

オンライン講座におけるドロップアウト軽減のための
学習行動分析に関する研究

2022年3月

古川 雅子

オンライン講座におけるドロップアウト軽減のための
学習行動分析に関する研究

筑波大学

図書館情報メディア研究科

2022年3月

古川 雅子

概要

オンライン講座におけるドロップアウト軽減のための学習行動分析に関する研究

学術情報や教育情報をオープン化し、インターネット上で流通させようという取り組みが進んでいる。その中で、大規模公開オンライン講座（以下、MOOC）は、対象者を限定せず誰でも大学レベルの教育を受けることができるオンライン講座として、世界各地でサービスが提供され、広く社会から支持を得ている。たとえば、MOOCの代表的なプラットフォームである Coursera や edX の学習者数は、2016年には3,000万人以上に達しており、社会全体に大学レベルの教育機会を提供することに貢献している。国内においても JMOOC が2019年には累計340の講座を提供し、学習者の数は100万人を超えている。しかし、MOOCでは、大規模な学習者数が期待できる反面、講座を最後まで修了できずに途中でドロップアウトする学習者が多く、その修了率は10%程度と低いという問題がある。これは、MOOCにおいて解決すべき問題の1つである。

一方で、MOOCのようなオンライン講座では、学習者の膨大な学習行動に関連するログ（学習ログ）がシステム上に蓄積されることから、これらを収集・分析することで、学習における問題点を解決できる可能性がある。学習ログを収集、分析することで、学習における問題点を解決し教育改善に繋げようとする研究は、ラーニングアナリティクス（Learning Analytics, LA）と呼ばれ、学習行動の分析や、学習者の興味や能力に応じた教材の推薦等、様々な研究が行われている。また、学習行動や成績等の特徴によって学習者を分類する研究や、学習行動から、最終的にドロップアウトするか否かを予測することに取り組んだ研究などが行われている。

しかしながら、ドロップアウトを軽減しようとする場合、単純にドロップアウトを予測するだけでは十分ではない。MOOCの学習者は多様であり、また、必ずしも、常に、学習者のサポートに必要となる十分な時間や、人手、コストが用意できるとは限らないため、学習者に応じて適切なサポートを行うことが必要になってくる。たとえば、良い成績で合格するであろう学習者は、必ずしもサポートを必要としないと考えられる。また、MOOCで多く見られる Tasters と呼ばれるような、講座を少しだけ覗いてみることを目的で、学習活動をほとんど行わない学習者は、必ずしもサポートを望んでいないだろう。一方、サポートをすることで、不合格から合格に導けるであろう学習者に対しては、積極的にサポートを行う必要がある。このような学習者に応じたサポートを実現するためには、多くの学習者の中から、サポートすべき学習者クラスタを見い出す必要がある。

以上のような背景に基づき、本研究では、学習ログを分析することで、多様な学習者を分類し、その特徴を明らかにするとともに、サポートすべき学習者クラスタを見い出すために必要となる、学習の早い段階での学習者クラスタの推定を実現するための方略を明らかにすることを研究の目的とする。

具体的な研究課題は、以下のようになる。

課題 1: 学習ログを分析し、学習成果（学習終了時の点数/可否）を予測するためにどのような特徴量が有用であるかを明らかにする。

課題 2: 学習者を学習終了時の点数によりクラスタリングし、それぞれの学習者クラスタの特徴を明らかにする。

課題 3: 課題 1 の学習者特徴量を用いて、課題 2 の学習者クラスタを推定し、その精度を明らかにする。

課題 1, 課題 2 は、それぞれ、現在でも活発に研究が行われている分野であり、これらの成果は、課題 3 を解決するための基礎となる。課題 3 は、ドロップアウトするであろう学習者の中から、サポートにより合格に導くことができる可能性の高い学習者クラスタを選び出し、選択的にサポートを行うことを実現するために必要となる手法を開発しようとするもので、この点が本論文の主眼となる。

本論文の構成および各章の概要は次の通りである。

第 1 章は、研究の背景についてまとめている。MOOC において解決すべき問題の 1 つとしてドロップアウトの問題があることを述べるとともに、学習者の膨大な学習ログを収集、分析することで、学習における問題点を解決できる可能性があることを述べている。また、本研究の目的と、解決すべき 3 つの課題を示している。

第 2 章では、本研究に関連する研究を 3 つに分類しまとめている。「ラーニングアナリティクス」の研究例を挙げ、主な研究テーマには、学習行動の分析や、学習者の興味や能力に応じた教材の推薦、学習成果の予測、学習者特徴の分類等があることを述べている。また、本研究と関連の深い、「学習成果の予測」、「学習者特徴の分類」に関連する研究の具体例についてまとめるとともに、従来研究に基づき、本研究で用いる手法や方向性について述べている。

第 3 章は、課題に取り組むための予備的な検証として行った学習ログの分析について述べている。研究データ管理 MOOC 講座を対象とし、映像視聴ログを用いた学習者のクラスタリングを行い、再生エラー等による外れ値の影響によって、学習者が数多くの小さなクラスタに分割されてしまう場合があること、映像の視聴数を、1 日 1 回以上視聴した場合に 1 回とカウントすることで、それを回避することができることを明らかにした。また、概ね映像の視聴数が多いクラスタほど合格者の割合が大きくなるものの、最も視聴数が多いクラスタの合格率が最も高くなるわけではないことなど、学習者の特徴の違いを明らかにした。本章の結果に基づき、以降の分析では、映像の視聴数については、1 日 1 回以上視聴した場合に 1 回とカウントして処理を行っている。

第 4 章は、「課題 1: 学習ログを分析し、学習成果（学習終了時の点数/可否）を予測するためにどのような特徴量が有用であるかを明らかにする」に対応する章であり、プログラミング MOOC 講座を対象として、映像の視聴行動とアンケートから学習者の特徴を抽出し、成績との関連を分析した。この結果、全体的に点数が高い方が映像視聴が多いこと、

点数が高い学習者は、定期的に学習していること、点数が低い学習者は受講開始が遅いことなどが明らかになった。また、学習開始からN週後までに得られた特徴量をもとに、重回帰分析を用いて、学習終了時の点数および合否の推定を行い、抽出した特徴量の有効性を検証した。その結果、点数の予測結果は十分精度が高いとは言えなかったものの、合否の推定については、3週目以降では80%以上の精度で行えることを明らかにした。また、開始アンケートから得られる、年齢やプログラミングスキル等の情報を利用することで、学習開始から3週目までの点数の予測精度を向上できることを明らかにした。以上の結果から、映像の視聴数、視聴間隔、視聴開始日、年齢、プログラミングスキルといった特徴量は、学習者の学習終了時の成績を予測するために有効な特徴量であることが明らかになった。

第5章は、「課題2: 学習者を学習終了時の点数によりクラスタリングし、それぞれの学習者クラスタの特徴を明らかにする」、「課題3: 課題1の学習者特徴量を用いて、課題2の学習者クラスタを推定し、その精度を明らかにする」に対応する章であり、小テストの点数パターンに基づき学習者をクラスタリングし、それぞれの学習者クラスタの特徴を明らかにするとともに、その結果をもとに、それぞれの学習者の属するクラスタを推定する手法の提案を行った。第4章と同じ学習データを対象に、小テストの点数パターンに基づき学習者をクラスタリングし、クラスタごとの学習行動を比較することで、小テストの合計点が高いクラスタは映像の視聴数が多く、短い間隔で繰り返し映像を視聴しているといった特徴を明らかにした。次に、それらの特徴をもとに学習者の属するクラスタを推定することを試みた。学習開始からN週後までの特徴量をもとに、ランダムフォレストを用いたクラスタの推定を行い、3週目以降では、概ね7割を超える精度で、属するクラスタの推定ができることを明らかにした。また、学習終了時の合格、不合格については、90%という高い精度で推定ができることを示した。

第6章では、結論として、全体をまとめ、今後の課題について述べている。

設定した3つの課題を解決することで、学習開始から早い時期に、学習終了時の学習者クラスタおよび合否をある程度高い精度で推定できるようになった。これにより、不合格になるであろう学習者を予測し、更に、その中から、全ての学習活動が低いレベルである Tasters と呼ばれる学習者ではない、サポートをすることで不合格から合格に導けるであろう学習者を見い出すことができるようになる。このような学習者クラスタに対して、より積極的にサポートを行うことで、ドロップアウトを軽減できることが期待される。本研究で提案した学習者クラスタの推定手法は、それぞれの学習者に応じた最適なサポートを実現するための基礎の1つとなると考えられる。

一方、今後、更に、検証すべき課題も残っている。本研究の成果の一般化については、学習者がどのようなクラスタに分割されるかは、講座の目的や修了条件、難易度等、様々な条件によって変化すると考えられる。一方で、学習者のクラスタには、ある程度の類似性も見られ、多数の講座に対して、今回と同様の検証を行っていくことで、より汎用

性の高いクラスタ分けやその推定を行える可能性があり，この点について今後も検証を重ねていく．また，学習成果の予測を実際の教育の場面で利用しようとする場合，誤った予測により，学習に不利益が生じた場合の責任はどうなるのかといった，LAの倫理的な側面についても，同時に，考えていく必要がある．

インターネット上で様々な教育コンテンツが流通，利用される環境の中で，学習行動の分析により学習者クラスタを推定し，学習者に応じたコンテンツの提供やサポートを実現することができれば，オンライン講座の更なる利用の促進に繋がっていくものと考えられ，本研究が，その一助となることを期待する．

Abstract

A Study on Learning Behavior Analysis for Reducing Dropout in Online Courses

There is a growing trend to open up academic and educational information and distribute it on the Internet. In this context, Massive Open Online Courses (MOOCs) are being offered worldwide as online courses that allow anyone to receive university-level education without limiting the target audience. The number of learners on Coursera and edX, the leading MOOC platforms, reached more than 30 million in 2016. In Japan, JMOOC has provided a total of 340 courses in 2019, and the number of learners has exceeded one million. However, while MOOCs are expected to have a large number of learners, there is a problem that many learners drop out of the course without completing it, and the completion rate is as low as 10%. This is one of the problems that should be solved in MOOCs.

On the other hand, in online courses such as MOOCs, a large number of logs related to learners' learning behavior (learning logs) are accumulated on the learning systems. By collecting and analyzing these logs, we may be able to solve the problems in learning. Research that attempts to solve problems in learning and improve education by collecting and analyzing learning logs is called Learning Analytics (LA), and various studies are being conducted, such as recommending teaching materials according to ability, classifying learner characteristics, and predicting learning outcomes.

However, when trying to reduce dropouts, simply predicting dropouts is not enough. MOOC learners are diverse, and it is not always possible to provide sufficient time, manpower, and costs to support all learners. Therefore, it is necessary to provide appropriate support according to the learner. For example, learners who are likely to pass the course with good grades will not necessarily need support, and learners who are likely to be Tasters, who have poor learning activities in MOOCs, will not necessarily want support. On the other hand, learners who are likely to be able to move from failing to passing by providing support may need to be actively supported. In order to realize such support according to the learner, it is necessary to find a learner cluster to be supported from among many learners.

Based on the above background, the purpose of this research is to classify various learners by analyzing their learning logs, to clarify their

characteristics, and to clarify a strategy for estimating the learner clusters at an early stage of learning, which is necessary for finding the learner clusters to be supported.

The specific research tasks are as follows.

Task 1: Analyze the learning logs to determine which features are useful for predicting learning outcomes (end-of-lesson scores and pass/fail).

Task 2: Cluster the learners according to their end-of-lesson scores, and identify the characteristics of each learner cluster.

Task 3: Estimate the learner clusters of Task 2 using the learner features of Task 1, and determine their accuracy.

The structure of this thesis and the outline of each chapter are as follows.

Chapter 1 summarizes the background of the research, and describes that one of the problems to be solved in MOOC is the dropout problem, and that it is possible to solve the problem by collecting and analyzing enormous learning logs of learners. In addition, the purpose of this research and the three tasks to be solved are shown.

Chapter 2 summarizes research on "learning analytics". In addition, specific examples of research related to "prediction of learning outcomes" and "classification of learner characteristics," which are closely related to this research, are summarized, and the method used in this research and the direction of the research are described.

Chapter 3 describes the preliminary analysis of learning logs. We conducted clustering of learners using video viewing logs for a research data management MOOC course, and found that outliers such as playback errors can cause learners to be divided into many small clusters, and that the problem can be avoided by counting the number of video views as one if the video is viewed at least once a day. Based on the results of this chapter, in the following analysis, the number of video views is counted as one if the video is viewed at least once a day.

In Chapter 4, which corresponds to Task 1, we extracted the characteristics of learners from their video viewing behavior and questionnaires of a programming MOOC course, and analyzed the relationship with their outcomes. As a result, it was found that learners with higher scores watched more videos, learners with higher scores studied regularly, and learners with lower scores started the course later. In addition, the effectiveness of the extracted features was verified by estimating the scores and pass/fail at the

end of the learning using multiple regression analysis based on the features obtained from the start of the learning to N weeks later. As a result, it was found that the prediction of the score was not sufficiently accurate, but the estimation of the pass/fail can be performed with an accuracy of 80% or more after the third week. In addition, it was found that the prediction accuracy of the score from the start of learning to the third week could be improved by using the information such as age and programming skills obtained from the questionnaire. From these results, it is clear that features such as the number of video views, video viewing interval, start date of video viewing, age, and programming skills are effective features for predicting learners' outcomes at the end of learning.

Chapter 5 corresponds to Task 2 and Task 3. In this chapter, we proposed a method to cluster learners based on their quiz score patterns, identify the characteristics of each learner cluster, and estimate the cluster to which each learner belongs based on the results. By comparing the learning behaviors of the clusters, we found that the clusters with the highest total quiz scores watched more videos and watched them repeatedly at short intervals. Next, we attempted to estimate the clusters to which the learners belonged based on these characteristics. We estimated the clusters using random forests based on the features from the start of learning to N weeks later, and found that we could estimate the clusters to which the learners belonged with an accuracy of more than 70% after the third week. We also showed that we could estimate the pass/fail at the end of learning with a high accuracy of 90%.

In Chapter 6, we conclude by summarizing the entire research and discussing future works.

By solving the three Tasks, we were able to estimate the learner clusters and pass/fail at the end of the learning with a certain degree of accuracy at an early stage after the start of the learning. This allows us to predict the learners who are likely to fail, and also to find learners among them who are not Tasters, but who can be brought from failure to success with support. By providing more active support to these clusters of learners, it is expected that dropouts can be reduced.

On the other hand, there are still issues that need to be further examined in the future. As for the generalization of the results of this study, it is necessary to examine how to realize more versatile clustering and its

estimation. In addition, when using predictions of learning outcomes in actual educational situations, it is necessary to consider the ethical aspects of LA.

If the results of this study can be used to estimate learner clusters and provide content and support tailored to learners, it will help promote the use of online courses.

目次

1. 研究の背景と目的	1
1.1. 研究の背景	1
1.2. 研究の目的	2
1.3. 本論文の構成	3
2. 関連研究	5
2.1. ラーニングアナリティクス	5
2.2. 学習成果の予測	7
2.3. 学習者特徴の分類	9
3. MOOC 講座における学習ログの分析手法の検討	11
3.1. はじめに	11
3.2. 研究データ管理 MOOC 講座の概要	11
3.3. アンケートの分析	17
3.4. 学習行動の分析	21
3.5. 分析手法の改良	23
3.6. まとめと考察	31
4. 学習者特徴の抽出とそれに基づく点数の推定	32
4.1. はじめに	32
4.2. プログラミング MOOC 講座の概要	32
4.3. 学習行動の分析	34
4.4. 点数および合否の推定	45
4.5. アンケートの利用による予測精度の向上	54

4.6. まとめと考察	71
5. 小テストの点数パターンによる学習者のクラスタリングとその推定	72
5.1. はじめに	72
5.2. 小テストの点数パターンによる学習者のクラスタリング	72
5.3. 学習者クラスタと学習行動	77
5.4. 学習者クラスタと開始アンケート	86
5.5. 学習者クラスタの推定	88
5.6. まとめと考察	95
6. 総合考察	97
6.1. 本研究のまとめ	97
6.2. 研究の限界と今後の展望	100
謝辞	103
文献リスト	104
全研究業績リスト	116

1. 研究の背景と目的

1.1. 研究の背景

学術情報や教育情報をオープン化し，インターネット上で流通させようという取り組みが進んでいる．たとえば，OpenCourseWare は，MIT から始まった大学等の講義で提供された教材やテスト問題等をインターネット上で無償公開する試みである[1,2]．OER(Open Educational Resources)は，学習内容やツール，公開の枠組み等も含めて教育に関連する資源をオープン化しようとする試みである[3,4]．大規模公開オンライン講座（以下，MOOC）は，対象者を限定せず誰でも大学レベルの教育を受講可能なオンライン講座として，世界各地でサービスが提供され，広く社会から支持を得ている[5-7]．

MOOC の代表的なプラットフォームである Coursera や edX の学習者の数は 2016 年には，3,000 万人以上に達しており，社会全体に大学レベルの教育の機会を提供することに貢献している[8,9]．国内においても JM00C により，2019 年現在で累計 340 講座が提供され，学習者数は 100 万人を超えている[10,11]．しかし，MOOC では，大規模な学習者数が期待できる反面，講座を最後まで修了できずに途中でドロップアウトする学習者が多く，その修了率は 10%程度と低いという問題がある[12-14]．これは，オンライン上の教育コンテンツが必ずしも有効に利用されていないということでもあり，MOOC において解決すべき問題の 1 つになる．一方で，MOOC のようなオンライン講座では，学習者の膨大な学習行動に関連するログ（学習ログ）がシステム上に蓄積されることから，これらを収集，分析することで，学習における問題点を解決できる可能性がある．

学習行動に関連するログを収集，分析することで，学習における問題点を解決し教育改善に繋げようとする研究は，ラーニングアナリティクス（Learning Analytics, LA）と呼ばれる．LA の主な研究テーマには，学習行動の分析や，学習者の興味や能力に応じた教材の推薦，学習成果の予測，学習者特徴の分類等がある．

学習行動から，最終的にドロップアウトするか否かを予測することに取り組んだ研究としては，たとえば，Tan ら[15]は，学生の年齢，専攻，学習した科目数，テストの平均点等の特徴として利用し，ドロップアウトの予測が行えることを示している．Manrique ら[16]は，学生の特徴として，登録した科目数や成績の平均といったグローバルな特徴を利用した場合と，登録した科目の成績を並べたロー

カルな特徴を利用した場合と、成績の時間変化を利用した場合の比較を行っている。Gitinabardら[17]は、ディスカッションの中心になっているか等の指標も利用してドロップアウトの推定を行っている。しかし、ドロップアウトを軽減しようとする場合、単純にドロップアウトを推定するだけでは十分ではない。MOOCの学習者は多様であり、また、必ずしも、常に、学習者のサポートに必要となる十分な時間や、人手、コストが用意できるとは限らないため、学習者に応じて適切なサポートを行うことが必要になる。

MOOCの学習者の類型に関しては、たとえば、Kizilcecら[18]は、映像視聴は行なうもののほとんど課題に取り組まない講義学習者や、少し映像を視聴ただけで脱落する学習者など、学習者を4つのクラスタに分類している。また、荒ら[19]は、実際の学習をほとんど行わない様子見型や主に映像視聴のみを行う知識獲得型など、学習者を4つのクラスタに分類している。Kahanら[20]は、映像講義、ディスカッションフォーラム、評価といった主な学習リソースにおける活動に基づいて学習者を7つのクラスタに分類している。その中で、全ての学習活動が低いレベルである Tasters と呼ばれるクラスタが全体の約 65%存在することを示している。

このように、学習行動や成績等、様々な特徴によって学習者の分類が行われているが、MOOC学習者へのサポートを考えた場合、どの学習者を対象とし、どのようにサポートすれば救えるかを考慮しながら、学習者特徴の分類を行うことが必要となる。また、学習者に応じたサポートを行おうとする場合、学習開始から早い時期にそれぞれの学習者がどの学習者クラスタに属するかを推定できる必要がある。

1.2. 研究の目的

以上のような背景に基づき、本研究では、ドロップアウトの軽減のために必要となる、サポートすべき学習者クラスタを見い出すための方略を明らかにすることを研究の目的とする。ドロップアウトの定義については、たとえば、映像を見ることを主体として、テストについては補助的に用意した講座の場合、テストに不合格であっても、映像を十分に視聴していればドロップアウトではなく、テストに合格しても、映像を十分に視聴していなければドロップアウトとして扱うべきかも知れない。しかし、講師の意図等の影響無しに、明確にドロップアウトか否かを定義して扱えるようにするため、以降では、ドロップアウト=不合格として

論を進める。

サポートすべき学習者クラスタを見い出すために必要となることは、学習開始から早い時期に、合格するか不合格となるかを予測することである。そして、もし、合格すると推定されるならば、ドロップアウトを軽減するという点では、サポートは必ずしも必要とはならない。一方、不合格になるであろう学習者の中には、Tasters のような、必ずしもサポートを望まない学習者も含まれる。このため、不合格者をより細分化して、サポートをすることで不合格から合格に導けるであろう学習者クラスタを見い出す必要がある。

