

# デジタル教材の学習ログと成績の関連分析

椎野 徹也<sup>1,a)</sup> 峰松 翼<sup>2,b)</sup> 島田 敬士<sup>2,c)</sup> 谷口 倫一郎<sup>2,d)</sup>

**概要：**現在、九州大学や京都大学など複数の大学では、デジタル教材配信システムによって提供される教材を用いた講義が行われている。学生がデジタル教材を利用する際、その閲覧操作状況は自動的に学習ログとして記録される。この学習ログの分析によって得られる有用なフィードバックはエビデンスに基づく教育を実現するために期待されている。そこで本研究では学習ログ分析の一つとして、収集された学習ログと学生の成績との関連性に着目した調査を行った。どのような学習行動が成績状況と結びついているかを理解するのは学生をサポートする手がかりを得る上で重要であると考えられる。本稿ではまず分析手法の提案を行い、その後実験によって明らかになった学生の成績と学習ログの関係性に関して議論を行う。

**キーワード：**デジタル教材, BookRoll, 学習ログ, LRP, ニューラルネットワーク

## 1. はじめに

近年、学習活動に関係するデータを収集・分析し、その分析結果をフィードバックすることで学習・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 [1]。収集可能な教育データの一つに M2B システム [2] におけるデジタル教材配信システム利用時の学習ログがある。このシステムにはバージョンの違いなどによっていくつかの名称がついているが本稿では統一して「BookRoll」と呼称する。BookRoll は現在、九州大学や京都大学など複数の大学で利用され (詳細は [3] 参照)、デジタル教材を用いた講義が行われている。BookRoll の特徴の一つに、学生がデジタル教材を利用した場合、その閲覧操作状況が自動的に学習ログとして記録されることがあげられる。このログを分析することで、学生の学習行動を理解し学習改善につなげることが期待されている。

BookRoll 利用時の学習ログを分析した研究としては、[4][5][6] などあるが、現状ではまだそれほど多くの分析がなされてきていない。本研究では学習ログ分析の一つとして、収集された学習ログと学生の成績との関連性に着目した分析を行った。どのような学習行動が成績状況と結びついているかを理解するのは学生をサポートする手がかりを得る上で重要であると考えられる。

りを得る上で重要であると考えられる。

成績に寄与した学習行動を分析する方法のひとつに重回帰分析を用いることが考えられる。重回帰分析では、学習行動を説明変数として、目的変数である成績に影響を及ぼす要因を探ることができる。しかし、重回帰分析のような単純な方法では、成績と学習行動間の複雑な関係を見つけ出すことが難しい。また、成績上位者や成績下位者にそれぞれ影響を及ぼした学習行動を分析することも難しい。そこで本研究では、非線形な式で関係性を表現できるニューラルネットワークを用いて要因分析を行う手法を提案する。具体的にはまず、ログから各学生の学習行動を特徴化し、成績との関係性を表現するニューラルネットワークモデルの構築を行う。その後、モデルによる成績の出力に対する入力の変動度を LRP [7] によって調べることで、どのような学習行動が成績に寄与するのかを分析する。この手法では、非線形な手法を取り入れることで複雑な関係性をとらえることができるだけでなく、成績上位や成績下位のグループになったそれぞれの要因を個別に発見できるという利点があり、成績上位と下位のグループの違いをより明確に捉えられる可能性がある。以降の節では提案手法に関する詳細な説明と、提案手法に関して実際に簡単な実験を行った結果に関して報告を行う。

## 2. BookRoll の学習ログを用いた研究

M2B のデジタル教材配信システム BookRoll から取得したログを分析した研究として、[4] では同一内容で教師の異なる 10 コースの講義における学習ログの分析を行い、コース割り当ての最適化に関して議論を行っている。また [5]

<sup>1</sup> 九州大学大学院 システム情報科学府  
744, Motoooka, Nishi-ku, Fukuoka, 819-0395 Japan  
<sup>2</sup> 九州大学 システム情報科学府  
744, Motoooka, Nishi-ku, Fukuoka, 819-0395 Japan  
a) shiino@limu.ait.kyushu-u.ac.jp  
b) minematsu@limu.ait.kyushu-u.ac.jp  
c) atsushi@limu.ait.kyushu-u.ac.jp  
d) rin@kyudai.jp

