

# 複数の歩容特徴量のDTW距離に基づくロバストな個人識別手法の提案

森 駿文<sup>1,a)</sup> 菊池 浩明<sup>2,b)</sup>

受付日 2018年11月27日, 採録日 2019年6月11日

**概要:** カメラを用いて個人を識別・追跡し, 防犯や商用に活用する動きが進んでいる. これまでに歩き方から特徴を抽出する種々な歩容識別手法が提案される中, 我々は歩行者の関節の動きを深度センサにより観測し, 得られた3次元時系列データのDynamic Time Warping (DTW) 距離に基づいて個人を識別する手法を提案する. 提案方式には, ウェアラブルセンサを用いたMuaazらの最先端の方式に対して次の長所がある. (1) 識別されることの同意が不要, (2) 複数の関節の動きを統合することによる精度向上, (3) 箱を運んだり, 歩きスマホにより意図的に加えられた追跡防止行為に対しての頑強性. 提案方式は複数の関節のデータを使うために, いくつかの特徴量が欠損しても補償して, 意図的な外乱に対しても精度を保つことができる. 145名の被験者を用いた精度評価により, 得られた複数の特徴量に対する, 各特徴量の統計量や分布に基づいた統合手法, 統合する特長数の最適値を明らかにする. 提案方式の等誤り率 Equal Error Rate (EER) は0.048である. また, 箱を持つ, スマートフォンを操作するなど, いくつかの外乱を含んだ歩行に対して頑強な識別手法を提案し, 関数を単体で用いたときと複数組み合わせ合わせた際の精度の変化を調査する.

キーワード: DTW, 歩容, 人物識別, 生体認証

## Proposal on Robust Person Tracking Method Based on Multiple DTW Distances of Gait Features

TAKAFUMI MORI<sup>1,a)</sup> HIROAKI KIKUCHI<sup>2,b)</sup>

Received: November 27, 2018, Accepted: June 11, 2019

**Abstract:** Human identification with camera has been widely used for many applications including a person tracking, a crime prevention, and marketing. In this work, we propose a new human identification method based on Dynamic Time Warping (DTW) distance of the time series of 3-dimensional coordinates of some joints in bodies observed from depth sensor. Our proposed method has some advantages against one of the state-of-art identification method with wearable sensors by Muaaz et al. in 2017, (1) identification without consent of person, (2) accuracy improvement from aggregation with multiple motions of joints, and (3) robust against intentionally added disruptions of tracking, e.g., carrying box, walking with smartphone. Since the proposed method uses multiple sensors of joints, we can compensate some faulty features and preserve accuracy against intentional obstacles. Since our proposed method observes human motions from depth sensor, it allows tracking persons without consent of identification. Experiment with 145 subjects reveal the distribution of features, the accuracy of aggregated features and the optimal values of parameters in proposed method. The propose new methods is robust against walking including some obstacles such as having box or texting phoning and evaluate the accuracy for that.

**Keywords:** DTW, gait, human identification, biometrics

<sup>1</sup> 明治大学大学院先端数理科学研究科  
Graduate School of Advanced Mathematical Sciences, Meiji University, Nakano, Tokyo 164-8525, Japan

<sup>2</sup> 明治大学総合数理学部  
School of Interdisciplinary Mathematical Science, Meiji University, Nakano, Tokyo 164-8525, Japan

### 1. はじめに

近年, カメラやセンサなどを用いて個人を識別・追跡し,

<sup>a)</sup> cs172059@meiji.ac.jp

<sup>b)</sup> kkn@meiji.ac.jp

表 1 先行研究との違い

Table 1 Comparison between this work and previous works.

	関節の統計量	一歩行分の 累積シルエット画	ウェアラブルセンサによる 時系列データ	本研究
代表例	Mori 2018 [5]	GEI [6]	Muaaz [7]	-
部位の数	1-36	1	1	1-24
センサ位置	外側	外側	内側	外側
観測期間	短期	短期	長期	短期
テンプレート数	単数	-	複数	単数
被験者の協力	不要	不要	要	不要
識別手法	統計量	GEI	DTW	DTW
外乱ロバスト性	弱	弱	弱	強
被験者数	10 人	-	35 人	31 人

マーケティングや防犯などに活用する試みが始まってきている。現在は顔画像による識別が主流であるが、マスクやサングラスなどによる外乱に弱いことが課題となっている [1]。我々は生体認証手法として歩容に注目する。なぜならば歩容には、長距離からでも観測が可能、複数の特徴量を容易に収集できる、対象者の協力が不要などといった特長があるためである。複数の特徴を統合することで、外乱に対しても頑強に識別できる可能性がある\*1。

