

# Knowledge Tracing による学習行動履歴からの獲得スキル予測

## Predicting Acquired Skills from Learning Behavior History Using Knowledge Tracing

柿崎 透真<sup>†</sup>  
Toma Kakizaki

大枝 真一<sup>‡</sup>  
Shinichi Oeda

### 1. はじめに

教育現場において ITS(Intelligent Tutoring System) を効果的に活用するには、学習者のスキル状態を把握し、それに見合った設問を推薦する必要がある。そのため学習者のスキル状態の推定が可能な学生モデリングを用いることで、ITS の性能を向上させる研究が行われている。

学生モデリング手法では KT(Knowledge Tracing) が主流となっており、近年では DKT(Deep Knowledge Tracing) や SAKT(Self-Attentive Knowledge Tracing) などのディープラーニングアプローチが盛んに研究されている。しかし、これらのモデルは学生が解いた問題の試験結果や試験を解くために用いたスキルを入力としており、ビデオの視聴や参考書の閲覧など、学習過程においてスキル獲得に大きく関わる学習行動履歴を考慮していない。

本研究では、これらの学習行動の履歴を用いた KT による学生モデリングを行う。また、KT の社会実装が滞っている理由の 1 つに、学校や塾で入手できるデータの数に足りず、機械学習モデルの学習が難しいことが挙げられる。そのため、上記の学習行動履歴を考慮した実験と併せて、データ数を変化させて KT による推定が有効な最小データ数を探索する。

### 2. 先行研究

#### 2.1. Deep Knowledge Tracing

KT の代表的なディープラーニングアプローチの手法として、2015 年に Google が提案した DKT が挙げられる [1]。DKT は、RNN(Recurrent Neural Network) や、RNN に忘却機能を搭載した LSTM(Long Short-Term Memory) を用いて学習者の能力変化を表現し、学習者の各項目への反応を予測するモデルである。RNN または LSTM を用いることで多次元のスキルの関係性を考慮した推定ができるため、従来の確率的アプローチと比較して予測精度が高いことが報告されている。

#### 2.2. Dynamic Key-Value Memory Network

DKT の精度向上のため、memory network を採用したモデルである DKVMN が 2016 年に提案された [2]。DKVMN は memory network として MANN(Memory-augmented neural networks) を用いている。

MANN は memory の読み書きの操作に再帰性が導入されているため、RNN の一種と解釈されるが、オリジ

ナルの RNN と比べて、“情報の記憶容量が多い”、“状態遷移が構造的である”、“パラメータ数が記憶スロットの数によって増加しない”など、多くの利点がある。

DKVMN は標準的な MANN とは違い、DKVMN は潜在スキルの状態を格納する 1 つの静的行列 key と、対象のスキル習得レベルを格納する 1 つの動的行列 value で構成されている。DKVMN のアーキテクチャを図 1 に示す。アーキテクチャにて、key は  $M^k$ 、value は  $M_t^v$  で表されている。

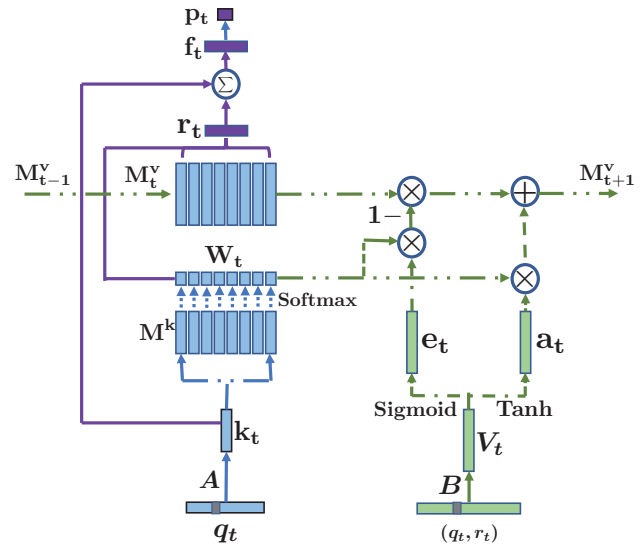


図 1 DKVMN のアーキテクチャ

#### 2.3. Self-Attentive Knowledge Tracing

SAKT は 2019 年に提案された比較的新しい手法で、近年自然言語処理の分野で目覚ましい結果を残している Transformer を構成する Attention という機構が使われている [3]。従来のディープラーニングアプローチのように RNN を使わず、Attention のみを使うことで、より長期的なスキルの依存関係や成長速度を捉えることができる。

#### 2.4. Deep Multi-Type Knowledge Tracing

DMKT は、DKVMN を改良し、評価されない学習行動 (non-assessed resources) を明示的に扱うことを試みたモデルである [4]。従来の KT 手法は、試験やクイズ、課題の回答結果など、2 値で評価できるものを扱うことがほとんどだったが、実際の学習では、“ビデオを視聴する”、“チューターから問題のヒントをもらう”、“参考書を読む”などの 2 値で評価できない学習行動が多くの割合を占めている。DMKT では、従来から使われている assessed resources に加えて、学習行動など

<sup>†</sup>木更津工業高等専門学校 制御・情報システム工学専攻  
Advanced Course of Control and Information Engineering, National Institute of Technology, Kisarazu College

<sup>‡</sup>木更津工業高等専門学校 情報工学科  
Department of Information and Computer Engineering, National Institute of Technology, Kisarazu College

の non-assessed resources を memory network のアーキテクチャに組み込むことで、KT の更なる精度向上を図っている。DMKT のアーキテクチャを図 2 に示す。アーキテクチャにて、中央部分の  $l_t$  を入力する箇所での non-assessed resources を処理している。

