12月に改正航空法が施行され、小型無人機を飛行させる空域及び飛行方法の基本的な飛行ルールが定められた（図4）。それを受けて、「小型無人機に係る環境整備に向けた官民協議会」（以下、「官民協議会」）が立ち上げられ、詳細な議論が実施されてきた。また、改正航空法の運用を通じ、機体、操縦者及び運航管理体制といった要件の具体化が進み、ガイドラインや民間団体等の取組も含め包括的なルール形成が進展している。



■図4 改正航空法における小型無人機の空域の考え方<sup>5</sup>

また、現在は補助者の配置が原則となっている目視外飛行については、物流サービスへの活用に向けては補助員なしでの飛行が不可欠になる。このことから、官民協議会では離島・山間部等の無人地帯におい

※5  
国土交通省ウェブサイト <[http://www.mlit.go.jp/koku/koku\\_tk10\\_000003.html](http://www.mlit.go.jp/koku/koku_tk10_000003.html)> より編集部作成。

ては、民間団体等の自主的取組等の運用を通じたレベルアップによる安全上のリスクの低減を通じて、2018年頃の実現に向けた制度整備を図る方向性が打ち出されている。都市部等の有人地帯においては、安全確保のためにはさらなる技術開発が必要であることから、2020年代頃の本格運用に向けた制度の検討・整備がうたわれている（表10）。

■表10 小型無人機の活用に向けた制度整備の方向性<sup>6</sup>

| 無人地帯における目視外飛行(レベル3)   | 有人地帯における目視外飛行(レベル4)   |
|---|---|
| <p>今後、機体、操縦者資格及び運航管理マニュアルについて民間団体等の自主的取組等の運用を通じたレベルアップにより、安全上のリスクの低減を図っていくこととする。これにより、民間団体等の機体の認証や操縦者の資格等を通じて、補助者を配置しなくても補助者を配置した場合と同等の安全性の確保を可能とし、業務として目視外飛行を行うような運用(レベル3)が2018年頃には本格化するよう、審査要領の改正等により必要な仕組みを導入する。</p> | <p>今後、運航管理システムの構築や衝突回避機能の向上、風雨等の環境変化への耐性の飛躍的向上等の技術の進展も考慮して、第三者の上空を飛行させることを可能とするため、機体の認証制度や操縦者の資格制度等について、2020年代頃に有人地帯での目視外飛行(レベル4)が本格運用出来るよう、早期に制度の検討・整備を行う。</p> |

なお、米国におけるドローンに関する規制としては、米国運輸省（DOT）及び連邦航空局（FAA）が2016年8月に、既存の航空規則に新たに追加した“SMALL UNMANNED AIRCRAFT RULE (Part107)”が挙げられる。この中では、「重量25kg未満」、「視界内」、「高度400フィート（約132m）以下」、「昼間のみ」、「リモートパイロットとして認定又はその指導下」等の制約が掲げられているが、荷物の運搬については、飛行や操縦の妨げにならない限り構わないとされている。また、申請者がそのドローン運航が例外認可のルールに準拠し安全であることを証明できれば、ほとんどの条件を適用除外することができる。

### 3.4.3 健康・医療・介護

現在のAI技術の主流である機械学習やディープラーニングは、ビッグデータの活用が前提となることが多く、拠り所になる制度がないためにデータ利活用が円滑に行われないと、AIの活用が促進されない可能性がある。

ヘルスケア等の領域でのAI活用においては、複数の個人データを必要に応じて機関をまたいで連携・活用することで、効果的なデータ分析やサービス提供が可能になる場合が多いと想定されるが、個人情報保護制度の制約条件や機関間の制度の違いにより、データ活用が困難なことが多くなっている。例えば、民間医療機関では「個人情報の保護に関する法律」、国の医療機関では「行政機関の保有する個人情報の保護に関する法律」、独立行政法人では「独立行政法人等の保有する個人情報の保護に関する法律」、地方自治体等の医療機関では各自自治体の個人情報保護条例が適用されている。だが、それぞれの規定に差異があり、それに基づいた手続が必要になる等、機関をまたいだデータ連携を図るにはきわめて煩雑で手間のかかる状況にある。

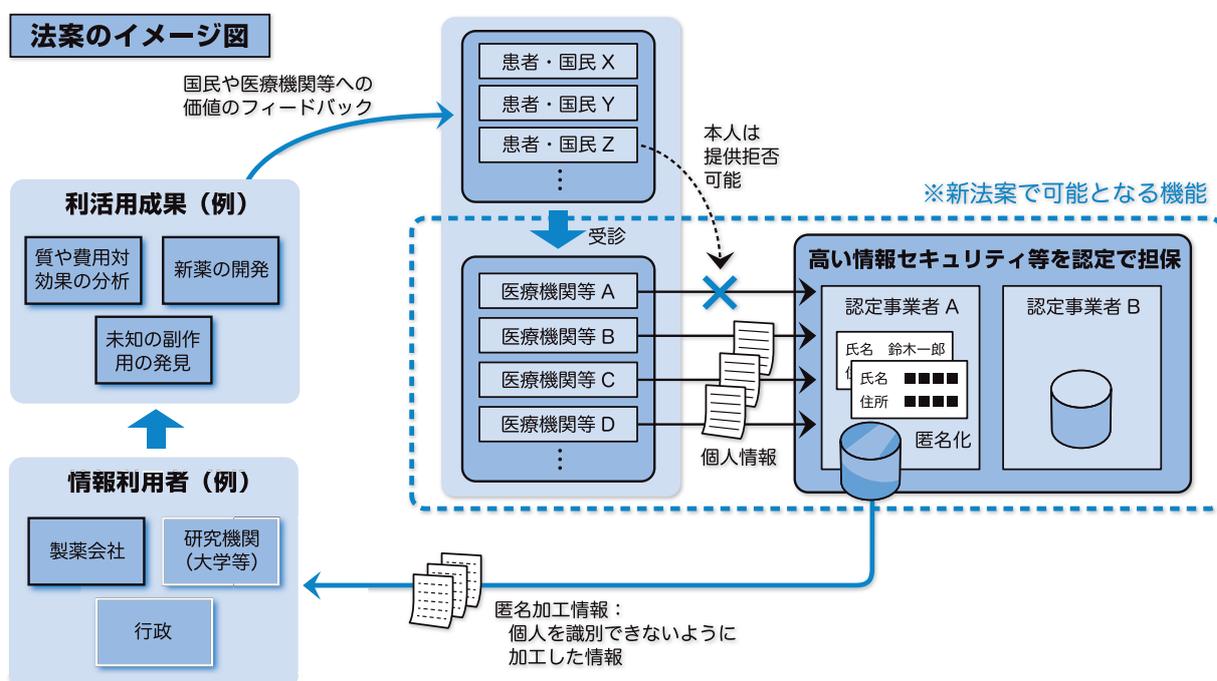
このような中で、制度的な制約を超えてデータ利活用を図る取組が始まっている。

※6  
「小型無人機の更なる安全確保に向けた制度設計の方向性」小型無人機に関する関係府省庁連絡会議ウェブサイト <<http://www.kantei.go.jp/jp/singi/kogatamujinki/dai6/siryou3.pdf>> より作成。

※7  
「次世代医療 ICT基盤協議会医療情報取扱制度調整ワーキンググループ(WG.B)とりまとめ」健康・医療戦略推進本部ウェブサイト <[http://www.soumu.go.jp/main\\_content/000462279.pdf](http://www.soumu.go.jp/main_content/000462279.pdf)>

次世代医療ICT基盤協議会 医療情報取扱制度調整ワーキンググループでは、「医療情報匿名加工・提供機関」（仮称）の制度化について検討を行い、2016年12月にとりまとめ結果を公表した<sup>7</sup>。この制度は、高い情報セキュリティを確保し、十分な匿名加工技術を有する等の一定の基準をみたす組織を公的に認定し、認定された組織は複数の医療機関等から医療情報の提供を受けて、匿名化等の加工をして一元的に研究機関や製薬会社等に提供をする。医療機関等からの情報提供の際には本人同意を不要とし（本人の提供拒否は可能）、情報収集の促進を図る。また本人同意があれば、個人別の医療情報をまとめて提供することもできるというものである。更に、複数の「医療情報匿名加工・提供機関」（仮称）間の情報を一元的に活用するための基盤として、それらをネットワーク化する中立的な「支援機関」を全国で一つ整備して、データ統合の機能を担うことも規定されている。

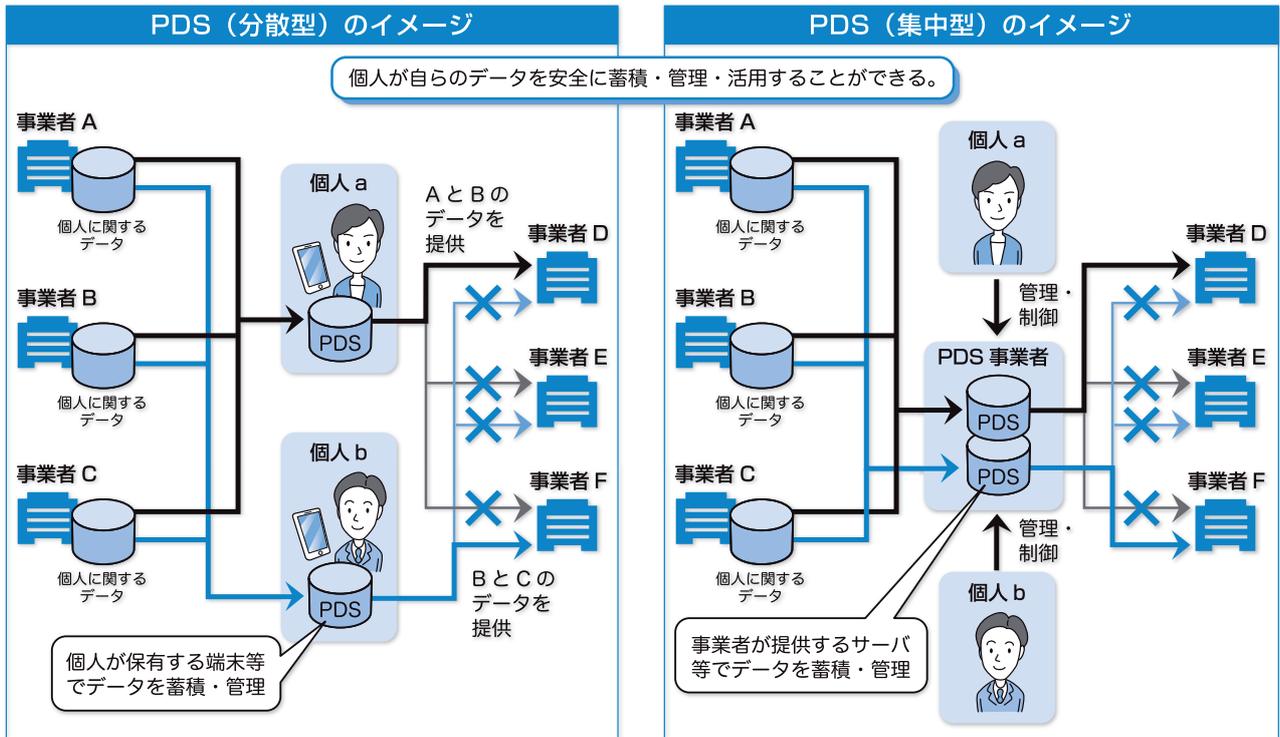
このうち、匿名化して情報提供をする機能については「認定匿名加工医療情報作成事業者」との呼称で定められ、2017年3月に「医療分野の研究開発に資するための匿名加工医療情報に関する法律案」（次世代医療基盤法案）として国会に提出されている。その内容は、図5に示したものであり、医療の「質や費用対効果の分析」、「新薬の開発」、「未知の副作用の発見」といった利活用の促進が期待されている。



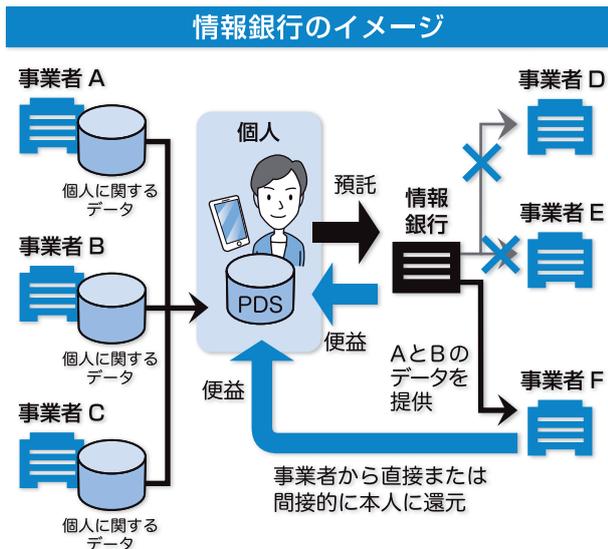
■図5 医療分野の研究開発に資するための匿名加工医療情報に関する法律案の概要<sup>8</sup>

また、医療情報等の個人データの安全なデータ流通の仕組みづくりとして、パーソナルデータストア (PDS) などの具体的な検討が進められている。具体的には図6に示したように、個人に集約されたデータがPDSを介して事業者も含めた第三者に共有されるような、個人主導型のデータ流通が実現することが企図されている。その検討の中では、図7に示したように、データを所有する個人による逐一の管理が煩雑と考えるユーザを想定して、その管理を預託する「情報銀行」も併せて構想されている。

※8  
「医療分野の研究開発に資するための匿名加工医療情報に関する法律案の概要」内閣官房ウェブサイト<<http://www.cas.go.jp/jp/houan/170310/siryou1.pdf>>より編集部作成。



■図6 パーソナルデータストアのイメージ<sup>9</sup>



※本人には便益が還元されず、社会全体にのみ便益が還元される場合もある。

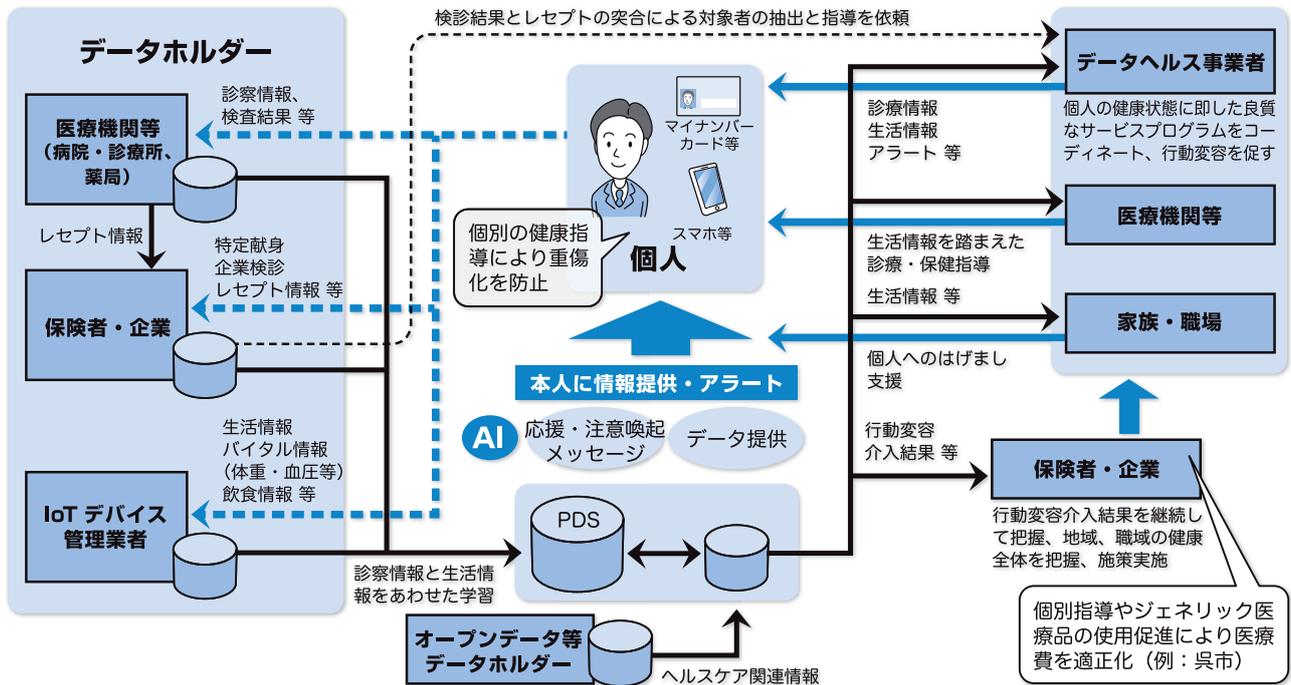
■図7 情報銀行のイメージ<sup>10</sup>

PDSは医療・介護分野以外にも観光、金融・フィンテック、人材、農業、防災減災といった様々な分野での活用が想定されているが、政府においては医療・介護・ヘルスケア分野におけるデータ流通・活用を促す観点から、医療データを含む多様なデータの本人への提供の在り方について検討することが想定され

※9  
「AI、IoT時代におけるデータ活用ワーキンググループ中間とりまとめの概要」データ流通環境整備検討会ウェブサイト <[http://www.kantei.go.jp/jp/singi/it2/senmon\\_bunka/data\\_ryutsuseibi/dai2/siryou1.pdf](http://www.kantei.go.jp/jp/singi/it2/senmon_bunka/data_ryutsuseibi/dai2/siryou1.pdf)> より編集部作成

※10  
「AI、IoT時代におけるデータ活用ワーキンググループ中間とりまとめの概要」データ流通環境整備検討会ウェブサイト <[http://www.kantei.go.jp/jp/singi/it2/senmon\\_bunka/data\\_ryutsuseibi/dai2/siryou1.pdf](http://www.kantei.go.jp/jp/singi/it2/senmon_bunka/data_ryutsuseibi/dai2/siryou1.pdf)> より編集部作成

ている。例えば、図8に示したようなAIを活用した生活習慣病の疾病管理サービスへの適用が例示されている。PDSについては既に複数の実証実験が実施されており、制度の具体化等の実現に向けた今後の取組が注目される。



■図8 医療・介護・ヘルスケア分野(生活習慣病の疾病管理)におけるPDS活用のイメージ<sup>11</sup>

### 3.4.4 物・サービスへのニーズとのマッチングや効率化

製造業、流通業、サービス業等においては、AIを活用して事業者や業種を超えて個人属性や行動特性に応じた商品・サービス提供がされることで高度なカスタマイゼーションが実現し、社会全体としての生産性を高めることが期待されている<sup>12</sup>。そのため、事業者間や業種間で、プライバシー保護や個人情報保護を配慮した形でのデータの利活用を適切に行うための新たな制度的な検討が進められている。

データの匿名化については、2017年5月施行の改正個人情報保護法において、ビッグデータを始めとするパーソナルデータの利活用に向けて、本人の同意に代わる一定の条件の下、特定の個人を識別することができないように加工された「匿名加工情報」制度が創設された。そのビジネスにおける運用を視野に入れて、業界団体、企業、認定個人情報保護団体等の事業者が、匿名加工情報や匿名加工情報に係るガイドラインを作成するにあたっての相場観を形成するべく、具体的なユースケースを用いて、匿名加工情報を作成するための具体的な手順や方法について、学界、産業界、消費者団体等における有識者によって作成された「匿名加工情報及び匿名加工情報作成マニュアル」が公表されている(図9)。

※11  
内閣官房IT総合戦略室「AI、IoT時代におけるデータ活用ワーキンググループ中間とりまとめ」データ流通環境整備検討会ウェブサイト <[http://www.kantei.go.jp/jp/singi/it2/senmon\\_bunka/data\\_ryutsuseibi/detakatsuyo\\_wg\\_dai9/siryou1.pdf](http://www.kantei.go.jp/jp/singi/it2/senmon_bunka/data_ryutsuseibi/detakatsuyo_wg_dai9/siryou1.pdf)>より編集部作成

※12  
人工知能技術戦略会議「人工知能技術戦略」新エネルギー・産業技術総合開発機構ウェブサイト<<http://www.nedo.go.jp/content/100862413.pdf>>p.5

## 具体的な手順として、以下を整理



| 識別子     |    | 属性 |    | 履歴    |           |
|---------|----|----|----|-------|-----------|
| アカウントID | 氏名 | 性別 | 年齢 | 購買品 1 | 購買品 2 ... |

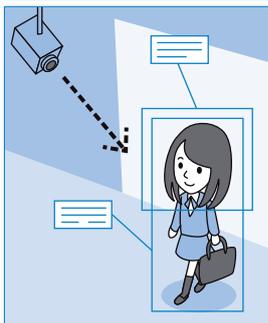
- ・留意すべきリスクを、個人が特定されるリスク、他の情報と照合されるリスク、本人にアプローチされるリスクに類型化し、リスクに応じた具体的な加工の方法を例示（特異値の削除、仮名化等）。
- ・電力利用データ、購買データ、移動データの3つの事例に基づく具体的な検討プロセスを提示。

■図9「匿名加工情報及び匿名加工情報作成マニュアル」のポイント<sup>13</sup>

また、データ活用についてわかりやすい共通の指針がないことから、各企業が利用の方針を定めることができず、結果として萎縮してデータ活用がなされなかったり、逆に配慮を欠いた形での活用がなされることがある。ユーザ側も、データ活用について過度にセンシティブになる可能性がある。そのため、データ活用についての具体的な指針やガイドを整備するという動きもある。一例として、ディープラーニングの発展に伴いますます利用が進むことが想定されるカメラ画像について「カメラ画像利活用ガイドブック」が定められている。

これは、個人を特定する目的以外でのカメラ画像の利活用を検討する事業者を対象として、ユースケースに即して配慮事項をまとめたものであり、今後利活用企業の指針となることが期待される（図10）。

### 例1 店舗内設置カメラ（属性の推定）

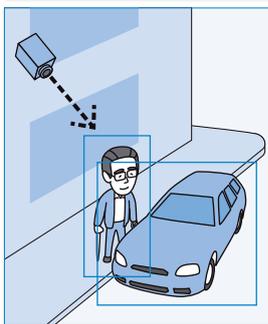


目的：レジ待ち時間の短縮等

#### 配慮事項の対応例（一部）

- ・入出時点で画像を取得
- ・特徴量データを抽出後、撮影画像を直ちに破棄
- ・来店者の人物属性（年齢等）を推定した時点で、特徴量データを直ちに破棄
- ・自社 HP 上でリリース（事前告知）を実施
- ・店舗入口にポスター掲示（通知）を実施
- ・他社へ提供しない

### 例2 屋外に向けたカメラ（人物形状のカウント）



目的：都市計画等

#### 配慮事項の対応例（一部）

- ・通行する人・物体の画像を取得
- ・人・車等を識別しカウント後、撮影画像を直ちに破棄
- ・自社 HP 上でリリース（事前告知）を実施
- ・店舗入口に撮影中であることを示す通知を実施
- ・カメラの計測対象 地点を HP 上に掲載
- ・個人の特定には至らない旨を HP 上に明記

■図10「カメラ画像利活用ガイドブック」におけるユースケースとそれに即した 配慮事項の例<sup>14</sup>

※13

経済産業省「IoT進展に立ちほだかる中期的課題への 新たなアプローチ .集めないビッグデータ、パーソナルデータストア、データ流通市場」データ流通環境整備検討会ウェブサイト <[http://www.kantei.go.jp/jp/singi/it2/senmon\\_bunka/data\\_ryutsuseibi/detakatsuyo\\_wg\\_dai6/siryou2.pdf](http://www.kantei.go.jp/jp/singi/it2/senmon_bunka/data_ryutsuseibi/detakatsuyo_wg_dai6/siryou2.pdf)>

※14

「IoT進展に立ちほだかる中期的課題への 新たなアプローチ .集めないビッグデータ、パーソナルデータストア、データ流通市場」データ流通環境整備検討会ウェブサイト <[http://www.kantei.go.jp/jp/singi/it2/senmon\\_bunka/data\\_ryutsuseibi/detakatsuyo\\_wg\\_dai6/siryou2.pdf](http://www.kantei.go.jp/jp/singi/it2/senmon_bunka/data_ryutsuseibi/detakatsuyo_wg_dai6/siryou2.pdf)>

農業分野においても今後AI活用が広がることが期待されているが、従前の農業ITサービスの利用規約においては、データの取扱い等について統一的でなく生産者等の利用者に内容が十分説明されない場合があった。そのため、内閣官房が事務局となった新戦略推進専門調査会農業分科会では「農業ITサービス標準利用規約ガイド」の内容を検討し、2016年3月にとりまとめ結果を公表した。この中では、農業ITサービスの利用規約において、「契約者等」と「提供者」との間の権利や義務についてどこを注意して確認する必要があるかを示すとともに、記載されるべきことが記載されているかどうかを簡単にチェックすることができるようなチェックのポイントが示されている（図11）。

#### 農業ITサービスの選定時には、特に下記の視点で規約を確認しましょう

- 0  農業ITサービスに係る取引先（候補）や指導員等は標準利用規約ガイドを知っている
- 1  利用契約の成立や、規約の効力の発生する時点が明確である
- 2  規約内容が変更される場合の手順等が示されている
- 3  提供者からの利用契約の拒否・解約の事由が明確である
- 4  契約者からの利用契約の解約方法や条件が示されている
- 5  提供者によるサービスの内容や範囲（仕様）が明確である
- 6  サービス内容が変更される場合や廃止される場合の手順等が示されている
- 7  サービス利用に係る禁止事項が明確である
- 8  サービス提供が停止される場合の手順等が示されている
- 9  提供者の免責事項が明確である
- 10  提供者によるサービスの保証や賠償の範囲が明確である
- 11  提供者や第三者の著作権等の知的財産権の範囲が明確である
- 12  個人情報等の対象や使用の範囲が明確である
- 13  サービス環境に蓄積するデータの取扱いが明確である
- 14  サービス環境に蓄積するデータの相互運用性や可搬性が配慮されている
- 15  提供者等がサービス環境に蓄積するデータを再利用する場合の方法が明確である
- 16  合意管轄や準拠法が示されている
- 17  規約の制定日や適用日が示されている

■図11 農業ITサービス利用規約確認の視点<sup>15</sup>

※15

「農業分野におけるデータの利活用」内閣官房情報通信技術総合戦略本部ウェブサイト<[http://www.kantei.go.jp/jp/singi/it2/senmon\\_bunka/data\\_ryutsuseibi/detakatsuyo\\_wg\\_dai6/siryou3.pdf](http://www.kantei.go.jp/jp/singi/it2/senmon_bunka/data_ryutsuseibi/detakatsuyo_wg_dai6/siryou3.pdf)>

## 第4章

# 政策動向

4.1 総論

4.2 国内の政策動向

4.3 海外の政策動向

# 第4章

## 政策動向

### 4.1 総論

先端技術である人工知能（AI）の研究開発の発展と産業への適用を促進し、国際的な産業競争力の強化を図るためには、政府においても研究開発、社会への実装や制度的な整備に関わる政策を推進することが重要と考えられる。

このような中で、我が国、海外のいずれにおいても関連する政策が次々と打ち出されている。本章では、このような政策の最近の動向について概説する。

#### 4.1.1 国内の政策動向

AIの研究開発に関しては、安倍総理の指示の下で産学官が結集して、関係省庁や関係研究機関における研究の総合調整や産業連携を図るものとして「人工知能技術戦略会議」が創設され、研究開発目標と産業化のロードマップの策定等が行われている。また、内閣府、経済産業省、総務省、文部科学省等の各省においても、研究開発事業や制度的な課題への対応に関わる検討等の政策が実施されている。

#### 4.1.2 海外の政策動向

米国では2016年にAIに関わる研究開発戦略、社会的課題の整理・対応、経済的なインパクトの分析・対応の三つの包括的な報告書が発表されており、AIの活用を本格的に推進する環境が整えられている。

EUでは、研究開発については欧州全体研究開発プログラムである「Horizon 2020」の中で、多数のAIに関わる研究開発プロジェクトが採択され、実施されている。また、欧州議会においてAIの倫理的な問題や法的な位置づけに関する報告書が作成され、それを受けた検討が進行している。

英国では、下院科学技術委員会において社会的・倫理的・法的問題を検討したレポートが発表され、雇用への影響等について論じられている。

ドイツでは国策である「Industry 4.0」の中で、AIが重要技術の一つとして位置づけられている。また、ドイツ人工知能研究センター（DFKI）が研究開発の中心を担っており、企業との共同研究やスピントアウトなども盛んに行っている。

中国では2016年にAI推進の3か年行動計画が策定され、1,000億元（約1.6兆円）級のAI活用市場の創出が目指されるとともに、研究開発とその環境整備についても言及されている。

## 4.2 国内の政策動向

### 4.2.1 人工知能技術戦略会議による研究開発、産業連携の推進

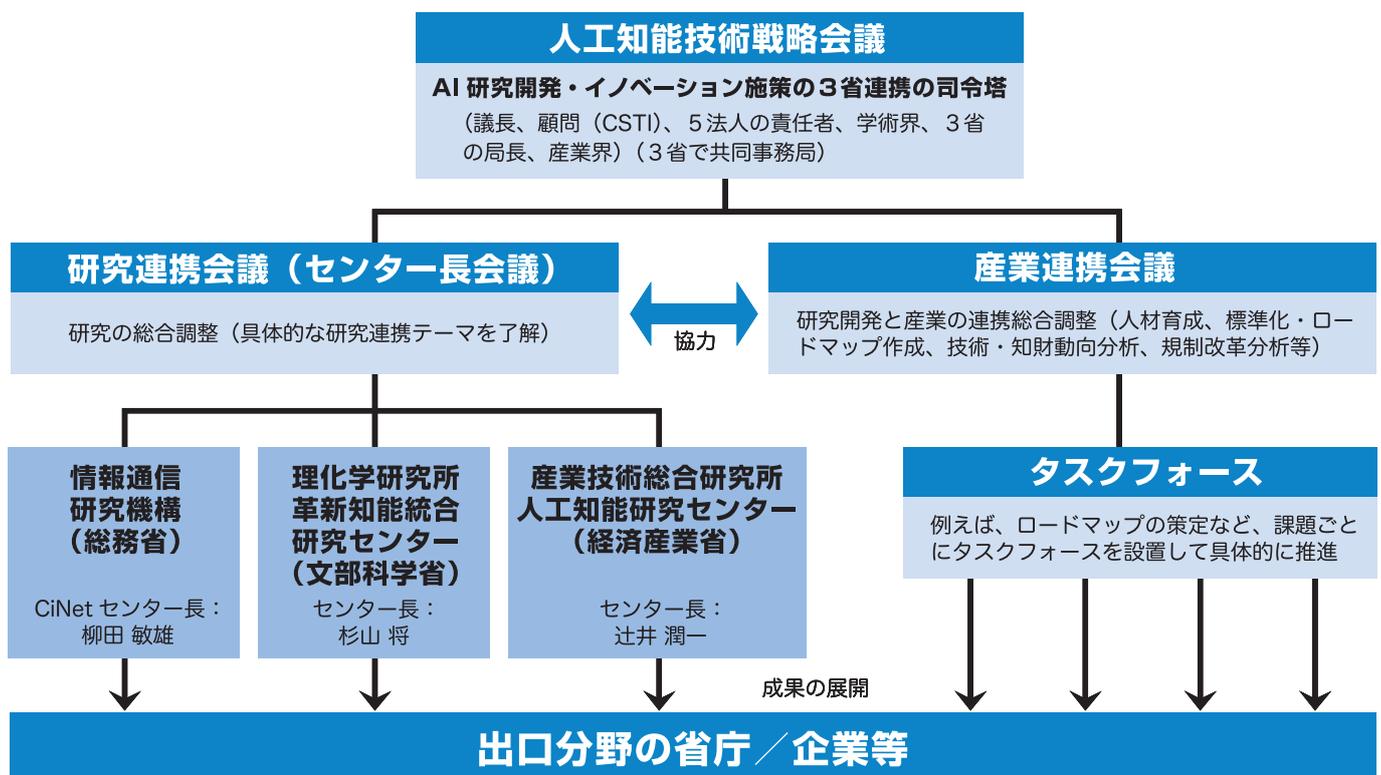
「日本再興戦略」改訂 2015（平成27年6月30日閣議決定）においては、鍵となる施策として「IoT・ビッグデータ・人工知能による産業構造・就業構造変革の検討」が挙げられた。

また、「第5期科学技術基本計画」（平成28年1月22日閣議決定）においても、戦略的強化を図る超スマート社会サービスプラットフォームの構築に必要となる基盤技術として、IoTやビッグデータ解析、高度なコミュニケーションを支える「AI技術」が位置づけられた。

これらを受けて、平成28年4月12日に開催された第5回「未来投資に向けた官民対話」において、安倍総理からAIの研究開発目標と産業化のロードマップを策定するため、産学官の叡智を集め、縦割りを排した「人工知能技術戦略会議」を創設することが指示された。人工知能技術戦略会議では、関係省庁、関係研究機関における研究の総合調整や研究開発と産業との連携が図られている。

具体的には図1に示したとおり、議長と顧問（総合科学技術・イノベーション会議）の下、総務省、文部科学省、経済産業省の3省が所管する研究開発を担う5法人と、産学のトップ及び3省の局長を構成員とする会議を組織し、その下に研究連携会議と産業連携会議を置いている。

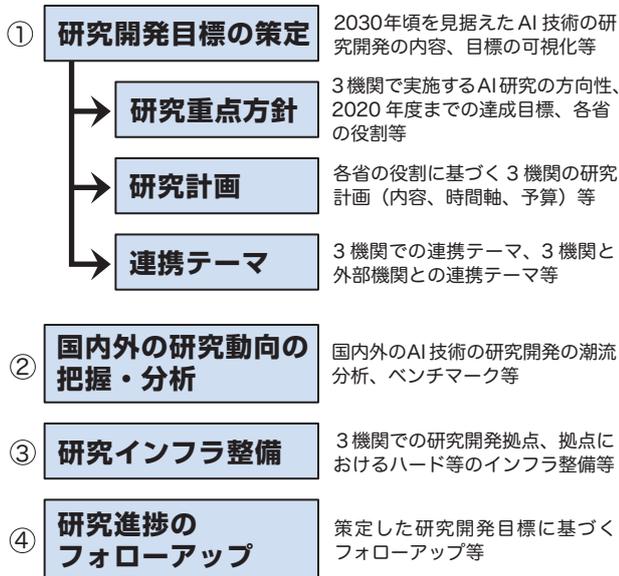
研究連携会議は情報通信研究機構（NICT）脳情報通信融合研究センター（CiNET）、理化学研究所革新知能統合研究センター（AIPセンター）、産業技術総合研究所人工知能研究センター（AIRC）の、



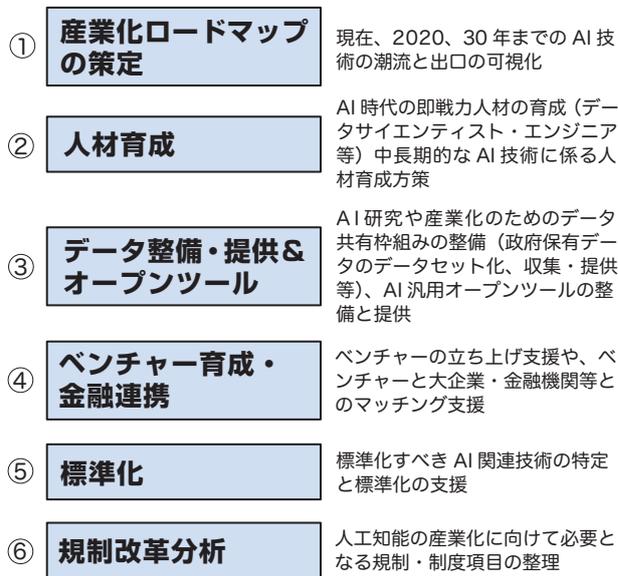
■図1 我が国におけるAI研究の体制<sup>※1</sup>

※1

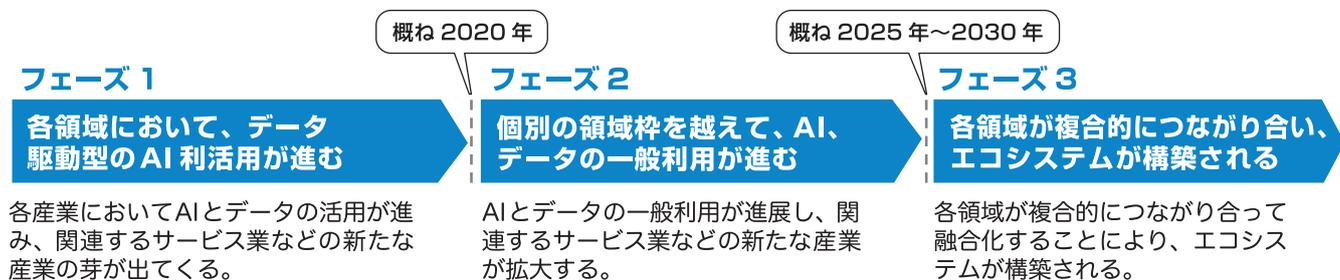
「AIポータル」新エネルギー・産業技術総合開発機構ウェブサイト  
<[http://www.nedo.go.jp/activities/ZZJP2\\_100064.html](http://www.nedo.go.jp/activities/ZZJP2_100064.html)>より  
編集部作成



