

## 学習活動ログに基づいて早期支援が必要な学生を判別する教員支援方略の提案

### Proposal for a Faculty Support Strategy to Identify Students in Need of Early Assistance Based on Learning Activity Logs

中畠 康二\*      森崎 晃\*\*

Koji NAKAJIMA      Akira MORISAKI

#### 抄 録

本研究は、学習ログデータ分析により「支援を要する学習者」を予測し、その状況に対応した個別学生サポートを行うための方略を担当教員に提案するところまでを一括りとした教員支援フレームワークを設計・開発しようとするものである。本稿ではまず予備調査として、授業出欠情報、LMS アクセス回数ならびに GPA のデータを用いて学習ログ分析モデル構築の試行を行い、その構築方法について検討した。さらに、インスタクショナル・デザイン (ID) のモデルや理論を応用したサポートを提供するために、「支援を要する学習者」の状況を説明する要因の分類について検討した。

#### I. 背景と目的

コロナ禍を通して、大学では、オンライン授業をはじめとする ICT ツールの学習環境への活用が常態化した。その結果として、学修を取り巻く環境の多様性が広く認識され、ポストコロナでも、LMS (Learning Management System) を中心とした ICT ツールの活用が教育・学習方法の選択肢として持ちうるものとして捉えられている。ICT ツールを活用することにより、オンデマンド型の学習を含むオンライン学習を実現し、個々の状況に合わせて学習を進めることができるようになった。一方で、少子化に伴って、大学で学ぶ機会を求める人々が多様となったことから、大学における「学生の多様性」が言われて久しい。これに対応した教育の提供が求められており (中央教育審議会、2024)、大学教育では、学習環境を適切に設計し、適時に学習者に提供することが肝要となっている。多様な学習環境やツールを有効活用し、適材適所に提供されることにより、大学の教育の質を担保することが求められている。時を同じくして、大学が教育目的を達成するために管理運営を行う「教学マネジメント」が促進されている (中央教育審議会、2020)。ここでは、学修者本位の教育を実現するために様々なデータを分析し、改善に資することを目指す「教学 IR (Institutional Research)」の実践が必須と謳われており、各大学ではそのための取り組みが進められている。

これに関連して、教育改善の取り組みのために蓄積された学習ログデータを分析して改善に充て

---

\* 関西国際大学社会学部/高等教育研究開発センター 教育総合研究所学内研究員

\*\*株式会社リクルート 関西国際大学客員准教授

る「ラーニングアナリティクス (LA)」という研究分野がある (緒方, 2021)。学習環境に LMS をはじめとする ICT ツールを活用することは、個々の学習者の学習ログが蓄積されることを意味する。学習者の個別最適な学習環境や学習支援を提供するために、この学習ログデータを分析する LA の取り組みが推進されている。例えば、土橋 (2020) は、LMS の学習ログデータを分析して学習状況を可視化することで、学習者のつまづきを発見しようとする研究に取り組んでいる。島田 (2020) は、デジタル教材の視聴状況等をリアルタイムで分析して学習状況を把握し、教師にフィードバックする仕組みの構築についての研究を行っている。退学等のドロップアウトに至る恐れのある学生の早期予測を試みる研究は、国内では、岩崎 (2013)、姉川 (2014)、天野 (2016)、竹端ら (2016)、松居ら (2016)、高岡ら (2017)、石川ら (2023)、川名ら (2024)、Ohkawauchi et al. (2024) など、多くの研究成果が公開されている。機械学習を活用した研究では、学習ログデータから予測モデルを構築し、学生個々に適時の学習支援を行う近藤・畠中 (2015) の研究が挙げられる。また、学習ログデータから学習者の学習意欲の予測を試みる研究 (小原ら, 2021) や、機械学習を用いて退学予測を行い、エンロールマネジメントシステムを構築する研究がある (石川ら, 2023)。他方、国外においても、各国で同様の研究が現在までに活発に取り組まれている (e.g. Aulck et al., 2016 ; Vaarma et al., 2024 ; Yang et al., 2020)。

ただし、LA を活用した研究や実践を推進するためには課題も多い。例えば、データ分析のためには、機関における既存のシステムをデータ連携することが必要となり、このためのインフラ整備等のための技術的、費用的制約が発生することが考えられる。また、データ管理においては、プライバシー保護への対応が必要であり、個人情報の取り扱いにおける法令順守の徹底が必要となる。その他、収集したデータの分析作業における教員のデータリテラシーの問題や、分析結果の実践への適用のための仕組みづくりも課題となる。さらに、学習者支援の実践においては、教育・学習理論を適切に適用した学習支援設計が必要となるだろう。

