

自己評価の縦断データによる学習者のパターン分析

Extracting Patterns of Learners from Longitudinal Data of Self-Evaluations

久富 望^{*1}, 寺澤 孝文^{*2}, 田中 利幸^{*1}
 Nozomu KUTOMI^{*1}, Takafumi TERASAWA^{*2}, Toshiyuki TANAKA^{*1}

^{*1} 京都大学大学院情報学研究所
^{*1} Graduate School of Informatics, Kyoto University
^{*2} 岡山大学大学院教育学研究科
^{*2} Graduate School of Education, Okayama University
 Email: kutomi.nozomu.83e@kyoto-u.jp

あらまし: ラーニング・アナリティクスの分野において中心的な課題の一つである学習モデリングにおいて、従来手法では生徒の反応値をそのまま用いることが一般的である。本研究では、出題日の間隔が調整されたマイクロステップ計測技術を用いて収集された学習者の自己評価の縦断データに対し、生徒の反応値の変遷を用いて解析した。遷移頻度をまとめ、非負値タッカー分解を用いてパターン分析した結果、全学習者に見られる典型的な遷移パターンと、各パターンに対する学習者ごとの適合度が得られた。本研究における数理モデルは、今年度中に複数の小学校から得られる縦断データに対して適用し、教師と学習者へのフィードバックに用いる予定である。

キーワード: 非負値タッカー分解, マイクロステップ, 生徒モデリング, パターン分析, 縦断データ

1. はじめに

ラーニング・アナリティクス (LA) の分野において、学習者が何らかの課題を行ったとき、その実施回数や、実施における課題の正誤などの情報から、学習者の学習状態を推測しようとする試みは生徒モデリング (Student Modeling) として重要な課題の一つである。その代表的な数理モデルとして Additive Factors Model⁽¹⁾, Performance Factors Analysis⁽²⁾, Bayesian Knowledge Tracing⁽³⁾などがあり、収集された学習者の回答データをそのまま用い、学習者の知識、技能、テスト成績の見積もり等を目指している。

本研究では、学習者の自己評価の縦断データに対して、学習者の回答データを直接用いるのではなく、回答の変遷に着目した解析に取り組む。

2. データ

本研究では数理モデルを検討するための解析対象として、12-13 歳 118 人に対し、193 種類の漢字の読みについての自己評価 (4 件法) がおよそ 12 週間、1 日 104 問 (金曜 44 問) ずつ集められた合計約 350000 件のデータを用いた。収集にあたってはマイクロステップ計測技術⁽⁴⁾によって出題日が調整され、出題日の不均一による誤差が抑えられている。また、いくつかの漢字に対しては生徒は 1 日に 4 回または 2 回の自己評価が求められる。

生徒は図 1 に示すような、漢字とその読みが記された回答用紙に対し、現在の自分の実力を 0「全然だめ」、1「だめ」、2「もう少し」、3「よい」のいずれかで答える。表示される漢字が 10-12 歳に学習するものでもあるため、3「よい」がデータの 84%と大多数を占め、2「もう少し」(5%)、1「だめ」(3%)、0「全然だめ」(8%) となっている。

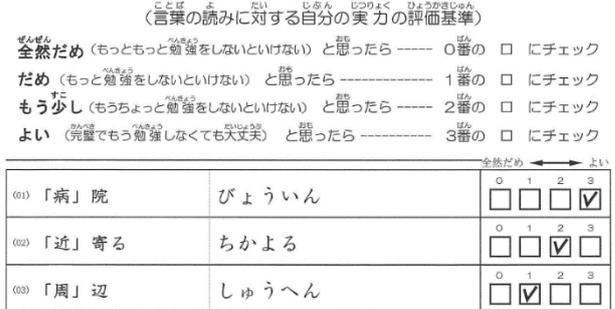


図 1 学習者に配られる回答用紙の例 (右下のチェックは、学習者自らが行う)