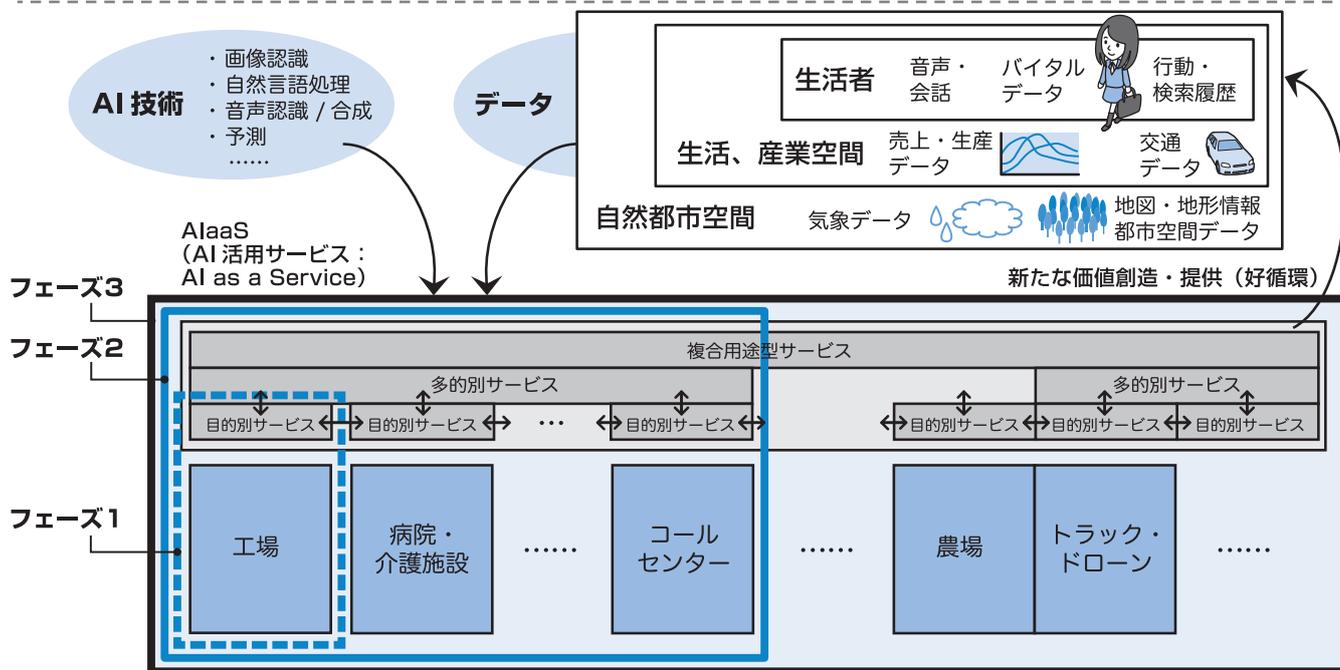
■図2 研究連携会議で調査・検討を行う課題<sup>2</sup>



■図3 産業連携会議で調査・検討を行う課題<sup>3</sup>



※分野によって現在の状況、今後の進展が異なるため、各フェーズの年限を記していない。

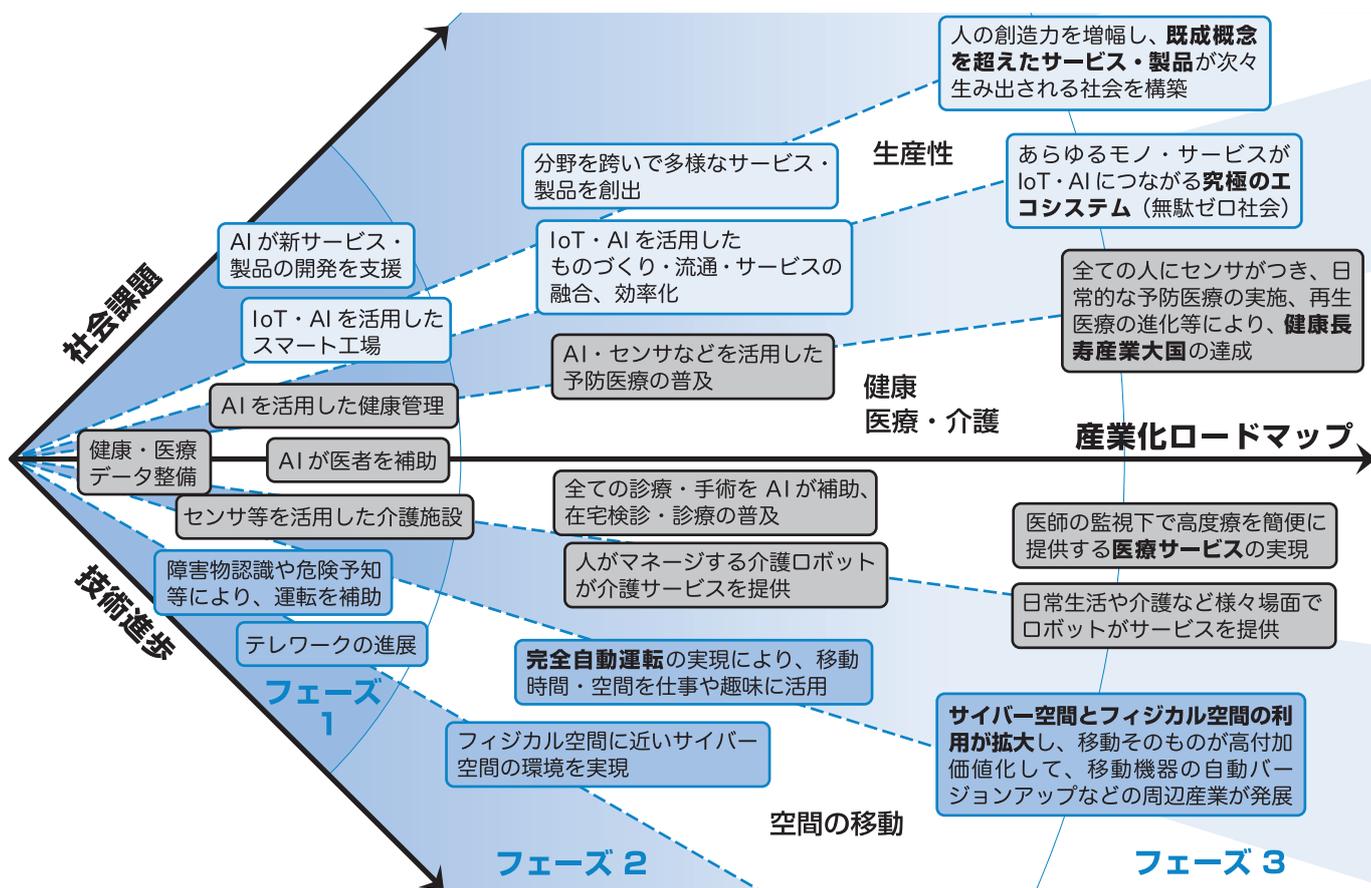


※AlaaSは、分野、国境を超えて、ボーダーレスに展開。

■図4 フェーズによるAIの発展段階の整理<sup>4</sup>

※2 「研究連携会議について(案)」新エネルギー・産業技術総合開発機構ウェブサイト<<http://www.nedo.go.jp/content/100790411.pdf>>より編集部作成

※3 「産業連携会議について(案)」新エネルギー・産業技術総合開発機構ウェブサイト<<http://www.nedo.go.jp/content/100790393.pdf>>より編集部作成



※公表時点における状況を踏まえた予測に基づき、技術的な観点から実現可能時期を設定した。  
 社会実装には規制・制度や社会受容性といった影響も考えられるため、実質的に異なる結果を招く不確実性がある。

■図5 AIの研究開発目標と産業化のイメージ<sup>5</sup>

3センターの長を構成員として、各センターの研究計画の共有・連携等を図っている。具体的には図2に示したように、研究開発目標の策定（研究重点方針、研究計画、連携テーマ）、国内外の研究動向の把握・分析、研究インフラ整備、研究進捗のフォローアップの調査、検討が実施されている。

産業連携会議は、日本経済団体連合会未来産業・技術委員会委員長が議長を務め、経済界の有識者を構成員としており、AI研究の産業連携上の課題を整理し、図3に示したように、その課題解決のための推進方策を検討している。具体的には産業化ロードマップの策定、人材育成、データ整備・提供&オープンツール、ベンチャー育成・金融連携の四つのタスクフォース（TF）を設置して検討を進めている。

「人工知能の研究開発目標と産業化ロードマップ」は平成29年3月に策定が完了し、公表された。その内容として、まず、図4のように①各領域におけるデータ駆動型のAI利活用、②個別の領域の枠を越えたAI、データの一般利用、③各領域が複合的につながり合ったエコシステムの構築という3フェーズでの進展が想定されている。また、図5のように、AIの研究開発目標とこのフェーズ別の産業化のイメージが「生産性」、「健康、医療・介護」、「空間の移動」といった分野別に整理されている。

人材育成TFでは、AI人材をめぐる現状として、企業・大学における現状、求められる人材の需給の現状、求められる人材の知識・技能、情報系人材の分類、人材不足の要因と今後の見通しを検討した。その上で、表1に示したような「AI人材育成に係る今後の方向性」をとりまとめている。

※4  
 「人工知能の研究開発目標と産業化のロードマップ」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100862412.pdf>>より編集部作成

※5  
 「人工知能の研究開発目標と産業化のロードマップ」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100862412.pdf>>より編集部作成

データ整備・提供&オープンツールTFでは産学官が有するデータ及びツール群の環境整備に関する方針として、表2に示した内容を整理した上で、方針ごとのアクションプラン（時期、主体、概要）をとりまとめている。

ベンチャー育成・金融連携TFではベンチャーの立ち上げ支援や、ベンチャーと大企業・金融機関等とのマッチング支援等、AI関連ベンチャーの活動の活性化の方針として、表3に示した内容を整理した上で、方針ごとのアクションプラン（時期、主体、概要）をとりまとめている。

■表1 人材育成TFによる「人材育成に係る今後の方向性」の概要<sup>6</sup>

| 項目                          | 主な内容   |
|-----------------------------|--|
| (1)即戦力育成のための教育プログラムの構想・実施   | 即戦力人材の育成の観点から、現時点で行われている教育プログラムに加え、新たにAIに関係する社会人を対象に、業務上必要な分野の最先端の知識やAIの体系的な知識の修得、リアルコモンデータ演習を通じた価値創造力の向上を目的とした教育プログラムを実施。産業界のニーズに応える人材育成を、産学官の連携のもとに進めていく。<br>【新たに実施する教育プログラム】<br>○社会人の学び直しにより、企業が求めるAI即戦力人材を短期的に育成<br>○非情報系の人材も対象に、CSやAI技術の知識を確実に習得しつつ、データを扱う技能も身に付けることができる<br>○画像や音声などの各メディアに固有のデータの扱い(ノイズの処理等)についての技術を習得できる  |
| (2)大学と産業界による共同研究・人材育成の推進    | 大学や研究機関と企業との間で、共同研究やそれらを通じた人材育成の取組が行われている。(33事例)こうした取組を個別なものとして、より面的なものとして普及させていくことが必要。  |
| (3)政府・研究機関等によるこれまでの取組と更なる充実 | ①AI人材の育成が効果を発揮するには、AI人材を惹き付ける環境整備の観点から、NICT、理研(AIPセンター)、産総研が積極的にグローバル水準で活躍できる国内外の若手研究者等を処遇するなど、AI人材の活躍できる場の確保が重要。<br>②人工知能/ビッグデータをはじめとする情報分野の若手研究者の育成は、第4次産業革命の実現に当たり最重要。研究者が、基礎研究に裏打ちされた理論・技術を、実社会におけるイノベーション創出に具体的に貢献できるよう、様々な支援制度を構築。これらを一層充実させることが必要。<br>③情報系コアだけではなく境界領域においても、AI開発やビッグデータ解析などを実施できる人材の育成が必要。(例：健康・医療・介護分野で医療ビッグデータ解析などを実施できる医学系研究者育成)このため、教育プログラムの受講等により、AIに係るスキルの修得を促進することが必要。 |

■表2 データ整備・提供&オープンツールTFによる「産学官が有するデータ及びツール群の環境整備に関する方針」の概要<sup>7</sup>

| 方針案                              | ニーズ、問題意識  | 期待される具体的な行動のイメージ(例)   |
|----------------------------------|---|---|
| 1. 重点取組分野のデータ整備強化                | 産業化ロードマップにおける重点分野(生産性等)については、新たなデータ取得による整備を行うべきではないか。 | ①府省庁連携研究におけるデータ整備の強化<br>②標準画像等、AI性能評価のためのデータ整備<br>③研究及び人材育成向けの学習用データセット整備 |
| 2. データ整備・提供を担う機関の強化              | 研究自体よりも地味で継続的なデータ整備について、支援の強化が必要ではないか。                | ①データ整備提供を担う専門機関の強化等   |
| 3. データ取得やツールの検証を加速する模擬環境、実証環境の整備 | 個人情報等データ取得の阻害要因がある中、データ取得できる特別の環境の確保が必要ではないか。         | ①工場や店舗、病院等、実物を模した模擬環境の整備<br>②AI製品・サービスの実証に利用できる現場の確保                      |
| 4. 産学連携によるデータ、ツールの集積の好循環         | 海外AIクラウドに依存せず、国内で好循環する枠組みが必要ではないか。                    | ①産学官における、データ解析力の提供とデータ提供を好循環させるAIクラウドの提供<br>②データの自動的登録(蓄積)を促す制度整備         |
| 5. データセット整備を加速する技術開発、制度整備        | 人海戦術となっているクレンジング、タグ付け等データセット化について、効率化が必要ではないか。        | ①AIで自動的に関連付けを行う技術、匿名化・秘密計算・秘密検索技術等、データ整備加速技術の開発<br>②データの自動的登録(蓄積)を促す制度整備  |
| 6. 国プロから生じるデータのオープンデータ化          | 国が率先してオープンデータを提供すべきではないか。                             | ①国プロで取得したデータの管理と提供<br>②データ取得自体を目的とする国のプロジェクトを整備                           |
| 7. データ及びツール群にかかるリソースの一覧化         | 所在情報等、ユーザーが利用しやすい環境を整備すべきではないか。                       | ①オープンデータ・オープンツール、計算機資源、データ取得環境(実証・模擬環境等)の一覧情報の提供・活用促進(3研究機関を含む)           |
| 8. 民間等保有データの共有、横断的活用等            | データ流通を巡る動きを、AI側としても積極的に対応すべき                          | ①情報銀行、データ取引ルール等、民間主体の枠組みの活用<br>②API公開等、データ連係・互換性の向上(IT本部等)                |

※6  
「各TF補足資料」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100862415.pdf>> より作成

※7 「各TF補足資料」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100862415.pdf>>

※8  
「各TF補足資料」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100862415.pdf>>

■表3 ベンチャー育成・金融連携TFによる「AI関連ベンチャーの活動の活性化の方針」の概要<sup>8</sup>

| 方針案                                      | ニーズ、問題意識   | 期待される具体的行動のイメージ(列)  |
|--|--|---|
| 1. AIを巡るコミュニティ・ネットワークの形成(オープンイノベーションの促進) | 個別の専門分野に特化したAIベンチャーが、ベンチャー企業間や大企業や大学等との連携により、研究及び事業化が図りやすい「場」が必要ではないか。 | ①オールジャパンのAIベンチャーコミュニティの場の形成<br>②AIベンチャーと大企業の交流機会<br>③AI分野でのベンチャーピッチ(金融との連携)の開催<br>④AIベンチャーを交えた産学官によるAIシンポジウムの開催<br>⑤AIを巡るコーディネータ、目利き人材ネットワークの形成 |
| 2. AIベンチャーの研究・事業化を促す環境整備                 | 大規模な設備等の保有が困難なAIベンチャーにとって利用しやすい公共リソースの提供が必要ではないか。                      | ①AI研究3機関におけるオープンラボ、インキュベーションラボの設置・拡充<br>②データ解析等のための公的コンピュータリソースの提供<br>③ハード・ソフトの試作環境の提供<br>④データ取得のための模擬環境、製品サービスの実証環境の提供                         |
| 3. AIのパフォーマンスを比較(ベンチマーク)出来る環境整備          | 知名度の低いベンチャー企業にとって、保有するAI技術のパフォーマンスを、客観的かつ外に対してアピールできる環境が必要ではないか。       | ①AIコンテストの実施(競技形式等)<br>②AIアワード(表彰)の実施<br>③AI性能評価指標の整備(標準画像等の標準化)   |
| 4. 公益目的(課題解決)のためのAI活用促進                  | AI製品・サービスの初期市場創出が重要ではないか。  | ①AI需要開拓のための出口府省庁との連携強化<br>②行政へのAI製品・サービスの拡大   |
| 5. AIと規制の調和                              | AI製品・サービスの市場化には、適切な規制レベルの設定が重要ではないか。                                   | ①AI等の最新の技術レベルに合わせた規制のあり方  |
| 6. 活用できるデータ・ツールの拡大                       | <データ整備・提供&オープンツールTFで検討>  | <データ整備・提供&オープンツールTFで検討>   |
| 7. トレーニング機会の拡大                           | <人材育成TFで検討>  | <人材育成TFで検討>   |
| 8. その他                                   | AIベンチャーによる活用が期待できる施策の見える化(一覧化)   | ①AIポータルにおける施策一覧の掲載  |

## 4.2.2 関係府省における政策動向

### 4.2.2.1 内閣府

内閣府所轄の総合科学技術・イノベーション会議（CSTI）では経済財政諮問会議と合同で「経済社会・科学技術イノベーション活性化委員会」を設置し、平成28年12月に「科学技術イノベーション官民投資拡大イニシアティブ」をとりまとめた。この中で、官民研究開発投資の量的・質的拡大として呼び水となる政府戦略的イノベーション創造プログラム（SIP）事業予算を拡充し、CSTIと産業界が選定した各省提案事業に新型推進費をアドオンすることとしている。それを受けて、平成29年1月からは「科学

### ターゲット領域検討に向けた全体俯瞰図

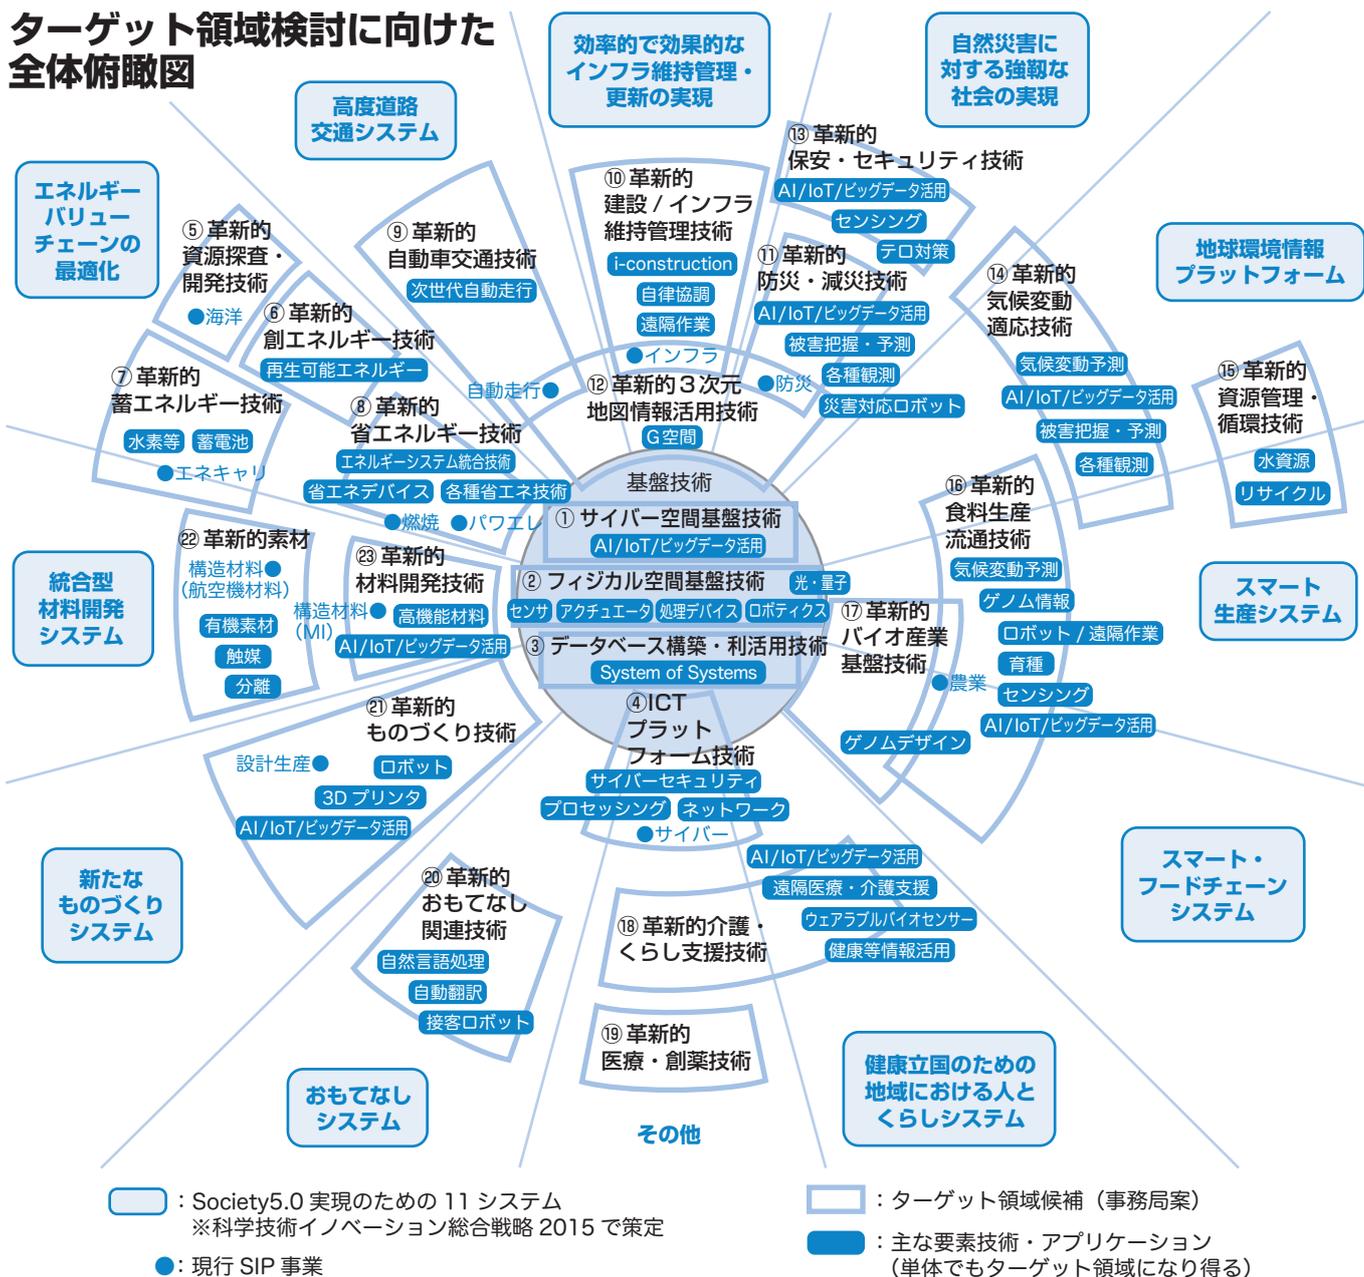


図6 科学技術イノベーション官民投資拡大推進費のターゲット領域に向けた全体俯瞰図<sup>※9</sup>

※9 「ターゲット領域検討に向けた全体俯瞰図」内閣府ウェブサイト  
<http://www8.cao.go.jp/cstp/tyousakai/target/5kai/siry05-2.pdf>より編集部作成

※10 とりまとめの概要は3.3.1項を参照されたい。

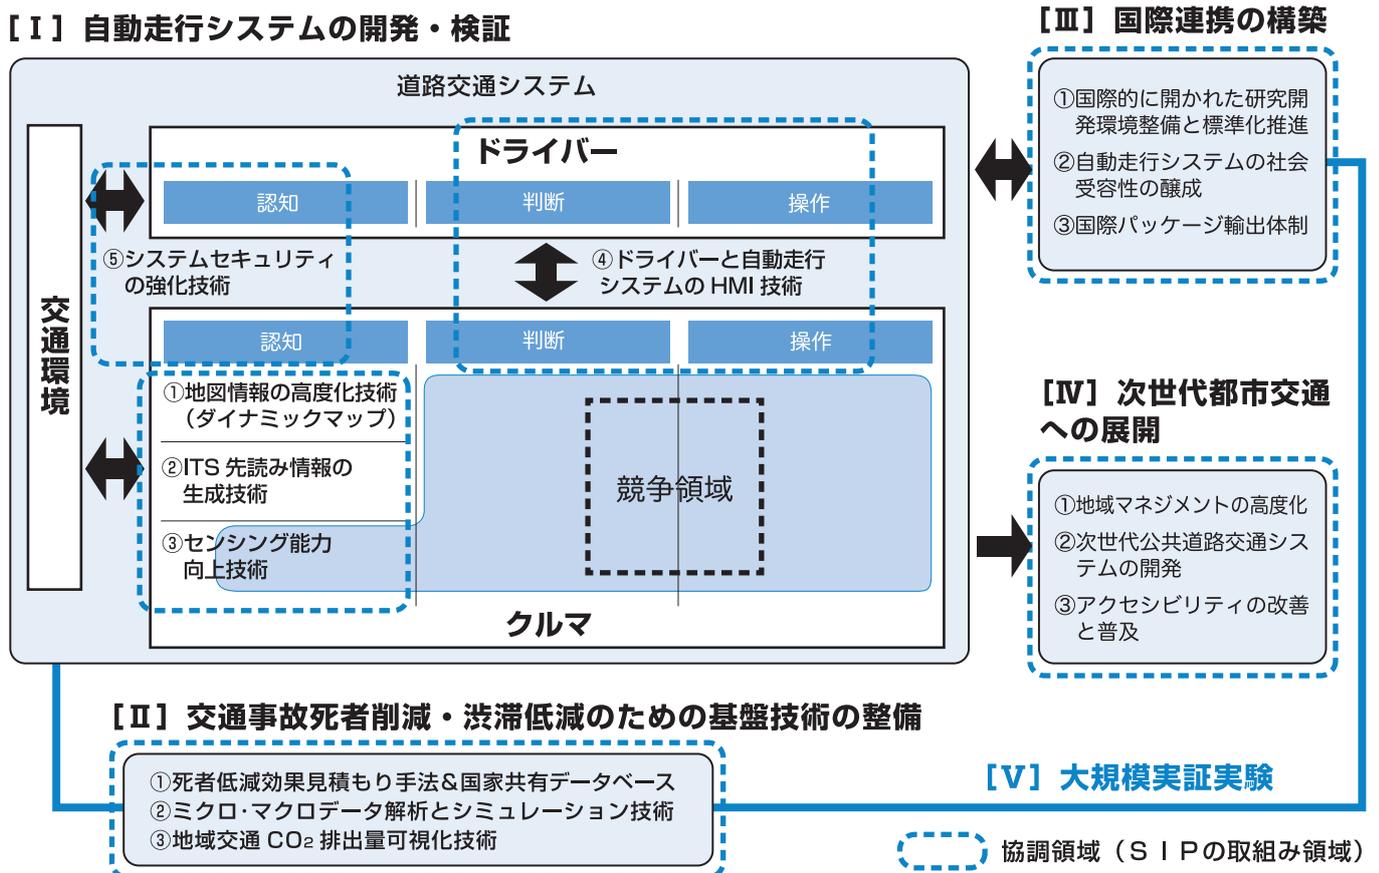
技術イノベーション官民投資拡大推進費 ターゲット領域検討委員会」を設置し、研究開発投資ターゲット領域の選定作業を進めている。図6に示したように「サイバー空間基盤技術（AI/IoT/ビッグデータ）」は基盤技術の一つとなっており、民間投資の関連性が高く各省庁施策とも関連性が高い領域とされており、先行して平成30年度に設定すべき領域の候補となっている。

また、平成28年5月～平成29年3月にかけて「人工知能と人間社会に関する懇談会」を設置。倫理、法、制度、経済、社会的影響など幅広い観点からAIが進展する未来の社会を見据えて、国内外の動向を俯瞰し、AIと人間社会の関わりについて今後取り組むべき課題や方向性を検討した。その結果は倫理的論点、法的論点、経済的論点、社会的論点、教育的論点、研究開発的論点としてとりまとめられている<sup>10</sup>。

戦略的イノベーション創造プログラム（SIP）においては、対象課題の一つとして「自動走行システム」が選定され、図7に示したように①自動走行システムの開発・検証、②交通事故死者削減・渋滞低減のための基盤技術の整備、③国際連携の構築、④次世代都市交通への展開の研究開発等が推進されている。なお、平成29年度からは大規模実証実験が開始される予定である。

#### 4.2.2.2 経済産業省

経済産業省では、産業構造審議会新産業構造部会にて「新産業構造ビジョン」の策定を行った。その中間とりまとめの中で、AIを活用した産業戦略の具体的な内容について検討が行われている。具体的には、データの利活用のための日本の強みとして、ハード面であるデータの取得（ロボット、センサ等の



■図7 SIP「自動走行システム」の全体像<sup>11</sup>

※11  
「戦略的イノベーション創造プログラム（SIP）自動走行システム 研究開発計画」内閣府ウェブサイト <[http://www8.cao.go.jp/cstp/gaiyo/sip/keikaku/6\\_jidousoukou.pdf](http://www8.cao.go.jp/cstp/gaiyo/sip/keikaku/6_jidousoukou.pdf)>より編集部作成

■表4 我が国の戦略～7つの対応方針～(未来に向けた経済社会システムの再設計)<sup>12</sup>

| 方針                              | 内容   |
|---------------------------------|--|
| ①データ利活用促進に向けた環境整備               | <ul style="list-style-type: none"> <li>・データプラットフォームの構築、データ流通市場の創成</li> <li>・個人データの利活用の促進</li> <li>・セキュリティ技術や人材を生み出すエコシステムの構築</li> <li>・第4次産業革命における知的財産政策の在り方</li> <li>・第4次産業革命に対応した競争政策の在り方</li> </ul> |
| ②人材育成・獲得、雇用システムの柔軟性向上           | <ul style="list-style-type: none"> <li>・新たなニーズに対応した教育システムの構築</li> <li>・グローバルな人材の獲得</li> <li>・多様な労働参画の促進</li> <li>・労働市場・雇用制度の柔軟性向上</li> </ul>   |
| ③イノベーション・技術開発の加速化(「Society5.0」) | <ul style="list-style-type: none"> <li>・オープンイノベーションシステムの構築</li> <li>・世界をリードするイノベーション拠点の整備・国家プロジェクトの構築・社会実装の加速(人工知能等)</li> <li>・知財マネジメントや国際標準化の戦略的推進</li> </ul>   |
| ④ファイナンス機能の強化                    | <ul style="list-style-type: none"> <li>・リスクマネー供給に向けたエクイティファイナンスの強化</li> <li>・第4次産業革命に向けた無形資産投資の活性化</li> <li>・FinTechを核とした金融・決済機能の高度化</li> </ul>  |
| ⑤産業構造・就業構造転換の円滑化                | <ul style="list-style-type: none"> <li>・迅速・果敢な意思決定を可能とするガバナンス体制の構築</li> <li>・迅速かつ柔軟な事業再生・事業再編等を可能とする制度・環境整備</li> <li>・労働市場・雇用制度の柔軟性向上(再掲)</li> </ul>   |
| ⑥第4次産業革命の中小企業、地域経済への波及          | <ul style="list-style-type: none"> <li>・中小企業、地域におけるIoT等導入・利活用基盤の構築</li> </ul>  |
| ⑦第4次産業革命に向けた経済社会システムの高度化        | <ul style="list-style-type: none"> <li>・第4次産業革命に対応した規制改革の在り方</li> <li>・データを活用した行政サービスの向上</li> <li>・戦略的な連携等を通じたグローバル展開の強化</li> <li>・第4次産業革命の社会への浸透</li> </ul>   |

世界シェア)、質の高い教師データ(現場の暗黙知)、社会実装産業化(少子高齢化のトップランナー、自動車などの市場シェア、高品質なモノを理解・評価できる消費者)があると分析し、弱みであるソフト面との一体的に接続する発想と仕組みを構築することをうたっており、そこに向けた我が国の戦略を「7つの対応方針」として表4のようにまとめている。

また、最終のとりまとめの中では目指すべき将来像として「Society5.0」(超スマート社会)、それを実現するための産業の在り方として「Connected Industries」が掲げられている。Connected Industriesは多様な人、組織、機械、技術、国家がつながり、新たな付加価値を創出し、社会課題を解決していくものとされている。その中で目指すべき社会の具体的内容の一つとして「個々人の、日本の、世界の抱える課題にタブーなく、いち早く挑戦し、解決を目指す、それぞれの真のニーズに対応する社会」が挙げられ、その内容の一つとして「AI等の技術革新・データ利活用により、今までは対応しきれなかった、個人の真のニーズ(移動困難者や交通事故を減らす、病気になる人・要介護者を減らす等)に対応」するものとされている(図8)。

また、産業構造審議会産業技術環境分科会研究開発・イノベーション小委員会では、イノベーションを推進するための取組施策について、平成28年5月に中間とりまとめを行った<sup>14</sup>。その中でAIを産業構造を一変させうる技術の一つと位置づけ、国内外問わず、優秀な人材・技術を取り込むことで、我が国のイノベーション拠点としての土壌を維持・向上していくことが重要としている。

経済産業省が総務省と共同で推進している組織体であるIoT推進コンソーシアムは、産学官が参画・連携し、IoT推進に関する技術の開発・実証や新たなビジネスモデルの創出推進するための体制を構築することを目的として、①IoT・ビッグデータ・AI等に関する技術の開発・実証及び標準化等の推進、②IoT・ビッグデータ・AI等に関する各種プロジェクトの創出及び当該プロジェクトの実施に必要な規制改革等の提言等、③セキュリティ等のIoT・ビッグデータ・AI等に関する特定課題に関わる検討

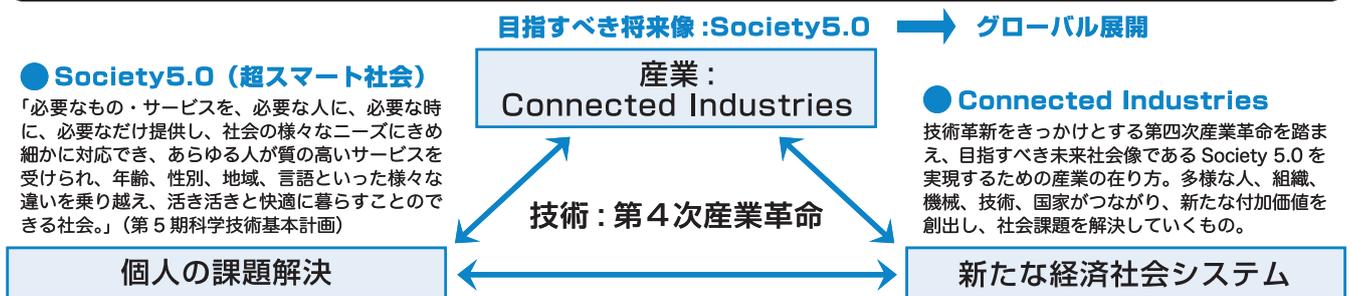
※12  
 「新産業構造ビジョン」中間整理を行いました～第4次産業革命をリードする戦略的取組を発表いたしました～ 経済産業省ウェブサイト <[http://www.meti.go.jp/committee/sankoushin/shin\\_sangyoukouzou/pdf/008\\_05\\_01.pdf](http://www.meti.go.jp/committee/sankoushin/shin_sangyoukouzou/pdf/008_05_01.pdf)>より作成

※13  
 「新産業構造ビジョン」をとりまとめました～「一人ひとりの、世界の課題を解決する日本の未来」を発表いたしました」経済産業省ウェブサイト <<http://www.meti.go.jp/press/2017/05/20170530007/20170530007-1.pdf>>より編集部作成

等を行っている。

この中で、平成28年1月にはデータ流通促進WGを設置し、BtoBにおけるデータ取引契約等の際に課題となる事象についてユースケースをベースに相談が出ている事業者に対して助言を実施した。ユースケースの例としては、「移動履歴をヒートマップ等で可視化し、マーケティング等へ利用」、「ドライバーのバイタルデータを活用したヘルスケアサービス」等が挙げられている。また、平成28年7月にはデータ流通促進WGの作業部会にカメラ画像利活用SWGを設置し、カメラ画像の利活用に関して、事業者

## Society5.0・Connected Industries を実現する「新産業構造ビジョン」



### 打ち破るべき壁

|   |   |  |   |   |
|---|---|--|---|---|
| <p><b>①不確実性の時代に合わない硬直的な規制</b></p> <ul style="list-style-type: none"> <li>・新たな技術やビジネスモデルの試行錯誤を許容しない規制</li> <li>・業規制による新規参入抑制等</li> </ul> | <p><b>②若者の活躍・世界の才能を阻む雇用・人材システム</b></p> <ul style="list-style-type: none"> <li>・座学中心、文理の壁、専門領域縦割り教育等</li> <li>・終身雇用・年功序列、職務内容無制限等</li> </ul> | <p><b>③世界から取り残される科学技術・イノベーション力</b></p> <ul style="list-style-type: none"> <li>・経営層のリーダーシップを阻む大学システム(学内統治、国の資金に依存した財政基盤)</li> <li>・外部からの健全なプレッシャーによる価値創造に向けた競争の欠如等</li> </ul> | <p><b>④不足する未来に対する投資</b></p> <ul style="list-style-type: none"> <li>・低調な科学技術予算</li> <li>・年配教授偏重による、若手研究者へのしわ寄せ(任期付研究員の増加)</li> <li>・人生100年時代、高齢者が何度も輝けるようになっていない等</li> </ul> | <p><b>⑤データ×AIを使いにくい土壌/ガラパゴス化</b></p> <ul style="list-style-type: none"> <li>・過度な「自前主義」</li> <li>・データサイエンスプログラムの不足</li> <li>・高いデータ処理コスト</li> <li>・データ利活用に関する理解度の欠如等</li> </ul> |
|---|---|--|---|---|

