

教師なし機械学習を用いたオンライン試験における問題行為 検知手法の提案

高江洲 舟^{1,a)} 渡名喜 瑞稀² 川越 響² 利光 能直² 高山 眞樹² 齋藤 孝道¹

概要: 新型コロナウイルス感染拡大の影響で、学校での集合教育が難しくなっている。そのため、インターネットを利用したオンライン試験の需要が高まっている。しかし、オンライン試験では、受験者による問題行為が比較的容易に行えてしまうといった課題がある。本論文では、この課題への対処として、問題行為の検知を試みる。現在様々な手法が提案されているが、本論文では、受験者のブラウザ上の挙動を取得して問題行為検知をする手法を提案する。具体的には、オンライン試験のページに JavaScript を埋め込んで取得した情報を利用し、教師なし機械学習を用いた手法で問題行為検知を行った。そして、問題行為をしたと判定された受験者に聞き取り調査を行った。その後、問題行為に共通した挙動を特定するため、ランダムフォレストを用いて問題行為検知に重要な特徴量の特定を行った。その結果、問題をフォーカスした時間と問題行為検知との間に相関があることが判明した。

A Method for Detecting Problematic Behavior in Online Examinations Using Unsupervised Machine Learning

1. はじめに

新型コロナウイルス感染拡大の影響で、大学ではオンラインでの授業が中心となった。また、オンラインのみで学生の評価を行わなければならないケースもあり、Web 上で実施できるオンライン試験の需要が高まった。オンライン試験では、試験監督者が直接受験者の監視を行うことはできない。それ故に、受験者が資料のカニングや他者との相談などの問題行為をすることが可能である。よって試験の妥当性が損なわれる。

問題行為を抑止するために、PC のカメラを利用して問題行為を検知するシステムの開発が進められている [1]。しかし、PC カメラで監視することに対して、プライバシーの侵害ではないかといった意見もある。また、PC カメラがない場合、当該手法が適用できない。

本論文では、Web ブラウザ上で取得できる情報のみで、問題行為の検知を試みた。Web ブラウザ上で取得できる情報とは、受験者のマウスの動きやスクロール、

クリックなど JavaScript を用いて取得できる情報である。

実験に使用したデータは、107 名の学生に 6 回のオンライン試験を受験してもらうことにより収集した。その際、問題行為検知のための情報収集を行っていることを学生に了承を得た上で実験を行った。

問題行為をした受験者の推定は、様々な分野での異常検知で成果が出ている教師なし機械学習を用いた [2][3]。

問題行為者の特定については、問題行為をした者に名乗り出るように試験後アンケートを行った。また、問題行為をしたと推定された受験者に対して、試験中に問題行為をしたかの聞き取り調査を個別に行うことにより実験の評価を行った。本論文の手法により、問題行為をした受験者を 3 人特定することができた。

2. 関連知識

2.1 教師なし機械学習

機械学習の分類として、教師あり学習・教師なし学習・強化学習の 3 種類が挙げられる。教師なし学習は、学習時に用いる学習データに正解ラベルを与えずに学習させる手法である。この手法は、データのグループ分け（クラスタリング）や情報の要約（次元圧縮）などに活用され、活用

¹ 明治大学
Meiji University

² 明治大学大学院
Graduate School of Meiji University

a) ee187039@meiji.ac.jp

法に異常検知がある。異常検知とは、正常な状態を表現したモデルの中から逸脱したものを異常と判断することである。

南里ら [4] は、セキュリティ分野における映像監視や老人介護モニタリングシステムにおいて、教師なし学習を利用することで複数人の歩行者の中での転ぶ動作を異常動作として検出し、手法の有効性を示した。

今回は、この教師なし学習を複数利用することで問題行為受験者の特定を試みた。

本論文で用いた異常検知アルゴリズムを以下に示す。

2.1.1 Isolation Forest

Isolation Forest (以降、IF と呼ぶ) とは、iTree をアンサンブル学習し異常検知するアルゴリズムである。iTree とは、決定木と同様にデータと特徴量をサンプリングして作った木のことである。異常データは、木の浅い段階で分割される確率が高いという考えのもと異常検知を行なっている。

