

コラボレーション抽出を目的とする IoT 実現に向けた協調学習分析ツールの基礎評価

山口 隼平[†] 大多和 修介[‡] 大島 律子[‡] 大島 純[‡] 藤橋 卓也^{†‡} 猿渡 俊介^{†‡} 渡辺 尚^{†‡}
[†]大阪大学工学部 [‡]静岡大学大学院総合科学技術研究所 ^{†‡}大阪大学大学院情報科学研究科

1 はじめに

協調学習とは、他者と協調（コラボレーション）しながら、創造的な問題解決に取り組む能力を育成することである。しかしながら、現状の学習科学の分野では定性分析の手法を用いて協調学習を分析しているため、数十人を対象として分析するには人的コストや時間的コストの面で課題がある。このような観点から、本稿では協調学習の分析をサポートすることを目的として、Internet of Things (IoT) 技術を用いて学習者の活動を定量的に分析するとともに、教師が着目すべきポイントを自動抽出する Sensor-based Regulation Profiler を提案する。

2 協調学習の場に対して定量分析ツールを導入するときの課題

協調学習において個人に合った学習活動を提供するためには、個々の学習の様子を定性分析する必要があるため、分析に長けた人物の存在や分析自体の労力を要する。協調学習の場に対して定量分析ツールを導入することで、従来の定性分析に即時性を持たせることができる。導入する定量分析ツールは以下の3つの要件を満たす必要がある。

1 つ目は、「学習環境に簡単に導入できること」である。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、本稿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や MIT の Sociometric Badge [1] が存在する。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 つ目は、「データの時刻同期が取れていること」である。データの時刻同期が取れていることは、本稿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必要となる。本稿では、学習者や学習環境などの様々な対象にセンサが設置されており、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るため、分析の結果が意味をなさないものになってしまう。コラボレーションを抽出するためのセンサとしては、先にも述べたとおりビジネス顕微鏡や Sociometric Badge が存在するが、各センサ間の時刻同期を実現する仕組みは提供されていない。時刻同期の精度としては、最低でもサンプリングレートの10分の1以下の精度が取得できていることが望ましい。例えば、100 Hz でセンサデータを取得している場合には、1 ミリ秒以下での時刻同期を取れていることが求められる。

3 つ目は、「協調学習のフェーズの自動抽出ができること」である。「協調学習のフェーズの自動抽出ができること」は、協調学習における定性分析と定量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。そこで本稿では、協調学習における学習フェーズの自動抽出と学習フェーズ内の情報自動抽出として発話者特定に対象を絞る。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。

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」を提案している [2]。一般的な協調学習における定性分析は、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。Sensor-based Regulation Profiler では、センサを用いたデータ収集、センサ間での高精度な時刻同期、センサデータのデータマイニング技術による分析という3つの仕組みを追加することで、定性分析に求められた労力を削減できる。

3.1 Sensor-based Regulation Profiler Badge

Sensor-based Regulation Profiler Badge は、赤外線センサ・音圧センサ・加速度センサを具備した名刺型センサである。図 1(a) に Sensor-based Regulation Profiler Badge の写真を、図 1(b) に Sensor-based Regulation Profiler Badge のブロック図を示す。センサノードは、電源制御部と CPU センサ部、無線部からなる。電源制御部の特徴として、USB 充電可能なリチウムイオン電池を搭載している。CPU センサ部では、CPU として STMicroelectronics 社の STM32L476 を用いて内部を制御する。センサとしては、赤外線センサ・音圧センサ・加速度センサが搭載されている。音圧センサは 100 Hz 12 bit、加速度センサは 100 Hz 3 軸 12 bit でサンプリングする。赤外線データを用いることで、学習フェーズを区別できる。音圧センサ・加速度センサを用いることで、協調学習中に学習者が発話しているかどうかを読み取ることができる。無線部には、無線同期モジュールが搭載されている。無線同期モジュールは 10 ミリ秒ごとに同期信号を送信して、センサ間での時刻同期を実現する。赤外線データ・音圧データ・加速度データは、メモリカードによって保存できる。FAT32 形式でフォーマットした 32 GB 以下のメモリカードを名刺型センサのスロットに差し込むことで、データが保存される。パソコン上で付属のデータ変換ソフトを用いると、保存したデータを CSV 形式のデータに変換することができる。

