

学習活動代表値に基づく Web 調べ学習履歴の分析

Analysis of Learning History based on Central Tendency of Learning Time

地神 聡美¹ 森谷 友昭¹ 高橋 時市郎¹ 瀬下 仁志²
 Satomi Jigami Tomoaki Moriya Tokiichiro Takahashi Hitoshi Seshimo
 藤本 強² 丸山 美奈² 鈴木 英夫² 田中 明通³
 Tsuyoshi 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]。本報告では、単位学習時間内で最長の学習stageを代表値とし、代表値stage間の学習スタイルの類似度により、学習スタイルを分類する方法を提案する。授業実践で得られた実データへの適用と分析を試み、良好な結果を得たので報告する。

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. クラスタの分析

4. 1. 学習者の特徴ベクトル

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のが目的である。

そこで、学習stage間の推移に注目して分析を行うことにした。つまりweb学習を行う際に、検索結果を順に見ていく人や閲覧したページの中で興味がある事項を次々とたどる人など、学習ステージ間の推移に学習者のスタイルが特徴的に現れると考えたからである。

最初の分析方法として、ある時間帯*j*での学習者*k*の学習活動時間をstage別に0~6に分類する。stage*f*からstage*t*へ推移した場合($f, t=0, 1, 2, \dots, 6$)、ある学習者の学習活動全時間内でのそれぞれの推移の合計回数を成分 $a_{ft}(k)$ とするベクトルを $\mathbf{a}(k)$ とし、学習活動の特徴ベクトルとする。

次に、学習時間を1分、3分、5分刻みに分割し、各時間帯で最も費やした時間が長かったstageを代表値とする。同様に代表値で記述された学習ステージの推移の回数により、ある学習者*k*の学習活動全時間内でのそれぞれの推移の合計回数を成分 $b_{ft}(k)$ とするベクトルを $\mathbf{b}(k)$ とする。 $\mathbf{b}(k)$ を学習活動代表値推移ベクトルと呼ぶ。

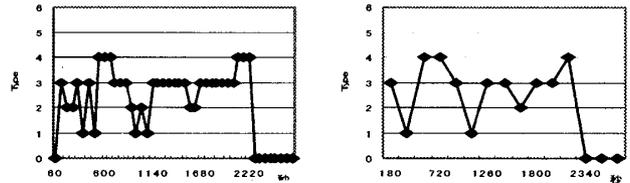


図1 代表値 (オイラー1・1分、3分刻み)

この2つのベクトルで学習者*k*の特徴を記述する。このベクトル $\mathbf{a}(k)$ 、 $\mathbf{b}(k)$ を単に特徴ベクトルと呼ぶ。特徴ベクトル $\mathbf{a}(k)$ 、 $\mathbf{b}(k)$ はそれぞれ $7 \times 7 = 49$ 次元ベクトルとする。

本研究では、学習者*k*の特徴ベクトル $\mathbf{a}(k)$ 、 $\mathbf{b}(k)$ と、比較対象学習者*m*の特徴ベクトル $\mathbf{a}(m)$ 、 $\mathbf{b}(m)$ の間の類似度 r_{fi} 、 s_{fi} を用いてデータ分析を試みる。類似度 r_{km} 、 s_{fi} はそれぞれ次式で与えられる。

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

$$s_{fi} = \frac{(\mathbf{b}(k), \mathbf{b}(m))}{(|\mathbf{b}(k)| \cdot |\mathbf{b}(m)|)} \dots\dots (2)$$

ただしstage0からstage0など、同stageへの推移回数成分は0とした。実際の特徴ベクトルを図2に示す。

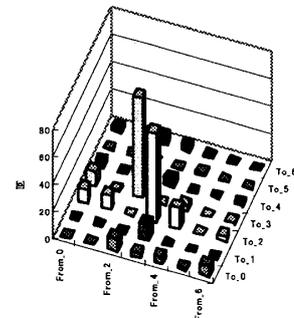


図2 学習推移ベクトルの例 (オイラー1の場合)