### その壁を打ち破った先に、どのような社会を目指すのか

|   |  |  |   |   |
|---|--|--|---|---|
| <p><b>個々人の、日本の、世界の抱える課題にタブーなく、いち早く挑戦し、解決を目指す、それぞれの真のニーズに対応する社会。</b></p> <ul style="list-style-type: none"> <li>・日本の目指すべき将来像、Society 5.0 を実現し、社会的、構造的課題を解決しつつ、それを経済成長に繋げていく。</li> <li>・AI等の技術革新・データ利活用により、今までは対応しきれなかった、個人の真のニーズ(移動困難者や交通事故を減らす、病気になる人・要介護者を減らす等)に対応。</li> </ul> | <p><b>変革期に必要な若者の情熱と才能を存分に解き放ち、それゆえ、人材が育ち、世界からも才能が集まる社会。</b></p> <ul style="list-style-type: none"> <li>・仕事によって、能力が最大限発揮できる「ピーク年齢」は異なる。データ×AIの分野は、「ピーク年齢」が低く、若者の能力が突き抜けている。若者の力を解き放つことが必要。</li> <li>・人生100年時代、1人1人が能力を高め続けることで、何度も輝ける社会にすることができる。国内で人材が育てば、世界からも才能が集まってくる。</li> </ul> | <p><b>不確実性の時代だからこそ、多様性とチャレンジを一層許容し、アントレプレナーシップ(起業家精神)に富む社会。</b></p> <ul style="list-style-type: none"> <li>・年齢、性別、国籍、人種といった全ての面で多様であることが、「データ×AI」の均質化圧力の下で、より一層新たな価値を生む。進展する市場のグローバル化への対応としても多様性は必要。</li> <li>・指数関数的な時代、もはや個人、企業、社会全体がマインドセットを変えて、従来の規制の枠組み等にとらわれないアントレプレナーシップ(起業家精神)に富む必要。</li> </ul> | <p><b>新技術等をいち早く取込み、スピーディかつグローバルに展開・刷新することで、未来を変える期待感にあふれる社会。</b></p> <ul style="list-style-type: none"> <li>・日本の強みの1つは、先進技術をいち早く取り込み、モノをグローバルに展開・刷新していく力。これまでも新たな技術を現実の世界に応用し、グローバルな課題を解決。</li> <li>・これからは、世界の課題を解決する等、未来を変える期待感こそが富を生み出す時代。後手後手に回らないよう、常に変化を生み出す側にいる必要。</li> </ul> | <p><b>絶え間ないイノベーションにより、成長と格差は正の両立を実現する世界に類を見ない社会。</b></p> <ul style="list-style-type: none"> <li>・第4次産業革命技術を、都市、大企業だけでなく、地域、中小企業、高齢者にも広げることで、生産性向上、賃金上昇の好循環を日本に生み出す世界初の最適化モデルを目指す。</li> <li>・社会全体として、働き方も変わるなか、生涯にわたって有意義で価値ある仕事と充実した暮らしを送れる社会にしていく必要。これに応じるセーフティネットを再構築していく。</li> </ul> |
|---|--|--|---|---|

■図8 新産業構造ビジョンにおける「目指すべき将来像」<sup>13)</sup>

※14

「イノベーションを推進するための取組について」経済産業省ウェブサイト <[http://www.meti.go.jp/committee/sankoushin/sangyougijutsu/kenkyu\\_kaihatsu\\_innovation/pdf/report01\\_01.pdf](http://www.meti.go.jp/committee/sankoushin/sangyougijutsu/kenkyu_kaihatsu_innovation/pdf/report01_01.pdf)>

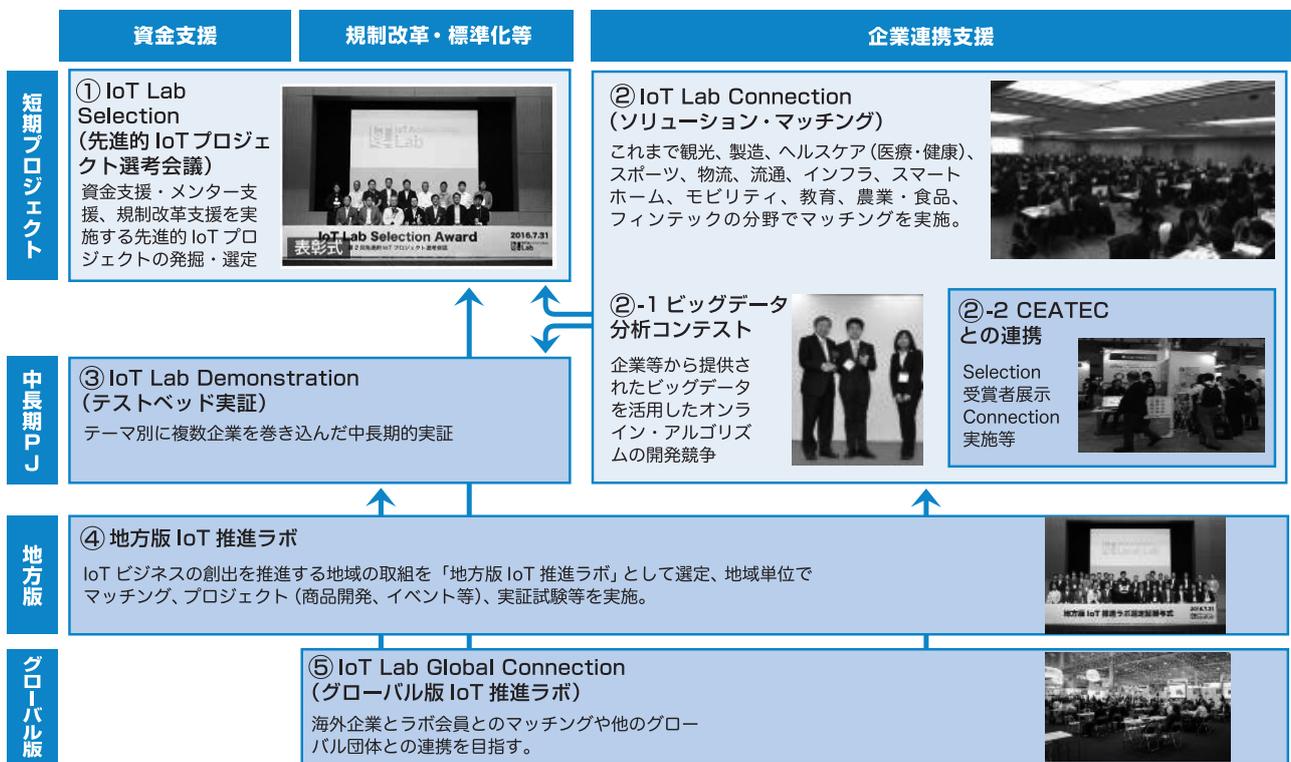


図9 IoT推進ラボの活動実績<sup>16</sup>

### オープンイノベーション・ハブ拠点の構築

AI技術と我が国の強みであるものづくり技術の融合等により、我が国発の新たな付加価値を創出するため、国内外の叡智を集めた産学官一体の研究拠点を構築します。

- 産学官が集い共創する物理的な場所・施設インフラの整備
- 模擬的な医療・介護現場、住環境、工場等の実証環境の整備
- 医療・介護分野など様々な個別分野データの
  - ①収集・管理、
  - ②解析、
  - ③二次提供を行うデータ基盤の構築
- AI技術を搭載した機器等の試作・実証・評価環境の整備 等

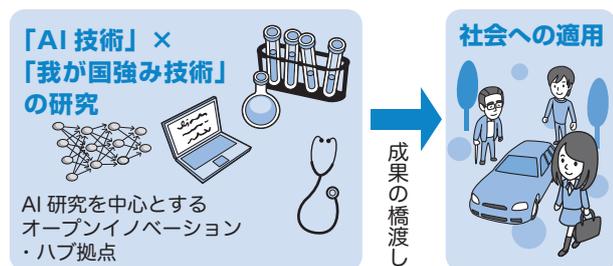


図10 人工知能に関するグローバル研究拠点整備事業<sup>17</sup>

が配慮すべき事項(主に、取得時の配慮、利用時の配慮、必要な安全管理策)と生活者に対する透明性の担保の方法を中心に、ユースケースベースで集中的な議論が行われた。その内容は「カメラ画像利活用ガイドブック」<sup>15</sup>としてとりまとめられている。

また、平成27年10月にはIoT推進ラボ(先進的モデル事業推進WG)を設置し、図9に示したように①資金支援、②規制支援(規制見直し、ルール形成)、③企業連携支援を通じて個別企業による尖ったプロジェクトや中長期の社会実装を見据えた複数企業によるプロジェクトを支援している。このうち、短期の個別企業による尖ったプロジェクトを対象としている「IoT Lab Selection」では、AI

※15 「カメラ画像利活用ガイドブックver1.0」を策定しました」経済産業省ウェブサイト <<http://www.meti.go.jp/press/2016/01/20170131002/20170131002.html>>

※16 「IoT推進ラボとこれまでの進め方と今後の進め方」IoT推進ラボウェブサイト <[https://iotlab.jp/common/pdf/161206\\_distribution\\_j.pdf?date=1612211700](https://iotlab.jp/common/pdf/161206_distribution_j.pdf?date=1612211700)>より編集部作成

※17 「人工知能に関するグローバル研究拠点整備事業」経済産業省ウェブサイト <[http://www.meti.go.jp/information\\_2/publicoffer/282jihosei/282ji\\_PR\\_10.pdf](http://www.meti.go.jp/information_2/publicoffer/282jihosei/282ji_PR_10.pdf)>より編集部作成

を活用した多数のプロジェクトが支援対象として選定されている。

平成28年度補正予算及び平成29年度予算の、経済産業省所管のAIに関わる研究開発等の事業としては、以下のようなものが挙げられる。

### ○人工知能に関するグローバル研究拠点整備事業

図10に示したように、AI技術と我が国の強みであるものづくり技術の融合等により、我が国発の新たな付加価値を創出するため、国内外の叡智を集めた産学官一体のオープンイノベーション・ハブ拠点を産業技術総合研究所に構築する。

- 産学官が集い共創する物理的な場所・施設インフラの整備
- 模擬的な医療・介護現場、住環境、工場等の実証環境の整備
- 医療・介護分野など様々な個別分野データの①収集・管理、②解析、③二次提供を行うデータ基盤の構築
- AI技術を搭載した機器等の試作・実証・評価環境の整備等を実施することとなっている。

### ○次世代人工知能・ロボット中核技術開発

未だ実現していない次世代のAI・ロボット技術のうち図11に示したような中核的な技術の開発を産学官連携で実施し、AI技術とロボット要素技術の融合を目指す。本プロジェクトは、後述するように新エネルギー・産業技術総合開発機構（NEDO）が研究開発プロジェクトマネジメントを実施している。併せて、産業技術総合研究所において新たな研究体制の整備（海外の卓越研究者の招へい等による研究チームの整備等）を行う。

### ○IoT推進のための横断技術開発プロジェクト

IoT社会の進展における大量のデータの一層の活用のための、技術シーズの性能向上とシステム全体としての最適化に向けて、システムとしてデータを収集、蓄積、解析するために必要となる基盤・実装技術及びそれらに必要となるセキュリティ基盤技術等の研究開発を行い、更に社会実装を進める公募プロジェクトである。

採択されたテーマにおいては、AIに関連の深いものがみられる。例えば、「省電力AIエンジンと異種エンジン統合クラウドによる人工知能プラットフォーム」は、図12に示したようにAIによる高度なデータ処理の実現に向けて、エッジ側とクラウド側双方で10倍の電力性能比を実現するAI処理の共通基盤技術の開発を行うものである。

以上の事業のほかにも、「IoTを活用した社会インフラ等の高度化推進事業」においては、産業保安

### 場面に合わせて柔軟に対応する人工知能

- 場面や人の行動を理解・予測し、適切に行動する賢い知能
- ロボット同士が高度に連携するための知識・経験共有基盤技術等

### 環境の変化に影響されない視覚・聴覚等（センシング）

- 屋外で高速かつ精密に距離を計測するセンサや光沢物等の難識別物を認識するカメラシステム
- 環境変化を学習し、柔軟に対応する視覚・聴覚・力触覚システム等

### 自律的に多様な作業を実現するスマートアクチュエーション

- 教示の省力化を実現するロボット動作の自動計画技術
- 重いものを持ち上げと精密な動作の両方を実現し、かつ軽量な人工筋肉等の革新的動作技術と制御技術等

### リスク評価・性能評価技術等

【例】

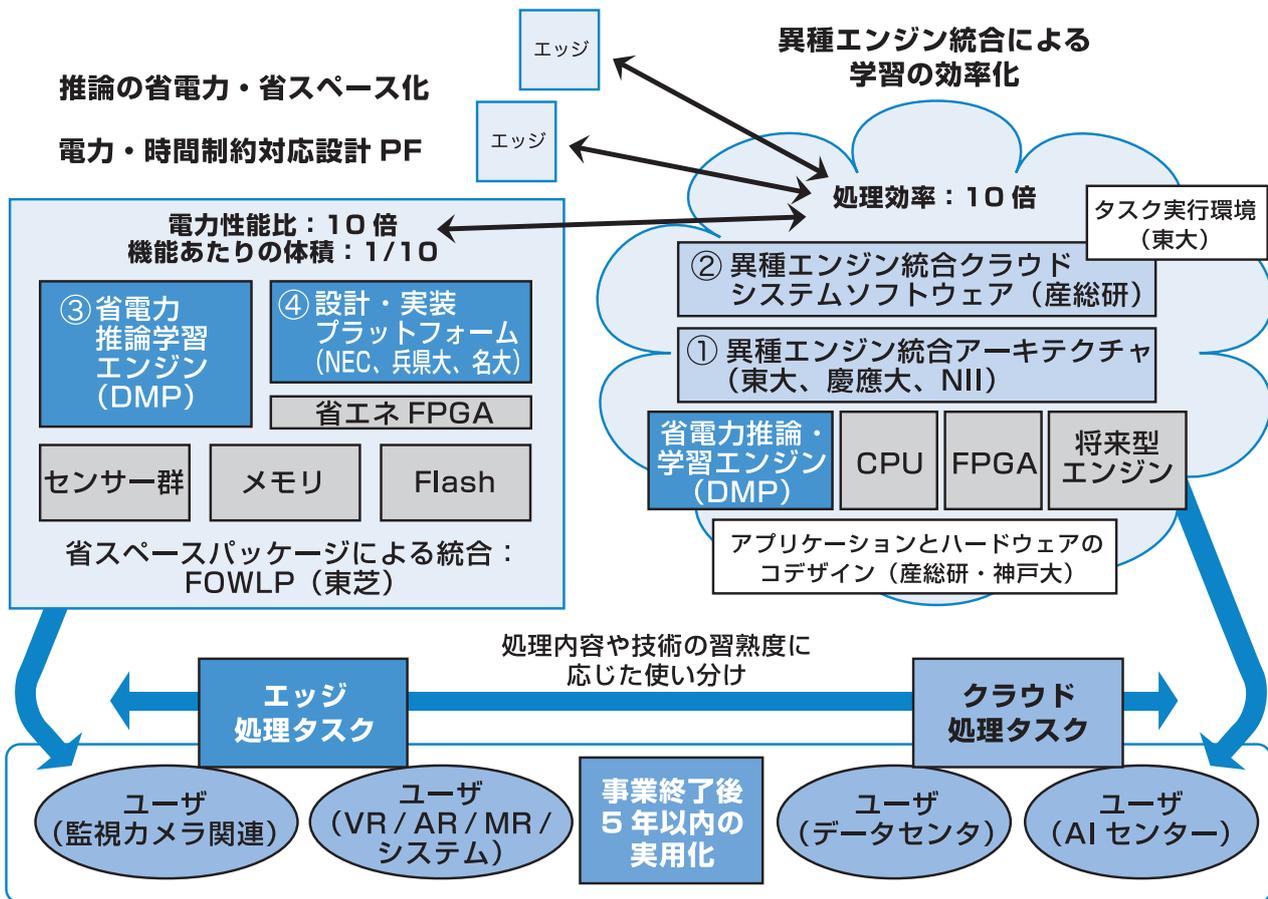


全方位に自律移動する次世代車椅子

■図11 次世代人工知能・ロボット中核技術開発<sup>18</sup>

※18

「次世代人工知能・ロボット中核技術開発」経済産業省ウェブサイト <[http://www.meti.go.jp/main/yosan/yosan\\_fy2017/pr/ippan/i\\_sangi\\_a\\_06.pdf](http://www.meti.go.jp/main/yosan/yosan_fy2017/pr/ippan/i_sangi_a_06.pdf)>より編集部作成



■図12 省電力AIエンジンと異種エンジン統合クラウドによる人工知能プラットフォーム<sup>19</sup>

水準の維持・向上を図るため、製油所が有する各種データと配管の腐食率との相関関係の分析やヒヤリハット情報・運転員行動データ等の相関分析等による事故予兆、複数の事業所間での事故や異常現象等の情報を共有するための情報共有プラットフォームの構築・実証といった様々なデータを活用した実証事業を行い、その中で分析ツールとしてAIを活用することを想定している。

「IoT推進のための新産業モデル創出基盤整備事業」では、現在、パイロットが手動で対応している悪天候時の飛行計画等について、AI技術を活用し、リアルタイムに運航データを解析し、安全かつ最適ルートを示す等のパイロット支援システムの実証等を行う予定である。

「企業保険者等が有する個人の健康・医療情報を活用した行動変容促進事業」では、IoT機器（ウェアラブル端末等）やその取得データを活用し、糖尿病予防・改善を図る実証研究等を実施対象としており、その中でAIを活用している。

また、製品評価技術基盤機構バイオテクノロジーセンター保有の微生物に関する情報や、農林水産省関係機関保有の植物に関する情報について、全遺伝情報（ゲノム）や代謝情報などのデータを大量に収集し、産業技術総合研究所がこれらのデータを基に、遺伝子機能を特定して最適な遺伝子の組み合わせを設計するAIを開発する実証事業を行う予定である。

※19  
「IoT推進のための横断技術開発プロジェクトに着手 別紙資料」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100790655.pdf>>より編集部作成

※20  
結果の一部は「3.2.知的財産」にて言及等している。

※21  
「次世代人工知能技術社会実装ビジョン」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100782828.pdf>>

経済産業省では、行政自身の業務改善へのAIの活用も視野に入れており、国会答弁の作成支援をAIで行う実証実験を平成29年1月～2月に実施した。

特許庁では、平成28年度に、AIを活用した創作について①技術的な立場から現状把握と今後の技術進展を確認すること、②産業財産権法上の保護に関するユーザニーズを把握すること、③諸外国での産業財産権法上の保護の現状や議論を確認すること、④法制上の問題点等について有識者の見解や議論を確認することを目的として調査研究を実施した。その結果は「AIを活用した創作や3Dプリンティング用データの産業財産権法上の保護の在り方に関する調査研究報告書」としてとりまとめられている<sup>20</sup>。

平成29年度には、「人工知能技術を活用した問合せ対応業務の高度化・効率化実証的研究事業」として、外部ユーザからの特許庁における各種手続等に関する問合せについて、AI技術を活用して応答を行うシステムを構築し、その導入について検証を行う予定である。

資源エネルギー庁では、「計算科学等による先端的な機能性材料の技術開発事業」として、従来技術の延長線上にない機能を有する超先端材料の創製とその開発スピードの劇的な短縮を目指し、AI等の計算科学、プロセス技術、計測技術からなる革新的な材料開発基盤技術を確立することを目指している。

中小企業庁では、平成28年度補正予算事業として「革新的ものづくり・商業・サービス開発支援補助金」を実施しており、この中の枠として「第四次産業革命型」の公募を行っている。これは、IoT・AI・ロボットを用いた設備投資を支援するもので、AI又はロボットの活用が応募の要件となっており、採択事業の中にはAIを活用した生産ラインの効率化、AI分析を活用した機械設備の劣化診断等、様々な活用事例がみられる。

NEDOでは、平成27年度から、「次世代人工知能・ロボット中核技術開発」（次世代人工知能技術分野）の研究開発拠点として、産業技術総合研究所AIRCに委託し、NEDOが委嘱したプロジェクトリーダーの辻井潤一研究センター長の指揮の下に研究開発を推進している。同プロジェクトは、NEDO技術戦略研究センター（TSC）が策定した技術戦略における研究開発拠点構想を具現化したもので、成果を最大化するため、拠点に英知を結集し、重要な研究開発テーマを選定して実施している。設立当初は、本拠

■表5 産業技術総合研究所AIRCにおけるAIに関わる研究計画<sup>22</sup>

| 分野                         | 研究テーマ   | 主な内容  |
|----------------------------|---|---|
| 製造業を革新する産業用ロボット技術の研究開発     | <ul style="list-style-type: none"> <li>産業用ロボットによるセル生産自動化</li> <li>動作模倣技術によるティーチングの容易化</li> </ul>                                  | <ul style="list-style-type: none"> <li>操作対象を状態も含めて認識し、ピッキング、折り畳み、ワイヤリングなどの操作を計画・実行。</li> <li>ロボットの感覚・運動連合、動作の観察からの模倣学習によるロボットの動作ティーチング。</li> </ul>  |
| 人々の生活環境を理解し改善する技術の研究開発     | <ul style="list-style-type: none"> <li>人間行動モデリング・社会シミュレーションによるサービス改善・創出</li> <li>画像・音声・言語解析による実世界理解とその応用（自動運転、インフラ検査等）</li> </ul> | <ul style="list-style-type: none"> <li>確率モデリングやエージェントシミュレーションによる人々の行動予測とそれに基づくサービス設計。</li> <li>画像、動画、音声データからの特徴抽出、異常検知技術の応用（インフラ検査、医療診断、監視カメラ等）</li> <li>セマンティック地図やオントロジーを用いた危機予測による自動運転、運転支援。</li> </ul> |
| ビッグデータ時代の科学技術研究を支える技術の研究開発 | <ul style="list-style-type: none"> <li>機械学習による要因発見・機能予測・実験計画</li> <li>学術データや技術データからの知識発見・未来予測</li> </ul>                          | <ul style="list-style-type: none"> <li>生命科学や材料科学等の実験データに機械学習技術を適用し、要因発見、機能予測等を行う。</li> <li>文献情報からの知識発見や技術の未来予測を可能にし、科学技術の研究開発を加速。</li> </ul>  |
| AIプラットフォーム技術の研究開発          | <ul style="list-style-type: none"> <li>次世代人工知能フレームワーク研究、先進中核モジュール研究開発</li> <li>次世代人工知能テストベッドの研究開発</li> </ul>                      | <ul style="list-style-type: none"> <li>主要モジュールの研究開発、それらモジュールを組み合わせたアプリ開発を容易にするワークフローの構築。</li> <li>大規模目的基礎研究や先端技術研究開発の成果の活用と検証を促進。</li> </ul>  |
| ブレイクスルーとなる要素技術の研究開発        | <ul style="list-style-type: none"> <li>次世代脳型人工知能研究開発</li> <li>データ・知識融合型人工知能研究開発</li> <li>機械学習・確率モデリングの高度化</li> </ul>              | <ul style="list-style-type: none"> <li>実世界課題に適用し、脳型人工知能システムやデータ知識融合型人工知能システムを概念実証。</li> <li>スケーラブルな機械学習・確率モデリング手法の研究開発。深層表現学習の高度化。</li> </ul>   |

※22

「3機関の研究計画(案) (概略版)」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100793065.pdf>> より作成

※23

「次世代人工知能推進戦略」総務省ウェブサイト <[http://www.soumu.go.jp/main\\_content/000424360.pdf](http://www.soumu.go.jp/main_content/000424360.pdf)>

点における100名超の研究員体制を目指し、これを早期に実現した。今後は、拠点のグローバル化を含め、先進的な次世代人工知能の社会実装と基礎研究の進展が相互に連携する好循環の形成を目指していく。

また、平成28年に「次世代人工知能技術社会実装ビジョン」<sup>21</sup>を有識者の検討会を設置して作成している。次世代のAI技術の発展に伴い、我が国主要分野（出口分野）においてどのような効果がもたらされるかについて、AI技術の進展予測とともに時間軸上に可視化したものである。出口分野としては、①ものづくり、②モビリティ、③医療・健康、介護、④流通・小売、物流が取り上げられている。

産業技術総合研究所AIRCにおいては、表5に示すようにAI関連研究開発として応用分野に即した「製造業を革新する産業用ロボット技術の研究開発」（AI for Manufacturing）、「人々の生活環境を理解し改善する技術の研究開発」（AI for Human life/Services）、「ビッグデータ時代の科学技術研究を支える技術の研究開発」（AI for Science/Technology）及び「AIプラットフォーム技術の研究開発」、「ブレイクスルーとなる要素技術の研究開発」が計画されている。

#### 4.2.2.3 総務省

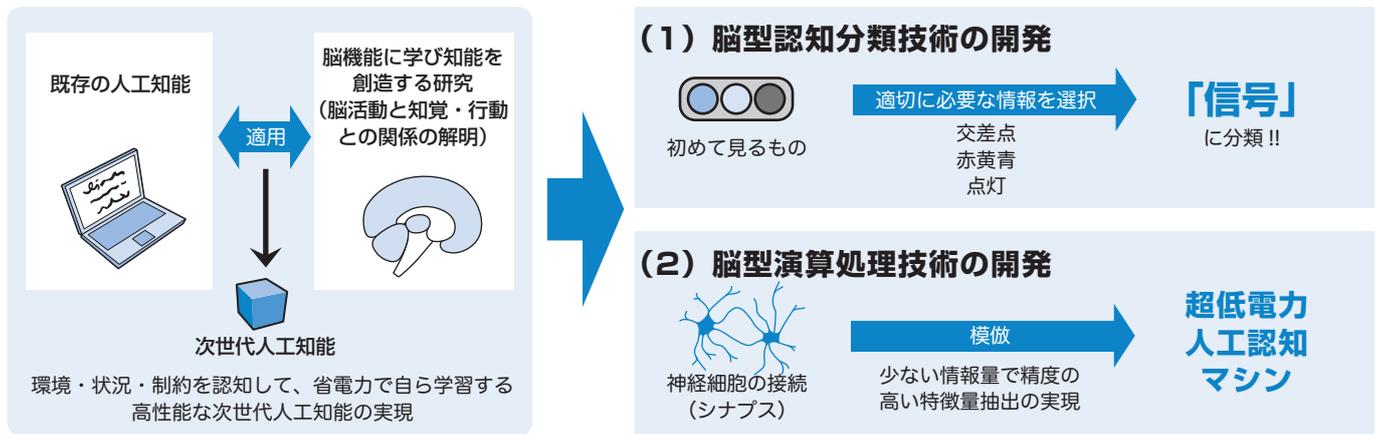
総務省では、平成28年1月から5月にかけて、情報通信審議会に情報通信技術分科会技術戦略委員会AI・脳研究WGを設置し、ビッグデータ解析と脳科学を融合した次世代人工知能に関する推進方策の検討がなされた。その検討を受けてとりまとめられた「次世代人工知能推進戦略」<sup>23</sup>においては、我が国が注力すべき研究開発分野として①小規模データで実現する人工知能技術の開発（スパース（疎）性の利用）、②深層学習の欠点を克服した新たな機械学習法の研究開発、③半教師あり学習など新たな機械学習法の研究開発、④運動と人工知能の組み合わせ、⑤自然言語処理の高度化、⑥ネットワーク型人工知能社会基盤の実現、⑦人工知能の脳科学への適用、⑧脳科学の知見の人工知能への適用（マルチモーダル人工知能技術、超小型計量低電力人工チップ、脳に学ぶ柔軟な学習法（半教師あり学習など）、深層学習で

■表6 AIネットワーク化社会の今後の課題<sup>24</sup>

| 項目   | 内容   |
|--|--|
| 1. 研究開発の原則・指針の策定                             | 開発原則及びその内容の説明から構成される指針（「AI開発ガイドライン」（仮称））の策定に向けた議論の推進 |
| 2. AIネットワーク化の進展に向けた協調の円滑化                    | 相互接続性・相互運用性の確保（確保の対象や方法の検討等）等                        |
| 3. 競争的なエコシステムの確保                             | 関連する市場の動向の継続的注視、ネットワーク形成に関する当事者間の協議の円滑化等             |
| 4. 経済発展・イノベーションの促進に向けた課題                     | 持続的な経済発展を実現するための取組の在り方の検討等                           |
| 5. AIネットワーク化の進展に伴う影響の評価指標及び豊かさや幸せに関する評価指標の設定 | 指標の設定に向けた検討の継続                                       |
| 6. 利用者の保護                                    | 関連する市場の動向の継続的注視、消費者保護に関する国際的な制度調和の在り方の検討等            |
| 7. AIネットワークシステムに関するセキュリティの確保                 | 情報セキュリティ等のAIネットワークシステムへの実装の在り方の検討等                   |
| 8. プライバシー及びパーソナルデータに関する制度的課題                 | プライバシー・パーソナルデータの保護と利活用のバランスに留意した検討等                  |
| 9. コンテンツに関する制度的課題                            | 多種多様かつ大量のコンテンツの創造・流通に適した法制度の在り方の検討等                  |
| 10. 社会の基本ルールに関する検討                           | ネットに関するルール（自己責任が基調）とモノの世界に関するルール（製造物責任が基調）との調和の在り方等  |
| 11. リスクに関するシナリオの作成・共有                        | AIネットワーク化の進展に応じたシナリオの継続的な作成・共有・見直し                   |
| 12. 情報通信インフラの高度化の加速                          | SDNに関する相互接続性・相互運用性の確保、試験環境の整備の推進等                    |
| 13. AIネットワーク・ディバイド形成の防止                      | AIネットワーク・ディバイドの要因となるデジタル・ディバイドの解消、高齢者等の利用環境整備等       |
| 14. 人間の在り方に関する検討                             | 「AI依存」等人間の心理や子供の発育への影響等に関する継続的注視、教育の改革等              |
| 15. AIネットワークシステムに関するリテラシーの涵養                 | リテラシー教育の在り方の検討、科学コミュニケーションの在り方の検討                    |
| 16. AIネットワーク化に対応した人材育成                       | 技術者、法的・倫理的・社会的問題に対処し得る人材、産業連携等に対処し得る人材等の育成等          |
| 17. AIネットワーク化に対応した就業環境の整備                    | 労働法制の在り方の検討等   |
| 18. セーフティネットの整備                              | 所得の再分配の在り方（ベーシック・インカム等）の検討                           |
| 19. 地球規模課題の解決を通じた人類の幸福への貢献                   | 途上国支援のための取組の在り方の検討                                   |
| 20. AIネットワークシステムのガバナンスの在り方                   | 国際的な議論の場の形成、国内の議論の場の形成                               |

※24

「これまでの検討状況 - AIネットワーク化検討会議とその成果 -」  
 総務省ウェブサイト <[http://www.soumu.go.jp/main\\_content/000447311.pdf](http://www.soumu.go.jp/main_content/000447311.pdf)>より作成



■図13 次世代人工知能技術の研究開発<sup>25</sup>

のブラックボックス化の抑制) が挙げられている。

平成29年1月には、この検討を受けて「次世代人工知能社会実装WG」が設置され、自然言語処理技術、脳情報通信技術等の次世代人工知能技術に関する今後の研究開発、社会実装について調査・検討が実施されている。

AIの実装に向けた社会課題等については、情報通信政策研究所が事務局となり、AIネットワーク化検討会議が設置されて平成28年2月から6月にかけて検討が行われた。この中では「AIネットワーク化」が社会・経済にもたらす影響とリスクについて、公共（公共インフラ、防災、スマートシティ、行政）／生活（生活支援、豊かさ創造（創造的活動、コミュニティ活動等））／産業（分野共通（コーポレート業務等）、農林水産、製造業、運輸・物流、卸売・小売、金融・保険、医療・介護、教育・研究、サービス業、建設）の分野ごとに、2020年代～2040年代の時系列で評価した上で、表6にあるようにAIの開発原則・指針の策定等今後の課題が整理されている。

同会議は平成28年10月にAIネットワーク社会推進会議と改組され、会議の下に開発原則分科会及び影響評価分科会が設置された。前者はAIの開発原則・指針の素案の検討、後者は「AIネットワーク化」が社会・経済にもたらす影響とリスクの評価等が実施されている。また、平成29年3月にはAIネットワーク社会推進フォーラム（国際シンポジウム）が開催され、OECD、EU、イタリア政府（次回G7議長国）、韓国政府、海外企業・団体、国内の専門家・実務家が参画して議論が行われた。

平成28年度補正予算及び平成29年度予算の、総務省所管のAIに関わる研究開発等の事業としては、以下のようなものが挙げられる。

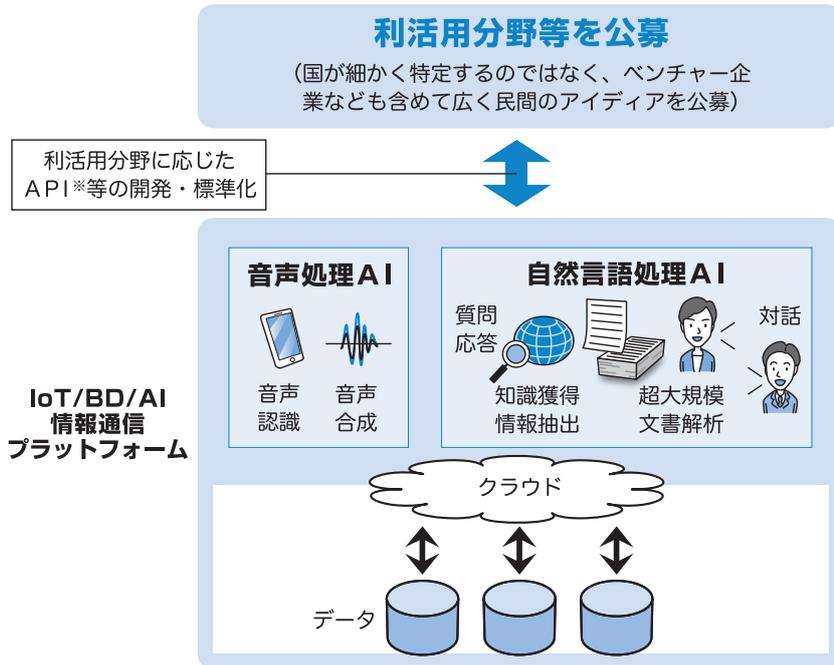
### ○次世代人工知能技術の研究開発

脳神経回路の演算メカニズムを模倣して、少数データ、無作為データからリアルタイムに取捨選択しながら特徴・意味を抽出し、分類・学習すること等を可能とする次世代人工知能技術の実現に向けた研究開発を行う。具体的には図13に示したように、脳型認知分類技術の開発、脳型演算処理技術の開発を実施することとなっている。

※25

「平成29年度予算案」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100860021.pdf>> より編集部作成

- 「IoT/BD/AI情報通信プラットフォーム」を通じた様々な分野におけるデータ収集とAIによる解析により新たな価値を創出することが我が国の国際競争力確保にとって決定的に重要
- 音声処理、自然言語処理等のAI基盤技術をもとに、多様な分野で人間と自在な対話が可能な次世代サービス等を実現



■図14 「IoT/BD/AI情報通信プラットフォーム」社会実装推進事業<sup>26</sup>



■図15 多様な経済分野でのビジネス創出に向けた『最先端AIデータテストベッド』の整備<sup>27</sup>

※26 「平成29年度予算案」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100860021.pdf>>より編集部作成

※27 「総務省における人工知能関連施策の予算要求の状況について」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100799733.pdf>>より編集部作成

## ○「IoT/BD/AI情報通信プラットフォーム」社会実装推進事業

最先端のAI基盤技術を様々な産業分野に早急に展開し、データ収集とAI解析により価値創出を図るため、産学官のオープンイノベーションによる先進的利活用モデルの開発や国際標準化を推進し、図14のような新たな価値創出基盤となる「IoT/BD/AI情報通信プラットフォーム」の構築と社会実装を推進する。具体的には最先端の自然言語処理技術を活用した高度自然言語処理プラットフォームの研究開発、国民生活分野における高度AIシステムの事業化に向けた研究開発、IoTデバイス/プラットフォーム等の連携技術の確立と相互接続に向けた研究開発の3課題の公募を実施することとなっている。

## ○多様な経済分野でのビジネス創出に向けた『最先端AIデータテストベッド』の整備

NICTが「多言語音声翻訳」「脳情報通信」等の研究開発を通じて蓄積してきた言語情報データ、脳情報モデル等について、図15のようにNICTの実証ネットワーク（JGN）を通じて全国規模で利用可能とし研究開発と実証を加速する『最先端AIデータテストベッド』を構築することとなっている。

