

自動選定した教学 IR データに基づく アカデミック・サクセスの予測

近藤 伸彦^{1,a)} 松田 岳士¹ 林 祐司¹ 渡辺 雄貴² 松河 秀哉³ 立石 慎治⁴ 椿本 弥生⁵
山下 英明¹

概要：多くの学生が大学生活を通して何らかの学業面での成功（アカデミック・サクセス，以下 AS）を収めるためには，教学 IR の観点から，個に応じた適切な指導や支援が有効であると考えられる．本稿では，AS の度合いの予測を学生の指導や支援に活用することを想定し，教学 IR データを用いた AS の予測モデリングについて提案する．本研究では，進化計算により，AS の度合いの予測に適した説明変数を教学 IR データから自動的に選択し，機械学習によって AS の度合いを高精度で予測するモデルを構築することを考える．実際の教学 IR データを用いた数値実験から，想定する AS に応じた予測モデルの構築が可能であることと，変数選択が予測性能の向上に有効であることが示唆された．

Prediction of Academic Success based on IR Data Selected Automatically

1. はじめに

近年，データに基づく教育・学習の改善についての研究や実践がさまざまな観点から発展している．高等教育の質保証の観点から多くの大学で導入されている教学 IR (Institutional Research) はその代表的なものといえる．なかでも，大学の定めるディプロマポリシー（学位授与の方針）のもとでの学生の学習成果に関する議論はとくに盛んに行われている．各大学あるいはそれぞれの学位プログラムが定めるディプロマポリシーは「望まれる学生像」を反映したものと考えられるが，そのありようは大学・学位プログラムごとに多様である．これは，対象とする分野の違いに加え，ユニバーサル化した現在の高等教育における学生の多様さなど，大学の置かれた環境が多様化しているこ

とでより顕著になりつつあるものと考えられる．また，「学士課程答申 [1]」で示された「学士力」のように，専門的知識・技能だけでなく，汎用的能力や態度・志向性のような広い意味での学習成果が獲得できるような教育が大学に求められているという背景もあり，各大学あるいは学位プログラムがどのような学生像を望み，そのための教育をどのように実践し，その成果をいかに評価するかということが多くの大学の課題となっている．教学 IR の観点からは，こうした大学や学位プログラムごとに異なるある種の「学生の成功」に関する指標を適切に設定し，そのモニタリングをもとに，学生に対する学習支援や教学施策へのフィードバックなどを行うことが重要であると考えられる．

本研究では，学生が大学生活を通して何らかの学業面での成功を収めることを「アカデミック・サクセス（以下 AS という．）」とよび，多くの学生が AS を達成するために必要な個に応じた適切な指導や支援を可能とするようなシステムの開発をめざしている．AS のための指導や支援に必要な機能にはさまざまなものが考えられるが，なかでも本稿では，経年後の AS の度合いを早期に予測することについて検討する．

これまでに著者らは，この観点から，学生の留年可能性を早期発見して指導に役立てるための IR システム「Risk

¹ 首都大学東京
Tokyo Metropolitan University

² 東京理科大学
Tokyo University of Science

³ 東北大学
Tohoku University

⁴ 国立教育政策研究所
National Institute for Educational Policy Research

⁵ 東京大学
The University of Tokyo

a) kondo@tmu.ac.jp

Detector」の試作版を開発してきた [2]。その形成的評価によると、留年予測の精度については満足が得られたものの、予測精度だけでなくどの変数が留年防止に重要かといった情報が指導上必要であるという示唆が得られた [3]。また、実用上、「留年しないこと」という観点だけでなく、より幅広い意味での AS を扱うことのできる汎用的なシステムが必要とされることも課題であった。

本稿では、幅広い AS のための指導や学習支援を補助するシステムにおける教学 IR データを用いた AS の予測モデリングの枠組みについて提案する。本研究では、進化計算により AS の度合いの予測に適した説明変数を教学 IR データから自動的に選択し、機械学習によって AS の度合いを高精度で予測するモデルを構築することを考える。本稿では、本手法の詳細について述べたのち、実際の教学 IR データを用いた数値実験の結果について紹介し、本手法の適用可能性と課題について検討する。

2. 教学 IR とアカデミック・サクセス

2.1 教学 IR とラーニングアナリティクス

第 1 章で述べたように、データに基づく教育・学習の改善に関する研究・実践の分野として IR (Institutional Research) がよく知られている。IR とは学内外のデータをもとに大学の意思決定を支援する機能や研究分野をさす。日本では、高等教育の質保証や説明責任の要求などを背景に 2010 年代前半頃から注目が集まり、とくに教育・学習に関する IR である「教学 IR」が独自に発展してきた [4]。教学 IR は、大学としての教育効果のような機関レベルの分析から、個々の学生に応じた学習支援のための分析まで、さまざまなレベルでのデータサイエンスとしての機能が期待されている。

