

ドロップアウト抑制のための 個別最適化指導法の提案の自動化

小高 一^{1,a)} 三末 和男^{1,b)}

概要: 2年制学科が多い専門学校では、学生のドロップアウト兆候を早期に発見して、適切な指導を行うことで、勉学の機会を失わせないことが重要である。本研究では、ドロップアウトする可能性のある学生を検出できたとして、その次の段階で必要となる、適切な指導方法を早期に提案することの支援を目指した。まず、指導方法を分類するために、過去にドロップアウトした学生の1年次末のデータを利用してクラスタリングを行い、さらに教員19名がクラスタリング結果に基づいて指導方法による学生のグループ分けを行った。次に、1年次前期までのデータを利用して、学生の指導方法グループへの自動分類を試みた。これは、半年後に必要となる指導方法を予測することを意味する。結果として、約88%の学生には効果的な指導を提案できることが分かった。また、分類としては不正解であり、提案された指導では逆効果となる可能性がある学生が2名存在したが、それらについても教員が前期末時点のデータを確認すれば、不適切な指導を行う可能性が低いことから、実用的にも問題ない精度が得られたと考えられる。

キーワード: ドロップアウト抑制, 個別最適化指導, X-means, LightGBM, ベイズ最適化

Automatic proposal of individual optimized teaching method for dropout control

Abstract: In vocational schools, many two-year courses, it is important to detect signs of student dropout at an early stage and provide appropriate guidance so that students do not lose the opportunity to study. In the case of vocational schools, many two-year courses, it is important to provide appropriate guidance so that they do not lose the opportunity to study, too. we assume that we can detect students who are likely to drop out. In this study, we support the early detection of students who may drop out, and to propose appropriate guidance methods in the next stage. First, for classify the teaching methods, we used the data at the end of the first year of students. In order to categorize the instructional methods, clustering was conducted using the data at the end of the first year, and 19 teachers grouped the students according to the instructional methods based on the clustering results. In addition, 19 teachers grouped the students according to their teaching methods based on the clustering results. Next, using the data up to the first semester of the first year, we attempted to automatically classify the students into instructional method groups. This means that we can predict the instructional methods that will be required after six months. As a result, about 88% of the students were classified into one of these groups. As a result, we found that we could propose effective teaching methods for about 88% of the students. In addition, there were two students who were suggested incorrectly group might be counterproductive. But the possibility of inappropriate instruction is low if the teacher checks the data at the end of the first semester. However, there were two students might have been counterproductive.

Keywords: Dropout restraint, individual optimization instruction, X-means, LightGBM, Bayesian optimization

¹ 筑波大学
Tsukuba University, Tsukuba city tennodai, Ibaraki 1-1-1,
Japan

a) kotaka@vislab.cs.tsukuba.ac.jp

b) misue@cs.tsukuba.ac.jp

1. はじめに

専門学校は、学生に技術習得をさせて、希望の進路に進んでもらうための教育を行う場である。しかし、学生が、

卒業せずにドロップアウト（退学，休学）をしてしまうことで，その機会を逃してしまうことが問題となる．また，日本では，一斉授業が一般的な授業手法であるが，汎用的な教育となり，個々の学生への適切な指導は難しい．そのため，教育の効果が個々の学生へ適切に反映されていない．この問題を解決するために近年では，機械学習を使用して，学習履歴の情報より，学生が将来的にどの程度の学力になるか，ドロップアウトしてしまうのか等を予測して学生に個別最適となる指導を提供する試みも存在する [7]．学業におけるこのような仕組みでは，学生に沿ったカリキュラムの提案を行っているものはあるが [12]，ドロップアウトしてしまう学生の指導の提案までは行っていない．そのため，ドロップアウトの予測後にどのような指導をするかは，現場の教員が判断して対応している．この場合では，経験の浅い教員は，学生の今後の状況を把握できても，その後の指導を適切に行えない場合がある．

本研究では，ドロップアウトする可能性のある学生を検出できたとして，それらの学生に対して個別に適切な指導を提供するために，指導内容によって学生を自動分類する仕組みを構築した．特に，適切な指導を早く開始できるように，1年次前期末の情報から，1年次末の状況を推測することを旨とした．