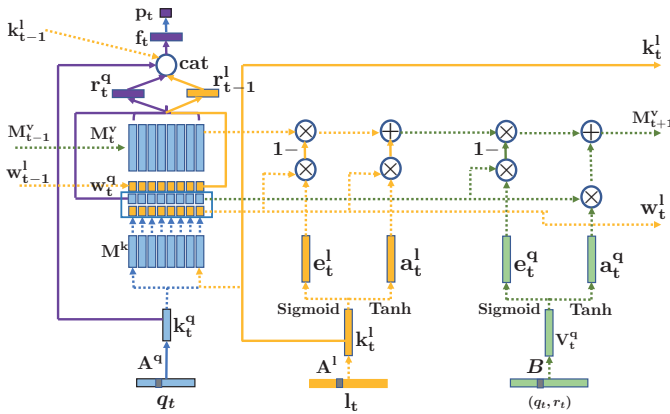


図 2 DMKT のアーキテクチャ

### 3. 実験概要

本研究では、先行研究により提案されている KT 手法を用いて、学習行動履歴を考慮した学生モデリングを行う。評価指標として、AUC(Area Under the Curve) を用いる。

#### 3.1. 提供されているデータセットによる実験

近年の盛んな学生モデリングの研究にかかわらず、KT の社会実装が滞っている理由の 1 つに、学校や塾で入手できる試験データの量が限られていることが挙げられる。授業内の試験は学校間で統一されておらず、同じ授業の試験でも、内容が毎年異なる。また、1 クラスの受講人数は数十人規模の機関がほとんどで、データの行数はおおよそ“学生(生徒)数 × 問題数 ≒ 数 100 行”と、機械学習の訓練データとしては数が少ない。

そこで、提供されているデータセットである EdNet<sup>1</sup> の KT4 データセットを用いて実験を行う。EdNet は、英語の公開テストである TOEIC の対策プラットフォームである。KT4 は約 800,000 ものユーザデータが格納されており、1 人のユーザにつき約 100 レコード記録されている。そのため、ランダムに 10,000 ユーザを抽出するとおおよそ 1,000,000 レコードになる。本実験では、抽出するユーザ数を 10,000~10 と減らしていくことにより、KT の精度の遷移を探索する。また、学習行動履歴として、“音声の再生”、“ビデオの視聴”の情報を用いる。

### 4. 実験結果

#### 4.1. データ数を変化させた際の AUC の遷移

DKVMN, SAKT を用いて EdNet のデータ量を変化させた際の AUC の遷移結果を図 3 に示す。今回、DKVMN と SAKT に関しては DMKT のように non-assessed resources を明示的に扱うことが難しいため、

<sup>1</sup><https://github.com/rriid/ednet>

“音声の再生回数”、“ビデオの視聴回数”を各ユーザ、各教材番号ごとにカウントして、特徴量として使用した。また、ユーザ数が 1,000 人以下の場合には、ランダムなデータの抽出を 3 回行い、AUC の平均を取ったものを図に記録している。

ユーザ数を減らしていくとどちらの手法も精度が落ちてくるが、ユーザ数が 500~100 でも AUC が上昇するケースがあったため、何かしらデータの特徴を捉えていると考えられる。また、全体を通して DKVMN, SAKT とともに似通った精度を示したが、ほとんどのデータ量で DKVMN の方が良い精度を示した。著しく上昇する箇所もあった。

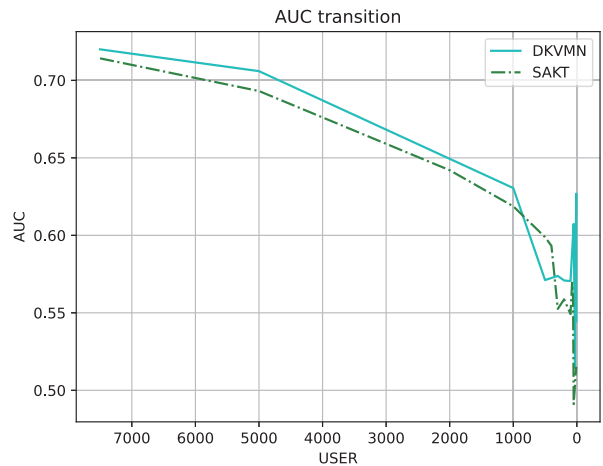


図 3 EdNet のデータ数の変化による AUC の遷移

### 5. まとめ

本研究では、学習行動履歴を考慮した Knowledge Tracing による学生モデリングを行う。また、実データのレコード数の変化による精度の遷移を検証することで、KT に必要な最小データ数を探索する。

### 謝辞

本研究は、JSPS 科研費 19H01728 の助成を受けたものです。

### 参考文献

- [1] Chris Piech, Jonathan Bassen, Jonathan Huang, Surya Ganguli, Mehran Sahami, Leonidas Guibas, and Jascha Sohl-Dickstein, “Deep knowledge tracing”, In NIPS ’15 Proceedings of the 28th International Conference on Neural Information Processing Systems, Volume 1, Vol. 28, pp. 505-513 (2015).
- [2] Jiani Zhang, Xingjian Shi, Irwin King, and Dit-Yan Yeung, “Dynamic key-value memory networks for knowledge tracing”, In WWW ’17 Proceedings of the 26th International Conference on World Wide Web, pp. 765-774 (2017).
- [3] Shalini Pandey and George Karypis, “A self-attentive model for knowledge tracing”, In 12th International Conference on Educational Data Mining, EDM 2019, pp.384-389 (2019).
- [4] Chunpai Wang, Siqian Zhao, Shaghayegh Sahebi, “Learning from Non-Assessed Resources: Deep Multi-Type Knowledge Tracing”, In 14th International Conference on Educational Data Mining, EDM 2021, pp. 195-205 (2021).