

特集 「機械学習、それが人に及ぼさる理由」

知識や経験の再利用による処理手続きの獲得

Acquisition of Internal Procedure by Reuse of Knowledge and Experience

大森 隆司
Takashi Omori

北海道大学工学研究科
Graduate School of Engineering, Hokkaido University.
omori@complex.eng.hokudai.ac.jp, <http://lis2.huie.hokudai.ac.jp/>

Keywords: functional parts combination, problem solving, procedure acquisition.

1. 問題提起

人の学習では、発達の非常に初期においては単純な学習を行い、成長とともにしだいに複雑な問題を学習し、最後には強力な問題解決能力をもつことが知られている。そのような発達の過程を学習機械の観点から見てみると、その根源には①過去の経験に新しい知識を追加して、②それらの知識を多様に組み合わせ、③眼前の問題に対してすばやく適用する能力、があるように見える。人は問題を解決する能力が発達や経験とともに増加していつている。

そこで個々の問題解決の処理過程を考えてみよう*1。例えば初めて見る新しい形のドアノブを操作してドアを開けるという行動を考えてみると、そこではドアノブの形の認識、状況から推測される必要な行動の推定、過去の経験に基づく可能な動作の選択、その動作の身体との協調的な実行、失敗した場合の代替行動の選択と実行、といった多様な内部処理があるはずである。そして我々は新しいドアノブに対してでもたいては数回の試行で開けることに成功する。類似の問題解決行動は、家電製品や計算機の操作、自動車や機械類の操作、コミュニケーションの実現など多様な場面で求められている。

その行動に関連した脳内の情報処理過程を考えてみると、そこには多様な感覚入力、記憶のアクセス、動作の効果の予測、既知の行動の実行、新しい動作の探索、など多様な処理と動作が含まれた一連の処理（計算機の用語で言うところの手続き）となっている。さらにそれらの内的手続きは前の処理の結果によってどんどん変更されていく動的な側面をもち、試行錯誤的に探索されていることも多い。もちろん、物理法則や日常的な動作などの過去の経験から来る知識は積極的に利用されるし、

*1 人における問題解決の内部過程はもちろん観測できないが、少なくとも過去のAI研究は類似の問題における情報処理過程を、また神経科学や心理学は類似課題における神経活動や行動を、さらに脳の非侵襲的な計測法は各種課題における人の脳の活動を明らかにしており、それらを統合すれば人の問題解決過程はそこそこに推定可能であろう。

作業記憶のような脳内の資源も動員される。すなわち、人は必要に応じて短期間に自分の内部処理を改変して多様な問題解決を行う能力をもっている。その能力の背景には、多様な知識や経験の段階的な蓄積があることは言うまでもない。

一方の機械学習では、我々は段階的な発達は期待しない。ある学習手法は応用としてたくさんの問題に適用される。しかし一つの学習器は一つの課題に特化して利用され、人のように次々と新しい問題にアプローチして汎用の能力を身につけることはない。それは我々が意図して選択した基本的な方針の違いかということでもなさそうである。鉄腕アトムにあこがれる我々は、そのような汎用知能を希求しているし、AIとはもともとはそのようなものであったと感じる。ではなぜ個々の問題に特化した技法があって、それらを統合して人間のような汎用知能に展開させる手法が少ないのか？そこに現在の機械学習の方向の弱みがあるような気がする。

人の脳の発達の基本的な流れは、個体の学習であり、単純なタスクから複雑なタスクへと段階的に経験を積みながら、その知的機能を増加させていく。そこにはどういいう処理原理があるのだろうか？本稿では脳のモデル化を通してそれについて論じてみたい。

2. 我々のアプローチ：脳の認知モデル構築と構成的研究

我々は脳の高次機能についての計算論的なモデルを研究してきた。その狙いは、知能といわれる人で特に強力な能力の実現原理を、脳のマクロな認知処理を対象として解明し、計算機などの情報処理装置で実現することで、人に近い、あるいは親和性の高い知能システムの原理を探し出すことにある。当面の研究対象は発達現象で、幼児の言語獲得や非言語の問題解決行動の現象について、計算論的モデル化と構成的研究を行っている。そのモデル化の過程で我々が取っている基本的な考え方は、脳の機能部品組合せモデルである。