図 1(b) に示した RF モジュールである Texas Instruments 社の CC2650 上では、高精度な時刻同期を実現する同時送信型フラッディングプラットフォーム「UNISONet (別名 Choco)」が動作している [3, 4]。同時送信型フラッディングとは、単一の経路を使用して時刻同期パケットを伝搬するのではなく、任意のセンサノードが近隣のセンサノードに対して時刻同期パケットを転送することで、宛先センサノードへと時刻同期パケットを伝搬するデータ配送方式である。各センサノードは、時刻同期パケットを受信すると、バックオフなどの遅延を挟むことなく即座に他のセンサノードに対して時刻同期パケットを転送する。各センサノードが受信・転送を繰り返すことで、ネットワーク全体へ時刻同期パケットが伝搬されると同時に精密な時刻同期が実現できる。

3.2 学習フェーズ抽出

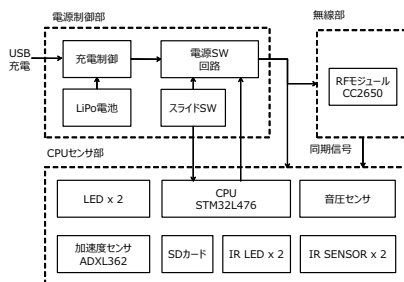
本手法では、名刺型センサから得られる赤外線データをもとにして、学習者やホワイトボードとのネットワークを構築するとともに、学習中のネットワークの変化から、学習フェーズを自動的に分類する。学習中のネットワークの変化は学習フェーズの変遷を表している。協調学習の学習フェーズは、動画視聴、議論、結論の3つに分かれている。学習フェーズが移り変わる時、人は今まで対面していたものから異なる対象への注目が増えたり、多数の対象に注目したりと特徴的な変化が表れる。学習中の特徴的な変化を赤外線データから捉えることで、学習プロセス全体を分析することなく学習フェーズの抽出をするとともに、定量的なデータとして活用する。

学習中のネットワークの変化は、各名刺型センサの赤外線データから得られる隣接行列の変化量をもとにして定量化する。各名刺型センサが記録する赤外線データには、1 秒ごとに検知した名刺型センサの ID が記録されている。データを平滑化するために、一定区間のウィンドウを定めて、ウィンドウ内で各名刺型センサが他の名刺型センサを検知した回数の総和をそれぞれ求める。ウィンドウ幅は 60 秒として、3 秒ごとにウィンドウを移動させて、ある名刺型センサが他の名刺型センサを各ウィンドウ内で何回検知したかを示す隣接行列を作成する。その後、ある時刻の隣接行列と直後の隣接行列について、要素ごとに差の平方を求めて、その総和を学習中のネットワーク変化量として求める。

ネットワークの変化量から各学習フェーズを高速かつ自動的に抽出するために AutoPlait [5] を使用した。AutoPlait は、様々なパターンを含む大規模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特徴を発見するとともに、時系列データのグループ化・グループの可視化ができる手法である。提案手法では、学習中のネットワーク変化量に



(a) 名刺型センサ



(b) ブロック図

図 1: Sensor-based Regulation Profiler Badge




図 2: 時刻同期精度

対して AutoPlait を用いることによって、各学習フェーズを AutoPlait が抽出する各時系列データグループとして発見することができる。具体的には、ネットワーク変化量を時系列に並べたシーケンスデータについて、多階層連鎖モデル (Multi-Level Chain Model: MLCM) に基づいてネットワーク変化量の変化点を発見することで、シーケンスデータ全体を部分シーケンス集合 (セグメント) に分割する。このとき、セグメント内のデータが類似するセグメント同士は、最小記述長 (Minimum Description Length: MDL) に基づくコスト関数にしたがって共通のグループ (レジーム) として割り当てられる。このとき、得られた各レジームを協調学習における各学習フェーズとしてみなすことができる。

