

受講生の状態推定のための圧力センサを用いた テーブルトップインタフェースの開発

羽山 徹彩^{1,a)} 大館 英隆¹ 石田 直登¹

概要：ラーニング・アナリティックでは大量の学習データの収集が必要であり、そのデータの質が学習者モデルの構築のために重要となる。そのひとつの原因として、教育コンテキストの違った学習データを一緒に解析することが、学習者の適切なモデル構築を困難にするとの指摘もある。そこで、本研究では授業中に学習者が机上で振る舞う行為に着目し、受講中の学習者状態が推定可能なテーブルトップインタフェースを開発した。我々はまず机上圧で検出可能な受講者の6種類の行為を定義し、そして、机上圧を検出可能なテーブル型デバイスを構築し、機械学習を用いてその机上圧から学習者の状態を認識する手法を開発した。

Development of Tabletop Interface with Pressure Sensors for Recognizing Student's In-class Behavior

HAYAMA TESSAI^{1,a)} ODATE HIDETAKA¹ ISHIDA NAOTO¹

1. はじめに

教育の質保証や教育方法の改善という観点から、教育ビッグデータを活用したラーニング・アナリティクスが注目されている。現状の取り組みの多くは、LMS(Learning Management System) やeポートフォリオの学習成果データを大量に収集し分析することで、学習者の達成度評価 [2], [8], 将来的な能力予測 [1], および隠された問題の発見 [3] などの方法が開発されてきた。その一方で、異なる科目やカリキュラムなど教育コンテキストの違った学習データを一緒に解析することが学習者に適応化されたモデル構築を困難にするとの指摘もあり、同じ学習環境下で得られた詳細な学習データを扱うことが必要視されてきている [11]。

これまで、授業中の学習行為までも分析対象とするラーニング・アナリティクスの研究がいくつか取り組まれてきた。例えば、Okuboら [9] は学習者の操作履歴や教材の閲覧履歴を分析し、結果の可視化および相関規則を明らかにして

いる。Parkら [10] は学習中のマウス操作の履歴を分析し、学習達成度を予測したモデル化を試みている。それら研究の多くが受講中の電子教材を対象とし、その操作行為を学習データとして分析してきた。その一方で、受講中の非学習行為も、学習成果に影響を与えているにも関わらず、それら非学習行為を扱った研究はほとんどない。また、Nosuら [7] は脈拍数、呼吸数、指の温度などの生体情報を用いて、学習者の学習時の心理状態の推定を行っている。しかしながら、受講中に生体情報を取得する現状のデバイスを用いることは運用性に難があると考えられる。

そこで、本研究では授業中に学習者が机上で振る舞う行為に着目し、机上圧で学習者の学習状況が認識できるテーブルトップインタフェースの開発を目的として、実施した。受講中の学習者は一般的に、机を前にしており、筆記やテキスト講読などの学習行為の多くを机上で行う。さらに、伏せ寝や手遊びなどの非学習行為においても机上で行うことがある。このような学習者の机上の振舞いを学習データとして、従来の学習データに加えた分析ができれば、授業に取り組む態度や学習方法に対しても問題点や改善点を見出すことが可能になる。

¹ 長岡技術科学大学
Nagaoka University of Technology, 1603-1, Kamitomioka Nagaoka, Niigata, Japan

^{a)} t-hayama@kjs.nagaokaut.ac.jp

Width: 60-cm(11 pieces of plates × 5 cm), Depth: 40-cm(7 pieces of plates × 5 cm)

