

# 深層学習を用いた知識獲得予測を最適化する知識分類の抽出

## Optimization of Deep Knowledge Tracing by Reconstructing Skill Tags

中川大海\*<sup>1</sup>    那須野薫\*<sup>1</sup>    上野山勝也\*<sup>1</sup>    松尾豊\*<sup>1</sup>  
 Hiromi Nakagawa    Kaoru Nasuno    Katsuya Uenoyama    Yutaka Matsuo

\*<sup>1</sup>東京大学

The University of Tokyo

Knowledge tracing is now a very active EdTech research theme. There are various approaches for knowledge tracing, but all of them depend on predefined skill tags which human experts made. In this paper, we propose that such skill tags are not optimized for knowledge tracing, and discuss the necessity of more knowledge-traceable skill tags. As a result, we found that we can make more knowledge-traceable skill tags by skill-tagging in parallel with the optimization of Deep Knowledge Tracing. This result suggests that we can make skill tags automatically and more appropriately for knowledge tracing, which will improve the students' learning efficiency by applying them to the online tutoring systems and help us to reveal the mechanism of human's knowledge acquisition.

### 1. はじめに

近年、教育と情報技術の融合が進む中で、生徒の学習内容を個人に最適化させる新たな教育システムの構築が進んでいる。学習内容を個人に最適化するという考え方は新しいものではないが、従来の学校教育では生徒の学習行動を網羅的に記録し分析することが困難であり、実現には障壁があった。一方、近年の情報技術を活用したオンライン教育サービスでは、サービスを利用する生徒の学習行動ログを収集することで、これまで困難であった大規模な学習効果分析を可能にし、また生徒が個人で学習する形態を活用し、研究成果を元に最適設計された学習内容を個人個人に提供することを容易にした。

一方、近年、教育に限らない多くの研究領域で、深層学習が注目されている。深層学習は、既存の機械学習の手法を上回る性能を得られることに加え、人間が認識できないようなデータの複雑な特徴を捉えることが可能になったため、これまで人間が作り上げてきた概念を塗り替える可能性を秘めており、学習効果分析にも活用が期待されている。中でも、深層学習の適用によって進展した分野として、知識獲得予測の研究が挙げられる。

### 2. 関連研究と問題提起

知識獲得予測 [Corbett 94] は過去の生徒の問題回答履歴から生徒が次に解く問題の正誤を予測するというものである。生徒の時刻  $t$  において観測された問題回答結果を  $q_t$  とすれば、 $q_1, q_2, \dots, q_t$  から  $q_{t+1}$  の正答確率を求めるという、事後確率  $p(q_{t+1} = \text{correct} | q_1, q_2, \dots, q_t)$  を求めるタスクとして設定できる。予測性能の評価指標は Accuracy や AUC など、目的に応じてさまざまである。

知識獲得予測には、ベイズの定理に基づき知識獲得の時系列性を考慮する Bayesian Knowledge Tracing [Corbett 94] や、知識ごとに重み付けを行い知識間の関係性を考慮する Performance Factor Analysis [Pavlik Jr 09] など、伝統的に様々なアプローチが存在するが、2015年に報告された深層学習を用いる Deep Knowledge Tracing (DKT) [Piech 15] の手法により、知識獲得の時系列性と知識間の影響を反映した包括的な知

識獲得予測が可能になった。

ただ、このような最先端の手法においても、予測アルゴリズムには深層学習が適用されているものの、獲得の対象とされる「知識」は事前に人間の専門家が作成した知識分類によって定義され、所与のものとされている。例えば、知識獲得予測の研究でよく用いられるデータセットである「ASSISTments 2009-2010」では、各問題 (problem) に事前に人間が作成した知識タグ (skill) が紐付けられており、この知識タグを用いて知識獲得予測が行われている。しかし、人間が作成した知識分類は、伝統的な枠組みや可読性といった定性的な尺度で作成されたものが多く、実際の生徒の知識獲得の予測という定量的な文脈において最適であるとは限らないため、それを用いた知識獲得予測も最適なものとはいえない。大規模データから潜在的な特徴を自動で学習できる深層学習を活用すれば、人間が認識できないような、知識獲得の過程に潜む潜在的な特徴表現を反映した、知識獲得を説明する上でより適切な知識分類を作成できる可能性は高く、生徒の学習効率を最大化するという目標を真に達成するには、知識分類自体も深層学習によって適切に設計される必要があるといえる。