これらのことを踏まえて、「支援を要する学習者」の状況に適した個別支援を提供するための「学修支援設計を行うこと」を最上位の到達目標に設定し、本稿では、そのための下位目標の構成を検討したうえで、これらの下位目標を実現するための手順について検討していく。つまり、「支援を要する学習者」への個別支援を提案するための方略を担当教員に提案するために、技術的・費用的制約が障壁とならない条件下で、「支援を要する学習者」の予測を目的とした学習ログデータの収集、分析、そして分析結果から予測モデルを構築するための考察を行うまでの手順について検討する。これは、学習ログデータを活用した予測モデル構築のための予備調査的位置づけとなる。

本稿ではまず、「支援を要する学習者」の個別支援のための「教育・学習理論を適用した学修支援設計」のフレームワークの考え方について示す。フレームワークは、学習ログデータから「支援を要する学習者」を予測し、教育・学習理論つまりインストラクショナルデザイン (ID) の知見を適用して学修支援設計した個別支援方略を教員に提供するところまでを一括りとしたものとなる。続けて、「支援を要する学習者」予測のための予備調査の結果について述べる。本研究では、機関の既存システムにおいて学習ログデータ連携の仕組みがまだ定型化・自動化されていない場合を想定し

ており、この予備調査では、まず現時点で収集できる幾つかの学習ログデータを活用して分析を行う。この分析では、学業のみならず、学修生活全般を対象とした学習者の「状況の分類」を予測するモデル構築を目指している。そのあとには、より学習者の状況に合った支援を担当教員が提供できるようにするために、「状況の分類」予測の確度を上げる方法に関する考察について記述し、次の検証作業のための今後の課題について述べる。

## II. 「教育・学習理論を適用した学習支援設計」のフレームワーク

本研究で提案を目指すフレームワークは、支援を提供することが有効と予想される学習者とその状況を予測する部分（以下、学習者予測段階とする）と、状況に合わせて当該学習者に対して提供する支援設計に関わる部分（以下、学習者支援段階とする）で構成される（図1）。このフレームワークは、学習者支援を行う教員を支援することを目的として提案する。

