

- [10] Dreyfus, H. *What Computers Can't Do: The Limits of Artificial Intelligence*. The MIT Press, 1972. 【邦訳】黒崎政男, 村若修 訳. コンピュータには何ができないか—哲学の人工知能批判. 産業図書, 1992.
- [11] Searle, J. *Minds, Brains, and Programs*. *Behavioral and Brain Sciences*, Vol. 3, No. 3, pp. 417–424, 1980. 【邦訳】守屋唱進 訳, 坂本 監訳. 心・脳・プログラム. マイナス・アイコンピュータ時代の「心」と「私」. 阪急コミュニケーションズ, 1992.
- [12] Penrose, R. *The Emperor's New Mind: Concerning Computers, Minds and The Laws of Physics*. Oxford University Press, 1989. 【邦訳】林一 訳. 皇帝の新しい心—コンピュータ・心・物理法則. みすず書房, 1994.
- [13] Russell, S. and Norvig, P. *Artificial Intelligence: A Modern Approach*. 3rd Edition. Pearson, 2009. 【邦訳】古川康一 監訳. エージェントアプローチ—人工知能 (第2版). 共立出版, 1997.
- [14] 人工知能学会 編. 人工知能ハンドブック. オーム社, 1990.
- [15] Barr, A. and Feigenbaum, E. A., editors. *The Handbook of Artificial Intelligence*. Vol. I, II, III. William Kaufmann, 1981. 【邦訳】田中幸吉, 淵一博 監訳. 人工知能ハンドブック (第I～III巻). 共立出版, 1983.
- [16] Shapiro, S. C., editor. *Encyclopedia of Artificial Intelligence*. 2nd Edition. John Wiley & Sons, 1992. 【邦訳】大須賀節雄 監訳. 人工知能大辞典. 丸善, 1991.

■石塚 満・山田誠二・橋田浩一・新田克己

[1-2]

探索

Search

人工知能はコンピュータによる「知」あるいは「知的振る舞い」を可能にする学問領域と言えるが、対象とする「知」の内容は、時代とともに少しずつ変化している。その時代の通常のコンピュータの利用法の一步先、数歩先の先進の利用法、特に「人間の知」を模倣したコンピュータ利用のフロンティアを、人工知能研究は切り拓いてきた。情報環境の進展と多様化により、人工知能にもいろいろな手法が導入され、アプローチが多様化してきている。本項目では、そのような手法の中でも特に基礎的な探索に関連する方法を紹介する。

問題が与えられてその解決を図る場合、一般のプログラムは解決する道筋を個々に（手続き的に）記述しておく。一方、人工知能によるアプローチでは、解決の道筋を探索（search）によって求めるケースが多い。人間が試行錯誤的思考により未知の問題状況に対して解決法を見出すように、個々の問題の具体的解法を持たなくても、探索により解法を見出すところに人工知能手法の特徴があると言え

る。特に、非常に多様な問題状況に対処する必要がある場合に、このように自動的に解法を探し出してくれる人工知能アプローチは効果的になる。

このように、探索は問題解決の道筋を自動的に見出すことで、知的能力を生む源泉となる。しかし、多くの場合、解決のゴールへ向かう道筋は分岐点ごとに複数の可能な選択肢が存在することから、探索の状態空間（state space）（または状態探索空間（state search space））は指数的に増大してしまうのが普通である。これを組合せ爆発（combinatorial explosion）という。したがって、いかにして効率的探索を達成するかが人工知能研究の初期からの大きな課題であった。

状態空間探索の定式化

多くの探索問題は、図1 (a) に示すように、スタート状態から出発し、状態を変化させる可能なオペレータの適用を繰り返し、ゴール状態に到達する経路を見出すこととして枠組みを設定できる。図1 (b), (c) には、それぞれ迷路と8-パズル（8-puzzle）を具体例として示している。8-パズルは、空き位置へ数字が書かれたタイルを移動させながら整列させるパズルである。通常遊びに使うのは15-パズル（4×4マス）で、8-パズルはこの縮小版である。

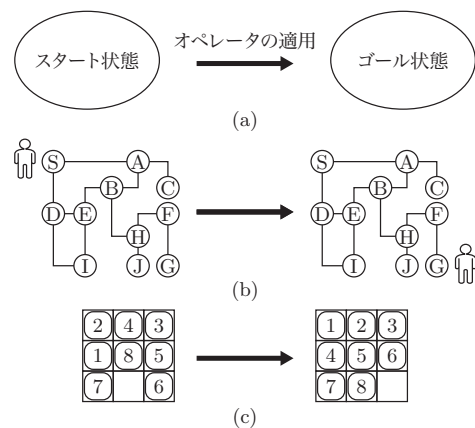


図1 スタート状態からゴール状態への状態空間探索

オペレータは、迷路の例では道によって繋がれた次の地点への移動、また8-パズルの例では空き位置への上下左右のタイルの移動であり、オペレータの適用により次々と状態が推移することになる。ある状態からオペレータにより移れる次の状態を継続状態（successor state）という。探索は、このような状態空間の中でゴール状態を達成する経路を見出すことである。

状態をノードで表し、オペレータによって移行可能な継続状態をリンクで繋いで表すと、状態空間の探索はスタート状態を表す開始ノード（start node）を根とし、ゴール状態を表す目標ノード（goal node）を葉とする木探索（tree

search) と見なせる。中間に同じ状態を表すノードが複数生じる場合には、それらのノードを一つに併合すると、より一般的なグラフ探索 (graph search) になる (この同一のノードでも、到達した経路が異なる場合には、別ノードとすれば木探索にすることができる)。

開始ノードを根とし、継続ノード (子ノードとも呼ぶ) を次々に生成して目標ノードを見つける際、あるノードで継続ノードを生成することを「ノードを展開する」という。あるノードが可能なすべての継続ノードを生成し尽くしているとき「ノードが閉じている」(closed) といい、未生成の継続ノードが残っているとき「ノードが開いている」(open) という。CLOSE ノード (CLOSE node) は調査済みノードであり、OPEN ノード (OPEN node) は調査が未完了のノードである。

どのような順序で展開するノードを選ぶかは探索手法により異なり、それが探索手法を特徴付ける。AND/OR グラフ探索 (AND/OR graph search) においては、開始ノードを根として伸びるおのおのの部分グラフをそれぞれの状態と見なして探索が行われることになる。

基本探索手法

基本的な探索手法は、ゴールへの距離の推定値などの情報を用いない情報なし探索 (uninformed search) あるいは盲目的探索 (blind search) と、それらの情報を利用する情報あり探索 (informed search) に大別される。情報なし探索は系統的探索となるが、別の面で見ると力づく探索 (brute force search) とも言える。情報あり探索は、利用する情報が常に正しい選択をもたらすとは限らないという意味でヒューリスティックス (heuristics) (p.6[1-d] 参照) の一種となることから、ヒューリスティック探索 (heuristic search) と呼ぶこともできる。

最も基本となるのが情報なし探索の代表である、深さ優先探索 (depth-first search) (縦型探索と呼ばれることもある) と幅優先探索 (breadth-first search) (あるいは横型探索) である。両者の探索効率に大差はないが、所要メモリ量は大きく異なる。横型探索では、探索が深くなるにつれて、所要メモリ量は指数的に増大してしまう。一方、縦型探索は探索の深さの上限を定めておき、その上限まで探索を進めてもゴールを見出せないときにバックトラック動作を行わせることでメモリ量をコントロールできる。しかし、深さ限界を事前に適切に定めることは難しいという問題と、最初に見出されるゴールが最も浅い (開始ノードから最も手数の短い) 解の経路であるとは限らないという問題がある。

幅優先探索と深さ優先探索のこれらの問題点を、探索量の増加を幾分許容することによって解決しようとするのが、反復深化 (iterative deepening) 法である ([1-7] 参照)。深さ優先探索を基本とする深さ優先反復深化 (depth-first

iterative deepening; DFID) 法は、その深さ限界を一つずつ増加させながら繰り返し縦型探索を行う。

迷路や8-パズルのようにゴール状態が陽にわかっている場合には、開始ノードと目標ノードの両方から探索を進める双方向探索 (bi-directional search) は、効率を上げるために有効となる。また、開始ノードから目標ノードへの経路の途中に、解経路が通るであろうことが確からしい中間ノードを見出すことができる場合、このような中間ノードを島として、これを起点に開始ノード方向と目標ノード方向への探索を行う方法を島駆動探索 (island-driven search) という。

山登り法 (hill-climbing method) ([1-4] 参照) は、ゴールへ最も近づく経路を選択して進んでいく、最も直接的な探索法である。ゴールへ近づく経路ばかりを選択するので、ゴールではないローカルな極値となるノードで行き詰まってしまうことがしばしば起こることが問題である。制約を満たす最終的な解を求めることが課題であり、探索の初期点を関知しないような場合、この問題に対処する簡単な方法は、行き詰まってしまったら探索の初期点をランダムに選び直す (ランダム再スタート) ことである。SAT 問題 ([1-13] 参照) に対して、この山登りとランダム再スタートの考え方を適用した方法がGSAT ([1-4] 参照) であり、制約が緩く多数の解が状態空間内に分散して存在する場合に、効率的であることが示されている。以上は離散状態空間探索の山登り法だが、アナログ関数の最大値 (最小値) 探索に用いられる山登り法も、同様な趣旨を持つ。

最良優先探索 (best-first search) ([1-5] 参照) も山登り法と同じくコスト (cost) (現探索点からゴールへの距離) の推定値に基づき探索を進める。ただし、展開して得られた継続ノード (子ノード) をすべて保持するところが異なり、保持するノードの中で評価値が最も良いノードを展開していく。展開して生成したすべてのノードを探索のフロントとして保持するので、山登り法のように行き詰まる問題はないが、横型探索に似て、探索が進むにつれてノードを保持するためのメモリ量が増大してしまう。このメモリ量増大の問題を解決し、近似的な最良優先探索を実現するのがビーム探索 (beam search) である。ビーム探索では、評価値が上位 n 個 (n はビーム幅) のノードのみを保持するようにする。

最良優先探索はコストに着目して探索を進めるので、ゴールが見出されたとしても、その経路は必ずしもコスト最小の最適経路であるとは限らない。これに対し、A* アルゴリズム (A* algorithm) ([1-6] 参照) は、開始ノードから現探索点までの距離と、現探索点からゴールまでの距離 (コスト) の推定値に基づいて探索を進めることで、適格性条件と呼ばれるある条件下で最適経路 (最小コスト経路) を効率的に見出す。A* アルゴリズムは AI の代表的な探索法であり、分枝限定法の特例な場合に関係している (p.19[1-f] 参照)。

A*アルゴリズムでもメモリ量の増大は深刻な問題となる。幾分かの探索量の増加を許容してこれに対処する方法が反復深化の適用であり、反復深化A* (iterative-deepening A*; IDA*) ([1-7] 参照) となる。

情報あり探索あるいはヒュリスティック探索は、コスト (現探索点からゴールまでの距離) の推定値などの情報が利用できる場合に、これを利用し優先して探索すべき経路を選択することで探索の効率化を図る。

AND/OR グラフ探索の解 (ゴール) は問題を AND 関係と OR 関係の部分問題への分割で解くことができる解グラフであり、状態の考え方が以上とは異なる。この AND/OR グラフ探索に A*アルゴリズムの考え方を適用したのが AO*アルゴリズム (AO* algorithm) である。

チェスや囲碁などの有限確定2人ゼロ和完全情報ゲーム (two-player finite zero-sum game with perfect information) は、人工知能の知的能力を示すわかりやすい指標になるため、人工知能研究の初期から研究対象になってきた。このようなゲームにおける探索も、状態が指し手により変換されていく状態空間探索として表すことができる。しかし、2人のプレイヤーが交互に指すので、交互に反対の目的を持つ指し手が選択されることになり、ゲーム木 (game tree) (あるいはミニマックス木) の探索となる。探索法はミニマックス探索 (mini-max search) 法が基本となるが、それを効率化するアルファベータ探索 (alpha-beta search) 法が中心的な役割を果たすことになる。

確率的探索法 (stochastic search) は、山登り法が局所最適点で行き詰まる (捕獲される) 問題を回避する方策を与える。シミュレーテッドアニーリング (simulated annealing; SA) ([1-9] 参照) と、複数の個体 (探索点に相当) からなる集団による遺伝的操作で探索する遺伝的アルゴリズム (genetic algorithm; GA) がその代表である。タブー探索 (tabu search) も局所最適点への捕獲を回避する効果的な方法を与える。これらの探索のゴールはある評価関数によって定まる最適解 (あるいは、それにできるだけ近い準最適解) であり、離散状態空間の最適化問題を対象にすることになる。この場合、ゴールに至る経路は問わない探索問題である。

■ 石塚 満・山田誠二・橋田浩一・新田克己

[1-3]

深さ優先探索と幅優先探索

Depth-First Search and Breadth-First Search

状態空間の木探索による問題解決において、状態空間中のスタートノードからゴールノードに至る経路の探索手法の最も基礎となるのが、**深さ優先探索** (depth-first search) (日本では「縦型探索」と称されることもある) と**幅優先探索** (breadth-first search) (「横型探索」と称されることもある) である。深さ優先探索と幅優先探索はゴールへの距離の推定値情報を用いないことから、この情報を利用する情報あり探索 (informed search) と対比して、**情報なし探索** (uninformed search) あるいは**盲目的探索** (blind search) に分類される。

深さ優先探索は、深さ方向を優先してノードを展開し、探索を進める (新継続 (子) ノードを生成して調査することを「展開する」と称する)。ゴールノードに到達せずノードの展開ができなくなったら、未展開の移動可能な継続ノード (子ノード) を持つノード (OPEN ノード) にバックトラック (backtrack; 後戻り) し、展開を続ける。不必要な深さまで縦型に進行してしまうことがあるので、ある**深さ限界** (depth cutoff) を定めておき、この深さ限界まできてもゴールノードが見つからないときもバックトラックするようにする。図1 (a) は迷路であり、スタートノードからゴールノードへ至る経路を探索する場合で、図1 (b) のノードの左肩の数字は深さ限界を5としたときの深さ優先探索のノード展開順序を示している (以前に調べた祖先ノードに存在する同じノードに戻ってしまう場合も、探索を中止してバックトラックするようにしている)。

幅優先探索は、スタートノードから深さが浅いノードを優先して展開していく。図1 (b) のノードの右肩の△内の数字は幅優先探索のノードの展開順序を示している。

深さ優先探索では、スタートノードから現在の探索ノードまでのルート上のノードの OPEN 子ノード (未調査ノード) だけを保持していればよいので、各ノードでの平均分枝数を b 、探索の深さを d としたとき、所要メモリ量は d の線形オーダー ($O(d)$) であり、大きくはない。これに対し、幅優先探索では、所要メモリ量は探索の深さ d の指数オーダー ($O(b^d)$) となり、これは非常に大きく、しばしば実用的に手の負えない量となってしまう。

幅優先探索は深さ最小のゴールノードを最初に発見できるのに対し、深さ優先探索は無限に深い枝に進んでしまうことがないように探索の深さ限界を定める必要があり、また、最初に見つかるゴールノードは深さ最小のゴールとは限らない。深さ優先探索と幅優先探索の計算効率について

独逸哲学の研究者でもある B. Smith が最も著名である。そのオントロジーに関する業績は、彼自身の Web サイト (<http://ontology.buffalo.edu/smith/>) から確認することができる。

参考文献

- [1] 加地大介. 穴と境界：存在論的探究. 春秋社, 2008.
- [2] 鈴木生郎, 秋葉剛史, 谷川卓, 倉田剛. 現代形而上学：分析哲学が問う人・因果・存在の謎. 新曜社, 2014.
- [3] 山内志郎. 普遍論争：近代の源流としての. 平凡社, 2008.
- [4] Gallois, A. Identity Over Time (The Stanford Encyclopedia of Philosophy), 2012. <http://plato.stanford.edu/archives/sum2012/entries/identity-time/>
- [5] Varzi, A. Mereology (The Stanford Encyclopedia of Philosophy), 2015. <http://plato.stanford.edu/archives/sum2015/entries/mereology/>
- [6] 柏端達也. 行為と出来事存在論：デイヴィドソンの視点から. 勁草書房, 1997.
- [7] Casati, R. and Varzi, A. Events (The Stanford Encyclopedia of Philosophy), 2014. <http://plato.stanford.edu/archives/fall2014/entries/events/>
- [8] Nelson, M. Existence (The Stanford Encyclopedia of Philosophy), 2012. <http://plato.stanford.edu/archives/win2012/entries/existence/>
- [9] Strawson, P. F. *Individuals: An Essay in Descriptive Metaphysics*. Routledge, 1959. 【邦訳】中村秀吉 訳. 個体と主語. みすず書房, 1979.
- [10] Searle, J. R. *The Construction of Social Reality*. Free Press, 1995.
- [11] Searle, J. R. *Making the Social Worlds: The Structure of Human Civilization*. Oxford University Press, 2010.
- [12] Gallotti, M. and Michael, J., editors. *Perspectives on Social Ontology and Social Cognition*, Vol. 4 of *Studies in the Philosophy of Sociality*. Springer, 2014.
- [13] Chalmers, D. J., Manley, D., and Wasserman, R., editors. *Metametaphysics: New Essays on the Foundations of Ontology*. Oxford University Press, 2009.
- [14] Guarino, N. Artefactual Systems, Missing Components and Replaceability. In Franssen, M., Kroes, P., Reynodon, T. A. C., and Vermass, P. E., editors, *Artefact Kinds: Ontology and the Human-Made World*, Vol. 365 of *Synthese Library*, pp. 191–206, Springer, 2014.

