

着座時の臀部圧力分布を用いた人物同定手法の評価

林 健太¹ 石田 繁巳¹ 田頭 茂明² 福田 晃¹

概要：近年、多くの人々の「座位時間」が長時間化している。座位行動の研究では、1日に座っている時間の合計が長くなるにつれて総死亡リスクが高まると報告されている。このような健康リスクに対応するため、個人の座位時間を管理するスマートチェアが提案されているが、同じ椅子に同じ人物が座ることが想定されて作られている。実際には違う人物が座る可能性があるため、座っている人物を同定する必要がある。本稿では、着座時の臀部圧力分布を用いた人物同定手法を提案する。着座時の臀部圧力分布には圧力の大きさや面積などに個々人の特徴が現れる。そこで座面に取り付けた圧力センサシートより取得した臀部圧力分布から抽出した特徴量を用いて機械学習により人物同定を行う。少人数集団における人物同定を行った結果、平均で0.915という精度での同定が可能であることを確認した。

Evaluation of Human Identification Method by Hip Pressure Distribution of Seating Postures

Kenta Hayashi¹ Shigemi Ishida¹ Shigeaki Tagashira² Akira Fukuda¹

1. はじめに

近年、多くの人々の生活スタイルでは家庭内や外出先、通勤時に座っていることが多く、「座位時間」が長時間化している。座位行動の研究では、世界保健機関による推奨身体活動量を満たしている場合であっても1日に座っている時間の合計が長くなるにつれて総死亡リスクが高まると報告されている [1]。

このような健康リスクに対応するため、個人の座位時間を管理するスマートチェアが提案されている。スマートチェアでは1つの椅子を同じ人物が使うことが想定されているが、複数人が暮らす家庭に導入する場合には複数人が椅子を共有することを想定して「誰が座っているか」を識別する必要がある。

人物同定に関しては、カメラを用いた人物同定手法が多く報告されている [2-9]。例えば文献 [2] では、顔表面を撮影した画像から顔領域を決定し、ホクロのパターンから類似度を計算することで人物を同定する手法が提案されている。また、一歩行映像から観測方向の異なる対象人物の映像を取得することで複数の特徴量を抽出し人物を同定するといった研究が行われている [3]。カメラを用いれば人物

同定を容易に行えるが、常に監視され映像に残るためプライバシーの侵害などユーザの心的負担につながる。

本稿では、ユーザの心的負担を軽減し日常的動作を用いて人物を同定することを目的として、圧力センサシートを用いた人物同定手法を提案する。椅子に座っている時に椅子の各部位にかかる圧力分布には個人差がある。そこで、椅子の座面に圧力センサシートを設置し、臀部圧力分布を用いて人物を同定する。具体的には、臀部圧力分布から坐骨間距離、右臀部と左臀部の平均圧力の比、右臀部と左臀部の面積の比、各臀部の最大圧力と最小圧力の比など9種類の特徴量を合計12個を抽出し、教師あり学習により人物同定を行う。椅子の座面に圧力センサシートを設置し圧力分布データを数値として扱うため、画像や動画として保管されずユーザの心的負担を軽減できる。また、日常的な動作によって同定をしているためユーザに意識させることなくセンシングすることが可能である。

本提案手法は家庭内での使用を想定しているため、1つの椅子を使用するユーザが3人、4人、5人の各場合で評価を行った。実験では10人の被験者のデータを取得し、被験者10人から3人、4人、または5人を無作為に選び出して評価した。評価結果としてF値を計算したところ、3人の場合は0.938、4人の場合は0.914、5人の場合は0.893で人物を同定できることを確認した。

本稿の構成は以下の通りである。2.で関連研究を示す。3.で着座時の臀部圧力分布を用いた人物同定手法を示し、

¹ 九州大学大学院システム情報科学研究院
ISEE, Kyushu University, Fukuoka 819-0395, Japan

² 関西大学総合情報学部
Faculty of Informatics, Kansai University, Osaka, 569-1095, Japan

4. で交差検証による本提案手法の評価について述べる。最後に 5. でまとめとして全体を総括する。

2. 関連研究

圧力センサを用いて人物の姿勢や行動を識別する研究はいくつか行われている。しかし圧力センサを用いた人物同定の研究は数が少ない。カメラを用いた人物同定に関してはこれまでに多数の研究が報告されている。本節では、関連研究としてカメラを用いた人物同定についての研究と圧力センサを用いた識別手法の研究について述べる。