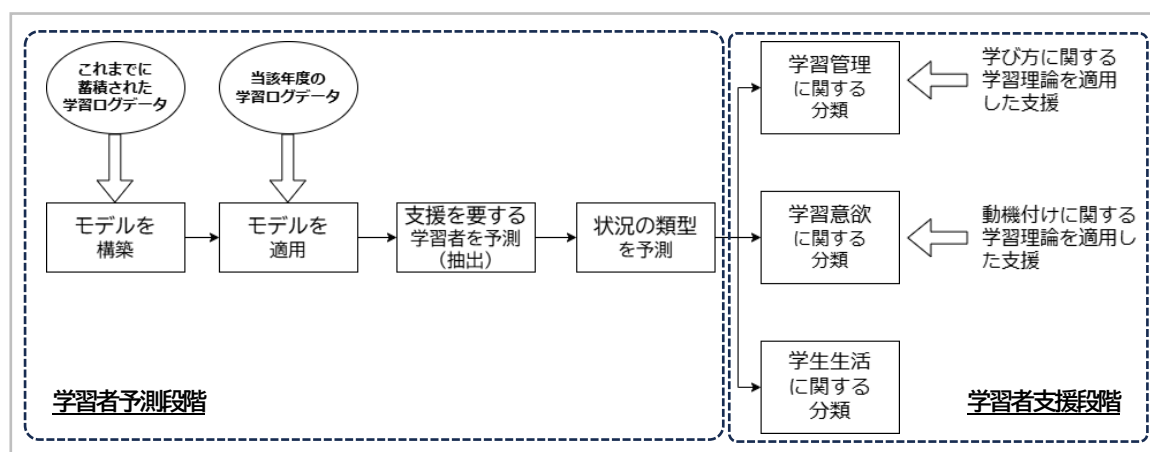


図1. 「教育・学習理論を適用した学習支援設計」のフレームワーク概念図

### 1. 学習者予測段階の概要

学習者予測においては、①当該機関にて運用されている既存のシステムをデータ連携すること、②そこから抽出されたデータの分析における教員のデータリテラシーの確保、③分析結果に基づく学習者支援方略の適用のための仕組みを整備することが必要となる。本研究では、これからこれらの事項について整備しようとする機関に有用な提案となることを目指す。今回は、K 大学における複数の既存システムから個人情報保護の対応処理を済ませたデータの提供を受け、予備調査として分析作業を行った。この調査のあと、その結果に基づいて課題抽出し、継続的に調査を行うことにより、十分な精度を持つ予測モデル構築ができるようになるという見立てにより計画を推進する。そこから得られる成果は、当該機関のシステムのデータ連携やデータ授受手順の確立方法を提案する裏付けとなる。本稿は、「予備調査」工程として、現行で授受できるデータを用いて、各変数間でどのような影響を及ぼしているかを計る作業の試行を実施する。これにより、今後の継続調査に向けての指針や課題を見出すことを目指す。

## 2. 学習者支援段階の概要

### 2.1 「支援を要する学習者」の支援の要因類型について

学習者に支援を提供する段階では、学習者がどのような支援を要する状況であるかを表すための類型を定義しておくことが肝要である。これにより、担当教員が当該学生に対して取るべき支援方法の選択が正しく行えるようになる。「支援を要する学習者」の支援の要因類型（以下、支援の要因類型）については、K 大学の運用によれば、①欠席が多い学生の原因調査において利用している分類、ならびに②退学・除籍時の原因調査での分類が設定されている。これらを合わせて大別すると、支援の要因類型は、（ア）学習意欲に関わるもの、（イ）学習管理に関わるもの、（ウ）それ以外のものとなる。これを支援の要因類型の原案とする（表1）。支援の要因類型は、本研究を通じて検討を繰り返し、その分類を明確化していく。なお、このフレームワークでは、学習活動と学習意欲に関わるものを対象とし、それ以外のもの（経済的要因など）は専門部局における諸支援制度に託すこととする。

### 2.2 教育・学習理論の知見の適用について

#### 2.2.1 学習意欲の支援

学習者への支援方略がその類型に適したものとなるようにするために、教育・学習理論の知見を適切に適用することが有効な手順となる。学習意欲の支援においては、学習者の学習意欲を阻害する要因を分析する方法を教員が学習者に伝授できるような教員支援を提案する。学習者の学習意欲が「なぜ下がっているのか、なぜ下がったのか、なぜ高まらないのか」について、その要因を分析し、その結果に基づいた対応方法を講じることができるようにする授業設計モデルを適用する。例えば、現在の学習意欲の状態を「注意・関連性・自信・満足感・継続意志」の5要因による分類のうち、いずれに該当するかを分析し、処方的に対応方策を検討することを促す「ARCS-V モデル（ケラー, 2010 ; Nakajima et.al, 2013) 」が活用できる（表2）。

#### 2.2.2 学習管理の支援

学習管理の支援においては、学習者が自分で学習計画の管理をできるようになるような学習者支援を提供することを目指した教員支援を提案する。「どこまでできていて、このあと何をするか、いつまでにするか、困ったらどうするか（誰に頼るか）」を学習者自身が明らかにできるようにする方法を学習者に伝授するために、教育・学習理論の知見を適用する。例えば、学習目標・学習評価方法・学習内容が相互に対応していることを認知できるようにする「メーガーの三つの質問（Mager, 1997)」、各科目の「入口・出口」の構造と、入口・過程・出口で実施される三つの評価方法の意味（鈴木, 2002)、一つひとつの学習目標は分類することができ、いずれの分類に当たるかでそれに対応した学習方法がわかる「学修成果の5分類（ガニェら, 2007) 」などを活用することにより、学習者が自分の現在地を知り、自己調整学習が可能になる。

学習管理の支援と学習意欲の支援を複合的に捉える場合、学習成果（どれだけ学べたか）を、「課題に必要な時間＝課題への適性×授業の質×授業理解力」ならびに「課題に費やした時間＝学習の

機会×学習持続力」の対比によって表す「キャロルの学校時間モデル（Carroll, 1963）」を適用することにより、学習者支援の介入方法を検討することができる。

表 1. 支援の要因類型と支援方略に適用する教育・学習理論の案

	要因類型		支援方略に適用する 教育・学習理論の知見
	欠席の原因より	退学・除籍理由より	
学習意欲に 関わるもの	学習意欲	就学意欲の低下 進路変更（他教育機関） 進路変更（就職）	ARCS-V モデル など
学習管理に 関わるもの	生活習慣・部活・就活	—	入口・出口 学修成果の 5 分類 など
それ以外	経済的・疾病・精神的	経済的困窮	—