一方、近年の ICT の進歩にともない、LMS (Learning Management System) や MOOCs (Massive Open Online Courses) などの教育・学習用システムまたはアプリケーションのログデータのように、教育・学習においても大規模なデータが利用可能になってきたことから、大規模データに基づく教育・学習の改善をめざすラーニングアナリティクスなどの研究分野がこの 10 年ほどの間に発展してきた。SoLAR (Society for Learning Analytics Research) によると、ラーニングアナリティクスは「学習とその環境の理解と最適化のための、学習者とそのコンテキストについてのデータの測定、収集、分析、レポート」と定義される [5]。

米国では教学 IR に近い概念として Academic Analytics があるが、近年はこれをラーニングアナリティクスと分離せず、機関レベルから個々の授業レベルまでの適用レベルの違いとして、ラーニングアナリティクスの分野の中で統一的に捉えることが多くなっているようである。ラーニングアナリティクスで用いられるデータをマイクロレベル、教

学 IR で用いられるデータをマクロレベルとして、これらを統合したマルチレベルな分析が必要であることも近年しばしば指摘されている [6][7]。

2.2 アカデミック・サクセスとスチューデント・サクセス

IR の文脈では、学生の何らかの意味での「成功」状態を示すスチューデント・サクセスと呼ばれる概念に関連する研究が海外では盛んである [8][9][10]。第 1 章で述べたように、大学や学位プログラムが望む学生像が多様であることに加え、学生自身が捉える「サクセス」のありようも多様であることから、なにをもってスチューデント・サクセスとするかを包括的に定義することは難しい。多様化を遂げる「サクセス」の指標から、機関として合意した指標をトップダウンに評価するアプローチもあれば、学生自身の考える「サクセス」を多様なまま捉えるアプローチも考え得る。いずれにしても、学生の「サクセス」を考えることは、教学 IR で関心のもたれる「学習成果」とも関連が深く、定量的か定性的かを問わずこれを捉えることが重要であると考えられる。

スチューデント・サクセスは必ずしも大学や学位プログラムの提供する学業上の成果に関連するもののみを指すのではなく、コミュニティ形成、満足度、キャリア形成など、幅広い意味でのサクセスを包含する。本研究では、学生が大学生活を通して何らかの学業面での成功を収めることをとくに「アカデミック・サクセス (AS)」とよぶこととし、本稿では教学 IR データに基づく AS の予測について議論する。

3. 機械学習・進化計算とその教育利用

本研究では、AS の予測モデル構築において、機械学習と進化計算の手法をあわせて用いたアプローチをとる。本章では、機械学習・進化計算それぞれについて概説し、その教育データ分析の分野における活用現状について簡単にまとめる。

3.1 機械学習と予測モデル

機械学習は、データに基づいて対象の数学モデルを構築するための枠組みの総称である。近年では人工知能の基盤技術として盛んに研究され、さまざまな分野における応用が進められている。なかでも、教師あり学習によるアプローチは予測や分類に活用され、適用可能なフィールドが広いことから頻繁に用いられている。教師あり学習は、問題の対象を表現しうる数学モデルのもとで、教師ラベルの付与された多変量のデータをもとに、予測や分類の誤差をなるべく小さくするようなモデルパラメータを統計的に推定する方法である。言い換えれば、多次元の説明変数から目的変数への写像を推定するための統計的手法である。

ラーニングアナリティクスにおいては、予測モデル (Pre-

dictive model) を用いたなんらかの予測に基づくアプローチがしばしば取られる [11]. データの規模が大きく, また対象が複雑になるにつれ, 予測モデルの構築には機械学習の手法を用いることが多くなっている. 教学 IR においても, 教学 IR データに基づくなんらかの予測に関する研究が多く行われており, たとえば単位修得状況の予測 [12] や, 留年・退学の予測についての数多くの報告がある [13][14][15][16][17].

ラーニングアナリティクスに関する予測モデル活用についてまとめられた文献 [11] では, よく使われる機械学習アルゴリズムとして, 線形回帰, ロジスティック回帰, 最近傍法, 決定木, ナイブベイズ分類器, ベイジアンネットワーク, サポートベクターマシン, ニューラルネットワーク, アンサンブル法が紹介されている. 近年では, Python などのプログラミング言語において豊富な機械学習パッケージが利用可能であり, これを活用することで容易に機械学習による予測モデルを構築することが可能である.

