

デジタル教科書の学習活動ログを利用した教材難易度分析

†椎野徹也, †島田敬士, †峰松翼, *畑埜晃平, *木實新一, †谷口倫一郎

†九州大学 工学部 電気情報工学科 †九州大学システム情報科学研究院 *九州大学 基幹教育院

1. はじめに

近年, 学習活動データを収集し, その分析結果を活用して学習・教育の改善を行うラーニングアナリティクスに注目が集まっている. 例えば講義中の電子教材操作ログのリアルタイム分析を行えば, その結果を踏まえ学生の学習状況を把握した柔軟な講義進行を行える. また[1]では学生の電子教材閲覧パターンと成績の関係性に着目した研究を行うなど, 収集したデータを用いたパターンマイニングなども行われている.

本研究では, 講義における電子教材操作ログを使用し, 電子教材のページ毎の難易度に着目した分析を行った. 具体的には, 操作ログから電子教材の閲覧状況を数値化した特徴量を計算し, 特徴量と難易度の関係を機械学習によりモデル化する方法を検討した. 以降では, 具体的な処理の流れと実験結果について述べる.

2. 電子教材システム

本研究では M2B 学習支援システム (詳細は[2]を参照) 内の電子教材システム「BookRoll」を利用して, 電子教材を利用した学習活動ログを収集した. BookRoll 上で学生が電子教材の操作を行うと, その度にユーザーID, 講義資料のID, ページ番号, 操作の種類, その時刻などが操作ログとして自動的に記録・蓄積される. 操作の種類には例えば教材を開いたことを示す「OPEN」, 次のページへ進むクリック動作を示す「NEXT」, 前のページへ戻るクリック動作を示す「PREVIOUS」など様々な種類がある.

3. 提案手法

本研究は電子教材のページ毎の難易度を自動推定することが目的である. 難易度推定は, 電子教材の操作ログからページ毎の特徴量を計算し, 難易度のラベルを付けて教師あり学習をさせることで難易度の推定モデルを作成し, そのモデルにより難易度が未知のページに対して難易度

の推定という流れで行われる. 以下にその手法の詳細を示す.

3.1. データセット

本実験のデータセットには 90 分間で行われる講義中に BookRoll で収集されたログデータを用い, 授業外のログについては分析対象から除外した. 対象とした講義は, 7 コース各 2 回の計 14 回分のログを利用した. 講義資料は 5 種類あり, 各講義ではそれらのうち 4 つの資料が各回 2 つずつ使われた. 最終的に実験に利用したログデータは 456 名の学生から集めた合計 110, 894 件であった.

またこれとは別に, 本実験で用いた 5 つの講義資料の各ページについて 15 人の学生に対しての 5 段階評価 (1: 易しい, 5: 難しい) でアンケートを行い, こちらは分類モデル作成の教師データとして利用した.

3.2. 分類モデルの作成

3.2.1. 特徴量の算出

図 1 は講義の時間を 1 分毎に区切り, 各時刻でのページ閲覧数をヒートマップ形式で表現したものである. 特徴量の算出方法の例として図 1 を用いて 13 ページにおける例を示す. まず各ページが最も多く閲覧された時刻を t とした. 13 ページが最も多く閲覧されたのは授業開始後 8 分台であり $t = 8$ となる. そしてこの時刻 t を基準として次の 3 つの特徴量を計算した.

1. 時刻 t にそのページを閲覧していた人数
2. 時刻 t よりも前の時刻にそのページを閲覧していた人数の合計
3. 時刻 t よりも後の時刻にそのページを閲覧していた人数の合計

さらに, 操作ログより以下の 3 つの特徴量もページ毎に算出した.

4. 「NEXT」操作によってそのページにアクセスされた回数
5. 「PREVIOUS」操作によってそのページにアクセスされた回数
6. 生徒全員によるページの総閲覧時間

従って, 各ページに対してそれぞれ上記の 6 次元特徴ベクトルを生成したことになる. なお, 各講義の受講人数にばらつきがあるので, その影響を抑えるために実際には上記特徴量をすべ

Page-wise Difficulty Level Estimation using e-Book Operation Logs

†Department of Electrical Engineering and Computer Science, School of Engineering, Kyushu University

‡Graduate School of Information Science and Electrical Engineering, Kyushu University