表 2. ARCS-V モデルと支援方略の指針

分類	下位分類	支援方略の指針
Attention 注意	A-1：知覚的喚起 A-2：探究心の喚起 A-3：変化性	目を向かせる 注意を惹く
Relevance 関連性	R-1：親しみ易さ R-2：目的指向性 R-3：動機との一致	自分と関係があると思わせる やりやすいやり方で学ばせる
Confidence 自信	C-1：学習要求 C-2：成功の機会 C-3：コントロールの個人化	無理のない工程で 成功の体験をさせながら
Satisfaction 満足感	S-1：自然の結果 S-2：肯定的な結果 S-3：公平さ	公平感や結果の納得感 努力の見返りがある
Volition 継続意志	V-1：実行計画の具体化 V-2：適切な制御 V-3：自己モニタリング	自分で自分の活動を管理 必要に応じて他者の支援を求 める選択肢もある

### III. 「支援を要する学習者」を予測するための予備調査

#### 1. 予備調査の考え方

本研究で提案を目指す「教育・学習理論を適用した学習支援設計」のフレームワークにおいては、学部別の別を問わない汎用性のあるものとすることを目指しているが、現在のフェーズは「予備調査」であることから、一つの学部をサンプルとして取り上げ、分析調査の対象とした。このたび学習ログデータの提供を得られた K 大学では、複数ある学部のうち、①対象学生数が相対的に多い学部であること、②著者が必要に応じて学部の実情を確認できる協力者（教員）が得られる学部であることを根拠として、文系 A 学部のデータをサンプルデータとすることとした。また、新型コロナ感染症の影響から非対面授業の形式での受講を強いられ、学習環境や学習方法のパラダイムが結果的に

それ以前のものから転換することとなった 2020 年度以降とそれ以前で、大学生を取り巻く環境は大きく異なることから、今回の分析調査では、2020 年度以降 2024 年度までの期間に在籍している学生を対象とし、年度末（2024 年度のみ前期末）時点のデータを対象とすることとした。なお、サンプルデータは、個人情報保護の観点から氏名等個人情報には含まず、キーコードとなる学籍番号を、該当する学生が特定できない変換コードに置換処理したうえで分析に利用している。なお、本研究は、関西国際大学研究倫理審査委員会により承諾されていることを付記しておく（受付番号 R6-31）。

## 2. 予備調査の方法：学習ログデータ分析の手順

予備調査では、試行を主旨として、現時点で利用することができるデータから、①総出席率（当該期間のすべての履修科目を合算した出席率。以下、出席率とする）、②LMS アクセス回数（当該期間中に LMS にログインした回数の合計を表す）が、③学修成果を表す GPA に対してどのような影響を及ぼしているかを分析することとした。この際、サンプルを 2 群に分けて分析結果を対比することを試みる。サンプルの分け方については、次のとおり 3 種類とした。

（ア）結果として退学等ドロップアウトに至った群と至らなかった群

（イ）GPA1.5 以上群と 1.5 未満群

（ウ）「初動対応あり」群と「初動対応なし」群（※）

（※）K 大学では、ある学生が、履修登録科目について学期始めの 5 回の授業のうち 2 回以上欠席した場合に「初動対応が必要」と判断され、ゼミ担当教員による面談（欠席理由の聞き取りと助言の提供）が実施される運用となっている。この運用によって「初動対応が必要」と判断された・されなかった者を「初動対応あり・なし」と記述する。

（ア）～（ウ）のそれぞれの群について、①出席率、②LMS アクセス回数を説明変数、③GPA を目的変数として重回帰分析を行えるかを検証したうえで、妥当と思われる分け方の群について重回帰分析によるモデル構築を試みる。また、群間の比較を行って考察し、知見を引き出すことを試みる。

