

原著

教学IRにおける機械学習の意義と可能性

高松 邦彦¹⁾²⁾³⁾ 村上 勝彦⁴⁾ 伴仲 謙欣²⁾³⁾⁵⁾ 野田 育宏²⁾³⁾⁶⁾
光成 研一郎⁷⁾ 大森 雅人⁷⁾ 中田 康夫²⁾³⁾⁸⁾

Significance and possibility of artificial intelligence in institutional research for education

Kunihiko TAKAMATSU¹⁾²⁾³⁾, Katsuhiko MURAKAMI⁴⁾,
Kenya BANNAKA²⁾³⁾⁵⁾, Ikuhiro NODA²⁾³⁾⁶⁾, Kenichiro MITSUNARI⁷⁾,
Masato OMORI⁷⁾, and Yasuo NAKATA²⁾³⁾⁸⁾

要旨

教学 IR においては、従来は説明モデルによる解析や可視化にもとづく意思決定支援が主要な機能であったが、近年では予測モデルにもとづく種々の予測に関してその重要性が高まっているといわれている。そこで本稿では、教学 IR における機械学習の意義と可能性について、われわれの経験を題材として検討した。われわれの経験では、機械学習を用いることで、大学における中途退学や学力進捗を予測できる可能性があることが明らかになっている。このことから、いわゆる教学データを用いた機械学習により、今までなし得なかった教学上の種々の予測が可能となり、今後のわが国の教学 IR が飛躍的に進展する可能性が示唆された。

キーワード：教学IR、機械学習、予測モデル、説明モデル

Abstract

In institutional research (IR) for education, the decision-making support based on the analysis and visualization by the explanation model was the main function in the past. However, the importance of various predictions based on predictive models is currently increasing in IR for education. Therefore, this paper examined the significance and possibility of artificial intelligence/machine learning (AI/ML) in IR for education using our experience as subjects. Our experience reveals that using AI/ML can predict dropouts and academic progress in university and college.

1) 保健科学部診療放射線学科 2) KTU 研究開発推進センター 3) ときわ教育推進機構 4) 東京大学医科学研究所
5) 神戸常盤大学短期大学部口腔保健学科 6) 事務局学術推進課 7) 教育学部こども教育学科 8) 保健科学部看護学科

Thus, it is suggested that using students' educational data, AI/ML could make various predictions in higher education that were not possible earlier, leading to dramatic progress in Japan's IR for education.

Key words: Artificial intelligence/machine learning, institutional research for education, predictive model, explanatory model

緒言

大学における Institutional Research (IR) は、1960年代に全米の大学に急速に普及し、この時期が米国における IR の黎明期であるといわれている。その後この 60 年間で、その活動および機能が急速に発展した。近年では、大学教育の「質保証」への社会的要請がますます強まっていることから、各大学における意思決定と戦略的な経営にとって不可欠なものとして位置づけられ、さらに社会に対する説明責任を果たすために、米国の各大学では大学組織内に独自の IR 部門を設け、そこに IR 専門職を配置するという体制が整備されている。

わが国では、2012 (平成 24) 年に中央教育審議会による答申「新たな未来を築くための大学教育の質的転換に向けて～生涯学び続け、主体的に考える力を育成する大学へ～」が、わが国における大学 IR の根拠文書とされている¹⁾。しかし、そこから遡ること 2008 (平成 20) 年の中央審議会答申「学士課程教育の構築に向けて」において、学位授与、教育課程・編成の実施、入学者受け入れの 3 つの方針を主体として、教学経営の明確化や教職員の職能開発の確立等が示された²⁾。この答申以降、統計データなどの科学的根拠に基づいて判断を行う、いわゆる「エビデンス・ベースド (evidence based)」な考え方や教育質保証³⁾が大学にも求められるようになった。

2011 (平成 23) 年に学校教育法施行規則が改正され、各大学が公表すべき教育情報が明確化された。上記の 2012 (平成 24) 年の中央教育審議会答

申のなかの「大学ポートレート」に関する用語説明において、「大学ポートレート (仮称) の整備により、①大学が教育情報を用いて自らの活動状況を把握・分析し、改革につなげる (いわゆる IR (Institutional Research) 機能の向上)」という IR の記述がみられ¹⁾、これ以降、日本の大学における IR への関心が本格的に高まってきた。大学ポートレートについては、その後 2014 (平成 26) 年 7 月に、独立行政法人大学評価・学位授与機構に大学ポートレート運営会議および同センターが設置され、私学については日本私立学校振興・共済事業団によって 2014 (平成 26) 年 10 月 6 日に、国公立については 2015 (平成 27) 年 3 月 10 日に大学ポートレート⁴⁾が公開された。