* Faculty of Arts and Science, Kyushu University

て受講人数で割ったものを利用した。

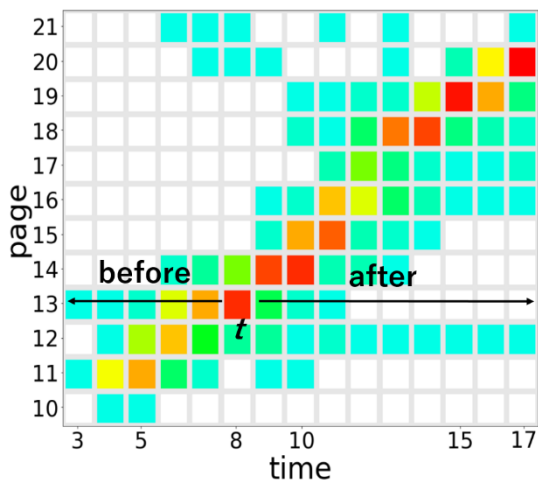


図 1: 1 分当たりのページ閲覧者数. 赤色に近いほど閲覧人数が多く、青に近いほど閲覧人数が少ないことを示す

3.2.2. 正解ラベルの設定

教師あり学習を行つたために難易度の正解ラベルが必要となる。本実験においては各ページのラベルを「難しい」か「難しくない」かのどちらかに設定することによって 2 値分類問題にするというアプローチをとった。そしてこの正解ラベルは、3.1 で述べた 15 人による 5 段階評価のアンケート元で作成した。具体的な手法は以下の通りである。

1. 15 人のアンケート結果から一人分を選択
2. 例えば難易度が [1P→5, 2P→1, 3P→2] のとき [1P>2P], [1P>3P], [3P>2P] のように難易度の大小関係比較を、全ページの組み合わせに対して行った。n ページの講義資料の場合、合計 nC_2 回の比較を行った。
3. 2 の操作を 15 人分に対して行った。
4. 15 人分の比較結果を集計し、不等号 (>) の左側、つまり相対的に他のページよりも難しかった割合が 0.7 以上のページを「難しい」、その他のページを「難しくない」と定義した。

3.2.3. 学習手法

3.2.1 と 3.2.2 により、全 921 ページのサンプルに対して 6 次元の特徴ベクトルとそれに対応するラベル(難しいか否か)が生成された。そのデータをランダムフォレスト [3] を用いて教師あり学習させて分類モデルの作成を行った。

4. 実験結果

表 1 は「難しい」185 サンプル、「難しくない」736 サンプルの計 921 サンプルから生成した分類

モデル対し、10 分割の交差確認法による検証結果である。不均衡データのため指標には precision と recall を用いた。ここで教員へのフィードバックという点を考慮すると、学生が難しいと感じるページの特定率が高い方が望ましい。表 1 の「難しい」ページに関する precision と recall はそれぞれ 0.430 と 0.454 と共に 4 割半ばの精度であった。精度としては改善の余地が残る結果であるが、サンプル数の割合を考慮してランダムに難易度を推定する場合のいわゆるチャンスレート (約 20%程度) よりは良い結果が得られた。

表 1: 交差確認の結果

	Precision	Recall	サンプル数
難しい	0.430	0.454	185
難しくない	0.861	0.849	736

5. おわりに

本研究では電子教材システムのログを利用して電子教材の難易度推定をする方法を検討し、その実験結果について報告した。本実験の手法では、難易度を推定においてある程度の精度を得ることができたが、教員へのフィードバックで講義の改善を図ることができる推定レベルには達していない。よって今後はより良いモデルを作成するために、特徴量抽出の戦略を改善し、より効果的な特徴量をログから抽出する必要がある。また、難易度の正解ラベルに関してもアンケート人数が 15 人と少ないこともあり、今後は教師あり学習に用いるラベルそのものの信頼性も高めていく必要がある。

参考文献

- [1] Shimada, A., Okubo, F., & Ogata, H. (2016). Browsing-Pattern Mining from e-Book Logs with Non-negative Matrix Factorization. In EDM (pp. 636-637).
- [2] Ogata, H., Taniguchi, Y., Suehiro, D., Shimada, A., Oi, M., Okubo, F., ... & Kojima, K. (2017). M2B System: A Digital Learning Platform for Traditional Classrooms in University. Practitioner Track Proceedings.
- [3] Ho, T. K. (1995, August). Random decision forests. In Document analysis and recognition, 1995., proceedings of the third international conference on (Vol. 1, pp. 278-282). IEEE.