本研究では, 後述の通り, 学士課程のある時点 (たとえば 1 年次終了時点など) において卒業時の AS を予測することを考えている. ここで, 機械学習による予測を行う場合, その時点までに利用可能な教学 IR データから適当なものを説明変数とし, AS のようすを示す何らかの指標を目的変数としてモデル化することになる.

機械学習のアルゴリズムには任意のものを利用可能であるが, 本稿では一例として, 後述の通りロジスティック回帰とランダムフォレストを用いる. ロジスティック回帰は一般化線形モデルの一種であり, 2 クラス分類によく用いられる. 扱いやすさと可解釈性に加え, 比較的良好な性能を示すことが多く, 実用的によく用いられるモデルである. ランダムフォレストはアンサンブル学習のひとつとして知られ, 弱学習器として単純な決定木を複数学習し, その平均値や多数決などによって出力を定めるモデルである. ノイズに対するロバスト性, 学習の速さ, 性能の高さなどからこれもよく用いられるモデルである.

3.2 進化計算

進化計算 (evolutionary computation) は, 生物の遺伝と進化のメカニズムを学習や最適化のプロセスへ応用した計算手法の総称である. 進化計算は, 確率的多点探索法であり複数の解を並列に求めることができること, 目的関数の勾配情報を必要としないこと, 確率的操作により局所解から回避するメカニズムをもつことなど多くの利点を有し, 複雑な実問題に対して現実的な時間内に実用的な解を求めることができるメタヒューリスティクスとして知られる [18].

本研究では, 進化計算のひとつとしてよく用いられる遺伝的アルゴリズム [19] を使用する. 遺伝的アルゴリズムは, 選択, 交叉, 突然変異を主な遺伝的操作とした枠組み

である. 遺伝的アルゴリズムでは, 最適化問題の解の候補をひとつの個体と考え, 複数の個体による集団を進化的に変化させることで, 集団として最適解を探索する. 各個体は, 解候補の情報をバイナリ列などの記号列として保持する. これは染色体のアナロジーである. 各個体はそれぞれ, 最適化問題における目的関数の値を評価し, これを適合度としてもつ. 適合度は, 個体が環境にどの程度適応しているかに相当する. これらの個体集団は, 選択 (淘汰), 交叉, 突然変異などの遺伝的操作を行うことで変化していく. 選択 (淘汰) は次世代に残す個体を決定する操作であり, 適合度が高い個体ほど次世代へ生き残りやすくなるような方法によって行う. そのうち, 選択された個体間で確率的な記号列の入れ替え (交叉) や記号列の要素の置き換え (突然変異) を行い, 情報を確率的に変化させる. こうした遺伝的操作を繰り返すことで, 親の形質を部分的に受け継ぎながら世代ごとに遺伝情報が変化していき環境に適した個体が集団として生み出されていく進化的なプロセスがシミュレートされる. この遺伝的アルゴリズムの流れを図 1 に示す.

遺伝的アルゴリズムは解候補として記号列を操作することから, NP 困難な組合せ最適化問題などに対する相性がよく, しばしば用いられる.

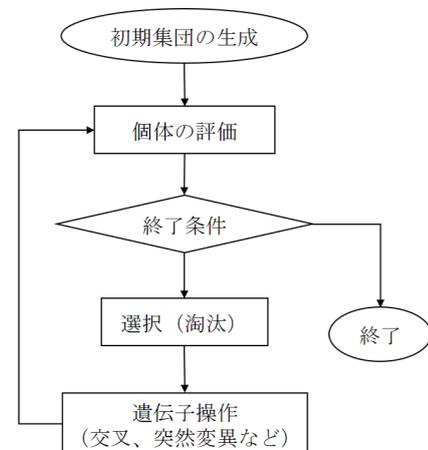


図 1 遺伝的アルゴリズムの流れ

4. 提案手法

本研究では, 学生の AS のための指導や支援に用いるものとして, 経年後の AS の度合いを早期に予測することについて検討している. 本章では, 機械学習と遺伝的アルゴリズムを用いた AS 予測モデル構築の手法について提案する.