### 3. 提案手法

本研究では、現在の知識獲得予測で用いられている人間が作成した知識分類は、人間の複雑な知識獲得過程を表現する上では最適な表現ではない、という仮定に立ち、より適切な知識分類、すなわちより高い精度で知識獲得予測を行えるような知識分類を、深層学習に自動的に学習させ抽出することを目的とする。この目的を達成するため、既存の DKT を 2 点において拡張した「知識分類学習モデル」を提案する (図 1)。以下では、まず既存の DKT について説明した後、本手法の 2 つの拡張について説明する。

#### 3.1 DKT のモデル構造と損失関数

DKT の構造は伝統的な RNN の構造に基づいており、時刻  $t$  における入力を  $\mathbf{x}_t$ 、隠れ層を  $\mathbf{h}_t$ 、出力を  $\mathbf{y}_t$  とすると、その関係性は以下の式で表される。

$$\mathbf{h}_t = f(\mathbf{x}_t, \mathbf{h}_{t-1})$$

$$\mathbf{y}_t = g(\mathbf{h}_t)$$

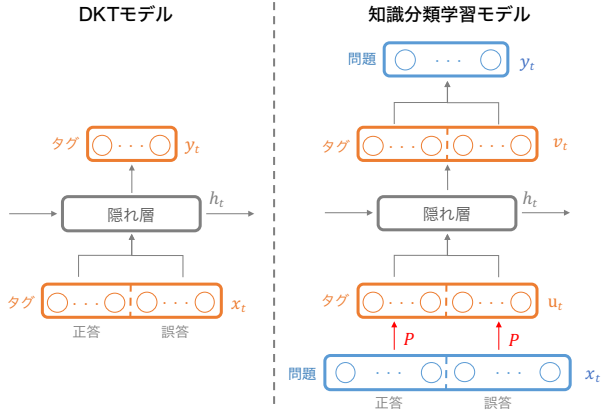


図 1: モデル構造上の拡張

モデルは関数  $f$  と  $g$  によって定義されており, LSTM [Hochreiter 97] や GRU [Cho 14] など様々な活性化関数を利用できる. 入力  $\mathbf{x}_t$  は, 全部で  $M$  個ある問題のうちどの問題に対して正答・誤答したかをそれぞれ長さ  $M$  の one-hot ベクトルで表現し, それらを結合した長さ  $2M$  のベクトルとして表現される.

最適化は式 1 で表される回答正誤予測に関する損失関数  $L_p$  を最小化することにより行われる.

$$L_p = \sum_t l(\mathbf{y}_t^T \tilde{\delta}(\mathbf{q}_{t+1}), \mathbf{a}_{t+1}) \quad (1)$$

ここで  $\mathbf{y}_t$  は時刻  $t$  の出力である問題正誤予測ベクトルであり,  $\tilde{\delta}(\mathbf{q}_{t+1})$  は実際の時刻  $t+1$  の問題回答ベクトルであり,  $\mathbf{a}_{t+1}$  は時刻  $t+1$  に対応する問題で正答したか否か (1 か 0) のベクトルであり,  $l$  は交差エントロピー誤差関数である.

### 3.2 拡張 1: モデル構造

まず, 一般的な DKT のモデルでは問題に紐づく知識タグに関する回答が入力とされるが, 本手法では問題に関する回答をそのまま入力とする. これは, 既存の知識分類を所与のものとせず, モデル自身に知識分類を学習させるためである.