IF には、計算コストが少ないことや小さなデータセットにも適応できるなどがメリットとしてある [5]。

2.1.2 Local Outlier Factor

Local Outlier Factor (以降、LOF と呼ぶ) とは、あるデータの局所の密度を計算することで外れ値 (異常) を発見するものである。データの局所とは k 個の最近傍で与えられ、それらの距離によって密度が推定される。そして、それぞれの密度を計算し他の数値よりも密度が小さい点が外れ値だと考えられる。

LOF には、外れ値検出の精度が高いといったメリットがある [6]。

2.1.3 One Class Support Vector Machine

One Class Support Vector Machine (以降、OC-SVM と呼ぶ) とは、SVM を応用した外れ値 (異常) を検出するアルゴリズムである。SVM とは、機械学習の分類アルゴリズムである。それを 1 クラス分類に応用することで、正常データと異常データに分類して異常検知を行なっている。

OC-SVM は、異常が少ないデータで有効な外れ値検出の手法である [7]。

2.2 ランダムフォレスト

ランダムフォレストとは、決定木をアンサンブル学習した教師あり機械学習アルゴリズムである。決定木とは、分類木と回帰木を組み合わせたもので、樹形図によってデータ分析する手法である。アンサンブル学習とは、別々の決定木の結果を平均することで単独より優れた分析を行うことである。ランダムフォレストには、過学習がないことや学習速度が速いことがメリットとして挙げられる。

また、ランダムフォレストを用いることで特徴量の重要度を算出することができる。本論文では、ランダムフォレストで異常度の高かった受験者や問題行為を行った受験者

に正解ラベルを付与することにより、問題行為と相関のある特徴点を算出した。

3. 実験データ

本節では、オンライン試験での問題行為検出の実験を行うにあたり、使用した実験データについて説明する。

3.1 オンライン試験の形式

オンライン試験は、対象となる 107 名の学生に対して行なった。学生には、当該オンライン試験は、授業の評価に関わることを周知した上で行った。さらに、問題行為の検知を目的とした情報を収集していることに了承してもらった上で試験を実施した。オンライン試験の日付や内容の詳細については、受験者の特定を避けるため本論文では明らかにしない。

実施形態は、Web ブラウザ上で行うオンライン試験で、全 6 回の小テストを行なった。それぞれの小テストは異なる試験問題を採用している。各回、問題は全部で 10 問あり、全て 5 択の選択形式になっている。また、問題は 10 問全て 1 ページに表示している。

受験者に禁止した事項を以下に示す。これらを行なったものは問題行為として見なす旨を伝えている。

- 教科書や参考 PDF などの閲覧
- 試験中の他の Web ページの閲覧
- 他受験者、第三者との会話、相談
- 本人以外による受験

また、他の Web サイトや PDF を閲覧することを防ぐ目的で、ウィンドウサイズを最大にして受験するように注意事項に記載した。

3.2 実験データの採取方法

本論文では実験を行うにあたり、オンライン試験のページに JavaScript を埋め込み、オンライン試験受験者のブラウザ上の挙動を取得した。本節では、実験データの採取方法を詳しく説明する。データの採取システム全体図を以下の図 1 に、受験者のテスト画面遷移図を図 2 に示す。

実験を行うにあたり、問題配信サーバと情報収集サーバの 2 つのサーバを用意した。受験者は、問題配信サーバから問題準備ページを受け取り、「受験開始」のボタンを押すことでテストが開始される (図 1 の①, ②)。

そして、テストが開始されたと同時に情報収集サーバから行動収集用の JavaScript がダウンロードされ行動収集が開始する (図 1 の③, ④)。

その時に、問題準備ページの URL をリファラで取得し、URL の最後のファイル名のみを抽出した。そして、それをデータベースのテーブル名として利用した。自動的にデータベースに保存する際に、全受験者が同じであること・データセットごとにテーブル名が変化することが必要だっ

