

# IoT を用いた協調学習分析ツールの初期的評価

秋本 ゆり<sup>†</sup> 大多和 修介<sup>†</sup> 大島 律子<sup>†</sup> 猿渡 俊介<sup>‡</sup> 大島 純<sup>†</sup>  
<sup>†</sup> 静岡大学 <sup>‡</sup> 大阪大学

## 1 はじめに

本研究では、協調学習における効果的な学習環境の構築を目的として、学習の分析コスト削減する協調学習分析ツールの提案を行う。分析コストを削減するためには、学習プロセスのフェーズを分類・可視化することが必要である。そこで本稿では、IoT 技術によって学習フェーズを自動抽出する Sensor-based Regulation Profiler を提案する。

## 2 要件

協調学習の場に対して定量分析ツールを導入するためには、1. 学習環境に簡単に導入できること、2. 協調学習のフェーズの自動分類ができること、3. データの時刻同期がとれていることの3つの要件を満たす必要がある。

「1. 学習環境に簡単に導入できること」は定量分析ツールを広く展開するために必要である。学習環境に対して設置するコストが高価な技術や入手性が悪い技術を利用することは現実的ではない。学習環境に簡単に導入することを目的として、本研究では学習者が首からぶら下げる名刺型センサの導入を考えている。名刺型のセンサとして、日立のビジネス顕微鏡 [1] や MIT の Sociometric Badge [2] が存在する。例えば、ビジネス顕微鏡では企業の組織内のコミュニケーションの定量分析に成功している。組織ネットワークの分析によって組織の壁などのコミュニケーションの問題を解決している。しかしながら、ビジネス顕微鏡も Sociometric Badge も市販されておらず、入手することができなかった。

「2. 協調学習のフェーズの自動分類ができること」は協調学習における定量分析と定性分析を接続するために必要である。理想的には現在の学習科学の研究者が行っている定性分析 [3] と同じ分析結果を全て自動抽出できることが望ましい。しかしながら、現状では機械と人間が取得・処理できる情報には大きな乖離があるため、定性分析で行っていることを定量分析で行うのは難しい。そこで本研究では、協調学習における学習フェーズの自動抽出に対象を絞る。協調学習を定性分析する場合に、現状で最も労力を必要としている作業の1つが協調学習プロセス全体を分析しなければならないことだからである。例えば筆者らが導入を検討している大学の授業の場合、授業の時間は90分で学生数が30人である。30人の学生を対象として90分全ての学習プロセスを担当教員が定性分析することは現実的ではない。

「3. データの時刻同期がとれていること」は、本研究が各個人ではなく人と人の協調を対象としていることから特に必要となる。本研究では、学習参加者や学習環境などの様々な対象に設置されており、かつ多様なセンサからのデータの整合性を確認しながら分析する。時刻同期が取れていないデータ同士を結合して分析した場合、実際に起こった事象の時系列的な順序が崩れてしまうため、分析の結果が意味をなさないものになってしまう。同期を取ることが望ましい。例えば50Hzでセンサデータを取得している場合には10ミリ秒未満の時刻同期を取れていることが求められる。

## 3 提案手法

2節で述べた要件を同時に実現するための手法として、「Sensor-based Regulation Profiler」を提案する。一般的な協調学習における分析手法は、映像・音声データの収集、文字起こし、対話分析の3つから構成される。それに対して Sensor-based Regulation Profiler では、一般的な分析手法のプロセスに対して新たに1. センサを使ったデータ収集、2. センサデータのデータマイニング技術による分析

## Algorithm 1 ソーシャルグラフの抽出

```

1: for  $i \leftarrow 0$  to  $size(U)$  do
2:    $m \leftarrow (\sum_{j=t_0}^{t_0+60} L_i[U_j]) / 60$ 
3: end for
    
```

表 1: Algorithm 1で使用する変数, 関数

変数, 関数	説明
$L$	全センサデータの集合
$U$	全てのセンサ ID の集合
$t_0$	ある時刻
$size(U)$	センサ ID の集合 $U$ に含まれる要素数
$m$	時刻 $t_0$ のソーシャルグラフを表すマトリクス

の2つの仕組みを追加することで文字起こしと対話分析の労力の削減を目指す。

図1にセンサとして開発した Sensor-based Regulation Profiler Badge を示す。開発した名刺型センサは、加速度センサと赤外線センサを具備している。加速度データは1秒間に50回のサンプリングを行い、赤外線データはセンサ同士の対面を1秒間に1回サンプリングする。入手性の高いモジュールを使用することで低価格で実現した。

学習者やホワイトボードにセンサを付けて、得られたセンサデータから学習フェーズを抽出するためにデータマイニング技術を開発した。また、センサデータから学習者やホワイトボードとのネットワークを構築して、ネットワークの変化を可視化した。学習中のネットワークの変化を分析することで、学習のフェーズを自動的に分類することに成功した。ネットワークの変化や学習フェーズの変遷を可視化することで、教師の定性分析をサポートする。