■ 鈴木生郎

[2-22]

人工知能と倫理

Artificial Intelligence and Ethics

人工知能の専門家たちが倫理 (ethics) に真剣な関心を持つようになったのは、比較的最近のことかもしれない。例えば、日本の人工知能学会でも倫理委員会 (ethics committee) が2007年には存在していたが、実質的な活動が行われ始めたのは2014年になってからである [1]。

スチュアート・ラッセルとピーター・ノーヴィグの著作『エージェントアプローチ人工知能』では、初版 (原著1995, 翻訳1997) から人工知能の哲学的基礎が内容に含まれていたが、そこには倫理問題は含まれていなかった [2]。この教科書で人工知能技術に関連する倫理という話題が取り扱われるようになったのは、第2版 (原著2003, 翻訳2008) からである。第3版 (2009) で言及されている問題は、雇用の喪失を含めた労働のあり方が変化する可能性、軍事や監視などの望ましくない目的に利用されるおそれ (いわゆるデュアルユース (dual use) の問題)、人工知能システムを利用することに関連して生じる可能性のあるアカウントビリティ (accountability) 喪失の問題、人工知能の登場によって人類が特別であるという感覚が失われ、ひいては人間性の喪失をも招く可能性、人間を超える超知能が誕生するシンギュラリティ (singularity) の可能性や、それに伴う人類の終焉の可能性、などである。

研究者や開発者に要求される専門職倫理 (professional ethics) や、プログラムのバグや誤った判断に起因して生じる可能性のある問題などは、それ自体としては新しい議論ではなく、情報倫理学 (information ethics) やコンピュータ倫理学 (computer ethics) [3] といった分野などですでに論じられてきたものである。日本でも1998年から2003年にかけて京都大学大学院文学研究科、広島大学文学部、千葉大学文学部によって行われた「情報倫理の構築」(FINE) プロジェクトなどにより、これらの分野については議論の蓄積がなされている。とはいえ、そうした議論は人工知能技術に限定されたものではなかった。コンピュータやインターネットの普及に伴う問題が主であっただけでなく、プライバシー (privacy) や著作権などの一部の議論は情報技術全般の社会的影響という話題にすら収まるものではなく、われわれの社会における自由や知識のあり方という、より射程の長い、普遍的な議論を含んでいたのである。

そもそも人工知能技術に固有と言える倫理問題は、実際のところ、どれほどあるのだろうか。例えば完全に自律的な兵器 (fully autonomous weapon) の登場に対する懸念

が近年高まっており、それらによる誤爆のために死者が出た場合、兵器自身以外に責任を負わせようの行為者が存在しないという事態が生じるのではないかという議論がなされてきている。人工知能への帰責可能性という、このような議論も実は新しいものではない。土屋俊 [4] によれば、「1970 年代以降の計算機の高速化、高度化の流れの中で、次第に計算機が、人間的な大きさをもちつつ人間的な速度で知覚し、思考し、判断することが夢ではなくなり、かつ、機能を限定したロボットが生活の中に浸透してくるようになると … その結果、そのような社会において人工知能的な判断力がそもそも人格的なものであるか否かということ論じることの意味が与えられるようになった」のであるが、結局のところ「この問題は、確かに興味深い問題ではあるが、人工知能が工業製品である以上は、その振る舞いがいかに知的であろうとも、その工業製品をわれわれの生活のどのような文脈に埋め込み、誰の責任においてそれを使用するかという問題に過ぎない。このような認識は、次第に浸透し、人工知能の責任などという問題を倫理学の観点から扱うことは少なくなっていく」。少なくとも責任という論点に関しては、人工知能は他の工業製品から特に区別する必要のあるものではないという評価がなされたというのである。そして、この評価は現在でも変わらないだろう [5]。

上で挙げたラッセルとノーヴィグが扱っている問題で言えば、シンギュラリティ、人間性の喪失、人類の終焉の可能性などが、「人工知能が」人類にもたらす事態として主張されている問題の例ということになる。しかしながら、これらの問題についてはその現実性が議論なしに受け入れられているとは言えない。

必ずしも固有とは言えない問題や、現実性があるかわからない問題も含めて、人工知能に関連して検討しておくべき倫理問題はいくつかのグループに分類できるだろう。例えば 1) 人工知能技術がもたらす社会的影響と、2) 人工知能研究・開発者に要求される専門職倫理に関連する問題がある。また、人工知能技術が社会に浸透していく将来を想定するなら、3) 一般消費者を含めた利用者側で生じる可能性のある倫理問題も検討しておく必要があるだろう。さらに言えば、4) 責任を含めた人工知能技術そのものの倫理性の問題についても、現時点における評価とは別に、議論することが可能である。1) の例としては人工知能の発展に伴って技術的失業 (technological unemployment) が生じる可能性とそれに対する社会的対策などがある [6]。2) については、2016 年度人工知能学会全国大会の際、人工知能学会倫理委員会が公開討論において「人工知能研究者の倫理綱領 (案)」を提示し、会場からの意見も受けた上でディスカッションを行っている。3) に該当する問題の例としては、防犯や監視を目的とした人工知能技術の応用が考えられるが、これは情報技術と監視という既存の議論に新たな要素が加わったものとなる。4) に関連しては、

人間を超える能力を得た人工知能が人間に敵対することがないように、何らかの安全機構について今から研究しておくべきではないかといった提案がなされている。

ここで注意が必要なのは、これらは排他的な分類ではないということである。自動運転車 (autonomous car) のトロロッコ問題 (trolley problem) あるいは衝突最適化問題として知られている問題を例に考えてみよう [7]。搭乗者、歩行者、他の車両の搭乗者などの少なくとも誰かに、死に至る可能性を含む重大な危害を与えざるを得ない状況に陥った場合、完全に自律的な自動運転車は誰に衝突することを選択するよう設計されるべきなのだろうか。例えば死者の数を最小限にするように自動運転車が判断し、その判断どおりの帰結をもたらしたとすれば、その自動運転車は可能な限り倫理的に最善の判断を下したと見なしてよいのだろうか。これは自動運転技術が社会にもたらしうる倫理問題であると同時に、そのような技術をどのようなものとして、またどのような価値観に基づいて研究開発すべきであり、かつもたらされる帰結に対してどのような責任を負うのかという専門職倫理の問題でもある。また消費者や市民の観点から見れば、そのような技術を拒絶することも含めて、技術のあり方に社会の価値観をいかに反映させるかという問題として、この問題は議論される必要がある。このことが意味するのは、人工知能技術に関連する特定の倫理問題を複数の倫理的観点から検討するのが適当である (少なくとも、そのような場合がある) ということだろう。

人工知能技術がより高性能になり、より広く普及していくであろう今後において、それに関連した倫理を考えていく上での基本的な方向性はどのようなものであるべきだろうか。ここでは 2 点だけ挙げておきたい。第一に、出現しつつある技術については、その技術そのものだけでなく、それを取り巻く制度や社会についても、それらがどのようなものであるべきか、あるいはそれらをどのようなものとしてわれわれは作り上げていくのかというデザインの観点に基づいて議論がなされるべきであろう。例えば人工知能学会の倫理委員会という仕組みがどのような「あるべき姿」に向けて作られていくのかは、日本における人工知能技術のあり方に大きな影響を与える、重要な社会的倫理問題の一つと言えるだろう。第二に、そのようなデザインは人工知能研究開発者という狭い専門職集団の観点だけでなく、倫理や法といった人文社会科学系の観点、さらには社会一般の観点にも基づかなければならない。このように言うと、倫理学者が余計な介入の機会を狙っているのかと、人工知能研究開発者は身構えてしまうかもしれない。そのため、技術開発を推進する立場から、技術の進歩に対して倫理や法はブレーキではなくハンドルとして働くべきとの予防線を張るような主張がなされることもある。実際、これは倫理学の側から見ても、一般的には正しい主張であるように思われる。ただし、それが正しい主張であ

るためには、前に進もうとする車体がハンドルからの入力にきちんと反応できなければならないのである。

参考文献

- [1] 松尾豊, 西田豊明, 堀浩一, 武田英明, 長谷敏司, 塩野誠, 服部宏充. 人工知能学会倫理委員会の取組み. 人工知能, Vol. 30, No. 3, pp. 358–363, 2015.
- [2] Russel, S. and Norvig, P. *Artificial Intelligence: A Modern Approach*. Prentice Hall Series in Artificial Intelligence. Prentice Hall, 1995. 【邦訳】古川康一 監訳. エージェントアプローチ—人工知能. 共立出版, 1997.
- [3] Johnson, D. G. *Computer Ethics*. 3rd Edition. Prentice Hall, 2001. 【邦訳】水谷雅彦, 江口聡 編訳. コンピュータ倫理学. オーム社, 2002.
- [4] 土屋俊. 第1章 コンピュータ・エシックス? インターネット・エシックス? 水谷雅彦, 越智貢, 土屋俊 編, 情報倫理の構築, ライブラリ電子社会システム, pp. 1–38, 新世社, 2003.
- [5] 神崎宣次. インテリジェントなエージェントはモラルなエージェントとみなされ得るか? 人工知能, Vol. 29, No. 5, pp. 489–493, 2014.
- [6] 井上智洋. 人工知能と経済の未来—2030年雇用崩壊. 文藝春秋社, 2016.
- [7] Lin, P. Why Ethics Matters for Autonomous Cars. In Maurer, M., Gerdes, J. C., Lenz, B., and Winner, H., editors, *Autonomous Fahren*, pp. 69–85, Springer, 2015.

■ 神崎宣次

[2-23]

ロボット倫理学

Robot Ethics

はじめに

ロボット倫理学は、ロボット技術に関する倫理的問題を扱う応用倫理の一分野である。ここで言う「ロボット」には、自律的に行動する機械のほか、ソフトウェアエージェント (software agent)、遠隔操作される無人機、人間の認知や行動をサポートする電子式・機械式の装具なども含まれる。

かつてはロボットが実際に使用されるのは、工場などの特定の閉じた環境に限られていた。しかし、現在ではロボットは、オフィス、家庭、店舗、公共のスペースなど、社会のさまざまな場面、そしてしばしばオープンな場面で応用されるようになってきている。そのようなロボットたちは、ロボットのオペレータや協働作業員ではない一般の人々と接触し、そして必ずしも想定されていないような状

況に遭遇することになる。それゆえにロボットたちがさまざまな仕方ではたいて人々に危害を及ぼす懸念が高まっている。ロボット倫理学はこのような背景のもとに生まれ、発展してきた。

ロボット倫理学は第一にロボットの導入が人間と社会に与える影響について考察し、開発者・製造者・利用者の守るべきルールについて考えるものである。他方で、ロボット倫理学には道徳的に判断し行動する能力をロボットに持たせる可能性や方法、その是非について考察するという側面もある。そしてまた、外見、振る舞い、能力においてますます人間に近づくロボットは、われわれに「ロボットをいかなる存在者として扱うか」という問いを突きつける。こういった問題について考えるのも、ロボット倫理学の重要な課題である。

ロボットが引き起こす倫理的問題

本節では、ロボットが具体的にどのような倫理的問題を引き起こすのかを考察しよう。

プライバシー

現在、われわれの身の回りのさまざまなデバイスに情報収集・情報処理・情報通信機能が付加され「モノのインターネット」(Internet of Things; IoT)と呼ばれるネットワークを構成している。これからわれわれの身近で活動するロボットの多くはモノのインターネットの中に接続され、常時ユーザーの情報あるいは周囲の環境の情報を収集し、それを他のデバイスと共有し合うようになるだろう。現在 Google やソフトバンクのような ICT 企業がロボットの開発・普及に力を入れていることから、そのことが伺える。おそらくロボットはパソコンやスマートフォン、あるいは他のデバイスでは集めることのできない実世界の豊かな情報を吸い上げるための能動的なセンサの役割を果たすだろう。しかし、このことはプライバシー (privacy) を重視する人々との間に摩擦を生じさせる可能性がある。実際、すでにプライバシーの問題は Google Glass のようなウェアラブルデバイス (wearable device) や、ドローン (drone) などの遠隔操作型の無人航空機などに関して生じている。われわれの生活に密着して自律的に行動、情報収集するロボットに関しては、この問題はより一層深刻になるだろう。

責任

近年、多くの企業、研究機関が自動運転車 (autonomous car; self-driving car) の開発を進めているが、自動運転車が事故を起こしたときの責任 (responsibility) の所在がしばしば問題にされる。自動車の運転手はときに重大な倫理的帰結をもたらす判断を迫られることがある。例えば対向車が中央線を越えてこちらに向かってきたときに、急いでハンドルを切れば自分は助かるが歩行者に重傷を負

するものと言えよう。なお、漸近的手法によらない解析が Freundら [3] により与えられており、より広いクラスの仮説空間について基本的に上記のような結果が成り立つことが示されている。

コミッティによる質問学習の現実問題への適用

コミッティによる質問学習を実際に適用する際の課題の一つに、ベースの学習法として理論上用いられているギブス学習法が現実的でない場合が多いことがある。現実問題に対して、手もとにある任意の学習アルゴリズムを用いてコミッティを構成でき、有効な質問学習を行う方法の例として、バギングによる質問学習 (query by bagging) が挙げられる [4]。この方法においては、受動学習用のアンサンブル学習 (ensemble learning) 法であるバギング (bagging) を用いて構成された仮説の集合を質問学習用のコミッティとして用いている。これにより、アンサンブル学習による精度向上の効果と、コミッティ学習による事例数の削減の効果の両方が得られる。このアプローチによる実世界問題への適用例として、免疫学における重要問題の、ある特定のT-細胞により「認識」されるペプチド (長さ10程度のアミノ酸の列) の部分集合の同定問題への適用がある [5]。この問題は、ワクチンの開発などの重要な応用可能性があるが、一つのペプチドを生成しその活性度を測る実験が高価であるため、 20^{10} に及ぶペプチド集合のうちいかに少数のペプチドの実験で精度高く活性関数を学習できるかが課題となる。バギングによる質問学習とペプチド文字列に関するドメイン知識を構造に盛り込んだ隠れマルコフモデルの学習を組み合わせることにより、必要実験数の大幅な削減が達成されている。

コミッティによる質問学習の改良と能動学習応用の展望

コミッティによる質問学習における理論的な問題点の一つに、学習対象の仮説が確率的な場合に、学習不足とは無関係に本来的に不確実性の高い領域に質問が集中してしまう可能性があるという点があった。近年、学習対象が確率的な設定 (例えばガウス過程 (Gaussian process; GP)) を用いて、この2種類の不確実性を区別することによりこの欠点を克服したベイズの能動学習 (Bayesian active learning) と呼ばれる手法が提案され、実験的にもコミッティによる質問学習を超える精度が達成されている [6]。この手法およびその最適化への応用であるベイズ的最適化 (Bayesian optimization) は、深層学習 (deep learning) のハイパーパラメータ学習への適用や材料設計などにおける実験計画への適用でも成功を取っており、能動学習の活躍場面は今後もさらに増えていくことが期待される。

参考文献

- [1] Seung, H. S., Oppor, M., and Sompolinsky, H. Query by Committee. In *Proc. the Fifth Annual Workshop on Computational Learning Theory*, pp. 287–294, 1992.
- [2] Angluin, D. Queries and Concept Learning. *Machine Learning*, Vol. 2, No. 4, pp. 319–342, 1988.
- [3] Freund, Y., Seung, H. S., Shamir, E., and Tishby, N. Selective Sampling Using the Query by Committee Algorithm. *Machine Learning*, Vol. 28, pp. 133–168, 1997.
- [4] Abe, N. and Mamitsuka, H. Query Learning Strategies by Boosting and Bagging. In *Proc. Fifteenth International Conference on Machine Learning*, pp. 1–9, 1998.
- [5] Udaka, K., Mamitsuka, H., Nakaseko, Y., and Abe, N. Empirical Evaluation of an Experimental Design Method for Predicting Binding Class-I Peptides. *Journal of Immunology*, Vol. 169, pp. 5744–5753, 2002.
- [6] Houlisby, N., Huszar, F., Ghahramani, Z., and Lengyel, M. Bayesian Active Learning for Classification and Preference Learning, 2011. (arXiv preprint arXiv:1112.5745).

■ 安倍直樹

[6-10]

強化学習

Reinforcement Learning

概要と研究の流れ

強化学習とは、行動系列の結果に対する正負のフィードバック情報を表す報酬 (reward) を手がかりに、学習主体が経験の活用 (exploitation) と新たな探索 (exploration) との間で試行錯誤し、累積的な報酬の期待値を最大化する行動系列を学習する手法である。強化学習は、人、生物、システムが直面する意思決定 (decision making) 問題に適用でき、AIとさまざまな分野とを結び付ける可能性 [1] を秘めている。近年は自律システム [2][3] だけでなく、教師データがない場合にデータを集める技術や、隠れた状態を持つ未知の環境に対する最適化技術 [4] として期待されている。強化学習の主要な研究分野は、転移学習 (transfer learning)・構成的表現・確率モデルなどを含む機械学習 [5]、ニューラルネットワーク [6]、ロボティクス (robotics) [7] などである。

強化学習の源流は、学習心理学 [8] での試行錯誤学習、1957年のベルマンによる最適制御問題における動的計画法 (DP)、そして進化計算分野の学習分類システムである。1980年代にバルト、サットンらによって行動選択器 ASE と報酬の予測学習器 ACE とを組み合わせた試行錯誤

学習の計算モデル (actor-critic 法の原型) および, ACE の学習アルゴリズムである TD 法が提案された. その発展として, 1992 年に最適方策への収束条件が Q 学習 (Q learning) で証明され, これらのモデルレス手法と DP に基づくモデルベースアプローチ (model based approach) とで強化学習分野が形成された. 1990 年代は, 隠れ状態を許す部分観測マルコフ決定過程 (partially observable Markov decision process; POMDP) や複数の学習主体を扱うマルチエージェント環境 (multi-agent environment) へと問題のクラスが拡張された. 2000 年代以降では, 行動履歴と既知のモデルから報酬関数を生成する逆強化学習法, 探索と活用のトレードオフ (exploration/exploitation tradeoff) の理論的解析 [9], 真のモデルを一つでなく確率分布と見なすベイズ推定 [10] に基づく強化学習などの理論的研究を背景に, さまざまな実用化研究が注目されている. 2013 年には, 広範囲の強化学習研究のリレー解説が, 学会誌で 1 年間連載 [1] された.

