

教育支援における知識トレーシングモデルの検討

A Study of Knowledge Tracing Models for Educational Support

金西 計英^{*1}, 戸川 聡^{*2}Kazuhide KANENINSHI^{*1} and Satoshi TOGAWA^{*2}^{*1} 徳島大学^{*1}Tokushima University^{*2} 四国大学^{*2}Shikoku University

Email: marukin@cue.tokushima-u.ac.jp

あらまし：本稿は、学習者の知識状態を推定・可視化する技術である Knowledge Tracing (KT) について、初期の確率的モデルから深層学習を活用した最新手法までを体系的に整理したものである。BKT や因子分析モデルなどの伝統的手法に加え、RNN・注意機構・グラフ構造・テキスト情報・忘却モデリングなどを組み込んだ多様な深層学習モデルを紹介する。さらに、KT の応用として個別最適化学習や教育支援ツールの高度化に言及し、今後の研究課題としてマルチモーダル情報の活用や解釈性の向上などを示す。

キーワード：Knowledge Tracing(KT), Deep Knowledge Tracing(DKT), 教育支援システム, 深層学習

1. はじめに

高等教育における基礎科目の中には、知識の伝達を目的とするものが存在する。これらの授業では、対象とする知識の提示と演習問題による反復練習が、学習の基本的な枠組みとなる。教師は、知識の提示や課題の提示タイミングを、個々の学習者の理解状態に応じて柔軟に調整する必要がある。学習者の理解状態の診断は、教師にとって重要な能力であり、正確な診断は個別最適化された学習の実現に不可欠である。このような診断機能は、Knowledge Tracing (KT) として知られている。

KT の目的は、学習者の知識状態、すなわち学習履歴から特定のスキルに対する習熟度を観察・定量化することである。KT が効果的に機能すれば、個別最適教材推薦や学習支援システムの開発に大きく寄与することができる。

本稿は、近年急速に進展する KT に関する研究動向を、初期の確率的手法から深層学習を活用した最近のアプローチに至るまで体系的に整理する。あわせて、現在の課題と将来の展望についても考察する。

2. KT モデルの進化

2.1 Knowledge Tracing の概要と背景

KT は、学習者の過去の解答履歴に基づき、現在および将来の知識状態を推定し、次に提示される問題に対する正答確率を予測する技術である。その起源は、Corbett と Anderson によって提案された「Bayesian Knowledge Tracing (BKT)」にあり、学習をマルコフ過程としてモデル化する確率的手法として発展してきた⁽¹⁾。

2.2 伝統的 KT モデル

伝統的な KT モデルには、BKT やロジスティック回帰に基づく因子分析モデルが含まれる。これらは少数のパラメータで動作し、計算効率が高いという

利点を持つ。一方で、スキル間の相互依存性や長期的な記憶効果の扱いには限界がある。

● BKT (Bayesian Knowledge Tracing) モデル

BKT は、知識状態を未習得か習得の 2 値で示す。また、知識はスキルの階層として適切に記述されており、上位のスキルの学習は下位スキルの学習が保証されていることが前提とされる。モデルは、初期習得確率、習得遷移確率、知識を持つが誤答する確率、知識を持たないが正答する確率の 4 つのパラメータを用いる。

● 因子分析モデル (Factor Analysis Models)

因子分析モデルは、項目反応理論 (IRT) を基盤とし、学習者の知識状態能力を、さまざまな要因に基づいて関数 (通常はロジスティック関数) を学習することで推定するというものである。代表的な手法には、AFM (Additive Factor Model)⁽²⁾ や PFA (Performance Factor Analysis)⁽³⁾ がある。近年では、KTM (Knowledge Tracing Machine) も提案されている⁽⁴⁾。

2.3 深層学習型 KT モデル

2015 年に Piech らが DKT (Deep Knowledge Tracing) を提案して以降、DKT が伝統的な KT より高い精度を示したことで、深層学習を用いた DKT が KT の主流となっている⁽⁵⁾。DKT は、リカレントニューラルネットワーク (RNN) および長短期記憶 (LSTM) を用いて、学習者と問題・回答のインタラクションの時系列動態を捉え、新しい問題に対する回答の正誤を予測するものである。

一方で、DKT の課題も指摘されている。隠れスキル (KC) を単一と仮定し、スキル間の関連性を十分に表現できない。また、すべての課題が等しく関連しているという前提も現実的ではない。

こうした課題に対応するため、多様な拡張モデルが提案されている。

- メモリ強化型モデル (Memory-Augmented KT) DKVMN (Dynamic Key-Value Memory Network) が代表的で、キー (スキル) とバリュー (習熟度) のペアで知識状態を動的に記録・更新することが可能となっている⁽⁶⁾.
- 注意機構 (Attention-based KT) モデル SAKT, AKT, SAINT などのモデルがあり、大規模言語モデルで注目される注意機構を活用し、過去のインタラクションの中で重要な質問に注目し、次の解答を予測するものである^(7,8).
- グラフベースモデル GNN (Graph Neural Network) を用いて、スキルや問題の依存関係をグラフ構造で表現する GKT や GIKT などがある⁽⁹⁾.
- テキスト活用型 KT EERNN や EKT などが、問題文のテキスト情報を活用して、より意味的なスキル認識と知識状態推定をおこなう⁽¹⁰⁾.
- 忘却考慮型モデル (Forgetting-aware KT) DKT に忘却機能を加えた DKT+Forget や、学習・忘却の両面を確率的にモデル化した KPT、時間的効果を Hawkes 過程で扱う HawkesKT などがある^(11,12).