2.1 カメラを用いた人物同定手法

カメラを用いた人物同定手法として、顔の動画像を用いた人物同定の研究 [2, 4-6] が報告されている。例えば文献 [2] では、顔表面の微小な特徴としてホクロに注目し、検出したホクロによって個人の認識を行っている。画像の中から顔領域を決定したのち、顔領域内から黒色円形領域をホクロとして検出する。検出したホクロから、個人を特徴付けるホクロパターン画像を生成し、類似度を計算することで人物同定を行う。

文献 [3] では、1 台のカメラを用いて撮影した歩行映像を用いた人物推定を行っている。また、スポーツの映像からチームや背番号を判別し選手を追跡、同定する研究 [7], [8] が行われている。背番号やチームの色、選手の動きなどを特徴量として抽出し、選手の位置情報や同定を行う。文献 [9] ではユーザに取り付けた RFID タグからの位置情報とカメラ映像からの位置情報を用いることで人物同定を行っている。

カメラを用いた人物同定は非常に高い精度を期待できるが、プライバシーの観点では、ユーザがカメラに撮られていると感じる点と映像が残る点でユーザの心的負担になるという問題がある。

2.2 圧力センサを用いた識別手法

文献 [10] では、重さや重さの分布データを基に着席者の姿勢や動きの識別を行っている。圧力センサパッドを椅子の 4 つの脚の裏にそれぞれつけ、椅子にかかる全体の垂直成分の重さと 4 つの脚に対する重さの分布のデータを取得する。この手法では、椅子に 4 つの脚が付いているものでなければ適用することができないという問題点がある。また、車の座席に圧力センサを設置して人物を識別する研究が行われている [11]。この研究では姿勢を固定した状態で識別を行っているため、家庭内で用いられるような姿勢を固定しない椅子には適用できない。

握るという動作を用いた個人認証システムの実装では、握るという動作から得られる圧力分布とその時間変化を用いて認証を行っている [12]。文献 [13] では、時空間分解能が高い圧力センサを用いて実時間性を重視した特徴量を抽出することで人の 5 種類の触行動を識別している。また、圧力センサマットを用いた個人識別の研究 [14-17] が行われている。これらの研究では、床に設置設置することで歩

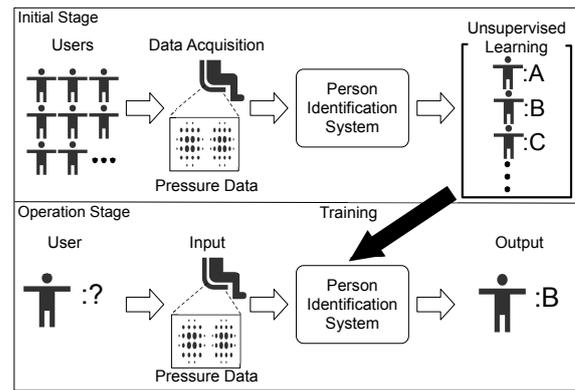


図 1 想定シナリオの概要

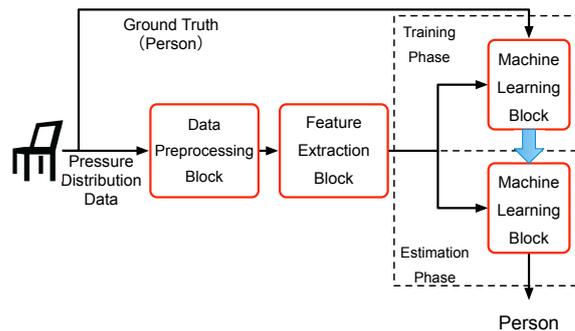


図 2 人物同定手法の概要

行時の足圧画像や歩行動作から人物を、ベッドに設置することで利用者の体位や呼吸の有無を識別している。

本研究では、座面に圧力センサシートを用いることで人物同定を行う手法を提案する。

3. 臀部圧力分布を用いた人物同定手法

3.1 想定シナリオ

本研究では、構成の大きく変わらない少人数が活動する家庭内などでの人物同定を想定する。図 1 に想定シナリオの概要を示す。人物同定手法は初期段階 (Initial Stage) と実運用段階 (Operation Stage) の 2 段階で利用される。初期段階では、椅子の座面に設置された圧力センサで圧力データを一定期間収集し、教師なし学習を用いることで椅子に座った人ごとにデータを分類する。分類後のデータと実際の人物との対応付け、すなわちラベル付けは、実際の行動履歴に基づいてユーザが与えるものとする。実運用段階では、教師あり学習により椅子に座った人が誰であるかを同定する。学習は初期段階で分類したデータ、ラベルを用いて実運用開始前に行っておく。