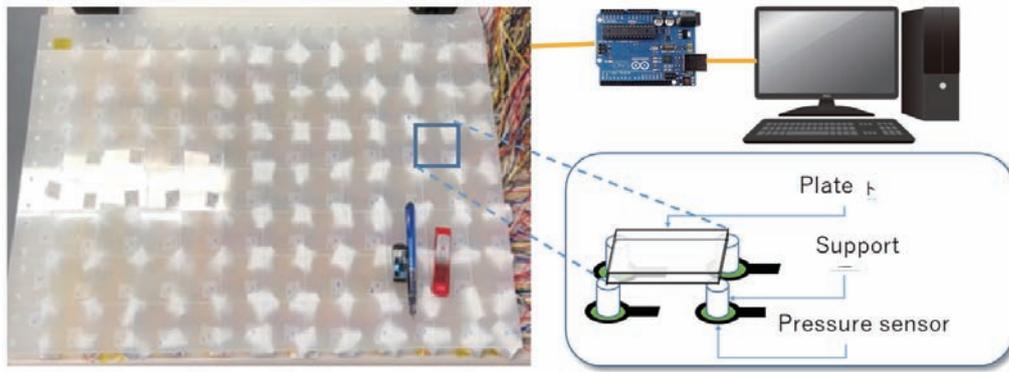


図 1 開発したテーブルトップインターフェース

2. システム実装

我々は机上圧から学習者の受講中の行為を認識するためのテーブルトップシステムを実装した。本章ではまず、本研究で対象とする受講中の学習者の振舞いについて 2.1 節で述べ、開発したテーブルトップシステムの概要、およびテーブルトップの机上圧から学習者の振舞い認識について、それぞれ 2.2 節、および 2.3 節で述べる。

2.1 対象とする受講中の学習者の振舞い

我々は受講のなかで学習者が机の前で振る舞っている行為を明確化するために、大学生 4 名へのインタビュー調査を行った。その結果、受講中の学習者の振舞いを以下の 6 種類に分類した。

- 前方の目視行為
- 筆記行為
- 寝る行為
- 飲食行為
- 資料閲覧行為
- 携帯端末操作行為

本研究ではテーブルトップインターフェースの机上圧から学習者の振舞いを推定する。そのため、その机上圧データから推定可能な学習者の状態だけを推定対象として扱うこととする。つまり、受講中の学習者の振舞いの各分類項目のなかで、テーブル表面に接触した行為に限定する。例えば、「前方の目視行為」や「寝る行為」では手や腕の一部がテーブルに接触しながら前方へ眼を向けている行為や伏せながら寝ている行為が挙げられる。「飲食行為」ではペットボトルに入った飲み物がテーブルに置かれている状態から飲んで、再びテーブルに置くという一連の行為が挙げられる。また「筆記行為」や「資料閲覧行為」ではテーブルにノートやテキストを置いた状態で、筆記する行為やテキストを講読し捲る行為が挙げられる。「携帯端末操作行為」ではスマートフォンをテーブルに置いた状態で、文

字入力やスワイプ操作などのタッチパネルを操作する行為が挙げられる。以上の受講中の学習者の行為に対し、それが学習のためかそうでないかの判別は机上圧から判断が難しいため、本研究では対象としないこととする。例えば、前方の目視行為が学習内容を考えての行為かそうでないかは机上圧から判断することが難しい。筆記行為はその筆記内容が学習内容に関するものかそうでないかを机上圧から判断することが難しい。

各授業や各コースを通して学習者たちの一連の振舞いを分析可能にすることで、学習成果が高い学習者たちとそうでない学習者たちの受講中の取り組み方の特徴が明らかにできる。例えば、成績が優良な学習者たちがメモしたり、前方に注視したりする行為とタイミングを、それ以外の学習者たちが取り組んでいないことが判明すれば、その異なる取り組み方が学習効果の違いを作り出している可能性がある。そのような取り組み方の特徴を検出できれば、学習成果が高くない学習者に対し、受講中の効果的な取り組み方を適切に教授できるシステムの実現が可能といえる。

2.2 テーブルトップデバイスの概要

本研究では図 1 に示すような、テーブル型のデバイス上に置かれた物の重さと位置を検出できるデバイスを開発した。開発したテーブルトップデバイスの大きさは日本の教室で一般的に使用されている机 (図 2) と同じサイズの 60cm × 40cm とした。

本テーブルトップデバイスでは 5cm² の正方形のモジュール 77 個から構成されている。各モジュールの角にはそれを支えるサポートがあり、各サポートの下には圧力センサーが取り付けられている。各モジュールに置かれた物の重さを、各サポートの下の圧力センサーでそれぞれ検知される。各モジュールで検知された圧力値は、0.04 秒の間隔で逐次収集され、接続された情報端末機器に送信される。そのため、テーブルデバイス上に対象物が置かれた場合には、その対象物が置かれたプレートの位置とその重みを、