四つの特徴

強化学習の特徴を, 学習目標 (learning goal) 設定, 行動選択, モデルと価値, 最適性基準の四つに分けて述べる.

学習目標を所望の行動に対する報酬関数で表す

第一の特徴は, 設計者が「何をすべきか」(学習目標)を報酬で指示すれば, 「どのように実現するか」(行動系列)が試行錯誤によって獲得される点である. 報酬は特定の行動 (状態 s と行為 a とのペア (s, a) を行動 (behavior) と呼ぶ) にスカラー値で設定され, 正の報酬に近づき, 負の報酬を回避する行動系列の学習が進む. 強化学習の特徴は, 状態入力と行為出力との写像の学習において, 設計者の所望の入出力 (行動) の場合にのみ報酬が発生し, それ以外はまったく評価されないことであり, 正しい入出力を直接教示する教師あり学習 (supervised learning), まったく教示しない教師なし学習 (unsupervised learning) どちらとも異なる.

行動選択で探索と活用のトレードオフを扱う

第二の特徴は, 未知環境でのデータの集め方である. これはバンディット問題 (bandit problem) と呼ばれ, 囲碁などのゲーム木探索 (game tree search), Web 閲覧時の人の好み行動選択の予測や広告・ニュース記事推薦 (recommendation), 学習アルゴリズムの選択や最適化パラメータのチューニングなど, 最近急速に応用範囲が拡大 [9] している. 定式化は, 期待値の異なる n 個のスロットマシンを繰り返し試行し, 期待値最大の手 (マシン) を推測する行動選択問題である. 試行した t 回で平均報酬最大の手を利用する貪欲法 (greedy algorithm) は局所解に陥るリスクがあるため, 他の手の探索が必要となる. 基本戦略は, 確率 ε でランダムに手を探索し, 確率 $1-\varepsilon$ で平均報酬最大の

手を利用する ε 貪欲法において $\varepsilon = 1/t$ で変化させる探索戦略だが, 最適な手を選ぶには多くの試行を要する. 有意水準 $1/t$ での信頼区間の上限が最大となる手を選ぶ UCB 戦略 (upper confidence bound policy) を 2002 年に Auer が証明して以来, 理論的解析が活発である.

状態遷移を伴う複雑な意思決定をモデルと価値で表す

強化学習は, 問題のクラスとしてマルコフ決定過程 (Markov decision process; MDP) モデルで定式化される. MDP モデルでは, 状態遷移確率が一定かつ直前の状態遷移のみで決まる単純マルコフ性が仮定され, モデルは状態集合, 行為集合, 状態 s で行為 a が実行された後, 得られる報酬 $R(s, a)$ の行列と状態 s' への遷移確率 $P(s'|s, a)$ の遷移行列とで表される. 各状態から行為への写像を方策 (policy), 状態 s から方策 π のもとで将来にわたって得られる期待報酬 (expected reward) 和を状態価値 (value) $V^\pi(s)$, 状態価値を最大化する行為を各状態で出力する方策を最適方策と呼ぶ. 学習手法は, 観測した行動系列から状態価値を直接推定するモデルレス手法と, モデルの遷移確率行列と報酬行列とを教師なし学習で推定し, それらから状態価値を算出するモデルベース手法とに大別され, 前者は実装が単純だが, 学習コストは後者のほうが小さい.

最適性基準で最適方策の質を決める

方策の最適性は, 方策を定常的に実行した場合のリターン (期待割引報酬和や平均報酬) の最大化が通常用いられるが, 期待値だけでなくリターンの分布を推定し, 大きな損失 (cost; risk) の程度を区別する基準を用いる最適性としてリスク (risk) 考慮型がある. リグレット (regret) (期待値の損失) とは, n 回の試行で初回から最適方策が既知の場合の最適期待報酬和から実際に n 回実行して得られた期待報酬和を引いた値を表し, リグレット最小化は学習コストのオンライン最適化基準の一つである.

2000 年代以降の研究動向

報酬関数の設計: 多目的化と高速化

まず, 多目的 (multi-objective) 強化学習を紹介する. 現実の問題では所望の複雑な学習行動に対する報酬関数, 特に複数報酬の重み設定は自明ではない. そこで, 報酬を位置を表す単位ベクトルと大きさを表す重み変数とに分けて, 複数報酬関数を各報酬の重み付き線形和で記述し, あらゆる重みの組合せに対する最適方策集合を一括学習する手法 [11] や, パレート最適 (Pareto optimal) 方策の Q 学習 [12] などがある. 次に, 探索を高速化する報酬生成として, 最適方策が不変な範囲で副報酬を自動生成するシェイピング (shaping) や, 学習意欲・動機付け (motivation) 研究 [13] に基づく内的報酬設定 [1] がある.

逆強化学習：報酬関数の自動生成と徒弟学習

逆強化学習法 (inverse reinforcement learning) とは、強化学習の入出力とは逆に、行動履歴を入力としてそれを最適化する報酬関数を出力する手法であり、車の運転、目的地予測などが研究され、人やエージェントの行動モデル化が期待されている。理論的なアイデアは1964年のカルマンの逆最適化に関する論文であり、2000年にNgらによって最適方策とMDPモデルからの報酬関数推定として定式化された。行動履歴を各状態 s での最適行為 a^* と見なし、残りの行為 a との行動価値が $Q(s, a^*) > Q(s, a)$ を満たす報酬関数を、非最適方策とのマージン最大化、最大エントロピーなどの制約を追加した目的関数の最小化で推定する。

逆強化学習と強化学習とを組み合わせた徒弟学習 (apprenticeship learning) では、エキスパートの演示 (手本となる行動履歴) から逆強化学習で推定した報酬関数を用いて強化学習し、従来手法で困難だった手本以外の状況を含めた最適方策を獲得する。2010年以降の研究では、Dvijothamらが逆強化学習時に最適価値 Q^* 値や V^* 値を直接求める高速化手法を、Makinoらが報酬関数だけでなく環境モデルを同時に推定する手法を提案している。

強化学習の並列化

並列化には、ベイズ推定 (Bayesian inference) に基づく並列モデル [1] や学習器の並列学習がある。前者は、真のモデルを一つと見なす従来統計学に対し、真のモデルを確率分布と見なすベイズ適応的MDPと呼ばれ、学習時の探索と活用のトレードオフを解決する並列モデリングが理論化され、その近似解法が研究されている。後者は、異なるパラメータや学習手法の学習器を複数用意し、選択した学習器の行動選択から得られる経験を共有して同時並列に学習させる枠組み [3] であり、学習器は、一般に学習速度 (特に学習の立ち上がり) と収束時の性能とが両立しないので、学習状況や環境変化の度合いに応じて速度優先・収束性能優先などと学習器の優先度を切り替え、系全体の学習性能を改善する。

応用：モデルの自動設計、人が好む活動の予測

実問題の応用を紹介する。ディープラーニング (deep learning) と強化学習とを組み合わせ、4フレームのビデオ画像列を入力としたゲームプレイの強化学習 [14] や、ニューラルネットワーク (neural network; NN) やリカレントNNを用いたロボット行動の強化学習 [6] では、センサ入力からモータ出力までを一つのNNで構成し、強化学習で生成した教師信号を用いたNN学習に重要な情報の抽象化を委ねてモデル設計を自動化することで、タスクに応じた柔軟な内部表現が中間層で獲得される。

ビジョン分野での人のモデル化の応用例として、人の好み (preference) 行動の予測 [15] では、駐車場シーンにお

ける人の行動軌跡と歩道、車、建物などの特徴を入力とし、特徴ベクトル (feature vector) の重み付き線形和で表した報酬関数を逆強化学習で求め、人が好む経路を強化学習で予測する。何が人や生物の強化刺激になるか [16] を実証する上で興味深い。

参考文献

- [1] 牧野貴樹. リレー解説「強化学習の最近の発展」. 計測と制御, Vol. 52, No. 1-12, 2013.
- [2] 宮崎和光, 山口智浩. エージェント-環境間相互作用—強化学習の立場からの再考. 計測と制御, Vol. 44, No. 12, pp. 859-864, 2005.
- [3] 内部英治, 銅谷賢治. サイバーローデントプロジェクト. 日本神経回路学会誌, Vol. 14, No. 4, pp. 293-304, 2007.
- [4] 牧野貴樹. 実用化する強化学習研究. 生産研究, Vol. 66, No. 3, pp. 305-308, 2014.
- [5] Wiering and van Otterlo, editors. *Reinforcement Learning: State-of-the-Art*. Springer, 2012.
- [6] 柴田克成. 強化学習とニューラルネットによる知能創発. 計測と制御, Vol. 48, No. 1, pp. 106-111, 2009.
- [7] Kober, J. et al. Reinforcement Learning in Robotics: A Survey. *Int. J. of Robotics Research*, Vol. 32, No. 11, pp. 1238-1274, 2013.
- [8] 実森正子, 中島定彦. 学習の心理—行動のメカニズムを探る. サイエンス社, 2000.
- [9] 本多淳也. 多腕バンディット問題の理論とアルゴリズム, 第17回情報論的学習理論WS (IBIS2014), 招待講演, 2014. <http://ibisml.org/archive/ibis2014/ibis2014-bandit.pdf>
- [10] 竹林由武. マルコフ連鎖モンテカルロ法, 2014. <http://www.slideshare.net/yoshitaket/32-35647139>
- [11] 平岡和幸, 三島健稔. 荷重報酬モデルで表されるタスク族に対する一括強化学習. 日本神経回路学会誌, Vol. 13, No. 4, pp. 137-145, 2006.
- [12] Moffaert, K. V. and Nowe, A. Multi-Objective Reinforcement Learning Using Sets of Pareto Dominating Policies. *Journal of Machine Learning Research*, Vol. 15, pp. 3483-3512, 2014.
- [13] 桜井茂男. 自ら学ぶ意欲の心理学—キャリア発達の視点を加えて. 有斐閣, 2009.
- [14] Mnih, V. et al. Human-Level Control Through Deep Reinforcement Learning. *Nature*, Vol. 518, pp. 529-533, 2015.
- [15] Kitani, K. et al. Activity Forecasting. In *Proc. ECCV 2012, LNCS 7575*, pp. 201-214, 2012.
- [16] Pryor, K. *Don't Shoot the Dog!: The New Art of Teaching and Training*. Simon and Schuster. 1984. 【邦訳】河嶋孝, 杉山尚子 訳. うまくやるための強化の原理—飼いや人から配偶者まで. 二瓶社, 1998.

■ 山口智浩

参考文献

- [1] Rosenblatt, F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychol. Rev.*, Vol. 65, No. 6, pp. 386–408, 1958.
- [2] Bock, H. D. The Perceptron, a Model for Brain Functioning. *Review of Modern Physics*, Vol. 34, No. 1, pp. 123–135, 1962.
- [3] Cybenko, G. Approximation by Superpositions of a Sigmoidal Function. *Mathematics of Control, Signals, and Systems*, Vol. 2, No. 4, pp. 303–314, 1989.
- [4] Funahashi, K. On the Approximate Realization of Continuous Mappings by Neural Networks. *Neural Networks*, Vol. 3, pp. 183–191, 1989.
- [5] Rumelhart, D. E., Hinton, G. E., and Williams, R. J. Learning Representations by Back-propagating Errors. *Nature*, Vol. 323, No. 9, pp. 533–536, 1986.
- [6] Looney, C. G. *Pattern Recognition Using Neural Networks*. Oxford University Press, 1997.
- [7] Bishop, C. M. *Pattern Recognition and Machine Learning*. Springer, New York, 2006. 【邦訳】元田浩, 栗田多喜夫, 樋口知之, 松本裕治, 村田昇 監訳. パターン認識と機械学習—ベイズ理論による統計的予測. シュプリンガー・ジャパン, 2007.
- [8] LeCun, Y., Léon, B., Yoshua, B., and Patrick, H. Gradient-based Learning Applied to Document Recognition. *Proceedings of the IEEE*, Vol. 86, No. 11, pp. 2278–2324, 1998.

■ 栗田多喜夫

[7-9]

ディープラーニング (深層学習)

Deep Learning

深層学習 [1] 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 (neural network) をモデルとして用いた機械学習のことである。より広い意味としては, 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階層的な構造を持つ特徴表現 (内部表現; internal representation) をデータから獲得するための学習を指す。

複数の中間層を持つ階層的な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, 誤差逆伝播学習法 (error backpropagation algorithm) が提案され, さまざまな問題に適用されて一定の成功を取めたが, 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, 入力層に近い層における勾配の値が小さくなり, 学習がうまく進まないこと (勾配消失現象) や,

(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などが挙げられる。

層の数が多いニューラルネットワークを用いることにより, より少ない中間層のニューロン数で, より複雑で変動の大きい入出力関係をモデル化できる場合があることは知られていたが, 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くなっていた。

しかし, この問題に対して, トロント大学の Hinton らのグループは, まず, 深層信念ネットワーク (deep belief network) と呼ばれる隠れ層の数が多い確率ネットワークに対する効率の良い近似学習手法を提案し [2], さらに, 制限ボルツマンマシン (restricted Boltzmann machine; RBM) とコントラストダイバージェンス法 (contrastive divergence) [3] を用いた教師なし学習による層ごとの事前学習 (pretraining) を導入し, その結果を初期値として誤差逆伝播学習をさせることで, 層の数が多い自己符号化器 (auto-encoder) が効率良く学習でき, さまざまな種類のデータに対して有効な階層的特徴表現が得られることを示した [4]。モントリオール大学の Bengio らは, 通常の確定的なニューラルネットワークを含むより広い範囲のニューラルネットワークモデルを用いた手法も提案した [5]。

こうして, 階層的な特徴表現の学習の可能性が広がり, 研究が増え始めた。さらに, 2011 年頃から不特定話者連続音声認識 (speaker independent continuous speech recognition) [6] や静止画像中の一般物体認識 (generic object recognition) [7] などのタスクで, 深層学習が従来法を大きく上回る性能を示したことから, 深層学習に大きな注目が集まり, 深層学習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いく。Bengio のサーベイ [8], [9] は, 深層学習および特徴表現学習についてよくまとめられている。

そこで用いられている手法は, 必ずしも層ごとの事前学習を用いているわけではない。例えば, 画像認識においては, 画像認識課題に適した性質を持つ畳み込みニューラルネットワーク (convolutional neural network; CNN) を多層化したモデルと通常の誤差逆伝播学習による教師あり学習を組み合わせた手法が多く用いられている。この手法の原型は福島が提案したネオコグニトロン (neocognitron) [10] や LeCun が提案した LeNet [11] に遡ることができるが, 学習用データ数の増加, 利用可能な計算機パワーの増大, 対象とする課題レベルの向上などがあいまって, 技術の有効性が改めて認識され, インターネット上の実サービスにも応用されたことから, 爆発的に研究が広がった。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は人間と同等の認識精度を達成しているものも多い。

そうした研究の広がりの中で、大規模なネットワークの学習性能を向上させるためのさまざまな工夫も生み出されている。例えば、従来のロジスティック関数などのシグモイド関数 (sigmoidal function) ではなくランプ関数 (ramp function) (0 で打ち切られた線形関数) を出力関数とするニューロン (rectified linear unit; ReLU) を用いる方法 [12]、学習中に一部のノード (ニューロン) をランダムに消去することで、プースティングと類似の効果を実現して過学習を防ぐドロップアウト (dropout) 法 [13]、ドロップアウト法に適した、区分線形な凸関数をニューロンの出力関数として用いて、それ自体の形も学習させるマックスアウト (maxout) 法 [14] などが広く用いられている。また、Caffe, Chainer, Tensorflow などの、層の数が多くニューラルネットワークモデルを用いた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。

自然言語テキストに代表される、構造を持った系列情報を扱うために、回帰結合のあるニューラルネットワークも再び研究されるようになった。中でも、Hochreiter らの提案した LSTM (long short-term memory) ネットワーク [15] 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、画像からの説明文の生成 [16] や機械翻訳 [17] 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 (discriminative model) 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 (generative model) として、層の数が多く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 [18][19][20]。さらに、識別モデルと生成モデルを組み合わせて相互に学習させることで、全体の性能を向上させられることも示されている [21]。

