

文献紹介

認知アーキテクチャを利用したスキル獲得に関する最近の研究の紹介

森田 純哉

計算機を利用した認知モデリングは、認知科学の設立当初から行われてきた。近年の認知モデルに関する研究では、認知アーキテクチャという概念が強く意識されるようになっていく。ここで認知アーキテクチャは、認知の構造的側面に関する理論を意味し、認知機能をモデル化するフレームワークとして用いられる。汎用的な認知アーキテクチャの上に、多様なモデルを構築することで、人間の認知に関する統合的な理解が得られると考えられている。

認知アーキテクチャの利用が特に活発な研究トピックとして、学習（スキル獲得）を挙げることができる。このトピックに関する研究は、認知アーキテクチャ上で開発されたモデルに、複数試行の課題を与える。試行を重ねる中で、モデルは新たな知識を獲得し、課題解決に至るまでの時間を漸進的に短縮させる。通常、モデル（あるいはアーキテクチャ）の妥当性は、課題解決の時間的変化を、モデルと人間とで比較することで検討される。

ここでは、認知アーキテクチャを利用した学習に関する最近の論文を3つ紹介する。これらは、ACT-R (Adaptive Control of Thought-Rational) とSoarという2つの認知アーキテクチャに関するものである。異なる認知アーキテクチャに関する研究を紹介することで、個々の研究の背後にある認知構造に対する仮定が、対比的に示されると考える。

第1の論文は、ACT-Rの学習メカニズムを用い、並列的な行動の生起をシミュレートしたものである。学習による課題解決時間の量的変化だけでなく、プロセスの質的な変化を示したという点で重要な研究である。ここでは、この論文に示される2つの課題に対するシミュレーションのうち、1つに焦点を絞った紹介をする。第2の論文では、Soarを利用した学習のシミュレーションが示される。この論文では、他の認知モデル研究に比べ、詳細なモデルの評価が示される。特に、構築されたモデルのパフォーマンスを、被験者個人のデータと対応づけた点で新奇な研究である。第3の論文は、SoarとACT-Rの両者における学習を比較したものである。2つのアーキテクチャ上に、共通の課題を解決するモデルが構築され、学習のプロセスが比較される。アーキテクチャ間での共通点と相違点を、データに基づいて示したという意味で重要な研究である。

Taatgen, N. A. (2005). Modeling parallelization and flexibility improvements in skill acquisition: from dual tasks to complex dynamic skills. *Cognitive Science*, 29 (3), 421-455.

ACT-Rでは、学習を宣言的知識（言語的な事実や教示）に基づく認知プロセスから、手続き的知識（ルール）に基づく認知プロセスへの変化ととらえ

Recent Studies on Skill Acquisitions using Cognitive Architectures

紹介者所属: 北陸先端科学技術大学院大学,

る。別の言葉を用いれば、何らかの問題を解決する際、初心者は言語的な思考をしばしばおこない、熟達者は環境を直接的に知覚・操作すると仮定される。

これまで、ACT-Rに実装される学習メカニズムを用いて、このような仮定を確かめようとするシミュレーション研究が行われてきた。しかし、それらの研究は、経験の蓄積による認知プロセスの質的な変化を具体的に示してこなかった。

それに対し、本論文は、学習に伴い、複数のモジュールの並列的な動作が生起するという仮説を提起する。そして、2重課題を解決するACT-R上のモ

デルと人間の被験者の学習パフォーマンスの対応が検討される。本論文におけるモデルを示す前に、以下、ACT-Rについて簡単な説明を示す。

ACT-R

概要 ACT-Rは、人間の認知を、複数の独立したモジュールにより構成されるものととらえる。中心的なモジュールはルールモジュール¹⁾であり、他の周辺的なモジュールを統合する。周辺的なモジュールは、それぞれ異なる種類の情報処理を受け持ち、一時的な情報の貯蔵場所(バッファ)をもつ。ルールモジュールは、各バッファの状態を条件とし、適合するルールを選択・発火させる。ルールの発火により、バッファは書き換えられ、新たな状態と合致するルールが循環的に探索される。以下は、本論文と関連するモジュールである。

- 宣言的モジュール: ルールモジュールからの要求に応じて、要求と適合する宣言的知識を検索する。検索された宣言的知識は、検索バッファに格納される。
- 視覚モジュール: 視界の変化を検知し、注目位置内の情報を視覚バッファへエンコードする。
- 聴覚モジュール: 音声を知覚し、聴覚バッファへ情報をエンコードする。
- 手運動モジュール: ルールモジュールからの要求に応じ、キー押しなどの出力を行なう。
- 発声モジュール: ルールモジュールからの要求に応じ、音声による出力を行なう。