提案手法の実現可能性を示すため、本稿では初期段階の学習がすでに終わっている状況において誤りのない学習データを得られる前提で、実運用段階でどの程度の精度で人物を同定できるのかを検証する。

3.2 提案手法の概要

人物同定手法の基本アイデアは、人が着席している時の臀部圧力分布が人によって異なることである。例えば、特

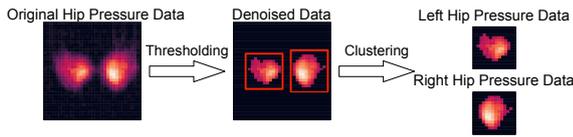


図 3 データ前処理ブロックの概要

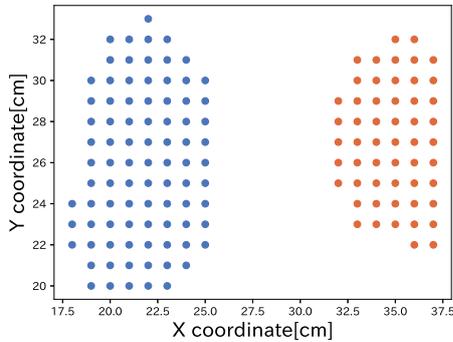


図 4 左右に分離した後の座標データ (k-means 法)

微量の 1 つである坐骨間距離は骨の位置が関与しているため個人差がある。そこで、椅子の座面に圧力センサシートを設置して人物ごとの臀部圧力分布データを取得する。各データの差異を特徴量として抽出することで人物を同定する。

図 2 に人物同定手法の概要を示す。本提案手法はデータ前処理 (Data Preprocessing) ブロック, 特徴量抽出 (Feature Extraction) ブロック, 機械学習 (Machine Learning) ブロックという 3 つのブロックで構成される。データ前処理ブロックでは, 圧力センサシートから得た臀部圧力分布データに前処理を行う。次に, 特徴量抽出ブロックでそのデータから左右の臀部の面積比などの特徴量を抽出する。最後に, 機械学習ブロックで教師あり機械学習を用いて人物同定を行う。

3.3 データ前処理ブロック

図 3 にデータ前処理ブロックの概要を示す。データ前処理ブロックでは, 圧力センサシートから取得した圧力データのノイズ除去, 右臀部と左臀部の分離を行う。

取得したデータには空気圧やセンサ回路のノイズなどが原因で臀部の触れていないところにも圧力の変化が生ずる。そのため, 閾値より小さい圧力値を無視し, 臀部の触れている部分のデータを取り出す。

左右臀部の分離は, 圧力データの xy 座標にクラスタリングアルゴリズムを適用して 2 つのクラスタに圧力データを分離することで行う。図 4 に, 圧力データ点を右臀部と左臀部に分離した例を示す。本提案手法では使用するクラスタリング手法を限定しない。本稿では, 非階層型クラスタリングのアルゴリズムである k-means 法を用いた。k-means 法のクラスタ数は $k = 2$ に設定した。図中, 左側のクラスタが右臀部, 右側のクラスタが左臀部である。

表 1 臀部圧力データから抽出する特徴量

特徴量の種類	個数	特徴量番号
最大圧力と最小圧力の比 (左・右)	2	左:1 右:2
左右の平均圧力の比	1	3
坐骨間距離	1	4
坐骨から各臀部の外周までの最長距離と最短距離の比 (左・右)	2	左:5 右:6
縦幅と横幅の距離の比 (左・右)	2	左:7 右:8
左臀部と右臀部の縦幅の比	1	9
左臀部と右臀部の横幅の比	1	10
臀部の間の距離と最も外側の距離の比	1	11
面積比	1	12

3.4 特徴量抽出ブロック

表 1 に, 臀部圧力分布データから抽出する特徴量を示す。前処理によって得られた右臀部と左臀部の圧力分布データを用いて 9 種類 12 個の特徴量を抽出する。圧力分布データは, xy 座標及びそれに対応する圧力値の情報を有している。左右臀部に対応する圧力分布データの座標の集合をそれぞれ \mathbf{A}_L , \mathbf{A}_R , 座標 $\mathbf{a} \in \mathbf{A}_L \cup \mathbf{A}_R$ の圧力値を $P(\mathbf{a})$ とする。各特徴量は以下のようにして得る。