パターン識別・生成や自然言語処理だけでなく、強化学習 (reinforcement learning) 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深層学習を拡張していく研究も進められている。強化学習と深層学習の組合せは、強化学習の性能を左右する状態空間の表現を深層学習によって獲得させられるという利点があり、例えば、Mnih 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 [22]。Levine らは接触の多いはめ合いなどの動作をロボットに学習させた [23]。さらに、深層学習、強化学習、モンテカルロ木探索 (Monte Carlo tree search; MCTS) を巧みに組み合わせたコンピュータ囲碁ソフトウェア“アルファ碁” (AlphaGo) [24] が、世界トップレベルの棋士に 5 番勝負で勝利するなど、目覚ましい成果を挙げており、今後、ロボット制御や社会最適化などへの適用がさらに広がることが期待されている。Graves らは深層学習と外部記憶構造を組み合わせ

たモデルの全体を確率的勾配法で学習させることで、指定された回数だけ同じ処理を繰り返す、などの複雑な制御構造を持つ情報処理過程を入出力データから近似的に学習できることを示している [25]。

こうした深層学習の研究の広がりは、タスクに適した情報表現の獲得の重要性を示している。実世界の多くの情報は、さまざまな情報が混ざり合ったものであり、その中で特定のタスクに必要な情報は一部であることが多い。そうした情報を特徴表現として抽出することによってタスクの実行が簡単になる。また、複数のタスクに必要な情報が重複している場合には、あるタスクのための良い中間表現を得ることが、関連する他のタスクにとっても役立つ。これは転移学習 (transfer learning) の一種である。

参考文献

- [1] 麻生英樹, 安田宗樹, 前田新一, 岡野原大輔, 岡谷貴之, 久保陽太郎, ボレガラダヌシカ 著, 人工知能学会 監修, 神島敏弘 編. 深層学習—Deep Learning. 近代科学社, 2015.
- [2] Hinton, S., Osindero, S., and Whye, Y. A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, Vol. 18, No. 7, pp. 1527–1544, 2006.
- [3] Hinton, G. E. Training Products of Experts by Minimizing Contrastive Divergence. *Neural Computation*, Vol. 14, No. 8, pp. 1771–1800, 2002.
- [4] Hinton, G. E. and Salakhutdinov, R. R. Reducing the Dimensionality of Data with Neural Networks. *Science*, Vol. 313, No. 5786, pp. 504–507, 2006.
- [5] Bengio, Y., Lamblin, P., Popovici, D., and Larochelle, H. Greedy Layer-Wise Training of Deep Networks. In *Proc. Advances in Neural Information Processing Systems (NIPS2006)*, pp. 153–160, 2006.
- [6] Seide, F., Li G., and Yu, D. Conversational Speech Transcription Using Context-Dependent Deep Neural Networks. In *Proc. Interspeech 2011*, pp. 437–440, 2011.
- [7] Krizhevsky, A., Sutskever, I., and Hinton, G. E. ImageNet Classification with Deep Convolutional Neural Networks. In *Proc. Advances in Neural Information Processing Systems*, pp. 1097–1105, 2012.
- [8] Bengio, Y. Learning Deep Architectures for AI. *Foundations and Trends in Machine Learning*, Vol. 2, No. 1, pp. 1–127, 2009.
- [9] Bengio, Y. Representation Learning: A Review and New Perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 35, No. 8, pp. 1798–1828, 2013.
- [10] 福島邦彦. 位置ずれに影響されないパターン認識機構の神経回路モデル—ネオコグニトロン. 電子通信学会論文誌 A, Vol. J62-A, No. 10, pp. 658–665, 1979.
- [11] LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., and Jackel, L. D. Back-propagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, Vol. 1, No. 4, pp. 541–551, 1989.
- [12] Nair, V. and Hinton, G. E. Rectified Linear Units

- Improve Restricted Boltzmann Machines. In *Proc. 27th International Conference on Machine Learning*, pp. 807–814, 2010.
- [13] Srivastava, N., et al. A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, Vol. 15, pp. 1929–1958, 2014.
- [14] Goodfellow, I., et al. Maxout Networks. In *Proc. 30th International Conference on Machine Learning*, pp. 1319–1327, 2013.
- [15] Hochreiter, S. and Schmidhuber, J. Long Short-Term Memory. *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780, 1997.
- [16] Vinyals, O., Toshev, A., Bengio, S., and Erhan, D. Show and Tell: A Neural Image Caption Generator. In *Proc. Computer Vision and Pattern Recognition (CVPR)*, pp. 3156–3164, 2015.
- [17] Sutskever, I., Vinyals, O., and Le, Q. V. Sequence to Sequence Learning with Neural Networks. In *Proc. Advances in Neural Information Processing Systems (NIPS)*, pp. 3104–3112, 2014.
- [18] Bengio, Y., Thibodeau-Laufer, E., Alain, G., and Yosinski, J. Deep Generative Stochastic Networks Trainable by Backprop. In *Proc. 30th International Conference on Machine Learning (ICML 2014)*, 2014.
- [19] Dosovitskiy, A., Springenberg, J. T., and Brox, T. Learning to Generate Chairs with Convolutional Neural Networks. In *Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 2015*, pp. 1538–1546, 2015.
- [20] Mansimov, E., Parisotto, E., Lei Ba, J., and Salakhutdinov, R. Generating Images from Captions with Attention. *arXiv:1511.02793*, 2015.
- [21] Goodfellow, I. J., et al. Generative Adversarial Nets. In *Proc. Advances in Neural Information Processing Systems (NIPS 2014)*, 2014.
- [22] Mnih, V. et al. Human-Level Control Through Deep Reinforcement Learning. *Nature*, Vol. 518, pp. 529–533, 2015.
- [23] Levine, S., Wagener, N., and Abbeel, P. Learning Contact-Rich Manipulation Skills with Guided Policy Search. In *Proc. the IEEE International Conference on Robotics and Automation (ICRA) 2015*, pp. 156–163, 2015.
- [24] Silver, D., et al. Mastering the Game of Go with Deep Neural Networks and Tree Search. *Nature*, Vol. 529, pp. 484–489.
- [25] Graves, A., Wayne, G., and Danihelka, I. Neural Turing Machines. *arXiv:1410.5401*, 2014.

■ 麻生英樹

[7-10]

ディープラーニング（深層学習）の実現技術

Implementation of Deep Learning

はじめに

深層学習は基本的に最適化問題として定式化され、一般に確率的勾配法に基づく手法によって実現される。最適化問題の多くは、多数の関数の合成で記述され、誤差逆伝播法によって効率的に勾配が計算できる。本項目では、深層学習におけるニューラルネットワークとその学習の典型的な実装手法を述べる。

ニューラルネットワークの実装

ニューラルネットワークの実装は、主に勾配計算と最適化ルーチンからなる。

行列演算による実装

ニューラルネットワークは多数のユニットとそれらを結ぶ重み付き有向辺からなり、入力ユニットをある値に固定した上で、その値を重み付けながら辺に流していくアルゴリズムである。ユニットは重み付けられた入力の和に何らかの非線形関数を適用した値を出力する。この定式化はニューラルネットワークを神経回路のアナロジーで捉えるのに都合が良いが、そのまま実装すると煩雑になりやすく、また計算効率も悪い。

実装の煩雑さを回避し、計算を効率的に行うために、ニューラルネットワークは行列演算と非線形関数の組合せで書かれることが多い。ユニット集合の出力をベクトルで表したとき、これらを重み付け辺に流す操作は行列とベクトルの掛け算で書かれる。行列演算は科学計算全般でよく用いられ、高度に最適化された実装が利用できる。

ニューラルネットワークを行列演算で記述するためには、行列計算基盤が必要となる。特に各関数のインタフェースとなるデータ構造を整備する必要がある。画像認識などの分野では、ベクトルや行列だけでなく三つ以上の軸を持つテンソルが用いられる。

勾配の計算手法

行列演算と非線形関数の組合せで書かれたニューラルネットワークは、全体としてはこれらをたくさん合成した巨大な関数と見なせる。勾配法を用いる場合、パラメータとなる辺の重みやバイアス項に関する合成関数の勾配を求める必要がある。合成関数の微分は連鎖律によって各関数のヤコビ行列の積の形に展開できる。

は別のアプローチで急速に高度化しつつある。より具体的には、言語生成対象のデータとそれらに対応する出力テキストの組を訓練データとし、そこから直接、テキストを生成するための統計モデルを学習するものである。初期の研究 [7] では、テキストプランニングと表層生成を区別するなど、伝統的な言語生成手法を踏まえたモデル化がなされていたが、近年では、コンピュータビジョン分野での成功を受け、入出力に共通する分散表現 (distributed representation) を学習する深層学習 (deep learning) のアプローチ [8][9] が用いられるようになってきた。機械翻訳や文書要約とは異なり、言語生成の入力はテキストに限られない。上述のように、深層学習に基づく言語生成手法は写真などの画像データを題材として発展したが、言語生成の入力は、将棋などのゲームの状態、料理のレシピなどの手続き、動画などへと広がりを見せている。また、出力するテキストも、単一の句や文だけでなく、複数の文からなる談話や対話 [10] へと一般化が進んでいる。

参考文献

- [1] McDonald, D. D. Natural Language Generation. In Dale, R. et al., editor, *Handbook of Natural Language Processing*, pp. 147–179, Marcel Dekker, 2000.
- [2] Reiter, E. and Dale, R. *Building Natural Language Generation Systems*. Cambridge University Press, 2000.
- [3] Belz, A. Comparing Automatic and Human Evaluation of NLG Systems. In Reiter, E., editor, *Proc. the 11th Conference of the European Chapter of the Association for Computational Linguistics (EACL)*, pp. 313–320, 2006.
- [4] van Deemter, K., van der Sluis, I., and Gatt, A. Building a Semantically Transparent Corpus for the Generation of Referring Expressions. In *Proc. the 4th International Conference on Natural Language Generation (INLG)*, pp. 130–132, 2006.
- [5] Spanger, P., Yasuhara, M., Iida, R., Tokunaga, T., Terai, A., and Kuriyama, N. REX-J: Japanese Referring Expression Corpus of Situated Dialogs. *Language Resources and Evaluation*, Vol. 46, No. 3, pp. 461–491, 2012.
- [6] Walker, M., Stent, A., Mairesse, F., and Prasad, R. Individual and Domain Adaptation in Sentence Planning for Dialogue. *Journal of Artificial Intelligence Research*, Vol. 30, pp. 413–456, 2007.
- [7] Kuznetsova, P., Ordonez, V., Berg, A., Berg, T., and Choi, Y. Collective Generation of Natural Image Descriptions. In *Proc. The 50th Annual Meeting of the Association for Computational Linguistics (ACL)*, pp. 359–368, 2012.
- [8] Vinyals, O., Toshev, A., Bengio, S., and Erhan, D. Show and Tell: A Neural Image Caption Generator. In *Proc. Computer Vision and Pattern Recognition (CVPR)*, pp. 3156–3164, 2015.
- [9] Venugopalan, S., Xu, H., Donahue, J., Rohrbach, M., Mooney, R., and Saenko, K. Translating Videos to Nat-

ural Language Using Deep Recurrent Neural Networks. In *Proc. the 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT)*, pp. 1494–1504, 2015.

- [10] Wen, T.-H., Gašić, M., Kim, D., Mrkšić, N., Su, P.-H., Vandyke, D., and Young, S. Stochastic Language Generation in Dialogue Using Recurrent Neural Networks with Convolutional Sentence Reranking. In *Proc. the 16th Annual Meeting of the Special Interest Group on Discourse and Dialogue (SIGDIAL)*, pp. 275–284, 2015.

■ 藤田 篤

[8-29]

機械翻訳

Machine Translation

機械翻訳は、1990年代以降、統計的な手法に基づいた統計的機械翻訳により実現されてきた。その枠組みは、句に基づく機械翻訳により進化し、同期文法に基づく機械翻訳により、文法的に正しい翻訳が実現可能となった。深層学習を活用したニューラル機械翻訳により、さらに高性能な翻訳が可能となっている。

統計的機械翻訳

統計的機械翻訳 (statistical machine translation) [1] は、雑音のある通信路モデル (noisy channel model) に基づいており、ある原言語の文 f に対して、可能なさまざまな目的言語の翻訳文 e を列挙し、 f が e へと翻訳される確率 $\Pr(e|f)$ をすべてのペア $\langle f, e \rangle$ に対し求める。 $\Pr(e|f)$ を最大化する \hat{e} を求めることにより、翻訳誤りが最小な英語の文を生成する。

$$\hat{e} = \underset{e}{\operatorname{argmax}} \Pr(e|f) = \underset{e}{\operatorname{argmax}} \Pr(f|e) \Pr(e) \quad (1)$$

ベイズの法則により二つの項が導入され、 $\Pr(f|e)$ および $\Pr(e)$ はそれぞれ翻訳モデル (translation model) および言語モデル (language model) と呼ばれる。翻訳は $\Pr(f|e) \Pr(e)$ を最大化する問題として考えられ、目的言語が原言語へと符号化される過程を逆にたどることから、復号あるいはデコードと呼ぶ。

この古典的な枠組みに基づいた単語翻訳モデルは、一般的に「IBM 翻訳モデル」 (IBM translation model) と呼ばれ、単語アラインメントにより対訳文の対応関係を表している [1]。IBM モデルでは、単語アラインメントと同時確率分布を想定し、翻訳モデル $\Pr(f|e)$ は、すべての可

能な $\mathbf{a} \in \mathcal{A}(\mathbf{f}, \mathbf{e})$ に対して条件付き確率 $\Pr(\mathbf{f}, \mathbf{a} | \mathbf{e})$ の和と考える。

$$\Pr(\mathbf{f} | \mathbf{e}) = \sum_{\mathbf{a} \in \mathcal{A}(\mathbf{f}, \mathbf{e})} \Pr(\mathbf{f}, \mathbf{a} | \mathbf{e}) \quad (2)$$

計算量の観点から、目的言語からは原言語の複数の単語への対応付けを許しつつ、原言語の各単語は目的言語の単語のうち最大1単語しか対応しない、という一対多の制約を加えている。IBM モデル1からモデル5 [1] および隠れマルコフモデル (hidden Markov model; HMM) [2] が定義されている。モデルのパラメータは、原言語および目的言語の対訳文の集合である対訳コーパス (parallel corpus) から、教師なし学習 (unsupervised learning) により自動的に学習される。

句に基づく機械翻訳

単語単位の翻訳は、英語とフランス語など、近い言語対に有効であるが、慣用句など単語へと分解できない表現をうまく翻訳できず、そもそも日本語や中国語など単語の境界が曖昧な言語へは直接適用するのは困難であった。句に基づく機械翻訳 (phrase-based machine translation; PBMT) [3] では、句単位に翻訳を行い、翻訳は、

1. 原言語文を句へと分割
2. 句単位で翻訳
3. 翻訳された句を並び替え目的言語文を生成

という生成過程で行われる。句を導入することにより、1単語だけでは表現できない局所的な文脈あるいは並び替えを直接表現でき、かつ大局的な並び替えを句単位で行うことが可能となった。

句単位の翻訳は、フレーズテーブルと呼ばれる対訳データから学習された原言語および目的言語の句単位の対応付け (フレーズペア) の集合を用いる。フレーズテーブルは、まず対訳データに対して IBM モデルなどの単語翻訳モデルにより、単語アラインメントを付与する。次に、各対訳文から単語アラインメントが内部で閉じているフレーズペアを列挙する。

デコーダは、すべての原言語の単語を被覆する可能なフレーズペアの組合せを列挙し、右から左へと目的言語の順番で結合し、動的計画法 (dynamic programming; DP) によりすべての可能な翻訳を生成する。この探索空間は巨大なため、ビーム探索 (beam search) により枝刈りを行い、スコアを最大化する翻訳を出力する。

ある翻訳に対して計算されるスコアは、生成モデルをより一般化した対数線形モデルを用いる。

$$\hat{\mathbf{e}} = \operatorname{argmax}_{\mathbf{e}} \frac{\exp(\mathbf{w}^\top \mathbf{h}(\mathbf{f}, \mathbf{e}))}{\sum_{\mathbf{e}'} \exp(\mathbf{w}^\top \mathbf{h}(\mathbf{f}, \mathbf{e}'))} \quad (3)$$

\mathbf{h} は、例えば翻訳モデルおよび言語モデルから構成される M 次元の素性関数であり、各素性関数が $\mathbf{w} \in \mathbb{R}^M$ により重み付けされる。対数線形モデルにより、さまざまな素性

を重み付けにより組み合わせることが可能となり、翻訳の精度と相関の高い素性関数を開発することで、容易に翻訳の精度を改善できる。 \mathbf{w} は、実際のテストデータに近い訓練データに対する翻訳誤りを直接最小化するエラー最小化学習 (minimum error rate training; MERT) [2] を用いて最適化する。

同期文法に基づく機械翻訳

句に基づく翻訳は、文法を仮定せずに翻訳を実現する手法であり、アラビア語、ドイツ語、フランス語、英語などの間の比較的近い言語対に対しては高精度な翻訳を実現している。ところが、中国語、日本語、英語などの間の文法的に非常に異なる言語対に対しては、語順がまったく異なるため、非常に挑戦的な課題であった。