3. 解析と結果の解釈

3.1 遷移頻度テンソル

筆者らはまず、各生徒 n について、回答 $p (= 0, 1, 2, 3)$ であった問題に対し、同じ日の次の自己評価において回答 $q (= 0, 1, 2, 3)$ と答えた回数を (p, q) 成分とする 4×4 の行列 $A^{(n)}$ を作成した。たとえば、2 つの漢字が同じ日にそれぞれ 2 回出題され、生徒 n は一方には順に 2, 3 と、他方には 3, 3 と答えたならば、 $A^{(n)}$ の (2, 3) 成分, (3, 3) 成分がそれぞれ 1 ずつ増える (図 2)。



図 2 $A^{(n)}$ の作成例

同様に、生徒 n が回答 p であった漢字に対し、週を

超えない翌日以降の次の自己評価で q と回答した回数を $B^{(n)}$ の (p, q) 成分とする。

これら $A^{(n)}, B^{(n)}$ のいずれかについて、全成分の和が100未満である場合は、十分にサンプルがないものとして除外し、結果的に80個の $A^{(n)}, B^{(n)}$ を解析対象とした。そして、 (n, p, q) 成分が $A_{pq}^{(n)} / \sum_{p,q=0}^3 A_{pq}^{(n)}$ となるようテンソル $\underline{A} \in [0,1]^{80 \times 4 \times 4}$ を作成し、これを遷移頻度テンソルと定義した。また $B^{(n)}$ からも遷移頻度テンソル $\underline{B} \in [0,1]^{80 \times 4 \times 4}$ を同様に求めた。

3.2 非負値タッカー分解(NTD)

NTD(Non-negative Tucker Decomposition)は、非負値のテンソルを非負値の行列やテンソルの積に分解する手法であり、Q-matrix⁽⁵⁾で用いられる非負値行列因子分解(Non-negative Matrix Factorization)の拡張である。いくつかのNTDのモデルのうち、本研究ではTucker1モデルを用い、 \underline{A} を非負値のテンソル \underline{W}_A と非負値の行列 H_A の積に近似的に分解する。

$$\underline{A} \approx \underline{W}_A \times_A H_A \Leftrightarrow A_{nij} \approx \sum_{k=0}^{k_A-1} (W_A)_{kij} (H_A)_{nk} \dots (1)$$

ここで、 $\sum_{i,j=0}^3 (W_A)_{kij} = 1, \sum_{k=0}^{k_A-1} (H_A)_{nk} = 1$ である。

$\underline{W}_A^k = ((W_A)_{kij})_{i,j=0,1,2,3}$ は $\{A^{(n)}\}$ の k_A 個のパターンを表し(以後、この各パターンを「遷移パターン」と記す)、 $(H_A)_{nk}$ は k 番目の遷移パターン \underline{W}_A^k に生徒 n の遷移がどの程度一致したかを表している(以後、この値を「適合度」と記す)。同様に、 $\{B^{(n)}\}$ の遷移パターン数を k_B とし、 $\underline{B} \approx \underline{W}_B \times_B H_B$ となるよう分解した。この結果、 k_B 個の遷移パターンである非負値のテンソル \underline{W}_B と、各遷移パターンに対する全生徒の適合度を表す非負値の行列 H_B を得た。

3.3 結果の解釈

筆者らは、 \underline{A} をNTDで分解するため、Multiplicative updating⁽⁶⁾を用いて l_2 正則化のもとでの2乗誤差

$$\|\underline{A} - \underline{W}_A \times_A H_A\|_2^2 + \lambda_A (\|\underline{W}_A\|_2^2 + \|H_A\|_2^2) \dots (2)$$

を最小化した。 \underline{B} に対しても同様である。図3, 4は $(\lambda_A, k_A) = (0,01,5), (\lambda_B, k_B) = (0,03,6)$ における結果である。 $k_A \geq 6, k_B \geq 7$ においては \underline{W}_A^0 のようなパターンが複数現れたため、 $k_A = 5, k_B = 6$ がもっとも相応しいと判断した。

