

Knowledge TracingとIRTを組み合わせた学生モデリング手法による 学習者の潜在状態推定

Estimation of Learners' Latent State by Student Modeling Method Combining
Knowledge Tracing and IRT

柿崎 透真[†]
Toma KAKIZAKI

大枝 真一[†]
Shinichi OEDA

1. はじめに

今日の教育現場では、e-Learning システムが普及しており、システムを利用した学習者のログが大量に蓄積されるようになった。近年、大量の教育データに対してデータマイニングの手法を活用し、有益な情報を抽出しようとする試みである Educational Data Mining が注目されている [1]。

ITS(Intelligent Tutoring System) は学習者のスキル状態に見合った設問を出題することで、効率の良い学習環境を提供するシステムである。ITS の性能向上のため、先行研究では、高精度なスキル状態の推定が可能な学生モデルが提案されてきたが、これらはログデータが正しいと仮定してモデリングをしている。すなわち、試験が公正かつ公平に行われたものとして、学生のカンニング行為や答えの丸暗記などの可能性が考慮されていない。昨今は新型コロナウイルス感染症対策としてオンラインで行われる試験も多く、そこではインターネットや書籍を使って試験のヒントを得ることも可能と思われる。このように、学生のスキル状態の推定において、学生の学習に対する取り組み方を知ることは重要である。

そこで本研究では、学生モデリング手法のデファクトスタンダードである Knowledge Tracing と項目反応理論を組み合わせたモデルを用いて、学習者の潜在状態を推定する手法を提案する。

2. 手法

2.1. Knowledge Tracing

Knowledge Tracing では、設問を解くために必要な各スキルについて図 1 のようなダイアグラムで表現される。

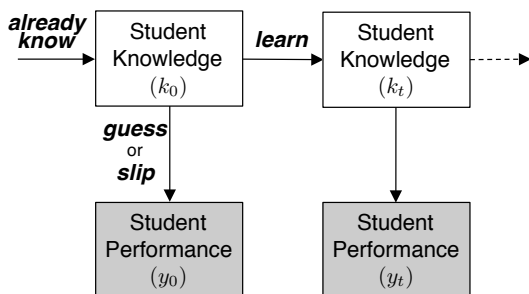


図 1: Knowledge Tracing のダイアグラム

このダイアグラムは、学習機会を t 、学習者のスキル

[†]Department of Information and Computer Engineering, National Institute of Technology, Kisarazu College

状態 (習得・未習得) を隠れ変数 k_t 、設問に関する解答結果 (正答・誤答) を観測値 y_t としている。マルコフ性を持つスキル状態は直接観測されず、解答結果のみが観測されるため、Knowledge Tracing は隠れマルコフモデル (Hidden Markov Model : HMM) である。

Knowledge Tracing では各スキルに対して 4 つのパラメータ $P(L_0)$, $P(T)$, $P(G)$, $P(S)$ が設定され、式 (1)~(4) で定義される。

already know

$$P(L_0) \stackrel{\text{def}}{=} P(k_0 = \text{true}) \quad (1)$$

learn

$$P(T) \stackrel{\text{def}}{=} P(k_t = \text{true} | k_{t-1} = \text{false}) \quad (2)$$

guess

$$P(G) \stackrel{\text{def}}{=} P(y_t = \text{true} | k_t = \text{false}) \quad (3)$$

slip

$$P(S) \stackrel{\text{def}}{=} P(y_t = \text{false} | k_t = \text{true}) \quad (4)$$

$P(L_0)$ は事前知識 (already know) として、学習者があらかじめスキルを習得している確率である。 $P(T)$ は学習者のスキルが “未習得” から “習得” に遷移する確率 (learn) である。Knowledge Tracing ではスキル状態が “習得” から “未習得” に遷移する確率を 0 としており、一度習得したスキルは忘れないということを仮定している。 $P(G)$ はスキルを習得していないにもかかわらず、設問に正答する確率であり、推測 (guess) を表している。 $P(S)$ はスキルを習得しているにもかかわらず、設問に誤答する確率であり、ケアレスミス (slip) を表している。これらの 4 つのパラメータは未知であり、エキスパートによって決定されることもあるが、過去の解答結果データからパラメータを推定する方法が一般的である。

学習者の学習機会 t までの解答結果、および各スキルに対して設定される $P(L_0)$, $P(T)$, $P(G)$, $P(S)$ を使って計算することで、学習機会 $t+1$ におけるスキル状態 $P(L_{t+1})$ および設問に正答する確率 $P(y_{t+1})$ を求めることができる。