これを実現するためには、まず、学習者の合格/不合格を予測するために有効な特徴量を明らかにする必要がある。また、学習者を、単純な合否ではなく、より細分化してクラスタ分けを行う必要がある。また、学習者クラスタをどの程度の精度で推定できるかを明らかにする必要がある。

具体的な研究課題は、以下のようになる。

課題 1: 学習ログを分析し、学習成果（学習終了時の点数/合否）を予測するためにどのような特徴量が有用であるかを明らかにする。

課題 2: 学習者を学習終了時の点数によりクラスタリングし、それぞれの学習者クラスタの特徴を明らかにする。

課題 3: 課題 1 の学習者特徴量を用いて、課題 2 の学習者クラスタを推定し、その精度を明らかにする。

課題 1, 課題 2 は、それぞれ、現在でも活発に研究が行われている分野であり、これらの成果は、課題 3 を解決するための基礎となる。課題 3 は、ドロップアウトするであろう学習者の中から、サポートにより合格に導くことができる可能性の高い学習者クラスタを選び出し、選択的にサポートを行うことを実現するために必要となる手法を開発しようとするもので、この点が本論文の主眼となる。

1.3. 本論文の構成

本論文の構成および各章の概要は次の通りである。

第 1 章は、導入のための章であり、研究の背景についてまとめる。また、本研究の目的と課題について述べる。

第 2 章では、本研究に関連する研究を、「ラーニングアナリティクス」、「学習成果の予測」、「学習者特徴の分類」の 3 つに分類しまとめる。また、本研究で用いる手法や方向性について述べる。

第3章は、課題に取り組むための予備的な検証として行った学習ログの分析について述べる。研究データ管理 MOOC 講座を対象とし、映像視聴数の分析を行い、再生エラー等の外れ値による影響や、それを回避する方法について議論する。

第4章は、課題1に対応する章であり、プログラミング MOOC 講座を対象に学習ログの分析を行い、学習者からどのような特徴量を抽出できるか明らかにする。また、抽出した特徴量をもとに、重回帰分析を用いて、学習終了時の点数および合否の推定を行い、抽出した特徴量の有用性を検証する。

第5章は、課題2、課題3に対応する章である。まず、小テストの点数パターンに基づき学習者をクラスタリングし、それぞれの学習者クラスタの特徴を明らかにする。次に、学習者から抽出した特徴をもとに学習者クラスタの推定をどの程度行えるか明らかにする。

第6章では、結論として、全体をまとめ、今後の課題について述べる。

2. 関連研究

本研究に関連する研究としては、ラーニングアナリティクスが挙げられる。本章では、ラーニングアナリティクスを俯瞰するとともに、本研究と関連が深い、学習成果の予測と学習者特徴の分類についてまとめる。

2.1. ラーニングアナリティクス

ラーニングアナリティクスは、学習行動に関連するログを収集・分析することで、学習における問題点を解決し教育改善に繋げようとする研究であり、主な研究テーマには、学習行動の分析や、学習者の興味や能力に応じた教材の推薦、学習成果の推定、学習者特徴の分類等がある[21-29]。

学習行動の分析は LA における大きなテーマの 1 つであり、従来から数多くの研究が行われている[30-32]。Park ら[33]は、学生のクリック操作を記録したクリックストリームデータの分析を行っている。クリック数をポアソン過程として、各日の平均値からの各学生のずれが、ある時点を境に大きさが変化する場合、それを学習行動の転換点として検出を行なっている。Käser ら[34]は、コンピュータ上の綱引きゲームを対象として、学生の学習のモデル化と予測を行い、探索戦略が学習成果の重要な予測因子であることを明らかにしている。

学習の振り返りである省察の分析に関しては、Gibson ら[35]は、自由記述された省察の内容を、Context, Challenge, Change の 3 種類に分類するフレームワークの提案を行っている。たとえば、Challenge の内容は、CONTRAST の概念 (challenge, unfamiliar, problem 等の単語を含む) と ANALYSIS の概念 (ideas, learning 等の単語を含む) で構成されるといったパターンを定義することで省察の分類を行っている。Ullmann[36]は、省察の内容を、Reflection, Experience, Feeling, Belief, Difficulty, Perspective, Learning, Intention の 8 種類に分類し、省察がどの分類に含まれるかの推定精度の評価を行っている。

学習者の感情の状態を分析することも行われている。Ez-zaouia ら[37]は、外国語学習を対象とした映像会議において、いくつかの感情測定 API を用いて学習者の感情状態に関する情報の収集を行い、それらを組み合わせて表示するためのダッシュボード EMODA を開発している。Xu ら[38]は、3D ゲームで学習している間、リアルタイムで顔の動きを検出し、外側の眉を上げる、唇を引き締めるといった顔の動きは、学習成果と相関があることなどを明らかにしている。Azevedo ら

[39]は、自己調整学習中の感情調整を促進するためにデータの可視化を利用するフレームワークを提案している。

分析アプローチの1つとして、Social Network Analysis (SNA)と呼ばれる手法もある[40-42]。これは、ディスカッションフォーラムや学習者のポジションを、ノードとそれらを結ぶリンクによるネットワーク構造で特徴付けし、分析を行うものである。また、磁性体のモデルであるイジングスピン系を学習の数理モデルとして利用する研究なども行われている[43-44]。

教材の推薦に関しては、Hsu ら[45]は、複数の専門家（教員）に対するインタビューから得られた知識をもとに、個々の学生の好みや知識レベル、記事のカテゴリや特性などを考慮した英語文献の推薦システムの開発を行っている。Kandula ら[46]は、患者の電子医療記録から患者の情報ニーズを推測し、トピックモデリングを利用して、患者に関連する教育記事を推薦する手法の提案を行っている。古川らは、プログラミング MOOC コースのアンケートの自由記述を分析し、その内容から、プログラミングスキルの推定を行った[47]。Zapata-Gonzalez ら[48]は、最近傍法とルールマイニングを用いて学習オブジェクトの推薦を行うシステムの提案を行っている。

機関レベルで LA を推進する試みが行われる一方で[49-54]、国レベルで LA を推進する試みも行われている。英国では、Jisc が高等教育および研究機関に対して、LA に必要なシステムの提供やデータ分析の支援等を行っている [55]。Koedinger ら[56]は、アメリカ国立科学財団から資金提供を受け、機密性を維持しながら、教育データや学習分析手法、可視化手法を共有するシステムである LearnSphere の開発を行なっている。LACE (Learning Analytics Community Exchange) は、ヨーロッパの 9 機関が参加する EU 資金によるプロジェクトである[57]。Ferguson ら[58]は、LACE プロジェクトにおいて、LA 研究におけるエビデンスを蓄積する Evidence Hub の構築を行っている。SHEILA プロジェクトも EU から資金を受けているプロジェクトであり、大学等が LA を実施する上で不可欠となる LA ポリシーの策定の支援を行っている[59]。

一方で、倫理的な問題についても LA の対象となっている。Arnold ら[60]は、英国と米国の教育機関に在籍する学生を対象に、学生データの倫理とプライバシーに関するアンケート調査を行い、多くの学生は、成績の向上を支援する目的でのデータ使用を受け入れていることなどを明らかにしている。また、Hildebrandt[61]は、個人データの処理と機械学習に基づくプロファイリングにつ

いての調査を行い、データ主導の教育方法がプライバシー等に与える影響の評価を行っている。Mislevy[62]は、教育効果の測定には、信頼性、妥当性、比較可能性、一般化可能性、公平性だけではなく、社会的価値も考慮すべきであると述べている。Prinslooら[63]は、機関が、学生データの分析に基づいて行動する義務には、プライバシーの保護や、学生データの倫理的な収集、分析だけでなく、適切で効果的な介入を確実に行うための資源の配分も含まれることを指摘している。本研究では、LAの手法について主に扱うが、このような倫理、行動の義務についても同時に考慮しながら研究を進めていく必要がある。

2.2. 学習成果の予測

学習行動から、最終的にドロップアウトするか否かを推定することに取り組んだ研究も行われている[64-65]。Leeら[66]は、過去10年間に発表された中等教育後のオンライン講座のドロップアウトに関する研究をレビューし、ドロップアウトに影響を与える要因としては、学生の要因、コース/プログラムの要因、環境の要因があることを示している。Khalilら[67]は、文献調査により、MOOCの高いドロップアウト率の原因として、時間の不足、学習者のモチベーションの欠如、孤立感等が挙げられることを示している。Tanら[15]は、学生の年齢、専攻、学習した科目数、テストの平均点等を特徴として利用し、90%ほどの正解率でドロップアウトの予測が行えることを示している。Manriqueら[16]は、学生の特徴として、登録した科目数や成績の平均といったグローバルな特徴を利用した場合と、登録した科目の成績を並べたローカルな特徴を利用した場合と、成績の時間変化を利用した場合の比較を行い、ドロップアウトの推定には、ローカルな特徴が有効であることを示している。Gitinabardら[17]は、教材の視聴等の学習行動とともに、ディスカッションの中心になっているか等の指標も利用してドロップアウトの推定を行っている。Chienら[68]は、「内容が面白そう」、「ソーシャルメディアの通知があると、チェックせずにはいられない」といった心理状態を反映したアンケートの結果を用いて最終成績の推定を行っている。

こうした従来の研究では、ドロップアウトを予測するための特徴量を抽出しようとする目的は一致するものの、それぞれの提案の内容は大きく異なり、共通の手段があるわけではない。その理由としては、対象とする学習者群の特徴や、LMS (Learning Management System, 学習管理システム) の機能や使われ方の違いが挙げられる[69]。また、学生が履修する授業全体の中でのLMSの使われ方やLMS

以外のシステムから得られる情報も、LAを実施する際の制約条件になり得る。こうした状況を考慮すると、MOOCのドロップアウトを軽減させるためのLAは、MOOCの特徴等を加味した方法で実施する必要がある。

また、推定に利用される手法も多岐に渡る。Zhangら[70]は、1987年から2002年までの9つの機関の87,167人の工学部学生のデータをロジスティック回帰モデルを用いて分析し、高校でのGPA、性別や民族の違い、SAT(大学進学適性試験)のスコア、国籍が卒業に大きな影響を及ぼしていることを示している。Nedevaら[71]は、電気電子工学分野の学生を対象に、年齢、収入、居住地、教育レベルの満足度等のデータをもとに、Naive Bayesを用いて、ドロップアウトの推定を行っている。Mendezら[72]は、アリゾナ州立大学の理工系の学生を対象に、ランダムフォレストを用いた分析を行い、高校および入学年のGPAが、学習の持続性を予測するために重要であることを示している。Chenら[73]は、DropoutSeerと呼ばれる学習ログのビジュアル分析システムの開発を行っている。クリックストリーム、フォーラム投稿、課題の3つの学習活動のログをもとに、ロジスティック回帰、最近傍探索、ランダムフォレストによるドロップアウトの予測を実現している。Lakkarajuら[74]は、米国の2つの学区の約20万人の生徒を対象に、複数の機械学習の手法を用いて、卒業できない危険がある学生の推定を行っている。この結果、ランダムフォレストが、ロジスティック回帰、決定木、サポートベクトルマシン等の手法に比べて精度が高いことを明らかにしている。

ニューラルネットワークを用いた研究も行われている[75,76]。Francescoら[77]は、2009年以降のローマ・トレ大学の教育学部の約6,000人の学生の管理データを使用して、畳み込みニューラルネットワークにより、学生がドロップアウトするかどうかを予測する予測モデルを構築し、1年生では、67.1%、3年生では、94.3%の精度でドロップアウトの推定を行えることを示している。Okuboら[78]は、10人の教師が共通のシラバスに従って実施した15コースの2,693人の学生のログデータを対象に、リカレントニューラルネットワークを使用して学生のクイズスコアの予測を行っている。Huら[79]は、多層パーセプトロン(MLP)とリカレントニューラルネットワーク(RNN)を用いて、以前のコースの成績から将来のコースの成績を予測し、時間順序を考慮したRNNの方が予測精度が高いことを示している。

以上のように、推定に用いられる手法は多岐に渡るが、第4章では、点数の推定が目的となることから重回帰分析による解析を行なう。また、Deep Learningに

よる推定は，一般に精度が良くなるものの，10万件程度の大規模なデータが必要となり，また，処理がブラックボックス化するという問題があることから，第5章では，ランダムフォレストを利用する．

2.3. 学習者特徴の分類

入試等でフィルタリングされている大学の学生に対する支援とは異なり，MOOCの学習者の全てを修了に導くことを前提とするのは非現実的である．また，従来の研究ではMOOCを対象としてドロップアウトを推定するものはあるが，MOOC学習者のよりきめ細かいサポートを考えた場合は，単純にドロップアウトを推定するだけではなく，より詳細なレベルで，MOOC学習者がどのような学習者クラスターに属するかについて推定を行うことが必要となる．

学習目的の違いについては，Reich[80]は，9つのHarvardXコースを対象とした分析を行い，コースを修了することを目的とした学生やコースを閲覧することを目的とした学生など，学習目的は多様であることを示している．また，コースを修了することを目的とした学生の22%が修了証を取得したのに対し，コースを閲覧することを目的とした学生が修了証を取得するのは，6%にとどまることを明らかにしている．

学習行動の違いにより，学習者をクラスタリングすることも行われている[81]．たとえば，Kizilcecら[18]は，学習者を，映像視聴は行なうもののほとんど課題に取り組みない講義学習者(Sampling)や，少し映像を視聴しただけで脱落する学習者(Auditing)，授業開始時に課題をこなすものの離脱する学習者(Disengaging)，最後まで成し遂げる学習者(Completing)の4つのクラスターに分類している．また，荒ら[19]は，学習者を，実際の学習をほとんど行わない様子見型や，主に映像視聴のみを行う知識獲得型，主にテストのみを行なう既有知識確認型，両方を行なう学習活動完遂型の4つのクラスターに分類している．Kahanら[20]は，映像講義，ディスカッションフォーラム，評価といった主な学習リソースにおける活動に基づいて学習者を，Tasters，Downloaders，Disengagers，Offline Engagers，Online Engagers，Moderately Social Engagers，Social Engagersの7つのクラスターに分類している．その中で，全ての学習活動が低いレベルであるTastersと呼ばれるクラスターが全体の約65%存在することを示している．このTastersは，前述の少し映像を視聴しただけで脱落する学習者や，実際の学習をほとんど行わない様子見型に対応する学習者群と考えられる．

永田ら[82]は、アクセスした講義動画の割合、および、回答したテストの割合の2つの特徴を用いたフィルタリングを行った上で、学習者のコンテンツ遷移に着目して学習様態のクラスタリングを行ない、学習者を、ほとんどアクセスをしない学習者、講義動画だけにアクセスしている学習者、テストだけにアクセスしている学習者、講義動画・テストの双方にアクセスしている学習者に分類できることを明らかにしている。また、ひとつひとつ順番に進み、きちんと戻って確認する学習者は修了率が高い傾向があることを示している。

Fergusonら[83]は、4つのFutureLearn M00Cでの学習への取り組みのパターンを分析し、学習者をSamplers, Strong Starters, Returners, Mid-way Dropouts, Nearly There, Late Completers and Keen Completersの7つのパターンへと分類している。Samplersは、アクセスはするものの、短時間に限られる。Strong Startersは、最初の課題は完了するもののドロップアウトする。Returnersは、2週目の課題も完了するがドロップアウトする。Mid-way Dropoutsは、3つか4つの課題を完了するがドロップアウトする。Nearly Thereは、ほぼ課題を完了するが、合格直前にドロップアウトする。Late Completersは、最終課題に合格するが、途中の課題は遅れる傾向がある。Keen Completersは、全体的に熱心に学習し、最終課題に合格する。

Hoら[84]は、edXプラットフォームの17のM00Cを調査し、学習者を4つのカテゴリに分類している。Only Registeredは、登録のみで、コースウェアにアクセスしない学習者であり、Only Viewedは、コースウェアのアクセスが半分以下で、修了の条件を満たさなかった学習者である。Only Exploredは、コースウェアの半分以上アクセスしたものの、修了の条件を満たさなかった学習者であり、Certifiedは、修了証を取得した学習者である。

このように、学習行動や成績等、様々な特徴によって学習者の分類が行われているが、M00C学習者へのサポートを考えた場合、どの学習者を対象とし、どのようにサポートすれば救えるかを考慮しながら、学習者特徴の分類を行うことが必要となる。また、学習者に応じた教材の提供やサポートを行おうとする場合、学習開始から早い時期にそれぞれの学習者がどの学習者クラスに属するかを推定できる必要がある。

3. M00C 講座における学習ログの分析手法の検討

3.1. はじめに

第3章では、予備的な検証として行った学習ログの分析について述べる[85]。研究データ管理 M00C 講座を対象とし、映像視聴ログを用いた学習者のクラスタリングを行い、学習ログの分析手法について検証する。また、それぞれの学習者クラスタの特徴についても明らかにする。

3.2. 研究データ管理 M00C 講座の概要

対象とした研究データ管理 M00C 講座のねらいは、学習者が研究データ管理に関する基礎的な知識を習得することと、研究データ管理サービス構築の足掛かりを得ることである。このコースのメインのターゲットは、研究データ管理支援を担うと期待されている大学・研究機関の図書系職員である。

2013年のG8科学大臣会合における研究データのオープン化に関する共同声明を皮切りとして、国内でもオープンサイエンスに関する議論が活発化し[86-88]、2018年には、内閣府の国際的動向を踏まえたオープンサイエンスの推進に関する検討会から、国立研究開発法人におけるデータポリシー策定のためのガイドラインが公開されている[89]。先行するイギリスのエジンバラ大学では、研究データを保存することだけでなく、それを共有して、公開して、再利用できるようなポリシーを大学として作成している[90]。また、研究データ管理に関して様々なオンライン教材が公開されており、エジンバラ大学のMANTRAは、研究プロジェクトの一環としてデジタルデータを管理する人を対象とした無料のオンライン講座を提供している[91]。FOSTERでは、オープンサイエンスの詳細を知るために必要なeラーニングコースが集められている[92]。Figshareは、研究データを公開するためのレポジトリであり、研究データ管理に関する教材も公開されている[93]。日本においても、オープンアクセスリポジトリ推進協会(JPCOAR)の研究データタスクフォースが、海外の動向も調査しながら研究データ管理(Research Data Management, RDM)の基礎を学ぶ教材の開発を行っている[94]。

JPCOARが開発したRDMトレーニングツールは、全7回の音声付きのeラーニング教材として作成され、各回は、スライドと解説と小テストで構成される。研究データのライフサイクル(生成, 加工, 分析, 保存, 公開, 再利用)をサポートできる教材として作成され、各章の構成は、以下のようになる。

第1回：導入編であり，RDMが必要とされる背景や，研究データおよびRDMの定義について解説している．

第2回：DMP (Data Management Plan)の定義や動向について述べた上で，実際のDMPの策定方法を解説している．あわせてDMPを支援するツールについても紹介している．

第3回：研究データの保存と共有をテーマとし，長期保存にあたってのセキュリティ上の留意事項や，共有・再利用のためのデータリポジトリの活用などについて解説している．

第4回：研究データの組織化，文書化，メタデータ作成をテーマとし，主要なメタデータスキーマを紹介するなど，データを再利用に供するためのシステムティックな管理方法を解説している．

第5回：法・倫理的問題をテーマとし，著作権に関するライセンスや，研究不正に関するポリシーについて解説している．

第6回：研究者が研究を進めるにあたってのポリシーをテーマとしており，研究公正に関するポリシーの事例と，そこでの研究データ取扱いについて解説している．

第7回：RDMサービスの設計をテーマとし，RDMを支援する人材の確保や，研究データ保存・公開の基盤システムについて解説している．

これらは，2017年6月6日付でJPCOARの公式ウェブサイト上でCC-BYで公開された．

RDMトレーニングツールの公開後，研究データタスクフォースでは，ツールのさらなる有効活用を目指し，国立情報学研究所と共同でMOOCプラットフォームのgacco[95]を利用して，RDMトレーニングツールを活用した講座を開講した．このMOOC講座「オープンサイエンス時代の研究データ管理」は，2017年11月15日から2018年1月15日まで開講された．

図3-1は，その受講画面を示している．RDMトレーニングツールでは7回で構成されていた教材をMOOC講座のために全4回（以下，それぞれの回をUnitと呼ぶ）に再編成し，研究データタスクフォースの協力を得て映像を補完した．このMOOC講座の各Unitは，4～5本の映像，ダウンロード教材，確認のための小テスト（10問の選択問題）で構成される．Unit1では，研究データ管理の重要性が増している背景や研究データ管理の意義について学ぶという内容になっている．Unit2では，研究データの保存と共有，文書化について学習する．Unit3では，

メタデータ・法・倫理的問題について学ぶ。Unit 4 では、研究データに関するポリシーと、研究者が研究データを適切に管理するために、サービスを組織としてどのように設計していけば良いのかについて学ぶ。

JPCOAR の RDM トレーニングツールでは、音声が付与したスライドのみであったため、JM00C 講座の一般的な映像のように講師が登場する部分を挿入し、JM00C の学習者になるべく違和感を与えないよう配慮をしている。具体的には、教材音声のナレーターと教材作成者が担当した内容について簡単な紹介をするシーンを挿入し、その後にナレーターのスライド音声が続くような構成としている。小テストは3回まで受験可能で、12月26日時点での点数の合計が70点に達した場合に修了証が発行された。12月26日以降も受講は可能であるが、この場合、小テストは受験できない。このほか、開始時と受講後に任意で回答するアンケートが用意された。受講後アンケートは、Unit 4 がアクセス可能になった時点で回答可能になる。

オープンサイエンス時代の研究データ管理

この講座に登録されています [学習する](#)

講座詳細をSTUDIOで参照

講座概要

講座内容

本講座は、研究データに関する基礎的な知識を得るためのものです。

研究活動に伴い研究データがたどるプロセスとその管理のあり方について理解し、研究の再現性と透明性の向上に欠かせない、効果的な研究データ管理を行うための方法について学ぶことができます。

さらに、概略を学んだ後、各学習者が、所属機関における研究データ管理サービス構築に向けた戦略立案を行うための足掛かりを得られるよう、構成されています。

以下のいずれかに該当する方を受講者として想定しています。

- ・大学や研究機関等において研究者の支援に携わる方（図書館・IT部門・研究支援部門の職員（URA含）、研究室で研究補助業務に携わる方等）
- ・オープンサイエンスや研究データ管理に関心のある方

第1週：研究データ管理とは

- 本講座の背景とねらい
- 研究データ管理の重要性が増している背景
- 研究データ、研究データ管理の定義
- 効果的なデータ管理に欠かせないデータ管理計画
- データ管理計画をめぐる国内外の動向
- データ管理計画の実例

第2週：保存・共有・文書化

- 研究データの保管や長期保存・共有・再利用
- 研究データの組織的な管理
- データを文書にまとめる

第3週：メタデータ・法倫理的問題

- データにメタデータを付与する
- データの引用
- 研究データをめぐる著作権再利用促進のためのライセンス
- 研究不正研究倫理
- センシティブデータ

第4週：運用に向けて

- ポリシーとは

※受講登録するとお客様の利用者情報は講座提供者（講師）に共有されます。詳しくは利用規約とプライバシーポリシーをご覧ください。

講座番号:ga088

受講開始日:2017年11月15日

想定される勉強時間/週:4.5時間程度

図 3-1 研究データ管理オンライン講座

Figure 3-1 RDM training online course.