各々のモジュールは、相互に独立して動作する。例えば、視覚モジュールが視界の変化を検知している間、他のモジュールはそれぞれの処理を進める。その一方で、モジュール内部での処理は系列的なものとなる。各時点において処理されるルール、各バッファに保持される情報は単一のものとなる。

学習メカニズム ACT-Rにおける学習メカニズムはコンパイルと呼ばれる。コンパイルとは、連続的に発火する2つのルール(親ルール)を統合し、新たなルール(新ルール)を生成することである。新ルールは、先行して発火された親ルールの条件部、後続して発火された親ルールの実行部をもつ。

コンパイルは、通常、宣言的知識の検索に関するルール(現在の状況と適合する教示を思い出すな

ど)と検索された宣言的知識の利用に関するルール(思い出された教示に即して取るべき行動を決定するなど)が連続して発火する場面で生じる。このような場面で生成された新ルールは、その実行部に宣言的知識の内容を含み、宣言的知識の検索をスキップさせる。

新ルールが生成されると、ACT-Rは、同一の条件において発火可能な2つのルール(新ルールと親ルール)を持つことになる。ACT-Rでは、ルールの選択における競合は、効用値の比較によって解消される。効用値は、そのルールを利用して、ゴール到達に成功する確率、ゴール到達に至るまでのコストから計算される。

コンパイルされた新ルールの効用値は、当初、親ルールよりも低いものとなる。そのため、学習の初期において、新ルールが用いられることはほとんどない(親ルールの使用のみが繰り返される)。ただし、同一の新ルールが複数回コンパイルされることで、その効用値は漸進的に向上する。そして、一旦、新ルールが用いられ始めると、その効用値は親ルールの効用値を越え、親ルールが用いられなくなる。

課題とモデル

以下2つの副課題を同時に素早く遂行することを求める2重課題が設定された。

- 視覚-運動課題: 画面の右・中央・左のいずれかの位置にランダムに が出現し、その位置に応じたキー押しをする。
- 聴覚-発声課題: トーンの異なる3種類の音声のうち、1つがランダムに提示され、その種類と対応した番号を発声する。

この課題を遂行するモデルが、ACT-R上に構築された。構築されたモデルは、視覚、聴覚モジュールによって刺激を認識し、手運動、発声モジュールによって反応を出力する。刺激と反応の対応関係(が左に提示されたら、左キーを押すなど)は、宣言的知識としてコーディングされる。ルールモジュールは、刺激に当てはまる教示を記憶中から検索し、それを利用して反応を生成する。

図1と図2は、モデルによる課題遂行のプロセスを表す。図1は学習前のプロセス、図2はモデルの学習が完了した後のプロセスを示す。図中の各行は、ACT-Rにおけるモジュールと対応し、時間の進行に伴う処理内容の推移を示す。また、視覚-運動課

1) プロダクションシステム。条件部と実行部をもつルールの適用によって、ワーキングメモリ(バッファ)の状態を循環的に書き換えていくシステム。

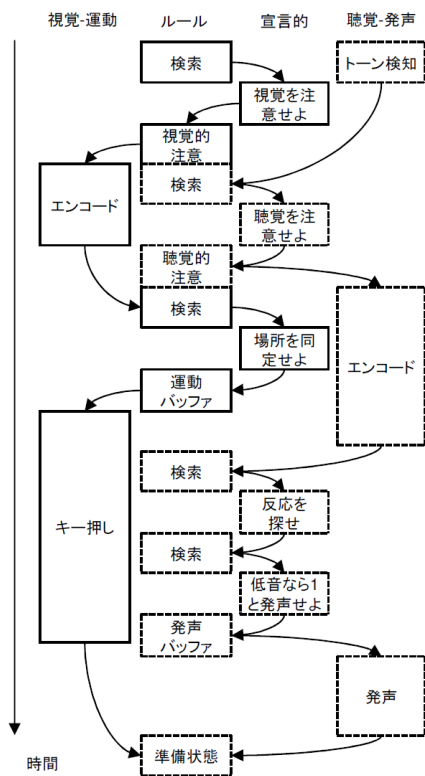


図1 学習前のプロセス。
Taatgen (2005) をもとに改変して作成。

題の遂行に関わる処理は実線で、聴覚-発声課題の遂行に関わる処理は点線で囲まれて示されている。

図から、学習前に比べ、学習後は、課題の解決に至る時間が短いことが確認できる。解決時間の短縮に関与する最も大きな要因が、宣言的モジュールの使用である。学習前のプロセスでは、刺激のエンコードと反応の生成が宣言的知識の検索に媒介される。それに対して、学習後は、コンパイルによって、宣言的知識の検索がなされなくなっている。