図 2 日本の学校にある一般的な教室机

ほぼ実時間で検出することができる。

本テーブルトップデバイスで検出可能な重みとして、2.1節で述べた対象とする学習者の振舞いの識別に必要なスマートフォンの重さに基づき、130gを最小基準とした。本テーブルトップデバイスで、その重さを検出し易くするために、サポートの重みで調節を行った。図3に、本テーブルトップデバイスで検出された圧力分布のヒートマップ図を示す。

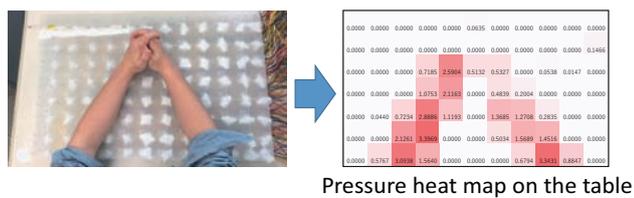


図 3 テーブルトップデバイスで検知された圧力分布のヒートマップ図

2.3 机上圧から学習者の振舞い認識

開発したテーブルトップデバイスから得られた圧力値から、機械学習手法を用いることで学習者の振舞いを認識する手法を開発する。本研究で対象とする学習者の振舞いではそのテーブルトップとの接触面の圧力と形状、およびその時間的変化に影響を与える。そこで、本研究では認識対象が影響を与えるテーブルトップの圧力値を捉えるために、以下の3種類の特徴量を算出し、機械学習によって分類モデルを開発する。

- 各フレームにおける圧力値の基本的な統計情報: 最大の重み値, 最小の重み値, 最大と最小の重み値の差, 平均の重み値, および重み値の分散を用いる。
- 各フレームにおける圧力が掛かる領域の形状: フレームごとの圧力分布を画像化し, Huの画像モーメント[4]の7変数を用いる。Huの画像モーメントはモノカラー画像の形状の特徴を7種類の変数で表現する方法である。
- 期間内の類似フレームの繰返し: 数秒間のなかで類似するフレームが出現する数, およびその累積時間を用

いる。

各フレームにおける圧力値の基本的な統計情報, および圧力が掛かる領域の形状は机上圧センサーを用いた従来研究において, ユーザ行動認識のために用いられてきた[7][8]。本研究ではその基本的な統計情報として, 5秒間の1秒間隔のフレーム5枚を扱うこととした。Huの画像モーメントではモノカラー画像を処理対象とするため, テーブルトップの圧力値の大きさを扱うことができない。そこで, 本研究では圧力値を3つのレベルに分け, そのレベルの識別値ごとにモノカラー画像を生成し, Huの画像モーメントに適用することを行う。ノートへの筆記およびスマートフォン操作は一般的に筆記用具および指動作による繰返し動作で特徴付けられる。そこで, 本研究では1秒間および3秒間で類似するフレームの最多数とその累積時間の特徴量として用いる。

以上より, 本研究の机上圧から学習者の振舞い認識では, 「各フレームにおける圧力値の基本的な統計情報」として25種類の特徴量, 「圧力値の形状」として21種類の特徴量, および「期間内の類似フレームの繰返し」として4個の特徴量をそれぞれ用いる。これら特徴量は各フレームごとに算出し, k-NN(Nearest Neighbor Algorithm), Random Forest, およびSVM(Support Vector Machine)の機械学習手法に適用し, 受講中の学習者の振舞いのひとつに分類する。

3. 評価

本研究では開発してきたテーブルトップインタフェースに対し, 学習者の状況がどの程度認識できるかの機能評価を行った。そのために, まず機械学習手法に適用するためのデータセットの作成を行い, それをもとに学習者の振舞いの分類精度を確認した。本章では本実験の設定, および結果と考察について, それぞれ3.1節および3.2節で述べる。

3.1 設定

機械学習手法に適用するためのデータセットを用意するために, まず大学生9名に対し, テーブルトップインタフェースを用いて受講中の振舞いの行為を実演させ, 机上圧データを収集した。そして, それら机上圧データの特徴量に変換し, 学習者の振舞いの分類ラベルを付与することでサンプルを生成した。