では教材の閲覧ページをもとに作成した行列に非負値行列因子分解を適用し、学生の教材閲覧パターンを5グループに分類を行っている。また分類したグループに対して小テストの成績との関連性を議論している。[6]では学習ログに加え、出席状況やレポートの提出状況を特徴量としたRNNモデルを作成し、交差検証による評価で高い性能を示している。本研究では学習ログと成績の関係を表現するニューラルネットワークモデルの学習を行うが、[6]のように成績予測を目的とするのではなく、モデルの入力と出力間の関係を分析することで、どのような学習行動と成績が関連しているかを理解することを目的とする。

### 3. BookRoll

BookRollはデジタル教材の配信システムである。このシステム上に教員が講義資料をアップロードすることで学生はwebブラウザ経由で講義資料の閲覧を行える。図1にBookRollでデジタル教材を開いた時の画面を示す。このシステムはマーカーの付加やメモの記載、ブックマークなどの機能を持つ。また学生はシステムを通して閲覧中のページが分かったか否かの意思表示を行うこともできる。BookRollで配布されるデジタル教材を利用した場合、その閲覧操作状況は自動的に学習ログとして記録される。学習ログとして記録される主な内容を表1に示す。表1の内容を見ると分かるように、学習ログからは「どの学生が」、「どの教材の」、「何ページで」、「どのような操作を」、「いつ」行ったのかが分かる。このうち「どのような操作を」に当たるoperation nameの詳細を表2に示す。

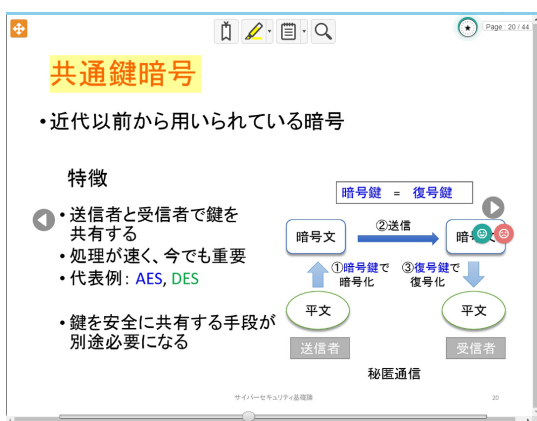


図1 BookRollを利用した時の表示画面

### 4. LRP

LRP(Layer-wise Relevance Propagation)[7]はニューラルネットワークにおける解釈手法の一つである。図2のように入力を一度通常通りに順伝播させた後、3のように出力から入力までレイヤー間の関係性を逆に伝搬していくことで、最終的に各入力値の出力値に対する関係性を貢献度

表1 ログとして記録される内容

名称	内容
user id	ユーザーごとに個別に割り振られたID番号
contents id	講義資料ごとに個別に割り振られたID番号
operation name	ユーザーが行った操作の名称
page number	操作を行ったページ
devicecode	システムを端末した端末(PCなど)
eventtime	操作が行われた時刻(秒まで)

表2 学習ログのoperation name

operation name	操作内容
OPEN	教材ファイルを開く
CLOSE	教材ファイルを閉じる
NEXT	次のページに遷移
PREV	一つ前のページに遷移
ADD MARKER	教材にマーカーを引く
ADD MEMO	教材にメモを書き込む
ADD BOOKMARK	ページのブックマークを残す
BOOKMARK JUMP	ブックマークのページへ遷移
SEARCH	教材内の文字列検索
GET IT	「分かった」ボタンをクリック
NOT GET IT	「分からない」ボタンをクリック
CLICK RECOMMENDATION	閲覧ページに関連するwebサイトへ遷移

として算出することができる。LRPにおいて出力から入力までのレイヤー間の関係性を伝播する際の式は以下のようになる。

$$R_i^{(l)} = \sum_j R_{i \leftarrow j}^{(l, l+1)}, \quad R_{i \leftarrow j}^{(l, l+1)} = \frac{z_{ij}}{z_j} R_j^{(l+1)}$$

$R_i^{(l)}$  : 第 $l$ 層のユニット $i$ の貢献度

$R_{i \leftarrow j}^{(l, l+1)}$  : 第 $l+1$ 層のユニット $j$ から第 $l$ 層のユニット $i$ へ逆伝播する貢献度