このほか、「医療・健康データ利活用基盤高度化事業」では「国民一人一人が自分自身の医療・健康データを管理・活用するモデル（PHR）や、AIを用いたデータ分析等について研究を実施する予定である。

また、総務省が所管しているNICTにおいては、表7に示すようにAI関連研究開発として社会問題の自動検出・自動回答生成等の「社会知解析基盤技術」、多言語同時通訳等の「多言語翻訳技術」、脳内ネットワークのモデルを用いた新たな情報処理アーキテクチャの研究開発等の「脳活動計測技術の研究開発」等が計画されている。

■表7 NICTにおけるAIに関わる研究計画<sup>※28</sup>

| 分野          | 研究テーマ  | 主な内容  |
|-------------|--|---|
| 社会知解析基盤技術   | <ul style="list-style-type: none"> <li>自律的社会知技術の研究開発</li> <li>リアルタイム社会知の研究開発</li> </ul>  | <ul style="list-style-type: none"> <li>社会における問題を自動検出し、より包括的な知識を得る質問の自動生成、および回答統合技術の研究開発</li> <li>SNS上の事象をリアルタイムに自動検出し、半自動で、特定の問題、分野等にシステムをチューニングする技術の研究開発</li> </ul>                                    |
| 多言語音声翻訳技術   | <ul style="list-style-type: none"> <li>音声翻訳の自動翻訳技術の多言語化と多分野化</li> <li>多言語音声翻訳・対話システムの拡張と高精度化</li> <li>超高速・超高精度な多言語自動翻訳技術の研究開発</li> </ul> | <ul style="list-style-type: none"> <li>多言語対訳コーパス収集法の確立および多言語汎用自動翻訳エンジンの研究開発</li> <li>多言語同時通訳技術の研究開発</li> </ul>  |
| 脳情報通信       | <ul style="list-style-type: none"> <li>脳内ネットワークのモデルを用いた新たな情報処理アーキテクチャの研究開発</li> <li>脳情報DBシステムの研究開発</li> </ul>                            | <ul style="list-style-type: none"> <li>脳内NWのモデルから応用可能なバイオマーカーを見出し、現在のアーキテクチャが苦手とする情報処理を効率的に実現する情報処理アーキテクチャの基盤を構築する</li> <li>脳計測システム(MRI,MEG,EEG,NIRS等)による実験データを大規模DBとして構築、関連するデータ処理ツールを含め共有化</li> </ul> |
| サイバーセキュリティ  | <ul style="list-style-type: none"> <li>パーソナルデータの利活用に適用できるプライバシー保護技術の研究</li> <li>セキュリティ技術の自動化の研究開発</li> </ul>                             | <ul style="list-style-type: none"> <li>パーソナルデータ利活用に資するプライバシー保護技術の研究開発およびプライバシー対策支援ツールの開発・運用</li> <li>実利用を鑑みたセキュリティ知識ベースの機能構築・拡充および組織内セキュリティの自動化技術の研究開発</li> </ul>                                       |
| 電磁波・センシング   | <ul style="list-style-type: none"> <li>ビッグデータを用いた太陽フレア発生確率予測の研究開発</li> </ul>   | <ul style="list-style-type: none"> <li>画像解析手法を用いたフレア発生確率の導出および磁場観測利用</li> </ul>   |
| 革新的ネットワーク技術 | <ul style="list-style-type: none"> <li>ネットワーク自動構築制御技術の研究開発</li> <li>自律型エッジクラウド連携技術の研究開発</li> </ul>                                       | <ul style="list-style-type: none"> <li>流通量変動や新サービス出現に対し、ネットワーク資源を各サービスへ適時適切に自動配分する技術の研究開発</li> <li>サービス要求に見合うよう、必要な処理機構を自律的にエッジクラウドに配置する技術の研究開発</li> </ul>  |

### 4.2.2.4 文部科学省

文部科学省では、平成28年度から「人工知能/ビッグデータ/IoT/サイバーセキュリティ統合プロジェクト」（AIPプロジェクト）を実施している。その内容は、①文部科学省が持つビッグデータの解析（コホート、環境のデータなど多様）を通じて、新たな価値を創造、②そのため、革新的な人工知能技術を開発・活用、③ビッグデータの充実のため、高度なセンサ/IoT技術を活用、併せて、堅牢なセキ

※28

「3機関の研究計画(案)(概略版)」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100793065.pdf>>より作成

※29

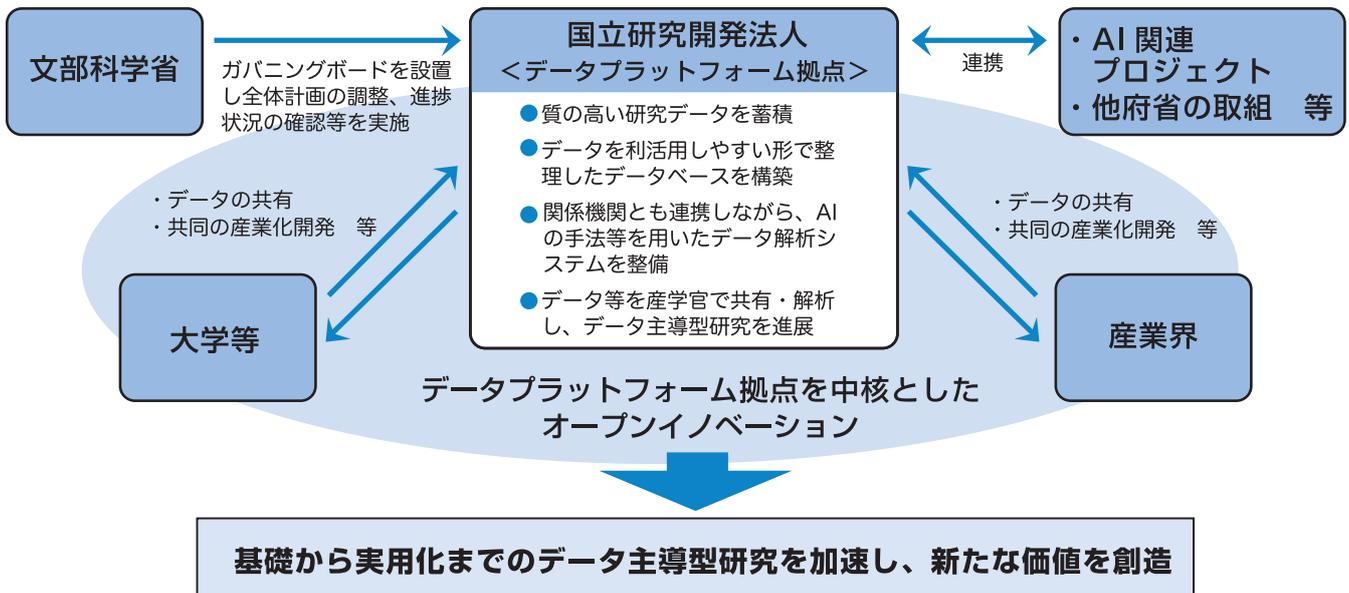
「3機関の研究計画(案)(概略版)」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100793065.pdf>>より作成

ユリティを構築するものとしている。実施体制は理化学研究所内に新たに「革新知能統合研究センター」(AIPセンター)を設置し、AIに関わる研究人材を結集して研究開発を推進するとともに、科学技術振興機構(JST)の戦略的創造研究推進事業を一部活用して、大学等の研究者から広く提案を募り、組織・分野の枠を超えた時限的な研究体制を構築して、戦略的な基礎研究を推進している。

理化学研究所AIPセンターにおいては、表8に示すように「革新的アルゴリズムに基づく基盤研究開発」、「複数分野におけるサイエンスの飛躍的発達」、「多数の応用領域の社会実装への貢献」、「倫理的・社会的課題への対応」、「データサイエンティスト、サイバーセキュリティ人材等の育成」が計画されている。

■表8 理化学研究所AIPセンターにおける研究計画<sup>29</sup>

| 分野                           | 主な内容  |
|------------------------------|---|
| 革新的アルゴリズムに基づく基盤研究開発          | <ul style="list-style-type: none"> <li>全く新しい疎・不完全・超高次元データから高精度学習を実現できるアルゴリズムの開発</li> <li>学習アルゴリズムの選択・調整の自動化及びハードウェアを考慮した学習技術の開発、最適なデータ収集戦略の策定</li> <li>既存手法を改良したさらなる高速学習アルゴリズムの開発</li> <li>ストリーミングデータからリアルタイムで学習できるアルゴリズムの開発</li> </ul> |
| 複数分野におけるサイエンスの飛躍的発達          | <ul style="list-style-type: none"> <li>細分化が進む科学研究への対応</li> </ul>  |
| 多数の応用領域の社会実装への貢献             | <ul style="list-style-type: none"> <li>社会実装を目的とした研究開発(超高齢社会へ向けた医療サポート、老朽化が進むインフラへの対応、甚大な自然災害への対応)</li> </ul>  |
| 倫理的・社会的課題への対応                | <ul style="list-style-type: none"> <li>プライバシー・説明責任を考慮した人工知能技術の開発</li> </ul>   |
| データサイエンティスト、サイバーセキュリティ人材等の育成 | <ul style="list-style-type: none"> <li>クラウドソーシングを用いた遠隔データ解析教育</li> </ul>  |



■図16 「データプラットフォーム拠点の形成」事業<sup>30</sup>

※30 「平成29年度 科学技術関係概算要求の概要」文部科学省ウェブサイト <[http://www.mext.go.jp/component/b\\_menu/other/\\_icsFiles/afieldfile/2016/08/30/1376633\\_1.pdf](http://www.mext.go.jp/component/b_menu/other/_icsFiles/afieldfile/2016/08/30/1376633_1.pdf)>より編集部作成

※31 科学技術振興機構ウェブサイト <[https://www.jst.go.jp/pr/jst-news/pdf/2016\\_11/2016\\_11\\_p10-11.pdf](https://www.jst.go.jp/pr/jst-news/pdf/2016_11/2016_11_p10-11.pdf)>; <[https://www.jst.go.jp/kisoken/crest/research\\_area/ongoing/bunyah26-2.html](https://www.jst.go.jp/kisoken/crest/research_area/ongoing/bunyah26-2.html)>; <[https://www.jst.go.jp/kisoken/crest/research\\_area/ongoing/bunyah25-5.html](https://www.jst.go.jp/kisoken/crest/research_area/ongoing/bunyah25-5.html)>; <[https://www.jst.go.jp/kisoken/crest/research\\_area/ongoing/bunyah25-6.html](https://www.jst.go.jp/kisoken/crest/research_area/ongoing/bunyah25-6.html)>; <[https://www.jst.go.jp/kisoken/presto/research\\_area/ongoing/1112069.html](https://www.jst.go.jp/kisoken/presto/research_area/ongoing/1112069.html)>より作成

また、AIPプロジェクトと連携した事業として、AI等の手法によるデータ主導型研究の推進に向けて「データプラットフォーム拠点の形成」事業が実施されている。図16に示したように、特定国立研究開発法人をはじめとした国立研究開発法人において、我が国が強みを活かせるナノテク・材料、ライフサイエンス、防災分野で、膨大・高品質な研究データを利活用しやすい形で集積。産学官で共有・解析することで、新たな価値の創出につなげるデータプラットフォーム拠点を構築する。そして、この中でAIの手法等を用いたデータ解析システムを整備する計画である。

JSTでは、戦略的創造研究推進事業の関連する研究領域で編成した「AIPネットワークラボ」を平成28年から開始している。表9に示した研究領域で構成されており、研究領域間の連携の促進も行われている。

また、JST社会技術研究開発センター（RISTEX）では、公募型研究開発領域「人と情報のエコシステム」を平成28年から開始している。ビッグデータを活用したAI、ロボット、IoTなどの情報技術の急速な進歩がもたらしうる問題に適切に対処していくために、情報技術を人間を中心とした観点で捉え直

■表9 AIPネットワークラボの研究領域<sup>31</sup>

| 研究領域   | 事業                 | 研究目標   |
|--|--------------------|--|
| イノベーション創発に資する人工知能基盤技術の創出と統合化                             | CREST              | 人工知能基盤技術と、その成果を組み合わせることにより社会問題の解決と産業の自動化・最適化に貢献するイノベーション創発に資する技術の確立をめざす。   |
| 新しい社会システムデザインに向けた情報基盤技術の創出                               | さきがけ               | ・情報技術に基づいた社会変革の時代に対応し、これからの新しい社会システムのデザインを可能にするための情報基盤技術の創出をめざす。   |
| 情報と未来  | ACT-i              | 若手研究者の育成を支援する新規プログラム。情報学に関わる幅広い専門分野において、新しい発想に基づいた挑戦的な研究構想を求め、多種多様な研究開発を推進する。  |
| 人間と機械の創造的協働を実現する知的情報処理技術の開発                              | CREST              | 人間と機械の協働により新たな知を創出し、人・集団の知的活動の質向上を実現する知的情報処理システムをめざす。  |
| 科学的発見・社会的課題解決に向けた各分野のビッグデータ利活用推進のための次世代アプリケーション技術の創出・高度化 | CREST              | 様々な科学的発見および社会的・経済的な挑戦的課題の解決や革新的価値創造を、ビッグデータを高度統合利活用する革新的技術によって実証的に実現する。目的達成に必要な次世代アプリケーション技術を新たに実証的に創出・高度化し、適応分野の特性に応じた総合的かつ統合的なビッグデータ解析システム技術を確立することをめざす。 |
| ビッグデータ統合利活用のための次世代基盤技術の創出・体系化                            | CREST・さきがけ<br>複合領域 | ビッグデータの複数ドメインに共通する本質的課題を解決し、様々な分野のビッグデータの統合解析を可能にする次世代基盤技術の創出・高度化・体系化をめざす。   |
| 社会と調和した情報基盤技術の構築   | さきがけ               | より良い社会の実現を目的とする情報基盤の要素技術の研究と、それらの技術を対象とする社会と調和させるために必要な制度や運用体制、ビジネスモデルまでも含めた総合的な議論と実践を行う場を提供する。  |

■表10 「人と情報のエコシステム」の平成28年採択プロジェクト<sup>32</sup>

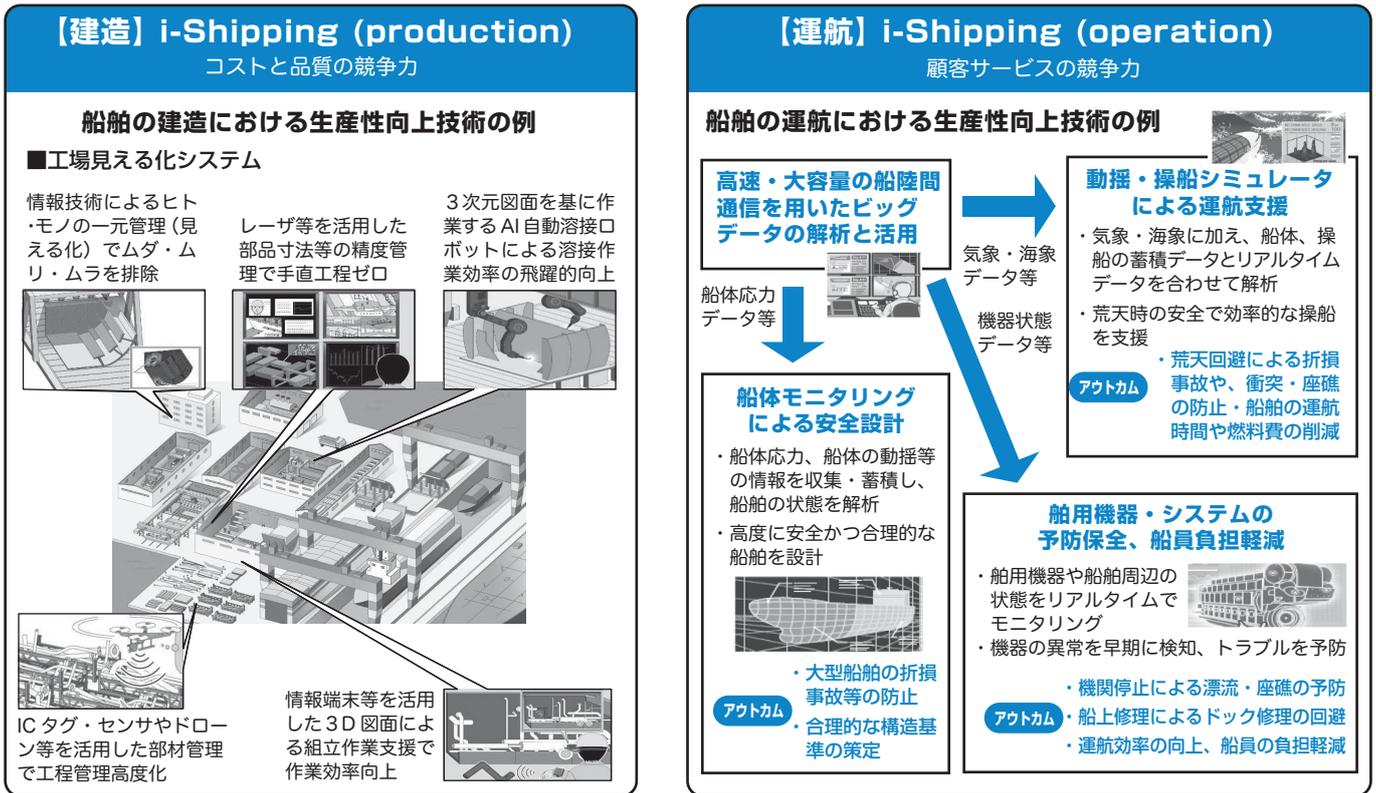
| 種別         | プロジェクト  |
|------------|---|
| 研究開発プロジェクト | 多様な価値への気づきを支援するシステムとその研究体制の構築   |
|            | 日本的Wellbeingを促進する情報技術のためのガイドラインの策定と普及                                 |
|            | 「内省と対話によって変容し続ける自己」に関するヘルスケアからの提案                                     |
|            | 未来洞察手法を用いた情報社会技術問題のシナリオ化  |
|            | 法・経済・経営とAI・ロボット技術の対話による将来の社会制度の共創                                     |
| プロジェクト企画調査 | 分子ロボット技術に対する法律・倫理・経済・教育からの接近法に関する調査                                   |
|            | 社会システムと情報システムの相互作用を促す共進型社会実験プロジェクト管理手法の検討～ITS(高速道路交通情報システム)の実用化を事例として |
|            | 多種ステークホルダーが関与した教育・育児支援ロボット技術の開発手法に関する調査                               |
|            | 高度情報社会における責任概念の策定   |
|            | リアルタイム・テクノロジーアセスメントのための議題共創プラットフォームの試作                                |

※32

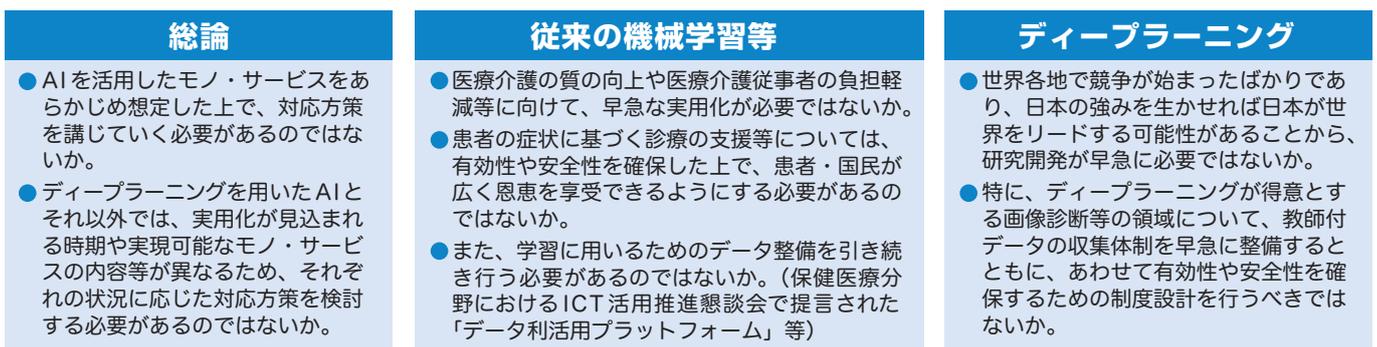
科学技術振興機構ウェブサイト <<http://ristex.jst.go.jp/hite/community/index.html>>より作成



IoT・ビッグデータ・AI等の情報技術等を活用した生産性向上に資する革新的技術やシステムの開発・実用化を支援／実証することにより、海事産業（造船及び海運）におけるコスト競争力の強化、品質の向上、サービスの革新を図る。



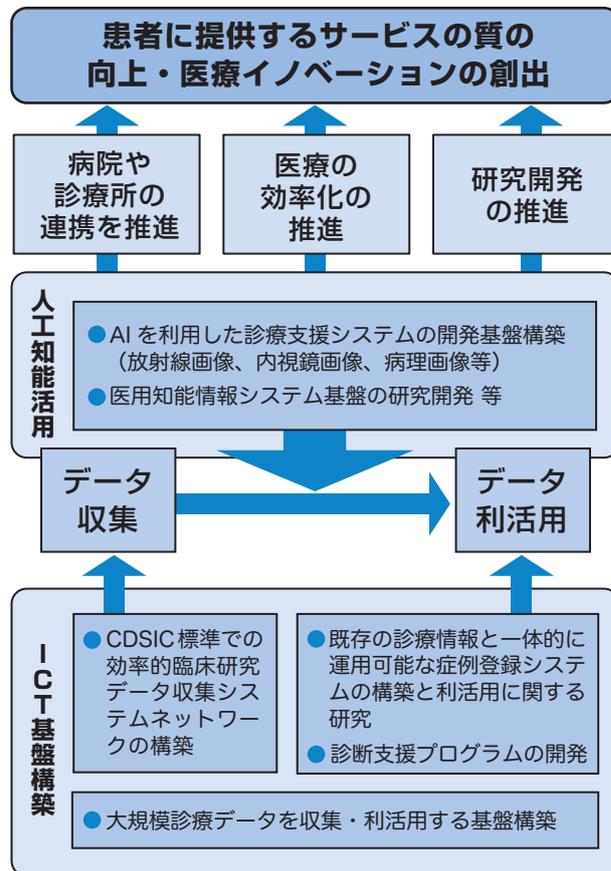
■図18 海事産業の生産性革命(i-Shipping)<sup>34</sup>



■図19 保健医療分野におけるAIの活用の論点(案)<sup>35</sup>

※35

「保健医療分野におけるAIの活用の論点(案)」厚生労働省ウェブサイト <<http://www.mhlw.go.jp/file/05-Shingikai-10601000-Daijinkanboukouseikagakuka-Kouseikagakuka/0000148674.pdf>>



■図20 臨床研究等ICT基盤構築・人工知能実装研究事業<sup>36</sup>

ることとなっている。また、造船業における生産性向上、船舶の運航における生産性向上におけるAIの活用を図18に示したように「海事産業の生産性革命」(i-Shipping)として推進することとなっている。

i-Shippingについては、平成28年度補正予算事業においては4件の事業が採択されており、AIに関連の深いものとしては「AI機能による溶接ロボット4台連携システム」が挙げられる。同事業では、船体構造の膨大な平板部材の組立接合において、3D設計情報を基に、複数台で連携して作業手順や配分を判断しながら自動溶接をするロボットにより、溶接の生産性及び生産量を向上させることを目的としている。

また、国土技術政策総合研究所では産業技術総合研究所と共同で、平成28年12月から平成30年3月末を目処として、従来の土砂災害検知センサが有する課題の解決を目指し、AI、IoT技術を導入した新しい土砂災害検知センサの開発を目的とした研究を開始している。この中で、AIを活用した土砂災害発生の判別精度の向上に関する研究を実施している。

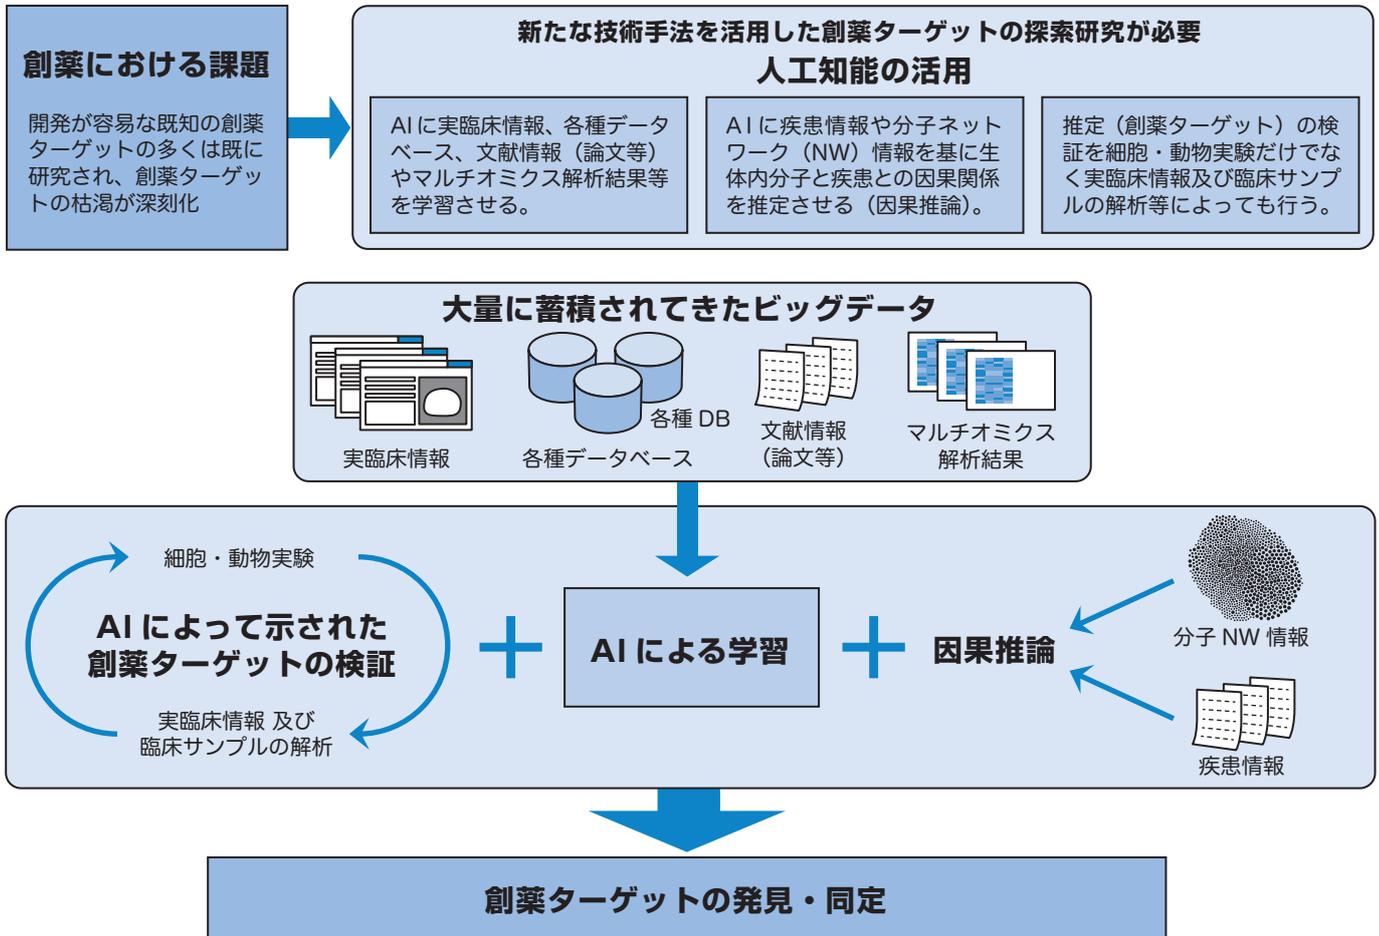
#### 4.2.2.6 厚生労働省

厚生労働省では、AIの特性を踏まえ、その活用が患者・国民にもたらす効果を明らかにするとともに、保健医療等においてAIの導入が見込まれる領域を見据えながら、開発推進のために必要な対応及びAIを用いたサービス等の質・安全性確保のために必要な対応等を検討することを趣旨として、平成29年1月から「保健医療分野におけるAI活用推進懇談会」を設置し議論を行っている。

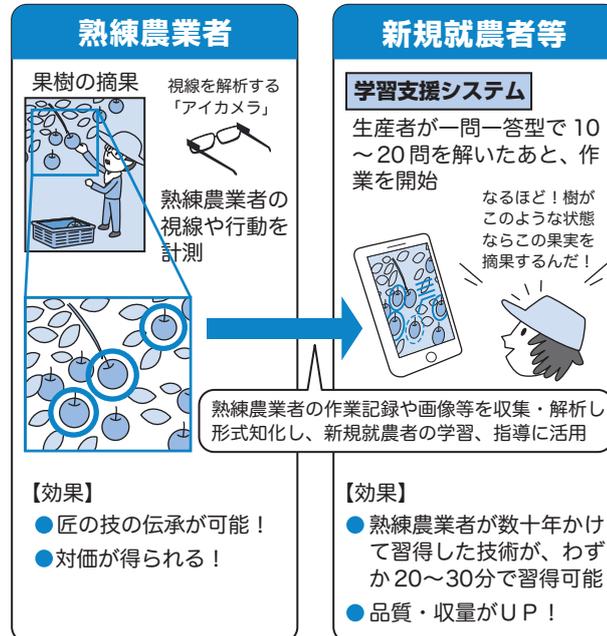
同懇談会における論点としては、図19に示したように、総論としては「AIを活用したモノ・サービスを想定した上での対応方策」、「深層学習とそれ以外を分けた対応方策」、従来の機械学習等については「早

※36  
「平成29年度予算案」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100860021.pdf>>

※37  
「人平成29年度予算案」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100860021.pdf>>より編集部作成



■図21 AIを活用した新たな創薬ターゲット探索<sup>37</sup>



■図22 AIを活用した熟練農業者の技能(匠の技)の伝承<sup>38</sup>

※38

「平成29年度予算案」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100860021.pdf>>より編集部作成

※39

「平成29年度予算案」新エネルギー・産業技術総合開発機構ウェブサイト <<http://www.nedo.go.jp/content/100860021.pdf>>より編集部作成

※40

「平成29年度委託プロジェクト研究 応募要領」農林水産省ウェブサイト <[http://www.affrc.maff.go.jp/docs/project/2017/attach/pdf/project\\_2017\\_1-5.pdf](http://www.affrc.maff.go.jp/docs/project/2017/attach/pdf/project_2017_1-5.pdf)>より作成

急な実用化の必要性」、「診療支援等における有効性・安全性を確保した上での患者・国民の恩恵享受」、「学習データ整備の継続的整備の必要性」、深層学習については「早急な研究開発の必要性」、「画像診断等における教師付きデータの収集体制の整備、有効性・安全性確保のための制度設計」が挙げられている。

AIに関連する予算事業としては、平成29年度予算事業「臨床研究等ICT基盤構築・人工知能実装研究事業」の一環として図20に示したようにAIを活用した診断支援システムの開発基盤（例：放射線画像、内視鏡画像、病理画像）等のAIによるデータ活用に関わる研究開発を実施することとなっている。

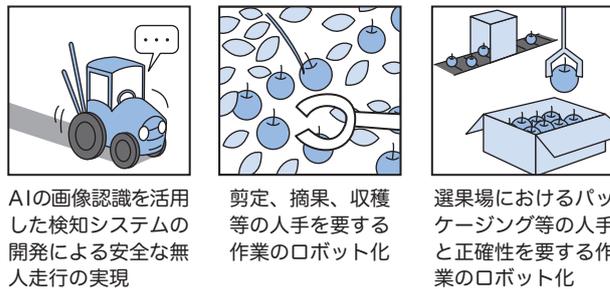
また、図21に示したように新たな創薬ターゲット探索手法として、AIの活用に関する研究を実施することとなっている。

#### 4.2.2.7 農林水産省

農林水産省では、図22に示したようにAIを活用して生産性の向上を図るため、熟練農業者の技能（匠の技）を形式知化するためのシステム構築を実施している。

また、図23に示したようなAIの画像認識を活用した農機の安全な無人走行の実現、剪定、摘果、収穫等の作業のロボット化、選果場におけるパッケージング等のロボット化を想定した研究開発を推進している。

さらに、平成29年度委託プロジェクト研究の中では、「人工知能未来農業創造プロジェクト」を設定し、表11に示したようにAIを活用した病害虫診断技術の開発、土壌病害診断技術の開発、栽培・労務管理の最適化技術の開発及び栽培・労務管理の最適化を加速するオープンプラットフォームの整備の4課題について公募を実施している。



AIの画像認識を活用した検知システムの開発による安全な無人走行の実現

剪定、摘果、収穫等の人手を要する作業のロボット化

選果場におけるパッケージング等の人手と正確性を要する作業のロボット化

■図23 農業の新たなイノベーション実現に向けたAIの活用例<sup>39</sup>

■表11 「人工知能未来農業創造プロジェクト」の公募研究課題<sup>40</sup>

| 公募研究課題                  |                                 | 内容   |
|-------------------------|---------------------------------|--|
| AIを活用した病害虫早期診断技術の開発     | AIを活用した病害虫診断技術の開発               | 新規就農者や普及指導員等が、農業現場で自らタブレット端末等を用いて病害虫を診断し、対策を講ずることを支援するための技術を開発する。<br>(小課題①)<br>農作物において問題となる病害虫やその被害を受けた作物等の画像情報等を蓄積してデータベースを構築する。<br>(小課題②)<br>それらをAIに学習させて病害虫を同定する技術を開発する。<br>(小課題③)<br>このような病害虫診断技術による安価なサービスを利用者に提供するため、使いやすく汎用性の高いアプリケーション等を含むシステムを開発する。 |
|                         | AIを活用した土壌病害診断技術の開発              | AIを活用し、土壌微生物の遺伝子情報等を用いて、発病リスクを栽培前に判断することを可能とし、輪作の導入、抵抗性品種の利用や土壌消毒剤の使用等の適切な対策を講ずることにより、土壌病害の発生を未然に防ぎ被害を最小化する技術を開発する。  |
| AIを活用した栽培・労務管理の最適化技術の開発 | AIを活用した栽培・労務管理の最適化技術の開発         | AIを活用し、施設園芸における主要品目において、作物の生育状態から栽培管理作業量を予測する技術等を利用して、生育制御、栽培管理作業の単純化、作業者の最適配置等により、労働時間の平準化を可能とする効率的な農場管理技術を開発する。  |
|                         | 栽培・労務管理の最適化を加速するオープンプラットフォームの整備 | 施設園芸におけるオープンイノベーションを支援し、AIを活用した栽培・労務管理の最適化技術の開発を加速化するため、オープンプラットフォームで利用することを前提に、AIの学習に利用できる栽培管理及び労務管理データセットを構築するとともに、栽培の最適化のほか、労働時間の平準化や短縮に資するAI技術を開発する。   |

## 4.3 海外の政策動向

### 4.3.1 米国

ホワイトハウスは2016年に、AIの社会実装に向けた課題の検討と対応する政策を、三つのレポートを通じて大きく打ち出している。その際にはPartnership on AI等の民間での取組も一定の貢献をしていると考えられる。

#### 4.3.1.1 イノベーション戦略

米国政府は2009年から3回にわたって、国家としてのイノベーション政策として「米国イノベーション戦略」(A Strategy for American Innovation)を打ち出している。2015年10月に発表された第3弾<sup>1</sup>では、国家的優先課題を前進させて経済的繁栄をもたらす戦略的なチャンスのある分野として以下の9分野が挙げられている。

- ①先進製造業 (Advanced Manufacturing)
- ②精密製薬 (Precision Medicine)
- ③BRAINイニシアティブ (BRAIN Initiative)
- ④先進自動車 (Advanced Vehicles)
- ⑤スマートシティ (Smart Cities)
- ⑥クリーンエネルギーとエネルギー効率化技術  
(Clean Energy and Energy Efficient Technologies)
- ⑦教育工学 (Educational Technology)
- ⑧宇宙 (Space)
- ⑨情報処理における新たなフロンティア (New Frontiers in Computing)

これらのうち、AIに関連が深い分野として、BRAINイニシアティブと先進自動車分野が挙げられる。BRAINイニシアティブは、神経学的疾患及び疾病の社会的及び経済的負担の軽減に向けて、脳機能の理解を目指したものであり、2016年度予算において3億ドルの供出が求められている。BRAINイニシアティブは脳科学の研究プロジェクトであるが、AIの経済的な便益にもつながることが想定されている<sup>2</sup>。

また、先進自動車分野の研究開発の推進については、ヒューマンエラーによる衝突の90%以上にマシンインテリジェンスの精密な意思決定を適用することにより、毎年何千もの命を救うことができるとしており、公道における自律運転、コネクテッド、自動運転車の機能向上と安全基準及び都市部、高速道路、商業地域における実証実験に向けた自動運転技術の研究への投資を2016年度予算で倍増させることが求められている。

#### 4.3.1.2 連邦予算によるAIの研究開発に関する戦略

米国政府は2016年10月に“THE NATIONAL ARTIFICIAL INTELLIGENCE RESEARCH AND DEVELOPMENT STRATEGIC PLAN”<sup>3</sup>を発表し、研究開発の必要性和、推進のために求められる環境整備等を示した。

※1  
“A STRATEGY FOR AMERICAN INNOVATION,” obamawhitehouse.archives.gov Website <[https://obamawhitehouse.archives.gov/sites/default/files/strategy\\_for\\_american\\_innovation\\_october\\_2015.pdf](https://obamawhitehouse.archives.gov/sites/default/files/strategy_for_american_innovation_october_2015.pdf)>