2007年から2017年に専門学校をドロップアウトした645名の学生の入学前の学歴や，高等学校時代の成績状況，専門学校前期の出席状況や成績等の情報を活用して，ドロップアウトしてしまう学生を対象に分類を行い，自動的に各学生の特徴に合わせた適切な指導の提案を行う手法を開発した．

2. 関連研究

学生の学習状況を把握し，効果的な指導をするには，適切な学習履歴情報が必要である．

教育機関では，ITの発達に伴い，eラーニングの活用が盛んになっている．学生にeラーニングを利用してもらうことからさまざまな学習履歴を収集し，システムに蓄積して，管理することが一般的となっている [20]．そして，学習用コンテンツを利用して蓄積した学習履歴は，学生の情報を分析し，把握するためには重要である．

eラーニングのコンテンツでは，小テストを行って，その結果から，学生はどの部分につまづいたのかを検出するものがある [5]．

また，デジタル教科書を導入し，ページ単位の閲覧状況を履歴として収集しながら，プログラムなどの実習の際のコードの記述状況もリアルタイムに収集し，それらの学習履歴を組み合わせて学生の学習状況の分析の精度を向上させている研究がある [15]．さらに，ページ単位ではなく，行単位での閲覧状況を把握することで教科書の閲覧状況と学生の成績の因果関係を求める取り組みも行われてい

る [18]．

そして，学習履歴からの分析結果より，学生の習熟度別にグループを分けて，適切な指導を行う仕組みを考案している研究がある [11] [17]．これらの研究では，学生をグループに分ける際，人間が独自のルールにて判断しており，時には，主観的にグループの人数のバランスを考えて分けていることもある．

また，eラーニングの情報を活用した学習分析はマイクロなレベルであるが，教学 IR データを活用した学生の現状予測など，マクロレベルでの学生の分析を行っている研究もある [9]．

教学 IR に基づく学生の予測に関する研究は多く行われており，単位習得状況の予測 [7] [13] や，留年・退学の予測に関する取り組みがある [8] [12] [14] [16] [19]．

機械学習などを使用して，現状把握や将来的な予測を行う研究は多く報告されている [7] [10]．しかし，現状把握や予測を行った後に，機械学習などで学生をフォローするための適切な指導を提案する仕組みは作られていない．

3. 指導方法の分類の構築

学生の特徴ごとに適切な学生指導を行うためには，各学生がどのような特徴をもつかを特定する必要があると考えた．先行研究によると，ドロップアウトとなる兆候を予測するための情報として最も重要とされる情報は，学生の出席率と成績（GPA）である [14]．そのため，出席率と GPA をもとに学生の特徴を分類した．

3.1 教員による経験的な分類

19名の教員と協議，検討し，ドロップアウトしてしまう学生の特徴の分類を1年生前期末（4月から9月まで）の出席状況と成績から行った（表1）．教員の分類案としては，出席率が低く，GPAも低く成績が悪い学生のグループ，出席率は高いが，GPAが低い学生のグループ，出席率が高く GPA が平均的な学生のグループ，出席率が高く GPA が高い学生のグループに分けられた．

結論としてドロップアウトする学生は4グループに分類できるのではないかと考えた．その4グループそれぞれに属する学生についての適切な指導法は異なると考えられるため，それぞれの特徴に合った指導法の提案が必要となる．

表 1 教員による学生の分類

出席率	GPA
不良	低
良好	低
良好	中
良好	高

3.2 1年時末までの出席率と GPA を使用したクラスタリング

教員の経験による分類だけでなくデータに基づく、クラスタリング結果を基に指導方法を検討することで分類の再構築を行いたいと考えた。

X-means 法を使用して、学生の1年生後期末までの出席率と1年生後期の GPA を基にクラスタリングを行った(図1)。横軸は1年生後期(4月から翌年3月まで)の出席率、縦軸は1年生後期の GPA である。

X-means 法は Pelleg and Moore [1] によって提案された非階層型クラスタリングの一種である。基本的な動きとしては、分割するクラスタ数を2としてk-means法を繰り返し、情報量基準が条件に達するまで繰り返し2分割を行い、自動的にクラスタの数を決定するものである[6]。

