

ドロップアウト予測における感情推定手法の有効性について

天野 直紀*

The Effectiveness of Emotional Forecasting in Predicting Dropouts Based on Students' Writing on the Educational Support System

Naoki Amano*

Abstract: Universities are facing increasing demands to handle dropouts. Although signs of this are frequently ascertained in interviews, it is difficult to interview many students within a short period. To this end, various efforts are underway to predict the dropping out of students. In this study, we hypothesize that signs of dropping out manifest as emotional changes in the student, which, in turn, result in changes in the student's writing. Based on this hypothesis, we used Deep Learning and Decision Tree to forecast results. We used these results and the emotional forecasting results as learning data. The results of the experiment showed that while no changes were seen in the accuracy of forecasts, the proposed method could improve the number of early detections of dropout signs. These showed the effectiveness of estimating emotional forecasting results. Further, actual operation cases can be divided into cases in which the proposed method is suitable and ones where the conventional method is suitable, depending on the number of interviews that can be implemented.

Keywords : dropouts, predict, emotional forecasting

1. はじめに

教員にとって休退学者数の抑止・削減は重要なタスクとなっている。[1]によると高等教育機関での平成19年から24年の間に休退学者は14.0%から20.4%へと増加している。特に平成23年度の学校教育法施行規則等の一部改正[2]の施行後、このような休退学抑制の要請は高まっている。本論文では退学、除籍、留年、休学をひとまとめにドロップアウトと呼称する。

このようなドロップアウトを抑止・削減

するために、その兆候を予測することは重要である。もしも抑止・削減する何らかの手立てがあるとなれば(外的要素により、大学での指導では抑止・削減できないこともあり得る)、個別に面談などの対処を行うことでその具体的な要因を見出し、対処できる可能性がある。

このようなドロップアウトの兆候を把握する、すなわち予測することに関して、研究分野として Education Data Mining (EDM) がある。この分野中でドロップアウト予測

* 東京工科大学 工学部
School of Engineering
Tokyo University of Technology

を行う研究では対象データとして成績、学生の属性情報、入学前試験結果などを用い、機械学習の手法を用いて予測が行われている ([3]、[4])。機械学習手法としては Decision Tree、K-Means、Neural Network などの手法がよく用いられている。

著者は[5]において、成績と教育支援システムの利用履歴を対象データとし、Deep Learning を用いることで早期のドロップアウト予測を効果的に行えることを示した。具体的には、成績データの蓄積が少ないが教育支援システムの利用履歴であれば得られる早期（最初の 2 年間）について、教育支援の利用履歴を用いることで成績だけでは足りない情報を補い、既存手法よりも優れた精度で予測が可能であることを示した。この手法は基本的に学業成績に兆候が現れるという前提に基づいたものと考えられる。また、多くの成績を用いた先行研究も同様に考えられる。

2. 感情推定に基づいた予測提案

2.1. 学生の感情状態の推定

先行研究[5]に対して本論文では、学生の精神状態をより細やかに推し量ることができれば、面談を行ったのと同じような意味で、ドロップアウトの兆候を把握できるのではないかと考えた。学業上の理由だけでなく、様々なドロップアウトの要因が考えられるが、いずれの場合も要因発生・発覚からドロップアウトするまでには一定以上の時間を要していると考えられる。このように考えると、ドロップアウトの要因が発生したことで、学生の精神状態には変化が発生していると考えた。

面談を行えば、そのような精神状態の変

化を推し量れる可能性がある。しかし、例えば毎月のような短い間隔で多くの学生（全学生）との面談を行うことは現実的ではない。多くの学生との面談を実施するとすれば、必然的に面談スキルの低い教員が対応することや短時間での面談になると推定される。そのような面談で精神状態を正しく把握することはたいへん困難である。

そこで、本論文では学生の記述にドロップアウトにつながる精神状態の変化が反映されるのではないかと仮定した。記述内容に精神状態が反映されるという考え方は、例えば SNS 上における発言から感情を推し量る、といった研究[6]がなされている。このような手法であれば、学生が通常の学習過程で生成する文書があれば、自動的に変化を検出できることとなり、面談を行う人的なコストを大幅に削減できる。

本論文では、現実的にそのような記述を把握するため、教育支援システム上で提出される記述式の簡易レポート (TextArea への記述) に着目した。また、学生の感情状態を推定する手法として、単語感情極性対応表[7]を用いることとした。