※2  
“INTERIM REPORT Brain Research through Advancing Innovative Neurotechnologies (BRAIN) Working Group,” National Institutes of Health Website <[https://braininitiative.nih.gov/pdf/09162013\\_interim\\_report\\_508C.pdf](https://braininitiative.nih.gov/pdf/09162013_interim_report_508C.pdf)>

■表12 “ THE NATIONAL ARTIFICIAL INTELLIGENCE RESEARCH AND DEVELOPMENT STRATEGIC PLAN” におけるAI研究開発の国家戦略<sup>4</sup>

| 戦略 |                                  | 概要   |
|----|----------------------------------|--|
| 1  | AI研究への長期的な投資を行う。                 | 発見と洞察を促進し、米国が世界の人工知能のリーダーであり続けることを可能とすべく、次世代のAIの投資を優先づける。  |
| 2  | 人間とAIとの協働の効果的な手法を開発する。           | 人間を置き換えるのではなく、AIシステムは最適なパフォーマンスを達成するために人と協働するものである。人間とAIシステムとの効果的なインタラクションを創造する研究が必要である。   |
| 3  | AIの倫理的、法的、社会的意味を理解し対応する。         | 我々はAI技術が我々が人として持つフォーマル及びインフォーマルの規範に基づいてふるまうことを期待する。AIの倫理的、法的、社会的意味を理解し、AIシステムが倫理的、法的、社会的目標に即するような設計手法を開発する研究が必要である。                  |
| 4  | AIシステムの安全性とセキュリティを確かなものとする。      | AIシステムが広くに利用される以前に、そのシステムが安全でセキュアで、コントロールされ、明確に定義され、十分に理解された形で運用される保証が必要である。この信頼でき、ディペンダブルで、信用できるAIシステムを開発するというチャレンジに対応した研究が今後必要である。 |
| 5  | AIの学習とテストのための共用公共データセットと環境を開発する。 | 学習データセットとリソースの深さ、質、正確さはAIのパフォーマンスに大きく影響する。研究者は、質の高いデータセットと環境を開発し、高い質のデータセットとテストと学習のリソースへのアクセスを可能とすることが必要とされている。                      |
| 6  | 標準とベンチマークを通じてAI技術を測定、評価する。       | AIの発展にとって不可欠なものは、AIの進歩を導き評価する標準、ベンチマーク、テストベッド、コミュニティの関与である。幅広い評価技術を開発する研究が今後必要である。   |
| 7  | 国家がAIの研究開発人材のニーズをより良く理解する。       | AIの発展のためは強力なAI研究者のコミュニティが必要である。本計画に示された戦略的研究開発分野に対応することができる十分なAI専門家が確保できるように、AIの現在および将来の研究開発人材需要のより深い理解が必要である。                       |

具体的には、①AI研究への長期的投資の重要性、②人間とAIの協働に向けた効果的な方法の開発、③AIの倫理的、法的及び社会的含意の理解、④AIの安全性及びセキュリティの確保、⑤共用公共データセット及びAIの学習の環境開発、⑥AIの進展を方向付けて評価するための標準、ベンチマーク、テストベッド及びコミュニティの関与、⑦国家のAI研究開発人材のニーズの理解を挙げている（表12）。

#### 4.3.1.3 社会実装に向けた課題等の網羅的な整理・施策の体系

同じく2016年10月に、米国政府は“PREPARING FOR THE FUTURE OF ARTIFICIAL INTELLIGENCE”<sup>5</sup>を発表し、AIの社会実装に向けた課題を網羅的に整理した。

具体的には、公共財に対するAI利用、AIと規制、研究と人材、AIの経済的影響、公平性・安全性・ガバナンス、グローバルな考慮事項及び防衛、未来のための準備について網羅的に書かれている。

また、それに対応した以下のような23の提言を行っている（表13）。

#### 4.3.1.4 AIの社会実装による経済的なインパクトへの対応

そして、米国政府は2016年12月に“ARTIFICIAL INTELLIGENCE, AUTOMATION, AND THE ECONOMY”<sup>7</sup>を発表し、AIの社会実装に伴う雇用への影響とそれを含めた経済的なインパクトへの対応を整理した。

※3  
“THE NATIONAL ARTIFICIAL INTELLIGENCE RESEARCH AND DEVELOPMENT STRATEGIC PLAN,” obamawhitehouse.archives.gov Website <[https://obamawhitehouse.archives.gov/sites/default/files/whitehouse\\_files/microsites/ostp/NSTC/national\\_ai\\_rd\\_strategic\\_plan.pdf](https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/national_ai_rd_strategic_plan.pdf)>

※4  
“THE NATIONAL ARTIFICIAL INTELLIGENCE RESEARCH AND DEVELOPMENT STRATEGIC PLAN,” obamawhitehouse.archives.gov Website <[https://obamawhitehouse.archives.gov/sites/default/files/whitehouse\\_files/microsites/ostp/NSTC/national\\_ai\\_rd\\_strategic\\_plan.pdf](https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/national_ai_rd_strategic_plan.pdf)>より作成

※5  
“PREPARING FOR THE FUTURE OF ARTIFICIAL INTELLIGENCE,” obamawhitehouse.archives.gov Website <[https://obamawhitehouse.archives.gov/sites/default/files/whitehouse\\_files/microsites/ostp/NSTC/preparing\\_for\\_the\\_future\\_of\\_ai.pdf](https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/preparing_for_the_future_of_ai.pdf)>

表13 “PREPARING FOR THE FUTURE OF ARTIFICIAL INTELLIGENCE” における提言<sup>6</sup>

| 対象   | 提言内容  |
|--|---|
| 1 民間及び公的機関   | 社会に便益をもたらすようにAI及び機械学習を責任を持って活用できるかの検討を奨励。   |
| 2 連邦政府機関   | 学習データの公開及びデータ標準の公開を優先づけるよう求める。  |
| 3 連邦政府   | 重要機関におけるAIの業務適用に向けた能力向上策を調査するよう求める。   |
| 4 国家科学技術会議機械学習・人工知能小委員会(NSTC MLAI)                               | AI実務家のための実践コミュニティの政府横断での展開を求める。   |
| 5 政府機関   | AI対応製品に対する規制政策策定時に、上級レベルの適切な技術的専門知識の活用を求める。   |
| 6 政府機関   | 技術の現状に関するより多様な視点をもって連邦の政府職員を育成するため、人員の最大限の割り当て等を求める。  |
| 7 運輸省(DOT)   | 安全、研究その他の目的でデータ共有を増進して、産業界及び研究者との協働を求める。  |
| 8 米国政府   | 自動操縦機と操縦士付きの航空機に同様に適応可能な、先進的かつ自動的な航空交通管制システムの開発・実装への投資を求める。   |
| 9 運輸省(DOT)   | 完全自動運転車(新たな設計の自動車を含む)とドローンの交通システムへの安全な統合を可能とする、発展的な規制枠組みの継続検討を求める。                                      |
| 10 国家科学技術会議機械学習・人工知能小委員会(NSTC MLAI)                              | AIの開発動向をモニタリングし、AIの状況、特にマイルストーンについて、上級政府指導者への定期的な報告を求める。  |
| 11 政府  | 諸外国におけるAIの状況、特にマイルストーンについてモニタリングすることを求める。   |
| 12 産業界   | 産業界におけるAIの一般的発展状況について直近に到達しそうなマイルストーンを含め、政府が最新情報を持てるよう協働を求める。   |
| 13 連邦政府  | 基礎的かつ長期間のAI研究に優先順位を置くことを求める。  |
| 14 国家科学技術会議機械学習・人工知能小委員会(NSTC MLAI) ネットワーキング・情報技術研究開発(NITRD)小委員会 | AIの研究者、専門家、ユーザの量、質、業務の多様性の増大に向けた人材供給制度の検討着手を求める。  |
| 15 大統領府  | 米国労働市場におけるAIと自動化の影響をさらに調査するため、2016年末までに後継の報告書を発行し、推進すべき政策対応のアウトラインの提示を求める。                              |
| 16 個人に関わる重要な決定又はサポートを提供するAI活用システムを利用する連邦政府機関                     | エビデンスに基づく検証及び妥当性確認によって、システムの有効性・公正性を確保するため特段の注意を求める。  |
| 17 個人に関わる重要な決定を行うAI活用システムの利用支援として州及び地方政府に資金を交付する連邦政府機関           | 連邦補助金で購入されるAI活用製品やサービスが、十分に透明性の高い成果を挙げているものであり、有効正及び公平性に係るエビデンスにより裏付けられるものであることを確保するため、補助金の条件のレビューを求める。 |
| 18 学校及び大学  | AI、機械学習、コンピュータサイエンス、データサイエンスに関するカリキュラムの必須のものとして、倫理、セキュリティ、プライバシー及び安全性に関するトピックを含めることを求める。                |
| 19 AI専門家、セキュリティ専門家及びそれらの専門家ソサエティ                                 | AI安全工学の分野の成熟に向けた進展を継続するため、協働することを求める。   |
| 20 米国政府  | AIに関する国際的な関与についての政府全体の戦略策定、国際的な関与及びモニタリングが必要なAI関連分野のリスト作成を求める。  |
| 21 米国政府  | 情報交換及びAI研究開発協力を容易にするため、外国政府、国際機関、産業界、学界その他の重要な国際的ステークホルダーとの関与の深化を求める。                                   |
| 22 政府機関の計画及び戦略   | サイバーセキュリティに関するAIの影響及びAIに関するサイバーセキュリティの影響についての十分な説明を求める。   |
| 23 米国政府  | 国際人道法と一致する、自律型・半自律型兵器に関する政府全体の統一的政策策定の完遂を求める。   |

具体的には、AIが促進する自動化によって、10年間で9%から47%の仕事が脅かされるとの推計を紹介している。このように仕事が収縮する一方で、AIにより生まれる仕事もあり、一概には失業につながらない可能性についても言及している。また、この収縮は低賃金、低スキル、低教育の労働者に特に影響することにも言及している。

このようなインパクトに対して、①多くの便益を創出するAIへの投資・開発、②将来の仕事に向けた教育訓練の充実、③幅広い就労者が成長の果実を得られるための仕事の移行やエンパワメントの支援が挙げられている。

※6  
 “PREPARING FOR THE FUTURE OF ARTIFICIAL INTELLIGENCE,” obamawhitehouse.archives.gov Website <[https://obamawhitehouse.archives.gov/sites/default/files/whitehouse\\_files/microsites/ostp/NSTC/preparing\\_for\\_the\\_future\\_of\\_ai.pdf](https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/preparing_for_the_future_of_ai.pdf)>より作成

※7  
 “ARTIFICIAL INTELLIGENCE, AUTOMATION, AND THE ECONOMY,” Whitehouse Website <<https://www.whitehouse.gov/sites/whitehouse.gov/files/images/EMBARGOED%20AI%20Economy%20Report.pdf>>

#### 4.3.2.1 Horizon 2020

「Horizon 2020」は、EUが7年程度の間隔で継続的に策定・実施している研究開発プログラムの一つである。「卓越した科学」、「産業技術におけるリーダーシップ」、「社会的な課題への取組」の三つの柱に属するプログラム群から構成されており、2014年～2020年までで約800億ユーロの公的資金が提供される予定である。プログラムの中では研究開発の基本的な方向の検討と、研究開発プロジェクトの公募・推進を実施している。

AIに関わる研究開発は、多様な公募枠の中でAIのプラットフォームの研究開発から応用分野における研究開発まで、様々なプロジェクトが実施されている（表14）。

上記のほかにも、フロンティア領域の研究と位置づけられている“Future & Emerging Technologies (FET)”のなかでもロボティクス等、AIに関連した研究開発が行われているなど、AI関係の研究開発は幅広く実施されている。

#### 4.3.2.2 Robo Law

Horizon 2020の前に実施された研究開発プログラムであるFP7の中で、研究開発プロジェクトとして“Robo Law Regulating Emerging Robotic Technologies in Europe: Robotics facing Law and Ethics”が実施された。この中ではロボット技術の法的な位置づけや倫理的課題、ガイドラインに関する検討等がされた。

検討結果としては、①欧州がロボット技術の世界標準の確立において主導することの重要性、②ロボットのように発展している技術分野は国による法的規制よりも開発活動の実態に合わせて柔軟に内容を調整する「ソフト・ロー方式」が望ましいこと、③ヘルスケア等で個人情報保護、人権尊重への対策の必要性、④ロボットは人間生活に深く関わるため法的規制は倫理的な見地に基づくべきとことが結論づけられている。

#### 4.3.2.3 ロボティクスにかかる民法規則に関する欧州委員会への提言

欧州法務委員会では、2015年1月にロボティクスとAIの進展にかかる法的な問題に関するワーキンググループが設置された。同ワーキンググループから2016年5月「ロボティクスにかかる民法規則に関する欧州委員会への提言に関する報告書案」が公表され、2017年1月に最終報告書<sup>9</sup>が欧州議会で採択された。同報告書は、ロボットやAIについての広範な内容を含んでおり、AIの倫理的課題や法的な位置づけについての提言も行っている。これを受けて、欧州ではロボットやAIに関する法整備を進める機運が高まっている。欧州議会での議論が引き続き行われるとともに、市民や利害関係者からの意見を収集するパブリックコンサルテーションが2017年4月末まで実施される見通しである。

※8  
EUの研究開発プロジェクトウェブサイトにおいてArtificial Intelligenceで検索して抽出した2016年開始のHorizon2020のプロジェクト（概要説明でAIの明記のないものは除く）。European Commission Website <<http://cordis.europa.eu/project>>

※9  
“REPORT with recommendations to the Commission on Civil Law Rules on Robotics,” European Parliament Website <<http://www.europarl.europa.eu/sides/getDoc.do?pubRef=-//EP//NONSGML+REPORT+A8-2017-0005+0+DOC+PDF+V0//EN>>

■表14 Horizon 2020におけるAI関連の研究開発プロジェクトの例<sup>8</sup>

| プロジェクト名   | 概要  |
|---|---|
| CoolFarm – The intelligent and flexible system that provides to plants what they need, when they need it!   | B2B向けの温室のAIによる管理システム。作物が健康でかつ効率的に育つように精緻に環境管理を行う。   |
| LINGOKIDS: Adaptive mobile platform for language learning for early age children  | AI、ビッグデータ、ゲームによる学習方法論に基づく幼児の早期言語学習のプラットフォームを開発する。   |
| StoreHero: An AI (Artificial Intelligence) Virtual Business Coach for Physical Retailers  | AIをベースとした小売事業者のための「ビジネスコーチ」を開発する。テキストデータやセンサーデータなど様々なデータを活用する機械学習ソフトウェアとIoTプラットフォームを開発する。例えば、店外のイベントをモニタリングして最適な開店時間をアドバイスする機能などが想定される。                             |
| Icarus:Bringing Personalized Knowledge to Students in Public Schools Through Artificial Intelligence inELearning  | 既存の無料オープンソースのeLearningプラットフォームに向けたAIのプラグインを開発する。これにより、利用する生徒毎になじんだ学習経路を提供したり、各教師にパーソナライズされたチューターを実現する。  |
| MIREL - MIning and REasoning with Legal texts   | 法律文書を公式な表現に翻訳するためのマイニング及び推論プラットフォームを開発する。規範への疑問点の確認、コンプライアンスのチェック、意思決定に利用できることを目指す。   |
| iBILD: Imaging Biomarker for Intelligent Lung Cancer Detection  | 大量のCT画像データベースに機械学習を適用することにより、人間の眼では検知できないような肺ガンの診断を可能にする。   |
| Bonseyes:Platform for Open Development of Systems of Artificial Intelligence  | 低消費電力IoTデバイス(エッジコンピューティング)、組込システムあるいはデータセンターサーバー(クラウドコンピューティング)におけるAI適用に向けた、データマーケットプレイス、深層学習のToolbox、開発者向けの参照プラットフォームを含む、プラットフォームを開発することを目標としている。                  |
| PrECISE:PERSONALIZED ENGINE FOR CANCER INTEGRATIVE STUDY AND EVALUATION   | IBMのWatsonの技術を用いて、前立腺がんをターゲットに分子レベルのデータや臨床データの活用による治療法の最適化を図る。バイオマーカーパネルに基づいて、個々の患者のための疾患メカニズムを同定し、治療へのリコメンデーションを生成するための技術を開発する。                                    |
| TADIL and DITEL   | TADILは、線形のインフラ(道路、鉄道等)の自動設計のためのAIソフトウェア。DITELはトンネルや橋梁等の3D設計に適用するAIソフトウェア。   |
| HEMACON:ENTERPRISE RESOURCE PLANNING (ERP) SOLUTION INTERCONNECTING DEPARTMENTS' SOFTWARE IN HEALTHCARE FACILITIES  | 医療施設に特化したMicrosoft Dynamics NAV platformをベースとしたERP。AI(自動学習とパターン認識)をフィーチャーしており、柔軟なワークフローエンジンとRFIDアプリケーションを統合している。  |
| PRIZM2016:Platform for Open Development of Systems of Artificial Intelligence   | 歌を自動演奏するコンテキストウェアな学習デバイス。デバイスのAIが部屋にいる人や音楽のテイスト、その時の雰囲気に合わせて音楽を適用する。  |
| ENCASE:Enhancing seCurity And privacy in the Social wEb: a user centered approach for the protection of minors  | オンラインソーシャルネットワークの悪意のある主体から未成年者を保護するためのブラウザベースのアーキテクチャの設計・実装を行う。サイバー攻撃等からの保護、プライバシー流出への警告、コンテンツ保護等の機能を有する。学術パートナーが機械学習、ビッグデータ処理、データマイニングアルゴリズム設計のノウハウを提供する。          |
| GoSAFE RAIL:- Global Safety Management Framework for RAIL Operations  | 鉄道セクターにおける資産の安全性を革新的に向上させる。AIを用いたモデルで資産の劣化を予測する。  |
| Xepholution:Artificial General Intelligence software enabling workforce relief for optimised results and increased efficiency   | いわゆる「狭い」AI(または、弱いAI)ではなく、汎用AIに基づく先端的な技術開発を行うもの。人間に特有の創造性の発達や知的なタスクを可能にする。   |
| Bonseyes:Platform for Open Development of Systems of Artificial Intelligence  | 従来の空気フィルターでは不可能だった室内空気清浄を可能にする植物を使った「緑の壁」。クラウドサーバーに接続してAIが遠隔でコントロールすることで気温や季節の変化に適合できる。   |
| ENLIVEN:Encouraging Lifelong Learning for an Inclusive and Vibrant Europe   | 成人教育市場における政策介入がどのようにしてより効果的になるかをモデル化している。最先端の方法論と理論(例えば、AIにおける事例ベースの推論手法)を統合し、革新的な知的意思決定支援システムを実装し、評価し、政策議論のための新たな科学的基盤を提供する。                                       |
| TOUCHVIE: Catch what you watch; a game-changer technology that will change how people watch TV and revolutionise in-movie advertising and product placement                                       | スクリーン上のいかなるものもコンピュータビジョンとAIで認識し、ユーザのセカンドスクリーンに表示し、ユーザがそれを見るという世界初のプラットフォーム。ユーザはそれを詳細に見たり、シェアしたり、購入することができる。   |
| MORPHCAST:Real time video creation according to your emotions   | AIを使った顔画像認証により、最大限にパーソナライズされた広告を配信することを目指す。性別、年齢、感情に応じて瞬時に変化する軽くて低帯域の消費者向けテラーメイドビデオの作成を可能にする。   |
| Incomaker:intelligent marketing management automation for SME   | AIを活用した中小企業向けのマーケティングマネジメント活動の示唆、計画と実行のためのマーケティング自動化ツール。  |
| WORKSHOP4.0:Automated real-time production forecasting for industry   | 工場での材料溶融等を含む生産工程の稼働条件の最適化をリアルタイムに予測するビッグデータとAIを活用したツール。   |
| AGERISK:Neurocomputational mechanisms underlying age-related performance changes in goal-directed decisions from experience   | 加齢による意思決定能力の変化についてAIにより最適なモデリングを行う。実験室と家庭の両方での環境認知実験によりデータを取得する。  |
| iTRACK:Integrated system for real-time TRACKing and collective intelligence in civilian humanitarian missions   | 中東などの人道主義活動者等の安全を確保するための統合的な情報管理、ロジスティクスサービスをリアルタイムに更新するナビゲーション、ルーティング、スケジューリングのシステム。センサー開発、GIS、セキュリティ・プライバシー技術、AI、情報マネジメント、ロジスティクスの今日の発展の下で学際的で社会的技術的なアプローチで実現を図る。 |
| Fox-IT:Fitting-to-Outcome eXpert for semi-automated cochlear implant fine-tuning  | AIによる強力な手法を活用して人工内耳をユーザに精細に合わせた形で準自動で作成する。  |
| Nutrigen Service:MANAGING HEALTH THROUGH DIETARY NEEDS, VIRTUAL CONSULTATIONS, AND GENETICS   | AIを活用してユーザのライフスタイルに合わせたダイエットや栄養学的なプランを無料で提供するシステム。  |
| DTD SYSTEM:A disruptive innovation for the minimisation of railway maintenance costs  | 鉄道車両の車輪の劣化の発生時に欠陥を検出し、メンテナンス計画を設計できるシステム。AIのアルゴリズムを活用することで最適化を図っている。  |
| SecTrap:Critical urban infrastructure and soft target cyber attack protection. Users and application Behavioural Analysis supported by artificial intelligence to preempt security cyber attacks. | 守るべき資産を悪意のあるソフトウェアにアクセスさせず、先端AIを活用して異常な振る舞いを検出、ブロックしレポートする。都市のインフラを第一の対象と考えている。   |
| WhoLoDance:Whole-Body Interaction Learning for Dance Education  | 身体認識の学習理論とダンス教育の研究と革新を目的として、神経科学、教育・学習理論、教育心理とAI及びナレッジマネジメントの新技術を合わせて構築する。  |
| PeptiEUForce:a game-changing ingredient for the pre-diabetic population   | 糖尿病の解決に向けて。AIとDNA分析を使って自然食品中に新しい疾病を起こす分子を発見する。  |
| TrafficWise:Transforming Cellular Network Data Into the Next Generation of Mobility Management Platform   | セルラーネットワークの位置データの処理にAIのアルゴリズムを適用し、交通マネジメントの最適化を図る。  |
| GPBOX:Energy Platform   | AIを活用してコスト削減をしたエネルギー貯蔵システム(ESS:Energy Storage System)。  |
| BLINDFAST:INNOVATIVE BLIND FASTENER MONITORING TECHNOLOGY FOR QUALITY CONTROL   | ブラインドファスナー成形の品質管理を検知信号のデータマイニングとAI技術を活用して分析する。  |
| InDeal:Innovative Technology for District Heating and Cooling   | AIメーターによるリアルタイムエネルギー消費データ収集等によりインテリジェントで効率的な地域冷暖房システムを実現する。   |

### 4.3.3 英国

#### 4.3.3.1 ロボティクスと自律システム

英国ではロボティクスと自律システム（RAS：Robotics and Autonomous Systems）を8大優先的成長分野の一つとして位置づけている。2014年には専門家グループが「RAS 2020戦略（RAS 2020 Strategy）」<sup>10</sup>を発表しており、その中で、AIを含むソフトウェア開発人材の育成を目指すこととしている。2015年には政府がその支援を表明し、予算措置等の施策を推進している。

#### 4.3.3.2 ロボット・AIに関する社会的・倫理的・法的問題のレポート

下院科学技術委員会は2016年9月に、ロボット・AIに関する社会的・倫理的・法的問題を検討したレポート<sup>11</sup>を発表した。表15に主な内容を示す。

経済・社会的影響のうち、雇用への影響は、「仕事を奪い失業率が上昇する」と「雇用形態の変化が可能になる」という相反した意見がみられるが、教育・訓練のシステムが柔軟であり、変化に対する要求に応じて適応し、労働者の生涯学習に対応できることが重要だが、英国には欠けているとの指摘がされている。

ロボティクス・AIの安全性・制御に関しては、現時点で全体の規制を設定するのは時期尚早であるが、AIシステムの倫理的・法的・社会的側面を注視し、深く精査することから始める必要がある。同報告書

■表15 ロボット・AIに関する社会的・倫理的・法的問題のレポートの主な内容<sup>12</sup>

| セクション           | 主な内容  |
|-----------------|---|
| 経済・社会的影響        | 機械が人間の仕事を奪い、労働の必要性を排除するという懸念について、ロボティクス及びAIが生産性にどのように影響し、雇用構造を形成・変革するかについて、異なる見解を示している(例：ロボティクス及びAIによる生産性の向上については、一部の有識者は失業率の上昇を予測する一方、ロボティクス及びAIの普及が進むことで雇用形態の変化が可能になるとの見方もあるなど相反する意見が見られる等) |
|                 | ロボティクスとAIは、英国の国民の生活を根本的に変える可能性を秘めており、第4次産業革命がどのように進むのかも正確には予想できない。求められる働き方やスキルの変化についても予見できないが、ただし、教育と訓練のシステムが柔軟であり、変化に対する要求に応じて適応し、労働者の生涯的な学習に対応できることが重要であり、この分野のリーダーシップが英国国家には欠けている。         |
|                 | 政府は、将来の労働の変革に向けたデジタルスキルに関する計画・戦略を立てていく必要がある。  |
| 倫理的・法的問題        | ロボティクス及びAIのプログラミングおよび利用に起因する倫理的・法的問題について検討・考察。  |
|                 | 本セクションでは、ロボティクス及びAIの安全性と制御について取りまとめており、ロボティクスやAIの成果が有益であるだけでなく、透明性をどのように評価できるかを検討。  |
|                 | 加えて、標準・規制等、今後必要なガバナンスの枠組みについて言及。  |
| 研究・資金調達・イノベーション | 現時点で全体の規制を設定するのは時期尚早であるが、AIシステムの倫理的・法的・社会的側面を注視し、深く精査することから始める必要がある。  |
|                 | ロボティクス及びAIの研究・資金調達・イノベーションの実態を検証し、当該分野の発展を妨げる課題を検証。   |
|                 | 同報告書では、RAS(Robotics and Autonomous Systems)を英国における優先的成長分野として特定しているにもかかわらず、政府のリーダーシップが著しく欠如している点を指摘(例えば、当初発表された政府における施策を調整し、方向性を検討するRASリーダーシップ・カウンシルの設立も行われていない)。                              |
|                 | 英国政府は、RASリーダーシップ・カウンシルを設立し、学界・産業界等からの意見を招請し、官民一体となってRAS戦略を策定遂行すべきとしている。   |

※10  
“RAS 2020 Robotics and Autonomous Systems,” Innovate UK Website <<https://connect.innovateuk.org/documents/2903012/16074728/RAS%20UK%20Strategy>>

※11  
“Robotics and artificial intelligence Fifth Report of Session 2016-17,” Parliament Website <<https://www.publications.parliament.uk/pa/cm201617/cmselect/cmsctech/145/145.pdf>>

※12  
“Robotics and artificial intelligence Fifth Report of Session 2016-17,” Parliament Website <<https://www.publications.parliament.uk/pa/cm201617/cmselect/cmsctech/145/145.pdf>>より作成

では、意思決定の透明性、偏見の最小化、説明責任の増加、プライバシーと安全性の重視などを問題として提起している。

#### 4.3.4 ドイツ

##### 4.3.4.1 連邦政府のデジタル関連政策

ドイツ連邦政府は2014年に、「デジタルアジェンダ2014-2017」<sup>13</sup>を策定している。この中では重点項目として①デジタルインフラ（ブロードバンド網の整備）、②デジタル経済と雇用の場、③革新的な行政、④社会におけるデジタル環境の形成、⑤教育、科学、研究、文化とメディア、⑥社会経済におけるセキュリティ、防御と信頼の形成、⑦欧州及び国際的な規模でのデジタル・アジェンダの七つが設定されている。このうち、「デジタル経済と雇用の場」では、産業構造改革に向けて推進する研究開発の例として自律技術（autonomic technology）、3D、ビッグデータ、クラウドコンピューティング、マイクロエレクトロニクスが挙げられている。

これを受けて、経済・エネルギー省では「デジタル戦略2025」<sup>14</sup>を策定している。この中の「研究、開発及び技術革新」においては革新的技術開発の支援プログラムが施策としてあり、特に注力すべき対象技術の例示として「Industry 4.0自律システム」（Autonomous Systems）、「生産技術」（ロジスティクス、サービスロボット、産業用3Dアプリケーション、産業向けコミュニケーション）、「スマートデータとビッグデータ」、「IoT」が挙げられている。

##### 4.3.4.2 Industry 4.0推進の中でのAIの位置づけ

ドイツでは国家戦略である「Industry 4.0」推進の中で、AIが重要な要素技術の一つとして位置づけられている。

Industry 4.0の実現イメージは、マスカスタマイゼーションに対応可能で省エネ性能にも優れている、柔軟な生産システムを有した「スマートファクトリー」である。その実現には、動的なコントロールを可能にするAI技術も貢献している。

Industry 4.0推進のキーマンの1人はドイツ人工知能研究センター（DFKI）のウォルフガング・ヴァルスター（Wolfgang Wahlster）CEOであり、初期の実証実験は同センター内で実施された。

##### 4.3.4.3 DFKIによるAIの研究開発及び社会実装の推進

DFKIは1988年に、州、連邦政府、民間企業が出資し設立された研究開発機関であり、官民のバランスの取れた運営を行っている。データサイエンス、マルチメディア技術、自然言語処理、IoT、デバイス、ロボティクスから工場システム、教育工学、小売への応用まで幅広い範囲の分野別の研究を行う18のResearch Departmentと革新的技術のテスト、評価、デモを行う六つのLiving Lab、技術とノウハウ、スキルのバンドルを行う九つのCompetence Centerを擁しており、ドイツにおけるAIの研究開発の中心を担っている（表16）。

※13  
“Digital Agenda 2014 - 2017,” FEDERAL GOVERNMENT Website <[https://www.digitale-agenda.de/Content/DE/\\_Anlagen/2014/08/2014-08-20-digitale-agenda-engl.pdf?\\_\\_blob=publicationFile&v=6](https://www.digitale-agenda.de/Content/DE/_Anlagen/2014/08/2014-08-20-digitale-agenda-engl.pdf?__blob=publicationFile&v=6)>

※14  
“Digital Strategy 2025,” the Federal Ministry for Economic Affairs and Energy Website <<http://www.de.digital/DIGITAL/Navigation/EN/Strategy/strategy.html>>

■表16 DFKIの研究組織<sup>15</sup>

| 種別  | 組織  |
|---|---|
| Research Department<br>研究                 | Smart Data & Knowledge Services                   |
|   | Cyber-Physical Systems                            |
|   | Multilingual Technologies                         |
|   | Plan-Based Robot Control                          |
|   | Educational Technology Lab                        |
|   | Interactive Textiles                              |
|   | Robotics Innovation Center                        |
|   | Innovative Retail Laboratory                      |
|   | Institute for Information Systems                 |
|   | Embedded Intelligence                             |
|   | Smart Service Engineering                         |
|   | Intelligent Analytics for Massive Data            |
|   | Intelligent Networks                              |
|   | Agents and Simulated Reality                      |
|   | Augmented Vision                                  |
|   | Language Technology                               |
| Intelligent User Interfaces               |   |
| Innovative Factory Systems                |   |
| Living Lab<br>革新的技術のテスト、<br>評価、デモ         | Advanced Driver Assistance Systems Living Lab     |
|   | Bremen Ambient Assisted Living Laboratory - BAALL |
|   | Innovative Retail Laboratory - IRL                |
|   | Robotics Exploration Laboratory                   |
|   | SmartCity Living Lab                              |
|   | SmartFactory Laboratory                           |
| Competence Center<br>ノウハウ、スキルと<br>技術のバンドル | Ambient Assisted Living                           |
|   | Case-Based Reasoning                              |
|   | Deep Learning                                     |
|   | Emergency Response and Recovery Management        |
|   | Multimedia Analysis & Data Mining                 |
|   | Safe and Secure Systems                           |
|   | Semantic Web                                      |
|   | Smart Agriculture Technologies                    |
|   | Wearable AI                                       |

DFKIは、公的資金を活用した外部機関との連携による研究開発に積極的に取り組んでおり、ドイツ連邦政府の研究開発プログラムやEUの研究開発プログラムのAI関連のプロジェクトに参画し、多くのプロジェクトで中心的な役割を果たしている（表17）。

DFKIには、SAP（ドイツ）、Volkswagen（ドイツ）、BMW（ドイツ）、Robert Bosch（ドイツ）、Airbus（フランス）といった欧州の有力企業だけでなく、Microsoft、Google、Intelといった米国のIT企業も出資している。産業界との連携にも積極的に取り組んでおり、出資企業等との共同研究や78社のスピンオフ企業の輩出という形で、AIの社会実装の推進に大きな役割を果たしている。

DFKIは産業技術総合研究所と長期にわたるパートナーシップを確立することを想定し、密接な連携を行うための枠組みを築くことに合意する研究協力覚書（MOU）を、2017年3月に締結している。また、DFKIにはリコーが出資を行い、日立製作所がAI分野での共同開発を行っており、我が国との連携も積極的に推進している。

※15

DFKI Website <<https://www.dfki.de/web>>より作成

■表17 DFKIの参画しているAI関連外部連携研究開発プロジェクトの例<sup>16</sup>

| プロジェクト名                          | 概要  |
|----------------------------------|---|
| Smart Data Web                   | 企業がニュースサイト、ソーシャルメディア、公的機関の発表情報等のビッグデータから、サプライチェーンに影響を与える事象を迅速に特定し、生産計画や意思決定プロセスに組み込む仕組みを自然言語処理や機械学習を活用して実現する。Industry4.0関連の研究開発と位置づけられている。DFKIはコンソーシアムのリーダーを務める。経済エネルギー省の研究開発プログラム「Smart Data」の一環。  |
| KDI - Clinical Data Intelligence | 電子カルテ、ゲノムデータ、CTやMRIのスキャンデータ、テキストデータ音声データ、グラフィックデータやスマートフォン、スマートウォッチで取得できるデータ等の様々な患者データ関連づけてホリスティックな診断を可能にすることを目的とした研究開発プロジェクト。医療データのうちでも高次元でスパースなデータに特に有用な機械学習のアプローチを開発している。DFKIはコンソーシアムのメンバー。経済エネルギー省の研究開発プログラム「Smart Data」の一環。                                    |
| SD4M - Smart Data for Mobility   | 交通事業者の情報とソーシャルメディアのデータを統合的に扱い、幅広いユーザや交通事業者に提供するプラットフォームの構築を目的としたプロジェクト。通名などの曖昧性を独自のアルゴリズムで処理する自然言語処理の研究開発等、様々な要素技術の開発により実現している。DFKIはコンソーシアムのメンバーで解析技術のキープレイヤーとなっている。経済エネルギー省の研究開発プログラム「Smart Data」の一環。  |
| META-NET                         | 欧州の多言語情報社会の技術基盤の育成のためのプロジェクト。34カ国の60の大学、研究機関が参画している。EUの研究開発プログラムHorizon2020のプロジェクト。DFKIがコーディネーターを務める。以下の3つのサブプロジェクトからなる。META-VISION：共有ビジョンと戦略的な研究課題を中心に、ダイナミックで影響力のあるコミュニティを育成する。META-SHARE：資源の共有と交換のためのオープンな分散ファシリティの創設。音声データベースを含む。META-RESEARCH：関連する近接技術分野への橋渡し。 |
| QT21                             | 欧州の27言語のうち多くは、機械翻訳の恩恵にあずかっていない。そうした言語は語順が自由ないしは多様であるという特徴を有しており、しばしば学習資源や処理ツールが不十分である。こうした状況の解決に向けて、①統計学および機械学習に基づく翻訳モデルの改善、②翻訳者によって報告される品質上の障壁の体系的な分析により導かれる評価と継続的な学習の改善、③スケラビリティについて焦点を当てこれらのモデルによる学習と解読の有効性とデータへの依存の最小化を確保する。EUの研究開発プログラムHorizon2020のプロジェクト。     |
| CRACKER                          | 機械翻訳技術分野の欧州研究機関の提携を強化を目的としたプロジェクト。DFKIがコーディネーターを務める。EUの研究開発プログラムHorizon2020のプロジェクト。わかりやすい成功指標と大きな挑戦への合意、相互運用性と標準化に導かれる共有資源に関する共同研究を行い、他分野における事例に倣い効率性と効果における機械翻訳の改善を押し進める。  |

## 4.3.5 中国

### 4.3.5.1 製造業の高度化施策の流れ

中国では2010年以降、製造業の高度化を戦略的に推進してきた。

2010年の「戦略的新興産業の育成発展に関する国务院の決定」に端を発して製造業の高度化を指向した「智能製造（スマート製造業）」をベースにした施策が多数制定され、2015年には中国版Industry 4.0というべき「中国製造2025」が策定された。それ以降もロボットやIoTに関わる政策が打ち出されている（表18）。

■表18 中国における製造業IT化政策の動向<sup>17</sup>

| 公布年月    | 公布機関        | 施策                                 |
|---------|-------------|------------------------------------|
| 2015年5月 | 国务院         | 中国製造2025                           |
| 2015年7月 | 国务院         | 『互聯網+（インターネットプラス）』行動の積極的推進に関する指導意見 |
| 2016年3月 | 工業化情報部ほか    | ロボット産業発展計画（2016～2020）              |
| 2016年5月 | 国务院         | 製造業とインターネットの融合発展の深化に関する指導的意見       |
| 2016年5月 | 国家発展改革委員会ほか | インターネットプラス AI3年行動実施方案              |