4.1 機械学習による AS 指標の予測

本稿では, 幅広い意味での AS を扱うことのできる汎用的な AS 予測モデル構築の枠組みについて提案する. こ

では、学士課程のある時点（たとえば1年次終了時点など）において卒業時のASを予測することを考える。この枠組みでは、ASの度合いを定量的に表すものとし、なんらかのASの指標を設定してこの値の高低を予測する。これは典型的な分類問題となるため、3.1で述べたように、予測モデルの構築には機械学習（教師あり学習）のアルゴリズムを用いる。予測の時点までに利用可能な教学IRデータから適当なものを説明変数とし、ASの指標を目的変数としてモデル化することになる。このAS予測モデルのイメージを図2に示す。

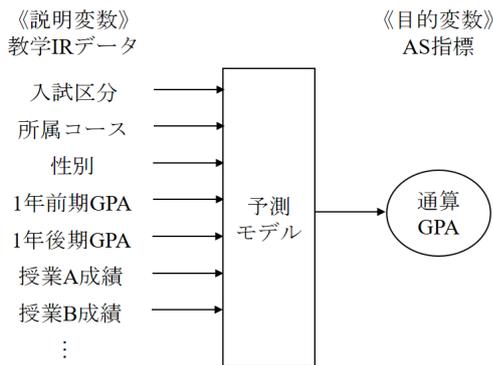


図2 AS予測モデル

ASの指標は、大学、学位プログラムなどさまざまなレベルで想定しうる。たとえば大学全体のレベルであれば、卒業時の通算GPAや、ディプロマポリシーに定められた汎用的能力の評価、あるいはストレート卒業の可否などが考えられるし、学位プログラムレベルでは、学位プログラムごとのディプロマポリシーに定められた専門的知識・技能の評価などが考えられるであろう。これらのAS指標は、成績や在籍状況のように大学が保有する教学IRデータを利用して求められるものもあれば、学生調査による間接評価やパフォーマンス評価による直接評価によって取得できるデータを利用して求められるものもあるが、なんらかの方法で定量化できる指標であれば、本手法によって予測の対象とすることが可能である。

4.2 遺伝的アルゴリズムによる説明変数の選択

機械学習による予測モデルを活用することでASの指標の達成度合いを教学IRデータから予測することは可能であると考えられる。しかしながら、これを実際の学生指導に用いることを想定したとき、もし指標の値の予測結果のみが与えられる状況であれば、「どのように」指導するかという指針を与えにくく、指導する教職員の能力や経験に依存する度合いが大きくなると考えられる。

ここで、予測モデルの説明変数となる教学IRデータはASの成否の予測に重要な指標となり得るが、第2章にて述べたように、大学が保持し、学生ごとに紐づけて利用可

能な教学IRデータは増加しており、ここから候補として抽出できる説明変数は高次元になると考えられる。高次元の説明変数からなる予測モデルを用いる場合、それらの説明変数の値を単に並べただけではどの変数が相対的に重要であるかといった情報を見出しにくい。これは、一般に統計モデルや機械学習モデルにおいて重要とされる変数選択あるいは特徴量選択と呼ばれる操作と関連が深い。モデルの説明変数の次元が学習データに対して大きい場合、過学習によって予測性能が低下することがあるため、適切な変数の部分集合を選択することが重要であることが知られている。また、変数選択は、予測性能の向上だけでなく、モデルの可解釈性を向上させる効果もある。本提案手法の場合も、重要な変数のみを選択してできるだけシンプルな予測モデルを構築できれば、ASの度合いの高低に関する重要変数を示すという意味でモデルの可解釈性が高まることが期待できる。

このような高次元の説明変数の選択にはさまざまな手法が存在するが、本研究では、3.2にて示した進化計算のひとつである遺伝的アルゴリズムを使用する。遺伝的アルゴリズムでは集団中の各個体が染色体とよばれる記号列をもつが、本提案手法では、説明変数の候補と同数のバイナリ値からなる染色体を考える。図3に示すように、染色体のそれぞれのバイナリ値を説明変数の候補と対応づけ、1ならば対応する説明変数を使用し、0ならば使用しないものとする。この染色体コーディングにより、遺伝的アルゴリズムの各個体と予測モデルを対応づけることができ、1の選ばれ方によって、異なる説明変数選択を実現することができる。