本研究のデータセット作成は図4に示すような環境で実施された。3つのディスプレイは講義動画が放映され, 学習者が様々な角度で聴講することを想定した机上圧データを取得できるようにするため, 異なる方向に配置された。

机上圧データを収集するために, 参加者が実施した手順を以下に示す。

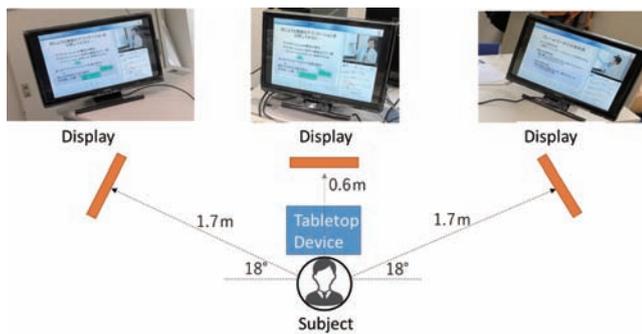


図 4 本研究のデータセット作成の環境

1. 6 分間、テーブルデバイスに接触しながら講義動画を視聴する。
2. 5 分間、テーブルデバイス上のノートに講義動画の内容のメモをとる。
3. 5 分間、テーブルデバイス上の本を講読する。
4. 5 分間、テーブルデバイス上で伏せ寝する。
5. 5 分間、テーブルデバイス上でペットボトルの飲み物を 10 回飲む。
6. 5 分間、テーブルデバイス上に置いているスマートフォンの操作を行う。

参加者は各手順において、行為を切り替えるタイミングが与えられた。実施項目 1 では 3 つのディスプレイの講義動画に対し、2 分ごとに切り替えて視聴することが指示された。実施項目 2 では 1 分ごとにノートのメモする位置が指示され、多様な筆記の圧力位置のデータを得られるようにした。実施項目 3 では本の講読するページを 1 分ごとに指示され、本の捲る行為の圧力データを得られるようにした。実施項目 6 ではスマートフォンで情報検索、およびメール作成のタスクが指示され、多様なスマートフォン操作が得られるようにした。図 5 に、参加者が実施している様子を示す。

テーブルトップデバイスに送られる机上圧データには参加者の指示を与えるタイミングで、対応する分類項目のラベルが付与され、PC に保存された。すべてのデータが収集できたのち、圧力値が検出されなかったフレームのデータを除去し、特徴量に変換することで、各分類のサンプルが含まれたデータセットを作成した。表 1 に、本研究で作成されたデータセットの分類項目ごとのサンプル数を示す。

本研究の評価方法には、kNN, Random Forest, SVM の機械学習に対し、k-分割交差検定が用いられた。その認識精度の比較には、式 (1)-(3) に示すような F-measure, Precision, Recall が使用された。k-分割交差検定では参加者 9 名のデータセットのため、1 名分のデータをテストデータ、残りの分を学習データとした 9 分割で精度を算出し、その平均を用いた。

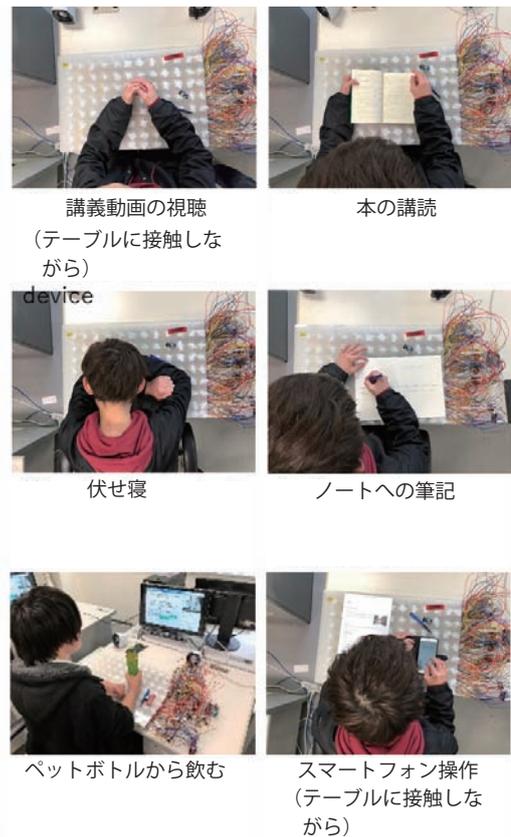


図 5 本研究のデータセット作成の様子

$$F\text{-measure} = \frac{2 * Precision * Recall}{Precision + Recall} \quad (1)$$

