

〈報告〉

本学の教学 IR 要件定義に向けた予備調査・試行

明神 知* 穴田有一† 中島 潤‡ 甫喜本司§ 齋藤健司**

Preliminary Study for Defining HIU IR Requirements for Teaching and Learning

Satoru MYOJIN* Yuichi ANADA† Jun NAKAJIMA‡ Tsukasa HOKIMOTO§ Kenji SAITO**

要旨

教学 IR システム構築に向けて、システムアーキテクチャおよび教学データの所在とデータ形式・アクセス可能性を調査研究した。統計分析モデル、機械学習モデルの初年度からの学修データ分析により、比較的高い精度で4年卒業を予測できた。さらに入学前教育のデータや POLITE3 に蓄積された学修データから学生の特性データを分析することにより、学生の早期個別支援で教育の質を向上し、退学率改善につながる可能性がある。

Abstract

This study looks at the system architecture of enrollment management, together with accessibility to educational data and student data at Hokkaido Information University. In order to visualize educational intelligence, a statistical-analysis model and a machine-learning model were created experimentally based on the analysis of educational data. We found that students who will graduate in four years can be estimated with high accuracy by analyzing educational data from a partial section of students. In addition to the two models, we found that quality of education and prevention of dropping out of university can be improved through individual guidance and coaching for each student in the early stages of enrollment with the characteristics visualized from the data of pre-enrollment education and POLITE3.

キーワード

教学 IR システム(Academic IR System) 教学 IR データ(Academic IR Data) データアナリシス(Data Analysis) 機械学習(Machine Learning) 情報連携基盤(Information Integration Platform) X-ROAD

* 北海道情報大学経営情報学部先端経営学科教授, Professor, Department of Business and Information Systems (Dept. of BIS.), HIU

† 北海道情報大学経営情報学部先端経営学科教授, Professor, Dept. of BIS., HIU

‡ 北海道情報大学経営情報学部システム情報学科教授, Professor, Department of Systems and Informatics, HIU

§ 北海道情報大学情報メディア学部情報メディア学科教授, Professor, Department of Information Media (Dept. of IM.), HIU

** 北海道情報大学情報メディア学部情報メディア学科准教授, Associate Professor, Dept. of IM., HIU

1. はじめに

大学が教育目的を達成するための管理運営を教学マネジメントというが、これを支える基盤として教育関連データを収集、分析して管理運営を支援することが教学 IR の役割である。さらに付言するならば、教学 IR が提供する情報には、大学の教育戦略を構築するためのマクロ情報と、日常的な教育活動に必須のマイクロ情報がある。このマイクロ情報は、教育を改善し質を高めるための FD・SD 活動に必須のものであり、教学 IR と FD・SD は相補的な関係にある。これらを踏まえたうえで教学 IR の本格的な整備の前段階の「教学 IR システム予備調査」として以下の内容を調査、検証した。①教学関連データの調査 ②教学データ分析法の検討 ③教学 IR システムアーキテクチャの検討 ④教学 IR システム情報連携基盤の検討 ⑤教学 IR システム主要機能のプロトタイプ試行 (X-ROAD 検証, 教学データ・エクスポート, 学習データの時系列統計分析, 機械学習による予測) ⑥学習データ分析試行からの教育の質保証に向けた教育介入の検討

2. 現状 (問題点)

本学の教学 IR 関連データの蓄積については、日々の大学業務の遂行のために、その時々調達できる技術を使って随時、個々にシステムが構築されてきた。そのために、CANVAS, CAMPUS, e アシーナ, Web ポータル等のサーバが独立に構築されてきた。一方では、担当職員の PC, 書類に分散している場合もあり、その形式も多様であった (図 1)。その原因は、各部署からの要求に応じて、担当職員が分散し、多様なデータを主に手作業で収集して形式を整えて提示するか、

担当者の PC に、Excel, Word 等のアプリケーションを利用して個別に蓄積してきたことにある。

さらに、システム更新時に古いデータが消去されたり、保存期間が担当者任せになっているために、既に消失したものもある。

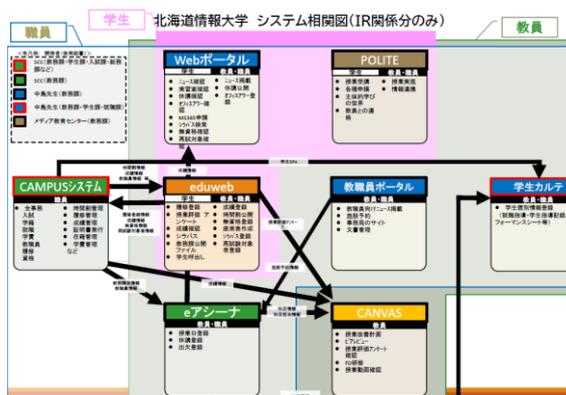


図 1 IR 関連システム関連図

3. 解決の方向性 (先行事例)