学生の記述に出現する単語について単語感情極性対応表を用いて、ポジティブ、ネガティブな単語をどれぐらい用いているかとそれぞれの感情極性値の平均値を求めることとした。その集計を学生・月ごとに行い、ドロップアウトの予測を行うこととした。

2.2. 機械学習アルゴリズムの選定

EDM 分野において多くの事例で精度が高く、よく用いられている Decision Tree に対し、[5]では成績と教育支援システムの利用履歴を用いた予測において Deep

Learning が早期において、より優れた予測を行う傾向が見られた。このため、本稿でも Deep Learning と Decision Tree による予測結果を提示する。

いずれの処理も実用性を考慮して、容易に導入可能なプラットフォームとして R 言語 (Microsoft R Open, Version 3.3, [8]) を用いた。Deep Learning には H2O (パッケージ h2o 経由, [9]) を用いた。Decision Tree は rpart 関数を用いた。ここで、隠れ層の定義を 8 層、各入力パラメーター数を両端を 400、それ以外を 800 と設定し、activation 手法は TanhWithDropout とした。これらはある程度、後述の予測精度が確保できるところを簡易的に手動で求めた。それ以外の特化したチューニングは行わないこととした。

3. 評価実験結果

3.1. 評価項目と実験データ

提案手法の有効性を検証するに当たり、以下の二つを比較することとした。

- 成績 (GPA と取得単位数) のみによる予測
- 成績 + 感情推定結果による予測

ここでは 2 学期制とし、成績は 9 月、3 月に得られるものとした。したがって成績による予測は実際には年に 2 回だけ行うことができる。これに対し、成績 + 感情推定結果による予測では、毎月のレポートでの記述データがあるので、毎月、予測できる可能性があるが、比較を行うため、9、3 月に予測を行うものとした。

比較は予測精度と捕捉率、不要面談数によって行うこととした。

予測精度は次式に示す Accuracy を用い

て評価することとした ([3])。

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

ここで TP=True Positive, TN=True Negative, FP=False Positive, FN=False Negative である。面談等の必要性の有無と言う視点から 47 ヶ月の卒業を N、それ以外を P と考え、予測精度を上の式で求めることとした。

捕捉数はドロップアウト予測できた数である。これに対し、(ドロップアウトの兆候ありとした数 - 捕捉数)は不要だった面談の数 (以降、不要面談数) となり、これは人的コスト面での評価の指針となる。

実験には[5]と同じデータを用いることとした。これは本学で導入していた教育支援システムにおけるレポート提出データで、予測対象の年度のデータ (予測データ) とその前年度の入学生の 4 年間のデータ (教師データ) である。今回、対象となるデータ (学習・予測期間において、有効な文章が一つも得られない学生のデータは対象外とした) は対象年度が 485 名分、教師データ用 (前年度分) は 471 名分となる。学習にあたっては予測タイミングに合わせて、その時点で知りうるデータのみを用いる。予測精度の計算では最終的な状態 (4 年後に卒業、3 年後に退学など) と比較を行った。

3.2. 実験結果

1 年目 9 月、3 月、2 年目 9 月、3 月におけるドロップアウト予測の予測精度を表. 1 に示す。このとき 1 年前のデータを用いて学習を行った。表において、学習手法を DL (Deep Learning)、DT (Decision Tree) と表記している。また対象データについて、

成績のみを GPA、成績に感情推定結果を加えたものを GPA+PN と表記した。

表. 1 予測精度の比較・評価

1年前 →当年度	DL (GPA+PN)	DL (GPA)	DT (GPA+PN)	DT (GPA)
9月	0.711	0.724	0.724	0.724
3月	0.743	0.760	0.766	0.766
次年度9月	0.769	0.784	0.786	0.808
次年度3月	0.767	0.800	0.775	0.794

予測精度は手法 (DL or DT) による差はほとんど見られない。予測時期の推移に伴い、予測精度は少し向上している。これは用いることのできるデータの増加によるものと考えられる。感情推定結果の利用についても予測精度には大きな差異は見られない。

次に、捕捉数について表. 2 に示す。捕捉数には大きな差異が見られる。特に感情推定結果を用いたときの Deep Learning による学習・予測では他の手法よりも早期に、ドロップアウトする学生を予測できている。

次に不要面談数について表. 3 に示す。こちらは捕捉数に反する形で感情推定結果を用いたときの Deep Learning による学習・予測の際に多くの面談が余計に発生している。

