

事前学習を利用した ACT-R の運動学習モデル ACT-R Modeling of Motor Learning Using Prior Training

長島 一真[†], 西川 純平[†], 米田 凌[†], 森田 純哉[†]

Kazuma Nagashima, Jumpei Nishikawa, Ryo Yoneda, Junya Morita

[†] 静岡大学

Shizuoka University

nagashima.kazuma.16@shizuoka.ac.jp

概要

人間の運動技能は、外界の変化に対する予測精度を向上させることで獲得される。こういった運動学習の過程について、様々なモデルが構築されてきた。しかし、多数のパラメータが関与する状況での急速な適応を説明するモデルは構築されてこなかった。本研究では、認知アーキテクチャである ACT-R をベースに、事前に獲得された運動スキーマを適用する学習を提案する。手法を適用した結果、人間と適合する急激な学習過程を確認した。

キーワード：運動スキーマ, 認知モデル, ACT-R

1. はじめに

人間を取り巻く環境は動的に変化する。よって、環境に対する素早く正確な働きかけを可能とするために、環境の変化を予測するパターンが必要となる。認知アーキテクチャに関わる研究は、このような運動学習の過程を再現するメカニズムの構築に取り組んできた。例えば現存する認知アーキテクチャのなかで、最も多くの機能を有する ACT-R (Adaptive Control of Thought-Rational [1]) は、外界とのインタラクションを担う知覚モジュールと運動モジュールを持つ¹。

これらのモジュールは、ACT-R の有する高次認知機能（記憶やゴール管理など）と統合されることで、外界との柔軟なインタラクションを伴うモデルの構築を可能にした。これまで様々な研究者が ACT-R の知覚と運動モジュールを用いて、知覚運動課題をリアルタイムに遂行するモデルを実装してきた。例えば、運動に関わる数値的なパラメータを調整する運動学習モジュールを用いる研究が存在する [2, 8]。ただし、既存の研究は、この運動学習のモジュールにより、多数のパラメータの関与する運動が、人間と同様の速度で学習されることを示していない。

上記の背景を踏まえ、本研究では、知覚運動課題に

おける人間の学習速度を表現する手法を ACT-R 上で表現する手法を提案する。本研究の手法は、事前に学習された運動系列をモデルがスキーマとして保持し、新規な状況において選択するものである。これにより、多数のパラメータをもつ運動を、人間と同様の速度で学習する。

2. 関連研究

本研究では、ACT-R の機能を組み合わせることで、知覚運動課題における人間の学習の速度を表現することを目指す。

人間の運動学習には関して、運動の記憶を感覚と動作を協調させるスキーマの獲得として説明する理論が存在する [9]。この理論では、人間の運動学習によって獲得されるスキーマとして、運動のパラメータ、過去の運動の内容、過去の運動の結果が想定される。運動スキーマによって過去の運動の内容が想起され、感覚の予測がなされる。運動に関するこのような抽象的知識を獲得することで、人間は新規な状況での動作パターンを素早く獲得することができる。

ACT-R を用いた運動学習に関して、様々な研究が行われている [2, 7, 8]。その中で、本研究では、著者らのグループにおいて利用してきたラインフォロイング課題 [4] を対象としたモデルを直接の先行研究とする。課題の詳細は後述するが、スクロールするラインに対する追従のタイミングを制御する課題である。これを達成するために、筆者らの先行研究では、ACT-R の有する運動学習のモジュールを利用するモデルを構築した [7]。ただし、このモデルは、1. 節で述べた研究 [2, 8] と同様、人間の学習速度を再現することには成功していない。ACT-R の運動学習モジュールは、課題の遂行に伴う試行錯誤の履歴から、知覚と運動を対応させるパラメータを学習する。通常、このような学習は人間による学習に比べて多くの試行を要する。この背景から、本研究では、知覚と運動の対応関係を短

¹Kotseruba による網羅的なレビューを参照 [3]