このモデルには二つの主要な概念がある。第一は、脳の部分機能のモジュール性である。認知科学や最近の脳

の非侵襲計測の研究成果は、脳には機能のモジュール性があり、タスクに合わせて脳の部位が選択的に活性化されて、与えられた問題を解決することを示している。つまり、脳の各部位には異なる機能があり、脳はタスクに合わせて異なる機能を組み合わせて処理回路を構成することで、入力に対する適切な出力をつくっている。つまり、モジュール群の選択は処理手続きの構築となる。

第二の概念は、脳には問題に依存してモジュール群を探索するシステムがあるということである。モジュール群は選択されれば処理回路を構成して自動的に機能を果たすので、問題解決の方法を探すということは脳ではその問題に対応した部品を組合せを探索するというに等しくなる。もし個々のモジュールの学習が事前に終わっているなら、その探索が終わった瞬間に入力に対する適切な出力が出されて問題は解決されるということになり、人間特有の早い、その場で考えて解を見つける学習の説明ができる。

もちろん現実には、必要なモジュールとそれらの間の結合などがすべて事前にできていることはまれで、モジュール群の活性化で即問題解決とはいかないが、脳には神経回路の学習とは異なる、おそらくは認知レベルの探索的学習が存在すると考えられる。従来、このタイプの学習は記号処理や思考研究として多くのアプローチがなされてきたが、シンボルグラウンディング問題も含めて多様な問題があり、いまだ汎用性のある学習システムは構築されていない。

3. タスク対応の処理手続きの獲得

我々は、機能部品の組合せという考え方の妥当性を検証するため、地図世界のナビゲーションの学習問題を事例として、手続きの獲得を試みてきた。ナビゲーションという課題は問題世界のつくり方によって多様な処理を要求するタスクがつくれ、その地図の中で「ゴールに到達する行動を学習する」手続きを探索するという課題は、機能部品組合せの概念でどこまで複雑な手続きが実現でき

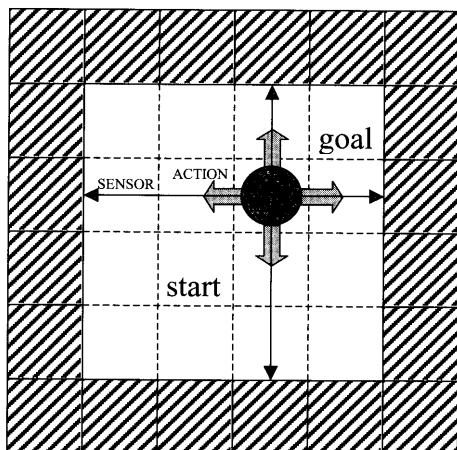


図1 「ナビゲーション行動を学習する」手続き探索のための世界

るのか検討するには都合が良い。ここでは図1に示した単純なグリッドワールドでのゴール到達を例題に説明する [Ogawa 02].

この目的のため我々は、もっている機能部品群が異なる2種類の学習エージェントを用意した。一つは、ナビゲーションを実現するのに必要最低限だけの機能部品群のみを与えられた basic agent (BA) である (図2)。もう一つは、basic agent に加えて環境の地図を覚える機能部品と作業記憶の機能部品を与えられた evolved agent (EA) である (図3)。各エージェントがもつ個々の機能部品は、場所の認識、Q学習、行動選択、乱数発生、作業記憶、環境の記憶(場所+行動→次の場所、場所+次の場所→行動)など比較的単純な神経回路であるが、そのほかにそれらの部品間のコネクションを選択的に活性化する内的な注意のベクトルを系列的に発生する注意システムがある。