3. KT の応用

KT は、教育分野において広範な応用が可能である。まず、個別最適な学習では、学習の理解度に応じた教材や問題の提示が可能となる。さらに、スキルの構造に基づいたカリキュラムの最適化や、学習順序の設計が可能となる。また、能力診断や学習の進捗把握といった評価の側面でも有用である。加えて、KT は教育支援ツールの構築に貢献しており、大規模公開オンライン講座 (MOOC) 等へ機能が統合されることで、より高度な教育支援が可能となっている。

4. KT の課題

KT には幾つか課題が存在している。第一に、視線・表情・音声など非言語的なマルチモーダルデータを活用し、学習者の理解状態をより精緻に把握する必要がある。第二に、モデルの解釈性と説明可能性の向上も不可欠であり、教育現場で信頼される KT システムの構築には、判断根拠を可視化する仕組みが求められる。第三に、学習履歴が少ない状況や新規問題への対応には、転移学習やメタラーニングの活用が望まれる。さらに、学習者の戦略的行動を追跡する試みも重要であり、単なる正誤データにとどまらず、問題解決の過程や学習パターンを捉える KT の開発が期待される。

5. おわりに

KT は、個別最適な教育支援を実現する上で中核を成す技術であり、深層学習の導入によってその精

度と柔軟性は飛躍的に向上している。本稿では、伝統的手法から最新の深層学習を活用した KT 研究を網羅的に整理し、KT の全体像と今後の発展方向を明らかにした。今後は、理論と応用の両面から KT のさらなる高度化が期待される。

謝辞

本研究の一部は、科学研究費補助金基盤研究(C) (課題番号 25K15371) 等の支援を受けた。

参考文献

- (1) 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(1995)
- (2) Cen, H. Koedinger, K. R. and Junker, B. : "Learning factors analysis - A general method for cognitive model evaluation and improvement". *Proc. of International Conference on ITS 2006*, Vol. 4053. pp. 164-175 (2006)
- (3) Pavlik, P. I. Cen, H. and Koedinger, K. R. : "Performance factors analysis - A new alternative to knowledge tracing". *Proc. of 14th International Conference AIED*, Vol. 200. pp. 531-538 (2009)
- (4) Vie, J. J. and Kashima, H. : "Knowledge Tracing Machines: Factorization Machines for Knowledge Tracing". *Proc. of The Thirty-Third AAAI Conference on Artificial Intelligence(AAAI)*, pp.750-757 (2019)
- (5) Piech, C. Bassen, J. Huang, J. Ganguli, S. Sahami, M. Guibas, L. J. and Sohl-Dickstein, J.: "Deep Knowledge Tracing". *Advances in Neural Information Processing Systems 28 (NIPS 2015)*, pp.505-513 (2015).
- (6) Zhang, J. Shi, X. King, I. and Yeung D-Y. : "Dynamic key-value memory networks for knowledge tracing". *WWW '17: Proc. of the 26th International Conference on World Wide Web*, pp.765-774 (2017)
- (7) Pandey, S. and Karypis, G. : "A Self-Attentive model for Knowledge Tracing". *Proc. of The 12th International Conference on Educational Data Mining (EDM 2019)*, pp.384-389 (2019)
- (8) Gan, W. Sun, Y. Peng, X. and Sun, Y. : "Modeling learner's dynamic knowledge construction procedure and cognitive item difficulty for knowledge tracing". *Applied Intelligence*, 50, pp.3894-3912 (2020)
- (9) Nakagawa, H. Iwasawa, Y. and Matsuo, Y.: "Graph-based Knowledge Tracing: Modeling Student Proficiency Using Graph Neural Network". *Proc. of WI '19: IEEE/WIC/ACM International Conference on Web Intelligence*, pp.156-163 (2019)
- (10) Su, Y. Liu, Q. Liu, Q. Huang, Z. Yin, Y. Chen, Ding, C. Wei, S. and Hu. G. : "Exercise-Enhanced Sequential Modeling for Student Performance Prediction". *Proc. of Thirty-Second AAAI Conference on Artificial Intelligence*, pp.2435-2443 (2018)
- (11) Nagatani, K. Zhang, Q. Sato, M. Chen, Y-Y. Chen, F. and Ohkuma, T. : "Augmenting Knowledge Tracing by Considering Forgetting Behavior". *WWW '19: Proc. of the 28th International Conference on World Wide Web*, pp.3101-3107 (2019)
- (12) Wang, C. Ma, W. Zhang, M. Lv, C. Wan, F. Lin, H. Tang, T. Liu, Y. and Ma, S. : "Temporal cross-effects in knowledge tracing". *Proc. of the 14th ACM International Conference on Web Search and Data Mining*, pp.517-525 (2021).