※16

DFKI Website <<https://www.dfki.de/web>>; Smart Data Program Website <[http://www.digitale-technologien.de/DT/Navigation/DE/Foerderprogramme/Smart\\_Data/smart\\_data.html](http://www.digitale-technologien.de/DT/Navigation/DE/Foerderprogramme/Smart_Data/smart_data.html)>等より作成

※17

各種公表資料より作成

### 4.3.5.2 AI推進の3か年行動計画

2016年にはAI推進の3か年行動計画である「インターネットプラスAI3年行動実施方案」が策定され、2018年までに、中国のAI技術・産業を世界水準に引き上げるとともに、重点領域において世界トップクラスの中核企業を育成すること等により、1,000億元（約1.5兆円）級のAI活用市場の創出を目指す計画が示された（表19）。

深層学習や脳型コンピューティングといった先端技術の開発、スマートホーム、自動運転、ロボットといった産業分野での応用とともに、文書、音声、画像、動画、地図等、AIの学習用ビッグデータのプラットフォーム形成によるAI開発コストの低減やコンピューティングリソースやアルゴリズムのオープンプラットフォーム化といった「オープンプラットフォーム戦略」、標準化、人材育成について一通り検討されており、社会実装にむけた環境づくりの面でのキャッチアップへの姿勢がうかがえる。

### 4.3.5.3 AIイノベーション発展計画

2017年3月には、科学技術部のワン・ガン（万鋼）部長がイノベーション駆動発展戦略の実施等について記者会見を行い、その中で「AIイノベーション発展計画」について、AI技術開発の新たな状況に対応し、特に深層学習のキーテクノロジー、境界を超えた情報技術の融合、人と機械の協働、群知能及びオープンリサーチに注力すると言及した。また、経済発展、社会・生活、環境保全事業等におけるAIの応用を推進するために、科学技術部は、現在「AIイノベーション発展計画」を策定中であり、中央政府が研究支援プログラムを策定し、基礎研究、キーとなる共通技術研究を推進することを表明した<sup>19</sup>。

■表19 「インターネットプラスAI3年行動実施方案」の概要<sup>18</sup>

| 計画概要および実施目標  |                         |   |
|--|-------------------------|---|
| 2018年までに、中国のAIの産業体系・サービス体系・標準化体系の基礎を構築し、技術と産業を世界水準に引き上げるとともに、AIの重点領域において、世界トップクラスの中核企業を育成すること等により、1,000億元級のAI活用市場を創出する |                         |   |
| 取組内容   |                         |   |
| AI産業の育成・発展   | コア技術の研究開発と産業応用          | <ul style="list-style-type: none"> <li>産学連携の促進：国家工程実験室、国家工程（技術）研究中心等の設立</li> <li>深層学習技術や脳型コンピューティングの研究開発等</li> <li>AI領域のチップ、センサー、OS、ミドルウェア等、各種ハードウェア・ソフトウェアの技術開発等</li> </ul>  |
|  | 開発リソースのオープン化・プラットフォーム化  | <ul style="list-style-type: none"> <li>文書、音声、画像、動画、地図等、AIの訓練用ビッグデータのプラットフォーム形成によるAI開発コストの低減</li> <li>コンピューティングリソースやアルゴリズムのオープン・プラットフォーム化</li> </ul>   |
| 重点分野における製品開発   | AI活用による製品・サービスのスマート化の促進 | <ul style="list-style-type: none"> <li>スマートホーム（ホームエンターテインメント、エネルギー管理、ホームセキュリティ等）</li> <li>自動運転（クルーズコントロール、自動駐車システム等）</li> <li>無人システム（飛行機、船舶等、各種産業機械・機器の無人化、物流、農業、測量、電力配線、保安、救急等での活用）</li> <li>公共安全（治安維持、災害予知等）</li> </ul> |
| 端末製品のスマート化   | 端末製品*のスマート化の促進          | <ul style="list-style-type: none"> <li>クラウド連携、カスタマイゼーション等の導入による端末製品のスマート化</li> <li>ウェアラブル端末の医療・ヘルスケア、労働、人身安全等での活用促進、ビジネスモデル等の変革</li> <li>産業用ロボット、特殊ロボット、サービスロボット等の開発強化、活用促進</li> </ul>                                    |
| 計画実行のための支援措置   | 資金支援                    | 中央政府予算の活用、ベンチャー企業投資・創業投資、適格企業による社債発行の認可等、資金チャネルの多様化   |
|  | 技術標準化                   | ネットワークセキュリティ、プライバシー保護等に関する技術の標準化等   |
|  | 知的財産権の保護強化・活用促進         | AIの基礎技術、応用アプリケーションに関する知的財産の保護強化等  |
|  | 人材育成                    | 高等教育の充実化、産学官連携、養成基地の設立等による人材育成<br>国内人材の海外派遣によるトップ人材の育成等   |
|  | 国際協力                    | 有力企業による海外市場開拓支援、海外企業との連携等による海外市場開拓支援等<br>国内外のイノベーション資源の融合による国際競争力の獲得<br>業界団体/連盟のプラットフォーム化による、AIベンチャー企業に対する国際協力・海外の技術紹介等のサービス提供  |
|  | 組織連携                    | 「インターネット+」政策連絡会議制度を利用し、領域横断的な専門家・中核企業による定期連絡会議体制の整備<br>中央政府、地方政府、研究機関、産業等の連携促進  |

\*移動端末、ウェアラブルデバイス、バーチャルリアリティ端末、ロボット等

※18

“‘互联网+’人工智能三年行动实施方案,” 中華人民共和国工業情報化部ウェブサイト  
<<http://www.miit.gov.cn/n1146290/n1146392/c4808445/part/4808453.pdf>>より作成

※19

“创新驱动发展下一步怎么干? 科技部部长万钢划重点,” 中華人民共和国科学技术部ウェブサイト<[http://www.most.gov.cn/xinwzx/mtjj/mtzf/201703/t20170313\\_131943.htm](http://www.most.gov.cn/xinwzx/mtjj/mtzf/201703/t20170313_131943.htm)>

# 資料編

**資料1** AIの取組状況に関するアンケート調査結果

**資料2** 情報系教育機関におけるAI分野の教育動向調査

# 資料編

## 資料1 AIの取組状況に関するアンケート調査結果

以下に示すグラフは、国内外の人工知能（AI）に関わる取組状況を把握するために実施した、アンケート調査結果に基づくものである。

### (1) 国内アンケート調査概要

国内企業におけるAIの取組状況及びその変化の動向、取組を進める上での課題の把握等を目的として、民間企業宛てにアンケート調査を行った。調査の概要は以下のとおりである。

- 調査方法：郵送調査
- 調査期間：2017年3月
- 調査対象：上場企業 3,787企業
- 業種区分：情報処理実態調査の調査業種26業種
- 回収数：有効回収数 296企業（有効回収率 7.8%）
- 主な調査項目：
  - AIに関する認識
  - AIに関する取組状況
  - AIの推進体制やデータ整備の状況
  - AIに関する投資状況、等

### (2) 海外アンケート調査概要

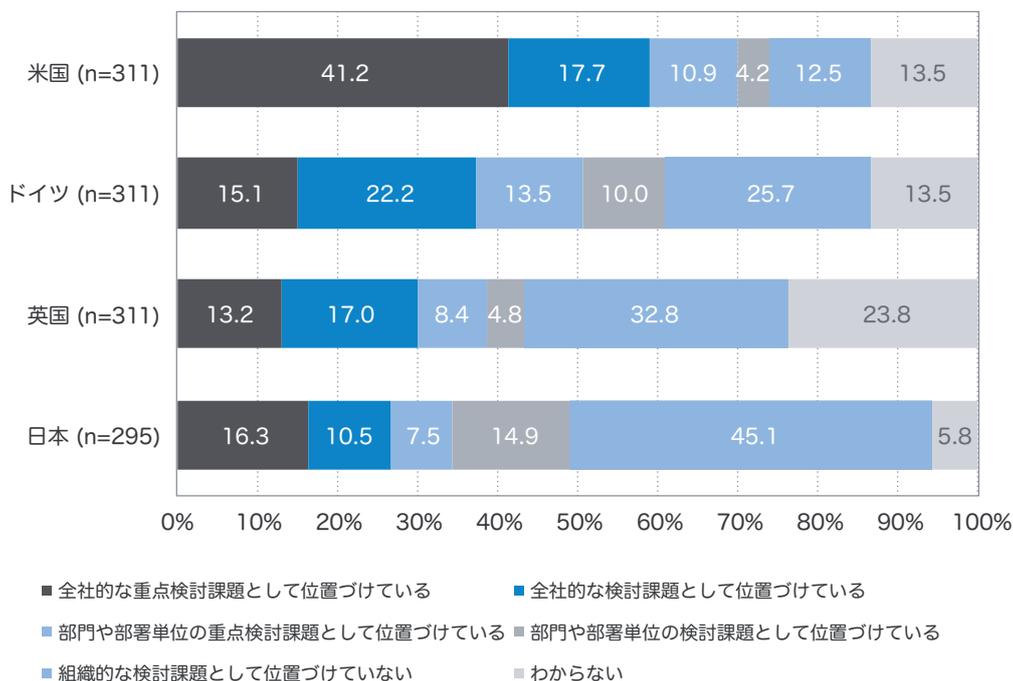
海外企業に対しても国内企業と同様の目的でアンケート調査を実施した。なお、海外アンケート調査は、ウェブモニタを通じて回答を得た。調査の概要は以下のとおりである。

- 調査方法：ウェブアンケート調査
- 調査時期：2017年3月
- 対象国：米国、英国、ドイツ
- 対象者：民間企業に勤めるマネジメント層
- 回収数：各国311件（日本の上場企業の従業員規模比率をもとに割り付け\*）
- 主な調査項目：国内企業アンケート調査と同様

\* 各国の回収数は従業員規模別に、1,000人超：130件／500人～1,000人未満：57件／100～500人未満：94件／100人未満：30件。

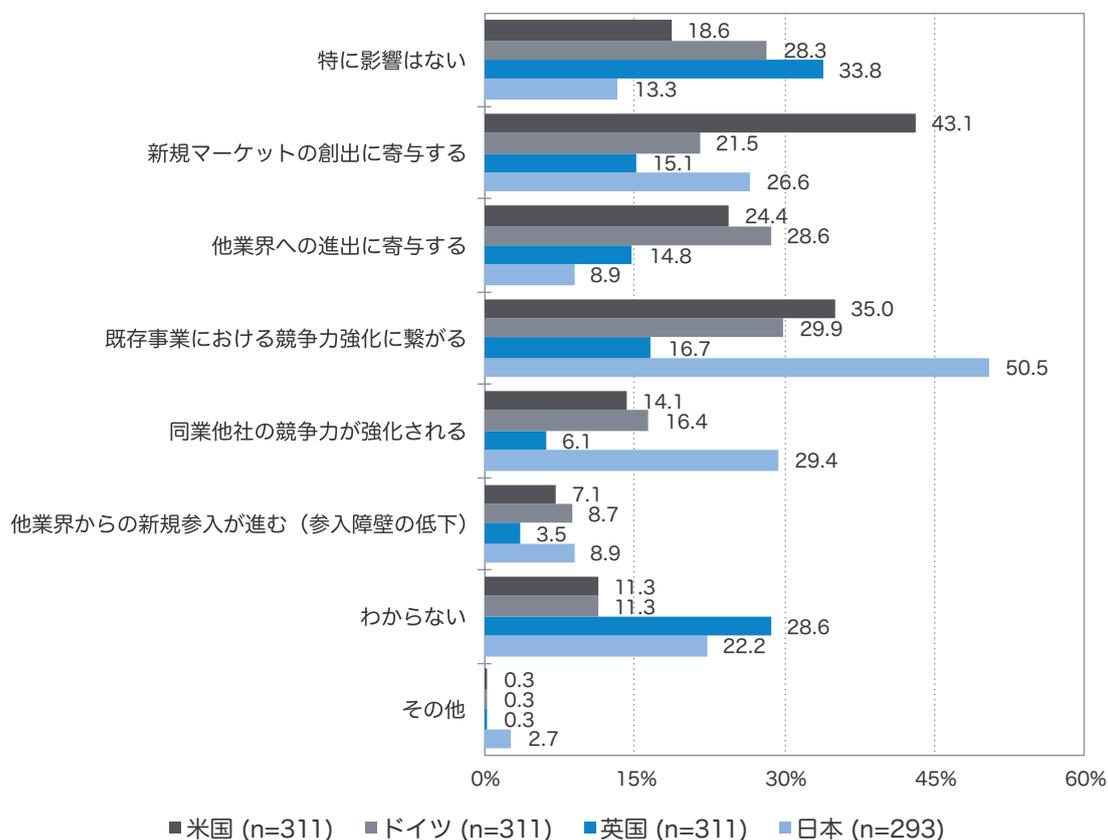
## 1.1 組織におけるAIの位置付け

[問] 貴社では、人工知能の取組（業務での活用や製品・サービス供給など）を組織的課題として位置づけていますか。当てはまるものを1つ選んでください。



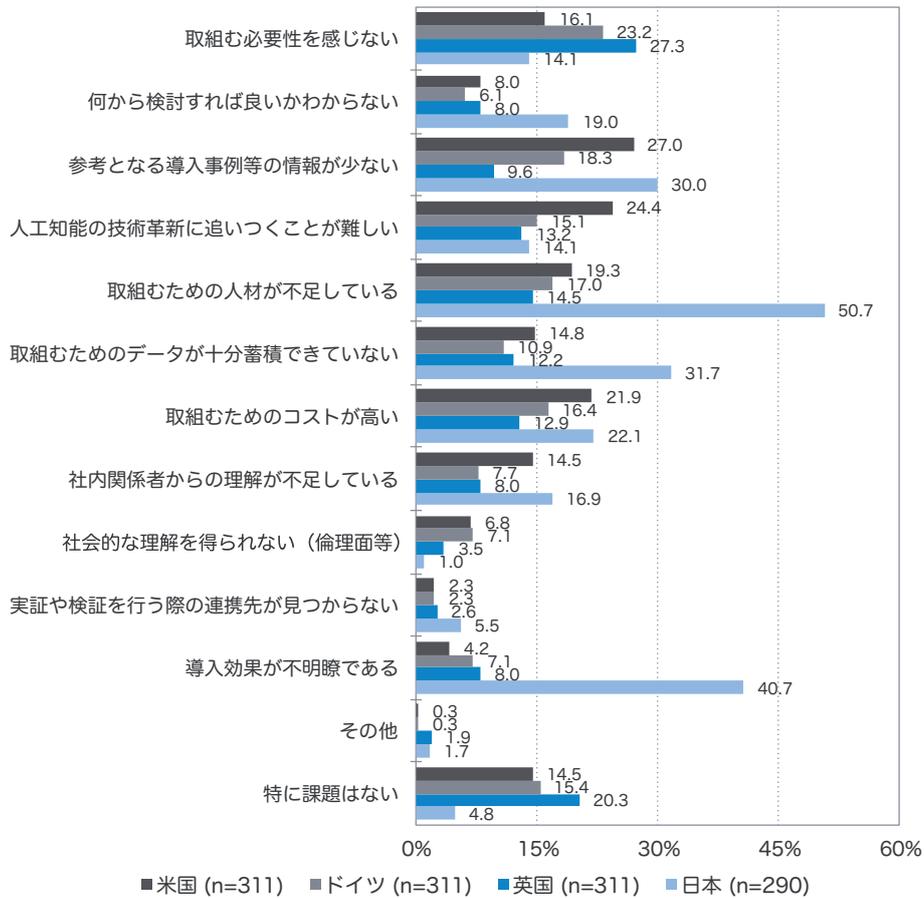
## 1.2 事業への影響に関する認識

[問] 人工知能は貴社の事業にどのような影響を及ぼすと認識していますか。当てはまるものをすべて選んでください。（複数選択可）



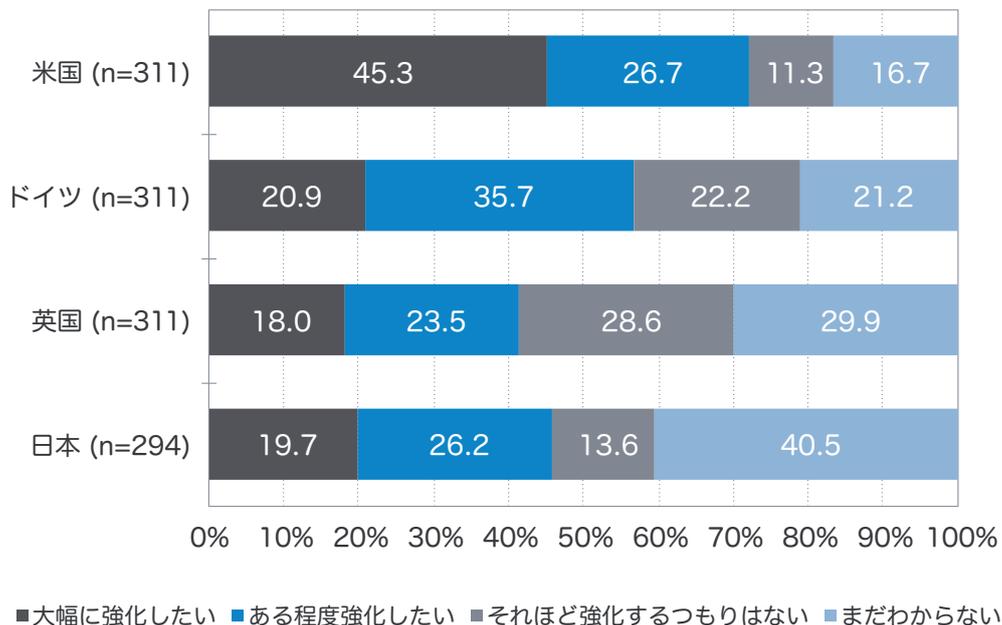
### 1.3 課題認識

[問] 人工知能の取組について、貴社が感じている課題認識について、当てはまるものをすべて選んでください。(複数選択可)



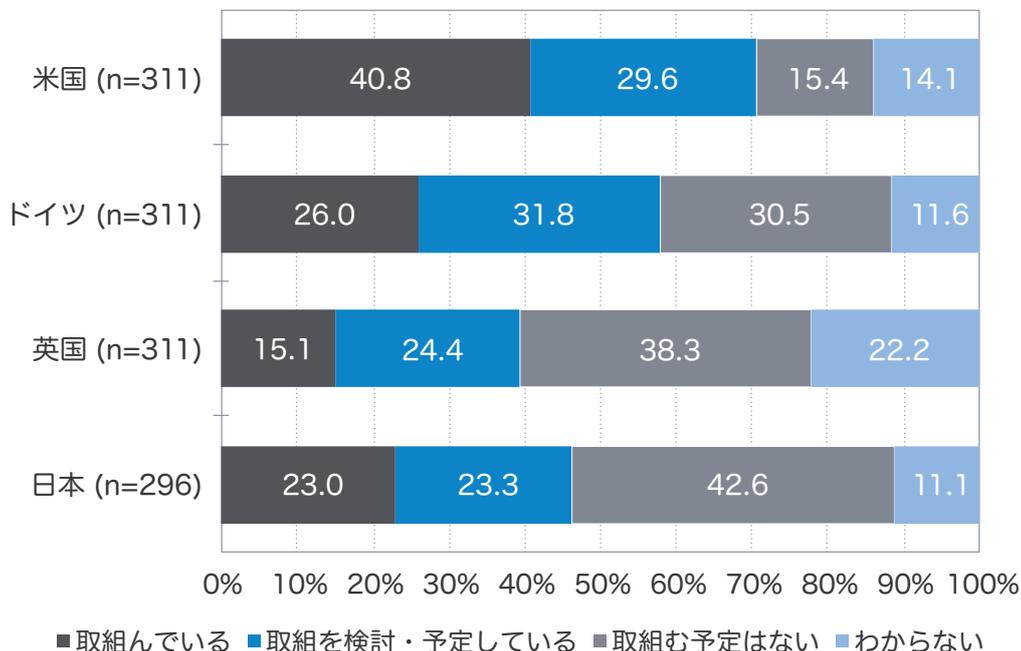
### 1.4 今後の意向

[問] 貴社では、今後、人工知能への取組をどの程度強化していきたいとお考えですか。当てはまるものを1つ選んでください。



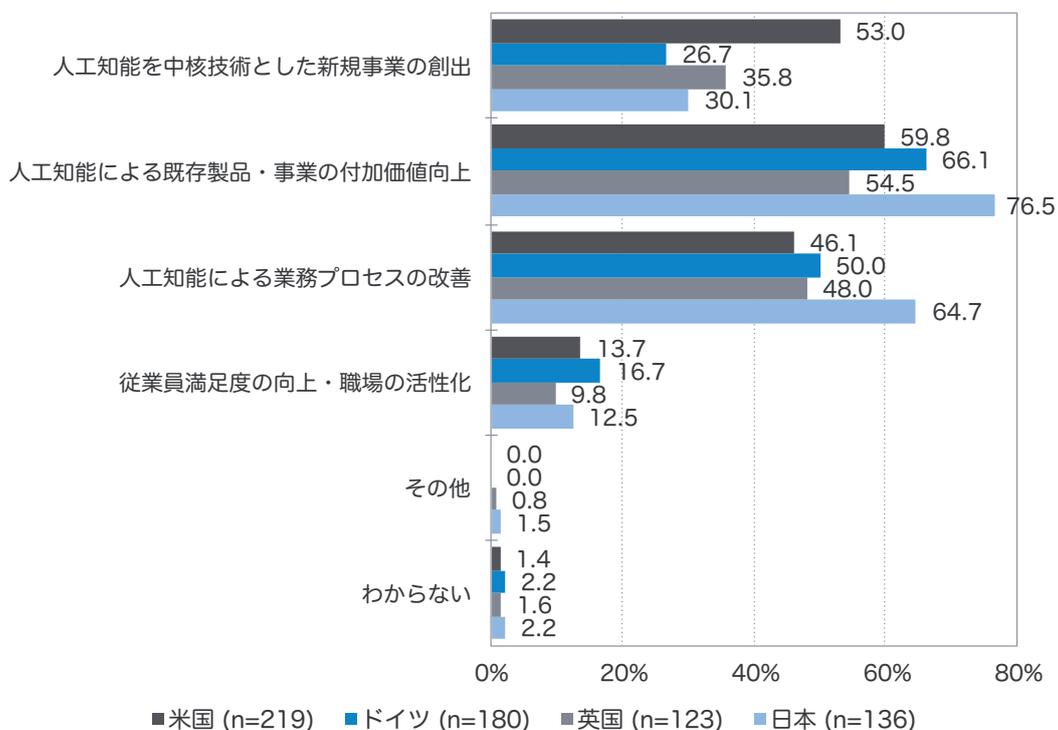
## 1.5 取組状況

[問] 2017年3月1日時点において、貴社では人工知能に関わる取組（業務での活用や製品・サービスの提供など）を行っていますか。当てはまるものを1つ選んでください。



## 1.6 取組目的<sup>1</sup>

[問] 貴社における人工知能の取組目的について、当てはまるものをすべて選んでください。（複数選択可）



※1 1.5. 取組状況で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。

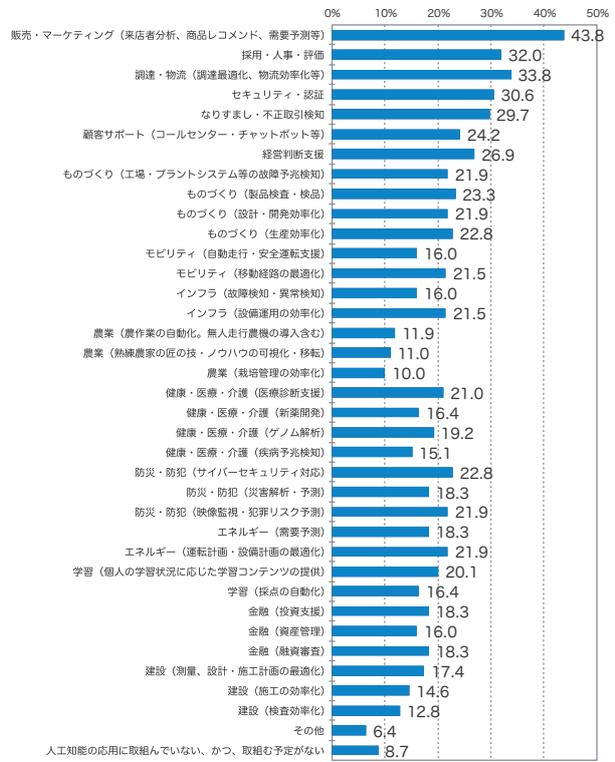
## 1.7 応用分野<sup>2</sup>

[問] 人工知能の応用先について、貴社が取組んでいる／取組を検討・予定している項目をすべて選んでください。(複数選択可)

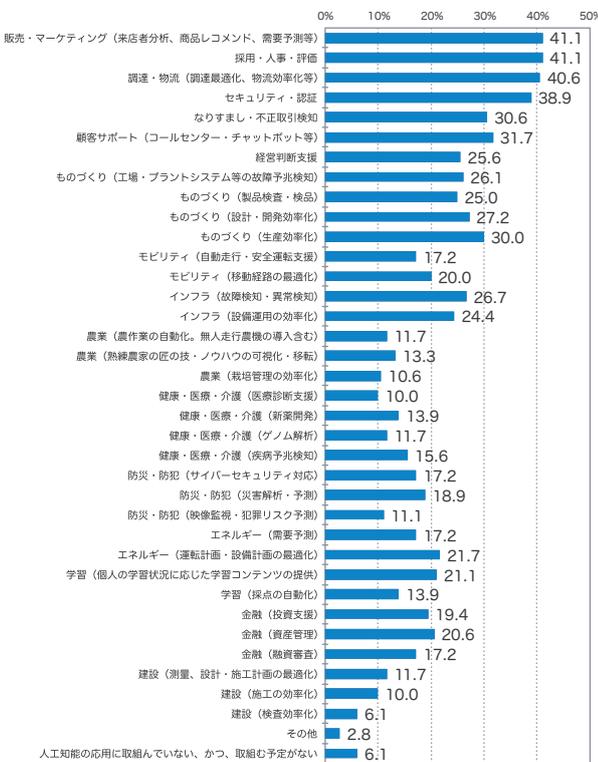
日本(n=67)



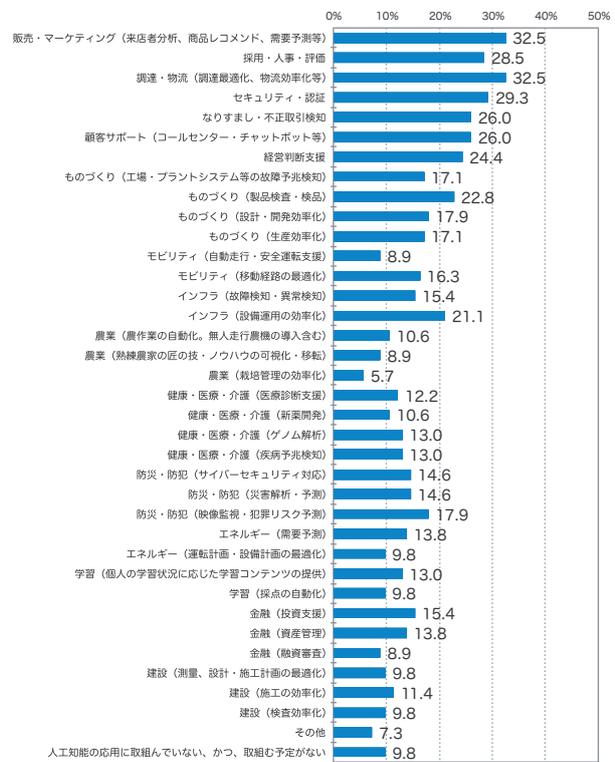
米国(n=219)



ドイツ(n=180)



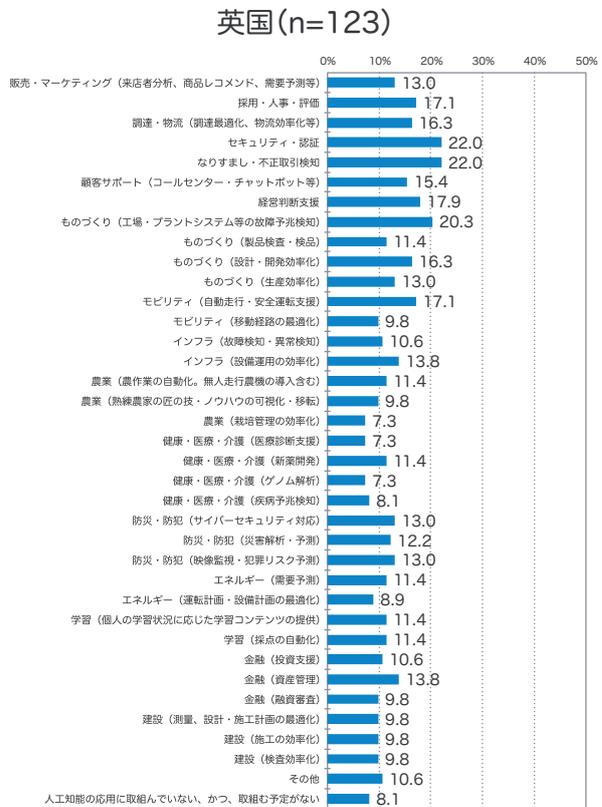
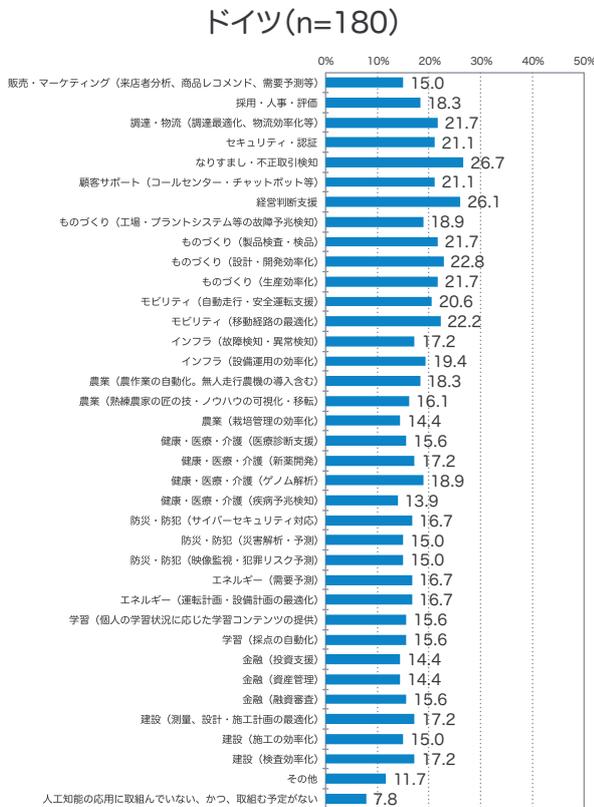
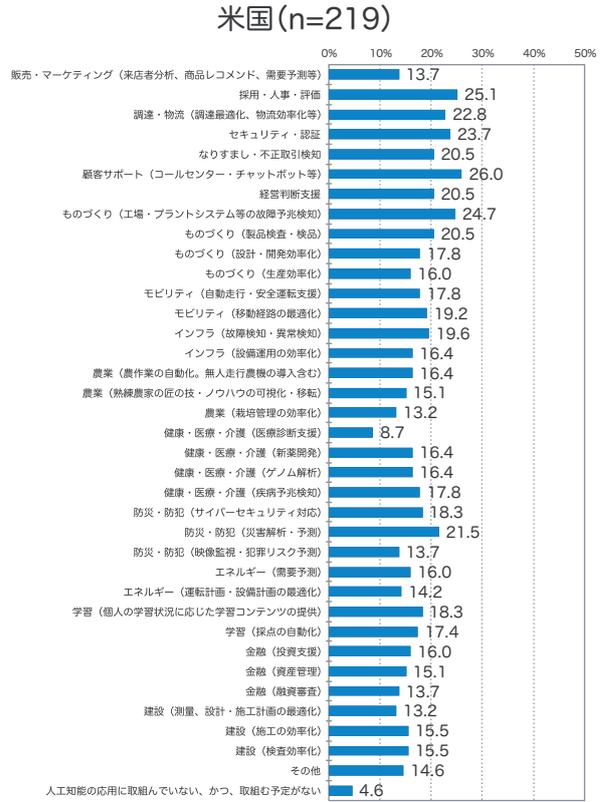
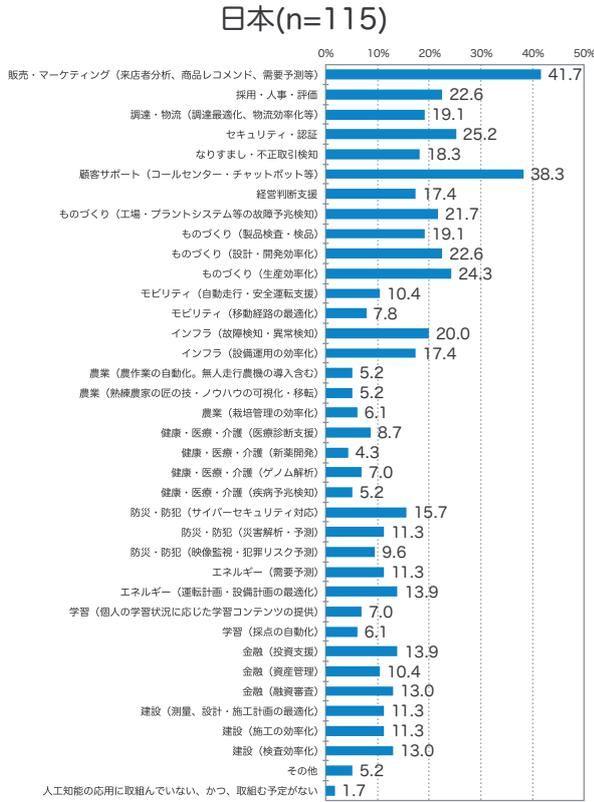
英国(n=123)



※2 1.5. 取組状況で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。

### 1.8 検討・予定中の応用分野<sup>3</sup>

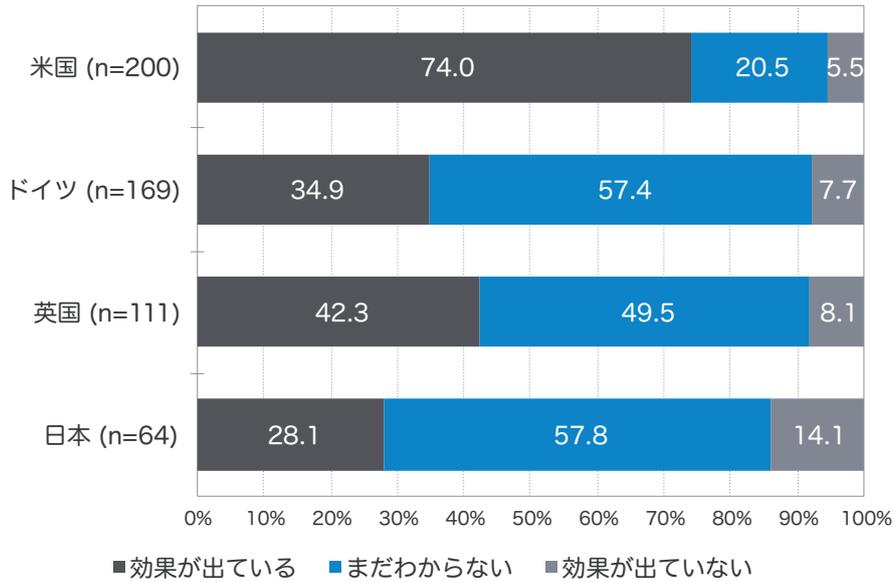
[問] 人工知能の応用先について、貴社が取組んでいる／取組を検討・予定している項目をすべて選んでください。(複数選択可)



※3 1.5. 取組状況で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。

### 1.9 取組効果<sup>4</sup>

[問] 貴社では、これまでに人工知能に関わる取組による効果が出ていますか。当てはまるものを1つ選んでください。



### 1.10 投資金額<sup>5</sup>

[問] 貴社の人工知能の取組における投資金額についてお尋ねします。2015年度および2016年度の投資金額について、最も近いものをそれぞれ1つずつ選んでください。