この問題に対して、同期文法など構文情報を用いた手法が提案された [4][5]。同期文脈自由文法 (synchronous context free grammar; SCFG) は2言語で定義される文脈自由文法 (context free grammar; CFG) である [6]。SCFG は、原言語の終端記号の集合 Σ と目的言語の終端記号の集合 Δ 、非終端記号の集合 \mathcal{N} で定義される。SCFG の各ルール $X \rightarrow \langle \alpha, \beta, \phi \rangle$ は原言語の記号列 $\alpha \in (\mathcal{N} \cup \Sigma)^*$ と目的言語の記号列 $\beta \in (\mathcal{N} \cup \Delta)^*$ を用いて、非終端記号 $X \in \mathcal{N}$ を両言語同時に書き換える。 ϕ は α と β にある非終端記号の一対一のマッピングを表現する。句に基づく翻訳と異なり、原言語と目的言語にある非終端記号の位置により明示的に並び替えを表現できる。SCFG が文字列に対して書き換えを行うのに対し、同期木置換文法 (synchronous tree substitution grammar; STSG) は各ルールの右辺を木構造へと一般化することで、木構造に対して直接置換操作を行う文法である [7]。

同期文法は句に基づく翻訳同様、単語アラインメントで対応付けられた2言語データから自動的に学習される。SCFG のルールは、階層的なルール抽出手法 [5] により、まずフレーズペアを計算し、その句に含まれるフレーズペアを非終端記号に書き換えることで実現される。STSG のルールは GHKM 法 (Galley-Hopkins-Knight-Marcu algorithm) [4] で、原言語の構文解析木に対して目的言語側の単語列の単語アラインメントを伝播させることにより、最小単位の木置換ルールを計算し、最小ルールを組み合わせた大きなルールを抽出することで実現される。

同期文法での翻訳あるいはデコードは、構文解析により入力と同期文法の原言語側との交差を計算し、交差した同期ルールの目的言語側のルールを組み合わせることで、翻訳森を生成する。SCFG では、同期ルールの原言語側を用い CYK 法 (Cocke-Younger-Kasami algorithm) で構文解析する。STSG では、入力文を構文解析し、トップダウン (あるいはボトムアップ) で STSG の原言語側でマッチングを行い、交差を計算する。翻訳森を生成した後、内側外側アルゴリズム (inside-outside algorithm) の内側アルゴ

リズムあるいはキューブ枝刈り (cube pruning) [8] によりすべての導出から最適な導出を計算し、翻訳を生成する。

ニューラル機械翻訳

従来法では、単語や句、ルールなどを使って翻訳が生成される過程をモデル化することで翻訳を実現してきた。このような生成モデルの枠組みでは、各ステップごとに問題を分割し、各モデルごとにパラメータが学習され、素性の重みを調整することで比較的容易に翻訳システムを構築できる。ところが、どのような素性が翻訳の精度へと貢献するかは未だに研究課題であり、言語に精通したエキスパートによる試行錯誤を必要とする。

ニューラル機械翻訳は、フレーズペアなどの明示的な対応関係を表現する代わりに、素性表現を自動的に学習するニューラルネットワーク (neural network) により2言語の対応付けを数値ベクトルで表現し、単一のモデルで機械翻訳を実現する。現在主流となっているモデルは、エンコーダ・デコーダモデル (encoder decoder model) あるいは系列・系列モデル (sequence to sequence model) とも呼ばれ、原言語の入力文を数値ベクトルで表現し、デコーダで逐次可変長の目的言語の出力シンボルを生成する [9]。エンコーダは回帰型ニューラルネットワーク (recurrent

neural network; RNN) [10] を用いて入力文 \mathbf{f} の各単語 f_j に対応した q 次元の内部表現あるいは隠れ層 $\mathbf{h}_j^s \in \mathbb{R}^q$ を得る。

$$\mathbf{h}_j^s = \text{RNN}(\mathbf{W}^s[\mathbf{h}_{j-1}^s; \mathbf{W}^{is}\mathbf{u}^{f_j}] + \mathbf{b}^s) \quad (4)$$

RNN は、前の単語 f_{j-1} に対応した内部表現 \mathbf{h}_{j-1}^s および f_j に対応する q 次元の数値ベクトル表現 \mathbf{u}^{f_j} を入力とし、 $\mathbf{W}^s \in \mathbb{R}^{q \times 2q}$ との行列積およびバイアス項 \mathbf{b}^s から新たに q 次元のベクトル表現を得て、例えば tanh や sigmoid などによる非線形な変換を行うことで \mathbf{h}_j^s を計算する。RNN の代わりに、セルおよびゲートにより詳細に情報の流れを制御する LSTM (long short-term memory) [11] や、より単純な GRU (gated recurrent unit) [12] が用いられることが多い。

デコーダは、最後に得られた隠れ表現 $\mathbf{h}_j^s = \mathbf{h}_0^t$ から順番に、各 i でモデルスコア p を最大化する目的言語の単語 \hat{e}_i を生成する。

$$\hat{e}_i = \underset{e \in \mathcal{V}_E}{\operatorname{argmax}} p(e|\hat{e}_1^{i-1}, \mathbf{h}_0^t, \dots, \mathbf{h}_i^t) \quad (5)$$

$$p(e|\hat{e}_1^{i-1}, \mathbf{h}_0^t, \dots, \mathbf{h}_i^t) = 1^e \text{softmax}(\mathbf{W}^o \mathbf{h}_i^t + \mathbf{b}^o) \quad (6)$$

$$\mathbf{h}_i^t = \text{RNN}(\mathbf{W}^t[\mathbf{h}_{i-1}^t; \mathbf{u}^{\hat{e}_{i-1}}] + \mathbf{b}^t) \quad (7)$$

[8-b] 2言語間アラインメント

2言語間アラインメント (bilingual alignment) とは、狭義には、二つの異なる言語で同じ内容が記述された文書や文などに対して、文単位・節単位・句単位・語単位など、さまざまな単位で、同じ内容を表す部分に対応付ける処理を指す。図1に、同じ内容を表す日本語文と英語文を節または句の単位で対応付けた結果の例を示す。

2言語間アラインメントの手法は、機械翻訳 (machine translation) の研究において、大規模な2言語コーパスが利用可能となった1990年代以降に盛んに研究されるようになった。それらの研究は、いずれも、機械翻訳用の対訳辞書や翻訳規則を、大規模な2言語コーパスから自動獲得するという目的のもとで行われてきた。

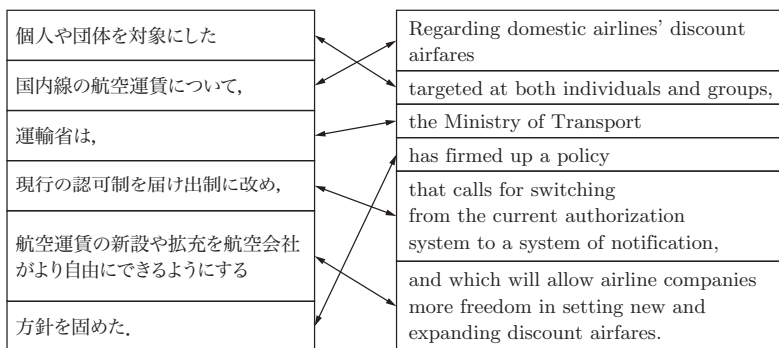


図1 日英対訳文の節または句の単位のアラインメントの例

(つづく)

2言語間アラインメントに関する研究において、初期の頃から最もよく研究されたのが、二つの異なる言語で同じ内容が記述された文書に対して、同じ内容を表す文を対応付ける文アラインメント (sentence alignment) の手法である [1]。文アラインメントの一般的な手法においては、文書の大局的な構造として、文書中のおおのの内容は、2言語間でだいたい同じ順序で記述されると仮定する。ここで、片方の言語における一つの文の内容は、もう一方の言語において、必ずしも一つの文で記述されるとは限らず、場合によっては数文に分割されたり、逆に、省略されたりすることもある。したがって、2言語間で対応する文の数については、最大で数文対数文程度の対応を許容した上で、文の対応付けを行うといった手法が多い。文の対応付けの際には、文の単語数や文字数、同語源語の語幹情報、既存の対訳辞書中の訳語対応などの情報を参照して、文中の単語などの単位で2言語間の対応の度合いを測定した上で、文全体の2言語間の対応の度合いを推定する。文アラインメントのアルゴリズムとしては、動的計画法 (dynamic programming; DP) に基づくもの、反復計算法に基づくものなどが知られている。また、二つの異なる言語で同じ内容が記述された文書の一例として、現存する言語資源の中でも、比較的低コストで整備可能な資源として、異なる言語で書かれ2か国以上に出版された特許文書 (パテントファミリー) が利用可能であることがよく知られている [2]。これらの2言語以上で記述された同一内容の特許文書に対して、文アラインメント手法を適用することによって、高品質な対訳文組を大規模に収集することが可能である。

さらに詳細な単位の2言語間アラインメントにおいては、二つの異なる言語で同じ内容が記述された文に対して、同じ内容を表す節・句・語などを2言語間で対応付ける処理を行う。最も初期の、統計的機械翻訳 (statistical machine translation) モデルに基づく手法では、文の構文構造は利用せず、1次元の単語列上で語順を変える操作を確率的にモデ

ル化することにより、2言語の対訳文に対して語単位のアラインメントを行う [3]。この手法のモデル化は、英語・仏語などの構文構造が類似した言語間ではある程度有効であったが、英語と日本語のような構文構造が異なる言語間では限界があった。その後、構文構造を利用して、2言語の対訳文に対して語単位のアラインメントを行う手法の研究も行われ、現在も研究が進められている。

同じ内容を表す部分に対応付けるという観点で言えば、ある言語で書かれた文書の集合と別の言語で書かれた文書の集合が与えられたとして、同じ内容を表す2言語の文書組に対応付ける処理も、広義の2言語間アラインメントとして捉えることができる。この処理で用いられる手法の基本的な考え方は、言語横断文書検索の技術に基づいており、片方の言語の文書を検索質問として、もう一方の言語の文書集合中から、最も類似した文書を選び出す過程として捉えることができる。さらに、より広義には、ある程度以上の規模の2言語文書から、句・連語・単語などの訳語対応を推定する処理までを含めて、2言語間アラインメントと呼ぶこともある。情報源となる2言語文書としては、二つの異なる言語で同じ内容が記述された文書や、内容は異なるが対象分野が同一の2言語文書などが用いられる。

参考文献

- [1] Manning, C. D. and Schütze, H. Statistical Alignment and Machine Translation. In *Foundations of Statistical Natural Language Processing*, Chapter 13, pp. 463–494, The MIT Press, 1999.
- [2] 藤井敦, 谷川英和, 岩山真, 難波英嗣, 山本幹雄, 内山将夫. 5.3節: 特許対訳コーパス. 特許情報処理: 言語処理的アプローチ, 自然言語処理シリーズ, 第5巻, pp. 132–141, コロナ社, 2012.
- [3] 渡辺太郎, 今村賢治, 賀沢秀人, Graham Neubig, 中澤敏明. 第4章: 単語アライメント. 機械翻訳, 自然言語処理シリーズ, 第4巻, pp. 81–124, コロナ社, 2014.

■ 宇津呂武仁

式 (7) では、 h_{i-1}^t および直前に生成された目的言語の単語 \hat{e}_{i-1} から RNN によりデコードの内部表現 h_i^t を求め、式 (6) の softmax により目的言語の各単語の確率値を求め、単語 e に対応した確率を出力している。デコードは文末を示す特殊な記号 $\langle /s \rangle$ を生成すると終了する。

デコードの初期には、エンコーダの内部表現を直接反映することはできるが、デコードが進むにつれてその影響が小さくなるという欠点があった。注意モデル (attention model) は、エンコーダのすべての内部表現を重み付けて足すことで、その問題を解決している [12]。

参考文献

- [1] Brown, P. E., Pietra, S. A. D., Pietra, V. J. D., and Mercer, R. L. The Mathematics of Statistical Machine Translation: Parameter Estimation. *Computational Linguistics*, Vol. 19, No. 2, pp. 263–311, 1993.
- [2] Och, F. J. and Ney, H. A Systematic Comparison of Various Statistical Alignment Models. *Computational Linguistics*, Vol. 29, No. 1, pp. 19–51, 2003.
- [3] Koehn, P., Och, F. J., and Marcu, D. Statistical Phrase-Based Translation. In *Proc. the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL/HLT)*, pp. 48–54, 2003.
- [4] Galley, M., Hopkins, M., Knight, K., and Marcu, D.

- D. What's in a Translation Rule? In *Proc. the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL/HLT)*, pp. 273–280, 2004.
- [5] Chiang, D. Hierarchical Phrase-Based Translation. *Computational Linguistics*, Vol. 33, No. 2, pp. 201–228, 2007.
- [6] Aho, A. V. and Ullman, J. D. Syntax Directed Translations and the Pushdown Assembler. *Computer and System Sciences*, Vol. 3, No. 1, pp. 37–56, 1969.
- [7] Eisner, J. Learning Non-Isomorphic Tree Mappings for Machine Translation. In *Proc. ACL*, pp. 205–208, 2003.
- [8] Huang, L. and Chiang, D. Forest Rescoring: Faster Decoding with Integrated Language Models. In *Proc. ACL*, pp. 144–151, 2007.
- [9] Sutskever, I., Vinyals, O., and Le, Q. V. Sequence to Sequence Learning with Neural Networks. In *Proc. Advances in Neural Information Processing Systems (NIPS)*, pp. 3104–3112, 2014.
- [10] Elman, J. L. Finding Structure in Time. *Cognitive Science*, Vol. 14, No. 2, pp. 179–211, 1990.
- [11] Hochreiter, S. and Schmidhuber, J. Long Short-Term Memory. *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780, 1997.
- [12] Bahdanau, D., Cho, K., and Bengio, Y. Neural Machine Translation by Jointly Learning to Align and Translate. In *Proc. the International Conference on Learning Representations (ICLR)*, 2015.

■ 渡辺太郎

[8-30]

機械翻訳の歴史

History of Machine Translation

黎明期

機械翻訳は、1947年にロックフェラー財団のウォーレン・ウィーバー（クロード・シャノンの情報理論の書籍の共同執筆者）が、ノーバート・ウィーナー（サイバネティクスの先駆者）に出した手紙で、その基本アイデアが示された [1][2].

…（前略）… 私がロシア語の記事を見たとき、「これは実は英語で書かれているが、変なシンボルで暗号化されている。今から解読しよう」と思った …

ウィーナーは悲観的な返事を返したが、コンピュータによる翻訳に期待を感じたウィーバーは、2年後の1949年、アイデアを覚書としてまとめ、20～30人程度の知人

に配った [3][4]. 特にアメリカでは、ウィーバーは数学とコンピュータの専門家として影響力を持っていたため、これを契機に機械翻訳の研究が開始された。

ウィーバーの覚書から3年後の1952年、最初の機械翻訳に関する会議（the first machine translation conference）がマサチューセッツ工科大学で開催された [5]. ここでは、前編集、後編集や制限言語のような人間が介在する翻訳方式、全言語共通の概念構造を介して翻訳する中間言語方式、コンピュータが扱う自然言語文法など、現在でも検討されているいくつかの提案がなされた。機械翻訳に必要な技術は、のちに計算言語学という分野になった。この会議の結論としては、可能性を示すだけでなく、早期に動作するシステムを作る必要があるというものだった。

1954年1月7日、IBMとジョージタウン大学が機械翻訳の公開デモ（IBM-Georgetown demonstration）を行った [6]. これは、49文のロシア語を英語に翻訳するものだった（語彙は250語）。実験には初の商用コンピュータIBM 701が使用された。この実験は、翌日の新聞の一面を飾るなど、大きな反響があり、アメリカ政府は機械翻訳研究に多額の支援を行うこととなった。

日本では、1959年に電気試験所が「やまと」と呼ぶ英日翻訳専用機を開発した。同時期、九州大学では翻訳実験用計算機KT-1を開発している [7].

ALPAC 報告書とその後

1966年、アメリカの全米科学アカデミーから、報告書が発行された（いわゆるALPAC報告書（ALPAC report））。これは過去10年の政府による機械翻訳開発支援を含め、さまざまな翻訳技術の効果を評価するものであった [8]（詳細は [8-c]（p.669）参照）。この報告書では、人手をまったく介さない全自動翻訳は当分の間大きな進展は期待できず、機械支援型人間翻訳や、コンピュータ用文法などの自然言語処理汎用技術の開発に資金援助すべきと結論されており、機械翻訳の研究は急速に縮小した。

しかし、研究の縮小とは別に、一部の企業はこれまでの機械翻訳技術を実用化し、政府機関・他企業などに提供していた [9].

ジョージタウン大学で開発されたGATシステム（ロシア語→英語翻訳）は、プロジェクト中止後会社を設立したメンバーによって、SYSTRANシステムとなった。SYSTRANシステムは、後編集を前提とした翻訳システムである。1970年にアメリカ空軍に納入され、1974年にはNASAにも納入された。1976年には欧州共同体が、情報拡散を目的として、SYSTRANの英仏翻訳システムを購入した。SYSTRANシステムは辞書などをモジュール化することで、複数の言語を翻訳できるようになっていった。

全自動翻訳に関しては、カナダのモントリオール大学が開発したTAUM英仏翻訳システムを気象予報に特化させ

- [2] Ishiguro, H. and Trivedi, M. Integrating a Perceptual Information Infrastructure with Robotic Avatars: A Framework for Tele-existence. In *Proc. International Conference on Intelligent Robots and Systems*, pp. 1032–1038, 1999.
- [3] 石黒浩. ロボットとは何か—人の心を映す鏡. 講談社, 2009.
- [4] 石黒浩. アンドロイドサイエンス. システム制御情報, Vol. 49, No. 2, pp. 47–52, 2005.
- [5] Ishiguro, H. Scientific Issues Concerning Androids. *International Journal of Robotics Research*, Vol. 26, No. 1, pp. 105–117, 2007.
- [6] Nishio, S., Ishiguro, H., and Hagita, N. Geminoid: Tele-operated Android of an Existing Person. In de Pina Filho, A. C., editor, *Humanoid Robots, New Developments*, pp. 343–352, I-Tech Education and Publishing, 2007.

