

# ゲーム型教材のプレイ履歴からの行動知識の学習

## Learning Action Knowledge from Play Data in Educational Game

市瀬 龍太郎\*1

Ryutaro Ichise

山川 宏\*3\*2

Hiroshi Yamakawa

\*1 国立情報学研究所

National Institute of Informatics

\*2 玉川大学

Tamagawa University

\*3 研究人生を楽しむ会

Academic Life Club

We propose a method to construct knowledge models for novice and expert on intelligent tutoring system for educational game. The method is based on behavioral cloning method using machine learning approach. We conducted experiments with real play data and discuss about the models for detecting the difference in knowledge.

### 1. はじめに

ゲーム型の教育教材には、体験行動を通して、楽しみながら学習を行えるという利点がある。そのため、様々な場所でゲーム型の教材が教育に取り入れられ始めている。例えば、IBMでは、新入社員の教育などに使うために Innov8(イノベイト)というゲームを開発している。また、大学では、Happy Academic Life 2006 [山川 06] というゲームがキャリア教育の授業に用いられていたりする。

従来から用いられている E ラーニングシステムでは、学習項目を設定し、その学習項目に関する知識を一つ一つ学習したかチェックすることで、学習効果を高めている。しかし、ゲーム型教材においては、ある状況において、学習者が行動を選択していくことで、学習が進んで行くため、E ラーニングシステムと比べて、より実践的な知識が身につくという利点の一方で、学習者がどのような知識を学習し、どのような知識をまだ学習していないのかということを示明することが難しいという問題点がある。

このような問題に対して、市瀬らは、行動クローニング [Sammur 96] の技術を応用することで、ゲーム型教材のプレイヤーが持っている知識を把握する手法を提案してきた [市瀬 07]。本稿では、市瀬らが提案していた手法により、初心者と専門家の行動知識を学習し、それを利用することで、ゲーム型学習教材における学習済みの知識と未学習の知識を検知する手法についての考察を行う。

### 2. Happy Academic Life 2006

本研究では、ゲーム型教材として、Happy Academic Life 2006(HAL2006) [山川 06] を用いた。HAL2006 は、若手を中心とした研究者が、キャリアデザインを考えるために、研究関連のイベントを疑似体験できる教材として開発された。HAL2006 は、3人から5人用のボードゲームになっており、ゲーム中のイベントを疑似体験することで、プレイヤーの目指す将来像に適合するように、行動を決定していく。ゲームは、基本的にすごろくのように、ボード上のコマを移動させていき、学会活動や学内活動などの活動イベントに対応するカードをめくりながら、次第に高度な研究業績をあげていく。そして、最後に、

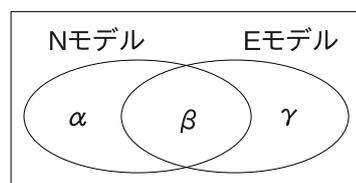


図 1: 行動選択における初心者モデル (N モデル) と専門家モデル (E モデル) の関係

自分の目指す将来像を実現することが、このゲームの目的となる。

ゲームにおいては、各々の行動選択がゴールの達成に大きな影響を与える。例えば、学会活動のイベントカードにおいては、「査読の依頼」などがあり、その依頼を受けると人脈ポイントがあがる一方で、純粋な研究に費やす時間が削られるといったトレードオフの関係がある。本研究では、イベントカードを引いた時の適用/非適用の行動選択に注目し、初心者と専門家間の行動知識の差の抽出を試みる。

### 3. プレイヤの知識モデル

ゲーム型学習教材においては、プレイヤーの知識は、2つのモデルで考えることができる [市瀬 07]。一つは、学習がまだできていない者が持っている知識モデルで、本稿では、初心者モデル (Novice model: N モデル) と呼ぶことにする。一方、学習が進み、そのゲームに精通すると初心者モデルが変化し、専門家が持つ知識のモデルに近づく。ここでは、専門家が持つ知識モデルを専門家モデル (Expert model: E モデル) と呼ぶ。これらのモデルは、個人差があると考えられるが、本稿では、一般的な知識モデルを構築するために、多人数に見られる共通の構造をそれぞれのモデルとする。