表. 2 捕捉数の比較・評価

1年前 →当年度	DL (GPA+PN)	DL (GPA)	DT (GPA+PN)	DT (GPA)
9月	10	0	0	0
3月	30	17	21	21
次年度9月	23	32	31	43
次年度3月	22	40	26	35

表. 3 不要面談数の比較・評価

1年前 →当年度	DL (GPA+PN)	DL (GPA)	DT (GPA+PN)	DT (GPA)
9月	16	0	0	0
3月	21	0	1	1
次年度9月	0	2	0	1
次年度3月	0	2	0	0

3.3. 考察

提案した感情推定結果の導入は全体としての予測精度の改善にはつながらなかったが、Deep Learning との組み合わせにおいて、早期における捕捉数の向上という結果を示した。このことは感情推定結果の利用の有効性を示したものと考えられる。

4. おわりに

成績だけでなく感情推定結果を用いることで、ドロップアウト予測を行うことの検証を行った。

その結果、予測精度には影響が見られなかったが、Deep Learning との組み合わせによって、早期の捕捉数が大きく改善されること、一方で不要面談が増えることを示した。このことは実運用を考えたときに、面談をどれぐらいの件数であれば実施可能か、という視点があれば、どちらが適しているかを判断できることを示唆している。一定量の面談が可能であれば、提案手法による予測結果を用いれば、他の手法では困難だったより多くの学生について、早期にドロップアウトの兆候を把握した対処が可能になる。逆に最小限の面談でその可能な範囲で対応するような場合(その分、兆候を見逃すケースも多い)には従来手法の方が適していると考えられる。

ここでは論じていないが、多年度のデー

タを用いることにも提案手法は適した傾向が見られる。[5]の手法では年度間が離れると予測精度が低下する傾向が見られたが、提案手法ではその傾向は試行した範囲では見られなかった。これは教育実施内容に大きく左右される提出回数に対して、感情推定は年度ごとの教育実施内容に依存する要素が小さいからではないかと推測できる。

今後の展望として、本論文では `TextArea` での記述のみを対象としたが、文書やプレゼンテーション資料など多くのテキストを含んだファイルによる文書の提出を対象とすることが考えられる。予測に供する文章量が増えるので、より予測精度を高められる可能性がある。一方で、データ量の増加に伴い、機械学習のために必要な計算力やパラメーター数の増加や調整が困難になることも危惧される。

参考文献

- [1] 文部科学省：学生の中途退学や休学等の状況について、
http://www.mext.go.jp/b_menu/houdou/26/10/_icsFiles/afieldfile/2014/10/08/1352425_01.pdf, 2014.
- [2] 文部科学省：学校教育法施行規則等の一部を改正する省令の施行について、
http://www.mext.go.jp/b_menu/hakusho/nc/1294750.htm, 2010.
- [3] Carlos Márquez-Vera, Alberto Cano, Cristobal Romero, Amin Yousef, Mohammad Noaman, Habib Mousa, Fardoun, Sebastian Ventura : Early dropout prediction using data mining: a case study with high school students, *Expert Systems*, Volume 33, Issue 1, pp.107–124, February 2016
- [4] Erman Yukselturk, Serhat Ozekes, Yalin Kılıç Türel : Predicting Dropout Student: An Application of Data Mining Methods in an Online Education Program, *European Journal of Open, Distance and E-Learning*, Volume 17, Issue 1, pp.118–133, December 2014
- [5] 天野直紀：成績と教育支援システム利用履歴からのドロップアウト予測, 日本 e-Learning 学会, No.16, pp.83-91, 2016
- [6] 江村優花, 関洋平：テキストに現れる感情, コミュニケーション, 動作タイプの推定に基づく顔文字の推薦, 情報処理学会研究報告, Vol.2012-IFAT-106, No.1, pp.1-7, 2012
- [7] 高村大地, 乾孝司, 奥村学：隠れ変数モデルによる複数語表現の感情極性分類, 情報処理学会論文誌, Vol.47, No.11, pp.3021-3031, 2006
- [8] Microsoft R Open :
<https://mran.microsoft.com/open/>
- [9] H2O : <http://www.h2o.ai/>

[著者紹介]

天野 直紀 (学会員)



1999 年 東京工科大学
大学院工学研究科シス
テム電子工学専攻博士
課程単位取得退学。

1999 年 東京工科大学
助手, 2003 年同講師,
2011 年同准教授。博士
(工学)。おもに画像処
理・認識, ネットワーク
アプリケーションに関
する研究に従事。日本 e-
Learning 学会、計測自
動制御学会, 電子情報
通信学会等の会員。