

課題演習に基づく適応的学習システムにおける学習履歴の追跡について

金西 計英¹⁾, 戸川 聡²⁾

1) 徳島大学 高等教育研究センター

2) 四国大学 経営情報学部

marukin@cue.tokushima-u.ac.jp

On Knowledge Tracking Functions in Adaptive Learning Systems Based on Exercises

Kazuhide Kanenishi¹⁾, Satoshi Togawa²⁾

1) Research Center for Higher Education, Tokushima Univ.

2) Faculty of Management and Information Science, Shikoku Univ.

概要

本研究は、高等教育における基礎科目の知識伝達を対象に、適応的学習システムの構築を目的とする。CBTをベースにした適応的学習システムを構成する。システムには、学習履歴の分析による学習者の理解状態の診断が必要となる。本研究では、自己注意機構とQ-Matrixを組み込んだEAKTモデルの利用を提案する。本研究では、学習履歴の解釈可能性と診断精度の向上を検証した。特に、筆者らが用意したCBTを用いて収集した解答履歴を用い、EAKTの評価をおこなった。その結果、本手法の一定の有効性を確認した。

1 はじめに

コロナ禍以降、高等教育の現場ではオンライン授業が急速に普及し、デジタル技術の導入が加速した。COVID-19流行期のオンライン授業への移行は、緊急対応としての性格が強かった。2025年を、ポストコロナ期として捉えると、コロナ禍の経験を踏まえ、教育の質保証と学習者中心の学びを実現する、新たな価値の創出としての教育DXの推進が求められる。

大学教育における知識伝達を目的とする科目においても、教育DXの必要性は同じである。知識伝達型授業では、これまで大人数講義を中心に、教員から学生への一方向的な情報伝達をおこなってきた。しかし、デジタルネイティブ世代の学生は、多様なメディアや学習リソースを用いた学びに慣れ親しんでいる。そのため、単なる対面講義のみでは、学習意欲や理解度を十分に保証できない。教育DXは、オンデマンド教材やオンライン授業、学習支援システムの活用を通じて、知識伝達の効率化と学習機会の拡張を実現する。具体的には、教員による一斉講義を補完する形で、学習者は自らのペースで学修を進めることが可能となり、進捗の差を縮めることができる。また、学習履

歴の収集と分析を通じ、理解状況が可視化され、必要に応じて補助教材やリメディアル教育を提供することも可能となる。したがって、知識伝達型科目における教育DXの推進は、知識の効率的習得を支援すると同時に、学習者一人ひとりに適合した、個別最適な学習環境を実現することになる。

国内の多くの大学では、初年次の学生に対し、専門教育への橋渡しとして、基礎的な知識の伝達を目的とした科目（数学や物理等）が設定されている。知識伝達を目的とするこれら科目の講義を、自学自習型の学習システム（eラーニング）で補完することが可能と考える。さらに、そうした自学自習型のeラーニングに、個別最適の学習をおこなう機能を付与することで、適応的な学習システムが実現できると考える。

本研究では、適応的学習システムをCBT(Computer Based Test)をベースに実現する方法について提案する。通常、CBTは学習者の理解状態を判定するために用いられる⁽¹⁾。一方、CBTには、大量の問題が蓄積されており、大量の問題があるならば、この問題群を試験と演習用に分け、演習環境を提供可能と考える。問題を繰り返し解く演習は、知識の定着に有効であり、学習の重要な方法といえる⁽²⁾。

本稿では、適応的な学習システムの構成について提案する。とくに、我々が対象とする知識伝達における学習過程において、学習者の理解状態の診断に機械学習を用いる方法について提案する。

2 知識伝達を学習と個別最適化

2.1 知識伝達における自学自習

我々は、自学自習による知識伝達を、eラーニングシステムで実現可能と考える。一般的に、知識伝達は、学習者がデジタル化されたコンテンツを繰り返し視聴することで進む。ただし、コンテンツの視聴だけでは、知識獲得が十分ではないことが想定される。そこで、知識獲得を定着させるためには、演習問題を解く必要がある。学習者は、学習として、コンテンツの視聴、演習を、繰り返しおこなう。知識の獲得を確実にするため、反復練習が必要となる。必要十分な反復練習をおこなえば、対象領域の知識の獲得は可能である。