2.2. 項目反応理論

学力のように直接的に測ることのできない潜在的能力を、複数の項目を用いて間接的に推定することを目的とした理論が項目反応理論 (Item Response Theory : IRT) である。項目反応理論では項目の形式に合わせた様々なモデルが考案されているが、中でも代表的なモデルとして、項目への反応を 2 種類に分類可能なテ

スト (正答・誤答) を対象とした 1 母数ロジスティックモデル (Rasch モデル) が挙げられる。

Knowledge Tracing と Rasch モデルを組み合わせたモデルである FAST[2] と LFKT[3] が 2014 年に発表されたが、どちらも従来の Knowledge Tracing の予測精度を大きく上回ることが判明している。

3. 提案手法

本研究では、Knowledge Tracing と項目反応理論を組み合わせたモデルを使って、学習者の潜在状態を予測することを目的とする。具体的には、学生の試験への向き合い方を、学習機会 t での guess(当て推量) の確率 $P(G_t)$, slip(ケアレスミス) の確率 $P(S_t)$ を指標に評価する。各確率は、式 (5)~(8) で計算する。学習機会 $t+1$ での設問への正解率 $P(y_{t+1})$ が閾値 0.5 より大きいかどうか、また実際に設問に正答したか否かを基準に、4 つに場合分けをして確率を計算する。

$$\textcircled{1} P(y_{t+1}) \geq 0.5 \text{ かつ 設問に正答} \\ P(G_t) = P(S_t) = 0 \quad (5)$$

$$\textcircled{2} P(y_{t+1}) < 0.5 \text{ かつ 設問に正答} \\ P(G_t) = 1 - P(y_{t+1}), P(S_t) = 0 \quad (6)$$

$$\textcircled{3} P(y_{t+1}) \geq 0.5 \text{ かつ 設問に誤答} \\ P(G_t) = 0, P(S_t) = P(y_{t+1}) \quad (7)$$

$$\textcircled{4} P(y_{t+1}) < 0.5 \text{ かつ 設問に誤答} \\ P(G_t) = P(S_t) = 0 \quad (8)$$

また、確率が 0.4~0.6 と、閾値 0.5 に近い値のデータに対しては判断が困難だと判断し、この範囲の確率が算出された場合、そのレコードをドロップアウトすることで対応する。

4. 実験

人工データを生成して実験を行う。人工データの生成には、項目反応理論を用いる。人工データを作るとき、0.1 などの微小な確率で解答結果を反転させる。解答結果は 0 が誤答、1 が正答として、0 から 1 に反転したら guess, 1 から 0 に反転したら slip とする。

評価方法として、2 群の分類問題における制度評価指標として知られている AUC(Area Under Curve) を用いる。また、 $P(G_t), P(S_t)$ の精度は $P(y_{t+1})$ の精度に依存しているため、 $P(y_{t+1})$ の評価も同様に行う。

5. 実験結果

潜在状態の推定結果の ROC 曲線グラフについて、未来の成績推定の場合を図 2 に、guess の場合を図 3 に、slip の場合を図 4 に示す。

AUC はそれぞれ 0.69, 0.79, 0.65 と、似通った値を示しており、実用的とは言えないが半数以上は正しく判断できている。このことから、潜在状態推定に未来の正答確率を使うことは有用であると考えられる。




図 2: 未来の成績推定結果





図 3: guess(当て推量) の推定結果

図 4: slip(ケアレスミス) の推定結果

6. まとめ

本研究では、学習者の潜在状態推定を目的として、Knowledge Tracing と項目反応理論を用いて実験をした。今後は、潜在状態推定の精度向上や、実際に潜在状態推定を利用した CBT(Computer Based Testing) の作成などを行いたい。

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] Shinichi Oeda, Kouta Asai, “Student Modeling Method Integrating Knowledge Tracing IRT with Decay Effect”, Second International Workshop on Educational Knowledge Management(EKM 2016), pp.19-26,2016.
- [2] JP González-Brenes, Yun Huang, and Peter Brusilovsky. General features in knowledge Tracing: Applications to multiple subskills, temporal item response theory, and expert knowledge. *Proceedings of the 7th International Conference on Educational Data Mining*, 2014.
- [3] Mohammad Khajah, Rowan M Wing, Robert V Lindsey, and Michael C Mozer. Integrating latent-factor and knowledge-tracing models to predict individual differences in learning. *Proceedings of the 7th International Conference on Educational Data Mining*, 2014