■ 石黒 浩

[13-19]

ヒューマンロボットインタラクション

Human-Robot Interaction; HRI

はじめに

ヒューマンロボットインタラクション (HRI) とは、人が使ったり、人と共存して活動したりするようなロボットシステムを理解し、デザインし、評価するような研究領域である [1]。特に、近年、ロボットが複雑化、高機能化、自律化し、時には擬人的になっていく中で、多くの要素のデザインが必要となり、研究が盛んになってきた。なお、ヒューマンロボットインタラクションには、広くは、無人偵察機に代表される UAV (unmanned aerial vehicle) のような遠隔操作型ロボットを操縦するオペレータとロボットシステムの間インタラクションや、外骨格型ロボットのような装着型ロボットがその利用者の体にどうフィットするかといった物理的なインタラクション (physical HRI と呼ばれる) までも含むが、本項目では、主に、ユーザーと同じ場所に共存してインタラクションするようなロボットについて述べる。

社会的ロボット

1990年代後半ごろに、人らしいロボットが作り出されるようになる中で、人々が単なる機械であるはずのロボットと社会的に関わり合う場面が見られ始めた。人同士が社会的にインタラクションしているのと同様に、ロボットも人と何らかの形で社会的にインタラクションができるのでは

ないか、と考えられるようになってきた。このような、社会的なインタラクションをするロボットを社会的ロボット (social robot) [2][3][4] と呼ぶ。中でも、擬人的な対話ロボットをコミュニケーションロボット [5] と呼ぶ。人と似た反応を返すために人と同様の認知情報処理を実現する研究や、ロボットを作ることで人の認知情報処理のメカニズムを推測する構成的アプローチの研究などが始まった。

擬人性

ロボットの見かけや振る舞いについて、さまざまな程度の擬人性を持つロボットがデザインされてきた。動物を模したロボットのように人らしさが少ないロボットでも、触れ合いインタラクションが行われ、ストレス軽減などの効果も見出されている [6]。多くのロボットは、機械的でありながらも、頭部、目、腕、といった要素を持つなど、一定の擬人性がデザインされている。中には、人間との見分けがつきにくい人間酷似型のアンドロイドなども作り出されており、その擬人性がもたらす人らしい存在感の解明といった研究も進んでいる [7]。

身体を利用したコミュニケーション

良いヒューマンロボットインタラクションの実現方法には未解明の点も多いが、擬人的なロボットにおいては、少なくとも、身体を適切に利用することが重要であることが明らかになってきている。また、その知見には、人同士のコミュニケーションの際の知見と重なるものが多いため、心理学分野などの知見が参考になる場合も多い。例えば、ロボットが視線 (頭部方向の向き) をユーザーの頭部に向けてアイコンタクトすることで、ユーザーはロボットからの発話をより注意深く聞くようになる [8]。逆に、ロボットとの対話に注意を払っていないユーザーは、視線をロボットから外しがちである [9]。対話距離、体の向き、指差しなどのジェスチャー、顔表情など、多くの身体要素から社会的なシグナルが伝わる。これらの振る舞いを適切にデザインし、利用することで、インタラクションをより良くすることができる (図1)。



図1 ヒューマンロボットインタラクションの一場面：ロボットが道案内する際に、視線や指差しによって方向を示している様子

認知モデル

ヒューマンロボットインタラクションを円滑に進めるために重要となるのが、認知モデルである。例えば、以下のような共同作業場面でのやりとり [10] の例を考えてみる。

ロボットとユーザーの2者が、一緒に車の組み立てをしている。ユーザーが取り付けの部品を取りに行き、ロボットはその補助者として、必要になる工具を手渡す。組み立て作業の流れとして、「レンチ」でタイヤを取り付け、「溶接機」でドアを取り付けていくとしよう。タイヤの取り付けを終えたユーザーが、ドアを取りに行ったら、ロボットはどうすべきだろうか？ 指示される前に「溶接機」を取りに行けるだろうか？

もしロボットが、ユーザーが何を考えているのか、その認知モデルを持つことができれば、ユーザーの行動の断片を観察しただけでも、ユーザーに指示されるまでもなく、次に必要な行動を理解し、それに備えて行動を開始することができるだろう。上記の例は非常に単純化されたものではあるが、一般に、このように相手の視点に立って状況を理解すること（心理学分野ではパースペクティブテークング（perspective-taking）と呼ばれる）が、円滑なインタラクションを可能にすることが見出されてきている。相手がこの先どのように振る舞うのか、あらかじめ予期（anticipation）し、それに応じた振る舞いができる。認知モデルによってさまざまなインタラクションが円滑になる。例えば、集団で道をふさいでおしやべりしていたら迷惑になってしまう、といった社会常識に沿った振る舞いも、他者の視点に立てるようになることで計算可能になる [11]。

長期的インタラクション

ロボットは、古くは、人間の命令を忠実に実行する「ツール」というイメージがあったが、近年、人らしい社会的ロボットが作られる中で、将来のロボットは人間の「パートナー」になるのではないかと期待がある。パートナーロボットといった言葉も出てくるようになった。ロボットが人間のパートナーとなるために、何が必要なのか、解明の道のりはまだ遠いが、少なくとも、実際の日常環境で長期にわたってインタラクションが続く必要があるのではないかと考えられている。一方、ロボットは現状珍しい存在であり、子供をはじめとして、初見のユーザーの興味を引きやすい。しかし、しばらく慣れて珍しくなくなると飽きてしまうことも多い。2週間ほどで飽きられてしまったという報告もある [12]。ペットロボットも、実際のペットのように長期にわたってのインタラクションは続かない。ゆえに、パートナーとなるロボットの実現のためには、短期のインタラクションだけではなく、長期にわたってインタラクションを観察し、またそれが続くようにするためのメカニズムを実現することが期待されている。自己開示

[13] など、パートナーのような関係を作り出すための要素についての探索が行われ始めている。

参考文献

- [1] Goodrich, M. A. and Schultz, A. C. Human-Robot Interaction: A Survey. *Foundations and Trends in Human-Computer Interaction*, Vol. 1, No. 3, pp. 203–275, 2007.
- [2] Breazeal, C. Towards Sociable Robots. *Robotics and Autonomous Systems*, Vol. 42, pp. 167–175, 2003.
- [3] Fong, T., Nourbakhsh, I., and Dautenhahn, K. A Survey of Socially Interactive Robots. *Robotics and Autonomous Systems*, Vol. 42, pp. 143–166, 2003.
- [4] Breazeal, C., Dautenhahn, K., and Kanda, T. Chapter 72: Social Robotics. In Siciliano, B. and Khatib, O., editors, *Handbook of Robotics*, 2nd Edition. Springer, 2008.
- [5] 石黒浩, 宮下敬宏, 神田崇行. コミュニケーションロボット. 知の科学. オーム社, 2005.
- [6] Wada, K., Shibata, T., Musha, T., and Kimura, S. Robot Therapy for Elders Affected by Dementia. *IEEE Engineering in Medicine and Biology Magazine*, Vol. 27, pp. 53–60, 2008.
- [7] Ishiguro, H. Android Science. *Robotics Research*, pp. 118–127, 2007.
- [8] Mutlu, B., Shiwa, T., Kanda, T., Ishiguro, H., and Hagita, N. Footing In Human-Robot Conversations: How Robots Might Shape Participant Roles Using Gaze Cues. In *Proc. ACM/IEEE Int. Conf. on Human-Robot Interaction (HRI 2009)*, 2009.
- [9] Rich, C., Ponsler, B., Holroyd, A., and Sidner, C. L. Recognizing Engagement in Human-Robot Interaction. In *Proc. ACM/IEEE Int. Conf. on Human-Robot Interaction (HRI 2010)*, 2010.
- [10] Hoffman, G. and Breazeal, C. Effects of Anticipatory Action on Human-Robot Teamwork. In *Proc. ACM/IEEE Int. Conf. on Human-Robot Interaction (HRI 2007)*, 2007.
- [11] Kidokoro, H., Kanda, T., Brscic, D., and Shiomi, M. Will I Bother Here? — A Robot Anticipating Its Influence on Pedestrian Walking Comfort. In *Proc. ACM/IEEE 8th Annual Conference on Human-Robot Interaction (HRI 2013)*, 2013.
- [12] Kanda, T., Hirano, T., Eaton, D., and Ishiguro, H. Interactive Robots as Social Partners and Peer Tutors for Children: A Field Trial. *Human Computer Interaction*, Vol. 19, No. 1-2, pp. 61–84, 2004.
- [13] Bickmore, T. W. and Picard, R. W. Establishing and Maintaining Long-Term Human-Computer Relationships. *ACM Transactions on Computer-Human Interaction*, Vol. 12, pp. 293–327, 2005.

として多くのプログラムが開発されてきた。1982年に発表されたP. RosenbloomのIAGOは、初めて人間のトップクラスの実力に達した。基本的に全数探索をアルファベータ探索(alpha-beta search)とともにを行い、可動性(指し手の選択肢の大きさ)や安定性などを要素とする評価関数を用いた。1990年にはIAGOより強く世界チャンピオン並みと称するプログラムがLeeらによって開発されたが、実際に世界チャンピオンと対戦して勝ったものではなかった。1997年にM. Buroが開発したロジステロ(Logistello)が世界チャンピオンの村上健と戦って勝利し、オセロにおいてはコンピュータが人間を凌駕したと言える。

オセロの盤面は 8×8 であるが、これを 6×6 に小さくしたゲームは後手必勝であることが解明されている(先手が最善を尽くしても後手が最善を尽くせば21対15で後手が勝つ)。

■ 松原 仁

[16-13]

将棋

Shogi

将棋のプログラムの研究が始まったのは、チェスに比べると非常に遅く、1970年代になってからである。これには、後述するように将棋がチェスに比べてコンピュータにとって難しいゲームであるという理由もあるが、長い間日本でゲームが人工知能の研究対象とされていなかったことが大きいと思われる。

ゲームの初手から勝負がつくまでにルール上可能なすべての手を読んだときの場合の数が、コンピュータにとってそのゲームがどれくらい難しいかの指標となる。さまざまな枝刈りをしてはいるものの、探索空間の全数探索が基本となっているためである。チェスは平均分岐数(分岐数とは局面でルール上指すことのできる手の数である)が約35で平均手数(約80)なので、場合の数は35の80乗で約 10^{120} になる。将棋はチェスとは異なり、敵から取った駒を再利用できるという持ち駒制度がある。将棋の平均分岐数は約80で平均手数は115なので、場合の数は80の115乗で約 10^{220} になる。将棋の場合の数はチェスのそれに比べてはるかに大きいので、チェスで有効だった手法だけでは、将棋のプログラムを強くすることはできなかった。結果的には、機械学習が将棋には有効だったことになる。

将棋のプログラムは、基本的にはアルファベータ探索(alpha-beta search)と静的評価関数(static evaluation function)というチェスのプログラムと同じ方法を採用し

ている。以前は、静的評価関数を手作業で作成していた(その時点では、アマ4, 5段の強さに留まっていた)が、ボナンザ(Bonanza)が機械学習で評価関数を作成する手法を提案して以降は、どのプログラムも機械学習で静的評価関数を作成している。また、将棋は分岐数が大きく、チェスのような全数探索は大変なので、見込みの高い候補手だけを先読みする前向き枝刈り(選択的探索)を行っているものが多かったが、ボナンザはチェスのような全数探索を採用している。ボナンザ以降、コンピュータは急速に強くなり、プロ棋士に勝つようになっていく。すでに事実上コンピュータのほうが人間よりも強くなったとして、2015年には情報処理学会がトッププロ棋士に勝つコンピュータ将棋のプロジェクトの終了宣言を行っている。

最初に動作した将棋のプログラムは、1975年頃に瀧澤武信らによって作成された。コンピュータ同士の対戦は、1979年に始まっている。チェスに比べると、20年程度遅れてスタートしている。1983年には最初の市販ソフトが発売された。1990年からは毎年コンピュータ将棋の大会が行われている。チェスと同様に最初の頃はとても弱かったが、1990年代に入ってアマ有段者のレベルになり、順調に強くなってきた。2006年にボナンザが機械学習によって静的評価関数を作成するようになって、プロ棋士のレベルに達した。2010年には、情報処理学会の50周年イベントとして、女流プロ棋士の清水市代女流王将にコンピュータ将棋4個の合議チーム「あから2010」が挑戦し、「あから2010」が勝利した。その後は男性プロ棋士にも大きく勝ち越しており、事実上コンピュータのほうが人間よりも強くなったと言える。

チェス同様に、反復深化(iterative deepening)、選択的深化(selective deepening)、置換表(transposition table)などの工夫を将棋でもしている。チェスで有効だった終盤データベース(endgame database)は、将棋では使えない。持ち駒制度のために、終盤(endgame)で同じ局面になることはないためである。その代わりに、将棋では詰め将棋を解くルーチン(PN探索(PN search)を改良したものを用いられることが多い)を用意して、終盤はそれを用いている。将棋のプログラムにおける具体的な工夫については、文献[1]を当たっていただきたい。

将棋は、強くする研究開発の段階は終わったと言える。今後は、例えば相手の人間の實力を見極めて、いい勝負を演じることのできるプログラム(いわゆる接待将棋のプログラム)の開発など、人間が将棋を楽しむための研究開発に移ると思われる。

参考文献

[1] 松原仁 編。コンピュータ将棋の進歩1~6。共立出版、1996。

■ 松原 仁

コンテンツを含む検索結果をクラスタリングするなどして、利用者が求めるコンテンツを含む検索結果を適切な順序で表示する必要がある。そこで、検索結果を表示するランキングアルゴリズム (ranking algorithm) やレーティングアルゴリズム (rating algorithm) として、情報検索 (information retrieval)、情報フィルタリング (information filtering) や、データマイニング (data mining) などの技術が用いられる。

情報検索に関しては、シソーラス (thesaurus) を用いた同意義語による問い合わせ展開や関連性フィードバック (relevance feedback)、ダブリンコア (Dublin core) を代表とするメタデータ記述、セマンティック Web (Semantic Web) におけるオントロジー (ontology) など、意味的検索と関係する。また、検索エンジンの性能評価に、情報検索システムの評価指標である再現率 (recall) や適合率 (precision) などの評価指標が用いられることがある。

情報フィルタリングは、検索エンジン利用者の選好 (preference) を分析し、同じ関心を持つ利用者群の情報取捨に関わる行動を共有することで、推薦 (recommendation) を行う。記述内容に基づくフィルタリング (content-based filtering) や認識フィルタリング (cognitive filtering)、情報の送信者と受信者間に存在する関係に基づく社会的フィルタリング (social filtering)、協調フィルタリング (collaborative filtering) などの手法が用いられる。

ランキングアルゴリズム

コンテンツの特徴や Web グラフ構造に基づいて検索結果表示順を決定する、ランキングアルゴリズムが提案されている [8][9]。例えば、Google における PageRank アルゴリズム (PageRank algorithm) である。PageRank は、Google 創業者であるセルゲイ・ブリンとラリー・ペイジが提案したランダムサーファ (random surfer) の概念によるアルゴリズムであり、あるページからリンクされているページにランダムに遷移する参照構造を定式化し大規模行列計算を行うランキングであり、マルコフ連鎖に基づいて説明される。

Ask.com における HITS (hypertext induced topic search) と呼ばれるランキングアルゴリズムは、多くの有用なページへのリンクを含むハブ (hub) のレーティングと、多くの有用なページからリンクされるオーソリティ (authority) のレーティングとの相互依存関係を定式化し反復計算する。数学的には、ペロンフロベニウスの定理 (Perron-Frobenius theorem) と関係する。その他、SALSA (stochastic approach for link structure analysis) などが知られている。

参考文献

[1] TheSearchEngineList.com. The Search Engine List, The Search Engine List Comprehensive List of Search Engines, 2016. <http://www.thesearchenginelist.com/>

- [2] Bughin, J., Corb, L., Manyika, J., Nottelbohm, O., Chui, M., Barbat, B.-M., and Said, R. The Impact of Internet Technologies: Search. Technical report, High Tech Practice, McKinsey & Company, 2011.
- [3] MacKinnon, R., Hickok, E., Bar, A., and Lim, H. *Fostering Freedom Online: The Role of Internet Intermediaries*. UNESCO Series on Internet Freedom. UNESCO, 2014.
- [4] StatCounter. StatCounter Global Stats. <http://gs.statcounter.com/>
- [5] 国立国会図書館関西館電子図書館課. ウェブアーカイブのしくみ, 2014. <http://warp.da.ndl.go.jp/contents/recommend/mechanism/mechanism.pdf>
- [6] Ricardo, A. and Serrão, C. Comparison of Existing Open-source Tools for Web Crawling and Indexing of Free Music. *Journal of Telecommunications*, Vol. 18, No. 1, pp. 1-6, 2013.
- [7] Olston, C. and Najork, M. Web Crawling. *Journal of Foundations and Trends in Information Retrieval*, Vol. 4, No. 3, pp. 175-246, 2010.
- [8] Langville, A. N. and Meyer, C. D. *Google's PageRank and Beyond: The Science of Search Engine Rankings*. Princeton University Press, 2006. 【邦訳】岩野和生, 黒川利明, 黒川洋 訳. Google PageRank の数理—最強検索エンジンのランキング手法を求めて. 共立出版, 2009.
- [9] Langville, A. N. and Meyer, C. D. *Who's #1?: The Science of Rating and Ranking*. Princeton University Press, 2012. 【邦訳】岩野和生, 中村英史, 清水咲里 訳. レーティング・ランキングの数理—No.1 は誰か? 共立出版, 2015.

