

## 空間 UI における活動ログを用いたグループの協働学習状態の推定

黒宮 寛之\* 陳 彬† 戸上 和正‡ 日高 一郎\* 岡林 桂樹† 山本 義春\*

\* 東京大学大学院教育学研究科 † 株式会社富士通研究所 ‡ 東京大学教育学部附属中等教育学校

### 1 はじめに

グループでコミュニケーションをとりながら課題解決を目指す協働スキル (collaboration skill) は現代の学習者にとって重要なスキルの一つである。一方でどのような協働学習の進め方が学習者の協働スキルを高めるのかについては科学的なエビデンスが不足している。東京大学教育学部附属中等教育学校では協働学習の過程をデータとして蓄積し、様々な学習手法に関する議論を実証的に検証する目的で、富士通研究所の開発した空間 UI システム [1] を導入した。空間 UI システムとは壁や机などの共有スペースにプロジェクトからスクリーンを投影し、センサによってタッチパネルの機能をもたせるシステムである。空間 UI 上で教員は作成した PDF 資料を電子媒体で学習者の机の上に配布できるほか、学習者は電子付箋やノートを机上で作成し成果物を大画面で共有することができる (図 1)。



図 1: 空間 UI を用いた協働学習の様子

本研究の目的は空間 UI 上でのデジタル付箋システムの操作ログから学習者の行動を抽出し、グループ活動の状態を推定するモデルを構築することである。グループの活動状態を機械的に推定することによって授業の評価が定量的かつ容易なものになり、「協調的な行動を促進する授業にはどのような題材が適しているか」あるいは「質の高い協同学習を行うためにはどのような割合で個人作業を含めたほうが良いか」などの課題を実

Group Activity State Estimation in Collaborative Learning with Operation Log in the Creative Digital Spaces

\*Hiroyuki KURUMIYA †Bin CHEN ‡Kazumasa TOGAMI

\*Ichiro HIDAKA †Keiju OKABAYASHI \*Yoshiharu YAMAMOTO

\*Graduate School of Education, The University of Tokyo

†Fujitsu Laboratories Ltd.

‡The University of Tokyo Secondary School

証的に検証することにつながると考えられる。

### 2 関連研究

協働学習中の活動ログを用いてグループの活動状態を推定した研究の一例として Martinez et al. (2011) [2] がある。彼らはグループの活動状態を 3 状態 (collaborative, somewhat collaborative, non-collaborative) に分類し、ベイジアンネットワークとナイーブベイズをモデルとして状態の予測を試みた。精度としては約 65% を達成したが、一方で彼らの研究ではデバイスとしてラップトップ PC を用いており一般的な協働学習のスタイルと乖離がある点は否めない。また予測に使われたモデルが限定的であり十分な予測性能を有していない可能性がある。同様に 2017 年にもオンライン上での協働学習の状態を機械学習を用いて推定する研究が行われている [3] が、未だ空間 UI のようなテーブルトップ型スクリーンのログを用いて学習状態を推定した研究は少ない。

### 3 提案方式

本研究では学習者の状態を静止 (standby)、個人作業 (individual)、協働作業 (collaborative) の 3 つに分け、30 秒間のグループの活動ログからその時のグループの活動状態を推定するモデルを提案する。解析対象とした授業は授業時間 50 分、3 つのグループで行った。学習状態のラベリングについては各グループの作業中の様子を記録したビデオを見ながら 30 秒毎に 2 名の分析者が独立に状態判定を行った。分析者間の判定が一致しなかった箇所についてはさらに第三者に判定してもらい、その結果を学習状態のラベルとして用いた。その結果合計で 294 個のデータが分析に用いられた。

また取得したログは 30 秒間あたりのテーブルへのタッチの数、ペンのストローク回数、付箋の作成回数、付箋の選択回数、付箋の移動回数、付箋の回転・拡大回数、付箋・ストロークの消去回数の 7 つである。学習器にはランダムフォレスト、サポートベクターマシン (SVM)、ナイーブベイズ、線形判別分析 (LDA)、ロジスティック回帰の 5 つを用意し性能を比較した。モデルの学習には Python の scikit-learn パッケージ\*を用いた。