教学 IR で先行する海外に対して、国内の事例も多く報告されている。その内容は Excel 活用の簡易型から、本格的データウェアハウス、さらにはクラウド型データベースに登録してベンチマーク活用ができる大学 IR コンソーシアムなどもある。クラウドサービスは暗号化やアクセスログの管理など情報セキュリティ上の配慮が可能で無料もしくは安価で利用可能な Google Cloud や BI では Tableau などが多用されている。参考文献から、以下のような事項を踏まえて予備調査を実施した。

- ・4年次の成績や退学は1年次の前期や1年修了時といった早い時期までのデータだけでも高い精度で予測できる (川崎昌 2021)
- ・機械学習の中でもランダムフォレストが比較的予測精度が高い (川崎昌 2021; 近藤伸彦 2016)

さらに以下の事例が教学 IR の将来構想において参考になる。

・POLITE3 データの活用などデータ量が巨大化，リアルタイム化するような場合はクラウドサービスの利用が現実的 (Glenn Lopez 2017;大阪ガス 2020)

・教学 IR には多様なスキルが必要であり，複数メンバーの協働が必要なことから分権型の IR システムの考え方が参考になる (北陸大学 2021)

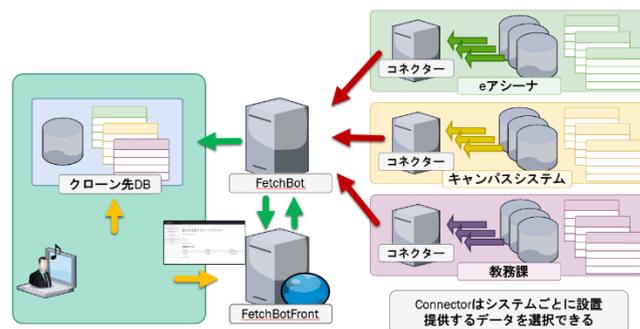


図2 コネクタを使ったシステム間連携の提案

4. 実施内容

4-1 情報連携基盤のありかた

エストニア電子政府の情報連携基盤である「X-Road」(日立コンサルティング 2018)を，民間向けにオープンソースとして公開・配布されている「Planet Cross」を利用し，機能確認を行った。その結果，本学の複数のシステムに多様な形式で実装されている教学関連データの中から，IR 用データとして収集・蓄積するために，既存の学内システムへの接続，形式変換機能を実現するための一手法として，Planet Cross の「Connector Server」(Planetway 2020) の機能 (情報資産の発掘，システム間連携) が参考になることが明らかになった。

Connector からデータを自動取得し手元のデータベースに登録するライブラリ (FetchBot) とデータの同期を定期実行し Web ページで Connector の接続先の登録等ができる Web アプリケーション (FetchBotFront) を開発し動作を確認した (図 2)。さらに外部組織との間でデータ連携を行うには，Security Server の機能を利用して DB 間のデータ伝送の安全性を高めることが可能であることを確認した。

4-1-1 分析データ

分析は 2 年時から 3 年時への進級要件単位数制限が廃止された後の 2017 年度に入学した学生 332 名 (2020 年度卒業・翌年度卒業見込みとなる学生 250 名，および退学・除籍となった学生 82 名から構成) を対象とした。修学状況を測る基礎データとして，学内や外部から以下のものを収集した。

- ・ GPA (Grade Point Average)
- ・ 修得済み単位数
- ・ 講義の欠席率 (学期の前半，後半で計算)
- ・ 入試区分 (AO・学校推薦・一般入試・センター利用)
- ・ 高校での成績
- ・ 高校の偏差値 (トライ教育情報センター。通信制高校については偏差値の考え方がないため，分析に使用した全データの平均値を用いた)
- ・ 入学直後に実施した習熟度調査の得点

4-1-2 分析方法

一般的に学生の修学状況は入学直後が良く，学期の進行と共に徐々に悪くなる傾向がある。

本研究では 1 年次と 2 年次の期間に焦点をあて，上記のデータに基づく総合的な修学状況を測る指標を統計的な主成分 (principal component) として定義したとき，この分布が学期の経過と共にどのように変化するかを調べた。具体的には，前期前半，前期後半，後期前半，後期後半の 4 期を単位としたとき

