

「Knowledge Tracingの英単語学習への導入は可能か？」

～機械学習を用いた個人最適化による学習効率化を目指して～

熊本県立宇土高校2年 吉野泰生

①. 背景・目的

1. 本研究の概要

●内容

●機械学習の技術を使って英単語学習をより効率的にする。

●英単語学習に注目した理由


・自分自身、**多くの時間**を英単語学習に使ってきた。 → **学習の効率化はきっと多くの学生に需要がある。**

●どうやって実現するか？

・**Knowledge Tracing**という機械学習の技術を利用する。

2. Deep knowledge tracing とは

●RNN



問題(x_t)における生徒の理解度(y_t)を予測する。 → **生徒が解けない問題の予測。最適な学習パスを見つけ出す。**

3. 先行研究

●先行研究①：“Deep Knowledge Tracing”

Khan Academyという世界的に利用されているe-Learningサービスに蓄積された学習ログをもとに、生徒の理解度の予測を行う。

●先行研究②：“スタディサプリと東大松尾研究室の共同研究”

スタディサプリに蓄積された学習ログをもとに深層学習を行い、生徒が次に解く問題の正誤を予測。

先行研究の多くが**数学**の学習ログを使用してきた。 → **本研究では、英単語学習に導入したい。**

4. 研究の目的と流れ

●目的

・英単語学習の学習ログを使用して**Deep Knowledge Tracing**を行い、先行研究(数学の学習ログ)のモデルとの**精度の比較**を行う。


●研究の流れ

- ①独自の英単語アンケートを作成し、データセットを作る。
- ②データ分析、データ比較(先行研究と本研究)。
- ③DKTに導入する。
- ④先行研究のモデルとの精度を比較する。

④. 結果・考察

7. データ分析

●英単語クイズ スコアの分布



●誤答率と正誤の関係
ある特定の生徒Aの「回答の正誤(0, 1) (縦軸)」と「その問題の誤答率(横軸)」の関係を表す。
問題の誤答率だけによる予測は難しく、**個人最適化が必要だと分かる。**


●先行研究との比較

| 種類 | 数学の問題 (skill_id) | 英単語 |
|--------|------------------|-------|
| 問題数 | 124 | 100 |
| 生徒数 | 3373 | 46 |
| データ数 | 262652 | 4600 |
| ユニーク問題 | 33844 | 4600 |
| 回答数 | | |
| 平均正答率 | 0.655 | 0.731 |

※ユニーク問題回答数は、データ数から同じ学習者が同じ問題を複数回解いた回数を除いた回数。

8. 結果の比較

●先行研究との比較



・先行研究と比較すると精度は劣るが、**エポック数を増やすことにAUCが向上することが確認できた。**
・**英単語学習にもDKTが導入できる可能性が示唆される。**しかし、より多くのデータでの検証が必要。

②. 方法

5. データセット

●英単語クイズを実施

英単語学習については**オープンデータがない**ので、独自にアンケートを実施し、データセットを作成した。

<アンケート>

形式: Googleフォームを利用した4択クイズ、匿名で収集
対象: **高校1年生～3年生 全46名**
問題: 旺文社 ターゲット1900より参照
データ: 各100問 **計4600問**



6. 手法

●Deep Knowledge Tracingを用いた学習と予測

①学習データとテストデータに分割

●オリジナル(46名分) → ●学習データ (30名分)
●テストデータ (16名分)

②学習データに学ばせた後に、**テストデータで精度(AUC)**を確認。(モデルは 参考[1]を利用する。)

データが少ないため、学習データとテストデータをランダムに選び直し、①、②を3回繰り返して**再現性**を担保する。

③先行研究(数学)の結果と比較する。

参考[1] <https://github.com/ckyeungc/deep-knowledge-tracing-plus>

⑤. 追加実験

11. Word Embedding

●Word Embedding とは。

Word Embeddingによる単語の多次元評価

| | Man | Woman | King | Queen |
|--------|-------|-------|-------|-------|
| Gender | -1.00 | 1.00 | -0.95 | 0.97 |
| Royal | 0.01 | 0.02 | 0.93 | 0.95 |
| Age | 0.03 | 0.02 | 0.70 | 0.69 |
| Ethnic | 0.09 | 0.01 | 0.02 | 0.01 |