図1は2007年から2017年までのドロップアウトした645名の学生をクラスタリングした結果である。縦軸が、1年生後期の GPA、横軸が、1年生後期末までの出席率である。データは標準化しており、平均0、分散1にスケールしている。また、各クラスタを色で識別している。数字はクラスタ番号である。

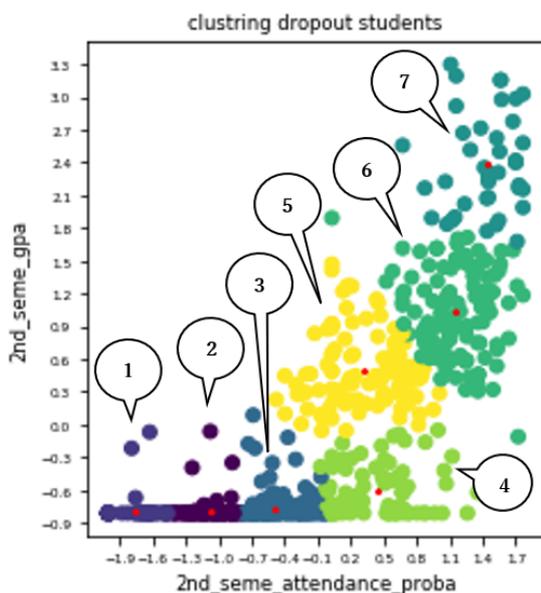


図1 1年次末までの出席率と GPA によるドロップアウトした学生のクラスタリング結果

3.3 指導方法の分類の再構成

X-means によりクラスタリングを行った結果、7つのクラスタが得られた。19名の教員により、各クラスタにおいてどのような指導法を行えるかを検討した。

表2は、当初の教員の経験則をもとにした分類と X-means によるクラスタの対応を検討したものである。教員による経験則による分類としては4分類になったが、出席不良の学生は、X-means によるクラスタリングでは1, 2, 3, 4に

細分化されるのではないかとの意見があった。

もし複数のクラスタに指導法の類似性があればそれらのクラスタは、一つにまとめるべきである。そこで、教員19

表2 教員による分類と X-means によるクラスタリングの対応

出席率	GPA	クラスタ番号	補足
不良	低	1, 2, 3, 4	
良好	低	5	(GPA) C
良好	中	6	(GPA) B
良好	高	7	(GPA) A

名によりさらに3回の検討を行った。1回目は、コミュニケーションをとる対象と学習フォローの指導の類似性について検討した。結果として表3の案1となった。なお、表3は、指導法案に類似性があるグループを、同じ色で表している。2回目の検討では、優先改善部分と学習フォローの類似性に注目した。その結果が案2である。最後に、案1と案2による指導案、注目、優先改善部分を基にどのような分類が適切かを検討した。その結果、案3が最終的な結論となった。

表4は案3の分類にもとづいて学生の特徴とそれに適した指導法案を整理したものである。

教員の経験則に基づく分類は、4グループであったが、最終的な検討により5グループとなり、指導提案のグループが一つ増えた。

表3 各に分類された学生の指導法案の類似性

案1	案2	案3
1	1	1
2	2	2
3	3	3
4	4	4
5	5	5
6	6	6
7	7	7

4. ドロップアウトの兆候がある学生の分類の予測

休退学傾向のある学生へ早期に効果のある指導をするために、1年生の9月までの情報を用いて、学生の自動分類を行った。再構築した5つの分類を目的変数とし、各学生がどの分類に属するのかを判断するための多値分類を行った。

4.1 早期に特徴を判断するための情報

本研究では、各学生の特徴をとらえて、それらに適した指導を提案することが目的であり、そのために学生の特徴の判別には、入学後の成績と出席率を使用した。1年生の後期末にドロップアウトする学生が多いため、その時期の