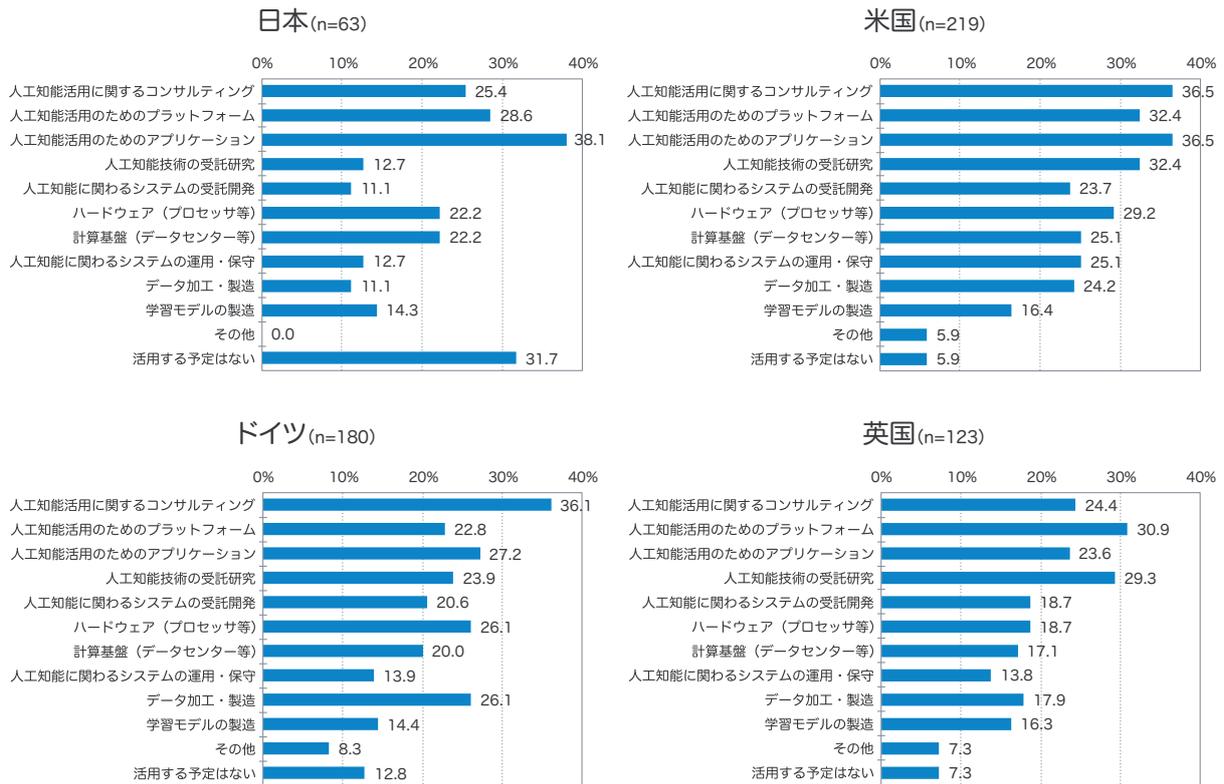


※4 1.7. 応用分野 又は 1.8.検討・予定中の応用分野において、「人工知能の応用に具体的に取組んでいない/取組む予定がない」以外のいずれかに回答した企業が対象。

※5 1.5. 取組状況で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。

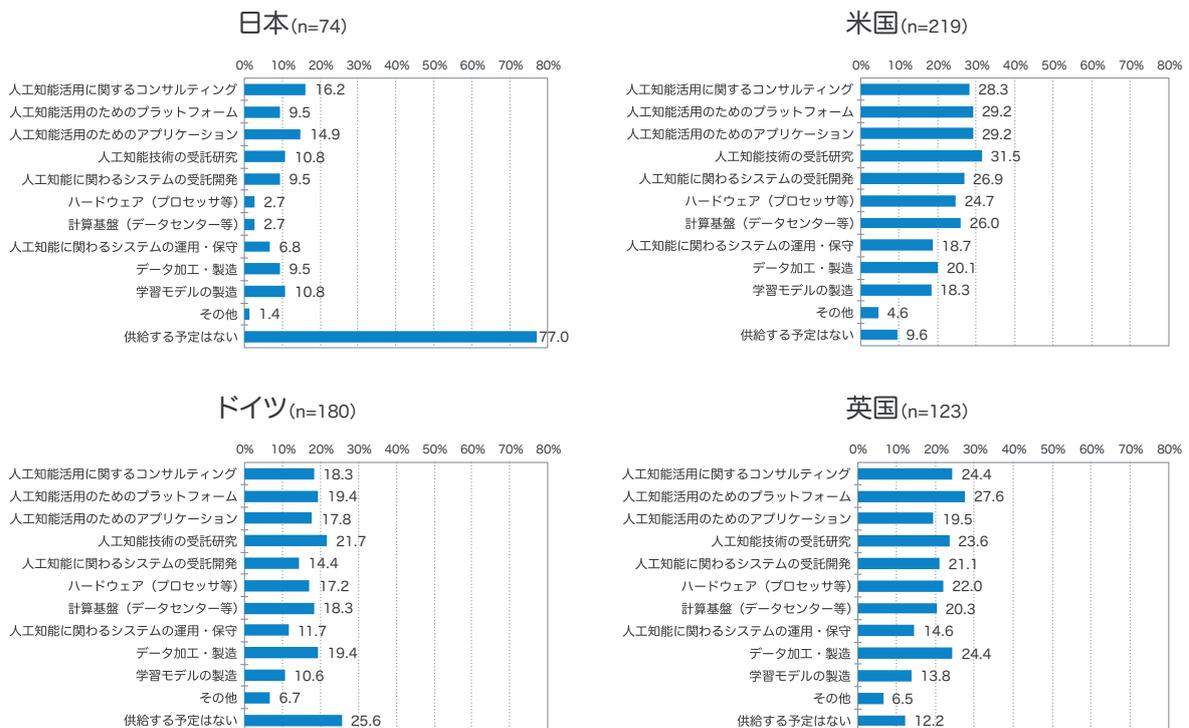
### 1.11 活用しているAI関連製品・サービス<sup>6</sup>

[問] 貴社が活用している／活用を予定・検討している製品・サービスについて、当てはまるものをすべて選んでください。(複数選択可)



### 1.12 供給しているAI関連製品・サービス<sup>\*7</sup>

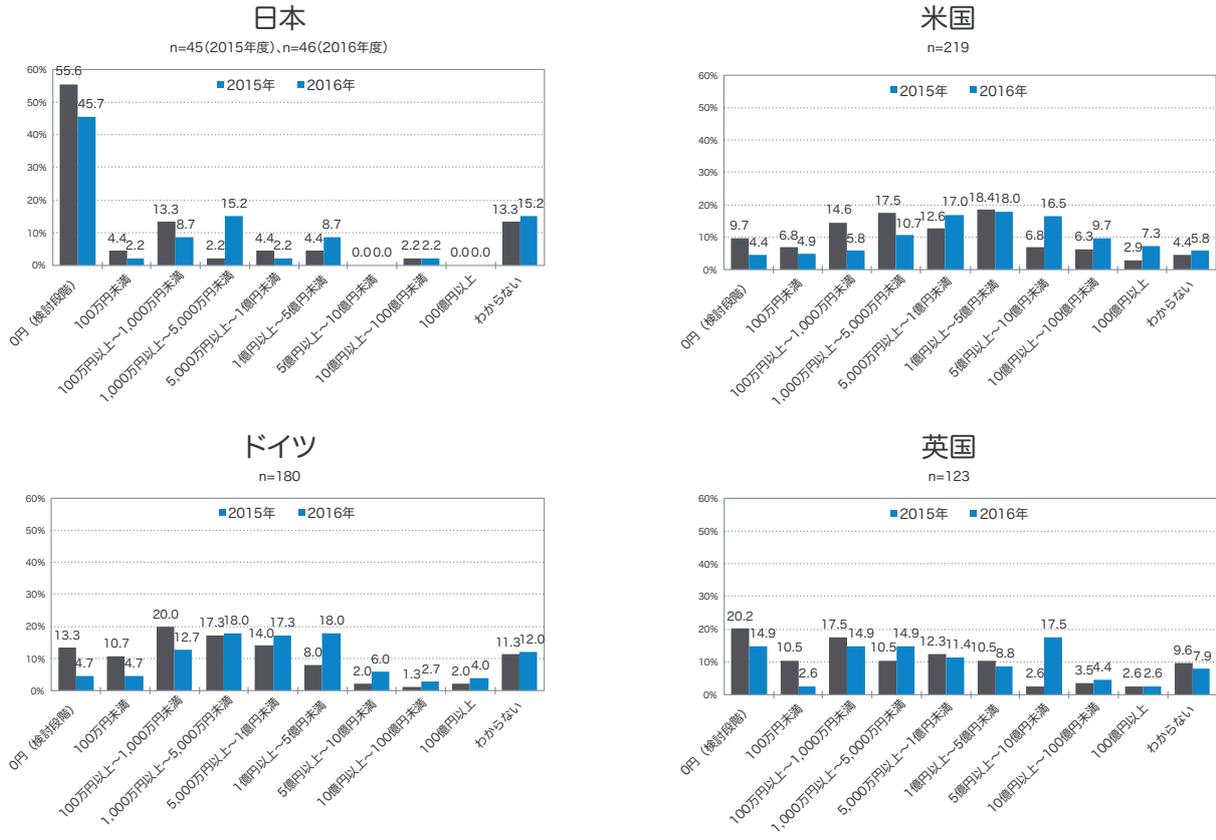
[問] 貴社が供給している／供給を予定・検討している製品・サービスについて、当てはまるものをすべて選んでください。(複数選択可)



\*6 1.5. 取組状況で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。

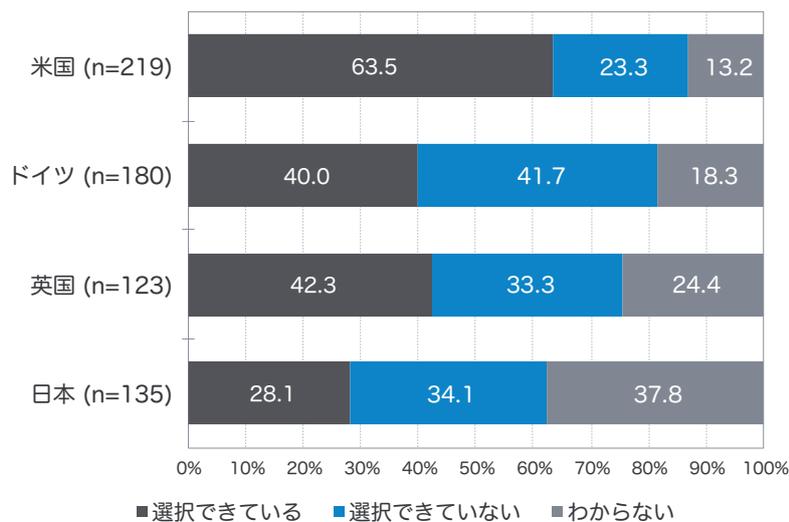
### 1.13 AI関連製品・サービスの売り上げ<sup>7</sup>

[問] 人工知能に関わる製品・サービスの売上についてお尋ねします。貴社の2015年度の売上及び2016年度の売上見込について、最も近いものを1つずつ選んでください。



### 1.14 AIの手法やアルゴリズムの選択<sup>8</sup>

[問] 解決したい目的や分析対象となるデータにあわせて、最適な人工知能の手法やアルゴリズムを選択することができますか。当てはまるものを1つ選んでください。

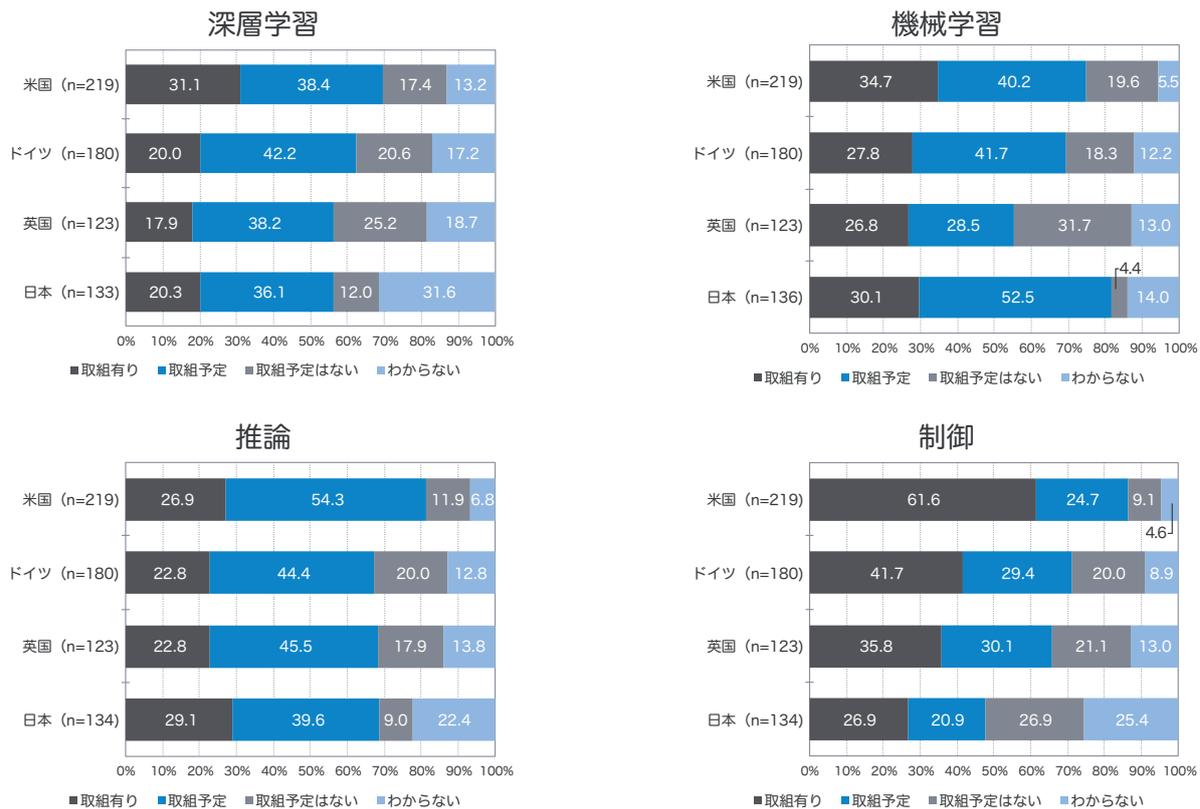


※7 1.12. 供給しているAI関連製品・サービスで「供給する予定はない」以外のいずれかの設問で「供給している」または「検討中」を回答した方が対象。

※8 1.5. 取組状況で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。

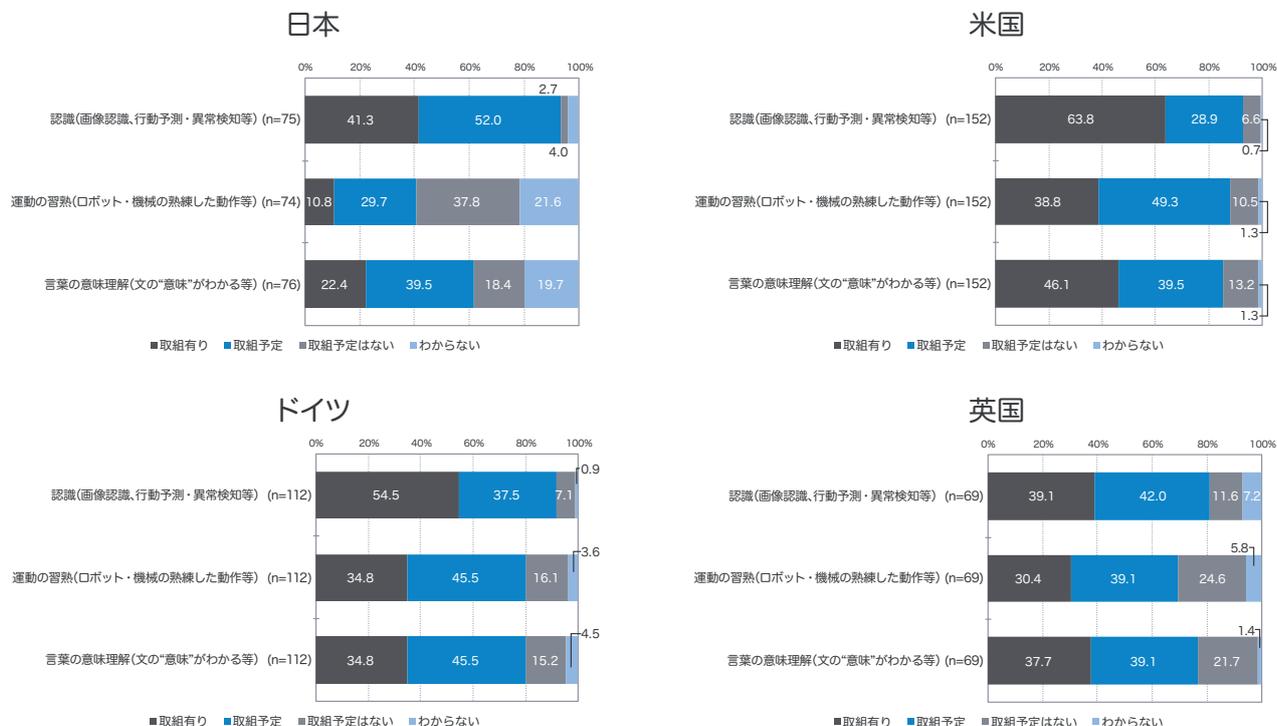
### 1.15 手法別の取組状況<sup>9</sup>

[問] 人工知能の手法について、貴社の取組状況をそれぞれ1つずつ選んでください。



### 1.16 深層学習に関する取組状況<sup>10</sup>

[問] 貴社の深層学習の取組状況について、当てはまるものをそれぞれ1つずつ選んでください。

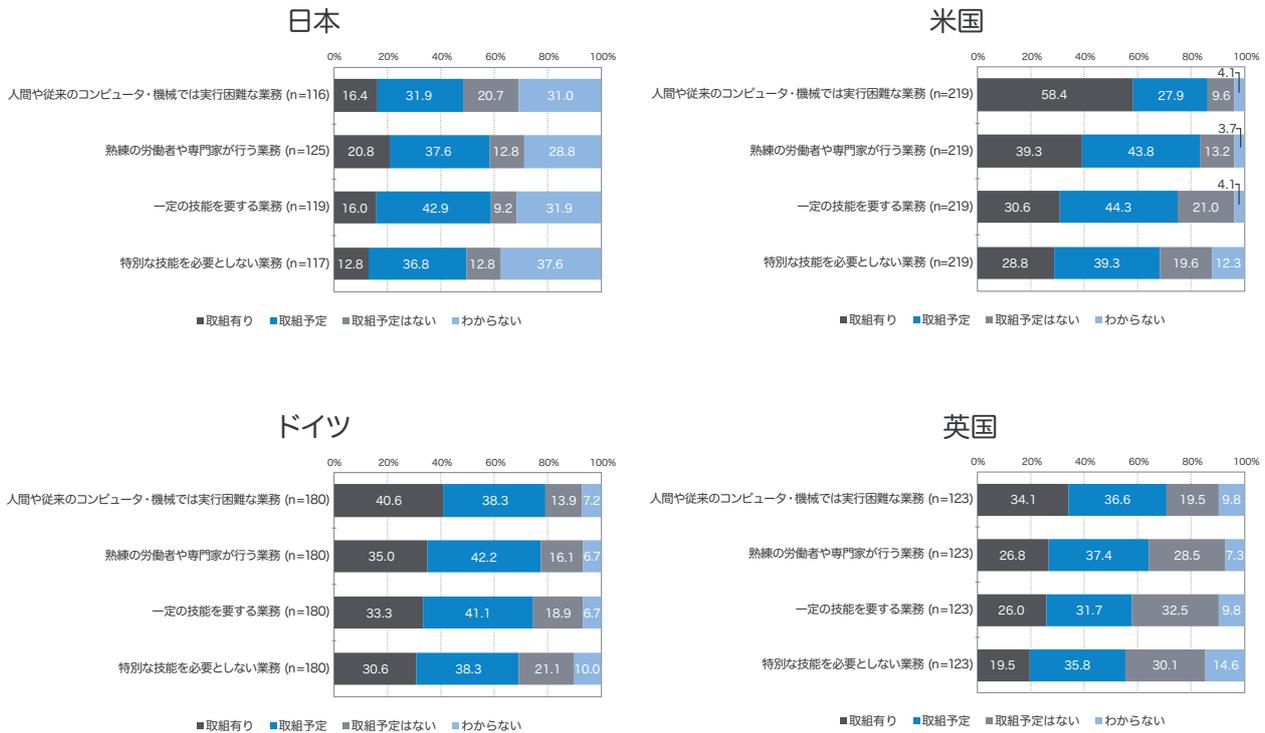


※9 1.5. 取組状況で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。

※10 1.15. 手法別の取組状況で深層学習に「取組有り」又は「取組予定」と回答した企業が対象。

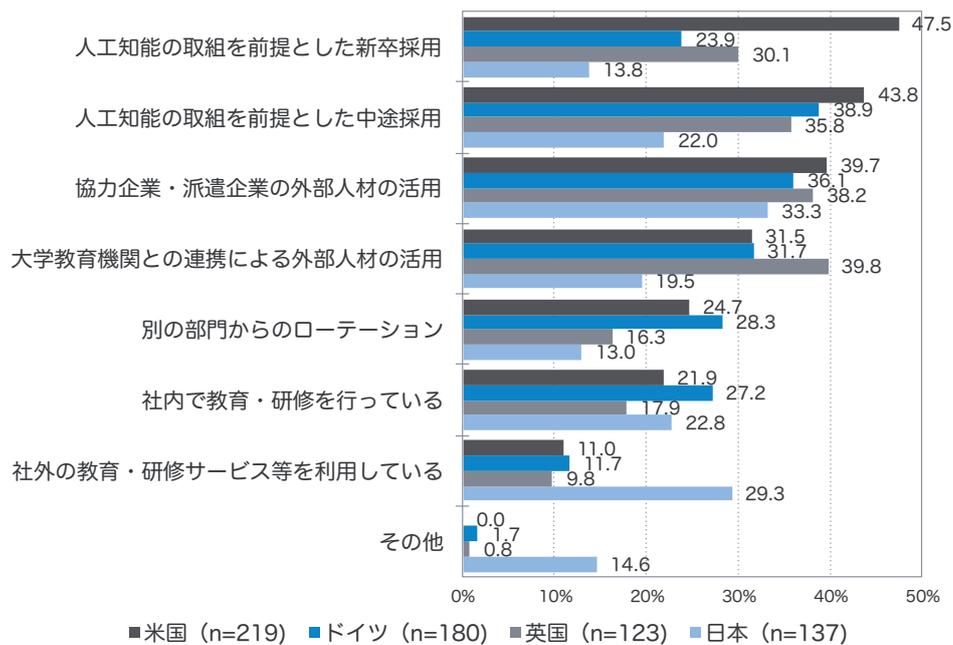
### 1.17 適用先の業務レベル<sup>11</sup>

[問] 貴社では、人工知能をどのような業務レベルに適用することをお考えですか。当てはまるものをそれぞれ1つずつ選んでください。



### 1.18 人材の確保・育成<sup>※11</sup>

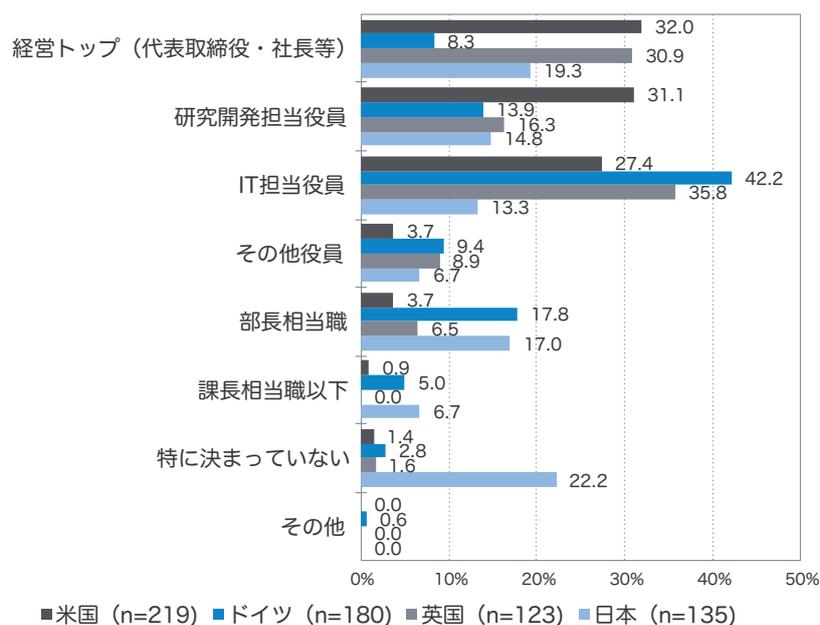
[問] 貴社では、人工知能の取組を推進する人材をどのようにして確保・育成していますか。当てはまるものをすべて選んでください。(複数選択可)



※11 1.5. 取組状況で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。

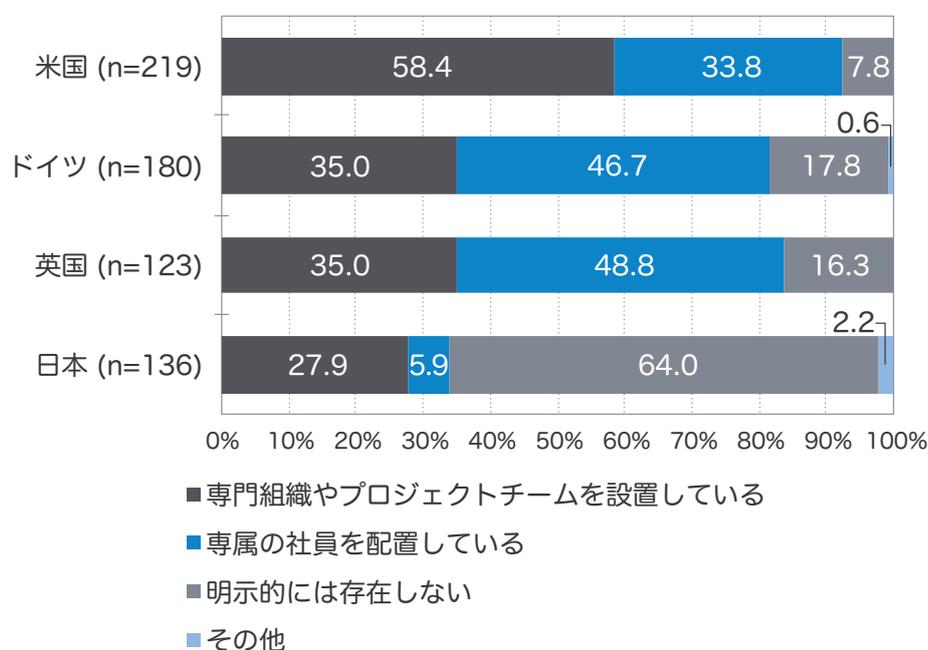
### 1.19 取組を主導する責任者<sup>12</sup>

[問] 貴社の人工知能の取組を主導する責任者について、最も近いものを1つ選んでください。



### 1.20 専門組織・専属要員の設置状況<sup>\*12</sup>

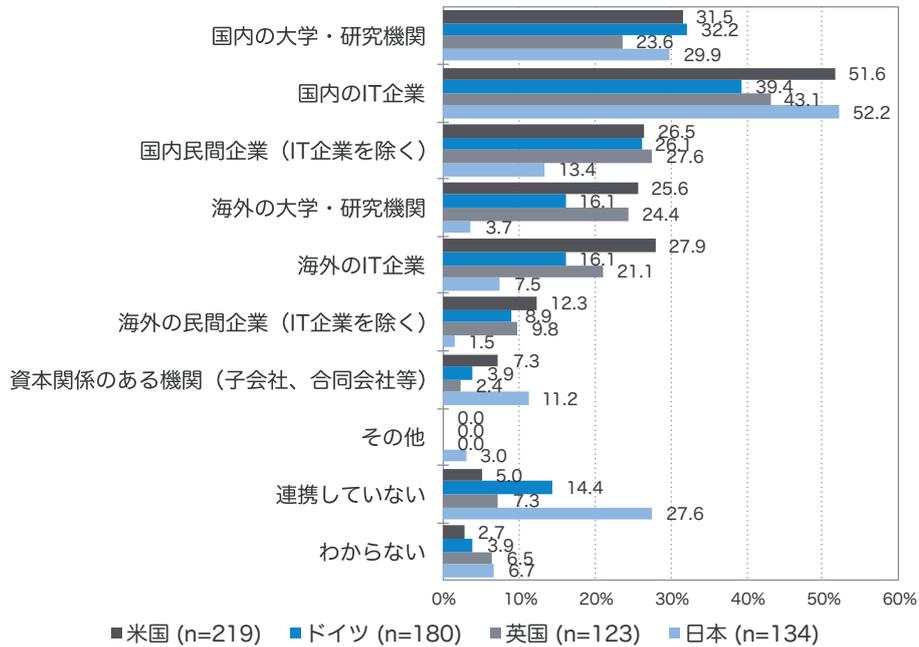
[問] 貴社では、人工知能の利用を推進する専門組織・専属要員を設置していますか。最も近いものを1つ選んでください。



\*12 1.5. 取組状況で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。

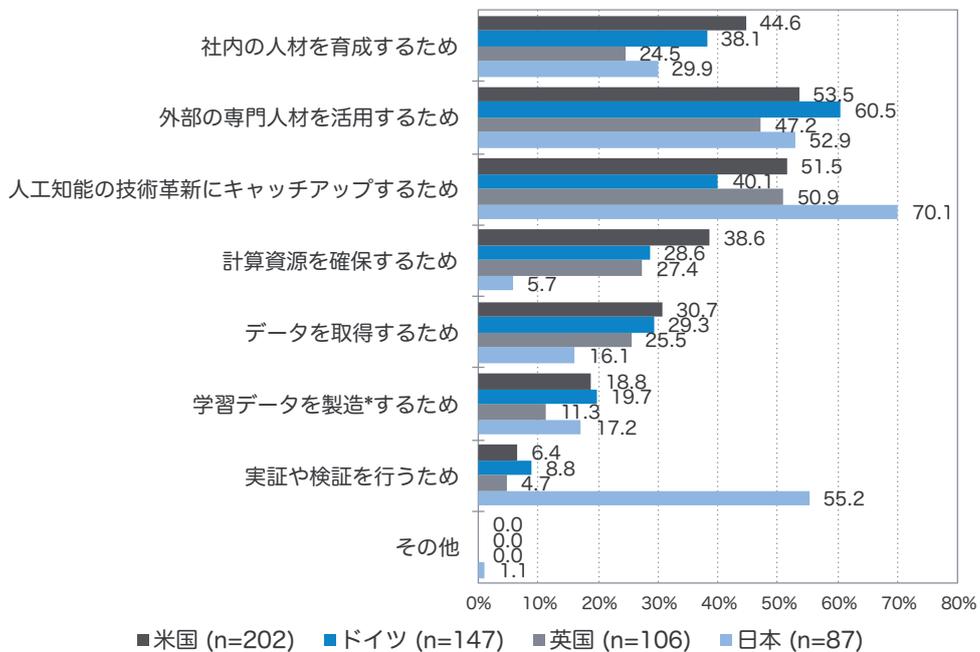
### 1.21 外部機関との連携状況<sup>13</sup>

[問] 貴社では人工知能に関する取組を進めるために、外部機関との連携を行っていますか。当てはまるものをすべて選んでください。(複数選択可)



### 1.22 外部機関との連携目的<sup>14</sup>

[問] 外部機関と連携を行う目的について、当てはまるものをすべて選んでください。(複数選択可)

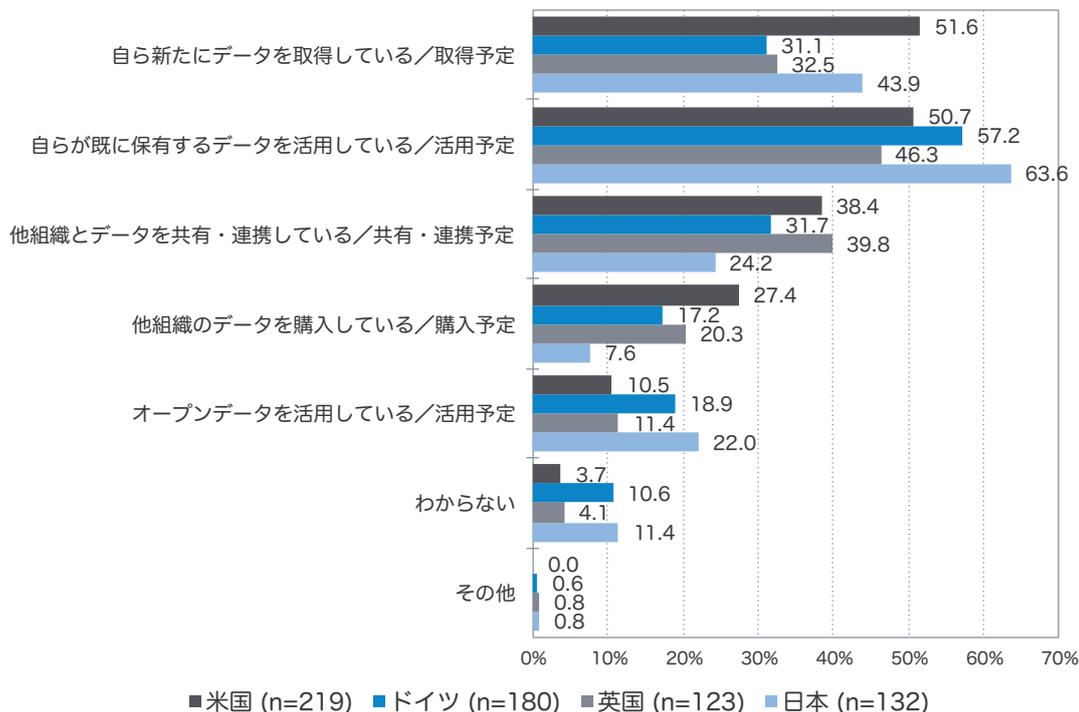


※ 13 1.5. 取組状況で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。

※ 14 1.21. 外部機関との連携状況で「連携していない」及び「その他」以外のいずれかに回答した企業が対象。

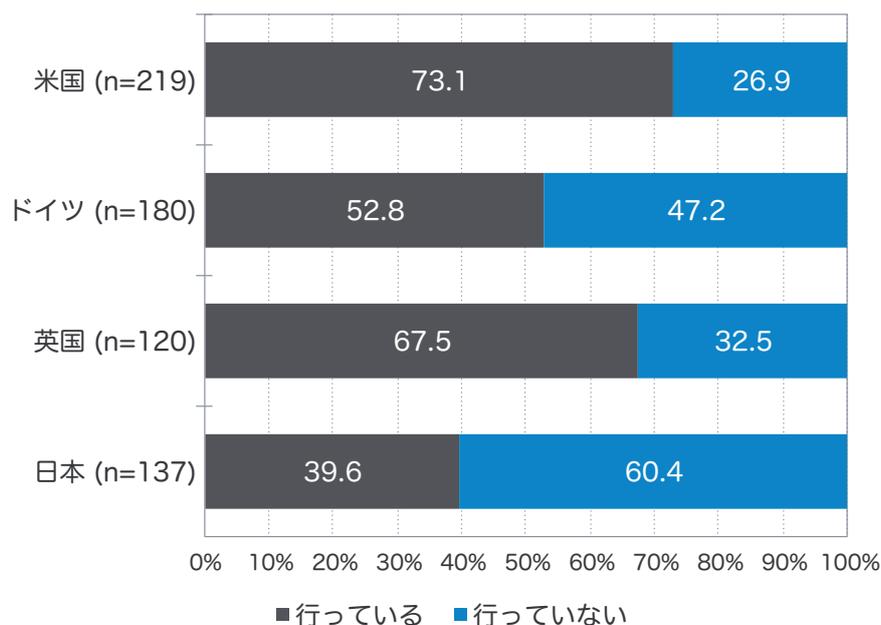
### 1.23 データの獲得方法<sup>15</sup>

[問] 貴社の人工知能に関する取組において、活用している／活用予定のデータの取得方法について、当てはまるものをすべて選んでください。(複数選択可)



### 1.24 研究開発の実施状況<sup>※15</sup>

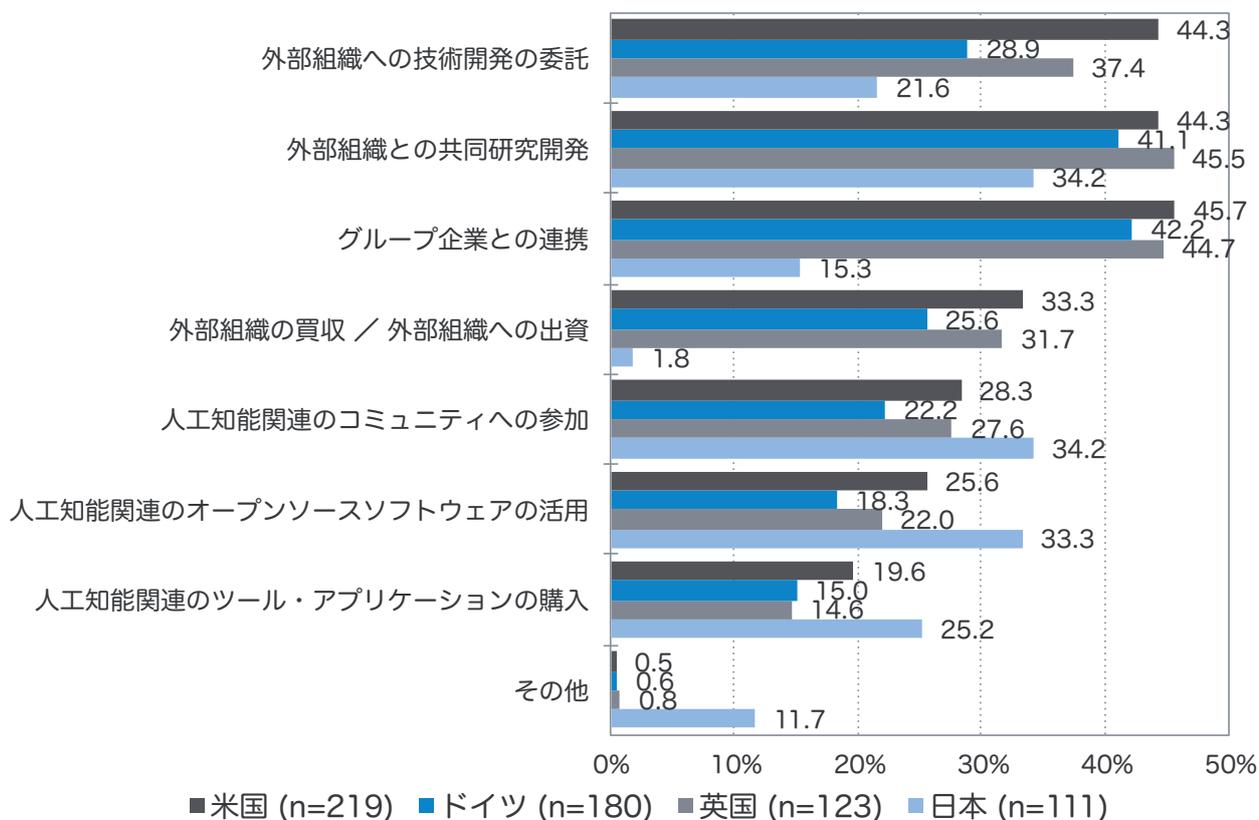
[問] 貴社では、人工知能に関する研究開発を行っていますか。当てはまるものを1つ選んでください。