開発した研究データ管理 MOOC 講座の学習者数は、2,305 名だった。講座を開講した 2017 年 11 月の直近 1 年の gacco における学習者数平均は 4,145 名であり、学習者数は、平均と比べると約半分であるが、gacco では一般的な教養内容の講座が多い中で、専門性の高い内容であることから、800 人程度の学習者数を見込んでおり、当初の予想を上回ったと言える。また、修了率は 25%であり、gacco の平均修了率は 15%、MOOC の世界的なレベルでの修了率も 10%前後という中で高いと言える（表 3-1）。

表 3-1 学習者数と修了率

Table 3-1 Number of attendants and completion rates.

	学習者数	修了率
オープンサイエンス時代の研究データ管理	2,305	25%
gacco 講座平均 (直近 1 年)	4,145	15%

図 3-2 に点数分布を示す。合格者について見ると、70 点が合格のラインであるのにも関わらず、合格者の多くが 100 点で合格していることが分かる。





図 3-2 点数の分布

Figure 3-2 Distribution of scores.

3.3. アンケートの分析


開始アンケートについては、回答は必須ではないものの、770名の回答を得た。職種については656名が回答し、大学・研究機関(職種1~5)が回答者の50%以上を占めた。その中でも特に多かったのは大学・研究機関(図書系)(職種3)と回答した者で、回答者の30%を占めていた(図3-3)。(中等高等教育機関(職種7)の高等教育機関については、大学以外を想定している。)



3-3 回答者の職種

Figure 3-3 Job category of respondents.

受講後アンケートに関しては、回答者数は 345 名だった。「講座の内容は、あなた自身にとって有用でしたか」について質問したところ、「大変有用である」、「有用である」の割合は 9 割程度であった（図 3-4）。大学・研究機関（図書系）の職種 3 とそれ以外を比較すると、大学・研究機関（図書系）の学習者は、「大変有用である」と答えた割合が高かった。




3-4 有用であったか否か

Figure 3-4 Whether the course was useful or not.

また、講座の内容は有用であったか否かについて、そのように回答した理由を自由記述により聞いた。大学・研究機関(図書系)(職種3)でこの問に答えた人は116名、それ以外で答えた人は233名であった。それぞれの内容の違いを見るために、それぞれの自由記述の内容を共起ネットワークにより分析した。共起ネットワークでは、共起性が高い単語同士が線で繋がれて表示される。ツールとしては、KH Coder を利用した。


図3-5は、大学・研究機関(図書系)(職種3)の学習者の回答について共起ネットワークを作成したものである。この図ともとの記述を見ると、たとえば、「オープンサイエンスの基本的な考え方について学ぶことができた」、「図書館の現状について認識できた」といった記述がある反面、「図書館と他の部局との連携が課題」といった内容の記述があることが分かった。



3-5 共起ネットワーク (職種3)

Figure 3-5 Co-occurrence network (Job category 3).

図 3-6 は、大学・研究機関(図書系) (職種 3) 以外の学習者の回答について共起ネットワークを作成したものである。この図ともとの記述を見ると、たとえば、「今回、勉強して RDM について分かった」、「仕事に役立つ」といった記述がある反面、「大学として整備することは困難」といった、現状の難しさについて言及する記述が見られた。



3-6 共起ネットワーク (職種 3 以外)

Figure 3-6 Co-occurrence network (Other than job category 3).

3.4. 学習行動の分析

学生が LMS 上で、コース内の映像の再生、小テストの受験といったモジュールを使用するたびに、学習行動の記録である学習ログが LMS のデータベースに追加される。学習ログには、映像の視聴、オンラインディスカッション、レポートの採点結果などの情報が含まれる。この LMS のデータベースから学習ログデータを抽出し、分析を行った。


対象としたコースは、映像をメインとして構成されていることから、学習者によって映像の視聴傾向に違いがあるかを分析の対象とした。gacco のプラットフォームは、オープンソースの MOOC プラットフォームである Open edX をベースに構築されており、学習ログから play_video イベントを抽出することで、視聴数の情報を得ることができる。

学習者のクラスタリングには、クラスタリングに広く用いられる手法の 1 つである k 平均法を利用した。具体的には、各 Unit の映像の視聴数を並べた 4 次元データを個人ごとの特徴量とした。そして、この 4 次元データを k 平均法により、クラスタに分割した。k 平均法における適切なクラスタ数を決めるための方法の 1 つとしてエルボー法があるが、これは、クラスタ数を小さくしながら、データとクラスタ重心の自乗誤差が急に大きくなる直前を適切なクラスタ数とするものである。しかし、今回分析したデータでは、エルボー法を用いると、データ数がごく小さい数多くのクラスタと、ほとんどのデータが属する 1 つのクラスタに分離された。このため、クラスタ数を大きくしながら、大きなクラスタが 4 程度に分かれるという条件で、クラスタ数を 16 と設定した。

図 3-7 に、クラスタごとの人数と、合格/不合格者数を示す。クラスタリング結果については、平均の視聴数が多い方から順に a~p のラベルを付与した。人数については、a~l の 12 のクラスタで人数が 10 名未満となった。一方、最も人数が多かったクラスタ p の人数は、1,681 名であり、クラスタごとの人数に大きな偏りがあることが分かる。

映像視聴数については、最も多くの学習者が含まれるクラスタ p では、各 Unit の映像視聴数の平均は 0.17 回であった。また、合格/不合格の割合を見ると、9 割以上が不合格であり、学習をほとんど行っていないクラスタであると考えられる。クラスタ m, n, o の各 Unit の映像視聴数の平均は 49.0 回、26.2 回、8.5 回となった。クラスタ a~i の映像の視聴数については、平均で 100 回を超えており、最も視聴数が多いクラスタ a では 5,000 を超えていた。このように、一部の学習者の

視聴数が極端に大きい場合があることが、数多くの小さなクラスタに分割してしまう原因と考えられる。このような数の映像視聴は実際に映像を操作した数とは考えにくく、このような映像視聴をどのように扱うかについては、3.5で議論する。



3-7 クラスタごとの合格/不合格者数

Figure 3-7 Pass / fail number in each cluster.


3.5. 分析手法の改良

3.4. では、映像視聴数により学習者のクラスタリングを行い、単純な映像視聴数を使った場合、視聴数が極端に大きくなる学習者がおり、そのため数多くの小さなクラスタに分割されるという問題があることを明らかにした。視聴数が特に多い学習者の play_video イベントを見ると、play_video イベントが1秒間に数回発生し、それが数十秒に渡って続くといった場合があることが分かった。これは、人が実際に再生ボタンを押した回数とは考えにくく、再生エラー等が原因と考えられる。視聴数の分析を行うことのみが目的であれば、このような学習者は分析対象から除外することも考えられる。しかし、最終的に学習者をクラスタ分けしてサポートを行うことを考えるならば、視聴数が極端に大きくなる学習者も含めて対応できる必要がある。

再生エラー等が原因の場合、映像の視聴数が多くても、必ずしもそれに比例して学習を行ったことにはならない。しかし、実際に映像を視聴しようとしたことは事実であることから、映像の視聴数は、単純な回数よりも、見たか見ないかをより重視して考える必要がある。このため、分析手法の改良として、各 Unit の映像を1日1回以上視聴した場合に視聴を1回と数えることを提案し、その場合に、学習者のクラスタリング結果が改善するかを検証する。この場合、各 Unit の映像を何日視聴したかを視聴数の指標として利用することになる。

複雑でノイズの多い、学生のクリック操作を記録したクリックストリームデータの分析を行う手法として、Park ら [33] は、1日1回以上クリックした場合は1、そうでない場合は0として、そのパターンがベルヌーイ過程であるとして分析を行うモデルの提案を行なっているが、映像の視聴数を1日1回以上視聴した場合に1とカウントすることは、それに類似した手法とも言える。このようなカウント手法をとることにより、映像の再生エラー等のために play_video イベントが増加する場合などに、大きな外れ値の影響を受けにくくなると考えられる。

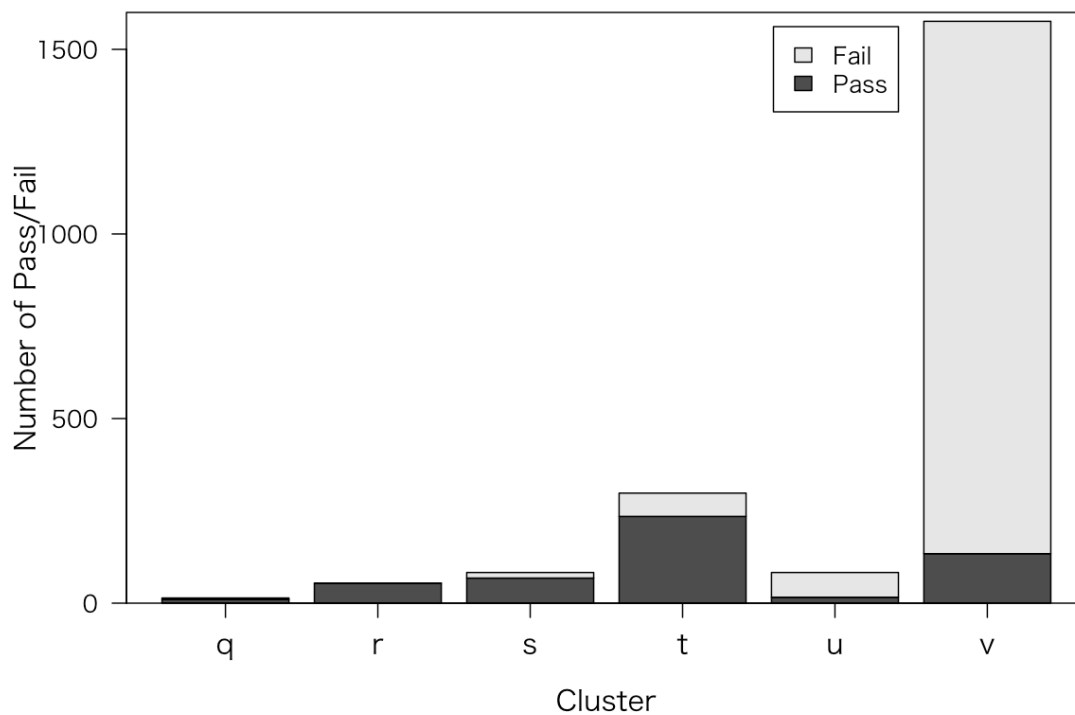
学習者のクラスタリングは、3.4. と同様に、各 Unit の映像の視聴数を並べた4次元データを k 平均法により分割することで行った。クラスタ数の決定には、エルボー法を利用した。図 3-8 に、分割数を変えた場合の自乗誤差の和を示す。この図で分割数を小さくしていった場合、クラスタ数が6から5に変わる時点で、自乗誤差の和が大きくなるとして、クラスタ数は6とした。



3-8 クラスタ数の決定

Figure 3-8 Decision of cluster number.

図 3-9 は、クラスタごとの人数と、合格/不合格者数を示したものである。平均の視聴数が多い方から順に q~v のラベルを付与している。クラスタ q~v のそれぞれの人数は、表 3-2 のようになる。10 人未満の小さなクラスタは無くなっており、3.4 のクラスタリング結果に比較して、小さなクラスタに過度に分割することを避けられていることが分かる。また、3.4 の図 3-7 に示したクラスタ p が概ねクラスタ u, v に分かれており、クラスタごとの人数のばらつきが小さくなっていることが分かる。



3-9 クラスタごとの合格/不合格者数

Figure 3-9 Pass / fail number in each cluster.

表 3-2 各クラスタの学習者数

Table 3-2 Number of learners in each cluster.

クラスタ	人数
q	14
r	54
s	83
t	298
u	83
v	1,576

以下，クラスタごとの特徴の違いをより詳細に見ていく．

クラスタ毎の映像視聴数は，図 3-10 のようになる． q は，最も視聴数が多いクラスタで，4つの Unit の映像を満遍なく視聴している． r は，むしろ後半の Unit の視聴数が増えている． t は平均 1 回程度視聴しており， v はほとんど視聴していない． s, u は，徐々に視聴数が減少し，特に， u の視聴数の減少は大きい．




図 3-10 クラスタごとの映像視聴数

Figure 3-10 Number of video views in each cluster.

図 3-11 は，クラスタごとの映像視聴数の分布を見たものである．特に，図 3-11(d)の Unit4 における映像の視聴数のピーク位置を見ると，クラスタ q は 3 回，クラスタ r は 2 回，クラスタ s, t は 1 回，クラスタ u, v は 0 回と，クラスタ間の違いが明確になっていることが分かる．




図 3-11(a) クラスタごとの映像視聴数の分布 (Unit 1)

Figure 3-11(a) Number of video views in each cluster (Unit 1).




図 3-11(b) クラスタごとの映像視聴数の分布 (Unit 2)

Figure 3-11(b) Number of video views in each cluster (Unit 2).




図 3-11(c) クラスタごとの映像視聴数の分布 (Unit 3)

Figure 3-11(c) Number of video views in each cluster (Unit 3).




図 3-11(d) クラスタごとの映像視聴数の分布 (Unit 4)

Figure 3-11(d) Number of video views in each cluster (Unit 4).

図 3-12 は、クラスタごとの職種分布を求めたものである。職種 3(大学・研究機関(図書系))、職種 3 以外の職種、職種について回答無しの 3 つの割合をグラフ化している。この図を見ると、視聴数の多いクラスタほど職種について回答し、その中で職種 3 に勤務している割合が大きくなっていることが分かる。




図 3-12 クラスタごとの職種の分布

Figure 3-12 Job category in each cluster.

図 3-13 は，クラスタごとの合格/不合格の割合を見たものである．クラスタ q ~t は合格の割合が大きく，クラスタ u,v は不合格の割合が大きい．また，クラスタ r は全員が合格しており，最も視聴数が多いクラスタ q は，それよりも合格の割合が小さくなっている．これは，視聴数が多ければ熱心に学習していて成績が良いとは単純に言うことはできないことを示している．むしろ，理解できないために視聴数が増えている場合と考えられる．




図 3-13 クラスタごとの合格/不合格割合

Figure 3-13 Pass/Fail ratio in each cluster.

3.6. まとめと考察

本章では、予備的な検証として行った学習ログの分析について述べた。研究データ管理 M00C 講座を対象とし、映像視聴数を用いた学習者のクラスタリングを行い、再生エラー等による外れ値の影響によって、学習者が数多くの小さなクラスタに分割されてしまう場合があること、映像の視聴数を、1日1回以上視聴した場合に1回とカウントすることで、それを回避することができることを明らかにした。また、視聴数の多いクラスタほど職種について回答し、その中で大学・研究機関(図書系)に勤務している割合が大きくなっていること、概ね映像の視聴数が多いクラスタほど合格者の割合が大きくなるものの、最も視聴数が多いクラスタの合格率が最も高くなるわけではないことなど学習者の特徴の違いを明らかにした。

もし、学習行動を分析することだけが目的であるのであれば、再生エラー等による外れ値のデータを除いて処理を行うことも考えられるが、本研究の最終的な目的は、ドロップアウトの軽減に向けて、支援が必要となるであろう学習者クラスタを見つけ出すことである。この場合、再生エラーを伴う場合には対応できないと言うわけにはいかない。本章の結果、映像の視聴数については、1日1回以上視聴した場合に1回とカウントすることで、学習者が数多くの小さなクラスタに分割されてしまうことを回避できることが明らかになったことから、以降の分析では、映像の視聴数については、1日1回以上視聴した場合に1回とカウントして処理を行うこととする。

4. 学習者特徴の抽出とそれに基づく点数の推定

4.1. はじめに

第4章では、プログラミング MOOC 講座を対象として、学習終了時の成績を予測するために有用な学習者の特徴量を明らかにする。具体的には、対象とした講座の学習は主に映像を視聴することにより行われることから、映像の視聴行動とアンケートから学習者の特徴を抽出し、成績との関連を分析した。また、学習開始から N 週間までに得られた特徴量をもとに、重回帰分析を用いて、学習終了時の点数および合否の推定を行い、抽出した特徴量の有効性を検証した [96]。

4.2. プログラミング MOOC 講座の概要

情報化が加速する現代社会において、プログラミング教育の重要性に対する認識は世界中で高まり、各国でプログラミング教育が実施されている [97]。国内においてもその重要性が論じられ [98]、小学校教育への導入も行われている。プログラミング教育に関する研究はこれまで様々な分野でなされており、その教育効果も多数報告されている [99, 100]。国立情報学研究所では、大学等で共通に利用可能な教材の開発や、それを利用するための学習管理システムの提供が行われているが [101]、プログラミング入門の MOOC 講座として、「はじめての P」が開講されている [102]。第4章、第5章では、この MOOC 講座を対象に分析を行う。

MOOC 講座「はじめての P」は、JM00C のプラットフォームの一つである gacco で、2016 年 8 月 9 日から 70 日間開講された。講座は、3 人の講師と 1 人のナビゲータが担当し、全 4 回（以下、それぞれの回を Unit と呼ぶ）で構成される。各 Unit の講義タイトルと内容は表 4-1 の通りである。各 Unit は 15 分～30 分程度の映像 3～5 本による講義と、5 問程度の小テストで構成されている。開講時に Unit 1 が視聴可能になり、1 週間ごとに以降の Unit が順次視聴可能になる。一度、視聴可能になった Unit は、講座の終了まで視聴できる。小テストは 3 回まで受験可能で、小テストを受験しなかった場合は 0 点となり、学習終了時の点数で合否が判断される。各 Unit の小テストは、100 点満点で採点され、それらに 0.25 の重みをかけて足し合わせたものが全体の点数になる。全体の点数が 70 点以上になった場合は合格となり、修了証が発行される。また、学習者の属性を把握するために、開始時に Web 上でアンケートを実施した。

表 4-1 講座の内容

Table 4-1 Content of the course.

Unit	タイトル	内容
1	プログラマになる ープログラミングの 魅力を学ぼう！ー	講師の体験をもとにプログラミングの魅力 や学習方法等について紹介する. Unit 2 の演 習を行うための基礎的なプログラミングの 知識 (変数と代入, 四則演算, 値の種類, 配 列) を学ぶ.
2	プログラミングのい ろはービットくん のツイート进行いじり 倒そう！ー	Web ブラウザ上で簡単な JavaScript プロ グラムを入力することで, ビットくんのツイ ート表示を改造する. プログラミングの基礎 (ステートメント, ループ, 条件分岐, 関数) について学ぶ.
3	プログラミング入門 ービットくんのゲー ムを完成させよう！ ー	ビットくんのゲーム (車にぶつからないよ うに家にたどり着く) を通じて, 自分にもプ ログラミングが出来そうという感覚を持っ てもらおう. ゲームプログラムの変更を通じて case 文, 関数を学ぶ.
4	アルゴリズム入門 ープログラミングの 理論を体験で学ば う！ー	身近な題材を使って, コンピュータの背後に ある数理のエッセンスを学ぶ. 選択ソートと マージソート, 右手法と幅優先探索, 二進法 と XOR.

「はじめての P」の学習者数は 6,859 名となり、講座を開講した 2016 年 8 月の直近 1 年の gacco における学習者数平均の 4,139 名を上回った。また、修了率は 18%であり、gacco の平均修了率が 15%、MOOC の世界的なレベルでの修了率も 10%程度という中で比較的高い修了率となった（表 4-2）。

表 4-2 学習者数と修了率

Table 4-2 Number of attendants and completion rate.