■河野浩之

[17-3]

推薦システム

Recommender System

はじめに

最初に、推薦システムの目的について、その原点の一つである文献 [1] での定義を紹介する。

自分の経験だけでは違いがあまりよくわからないものの中からでも、どうしてもどれかを選ばなければならないということはよくある。こうしたときには、口コミ、推薦状、新聞の書評や映画評、ザガットのレストランガイドなどの他人からの推薦に頼ることを日常的に行っている。

推薦システムは、こうした社会で普通に行われている一連の行為を補助したり、促進したりする。

より簡潔には、Konstan によるチュートリアル [2] にある「どれに価値があるかを特定することを助ける道具」(tools

to help identify worthwhile stuff) という定義もある。このように、利用者にとって有用と思われる対象、情報、または商品などを選び出し、それを利用者の目的に合わせて提示するのが推薦システムである。

推薦システムの歴史

この推薦システムが必要になった背景には、情報過多 (information overload) [3] という状況がある。情報技術の進展により、大量の情報を収集し、それらを蓄積したり、流通させたりすることが可能になった。しかし、あまりにも大量の情報があるため、目的の情報を参照できる状態にあるにもかかわらず、それを特定できないという状況が情報過多である。この状況に対処すべく、利用者にとって有用な情報を見つけ出す推薦システムは考案された。

推薦システムがどのように誕生し、広まっていったかを述べておく。広義には情報検索や情報フィルタリング技術の一つと見なせるので、初期の推薦システムはこれらの技術を基盤としていた。1994年に、他人が知っている情報を検索するという過程を自動化した GroupLens [4] などのシステムが開発され、現在の推薦システムの基礎となった。1997年には *ACM Communications* 誌での上記の特集 [1] により、この種のシステムの呼び名として “Recommender System” が定着した。このころには推薦システムの商業化も始まり、Web を通じた各種サービスの機能として活用されたり、セットトップボックスなどの機器に組み込まれたりし始めた。現在では、多方面で利用されるようになり、研究も継続的に行われ、多様な方法が目的に応じて考案されている。

推薦システムの構成

推薦システムは、データの入力、嗜好の予測、そして推薦の提示の三つの段階で推薦を行う。これは O-I-P モデル (output-input-process model) [2] とも呼ばれている。

データの入力 推薦を受けようとしている活動利用者 (active user) が、いろいろな商品などの対象についての好みの度合いを示した嗜好データ (preference data) や、自身の関心のある対象についての具体的な記述である批評 (critique) をシステムに入力する。そのほか、アイテムの特徴データ、活動利用者自身の属性情報なども扱う場合がある。

嗜好の予測 活動利用者の嗜好データに加え、収集しておいた利用者の他の情報やアイテムの情報を利用して、活動利用者には未知のアイテムへの活動利用者の嗜好を、機械学習技術や人手で獲得したルールを用いて予測する。

推薦の提示 予測した嗜好に基づいて、目的に応じた適切な形式で、推薦結果を活動利用者に提示する。

推薦システムの設計要素

推薦システムの設計時に考慮すべき要素を紹介する。

予測精度とは、推薦したアイテムに、実際にどれくらい利用者が関心を持つかという規準である。利用者に関心のないアイテムを推薦しても役に立たないので、予測精度は最も重視すべき規準である。活動利用者がアイテムに与えるであろう5段階評価などの評価値を予測する評価値予測 (predicting ratings) の場合では、実際に利用者が与えた評価値との類似度を評価指標とする。利用者にとって関心のあるものを何かしら提示する適合アイテム推薦 (recommending good items) の場合では、適合率や再現率といった情報検索分野の指標を利用する。

多様性は、同時に推薦したアイテム群や、続けて推薦した一連のアイテム群などが互いにどれほど似ていないかという規準である。たとえ関心があるものを推薦されていても、色違いなど似通ったものが続くとは利用者は推薦に飽きるであろう。そのため、たとえ予測精度を多少下げても、多様性を確保することは重要である [5]。

コールドスタート問題 (もしくは、スタートアップ問題) とは、推薦システムを使い始めた新規利用者や、新たに推薦候補としてシステムに加えられた新規アイテムに対して、利用者の嗜好を予測することが難しいという問題である。推薦理由とは、このアイテムを推薦する理由であり、これを提示することで利用者は推薦をより受け入れるようになる [6]。プライバシー保護推薦システムでは、嗜好データは重要な個人情報であるので、これを保護する目的で個人の嗜好データを秘匿したままで推薦を行う。サクラ攻撃 (shilling attack) とは、特定のアイテムがより頻繁に推薦されるように、もしくはあまり推薦されないようにするために、ニセの嗜好データを入力して推薦システムの挙動を操作しようとすることである。人気バイアスとは、多くの人が好むアイテムを推薦することが多いという傾向のことで、推薦の多様性が低下したりするため望ましくない性質とされている。その他、家族など複数の利用者が好むであろうアイテムを見つけるグループ推薦や、利用者間の友人関係などを利用するソーシャル推薦などが研究されている。

嗜好の予測手法

利用者の嗜好を予測する主な方針には、内容ベースフィルタリング (content-based filtering) と協調フィルタリング (collaborative filtering) がある。内容ベースフィルタリングでは、アイテムの性質と利用者の嗜好パターンとの関連性のパターンを抽出して、このパターンに基づいて利用者の嗜好を予測する。アイテムの性質を特徴ベクトルで表し、そのアイテムに利用者が関心があるかどうかを予測する分類問題として定式化することで、既存の機械学習手法を用いて実現できる。もう一つの協調フィルタリ

ングでは、アイテムの性質はまったく考慮せず、あらかじめ蓄積しておいた、多くの利用者の、いろいろなアイテムに対する嗜好データを利用する。そして活動利用者と嗜好パターン、すなわち、どのアイテムを好み、どのアイテムを嫌うのかという傾向を活用して推薦する。この協調フィルタリングには、GroupLensの方法をはじめとする専用のアルゴリズムを用いる。

両者の特長を比較しておく。内容ベースフィルタリングでは、新規アイテムに対しては、そのアイテムの特徴さえわかれば推薦対象として考慮できるため、スタートアップ問題については有利である。なお、新規利用者に対しては大きな差はない。内容ベースフィルタリングでは自身の過去の嗜好データのみを利用しているので、協調フィルタリングのほうが多様性のある推薦ができると言われている。また、アイテムの特徴を獲得し、それらを維持・管理するコストが内容ベースフィルタリングでは必要になるが、これが不要である点も協調フィルタリングの長所と言える。

なお、これらの二つの方針のそれぞれの長所を生かすように組み合わせたハイブリッドな方法も一般的になっている。その他、自分の嗜好を満たすアイテムの条件を指定する検索質問や、現在の候補に対して改善すべき点を指定する批評を用いる知識ベースフィルタリング (knowledge-based filtering) もある。

参考文献

- [1] Resnick, P. and Varian, H. R. Recommender Systems. *Communications of the ACM*, Vol. 40, No. 3, pp. 56–58, 1997.
- [2] Konstan, J. A. and Riedl, J. Recommender Systems: Collaborating in Commerce and Communities. In *Proc. the SIGCHI Conf. on Human Factors in Computing Systems, Tutorial*, 2003.
- [3] Maes, P. Agents That Reduce Work and Information Overload. *Communications of the ACM*, Vol. 37, No. 7, pp. 30–40, 1994.
- [4] Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., and Riedl, J. GroupLens: An Open Architecture for Collaborative Filtering of Netnews. In *Proc. the Conf. on Computer Supported Cooperative Work*, pp. 175–186, 1994.
- [5] Ziegler, C. N., McNee, S. M., Konstan, J. A., and Lausen, G. Improving Recommendation Lists Through Topic Diversification. In *Proc. the 14th Int'l Conf. on World Wide Web*, pp. 22–32, 2005.
- [6] Jannach, D., Zanker, M., Felfernig, A., and Friedrich, G. *Recommender Systems: A Introduction*. Cambridge University Press, 2012. 【邦訳】田中克己, 角谷和俊 訳. 情報推薦システム入門—理論と実践. 共立出版, 2012.

■ 神鷹敏弘

[17-4]

協調フィルタリング

Collaborative Filtering

はじめに

協調フィルタリングは、推薦システム (recommender system) で利用者のアイテムに対する嗜好を予測する方針の一つである。アイテムの特徴に基づいて予測する内容ベースフィルタリングに対し、協調フィルタリングではアイテムの特徴は用いない。その代わりに、多くの利用者の、いろいろなアイテムに対する嗜好データを事前に集積して予測に利用する。嗜好データを集積しているこれらの利用者を標本利用者 (sample user) といい、推薦をこれから受けようとする利用者を活動利用者 (active user) という。そして、嗜好パターン、すなわち、どのアイテムを好み、どのアイテムを嫌うのかという傾向を活用して推薦するのが協調フィルタリングである。

協調フィルタリングという用語は推薦システムという用語より古く、1992年に文献[1]において使われた。しかし、他人が手動で行った推薦を検索できる協調作業支援のシステムであり、これは現在の協調フィルタリングとは異なっていた。現在のような自動化されたGroupLens法[2]などは、1994年に提案され、その後電子商取引サイトなどで普及した。

形式的問題設定

協調フィルタリングによる嗜好の予測問題を形式的に定義する。 n 人の全利用者の集合を $\mathcal{X} = \{1, \dots, n\}$ とし、 m 種類の全アイテムの集合を $\mathcal{Y} = \{1, \dots, m\}$ とする。評価値行列 \mathbf{R} は利用者 $x \in \mathcal{X}$ の、アイテム $y \in \mathcal{Y}$ への評価値 r_{xy} を要素とする行列である。活動利用者を添え字 a で表す。すなわち、 r_{ay} は活動利用者のアイテム y への評価値である。

利用者にアイテムを明示的に5段階尺度などで評価してもらるか、暗黙的に評価してもらうかによって、 r_{xy} の定義は異なる。明示的評価では、標本利用者 x が明示的に評価したアイテム y については、 r_{xy} は評価値の定義域 \mathcal{R} (例: 5段階評価では $\mathcal{R} = \{1, \dots, 5\}$) 中のいずれかの値をとる。一方、未評価であれば欠損値 \perp となり、この欠損している評価値を、 \mathbf{R} 中の評価済みの値から予測する。

暗黙的評価では、利用者 x が閲覧・購入するなどの行動をしたアイテム y を暗黙のうちに肯定的に評価したと見なし、 $r_{xy}=1$ とする。行動が何もなく利用した利用者・アイテムの対については、否定的評価か、単に未評価なのか区別で

pedia, ConceptNet 5とは異なり、関係名の統制は行われていない。そのため、ReVerbにより獲得した関係を、より形式的な大規模知識ベースとするためには、何らかの後処理が必要だと考えられる。例えば、ConceptNet 5では、Wikipediaのテキストを対象に、ReVerbを用いて関係を抽出し、フィルタをかけることによって、ConceptNetに利用可能な関係のみの抽出を行っている。

Freebaseは、集合知的に構築された大規模知識ベースであり、そのシステムは2007年3月にアメリカのソフトウェア会社Metawebにより開発された。Metawebは2010年にGoogle社に買収され、現在Freebaseは、Googleのナレッジグラフ（さまざまな情報源からGoogle社が構築した知識ベースで、検索結果の拡張に利用されている）の一部に利用されている。2014年12月に、Freebaseのデータは、Wikidataに移されることが発表され、2015年12月には、Freebase APIをKnowledge Graph APIに置き換えることが発表された。Wikidataは、ウィキメディア財団により2012年10月に設立された、Wikipediaなどで利用可能な構造化データを集合知的に構築するプロジェクトである。2016年2月現在、約1600万のデータ項目が定義されている。

このように、1980年代と1990年代の専門家による手動構築では数十万オーダーであった大規模知識ベースは、2000年代に入り、集合知アプローチにより多言語対応が行われるとともに、数千万から数十億オーダーへと規模が拡大している。しかしながら、(半)自動や多人数での集合知アプローチによる知識ベース構築では、作業間で整合性を確保することは難しく、規模は拡大したが、質の面では課題が増えていると考えられる。近年、schema.orgや共通語彙基盤[17]など、ドメインに依存せずに、広く利用可能なクラスやプロパティ（関係名）を標準化する活動が進められている。今後、これらの標準語彙に基づく大規模知識ベースが集合知アプローチにより構築されることで、量と質がともに高い知識モデリングが可能になっていくと考えられる。

参考文献

- [1] Cyc. <http://www.cyc.com/>
- [2] WordNet. <https://wordnet.princeton.edu/>
- [3] EDR 電子化辞書. https://www2.nict.go.jp/out-promotion/techtransfer/EDR/J_index.html
- [4] The Global WordNet Association. Global WordNet Association, 2013. <http://globalwordnet.org/>
- [5] Lehmann, J., Isele, R., Jakob, M., Jentzsch, A., Kontokostas, D., Mendes, P. N., Hellmann, S., Morsey, M., van Kleef, P., Auer, S., and Bizer, C. DBpedia — A Large-scale, Multilingual Knowledge Base Extracted from Wikipedia. *Semantic Web Journal*, Vol. 6, No. 2, pp. 167–195, 2015.
- [6] 玉川奨, 桜井慎弥, 手島拓也, 森田武史, 和泉憲明, 山口高平. 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, 2010.

- [7] Speer, R. and Havasi, C. ConceptNet 5: A Large Semantic Network for Relational Knowledge. In Hovy, E., Johnson, M., and Hirst, G., editors, *Theory and Applications of Natural Language Processing*, Chapter 6, pp. 161–176, Springer, 2013.
- [8] Fader, A., Soderland, S., and Etzioni, O. Identifying Relations for Open Information Extraction. In *Proc. the Conference on Empirical Methods in Natural Language Processing (EMNLP'11)*, pp. 1535–1545, 2011.
- [9] Wikidata. <https://www.wikidata.org/>
- [10] Suchanek, F., Kasneci, G., and Weikum, G. Yago: A Large Ontology from Wikipedia and WordNet. *Journal of Web Semantics*, Vol. 6, No. 3, pp. 203–217, 2008.
- [11] Singh, P., Lin, T., Mueller, E. T., Lim, G., Perkins, T., and Zhu, W. L. Open Mind Common Sense: Knowledge Acquisition from the General Public. In *Proc. the 1st. International Conference on Ontologies, Databases and Applications of Semantics for Large Scale Information Systems*, pp. 1223–1237, 2002.
- [12] Wiktionary. https://en.wiktionary.org/wiki/Wiktionary:Main_Page
- [13] UMBEL. <http://umbel.org/>
- [14] von Ahn, L., Kedia, M., and Blum, M. Verbosity: A Game for Collecting Common-Sense Facts. In *Proc. the SIGCHI Conference on Human Factors in Computing Systems (CHI 2006)*, pp. 75–78, 2006.
- [15] 中原和洋, 山田茂雄. 日本でのコモンセンス知識獲得を目的とした Web ゲームの開発と評価. *Unisys 技報*, Vol. 30, No. 4, pp. 295–305, 2011.
- [16] ClueWeb09. <http://lemurproject.org/clueweb09.php/>
- [17] 共通語彙基盤. <http://goikiban.ipa.go.jp/>

■ 森田武史

[18-14]

オントロジー

Ontology

定義

オントロジーとは本来哲学用語であり、「存在に関する体系的理論（存在論）」という意味である。しかし、情報科学においては哲学とは少し異なった意味で用いられている[1]～[4]。普遍的な定義はないが、トム・グルーバーによる“an explicit specification of a conceptualization”（概念化の明示的規約）[1]が広く受け入れられている。ここでの「概念化」（conceptualization）とは、対象世界を計算機内にモデル化した際に、「その記述者が対象世界に

存在すると考えたものやそれらの間の関係」を指す。概念化には複数のものがありうることから、ある特定の概念化を（計算機的に）明確に意味的規約として記述したものがオントロジーである、ということの意味している。

この概念化という観点からより明確にオントロジーを定義したものが、溝口による「対象とする世界の情報処理的モデルを構築する人が、その世界をどのように「眺めたか」、言い換えるとその世界には「何が存在している」と見なしてモデルを構築したかを（共有を指向して）明示的にしたものであり、その結果得られた基本概念や概念間の関係を土台にしてモデルを記述できるような概念体系」[2]である。この定義は、オントロジーの本質的な使われ方にも言及しており、より包括的になっている。

一方、共有性や共通性に注目すると、オントロジーは対象領域に共通に現れる基盤的な概念の意味と関係を定義し、コミュニティなどにおいてモデルや知識の中で共通に利用されるものと捉えられる。

構成内容と構築

オントロジーをどのような要素から構成されるものか（構成論）という観点から見ると、「知識・モデルに現れる基盤的な概念クラスとそれらの間の意味リンクから構成された“概念体系”（conceptual system）」であると言える。ここで、概念クラスとは対象世界を構成する個別的な要素（個物; individual; instance）の種類（型またはタイプ）を表すようなものと理解しておく。例えば、「人間」のようなエンティティ的なもの、「運行情報」のようなプロセス的なもの、「親戚関係」のような関係的なもの、「著者」のような役割（ロール）を表すもの（[18-15], [18-16]参照）などがある。ここでの“概念体系”とは、概念クラスの意味が、意味リンクによって示される計算機的に明示的な関係性をもって、一つの整合性のあるシステム（体系）として定義されていることを意味する。