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

4. 2. 類似度 r_{ft} , s_{ft}

類似度を求める。図3に、オイラー1の類似度 r_{ft} と、時間分割帯を1分、3分、5分としたときの類似度 s_{ft} を求めた結果を示す。

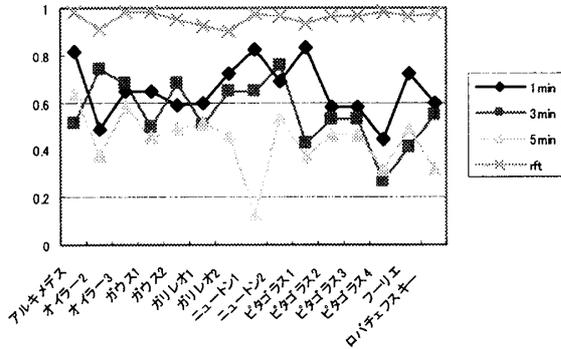


図3 オイラー1の類似度

4. 3. クラスタリング

類似度 r_{ft} を用いて、学習者のクラスタリングを行った結果を図4に示す。類似度が閾値以上の学習者でクラスタが構成される。同様に、代表値を求める時間分割帯を1分、3分、5分単位としたとき、 s_{ft} を用いて学習者のクラスタリングを行った結果を図5、6、7に示す。

4. 4. 分析

類似度 r_{ft} を用いた場合、類似度の値に大きな差がなく、クラスタリングした結果、図4のように1つの大きなクラスタになってしまう。

代表値を利用した類似度 s_{ft} では、1分、3分、5分と刻む時間を長くするに従って、クラスタを形成する学習者の構成が変化してくる。例えば、ピタゴラス4とロバチェフスキーはどの代表値を利用しても同じクラスタになるが、ピタゴラス2とロバチェフスキーは3分刻みのときのみ(図6)、ガウス1とフーリエは5分刻みのときのみ(図7) 同じクラスタになる。また、刻む間隔が短いほど、ひとつのクラスタに分類される人数が多くなること分かる。

このように、 s_{ft} を用いるといくつかのクラスタに分かれていく。すなわち、時間分割帯を変えて分析することによって学習者の学習スタイルが明確になっていくと考えられる。

推移回数のみを考慮する r_{ft} にはノイズが含まれる可能性が高いため、クラスタリングの有効性に疑問が残る。推移回数及び stage 別の滞在時間も考慮した s_{ft} の方が安定してクラスタリングできる傾向にある。

5. むすび

単位学習時間内で最長の学習 stage を代表値とし、代表値 stage 間の学習スタイルの類似度を求めた。類似度によって学習スタイルをクラスタリングしたその結果、学習活動時間内の代表値をとらずに推移回数のみで類似度を求めるよりも、学習時間を短い時間で分割し、その時間帯の

stage の代表値を利用して stage 推移の類似度を求めた方が安定したクラスタリングを行うことができた。

学習活動別時間に基づく手法[3]との関係は今後の課題である。

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」信学技報, Vol.103, No.697, pp.137-142 (2004)
- [3] 森谷他「学習活動別時間に基づく Web 調べ学習履歴の分析」FIT2004 (to appear)

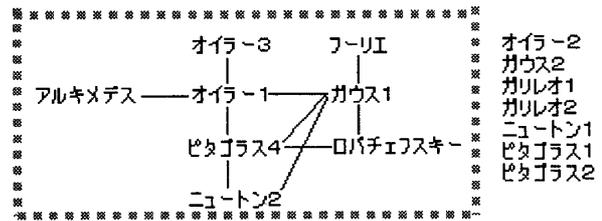


図4 類似度 r_{ft} によるクラスタリング

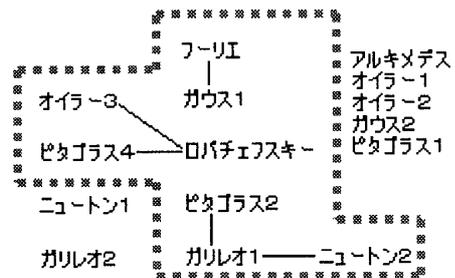


図5 類似度 r_{ft} (1分) によるクラスタリング

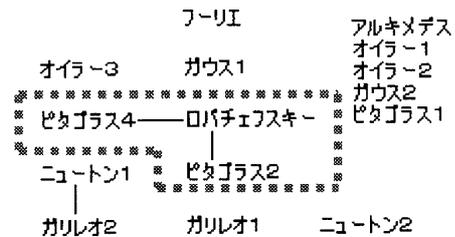


図6 類似度 r_{ft} (3分) によるクラスタリング



図7 類似度 r_{ft} (5分) によるクラスタリング