表 4 各クラスに分類された学生の特徴と指導法案

クラス	特徴	指導法（教員の意見）	注目	優先改善部分
1	出席状況が悪い。およそ 20%以下 成績も GPA0.5~1.5 が多い	保護者と連携をとり、学校が楽しいと思わせる 専門学校で勉強する意義を伝え、理解してもらう (将来設計をさせる)	保護者	出席
2	出席率 40%~65% 成績は GPA1.0~2.4 が多い 3 とさほど GPA に差はないと判断 入学から時がたつほど出席率が悪くなる やる気はあるが、勉強が苦手である	定期的に面談をして、登校させる指導が必要 補講等での学習面フォローが必要	学生	出席
3	出席率 65%~85% 成績は GPA1.0~2.2 が多い	目標設定をさせて、自ら勉強等に取り組ませる 科目の不合格が多いため、基礎的な内容の補講	学生	学業フォロー
4	出席率 65%~100% 成績は GPA2.0~3.0 が多い	目標設定をさせて、自ら勉強等に取り組ませる 基礎力はあるため、通常授業としてのフォロー	学生	学業フォロー
5	出席率 80%以上 成績は GPA 3.0~4.0 学費が原因かもしれない。 生活環境が変わった学生 (家庭環境が原因) 大学進学を希望し進路変更	新しいチャレンジ、活躍する場をつくる。 学費が原因かもしれない。学費支援の紹介 生活環境が変わった学生には学校としてフォロー	学生	専門学校の価値認識

前に適切な指導を行うことで、ドロップアウト抑制を行う。

1 年生後期の前に適切な指導を行いたいため、1 年時前期 (9 月まで) の出席と GPA, 入学前情報を利用し、早期に学生を分類し指導の提案を行う。入学前情報とは、学生が入学する前の高校の成績や、経歴などの情報である。(表 5)

表 5 入学前の学生情報

属性名	詳細
enrollyear	専門学校入学年度 (説明変数に使用せず)
enrollflg	入学, 編入学を管理
degreeflg	入学時の学歴を管理 (大学卒, 他の専門学校卒等)
scoreavg	高等学校在籍時の評定平均
kougakcd	高校の学科コード (普通科, 通信科等)
gradysa	入学年度と高等学校の卒業年度の差
grade	その時点の学年 (説明変数に使用せず)
graduyear	高校卒業年度 (説明変数に使用せず)
schdev	高等学校偏差値
dis	実家からの学校までの距離

4.2 学生の自動分類

517 名分を学習データとして、128 名のデータをテストデータとして分類精度を測定した。学生の自動分類には、LightGBM を用いた。LightGBM は、2016 年に米マイクロソフト社が公開した。勾配降下法と決定木を組み合わせるアンサンブル学習を行う勾配ブースティング決定木の一つの手法である [4]。勾配ブースティング決定木は、予測精度が高いが、決定木の最適な分岐条件を決める際の計算処理に多くの時間が必要である。学生情報のデータ量は、年々追加され増加していくため、計算処理を効率化し、時

間を短縮することが課題となる。

LightGBM は、勾配ブースティング決定木の計算処理の時間の問題点を解決するための手法を導入している。一つ目は、Gradient-based One-Side Sampling(GOSS) である。これは、学習データのサイズを削減するために利用されるダウンサンプリングの手法において、元の分布と異なる形状になってしまうことを解決する手法である。勾配の大きいデータは残し、勾配の小さなデータはランダムサンプリングを行うことで、元の分布を失わないようにする。二つ目は、Exclusive Feature Bundling(EFB) である。LightGBM は、全ての条件を比較して、最適な分岐を見つけるのではなく、Histogram-based アルゴリズムにて、近似しているデータの一つにまとめることから、大まかに最適な分岐を見つけていく。Histogram-based アルゴリズムは、0 の特徴量も含み、すべての bin にアクセスする必要があるため、適切な特徴量の削減ができない。この問題を解決するため、疎な排他的特徴量を単一の特徴量へと束ねることで、特徴量の削減を可能とするアルゴリズムである [3]。三つ目は、LightGBM は、勾配ブースティングの訓練過程での決定木の扱い方として、Level-Wise ではなく Leaf-Wise を手法としている。LightGBM は、この三つの手法を取り入れたことで、高い精度を保ったまま、計算処理時間の短縮が可能である [2]。しかし、LightGBM は、与えられた情報の特性に敏感であり、過学習となる傾向がある。

e ラーニングからの学習履歴や、教学 IR データは、各学校で取得するタイミングや情報の種類を特には統一していない。また学校によって学生の特性が異なる。従って、本研究で扱う学生の情報は、個々の学校特有となる。そのため、その学校の学生情報に沿った予測モデルの構築が必要