の主成分分布の学期進行に伴う変化について、卒業者と退学者の双方の観点から調査を行った。

前節で示した基礎データに基づいて以下の変量を定義し、修学状況を評価するための主成分を推定した。

V1 : GPA

V2 : 修得済単位数

V3 : 平均欠席率 (直近 2 期でより大きい値)

V4 : 高校偏差値

V5 : 高校内の平均評定値

V6 : 入学直後に実施した習熟度調査の結果 (数学)

まず、1 年次の前期後半 (第 2 期) の終了時点における 6 変量のデータより分散共分散行列の固有値を求め、主成分を推定した。第 1 主成分については全変動の約 35 パーセント、第 2 主成分については全変動の約 20 パーセントが説明でき、それぞれ以下のように推定された。

第 1 主成分 =

$$0.53 \times V1 + 0.40 \times V2 - 0.46 \times V3 - 0.04 \times V4 + 0.37 \times V5 + 0.19 \times V6$$

第 2 主成分 =

$$0.15 \times V1 + 0.08 \times V2 + 0.23 \times V3 + 0.72 \times V4 - 0.18 \times V5 + 0.60 \times V6$$

係数の絶対値が大きい変数に着目して、これらの主成分が何を意味するかを検討した。

第 1 主成分については、入学後の修学活動の成果にあたる GPA (V1) や修得済単位数 (V2) の値が大きくなるほど大きな正の影響を与え、平均欠席率 (V3) の値が大きくなるほど大きな負の影響を与える。このことから、入学後の修学状況が順調なほど正の大きな値を示す指標となる。第 2 主成分については、高校入学時の偏差値 (V4) や入学時に実施された習熟度調査の結果 (V6) の値が大きくなるほど大きな正の影響を与える。従って、入学前の学力が高いほど正の大きな値をとる指標

であることがわかる。

4-1-3 学生の修学状況に関する知見

前節で定義された第 1 主成分と第 2 主成分を導入して行った分析を通して得られた知見のいくつかについて報告する。

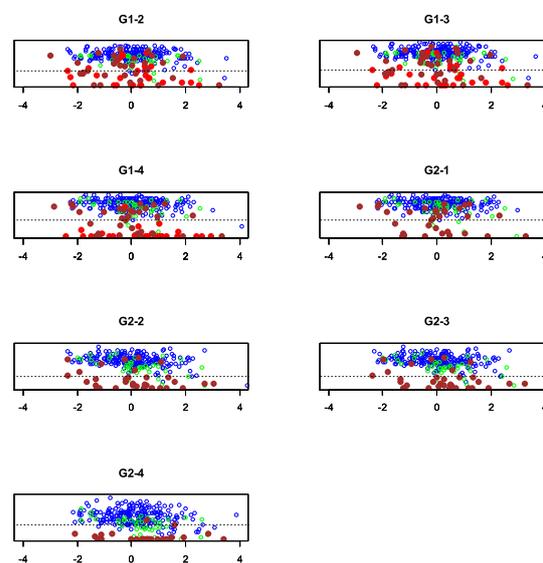


図 3 第 2 主成分得点と修得単位数

(A)1 年次の前期後半 (G1-2) から 2 年次の後期後半 (G2-4) までの連続する 7 期において、「入学前の学力」を評価した第 2 主成分と修得済単位数との 2 次元分布の変化を図 3 に示す。ここで、横軸は第 2 主成分得点、縦軸は修得済単位数である。

また、青色の点は卒業生、緑色の点は翌年度卒業見込み者、赤色と茶色はそれぞれ 1 年次、2 年次に退学、あるいは除籍となった学生を示す。

2 次元分布の下方にプロットされているデータは修得済単位数が少ない学生を意味する。そのほとんどは赤色、あるいは茶色で示されており、2 年次までに退学や除籍となった学生である。

これらのデータは、第 2 主成分得点に関して正負の範囲にわたって広く分布している。第 2 主成分の値は、高校偏差値が高くなるほど大きな正の値をとることから、負の値は偏差値の高い高校を出た学生が入学後に成績不良となって

いと解釈される。従って、図3の結果は偏差値の高い高校の出身者が入学後も優等な成績を収めているとは限らない可能性を示唆している。

(B)次に「入学後の修学状況」を測る第1主成分の学期進行に伴う変化について調べた。

ここで1年生の後期後半、2年生の前期後半、および2年生の後期後半の3期において、前期との第1主成分得点に関する差(階差)を変量として導入する。

上記の階差とGPAに関する前学期からの増加率との間で2次元プロットを行い、その傾向を線形回帰モデルで推定した結果を図4に示す。いずれの学期においても、両者の間には線形とみなせる増加傾向がある。GPAの増加率は、前学期からGPAの測定値がどの程度向上したかを測るもので、修学に関するモチベーションを測る指標の一つとみなせる。図4の結果より、第1主成分得点の階差も修学意欲を測る指標と解釈できることがわかる。すなわち、第1主成分得点の階差の値が正の大きな値となるほどGPAの増分も増加するため、修学意欲が高くなると評価される。