- 最大圧力と最小圧力の比は, 最大圧力の値を最小圧力の値で除することで求める。左臀部の最大圧力と最小圧力の比は,

$$\frac{\max_{\mathbf{a} \in \mathbf{A}_L} P(\mathbf{a})}{\min_{\mathbf{a} \in \mathbf{A}_L} P(\mathbf{a})} \quad (1)$$

である。右臀部も同様に計算する。

- 左右の平均圧力の比は, 右臀部に対応する部分の圧力を平均した値を左臀部に対応する部分の圧力を平均した値で除することで求める。

$$\frac{\frac{1}{|\mathbf{A}_R|} \sum_{\mathbf{a} \in \mathbf{A}_L \cup \mathbf{A}_R} P(\mathbf{a})}{\frac{1}{|\mathbf{A}_L|} \sum_{\mathbf{a} \in \mathbf{A}_L \cup \mathbf{A}_R} P(\mathbf{a})} \quad (2)$$

- 坐骨間距離は各臀部の坐骨間の距離である。坐骨の位置は各臀部の最大圧力の座標として求める。

$$D \left(\arg \max_{\mathbf{a} \in \mathbf{A}_L} P(\mathbf{a}), \arg \max_{\mathbf{a} \in \mathbf{A}_R} P(\mathbf{a}) \right) \quad (3)$$

ここで, $D(\mathbf{a}_1, \mathbf{a}_2)$ は \mathbf{a}_1 と \mathbf{a}_2 のユークリッド距離を表す。

- 坐骨から各臀部の外周までの最長距離と最短距離の比は, 各臀部の坐骨から臀部の輪郭部分の最長距離を最短距離で除することで求める。左右臀部の外周の座標の集合をそれぞれ \mathbf{F}_L , \mathbf{F}_R とすると, 坐骨から左臀部の外周までの最長距離と最短距離の比は,

$$\frac{\max_{f \in \mathbf{F}_L} D \left(\arg \max_{\mathbf{a} \in \mathbf{A}_L} P(\mathbf{a}), f \right)}{\min_{f \in \mathbf{F}_L} D \left(\arg \max_{\mathbf{a} \in \mathbf{A}_L} P(\mathbf{a}), f \right)} \quad (4)$$

である。右臀部も同様に計算する。

- 縦幅と横幅の比は, それぞれ圧力データ点の y , x 方向

の長さの比である。縦幅は y 座標が最大・最小となる座標群間の最長距離，横幅は x 座標が最大・最小となる座標群間の最長距離である。まず， xy 座標が最大，最小となる点群の集合を

$$\mathbf{A}_{L(X_{\max})} = \arg \max_{\mathbf{a} \in \mathbf{A}_L} X(\mathbf{a}), \mathbf{A}_{L(X_{\min})} = \arg \min_{\mathbf{a} \in \mathbf{A}_L} X(\mathbf{a})$$

$$\mathbf{A}_{L(Y_{\max})} = \arg \max_{\mathbf{a} \in \mathbf{A}_L} Y(\mathbf{a}), \mathbf{A}_{L(Y_{\min})} = \arg \min_{\mathbf{a} \in \mathbf{A}_L} Y(\mathbf{a})$$

などと求める。ここで， $X(\mathbf{i})$ ， $Y(\mathbf{i})$ はそれぞれ圧力データ点 \mathbf{i} の x 座標， y 座標を表す。次いで，縦幅，横幅の比を計算する。

$$\frac{\max_{a_1 \in \mathbf{A}_{L(Y_{\max})}, a_2 \in \mathbf{A}_{L(Y_{\min})}} D(a_1, a_2)}{\min_{a_1 \in \mathbf{A}_{L(X_{\max})}, a_2 \in \mathbf{A}_{L(X_{\min})}} D(a_1, a_2)} \quad (5)$$

右臀部も同様に計算する。

- 左臀部と右臀部の縦幅の比は，右臀部の縦幅を左臀部の縦幅で除することで求める。

$$\frac{\max_{a_1 \in \mathbf{A}_{R(Y_{\max})}, a_2 \in \mathbf{A}_{R(Y_{\min})}} D(a_1, a_2)}{\max_{a_1 \in \mathbf{A}_{L(Y_{\max})}, a_2 \in \mathbf{A}_{L(Y_{\min})}} D(a_1, a_2)} \quad (6)$$