	学習者数	修了率
はじめての P	6,859	18%
gacco 講座平均 (直近 1 年)	4,139	15%

4.3. 学習行動の分析

対象とした MOOC 講座の場合、主に映像を視聴することで学習が行われる。このため、LMS 上に蓄積された映像視聴行動は、学習行動の大きな特徴の一つとして利用することができる。以下の分析では、学習者の属性情報も処理に利用するため、受講した 6,859 名の中から、開始アンケートに回答した 2,415 名の学習者の学習ログを利用して分析を行うこととした。「はじめての P」全体の修了率が 18%であるのに対して、開始アンケートに回答した学習者の修了率は 35%であり、合格者の割合が高くなっているが、65%は不合格者であることから、合格者、不合格者のいずれの行動も分析対象とすることができると考えられる。

映像の視聴数については、3.5. で述べたように、単純な映像視聴数を使った場合、視聴数が極端に大きくなる学習者があり、そのため数多くの小さなクラスターに分割されるという問題があることから、各 Unit の映像を 1 日に 1 回以上見た場合に 1 回として分析を行い、このようにカウントした映像の視聴数を映像視聴数と呼ぶこととする。

図 4-1 に、映像視聴数のヒートマップを示す。縦軸はコース全体の経過時間であり、一番上には講座開始から 1 日目が表示され、1 番下には講座が終了する 70 日目が表示されている。縦の 1 本の線は一人の学習者に対応しており、2,415 人の学習者全てが表示されている。横軸は学習者を点数の降順に並べ、同点の場合は小テストの受験日時の早い順に並べられている。横軸の目盛りの 0 と 10 の間

が 0 点以上 10 点未満に対応する。100 より左側は全て 100 点となる。視聴数は、白色は閲覧数が 0 回、灰色は閲覧数が 1 回、黒色は閲覧数が 2 回以上を意味する。講座は 4 つの Unit で構成されるため、それぞれの学習者の映像視聴数は、1 日で最大 4 増えることになる。一般的な傾向として、図の左の方が暗くなっており、点数が低い学習者よりも点数が高い学習者の方が映像の視聴数が多いことが分かる (FEATURE 1)。また、図の左端の部分は 1 週間ごとに暗くなっており、右側の部分よりもグラデーションがはっきりと見られる (FEATURE 2)。これは、本講座では、1 週間ごとに Unit が順次視聴可能になることから、高点数の学習者がそれに合わせて定期的に学習しているという傾向を反映していると考えられる。また、図の右上の部分が白く、その下の部分では、左から右に向かって暗い線が落ちている (FEATURE 3)。この暗い部分が、学習者が映像を視聴し始めた時点になる。このパターンは、点数の低い学習者がコースを始めるのが遅い傾向にあることを反映している。以下では、それぞれの特徴についてより詳しく見ていく。

FEATURE 1 について見るために、図 4-2 に映像の視聴数を示す。図 4-2(a) は初回視聴から 1 週間後の結果、図 4-2 (b) は初回視聴から 3 週間後の結果、図 4-2 (c) は初回視聴から 10 週間後の結果を示している。横軸は、図 4-1 と同様に、学習者を点数の降順に並べている。縦線は 1 人の学習者に対応しており、4 本の線は、上から順に、Unit 1 から Unit 4 までの映像の視聴数に対応している。視聴数を 5 段階のグレースケールで表示しており、白は 0 回、黒は 4 回以上の視聴を表している。1 週間後の図 4-2 (a) を見ると、学習者は主に Unit 1 を見ていることが分かる。3 週間後の図 4-2 (b) では、点数の高い学習者は、Unit 2 と Unit 3 を繰り返し見ていることが分かる。これは、Unit 2 と Unit 3 がこの MOOC コースの主要な内容であり、比較的難易度が高いためと考えられる。Unit 2 の場合、合格ラインの 70 点の少し下の 50 点前後まで暗い部分が続いている (α)。また、コースを進めていくうちに濃淡が低下している学習者がいることが分かる (β)。このような学習者は、途中で学習をやめた学習者と考えられ、適切な支援を行うことで救済できる可能性がある。10 週間後の図 4-2 (c) では、点数が高い学習者ほど Unit 4 を見ていることが分かる。このコースでは、全体の点数が 70 点以上であれば合格となり、この図に示された 2,415 人の学習者のうち、833 人の学習者が最終的に合格している。これらの学習者は図の 1/3 近くを占めており、Unit 4 を繰り返し視聴した学習者とほぼ一致していることが分かる。

FEATURE 2 について見るために、図 4-3 に映像の視聴間隔を示す。図 4-3 (a)

は初回視聴から1週間後の結果、図4-3 (b)は初回視聴から3週間後の結果、図4-3 (c)は初回視聴から10週間後の結果を示している。横軸は、図4-1と同様に、学習者を点数の降順に並べている。縦軸は映像の視聴間隔であり、上から順に0日から29日までとなっている。間隔は、学習者が同じ日に複数のUnitの映像を視聴した場合は0日、学習者がいる日とその前日に映像を視聴した場合は1日としている。濃淡は4段階のグレースケールで示しており、白は0回、黒は3回以上を表す。3週間後の図4-3 (b)を見ると、高点数の学習者は1日以上の間隔で繰り返し映像を視聴している(α)。10週間後の図4-3(c)では、特に点数が高い学習者では7日間隔の濃淡が顕著になり(β)、高点数の学習者は1週間間隔で定期的に映像を見ていることが分かる。また、20日以上の間隔については、頻度がほぼ0であることが分かる(γ)。

FEATURE 3について見るために、図4-4では学習者の視聴開始日を示している。横軸は、図4-1と同様に、学習者を点数の降順に並べている。縦軸は受講開始からの経過日数で、一番上が1日目、一番下が70日目となる。黒い点が、それぞれの学習者の映像視聴の開始日に対応する。この図を見ると、特に成績が良い学習者は、1日目から受講している人数が多いことが分かる(α)。これは、講座がいつ始まるかを予め知っていて、開講初日から視聴を開始した学習者と考えられる。(α)の部分の後に黒い線が落ちるが、これは、同じ点数でも、遅れて視聴を始める学習者がいることを示している。一方、成績が低い学習者は、比較的視聴が遅い学習者の割合が多い(β)。これは、講座の開講後に講座の存在を知り、アクセスをした学習者の割合が多かったためと考えられる。(α)と(β)の間の、点数が50点前後の学習者を見ると、点数の高い学習者と同様に視聴開始が早い学習者も多く、これらの学習者は適切なサポートを行えば救済できる可能性がある。一方、(β)で示される7日目以降に受講を開始した学習者については、10点未満の点数となっており、サポートを行ったとしても、コースを終了させることは容易ではないと考えられる。




図 4-1 映像視聴数のヒートマップ

Figure 4-1 Heat map of Video Views.




図 4-2(a) 映像視聴数 (1 週)

Figure 4-2(a) Number of Video Views (1 week).




图 4-2(b) 映像視聴数 (3 週)

Figure 4-2(b) Number of Video Views (3 weeks).




图 4-2(c) 映像視聴数 (10 週)

Figure 4-2(c) Number of Video Views (10 weeks).




図 4-3(a) ビデオの視聴間隔 (1 週)

Figure 4-3(a) Intervals of Video Views (1 week).




図 4-3(b) ビデオの視聴間隔 (3 週)

Figure 4-3(b) Intervals of Video Views (3 weeks).




図 4-3(c) ビデオの視聴間隔 (10 週)

Figure 4-3(c) Intervals of Video Views (10 weeks).




图 4-4 映像視聴開始日

Figure 4-4 First Access to Videos.

4.4. 点数および合否の推定

4.3.の結果から、映像視聴行動から得られた特徴量は、学習者の点数を推定するために利用することができると考えられる。

学習終了時の点数の推定には、最初の映像視聴からN週間後の以下の特報量を用いる。最初の映像視聴からN週間後の特徴量を用いた場合、遅れて受講を開始した学習者は、ある時期以降、特徴量に変化しない状態になるが、MOOC講座の場合、必ずしも全員が同期して学習するわけではないことから、学習者ごとの時間経過によって推定を行うこととした。

1) 映像視聴数

各Unitの映像を1日に1回以上見た場合に1、それ以外を0として、N週間の合計を映像視聴数とした。学習教材は4つのUnitで構成されているため、映像視聴数の特徴量は4次元データとなる。

2) 映像の視聴間隔

間隔は、学習者が同じ日に複数のUnitの映像を視聴した場合は0日、学習者がある日とその前日に映像を視聴した場合は1日としてカウントされる。これは、集中的に短い間隔で視聴するか、間を空けて見るかの特徴になる。図4-3により、20日以上頻度はほぼ0であるため、視聴間隔は0日から19日までの20次元のデータとした。

3) 映像の視聴開始日

映像への最初の視聴日が開講日の何日後かを示す整数。学習開始時点で、開講から何日目かが分かる。これは1次元データであり、一度も視聴がなければ開講後の71日目を学習開始日とした。

学習終了時の点数の予測は、上述の映像視聴数(V1~V4)の4次元データ、映像視聴間隔(D0~D19。DNは、N日間隔とする)の20次元データ、映像の視聴開始日(Start)の1次元データを合わせた、全体で25次元データを入力とし、重回帰分析を用いて学習終了時の点数を最も再現するように標準偏回帰係数を決定することで行った。ツールとしては、オープンソースの統計解析ソフトであるRを利用した。

表4-3に、重回帰分析の結果を示す。最初の映像視聴から1週間後のデータを用いて算出した標準偏回帰係数が表4-3(a)、3週間後のデータを用いて算出した標準偏回帰係数が表4-3(b)、10週間後のデータを用いて算出した標準偏回帰係数が表4-3(c)である。

表 4-3(a)を見ると、最初の映像視聴から 1 週間後では、0 日から 6 日の視聴間
隔(D0～D6)、映像の視聴数(V1～V4)、映像の視聴開始日(Start)のいずれの標準偏
回帰係数も有意なものになっている。特に、0 日から 1 日の視聴間隔 (D0～D1)
の値が大きく、これらが点数の予測に影響が大きいことが分かる。

表 4-3(b)を見ると、最初の映像視聴から 3 週間後では、18 日から 19 日の視聴
間隔(D18～D19)、Unit4 の映像視聴数(V4)の標準偏回帰係数以外は有意なものに
なっている。特に、7 日の視聴間隔 (D7) の値が大きく、3 週間後では、1 週間程
度の繰り返しの視聴が点数の予測に影響があることが分かる。

表 4-3(c)を見ると、最初の映像視聴から 10 週間後は、ほぼ、3 週間後と同様の
傾向があるが、1 週間後と同様に、0 日から 1 日の視聴間隔 (D0～D1) の値が大き
いという傾向も見られる。

表 4-3(a) 重回帰分析結果(1 週)

Table 4-3(a) Results of multiple regression analysis (1 week).

自由度修正済み決定係数 0.326

	標準偏回帰係数	t値	p値	
V1	-0.628	-17.394	< 0.001	***
V2	-0.452	-15.26	< 0.001	***
V3	-0.097	-4.914	< 0.001	***
V4	-0.069	-3.775	< 0.001	***
D0	0.528	18.767	< 0.001	***
D1	0.484	17.051	< 0.001	***
D2	0.240	11.951	< 0.001	***
D3	0.149	8.079	< 0.001	***
D4	0.160	8.934	< 0.001	***
D5	0.152	8.558	< 0.001	***
D6	0.143	8.074	< 0.001	***
Start	-0.382	-16.978	< 0.001	***

*** p < 0.001, ** p < 0.01, * p < 0.05, · p < 0.1

表 4-3(b) 重回帰分析結果(3週)

Table 4-3(b) Results of multiple regression analysis (3 weeks).

自由度修正済み決定係数 0.574

	標準偏回帰係数	t値	p値	
V1	-0.289	-9.058	< 0.001	***
V2	-0.216	-4.775	< 0.001	***
V3	0.158	4.699	< 0.001	***
V4	-0.026	-1.462	0.144	
D0	0.229	6.048	< 0.001	***
D1	0.256	5.949	< 0.001	***
D2	0.168	7.815	< 0.001	***
D3	0.115	6.651	< 0.001	***
D4	0.180	11.197	< 0.001	***
D5	0.146	9.407	< 0.001	***
D6	0.197	13.168	< 0.001	***
D7	0.268	17.446	< 0.001	***
D8	0.166	11.627	< 0.001	***
D9	0.137	9.763	< 0.001	***
D10	0.106	7.795	< 0.001	***
D11	0.072	5.308	< 0.001	***
D12	0.082	6.021	< 0.001	***
D13	0.062	4.537	< 0.001	***
D14	0.052	3.877	< 0.001	***
D15	0.055	4.085	< 0.001	***
D16	0.069	5.140	< 0.001	***
D17	0.036	2.676	0.008	**
D18	0.021	1.582	0.114	
D19	0.002	0.118	0.906	
Start	-0.156	-8.555	< 0.001	***

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$, • $p < 0.1$

表 4-3(c) 重回帰分析結果(10 週)

Table 4-3(c) Results of multiple regression analysis (10 weeks).

自由度修正済み決定係数 0.591

	標準偏回帰係数	t値	p値	
V1	-0.399	-13.533	< 0.001	***
V2	-0.419	-9.442	< 0.001	***
V3	-0.053	-1.449	0.147	
V4	0.045	1.546	0.122	
D0	0.410	9.703	< 0.001	***
D1	0.400	8.803	< 0.001	***
D2	0.193	8.411	< 0.001	***
D3	0.117	6.309	< 0.001	***
D4	0.175	10.536	< 0.001	***
D5	0.165	10.493	< 0.001	***
D6	0.199	13.042	< 0.001	***
D7	0.278	17.752	< 0.001	***
D8	0.136	9.546	< 0.001	***
D9	0.099	7.146	< 0.001	***
D10	0.090	6.674	< 0.001	***
D11	0.071	5.274	< 0.001	***
D12	0.063	4.702	< 0.001	***
D13	0.046	3.418	< 0.001	***
D14	0.064	4.836	< 0.001	***
D15	0.048	3.609	< 0.001	***
D16	0.051	3.829	< 0.001	***
D17	0.028	2.136	0.033	*
D18	0.012	0.931	0.352	
D19	-0.014	-1.032	0.302	
Start	-0.187	-10.937	< 0.001	***

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$, • $p < 0.1$

図 4-5 は、学習開始からの経過期間を大きくしていった場合の自由度修正済み決定係数の変化を示す。3 週目以降は、0.6 前後になっており、映像の視聴行動はある程度、点数を説明できていることが分かる。





図 4-5 自由度修正済み決定係数の変化

Figure 4-5 Variation of adjusted coefficient of determination.


図 4-6 は、実際の点数と予測点数の相関を見たものである。図 4-6(a)は、受講開始から 1 週間後、図 4-6(b)は 3 週間後、図 4-6(c)は 10 週間後の結果である。横軸は実際の点数、縦軸は重回帰分析で予測した点数である。点数が完全に予測できれば、点は(0, 0)と(100, 100)の間の直線上に並ぶ。1 つの○は、一人の学習者に対応し、この図には 2, 415 個の○が表示されている。1 週間後の実際の点数と予測点数との相関は低いものの、時間が経つにつれて相関が強くなっていることが分かる。



自由度修正済み決定係数 0.326

図 4-6(a) 点数と予測点数 (1 週)


Figure 4-6(a) Correlation between score and predicted score (1 week).



自由度修正済み決定係数 0.574

図 4-6(b) 点数と予測点数 (3 週)

Figure 4-6(b) Correlation between score and predicted score (3 weeks).



自由度修正済み決定係数 0.591

図 4-6(c) 点数と予測点数 (10 週)

Figure 4-6(c) Correlation between Score and Predicted Score (10 weeks).

図 4-7 は、点数と予測点数の相関係数の変化を示したものである。3 週目以降は、0.8 弱になっており、映像視聴行動と点数には、ある程度強い相関があることが分かる。




図 4-7 相関係数の変化

Figure 4-7 Variation of correlation coefficient.

図 4-8 に、推定した点数を用いた合否の推定結果を示す。この講座では点数が 70 点以上は合格、70 点未満は不合格になる。このため、実際の点数が 70 点以上で、予測された点数が 70 点以上の場合、および、実際の点数が 70 点未満で、予測された点数が 70 点未満の場合、合格、不合格を正しく推定できたことになる。図 4-8 を見ると、3 週以降は、80%以上の精度で合否の推定を行えている。分析対象とした 2,415 名の合格率は 35%であり、単純に全員不合格とした場合よりも高い精度で合否の推定を行えている。以上の結果から、映像の視聴行動は、点数の推定に有用な特徴量であることが分かる。




図 4-8 合格/不合格の予測

Figure 4-8 Prediction of Pass/Fail.

4.5. アンケートの利用による予測精度の向上

対象とした講座では、学習者の属性を把握するために、開始時に Web 上でアンケートを実施している。ここでは、このアンケートの結果を用いて、点数の予測精度、および、合格/不合格の推定がどの程度改善されるかを検証した。

図 4-9 に年齢の分布を示す。横軸は、年齢であり、横軸の目盛りの 0 と 10 の間は、0 歳以上、10 歳未満に対応する。開始アンケートでは、生年を答えるようになっていたため、開講年である 2016 年から生年を引いた値を年齢とした。ただし、生年については、数値を入れる形式であったため、開講した 2016 年時点での年齢が 0 から 100 歳の範囲以外の不自然な値になっているものが 24 件あったため、これらは除外して分布を求めている。全体の平均年齢は、46.9 歳であった。




図 4-9 年齢の分布

Figure 4-9 Distribution of ages.

図 4-10 に年齢と点数分布の関係を示す。横軸は、点数であり、横軸の 0 は、0 点以上、9 点未満を表す。横軸の 100 は、100 点を表す。縦軸は、年齢ごとの構成割合を示している。年齢については、0 歳以上 25 歳未満を W、25 歳以上 50 歳未満を X、50 歳以上 75 歳未満を Y、75 歳以上を Z としている。全体的な傾向を見ると、0 点以上 10 点未満のほとんど 0 点をとる人と、100 点をとる人の割合が大きいことが分かる。20 点以上 30 点未満の割合も大きくなっているが、これは、主に、Unit 1 の小テストのみを受験した人に対応する。また、比較的年齢の若い W, X については、100 点をとる割合が低く、0 点以上 10 点未満、20 点以上 30 点未満といった低い点数をとる割合が大きいことが分かる。平均点数については、W, X, Y, Z の順に、29.6, 32.7, 51.3, 55.0 点となった。この講座は、主に若い人向けのプログラミング講座として開設したものであるが、実際には、年齢が上がるにつれて点数が上がる傾向があることが分かった。




図 4-10 年齢と点数分布

Figure 4-10 Age and score distribution.

図 4-11 にプログラミングスキルの分布を示す。開始アンケートでは、プログラミング経験について、

Skill レベル 1: 未経験

Skill レベル 2: プログラミング入門書や入門サイトで勉強したことがある

Skill レベル 3: 自分で考えたプログラムを作ったことがある

Skill レベル 4: 日常的にプログラミングをしている（専攻、職業）

の 4 つから選択するようになっており、その人数を示している。それぞれの人数は、1, 309, 597, 391, 118 であり、スキルが高くなるにつれて人数は減っている。




図 4-11 プログラミングスキルの分布

Figure 4-11 Distribution of programming skills.

図 4-12 にプログラミングスキルと点数分布の関係を示す。横軸は、点数であり、横軸の 0 は、0 点以上、9 点未満を表す。横軸の 100 は、100 点を表す。縦軸は、プログラミングスキルごとの構成割合を示している。全体的な傾向は、図 4-11 と同様に、0 点以上 10 点未満、100 点、20 点以上 30 点未満の割合が大きくなっている。また、スキルが低い 1 については、100 点を取る割合が低く、0 点以上 10 点未満といった低い点数をとる割合が大きいことが分かる。スキルごとの平均点数は、Skill レベル 1~4 の順に、35.3, 47.3, 52.2, 47.0 点となった。Skill レベル 4 の平均点が Skill レベル 3 よりも若干下がるものの、Skill レベル 1~3 では、スキルが上がるにつれて点数が上がる傾向があることが分かる。




図 4-12 プログラミングスキルと点数分布

Figure 4-12 Programming skill and score distribution.