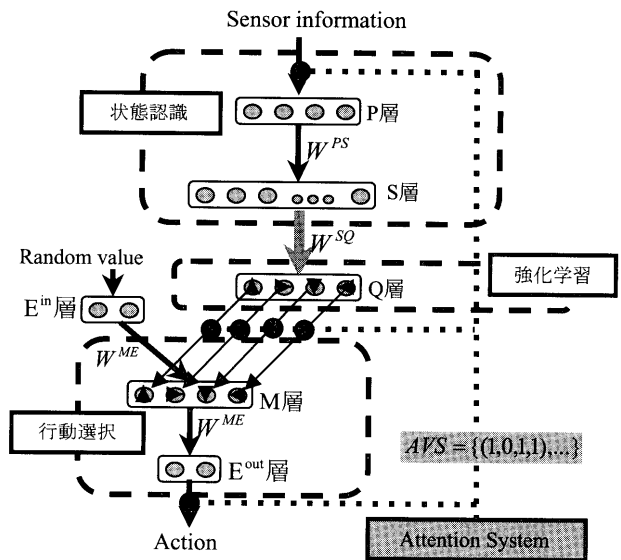


図2 Basic エージェント. 必要最低限の機能部品をもつ

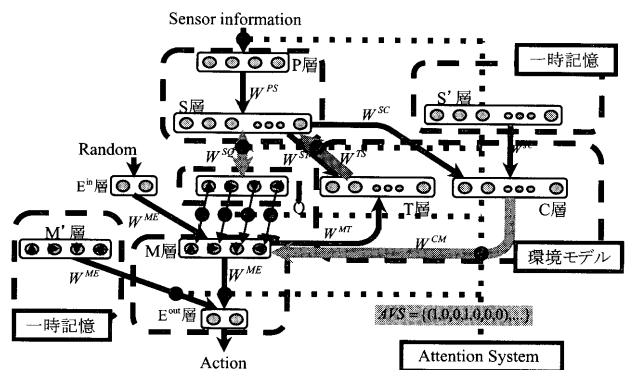


図3 Evolved エージェント. Basic agent に加えて、環境地図を覚えるのに必要な回路などをもつ

機能部品組合せモデルの特長は、タスクとその評価方式を与えられたなら、注意システムが注意ベクトルの系列を探索し、できるだけ高い評価を与えてくれる注意ベクトル系列、すなわち処理手続きを発見することにある。人

の個体で考えると、この探索には過去の類似タスクで用いた処理過程をもってそれを一部修正することになるが、過去の経験をもたない今回の探索では、ベクトル列の探索に有効な方式として知られている可変長 GA を使用した。もちろん、個体の学習に GA が適切かと言われると苦しいところではあるが、現実の探索には有効な道具であり採用した。探索パラメータは、集団サイズは 50、注意ベクトル列の系列は 10 まで、初期化は 0 または 1 のランダムである。各エージェントは、初期状態としては環境についても行動についても何も学習していない状態から、Q 学習タイプの強化学習によって最短ステップ数でゴールに到達するようになるまでの学習時間をその適応度とした。

その結果、以下のような機能部品の組合せが得られた。BA では、強化学習に必要な最低限の部品しかもっておらず、現在いる場所で最大の行動価値をもつ行動を取るといふ、強化学習ではよく知られた ϵ -greedy 戦略が獲得された [Sutton 98]。一方の EA では、初めの数世代では BA と同じ戦略を取っていたが、9 世代目に環境地図を利用して自分の行動の結果を予測・評価して行動を決定する予測モデルベースの強化学習の行動戦略が獲得された。図 4 に両エージェントの適合度の世代変化を示す。

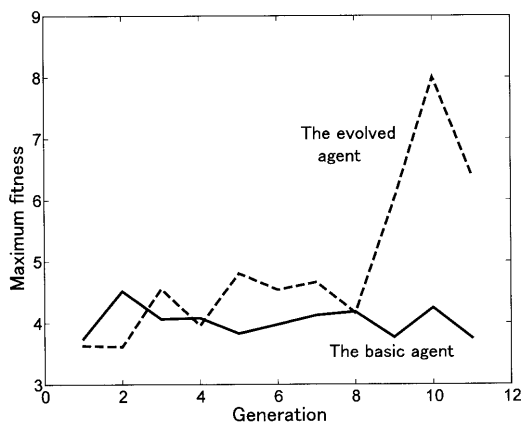


図 4 BA と EA の各世代での適応度の変化

このほかにも、EA を用いて異なる 2 種類の環境で注意ベクトル列の探索を行い、単純な環境では予測モデルベースの強化学習が、より困難な環境では現在位置を知ることによって過去の情報も使うメモリベースの強化学習が獲得された。結果として、機能部品の適切な組合せを探索すれば、タスクが要求する処理と自分のもっている機能部品集合に応じた多段の内部処理手続きが発見された、ということになる。しかし、現段階では多くのモジュールが作りこまれており、処理内容の一般性、大規模になったときの探索の困難度、GA ではない個体に適した探索方式、知識の再利用、など解決されていない部分が非常に多い。その意味でこの研究はまだ未熟であるが、従来の学習という概念とは異なる処理手続きの探索であり、しかも脳のモジュール性を原点とした人のモデルのようにも見