- 左臀部と右臀部の横幅の比は，右臀部の横幅を左臀部の横幅で除することで求める。

$$\frac{\max_{a_1 \in \mathbf{A}_{R(X_{\max})}, a_2 \in \mathbf{A}_{R(X_{\min})}} D(a_1, a_2)}{\max_{a_1 \in \mathbf{A}_{L(X_{\max})}, a_2 \in \mathbf{A}_{L(X_{\min})}} D(a_1, a_2)} \quad (7)$$

- 臀部の間の距離と最も外側の距離の比は，臀部の間の距離を臀部の最も外側の距離で除することで求める。臀部の間の距離は右臀部の x 座標が最大となる圧力データ点と左臀部の x 座標が最小となる圧力データ点の距離である。臀部の最も外側の距離は右臀部の x 座標が最小となるデータ点と左臀部の x 座標が最大となるデータ点の距離である。以下の式で与えられる。

$$\frac{\max_{a_1 \in \mathbf{A}_{R(X_{\max})}, a_2 \in \mathbf{A}_{L(X_{\min})}} D(a_1, a_2)}{\max_{a_1 \in \mathbf{A}_{R(X_{\min})}, a_2 \in \mathbf{A}_{L(X_{\max})}} D(a_1, a_2)} \quad (8)$$

- 面積比は，右臀部の面積を左臀部の面積で除することで求める。圧力データは離散的であるため，圧力データの点数を面積として計算する。

$$\frac{|\mathbf{A}_L|}{|\mathbf{A}_R|} \quad (9)$$

3.5 機械学習ブロック

機械学習ブロックでは，抽出された特徴量を用いて多クラス分類問題として人物を識別する。本提案手法では使用する機械学習アルゴリズムを限定しない。多クラス分類問題に対応したニューラルネットワークや Random Forest, Support Vector Machine (SVM) などの利用を想定している。

提案システムの基本性能を評価するため，本稿では RBF

表 2 データ処理計算機の諸元

モデル	MacBook Air 13-inch, 2014
OS	macOS Sierra 10.12.6
プロセッサ	1.4GHz Intel Core i5
メモリ	8GB

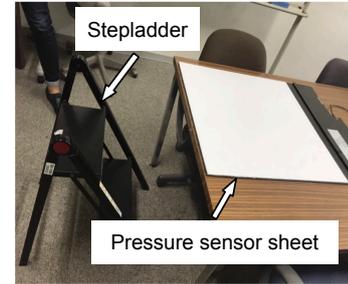


図 5 評価環境

カーネルを用いた SVM によって人物識別を行う。SVM のコストパラメータは $C = 10$ ，RBF のカーネルパラメータ $\gamma = 1$ とした。SVM のコストパラメータの決定には Grid Search 法を用いた。C の探索範囲を $[1, 10, 100, 1000, 10000]$ ， γ の探索範囲を $[0.001, 0.01, 0.1, 1, 10]$ とし，F 値の平均の値が最も高いパラメータに決定した。

多くの機械学習アルゴリズムにおいて，特徴量の取り得る値の範囲が異なる場合に識別精度の低下や学習効率の大幅な低下などの問題を招く。そのため，特徴量抽出ブロックで取得したデータに正規化処理を施した。

4. 評価

提案手法の実用可能性について検討するため，人物同定精度と特徴量の重要度を評価した。

4.1 評価環境

図 5 に評価実験環境を示す。図に示すように，机の上に圧力センサシートを置き，その前に脚立を置いた。圧力センサシートは LLSensor [18] を用いた。LLSensor はサイズが $600\text{mm} \times 600\text{mm}$ ，空間分解能が $10\text{mm} \times 10\text{mm}$ の圧力センサである。データ処理計算機は MacBook Air を用いた。表 2 にデータ処理計算機の諸元を示す。人物同定プログラムは Python 3.6.5 及び scikit-learn 0.20.1 [19] の SVM ライブラリを用いて実装した。

22～24 歳の男性被験者 10 人に圧力センサシート上への着座動作を 20 回行ってもらい，臀部圧力分布データを取得した。着座動作とは，机の前の脚立に立ってからセンサシートに腰をおろして静止し，合図を出したら立ち上がるという動作である。

本提案手法の想定環境は家庭内などの少人数集団内での識別であることから 10 人の中から一部の人物を選択して各人にラベル A, B, \dots を割り当て，人物識別精度を 10 分割交差検証により評価した。この評価を選択する人物の組み合わせ全てで行った。選択する人数は 3～5 人と変化させた。

評価では，人物推定結果のラベル \hat{X} と真値 X とを比

表 3 各パターンにおける評価結果

Number n of users	Precision	Recall	F measure
3	0.941	0.938	0.938
4	0.917	0.907	0.914
5	0.896	0.894	0.893