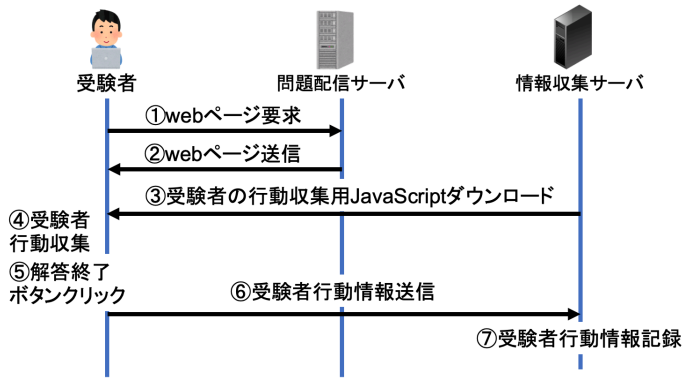


図 1 実験データの採取の全体図




図 2 テスト画面の遷移図

たためにこの方法をとった。

その後、受験者が問題を解き終えページ下部の「次へ」のボタンを押すと、解答を終了するか確認するページに移動する。そこで、「終了する」というボタンを押すことで受験者の行動情報が送信され、データベースに記録される(図1の⑤, ⑥, ⑦)。

3.3 JavaScript で採取した実験データの種類

ここでは、オンライン試験のページに JavaScript を埋め込み採取したデータを以下に示す。

- 問題ページ全体で取得した特徴点
 - ページ上をクリックした回数やマウスがページから離れた回数など問題ページ全体で取得した特徴点。特徴点の詳細を表 1 に示す。また、その中で表内で印をつけたいくつの特徴点について以下で説明する。
 - － スリープした総時間
 - スリープとは、スクロール・マウス操作・キーボード操作がされない状態のことである。この特徴点は、スリープされている時間を合計したものである。
 - － 連続して 1~20 分以上スリープした回数 (1 分刻み)
 - 例えば、連続して 3 分スリープされたら、1 分以上・

2 分以上・3 分以上でスリープした回数でカウントが増える。このように 1 分刻みで連続してスリープされた回数をカウントする特徴点である。

- － ページ領域を表示した回数 (10 %刻み)
 - ページ全体を 10 個に分割する。それから、どこのページ領域でリロード・スクロールなどが行われたかその回数をカウントする特徴点である。
- － 画面がフォーカス外れていた総時間
 - フォーカスとは、そのウィンドウが選択されている状態のことである。
- 問題ごとに取得した特徴点
 - 各設問をクリックした回数や各設問の解答を最後に編集した時刻など問題ごとに取得した特徴点。特徴点の詳細を表 2 に示す。

表 1 問題ページ全体で取得した特徴点

特徴点
ユーザネーム (こちらで指定)
ページの表示時間
ページ上をクリックした回数
スリープした総時間*
連続して 1~20 分以上スリープした回数 (1 分刻み) *
ページ領域を表示した回数 (10 %刻み) *
ページ内のテキストがコピーされた回数
テキストがペーストされた回数
画面がフォーカス外れていた総時間*
画面からフォーカスが外れた回数
問題ページ上からマウスが離れた総時間
問題ページ上からマウスが離れた回数
スクリーンの幅
スクリーンの高さ
ウィンドウの幅
ウィンドウの高さ
ウィンドウサイズを変更した回数

表 2 問題ごとに取得した特徴点

特徴点
初めてフォーカスした時刻
最後にフォーカスした時刻
初めて解答を編集した時刻
最後に解答を編集した時刻
フォーカスした回数
編集した回数

3.4 データセットの作成

採取した実験データを用いてデータセットの作成を行う。データセットは、JavaScript で採取したデータとオンライン試験の受験データを、受験者の識別子をもとに結合して作成した。オンライン試験の受験データの詳細を表 3

