

Encoder-Decoder DKT モデルによる eラーニング推薦システム

潘 秋実^{1,a)} 富平 準喜^{1,b)} 手塚 太郎^{1,c)}

概要 : eラーニングシステムは世界的に急速な普及を続けている。その学習ログに機械学習による推薦機能を加え、生徒の特性に合わせて最適な学習プログラムを提供するための様々な試みが近年活発に行われてきた。eラーニングにおいて機械学習が利用される代表的なタスクとして、生徒が次に解く問題の正解確率を予測する Knowledge Tracing (KT) がある。このタスクに対する手法としては現在、Bayesian Knowledge Tracing (BKT) と Deep Knowledge Tracing (DKT) が活発に研究されている。しかし既存の KT モデルとその実用的な利用の間にはギャップがあるのが現状である。DKT が抱える限界の一つは学習者が過去に学習した概念が現在に与える影響をうまく考慮できないことである。この問題に対処するため、本研究では encoder-decoder モデルを用いることでより適切に学習パスを予測する手法を提案する。これにより、生徒は eラーニングシステムにおいてより良い学習効果を得られるような問題を選択できるようになることが期待される。

1. はじめに

近年、教育の分野における eラーニングの普及が急速に進んでおり、特にオンライン学習サービスや massive open online courses (MOOCs) は広く使われるようになってきている。生徒の成績を伸ばすためには、eラーニングにおける推薦アルゴリズムは非常に重要であり、研究が盛んに行われている。

日本では、教育の現場では公的な制度の整備に先んじて、Z会^{*1}やスタディプラス^{*2}のように、学習塾や企業が eラーニングシステムを導入するケースが見られる。

本研究では eラーニングの学習ログに対して、機械学習などの手法を適用し、新たな推薦システムの構築を行う。現在、eラーニングの学習ログを用いて問題を推薦するシステムとして、Knowledge Tracing (KT) が一般的に使用されている。KT は学習者の時間経過を伴った知識状態をモデリングするタスクである。これによって、将来学習者がどのように応答するのかを予測する。このタスクの精度を向上させることで、個人のニーズに見合った問題を提示し、簡単すぎたり難しすぎる問題を避けることができるよ

うになる。

特に KT に対して、Piech らは深層学習を用いた手法として Deep Knowledge Tracing (DKT) を提案している [1]。これは RNN を用いることで、ドメイン知識を手動で入れることなしでも複雑な知識構造を獲得できるようになっている。評価実験では複数のデータセットに対し、従来のモデルより卓越した結果が得られることが示されている。また、学習されたモデルを知的カリキュラム設計に利用して、問題の解釈と構造発見に活用できる。

DKT は広く使われるようになってきているが、複数の問題点が指摘されている。その一つとして、DKT の使用している損失関数では過去の実際の学習結果が必ずしも再現できないことが挙げられる。問題を解くことのできる潜在能力を表すスキル A とスキル B があったとして、スキル A を持つ問題を正解した後にスキル B を解いた場合、すでに知識状態が遷移してしまっている一方、既存の DKT の最適化器は直後の問題だけに最適化されるため、すでに解いたスキル A で問題が解かれる場合、正解率が下がってしまう可能性がある。

従来の手法では直後の時点における知識状態しか分からないが、生徒が今後どのような学習を経ていくかは予測できなかった。我々の提案手法では sequence-to-sequence のモデル構造を新たに導入することで、生徒が今後到達するであろう知識状態、未来の学習パスを予測することのできるモデル構築を試みる。

¹ 筑波大学

University of Tsukuba

a) qiugits@klis.tsukuba.ac.jp

b) tomihira@klis.tsukuba.ac.jp

c) tezuka@slis.tsukuba.ac.jp

*1 <https://www.zkai.co.jp/home/z-asteria/>

*2 <https://weblab.t.u-tokyo.ac.jp/project/スタディプラス>

今まではスキルを与えたときに適切かどうかの判断しかできなかったために、モデルを運用するにあたって複数回モデルにスキルを入れて適切かどうか判断する必要があった。未来の学習パスが分かることで、一回の予測で最も適切なスキルを推薦することができる。

また未来の学習パスが前もって予測できることで、eラーニングにおいて生徒の解くべき問題の道しるべとするなどの応用が期待できる。他にも、入力も sequence になるために、入力データを人間の忘却曲線に合わせて加工することで、時間の経過と共に生じる忘却を考慮した予測モデルも構築することができる。

本論文では、従来の DKT モデルを改良した、新しい encoder-decoder のモデルを使用した DKT モデルを提案し、Piech ら [1] の研究と同じ ASSESTments データセットで実験することで、既存手法のスコアに匹敵するモデルであることを示す。さらに提案した encoder-decoder のモデルと従来手法で問題点が解決されているかという点について考察する。