しかし、必要十分な回数というのは、学習者によって様々である。現状では、学習者に対し、一律、あるいは網羅的な繰り返しが課せられる。一律な繰り返しは、学習者の学習意欲の維持に、肯定的な影響を与えない。反復練習の回数は、学習者の理解状況に合わせておこなうことが望ましい。

2.2 知識伝達における適応的学習

知識伝達を対象とした自学自習の効率化とは、個々の学習者の理解状態に沿った形で、反復練習の回数を決定することである。

知識伝達を目的とした自学自習は、コンテンツ視聴、演習問題を解く、判定試験を受ける等の細分化された行為の繰り返りで構成される。自学自習をおこなっている学習者は、学習の進行において、適切に細分化された行為を選んでいないとは限らない。学習者は、既に理解している知識に対し、コンテンツ視聴を繰り返しているかもしれない。自身の理解レベルに合っていない演習をおこなっているかもしれない。こうした学習の進め方は、学習意欲を下げる可能性がある。

効率的に学習を進めるには、学習者の理解状態に沿った学習単位の選択が求められる。システムが、学習者が分かっているところと、分かっていないところを判定し、分かっていないところのコンテンツや演習を提示する必要がある。つまり、システムによる診断が必要となる。

問題 15

次の文章のうち、ノイマン型コンピュータの説明として正しいものをすべて選べ。

- ①ノイマン型コンピュータの処理速度を上げるため命令を平行実行することができる。
- ②ノイマン型コンピュータは、命令を実行するためには必ず主記憶装置にアクセスしなければならない。
- ③現在動いているコンピュータは、全てノイマン型コンピュータである。
- ④CPUの処理速度が速く、主記憶装置の記憶容量が不足するため、CPU本来の処理速度で実行できないことを「ノイマン・ボトルネック」という。

解答

図 1 演習問題の例

3 適応的な学習の構成

3.1 Knowledge Tracing による診断

個別最適な学習を実現するには、学習者の理解状態を適切に判断する診断機能が必要となる。学習者の理解状態の推定手法として、Knowledge Tracing(KT)が知られる。

KTは、学習者の解答履歴から知識状態を推定し、将来の解答を予測する枠組みとして知的学習システムの研究の中で発展してきた。Corbett と Anderson (1995) による Bayesian Knowledge Tracing (BKT) がその嚆矢であり、学習者が各知識要素を「習得している／していない」という潜在状態を持つと仮定し、正答や誤答を通じて知識の獲得や忘却を確率的に表現した⁽³⁾。BKTはKTの標準的手法として活用されたが、一方で知識獲得の複雑性を単純化しすぎるとの指摘もあった。こうした課題に対し、深層学習を応用した手法が登場した。Piechら(2015)はリカレントニューラルネットワークを用いた Deep Knowledge Tracing (DKT)を提案し、従来手法を上回る予測精度を示した⁽⁴⁾。さらに、その後は演習問題の特徴を組み込む様々な拡張モデル(EKT, HawkesKTなど)が開発され、学習者の知識状態をより多面的に捉える研究が進んでいる^(5,6)。

Vaswani(2017)らが大規模言語モデルの手法として自己注意機構 (self-attention) を用いた Transformer を提案すると、KTにおいても自己注意機構が注目された⁽⁷⁾。自己注意機構は、全ての解答履歴間の関係性を同時に考慮できるため、学習者の知識状態をより柔軟かつ精緻に表現することが可能となる。Pandey と Karypis (2019) は Self-Attentive Knowledge Tracing (SAKT) を提案し、学習履歴の重要部分に動的に着目することで予測精度を向上させた⁽⁸⁾。さらに、Ghoshら(2020)は、Transformerに基づくモデルを導入し、より大規模

な教育データに対して高い性能を示した⁽⁹⁾。このような研究は、学習者の状態推定の精度向上だけでなく、学習過程の解釈可能性の向上にも寄与する点で注目されている。

3.2 EAKT モデルについて

我々は、適応的な学習システムにおける診断機能の実現を目指している。具体的には、Pu(2022)らが提案した自己注意機構を用いた KT の一種である Embedding cognitive framework with self-attention for interpretable Knowledge Tracing (EAKT) の利用を想定する⁽¹⁰⁾。