次に,  $M$  次元の問題回答ベクトルを  $N$  次元のタグ回答ベクトルに変換する写像行列  $\mathbf{P}$  を式 2 のように定め, これをモデルのパラメータとして追加することで, DKT の最適化と同時に  $\mathbf{P}$  も最適化させる.

$$\mathbf{P} = \sigma(\mathbf{W}_{xu}) \quad (2)$$

ここで,  $\mathbf{W}_{xu}$  は  $M \times N$  の大きさの重み行列を指し,  $\sigma$  はシグモイド関数を指す. 入力された問題に対する正答・誤答ベクトル  $\mathbf{x}_t$  は  $\mathbf{P}$  によってそれぞれタグに関する正答・誤答ベクトル  $\mathbf{u}_t$  に変換され, RNN の隠れ層  $\mathbf{h}_t$  を経由した後, タグに関する正答予測ベクトル  $\mathbf{v}_t$  を経て最終的に問題に関する正誤予測ベクトル  $\mathbf{y}_t$  が出力される.

$$\begin{aligned} \mathbf{x}_t &= [\mathbf{x}_{t\_positive}, \mathbf{x}_{t\_negative}] \\ \mathbf{u}_t &= [\mathbf{P}\mathbf{x}_{t\_positive}, \mathbf{P}\mathbf{x}_{t\_negative}] \\ \mathbf{h}_t &= \varphi(\mathbf{u}_t, \mathbf{h}_{t-1}, \theta) \\ \mathbf{v}_t &= \sigma(\mathbf{W}_{hv}\mathbf{h}_t + \mathbf{b}_v) \\ \mathbf{y}_t &= \sigma(\mathbf{W}_{vy}\mathbf{v}_t + \mathbf{b}_y) \end{aligned}$$

ここで,  $\mathbf{x}_{t\_positive}$ ,  $\mathbf{x}_{t\_negative}$  はそれぞれ問題回答の正答と誤答を表す長さ  $M$  のベクトルであり,  $\mathbf{W}_{hv}$ ,  $\mathbf{W}_{vy}$  は重み行列を指し,  $\mathbf{b}_v$ ,  $\mathbf{b}_y$  はバイアス項を指し,  $\varphi$  は活性化関数を表す. なお,  $\theta$  は任意のパラメータを指し, 用いる活性化関数によって異なる.

### 3.3 拡張 2: 損失関数

3.2 項の拡張によって問題をタグに変換する表現は得られるが, 得られるタグを知識獲得予測に適用する際の精度を向上させるため, 2 つの損失関数を追加で導入する.

1 つは式 3 で表される「再構成誤差 ( $L_r$ )」である. 本研究では, 問題に対する回答の正誤とタグに対する回答の正誤は相互に可換なはずであるという仮定を立て, この再構成誤差によってその設定を学習に反映させることを目的としている.

$$\begin{aligned} g(\mathbf{u}_t) &= \sigma(\mathbf{W}_{vy}\mathbf{u}_t + \mathbf{b}_y) \\ L_r &= \sum_t l(\mathbf{x}_t, g(\mathbf{u}_t)) \end{aligned} \quad (3)$$

もう 1 つは式 4 で表される「スパース正則化項 ( $L_s$ )」である. これにより  $\mathbf{P}$  の値が 0 か 1 に近づくように学習が進むため, 離散行列に近い  $\mathbf{P}$  が得られる. 本研究で比較対象とする既存の知識分類は「タグ」として離散的に表現されており, 本手法によって抽出される知識分類も, 比較の公平性の面でも, 人間にとっての可読性の面でも, 離散表現であることが望ましい. そのため, 本研究では  $\mathbf{P}$  を学習した後一定の条件に基づき  $\mathbf{P}$  を離散化して比較実験を行うが, 初めから  $\mathbf{P}$  が離散表現に近いほうが離散化する際に情報量の損失が少ない. よってこのスパース正則化項を導入することにより,  $\mathbf{P}$  を事前に離散表現に近づける.

$$L_s = \sum_t (0.5 - |\mathbf{u}_t - 0.5|) \quad (4)$$

結果的に, モデル全体の損失関数  $L$  は以下の式 5 によって定められ, この損失関数を最小化するようにモデルが最適化される.

$$L = L_p + \alpha L_r + \beta L_s \quad (5)$$

なお  $\alpha$ ,  $\beta$  は任意の正の実数を取るが, 本研究では  $\alpha = \beta = 1.0$  とした.