このような状況に鑑み、本学 (保健科学部に医療検査学科と看護学科の 2 学科、教育学部にこども教育学科の 1 学科、短期大学部に口腔保健学科の 1 学科、合計 4 学科) では、まず準備段階として 2015 (平成 27) 年度に IR 委員会を、翌 2016 (平成 28) 年度には IR 推進室を、さらに 2017 (平成 29) 年度に新たに IR 推進ユニットを設置した。IR 推進室が職員だけの部門であるのに対し、IR 推進ユニットは、教員と職員のメンバーから構成される教職協働のユニットである。本学の IR は、大学 IR の 3 つの機能 (経営 IR、教学 IR、研究 IR) のうち、とくに教学 IR を目的として、学内のさまざまな学生に関する情報を収集、整理、管理、提案を行っている。

教学 IR においては、従来は説明モデルによる解析や可視化にもとづく意思決定支援が主要な機能

であったが、近年では予測モデルにもとづく種々の予測に関してその重要性が高まっているといわれている⁵⁾。また、各高等教育機関において大規模に集積・格納されつつあるいわゆる「教育ビッグデータ」「学修ビッグデータ」を有効活用するために、ラーニングアナリスティックスなどの関連分野との有機的な統合が望まれている⁶⁾。ラーニングアナリスティックスなどでは、学修に関する何らかの「予測」が主要な役割を果たすことが多く、そのための予測モデルは一般に機械学習やデータマイニングの手法を用いて構築される⁵⁾。

そこでわれわれは、機械学習による「予測」が教学IRに資することができるかどうか分析・検討を重ねてきた。まず2017（平成29）年度には、さまざまな理由が存在するためにその予測・予防がこれまで非常に難しいとされてきた中途退学⁷⁾⁸⁾について、そして翌2018（平成30）年度には学力進捗⁹⁾¹⁰⁾に関する予測を試み、そのいずれにおいても機械学習により予測ができる可能性を見出すことができた。

本研究は、教学IRにおける機械学習の可能性について、われわれの経験を題材として分析・検討することを目的とする。

方法

解析はmac OS X 10.11.6で行った。解析には、Python (3.6.0) とPerl (5.18.2) を用いた。PythonのライブラリとしてNumPy¹¹⁾、Matplotlib¹²⁾、scikit-learn¹³⁾、pandas¹⁴⁾を使用した。機械学習においては、全ケースのうち約70%をトレーニングデータ（具体的な予測モデルの構築）として用い、残り約30%をテストデータ（学習に使っていない未知のデータであり、予測モデルの評価に利用）として用いた。割当については、変数値の偏りがなるべくないようにscikit-learnによる仕組みで割り当てている。

本学における「教育データ」「学修データ」を用いた機械学習

1) 機械学習の方法

ここでは、本学における「教育データ」「学修データ」を用いた2つの機械学習の成果、すなわち「中途退学の予測」と「学力進捗の予測」について簡潔に述べる。

なお、本研究による機械学習は、いずれも以下の方法で実施した。

解析に用いたデータであるが、本学の教学IRのデータについては、原則非公開となっている。そのため、本研究においては、IR推進室より学籍番号、氏名などをすべて削除した匿名な状態で、また各項目についてもすべて番号へ変換して項目内容がわからないように秘匿した状態でデータを入力した。そのため、各項目が何を表しているのか、解析者には理解できないようになっている。

機械学習の分野にno free lunchという定理がある¹⁵⁾。この定理が示していることは、機械学習で注意すべき事象であり、それは「どのようなデータにおいても、高い精度を出せる万能な機械学習手法が存在しない」ということである。そこでわれわれは、3つの手法を用いて機械学習を行った。第1と第2の手法は、ロジスティック回帰（logistic regression）を用いた機械学習である¹⁶⁾。回帰分析は、目的変数（従属変数とも呼ばれ、本研究の場合は卒業することに相関する潜在値）を、説明変数（独立変数とも呼ばれ、本研究の場合は1,246の項目）の関数で表現し、その関数をデータから求めることにより、任意の説明変数の値に対する目的変数の予測や、各説明変数の目的変数への効果の推定に用いられる手法である。回帰ロジスティック回帰は、目的変数を0以上1以下で回帰をし、その後、閾値以上かどうかをみて2値予測問題にも適用されている。本研究の場合、2値（離散的）で表された変数を、ロジスティック回帰を用いて2値予測を実行した。通常の回帰では、トレーニン