さらに、学習前のプロセスでは、視覚-手運動課題と聴覚-発声課題のそれぞれに関わる処理が競合していることも確認できる。例えば、聴覚モジュールは、課題開始直後、提示された刺激（トーン）を検知する。しかし、聴覚モジュールが刺激を検知した時点において、ルールモジュールは視覚的刺激の処理を行なっている。そのため、検知されたトーンの処理に遅延が生じている。

それに対して、学習後のプロセスでは、処理間での競合が完全に解消されている。視覚-手運動課題

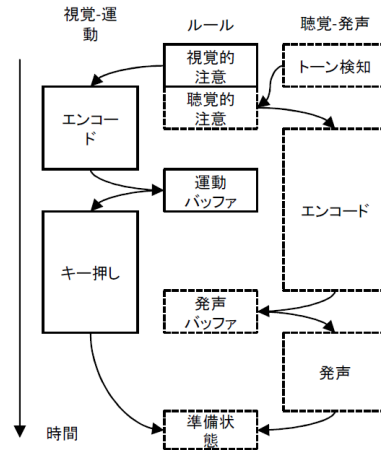


図2 学習後のプロセス。
Taatgen (2005) をもとに改変して作成。

と聴覚-発声課題のそれぞれに関与する処理は、時間的な隙間のない連続したものとなっている。著者は、このような隙間のない並列プロセスを完全時分割処理と呼び、スキル獲得による認知プロセスの質的变化であると主張している。

本論文におけるモデルでは、課題試行の繰り返しにより、このようなプロセスの変化が漸進的に生じ、課題解決のシミュレーション時間が短縮される。本論文では、モデルによる課題解決時間の変化を、同様の学習の状況における被験者の反応時間と対応づけた。結果、モデルが被験者の反応時間をよく予測することが示された。このことから、本論文で示したモデルの仮定（コンパイルによるプロセスの並列化）が支持されたとみなされた。

Ritter, E. F. & Bibby, P. A. (2008). Modeling How, When, and What is Learned in a Simple Fault-Finding Task. *Cognitive Science*, 32 (5), 862–892.

認知モデルの研究において、モデルの妥当性は、被験者のパフォーマンスとの適合によって検討される。しかし、従来の研究は、複数の被験者の平均的なパフォーマンスとモデルとの適合を検討するにとどまり、個人単位でのパフォーマンスとの適合を検討していなかった。本論文では、このような従来の認知モデル研究の限界を踏まえ、モデルと個人との適合を検討することを試みる。




図3 装置の回路図．Ritter & Bibby (2008) をもとに改変して作成．




図4 診断用インタフェース．Ritter & Bibby (2008) をもとに改変して作成．

課題とデータ

扱われた課題は、ある装置（レーザービームの発射装置）が故障している状況を提示し、その原因を同定させるものである。故障の同定には、装置の回路図（図3）と診断用インタフェース（図4）が用いられる。

装置は、電源（PS）、2つのブースタ（EB1、EB2）、3つのアキュムレータ（MA、SA1、SA2）、出力装置（LB）から構成される。複数個のブースタ・アキュムレータのうち、いずれが用いられるのかはスイッチの状態により定まる。

診断用インタフェースには、パーツの稼働状況とスイッチの状態が示される。そのパーツに電流が至り、パーツが正常に稼働しているのなら、該当するパーツのライトが点灯する。電流が至っているにも関わらずライトが点灯しない場合、パーツの故障が診断される。

本論文におけるシミュレーションは、この課題に対する被験者10名の20試行のデータを対象とした。被験者は、課題に取り組む前に、あらかじめ回路図を記憶した。各試行において、彼らは、異なる状態のインタフェースを提示され、故障の原因を同定した。試行の提示順序は、被験者間で異なっていた。

モデル

Soar上で、この問題を解決するモデルが構築された。Soarでは、問題解決を問題空間の内部、あるいは複数の問題空間をまたぐ探索とみなす。問題空間内部の探索は、オペレータ（状態を変化させるルー