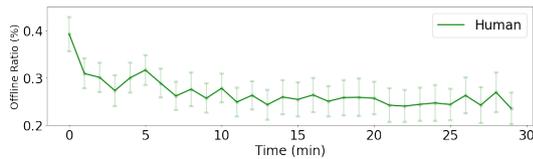


図1 人間のデータ。エラーバーはSE (Standard Error)。

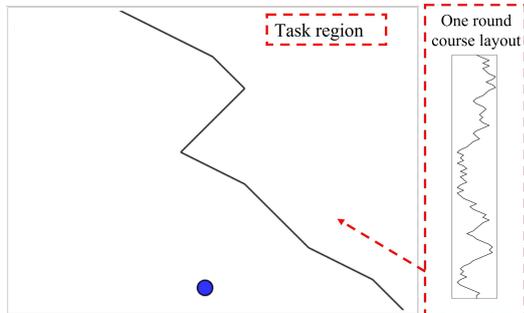


図2 タスクインターフェイス

期間に収束させるメカニズムを検討する。

3. 課題とデータ

先行研究 [6, 7] と同様、ラインフォローイング課題を設定した。図2にタスクのインターフェイスを示す。このタスクにおいて、参加者は青い円を操作して、画面上に表示される上から下へ自動スクロールするポリラインを追うことを目指す。線は、図2右側に示すように、あらかじめ設定されたコースに従って変化していく。このコースは、およそ1分ごとに最初から繰り返される。このゲームの繰り返しを、以下、ラウンドと呼ぶ。

本研究で対象とするデータは、この課題に対してオンライン実験で得られたデータである。このデータは、クラウドソーシングサイト (Lancers.jp) における募集を介して得られた24名分のデータを分析の対象とした。本実験にて参加者は30分間、課題に従事した。

なお、本研究では先行研究に対して、スクロール速度を先行研究の3倍の速度とし、より曲折の多いコースを採用した。本研究では、人間の運動学習に焦点をあてるものであるため、先行研究に対してより難易度の高い状況での検討が必要であると考えたためである。

図1は、課題のパフォーマンスの推移を示す。縦軸はオフライン率 (セグメントの総時間において、円が線に沿わなかった時間の割合)、横軸は30分のタスクを1分間隔で区分した時間を示す。グラフから、時間に応じたオフライン率の減少傾向が示される。特にオ

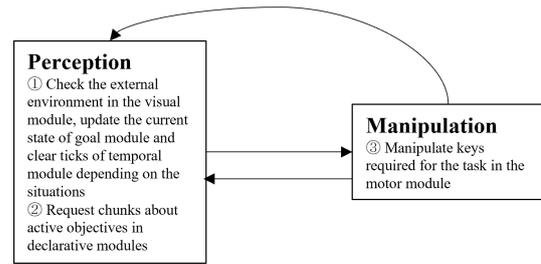


図3 モデルの状態遷移

フライン率の減少は課題の初期に急激に生じていることがわかる。

4. モデル

本研究は、知覚運動課題におけるモデル [5, 7] を引き継ぎ、図1で示されるような人間の急激な学習を表現することに焦点を置く。

このような学習の問題は設定されるパラメータの数に応じて、組み合わせの数が膨大となり、最適なパラメータの値への収束に時間を要することである。本研究では人間によるラインフォローイングタスクの課題遂行において観察される急激な学習を再現するために、運動スキーマ理論 [9] に従ったパラメータセットを仮定する。すなわち、図1にて観察された急激な学習は、事前にその個人が記憶中に保持する運動スキーマを思い出すことによって成し遂げられたと考える。この実験においてこの課題を初めて実施する参加者でも、過去に類似したゲームを行った経験を有すると考えることはできる。実験時に、その際の知覚と運動の対応関係を想起し、課題の遂行を上達させることは理にかなった仮説である。

5. シミュレーション

前節の仮説を検討するため、本研究におけるシミュレーションでは、前節で述べた事前のスキーマ構築フェーズを設定し、人間に迫る急速な運動学習を再現する。また、スキーマ適用フェーズにおいても、構築されたスキーマの発見のされやすさを操作した複数の条件を設定する。さらに、人間のパフォーマンスとの整合を強化するために、ACT-Rのプロダクションの発火時間を定める *dat* パラメータを操作する²。

²本研究では ACT-R におけるベースとなる知覚運動過程のパフォーマンスの妥当性を検証するために、デフォルトの設定 (*dat* = 0.050) に加え、倍の速さの設定 (*dat* = 0.025) を検討した。

5.1 手続き

シミュレーションの手続きは、スキーマの構築フェーズとスキーマ適用フェーズに分かれる。

5.1.1 スキーマの構築

運動学習モジュールの最適なパラメータを以下の手順により発見する。この際、最適なパラメータは十分に広いパラメータ空間に対して、ある程度長時間に渡る学習によって得られると考える。

