

第2章

はじめに

本調査における回答率は、第1章で示したように、必ずしも高いとはいえない。その結果、全体の約30%の範囲しか説明できていない。一方で、回答者の傾向については、成績特にGPAとの関連性が示されてきた。GPAが高い学生は回答し、逆に低い学生は回答しないという傾向である。これら背景から、GPA等の変数を用いて欠損値の補完を行い、補完前後でどのような違いが見られるかを検証した。またそのための手法が妥当な範囲で運用できているか、その評価を行った。

対象のデータおよび手法

欠損値の補完に用いる説明変数の探索

解析の対象は、1年生から4年生までの学生に共通するQ1からQ4までの計52項目とした。そして52項目の回答結果を目的変数とし、それに強い影響を持つ説明変数を探索するため、ランダムフォレスト分類を行った。説明変数には入学年度、所属学部、所属学科、性別区分、入試区分、高校評定平均、高校コード、出身都道府県、高等学校ランク等の属性に関する9つの変数と、GPA、成績区分（秀・優・良・可・不可、認定、合格、保留、履修取消）の数、単位数の合計、得点の合計、総修得単位の31の変数を用い、合計で40の変数を設定した。

高等学校のランクについては、高校生の進学事情に詳しいA社の作成する高校ランクを使用し、ランクの設定がされていないものには、便宜的に特定の数値を代入した。また、高校の評定平均値が欠損しているデータに対しては、学年と学科をグループとし、その平均値を欠損値に代入した。

カテゴリカルデータに関しては、ラベルエンコーディングを施した。高校コードと出身都道府県はOne-Hotエンコーディングによりbool型に変換を行った。ランダムフォレスト分類の計算には、Pythonのscikit-learnライブラリ（バージョン1.4.1）を使用し、パラメータの設定については、木の数（n_estimator）は1000とし、その他はデフォルトとした。

52項目の質問に対する変数重要度を計算し、重要度の高い上位10件の変数を抽出した。これらの変数を、目的変数と強い関連性を持つと判断し、欠損データの予測精度を高めるために選出した。

抽出した説明変数

GPA, 高校ランク, 入学年度, 学年コード, 成績区分 1:SA(秀)の単位数合計, 成績区分 1:SA(秀)の得点合計, 成績区分 1:SA(秀)の数, 成績区分 2:A(優)の単位数合計, 成績区分 2:A(優)の得点合計, 成績区分 2:A(優)の数, 成績区分 3:B(良)の単位数合計, 成績区分 3:B(良)の得点合計, 成績区分 3:B(良)の数, 成績区分 4:C(可)の単位数合計, 成績区分 4:C(可)の得点合計, 成績区分 4:C(可)の数, 成績区分 5:D(不可)の単位数合計, 成績区分 5:D(不可)の得点合計, 成績区分 5:D(不可)の数, 所属2コード, 所属3コード, 総修得単位数, 高校評定平均

多重代入法の計算と欠損値補完

上記で抽出した変数を多重代入法による計算に組み込み、欠損値の補完を実施した。多重代入法は欠損データを扱う手法で、欠損値を複数の異なる値で補完し、それぞれの補完されたデータセットに対して解析を行い、その結果を統合する手法である。欠損がランダムに発生している場合に効果的に機能するとされているが、目的変数に影響を与える説明変数をモデルに組み込むことでバイアスを軽減し、信頼性の高い推論を行える。

今回、多重代入法の計算モデルには、ベ이지アンリッジ回帰を使用した。アンケートの回答は4件もしくは5件法による順序尺度で作られているため、補完された値は四捨五入を行い、整数値に置き換えた。

結果

図1から4までは、欠損値を補完した前後の分布を可視化したもので、値は回答を単純平均したものである。図1では、元のデータセットと似た分布を持っており、極端な誤差は含んでいないものと考えられる。もっとも大きく変動しているのは、「履修登録時には、自分の学科の4年間のカリキュラムをよく確認した」で、10パーセント程度の開きが見られる。

図2では、図1と同様に元のデータセットに沿った分布を維持しているが、多くの項目で補完後に高い値が示されている。図3は、項目ごとで、もとの分布を維持しているものと、大きくかわったものとで分かれた。Q03_IT03, IT07 から IT09 までは、補完後の値は小さくなっている。

図4では、ほとんどの項目で補完後の値は小さくなっており、もとのデータセットの分布から大きく形を変えている。

考察および妥当性の検証

図1から図4を視覚的に評価すると、学業に強く関連する質問項目においては、欠損値補完の前後で値は変化するが、補完前の分布を概ね保持していることが認められた。一方で、学業に關係のない質問項目については、大きく変動が認められた。

これらの結果をうけ、妥当な範囲で適用されているかどうか確認するため、5分割クロスバリデーションを実施し、RMSE (Root Mean Square Error) により評価を行うこととした。RMSE は値が小さければ、モデル誤差が小さいことを示している。

この結果、RMSE の値は Q01 で約 0.42、Q02 で約 0.49、Q03 で約 0.63、Q04 で約 0.70 であった。適切な評価はスケールを踏まえて個々の質問項目ごとに考える必要があるが、およそ Q03、Q04 では大きな誤差が見られたと評価できる。モデルに投入した変数は GPA 等の成績であるため、環境や学生生活全般を扱う質問項目に対し、予測精度が低くなるのは妥当だと考えられる。

結論

GPA 等の変数を使用した多重代入法モデルは、学業に関する質問項目への適用時には有効に認められた。また適用の結果、数パーセントから最大で 10 パーセント程度の範囲で分布の変化が認められた。しかし、環境や学生生活全般に関する質問項目に対しては、モデルは適切に機能せず、

顕著な誤差が認められた。これらの質問項目に対して欠損値の補完を検討する場合、適用する変数を見直し、モデルの改良を行う必要がある。

図1「Q01 あなたは、この1年間、どのような学び方をしてきましたか」の欠損値補完前後の分布

回答：“全くあてはまらない”から“とてもあてはまる”の4段階の順序尺度)




図2 「Q02 あなたは大学入学から現在までに、以下の知識・能力をどのくらい身に付けることができた実感していますか」の欠損値補完前後の分布

回答：回答は“全く身につかなかった”から“しっかり身についた”の5段階の順序尺度




図3「Q03 あなたは、この1年間の環境や学生生活にどの程度満足していますか」の欠損値補完前後の分布

回答：“全く満足していない”から“とても満足している”の4段階の順序尺度




図4 「Q04 あなたは、今年度の授業期間中、大学の授業やその他の学習などにどのくらい意欲的により組みましたか」の欠損値補完前後の分布

回答：“全く意欲的でなかった”から“とても意欲的だった”の4段階の順序尺度