## 4. 実験

### 4.1 実験設定

実験には, オンライン教育サービスの ASSISTments が提供する「ASSISTments 2009-2010(skill\_builder)」\*1 と, KD-DCup の Educational Data Mining Challenge で使用された「Bridge to Algebra 2006-2007」[Stamper 10] という, 数学に関するオンライン教育サービス上の生徒の問題回答ログからなる 2 つのデータセットを用いた. その際, 各データセットについて以下の条件に基づいてデータ抽出を行った.

#### 「ASSISTments 2009-2010」

1. 同時回答を意味する重複ログを 1 つにまとめる.
2. 名前が割り当てられている知識タグを持つ問題の回答ログのみを抽出する.

\*1 <https://sites.google.com/site/assistmentsdata/home/assistment-2009-2010-data/skill-builder-data-2009-2010>

- 2のうち、最低30回以上回答されている問題の回答ログのみを抽出する。
- 3に含まれる問題を、最低2回以上回答している生徒に関するログを抽出する。

### 「Bridge to Algebra 2006-2007」

- 問題 (problem) とステップ (step) の組み合わせを1回の問題回答とみなす。
- 名前が割り当てられており、かつダミーでない知識タグを持つ問題の回答ログのみを抽出する。
- 2のうち、最低100回以上回答されている問題の回答ログのみを抽出する。
- 3に含まれる問題を、最低2回以上回答している生徒に関するログを抽出する。

以上の条件から抽出された、本実験に用いるデータセットの統計量を表1に示す。

表1: 各データセットの統計量

データセット名	生徒数	問題数	知識タグ数	ログ数
ASSISTments 2009-2010	3,410	2,635	55	129,317
Bridge to Algebra 2006-2007	1,136	3,439	192	606,819

以上のデータを用いて「知識分類学習モデル」によって写像行列  $\mathbf{P}$  を学習した後、以下の条件に基づいて  $\mathbf{P}$  を離散化し、タグとして抽出した。「ASSISTments 2009-2010」では  $Y = 0.85$ 、「Bridge to Algebra 2006-2007」では  $Y = 0.90$  とした。

- 各問題の写像ベクトルにおいて、最も値が大きいタグを1とする。
- 写像行列全体において、値が閾値  $Y$  以上のタグを1とする。
- 写像行列全体において、1でない要素を0にする。

抽出された知識分類 (提案手法タグ) を入力として DKT によって知識獲得予測を行い、既存の知識分類 (既存タグ) を入力とした場合との精度比較を行った。その際、差分を明確に検証するため、式3や式4の損失関数を導入しない場合や、知識獲得予測の文脈と無関係に、オートエンコーダーで低次元に圧縮・離散化して作成した知識分類 (事前学習タグ) を入力とした場合とも比較を行った。

また、精度の違いが何に起因するかを分析するため、各タグの性質についても定量的・定性的分析を行った。

## 4.2 実験結果

まず、各知識分類の知識獲得における予測性能の比較を表2に示す。提案手法タグについては、知識分類学習モデルにおいて、式1で表される回答正誤予測に関する誤差関数  $L_p$  のみを損失関数として単純な Embedding を行っている「 $L_p$ 」、 $L_p$ に加え、式3で表される再構成誤差  $L_r$  も損失関数に導入した「 $L_p + L_r$ 」、そして式4で表されるスパース正則化項  $L_s$  も損失関数に導入した「 $L_p + L_r + L_s$ 」の場合について、それぞれ作成した知識分類を用いた結果を示した。既存タグの「marginal」は各問題の単純な正解確率を予測結果とするものであり、[Piech 15]にも記載されていたため本稿でも同様にベースラインの参考として記載した。また、値が大きい箇所は太字で記載した。