であり、同時に、過学習にならないような対策が必要である。そこで、分類の精度向上と過学習を防ぐための対策を含めて、ハイパーパラメータの最適化を行った。

4.3 ベイズ最適化によるハイパーパラメータの決定

表 6 最適化されたパラメータ

パラメータ	値
ブースティングタイプ	gbdt
一つの木の最大葉数	85
学習率	0.4161
木の最大の深さ	6
L1 正則化	14.150
L2 正則化	0.0092
弱学習木ごとに使う特徴量の割合	0.6821

4章2節より、精度を高めつつ、過学習を抑えるためにテストデータに合わせたパラメータの設定が必要となる。そこで、ベイズ最適化を用いて、自動分類を行うごとに算出された正解率の最大値となったときのパラメータを最適値とすることにした(表6)。ベイズ最適化は、処理時間が短くパラメータ設定を的確に行えるため活用した。

我々が使用したデータでは、ブースティングタイプは、gbdtが選択された。これは、通常の勾配ブースティング決定木の手法である。GOSSの選択もあるが、gbdtが適切であると算出された。これは、データ量がそれほど多くないため、サンプルサイズを減らすことでの計算処理時間削減は必要がないためである。

正則化は、損失関数に特定の値を足すことで、過学習になることを防ぐ。L1, L2ともに予測に関して重要ではない説明変数に対しての重みの値を小さくすることで複雑なモデルを一般化する。

L1は、重要でない説明変数の重みを0にする。L2は、重要でない説明変数の重みを小さくする。パラメータの設定では、L1の値が14.15であり、L2は0.0092である。つまり、L1の値は高く、L2の値は0に近い。従って、分類の予測に重要ではない説明変数の重みを0として、次元削減を行っていることを表しており、その結果として過学習を抑えて精度が向上したと判断できる。

4.4 自動分類の結果

表7に分類結果の数値を示す。行が自動分類により分類されたグループを、列が正解のグループを表している。たとえば、グループ1の行、グループ2の列に「8」があるが、これはグループ1に自動分類された学生のうち8名は本来はグループ2であったことを表している。正解率は0.7031となった。

本文は実際には論文誌ジャーナル編集委員会で作成したものである。

表 7 分類別の提案にて指導されるグループごとの学生の人数

自動分類されたグループ	正解のグループ				
	1	2	3	4	5
1	47	8	0	0	0
2	5	22	3	0	2
3	3	6	11	2	1
4	0	1	4	8	1
5	0	0	0	2	2

5. 指導の観点での分類予測の精度評価

分類の予測が外れてしまった場合でも、その間違え方によっては、多少の効果が見込まれるのではないかと考えた。そこで、分類の予測により提案された指導が最適ではなかった時の影響度について、教員19名で論議した。論議の結果を表8に示す。◎は最も効果あり、○は効果あり、△は指導の効果はない、×は逆効果の指導を表している。

表 8 指導の効果

自動分類されたグループ	正解のグループ				
	1	2	3	4	5
1	◎	○	△	×	×
2	○	◎	△	×	×
3	○	○	◎	△	△
4	×	△	△	◎	△
5	×	×	△	△	◎

最も効果ありとは、学生のドロップアウトを抑制できる適切な指導を言う。効果ありとは、最も適切までの効果は期待できないが、大方はずれてはいない指導であり、多少なりとも効果があると判断したものである。効果なしとは、その指導が学生に必要な指導ではないが、その指導によりドロップアウトの傾向を強めることもないものである。逆効果の指導とは、その指導により学生がドロップアウトをしてしまう傾向を強めてしまう危険性があるものである。