$z_j$  : 第 $l+1$ 層のユニット $j$ の出力値

$z_{ij}$  : 第 $l$ 層のユニットから第 $l+1$ 層のユニット $j$ へ順伝播する値。

ただし、 $z_j = \sum_i z_{ij}$ である。まとめると $d$ 次元の入力ベクトル $x$ に対して $f(x)$ を出力するようなモデルであった場合、LRP法では各入力要素 $x_i (1 \leq i \leq d)$ が $f(x)$ に関連する度合い $R_i$ を求めることができる。本研究の実験では、成績が「上位」、「中位」、「下位」の3クラス分類モデルを作成する。LRPを用いることで、例えば成績が上位という予測が出力されたとき、どの特徴量によってそのように判断されたかという各特徴量の貢献度合いを求めることができる。

### 5. 成績と学習行動の関係分析

本節では学習ログと学生の成績の関係性を分析するためのアプローチについて述べる。まず学習ログから学生の学習行動を特徴化する。その後、成績の「上位」、「中位」、「下位」を予測する3クラス分類のニューラルネットワークモ




図 2 ニューラルネットワークにおける通常の順伝播 ([7] より引用)




図 4 小テストの平均点のヒストグラム




図 3 LRP による貢献度の逆伝播 ([7] より引用)

デルの学習を行う。この際、本研究においては講義コース単位でモデルの作成を行う。これは講義コースによって講義スタイルが異なり、学習ログの傾向もかなり異なるため、講義コース単位で傾向を見たほうが良いと判断したためである。また学習の際にはコース内の学生の全データを用いて学習を行い、講義コース内の関係性を獲得するためにあえて過学習させてモデルの作成を行う。

その後、学習済みモデルを利用し各学生に対するモデルの出力を得る。さらに成績が上位と出力された場合と、成績が下位と出力された場合の、出力に対する入力の特徴度を LRP によって求めることで成績が上位の学生と下位の学生の学習行動の違いの検出を試みる。

## 6. 実験

### 6.1 データセット

本実験では 2019 年度春学期に九州大学において開講されたサイバーセキュリティ基礎論のコースを受講した 162 名の学生の学習ログをデータセットとして利用した。講義回数は全 8 回で、総ログ数は 372,197 であった。

またサイバーセキュリティ基礎論では毎回講義の終わりに 10 点満点の小テストが行われた。本実験では各学生の 8 回の小テストの平均点を成績として扱う。図 4 は 162 名の成績分布をヒストグラムで表したものである。162 名の成績の平均は 8.402 点で標準偏差  $\sigma$  は 0.649 点であった。この点数に従い 162 名の学生を「上位」、「中位」、「下位」の 3 つにグループ分けを行った。具体的な基準としては平均点  $+1\sigma$  以上の学生を「上位」平均点  $-1\sigma$  以下の学生を「下位」、その他の学生を「中位」とした。

### 6.2 モデルと学習

モデル構築のために、まずイベントログから特徴量の設計と計算を行った。今回は全 8 回の各講義毎に以下の 11 種類の特徴量を設計した。これらの特徴量は LRP を適用した場合に解釈がしやすい用に比較的シンプルなものとなっている。

- 表 2 に示す学習行動のうち、NEXT, PREV, ADD MARKER, ADD BOOKMARK, BOOKMARK JUMP, SEARCH, GET IT, NOT GET IT, CLICK RECOMMENDATION の 9 種類の操作を行った回数をそれぞれ単純集計したもの。
- 講義前の予習時間
- 講義中に残したメモの文字数

これらの 11 種類の特徴量を全 8 回の講義毎に計算し 88 次元の特徴ベクトルとした。また各特徴量の値が [0-1] の範囲に収まるように正規化を行った。

モデルを学習する際の目的変数は 6.1 でグループ分けをした、成績が「上位」、「中位」、「下位」を表現する 3 次元の one-hot ベクトルとして与えられ、3 クラス分類モデルとした。なおそれぞれのラベル数は 20, 23, 119 であった。

次に実験で用いたニューラルネットワークだが、隠れ層 2 層のシンプルなモデルを採用した。隠れ層のニューロン数はそれぞれ 256 と 64 で、出力層は 3 クラス分類のため 3 と設定した。活性化関数は Relu 関数、最終層のみ softmax 関数を適用している。実験では全てのデータセットを利用して、交差エントロピーロスを最小化することによりモデルの学習を行った。学習したモデルは同じく学習に利用したデータに対しては 100 % の分類ができるモデルとなった。