いずれのデータセットにおいても、「提案手法タグ ( $L_p + L_r + L_s$ )」が、最も高い AUC を記録した。この結果より、提案手

法によって作成された知識分類が、既存の知識分類よりも知識獲得の予測性において優れていることが示された。以下、このタグを「抽出タグ」とする。

次に、既存タグと抽出タグの性質を比較した。まず、各タグの回答ログにおける出現回数という定量的な指標に着目し、度数分布と各分布の標準偏差  $\sigma$  を分析し、図2に示した。図より、既存タグは偏りが大きく、抽出タグは偏りが小さいことがわかる。




図2: 各タグの回答ログにおける出現回数の分布 (「ASSISTments 2009-2010」の場合)

また、内容的関係性という定性的な性質を分析するため、[Piech 15]の手法に則って既存タグの知識間影響ネットワークを作成した後、既存タグに抽出タグを紐付けたネットワークに加工し、図3、4に示した。赤や青のノードが既存タグを、橙色のノードが抽出タグを表す。ネットワークの局所の特徴に注目した結果、図3の「ASSISTments 2009-2010」の一例では「Probability of Two Distinct Events(2つの異なる事象の確率)」「Venn Diagram(ベン図)」「Percent Of(百分率)」, 図4の「Bridge to Algebra 2006-2007」の一例では「Identify GCF(最大公約数)」「Identify number as common factor(公約数)」「Identify number as common multiple(公倍数)」というように、内容的に近い複数の既存タグを束ねる抽出タグが得られたことが確認された。

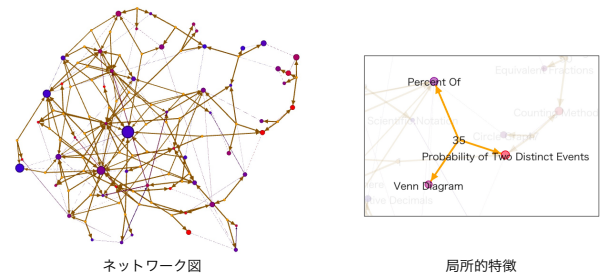


図3: 「ASSISTments 2009-2010」のネットワーク

## 5. 考察

まず、各タグの知識獲得予測における予測性能の比較実験の結果から、深層学習が学習した知識分類を抽出して知識獲得予測に用いることで、人間が作成した既存の知識分類を用いる場合よりも高い精度が得られることが検証され、知識獲得の過程を反映した適切な知識分類が抽出されていると考えられる。

また、性質比較の実験から、抽出タグはタグごとの回答ログにおける出現回数の偏りが小さいことがわかり、これにより DKT において各ユニットが効率よく情報を保持できるような、

表 2: 各知識分類の知識獲得予測における予測性能

データセット	AUC				
	既存タグ (marginal)	事前学習タグ	提案手法タグ		
			$L_p$	$L_p + L_r$	$L_p + L_r + L_s$
ASSISTments 2009-2010	0.72 (0.60)	0.69	0.68	0.69	<b>0.73</b>
Bridge to Algebra 2006-2007	0.78 (0.70)	0.75	0.78	0.78	<b>0.79</b>

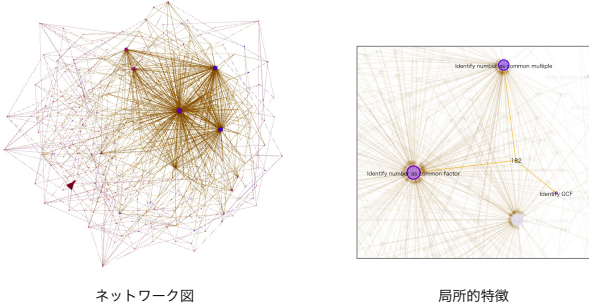


図 4: 「Bridge to Algebra 2006-2007」のネットワーク

ニューラルネットを用いた知識獲得予測に適した構造となっていると考えられる。また、抽出タグのネットワーク分析の結果から、この情報量の均等な分配が知識の領域的な内容と無関係ではなく、一定の内容的関係性を保ったまま行われていることがわかり、これらのことから領域知識の内容的関係性と生徒の回答行動に関する情報量を最適に分配することが、知識獲得予測の精度向上に寄与したのではないかと考えられる。一方、得られたタグをどのように人間が解釈し、より良い教育設計に役立てるかという上では解釈性の課題もあり、今後の研究課題である。