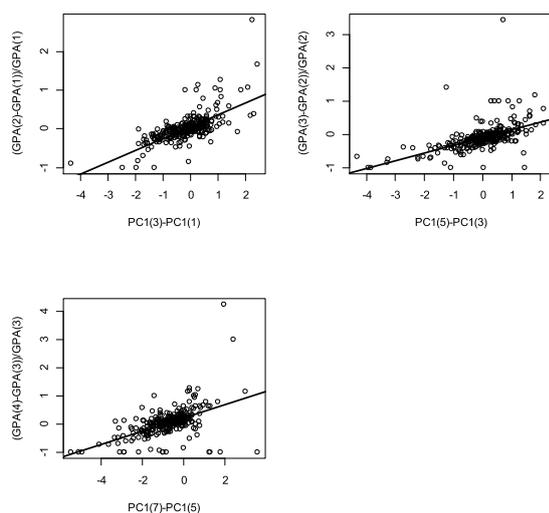


図4 第1主成分得点の階差とGPAの増加率の関係

上記で定義した第1主成分得点の階差の値に基づいて、GPAが公表された翌期に修学状況の変化があるかどうかを調べた。1年前期から1年

後期の階差の値を横軸、1年後期から2年前期の階差の値を縦軸にとってプロットした結果を図5に示す。ある程度線形的とみなせる減少傾向が観察される。この傾向を相関係数で測った結果は-0.21であった。1年後期から2年前期と2年前期から2年後期との間の関係には図6に示されるように、より線形的な減少傾向があらわれる。実際、このケースの相関係数は-0.34である。こうして、当学期の成績が良くても、より良い成績を目指していこうという意欲のある学生は傾向としてはあらわれないことがわかる。

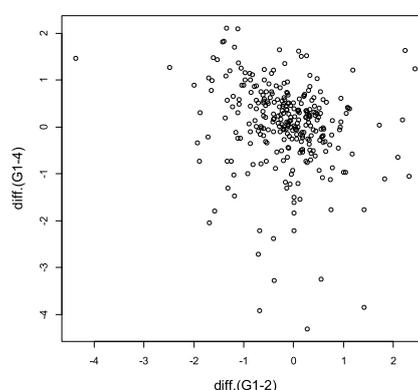


図5 第1主成分の階差の変化(1年前期～1年後期)

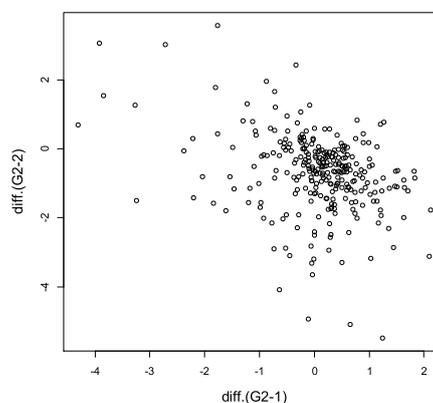


図6 第1主成分の階差の変化(2年前期～2年後期)

(C)第1主成分と修得済単位数に関する2次元分布について、(A)と同様に描いた結果を図7に示す(横軸は第1主成分得点、縦軸は修得済単位数)。「入学後の学力」を測る第1主成分得点は、負の小さな値をとるほど修学状況が悪いと評価される。

1年次前期後半(G1-2)の時期から、負の極端

に小さな値をとる学生が既に一定数存在する。

これらの多くは赤、あるいは茶色の点として示されており、2年次までに退学や除籍となった学生である。

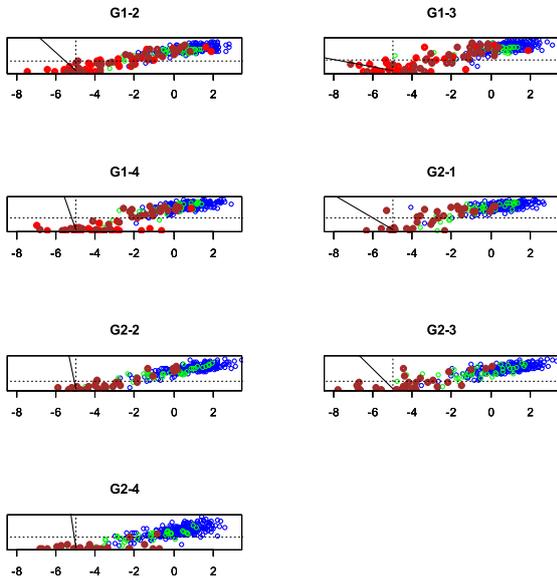


図7 第1主成分得点と修得単位数の関係

(D)第1主成分と第2主成分に関する2次元分布に基づいて、「修学が順調に進んでいることを評価するための信頼区間」を推定する方法についても検討した。2つの主成分は互いに直交するように推定される。無相関な2次元分布の信頼区間は楕円(軸がx軸、あるいはy軸と平行となるもの)になると考えられる。