1. 各パラメータの値域を起点 0 と円の大きさの 10 倍を足した 241 段階に設定する³。
2. 通常の課題 30 分に対し、3 時間学習する。
3. 後半 1 時間中のオフライン率が $\mu - 3\sigma$ 以下だったラウンドを探索する。
4. その各ラウンドに対し、各パラメータの最大値と最小値の差を計算し、全て足し合わせる。
5. 足し合わせた値が最も低いラウンドを訓練後のパラメータの候補とする。

本研究では、上記の手続きを 10 回行う。得られた候補に対し、各パラメータが取りうる最大値と最小の差が最も低いラウンドの値を、最適なパラメータとした。

5.1.2 スキーマ適用

上記により発見された最適なパラメータを、人間は実験の開始以前に経験的に獲得していると考える。そして、人間による実験時の学習は、その最適なパラメータを再発見するプロセスと考える。この仮定にもとづき、スキーマ適用フェーズにおいて、以下の手続きで人間が遂行したコースをフォローする。

1. 各パラメータの値域を、以下の条件でスキーマ構築フェーズにおいて得られた最適値をもとに上下幅を設定し、その値の段階を 3 に設定する。
 - (a) 0 以上: 最適値を下限とし、上限をその下限に変数である Var_{Apply} を 2 倍した値を設定
 - (b) 負を含む: 最適値を中心に Var_{Apply} 分の上下幅を設定
2. モデルは 30 分間シミュレーションを行う。

上記の設定により、段階が少なくなることで、モデルは構築された最適パラメータをスキーマとして発

³値域が 0 以上のパラメータは、最小値 0、最大値 240、値域が負を含む場合は、最小値-120、最大値 120 に設定した。

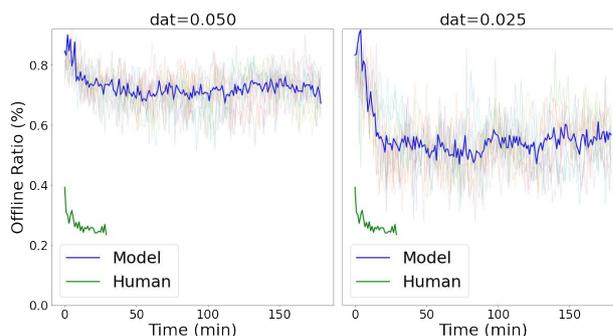


図 4 スキーマ構築の結果。太線は平均値、細い線は個別事例を表す。(n = 10)

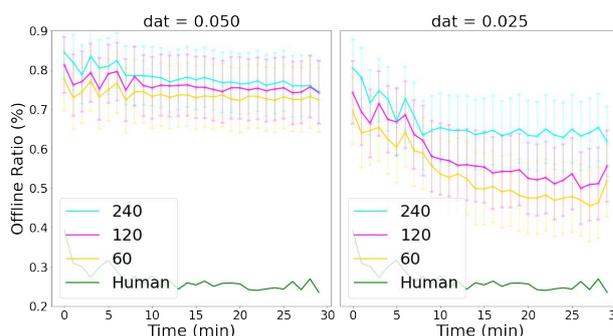


図 5 スキーマ適用結果。オフライン率のエラーバーは、SE を表す。(n = 100)

見しやすくなる。また、本研究では、 Var_{Apply} に 60, 120, 240 の 3 つの条件を設定した⁴。

5.2 結果

図 4 は、2 種類の dat で事前学習をしていく過程で得た、3 時間分のオフライン率の推移である。青の系列はモデル、緑の系列は比較のために載せた人間の結果を表す。課題が進むに連れ、オフライン率が低くなりモデルのパフォーマンスが向上していることが確認できる。また、dat が低い方が、全体的にパフォーマンスが向上していることが確認できる。

図 5 は、構築したスキーマを適用させたモデルのシミュレーション結果である。各系列は異なる Var_{Apply} の設定を示す。いずれの dat でも、探索する値域の幅が狭いほど課題初期のパフォーマンスが良い傾向であることが確認できる。また、dat が 0.025 では、その人間の初期の急激な学習の特徴を再現できていることが確認できる。なお、dat を小さく設定した際により、人間のパフォーマンスに近づいていることがわかる。

⁴その他の運動学習モジュールのパラメータは、先行研究 [8] を踏襲した。

表1 人間の結果とモデルの結果の相関係数.