アンケート項目「本講座に期待することがあれば、自由にお書きください。」については、自由記述による回答を得た。自由記述の中には、プログラミングを学ぶ目的や意欲等を反映した記述も含まれることが予想される。たとえば、プログラミングに対して強い興味があれば、意欲的に学習に取り組むかも知れない。一方で、不安を口にしていない学習者であれば、比較的早い段階で学習を諦めるかも知れない。自由記述を分析することで、話題としている内容と点数との関連性が分かれば、特に、取得できる学習ログが必ずしも多くない、学習の初期段階での成績推定に役立つ可能性がある。

自由記述の分析については、自由記述に対して形態素解析を行い、名詞のみを抽出した上で、キーワードの重要度の指標として用いられる TF-IDF 値を計算し、値が大きい順に以下の 60 の単語を重要なキーワードとして選び出した。これらの単語の出現数をそれぞれの学習者の特徴として利用する。

「プログラミング, 理解, 期待, プログラム, 講座, 基礎, 初心者, 内容, お願い, 自分, 知識, 基本, 言語, 受講, 学習, 講義, 勉強, 簡単, 興味, 楽しみ, 身, きっかけ, レベル, 習得, 説明, 作成, 考え方, 経験, 素人, スキル, 授業, 今後, 人, 仕事, 今, 初歩, 方法, 入門, 最後, 技術, わかりやすさ, 継続, アップ, 私, 実践, ステップ, 応用, 用語, 概念, 不安, 解説, 独学, 教育, 専門, 程度, パソコン, 最近, 挫折, アプリ, 終了」

ここで, 4.4. で述べた映像視聴行動から得られた特徴量に, 開始アンケートから得られる年齢とプログラミングスキル, 自由記述中のキーワードの数の情報を追加し, 学習者の点数を推定する. 年齢については, 年齢が 0-100 の範囲以外の不自然な値になる 24 件については, 全体の年齢の平均値の小数点以下を切り捨てた 46 歳として扱った. プログラミングスキルについては, Skill レベル 1 から Skill レベル 4 までを, それぞれ, 1 から 4 で数値化した. 数値が大きいほど, プログラミングの経験があるという指標になる. 自由記述中のキーワードの数は, 先に述べた TF-IDF が大きな 60 の単語の出現数を並べた 60 次元のベクトルとなる.

表 4-4 に, 重回帰分析の結果を示す. 最初の映像視聴から 1 週間後のデータを用いて算出した標準偏回帰係数が表 4-4(a), 3 週間後のデータを用いて算出した標準偏回帰係数が表 4-4(b), 10 週間後のデータを用いて算出した標準偏回帰係数が表 4-4(c)である. 表中の Age は年齢, Skill はプログラミングスキルであり, それ以外の単語は, TF-IDF の値が大きい順に選んだ 60 のキーワードに対応する.

この結果を見ると, プログラミングの経験 (Skill) に関しては, 標準偏回帰係数の値自体は必ずしも大きくはないものの, いずれの週でも有意なものになっている. 年齢 (Age) に関しては, 3 週間後, 10 週間後では有意ではなかったものの, 1 週間後には, p 値が 0.001 未満と高い有意性を示した. 3 週間後, 10 週間後に有意ではなかったのは, 学習開始からの時間が経過し, 映像視聴に関する学習ログが蓄積するにつれて, 相対的に年齢の重要度が下がったためと考えられる. キーワードについては, 1 週間後では, 「最近」, 「習得」, 「継続」といったキーワードが有意なものとなっている. 「最近のプログラミングに関して関心がある」や, 「プログラミングを習得したい」といった興味や意欲を反映したものと考えられる.

表 4-4(a) 重回帰分析結果(1週)

Table 4-4(a) Results of multiple regression analysis (1 week).

自由度修正済み決定係数 0.355

	標準偏回帰係数	t値	p値	
V1	-0.577	-16.103	< 0.001	***
V2	-0.416	-14.041	< 0.001	***
V3	-0.088	-4.528	< 0.001	***
V4	-0.064	-3.543	< 0.001	***
D0	0.472	16.732	< 0.001	***
D1	0.454	16.026	< 0.001	***
D2	0.232	11.673	< 0.001	***
D3	0.135	7.377	< 0.001	***
D4	0.145	8.086	< 0.001	***
D5	0.149	8.520	< 0.001	***
D6	0.128	7.289	< 0.001	***
Start	-0.368	-16.431	< 0.001	***
Skill	0.136	7.764	< 0.001	***
Age	0.099	5.646	< 0.001	***
プログラミング	0.024	1.347	0.178	
理解	0.032	1.879	0.060	・
期待	-0.013	-0.723	0.469	
プログラム	0.030	1.675	0.094	・
講座	-0.010	-0.561	0.575	
基礎	0.006	0.344	0.731	
初心者	0.007	0.419	0.675	
内容	0.007	0.427	0.669	
お願い	-0.007	-0.442	0.658	
自分	-0.001	-0.059	0.953	
知識	0.011	0.609	0.542	
基本	-0.008	-0.471	0.638	
言語	0.014	0.854	0.393	
受講	0.001	0.037	0.971	
学習	-0.017	-1.007	0.314	
講義	0.007	0.408	0.683	
勉強	0.027	1.584	0.113	
簡単	0.027	1.551	0.121	
興味	-0.004	-0.264	0.792	
楽しみ	0.031	1.863	0.063	・
身	0.011	0.613	0.540	
きっかけ	-0.023	-1.379	0.168	
レベル	0.011	0.668	0.504	
習得	0.036	2.063	0.039	*
説明	0.021	1.213	0.225	
作成	0.012	0.704	0.482	
考え方	-0.002	-0.137	0.891	
経験	0.006	0.384	0.701	
素人	0.020	1.165	0.244	

(前ページから続く)

スキル	-0.002	-0.113	0.910	
授業	-0.013	-0.771	0.441	
今後	-0.005	-0.323	0.747	
人	-0.011	-0.639	0.523	
仕事	-0.025	-1.500	0.134	
今	0.016	0.956	0.339	
初歩	-0.020	-1.207	0.228	
方法	-0.015	-0.886	0.375	
入門	0.018	1.068	0.285	
最後	0.016	0.949	0.343	
技術	0.003	0.192	0.848	
わかりやすさ	-0.001	-0.050	0.960	
継続	0.033	1.990	0.047	*
アップ	-0.023	-1.069	0.285	
私	-0.012	-0.696	0.487	
実践	-0.011	-0.639	0.523	
ステップ	0.014	0.742	0.458	
応用	-0.021	-1.234	0.217	
用語	-0.023	-0.967	0.334	
概念	-0.018	-1.072	0.284	
不安	0.007	0.393	0.694	
解説	0.009	0.522	0.602	
独学	0.023	1.334	0.182	
教育	0.013	0.759	0.448	
専門	0.031	1.337	0.181	
程度	0.003	0.167	0.868	
パソコン	0.005	0.314	0.754	
最近	0.051	3.013	0.003	**
挫折	-0.006	-0.368	0.713	
アプリ	-0.015	-0.875	0.382	
終了	0.021	1.249	0.212	

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$, • $p < 0.1$

表 4-4(b) 重回帰分析結果(3週)

Table 4-4(a) Results of multiple regression analysis (3 week).

自由度修正済み決定係数 0.577

	標準偏回帰係数	t値	p値	
V1	-0.274	-8.565	< 0.001	***
V2	-0.192	-4.223	< 0.001	***
V3	0.151	4.488	< 0.001	***
V4	-0.033	-1.778	0.075	・
D0	0.207	5.454	< 0.001	***
D1	0.254	5.894	< 0.001	***
D2	0.168	7.758	< 0.001	***
D3	0.104	5.978	< 0.001	***
D4	0.176	10.785	< 0.001	***
D5	0.140	8.910	< 0.001	***
D6	0.194	12.847	< 0.001	***
D7	0.258	16.629	< 0.001	***
D8	0.158	11.043	< 0.001	***
D9	0.132	9.334	< 0.001	***
D10	0.105	7.582	< 0.001	***
D11	0.070	5.103	< 0.001	***
D12	0.079	5.766	< 0.001	***
D13	0.058	4.201	< 0.001	***
D14	0.051	3.771	< 0.001	***
D15	0.054	3.938	< 0.001	***
D16	0.069	5.130	< 0.001	***
D17	0.031	2.296	0.022	*
D18	0.018	1.298	0.194	
D19	0.004	0.296	0.768	
Start	-0.158	-8.595	< 0.001	***
Skill	0.095	6.627	< 0.001	***
Age	0.007	0.490	0.624	
プログラミング	0.002	0.112	0.911	
理解	0.007	0.477	0.634	
期待	-0.006	-0.394	0.693	
プログラム	0.028	1.916	0.055	・
講座	-0.015	-1.088	0.277	
基礎	0.001	0.084	0.933	
初心者	0.003	0.197	0.844	
内容	0.011	0.795	0.427	
お願い	0.003	0.222	0.825	
自分	0.013	0.935	0.350	
知識	0.006	0.411	0.681	
基本	-0.001	-0.102	0.919	
言語	0.002	0.130	0.896	
受講	-0.016	-1.140	0.254	
学習	-0.005	-0.380	0.704	
講義	0.010	0.697	0.486	

(前ページから続く)

勉強	0.017	1.216	0.224	
簡単	0.010	0.738	0.461	
興味	-0.003	-0.184	0.854	
楽しみ	0.013	0.942	0.346	
身	0.020	1.418	0.156	
きっかけ	-0.011	-0.808	0.419	
レベル	0.002	0.159	0.874	
習得	0.032	2.268	0.023	*
説明	0.013	0.922	0.357	
作成	0.005	0.375	0.708	
考え方	0.004	0.257	0.797	
経験	0.002	0.112	0.910	
素人	0.010	0.754	0.451	
スキル	-0.005	-0.304	0.761	
授業	0.005	0.376	0.707	
今後	0.004	0.299	0.765	
人	-0.007	-0.495	0.620	
仕事	-0.024	-1.757	0.079	・
今	0.009	0.658	0.511	
初歩	-0.028	-2.066	0.039	*
方法	-0.012	-0.878	0.380	
入門	0.022	1.630	0.103	
最後	0.022	1.609	0.108	
技術	-0.006	-0.410	0.682	
わかりやすさ	-0.002	-0.120	0.904	
継続	0.033	2.404	0.016	*
アップ	-0.002	-0.094	0.925	
私	-0.004	-0.297	0.766	
実践	0.005	0.331	0.740	
ステップ	0.011	0.730	0.466	
応用	-0.006	-0.418	0.676	
用語	-0.035	-1.828	0.068	・
概念	0.005	0.346	0.729	
不安	-0.001	-0.048	0.961	
解説	0.004	0.289	0.773	
独学	0.013	0.924	0.356	
教育	0.001	0.089	0.929	
専門	0.017	0.896	0.370	
程度	0.014	1.049	0.294	
パソコン	0.000	-0.008	0.994	
最近	0.024	1.707	0.088	・
挫折	-0.011	-0.837	0.403	
アプリ	-0.002	-0.167	0.867	
終了	0.024	1.799	0.072	・

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$, ・ $p < 0.1$

表 4-4(c) 重回帰分析結果(10 週)

Table 4-4(a) Results of multiple regression analysis (10 week).

自由度修正済み決定係数 0.594


	標準偏回帰係数	t値	p値	
V1	-0.381	-12.815	< 0.001	***
V2	-0.390	-8.689	< 0.001	***
V3	-0.051	-1.382	0.167	
V4	0.039	1.296	0.195	
D0	0.381	8.945	< 0.001	***
D1	0.390	8.521	< 0.001	***
D2	0.190	8.185	< 0.001	***
D3	0.109	5.848	< 0.001	***
D4	0.171	10.080	< 0.001	***
D5	0.160	10.062	< 0.001	***
D6	0.195	12.682	< 0.001	***
D7	0.269	17.010	< 0.001	***
D8	0.133	9.280	< 0.001	***
D9	0.099	7.048	< 0.001	***
D10	0.091	6.647	< 0.001	***
D11	0.066	4.897	< 0.001	***
D12	0.060	4.455	< 0.001	***
D13	0.042	3.152	0.002	**
D14	0.062	4.618	< 0.001	***
D15	0.046	3.425	< 0.001	***
D16	0.050	3.727	< 0.001	***
D17	0.024	1.798	0.072	•
D18	0.010	0.790	0.430	
D19	-0.012	-0.900	0.368	
Start	-0.185	-10.766	< 0.001	***
Skill	0.094	6.727	< 0.001	***
Age	0.018	1.295	0.196	
プログラミング	-0.002	-0.138	0.890	
理解	0.008	0.572	0.567	
期待	-0.008	-0.592	0.554	
プログラム	0.014	1.013	0.311	
講座	-0.013	-0.965	0.335	
基礎	0.001	0.090	0.928	
初心者	0.014	1.026	0.305	
内容	0.012	0.894	0.371	
お願い	0.001	0.077	0.939	
自分	0.007	0.535	0.593	
知識	0.004	0.283	0.777	
基本	-0.006	-0.432	0.666	
言語	0.010	0.738	0.461	
受講	-0.007	-0.500	0.617	
学習	-0.007	-0.543	0.588	
講義	0.006	0.481	0.630	

(前ページから続く)

勉強	0.019	1.416	0.157	
簡単	0.006	0.435	0.664	
興味	-0.006	-0.428	0.669	
楽しみ	0.008	0.632	0.527	
身	0.017	1.225	0.221	
きっかけ	-0.004	-0.330	0.742	
レベル	-0.005	-0.341	0.733	
習得	0.027	1.978	0.048	*
説明	-0.001	-0.084	0.933	
作成	0.014	1.006	0.315	
考え方	0.011	0.812	0.417	
経験	0.004	0.285	0.776	
素人	0.008	0.608	0.543	
スキル	-0.002	-0.113	0.910	
授業	0.000	-0.030	0.976	
今後	0.000	-0.022	0.982	
人	-0.009	-0.676	0.499	
仕事	-0.024	-1.839	0.066	・
今	0.012	0.936	0.349	
初歩	-0.008	-0.615	0.539	
方法	-0.004	-0.328	0.743	
入門	0.004	0.289	0.773	
最後	0.026	1.952	0.051	・
技術	-0.003	-0.197	0.844	
わかりやすさ	-0.004	-0.285	0.776	
継続	0.034	2.574	0.010	*
アップ	-0.015	-0.865	0.387	
私	-0.005	-0.403	0.687	
実践	0.006	0.457	0.648	
ステップ	0.010	0.656	0.512	
応用	-0.004	-0.272	0.786	
用語	-0.029	-1.532	0.126	
概念	0.007	0.555	0.579	
不安	0.011	0.802	0.423	
解説	0.011	0.817	0.414	
独学	0.014	1.002	0.316	
教育	0.007	0.532	0.594	
専門	0.026	1.420	0.156	
程度	0.012	0.910	0.363	
パソコン	-0.015	-1.118	0.264	
最近	0.025	1.838	0.066	・
挫折	-0.002	-0.172	0.864	
アプリ	0.008	0.613	0.540	
終了	0.019	1.459	0.145	

*** p < 0.001, ** p < 0.01, * p < 0.05, ・ p < 0.1


図 4-13 は、実際の点数と予測点数の相関を見たものである。図 4-13(a)は、受講開始から 1 週間後、図 4-13(b)は 3 週間後、図 4-13(c)は 10 週間後の結果である。横軸は実際の点数、縦軸は重回帰分析で予測した点数である。図 4-6 と同様に、実際の点数と予測点数との相関関係は、時間が経つにつれて強くなることが分かる。



自由度修正済み決定係数 0.355

図 4-13(a) 点数と予測点数 (1 週)


Figure 4-13(a) Correlation between score and predicted score (1 week).



自由度修正済み決定係数 0.577

図 4-13(b) 点数と予測点数 (3 週)

Figure 4-13(b) Correlation between score and predicted score (3 weeks).



自由度修正済み決定係数 0.594

図 4-13(c) 点数と予測点数 (10 週)

Figure 4-13(c) Correlation between score and predicted score (10 weeks).

図 4-14 は、学習開始からの経過期間を大きくしていった場合の自由度修正済み決定係数の変化を示す。+ は、映像視聴行動から得られた特徴量のみを利用した場合であり、○は、開始アンケートから得られる情報を追加した場合の結果である。開始アンケートから得られる年齢、プログラミングスキル等の情報を利用することで、3 週目以前の自由度修正済み決定係数が改善されていることが分かる。




図 4-14 自由度修正済み決定係数の変化

Figure 4-14 Valiation of adjusted coefficient of determination.

図 4-15 に、推定した点数を用いた合否の推定結果を示す。+は、映像視聴行動から得られた特徴量のみを利用した場合であり、○は、開始アンケートから得られる年齢、プログラミングスキル等の情報を追加した場合の結果である。3週目以前の精度が向上しており、開始アンケートから得られる情報は、まだ十分に学習行動の情報を得られない、比較的早い時期の合否の推定に有用であることが分かる。




図 4-15 合格/不合格の予測

Figure 4-15 Prediction of Pass/Fail.

4.6. まとめと考察

4章では、プログラミング MOOC 講座を対象として、学習終了時の成績を予測するための有用な学習者の特徴量を明らかにするために、映像の視聴行動とアンケートから学習者の特徴を抽出し、成績との関連を分析した。この結果、全体的に点数が高い方が映像視聴が多いこと、点数が高い学習者は、定期的に学習していること、点数が低い学習者は受講開始が遅いといった特徴を明らかにした。

また、学習開始から N 週間までに得られた特徴量をもとに、重回帰分析を用いて、学習終了時の点数および合否の推定を行い、抽出した特徴量の有効性を検証した。その結果、点数の予測結果は十分精度が高いとは言えなかったものの、合否の推定については、3 週目以降では 80%以上の精度で行えることを明らかにした。また、開始アンケートから得られる、年齢やプログラミングスキル等の情報を利用することで、受講 3 週目までの点数の予測精度を向上できることを明らかにした。

以上の結果から、映像の視聴数、視聴間隔、視聴開始日、年齢、プログラミングスキルといった特徴量は、学習者の成績を予測するために有用な特徴量であることが明らかになった。

5. 小テストの点数パターンによる学習者のクラスタリングとその推定

5.1. はじめに

本章では、学習支援対象となる学習者群を特定し、その学習者群をできるだけ早期に推定するための方法を確立することを目的とする。具体的には、小テストの点数は修了条件に直接的に関係することから、プログラミング M00C 講座の学習者を対象として、小テスト点数を用いたクラスタリングにより学習者を細分類し、各クラスタの特徴を明らかにする。そして、それぞれの学習者がどのクラスタに属するかを推定することで、学習支援対象となる学習者を推定することを試みる [103].

5.2. 小テストの点数パターンによる学習者のクラスタリング

M00C における Tasters のような学習者群の存在を加味した場合、ドロップアウトから救う学習者群を単純なコースの合格者と不合格者と分けるのでは不十分である。不合格者となり得る群にも、特徴的なサブクラスタが存在し、それぞれにおいて適切な学習支援を提供できる可能性がある。このため、小テストの点数パターンに基づき学習者を複数のクラスタに分割し、その特徴を明らかにする。

具体的には、

Step.1 学習終了時の小テストの点数パターンに基づき学習者をクラスタリングし、学習者にどのようなクラスタがあるかを明らかにする。

Step.2 それぞれの学習者クラスタの分析を行い、その特徴を明らかにする。

という手順で分析を行う。

小テストの点数は修了条件に直接的に関係するため、たとえば、ある Unit 以降、小テストを受けていなければ、その時点でドロップアウトをしたと考えられる。また、Unit ごとで小テストの点数の差があれば、各 Unit の理解度を推定するための指標として利用できる。このように、小テストの点数は、学習者の学習行動や習得度の違いを把握するために利用できるとともに、複数回の小テストがあれば、より細かい単位で学習者のクラスタ分けを行えると考えられる。

そこで Step.1 では、クラスタリングに小テストを利用することとした。小テストが全部で N 回あれば、その点数を並べた N 次元のベクトルがそれぞれの学習者の特徴となる。クラスタリングには、一般に用いられる k 平均法を利用する。これにより、学習者にどのようなクラスタがあるかを明らかにすることができる。

このクラスタが，そのコースに特有のものであることを仮定すれば，任意の学習者について，学習終了時の小テスト点数と，各クラスタ重心との距離を求め，最も距離が近いクラスタを求めることで，その学習者がどのクラスタに属するかを決めることができる．

Step.2では，Step.1で分割されたクラスタの分析を行い，それぞれのクラスタの特徴を明らかにする．特徴としては，第4章で述べた映像の視聴数，受講開始日，繰り返して学習を行う間隔を，学習行動を反映した特徴量として利用する．また，開始アンケートから得られる年齢やプログラミングスキルも，学習者の属性を分析する上での有用な情報として利用する．

ここでは，学習者の属性情報を合わせて分析を行うため，4章と同じ，開始アンケートに回答した2,415名を対象として，学習者のクラスタリングを行った．対象とした講座の4つのUnitには，100点満点となる小テストが用意されていることから，学習者ごとに，4つの小テストの点数を並べた4次元データを得ることができる．この4次元データをk平均法によりクラスタリングすることで，学習者をいくつかの特徴的なクラスタへと分割する．

分割するクラスタ数については，エルボー法によって決定した．分割するクラスタ数を変化させた場合の自乗誤差の和を図5-1に示す．この図を見ると，クラスタ数を4から3にした時に，自乗誤差の増加が大きくなっていることから，クラスタ数を4とした．




図 5-1 クラスタ数の決定

Figure 5-1 Decision of the number of clusters.

クラスタリングした結果を図 5-2 に示す。図 5-2 では、4 つのクラスタそれぞれの重心の点数を示している。点数が高い順に A, B, C, D のラベル付けを行っており、それぞれのクラスタの人数は、表 5-1 のようになる。

クラスタ A は、全ての小テストにおいて、ほぼ満点を取っている。クラスタ B は、他のクラスタに比べて人数は少ないものの、Unit 1 から Unit 3 まではほぼ 100 点、Unit 4 は、ほとんど 0 点という特徴的な点数分布になっている。対象とした MOOC 講座では、小テスト点数が、全体で 70 点以上になる場合に修了証が発行されることから、クラスタ B は、修了証が発行された時点で学習を終了した学習者が属するクラスタと考えられる。クラスタ C は、Unit 1 はほぼ 100 点であるものの、Unit 2 は、平均で 20 点程度であり、それ以降は、ほぼ 0 点となっており、最初の 1 回は学んだものの、それ以降は、学習をやめてしまったクラスタと考えられる。クラスタ D は、Tasters のように、全ての Unit について、小テストの点数がほぼ 0 点であり、学習をほとんど行っていないクラスタと考えられる。




図 5-2 小テスト成績のクラスタリング結果
Figure 5-2 Clustering results of quiz scores.