そこで、4年間で卒業した学生の2次元分布から第1主成分(PC_1)と第2主成分(PC_2)に関する各周辺分布をみて、その平均を標本平均 \bar{x} , \bar{y} , 標準偏差を標本分散の平方根 S_x , S_y とするとき、以下で与えられる楕円の式を用いて推定を行った。

$$\frac{(PC_1 - \bar{x})^2}{(3S_x)^2} + \frac{(PC_2 - \bar{y})^2}{(3S_y)^2} = 1$$

1年次前期後半から後期後半までの連続する3期、および2年次前期後半から後期後半までの3期における推定結果を図8と図9にそれぞれ示す。点線で示される区間の内部を信頼区間と定義し、この区間の内部にプロットされる学生は

その学期において修学が順調に行われたと評価する。この区間から横軸の負の方へ外れていくほど修学状況は悪いと評価され、ケアが必要な対象となる。ただし、推定された区間の内部にプロットされる学生がある学期から円外へ移動する可能性もあることに注意が必要である。

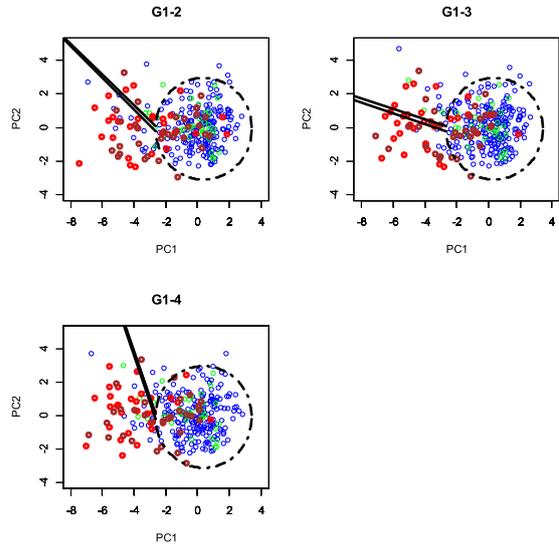


図8 主成分得点の2次元分布(1年2期~1年4期)

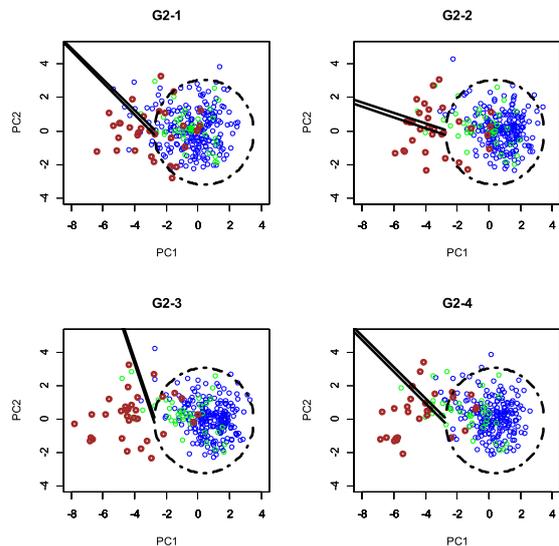


図9 主成分得点分布の2次元分布(2年1期~2年4期)

4-1-4 考察

分析結果を通して得られた主な所見は以下の通りである。

(A) 第1主成分得点に関する前学期からの階

差は、学期の経過と共に増加と減少を繰り返しており、成績を計画的に向上させようという強い向学意欲は認められないことを示した。

学生の向学心を高めるためのカリキュラム計画や講義内容のさらなる工夫が望まれる。

(B) 図 7 に示されるように、入学後の早い時期から第 1 主成分が負の極端に小さな値をとる学生は、退学の予備軍として対応していく必要がある。

(C) 図 8 や図 9 において緑色でプロットされている点を見ると、4 年後も在籍している学生の中には、学習状況の観点からは退学者と同様な状況とみなされる学生が一定数存在する。