$$Precision = 100 * \frac{TP}{TP + FP} \quad (2)$$

$$Recall = 100 * \frac{TP}{TP + FN} \quad (3)$$

ここで、TP, FP, TN, および FN は、真陽性、偽陽性、真陰性、および偽陰性のデータのサンプル数をそれぞれ示す。

3.2 結果と考察

開発デバイスで作成したデータセットを用いて、3 種類の機械学習手法ごとに提案手法の学習者状態の分類精度を求めた。その結果を表 2 に示す。

SVM を用いた提案手法では F-measure が 66.69% の分類精度が達成された。その結果は k-NN とランダムフォレストを用いた方法の 61.57% および 61.07% の F-measure の値よりも、高い結果であった。この理由として、本評価で使用したデータセットには参加者ごとのテーブルトップに掛かる圧力や姿勢にばらつきがあり、それを補うほどの十分なサンプルが含まれていなかったためと思われる。そのため、他の 2 つよりも汎化能力が高い SVM を用いた提案手法が他の 2 つの機械学習を適用した場合よりも、有効であったと考えられる。

次に、提案手法で検出された分類クラスは実際の分類ク

表 1 本実験の機械学習に用いたデータセットのサンプル数

受講中の学習者の振舞い	講義動画の視聴	本の講読	伏せ寝	ノートへの執筆	ペットボトルからの飲食	スマートフォン操作
サンプル数	81,385	36,549	78,860	91,209	39,515	68,854

表 2 機械学習による学習者の状態の分類精度の結果

	F-measure	Precision	Recall
NN(k=30)	61.57	64.55	62.20
Random Forest	61.07	64.37	62.12
SVM	66.69	69.39	68.00

ラスのいずれが分類されているのかを確認する。そのために、表 3 に示す、分類精度 75.54% の SVM を用いた提案手法による混同行列をもとに考察する。

分類クラス“伏せ寝”に分類された結果は 99.85% と高い精度であった。一方で、分類クラス“ペットボトルから飲む”および“スマートフォン操作”の分類結果はそれぞれ、56.52% および 58.17% と低い精度であった。この結果に含まれる誤分類では、分類クラス“ペットボトルから飲む”は“講義動画の視聴”および“スマートフォン操作”に対し、それぞれ 15.42% および 11.79% と高い割合で誤って分類されていた。この誤分類の原因として、両分類クラス間では圧力の大きさや領域が類似し、ペットボトルが圧力から識別できなかつたためと考えられる。分類クラス“スマートフォン操作”に分類された結果は分類クラス“講義動画の視聴”に 34.88% と高い割合で誤分類されていた。この誤分類の原因として、スマートフォン操作に掛かる程度の圧力とその形状を適切に識別できなかつたためと考えられる。また分類クラス“本の講読”は“スマートフォン操作”および“ノートへの筆記”に、17.41% および 18.93% と高い割合で誤分類されていた。この誤分類の原因に関しても、両分類クラス間の圧力の大きさやその形状の違いが適切に認識できなかつたためと考えられる。つまり、いずれの誤認識の原因も、小さな圧力を正確に取得し、識別に利用することが難しかった場合が今回のデータセットに含まれていたためと考えられる。

次に、提案手法で採用した特徴量の有効性を確認するために、表 4 のように、分類結果 F-measure 67.6% の Random Forest を用いて、特徴量の重要度を算出した。

提案手法で採用したすべての特徴量には重要度が付与されていた。そのため、本研究で提案した特徴量はすべてが分類に貢献していたため、有効であったといえる。そのなかで、圧力データの基本的な統計情報を用いた特徴量においては、時間が経過したデータよりも、直近のデータの方が重要度の高い傾向にあった。圧力が掛かる領域の形状に関する特徴量においては、大きな圧力値で識別したモノクロ画像よりも小さな圧力値で識別したモノクロ画像を用いた方が重要度が高かった。類似フレームの繰返しに関する特徴量においては、1 秒間の繰返しフレーム数のその累