\*<https://scikit-learn.org/>

表 1: 各テーブルの活動状態頻度

	collaborative	individual	standby
table01	75	7	16
table02	68	7	23
table03	67	6	25

モデルの性能指標としては単純な正解率ではなく weighted F1 score を用いた. 本データセットは 2 つ以上のラベルを含み, かつ各ラベルの頻度に偏りがあるのがその理由である (表 1). F1 score は二値分類問題における recall と precision の調和平均であるが, weighted F1 score はこれを各クラスについて計算し, それらをラベルの数で重み付けし平均をとったものである. 本研究ではデータを得られたテーブル単位でグループ分けし, 3-fold の交差検証を行い, それぞれについて計算した weighted F1 score を平均したものを最終的なモデルのスコアとした.

#### 4 評価と考察

表 2 に 3-fold cross validation の結果を示す. 表 2 から本データセットにおいてはランダムフォレストが最も良い分類性能を有していることがわかった. また線形モデルよりもランダムフォレストや SVM などの非線形モデルの性能が高いことから変数と状態の間には非線形な関係があることが推測される.

表 2: モデルと予測精度

model	F1-score
Random Forest	0.799
SVM	0.778
Naive Bayes	0.640
LDA	0.633
Logistic Regression	0.644

グループ 2,3 で得られたデータを学習用, グループ 1 で得られたデータをテスト用として, テストセットにおけるランダムフォレストの分類結果と実際のラベルの対応を表 3 に示した. 表 3 から本モデルは collaborative の分類性能と比較して individual と standly の性能が悪いことが分かる.

ランダムフォレストは分類に寄与した各変数の重要度を算出することができる. 図 2 に各特徴量の重要度を示した. 図 2 から机上へのタッチの頻度, 次いでペンのストローク量が分類に寄与したことがわかった. これらの変数と状態との関係は今後明らかにしていきたい.

表 3: テストセットにおける分類結果

Predicted	collaborative	individual	standby	All
collaborative	66	0	9	75
individual	3	4	0	7
standby	6	0	10	16
All	75	4	19	98

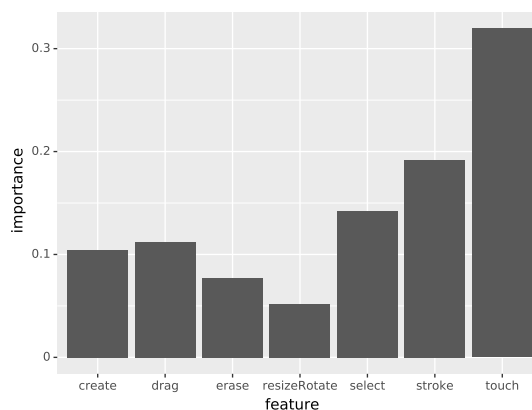


図 2: 各特徴量の分類貢献度

#### 5 まとめ

複数のモデルを比較検討した結果, ランダムフォレストによって机へのタッチ回数や付箋移動の回数などを用いてグループの活動状態 (待機, 個人作業, 協働作業) を約 79% の精度で推定することができた. このモデルを適用することで日常的に授業の状態を記録し, より良い協働学習の統計的な検証を目指したい.

#### 参考文献

- [1] 岡林桂樹, 宇山政志, 由良淳一, 武理一郎. コラボレーションワークを活性化する空間 UI 技術. 電子情報通信学会誌, Vol. 101, No. 5, pp. 510–515, 2018.
- [2] Roberto Martinez, James R Wallace, Judy Kay, and Kalina Yacef. Modelling and identifying collaborative situations in a collocated multi-display groupware setting. In *International Conference on Artificial Intelligence in Education*, pp. 196–204. Springer, 2011.
- [3] Sree Aurovindh Viswanathan and Kurt VanLehn. High accuracy detection of collaboration from log data and superficial speech features. Philadelphia, PA: International Society of the Learning Sciences., 2017.