えるものであり、期待できるものと考えている。

なお、我々のモデルでは比較的大きな処理単位のモジュールで手続きを構成しており、要求される計算に対して探索は比較的容易である。このモジュールの粒度がマイクロである場合、探索が非常に大規模になってしまい、処理の獲得は実質的に困難であろうと予測される。その意味で、適切な処理単位のモジュールの自己組織的形成や、多様な実世界データの中からの汎用の知識モジュールの獲得もまた重要な問題である。

探索の規模に関してはまた、段階的なモジュールの獲得による処理システムの段階的な複雑化という戦略も考えられる。幼児は初期には少ないモジュールで過去の蓄積のないランダム探索に近い手続き獲得手法で行動し、次第にモジュールが増えてくると過去に獲得した手続きに新しいモジュールを少しずつ組み込むことで探索空間を大幅に縮小している可能性が高い。幼児の発達現象のより詳細な観察と理解が必要である。

さて、ここまで機能部品組合せの探索による内的手続きの獲得モデルについて述べてきた。人の脳でもいかにもありそうな話である。しかしこの方法では、獲得されるのは場面に応じた処理であり、結果としてうまく動くシステムが得られるのみである。人はそのような知能の段階を通過すると考えても間違いはないだろうが、ある時期になるとそれを超えた知能を示してくる。機能部品組合せからいかなる経緯を経て知能が生まれてくるのか、さらには人の知能では必ずといっていいほど議論されるシymbol的な処理が生まれてくるのか？ そこが次の問題となろう。

4. ブレイクスルー

では、何が実現されたらブレイクスルーが得られたことになるのであろうか。ここでの問題は、多数の機能部品の組合せ探索という考え方が、人の知的機能の実現原理としてどれほど有効であるか、有効でないなら原因はどこにあるか、などを確認することである。ここで実現したいシステム機能は、

1. 多様な種類の機能部品を高い自由度で、
2. 学習済みの機能部品も含めて動的に組み合わせて、
3. 短時間で問題に適した処理回路の系列を発見し、
4. 利用できる機能部品や処理回路のライブラリーを増加させていく

ことである。そしてそれを、段階的に難度が増加していく実世界の問題群で実現することによって、オンラインで次々と問題を解決していく人の知的機能を実現することである。

このようなシステムは、実体としては外界の問題処理の過程で獲得した実世界の信号を扱う機能モジュールを用いて、外見上は離散的な材料の組合せ探索を行う動作を示すはずであり、人という動物が特異的にもっているといわれるシymbol的な問題解決に近い行動を示すことが期

待できる。実現したシステムがもしそのような行動を示すなら、これは人の知能の動作原理に一步近づいたものと言えるし、そうでないなら、何が違っているのかを追求することで次の課題が見えてくるというものである。

もちろん、これを実現するためには解くべき問題がたくさんある。そのような機能部品、あるいは処理モジュールはどうやって獲得するのか？ またそれぞれの部品の粒度・細かさはどの程度なのか。組合せ探索をどう効率的に行っていくのか？ 部品には領域依存性があるのか？ それぞれがシンボルグラウンディング問題やフレーム問題に結びつく難問であり、それぞれについて改めて人はどうやっているのか、研究を行わなければならない。それにしても、このような問題について議論ができるということは生物をヒントにしたシステムデザインがシンボル処理にまで及んだということであり、大きな進歩であろう。

また、上記の多様なモジュールを高い自由度で組み合わせるとのこと自体、工学的にはなかなかの難問である。我々の行ってきたシミュレーションでは、モジュールはニューラルネットであってつなげば学習することで意味のある信号のやり取りができるようになった。しかしより多様なモジュールを使おうとするとモジュールとしてプログラムコードを使うのは自然であり、そのとたんに複数のプログラムを試行錯誤的につないで機能させるというソフトウェア工学上の難問にぶつかる。現在の計算機はモジュールの組合せ探索に向けたプログラム構造になっているとは言いがたい。脳における機能部品組合せという知能原理は、神経回路のような学習を土台としたシステムでのみ可能な方式なのかもしれない。