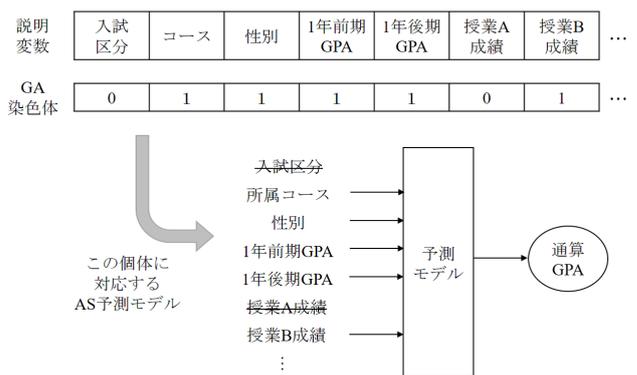


図3 遺伝的アルゴリズム（GA）の染色体と説明変数選択

遺伝的アルゴリズムでは、任意に設定した評価関数によって各個体の適合度が評価される。本提案手法では、「モデルの良さ」を測る基準はいくつか考えられるが、本稿における実験では、ASの予測性能を評価するものとした。

予測性能の指標には、クラス分類問題において一般に用いられるPrecision（適合率）とRecall（再現率）から計算されるF値を用いた。正と予測された正のデータの数をTP

(True Positive), 正と予測された負のデータの数を FP (False Positive), 負と予測された正のデータの数を FN (False Negative) とすると, Precision は $TP/(TP + FP)$, Recall は $TP/(TP + FN)$ と計算される. Precision は「モデルが正と予測したデータのうち実際に正である(予測が当たっている)割合」, Recall は「正と予測すべき全データのうち正であると予測できた(正しく発見できた)割合」であるといえる. Precision と Recall はトレードオフの関係にあるため, バランスをとった指標として, これらの調和平均 $(2 * Precision * Recall)/(Precision + Recall)$ で計算される F 値がよく用いられる. 上述の遺伝的アルゴリズムにおける評価関数においては, 各個体について 5-fold cross validation を行って F 値の平均を計算し, これを適合度とするものとした.

5. 数値実験

5.1 実験の設定

数値実験は, X 大学 Y 学部における 2017 年度卒業生のうち, 用いる変数において欠測値のない 456 名の教学 IR データにより行った.

実験設定として, 1 年次終了時点において 4 年次末の AS を予測することを想定した. すなわち, 予測モデルに用いる説明変数は, 1 年次終了時点において利用可能な教学 IR データから構成することとなる. 本実験においては, 以下の 172 種類の変数を説明変数とした.

- 入試区分
- 所属コース
- 性別
- 1 年次前期 GPA
- 1 年次後期 GPA
- 入学時の英語試験スコア
- 1 年次末の英語試験スコア
- 1 年次に開講された科目の成績 (165 科目)

このうちとくに, 1 年次に開講された科目の成績については, 履修していない科目については「履修していない」という値をもつものとし, 欠測値とはしないものとした.

予測する AS 指標には以下の 9 種類を用い, これを目的変数とする予測モデルを学習した. いずれも, 4 年次末の状態を予測するものとした.

- 通算 GPA
- 専門 GPA1~専門 GPA7 (7 種類の専門 DP について, それぞれに関連する履修科目のみの GPA を算出)
- ストレート卒業 (標準修業年限 (4 年) で卒業したか否か)

予測は 2 値分類とした. 通算 GPA・専門 GPA1~7 に関しては, 456 名のデータにおける第 3 四分位数より高いものを「AS である状態」, それ以外を「AS でない状態」とみなして教師データを作成した. AS である状態のデータ数は

それぞれ, 通算 GPA が 118 (25.9%), 専門 GPA1 が 119 (26.1%), 専門 GPA2 が 112 (24.6%), 専門 GPA3 が 113 (24.8%), 専門 GPA4 が 119 (26.1%), 専門 GPA5 が 111 (24.3%), 専門 GPA6 が 112 (24.6%), 専門 GPA7 が 115 (25.2%) であった. 「ストレート卒業」の目的変数については, 先行研究の留年予測や退学予測の例と同様に, 標準修業年限で卒業できないことを予測するほうが重要でかつ難しいと考えられるため, 「非ストレート卒業」のラベルを正とした場合の予測 (クラス分類) 結果について検討する. なお, 「非ストレート卒業」には, 標準修業年限を超えて卒業した者だけでなく, 退学・除籍した者も含まれる. 非ストレート卒業のデータ数は 70 (15.4%) であった.

提案手法の実装は Python 3.6.0 により行った. 機械学習のアルゴリズムにはロジスティック回帰およびランダムフォレストを使用し, scikit-learn パッケージ [20] の LogisticRegression と RandomForestClassifier をそれぞれ用いてこれを実装した. 遺伝的アルゴリズムの実装には DEAP パッケージ [21] を使用した.

本稿では, 遺伝的アルゴリズムのパラメータを以下のように設定し, これらのパラメータおよび機械学習のアルゴリズムの違いによる挙動の変化のようすを, 対象とする目的変数ごとに検討した.