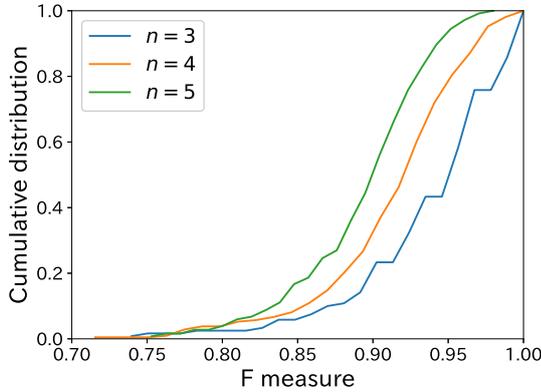


図 6 F 値の累積分布図

較することで各ラベルごとに適合率 (Precision), 再現率 (Recall), F 値 (F measure) を算出した. 適合率, 再現率は, それぞれラベル X であると判定したデータがどれだけ正しいか, ラベル X のデータのうちどれだけ正しく推定できたかを示す指標であり, F 値は適合率と再現率の調和平均である. 本提案手法は多クラス分類を行うため, 各ラベルの適合率, 再現率, F 値を平均することでマクロ適合率, マクロ再現率, マクロ F 値を算出した. 各ラベルの適合率, 再現率, F 値は以下で定義される.

$$\text{Precision}_X = \frac{|\mathbf{S}_X \cap \mathbf{S}_{\hat{X}}|}{|\mathbf{S}_{\hat{X}}|} \quad (10)$$

$$\text{Recall}_X = \frac{|\mathbf{S}_X \cap \mathbf{S}_{\hat{X}}|}{|\mathbf{S}_X|} \quad (11)$$

$$\text{Fmeasure}_X = \frac{2 \cdot \text{Precision}_X \cdot \text{Recall}_X}{\text{Precision}_X + \text{Recall}_X} \quad (12)$$

ここで, \mathbf{S}_X , $\mathbf{S}_{\hat{X}}$ はそれぞれ真値が X である試行の集合, 人物識別システムの推定結果ラベルが \hat{X} である試行の集合である.

4.2 人物同定の精度

表 3 に人物同定の精度の評価結果を示す. 表 3 は, 10 人から無作為に n 人を取り出して評価したマクロ適合率, マクロ再現率, マクロ F 値を, ${}_{10}C_n$ 通り全てで算出して平均した値を示している. 評価結果より, $n = 3$ 人を識別する場合は適合率 0.941, 再現率 0.938, F 値 0.938 と高い精度で判別可能であったことが分かる. 一方で, n を 4 人, 5 人と増加させたとき適合率, 再現率, F 値は全て低下した.

図 6 に $n = 3, 4, 5$ の場合それぞれの F 値の累積分布図を示す. 図より, F 値が 0.85~0.95 の範囲にデータが集中していることと, 人数が増えると F 値が 0.95 以上のデータが極端に少なくなることがわかる. 本稿の評価では 22

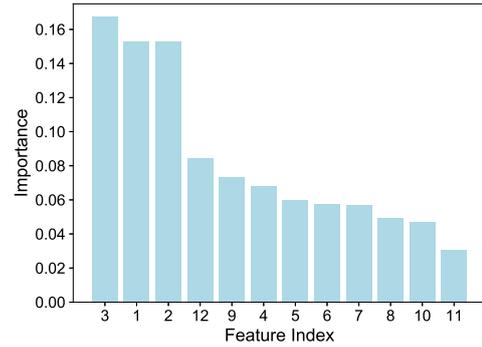


図 7 特徴量の重要度 ($n = 3$)

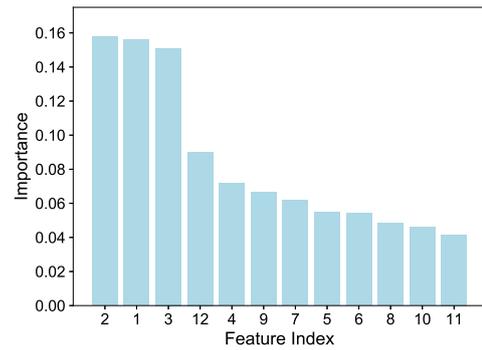


図 8 特徴量の重要度 ($n = 4$)