3.3 発話者特定

本手法では、各学習者が身につけた名刺型センサから取得できる音圧データおよび加速度データを組み合わせて、学習中の各発言がどの学習者によるものかを特定する。学習中にいずれかの学習者が発話しているとき、各学習者の名刺型センサが音圧の変化を検知する。一方で、発話者が同じであっても発話時の向きや声量によって音圧の変化量の傾向は変わるため、各学習者の名刺型センサから得られる音圧データのみを用いて発話者を完全に特定することは困難となる。本手法では、名刺型センサが取得する音圧データと加速度データを同時に利用して発話者を特定する。

音圧データと加速度データを双方活用して発話者を特定するために、本手法では決定木分析を使用する。決定木分析とは、目的変数と説明変数の関係をツリー構造 (決定木) で表現することで、データ集団を効率的に分類できる手法である。本手法では、目的変数を名刺型センサを身につけていた学習者が発話していたか、説明変数を音圧データ、加速度 x 軸成分、加速度 y 軸成分、加速度 z 軸成分における最大値、最小値、平均、分散の計 16 個とした。

決定木分析のアルゴリズムとしてジニ係数をもとにした CART 法 (Classification and Regression Trees) を使用した。CART 法では、どの説明変数におけるどの値を閾値としてデータを分割するか、不純度を指標として決定する。本稿では、不純度を表す指標としてジニ係数を採用する。ジニ係数の値が 1 に近づくほど悪い分割を、0 に近づくほど良い分割を意味する。したがってジニ係数が 0 に近づくように、各説明変数に対する閾値を繰り返し変更することで、名刺型センサを身につけていた学習者が発話していたかを分類する。

4 評価

3 節で示した Sensor-based Regulation Profiler による時刻同期精度、学習フェーズの自動抽出精度、発話者特定精度を評価するために、名刺型センサを用いた評価実験を行った。

4.1 無線同期性能評価

名刺型センサ間での時刻同期精度の評価を行った。机の上にシンクノードとセンサノード 1 台ずつを近距離で配置して、シンクノードが送信する信号をもとにシンクノードとセンサノード間の時刻のずれを計測した。3.1 節で示したとおり、各センサの無線同期モジュールは 10 ミリ秒ごとに同期信号を送信するものとして、サンプル数は 30003 個とした。

図 2 に、無線同期実験で計測した名刺型センサの時刻同期精度を示す。図 2 の横軸は、計測された時刻同期のずれ、縦軸は度数を示す。図 2 から、同期誤差は $\pm 30 \mu\text{s}$ 以内に抑えられていることが分かる。また、平均値 $-7.7 \mu\text{s}$ 、最小値 $-30 \mu\text{s}$ 、最大値 $17 \mu\text{s}$ が得られた。加速度センサのサンプリングレートは 100 Hz であるため、要求される精度である 1 ミリ秒以下の時刻同期精度を十分に満たしていることが分かる。名刺型センサ間では、定期的な周波数とタイミングを同期することで、同期誤差を常に $\pm 30 \mu\text{s}$ 以内に抑えられるため、時刻同期を保ったまま、複数の名刺型センサによる長時間のセンサデータ記録が可能となる。

4.2 協調学習を対象とした実証実験評価

各学習者の名刺型センサから得られた定量的なデータを用いて、協調学習中の学習者の活動から学習フェーズの自動抽出および発話者特定ができるかどうかを評価するために評価実験を行った。図 3 に実験環境の概要を示す。Sensor-based Regulation Profiler Badge を所持した学生 3 人のグループによる問題解決の様子をモニタリングした。各学生は胸元に Sensor-based Regulation Profiler Badge を装着した。ホワイトボードは、学生の議論を補助するために設置した。iPad は、学生に学習課題を提示するために設置した。