5. ほかのアプローチとの関係

過去 50 年の AI 研究においては、多様な問題に対してそれに応じた処理手続きが開発され、多くの問題が解決されてきた。しかしその結果として、すべての問題に対応できる万能のアルゴリズムは存在せず、ある特定のアルゴリズムでも人が介入せずに問題に自動的に適応するプログラムというものも存在しない、ということも現在では多くの方が認めるであろう。それに比べると、人の知能というもののすごさがよくわかる。

過去にも、人のこの能力に迫ろうとした研究は多くあった。例えば GPS に始まる記号処理、特に **production system** は人の推論能力をまねるといわれ、第五世代コンピュータは人をはるかに超える推論能力をもっている。しかし上記のアルゴリズムやプログラムの万能性は解決できていない。

ニューラルネットワークは、脳の学習方式だからデータを与えて学習させておけばいずれは人なみの知能が出現する、といわれた時期もあったかに聞いている。しかし現時点でいえることは、その学習能力には厳しい限界があり、学習時間もまた人とは比べものにならないほど長い。

ここで考えている機能部品組合せによる知能の原理に最も近いものは、探索系のプログラム合成システムや回路合成システムなどであろう [Hemmi 00]。しかしその多くの研究においては非常に細かい粒度で探索を行っており、探索空間の巨大さの問題は解決できていない。やはり発達の戦略を取る必要があらう [Buller 03]。

6. 人の学習と工学的な学習

本稿を書いていて感じることの一つは、工学的な知能研究と人の知能発達の基本的な問題設定の違いである。すなわち、問題の解決と個体の発達である。工学では目指すことは問題の解決であり、解決に関わる人間が専用の手法でプログラムを書いて学習に時間をかけてでもいいから、合理的な範囲で解が求めればよい。できたものを必要な場所に組み込んで問題は終わる。

それに対して人の発達的な問題解決は、乳児のときのお母さんを認識することから始まり、だんだんと難しくなる、あるいは世の中から今学習できる程度にやさしい問題を選んで、段階的に自己の能力を充実していくことである。その結果、知識や処理手続きは蓄積され、新たな問題も過去の類型の問題解決を思い出してそれをその場の環境に少し合わせれば即座に解けてしまえるものが多くなる。その結果、個々の問題は短期間で解けること、知識や経験は別の問題でも再利用ができることが大きな要請となり、結果として本稿の最初に述べた手続きの発見やシンボル処理様の行動が生まれてくる。

しかしここに来て、多くのロボットが家庭に入ろうとしている。ところが家庭は千差万別であり、ロボットが出会うのはまさに人が出会うのと同じ問題になる。そこでいきなり方向転換とはいくまいが、AI はこれまでの問題設定とは異なる問題設定に出会っているようである。問題設定に関する議論が必要なのではなからうか。

◇ 参考文献 ◇

- [Buller 03] Buller, A.: CAM-Brain Machine and Pulsed Para-Neural Networks (PPNN): Toward a hardware for future robotic on-board brains, *Proc. 8th Int. Symp. on Artificial Life and Robotics*, p. 490-493 (2003)
- [Hemmi 00] Hemmi, H., Shinozawa, K., Hikage, T. and Shimohara, K.: Learning and Relocation Capability of CAM-Brain Machine, *Artificial Life and Robotics*, Vol. 3, No. 4, pp. 213-216 (2000)
- [Ogawa 02] Ogawa, A. and Omori, T.: Looking for a suitable strategy for each problem — Multiple tasks approach to navigation learning task —, *EpiGenetic Robotics Symposium* (2002)
- [Sutton98] R. S. Sutton: *Reinforcement Learning: An Introduction*, MIT Press (1998)

2003年6月24日 受理

著 者 紹 介



大森 隆司

1980年東京大学大学院工学研究科計数工学専攻修了，1981年より同大学助手，1987年東京農工大学工学部講師を経て1988年より同大学工学部助教授，1998年より同大学電気電子工学科教授，2000年5月より北海道大学大学院工学研究科複雑系工学講座教授，現在に至る．博士（工学）．この間，1989～90年ブラウン大学言語と認知学科客員研究員，1994～97年科学技術振興事業団さきがけ研究21研究員．脳の記憶系，特に記憶の利用過程としての思考のモデル化と計算理論化に興味がある．日本認知科学会，神経回路学会，電子情報通信学会などの各会員．