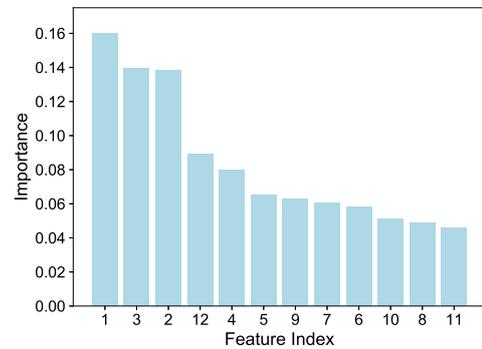


図 9 特徴量の重要度 ($n = 5$)

~24 歳の男性のデータを用いているため, 体重や体格が似ている人物の同定評価であると言える. 人物によって体格や体重の差異が大きい場合には高い精度で人物同定が可能であると考えられる. 一般家庭では性別や年代の異なる人物で構成されることが多く, 性別や年代の違いにより体格差が生じるため, 今回の評価結果に比べて高い精度での人物同定が期待できる.

4.3 特徴量の重要度

分類アルゴリズムである Random Forest を用いて各特徴量の重要度を $n = 3, 4, 5$ の場合でそれぞれ算出した. 図 7, 図 8, 図 9 に $n = 3, 4, 5$ の場合の特徴量の重要度を示す. 横軸の値は特徴量番号 (Feature Index) を, 縦軸の値は重要度を示している. 各特徴量と特徴量番号の対

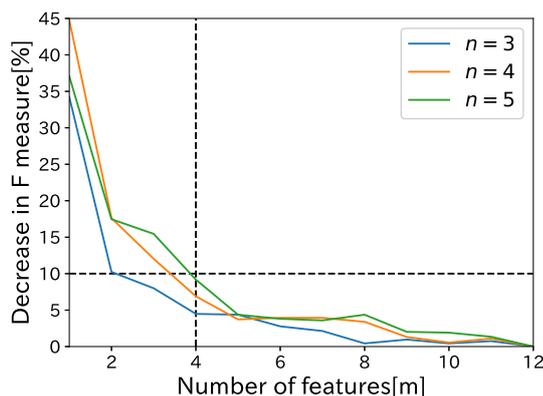


図 10 特徴量の個数と最大 F 値との割合の関係

応は表 1 に示している。重要度は各特徴量を全体から見た相対的な指標であり、数値が高いほど重要度が高いことを示している。各図より、上位 4 つと下位 3 つの特徴量が重要度の順序は異なるものの各パターンで等しいことが分かる。上位 4 つは左右それぞれの最大圧力と最小圧力の比、左右の平均圧力の比、左右面積比である。下位 3 つは左右の横幅の比、縦幅の比、縦幅と横幅の比である。圧力の比を用いたものと面積比の特徴量は人物によって差異が大きいこと、各臀部の長さの比を用いた特徴量は類似していることが分かる。

$n = 3, 4, 5$ の各パターンにおいて重要度の高い順に m 個の特徴量を用いた場合の同定精度を評価した。図 10 に m 個の特徴量を用いた場合と全ての特徴量を用いた場合を比べた際の F 値の減少幅を示す。図 10 より、 m が 4 以上の場合に減少幅が 10% を下回る。4 つ以上の特徴量を用いることで全特徴量を用いた場合の 90% 以上の F 値を達成できることが確認できた。

5. おわりに

本稿では、圧力センサシートを用いて取得した着座時の臀部圧力分布データを利用した人物同定システムを提案した。本提案手法は着座時の臀部圧力分布に個人差があることに着目し、臀部圧力分布データから抽出した特徴量を用いて教師あり学習により人物同定を行う。提案する人物同定手法の実現可能性を検証するため、実際に取得した臀部圧力分布データを用いて 10 分割交差検証により初期的評価を行った。評価は被験者 10 人から 3 人、4 人、または 5 人を選び出して行った。評価結果として 3 人の場合は F 値 0.938、4 人の場合は 0.914、5 人の場合は 0.893 という精度で人物同定が可能であることを確認した。また、特徴量の重要度を求めることで必要な特徴量の種類と個数を求めた。今後の課題として、データ収集の効率化、着席角度の考慮、ユーザの姿勢を考慮した人物の同定などが挙げられる。課題の解決のため、座る動作中の圧力データのサンプリング、着席角度の補正、様々な姿勢に対応する特徴量の考察などを行う予定である。