こうした学生に関するケアも欠かすことができない。

(D) 学生が退学する状況を 0 と 1 で表した 2 値データについて、第 1 主成分と第 2 主成分を説明変数とした非線形なロジットモデルで推定して外挿による予測実験を行った結果、1 年生の前期終了時点で 1 年末の退学を 9 割の精度で予測できることがわかった。

退学の前兆のある学生をできるだけ早く見出すために、学内で計測される基礎データのモデル化に基づく予測情報を参考にすることは意義のあることといえる。この予測の精度をより高いものにするためにも、平素の学習に関するアクティビティを積極的にデータ化していくことの必要性が高まっている。

4-2 機械学習

近年では様々な分野で機械学習による情報処理が活用され成果をあげているが、教学 IR の分野でも機械学習の活用の実績があり有用な成果をあげている(川崎昌 2021;近藤伸彦 2016)。本学の教学 IR においても機械学習の手法の導入を検討するためにニューラルネットワーク、ランダムフォレスト、ベイジアンネットワークの 3 つの手法についてシミュレ

ーションを行い、その予測精度などについて検証を行った。

それぞれの実験で学習に用いたデータは、2017 年度に本学に入学した学生の 4 年間の GPA と取得単位である。用意することができたのは 367 名分のデータで、GPA と取得単位は前期、後期で集計されているので、1 人の学生に関する成績データは 16 個の数値となる。

これに加えて、該当する学生が 4 年間で卒業したかどうかのデータが加わる。ニューラルネットワークとランダムフォレストの実験では用意したデータの中からランダムに抽出した 70%を学習用として用い、残り 30%を予測精度の測定のために使用した。

4-2-1 ニューラルネットワーク

本研究では、学生の様々な状態を表すデータから、その学生が退学する可能性が高いか、4 年間で卒業するかを予測することを一つの目標としているが、これは学生の集合を 2 つのクラスに分類するクラスタリングの問題と考えられる。このクラスタリングの問題をニューラルネットワークを用いて処理することを試みた。また、本研究では機械学習とは別に、統計的な手法でも同じクラスタリング問題を扱うが、この 2 つの手法を比較する上で統計的手法で非線形な当てはめを行うために使用する関数と、ニューラルネットワークの活性化関数を同じシグモイド関数として実験を行った。

学生の成績データ 16 個を入力層のユニットに入力し、4 年で卒業したかどうかをカテゴリ分けするために 2 つのユニットを出力層に用意した。今回の実験ではデータ量が多くないこともあり、過学習になることを避けることに注意して学習パラメータを設定した。

中間層のユニット数は 10 とし、バッチサイズ 16、損失関数はバイナリクロスエントロピー、学習エポック 500、最適化法 SGD(確率的

勾配降下法),出力層の活性化関数はクラスタリングに用いているのでソフトマックス関数,中間層の活性化関数は前述した理由でシグモイド関数を採用した。

学習したニューラルネットワークの退学予測精度は,学習するごとに変動するが 91%から 92%ほどになることが多かった。最大で92.79の予測精度だった。学習に要する時間は20秒ほどである。使用したプログラムは Python の機械学習のライブラリである Tensorflow に含まれる Keras である。

4-2-2 ランダムフォレスト

教学IRの先行研究において,ランダムフォレストを使用することで,他の機械学習より良い予測精度を達成しており,本研究でも実験を試みた。

ランダムフォレストは複数の決定木の判定結果の多数決により最終的な判定結果を決定する機械学習アルゴリズムである。決定木は図10に示されるような木構造のモデルで表わされる。図の例では,性別,友達の数,GPA,暮している場所,出席率が木の節点に書かれており説明変数に対応している。木のルートである性別の節点から説明変数の値に従い木の枝をたどる事により,木の葉までたどりつくと退学の危険が高いか低いかの判定が出るようになっている。

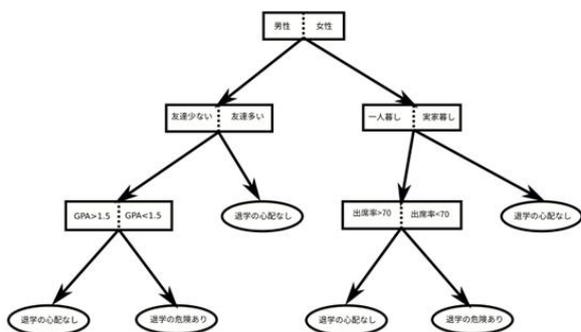


図 10 決定木

しかし 1 つの単純な決定木では説明変数の

データに対する分解能が低くなってしまふなどの欠点があるため,複数の決定木を作りこれらの木の予測結果を集計して,最も多かった予測結果を最終的な予測結果として出力するように改良したアルゴリズムがランダムフォレストである。図 11 にランダムフォレストの概要を示す。

