

学習活動別時間に基づくWeb調べ学習履歴の分析

Analysis of Learning History based on Elapsed Time of Each Learning Stage

森谷 友昭¹ 地神 聡美¹ 高橋 時市郎¹ 瀬下 仁志²
 Tomoaki Moriya Sathomi Digami Tokiichiro Takahashi Hitoshi Sesimo
 藤本 強² 丸山 美奈² 鈴木 英夫² 田中 明通³
 Tuyoshi Fujimoto Mina Maruyama Hideo Suzuki Akimichi Tanaka

1. はじめに

学習活動におけるIT利用が進む中で、学習中の活動履歴を豊富に取得することが可能となってきた。しかしその反面、多量で詳細な学習履歴は、特に各学習者への適切なフィードバックとして随時利用するという意味では、取り扱いが困難であった。我々の一部は既に、各学習者の学習履歴を抽象化し、学習スタイルとして可視化する手法を提案してきた[1][2]。本稿では、学習履歴を全学習時間における学習活動別時間及び、全学習時間を等分割し、各々の時間帯で学習活動別に費やされた学習時間から特徴を分析する手法を提案する。授業実践で得られた実データへ適用し分析を試みたところ良好な結果が得られたので報告する。

2. 学習履歴データ

中学1年生15名のデータを対象とし、選択数学の時間(2時間+ α)において、興味のある数学者をテーマに調べ学習を行った。学習者は、後述する調べ学習支援システム linkWorks[1]を用いて、主にインターネットからの情報を収集した。linkWorks上では、予め教師によって作成された教材が提示されている。課題の確認や参考となるWebページへのリンクなど、学習を進めるにあたって指針となる情報が掲載されている。

本研究では、linkWorksを用いた調べ学習活動での学習履歴データを用いて、学習者の思考スタイルを分析する。

3. 調べ学習支援システム linkWorks の概略[1]

linkWorksは、Webを調べ学習における探索の情報源としてだけでなく、情報発信のツールとしても使い、それらを「リンク」という形で蓄積、編集、共有することを可能とする学習支援システムである。

表1 学習活動の種類

stage0:学習開始・終了	stage4:まとめる
stage1:調べる(収集)	stage5:発表
stage2:調べる(検索)	stage6:交流
stage3:調べる(閲覧)	

linkWorksのサポートする一連の学習活動を表1に示す。表1のstage別に費やした時間が基礎データとなる。

4. データの分析方法

Webを利用した調べ学習を題材とし、学習者の活動履歴から特徴的な学習スタイルの発見を試みることを目的とする。

学習者の学習活動履歴を次のように記述する。ある時間帯 j での学習者 k の学習時間を stage0~6 に分類し、stage i

に費やした時間を成分 $a_{ij}(k)$ とするベクトル $\mathbf{a}(k)$ になり、学習者 k の特徴を記述する。このベクトル $\mathbf{a}(k)$ を学習履歴特徴ベクトルと呼ぶ。

本研究では、特徴ベクトル $\mathbf{a}(k)$ と、比較対象学習者 m の特徴ベクトル $\mathbf{a}(m)$ の間の類似度 r_{km} を次式から求める。

$$r_{km} = (\mathbf{a}(k), \mathbf{a}(m)) / (|\mathbf{a}(k)| \cdot |\mathbf{a}(m)|) \dots \dots (1)$$

次に、求めた類似度に基づいてクラスタ分析を行う。学習者 k について、他の全学習者 m との類似度が閾値を超えていた場合、似た学習スタイルを持つ学習者とみなす。その作業を全ての学習者に対して行い、クラスタを形成する。

5. 分析結果

我々の一部は既に全学習時間帯に対するクラスタ分析を行い良好な結果を得ている[2]。その結果、各学習 stage が全学習時間帯に対する割合により、学習スタイルを分析できることが分かった。今回は、時間の経過によりどのように学習スタイルが変化していくかを見るため学習活動時間帯別類似度を算出した。

まず調べ学習における全学習時間を任意の数 n で分割する。次に、それぞれの時間帯内で stage 別に費やされた合計時間を求める。これにより stage0~6 それぞれの時間を要素に持つ7次元のベクトル $\mathbf{a}_1(k), \mathbf{a}_2(k) \dots \mathbf{a}_n(k)$ を求め、時間帯①では、 $\mathbf{a}_1(k)$ と $\mathbf{a}_1(m)$ の類似度、時間帯②では $\mathbf{a}_1(k)+\mathbf{a}_2(k)$ と $\mathbf{a}_1(m)+\mathbf{a}_2(m)$ といった14次元のベクトル間の類似度を求める。時間帯 n では $n \times 7$ 次元のベクトル間の類似度を求める。