表 3 オンライン試験の受験データ

特徴点
開始日時
受験完了日時
所要時間
試験結果
問題ごとの正解判定

に示す。

今回、試験結果・受験完了日時・開始日時など問題行為と関係ないと考えたものは、データセットから除外した。機械学習で使用した特徴点の詳細を表 4 に示す。

表 4 機械学習で使用した特徴点

	特徴点
テスト全体の特徴点	ページの表示時間 ページ内をクリックした回数 スリープした総時間 1~20 分以上スリープした回数 ページ領域を表示した回数 (10 % 刻み) ページ内のテキストがコピーされた回数 テキストがペーストされた回数 画面がフォーカスされていない総時間 画面からフォーカスが外れた回数 画面にマウスがなかった総時間 画面からマウスが離れた回数 スクリーンの幅 スクリーンの高さ ウィンドウの幅 ウィンドウの高さ ウィンドウサイズを変更した回数
問題ごとの特徴点	初めてフォーカスした時間 最後にフォーカスした時間 初めて編集した時間 最後に編集した時間 フォーカスした回数 編集した回数
受験データ	所要時間

データセットの詳細を表 5 に示した。カラム数は全て同様に 123 だったため表には省略する。

今回の実験では 107 名の受験者に協力してもらったが、各小テストごとに作成したデータセットに含まれるデータ数が 107 名分よりも少ない結果になった。

受験者数よりもデータ数が少ない原因は、オンライン試験に欠席者がいたことや、試験当日欠席者がいたことが理由であるが、多くの場合は、ブラウザ上の挙動をデータベースに保存できていなかったことが原因であると考えられる。これは、テーブル名の指定に利用したリファラ取得が狙い通りにできなかった際や、情報収集サーバに行動情報を送信できなかった際に起こった。

表 5 データセットの詳細

	第 1 回	第 2 回	第 3 回	第 4 回	第 5 回	第 6 回
データ数	99	100	98	99	96	94

4. 実験

4.1 実験概要

本論文では、全 6 回の小テストごとにデータセットを作成して、それぞれのデータセットで受験者ごとに異常度を算出した。小テストは各回試験問題が異なるため、受験者の挙動はそれぞれの小テストに合わせて変化する。そのため、すべての小テストでの結果を一纏めにしたデータセットでは異常度を検出することが困難であると考え、小テストごとに作成した。

そして、全 6 回分のうち 2 回以上で異常度 3 以上だった受験者を問題行為を行なったと判断し検知を行なった。

その結果を参考に、問題行為を行なったと推定された受験者に問題行為を行なったか聞き取り調査を行なった。

また、問題行為と関連のある特徴点を特定するため、ランダムフォレストを用いて重要特徴点を算出した。

4.2 問題行為

今回、受験者の Web ブラウザ上の挙動のみで検知できると見込んだ問題行為を以下に示す。なりすましに関しては、今回の実験では検知できないと考えた。

- 教科書や参考 PDF などの閲覧
- 試験中の他の Web ページの閲覧
- 多受験者、第三者との会話、相談

4.3 異常度の算出方法

本論文では、異常度を全 6 回の小テストごとに算出して、6 つの異常度検出方法を合算して問題行為の検知を試みた。

ここでは、異常度スコアの算出方法について説明する。3 つの教師なし学習アルゴリズムを 2 種類の特徴点、計 6 通りの異常度検出方法を利用した。

まず、3 つの教師なし学習アルゴリズムを以下に示す。

- (1) Isolation Forest
- (2) Local Outlier Factor
- (3) One Class SVM

次に、2 種類の特徴点を以下に示す。

- (A) 表 4 に示した特徴点
- (B) それらの特徴点をページの表示時間で割った特徴点

ページの表示時間は、ページ内をクリックした回数やスリープした回数などに相関がある。そのため、ページの表示時間が長い割にページ内をクリックした回数が少ないな

どの異常が検知できるのではないかと考えた。

これら3つのアルゴリズムを2種類の特徴点で学習し、計6つで異常かどうかを判定した。そして、6つの内いくつで異常と判定されたかを異常度とした。よって、異常度をデータセットごとに0~6の7段階とした。