5.1 指導効果の予測の評価

これをもとに最も「効果があり」、また、「最も効果ありと効果ありの両方を含めたもの」、「効果なしも含めたもの」、「逆効果となる」ものの割合をもとめた。表9が、それぞれの割合を表したものである。

表 9 効果を基準とした割合

指導効果記号	指導効果	該当人数	割合の累計
◎	最も効果あり	90	0.70310
○	効果あり	22	0.87500
△	効果なし	14	0.98430
×	逆効果	2	0.01562

割合の累計は逆効果ではないものと逆効果のもので分けて算出している。最も効果ありの正解率は、0.70ほどあり、最も効果ありと効果ありの両方を含めた精度は、0.88ほど

であった。最も効果ありと効果ありに効果なしを加算した正解率の累計は、0.98であった。つまり、本研究にて作成したドロップアウト抑制のための個別最適化指導法の提案を自動化するアルゴリズムでの予測のおよそ98%は、逆効果とはならない指導を提案できることがわかった。

最も効果がある指導を0.70ほどの割合で予測できるということは、ドロップアウトの兆候があると予測された学生が5人いた場合、そのうちの3人から4人には適切な指導ができるということである。

また、指導が不適切で、学生がドロップアウトとなることをより推し進めてしまうような対応となる割合は、0.015であった。

5.2 ドロップアウトの兆候がある学生への指導提案アルゴリズムの評価

逆効果の指導を提案された二人の学生について調査を行った。予測された分類のグループが2で実際に属するグループが5である学生のうち一人は、9月までの出席率が0.7556であり、GPAが2.14であった。また、もう一人の学生の9月までの出席率は0.9826、GPAは2.34であった。

9月までの情報から、両学生は、出席率が比較的高く、この時期に学業フォローではなく、グループ2の登校指導を行うことは適切ではない。

しかし、9月時点で指導が行われることを考えると、教員が出席状況を確認した際、このような学生に登校指導を行うことはない。従って、このような場合に、教員は逆効果である指導は行わないと考えられる。

6. おわりに

本研究の目的は、ドロップアウトの兆候がある学生に個別最適な指導を行うことでドロップアウト抑制を行うことである。そのため、各学生への適切な指導を提案する手法を開発した。

まずは学生をクラスタリングし、それを基に分類を構築した。その分類の際、経験のある教員19名で検討し、各学生の特徴に対する適切な指導案を作成した。指導案が類似しているクラスは、一つのグループにまとめることで、指導ごとのグループに再構築した。X-meansが算出した学生の特徴ごとのグループは、7つであったが、教員が考案した指導案をもとにグループを併合した結果、5つのグループとなった。そして、5つのグループを目的変数とし、多値分類を行った。

多値分類の精度は、実践活用として十分であると考えられる。最も効果がある指導の提案の正解率は、およそ70%であり、予測が外れてしまった場合の効果ありの指導の提案までの正解率は87%、逆効果とはならない指導の提案の正解率は98%程であった。

また、9月の時点での状況で、教員は学生の状況を確認

することで、逆効果の指導を提案された学生へそのような指導を行わない。今回作成したドロップアウトの兆候がある学生への指導提案アルゴリズムは、逆効果である指導を提案することはあるが、教員が学生の状況を見て指導の変更するため、実際には学生への逆効果の指導は行わないと考えられるため、大きな問題はないと考える。