積時間に比べ、5 秒間の繰返しフレーム数とその累積時間の方が重要度が高かった。

以上より、本提案手法の認識率を改善するためには、特徴量選択において以下の 3 点を考慮することが有効であると考えられる。

- より直近の圧力フレームの基本的な統計情報に関する特徴量を用いること
- より小さな圧力が掛かる領域の形状に関する特徴量を用いること
- より長い期間で繰返し動作に関する特徴量を用いること

4. さいごに

ラーニング・アナリティクスでは学習者に適応した学習モデル構築のために、同じ学習環境下で得られた詳細な学習データを扱うことが必要視されてきた。本研究では授業中に学習者が机上で振る舞う行為に着目し、机上圧で学習者の学習状況が認識できるテーブルトップインタフェースを開発した。そのために、我々はまず机上圧で検出可能な受講者の 6 種類の行為を検討し、認識対象を明確にした。そして、机上圧を検出可能なテーブル型デバイスを構築し、機械学習を用いてその机上圧から学習者の状態を認識する手法を開発した。評価実験では開発してきたテーブルトップインタフェースに対し、学習者の状況がどの程度認識できるかの機能評価を行った。我々はまず機械学習手法に用いるデータセットを大学生 9 名によって作成し、それを使用し、kNN, Random Forest, SVM の機械学習手法の分類精度を比較した。その結果、SVM を用いた提案手法が F-measure 66.69% の認識精度を達成し、他の方法よりも高い結果が得られた。

今後の課題としては、本研究で機械学習に適用した特徴量を更に検討し、認識精度を高めること、およびデータセットを増やし再評価することが挙げられる。今回の評価実験により、基本的な統計情報、圧力が掛かる領域の形状、繰返し動作に関する特徴量を用いて有効性を確認した。その一方で、それら特徴量を精緻に設定することで、認識精度を改善する可能性が示せた。今後はそれら特徴量の最適化に努めたい。また今回は参加者 9 名が作成したデータセットを用いたが、その参加者を追加したデータセットを作成し評価することでデータセットの妥当性も検証したい。今後の進展としては、本システムを eラーニング授業に適用し、その学習データ分析を行っていきたい。

表 3 SVM を用いた提案手法による混同行列 (分類精度 75.54%)

		検出されたクラス					
		ペットボトル から飲む	講義動画 の視聴	ノートへ の筆記	本の講読	伏せ寝	スマートフォン 操作
実際の クラス	ペットボトルから飲む	56.52	0.24	0.22	0.68	0.03	0.35
	講義動画の視聴	15.42	80.49	1.92	0.22	0.00	34.88
	ノートへの筆記	6.18	0.30	79.94	18.93	0.04	6.17
	本の講読	8.91	0.04	8.90	79.87	0.00	0.43
	伏せ寝	1.18	1.53	0.12	0.00	99.85	0.00
	スマートフォン操作	11.79	17.41	8.90	0.29	0.08	58.17