枠 1: 赤外線データの例

```

3,1052 1,2 2,2
3,2054 1,3 2,3 1,4 2,4 1,2 2,2
3,3055 1,4 2,4 1,3 2,3 1,5 2,5
    
```

枠 1 に名刺型センサから得られる赤外線データの例を示す。赤外線データは ID, データの2つの値のペアとなっている。ID が3の場合は名刺型センサが起動してから時間(ミリ秒)を示しており、ID が1の場合は名刺型センサの裏の赤外線センサ、ID が2の場合は名刺型センサの表の赤外線センサを示している。データ部分は検出した名刺型センサのセンサ ID を示している。赤外線データは、各センサノードが1秒ごとに他のセンサノードを検知できたかどうかのデータである。このことから、全ての赤外線データを集約したものは有向グラフとなり、学習中に構築されるネットワークを意味したもとなる。

学習中のネットワークの変化は学習フェーズの変遷を表している。協調学習の学習フェーズは、動画視聴、情報確認・整理、議論、結論の4つに分かれている。学習フェーズが移り変わるとき、人は今まで対面していたものから異なる対象への注目が増えたり、多数の対象に注目したりと特徴的な変化が表れる。特徴的な変化を名刺型センサによって捉えることで、学習プロセス全体を分析することなく学習フェーズの抽出をするとともに、定量的なデータとして活用する。




図 1: Sensor-based Regulation Profiler Badge




図 2: 評価実験による AutoPlait の使用例




図 3: 実験環境

表 2: DSM の例

-	1	2	3	4
1	-	42	46	29
2	53	-	16	10
3	46	42	-	57
4	21	0	43	-

学習中のネットワークである有向グラフをソーシャルグラフと表現する。また、学習中のネットワークの変化量をソーシャルグラフの変化量として、学習フェーズの抽出に活用する。

Algorithm 1 にソーシャルグラフの抽出アルゴリズムを、表 1 に Algorithm 1 で用いる変数と関数を示す。Algorithm 1 は、全センサデータの集合  $L$ 、全てのセンサ ID の集合  $U$ 、ある時刻  $t_0$  を入力として、 $L$  における時刻  $t_0$  の学習中のネットワークを表すマトリクス  $m$  を出力するアルゴリズムである。

求めた  $m$  は Design structure matrix (DSM) となる。DSM はシステムやプロセスの関連を正方行列の形で視覚的に表現したものである。また、グラフ理論における隣接行列と同等である。表 2 に DSM の例を示す。表 2 の最初の行と列はセンサ ID となっている。例えば、2 行 3 列目の 42 はセンサ ID1 がセンサ ID2 の赤外線を受信していることを示す。各要素の最大値は  $m$  を算出するときのウィンドウ幅である 60 となっている。Sensor-based Regulation Profiler Badge から得られた赤外線センサデータを DSM によってソーシャルグラフとして抽出した。

全てのソーシャルグラフのマトリクスの集合を  $M$ 、時刻を  $t$  とすると、 $M$  における時刻  $t$  と  $t+1$  とのソーシャルグラフの変化量  $v$  を求める式は、

$$v = \sum_{t=0}^n \sqrt{(M_{t+1} - M_t)^2} \quad (1)$$

となる。全マトリクスの時刻  $t$  と  $t+1$  の変化量を用いて時系列データとしてソーシャルグラフの変化量は算出される。

ソーシャルグラフの変化量から学習のフェーズの自動抽出をするために AutoPlait [4] を使用した。AutoPlait は大規模な時系列データの特徴自動抽出手法である。様々なパターンを含む時系列データを入力として、時系列データの中から重要だと思われるパターンを発見し、分類・可視化する手法である。

図 2 にソーシャルグラフの変化量を AutoPlait によって分析した結果を示す。上半分のグラフは横軸が映像の時刻 (秒)、縦軸がソーシャルグラフの変化量を、下半分のグラフは横軸が映像の時刻 (秒)、縦軸が発見されたパターンの数、色が塗られている部分がそれぞれのパターンの持続時間を示している。AutoPlait によって 3 種類のパターンが発見され、それぞれのパターンが切り替わる境界が 4 箇所発見されていることがわかる。

#### 4 評価

Sensor-based Regulation Profiler を用いて学習フェーズの抽出ができるかどうかを評価するために評価実験を行った。具体的には、学生 3 人のグループによる問題解決の様子を名刺型センサによってモニタリングした。

図 3 に実験環境の概要を示す。ホワイトボードは USER が議論を行うために設置されている。また、iPad は USER に学習課題を提示するために設置されている。各 USER は利き腕と首からぶら下げた Sensor-based Regulation Profiler Badge を装着している。ホワイトボードに 2 つ、iPad に 1 つのセンサが設置されている。