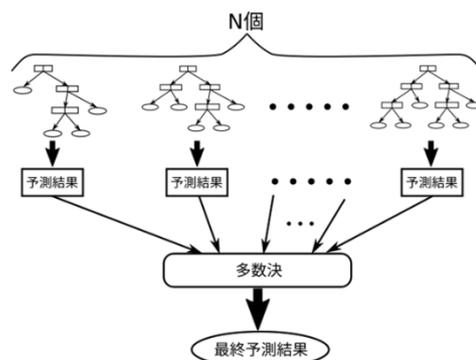


図 11 ランダムフォレスト

ランダムフォレストの実験では,簡単のために学生の成績データを二値化する処理を行った。二値化する時の閾値はデータの中央値を使った。使用したプログラムは Python の機械学習ライブラリ scikit-learn に含まれる RandomForestClassifier である。学習パラメータとして,ランダムフォレストに含まれる木の本数を 100 とし,木の深さを 5 としている。

学習はほぼ一瞬で終了し,退学の予測精度は 93.69%と高い結果が得られた。予測のためのデータが二値化されて情報が落ちていることを考えると非常に良い結果であると考えられる。

4-2-3 ベイジアンネットワーク

ベイジアンネットワークは因果関係を確率変数を節点とする有向グラフにより表現する確率モデルである(図 12)。図中に示されているように,各確率変数は対応する条件付き確率分布を持ち,その確率変数に影響を及ぼす他の確率変数の値により異なる確率分布を持つことができるようになっている。

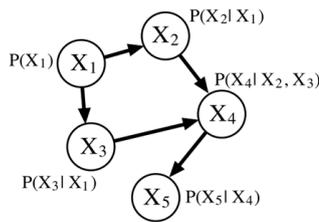


図 12 Bayesian Network

ベイジアンネットワークは、学習データからネットワークの構造を学習するアルゴリズムが提案されており、これにより様々な事項の因果関係をグラフィカルに図示することが可能である。このベイジアンネットワークについては、本研究では退学の予測ではなく、主に説明変数と目的変数間の因果関係を見るために実験を行なった。因果関係の再現を目的とするために367名の学期ごとのGPAと取得単位数のデータの全て使って学習を行なった。

ランダムフォレストと同様に、簡単のためにデータは二値化した。プログラムはJava言語で書かれた自作のプログラムである。因果関係を表現するベイジアンネットワークの構造を学習するためのアルゴリズムはシミュレーティドアニーリングであり、確率モデルの評価値として情報量基準のMDL(Minimum Description Length)を採用した。

シミュレーティドアニーリングのアルゴリズムでは温度勾配を調整するパラメータや停止条件の定数を指定する必要があるが、様々な値を試し最大で45分ほどの学習を行ったが、学習毎に毎回異なるグラフ構造が表われたため、学習は失敗していると判断した。失敗の理由は特定できないが、学習パラメータの調整不足や学習に用いた学期ごとのGPAと取得単位数のデータに因果関係に寄与する重要な項目が欠落していた可能性がある。

5. 教学IRシステム予備調査結果

教学IRシステムの定義とともに、先行事例を調査し、本学の現状と将来を見据えて教学

IRシステム予備調査結果を以下にまとめた。

- 教学IRシステムとは、「大学がその教育目的を達成するために行う管理運営」と定義される教学マネジメントを支援する情報システムである。
- 教学IRシステムの機能は、教学マネジメントに必要なデータを収集、蓄積、分析、報告を個人情報保護し、外部からの不正なアクセスや改ざんを防ぐ情報セキュリティの元に行う。
- 本学における教学IRの現状は、組織的には準備段階である。
- 関連するデータはキャンパスシステム(学園総合情報システム)、eアシーナ、Webポータル、担当職員のPC、書類に分散し、その形式も多様である。
- 教学マネジメントを教学IRシステムを使って実施するためのスキルはデータサイエンス職のエンジニア、アナリスト、サイエンティストといったITと分析の専門知識、大学の経営と意思決定、高等教育と本学の文化やポリシーなど多岐に渡るもので多くの部署の専門家の協働作業となる。
- 協働作業を支援する情報システムはクラウドサービスに代表される分権型IRのプラットフォームとなるが、教学IR組織の発展とともに成長させる段階的な開発が費用面でも現実的である。
- 開発ステップは企業におけるデータウェアハウスの発展段階を参考にすると、当面必要な分析に絞った目的別にCSVを提供するデータマートから始めて、多様なデータをデータレイクに蓄積して用途を広げ、クラウドサービスでデータの共有とETL(前処理)やTableauといったBIツールで分権型IRプラットフォームとしていく。
- 留意点としては、多様なレベルの参加者