※15 1.5. 取組状況で「取組んでいる」又は「取組を検討・予定している」と回答した企業が対象。

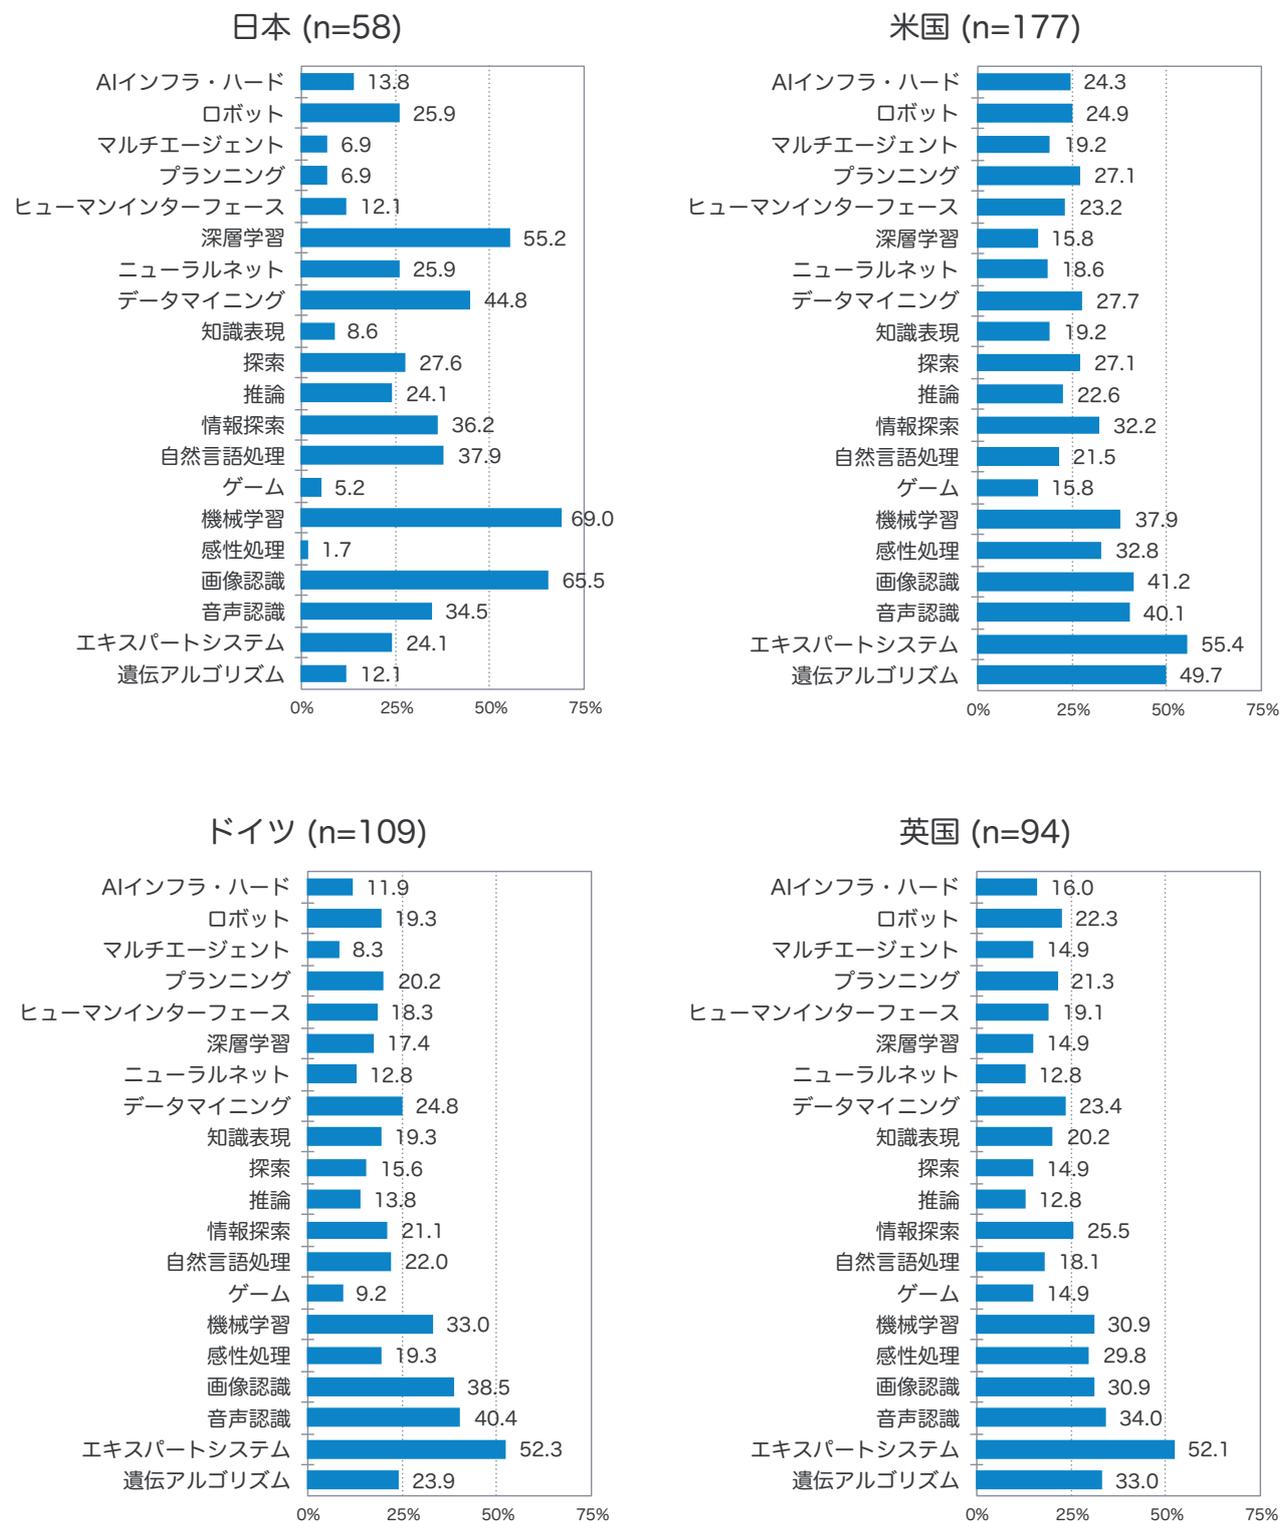
### 1.25 研究開発以外の技術獲得の状況

[問] 貴社では人工知能に関する技術を獲得するために、組織内での研究開発以外にどのような取組を行っていますか。当てはまるものをすべて選んでください。(複数選択可)



## 1.26 研究開発対象領域<sup>16</sup>

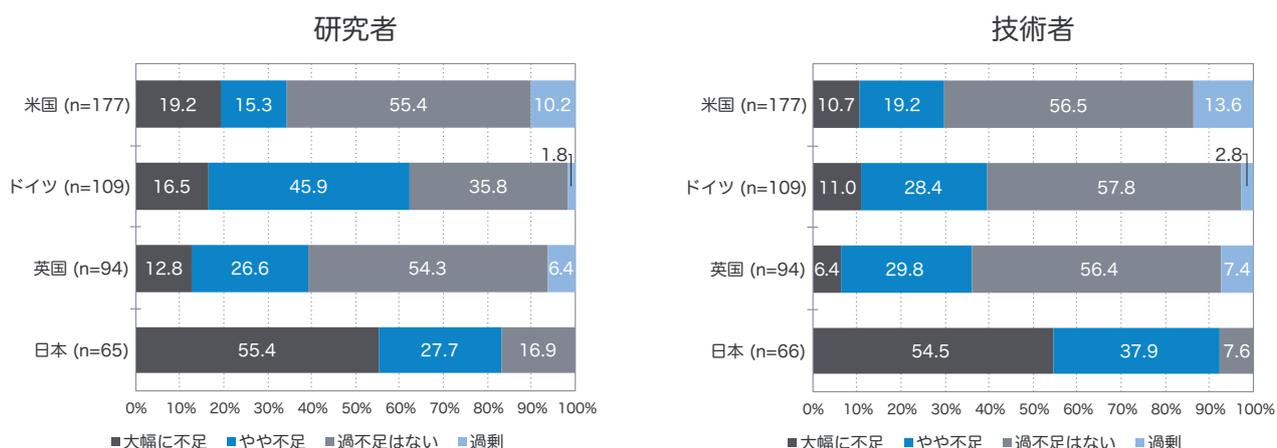
[問] 2016年度における貴社の研究開発対象領域について、当てはまるものをすべて選んでください。  
(複数選択可)



※ 16 1.24. 研究開発の実施状況で「行っている」と回答した企業が対象。

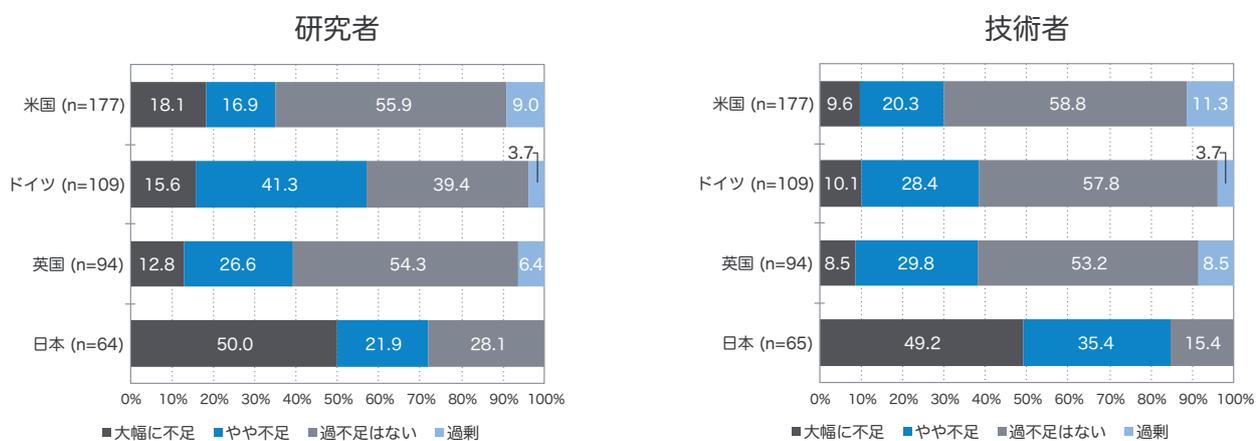
## 1.27 研究開発人材の量の不足感<sup>17</sup>

[問] 研究者、技術者<sup>18</sup>に関わる要員の「数」について、最も近いものをそれぞれ1つずつ選んでください。



## 1.28 研究開発人材の質の不足感<sup>17</sup>

[問] 研究者、技術者<sup>18</sup>に関わる要員の「質」について、最も近いものをそれぞれ1つずつ選んでください。



※ 17 1.24. 研究開発の実施状況で「行っている」と回答した企業が対象。

※ 18 研究者を学会等への論文を投稿しているあるいはそれに準ずる研究活動をしている要員、技術者を人工知能分野における研究開発を支援するソフトウェア開発、データセット作成等の技術開発や関連する技術的な業務に従事している要員と定義。

## 資料2 情報系教育機関におけるAI分野の教育動向調査

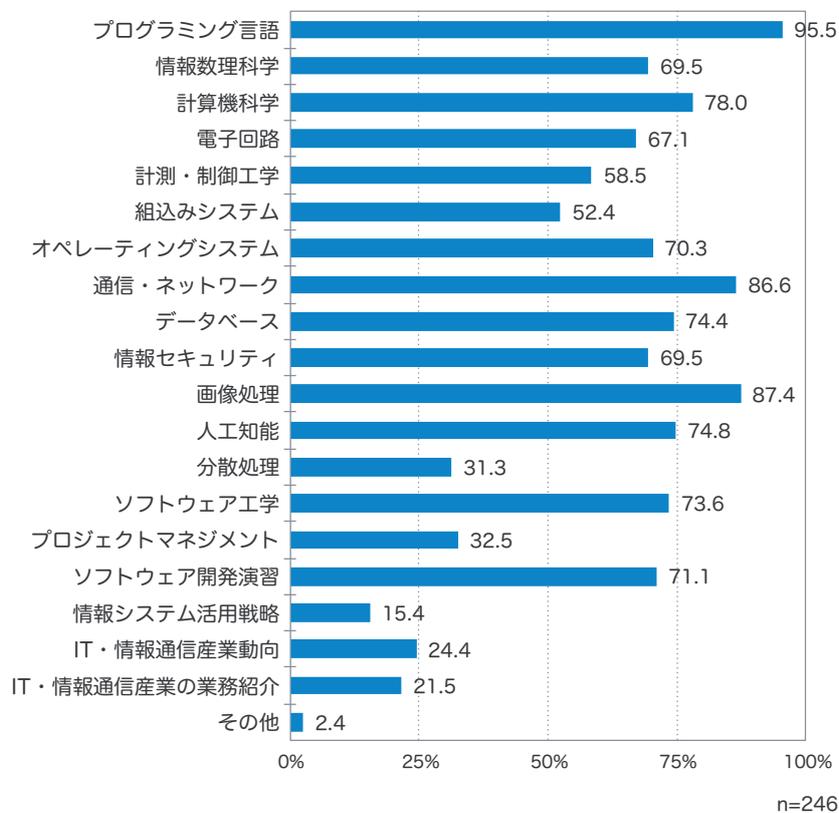
以下に示すグラフは、国内の情報系教育機関における人工知能（AI）に関する教育実態を把握するために実施した、アンケート調査結果に基づくものである。

国内における情報工学・情報科学の教育機能を持つ大学院専攻・学部学科・コース等を対象に、教育活動や学生の動向、教育に関わる課題の把握等を目的としてアンケート調査を行った。調査の概要は以下のとおりである。

- 調査方法：郵送調査
- 調査期間：2017年3月
- 調査対象：情報系教育機関<sup>19</sup>561機関<sup>20</sup>
- 回収数：有効回収数 247機関（有効回収率 44.0%）
- 主な調査項目：
  - AIに関する教育内容
  - AIを学んだ学生の数や進路
  - AIに関する教育を行わない理由、等

### 2.1 AIに関する教育実施状況

[問] 貴学科で実施されている教育内容として、当てはまるものをすべてお選びください。（複数選択可）

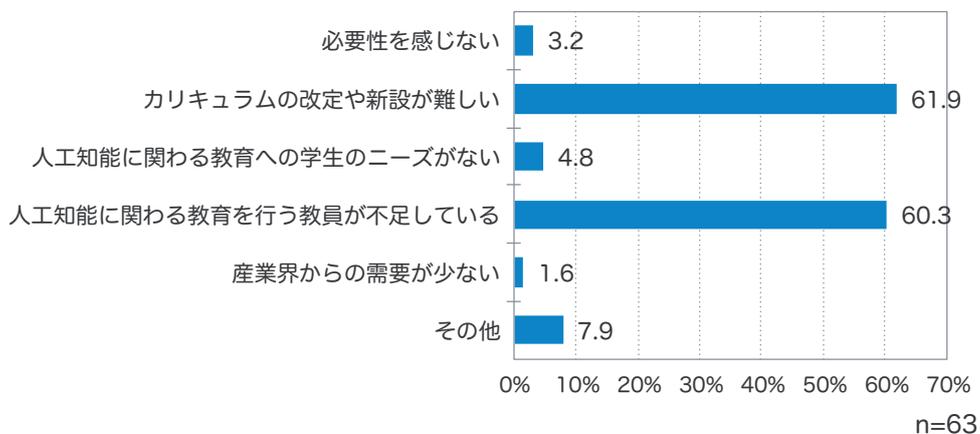


※ 19 高等専門学校、大学学部、大学院を対象とした。

※ 20 大学学部、大学院の取組状況を合わせて回答した機関も含む。

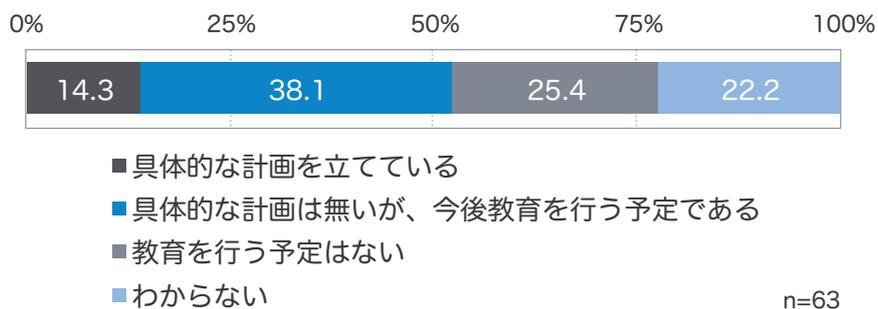
## 2.2 教育を行わない理由<sup>21</sup>

[問] 貴学科が人工知能に関する教育を行わない理由について、当てはまるものをすべてお選びください。  
(複数選択可)



## 2.3 今後の教育実施予定<sup>※3</sup>

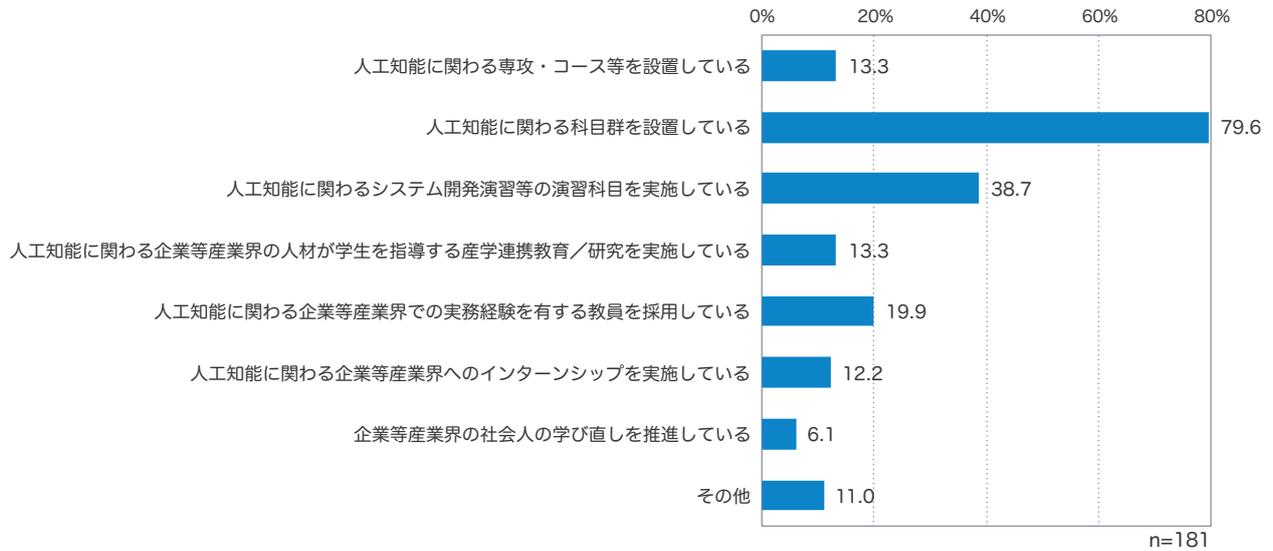
貴学科では、今後人工知能に関する教育を行う予定はありますか。当てはまるものを1つお選びください。



※21 2.1. AIに関する教育実施状況で「人工知能」を回答しなかった機関が対象。

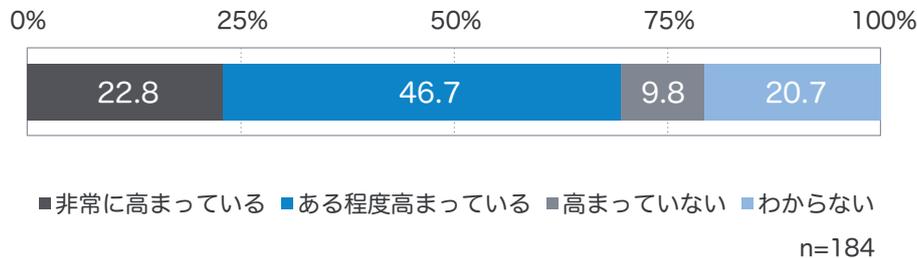
## 2.4 教育内容<sup>※2</sup>

[問] 貴学科における人工知能分野に関する取組についてお尋ねします。貴学科が実施している取組をすべてお選びください。(複数選択可)



## 2.5 学生からの需要<sup>※4</sup>

[問] 人工知能に関する教育について、学生からの需要は高まっていますか。当てはまるものを1つお選びください。



## 2.6 今後の教育に関する意向<sup>※4</sup>

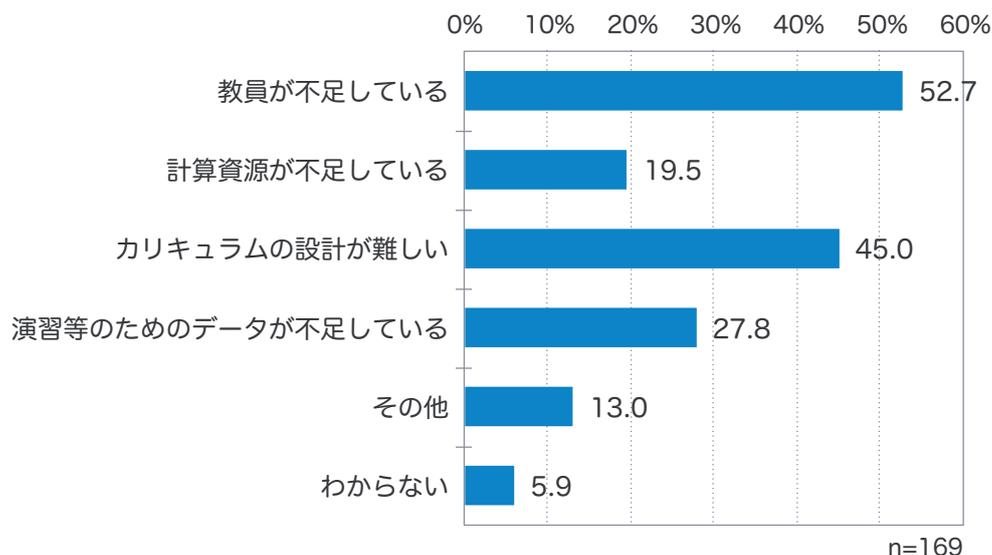
[問] 貴学科では、人工知能に関する教育を今後拡大する予定はありますか。当てはまるものを1つお選びください。



※22 2.1. AIに関する教育実施状況で「人工知能」を回答した機関が対象。

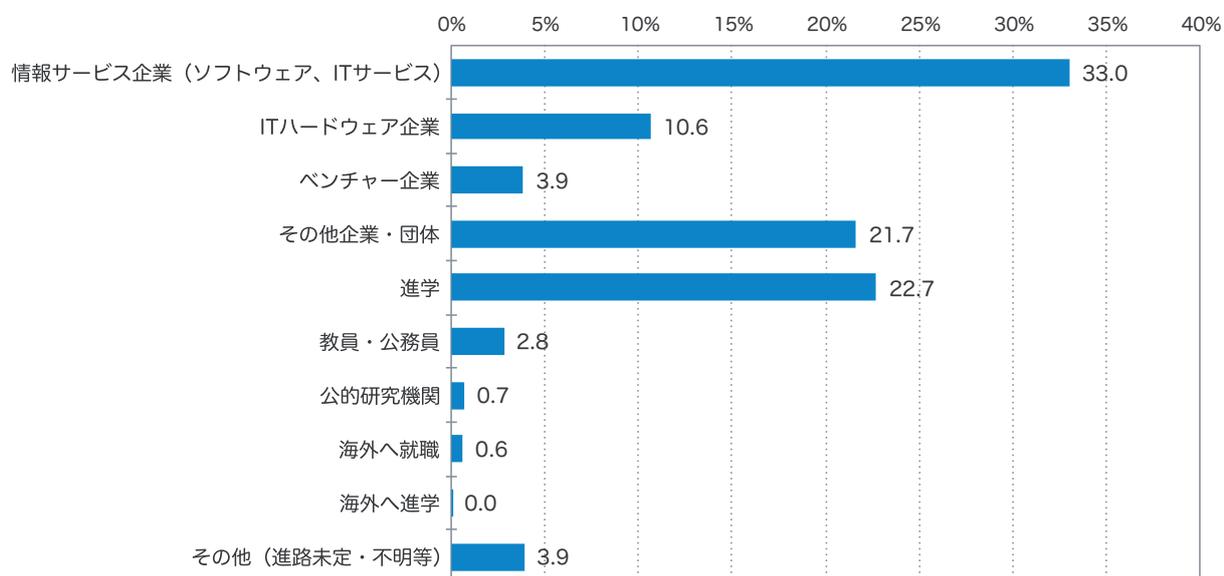
## 2.7 AIに関する教育課題<sup>23</sup>

[問] 貴学科において人工知能に関する教育を行う際の課題についてお尋ねします。当てはまるものすべてをお選びください。(複数選択可)



## 2.8 AIに関する教育を受講した学生の進路<sup>24</sup>

[問] 貴学科において人工知能に関する教育を受けた人材の卒業後の就職先・進路についてお尋ねします。就職先・進路ごとに2015年度の進路別の人数をご記入ください。



※ 23 2.1. AIに関する教育実施状況で「人工知能」を回答した機関が対象。

※ 24 グラフは就職先・進路ごとの学生の割合。いずれかに回答した機関は75機関であった。









## 委員名簿

# 編集委員

(敬称略、五十音順)

### 委員長 中島 秀之

東京大学 大学院情報理工学系研究科 知能機械情報学専攻 特任教授

1983年、東京大学大学院情報工学専門課程修了(工学博士)。通産省工業技術院電子技術総合研究所に入所後、産総研サイバーアシスト研究センター長、公立はこだて未来大学学長を経て、2016年6月より現職。人工知能を状況依存性の観点から研究。マルチエージェントならびに複雑系の情報処理とその応用に興味を持っている。



### 委員長代理 浅田 稔

大阪大学 大学院工学研究科 知能・機能創成工学専攻 教授

1982年、大阪大学大学院基礎工学研究科修了(工学博士)。大阪大学工学部教授を経て現職。同大学先導的学際研究機構システム知能学部門長。国際的なロボット競技会「ロボカップ」の提唱者の一人(2002~8年までプレジデント)。認知発達ロボティクスを提唱し推進している。日本赤ちゃん学会理事。NPOダ・ヴィンチミュージアムネットワーク理事長。



### 委員 川上 量生

株式会社ドワンゴ 代表取締役会長

1991年、京都大学工学部卒業。1997年にドワンゴを設立、2000年代表取締役会長就任。2006年に「ニコニコ動画」を開始。その後も「ニコニコ超会議」や「プロマガ」など、数々のイベントやサービスを生み出している。2014年に、ドワンゴ人工知能研究所を設立した。



### 委員 北野 宏明

株式会社ソニーコンピュータサイエンス研究所 代表取締役社長

1984年、国際基督教大学教養学部理学科卒業、1991年京都大学博士号(工学)取得。1993年にソニーコンピュータサイエンス研究所へ入社。2011年より現職。また2001年にはシステム・バイオロジー研究機構を設立し、会長を務める。「ロボカップ」提唱者の一人で、国際委員会ファウンディング・プレジデント。World Economic Forum(世界経済フォーラム)AI & Robotics Council委員。ソニー株式会社 執行役員コーポレートエグゼクティブ。



### 委員 喜連川 優

国立情報学研究所 所長、東京大学生産技術研究所 教授

1983年、東京大学大学院工学系研究科情報工学専攻博士課程修了(工学博士)、同年東京大学生産技術研究所入所。2007年8月~2008年3月、経済産業省「平成19年度情報大航海プロジェクト」戦略会議議長を務める。2013年に国立情報学研究所所長就任。ビッグデータの第一人者で、そのブームの8年前に情報爆発を提唱。情報処理学会会長等を歴任。



### 委員 辻井 潤一

国立研究開発法人産業技術総合研究所 フェロー 人工知能研究センター 研究センター長

1973年京都大学大学院修士課程修了。1978年同大学博士号(工学)取得。質問応答システム、言語理解の研究に従事。1979年京都大学助教授、1988年マンチェスター大学教授、1995年東京大学大学院教授、2011年マイクロソフト研究所(北京)首席研究員を経て2015年より現職。マンチェスター大学教授兼任。計算言語学会(ACL)、国際計算言語学会(ICCL)の会長を歴任。



### 委員 松尾 豊

東京大学 大学院工学系研究科 技術経営戦略学専攻 特任准教授

2002年東京大学大学院工学系研究科電子情報工学専攻博士課程修了。博士(工学)。同年産業技術総合研究所研究員、2005年スタンフォード大学言語情報研究センター客員研究員、2007年東京大学大学院工学系研究科 准教授就任。2014年より現職。人工知能とウェブ工学を専門とし、人工知能学会の編集委員長、倫理委員長を歴任。



# 執筆委員

(敬称略、五十音順)

|        |   |
|--------|---|
| 浅川 伸一  | 東京女子大学 情報処理センター 助手  |
| 麻生 英樹  | 国立研究開発法人産業技術総合研究所 人工知能研究センター 副研究センター長   |
| 石田 亨   | 京都大学 大学院情報学研究科 社会情報学専攻 教授   |
| 石塚 満   | 国立情報学研究所 コグニティブ・イノベーションセンター 特任教授/センター長  |
| 和泉 潔   | 東京大学 大学院工学系研究科 システム創成学専攻 教授   |
| 井之上 直也 | 東北大学 大学院情報科学研究科 助教  |
| 上野 達弘  | 早稲田大学 大学院法務研究科 教授   |
| 尾形 哲也  | 早稲田大学 理工学術院 基幹理工学部 表現工学科 教授   |
| 小田 悠介  | 奈良先端科学技術大学院大学 情報科学研究科 知能コミュニケーション研究室<br>国立研究開発法人情報通信研究機構 先進の音声翻訳研究開発推進センター<br>先進的翻訳技術研究室 研究技術員                      |
| 金広 文男  | 国立研究開発法人産業技術総合研究所 知能システム研究部門<br>ヒューマノイド研究グループ 研究グループ長   |
| 河原 達也  | 京都大学 大学院情報学研究科 知能情報学専攻 教授   |
| 清水 亮   | 株式会社UEI 代表取締役社長兼CEO<br>東京大学 先端科学技術研究センター 客員研究員  |
| 庄野 逸   | 電気通信大学 大学院情報理工学研究科 情報学専攻 教授   |
| 武田 英明  | 国立情報学研究所 情報学プリンシプル研究系 教授  |
| 田所 諭   | 東北大学 大学院情報科学研究科 教授  |
| 谷口 忠大  | 立命館大学 情報理工学部 情報理工学科 教授  |
| 中原 啓貴  | 東京工業大学 工学院 情報通信系 准教授  |
| 二宮 洋一郎 | 国立情報学研究所 コグニティブ・イノベーションセンター 特任研究員   |
| 野田 五十樹 | 国立研究開発法人産業技術総合研究所 人工知能研究センター 計算社会知能研究チーム<br>総括研究主幹・研究チーム長   |
| 原田 達也  | 東京大学 大学院情報理工学系研究科 知能機械情報学専攻 教授  |
| 比戸 将平  | 株式会社Preferred Networks Chief Research Officer   |
| 平田 圭二  | 公立はこだて未来大学 システム情報科学部 複雑系知能学科 教授   |
| 松井 俊浩  | 情報セキュリティ大学院大学 大学院・情報セキュリティ研究科 教授<br>国立研究開発法人新エネルギー・産業技術総合開発機構 技術戦略研究センター フェロー                                       |
| 松岡 聡   | 東京工業大学 学術国際情報センター 教授<br>産総研・東工大 実社会ビッグデータ活用オープンイノベーションラボラトリ(RWBC-OIL) ラボラトリ長<br>国立研究開発法人産業技術総合研究所 人工知能研究センター 特定フェロー |
| 松原 仁   | 公立はこだて未来大学 副理事長 兼 同大学 システム情報科学部 複雑系知能学科 教授  |
| 宮尾 祐介  | 国立情報学研究所 コンテンツ科学研究系 准教授   |
| 山川 宏   | 株式会社ドワンゴ ドワンゴ人工知能研究所 所長   |

## 執筆協力

(敬称略、五十音順)

|       |                                     |
|-------|-------------------------------------|
| 大淵 栄作 | 株式会社デジタルメディアプロフェッショナル 常務取締役 開発統括部長  |
| 大山 洋介 | 東京工業大学 情報理工学院 数理・計算科学系              |
| 國吉 康夫 | 東京大学 大学院情報理工学系研究科 知能機械情報学専攻 教授      |
| 佐藤 育郎 | 株式会社デンソーアイティラボラトリ 研究開発グループ シニアリサーチャ |
| 野村 哲弘 | 東京工業大学 学術国際情報センター 研究員               |

## 寄稿

(敬称略、五十音順)

|       |   |
|-------|---|
| 安宅 和人 | ヤフー株式会社 CSO(チーフストラテジーオフィサー)<br>データサイエンティスト協会 理事・スキル委員長<br>慶應義塾大学SFC 特任教授<br>人工知能技術戦略会議 産業化ロードマップタスクフォース 副主査 |
| 富山 和彦 | 株式会社経営共創基盤 代表取締役CEO   |

## オブザーバー

(敬称略)

|       |  |
|-------|--|
| 滝澤 豪  | 経済産業省 商務情報政策局 情報処理振興課長                     |
| 田中 伸彦 | 経済産業省 商務情報政策局 デバイス産業戦略室長                   |
| 中 智晴  | 経済産業省 商務情報政策局 情報処理振興課 課長補佐                 |
| 中村 敬子 | 特許庁 総務部 企画調査課長                             |
| 関根 久  | 国立研究開発法人新エネルギー・産業技術総合開発機構 ロボット・AI部 統括研究員   |
| 金山 恒二 | 国立研究開発法人新エネルギー・産業技術総合開発機構 ロボット・AI部 主任研究員   |
| 松田 成正 | 国立研究開発法人新エネルギー・産業技術総合開発機構 技術戦略研究センター 統括研究員 |
| 富田 達夫 | 独立行政法人情報処理推進機構 理事長                         |
| 川浦 立志 | 独立行政法人情報処理推進機構 理事                          |
| 米田 健三 | 独立行政法人情報処理推進機構 参事・戦略企画部長                   |
| 和田 恭  | 独立行政法人情報処理推進機構 技術本部 ソフトウェア高信頼化センター 副所長     |

## 事務局

みずほ情報総研株式会社

本白書の記載内容は、原則として2017年4月までの執筆、寄稿、事務局調査に基づきます。  
本白書中に記載されている会社名、製品名、及びサービス名は、それぞれ各社の商標または登録商標です。本文中には、™及び®マークは記載していません。

本白書は著作権法上の保護を受けています。  
本白書より引用、転載については、IPA Webサイトの「よくある質問と回答」(<https://www.ipago.jp/sec/qa/index.html>)に掲載されている「著作権および出版権等について」をご参照ください。  
なお、出典元がIPA以外の場合、当該出典元の許諾が必要となる場合があります。

問い合わせ先：  
独立行政法人情報処理推進機構 社会基盤センター  
イノベーション推進部 リサーチグループ  
〒113-6591 東京都文京区本駒込2-28-8  
文京グリーンコート センターオフィス  
<https://www.ipago.jp/>

# AI白書 2017

## 人工知能がもたらす技術の革新と社会の変貌

2017年7月20日 初版発行  
2017年8月25日 第1版第2刷発行

編： 独立行政法人情報処理推進機構 AI白書編集委員会  
発行者： 福田 正  
編集人： 遠藤 諭  
発行所： 株式会社角川アスキー総合研究所  
〒113-0024 東京都文京区西片1-17-8 KSビル2F  
<http://www.lab-kadokawa.com/>  
イラスト： 永野雅子  
装丁： 株式会社中嶋デザイン事務所  
デザイン： 株式会社トラエディット  
松田タダシ、羽石 相、石渡克彦、前川敦子  
編集： 中西祥智