図 4 に評価実験に対する学習科学の研究者による手動での分析結果を示す。横軸は撮影した映像の時刻 (秒)、縦軸は分析できた要素になっている。68 秒 ~ 1104 秒の間は動画視聴フェーズ、1166 秒 ~ 1888 秒は情報確認・整理フェーズ、1889 秒 ~ 3605 秒は議論フェーズ、3606 秒 ~ 4352 秒は結論フェーズとなっている。図 4 の学習科学の研究者による手動での学習フェーズの抽出と Sensor-based



図 4: 学習科学の研究者による手動でのフェーズ分け結果

表 3: 既存手法と提案手法の学習フェーズ抽出の比較

フェーズ	手動 [秒]	提案手法 [秒]	重複割合 [%]
動画視聴	68 ~ 1104	0 ~ 1075	91.2
情報確認・整理	1166 ~ 1888	1076 ~ 1699	65.6
議論	1889 ~ 3605	1700 ~ 3715	85.2
結論	3606 ~ 4352	3718 ~ 4352	85.0

Regulation Profiler を用いたセンサデータの分析による学習フェーズの抽出を比較した。

#### 4.1 ソーシャルグラフ

図 5 と図 6 に動画視聴フェーズと情報確認・整理フェーズの境界付近のソーシャルグラフを示す。図の左上に撮影した映像の時刻 (秒)、丸が名刺型センサと使用者、矢印が名刺型センサによって検出した赤外線データを示す。USER\_A, USER\_B, USER\_C, iPad, WB\_L, WB\_R はそれぞれ図 3 のセンサ ID (1, 2), (3, 4), (5, 6), 10, 9, 8 を意味する。図 5 と図 6 を比較すると動画視聴フェーズにおいてホワイトボードと iPad のみを検知していたセンサが情報確認・整理フェーズに移行してから複雑なネットワークを検知しているのがわかる。

#### 4.2 学習のフェーズ抽出

図 2 に示したように、この評価実験に対するソーシャルグラフの変化量を AutoPlait によって分析した。表 3 に図 2 と図 4 に示した学習フェーズ分けを比較した結果を示す。表 3 から分かる通り、若干の範囲のずれはあるもの、フェーズの抽出に成功していることが分かる。範囲のずれの要因としては、センサの同期ずれ、データ処理の際の 60 秒のウィンドウ幅、人間が捉えられていない現象によるずれ、センサが捉えることができていない現象によるずれなどが考えられる。また、図 2 では実験の中で一度議論を行った後に再び動画を見直しているフェーズも 1700 秒 ~ 2070 秒として捉えることもできている。

#### 5 おわりに

本稿では、既存の学習環境に簡単に導入できる学習科学の分析を補助するための手法である「Sensor-based Regulation Profiler」が学習のフェーズを定量的かつ自動的に分けられることが示された。現在、様々な学習環境での導入を考えた実証実験を進めている。

#### 参考文献

- [1] Wakisaka, Y., Ohkubo, N., Ara, K., Sato, N., Hayakawa, M., Tsuji, S., Horry, Y., Yano, K. and Moriwaki, N.: Beam-scan sensor node: Reliable sensing of human interactions in organization, *Proceedings of the 6th IEEE International Conference on Networked Sensing Systems (IEEE INSS'09)*, pp. 1-4 (2009).
- [2] Wu, L., Waber, B. N., Aral, S., Brynjolfsson, E. and Pentland, A.: Mining Face-to-Face Interaction Networks using Sociometric Badges: Predicting Productivity in an IT Configuration Task, *Proceedings of the 29th AIS International Conference on Information Systems (AIS ICIS'08)*, pp. 1-19 (2008).
- [3] Oshima, J., Oshima, R. and Fujii, K.: Student Regulation of Collaborative Learning in Multiple Document Integration, *Proceedings of the 11st ISLS International Conference of the Learning Sciences (ISLS ICLS'14)*, pp. 967-971 (2014).
- [4] Matsubara, Y., Sakurai, Y. and Faloutsos, C.: AutoPlait: Automatic Mining of Co-evolving Time Sequences, *Proceedings of the 33rd ACM International Conference on Management of Data (ACM SIGMOD'14)*, pp. 193-204 (2014).

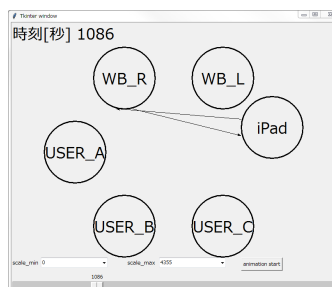


図 5: 動画視聴フェーズのソーシャルグラフ

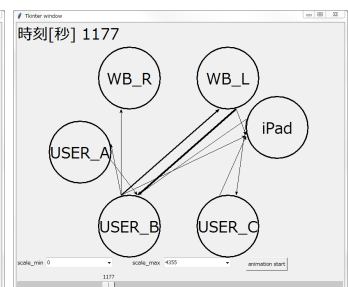


図 6: 情報確認・整理フェーズのソーシャルグラフ