2. 関連研究

2.1 従来の Knowledge Tracing モデル

多くの研究者によって、問題によって身につけられるスキルを考慮することが Knowledge Tracing において重要な要素となることが指摘されてきた [2], [3], [4], [5]. Corbett らは Bayesian ネットワークを用いたモデルである BKT (Bayesian knowledge tracing) を機械的にコントロールされた Knowledge Tracing モデルとして提案した [6]. このモデルは学習過程において学習者間での相違を考慮に入れることができる。

Wilson らは Hierarchical IRT (HIRT) と Temporal IRT (TIRT) が深層学習を用いたモデルよりも学習者のパフォーマンスを予測するときにより良い結果をもたらすことを示したが、コンテキスト情報を適切に設定する必要があった [7].

2.2 Deep Knowledge Tracing

Piech らは Knowledge Tracing のための DKT モデルを提唱した [1]. ドメイン知識を有した専門家によるラベリングに依らなくても、それまでの BKT を含む KT モデルより高い精度を達成した。さらに、DKT モデルのパフォーマンスを改善しようと追加研究がなされてきた [7], [8], [9], [10], [11].

2.3 Deep Knowledge Tracing の限界

Yeung らは DKT における 2 つの問題点として、再構成問題 (*reconstruction problem*) と遷移振動問題 (*wavy transition problem*) を指摘した [12]. 学生がスキル A を必要とする問題に時刻 t で答えたとする、DKT は時刻




図 1: An encoder-decoder architecture for Knowledge Tracing

$t + 1$ で答えることになるスキル B の問題の正解率を学習することになるが、スキル A に対する学生のパフォーマンスを学習するわけではない。さらに、DKT では予測された正解率が時刻によってブレるように変化する。時刻 t で回答された問題のスキルと異なるスキルに対する予測値まで大きく変化してしまう。このような特徴は、学習者の能力は徐々に変化するのであって頻繁に大きくブレるはずではないという直感に反しており、理想的ではない。Yeung らはこの問題点に対し、正則化項と振動尺度を用いることを提唱している。

本研究では新たに encoder-decoder モデルによる DKT (EDDKT) を提案することで、Yeung らと異なるアプローチで DKT の問題点に対処する。

3. 手法

3.1 Encoder-decoder アプローチ

本論文では encoder-decoder 構造をもつ新たなモデルを提案し、これを EDDKT (encoder-decoder Deep Knowledge Tracing) と名付ける。このモデルはシーケンス処理で広く用いられる sequence-to-sequence ニューラルネットワークのアーキテクチャに触発されている [13], [14]. そのようなアーキテクチャを用いる一つのメリットは、既存のモデルよりも出力結果における表現力が高いことである。

デコーダは生成モデルであり、学習者の未来の knowledge path を予測することに用いることもできる。

KT のタスクは、学習者の一連の学習行動の記録を x_0, \dots, x_t とするとき、次の行動 x_{t+1} を予測するものである [6]. 行動は解いた問題 q_t とその正誤情報 a_t を並べたタプル $x_t = \{q_t, a_t\}$ として表現される。私たちが提案する EDDKT モデルでは、 x_1, \dots, x_{t-1} までの学習ログを、学習データのソースシーケンス X_{src} として、エンコーダに学習させる。その結果エンコーダの隠れ層の出力から encoded vector を獲得する。時刻 t における学習ログをターゲットシーケンス y として、encoded vector と合わせて、デコーダに渡し、時刻 $t + 1$ の正解確率を予測する。 $\delta(q_{t+1})$ は $t + 1$ 時点で回答される問題番号を one-hot エンコーディングしたものとする。損失関数は $l(y^T \delta(q_{t+1}), a_{t+1})$ によって、予測される y の問題 q_{t+1} についての予測正解率と実際の正誤データ a_{t+1} との損失を計算した。