## IV. 予備調査の結果

### 1. 重回帰分析のための分析対象の検証

上記（イ）は、「GPA1.5 以上」群のサンプル数が（N=131）であり、「GPA1.5 未満」群が（N=971）、（ウ）では、「初動対応あり」の群が（N=147）であり、「初動対応なし」の群が（N=955）であった。群間でサンプルサイズに差はあるが、いずれも数量として十分なデータがあり、分析対象となると判断した。一方、（ア）では、ドロップアウトに至った者（N=34）が、至らなかった者（N=1068）に対して極端な差があるため、分析に適さないと判断し、（ア）を分析対象から外した。次に（イ）について検証すると、「GPA1.5 以上」群について、説明変数である出席率と LMS アクセス回数の相関係数は 0.440 と比較的 low、多重共線性のリスクは低いと判断されたが、GPA を目的変数として重回帰分析した場合、説明力が弱い（ $R^2=0.224$ ）ことから、（イ）も分析・考察の対象から省き、本稿では、（ウ）についての分析結果を記述して考察の材料とする（表 3・4）。

表 3. 「初動対応あり」者の学習ログデータの基本統計量

変数	N	平均値	標準偏差	最小値	最大値
出席率 (%)	147	73.71	13.24	12.10	90.70
LMS アクセス回数	147	487.08	263.19	43	2103
GPA	147	2.09	0.89	0	3.67

表 4. 「初動対応なし」者の学習ログデータの基本統計量

変数	N	平均値	標準偏差	最小値	最大値
出席率 (%)	955	75.80	13.48	4.6	98.6
LMS アクセス回数	955	392.82	276.18	2	2079
GPA	955	2.57	0.80	0	4

## 2. 出席率と LMS アクセス回数が GPA に及ぼす影響

### 2.1 「初動対応あり」群の場合

「初動対応あり」群について、出席率と LMS アクセス回数を説明変数として、GPA を目的変数として重回帰分析を行った。出席率と LMS アクセス回数の VIF は 1.354 と低く、多重共線性のリスクは低いと判断された。重回帰分析の結果、出席率 ( $\beta = 0.799$ ) は、GPA にポジティブな影響を与える要因であり、LMS アクセス回数 ( $\beta = 0.101$ ) は小さいながら統計的には有意であることが示された (表 5 ならびに図 2)。なお、このモデル全体の説明力 ( $R^2$ ) は 0.732 であった。GPA には、出席率がより重要な要因であることが示唆された。

表 5. 「初動対応あり」者の学習ログデータに基づく重回帰分析の結果 (N=147)

変数名	GPA		下限	上限
出席率	0.799	**	0.700	0.899
LMS アクセス回数	0.101	*	0.002	0.201
$R^2$	0.732	**		

(\*\*  $p < 0.01$ , \*  $p < 0.05$ )




図 2. 出席率ならびに LMS アクセス回数と GPA の分布図：「初動対応あり」者の場合

## 2.2 「初動対応なし」群の場合

続いて、「初動対応なし」群について、出席率と LMS アクセス回数を説明変数として、GPA を目的変数として重回帰分析を行った。出席率と LMS アクセス回数の VIF は 1.142 と低く、多重共線性のリスクは低いと判断された。重回帰分析の結果、出席率 ( $\beta = 0.631$ ) は、GPA にポジティブな影響を与える要因であるが、「初動対応あり」群と比較するとその影響は小さいことがわかった。また、LMS アクセス回数 ( $\beta = 0.118$ ) は「初動対応あり」群と同じく小さいながら統計的には有意であることが示された (表 6 ならびに図 3)。なお、このモデル全体の説明力 ( $R^2$ ) は 0.464 であった。

表 6. 「初動対応なし」者の学習ログデータに基づく重回帰分析の結果 (N=955)

変数名	GPA		下限	上限
出席率	0.631	**	0.581	0.680
LMS アクセス回数	0.118	**	0.068	0.168
$R^2$	0.464	**		

(\*\*  $p < 0.01$ , \*  $p < 0.05$ )




図 3. 出席率ならびに LMS アクセス回数と GPA の分布図：「初動対応なし」者の場合

## V. 考察

予備調査の結果から、「初動対応なし」群に比較して「初動対応あり」群の方が、出席率による GPA への影響が強く、出席率が上がると GPA に好影響が出ることが示された。また、LMS アクセス回数は、両群において同様に、弱いながらも統計的に有意な正の影響があることが示唆された。他方、「初動対応あり」群に比して「初動対応なし」群は説明力が低いことが示された。説明力を高めるには、学業以外の要因を含む、他の要因を考慮して分析する必要がある。