表 5-1 各クラスタの人数

Table 5-1 Number of learners in each cluster.

クラスタ	A	B	C	D
人数	793	80	606	936

小テスト点数は 4 次元データとなるが、その 4 次元空間中で、クラスタ A, B, C, D がどのように分布するかを見たのが図 5-3 である。主成分分析を行い、4 次元データを 2 次元データに次元を落としている。図の PC1 が第 1 軸、PC2 が第 2 軸である。固有ベクトルの値は、表 5-2 のようになる。第 1 軸は、すべての固有ベクトルの値がマイナスで、ほぼ同じ大きさであることから、マイナス側に行くほど点数が高くなる軸と考えられる。第 2 軸は、Unit 1 の値がマイナスであり、Unit 3 と Unit 4 の値がプラスであることから、マイナス側に行くほど、Unit 1 の点数が高く、Unit 3 と Unit 4 の点数が低くなる軸と考えられる。残り 2 軸があるため B の分布は多少広がっているものの、A, C, D については、明確に分布

が分かれていることが確認できる。




図 5-3 クラスタ A, B, C, D の分布

Figure 5-3 Distribution of A, B, C, D.

表 5-2 固有ベクトル

Table 5-2 Eigenvectors.

	PC1	PC2	PC3	PC4
Unit 1	-0.4380009	-0.87650596	0.1990193	-0.01684579
Unit 2	-0.5336600	0.07636845	-0.8229807	0.17910201
Unit 3	-0.5152636	0.31671212	0.1955049	-0.77199394
Unit 4	-0.5078046	0.35439892	0.4948453	0.60964256

図 5-4 は、クラスタごとの合格者/不合格者の人数を示したものである。クラスタ A については、11 名以外は合格であり、合格率は、98.6%であった。B については、29 名が不合格となった。クラスタ C, D については、すべての学習者が不合格となった。クラスタ B については、合格者と不合格者の混在が見られるが、クラスタ A, C, D については、ほぼ、合格/不合格と対応していることが分かる。




図 5-4 クラスタごとの合否

Figure 5-4 Pass/Fail in each cluster.

5.3. 学習者クラスタと学習行動

次に、学習者クラスタと学習行動との関係を見る。対象とした講座の学習は基本的に映像を視聴することにより行われるため、映像の視聴数は、学習行動の特徴として利用することができる。

映像の視聴数については、3.5. で述べたように、各 Unit の映像を 1 日に 1 回以上見た場合に 1 回として分析を行い、このようにカウントした映像の視聴数を映像視聴数と呼ぶこととする。

図 5-5 にクラスタごとの映像視聴数の分布を示す。縦軸は、各 Unit の映像の平

均視聴数である。この図を見ると、成績が良い A, B, C, D の順に、映像の視聴数が多いことが分かる。また、クラスタ B は、Unit 4 の小テストの点数がほぼ 0 であるものの、Unit 4 の映像を、他の映像の半分程度であるが見ていることが分かる。また、クラスタ C は、小テストの点数が Unit 2 以降低くなるものの、Unit 2 の映像を Unit 1 の映像と同程度見ていることが分かる。このことから、学習をやめるのは、映像を視聴した後、小テストを行う直前であることが分かる。クラスタ D については、小テストの点数が全 Unit でほとんど 0 であるものの、Unit 1 の映像を、ある程度見ていることが分かる。




図 5-5 映像視聴数の分布

Figure 5-5 Distribution of video views.

図 5-6 に、Unit ごとの映像視聴数の分布を示す。図 5-6(a)の Unit 1 の映像視聴数の分布を見ると、A, B, C にほとんど差がないことが分かる。図 5-6(b)の Unit 2 の映像視聴数の分布を見ると、映像を 2 回見る人は A よりむしろ B が多いことが分かる。図 5-6(c)の Unit 3 の映像視聴数の分布を見ると、A, B と C, D の差が顕著に出ていることが分かる。図 5-6(d)の Unit 4 の映像視聴数の分布を見ると、A と B の差が 0 回で顕著に出ていることが分かる。




図 5-6(a) 映像視聴数の分布 (Unit 1)

Figure 5-6(a) Distribution of video views (Unit 1).




図 5-6(b) 映像視聴数の分布 (Unit 2)

Figure 5-6(b) Distribution of video views (Unit 2).




図 5-6(c) 映像視聴数の分布 (Unit 3)

Figure 5-6(c) Distribution of video views (Unit 3).




図 5-6(d) 映像視聴数の分布 (Unit 4)

Figure 5-6(d) Distribution of video views (Unit 4).

映像の視聴数は4次元データとなるが、その4次元空間中で、クラスターA, B, C, Dがどのように分布するかを見たのが図5-7である。主成分分析を行い、4次元データを2次元データに次元を落ととしている。この図のPC1が第1軸、PC2が第2軸である。固有ベクトルは表5-3のようになる。

第1軸は、すべての固有ベクトルの値がマイナスで、マイナス側に行くほど映像の視聴数が増える軸と考えられる。第2軸は、Unit 1, Unit 2の値がプラスであり、Unit 3とUnit 4の値がマイナスであることから、プラス側に行くほど、Unit 1, Unit 2を視聴し、Unit 3とUnit 4を視聴しない、すなわち、後半に視聴数が落ちることを表す軸と考えられる。A, B, C, Dの分布の重なりは大きいですが、右上の端の部分には、視聴数が少なく、後半ほど視聴数が少なくなるC, Dが比較的多く見られる。




図 5-7 クラスタ A, B, C, D の分布 (映像視聴数)

Figure 5-7 Distribution of A, B, C, D (Video views).

表 5-3 固有ベクトル

Table 5-3 Eigenvectors.

	PC1	PC2	PC3	PC4
V1	-0.2688760	0.3738792	0.86916998	-0.1801766
V2	-0.7073343	0.5449046	-0.41904386	0.1648014
V3	-0.5627811	-0.5871852	-0.04180737	-0.5802957
V4	-0.3326580	-0.4674472	0.25922563	0.7769387

図 5-8 に、映像の視聴間隔の分布を示す。映像の視聴間隔は、短い期間で集中的に学習しているか、あるいは、長い時間をかけて学習しているかの目安として利用することができる。映像を見た同じ日に別の Unit の映像を見ていれば間隔は 0 日、前日に映像を見ていれば間隔は 1 日とカウントしている。

図 5-8 を見ると、クラスタ A, B では、0 日や 1 日の間隔で映像を見ていること

が分かる．これは，集中的に学習している学習者と考えられる．また，クラスター A, B では，間隔が 6 日，7 日の部分にもピークが見られる．これは，1 週間に一度程度，定期的に学んでいる学習者と考えられる．




図 5-8 映像の視聴間隔の分布

Figure 5-8 Distribution of intervals of video views.

図 5-9 に、最初に映像を視聴したのが、講座開講から何日目であるかの分布を示す。開講日を1日目としている。この図を見ると、いずれも1日目から受講している人数が多いが、これは、講座がいつ始まるかを予め知っていて、開講初日から映像を視聴した学習者と考えられる。

それぞれのクラスごとに、映像を1回以上視聴した学習者の平均開始日を求めると、クラスA, B, Cについては、4.7, 4.9, 5.2 となり、概ね開講から1週間以内に視聴を開始する学習者が多いことが分かる。一方、クラスDについては、平均で17.1となり、2週目以降に視聴する学習者の割合が多かったためと考えられる。




図 5-9 映像の視聴開始日の分布

Figure 5-9 Distribution of first access to videos.

5.4. 学習者クラスと開始アンケート

ここでは、学習者クラスと開始アンケートとの関係性について調べる。

図 5-10 にクラスごとの年齢の分布を示す。4.5.と同様に、開講した 2016 年時点での年齢が 0 から 100 歳の範囲以外の不自然な値になっているものが 24 件あったため、これらは除外して分布を求めている。平均年齢は、A, B, C, D の順に、52.4, 44.4, 44.6, 44.0 歳であった。年齢の分布を見ると、B, C, D では、40代が最も多く、A では、50代、60代が多いことが分かる。




図 5-10 年齢の分布

Figure 5-10 Distribution of ages.

図 5-11 にプログラミングスキルの分布を示す. 開始アンケートでは, プログラミング経験について,

Skill1 レベル 1: 未経験

Skill1 レベル 2: プログラミング入門書や入門サイトで勉強したことがある

Skill1 レベル 3: 自分で考えたプログラムを作ったことがある

Skill1 レベル 4: 日常的にプログラミングをしている (専攻, 職業)

の 4 つから選択するようになっている. 縦軸は, それぞれの構成割合を示している. A から D に向かうに連れてプログラミングの未経験者が増えていくことが分かる.




図 5-11 プログラミングスキルの分布

Figure 5-11 Distribution of programming skills.

5.5. 学習者クラスタの推定

ドロップアウト率を軽減する策を講じるためには、学習者がどのクラスタに属するかを、学習を開始してからなるべく早い時期に推定する必要がある。これにより、学習者に応じた適切なサポートを行うことが可能になり、修了率等の向上を図ることができると考えられる。このため、学習者から得られた様々な特徴から、学習者クラスタをどの程度推定できるか評価を行った。

クラスタの推定に利用した特徴量については、4章と同様に、学習行動については、以下の特徴量を利用した。

1) 映像視聴数

各 Unit の映像を 1 日に 1 回以上見た場合に 1、それ以外を 0 とし、N 週間の合計を映像視聴数とした。学習教材は 4 つの Unit で構成されているため、映像視聴数の特徴量は 4 次元データとなる。

2) 映像の視聴間隔

間隔は、学習者が同じ日に複数の Unit の映像を視聴した場合は 0 日、学習者がある日とその前日に映像を視聴した場合は 1 日としてカウントされる。これは、集中的に短い間隔で視聴するか、間を空けて見るかの特徴になる。20 日以上 of 頻度はほぼ 0 であるため、視聴間隔は 0 日から 19 日までの 20 次元のデータとした。

3) 映像の視聴開始日

映像への最初の視聴日が開講日の何日後かを示す整数。学習開始時点で、開講から何日目かが分かる。これは 1 次元データであり、一度も視聴がなければ開講後の 71 日目を学習開始日とした。

開始アンケートからは、以下の特徴量を利用した。

4) 年齢

年齢については、5.4. で欠損値とした 24 件については、全体の年齢の平均値の小数点以下を切り捨てた 46 歳として扱った。

5) プログラミングの経験

プログラミングの経験については、Skill レベル 1 から Skill レベル 4 を、それぞれ、1 から 4 で数値化した。数値が大きいほど、プログラミングの経験があるという指標になる。

以上の映像の視聴数 4 次元、視聴間隔 20 次元、映像の視聴開始日の 1 次元、年

年齢 1 次元、プログラミングの経験 1 次元を足し合わせた 27 次元のデータを各学習者の特徴とした。これらの特徴量をもとに、5.2. で述べたクラスターの推定を行う。

データを分類するための手法としては、線形判別分析、サポートベクトルマシン等、様々な手法があるが、ランダムフォレストの場合、比較的精度が高く、どの特徴量がクラスターの推定に寄与しているかを知ることができることから、ランダムフォレストを用いて、学習者クラスターの推定を行う。ランダムフォレストは、機械学習に用いられる手法の 1 つであり、多数の決定木の多数決により分類を行う手法である。全特徴量の中から分類に用いる特徴量をいくつか選択し、また、全データのうち一部を学習データとして選択した上で、データを分類するための決定木を作成する。このような決定木を、例えば、500 本作成し、その多数決により分類を行う。ランダムフォレストの処理には、オープンソースの統計解析ツールである R 上の randomForest パッケージを利用した。また、構成する木の数等、全てのパラメータは、デフォルト値のまま利用した。

ランダムフォレストの場合、ジニ係数の減少量を見ることで、どの特徴量がクラスターの推定に寄与しているかを知ることができる。ジニ係数は、データがどれだけ高い純度で分離できているかの指標であり、例えば、ある枝であるクラスターのデータが、0.3 と 0.7 の割合で分かれた場合、 0.3×0.7 を足すという操作を繰り返すことで計算される。もし、全てのデータを完全に 0, 1 で分離できる場合は、ジニ係数は 0 となり、分離の純度が低くなるほど、値が大きくなる。ジニ係数の減少量は、その特徴量を利用することで、どれだけジニ係数を減らせるかを表すもので、重要な特徴量を見るための指標となる。

このジニ係数の減少量を求めるため、2,415 件の全てのデータを使い、1 つの学習モデルを作成した。その場合のジニ係数の減少量を図 5-12 に示す。図 5-12(a) は、学習開始から 1 週間後、図 5-12(b) は、3 週間後、図 5-12(c) は、10 週間後の結果である。これらの図で、V1 から V4 は Unit 1 から Unit 4 の映像の視聴数を表す。DN は、視聴間隔が N 日の数を表す。Start は、映像の視聴開始日、Skill は、プログラミングスキル、Age は、学習者の年齢である。

図 5-12(a) を見ると、学習開始から 1 週間後では、開始日 (Start) や年齢 (Age)、プログラミングスキル (Skill) と Unit 1 の映像視聴数 (V1) などがクラスターの推定に重要であることが分かる。図 5-12(b) を見ると、Unit 2, Unit 3 の視聴数 (V2, V3) の順位が上がっており、年齢 (Age) やプログラミングスキル (Skill) も順位は下が

るものの、比較的上位に位置していることが分かる。図 5-12(c)を見ると、Unit 2 から Unit 4 の映像視聴数 (V2~V4) が上位に位置している。映像の視聴間隔については、D0, D1, D2 は短い間隔での繰り返しの学習、D6, D7 は、週 1 程度での繰り返しの学習に対応し、これらの数もクラスターの推定に有用であることが分かる。

学習開始からの時間によらず、開始日や年齢、プログラミングスキルといった特徴量が上位に位置しているが、これは、ランダムフォレストの場合、それぞれの枝で、最もデータをうまく分けることができる特徴量が選ばれて分割が行われ、第 1 週で上位に位置した特徴量は、その後もデータの分割に有用となりやすいためと考えられる。




図 5-12(a) ジニ係数の減少量(1 週後)

Figure 5-12(a) Mean decrease Gini (1 week).




図 5-12(b) ジニ係数の減少量(3 週後)

Figure 5-12(b) Mean decrease Gini (3 weeks).




図 5-12(c) ジニ係数の減少量(10 週後)

Figure 5-12(c) Mean decrease Gini (10 weeks).

クラスタの推定精度の評価については、学習データと評価データを分けて評価を行うため、10-foldクロスバリデーションを行った。すなわち、N週目の精度を求めるために、N週目までに取得できた視聴数等のデータを10に分け、そのうち9のデータを使って、A、B、C、Dのラベルを推定できるように学習を行った。そして、その学習結果をもとに、残りの1つのデータのラベルの推定を行うという処理を10回繰り返し、推定したラベルのうち正しかった割合の平均を求めN週目の精度とした。

学習開始からN週後のクラスタ推定の精度を図5-13に示す。マーカーが+のものがクラスタA、B、C、Dの4つに分類した場合を示しており、3週目以降は、70%を超える精度で学習者クラスタの推定ができています。また、クラスタCについては、3週目で平均63.6%、10週目で平均68.2%を正しく推定することができた。

一方、図5-4で示したように、小テスト全体の点数が70点以下でクラスタA、Bに分類されたものが40例あったが、それ以外については、クラスタA、Bに属していれば合格、クラスタC、Dに属していれば不合格であり、クラスタA、Bと、クラスタC、Dの分類は、ほぼ、学習者の合格、不合格に対応する。

マーカーが○のものが、10-foldクロスバリデーションを用いて、クラスタA、Bと、クラスタC、Dの分類を行った場合を示しており、これが、ほぼ、合格、不合格の分類に対応する。3週目以降は、90%という高い精度で推定ができており、本手法は、合格/不合格の推定にも有用であることが分かる。合格/不合格の推定の誤りについては、3週目では、176名の合格者を不合格と推定し、118名の不合格者を合格と推定していた。ドロップアウトの軽減という意味では、合格者を不合格と推定するよりも、不合格者を合格と推定する方が、サポートの対象から外れるという意味で不利益が大きいと考えられる。今回の結果は、不合格者を合格と推定する数の方が少ないという結果であったが、推定による不利益をより小さくするのであれば、不合格者を合格と推定するエラーをより重視して機械学習を行うといった方法も考えられる。




図 5-13 学習者クラスターの推定

Figure 5-13 Prediction of learners' cluster.

5.6. まとめと考察

本章では、小テストの点数パターンに基づき学習者をクラスタリングし、それぞれの学習者クラスターの特徴を明らかにした。また、その結果をもとに、それぞれの学習者の属するクラスターの推定を行った。

全4回分の小テストの点数を並べた4次元データをもとに、k平均法により4つのクラスターに分割し、クラスターごとの学習行動を比較した結果、小テストの合計点が最も高いクラスターAは映像の視聴数が多く、短い間隔で繰り返し映像を視聴しているといった特徴があることが明らかになった。2番目に小テストの点数が高かったクラスターBは、最初の3回分は、小テストでほぼ満点を取っているものの、Unit 4の小テストの点数は0点に近かった。対象とした講座では、テスト全体で70点以上を取れば修了証が出ることから、学習することよりも、修了証を取ることが目的のクラスターと考えられる。クラスターCは、最初の1,2回のみを学習し、それ以降の学習をやめてしまったクラスターと考えられる。クラスターDは、

小テストの点数がほとんど全て0点であり、また、映像への最初の視聴が他のクラスタに比べて遅いことから、学習するというよりも、講座の開講後、講座があることを知り、どのような講座かを見るためにアクセスしてきたクラスタと考えられる。

学習者の支援を考えた場合、クラスタ A とクラスタ B は、基本的に合格点に達していることから、合格点に達していないクラスタ C やクラスタ D が支援対象の候補になると考えられる。しかしながら、クラスタ D は、必ずしも学習することが目的ではないと考えられることから、クラスタ D を合格にまで導くことは必ずしも容易ではないと考えられる。一方、クラスタ C は、開講すぐにアクセスする人の割合が高く、予め開講を知っていたと考えられ、また、Unit 1 の小テストでは、ほぼ満点を取っていることから、講座を修了するために必要な能力は基本的に持っていると考えられる。このため、より早い時期に、学習者がどのクラスタに属するか、特にクラスタ C に属する学習者を推定できれば、効率的に、学習の際にドロップアウトを防ぎ、修了率を高めることができると考えられる。そこで、学習開始時からの学習行動等をもとに、ランダムフォレストを用いたクラスタの推定を行い、3 週目という早い時期に、クラスタ C については平均 63.6%、全体では 70%を超える精度で、クラスタの推定ができることを明らかにした。また、学習終了時の合格、不合格については、90%という高い精度で推定ができることを示した。

以上のように、小テストの点数パターンに基づき学習者をクラスタリングすることで、学習者を細分化し、その特徴を明らかにすることができた。また、それらの特徴をもとに高い精度で学習者クラスタを推定できることを示した。これらの成果は、MOOC 上で、より学習者に適応したサポートを実現する上での基礎の 1 つとなると考えられる。

6. 総合考察

6.1. 本研究のまとめ

本研究では、ドロップアウトの軽減のために必要となる、サポートすべき学習者クラスタを見い出すための方略を明らかにすることを研究の目的として、解決すべき課題として、以下の3つの課題を設定した。

課題1: 学習ログを分析し、学習成果（学習終了時の点数/可否）を予測するためにどのような特徴量が有用であるかを明らかにする。

課題2: 学習者を学習終了時の点数によりクラスタリングし、それぞれの学習者クラスタの特徴を明らかにする。

課題3: 課題1の学習者特徴量を用いて、課題2の学習者クラスタを推定し、その精度を明らかにする。

第1章では、研究の背景についてまとめた。MOOCでは、大規模な学習者数が期待できる反面、講座を最後まで修了できずに途中でドロップアウトする学習者が多く、MOOCにおいて解決すべき問題の1つになっていることを述べるとともに、MOOCのようなオンライン講座では、学習者の膨大な学習ログがシステム上に蓄積されることから、これらを収集、分析することで、学習における問題点を解決できる可能性があることを述べた。

第2章では、本研究に関連する研究を、3つに分類しまとめた。「ラーニングアナリティクス」の研究の例を挙げ、主な研究テーマには、学習行動の分析や、学習者の興味や能力に応じた教材の推薦、学習成果の予測、学習者特徴の分類等があることを述べた。また、本研究と関連の深い、「学習成果の予測」、「学習者特徴の分類」に関連する研究の具体例についてまとめるとともに、MOOC学習者へのサポートを考えた場合、どの学習者を対象とし、どのようにサポートすれば救えるかを考慮しながら、学習者特徴の分類を行うことが必要となること、また、学習者に応じた教材の提供やサポートを行おうとする場合、学習開始から早い時期にそれぞれの学習者がどの学習者クラスタに属するかを推定できる必要があることを述べた。