- 個体数: 30 または 100
- 世代数: 100
- 交叉確率: 0.7 (ある 2 個体に対してこの確率で交叉が行われる)
- 突然変異確率: 0.2 または 0.4 (各個体に対してこの確率で突然変異が行われる)
- 遺伝的操作: 2 点交叉, ビット反転突然変異 (遺伝子座ごとに 0.05 の確率でビット反転), トーナメント選択 (トーナメントサイズ 3), エリート保存 (最良 2 個体は確実に保存)

5.2 実験結果

遺伝的アルゴリズムのパラメータのうち, 個体数と突然変異確率については, いずれのパラメータ設定においても結果が大きく変わらなかったため, 本稿においては個体数 100, 突然変異確率 0.4 の結果のみを示す.

表 1 に, 遺伝的アルゴリズムの最終世代の個体集団について, 目的変数ごと・アルゴリズムごとに, 最良個体の F 値と全個体の F 値の平均値を示す. また, 遺伝的アルゴリズムにおける探索のようすをみるため, とくに代表的なものとして「通算 GPA」「専門 GPA6」「非ストレート卒業」の 3 種類の目的変数について, 集団中の最良個体の F 値および全個体の F 値の平均値の 100 世代における推移を図 4~6 に示す.

表 1 からわかるように, 得られた F 値 (予測性能) は目的変数によって大きく異なる. また, 2 つの機械学習アル

表 1 遺伝的アルゴリズム最終世代の個体集団における最良個体の F 値と全個体の F 値の平均値. 「非スト卒業」は非ストレート卒業の略.

目的変数	ロジスティック回帰		ランダムフォレスト	
	最良個体	集団平均	最良個体	集団平均
通算 GPA	0.978	0.965	1.000	0.983
専門 GPA1	0.733	0.711	0.726	0.684
専門 GPA2	0.684	0.664	0.727	0.679
専門 GPA3	0.663	0.649	0.676	0.649
専門 GPA4	0.768	0.762	0.802	0.759
専門 GPA5	0.785	0.756	0.790	0.757
専門 GPA6	0.556	0.542	0.550	0.494
専門 GPA7	0.734	0.722	0.712	0.676
非スト卒業	0.484	0.460	0.457	0.400

表 2 遺伝的アルゴリズム最終世代の個体集団における最良個体の F 値と全説明変数を使用した場合の F 値. 最良個体については, 使用した説明変数の数を括弧内に併記. 変数の総数は 172. 「非スト卒業」は非ストレート卒業の略.

目的変数	ロジスティック回帰		ランダムフォレスト	
	最良個体	全変数使用	最良個体	全変数使用
通算 GPA	0.978 (92)	0.892	1.000 (93)	0.957
専門 GPA1	0.733 (90)	0.682	0.726 (82)	0.599
専門 GPA2	0.684 (91)	0.641	0.727 (84)	0.585
専門 GPA3	0.663 (77)	0.616	0.676 (83)	0.525
専門 GPA4	0.768 (86)	0.705	0.802 (84)	0.673
専門 GPA5	0.785 (95)	0.726	0.790 (90)	0.653
専門 GPA6	0.556 (88)	0.424	0.550 (89)	0.420
専門 GPA7	0.734 (92)	0.642	0.712 (75)	0.613
非スト卒業	0.484 (81)	0.323	0.457 (80)	0.283

ゴリズムの違いは目的変数による違いほど大きくはなかった. いずれのアルゴリズムも, 通算 GPA については非常に高い予測性能を示している一方, 専門 GPA についてはこれより予測性能が劣り, とくに「専門 GPA6」は比較的予測が困難であることがわかる. 非ストレート卒業の予測はこれらよりさらに難しい. さらに図 4~6 から遺伝的アルゴリズムによる予測性能の変化のようすをみると, 通算 GPA は最初から高い予測性能を示している一方, 専門 GPA6 や非ストレート卒業は世代を追うごとに予測性能が改善しているようすがわかることから, 予測が難しい目的変数ほど最適な説明変数の組合せを探索することの重要性が高いことが示唆される. なお, 専門 GPA6 を除く専門 GPA に関する F 値の推移の図については, 通算 GPA と同様に初期の世代から予測性能があまり変化していないため, 本稿では割愛した.

