

1. はじめに

教材のデジタル化によって、学生の電子教材に対する操作ログや成績に関するデータの収集が可能となった。これらのデータを分析することで退学リスクのある学生の早期発見や、学生一人一人の学習状況に合わせたサポートの提供が期待されている。そのため、機械学習モデルを用いた成績予測に関する研究が活発に行われている。

従来手法 [1, 2] では、一つのトークンに複数回の行動がまとめられている。そのため、短い時間単位での操作パターンを捉えることができない。そこで、本研究では、操作同士の関連性を考慮することで成績予測精度の向上を図る。具体的には、1回の操作ログを1つのトークンとして Transformer に入力して成績を予測する。

2. 先行研究

従来の成績予測手法 [1] では、Attention ベースの機械学習モデルである Transformer[3] により成績予測を行う。教材単位でのヒストグラムや一定時間で疑似単語化した学習行動の埋め込み特徴を入力とするため、1トークンに複数回の行動が含まれている。そのため、一連の行動の中に含まれる成績予測に重要な操作パターンを十分に考慮されないという問題がある。

3. 提案手法

本研究では、1回の操作ログを1つのトークンとして扱う。これにより、操作同士の関係性を考慮し、一連の行動の中に含まれる成績予測に重要な操作パターンを考慮することで成績予測精度の向上を図る。

提案手法の流れを図 1 に示す。図中の Open, Close, Next, Prev は教材を開く・閉じる、ページを進む・戻るといった学生が行った操作を表す。1回の操作を1トークンとして扱う場合、操作回数そのままトークン長となる。そのため、トークン長が長くなり、計算コストが膨大になる。そこで、本手法では入力するトークンを分割して計算を行う。まず、入力の前処理として各学生の操作ログを長さ 256 トークンのトークンシーケンスに分割する。分割の際は 128 トークンずつずらしながら行う。得られた n 個のトークンシーケンスを Transformer に入力する。トークンシーケンスの数 n は各学生の操作回数に依存するため、学生により異なる。また、Positional Encoding は分割前の位置情報を加える。Transformer で獲得した n 個の特徴ベクトルの平均を求め、MLP Head に入力し、A,B,C,D,F の5クラスの成績の予測を行う。実際の学生の成績を教師データとし、予測した確率分布とのクロスエントロピー誤差を計算することで Transformer と MLP Head を学習する。

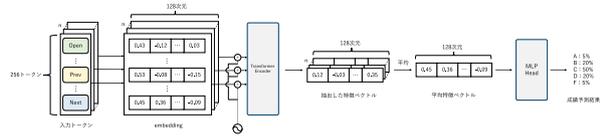


図 1: 提案手法

4. 評価実験

提案手法による有効性を評価する。従来手法である操作回数ヒストグラム特徴を入力とする手法と fastText を用いた埋め込み特徴を入力とする手法との比較を行う。

4.1. 実験条件

提案手法のモデルには Transformer Encoder を使用し、入力サイズは 256 トークン、トークンの埋め込みベクトルの次元数は 128、ブロック数は 2、head 数は 4、学習率は $5e-6$ 、更新バッチサイズは 32、エポック数は 100、損失関数は訓練データの各成績の人数の逆数を重みとする Weighted Cross Entropy でモデルを学習する。学習は 10 回行い、各モデルの平均精度を評価する。評価指標には、

Accuracy, Macro-F1 スコア、隣り合う成績の差を 1 とした Root Mean Square Error (RMSE) の平均と標準偏差を用いる。

4.2. 定量的評価

表 1 に、従来手法と提案手法による成績予測精度を示す。表 1 より、提案手法は従来手法と比べて 3 つの評価指標において成績予測精度が向上した。

表 1: 従来手法との成績予測精度比較

| | Accuracy(↑) | F1 Score(↑) | RMSE(↓) |
|-------------|----------------------|----------------------|----------------------|
| ヒストグラム [1] | 48.42% ± 1.53 | 46.58% ± 2.34 | 1.048 ± 0.040 |
| fastText[2] | 48.06% ± 1.37 | 44.29% ± 2.11 | 0.962 ± 0.028 |
| 提案手法 | 55.60% ± 0.74 | 57.12% ± 0.57 | 0.725 ± 0.028 |

提案手法と従来手法の混同行列を図 2 に示す。図 2 より、従来手法と比較して成績 B を除く全ての成績での予測精度が向上した。また、従来手法では成績 F の学生に対して成績 A と予測していた割合がヒストグラム, fastText でそれぞれ 47.83pt, 19.05pt であったが、提案手法では 4.35pt となり、成績予測の大きなずれを減少させることができた。

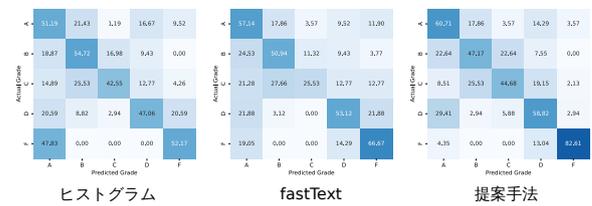


図 2: 評価データにおける混同行列

4.3. 定性的評価

評価データに対して Transformer が出力した 128 次元の特徴ベクトルを UMAP を用いて可視化した結果を図 3 に示す。ここで、1つの点は一人の学生の特徴ベクトル、×印は各成績における学生特徴の重心を表す。図 3 より提案手法は成績 B と C の重心が近いことが確認できる。また、成績 F の学生特徴は他の成績と比べ、重心が離れていることが確認できる。これより、特徴空間での距離が成績予測精度に影響していることが分かった。

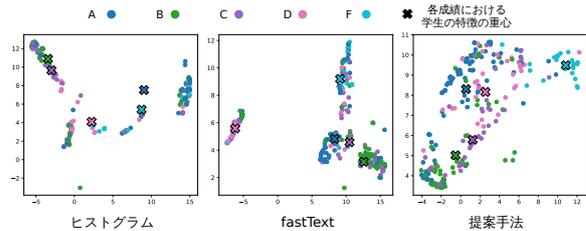


図 3: Transformer の出力の可視化

5. おわりに

本研究では、学習時の操作情報の関連性を考慮した Transformer による成績予測手法を提案した。評価実験では、提案手法が従来手法に比べ、3 つの評価指標において成績予測精度が向上したことを確認した。今後は、一定時間操作しないという行動を追加し、時間情報を加えることによる成績予測の精度向上を図る。

参考文献

[1] H.Kohama, et al., "Recommending Learning Actions Using Neural Network", ICCE, 2023.
 [2] Y. Miyazaki, et al., "E2Vec: Feature Embedding with Temporal Information for Analyzing Student Actions in E-Book Systems", EDM, 2024
 [3] A.Vaswani et al., "Attention is all you need", NIPS, 2017.