謝辞 本稿で示した研究の一部は、科研費 (JP15H05708, JP17H01741) 及び東北大学電気通信研究所における共同

プロジェクト研究の助成で行われた。

参考文献

- [1] 岡浩一郎, 杉山岳巳, 井上茂, 柴田愛, 石井香織. 座位行動の科学. 日本健康教育学会誌, Vol. 21, No. 2, pp. 142–153, 2013.
- [2] 河原智一, 山口修, 福井和広. 顔表面の微小特徴がなすグローバル構造を用いた人物認証. 第 5 回システムインテグレーション部門講演会, pp. 619–620, 2004.
- [3] 村松大吾, 岩間晴之, 木村卓弘, 楨原靖, 八木康史. 一歩行映像から取得される複数特徴を用いた個人認証. 電子情報通信学会論文誌 A, Vol. 97, No. 12, pp. 735–748, 2014.
- [4] 山口純平, 嶋田和孝, 榎田修一, 江島俊朗, 遠藤勉. 顔特徴とコンテキスト情報に基づく人物識別. 知能と情報, Vol. 23, No. 2, pp. 137–145, 2011.
- [5] 加藤文和, 向川康博, 尺長健. 安定な顔認識のための分散協調登録. 電子情報通信学会論文誌 D, Vol. 84, No. 3, pp. 500–508, 2001.
- [6] 安本護, 本郷仁志, 渡辺博己, 山本和彦, 輿水大和. マルチカメラ統合を用いた人物識別と顔方向推定. 電子情報通信学会論文誌 D, Vol. 84, No. 8, pp. 1772–1780, 2001.
- [7] 岩元浩太, 麻田知嗣, 小松尚久. 信頼度パラメータを用いた広域動画における人物追跡: サッカー選手の追跡. 電子情報通信学会技術研究報告. IN, 情報ネットワーク, Vol. 101, No. 558, pp. 13–18, 2002.
- [8] 三須俊彦, 苗村昌秀, 高橋正樹, 和泉吉則. オブジェクト追跡と背番号認識の連携による画像用スポーツ選手同定手法. 情報技術レターズ, Vol. 2, pp. 187–189, 2003.
- [9] 中嶋大介, 伊藤義道, 新田直子, 馬場口登. RFID タグとカメラ映像を用いたサーベイランス映像中の人物同定. 電子情報通信学会技術研究報告. PRMU, パターン認識・メディア理解, Vol. 107, No. 281, pp. 81–86, 2007.
- [10] J. Cheng, B. Zhou, M. Sundholm, and P. Lukowicz. Smart chair: What can simple pressure sensors under the chairs legs tell us about user activity. In *UBICOMM13: The Seventh International Conference on Mobile Ubiquitous Computing, Systems, Services and Technologies*, pp. 81–84, 2013.
- [11] 越水重臣. 着座認証システム (特集 ここまできたセキュリティ/認証技術). ディスプレイ, Vol. 18, No. 7, pp. 69–72, 2012.
- [12] 佐藤勝規, 佐藤究, 小笠原直人, 布川博士. 握るという動作を用いた個人認証システムの実装. 情報処理学会研究報告 コンピュータセキュリティ (CSEC), Vol. 2006, No. 129 (2006-CSEC-035), pp. 7–12, 2006.
- [13] 納谷太, 篠沢一彦, 大和淳司, 小暮潔. 圧力分布センサによる人の触行動の実時間識別とその個人適応手法. 電子情報通信学会論文誌 D, Vol. 85, No. 4, pp. 613–621, 2002.
- [14] 大和淳司, 数藤恭子, 伴野明. 圧力センサマットを用いた足圧画像からの個人識別の検討. 電子情報通信学会技術研究報告, pp. PRU94–61, 1994.
- [15] 関進, 藤井崇介, 沢田篤史, 美濃導彦. 歩行時の両足床反力を用いた個人識別. 電子情報通信学会論文誌 D, Vol. 90, No. 2, pp. 441–449, 2007.
- [16] 中島一樹, 水上嘉樹, 田中幹也, 田村俊世. 足形を利用した個人識別. 電気学会論文誌 D (産業応用部門誌), Vol. 121, No. 7, pp. 770–776, 2001.
- [17] 西田佳史, 武田正資, 森武俊, 溝口博, 佐藤知正. 圧力センサによる睡眠中に呼吸・体位の無侵襲・無拘束な計測. 日本ロボット学会誌, Vol. 16, No. 5, pp. 705–711, 1998.
- [18] Xiroku 株式会社シロク. LLSSENSOR. <https://www.llsensor.com/>.
- [19] scikit learn. scikit-learn machine learning in python. <https://scikit-learn.org/stable/>.