グデータに最も適合した結果を返すため、過度な学習（過学習）を引き起こす可能性がある。これを回避するため、正則化項（罰則項とも呼ばれる）として、L1 正則化項と L2 正則化項と呼ばれる方法を用いた。L1 正則化項は、係数の絶対値の和として、L2 正則化項は係数の 2 乗和を用いる。第 1 の手法は正則化として L2 を用い、第 2 の手法は正則化として L1 を用いた。ロジスティック回帰は、3 次式以上で判別させると、線形分離不可能な問題も解けるという特徴がある。

第 3 の手法は、ランダムフォレスト (random forest) ¹⁷⁾ である。ランダムフォレストは、アンサンブル学習による機械学習アルゴリズムの 1 つである。複数の決定木 (tree) を弱識別器として用い、その結果を集約する判定器 (forest) により精度の高い結果を得るアルゴリズムである。パターン識別をはじめとして、回帰、クラスタリングに利用できる特徴をもっている。

2) 中途退学のデータの準備

データは、IR 推進室から csv 形式で入手した。機械学習の正解（中途退学者を示すデータ）が第 1 項目であること、また中途退学を直接表すデータは除外されていることのみ、IR 推進室から伝えられた。入手したデータをタブ形式にして保存し、改行コードを Unix 形式に変換した。この際、改行が 2 回含まれているセルが複数あったため、それらを修正した。その後、漢字コードを nkf を用いて utf-8 に変換した。また、欠損データは 0 とした。

3) 学力進歩のデータの準備

データは、IR 推進室からエクセル形式で入手した。科目ごとの数値範囲は基本的に点数であり、0 ~ 100 の範囲である。科目登録していない学生は 0 点としている。よって欠損データはない。0 より大きい数値となっている学生の場合、大多数は 60 から 100 の範囲で、60 以下は極端に少ない。登録した学生が（離脱をのぞいて）0 点をつけられることは基本的にないが、その事象が起こったとしても解析に対する支障はとくにない。

結果

1. 中途退学の予測

IR 推進室から入手したデータ数は、全部で 2,163 人分であった。各データに対して 1,246 項目が存在した。

表 1 に、3 手法の機械学習の結果を示す。第 1 の機械学習法では、トレーニングデータを用いた機械学習の正解率は 0.643 で、テストデータを用いた機械学習の正解率は 0.649 であった。トレーニングデータとテストデータを用いた機械学習の正解率に、ほとんど違いはみられなかった。第 2 の機械学習法では、トレーニングデータを用いた機械学習の正解率は 0.573 で、テストデータを用いた機械学習の正解率は 0.603 であった。トレーニングデータを用いた機械学習の正解率よりも、テストデータを用いた機械学習の正解率のほうが高くなった。第 1 と第 2 の手法の違いは、正則化の違いであった。この結果から、中途退学については、L1 の正

表 1 3 手法の機械学習によるトレーニングとテストの正解率

手法	正解率		
	1	2	3
トレーニングの正解率	0.643	0.573	0.914
テストの正解率	0.649	0.603	0.895

則化よりも L2 の正則化のほうが、正解率が高いということが明らかとなった。

第3の機械学習法では、トレーニングデータを用いた機械学習の正解率が0.914で、テストデータを用いた機械学習の正解率が0.895となった。ランダムフォレストの結果は、ロジスティック回帰よりも約25ポイントも正解率が高いことが明らかとなった。

機械学習のテストデータを用いた機械学習の正解率が高いほうが、中途退学の予測が正確にできることから、この結果は、第3の機械学習法であるランダムフォレストが最も中途退学を高精度に予測できることを表している。

2. 学力進捗の予測

IR 推進室から入手したデータ数は、1,155人、説明変数（1年次の科目の成績等）は118変数であった。今回の解析に使用したデータは、全4学科のデータとなっている。この全4学科の各データに対して、1年次の成績の項目（科目）が118項目存在した。この118項目（科目）は、全学科の科目を合計し、重複を抜いたものと同様である。