第3章では、課題に取り組むための予備的な検証として行った学習ログの分析について述べた。研究データ管理MOOC講座を対象とし、映像視聴ログを用いた学

習者のクラスタリングを行い，再生エラー等による外れ値の影響によって，学習者が数多くの小さなクラスタに分割されてしまう場合があること，映像の視聴数を，1日1回以上視聴した場合に1回とカウントすることで，それを回避することができることを明らかにした．また，概ね映像の視聴数が多いクラスタほど合格者の割合が大きくなるものの，最も視聴数が多いクラスタの合格率が最も高くなるわけではないことなど学習者の特徴の違いを明らかにした．本章の結果に基づき，第4章以降の分析では，映像の視聴数については，1日1回以上視聴した場合に1回とカウントして処理を行うこととした．

第4章は，「課題1：学習ログを分析し，学習成果（学習終了時の点数/可否）を予測するためにどのような特徴量が有用であるかを明らかにする」に対応する章であり，プログラミングMOOC講座を対象として，学習終了時の成績を予測するために有効な学習者の特徴量を明らかにするため，映像の視聴行動とアンケートから学習者の特徴を抽出し，成績との関連を分析した．この結果，全体的に点数が高い学習者のほうが，映像視聴が多いこと，点数が高い学習者は定期的に学習していること，点数が低い学習者は学習開始が遅いといった特徴を明らかにした．また，学習開始からN週間までに得られた特徴量をもとに，重回帰分析を用いて，学習終了時の点数および可否の推定を行い，抽出した特徴量の有効性を検証した．その結果，点数の予測結果は十分精度が高いとは言えなかったものの，可否の推定については，3週目以降では80%以上の精度で行えることを明らかにした．また，開始アンケートから得られる，年齢やプログラミングスキル等の情報を利用することで，学習3週目までの点数の予測精度を向上できることを明らかにした．以上の結果から，映像の視聴数，視聴間隔，視聴開始日，年齢，プログラミングスキルといった特徴量は，学習者の学習終了時の成績を予測するために有効な特徴量であることが明らかになった．

第5章は，「課題2：学習者を学習終了時の点数によりクラスタリングし，それぞれの学習者クラスタの特徴を明らかにする」，「課題3：課題1の学習者特徴量を用いて，課題2の学習者クラスタを推定し，その精度を明らかにする」に対応する章であり，小テストの点数パターンに基づき学習者をクラスタリングし，それぞれの学習者クラスタの特徴を明らかにするとともに，その結果をもとに，それぞれの学習者の属するクラスタを推定する手法の提案を行った．第4章と同じ学習データを対象に，小テストの点数パターンに基づき学習者をクラスタリングし，クラスタごとの学習行動を比較することで，小テストの合計点が高いクラ

スタは映像の視聴数が多く、短い間隔で繰り返し映像を視聴するといった特徴があること、最初の1回は学んだものの、それ以降は、学習をやめてしまったクラススタは、小テストの点数がUnit 2以降低くなるものの、Unit 2の映像をUnit 1の映像と同程度見ているといった特徴があることを明らかにした。次に、それらの特徴をもとに学習者の属するクラススタを推定することを試みた。学習開始からN週間までの特徴量をもとに、ランダムフォレストを用いたクラススタの推定を行い、3週目以降では、概ね7割を超える精度で、属するクラススタの推定ができることを明らかにした。また、学習終了時の合格、不合格については、90%という高い精度で推定ができることを示した。

「課題1: 学習ログを分析し、学習成果（学習終了時の点数/可否）を予測するためにどのような特徴量が有用であることを明らかにする。」を解決することで、映像の視聴数、視聴間隔、視聴開始日、年齢、プログラミングスキルといった特徴量は、学習者の成績を予測するために有用な特徴量であることを明らかにした。

「課題2: 学習者を学習終了時の点数によりクラスタリングし、それぞれの学習者クラススタの特徴を明らかにする。」を解決することで、不合格となるであろう学習者のうち、Tastersではない、サポートによって不合格から合格に導けるであろう学習者クラススタは、小テストの点数がUnit 2以降低くなるものの、Unit 2の映像をUnit 1の映像と同程度見ているといった特徴があることを明らかにした。

「課題3: 課題1の学習者特徴量を用いて、課題2の学習者クラススタを推定し、その精度を明らかにする。」を解決することで、学習開始から早い時期に、学習終了時の学習者クラススタおよび可否をある程度高い精度で推定できることを明らかにした。

以上の成果により、不合格になるであろう学習者を予測し、更に、その中から、Tastersではない、サポートをすることで不合格から合格に導けるであろう学習者を見い出すことが可能になる。このような学習者クラススタに対して、より積極的にサポートを行うことで、ドロップアウトを軽減できることが期待され、本研究で提案した学習者クラススタの推定手法は、それぞれの学習者に応じた最適なサポートを実現するための基礎の1つとなると考えられる。

学習者に対する支援としては、様々なものを考えることができる。たとえば、ドロップアウトすると推定される時点の前に、特定の学習者クラスタに対してサポートのメールを送って学習が継続できるよう励ましたり、より理解を促進するために補足的なコンテンツを推薦したりするといったことが考えられる。また、コース内容を十分に理解していると考えられるクラスタと、ドロップアウトする可能性の高いクラスタの学習者同士の交流をフォーラム上で促進するといったことも考えられる。個々の理解に応じたきめ細かいサポートが期待できるとともに、MOOCにおけるドロップアウトの原因の1つとして挙げられる孤立感[67]の軽減も期待できる。また、学習者の映像視聴行動の違いについてのデータがあれば、「合格した人は、この映像をこれだけ見ています」といった情報を提供することで、学習者がより効率的に学ぶことを支援することも可能になる。

また、本研究の成果により、映像視聴を主としたMOOC講座において、映像の視聴数、視聴間隔、視聴開始日、年齢、スキルといった特徴量は、学習者の学習終了時の成績を予測するために有効な特徴量であることが明らかになり、これは、同様のMOOC講座を作成し、学習者の学習終了時の成績を予測する際の指針としても有用となると考えられる。

6.2. 研究の限界と今後の展望

本研究では、ドロップアウトの軽減のために必要となる、サポートすべき学習者クラスタを見い出すための方略を明らかにすることを研究の目的として、その検証を行い、6.1.で述べたような一定の成果を上げることができた。しかしながら、今後、更に、検証すべき課題も残っている。

1つは、学習のサポートの対象は、5章で述べたクラスタCだけと考えて良いかという問題である。5章で対象としたMOOCコースでは、学習者をクラスタAからクラスタDまでの4つに分類し、クラスタA、クラスタBについては、ほぼ合格しているため、ドロップアウトを軽減する意味では、サポートは必要ないであろうと考え、また、クラスタDについては、ほとんど学習を行わないTastersに対応し、必ずしもサポートを望んでいないだろうと考え、クラスタCをサポートの対象であるとした。しかし、クラスタBについても、数は多くはないものの、不合格者が含まれている。また、平均的な点数もクラスタAに比べて低いことから、学習の困難さを軽減するという意味では、サポートの対象に含めることも考えられる。また、クラスタCに属する学習者の中でも、学習行動が異なる場合は、必

要なサポートが変わってくる可能性もある。講座の意図や、サポートの目的といったものも考慮して、どの学習者クラスタを対象とし、どのようにサポートするかを考えることも必要になる。

また、クラスタ C に対して、より適応的なサポートを行おうとする場合、クラスタ C について、より詳細な特徴を明らかにする必要がある。これには、クラスタ C に属する学習者の、他の MOOC 講座での学習行動などを利用できる可能性がある。たとえば、クラスタ C の学習者は、最初のうちは学習活動を行うものの、途中で学習活動をやめてしまっており、他の MOOC 講座でも同様の行動をとっている可能性がある。また、過去にどれだけの数の講座をとっていたかや、それらの成績の情報 [16] など、クラスタ C のより詳細な特徴を明らかにするために利用できる可能性がある。このため、複数の MOOC 講座を対象とした学習履歴等の分析が必要となり、これは、今後の課題の 1 つとなる。

本研究の成果の一般化についても、更に検証する必要がある。一般の MOOC 講座を対象とした場合、必ずしも、本研究の結果のような 4 つのクラスタに分類できるとは限らず、また、分類されたクラスタの特徴も必ずしも同様になるとは限らない。たとえば、クラスタ B は、講座の修了条件を満たした段階で小テストの受験をやめたクラスタと考えられ、講座の修了条件に依存したクラスタと考えられる。一般には、学習者がどのようなクラスタに分割されるかは、講座の目的や修了条件、難易度等、様々な条件によって変化すると考えられる。一方で、「2.3. 学習者特徴の分類」で述べたように、学習者のクラスタには、ある程度の類似性もある [18-20, 82-84]。このため、多数の講座に対して、今回と同様の検証を行っていくことで、より汎用性の高いクラスタ分類やその推定を行える可能性もあり、この点についても今後検証を重ねていく。

また、本研究では、MOOC 講座から得られる映像の視聴数、視聴間隔、視聴開始日、年齢、スキルといった特徴量を用いて、学習終了時の成績を予測する手法を提案したが、複数の MOOC 講座を対象とした分析を行うことで、逆に、映像の視聴数をカウントする場合の粒度はどのぐらいの時間間隔が良いのか、時間を区切る際、どの時間で区切るのが良いのか等、特徴量の最適化を進めることができる可能性があり、この点も今後の課題になる。

一方、本研究の成果を実際の教育の場面で利用しようとする場合の課題も考え

られる。学習行動から合格/不合格を推定する精度，あるいは特定のクラスタを推定する精度は，必ずしも 100%になるわけではない。誤って合格すると推定し，サポート等をしなかった結果，不合格となる場合や，サポートすべきクラスタと推定し，不必要なサポートを行うことで，不利益が生じるといった場合が起こることも考えられる。このような学習成果の予測を実際の教育の場面で利用しようとする場合の倫理的な側面については，LA に関する国際会議等でも，“Learning analytics ethics”等，倫理に関するセッションが設けられるなど議論が進められているが[104,105]，教育する側だけではなく，学習者側も含めてコンセンサスを形成していく必要がある。

今後更に検証を行っていくべき点もあるものの，学習者クラスタを推定し，学習者に応じたコンテンツの提供やサポートを実現することができれば，オンライン講座の更なる利用の促進に繋がっていくものと考えられ，本研究が，その一助となることを期待するものである。

謝辞

本論文の執筆にあたり、大変多くの皆様からのご指導とご支援をいただきました。本研究の遂行にあたって、大変親身な御指導を賜りました筑波大学図書館情報メディア系 逸村裕教授に心から感謝致します。筑波大学図書館情報メディア系 佐藤哲司教授、並びに、筑波大学図書館情報メディア系 歳森敦教授には、ご多忙のなか副指導教員をお引き受けいただき、懇切丁寧な御指導をいただきました。深く感謝致します。審査委員を引き受けていただきました筑波大学図書館情報メディア系 鈴木佳苗教授、熊本大学 喜多敏博教授には、本論文の細部にわたり多大なる御助言、御協力をいただき深く感謝致します。

国立情報学研究所 山地一禎教授、及び、オープンサイエンス基盤研究センター 特任研究員 尾城孝一様には本研究全般にわたり御指導・御協力をいただき深く感謝致します。

本研究に取り組む機会を与えていただき、厚くご支援をいただきました国立情報学研究所 喜連川優教授をはじめ、同研究所の諸先生方、研究戦略室 岡本裕子様、広報チーム 関根卓史様、オープンサイエンス基盤研究センターの皆様、その他の皆様に深く感謝致します。

本研究のテーマであるラーニングアナリティクス等に関して多くの御助言をいただきました京都大学 緒方広明教授、京都大学 梶田将司教授、放送大学 山田恒夫教授、放送大学 柳沼良知教授、放送大学 森本容介准教授、大手前大学 畑耕治郎教授、その他の皆様に深く感謝致します。また、逸村研究室の皆様にはゼミや合宿等で活発な議論をいただき感謝致します。最後に、長きにわたり支えてくれた家族に心から感謝の意を表します。

文献リスト

- [1] MIT OpenCourseWare, <https://ocw.mit.edu/index.htm/>
- [2] 福原美三, 日本におけるオープンコースウェアの現状と課題・展望, 情報管理, Vol.49, No.6, pp.301-312, 2006.
- [3] UNESCO, Open Educational Resources (OER),
<https://en.unesco.org/themes/building-knowledge-societies/oer>
- [4] Berti, M., Open Educational Resources in Higher Education, Issues and Trends in Educational Technology, Vol.6, No.1, pp.4-15, 2018.
- [5] Coursera, <https://www.coursera.org/>
- [6] Udacity, <https://www.udacity.com/>
- [7] edX, <https://www.edx.org/>
- [8] 松永義昭, デジタルラーニングプラットフォーム「Fisdom」, FUJITSU, Vol.68, No.6, pp.16-22, 2017.
- [9] 文部科学省専門教育課, リカレント教育の拡充に向けて,
https://www.mext.go.jp/b_menu/shingi/chukyo/chukyo4/043/siryu/___icsFiles/afieldfile/2018/08/03/1407795_2.pdf
- [10] 福原美三, 日本初 MOOC の可能性と課題, 研究報告教育学習支援情報システム (CLE), Vol.2014-CLE-12, No.1, p.1, 2014.
- [11] JMOOC, <https://www.jmooc.jp/en/>
- [12] Reich, J. and Ruipérez-Valiente, J.A., Supplementary Material for The MOOC pivot,
<https://science.sciencemag.org/content/sci/suppl/2019/01/09/363.6423.130.DC1/aav7958-Reich-SM.pdf>
- [13] Pursel, B.K., Zhang, L., Jablockow, K.W., Choi, G.W., and Velegol, D., Understanding MOOC students: motivations and behaviours indicative of MOOC completion, Journal of Computer Assisted Learning, Vol.32, No.3, pp.202-217, 2016.
DOI: <https://doi.org/10.1111/jcal.12131>
- [14] Koller, D., Ng, A., Do, C., and Chen, Z., Retention and intention in Massive Open Online Courses, EDUCAUSE Review, Vol.48, No.3, pp.62-63, 2013.
- [15] Tan, M. and Shao, P., Prediction of Student Dropout in E-Learning

Program Through the Use of Machine Learning Method, International Journal of Emerging Technologies in Learning, Vol.10, No.1, pp.11-17, 2015.

DOI: <http://dx.doi.org/10.3991/ijet.v10i1.4189>

- [16] Manrique, R., Nunes, B.P., Marino, O., Casanova, M.A., and Nurmikko-Fuller, T., An Analysis of Student Representation, Representative Features and Classification Algorithms to Predict Degree Dropout, Proceedings of the 9th International Conference on Learning Analytics & Knowledge (LAK '19), pp.401-410, 2019.
- [17] Gitinabard, N., Khoshnevisan, F., Lynch, C.F., and Wang, E.Y., Your Actions or Your Associates? Predicting Certification and Dropout in MOOCs with Behavioral and Social Features, Proceedings of the 11th International Conference on Educational Data Mining, pp.404-410, 2018.
- [18] Kizilcec, F., Piech, C., and Schneider, E., Deconstructing disengagement: analyzing learner subpopulations in Massive Open Online Courses, In Proceedings of the Third International Conference on Learning Analytics and Knowledge, pp.170-179, 2013.
- [19] 荒優, 藤本徹, 一色裕里, 山内祐平, MOOC 学習者の多様性を考慮した教育効果分析観点の提案, 日本教育工学会第 30 回全国大会講演論文集, pp.743-744, 2014.
- [20] Kahan, T., Soffer, T., and Nachmias, R., Types of Participant Behavior in a Massive Open Online Course, The International Review of Research in Open and Distributed Learning, Vol.18, No.6, pp.1-18, 2017.
- DOI: <https://doi.org/10.19173/irrodl.v18i6.3087>
- [21] 山川修, Learning Analytics とは, 情報処理, 2014, Vol.55, No.5, p.495.
- [22] 安武公一, 中村泰之, 山地一禎, 古川雅子, 梶田将司, 山川修, 多川孝央, 最先端の Learning Analytics を目指して, 教育システム情報学会第 41 回全国大会講演論文集, pp.345-346, 2016.
- [23] New Media Consortium: Learning Analytics and Adaptive Learning,

- NMC Horizon Report 2016 Higher Education Edition, pp.38-39, 2016.
- [24] Sun, P.C., Tsai, R.J., Finger, G., Chen, Y.Y., and Yeh, D., What drives a successful e-Learning? An empirical investigation of the critical factors influencing learner satisfaction, *Computers & Education*, Vol.50, No.4, pp.1183-1202, 2008.
- [25] Sekiya, T., Matsuda, Y., and Yamaguchi, K., Curriculum analysis of CS departments based on CS2013 by simplified supervised LDA, *Proceedings of the 5th International Conference on Learning Analytics and Knowledge*, pp.330-339, 2015.
- [26] Moretti, A., González-Brenes, J.P., and McKnight, K., Data-Driven Curriculum Design: Mining the Web to Make Better Teaching Decisions, *Proceedings of the 7th International Conference on Educational Data Mining*, pp.421-422, 2014.
- [27] Pechenizkiy, M., Trcka, N., Bra, P.D., and Toledo, P., CurriM: Curriculum Mining, *Proceedings of the 5th International Conference on Educational Data Mining*, pp.216-217, 2012.
- [28] 古川雅子, 山地一禎, 安武公一, 中村泰之, 山田恒夫, 梶田将司, 第6回 Learning Analytics & Knowledge Conference (LAK16) 参加報告, *情報処理学会情報教育シンポジウム 2016 論文集*, pp.53-58, 2016.
- [29] 古川雅子, 中村泰之, 山川修, 柳沼良知, 多川孝央, 魚崎典子, 山田恒夫, ラーニング・アナリティクスの動向-第7回 Learning Analytics & Knowledge Conference (LAK' 17) 参加報告-, *情報処理学会情報教育シンポジウム 2017 論文集*, pp.31-36, 2017.
- [30] 緒方広明, 殷成久, 毛利考佑, 大井京, 島田敬士, 大久保文哉, 山田政寛, 小島健太郎, 教育ビッグデータの利活用に向けた学習ログの蓄積と分析, *教育システム情報学会誌*, Vol.33, No.2, pp.58-66 2016.
- [31] Bouchet, F., Kinnebrew, J., Biswas, G., and Azevedo, R., Identifying Students' Characteristic Learning Behaviors in an Intelligent Tutoring System Fostering Self-Regulated Learning, *Proceedings of the 5th International Conference on Educational Data Mining*, pp.65-72, 2012.
- [32] Peckham, T. and McCalla, G., Mining Student Behavior Patterns in

- Reading Comprehension Tasks, Proceedings of the 5th International Conference on Educational Data Mining, pp.87-94, 2012.
- [33] Park, J., Denaro, K., Rodriguez, F., Smyth, P., and Warschauer, M., Detecting changes in student behavior from clickstream data, In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17), pp.21-30, 2017.
DOI: <https://doi.org/10.1145/3027385.3027430>
- [34] Käser, T., Hallinen, N.R., and Schwartz, D.L., Modeling exploration strategies to predict student performance within a learning environment and beyond, In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17), pp.31-40, 2017.
DOI: <https://doi.org/10.1145/3027385.3027422>
- [35] Gibson, A., Aitken, A., Sándor, A., Shum, S.B., Tsingos-Lucas, C., and Knight, S., Reflective writing analytics for actionable feedback. In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17), pp.153-162, 2017.
DOI: <https://doi.org/10.1145/3027385.3027436>
- [36] Ullmann, T.D., Reflective writing analytics: empirically determined keywords of written reflection, In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17), pp.163-167, 2017.
DOI: <https://doi.org/10.1145/3027385.3027394>
- [37] Ez-zaouia, M. and Lavoué, E., EMODA: a tutor oriented multimodal and contextual emotional dashboard. In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17), pp.429-438, 2017.
DOI: <https://doi.org/10.1145/3027385.3027434>
- [38] Xu, Z. and Woodruff, E., Person-centered approach to explore learner's emotionality in learning within a 3D narrative game, In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17), pp.439-443, 2017.

DOI: <https://doi.org/10.1145/3027385.3027432>

- [39] Azevedo, R., Millar, G.C., Taub, M., Mudrick, N.V., Bradbury, A. E., and Price, M.J., Using data visualizations to foster emotion regulation during self-regulated learning with advanced learning technologies: a conceptual framework, In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17), pp.444-448, 2017.

DOI: <https://doi.org/10.1145/3027385.3027440>

- [40] Hecking, T., Chounta, I., and Hoppe, H.U., Investigating social and semantic user roles in MOOC discussion forums, In Proceedings of the LAK '16, pp.198-207, 2016.

DOI: <http://dx.doi.org/10.1145/2883851.2883924>

- [41] Zhu, M., Bergner, Y., Zhang, Y., Baker, R., Wang, Y., and Paquette, L., Longitudinal engagement, performance, and social connectivity: a MOOC case study using exponential random graph models, In Proceedings of the LAK '16, pp.223-230, 2016.

DOI: <http://dx.doi.org/10.1145/2883851.2883934>

- [42] Joksimović, S., Manataki, A., Gašević, D., Dawson, S., Kovanović, V., and De Kereki, I.F, Translating network position into performance: importance of centrality in different network configurations, In Proceedings of the LAK '16, pp.314-323, 2016.