図1は時間帯数 $n=5$ 、オイラーを調べた1人目の生徒(以下「オイラー1」と記す)の類似度 r_{km} の変化を示している。

クラスタ分析の結果は、閾値を超えた学習者同士を線で結び、結ばれた学習者の集団をひとつのクラスタとして図示した。図2、図3、図4に結果を示す。

6. 考察

クラスタ分析の結果から、図2⇒図3⇒図4と、長時間の学習活動時間が経過するにつれ、クラスタの特性が徐々に明確になってくることが分かる。今、例として、アルキメデス-ニュートン1-ニュートン2の集団を挙げる。この集団は図2においては他に類似している学習者が多いが、図3⇒図4と時間が経過するにつれ、他の学習者との類似性が低下する。しかしながら、この集団内での互いの類似性はあまり変化しないことが分かる。

最終的に求められた図4のクラスタを基に、各学習者の全学習時間における stage 別に費やした時間の割合を図5に示す。図5から各クラスタ内の学習者の stage 毎の学習時間の割合が類似していることが分かる。クラスタ A、B

1.東京電機大学 Tokyo Denki University
 2.NTTサイバーソリューション研究所
 NTT Cyber Solutions Laboratories
 3.NTTサイバースペース研究所
 NTT Cyber Space Laboratories

では stage3、クラスタ C では stage1、クラスタ D では stage0 が相対的に多い。

全学習時間帯で見た場合、すなわち学習時間の分割数 $n=1$ の場合、例えばオイラー2 はクラスタ A を形成する学習者に類似していると分析される。しかし学習活動時間帯別に分析した場合、その学習スタイルはクラスタ A とは大きく異なってきた、最終的には別のクラスタを形成する。




図1 $n=5$ における類似度 r_{km} (オイラー1)の場合

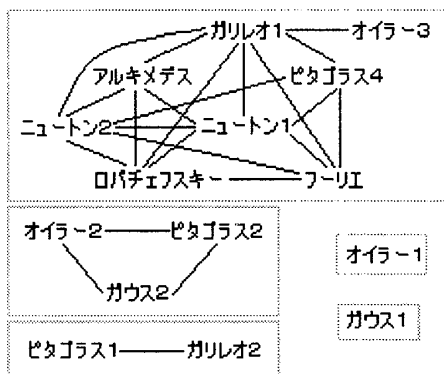


図2 時間帯③におけるクラスタ分析結果 (閾値:0.95)

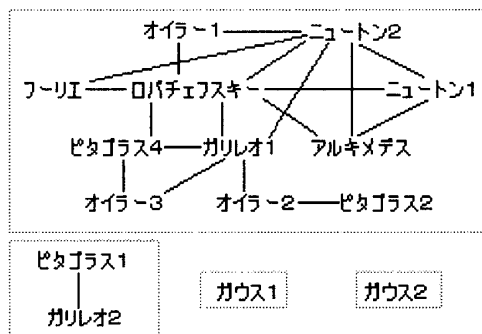


図3 時間帯④におけるクラスタ分析結果 (閾値:0.80)

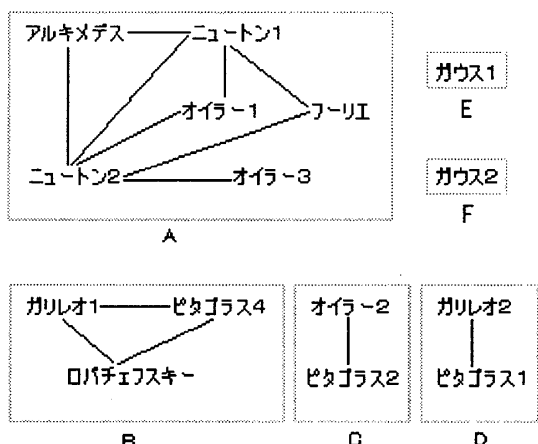


図4 時間帯⑤におけるクラスタ分析結果 (閾値:0.80)




図5 学習活動時間

7. むすび

本報告で提案した学習活動時間帯別に各学習ステージの時間割合を求めて分析する手法は学習スタイルの動的な特徴を捉えることができる利点がある。先の手法[2]が学習終了後にはしかクラスタ分析が行うことができなかった。これに対して本手法では、学習中に漸次分析を行うことができる利点がある。すなわち学習者のフィードバックを授業に行えるので教育現場で有効と考えられる。

文献

- [1] 瀬下他「調べ学習活動支援システム：linkWorks の開発と実践」2004 信学総大
- [2] 瀬下他「Web を利用した調べ学習活動における学習スタイルの可視化・分析」信学技法 103、697、pp.137-142 (2004)