これらのことから得られる含意として、今後取り組むべきこととして次のようなことが考えられる。

- (1) 初動対応を行い、出席率向上に取り組むことが GPA 向上に有効であると考えられるため、より効果的な初動対応となるよう、方策を改良すること



- (2) LMS の利用が高まることが僅かながら GPA に影響があることから、より正の影響の高まる LMS 利用を喚起できるよう、授業設計の中での LMS の有効活用について検証すること
  - (3) これらのことを促進していくために、より多くの説明変数となる学習ログデータを集め、活用できるよう分析計画を立てること
- 以上のことをもとに、今後の学習ログデータの活用に関する指針について検討した。

## 1. 初動対応を強化するための改善方策

### 1.1 学習者の状況を表す「支援の要因類型」の検討

本研究で提案を目指すフレームワークでは、学習者の（支援を要すると思われる）状況を予測して支援の要因類型を見定め、その別に基づく個別支援方略を的確に提供するために教育・学習理論の知見を適用しようとする。初動対応において学習者の状況を聞き取り、状況に基づいた支援方略をより的確に設計するには、「支援の要因類型」は適当な粒度と種類で分類されていることが肝要であるが、現行の分類（表 1）は、支援方策を明らかにするには細分化を要する。「支援の要因類型」の分類を精査するためにはデータサンプル数を増やして、①欠席が多い学生の原因調査、ならびに②退学・除籍等ドロップアウト者の原因調査、をより精緻に分析することが必要である。

### 1.2 調査・分析の方法について

予備調査では、既存システムのデータ連携がまだ確立されていない状況において活用可能なデータを用いて分析を始め、予測モデルを構築することを目指した。今後、分析結果を信頼できるものにしていくためには、活用すべきデータの種類（説明変数）を見定めるための試行が必要となる。学習活動に関連するものでは、出席状況に関するデータや LMS での学習活動の履歴などを時系列で見ることができるようデータ分析することが必要と考えられる。また、学業以外の学生生活に関する、クラブ・サークルへの参加等、他者との関わりに関する情報などについてのデータを用いて分析することを検討する必要がある（表 7）。併せて、個々の学生が抱える「支援を要する」要因を具体的に説明する情報（教員面談記録に基づく原因の記述など）が活用できるよう、機関内でのデータ提供の仕組みの整備が必要となると考えられる。

今後の追加分析により、予測モデルを提案できた際には、例えば、大学 1 年生の春学期（前期）の期間中のある時点でこの予測モデルを適用して分析することにより、支援を要することになる学生をタイムリーに予測できるようになる。この予測をもとに、初動対応等の中で、ゼミ等担当教員は未然の内に支援を提供できるようになることが期待される。

なお、分析調査における外れ値の扱いについては、本研究の文脈においては「外れ値」該当者の状況を把握することが予測モデルから考察するうえで有用な情報となる可能性があることから、個別データをより詳しく質的に調査することが必要であると考えられる。また、機械学習を活用した分析手法を今後取り入れていくことは、そのための環境整備とともに課題として捉えておく必要がある。

表 7. 説明変数・目的変数の候補となる要因一覧

データの区分	学習関連	生活等、学業以外に関する事項
プロセス	初年次の初動出席状況 出席不良者への指導面談有無 LMS 利用状況（アクセス回数・課題提出・テスト受験・ディスカッション発言回数など）	経済面 人間関係 個別面談
結果	出席率 GPA	退学等の有無

## 2. LMS に関する検証方法についての検討

予備調査では、対象者の各年度での LMS へのアクセス回数データを入手し、分析に活用した。LMS は、特にコロナ禍以降、学校教育における有効な学習ツールとして認知され、広く活用されるようになっており、対面・非対面に関わらず、学習活動の中で重要な役割を担っている。ここで行われる学習活動の履歴は、当該学習者の状況を確認するための有効な手掛かりを提供するものと考えられる。

また、LMS アクセス回数は、GPA に対してポジティブな影響を及ぼすことが示されたが、その影響は非常に弱いことが示された。LMS による影響を高めるためには、変数に適用するための適切なデータの種類の検証しながら調査を継続することが必要である。LMS における学習ログを活用した分析をより信頼性のあるものとするためには、検討すべき二つの課題があると考えられる。

### 2.1 分析対象とする LMS の学習ログデータの種類の再検討

LMS での学習ログの分析においては、アクセス回数だけでなく、その利用内容（資料の閲覧状況、課題提出状況、小テスト受験状況、ディスカッション参加状況などを時系列で集計した情報）を新たな変数として加えて分析すれば、適切なタイミングで的確な予測を行うことができるようになることが期待できる。また、時系列のデータを分析することにより、LMS 活用が出席率や GPA、またはドロップアウト有無にどのような影響を及ぼすのか、時期を加味した分析ができるため、時系列に基づく予測モデル構築ができるようになるものと考えられる。