4.4 問題行為検知の基準

今回、1度問題行為を行なった受験者は複数回問題行為を行うであろうという仮定のもと問題行為検知の基準を決定した。

よって問題行為検知の基準を、2回以上の小テストで異常度3以上になった場合とした。例えば、全6回のテストで異常度が[0,1,1,3,5,0]だった場合は異常、[2,2,2,2,2,2]の場合は異常でないとした。

4.5 評価方法

本論文では、問題行為を行なったと判定された受験者のみに聞き取り調査を行い事実確認をした。

また、今回、問題行為を認めた者のみを問題行為を行ったものとしており、実際に問題行為を行なったにも関わらず、それを否定しているものはないと言う仮定に基づいて実験を行なった。

その結果を元に、精度と誤検知の割合を算出した。

- 精度
事実確認をした受験者の内、問題行為を認めた受験者の割合
- 誤検知
事実確認をした受験者の内、問題行為を認めなかった受験者の割合

4.6 重要特徴点の算出

今回、問題行為検知と相関のある特徴点を特定するために、scikit-learn ライブラリのランダムフォレストを利用して重要特徴点を算出した。

その時、全6つのデータセットそれぞれで重要度を算出し、その合計で上位5つの特徴点を抽出した。しかし、問題ごとの特徴点はデータセットによって問題も違うため合計を取るのに適していない。よって、問題ごとの特徴点はデータセットごとに10問全ての平均を取った。

また、ランダムフォレストの正解ラベルの付与方法として以下の2つで実験を行った。特徴点は、採取したままのカラムとそれらのカラムをページ表示時間で割ったもので計210カラムであった。

- 各データセットで異常度が4以上の受験者に対してラベル付け
異常度の高さと同相関のある特徴点が見える
- 問題行為を認めた受験者に対してラベル付け
問題行為と同相関のある特徴点が見える

5. 実験結果

本論文では、各小テストごとに異常度スコアを算出して、すべての結果から問題行為検知を行なった。そして、問題行為を行ったと検知された受験者に聞き取り調査を行うことにより精度を算出した。

また、問題行為を行なった受験者の共通したブラウザ上での挙動を明らかにするために重要特徴点を算出した。

5.1 各小テストごとの結果

ここでは、各小テストごとの異常度スコア別の人数の結果を、表6~表11に示す。

表6 第1回小テストの異常度結果

異常度	人数
0	79
1	6
2	4
3	4
4	2
5	2
6	2
合計	99

表7 第2回小テストの異常度結果

異常度	人数
0	78
1	2
2	5
3	5
4	4
5	5
6	1
合計	100

表8 第3回小テストの異常度結果

異常度	人数
0	75
1	7
2	5
3	5
4	1
5	2
6	3
合計	98

表 9 第 4 回小テストの異常度結果

異常度	人数
0	78
1	8
2	5
3	2
4	2
5	0
6	4
合計	99

表 10 第 5 回小テストの異常度結果

異常度	人数
0	74
1	6
2	4
3	5
4	6
5	0
6	1
合計	96

表 11 第 6 回小テストの異常度結果

異常度	人数
0	67
1	9
2	6
3	5
4	4
5	2
6	1
合計	94

表 12 異常度結果まとめ

異常度 3 以上の回数	人数
0	68
1	26
2	3
3	5
4	4
5	1
合計	107

上位 5 つの重要特徴点の結果を表 13 に示す。また、上位 5 つの特徴点の重要度チャートを図 3 に示す。図 3 の各グラフは、表 13 の各項目に対応する。

結果として、ページ上をクリックした回数が異常度と相関のある特徴点だと判明した。また、異常度チャートからページ上をクリックした回数が特に重要度が高いことがわかる。

表 13 異常度の高い受験者にラベル付け

特徴点
ページ上をクリックした回数
ページ上をクリックした回数を表示時間で割ったもの
ページの上 10%~20%を表示された回数
ページの上 60%~70%を表示された回数
問題ごとの最後のクリック時間



図 3 異常度チャート

5.2 各小テストごとの結果まとめ

各小テストの異常度の結果から問題行為をしたと推測される受験者を特定する。今回、異常度が 3 以上になった回数が 2 回以上あった場合に問題行為を行ったと判定した。その結果、13 名の受験者を問題行為を行なったと判定された。