の協働作業は、そのスキル向上のための教育や支援が並行して必要となる。

6. 教学 IR システムの整備ステップ

本学の教学 IR 関連データの状況と先行事例から、以下のステップで段階的にシステムを整備する方法が有効と考える。

- (1)IR 用データ収集・蓄積システムの構築：
学内各種データリソースから Planet Cross の Connector Server 等の機能によって、必要なデータを定義して収集し、併せてセキュリティやプライバシーに配慮した方法によりデータを長期的に蓄積する
- (2)ファイル転送・前処理用の ETL や BI ツールの導入により、データ収集の自動化と分析環境を提供する
- (3)クラウド型の分権型アーキテクチャへ順次移行・整備する

7. 今後の課題

今後、さらに検討すべき事項を以下にあげる。

- (1)早期フィードバックの可能性
 - ・POLITE3 データ：POLITE3 には各科目の課題提出状況や評価、学生のアクセス項目、時間などの詳細な学習データが記録されている。また、セルフシートに学生が入力した振り返り文やテキスト提出課題等の膨大なテキストデータが蓄積されている。これらのデータをテキスト分析することで、学生のメタ認知特性を早期に把握して個別の学修指導やフィードバックが可能であることから、退学率改善のみならず学修の質向上の有効な手段となる可能性がある。
- (2)テキストデータの活用
 - ・2021 年度入学前教育から蓄積し始めた入学前の学習データとアンケート記述データ、および原則 3 年に一度実施している学生満足後調査データについて、量的統計分析や質的テ

キスト分析を行うことにより、上記と同様な個別学習指導の有益な情報が得られる可能性がある。

- ・紙ベース資料：退学者の所見が学生サポートセンターに保管されている。全てが有用なデータとは限らないがテキストマイニングや感情分析等によって抽出して詳細な分析をすれば有効な改善点を見出す可能性がある。
- ・e ポートフォリオ：POLITE3 に蓄積されている学生の学修成果物や振り返り文や 2021 年度から入学前教育で試行されている日誌等を学生の学修ポートフォリオとして活用し、学生自身の気づきや振り返りを促すことで、学生自身が自己の有用な改善点を見出す教育へ移行する可能性がある。

8. おわりに

教学 IR が提供する教学マネジメントへの価値にはマクロ IR とマイクロ IR による教育戦略と教育戦術上の価値がある。さらに教学データ間の関係には相関関係と因果関係がある。これらを整理し、教学マネジメント上の問題解決に必要な問題原因にフォーカスした教育指導アプローチを検討したい。その手法としては本研究で端緒を捉えた教学マネジメントにおけるデータ解析、機械学習による相関関係に加えてシステム思考による因果モデルの仮説検証により学生に寄り添ったデザイン思考アプローチの指導を提案したいと考えている。

謝辞

本研究にあたって協力頂いたメディア教育センターの前田真人氏、データ収集に尽力いただいた教務課、入試課、学生サポートセンターの皆様に深謝します。

参考文献

- 川崎昌(2021) 「機械学習による GPA 予測を用いた e ポートフォリオ活用の試み」
2021 年私情協教育イノベーション大会。
- 近藤伸彦(2016) 「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』
Vol33.No2, 2016。
- Glenn Lopez(2017) Google BigQuery for Education: Framework for Parsing and Analyzing edX MOOC Data, Proceedings of the Fourth (2017) ACM Conference on Learning。
- 大阪ガス(2020) 「IoT データ分析基盤や新たなアプリサービスを支えるプラットフォーム」
<https://www.sbbi.jp/document/Item/16761>(2022 年 5 月 27 日アクセス)。
- 北陸大学 (2021) 「クラウドを活用した IR プラットフォームの構築と運用」
<https://ir-info.hokuriku-u.ac.jp/symposium>(2022 年 5 月 22 日アクセス)。
- Planetway (2020) 「Connector 設定ガイド」
https://planetway.com/63bfab39a4bf1418fc33382709762200/Connector%E8%A8%AD%E5%AE%9A%E3%82%AC%E3%82%A4%E3%83%89_v1.4.pdf(2022 年 5 月 30 日アクセス)。
- 日立コンサルティング(2018) 「平成 30 年度経済産業省デジタルプラットフォーム構築事業(官民におけるデータ交換基盤の構築に向けた調査等事業)報告書」
https://www.meti.go.jp/meti_lib/report/H30FY/000281.pdf(2022 年 6 月 1 日アクセス)。