本手法は、発展途上の学問や学習サービスのように、事前に知識が構造化されておらず既存の DKT の適用が困難なデータに対しても適用できるため、既存の DKT より汎用性が高いと考えられる。また、本手法はオンライン教育サービスにおける教材推薦システムに活用することで、生徒の学習効率を高めるといった社会的な価値を持つとともに、未だ構造化されていない発展途上の学問体系を構造化することにより、その学問の発展を助けるという学術的な価値も持つと考えられる。

さらに、本研究では提案手法を教育学の知識獲得予測という領域において適用しその有効性を確認したが、提案手法が行っているのは、人間の何らかのコンテンツ集合に対する時系列行動ログから、行動を重ねるごとに遷移していく人間の何らかの状態をモデリングし、その遷移を最適に説明する分類表現を学習して構造化するものとして一般化でき、これは教育学に限らず人間の購買行動や消費嗜好の遷移など、さまざまな事象に共通する事象であるため、幅広い領域で適用できる蓋然性がある。

## 6. 結論

本研究は、既存の知識獲得予測が、人間が作成した知識分類を所与のものとしていることに問題提起を行い、DKT の手法を拡張することによって既存の知識分類よりも高精度で知識獲得予測を行うことのできる知識分類を抽出できることを示

した。本手法は、教材推薦システムへの適用による社会的価値や、人間の専門家の手を必要とせずに学問を構造化できる学術的価値を有することに加え、教育学に限らない多様な範囲に適用できる蓋然性がある。本研究は、教育と情報技術の融合の進展やオンライン教育サービスの普及、教育分野における大規模分析の活性化や深層学習の躍進など、ここ数年の多様な領域の進展によって初めて可能になったものである。本研究が、あらゆる学問における生徒の学習効率を向上させ、また、新たな教育システムの構築や学問の発達、そして人間の学習や知識の解明につながると信じている。

## 謝辞

本研究は JSPS 科研費 JP25700032, JP15H05327, JP16H06562 の助成を受けたものです。

## 参考文献

- [Cho 14] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., and Bengio, Y.: Learning phrase representations using rnn encoder-decoder for statistical machine translation, *arXiv preprint arXiv:1406.1078* (2014)
- [Corbett 94] Corbett, A. T. and Anderson, J. R.: Knowledge tracing: Modeling the acquisition of procedural knowledge, *User modeling and user-adapted interaction*, Vol. 4, No. 4, pp. 253–278 (1994)
- [Hochreiter 97] Hochreiter, S. and Schmidhuber, J.: Long short-term memory, *Neural computation*, Vol. 9, No. 8, pp. 1735–1780 (1997)
- [Pavlik Jr 09] Pavlik Jr, P. I., Cen, H., and Koedinger, K. R.: Performance Factors Analysis—A New Alternative to Knowledge Tracing., *Online Submission* (2009)
- [Piech 15] Piech, C., Bassen, J., Huang, J., Ganguli, S., Sahami, M., Guibas, L. J., and Sohl-Dickstein, J.: Deep Knowledge Tracing, in *Advances in Neural Information Processing Systems*, pp. 505–513 (2015)
- [Stamper 10] Stamper, J., Niculescu-Mizil, A., Ritter, S., Gordon, G., and Koedinger, K.: Bridge to Algebra 2006-2007. Development data set from KDD Cup 2010 Educational Data Mining Challenge., <http://pslshop.web.cmu.edu/KDDCup/downloads.jsp> (2010)