それから直接聞き取り調査を行うため、該当 13 名に本学のサイト経由で呼びかけた。その結果 7 名が集まり、聞き取り調査を行うと 3 名が問題行為を認めた。

よって、聞き取り調査ができた 7 名による判定をしたところ、精度は 0.428、誤検知は 0.571 という結果になった。

5.3 重要特徴点の算出結果

問題行為と相関のある特徴点を特定するために、ランダムフォレストにより重要特徴点の算出を行なった。そのとき、以下の 2 つの方法で正解ラベルを付与した。

- (1) 各小テストごとに異常度が 4 以上の受験者にラベルづけ

- (2) 問題行為を認めた 3 名の受験者にラベルづけ

上位 5 つの重要特徴点の結果を表 14 に示す。また、上位 5 つの特徴点の重要度を図 4 に示す。図 4 の各グラフは、表 14 の各項目に対応する。

結果として、画面からフォーカスが外れた回数が問題行為と相関のある特徴点だと判明した。また、異常度チャートから画面からフォーカスが外れた回数が特に重要度が高いことがわかる。

表 14 問題行為を認めた受験者にラベル付け

特徴点
画面からフォーカスが外れた回数を表示時間で割ったもの
画面からフォーカスが外れた回数
ウィンドウの幅を表示時間で割ったもの
画面がフォーカスされていない総時間を表示時間で割ったもの
画面からマウスが離れた回数




図 4 異常度チャート

6. 考察

6.1 問題行為検知について

各小テストの異常検知の結果から、問題行為を行っていると予測された受験者を抽出し事実確認をした。その結果、問題行為を検知した7名の内、3名が問題行為を認めた。これは、精度として高くないものだと考える。

考察のため、問題行為を行ったと認めた受験者と問題行為を行ったと認めなかった受験者の異常度を以下の表 15・表 16 に示す。

表 15 問題行為を行ったと認めた受験者の異常度

	第1回	第2回	第3回	第4回	第5回	第6回
受験者 1	0	5	3	0	3	3
受験者 2	0	4	0	3	4	5
受験者 3	6	3	5	2	2	4

表 16 問題行為を行ったと認めなかった受験者の異常度

	第1回	第2回	第3回	第4回	第5回	第6回
受験者 4	3	2	3	4	0	0
受験者 5	0	4	0	3	4	3
受験者 6	5	3	6	6	6	2
受験者 7	0	0	2	6	4	4

今回、異常度3以上が2回以上あることを問題行為検知の基準としたが、受験者1から異常度の基準を下げることはできないことがわかる。また、受験者6から異常度の高い受験者でも問題行為をしていない場合もあることがわかる。これらのことから、問題行為検知の基準よりも異常度の算出方法が原因で誤検知が増えてしまったのではないかと考える。

6.2 問題行為と相関のある特徴点について

今回、ランダムフォレストを用いて2種類の正解ラベルの付与方法で重要特徴点を算出した。その結果、解答選択や文章が無い位置でのクリックなどのページ上をクリックした回数が異常度と最も相関があった。また、画面からフォーカスが外れた回数が問題行為と最も相関のあることがわかった。よって問題行為として、問題ページの画面から離れて別の Web ページや PDF などを閲覧した可能性が高いことがわかった。

また、今回の結果から重要特徴点に重みをつけて異常度の算出を行うとより精度が上がるのではないかと考える。

7. 今後の課題

7.1 実験データの課題

実験の課題として、全ての受験者の挙動データを保存できていないことが第一に挙げられる。どの段階での不具合か不明なので、この課題の解消方法を模索したい。

次に、今回取得したブラウザ上の挙動に加えて新たにキーボード操作の挙動が取得できると望ましい。例えば、Windows キーの操作を取得することで、ウィンドウの切り替えや画面のロックなどを検知できる。新たな問題行為につながる情報を取得することで、問題行動検知の精度が向上すると考えられる。