参考文献

- [1] M. H. Abdous, W. He and C. Yen: “Using Data Mining for Predicting Relationships between Online Question Theme and Final Grade”, Educational Technology & Society, Vo.15 (3), p77-88 (2012).
- [2] L. Ali, M. Hatala, D. Ga?evi?, and J. Jovanovi: “A qualitative evaluation of evolution of a learning analytics tool”, Computers & Education , Volume 58 (1), 2012.
- [3] K. Dejeager, F. Goethals, A. Giangreco, L. Mola and B. Baesens: “Gaining insight into student satisfaction using comprehensible data mining techniques”, European Journal of Operational Research, Vol.218 (2), pp.548-562 (2012).
- [4] C. Holzmann and A. Hader: “Towards tabletop interaction with everyday artifacts via pressure imaging”. In Proceedings of the fourth international conference on Tangible, embedded, and embodied interaction (TEI’10), pp.77-84 (2010).
- [5] M. K. Hu: “Visual Pattern Recognition by Moment Invariants”, IRE Trans. Info. Theory, Vol. IT-8, pp.179–187 (1962).
- [6] K. Murao, J. Imai, T. Terada, and M. Tsukamoto: “Activity Recognition and User Identification based on Tabletop Activities with Load Cells”, Journal of Information Processing, Vol. 25, p. 59-66 (2017).
- [7] K. Nosu and T. Kurokawa. “A multi-modal emotion-diagnosis system to support e-learning”, Proc. 1st International Conf. on Innovative Computing, Information and Control, vol.2, pp.274-278 (2006).
- [8] 緒方 広明, 殷 成久, 毛利 考佑, 大井 京, 島田 敬士, 大久保 文哉, 山田 政寛, 小島 健太郎. 教育ビッグデータの利活用に向けた学習ログの蓄積と分析, 教育システム情報学会誌, Vol.33(2), pp.58-66 (2016).
- [9] Okubo, F., Hirokawa, S., Oi, M., Shimada, A., Kojima, K., Yamada, M., and Ogata, H.. Learning activity features of high performance students. CEUR Workshop Proceedings, Vol.1601, 28-33 (2016).
- [10] J. Park, K. Denaro, F. Rodriguez, P. Smyth and M. Warschauer, “Detecting changes in student behavior from clickstream data”, Proc. 7th International Learning Analytics and Knowledge (LAK2017), pp.21-30 (2017).
- [11] 山川 修, 組織を越えた Learning Analytics の可能性, コンピュータ&エデュケーション, Vol.38, p. 55-61 (2015).

表 4 Random Forest の特徴量の重要度 (分類結果 F-measure 67.6%)

基本統計量を用いた特徴		圧力領域の形状に関する特徴		繰返し動作に関する特徴	
特徴	重要度	特徴	重要度	特徴	重要度
Min. (正時間)	0.1642	hu1 (小圧力のモノカラー画像)	0.0413	類似フレームの累積時間 (1 秒間)	0.0013
Max. (正時間)	0.0641	hu2 (小圧力のモノカラー画像)	0.0138	類似フレーム数 (1 秒間)	0.0016
Mean. (正時間)	0.0687	hu3 (小圧力のモノカラー画像)	0.0097	類似フレームの累積時間 (5 秒間)	0.0018
Var. (正時間)	0.0330	hu4 (小圧力のモノカラー画像)	0.0391	類似フレーム数 (5 秒間)	0.0155
Dif. (正時間)	0.0300	hu5 (小圧力のモノカラー画像)	0.0200		
Min. (1 秒前)	0.0364	hu6 (小圧力のモノカラー画像)	0.0162		
Max. (1 秒前)	0.0547	hu7 (小圧力のモノカラー画像)	0.0057		
Mean. (1 秒前)	0.0374	hu1 (中圧力のモノカラー画像)	0.0086		
Var. (1 秒前)	0.0330	hu2 (中圧力のモノカラー画像)	0.0155		
Dif. (1 秒前)	0.0303	hu3 (中圧力のモノカラー画像)	0.0032		
Min. (2 秒前)	0.0217	hu4 (中圧力のモノカラー画像)	0.0023		
Max. (2 秒前)	0.0307	hu5 (中圧力のモノカラー画像)	0.0127		
Mean. (2 秒前)	0.0265	hu6 (中圧力のモノカラー画像)	0.0049		
Var. (2 秒前)	0.0035	hu7 (中圧力のモノカラー画像)	0.0089		
Dif. (2 秒前)	0.0068	hu1 (大圧力のモノカラー画像)	0.0051		
Min. (3 秒前)	0.0025	hu2 (大圧力のモノカラー画像)	0.0024		
Max. (3 秒前)	0.0023	hu3 (大圧力のモノカラー画像)	0.0020		
Mean. (3 秒前)	0.0027	hu4 (大圧力のモノカラー画像)	0.0026		
Var. (3 秒前)	0.0025	hu5 (大圧力のモノカラー画像)	0.0026		
Dif. (3 秒前)	0.0230	hu6 (大圧力のモノカラー画像)	0.0141		
Min. (4 秒前)	0.0251	hu7 (大圧力のモノカラー画像)	0.0016		
Max. (4 秒前)	0.0118				
Mean. (4 秒前)	0.0076				
Var. (4 秒前)	0.0098				
Dif. (4 秒前)	0.0061				