### 2.2 各科目での LMS の授業運用方法に関する調査分析

LMS アクセス回数の GPA への影響が統計的に有意ながら非常に弱かった背景として、科目担当教員による授業での LMS 運用の方法や手順に要因があったことも可能性として考えられる。つまり、LMS 上の学習環境が、1 年生に十分配慮されておらず、教材が学びにくいものだった場合、学生が学習内容に関心を高めることが妨げられることが考えられる。また、科目担当教員や他の受講生とのポジティブな「つながり」を感じられる機会が整備されていない場合、LMS の有効性を十分に発揮できていないものと考えられる。このため、教員による LMS での授業運用の状況についても調査し、学生のプロセスや結果との関係性を分析する必要がある。

## VI. まとめ

本論文では、学習ログデータ分析により「支援を要する学習者」を予測し、その状況に対応した個別学生サポートを行うための方略を担当教員に提案するところまでを一括りとした教員支援フレームワークを設計・開発することを目的として、予測モデル構築を目指した学習ログ分析の予備調査を行い、対象とするデータの種類や分析の方法などについて検討した。

予備調査では、既存システムのデータ連携をすることなどの環境的な制約のない、現時点で利用可能なデータの分析を進めた。K大学のA学部における4年度分のデータを参照し、授業出席率、LMSアクセス回数のデータとGPAを用いて、「初動対応あり・なし」の2群それぞれについて重回帰分析して考察を加えた。その結果、「初動対応なし」群に比較して「初動対応あり」群の方が、出席率によるGPAへの影響が強く、LMSアクセス回数は両群においても同様に非常に弱いながらも統計的に有意な影響があることなどが示された。信頼に足る予測モデル構築を行うには、新たな説明変数を追加してより詳細な分析を繰り返す必要があることがわかった。

他方、学習者に合った効果的な個別支援が提供できるよう、担当教員に支援方略を提案するためには、「支援を要する学習者」の状況を説明する「要因類型」の検討がさらに必要であると考えられるため、今後、分析対象の範囲を広げ、時系列で精緻に分析することにより、1年生の入学後の然るべき時期に予測モデルを適用し、適切な時期に的確な内容の支援提供ができる方略をフレームワークとして担当教員に提供できるよう仕組みづくりの提案を目指す。

## 謝辞

本研究はJSPS科研費基盤研究(C)24K06346の助成を受けたものです。

## 参考文献

- 1) Carroll, J.B., A model of school learning. *Teachers College Record*, 64:723-733, 1963.
- 2) Aulck, L., Velagapudi, N., Blumenstock, J., West, J., Predicting Student Dropout in Higher Education, ArXiv., 16-20. <https://arxiv.org/abs/1606.06364>, 2016.
- 3) Mager, R.F., How to turn learners on...without turning them off. *Atlanta : Center for Effective Performance*, 1997.
- 4) Nakajima, K., Nakano, H., Watanabe, A., & Suzuki, K., Proposal for the Volition Subcategories of the ARCS-V Model. *International Journal for Educational Media and Technology*, 7 (1), 59-69, 2013.
- 5) Ohkawauchi, T. , Tanaka, E., Predicting Student Dropout Risk Using LMS Logs, *Data Science and Institutional Research*, 4, 1-8, 2024.
- 6) Vaarma, M. & Li, H., Predicting student dropouts with machine learning: An empirical study in Finnish higher education, *Technology in Society, Elsevier*, 76(C), 1-10, 2024.
- 7) Yang, Y., Wen, Z., Cao, J., Shen, J., Yin, H., Zhou, X., Early Prediction of At-risk

Students with Online and Offline Learning Behaviors, arXiv preprint1-16, 2020.