説明変数の選択の効果を示すものとして, 最終世代の最良個体の F 値と, 全説明変数を使用した場合の F 値の比較を表 2 に示す. いずれの目的変数についても, すべての説明変数を用いる場合よりも最良個体の予測性能は高い. また, 172 ある説明変数に対し, 選択された変数は 75~93 と

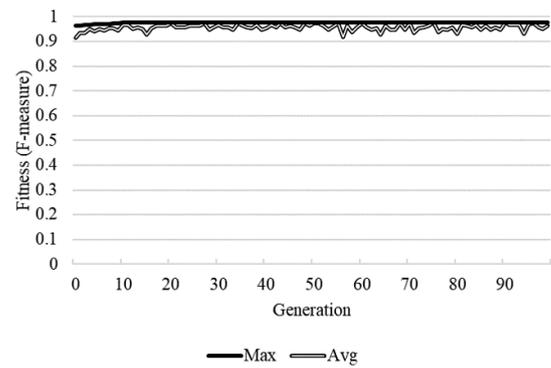


図 4 集団中の最良個体の F 値および全個体の F 値の平均値の推移 (目的変数: 通算 GPA)

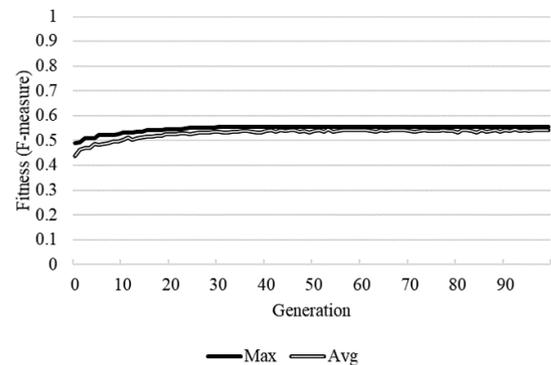


図 5 集団中の最良個体の F 値および全個体の F 値の平均値の推移 (目的変数: 専門 GPA6)

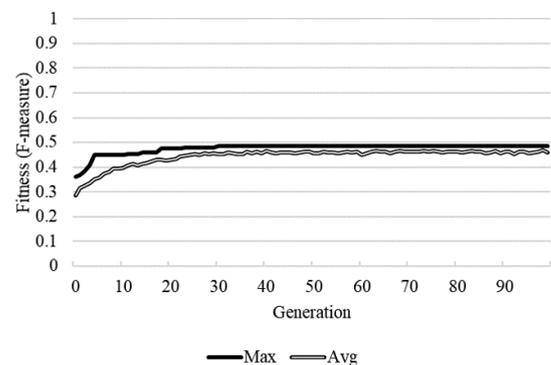


図 6 集団中の最良個体の F 値および全個体の F 値の平均値の推移 (目的変数: 非ストレート卒業)

半数近くになっており, 可解釈性を高めつつ予測精度を上げることができていると考えられる.

5.3 今後の課題

今回の実験では, 機械学習アルゴリズムのパラメータは scikit-learn パッケージにおけるデフォルトの値を用いているため, より適当なパラメータ設定により予測性能をさらに向上させることができる可能性が高い. 機械学習パラメータの最適化にはさまざまな方法があるが, ひとつの方法として, これらのパラメータを含めて遺伝的アルゴリズ

ムで最適化するというアプローチも考えられる。

また、今回は遺伝的アルゴリズムの適合度として F 値を使用した。先述のように F 値は Precision と Recall のトレードオフを考慮した値である。教学 IR での実践を念頭に置いた場合、Precision が高い、すなわち「予測したものが外れない」ということと、Recall が高い、すなわち「本来見つけたいものが見つけられる」ということのどちらが望ましいかはケースバイケースであると考えられる。さらには、今回は適合度に F 値のみを用いたため、説明変数の数を少なくする（よりシンプルなモデルにする）方向への淘汰圧はかかっておらず、あくまで結果的に変数が少なくなったにすぎないが、本来は説明変数をなるべく少なくすることは陽に求めるべきものと考えられる。そこで、予測モデルの構築を Precision, Recall, 説明変数の数についての多目的最適化問題と捉え、多目的進化計算によってパレート解集合を求めるというアプローチが考えられる。

今後の課題として、これらのアプローチについて検討したいと考えている。

6. おわりに

本稿では、大学や学位プログラムごとに異なる AS を念頭に、幅広い AS のための指導や学習支援を補助するシステムの要素技術として、教学 IR データを用いた AS の予測モデリングの汎用的枠組みについて提案した。