図5 モデルにおける問題空間．Ritter & Bibby (2008) をもとに改変して作成．

ル）の適用によりなされる。ある問題空間において、オペレータの適用に失敗した場合（インパスと呼ぶ）、他の問題空間が探索される。

本論文において構築されたモデルは、階層的に配置された7つの問題空間を探索する。問題空間の構成を図5に示す。

モデルによる問題解決は、diagnose空間から始まる。この空間は、問題解決の開始、最終結果の報告、対象物への注目と認識に関わるオペレータを持つ。

diagnose空間において、報告すべき結果がない場合、あるいは注目すべき対象が不明な場合、探索がfind-fault空間に移される。この空間では、パーツの1つが選択され、その故障がテストされる。選択すべきパーツが不明な場合には、さらに下位のselect-comp空間が探索される。

select-comp空間は、diag-select空間、intef-select空間と結合する。これら2つの空間には、回路図に関する知識（パーツの連結関係）、インタフェースに関する知識（ライトの隣接関係）、テスト済みのパーツリストが保持される。モデルは、これら2つの空間に蓄積された知識を利用し、テストすべきパーツを選択する。テスト済みのパーツがない場合、PSが選択される。それ以外のときは、インタフェース上で、直前にテストしたパーツの右側に位置するもの、あるいは回路図上で、直前にテストしたパーツと連結するものが選択される。インタフェースと回路図で選択されたパーツが異なる場合は、スイッチの状態に応じた決定がなされる。

選択された要素のテストは、test-comp空間にてなされる。ライトの状態に基づき、要素の故障が診断される。テストしたパーツのライトが点灯していなかった場合、diagnose空間において、故障のレポートがなされ、問題解決が終了する。テストされたパーツに異常が見つからなかった場合、新たなパーツへの注目があき、循環的に探索が行なわれる。

学習メカニズム

Soarにおける学習はチャンキングと呼ばれるメカニズムに基づく。チャンキングとは、インパス（下位の空間へ移動）に陥ったときの状況を条件部に、インパスの解消を導いた下位問題空間での行動を実行部にもつルールを生成することである。

チャンキングによる学習は、下位の空間に存在した知識を上位の空間のオペレータに組み入れることを意味する（下位空間の探索をスキップする）。生成された新ルールは、直後の試行から用いられ始める。試行を繰り返すことで、チャンキングにより生成された知識が増加し、下位空間の探索が減少する。それにより、課題の解決に要するサイクルが減少する。

結果と考察

本論文では、上記モデルの妥当性を3つの方法で検討した。1つめと2つめの方法では、モデルと被験者の平均的パフォーマンスの対応が検討され、3つめの方法では、個人単位でのシミュレーションが行われた。本研究の新規性は、このうち3つめの方法による検討を採用したことにある。

問題タイプ別での解決時間の平均値 まず、問題のタイプ（故障たパーツ）ごとに、解決時間の平均値（ $n = 10$ ）を算出し、モデルのパフォーマンスとの対応を検討した。結果、被験者・モデルともに、故障したパーツが、インタフェースの右側に配置されたときに、問題解決の所要時間が長くなった。また、モデルと被験者の解決時間平均値とは、強く相関し（ $r = .99$ ）、モデルが課題タイプによる問題解決の困難さを正確に説明することが示された。

試行順序での解決時間の平均値 被験者の解決時間を試行順序によって平均し、モデルとの対応を検討した。結果、モデル・被験者ともに、試行の繰り返しによる解決時間の減少が確認された。また、モデルと被験者の解決時間の平均値は、強く相関し（ $r = .99$ ）、モデルが試行の蓄積による解決時間の減少を説明することが示された。

個人とモデルとの対応 最後に、個別の被験者によるパフォーマンスとモデルとの対応が検討された。本論文における実験では、被験者ごとに課題の遂行順序は異なっていた。モデルは、それぞれの被験者と同様の順序で課題を遂行した。結果、モデルは、10名中8名の解決時間をよく予測することが示され




図6 積み木問題の例。Kennedy & Trafton (2007) をもとに改変して作成。

た（ $r^2 > .90$ ）。残り2名の予測率は低いものであった（ $r^2 = .007$, $r^2 = .18$ ）が、モデルが多くの被験者の学習パターンを説明することに成功したことは示された。この結果は、モデルの仮定（チャンキングによる学習）を強く支持するものといえる。

Kennedy, W. G. & Trafton, J. G. (2007). Long-term symbolic learning. *Cognitive Systems Research*, 8 (3), 237–247.