モデルの具体的な構成は図 1 に示した。まず、エンコー

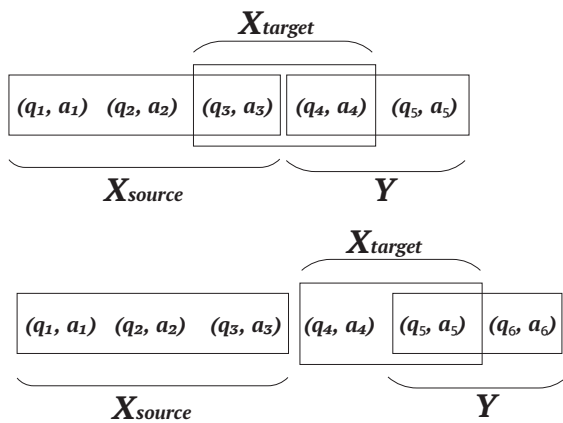


図 2: Input and output examples

ダは、インデックスを受け取り、embedding を行う。この入力のインデックスは、ユーザがそのタイムステップで、「どの問題を正解あるいは不正解したか」という情報を持っている。スキル数を M とすると、 $\{1, 0\}^{2M}$ の one-hot ベクトルとして表現できる。本論文では embedding を行い、 $\log(2M)$ 次元の潜在表現に圧縮する。これによりスキル数が増えた場合、高次元のスパースなベクトルとなることを防ぐことができる。これは Piech らによる compressive sensing を用いたことに相当する。最後に、embed 済みのものを、LSTM に渡し、LSTM の hidden cell を出力する。エンコーダから出力されたこの隠れ層の情報は context vector である。

次に、デコーダモデルの定義を行う。デコーダは入力 X_{trg} を受けると、embedding を行い、dropout を適用したものと掛け合わせ、予測結果 y を出力する。予測時には出力の際に linear レイヤーを通す、すなわち線形変換を行うことで次元を調整する。

encoder-decoder 構造を採用したことによる利点として、より柔軟な入力長・出力長に対応できることが挙げられる。実際、予測結果 y を使って繰り返しさらなる予測を行うことで、knowledge path の未来予測ができる応用が可能となる。また、過去方向に学習を拡張させることで、Yeung らの提案におけるよう、時刻 $t+1$ と t を学習対象としたのと同様な拡張を過去方向にも任意の長さについて行える。

また、knowledge path を予測できるようになることの好ましい点は e ラーニングへのさらに実用的な活用が可能になることである。例えば knowledge path を予測することで学習計画の提案が行える。生徒にいくつかの効果が高い学習計画をサジェストし、選択してもらうというような応用が考えられる。

3.2 最適化器

損失関数は比較のため、以下に示す Piech らと同じ損失関数を用いて学習し、結果を評価した。

$$L = \sum_t l(y^T \delta(q_{t+1}), a_{t+1}) \quad (1)$$

結果の項目で後述するが、比較を通して我々の提案手法が同等以上の性能を持つことが示せた。

4. 実験

4.1 データセット

本研究では Khan Academy が公開している ASSISTments 2009-2010 のデータセット*3を使用する。このデータセットは ASSISTments オンライン学習プラットフォームで収集された学習ログである。このプラットフォームは一般に公開されており、教師が学習者に課題を与えるのに使用できる。2018 年までに 14 カ国を超える 600 人以上の教師に使用されている。データセットは 4,417 名の生徒が 328,291 個の問題に回答する記録を含んでおり、それぞれの問題について回答の正誤情報が付けられている。さらに、問題はスキルでタグ付けされている。スキルは 124 種類あり、学習者が特定のスキルの問題を解決する能力を表している。

4.2 ベースライン

本研究では Piech らの DKT モデル [1] を再現実装しベースラインとした。ハイパーパラメータは Piech らの論文 [1] に基づき、シーケンスサイズは 30、学習率は 0.01、バッチサイズは 100、隠れ層の数は 2、隠れ層 1 層あたりのノード数を 200 に設定した。

ベースラインの実験結果における AUC は 0.789 となった。Piech らは RNN/LSTM としてモデルを提案したが、再現実験の結果がわずかに良い LSTM の実装を採用した。

4.3 実験結果

通常の EDDKT では、1,000 エポック学習させたところ、200 エポック付近で AUC が最大値となり、テスト損失が上昇をやめて訓練損失から乖離し始めた。結果の AUC は 81.3 程度だった。

また、EDDKT は未来方向に拡張することが容易なので、時刻 t を増やす方向に対して実験を行った。

結果的に、再現実験したベースラインに対して 2 ポイント高いスコアを達成し、既存モデルに匹敵する、あるいはより良い結果となった。

図 2 のヒートマップは、学習者の正答確率によって予測される知識状態が時刻に伴って変化する様子を表したものである。この図が示すように、RNN/LSTM ベースの DKT では、時刻によって学習者の予測正解率が劇的に変化している。また、複数の時点で大半のスキルの予測正答率が同時に大きく変化している。学習者の知識状態は、あるスキルに対して理解と無理解の間を頻繁に変化させるの

*3 ASSISTment[15] <http://www.aboutus.assistments.org/>




図 3: 生徒一人の学習ログに対する予測正解率を表したヒートマップ。縦軸はスキル、横軸はタイムステップ。(a) は LSTM モデル、(b) は EDDKT の結果。