今後は、ドロップアウトの兆候がある学生を早期に予測するシステムを構築し、本研究の仕組みと連動することで、より個別最適な指導の提案の精度を高めていきたい。

謝辞

学校法人片柳学園 日本工学院専門学校より、学生情報の使用の許可をいただき、本研究に取り組むことができたことに感謝し、お礼の言葉とする。

参考文献

- [1] Andrew Moore Dan Pelleg. X-means: Extending Kmeans with Efficient Estimation of the Number of Clusters. *ICML-2000*, pp. 727–734, 2000.
- [2] Essam Al Daoud. Comparison between XGBoost, LightGBM and CatBoost using a home credit dataset. *Engineering and Technology International Journal of Computer and Information Engineering*, Vol. 13, No. 1, pp. 6–10, 2019.
- [3] Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, Wei Chen, Weidong Ma, Qiwei Ye, and Tie-Yan Liu. LightGBM: A Highly Efficient Gradient Boosting Decision Tree. In *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS 2017)*, pp. 3149–3157, 2017.
- [4] Carlos Guestrin Tianqi Chen. XGBoost: A Scalable Tree Boosting System. *22nd ACM SIGKDD International Conference on Knowledge Discovery Data Mining*, pp. 785–794, 2016.
- [5] 加藤利康. 授業支援システム Moodle における小テストマイニング. 情報処理学会研究報告, Vol. 2012-CLE-8, No. 4, pp. 1–6, 2012.
- [6] 久保尚輝, 今村幸祐, 橋本秀雄. X-means クラスタリングによるクラス数を用いた動オブジェクト抽出. 情報処理学会研究報告, Vol. 2010-AVM-70, No. 5, pp. 1–6, 2010.
- [7] 近藤伸彦, 松田岳士, 渡辺雄貴, 松河秀哉, 立石慎治, 椿本弥生, 山下英明. 自動選択した教学 IR データに基づくアカデミック・サクセスの予測. 情報処理学会研究報告, Vol. 2019-CLE-27, No. 10, pp. 1–7, 2019.
- [8] 近藤伸彦, 畠中利治. 学士課程における大規模データに基づく学修状態のモデル化. 教育システム情報学会誌, Vol. 33, No. 2, pp. 94–103, 2016.
- [9] 近藤伸彦, 畠中利治. ベイジアンネットワークによる修学状態推移モデルの構築. 日本教育工学会論文誌, Vol. 41, No. 3, pp. 271–281, 2017.
- [10] 吉田淳一高岡詠子. e-Learning 学習履歴を用いたドロップアウト兆候者早期抽出手法の提案, 検証および今後の可能性. 情報処理学会論文誌, Vol. 52, No. 12, pp. 3080–3095, 2011.
- [11] 手塚祐樹, 高木正則, 佐々木淳, 山田敬三, 澤里耕太郎, 森本康彦. 理解度向上と学習方略の改善を促す振り返り支援システムの提案・開発. 情報教育シンポジウム, pp. 43–50, 2017.
- [12] 近藤伸彦. 教育/学習における予測モデルの活用. 教育システム情報学会誌, Vol. 37, No. 2, pp. 93–105, 2020.
- [13] 大友愛子, 岩山豊, 毛利隆夫. 学内データの活用～大学における IR (Institutional Research) への取組み. *FUJITSU*,

- Vol. 65, No. 3, pp. 41–47, 2014.
- [14] 竹橋洋毅, 藤田敦, 杉本雅彦, 藤本昌樹, 近藤俊明. 退学者予測における GPA と欠席率の貢献度. 大学評価と IR, Vol. 5, pp. 28–35, 2016.
 - [15] 中野真, 梅澤克之, 平澤茂一. 粒度の高いコンテキストウェアな学習履歴を組み合わせた学習者分析. 経営情報学会, pp. 43–46, 2018.
 - [16] 藤原宏司. 学業を中断する学生の予測モデル構築について. 大学評価と IR, Vol. 5, pp. 8–22, 2016.
 - [17] 梅澤克之. 効果的な反転授業の提案と実験による評価. *SHONAN INSTITUTE OF TECHNOLOGY JOURNAL*, Vol. 52, No. 1, pp. 37–52, 2018.
 - [18] 毛利考佑, 島田敬士, 殷成久, 魚崎典子, 金子敬一, 緒方広明. 非負値行列因子分解を用いたデジタル教科書におけるスクラッチ機能の閲覧パターン分析. 情報処理学会研究報告, Vol. 2018-CLE-25, No. 10, pp. 1–6, 2018.
 - [19] 葛田敏行. 留年してしまう学生の効率的・効果的な検出方法についての検討. 大学評価と IR, Vol. 4, pp. 18–25, 2015.
 - [20] 槇原竜之輔, 永井孝幸, 中野裕司. Apache ログと OpenLRS を利用した xAPI による Mahara の活動履歴蓄積システムの開発. 情報処理学会研究報告, Vol. 2016-CLE-19, No. 2, pp. 1–4, 2016.