	$dat = 0.05$		$dat = 0.025$	
<i>base</i>	0.63	(0.25)	0.69	(0.16)
240	0.80	(0.26)	0.82	(0.16)
120	0.75	(0.24)	0.80	(0.10)
60	0.64	(0.22)	0.79	(0.08)

* 括弧内の数値は RMSE (Root Mean Squared Error) を示す。また, *base* は, 図4に示すスキーマ構築時の課題の最初の30分に対するものである。その他は, 図5に対応する。太字はベストフィットを示す。

表1にモデルと人間の適合を検討した結果を示す。各々の dat の設定に対して, 相関は, スキーマ構築フェーズに対して, スキーマ適用フェーズにおいて高くなっていることがわかる。また, RMSE についても, スキーマ構築フェーズの *base* がスキーマ適用フェーズに対して低くなる傾向が示される。この結果は, 人間における急激な学習が, 事前に構築されたスキーマの再発見として説明されるという仮説を確かめるものである。

なお, モデルと人間との最も良い適合は, dat を ACT-R のデフォルトから倍の速度に早めた条件において得られた。この結果は, 本研究におけるモデリングの改善の余地, あるいは ACT-R におけるプロダクションサイクルの設定の限界を示すものと捉えられる。

6. まとめ

本研究では, ACT-R の運動学習モジュールを用いて, 人間の急激な運動学習を説明することを目指した。本研究の提案は, 事前学習された運動スキーマを課題時に再構成することにより, 人間は課題に対する急激な学習を達成するというものである。この仮説を検証するために, シミュレーションを実施した。その結果, スキーマ構築フェーズに対して, スキーマ適用フェーズでは, より人間の学習パフォーマンスと整合する結果が得られた。

本研究の意義は, 通常は長時間の学習が必要になるパラメータ最適化のプロセスを利用して人間の学習をモデル化する手法を提案したことである。近年発展した end-to-end な枠組みについても, 同様の考え方を適用することで人間の課題学習のモデルを構築できる可能性はある。

今後, このアプローチをさらに進めていく必要がある。今回の研究では, スキーマの構築と適用に伴う事前学習はパフォーマンスの向上という点で一定の効果

があったものの人間のパフォーマンスを達成するという意味では十分ではなかった。より長期に渡る多数のモデルの実行を通すことで, より最適なパラメータが発見される可能性がある。

文献

- [1] Anderson John R. *How Can the Human Mind Occur in the Physical Universe*. Oxford University Press, New York, 2007.
- [2] Anderson John R., Shawn Betts, Daniel Bothell, Ryan Hope, and Christian Lebiere. Learning rapid and precise skills. *Psychological Review*, Vol. 126, No. 5, pp. 727–760, 2019.
- [3] Iuliia Kotseruba and John K. Tsotsos. 40 years of cognitive architectures: core cognitive abilities and practical applications. *Artificial Intelligence Review*, Vol. 53, No. 1, pp. 17–94, 2020.
- [4] Akihiro Maehigashi, Kazuhisa Miwa, Hitoshi Terai, Kazuaki Kojima, and Junya Morita. Experimental investigation of calibration and resolution in human-automation system interaction. *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, Vol. 96, No. 7, pp. 1625–1636, 2013.
- [5] Junya Morita, Kazuhisa Miwa, Akihiro Maehigashi, Hitoshi Terai, Kazuaki Kojima, and Frank E Ritter. Cognitive modeling of automation adaptation in a time critical task. *Frontiers in Psychology*, p. 2149, 2020.
- [6] Kazuma Nagashima, Junpei Nishikawa, Ryo Yoneda, and Junya Morita. ACT-R Modeling of Rapid Motor Learning Based on Schema Construction (in press). In *Proceedings of the 21th International Conference on Cognitive Modeling*, 2023.
- [7] Kazuma Nagashima, Junpei Nishikawa, Ryo Yoneda, Junya Morita, and Tetsuya Terada. Modeling optimal arousal by integrating basic cognitive components. In *Proceedings of the 20th International Conference on Cognitive Modeling*, pp. 196–202, 2022.
- [8] Gianferrara P. Giovanni, Shawn Betts, and Anderson John R. Cognitive motor skill transfer across speeds: A video game study. *PLOS ONE*, Vol. 16, No. 10, pp. 1–31, 10 2021.
- [9] Schmidt Richard A. A schema theory of discrete motor skill learning. *Psychological Review*, Vol. 82, pp. 225–260, 1975.