ではなくて、学習に伴って徐々に成長・変化するものであるから、このような予測結果は理想的とは言えない。一方、EDDKT モデルによる出力結果は、徐々に変化していることがヒートマップのグラデーションとして現れている。さらに、大半のスキルの予測正答率が同時に大きく変化するようなことがほとんどない。総じて、RNN/LSTM ベースの DKT よりも緩やかな変化が観察される。

5. 考察

RNN/LSTM は時系列予測であるため、直前のセル・シーケンスの結果を強く影響を受けてしまう。また、それより前の状態が反映されづらい。それによって再構成問題や遷移振動問題が発生したと考えられる。

一方、EDDKT ではエンコーダから潜在ベクトルに変換することを通して直前までのセル・シーケンスを一度抽象化している。そのためデコーダで予測を行う際、予測結果の直前のセル・シーケンスの影響が緩和され、平滑化されたことで遷移振動問題が緩和されたと考えられる。

6. まとめ

本論文では、既存の DKT 手法がもつ問題点を再確認し、それらを解決するための新しい encoder-decoder モデルを提案した。このモデルは従来の DKT モデルよりも柔軟性と表現力において優れており、従来のモデルに匹敵するか、より高いスコアを出した。また、encoder-decoder は生成モデルであるために、従来の手法では直後の時刻しか求めることができなかったのに対して、数ステップ先の未来まで予測できるという強みがある。未来の knowledge path を予測することは、e ラーニングにおいて目標を定めることができるようになるなどの応用が考えられる。

以上から、提案手法が既存の遷移振動問題を解決するこ

とや、将来の学習を予測する際にも有効であることを述べた。これらの利点から、e ラーニングモデルへの応用により適したモデルとなることが期待される。

参考文献

- [1] 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*, pp. 505–513 (2015).
- [2] Resnick, L. B. and Resnick, D. P.: Assessing the thinking curriculum: New tools for educational reform, *Changing Assessments*, Springer, pp. 37–75 (1992).
- [3] Shepard, L. A.: Psychometricians' beliefs about learning, *Educational Researcher*, Vol. 20, No. 7, pp. 2–16 (1991).
- [4] Ritter, S., Harris, T. K., Nixon, T., Dickison, D., Murray, R. C. and Towle, B.: Reducing the Knowledge Tracing Space., *International Working Group on Educational Data Mining* (2009).
- [5] Cen, H., Koedinger, K. and Junker, B.: Learning factors analysis—a general method for cognitive model evaluation and improvement, *International Conference on Intelligent Tutoring Systems*, Springer, pp. 164–175 (2006).
- [6] 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).
- [7] Wilson, K. H., Karklin, Y., Han, B. and Ekanadham, C.: Back to the basics: Bayesian extensions of IRT outperform neural networks for proficiency estimation, *arXiv preprint arXiv:1604.02336* (2016).
- [8] Khajah, M., Lindsey, R. V. and Mozer, M. C.: How deep is knowledge tracing?, *arXiv preprint arXiv:1604.02416* (2016).
- [9] Sapountzi, A., Bhulai, S., Cornelisz, I., van Klaveren, C., Kardaras, D. and Semanjski, I.: Dynamic Models for Knowledge Tracing & Prediction of Future Performance, *Proceedings of the Seventh International Conference on Data Analytics* (2018).
- [10] Xiong, X., Zhao, S., Van Inwegen, E. G. and Beck, J. E.: Going Deeper with Deep Knowledge Tracing., *International Educational Data Mining Society* (2016).
- [11] Yang, T.-Y., Brinton, C. G., Joe-Wong, C. and Chiang, M.: Behavior-Based Grade Prediction for MOOCs Via Time Series Neural Networks, *IEEE Journal of Selected Topics in Signal Processing*, Vol. 11, No. 5 (online), DOI: 10.1109/JSTSP.2017.2700227 (2017).
- [12] Yeung, C.-K. and Yeung, D.-Y.: Addressing two problems in deep knowledge tracing via prediction-consistent regularization, *arXiv preprint arXiv:1806.02180* (2018).
- [13] 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).
- [14] Sutskever, I., Vinyals, O. and Le, Q. V.: Sequence learning with neural networks, *Advances in Neural Information Processing Systems*, pp. 3104–3112 (2014).
- [15] Feng, M., Heffernan, N. and Koedinger, K.: Addressing the assessment challenge with an online system that tutors as it assesses, *User Modeling and User-Adapted Interaction*, Vol. 19, No. 3, pp. 243–266 (2009).