国家試験の合格・不合格の予測方法については、多くのタイプのデータで比較的安定的に高精度の予測ができるといわれる、上述の「中途退学の予測」の際にも用いたランダムフォレスト（random forest）¹⁷⁾を用いた。

表2に、機械学習の結果を示す。第1の機械学習法では、学習の正解率は0.966で、テストデータを用いた機械学習の正解率は0.913であった。学習とテストの正解率はどちらも高く、過学習の可能性はわずかであるとみられる。機械学習のテ

表2 機械学習（Random Forest 法）の正解率

評価に使用したデータ	正解率
学習データ	0.966
テストデータ	0.913

トデータを用いた機械学習の正解率が高いほうが、学力進捗の予測が正確にできることから、この結果は、第1の機械学習法では学力進捗を高精度に予測できることを表している。

次に、テストデータを用いた、合格と予測した数を分母とした正解率（精度、Precision、P）と、実際に合格した数を分母とした正解率（再現率、Recall、R）を比較し、さらにこれらの調和平均であるF値を計算した（表3）。F値の定義は $1/F = (1/P + 1/R) / 2$ である。今回のモデルでは合格と予測した場合には96.7%正しいと期待できる。再現率をみると合格者の81.7%を正しく予測できたことからみても、非常に高い正解率である。

表3 2種類の正解率とその調和平均

Precision（精度）	Recall（再現率）	F 値（調和平均）
0.967	0.817	0.885

考察

先にも引用した2012年の中央教育審議会による答申「新たな未来を築くための大学教育の質的転換に向けて」において、学士課程教育を改善し体系的・組織的な教育を提供することによって、予測困難な時代を自ら切り拓いていける力を身に付けた学士を育成するためには、全学的な教学マネジメントの確立が重要な方策の一つであるとしている¹⁾。そして、現在の教学マネジメントは、従来の「教育（Teaching）」のマネジメントだけでなく、「学習（Learning）」のマネジメントがより重要な役割となってきている。つまり、教学マネジメントとは、学習と教育のマネジメントであり、学生の学習成果を最大限生み出すために、大学の有する物的・人的資源を効果的、効率的に配分し、活用することである¹⁸⁾。

近年のわが国の大学における教学上の懸案事項の1つとして中途退学があり、そこに至る原因の1つとして学力進捗が芳しくないこと（成績低迷）が挙げられる。大学の中途退学者は、非正規雇用

増加の要因になるなどの社会的損失を指摘するものもある。中途退学者が生じるということは、大学の教育機関としての役割が十分果たされない懸念が生じる。中途退学者の増加は授業料収入の減収が伴うため、大学財政にも悪影響を及ぼす可能性がある¹⁹⁾。また、山本²⁰⁾は「学生の中退率が高いということは、背後にどのような事情があるにせよ、多くの学生が大学に満足しなかったことの結果であり、単位不足による留年を理由に退学する場合にも、その本質的な原因は単位を取れるように学生を教育できなかった大学側にあると考える」としている。これらのことから、今後の大学IRにおいては教学IRが十全に機能するようにしていくことが極めて重要である。

中途退学は、「海外留学」や「他大学への編入」などの積極的・自発的な理由だけでなく、「経済的困難」や「就学意欲の低下」などの消極的・非自発的な理由とも関連している²¹⁾。このように、中途退学にはさまざまな理由が存在するため、中途退学の原因を特定することはこれまで非常に難しいとされてきた。

中途退学者については、これまでも学校基本調査報告のデータをもとにマクロなレベルで研究されている²¹⁾²²⁾。ミクロなレベルでは、船戸²³⁾²⁴⁾は、退学防止対策のポイントを論ずるなかで、欠席の増加や成績の低下などの退学につながる兆候をできるだけ早くつかむことの重要性を強調するとともに、データ分析に基づく対策の重要性を指摘しているものや、退学防止を目的として学生相談的アプローチに関する研究もなされている²⁵⁾。

また、ロジスティック回帰や重回帰分析を用いてGPAと欠席率による退学者予測の有用性について検討しているもの²⁶⁾、入学前または入学直後に入手できる情報を用いて、その後の中途退学に関連する要因の特定を試みたもの²⁷⁾、マス型大学における中途退学者予測モデルを作成しているものもある²⁸⁾。さらに、Enrollment Management Institutional Research (EMIR) に関しては、山形