DOI: <http://dx.doi.org/10.1145/2883851.2883928>

- [43] Bordogna, C.M. and Albano, E.V., Theoretical Description of Teaching-Learning Processes: A Multidisciplinary Approach, Phys. Rev. Lett., Vol.87, No.11, 118701, 2001.

DOI: <https://doi.org/10.1103/PhysRevLett.87.118701>

- [44] 安武公一, 山川修, 多川孝央, 隅谷孝洋, 井上仁, ネットワーク・コミュニティを通じた学習者間の相互作用とその効果に関するシミュレーション分析, 教育システム情報学会誌, Vol.28, No.1, pp.50-60, 2011.

- [45] Hsu, C.K., Hwang, G.J., and Chang, C.K., Development of a reading material recommendation system based on a knowledge engineering approach, Computers & Education, Vol.55, No.1, pp.76-83, 2010.

- [46] Kandula, S., Curtis, D., Hill, B., and Zeng-Treitler, Q., Use of topic modeling for recommending relevant education material to diabetic patients, Proceedings of the AMIA Annual Symposium, pp.674-682, 2011.
- [47] Furukawa, M. and Yamaji, K., Adaptive Recommendation of Teaching Materials Based on Free Descriptions in MOOC Course, Proceedings of the 6th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI), pp.1011-2012, 2017.
DOI: <https://doi.org/10.1109/IIAI-AAI.2017.176>
- [48] Zapata-Gonzalez, A., Menendez, V.H, Prieto-Me´ndez, M.E., and Romero, C., Using data mining in a recommender system to search for learning objects in repositories, Proceedings of the 4th International Conference on Educational Data Mining, pp.321-322, 2011.
- [49] Drachsler, H. and Greller, W., Privacy and analytics: it's a DELICATE issue a checklist for trusted learning analytics, In Proceedings of the LAK '16, pp.89-98, 2016.
DOI: <http://dx.doi.org/10.1145/2883851.2883893>
- [50] Oster, M., Lonn, S., Pistilli, M., and Brown, M., The learning analytics readiness instrument, In Proceedings of the LAK '16, pp.173-182, 2016.
DOI: <http://dx.doi.org/10.1145/2883851.2883925>
- [51] Harrison, S., Villano, R., Lynch, G., and Chen, G., Measuring financial implications of an early alert system, In Proceedings of the LAK '16, pp.241-248, 2016.
DOI: <http://dx.doi.org/10.1145/2883851.2883923>
- [52] Rienties, B. and Toetenel, L., The impact of 151 learning designs on student satisfaction and performance: social learning (analytics) matters, In Proceedings of the LAK '16, pp.339-343, 2016.
DOI: <http://dx.doi.org/10.1145/2883851.2883875>
- [53] Wells, M., Wollenschlaeger, A., Lefevre, D., Magoulas, G., and

- Poulovassilis, A., Analysing engagement in an online management programme and implications for course design, In Proceedings of the LAK '16, pp.236-240, 2016.
DOI: <http://dx.doi.org/10.1145/2883851.2883894>
- [54] Bakharia, A., Corrin, L., Barba, P., Kennedy, G., Gaevi, D., Mulder, R., Williams, D., Dawson, S., and Lockyer, L., A conceptual framework linking learning design with learning analytics, In Proceedings of the LAK '16, pp.329-338, 2016.
DOI: <http://dx.doi.org/10.1145/2883851.2883944>
- [55] JISC, <https://www.jisc.ac.uk>
- [56] Koedinger, K., Liu, R., Stamper, J., Thille, C., and Pavlik, P., Community based educational data repositories and analysis tools, In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17), pp.524-525, 2017.
DOI: <https://doi.org/10.1145/3027385.3029442>
- [57] LACE - Learning Analytics Community Exchange, <http://www.laceproject.eu/>
- [58] Ferguson R. and Clow, D., Where is the evidence?: a call to action for learning analytics, In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17), pp.56-65, 2017.
DOI: <https://doi.org/10.1145/3027385.3027396>
- [59] Tsai, Y., Gasevic, D., Muñoz-Merino, P.J., and Dawson, S., LA policy: developing an institutional policy for learning analytics using the RAPID outcome mapping approach, In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17), pp.494-495, 2017.
DOI: <https://doi.org/10.1145/3027385.3029424>
- [60] Arnold, K.E. and Sclater, N., Student perceptions of their privacy in leaning analytics applications, In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17), pp.66-69, 2017.

DOI: <https://doi.org/10.1145/3027385.3027392>

- [61] Hildebrandt, M., Learning as a machine: Crossovers between humans and machines, *Journal of Learning Analytics*, 4(1), pp.6-23, 2017.
DOI: <http://dx.doi.org/10.18608/jla.2017.41.3>
- [62] Mislevy, R.J., A Dispatch from the Psychometric Front, 2016,
http://lak16.solaresearch.org/wp-content/uploads/2016/05/Mislevy_LAK.Keynote.05-17-2016.pdf
- [63] Prinsloo, P. and Slade, S., An elephant in the learning analytics room: the obligation to act, In *Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17)*, pp.46-55, 2017.
DOI: <https://doi.org/10.1145/3027385.3027406>
- [64] Ye, C. and Biswas, G., Early Prediction of Student Dropout and Performance in MOOCs using Higher Granularity Temporal Information, *Journal of Learning Analytics*, Vol.1, No.3, pp.169-172, 2014.
DOI: [10.18608/jla.2014.13.14](https://doi.org/10.18608/jla.2014.13.14)
- [65] Askinadze, A. and Conrad, S., Predicting Student Dropout in Higher Education Based on Previous Exam Results, *Proceedings of the 12th International Conference on Educational Data Mining*, pp.500-503, 2019.
- [66] Lee, Y. and Choi, J., A review of online course dropout research: implications for practice and future research, *Educational Technology Research and Development*, Vol.59, No.5, pp.593-618, 2011.
DOI: <https://doi.org/10.1007/s11423-010-9177-y>
- [67] Khalil, H. and Ebner, M., MOOCs Completion Rates and Possible Methods to Improve Retention - A Literature Review, In *World Conference on Educational Multimedia, Hypermedia and Telecommunications*, Vol.2014, No.1, pp.1305-1313, 2014.
- [68] Chien, H.Y., Kwok, O.M., Yeh, Y.C., Sweany, N.W., Baek, E., and McIntosh, W., Identifying at-risk online learners by

psychological variables using machine learning techniques, Online Learning, Vol.24, No.4, pp.131-146, 2020.

DOI: <https://doi.org/10.24059/olj.v24i4.2320>

- [69] Milliron, M.D., Malcolm, L., and Kil, D., Insight and action analytics: Three case studies to consider, Research and Practice in Assessment, Vol.9, pp.70-89, 2014.
- [70] Zhang, G., Anderson, T.J., Ohland, M.W., et al., Identifying factors influencing engineering student graduation: A longitudinal and cross-institutional study, Journal of Engineering Education - Washington-, Vol.93, No.4, pp.313-320, 2004.
- DOI: <http://dx.doi.org/10.1002/j.2168-9830.2004.tb00820.x>
- [71] Nedeva, V. and Pehlivanova, T., Using Machine Learning To Analyze University Students' Dropout Rate - A Case Study, International Journal on Information Technologies & Security, Vol.12, No.3, pp.37-50, 2020.
- [72] Mendez, G., Buskirk, T.D., Lohr, S., et. al., Factors associated with persistence in science and engineering majors: An exploratory study using classification trees and random forests, Journal of Engineering Education, Vol.97, No.1, pp.57-70, 2008.
- [73] Chen, Y., Chen, Q., Zhao, M., Boyer, S., Veeramachaneni, K., and Qu, H., DropoutSeer: Visualizing Learning Patterns in Massive Open Online Courses for Dropout Reasoning and Prediction, In Proceedings of the 2016 IEEE Conference on Visual Analytics Science and Technology (VAST), pp.111-120, 2016.
- [74] Lakkaraju, H., Aguiar, E., Shan, C., Miller, D., Bhanpuri, N., Ghani, R., and Addison, K.L., A machine learning framework to identify students at risk of adverse academic outcomes, Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp.1909-1918, 2015.
- [75] Delianidi, N., Diamantaras, K., Chrysogonidis, G., and Nikiforidis, V., Student Performance Prediction Using Dynamic

- Neural Models, Proceedings of the 14th International Conference on Educational Data Mining, pp.46-54, 2021.
- [76] Murata, R., Minematsu, T., and Shimada, A., Early Detection of At-risk Students based on Knowledge Distillation RNN Models, Proceedings of the 14th International Conference on Educational Data Mining, pp.699-703, 2021.
- [77] Francesco, A., Mauro, M., and Gianmarco, B., Deep learning approach for predicting university dropout: a case study at Roma Tre University, Journal of E-Learning and Knowledge Society, Vol.16, No.1, pp.44-54, 2020.
DOI: <https://doi.org/10.20368/1971-8829/1135192>
- [78] Okubo, F., Yamashita, T., Shimada, A., Taniguchi, Y., and Konomi, S., On the Prediction of Students' Quiz Score by Recurrent Neural Network, CEUR Workshop Proceedings, Vol.2163, 2018.
- [79] Hu, Q. and Rangwala, H., Reliable Deep Grade Prediction with Uncertainty Estimation, Proceedings of the 10th International Conference on Learning Analytics & Knowledge, pp.76-85, 2019.
DOI: <https://doi.org/10.1145/3303772.3303802>
- [80] Reich, J., MOOC completion and retention in the context of student intent, Educause Review, 2014.
<https://er.educause.edu/articles/2014/12/mooc-completion-and-retention-in-the-context-of-student-intent/>
- [81] 藤本徹, 荒優, 山内祐平, 大規模公開オンライン講座(MOOC)におけるラーニング・アナリティクス研究の動向, 日本教育工学会論文誌, Vol.41, No.3, pp.305-313, 2017.
- [82] 永田裕太郎, 村上正行, 森村吉貴, 椋木雅之, 美濃導彦, MOOCにおける大規模学習ログデータからの学習者の学習様態獲得, 人工知能学会第73回先進的学習科学と工学研究会, Vol.73, pp.25-30, 2015.
- [83] Ferguson, R. and Clow, D., Examining engagement: Analysing learner subpopulations in massive open online courses (MOOCs), Proceedings of the Fifth International Conference on Learning Analytics and Knowledge, pp.51-58, 2015.

DOI: 10.1145/2723576.2723606

- [84] Ho, A.D., Reich, J., Nesterko, S., Seaton, D.T., Mullaney, T., Waldo, J., and Chuang, I., HarvardX and MITx: The first year of open online courses, HarvardX and MITx Working Paper, No.1, 2014.
- [85] 古川雅子, 尾城孝一, 山地一禎, 研究データ管理オンライン講座の開発と学習者特性の分析, 情報処理学会情報教育シンポジウム 2018 論文集, pp.84-89, 2018.
- [86] 逸村裕, オープンアクセス・オープンデータ・オープンサイエンス, 知能と情報, 日本知能情報フレンジイ学会, Vol.27, No.3, pp.90-95, 2015.
- [87] 武田英明, オープンサイエンスの成り立ちと学術コミュニケーションの未来, 情報処理, Vol.60, No.5, pp.392-398, 2019.
- [88] 船守美穂, オープンサイエンス推進に関わる学術機関の役割と課題, 情報知識学会誌, Vol.27, No.4, pp.309-322, 2017.
- [89] 国立研究開発法人におけるデータポリシー策定のためのガイドライン, <http://www8.cao.go.jp/cstp/stsonota/datapolicy/datapolicy.pdf>
- [90] Rice, R. and Haywood, J., Research Data Management Initiatives at University of Edinburgh, The International Journal of Digital Curation, Vol.6, No2, pp.232-244, 2011.
DOI: <https://doi.org/10.2218/ijdc.v6i2.199>
- [91] MANTRA, <https://mantra.edina.ac.uk/>
- [92] Orth, A., Pontika, N., and Ball, D., FOSTER's Open Science Training Tools and Best Practices, IOS Press, 2016.
DOI: <https://doi.org/10.3233/978-1-61499-649-1-135>
- [93] Figshare, <https://knowledge.figshare.com/open-data/about-rdm>
- [94] 常川真央, 天野絵里子, 大園隼彦, 西藺由依, 前田翔太, 松本侑子, 南山泰之, 三角太郎, 青木学聡, 尾城孝一, 山地一禎, 研究データ管理 (RDM) トレーニングツールの構築と展開, 情報知識学会誌, Vol.27, No.4, pp.362-365, 2017.
DOI: https://doi.org/10.2964/jsik_2017_042
- [95] gacco, <http://gacco.org/>
- [96] Furukawa, M., Itsumura, H., and Yamaji, K., Estimation of Test Scores Based on Video Viewing Behavior in the Programming MOOC

- Course, Proceedings of 9th International Congress on Advanced Applied Informatics (IIAI AAI 2020) , pp.155-162, 2020.
- [97] 文部科学省, 諸外国におけるプログラミング教育に関する調査研究 (文部科学省平成 26 年度・情報教育指導力向上支援事業), 大日本印刷株式会社, 2015.
- [98] 文部科学省, 小学校段階におけるプログラミング教育の在り方について (議論の取りまとめ), 2016.
http://www.mext.go.jp/b_menu/shingi/chousa/shotou/122/attach/1372525.htm
- [99] 兼宗進, 中谷多哉子, 御手洗理英, 福井眞吾, 久野靖, 初中等教育におけるオブジェクト指向プログラミングの実践と評価, 情報処理学会論文誌プログラミング (PRO), Vol. 44, pp. 58-71, 2003.
- [100] 田口浩, 糸賀裕弥, 毛利公一, 山本哲男, 島川博光, 個々の学習者の理解状況と学習意欲に合わせたプログラミング教育支援, 情報処理学会論文誌, Vol. 48, No. 2, pp. 958-968, 2007.
- [101] 上田浩, 中村素典, 古村隆明, 神智也, 倫倫姫プロジェクトー学認連携 Moodle による多言語情報倫理 e ラーニングー. デジタルプラクティス, Vol. 6, No. 2, pp. 97-104, 2015.
- [102] はじめての P, <https://www.nii.ac.jp/service/jmooc/hajimete/>
- [103] 古川 雅子, 逸村 裕, 山地 一禎, 小テストの点数パターンによる学習者のクラスタリングとその推定, 情報処理学会論文誌教育とコンピュータ (TCE) , Vol. 6, No. 2, pp. 52-60, 2020.
- [104] LAK '16: Proceedings of the Sixth International Conference on Learning Analytics & Knowledge,
<https://dl.acm.org/doi/proceedings/10.1145/2883851>
- [105] LAK '17: Proceedings of the Seventh International Learning Analytics & Knowledge Conference,
<https://dl.acm.org/doi/proceedings/10.1145/3027385>

全研究業績リスト

- [1] Masako Furukawa, Hiroshi Itsumura, and Kazutsuna Yamaji: "Estimation of Test Scores Based on Video Viewing Behavior in the Programming MOOC Course". Proceedings of 9th International Congress on Advanced Applied Informatics (IIAI AAI 2020) . pp.155-162. 2020年9月
- [2] 古川 雅子, 逸村 裕, 山地 一禎: "小テストの点数パターンによる学習者のクラスタリングとその推定". 情報処理学会論文誌教育とコンピュータ (TCE). 6. (2). pp.52-60. 2020年6月
- [3] Nobukuni Hamamoto, Hiroshi Ueda, Masako Furukawa, Motonori Nakamura, Takeshi Nishimura, Shigetoshi Yokoyama, and Kazutsuna Yamaji: "Toward the Cross-Institutional Data Integration From Shibboleth Federated LMS". Procedia Computer Science. 159. pp.1720-1729. 2019年9月
- [4] 古川雅子, 尾城孝一, 常川真央, 西園由依, 天野絵里子, 山地一禎: "学術機関における研究データ管理支援の組織モデルに関する考察". 情報知識学会誌. 29. (2). pp.135-142. 2019年5月
- [5] Masako Furukawa, Koichi Ojio, and Kazutsuna Yamaji: "Development and Analysis of Online RDM Training Course". 2018 IEEE 7th Global Conference on Consumer Electronics (GCCE2018). pp.603-607. 2018年10月
- [6] 古川雅子, 尾城孝一, 山地一禎: "研究データ管理オンライン講座の開発と学習者特性の分析". 情報処理学会 情報教育シンポジウム論文集. 2018. pp.84-89. 2018年8月
- [7] Masako Furukawa, Yoshitomo Yaginuma, and Tsuneo Yamada: "Cluster Analysis of Learners based on Video Annotations". Proceedings of 7th International Congress on Advanced Applied Informatics (IIAI AAI 2018 [LTLE2018]) . pp.944-945. 2018年7月
- [8] Masako Furukawa and Kazutsuna Yamaji: "Estimation of Learners' Programming Level based on Free Descriptions in MOOC Course". Companion Proceedings of the 8th International Conference on Learning Analytics & Knowledge (LAK'18). pp.281-282. 2018年3月
- [9] Hiroshi Ueda, Masako Furukawa, Kazutsuna Yamaji, and Motonori Nakamura: "SCORMAdaptiveQuiz: Implementation of Adaptive e-Learning for Moodle.". Knowledge-Based and Intelligent Information & Engineering Systems: Proceedings of the 22nd International Conference KES-2018, Belgrade, Serbia, 3-5 September 2018. pp.2261-2270. 2018年
- [10] Masako Furukawa, Kazutsuna Yamaji, Yoshitomo Yaginuma, and Tsuneo Yamada: "Development of learning analytics platform for OUJ online courses". 2017 IEEE 6th Global Conference on Consumer Electronics, GCCE 2017. 2017. pp.1-2. 2017年12月19日
- [11] Masako Furukawa and Kazutsuna Yamaji: "Adaptive Recommendation of Teaching Materials Based on Free Descriptions in MOOC Course". Proceedings - 2017 6th IIAI International Congress on Advanced Applied Informatics, IIAI-AAI 2017. pp.1011-1012. 2017年11月15日
- [12] 古川雅子, 中村泰之, 山川修, 柳沼良知, 多川孝央, 魚崎典子, 山田恒夫: "ラーニング・アナリティクスの動向 -第7回 Learning Analytics & Knowledge Conference (LAK'17)参加報告-". 情報処理学会 情報教育シンポジウム論文集. 2017. (5). pp.31-36. 2017年8月

- [13] Yoshitomo Yaginuma, Masako Furukawa, and Tsuneo Yamada: "Video annotation tool for learning job interview". ACM International Conference Proceeding Series. pp.534-535. 2017年3月13日
- [14] 東海林以展, 古川雅子, 森田和行, 森田裕介: "視覚障がい者のウェブアクセシビリティに配慮した入力フォームの検討". 日本教育工学会論文誌. 40. (Suppl.). pp.73-76. 2017年1月
- [15] 古川雅子, 山地一禎, 安武公一, 中村泰之, 山田恒夫, 梶田将司: "第6回 Learning Analytics & Knowledge Conference(LAK16) 参加報告". 情報処理学会 情報教育シンポジウム論文集. 2016. pp.53-58. 2016年8月
- [16] Kazutsuna Yamaji, Toshihiro Aoyama, Masako Furukawa, and Tsuneo Yamada: "Development and deployment of the open access repository and its application to the open educational recourses". Advances in Intelligent Systems and Computing. 388. pp.395-403. 2016年
- [17] Koichiro Ishikawa, Masako Furukawa, Yutaka Saito, Takahiro Naito, and Mamiko Shichida: "Log Data Analysis of Learning Histories in an e-Learning Course". International Journal of Information and Education Technology. 3. (6). pp.587-590. 2013年8月
- [18] Kochiro Ishikawa, Masako Furukawa, Mamiko Shichida, and Yutaka Saito: "E-Mentor Autonomy: Learners' Support in the Next Generation". Proceedings of the 2nd Annual International Conference on Education & e-Learning (EeL2012). pp.127-131. 2012年9月
- [19] Masako Furukawa, Asuka Ichihara, and Shingo Imai: "Developing e-Learning System of Japanese Language Learning for foreign students". Proceedings of the 19th International Conference on Computers in Education (ICCE) . pp.21-23. 2011年11月
- [20] Koichiro Ishikawa, Masako Furukawa, Mamiko Shichida, and Yutaka Saito: "A Macroscopic Pattern at Global Level Shown in Learners' Behaviors". BEHAVIORAL, COGNITIVE AND PSYCHOLOGICAL SCIENCES. 23. pp.65-69. 2011年
- [21] 古川雅子, 柳沼良知, 山田恒夫: "映像記述の評価者属性間の相違に関する研究". メディア教育研究. 5. (1). pp.123-129. 2008年9月
- [22] 古川雅子, 柳沼良知, 山田恒夫: "観察者属性によるマルチアングル映像観察傾向の相違". 日本教育工学会論文誌. 28. (Suppl.). pp.161-164. 2005年3月
- [23] Masako Furukawa, Yoshitomo Yaginuma, and Tsuneo Yamada: "Developing a multi-angle video annotation package with layout editing functions: Evaluation from Comparison of Comments between Experienced and Inexperienced Video Observers". ED-MEDIA 2004: World Conference on Educational Multimedia, Hypermedia & Telecommunications, Vols. 1-7. 2004. pp.1773-1778. 2004年