N モデルに基づく行動選択と E モデルに基づく行動選択を模式的に表すと、図 1 のように表せる。図中の E モデルが専門家の取る行動を表し、N モデルが初心者の取る行動を表す。図中で両者が重なっている部分  $\beta$  は、N モデル、E モデルに共通した行動となる。図中の  $\alpha$  の部分は、初心者だけが取ってしまう間違った行動であり、 $\gamma$  の部分は、専門家だけが持っている学習すべき行動であると言える。これらの行動知識の差を検知することが、ゲーム型教材を用いた学習において、学習の進捗管理に必要となる。

連絡先: 市瀬 龍太郎, 国立情報学研究所情報学プリンシプル研究系, 〒 101-8430 東京都千代田区一ツ橋 2-1-2, Tel:03-4212-2000, Fax:03-3556-1916, E-mail:ichise@nii.ac.jp

表 1: プレイ履歴から得られる知識モデル

	モデル構築 で使った プレイヤー数	モデル構築 で使った プレイ数	モデルの ルール数	モデルのゴール 到達平均ターン 数 (標準偏差)
N モデル	28	28	33	57(20.5)
E モデル	6	28	24	45(7.6)

#### 4. 行動知識の学習

本研究では、初心者と専門家のそれぞれの行動知識の抽出に行動クローニング [Sammut 96] を用いる。行動クローニングでは、ある環境と人間の動作を対応付けることで、人間と同じ行動を取るエージェントを作成する。例えば、人工衛星の監視業務では、衛星の状態などのデータを基に、人間が制御行動を指示するが、ある環境（衛星の状態）を属性とし、そこでの行動をクラスとして機械学習を行うと、人間の行動を模倣する知識モデルを持つエージェントを作成することができる。本研究では、機械学習手法 CN2 [Clark 91] を行動クローニングの枠組みに適用し、プレイヤーの行動知識のモデル化を試みる。

HAL2006 では、行動決定のための要素として、個人の状態を表す資金力や、論文を書いた研究分野など、さまざまな要素が挙げられる。しかし、全ての要素をプレイヤーの知識モデルに取り入れると、モデルが複雑になってしまうと同時に、多くのプレイ履歴がモデルの構築に必要なになってしまう。そこで、本研究では、ゴール、地位、自分の研究時間、資金力、人脈ポイント、学内ポイント、論文数、資金力アップに関係するカードか否か、人脈ポイントアップに関係するカードか否か、学内ポイントに関係するカードか否か、カードは一時カードか固定カードかの 11 種類の要素を選択し、これを判断材料として、カードの適用/非適用の行動選択をするという知識モデルを構築することにした。

#### 5. 実験と考察

前章までの手法により、構築される知識モデルを調べるために、実験を行った。モデル構築には、表 1 に示した数の被験者とプレイ履歴を使用した。そして、収集されたプレイ履歴から、イベントカードを引いた際に、行動選択が必要になる場面だけを抽出し、その時の状況とプレイヤーが取った行動を取り出し、CN2 の学習データとした。その後、初心者のデータ、専門家のデータ、それぞれに対して、CN2 を適用し、N モデル、E モデルの作成を行った。その結果、「ゴールが学術社会型、かつ、人脈ポイントが上がるカード、ならば、カードを適用する」という If-Then 形式の知識モデルが構築された。構築されたモデルのルール数は、表 1 の通りである。

次に、作成された知識モデルの妥当性を検証するために、その知識を持ったエージェントをプレイさせ、プレイ結果の比較を行った。プレイに使ったエージェントは、作成した N モデル、E モデルに基づき、イベントカードを引いた時の行動を決定する。それ以外の行動知識は、予め妥当と思われる範囲で作成した知識を両方のモデルに実装した。例えば、レベル 3 以上の論文を多く書くゴールを持つプレイヤーは、レベル 3 以上の論文を優先して書く、といった同じ知識を両方のエージェントに実装した。プレイで使う対戦相手は、専門家が手動で 3 種類のプレイヤーエージェントを作成し、N モデル、E モデルの両方とも同じものを用いた。そして、それぞれのエージェントを 28 回ずつプレイさせた。ただし、プレイの途中で、ゴールに到達できなかった場合がそれぞれ、3 回ずつあったため、その