大学²⁹⁾や京都光華女子大学³⁰⁾においても積極的に中途退学の問題について研究されている。科学研究費の研究においても、EMIRにおけるデータに注目して中途退学の防止策が研究されている³¹⁾。

ここで改めて考えてみると、中途退学の最終的な目的はそれを防止することである。そのためには、中途退学の原因を突き止めるということはひとまずおいておき、高い精度で中途退学の予測を行い、その結果を用いて予防することが重要であるといえる。また、予測がある程度の確率でできるのであれば、チューターや担任などとの面談の予備データとして用いることで、これまで目が届かなかった学生に目が届くようになる可能性がある。

機械学習には、その原因を特定するのは難しいが、高い精度で予測が可能であるという特徴をもつ解析方法が存在する。そのような機械学習の特性を用いることで、中途退学と強い相関がある項目をいくつかに絞り込んで原因を特定することはできないが、中途退学と弱い相関がある多くの項目の組み合わせにより、予測精度を上げることが可能ではないかと考えた。さらに中途退学に至る原因の1つとして成績低迷をも同様の手法で予測できないかと考えた。

今回のわれわれの研究成果が示すように、中途退学のみならず学修進捗（成績低迷）のいずれにおいても機械学習により高い確率でそれを予測することができた。これらのことから、わが国の教学IRにおいて機械学習を用いることは、教学IRの可能性を大きく広げるものであり、かつ意義深いことだと考える。

本研究の一部は、第6回大学情報・機関調査研究集会(2017)、IEEE/International Institute of Applied Informatics (IIAI), 7th International Congress on Advanced Applied Informatics (AAI2018), 7th International Conference on Data Science and Institutional Research (DSIR 2018)、第7回大学情報・機関調査研究集会(2018)、IEEE/

International Institute of Applied Informatics (IIAI), 8th International Congress on Advanced Applied Informatics (AAI2019), 8th International Conference on Data Science and Institutional Research (DSIR 2019)において発表した。

文献

- 1) 中央教育審議会. “新たな未来を築くための大学教育の質的転換に向けて～生涯学び続け、主体的に考える力を育成する大学へ～”. 文部科学省, http://www.mext.go.jp/component/b_menu/shingi/toushin/_icsFiles/afieldfile/2012/10/04/1325048_3.pdf, (参照 2020-09-01).
- 2) 中央教育審議会. “学士課程教育の構築に向けて(答申)”. 文部科学省, https://www.mext.go.jp/b_menu/shingi/chukyo/chukyo0/toushin/1217067.htm, (参照 2020-09-01).
- 3) 松田岳士. 教学 IR の役割と実践事例－エビデンスベースの教育質保証をめざして. 教育システム情報学会誌. 2014, vol. 31, no.1, p. 19-27.
- 4) 独立行政法人大学改革支援・学位授与機構大学. “大学ポートレート”. <https://portraits.niad.ac.jp/>, (参照 2020-09-01).
- 5) 近藤伸彦, 松田岳士. 教学 IR における予測モデル活用の枠組み. 第 6 回 大学情報・機関調査研究集会会論文集. 2017, p. 42-47.
- 6) 船守美穂. デジタル技術は高等教育のマス化問題を救えるか? - MOOCs, 教育のビッグデータ, 教学 IR の模索. 情報知識学会誌. 2014, vol. 24, no. 4, p. 424-436.
- 7) 高松邦彦, 村上勝彦, 鷹尾和敬, 旭潤一郎, 桐村豪文, 伴仲謙欣, 野田育宏, 光成研一郎, 中村忠司, 中田康夫. 機械学習による中途退学の予測可能性. 第 6 回大学情報・機関調査研究集会会論文集. 2017, p. 60-65.
- 8) Murakami, K.; Takamatsu, K.; Kozaki, Y.; Kishida, A.; Bannaka, K.; Noda, I.; ASAHI, J.; TAKAO, K.; MITSUNARI, L.; NAKAMURA, T.; Nakata, Y. Predicting the Probability of Student Dropout through EMIR Using Data from Current and Graduate Students. Advanced 2018 7th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI) International Congress on. Institute of Electrical and Electronics Engineers (IEEE). 2018, p. 478-481. <https://doi.org/10.1109/IIAI-AAI.2018.00103>.
- 9) 高松邦彦, 村上勝彦, 鷹尾和敬, 村瀬有紀, 深川大, 旭潤一郎, 伴仲謙欣, 野田育宏, 光成研一郎, 中村忠司, 大森雅人, 中田康夫. 機械学習を用いた学力進捗予測の可能性. 第 7 回大学情報・機関調査研究集会会論文集. 2018, p. 48-53.
- 10) Takamatsu, K.; Murakami, K.; Oshiro, T.; Sugiura, A.; Bannaka, K.; Nakata, Y. Predicting the Probability of Student's Academic Abilities and Progress with EMIR and Data from Current and Graduated Students. 2019 8th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI) International Congress on. Institute of Electrical and Electronics Engineers (IEEE). 2019, p. 359-362.
- 11) Van Der Walt, S.; Colbert, S. C.; Varoquaux, G. The NumPy array: A structure for efficient numerical computation. Computing in Science and Engineering. 2011, vol. 13, no. 2, p. 22-30.
- 12) Hunter, J. D. Matplotlib: A 2D graphics environment. Comput. Sci. Eng. 2007, vol. 9, no. 3, p. 99-104.
- 13) Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Prettenhofer, P.; Weiss, R.; Dubourg, V.; Vanderplas, J.; Passos, A.; Cournapeau, D.;