7.2 問題行為検知の課題

今回は、受験者のブラウザ上の挙動しか取得していないため、本人が受験しているか特定ができない。よって問題行為検知の課題として、なりすましへの対策ができていないことが挙げられる。なりすましも試験の公平性を欠く検知すべき問題行為のひとつである。これから、なりすましについて検知や抑止ができるような仕組みづくりが必要である。

次に、正解より誤検知の方が多かったことが挙げられる。考察にもあるように、異常度の算出方法が主な原因であると考えられる。よって、異常検知アルゴリズムや特徴点の選定をすることで解決していきたい。

次に、今回の実験では問題行為を行なったかの実事確認として聞き取り調査しか行っていない。聞き取り調査のみだと、受験者が嘘をつくこともできるため、事実確認としては不十分だと考えられる。そのため、問題行為の実事確認方法の改善が必要であると考えられる。また、実験の評価として問題行為の見逃しがどれだけ発生しているか判定できるようにしていきたい。

最後に、今回の実験では全6回の小テストの内、2回以上で問題行為を行ったと判定された者を一律で問題行為者としている。今後は、小テストごとに問題行為を検知する仕組みとその事実確認方法を模索していきたい。

8. 研究倫理

センシティブな実験であるため、倫理的配慮をして実験を行い、さらに、当事者らが特定されないように論文への記載も最大限に配慮した。聞き取りの際には、当該受験者に心理的な負担を掛けないように最大限の配慮をした。

本論文で使用したデータセットは提供者の同意を得て使用しており、事実確認終了後データセットから個人を特定できる情報は削除した。

9. まとめ

本論文では、Web ブラウザ上で行われるオンライン試験

での問題行為の検知を、受験者のブラウザ上の挙動を用いることで試みた。また、問題行為と相関がある Web ブラウザ上における挙動の特定を図った。

今回の結果、精度は高いとは言えないが、3名の問題行為をした受験者を発見できた。ブラウザ上の挙動のみでの問題行為検知の可能性を見出せたと言える。また、画面からフォーカスが外れた回数が問題行為と相関のある挙動だということがわかった。

今回の実験の結果から、受験者から取得する挙動の選定や、学習に用いる特徴量の重み付けにより、より高い精度で検知できる可能性があると考えた。しかし、問題行為の確認方法が自己申告制で全ての問題行為を把握できていないといった課題もある。

参考文献

- [1] 富士通株式会社. "受験者、試験提供者双方に、安心して効果的なオンライン試験の実現に向けて AI による不審行動検知や試験問題作成を支援するシステムの実証研究を実施". 2021-03-22. 富士通株式会社. 入手先 (<https://pr.fujitsu.com/jp/news/2021/03/22.html>), (参照 2021-10-08)
- [2] Joudaki H., Rashidian A., Minaei-Bidgoli B., Mahmoodi M., Geraili B., Nasiri M., and Arab M. *Using data mining to detect health care fraud and abuse: a review of literature*, Global journal of health science, (2015).
- [3] Van Capelleveen G., Poel M., Mueller R. M., Thornton D., and van Hillegersberg J. *Outlier detection in health-care fraud: A case study in the Medicaid dental domain*, International journal of accounting information systems, (2016).
- [4] 南里 卓也, 大津展之. 複数人動画画像からの異常動作検出. 情報処理学会論文誌コンピュータビジョンとイメージメディア (CVIM) (2015)
- [5] Fei Tony Liu, Kai Ming Ting and Zhi-Hua Zhou: *Isolation Forest*, 2008 Eighth IEEE International Conference on Data Mining, (2008).
- [6] Markus M. Breunig, Hans-Peter Kriegel, Raymond T. Ng and Jörg Sander : *LOF: identifying density-based local outliers*, Proceedings of the 2000 ACM SIGMOD international conference on Management of data, (2000).
- [7] Kun-Lun Li, Hou-Kuan Huang, Sheng-Feng Tian and Wei Xu . *Improving one-class SVM for anomaly detection*, Proceedings of the 2003 International Conference on Machine Learning and Cybernetics (IEEE Cat. No.03EX693)(2003).