結果は取り除くこととした。各モデルのゴール到達までの平均ターン数と標準偏差は、表 1 の通りとなった。

両モデルのゴールまでの平均ターン数を Welch の方法による  $t$  検定で検証した結果、危険率 5% で差があることが分かった。有意な差があるため、E モデルに対して、N モデルは学習すべき知識があると言える。一方、学習されたルール数を比較してみると、表 1 の通り、N モデルの方が E モデルよりも多いため、N モデルは、E モデルに比べて、知識の組織化が行われておらず、不要な戦略を多く持っていると考えられる。

次に、実際の行動と構築されたモデルの間の関係を調べてみた。専門家実際の行動集合を  $E_E$ 、初心者の実際の行動集合を  $E_N$  とした時、E モデル、N モデルの両方で予測可能な行動は、 $E_E$  の 82.7%、 $E_N$  の 68.0% を占めた。これらの行動は、図 1 の  $\beta$  に当たる行動となる。一方、N モデルで予測可能であるが、E モデルで予測不可能な行動は、 $E_N$  の 17.7% を占めていた。この行動は、図 1 の  $\alpha$  に当たる行動となる。逆に、E モデルで予測可能であるが、N モデルで予測不可能な行動は、 $E_E$  の 11.8% を占めていた。この行動は、図 1 の  $\gamma$  に当たる行動となる。

この結果より、両モデルで共通する行動の  $\beta$  部分が大きな割合を占めていることが分かる。用いた学習データ全体の割合で換算すると、74.2% の割合に相当し、N モデルと E モデルで共通するような知識で、約 4 分の 3 の行動が説明できることが分かる。一方、 $\alpha$  の部分は、初心者は取るが、専門家は取らない行動であるため、初心者が陥りやすい行動選択ミスであると考えられる。このようなものが 17.7% も見られることは、学習による改善の余地が大きいと言える。一方、専門家特有の行動となる  $\gamma$  は、 $\beta$  に比べて少ないことから、初心者が学習する際には、まずは、専門家特有の行動を学習するよりも、初心者の行動選択ミス  $\alpha$  の部分を減らし、 $\beta$  の部分を増やすことで、学習が有効に進むのではないかと考えられる。

#### 6. おわりに

本研究では、プレイ履歴を用いて専門家と初心者の行動知識を学習し、その差異からゲーム型教材を用いた時の学習済み知識と未学習の知識を検知する手法を考察した。今後は、これらのモデルを教材に実装し、効果を検証していく。

#### 参考文献

- [Clark 91] Clark, P. and Boswell, R.: Rule Induction with CN2: Some Recent Improvements, in Kodratoff, Y. ed., *Proceedings of the European Working Session on Learning: Machine Learning (EWSL-91)*, Vol. 482 of *LNAI*, pp. 151–163, Porto, Portugal (1991), Springer Verlag
- [Sammut 96] Sammut, C.: Automatic construction of reactive control systems using symbolic machine learning, *Knowledge Engineering Review*, Vol. 11, pp. 27–42 (1996)
- [山川 06] 山川 宏, 市瀬 龍太郎, 太田 正幸, 加藤 義清, 庄司 裕子, 松尾 豊: Happy Academic Life 2006: 研究者の人生ゲーム – ゲーム型キャリアデザイン学習教材の開発 –, 人工知能学会誌, Vol. 21, No. 3, pp. 360–370 (2006)
- [市瀬 07] 市瀬 龍太郎, 山川 宏, 庄司 裕子, 三浦 麻子: シミュレーション世界における行為者の模倣エージェントの作成と知識獲得支援, 合同エージェントワークショップ & シンポジウム (2007)