歩容を用いた生体認証には、表 1 の 3 種類に大別される手法が提案されている。1 つ目は関節の長さなどの静的な特徴量の統計量に基づくもの、2 つ目は 1 歩行分の画像を累積したシルエット画像によるもの、そして、3 つ目は関節の動きの時系列データなどの動的な特徴量によるものである。静的な統計量による手法 [5] では、身体のいくつかの 2 カ所の関節間の距離を特徴量として個人を識別する。たとえば、左右の手の間の距離はその人の手の振り方の特徴を表しており、個体差が生じることを応用した方法である。[5] では 10 人の被験者を用いた実験により、両足の脛長と腿長の統計量からなる 4 次元のベクトルを特徴量とすることが EER の観点で最適であることを示した。しかし、最適のときでさえ EER は 0.25 であった。誤差の主な原因としては、

- 左右の手間の距離は変動が大きく、同一人物でも歩くごとに変化する。
- 静的な特徴量の解像度には限りがあり、身体や手足長が類似の被験者を識別不能である。

ことが考えられた。

静的な特徴量による方式の問題に対して、第 3 の手法では時系列データのあいまいなパターン認識を行う Dynamic Time Warping (DTW) がしばしば導入されている。DTW は、時間軸上での関節の変動パターンを効率よく比較することを可能とするので、統計量のような静的な特徴量からは分からない手足の動的な振り方を識別し、精度の向上が

期待できる。

DTW を用いた最新の研究には、Muaaz らの先行研究 [7] があげられる。彼らは、スマートフォンのセンサから得られる加速度を用いた個人認証手法を提案したが、以下の理由で人物識別には適さない。

- 専用アプリをインストールしたスマートフォンを所持する必要があり、利用者の協力が不可欠である。
- スマートフォンの加速度センサで得られる情報は数が限られ、また、身体を中心付近の加速度のみであるため、手足の動きを観測することが不可能である。
- 荷物を持つ、スマートフォンを操作しながら歩くなどの外乱に弱い。

GEI [6] などのシルエット画像をいくつかの部分に分割してそのうち有効な部分を用いて識別をする手法 [8] や性別推定をする手法 [9] も存在する。しかし、シルエット画像を用いる方式では加速度などの情報が欠落してしまいそれを用いた識別ができない、観測をする角度が変わってしまうと識別ができないなどの問題点がある。

そこで、本研究では、これらの問題を解決するため Kinect などのモーションキャプチャセンサを用いて身体の複数の関節の動きを外側から測定し、その時系列データに DTW を適用する方式を提案する。提案手法はスマートフォンなどのデバイスを持ち歩く必要はなく、手や足などの身体の複数の部位の動きを観測するため、仮に荷物を持ったために右手の情報が損なわれても、他の部位の特徴によりその影響を保証することが可能であり、なおかつアフィン変換などで座標軸を変換することができるため観測角度の変化に頑強であるという特長がある。Muaaz らの方式は単一のスマートフォンから EER=0.13 を達していたが、我々の提案方式は任意個の身体の部位の変化を統合して個人を識別できるので精度の向上や外乱への頑強性が期待できる。さらに、 $k$ -Nearest Neighbor ( $k$ -NN) を導入することで外乱の影響を受けていない部位のみを抽出し識別を行うことができる。以上の先行研究との比較を表 1 に整理する。

本稿では、提案手法に関する以下の点を明らかにするこ

\*1 本研究は DICOMO2018 [2]、CSS2018 [3] と SCIS2019 [4] の発表を基にまとめたものである。

とを目標とする。

- 身体の各関節の動きを特徴量としたとき、複数の特徴量を組み合わせると精度が向上すると考えられるが、どの特徴量をいくつを組み合わせるのが最適なのか。
- 荷物を持つ、大股で歩くなど、歩行に対する外乱を含む場合に有効な手法はあるか。

本稿は以下のように構成する。2章では、本研究に関連する先行研究をあげる。3章では、モーションキャプチャデバイスとDTWを用いた新たな歩容の個人識別手法を提案する。4章では、システムのプロトタイプを作成し、提案手法の精度や最適なパラメータを明らかにする。5章において提案手法のリアルワールドでの応用について述べ、最後に6章で本研究のまとめを行う。