- 8) 姉川恭子, 大学の学習・生活環境と退学率の要因分析, 九州大学大学院経済学会経済論究 149, 1-16, 2014 年
- 9) 姉川雄大, 大学生の退学要因の考察: 社会科学系学部のケース, 大阪経大論集 71(5), 1-13, 2021 年
- 10) 天野直紀, 成績と教育支援システム利用履歴からのドロップアウト予測, 日本 e-Learning 学会誌 16, 83-91, 2016 年
- 11) 石井貴春, ドロップアウトと成績に関する先行研究の整理, ビジネス・ブレイクスルー大学レビュー, 6 (2), 105-119, 2020 年
- 12) 石川千温・石本翔真, 機械学習を用いた退学予測に基づくエンrollmentメントマネジメントシステムの構築, 情報処理学会論文誌『デジタルプラクティス』4 (2), 1-8, 2023 年
- 13) 岩崎保道, 大学における休・退学防止の検討ー学内組織連携型の学生支援策に注目してー, 関西大学高等教育研究, 6, 81-86, 2013 年
- 14) 緒方広明, ラーニングアナリティクス: 教育ビッグデータの分析による教育変革, Nextcom, 45, 12-21, 2021 年
- 15) 小原百々雅, 梶浦照乃, 田村みゆ, 秋信有花, 倉光君郎, 学習意欲の予測モデル構築の経験に基づく学校教育における教育 AI の利活用に向けた考察, 情報教育シンポジウム論文集 2021, 138-142, 2021 年
- 16) ガニエ, R.M.ほか, 『インストラクショナルデザインの原理』北大路書房, 2007 年
- 17) 川名芽依, 小糸麻結, 小川賀代, 学習ログを用いた実習授業におけるドロップアウト兆候者の検出の検討, 情報処理学会研究報告 2024-CLE-42, 21, 1-5 (WEB ONLY), 2024 年
- 18) ケラー, J.M., 『学習意欲をデザインする: ARCS モデルによるインストラクショナルデザイン』, 北大路書房, 2010 年
- 19) 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 33(2), 94-103, 2016 年
- 20) 島田敬士, 大学教育における学習分析の活用事例, 情報処理学会論文誌『教育とコンピュータ』6 (2), 16-24., 2020 年
- 21) 鈴木克明, 『教材設計マニュアル』, 北大路書房, p. 34, 2002 年
- 22) 高岡祥子, 中井あづみ, 杉山恵理子, 野末武義, 清水良三, 学生の修学データを活用した多角的な学生支援の提案ー要注意学生の早期発見と支援, 明治学院大学心理学紀要 27, 81-93, 2017 年
- 23) 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』5, 28-35, 2016 年
- 24) 立石慎治, 小方直幸, 大学生の退学と留年, 高等教育研究 19, 123-143, 2016 年
- 25) 中央教育審議会教学マネジメント指針, 2020 年 (2024 年 12 月 13 日閲覧)

[https://www.mext.go.jp/content/20200206-mxt\\_daigakuc03-000004749\\_001r.pdf](https://www.mext.go.jp/content/20200206-mxt_daigakuc03-000004749_001r.pdf)

- 26) 中央教育審議会急速な少子化が進行する中での将来社会を見据えた 高等教育の在り方について (中間まとめ), 2024 年 (2024 年 12 月 13 日閲覧)  
[https://www.mext.go.jp/b\\_menu/shingi/chukyo/chukyo4/053/toushin/1411360\\_00001.html](https://www.mext.go.jp/b_menu/shingi/chukyo/chukyo4/053/toushin/1411360_00001.html)
- 27) 土橋 喜, エンゲージメントヒートマップ-Moodle ログのデータマイニングによる学習傾向の可視化, 情報教育シンポジウム論文集 2020, 23-30, 2020 年
- 28) 松居辰則, 吉田自由児, 決定木学習を用いた学習履歴データからの退学者予兆の試み, 教育システム情報学会全国大会予稿集, 403-404, 2016 年
- 29) 矢野博之, 辻 孝弘, 林 明子, 大学退学についての基礎研究, 大妻女子大学人間生活文化研究, 29, 2019 年
- 30) 葛本幸枝, 安田節之, 大学生の中退意図の測定, 生涯学習とキャリアデザイン 21(1), 65-74, 2023 年
- 31) 葛本幸枝, 安田節之, リスク・予防要因モデルに基づく大学生の中退意図の検証, 生涯学習とキャリアデザイン 22(1), 45-62, 2024 年

## Abstract

This study aims to design and develop a teacher support framework that predicts “learners in need of support” by analyzing learning activity log data and proposes strategies to teachers for providing individualized support to students in response to their situations. In this paper, as a preliminary study, we conducted a trial of building a learning log analysis model using data on class attendance, LMS access frequency, GPA, and whether or not students withdrew from University. In addition, we examined the categorization of factors that explain the situation of “learners in need of support” to apply instructional design (ID) models and theories to provide support.