本研究では、遺伝的アルゴリズムにより、AS の度合いの予測のために重要な説明変数を教学 IR データから自動的に選択し、機械学習によって AS の度合いを高精度で予測するアプローチをとった。実際の教学 IR データを用いた数値実験から、想定する AS について指標を設定することができれば予測モデルの構築は可能だが、指標により予測の難しさが大きく異なることが見出され、また変数選択が予測性能の向上に有効であることが示唆された。

今後は、5.3 に述べたような多目的最適化のアプローチについて検討するとともに、本手法を実装した AS のための学生指導・支援補助システムの開発を行い、AS 予測モデルに基づく学生指導・支援の有用性について検証したい。

謝辞 本研究の一部は JSPS 科研費 JP17H01998 および JP16K16331、ならびに JP16H03082 の助成を受けた。

参考文献

- [1] 中央教育審議会：学士課程教育の構築に向けて（答申）（2008）。
- [2] Hayashi Y., Watanabe Y., Matsukawa H., Matsuda T., Tsubakimoto M., Tateishi S., and Yamashita H.: Development of SVM based Risk Detector for Retention of University Students, *Proceedings of the 15th Annual Hawaii International Conference on Education*, pp.31 (2017).
- [3] 松田岳士, 林祐司, 渡辺雄貴, 松河秀哉, 立石慎治, 椿本弥

- 生, 山下英明：学生指導を目的とした IR システムの開発と形成的評価, 日本教育工学会第 33 回全国大会講演論文集, pp.599-600 (2017).
- [4] 松田岳士：教学 IR の役割と実践事例, 教育システム情報学会誌, Vol.31, No.1, pp.19-27 (2014).
- [5] 緒方広明：ラーニングアナリティクスの研究動向—エビデンスに基づく教育の実現に向けて—, 情報処理, Vol.59, No.9, pp.796-799 (2018).
- [6] 船守美穂：デジタル技術は高等教育のマス化問題を救えるか?—MOOCs, 教育のビッグデータ, 教学 IR の模索, 情報知識学会誌, Vol.24, No.4, pp.424-436 (2014).
- [7] 山川修：組織を越えた Learning Analytics の可能性—その批判的検討—, コンピュータ&エデュケーション, Vol.38, pp.55-61 (2015).
- [8] Parnell, A., Jones, D., Wesaw, A., and Brooks, D. C.: Institutions' Use of Data and Analytics for Student Success, EDUCAUSE Center for Analysis and Research (2018).
- [9] Herman, J. (Ed.) and Hilton, M. (Ed.): Supporting Students' College Success: The Role of Assessment of Intrapersonal and Interpersonal Competencies, National Academies Press (2017).
- [10] Rice, G. A. and Russell, A. B.: Refocusing Student Success: Toward a Comprehensive Model, *The Handbook of Institutional Research (Chapter 14)*, pp. 237-255 (2012).
- [11] Brooks, C. and Thompson, C.: Predictive Modelling in Teaching and Learning, *Handbook of Learning Analytics*, pp. 61-68 (2017).
- [12] 雨森聡, 松田岳士, 森朋子：教学 IR の一方略：島根大学の事例を用いて, 京都大学高等教育研究, Vol. 18, pp.1-10 (2012).
- [13] 大友愛子, 岩山豊, 毛利隆夫：学内データの活用～大学における IR (Institutional Research) への取り組み～, FUJITSU, Vol.65, No.3, pp.41-47 (2014).
- [14] 畠田敏行：留年してしまう学生の効率的・効果的な検出方法についての検討, 大学評価と IR, Vol. 4, pp.18-25 (2015).
- [15] 藤原宏司：学業を中断する学生の予測モデル構築について, 大学評価と IR, Vol. 5, pp.8-22 (2016).
- [16] 竹橋洋毅, 藤田敦, 杉本雅彦, 藤本昌樹, 近藤俊明：退学者予測における GPA と欠席率の貢献度, 大学評価と IR, Vol. 5, pp.28-35 (2016).
- [17] 近藤伸彦, 畠中利治：学士課程における大規模データに基づく学修状態のモデル化, 教育システム情報学会誌, Vol.33, No.2, pp.94-103 (2016).
- [18] Bäck, T.: *Evolutionary Computation*, Oxford Press (1996).
- [19] Goldberg, D. E.: *Genetic Algorithms in Search, Optimization & Machine Learning*, Addison-Wesley Publishing Company (1989).
- [20] scikit-learn: Machine Learning in Python (online), [<https://scikit-learn.org/stable/>] (2019.02.26 参照).
- [21] DEAP Project: DEAP documentation (online), [<https://deap.readthedocs.io/en/master/>] (2019.02.26 参照).