EAKT は、KT に自己注意機構を導入し、学習者の解答履歴のより精緻な推定を目指している。従来の DKT (Deep Knowledge Tracing) は RNN を用いて学習者の知識状態を時系列的に推定するが、問題間の関係性や知識要素ごとの特徴を十分に反映できないという課題があった。EAKT はこの制約を克服するため、Q-Matrix を利用することで、問題と知識の対応関係をモデル内部に明示的に組み込む。さらに、自己注意機構を用いることで、学習履歴全体の中から現在の予測に重要な演習を選択的に強調することが可能となる。これにより、EAKT は長期依存関係を考慮しつつ、学習者の習熟度を知識要素単位で推定する精度を高めている。加えて、EAKT は学習者がどの知識領域でつまづいているかを可視化する点でも有用であり、学習支援やカリキュラム設計への応用が期待される。

学習履歴として用いることのできる、演習に関する一般的な情報は、表 1 に示した通り利用者と演習問題の二次元の行列となる。演習問題の正解あるいは誤答を 0、1 の 2 値化したものである。この行列には問題と解答者の項目が配置され、問題の正答、誤答の結果が表示される。この表で解答者 1 は、問題 1 は誤答、問題 2 は正答といったことが表現されている。

表 1 解答履歴の例

	User1	User2	User3	User4	User5
Item1	0	1	0	0	0
Item2	1	1	0	0	0
Item3	0	1	0	1	1
Item4	1	1	0	1	0

一方、我々は Tatsuoka らの開発した Q-Matrix の利用も想定している。Tatsuoka らは初等教育の数学教育の分野で、学習者の理解を、演習問題と数学的なスキル間の関係として、二次元行列の形で記述する Q-Matrix を提案した⁽¹¹⁾。

表 2 に示した通り Q-Matrix は、問題 (Item) と問題を解くための潜在能力 (Skill) の項目からなる二次元行列である。例えば、表 1 では問題 1 を解くためには能力 4 が必要であることを表している。また、問題 1 と問題 3 は、どちらの問題も解くためには能力 4 が必要であることが分かる。Q-Matrix によって、問題がそれぞれどのように関連しているかが分かる。

表 2 Q-Matrix の例

	Attributes/Skills				
	Skill1	Skill2	Skill3	Skill4	Skill5
Item1	0	0	0	1	0
Item2	1	0	1	0	0
Item3	0	1	1	1	0
Item4	0	0	1	0	1

EAKT は、主に Q-Matrix による知識要素情報の導入と自己注意機構による重要演習の強調という二つの柱から構成されている。EAKT の内部では、入力、知識状態の更新、予測の手続きから構成される。この 3 つの段階を繰り返し、次問題の解答の確率を求める。

1. 入力埋め込み (Input Embedding with Q-Matrix)

学習者のある時刻 t における入力は、問題 a_t と解答結果 r_t である。問題は Q-Matrix を用いて知識要素 (Knowledge Component: KC) ベクトル c_t に変換される。解答の正誤 r_t に応じて、KC ベクトルを正答用/誤答用に拡張したベクトル d_t を生成し、これをニューラルネット入力 e_t に変換する。

2. 自己注意機構による知識状態更新 (Updating Knowledge State)

すべての履歴データ (d_1, d_2, \dots, d_t) と対応する KC ベクトル (c_1, c_2, \dots, c_t) を用いて、Query, Key, Value を構築する。自己注意機構により、現在の予測に有効な履歴を選択的に強調し、学習者の知識状態ベクトル s_t を更新する。この過程により、長期依存関係や複数の知識要素にまたがる学習履歴が効率的に反映される。

3. 多次元認知フレームワークによる予測 (Prediction with Cognitive Framework)

次の問題 a_{t+1} を Q-Matrix を介して KC ベクトル c_{t+1} に変換する。現在の知識状態 s_t と次の問題の KC 要件との差を計算し、合成ベクトル F_t を生成する。この差分は「学習者の知識状態と問題の要求との差」を表し、解答の正答確率 p_t を算出する基盤となる。出力層では修正シグモイド関数を用いて確率を求め、次の問題に正