自然言語処理の分野で用いられる手法で、英単語を**多次元ベクトル**で表現する。

大量のコーパスを学ばせることによって単語の持つ**意味を相対的に定義**する。

【図4 Word Embedding[6,7]】

似た意味を持つ単語の周辺には同じ単語が使われるという仮説をもとに学習が行われる。

人間が与えるラベル情報よりも、**合理的な情報抽出**ができる可能性がある。

12. 仮説

●近いベクトルの単語は「共に」覚えているor覚えていない。

例 学習者が「success」という単語に正当した場合、「successful」という単語を知っている可能性が高いという予測ができる。


to [521]: word_vectors.closest_similar(success)
Out[521]: [successful, 0.761286463737488, ← successに最も近い上位5つの単語。
[successful, 0.7578884011295776],
[winning, 0.6449779933013916],
[thanks, 0.6398561596879422].

一般的には、word embeddingの意味の近さを表すために使用。 → 学習のさせ方から考えて、意味以外にも抽出しているのでは？ (ex. 単語の品詞や頻度など。)

Word Embeddingを用いることで、**単語が持っている様々な特徴量を多次元的に抽出**できるのではないかと。

13. 検証

●”Word Embeddingの類似性を表すグラフ(左)”と”誤答の回答の関係を表すグラフ(右)”の比較。



↑ word_vectors.similarity(単語A, 単語B) を全て計算しベクトルの類似性が0.5以上のものを表示 (※ノードは単語の問題番号を表す。)

正当→1, 誤答→0とする。
同一回答者の(単語A, 単語B)の回答が
①(0, 0)のとき、単語A, Bに関係があると見なす。
②(1, 0) or (0, 1)のとき、関係がないと見なす。
→ 確率((①)/(①+②))を計算し、0.5以上を表示。

14. 考察

●Word EmbeddingをKnowledge Tracingに活用できるか？

・左図のno.9周辺で見られた、Word Embeddingのベクトルの類似性は、実際の誤答の関係を表す右図では**全く確認できなかった。**

・学習済みベクトルをそのまま値で導入することは難しい。値の閾値を大きくするか、Word Embeddingの手法自体を改善する必要がある。

・派生語などの予測をword embeddingで行う場合は、図3のような0.5以上ではなく、より高い数値(約0.7以上)で行う必要があると考える。

⑥. 結論・展望

15. 結論と展望

●結論

・英単語学習の学習ログをDKTに導入したところ、先行研究(数学)よりデータが少なく劣るものの、**英単語学習にも応用できる可能性が示唆された。**
・word embeddingについては、単純にそれを特徴量として用いることは難しく、導入するには**モデルを改善**などの工夫が必要である。しかし、これが可能になると、**面倒なラベリング**などが自動化できるので**他分野の単語学習にも広く応用**が期待できる。

●最終的な活用方法

- ・個人に最適化された**英単語帳**の作成。(順番や内容)
- ・学習者が**苦手な単語**の予測。
- ・**他分野の単語学習**への応用の可能性を示唆。

16. 謝辞・参考文献

本研究を行うにあたって、本校 梶尾浩宏先生にご指導いただきました。また、英単語学習アンケートでは46名の方に協力いただきました。感謝申し上げます。

- [1] <https://github.com/ckyeungc/deep-knowledge-tracing-plus>
- [2] Chris Piech, Jonathan Bassen, Jonathan Huang, Surya Ganguli, Mehran Sahami, Leonidas Guibas, Jascha Sothi-Dicksteiny, Deep Knowledge Tracing
- [3] Toiga Bobulovskii, Kai-Wai Chang, James Zou, Venkatesh Saligrama, Adam Kalai. Man is to Computer Programmer as Woman is to Homemaker? Debiasing Word Embedding
- [4] Tomas Mikolov, Kai Chen, Greg Corrado, Jeffrey Dean. Efficient Estimation of Word Representations in Vector Space.
- [5] GENSIM ホームページ <https://radimrehurek.com/gensim/index.html>
- [6] Andrew Ng, Coursera: Deep Learning specialization. <https://www.coursera.org/specializations/deep-learning>
- [7] Andrew Ng, Coursera: Machine learning. <https://www.coursera.org/learn/machine-learning>
- [8] 関東大学校尾研究室A-BAIA-リクルートマーケティングパートナーズ 共同研究、学習者の「解けない問題」の予測に成功「つまずき学習」の実現。
- [9] 旺文社、英単語ターゲット1800 総記サイトブック