- Brucher, M.; Perrot, M.; Duchesnay, E. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*. 2011, vol. 12, p. 2825-2830.
- 14) McKinney, W. Data Structures for Statistical Computing in Python. *Proc. 9th Python Sci. Conf.* 2010, vol. 1697900, no. Scipy, p. 51-56.
- 15) Wolpert, D. No free lunch theorems for search. *Most*, 1995, p. 1-38.
- 16) Cox, D. The Regression Analysis of Binary Sequences. *Journal of the Royal Statistical Society*. 1958, vol. 20, no. 2, p. 215-242.
- 17) Breiman, L. Random forests. *Machine Learning*. 2001, vol. 45, no. 2, p. 5-32.
- 18) 川嶋太津夫. 教学マネジメントと教育の質保証 (特集 大学教育の質的転換). *大学評価研究*. 2014, vol. 13, p. 5-18.
- 19) 岩崎保道, 宮嶋恒二, 蔭久孝政, 福島謙吉, 谷ノ内識. 中途退学の防止についての一考察. *高知大学教育研究論集*. 2016, vol. 20, p. 49-60.
- 20) 山本繁. 『中退予防』が大学存続の命運分ける: 大学の教育情報公開の時代. *大学マネジメント*. 2011, vol. 7, no. 8, p. 24-28.
- 21) 姉川恭子. 大学の学習・生活環境と退学率の要因分析. *経済論究*. 2014, vol. 149, p. 1-16.
- 22) 丸山文裕. 大学退学に対する大学環境要因の影響力の分析. *教育社会学研究*. 1984, vol. 39, p. 140-153.
- 23) 船戸高樹. 深刻化する退学者問題 全学的な取組みが求められるー上ー. *教育学術新聞*. 2007, 2279号 (7月4日).
- 24) 船戸高樹. エンロールメント・マネジメントの必要性ー下ー. *教育学術新聞*. 2007, 2280号 (7月11日).
- 25) 窪内節子. 大学退学とその防止に繋がるこれからの新入生への学生相談的アプローチのあり方. *山梨英和大学紀要*. 2009, vol. 8, p. 9-17.
- 26) 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*. 2016, vol. 5, p. 28-35.
- 27) 古曳牧人, 川邊讓, 岩熊史朗, 高岸百合子. 心理学部における中途退学の要因の検討. *駿河台大学論叢*. 2017, vol. 54, p. 73-83.
- 28) 西山慶太. マス型大学における中途退学者予測モデルの作成. *日本教育工学会研究報告集*. 2019, vol. 19, no. 3, p. 9-14.
- 29) 福島真司. 「総合的學生情報データ分析システム」の構築 山形大学におけるエンロールメント・マネジメントとインスティテューショナル・リサーチ. *情報管理*. 2015, vol. 58, p. 2-11.
- 30) 山本嘉一郎. エンロールメント・マネジメントを効果的に進めるための IR について. *京都光華女子大学研究紀要*. 2013, vol. 51, p. 89-98.
- 31) 橋本智也. “データに基づく大学生の中途退学防止策 (IR) のモデル構築: 日米の制度差に着目して”. *科学研究費助成事業データベース 2015年度実績報告書*, <https://kaken.nii.ac.jp/ja/report/KAKENHI-PROJECT-15H00090/15H000902015jisseki/>, (参照 2020-09-01).