解する確率を推定する。

3.3 EAKT を用いた診断の有効性

EAKT の診断能力について、Pu らは、演習問題のオープンデータセットである ASSIST2009、ASSIST2015、ASSIST2017 を用い、それぞれ AUC を求め、評価をおこなっている。AUC の値は、84.6、80.0、69.5 であった。ASSIST2009 の場合、AUC 値は 84.6 であり、有効性を示している。ASSIST2017 の場合は、69.5 とやや低い値となっているが、一定の信頼性は示していると考ええる。

我々は、独自に収集した演習問題の解答履歴を用いて、EAKT の評価をおこなった。我々が用いたのは情報リテラシーを対象にした自学自習環境 (CBT) における、演習問題の解答履歴である。約 500 問の演習問題、50 名程度の学習者のデータを用いた。Pu らの検証と同様に、AUC を求めた。その結果、AUC は、85.4 となった。Pu らがおこなった検証結果と同様の結果が得られた。EAKT の診断能力は、概ね有効であると言って差し支えないものと思われる。

4 適応学習システムの構成

適応的な学習システムは、システムの基本的なフレームワークに、標準的な LMS (Learning Management System) を用いる。多くの LMS は CBT の機能を装備しており、この CBT 機能を用いて、演習をおこなえるようにすることで自学自習用の学習システムを構成することができる。

適応的な学習システムは、標準的な LMS に、診断機能を付加することで構成できる。診断機能は、下位の構成要素として、学習者の解答履歴を収集する機能、Q-Matrix を求める機能、さらに、EAKT を実装することで、実現できる。

さらに、システムには教授戦略を用意する必要がある。適応的なシステムは、学習者の理解状態に応じて、コンテンツの提示を制御することが求められるからである。

5 まとめ

本稿では、高等教育の基礎科目の学習を対象とした、知識伝達を目的とした適応学習システムの概要について述べた。学習者の診断に KT の進展が大きく貢献をしている。中でも、我々は EAKT

の利用を提案した。EAKT の性能についての検証をおこない、一定の有用性があることを確認した。今後、実際のシステムの実現を進める予定である。

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) の支援を受けた。

参考文献

- [1] 植野 真臣, 永岡 慶三 “e テスティング,” 培風館, 2009.
- [2] 平澤 梓, 光永 悠彦, 小松川 浩 “項目応答理論を用いた適応型 e ラーニングによる学習効果に関する研究,” 教育システム情報学会学生研究発表会 (北海道地区), 17-18, 2014.
- [3] Corbett, A. T. and Anderson, J. R. “Knowledge tracing: Modeling the acquisition of procedural knowledge,” *User Modeling and User-Adapted Interaction*, 4(4), 253–278, 1995.
- [4] Piech, C., et al. “Deep knowledge tracing,” *In Proceedings of NIPS*, 505–513, 2015.
- [5] 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,” *In Proceedings of Thirty-Second AAAI Conference on Artificial Intelligence*, pp.2435–2443, 2018.
- [6] 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,” *In Proceedings of the 14th ACM International Conference on Web Search and Data Mining*, pp.517–525, 2021.
- [7] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. and Polosukhin, I., “Attention is all you need,” *NIPS’17: In Proceedings of the 31st International Conference on Neural Information Processing Systems*, 6000–6010, 2017.
- [8] Pandey, S. and Karypis, G. “A self-attentive model for knowledge tracing,” *In Proceedings of the 12th International Conference on Educational Data Mining (EDM)*, 384–389, 2019.
- [9] Ghosh, A., Heffernan, N. and Lan, A. S. “Context-aware attentive knowledge tracing,” *In Proceedings of KDD*, 2330–2339, 2020.
- [10] Pu, Y., Wu, W., Peng, T., Liu, F., Liang, Y., Yu, X., Chen, R. and Feng, P. “Embedding cognitive framework with self-attention for interpretable knowledge tracing,” *Scientific Reports*, 12, 17536, 2022.
- [11] Tatsuoaka, K. “Cognitive Assessment,” Routledge, 2009.