### 6.3 LRP の適用結果と考察

成績が上位の学生と下位の学生の差を調べるため、作成したモデルによって成績が上位と出力された 23 名と成績が下位と出力された 20 名の 2 つのグループのデータに対して LRP を適用し各入力特徴量の貢献度を算出した。その後それぞれのグループの全体的な傾向を見るため、それぞれのグループで貢献度の平均を計算した。図 6 は成績が

上位のグループに対して、前述したように LRP を適用しその結果を可視化したものである。横軸は特徴量名、縦軸は講義回番号をとっている。上位のグループに対しても同様に図 5 に示してある。図 6 を見ると初週の PREV や NEXT, GET IT, また 2 週目の PREV や NEXT も貢献度が大きいことから成績が下位の学生は最初の段階から何らかのつまずきが起こっているというような考察ができる。また、逆に図 5 を見ると 5 週目の NEXT の貢献が非常に高く、PREV の貢献も高い。実際サイバーセキュリティの講義の中で 5 週目は一番難しかったため、成績上位の学生は何度もページ遷移を行い講義資料を見返したのではないかというようなことが推測できる。




図 5 成績が上位の学生グループに対する LRP の結果

## 7. おわりに

本稿では、学習ログ分析の一つとして、収集された学習ログと学生の成績との関連性に着目した分析を行った。具体的には、学習ログから各学生の学習行動を特徴化し、成績との関係を表現するニューラルネットワークモデルの構築を行い、出力に対する入力の特徴度を LRP によって計算することによって、学習ログと成績との関係分析する手法の提案を行った。また、この手法を九州大学で実施された一つのコースに対して実際に適用し、その結果の可視化までを行った。LRP による結果の利用方法としては、コース終了後に成績の悪かった学生に対して成績の良かった学生との違いを伝えることで、今後の学習改善を促すといったことが考えられる。しかしながらそのためには、より理解しやすい結果の提示方法や、どのようにアドバイスをすると効果的なのかを慎重に検討する必要があると考え



図 6 成績が下位の学生グループに対する LRP の結果

られる。

## 謝辞

本研究は、JST AIP 加速課題 JPMJCR19U1, 科研費基盤研究 (A) JP18H04125, 基盤研究 (B) 19H04226 の支援を受けた。

## 参考文献

- [1] 武田俊之. ラーニング・アナリティクスとは何か. コンピュータ & エデュケーション, Vol. 38, pp. 12–17, 2015.
- [2] Hiroaki Ogata, Yuta Taniguchi, Daiki Suehiro, Atsushi Shimada, Misato Oi, Fumiya Okubo, Masanori Yamada, and Kentaro Kojima. M2b system: A digital learning platform for traditional classrooms in university. *Practitioner Track Proceedings*, pp. 154–162, 2017.
- [3] 教育ビッグデータを用いた教育・学習支援のためのクラウド情報基盤. [http://eds.let.media.kyoto-u.ac.jp/?page\\_id=14](http://eds.let.media.kyoto-u.ac.jp/?page_id=14).
- [4] Mouri K. Taniguchi Y Ogata H Taniguchi R Konomi S Shimada, A. Optimizing assignment of students to courses based on learning activity analytics. *Proceedings of the 9th International Conference on Educational Data Mining*, p. xxx, 2019.
- [5] Okubo F. Ogata H Shimada, A. Browsing-pattern mining from ebook logs with non-negative matrix factorization. *Proceedings of the 9th International Conference on Educational Data Mining*, pp. 636–637, 2016.
- [6] Fumiya Okubo, Takayoshi Yamashita, Atsushi Shimada, Yuta Taniguchi, and Shinichi Konomi. On the prediction of students' quiz score by recurrent neural network. *CEUR Workshop Proceedings*, Vol. 2163, , 1 2018.
- [7] Sebastian Bach, Alexander Binder, Grégoire Montavon, Frederick Klauschen, Klaus-Robert Müller, and Wojciech Samek. On pixel-wise explanations for non-linear classifier decisions by layer-wise relevance propagation. *PloS one*, Vol. 10, No. 7, p. e0130140, 2015.