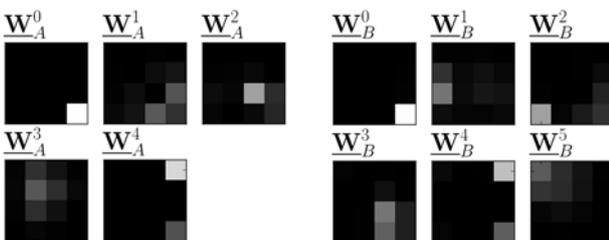


図3 学習者の遷移パターン $\underline{W}_A^k, \underline{W}_B^k$
(白: 1, 黒: 0)



図4 80人の学習者の適合度(白: 1, 黒: 0,
上5行: 上から $\underline{W}_A^0, \underline{W}_A^1, \underline{W}_A^2, \underline{W}_A^3, \underline{W}_A^4$ との適合度,
下6行: 上から $\underline{W}_B^0, \underline{W}_B^1, \underline{W}_B^2, \underline{W}_B^3, \underline{W}_B^4, \underline{W}_B^5$ との適合度)

$\underline{W}_A^0, \underline{W}_B^0$ はいずれも(3,3)要素がほとんど1であり(図3)、この2つの遷移パターンに対し多くの生徒が高い適合度を示している(図4)。これは、生徒の回答の多く(84%)が3であったためである。

\underline{W}_B^2 は(3,0)要素が多く、ある日は3「よい」を付けた漢字に、日が変わると0「全然だめ」を付けた傾向の強い遷移パターンである。これは20, 30, 32, 34, 40番などの生徒に強く見られ、何らかの復習課題を与える等の対策を教師に示唆している。

53番の生徒は他の生徒と異なり、2「もう少し」を含む遷移が多い $\underline{W}_A^2, \underline{W}_B^3$ の適合度が高い。この生徒は自己効力感が低下している可能性を示唆しており、教師の適切な指導によって有用な情報となりうる。

4. 今後の課題と応用

今回提案した数理モデルは、今年度中に複数の公立小学校において収集される縦断データに対して適用し、その結果を元に教師と学習者に対してフィードバックを行う予定である。また、この数理モデルは、学習者の正誤など、他の値の変遷にも適用可能であり、幅広い応用の可能性がある。

今後の課題として、パラメータ $\lambda_A, k_A, \lambda_B, k_B$ を統計的な手法で見積もることが挙げられる。

参考文献

- (1) Cen, H., Koedinger, K. R. and Junker, B.: "Is over practice necessary? - improving learning efficiency with the cognitive tutor through educational data mining", In Proceedings of the 2007 Conference on Artificial Intelligence in Education: Building Technology Rich Learning Contexts That Work, pp.511-518 (2007)
- (2) Pavlik, P. I., Cen, H. and Koedinger, K. R.: "Performance factors analysis - a new alternative to knowledge tracing", In Proceedings of the 2009 Conference on Artificial Intelligence in Education: Building Learning Systems That Care: From Knowledge Representation to Affective Modelling, pp.531-538 (2009)
- (3) Corbett, A. T. and Anderson, J. R.: "Knowledge tracing: Modeling the acquisition of procedural knowledge", User Modeling and User-Adapted Interaction, Vol.4, No.4, pp.253-278 (1994)
- (4) 寺澤孝文: "スケジュールの作成方法及びそのプログラム並びにスケジュールの作成方法のプログラムを記憶した記憶媒体", 特許第3764456 (2006)
- (5) Desmarais, M. C.: "Mapping question items to skills with non-negative matrix factorization", SIGKDD Explor. Newsl., Vol.13 No.2, pp.30-36 (2012)
- (6) Cichocki, A., Zdunek, R., Phan, A. H., and Amari, S.: "Nonnegative Matrix and Tensor Factorizations: Applications to Exploratory Multi-way Data Analysis and Blind Source Separation". Wiley (2009)