本論文では、SoarとACT-Rの両者における長期学習のプロセスが検討される。ここでいう長期学習とは、システムが安定状態（それ以上のパフォーマンス向上が望めなくなる状態）に至るまで、課題の試行を繰り返すことを意味する。認知アーキテクチャを利用した従来の学習研究は、実験室における短い試行数での学習をシミュレートするものが多かった。それに対して、人間は生涯にわたり知識を獲得していく。そのような現実的な学習領域を対象とするためには、現存する認知アーキテクチャの長期学習における特性を明らかにする必要がある。

課題

積み木問題と呼ばれる課題が扱われた（図6）。この課題は、3つの積み木を、初期状態から目標状態へと配置変えるものである。特に、本研究では、初期状態から目標状態への配置換えが、単一の動作により完了する30の問題を扱った。モデルは、安定状態に至るまで、ランダムに与えられる問題を解き続けた。

モデル

Soar, ACT-Rのそれぞれの上に、積み木問題を解決するモデルが構築された。2つのモデルは、学習前の段階において、共通のストラテジーを採用する。そのストラテジーとは、当該の状況において可

能な動作をランダムに選択するものである。動作のランダムな選択により、偶然、目標状態に至った場合、問題は解決され学習が生じる。

学習の方法は、両モデルで異なる。Soar上のモデルでは、問題解決に至った後に、動作前の状態と目標状態とを対応付けるルールが学習される。生成されたルールは、直後の試行から選択可能となる。

ACT-Rの場合、解決に至った動作は、まず宣言的知識として保存される。その宣言的知識は、次試行以降、ルールを介して呼び出されるようになる。宣言的知識を用いた問題解決が起きると、コンパイルが生じ、新たなルールが生成される。コンパイルの繰り返しにより、新ルールの効用値は高まり、宣言的知識が用いられなくなる。

結果と考察

2つのモデルのそれぞれが、どのようなプロセスを経て安定状態に至ったのかを検討した。問題試行の進行に伴うルールの生成数を検討した結果、両モデルともに、初期の試行において多くのルールが生成され、徐々に生成されるルールの数が減少した。そして、ともに、一定の試行の後にルールが生成されなくなった。

両者の違いは、安定状態にいたるまでの試行数、学ばれるルールの数にあった。Soar上のモデルに比べ、ACT-R上のモデルは、多くのルールを生成し、安定状態に至るまでに多くの試行を要した。この違いは、学習の段階性を原因とすると考察された。ACT-Rにおける学習は、宣言的知識の獲得、宣言的知識からルールへのコンパイル、効用値の更新という段階を経る。それに対し、Soarは、宣言的知識の学習を行わず、獲得されたルールは、直後の試行から使用可能となる。

さらに、著者は、このような差異を、両アーキテクチャの目的の違いと関連付けて解釈した。Soarは、広い意味での人工知能 (AI) システムとして開発されたものであり、ACT-Rは人間の認知をシミュレートすることに特化して開発されたものである。実用的なAIシステムの開発を目指すのであれば、学習が素早く進行することに意味はある。しかし、認知アーキテクチャとしては、人間と同様のスピードで学習が進行することが重要である。ACT-Rは、宣言的知識から手続き知識への段階的な学習を実現するものであり、人間の認知をシミュレートするアー

キテクチャとして適していると解釈された。

関連する文献

Anderson, J. R. (2007). *How can the human mind occur in the physical universe?* NY: Oxford University Press.

(ACT-Rに関する最新の著書。冒頭での認知アーキテクチャの定義は、本書を参考にしている。)

Anderson, J. R., Bothell, D., Byrne, M. D., Douglass, S., Lebiere, C., & Qin, Y. (2004). An integrated theory of the mind. *Psychological Review*, **111**, 1036–1060.

(ACT-Rに関するレビュー論文。1番目の論文で紹介した課題を用いた研究が示される。)

開一夫 (1994). Soarにおける学習 (小特集「Soarプロジェクト」). 『人工知能学会誌』, **9**(4), 497–504.

(Soarの学習を認知科学の他の学習理論との比較を通して解説している。)

Lehman, J. F., Laird, J., & Rosenbloom, P. (1996). A gentle introduction to Soar, an architecture of human cognition. In S. Stenberg & D. Scarborough (Eds.), *Invitation to Cognitive Science*, 211–253. MIT Press.

(Soarの解説。Soarの研究グループWebサイトから最新版をダウンロードできる。)

Marinier, R., Laird, J. E., & Lewis, R. L. (2008). A computational unification of cognitive behavior and emotion. *Cognitive Systems Research*. doi:10.1016/j.cogsys.2008.03.004

(Soarを用いた学習研究。感情的な反応と学習との関連が検討される。)

Taatgen, N. A., Huss, D., & Anderson, J. R. (2008). The acquisition of robust and flexible cognitive skills. *Journal of Experimental Psychology: General*, **137**(3), 548–565.

(1番目に紹介した論文の著者による研究。)

謝辞

「関連する文献」のACT-Rに関する最近の研究は、青山学院大学の寺尾敦氏に紹介していただきました。記して感謝いたします。