意味リンクの代表的な種類としては、以下のものが挙げられる（[18-16]参照）。

- 一般-特殊関係（general-specific relation）：ある概念クラスXが概念クラスYの一種であるという分類関係を表す。is-a関係（is-a relation）、kindOf、subClassOf、subsumption などと呼ばれる（厳密には意味が異なる）。この関係を用いて関係付けられた階層は概念分類階層（conceptual classification hierarchy）（または単に概念階層（conceptual hierarchy））と呼ばれ、オントロジーの主要な構成要素である。一般に、概念クラスXは下位クラス、クラスYは上位クラスと呼ばれ、例えば、人間クラスはほ乳類クラスの下位クラスである。下位クラスのすべてのインスタンスは上位クラスのインスタンスでもあり（包摂関係; subsumption relation）、推移律

（transitivity）が成り立つ。

- 全体-部分関係（whole-part relation）：一般に構造的な部分関係を表す。part-of関係（part-of relation）、hasPart、partOf、has-a などと呼ばれる。例えば、人間クラスと腕クラスの間には全体-部分関係が存在するという意味制約が定義され、典型的な人間インスタンスには二つの腕インスタンスとの間に全体-部分関係が成り立つ。
- 属性関係（attribute-of relation）：ある概念に密接に依存している概念との関係をいう。例えば、「もの」クラスには重さという属性があり、特定のもののインスタンスは重さ属性の値として特定の重さ（例えば15kg）を取る。

なお、[18-5]で述べられているように、オントロジーの記述内容のレベルはさまざまであり、これらのすべての記述要素が必ず現れるわけではない。また、それに伴ってさまざまな呼ばれ方がされている。

このような内容を持つオントロジーの構築には、大きく分けて、人間主導で手動を主とする方法（[18-20]参照）と、何らかの情報源から（半）自動的に構築する方法（[18-21]参照）がある。構築方法論についても多くの提案がある（[18-19]参照）。また、既存オントロジーの再利用や異なるオントロジー間の相互運用のために、異なるオントロジーの概念同士の対応付け（オントロジー写像; ontology mapping, [18-22]参照）も重要な技術である。

オントロジーは一般的にはオントロジー表現言語（[18-17]参照）を用いて記述される。領域固有の推論規則的なものは別途ルール記述言語を用いて記述される（[18-18]参照）。なお、オントロジー表現言語（例えば、OWL）で記述されたものがオントロジーというわけではなく、1階述語論理で論理的に表現されたり、UMLなどの図的形式で表現されたりすることもあり、オントロジーとは表現形式ではなく表現されている内容と果たす役割で規定されるものである。また、セマンティックWeb技術RDF、RDFS、OWLなどやその基礎となる記述論理においては、上述の意味リンクのうちsubClassOfを除くすべての2項関係を「プロパティ」（property）と呼び、関係やロールを表す概念クラスもプロパティとして表現されることがある。また、オントロジー工学的には「ある属性が特定の値を持つこと」（例：赤い）がプロパティと呼ばれるべきであるが、区別されていない[5]。一方、論理学では、概念（例：human(X)）と「特定の属性値を持つこと」（例：red(X)）は、ともに単項述語で表現され、区別されずに「プロパティ」と呼ばれる。

利用と役割

オントロジーの利用形態とその役割は、その記述内容のレベル（[18-5]参照）とも関連して、多岐にわたる[6]。基

本的な役割は[18-5]を、詳しい分類は[18-25]を参照されたい。ここでは知識やメタデータなどを記述するときと利用するときに分けて、典型的な役割と記述レベルとの関係を概観する。

(1) 知識を記述するとき

語彙統一 知識記述の際に現れる語彙を統一し、標準化を行う。この目的には語彙セット、ターミノロジー、タクソノミーなどの記述レベルのものが用いられることも多い。

構造統一 共通のデータ構造を与え、データ構造を統一し、標準化する。この利用形態のものは分類階層も持たないデータスキーマ的なものであることが多く、実際、スキーマと呼ばれることが多いが ([18-5] 参照)、統一性や標準性を指向している。

知識規約 語彙やデータ構造ではなく、知識やモデルの内容について規約を与え ([18-3] 参照)、知識の一貫性や再利用性を向上させる。知識やモデルに関する知識であることから、相対的にメタ知識やメタモデルと呼ばれることもある。

体系化 知識間の関係に関する概念と規約を与え、異種の知識を一貫性を持って位置付け・対応付けすることで、包括的統合に貢献する ([18-23] 参照)。

(2) 記述された知識を利用するとき

意味共有 ドキュメント、データ、知識などの意味を明確にし、共有する基盤を提供することで、人間同士のコミュニケーション支援、計算機システムのユーザーインタフェースの向上、計算機システム間のデータ交換や共有に貢献する。

意味的検索 (情報アクセス) Web リソースなどへのアクセスを、意味が明確で構造化された知識を用いて知的に行う。しばしば、意味 (的) 検索と呼ばれ、検索結果の構造化や、明確化された関係性に基づいて情報を結合してたどることを意味することが多い。

意味的な分析/抽出/推論 情報へのアクセスに加えて、その内容を意味的観点から分析することで、情報の分類や要約、知識の抽出/発見、情報推薦の実現に貢献する。広い意味で、意味的な推論と呼ばれる。

意味的な変換/統合 オントロジー写像 ([18-22] 参照) などに基づいて、異なる情報源におけるデータや知識の連携、統合、串刺し処理などを可能にし、分散型大規模知識ベース (large-scale knowledge base) として扱うことを可能にする。

なお、いずれの利用形態においても、オントロジー自体と、それに基づいて記述される領域の知識やモデルは、明確に区別する必要がある。オントロジーは、対象領域において一般性と時間的な安定性を持ち、一部の専門家によって記述され、その領域で共有されるものである。一方、領

域の知識やモデルは、多くの人によって大量に記述され、対象 (インスタンス) に固有な個別的な知識を含み、時間的変化も比較的速いと考えられる。セマンティック Web や Linked Open Data (LOD) における RDF トリプルの多くは、その典型的なものと言える。逆に言えば、対象領域で一般性を持ち安定的な基盤の概念がオントロジーで定義されるべきであり、オントロジー構築にかかるコストが一般性・共有性・安定性によってそれに見合うことが期待される。

分類

オントロジーは、まずその構成要素となる対象概念から、以下の三つに分類できる。

- 上位オントロジー (upper ontology) ([18-15] 参照): 物体、時間、空間、プロセスなどのいずれのオントロジーにも共通に現れるような抽象度の極めて高い概念から構成される。ドメインオントロジーを構築する際の指針を与える ([18-9] 参照)。
- タスクオントロジー (task ontology): 診断、設計、計画、制御、教育、訓練など、エキスパートシステムが対象とする問題解決の型 (タスク) を対象としたオントロジー [7][8]。例えば、診断タスクオントロジーには、故障仮説、兆候、信頼度などの概念と、仮説照合、観測、故障仮説生成などの診断に固有の操作が含まれる。タスクオントロジーは、対象とする問題解決過程をドメイン独立に記述するために必要な概念を提供すると同時に、問題解決過程において必要となるさまざまな知識 (概念) が果たす役割を明示する。
- ドメインオントロジー (domain ontology): 特定の具体的な対象世界のオントロジー。通常、オントロジーと言うと、この種のオントロジーを指すことが多い。信頼できる上位オントロジーに基づいて、タスク依存の概念を除いた客観性の高いオントロジーの構築が望まれるが、それは容易ではない。

別の観点からの分類として、[18-5]でも述べられているが、軽量オントロジー (light-weight ontology) と重量オントロジー (heavy-weight ontology) という区別がある。典型的な前者のオントロジーは、実用性を重要視し、概念の意味はあまり厳密性を意識せずに自然言語で定義され、緩い意味での「分類関係」で構成される。半自動なオントロジー学習 ([18-21] 参照) などによって機械的に構築される場合もある。後者は、対象の世界からの基盤の概念の切り出しという「概念化」を強く意識し、厳密な意味での一般-特殊関係や全体-部分関係などの多くの関係や公理によって豊かな概念の意味が記述されたものを指す。概念の切り出しや関係性の正当性や根拠が議論され、哲学的レベルの考察に基づくものもある。

なお、重量オントロジーにおける「概念クラス」と、軽量オントロジーまたはオブジェクト指向論で一般に言われる「クラス」とは意味が違うことに注意が必要である。後者におけるクラスは単に外延的なインスタンス集合を意味する（または直接的に対応する）ことが多いが、前者はそれに加えてクラスとして認定する哲学的な根拠や正当性が求められることが多い。また、クラスの同定と識別は、それが本質とする属性の性質に基づいてなされる [2][4] ([18-16] 参照)。

さらに、異なる分類として、概念と言語的な語彙との関係から、言語的オントロジー (linguistic ontology) ([18-24] 参照) と非言語的オントロジーに分けることができる。前者は言語的表現を中心としており、一般的な辞書と同じように各語彙が一般にこのような意味で用いられるという記述的 (descriptive) な定義を与える。非言語的オントロジーにおいては、概念が中心であり、言語的表現 (語彙) は概念を表すラベルでしかない。その意味定義は、オントロジー構築者が概念をそのような意味でのみ用いるということを宣言した規約的 (prescriptive) なものである。つまり、概念の意味や用いられ方を限定して誤解や解釈の揺れを防ぐ「意味制約」 (semantic constraint) を与え、知識やモデルを規約する役割を果たすものである。

参考文献

- [1] Gruber, T. R. A Translation Approach to Portable Ontology Specifications. *J. of Knowledge Acquisition*, Vol. 5, No. 2, pp. 199–220, 1993.
- [2] 溝口理一郎. オントロジー工学. オーム社, 2005.
- [3] Staab, S. and Studer, R., editors. *Handbook on Ontologies*. 2nd Edition. Springer-Verlag, 2009.
- [4] 溝口理一郎. オントロジー工学の理論と実践. 知の科学. オーム社, 2012.
- [5] 古崎晃司, 来村徳信, 笹島宗彦, 溝口理一郎 著, 溝口理一郎 編. オントロジー構築入門. オーム社, 2006.
- [6] 来村徳信 編著, 人工知能学会 編. オントロジーの普及と応用. オーム社, 2012.
- [7] Mizoguchi, R. et al. Task Ontology for Reuse of Problem Solving Knowledge. In *Knowledge Building and Knowledge Sharing (KB & KS'95)*, pp. 46–59, 1995.
- [8] 堀雅洋, 瀬田和久. 問題解決タスクのためのオントロジー. 人工知能学会誌, Vol. 19, No. 2, pp. 159–165, 2004.

■ 来村徳信・溝口理一郎

[18-15]

上位オントロジー

Upper Ontology

はじめに

上位オントロジーとは、世界に実在するすべての物事の実在の様相を説明するために必要十分なカテゴリの体系であり、領域に固有の概念体系の構築の際に有益な指針を与えてくれる。オントロジー ([18-14] 参照) は、上位オントロジー、領域オントロジー、アプリケーションオントロジー、そして、タスクオントロジー (task ontology) [1] に分けることができるが、上位オントロジーは最も哲学的である。上位オントロジーを構築する上で最も重要で根本的な観点に 3D vs. 4D がある。これらは、世界を 3 次元空間と時間とからできていると見るか、時間を 4 次元目の軸と見なして、一つの様な時空間を構成しているとするかの違いを意味する。前者ではオブジェクトが生起物 (occurrent) に優先する。後者では逆となり、オブジェクトは 4 次元空間の軌跡として概念化される。生起物が時間的な部分 (temporal part) を持つことは両者に共通の理解であるが、後者ではオブジェクトも時間的部分を持つと見なされ、前者ではオブジェクトは時間的部分を持たないとされる。オブジェクトは生起物の様相でしか実世界に存在できないことから、4D の観点が理論的には優勢に見えるが、常識との親和性は 3D 的観点のほうが高い。

基本的な区別

上位オントロジーを理解するためには、上述の観点に加えて、いくつかの基本的な区別が重要となる。代表的な例として、物 (continuant) と生起物 (occurrent)、独立物と従属物、プロセスとイベント、具体物と抽象物、物と属性、質と量などを挙げることができる。実際、これらは上位オントロジーを構成する重要なカテゴリとなっている。独立物とは、人、会社、山などのように、その存在に他の存在物を必要としないものであり、従属物は必要とするものである。従属物の例は夫、社長、標高などであり、それぞれ、妻、会社、山がなければ存在できない。プロセスとイベントはいずれも時間空間に存在する occurrent であるが、プロセスは ongoing かつ progressive であり、変化できる。一方、イベントは常に時区間全体として捉えなければならず、変化できないという相違がある。質と量に関しては、そもそも量とは何か？という問題などがある。例えば、10cm という長さが長さのインスタンスであるとする

- [9] *Journal of Field Robotics*, Vol. 25 of *Special Issue: Special Issue on the 2007 DARPA Urban Challenge, Part III*. John Wiley & Sons, 2008.
- [10] Fish, S. Route Description, 2003. <http://archive.darpa.mil/grandchallenge04/conference/route.pdf>
- [11] Fagan, M. DARPA Grand Challenge Rules, 2003. <http://archive.darpa.mil/grandchallenge04/conference/rules.pdf>
- [12] Course map and positions, 2005. <http://archive.darpa.mil/grandchallenge05/gcorg/index.html>
- [13] Stanford Racing Team's Entry In The 2005 DARPA Grand Challenge, 2005. <http://archive.darpa.mil/grandchallenge05/TechPapers/Stanford.pdf>

■ 坪内孝司

[21-12]

ロボカップ

RoboCup

ロボカップとは、幅広い技術の開発と統合を必要とするような標準問題を提供することで、人工知能や知的ロボットの研究および教育を促進しようとする国際的活動である。その最初のドメインとしてサッカーが取り上げられ、以下のような目標が掲げられている。

2050年までに完全自律人間型ロボット（ヒューマノイド）のチームを作成し、人間のワールドカップサッカーのチャンピオンチームに勝つ。

この目標はあくまで象徴的なものであり、自律エージェント（autonomous agent）や自律ロボット（autonomous robot）の制御、チームワークなど分散協調、実時間処理、センサフュージョンなど、さまざまな技術の確立を具体的な目標としている。

サッカーを例題としてマルチエージェント（multi-agent）やマルチロボットの研究を行う動きは、1990年代初頭から見られ始めた。これらの動きをまとめ上げ、多くの研究者に利用可能なテストベッドを提供する目的で、1995年にロボカップ委員会が設立され[1]、1997年より毎年、国際会議と競技会が催されている。また、サッカーに続く第二のドメインとしては、災害救助を題材とするロボカップレスキューが2000年から始められ、創造的な科学技術教育を推進するロボカップジュニアも、活動の一環として取り組まれている。

対戦型のゲームは人工知能の歴史の初期から例題として取り上げられてきており、特にチェスをはじめとするボードゲームは、簡潔で決定論的なルール記述が可能で、計算

機での扱いが容易であるため、精力的に研究されてきた。このチェスとサッカーの人工知能問題としての特徴を対比すると、表1のようにまとめることができる。

表1 チェスとサッカーの人工知能問題における特徴

	チェス	サッカー
環境	静的	動的
行動と状態の変化	ターン制	実時間
環境の知覚	完全	不完全
思考と制御	集中	分散

サッカーが例題として取り上げられてきた背景には、計算機の実世界への応用が広がるにつれ、確率的事象や情報の不完全性、実時間性など、ボードゲームには現れない問題の重要度が増してきたことが挙げられる。

ロボカップで実際に取り上げられている研究課題には、以下のようなものがある。マルチエージェント環境（multi-agent environment）における機械学習（machine learning）としては、学習によるエージェントの行動の変化が他のエージェントに及ぼす影響や、チームとしての効率の改善に対するクレジットアサインメント（credit assignment）などが課題となっている。また、ロボットやセンシング技術に関しては、動きの速い環境における実時間認識や、外乱に強いロバスト制御技術、能動的なセンシング技術などが重視されている。マルチエージェントシステム（multi-agent system）の分野では、協調行動における役割の記述方法や、状況に応じた動的な役割分担の機構、環境の変化に追従できる実時間分散プランニングが取り上げられている。また、他のエージェントやロボットの意図などを観察によって推定するエージェントモデリング（agent modeling）も重要課題となっている。

個々の要素技術だけでなく、これらの技術を組み合わせで安定して動作するシステムを作る統合化技術も重視されている。サッカーのような実世界問題では多岐にわたる技術が要求される。人工知能の分野に限っても低レベルのセンサの適応や行動制御の学習から、高レベルの分散プランニング（distributed planning）やモデル推定などまで、チームの実現には多くの技術を必要とする。

このような視点から、階層的学習法[2]など複数の技術を柔軟に組み合わせる手法の研究が取り組まれている。

参考文献

- [1] Kitano, H., Asada, M., Kuniyoshi, Y., Noda, I., Osawa, E., and Matsubara, H. RoboCup: A Challenge Problem for AI. *AI Magazine*, Vol. 18, No. 1, pp. 73–85, 1997.
- [2] Stone, P. Layered Learning in Multiagent Systems: A Winning Approach to Robotic Soccer, 2000. <http://www.cs.utexas.edu/~pstone/book/>

■ 北野宏明・浅田 稔