図 3: 協調学習を対象とした実験環境




図 4: AutoPlait による学習フェーズ分類結果




図 5: 学習者ごとの発話者特定精度

学習フェーズの自動抽出精度

図 4 に本評価実験における学習中のネットワーク変化量を AutoPlait によって分析したものを示す。上段は AutoPlait に入力した学習中のネットワーク変化量である。横軸は実験開始からの経過時刻 [秒]、縦軸は正規化した学習中のネットワーク変化量を表している。下段は AutoPlait による分析結果を示している。縦軸は AutoPlait が検出した学習フェーズを表している。学習科学の研究者による手動での学習フェーズの分類では、動画視聴フェーズが 0 秒 ~ 1211 秒、議論フェーズが 1212 秒 ~ 3337 秒、結論フェーズが 3338 秒 ~ 3937 秒と分類された。自動抽出の結果と若干の範囲のずれはあるものの、協調学習プロセス全体からおおよその学習フェーズの自動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、データ処理時の 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。

発話者特定精度

提案手法による発話者特定精度の評価するために、結論フェーズにおける各学習者の音圧データと加速度データを用いて決定木分析を行った。本評価では、協調学習中の結論フェーズに相当する 410 秒のセンサデータを使用して学習データを作成した。具体的には、一定区間のウィンドウを定めて、ウィンドウ内でどの学習者が発話していたかどうかをラベル付ける。ウィンドウ幅は 5 秒として、2.5 秒ごとにウィンドウを移動させて、各ウィンドウ内で名刺型センサを所持していた学習者が発話していたかをラベル付ける。名刺型センサを所持した学習者 1 人あたり 163 個の学習データが得られること、本実験では学習者が 3 人いることから、学習データとして計 489 サンプルを用意した。得られた 489 サンプルを一律に 7:3 でトレーニングデータとテストデータとに分けて、テストデータ使用時の発話者特定精度を評価した。

図 5 に、決定木分析による発話者特定精度を示す。図 5 の横軸は、名刺型センサを身につけた各学習者、縦軸は学習者が発話したときの特定率を示す。ここで、特定率は学習データから一律に 100 回テストデータを選出したときの特定率の平均値を取っている。図 5 から、User 1 発話時の特定率が 81.1%、User 2 発話時の特定率が 84.0%、User 3 発話時の特定率が 68.2%、全ユーザで平均特定率が 77.8% となることが分かった。User 3 の特定率が低下した理由の 1 つとして、User 3 の声量が小さく、平常時の音圧センサ値と発話時の音圧センサ値の差が小さくなったことが考えられる。

5 おわりに

本稿では、協調学習の場に対して定量的に分析する Sensor-based Regulation Profiler Badge の時刻同期精度および学習フェーズの自動抽出精度、学習フェーズ内の発話者特定精度について述べた。現在は、提案手法による学習フェーズの自動抽出精度と発話者特定精度の向上に取り組んでいる。

謝辞

本研究は JSPS 科研費 (JP19H01101, JP19H01714, 16H01817) 及び NTT アクセスサービスシステム研究所の支援の下で行った。

参考文献

- [1] L. Wu, B. N. Waber, S. Aral, E. Brynjolfsson, and A. Pentland, "Mining Face-to-Face Interaction Networks using Sociometric Badges: Predicting Productivity in an IT Configuration Task," Proceedings of AIS ICIS'08, pp.1-19, 2008.
- [2] 山口 隼平, 大和 修介, 大島 律子, 大島 純, 藤橋 卓也, 猿渡 俊介, 渡辺 尚, "コラボレーションを抽出するためのセンサネットワーク実現に向けた時刻同期精度に関する検討," 電子情報通信学会ソサイエティ大会, pp.11, 2019.
- [3] SONAS, "UNISONet," <https://www.sonas.co.jp>.
- [4] M. Suzuki, C. H. Liao, S. Ohara, K. Jinno, and Morikawa, "Wireless-Transparent Sensing," Proceedings of EWSN'17, pp.66-77, 2017.
- [5] Matsubara, Y., Sakurai, Y. and Faloutsos, C., "AutoPlait: Automatic Mining of Co-evolving Time Sequences," Proceedings of the 2014 ACM SIGMOD International Conference on Management of Data, pp.193-204, 2014.