## 2. 関連研究

### 2.1 RGBカメラを使った歩容認証

歩容認証に用いる特徴量としてはシルエット画像がよく使われる。代表的なものに、Hanらが2006年に提案した歩容エネルギー画像 (GEI: Gait Energy Image) [6]がある。これは歩行のシルエット画像の1周期分の平均をとるというものであり、1周期の全フレームの画像を比較する場合と比べ、処理の高速化や使用ストレージの削減、ノイズへの耐性などが期待できる。

GEIを用いた研究はいくつか行われている。Backchyらは自己組織化写像 (SOM) を用いた認証手法 [10] を提案した。彼らの研究では、SOMを用いてGEI画像の分類を行うことで、121名の被験者で、カバンを持ったりコートを着たりした多様な歩き方において、57%の正解率 (正しく識別できた被験者の割合) を達成した。

また、ShiragaらはGEINet [11] を提案した。彼らは近年画像処理の分野において注目されている畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) を用いて、GEI画像を分類することで高精度な歩容認証を可能とした。この手法では、EERは最適な場合で0.01であった。

Rokanujamanらはシルエット画像をいくつかの部分に分割して、その中で有効な部分を用いて識別を行う手法 [8] を提案した。彼らの手法は、32種類の服装をした68名の被験者を用いた評価実験により、正解率 (正しく識別できた被験者の割合) が最高で73.84%であった。

村松らはGEIに任意視点変換モデルを適用することで視点の異なる歩容特徴を用いて認証を行う手法 [12] を提案した。しかし、彼らの手法はシルエット画像に対して視点変換処理を行うコストがかかる。

### 2.2 深度センサを使った歩容識別・属性推定

Kinectなどの深度センサを用いた歩容識別も研究されている。PreisらはKinectを用いた歩容識別手法 [13] を提案

した。彼らは決定木とナイーブベイズ識別器を用いて歩容識別を行う手法を提案し、9人の被験者を用いた実験により91.0%の識別率となった。

Igualらは、深度センサを用いた性別推定手法 [14] を提案した。本手法では、RGBの代わりに深度センサにより得られた深度画像を平均化した画像を用いて性別推定をする。実験の結果、正解率は91.0%となった。

我々の研究 [5] では、深度センサにより得られた腕や足などの関節の動きの3次元座標に対し、関節間の距離や角度など36個の特徴量を定義し、それらの特徴量の平均値などの統計量を比較することにより識別を行った。本研究では、10人の被験者を用いてEERは0.25であった。本研究により、単純な統計量のみでは識別が困難であることを示した。

### 2.3 加速度、角度センサを使った歩容識別手法

渡辺らは、スマートフォンとウェアラブル端末の加速度センサを用いた歩行認証手法 [15] を提案している。2つの端末の特徴量を組み合わせ機械学習による識別を行った。15名の被験者を用いて識別率は最大で95.3%となった。Mondalらは、身体の関節8カ所 (両肩, 両肘, 両膝, 左右の足の付根) に角度センサを装着し、Neural Networkなどを用いて識別する手法を提案した。30名の被験者を用いて、最大で100%の精度で識別を行った。

Muaazらは、スマートフォンの加速度センサを用いた個人認証手法 [7] を提案している。Muaazらの手法では、ポケットに入れたAndroid端末の加速度情報の特徴量としており、歩行1サイクル分を1つのテンプレートし、テンプレートを複数登録する。認証時はそれぞれのテンプレートとのDTW距離を計算し、50%以上のテンプレートとのDTW距離が閾値以下であれば本人と判定している。

### 2.4 歩容からの属性推定

橋口らは、歩行の軌跡データを用いてパーキンソン病 (PD) の診断をする手法 [16] を提案した。本手法は、ウェアラブルセンサから取得した加速度に対してサポートベクターマシン (SVM) を用いることで健常高齢者、軽度PD患者、重度PD患者を識別した。

### 2.5 DTW

DTW [17] は、音声識別などに使用されるパターンマッチングの手法である。長さの異なる2つの時系列データの距離が与えられたとき、一部のデータが損失していても、時間軸を収縮させてデータの類似距離を算出する。長さ  $N_p \neq N_q$  の2つの時系列データ  $P = (p_1, p_2, \dots, p_{N_p})$ ,  $Q = (q_1, q_2, \dots, q_{N_q})$  のDTW距離は  $d(P, Q) = f(N_P, N_Q)$  と定める。ただし、 $f(i, j)$  は次のように再帰的に定める。

$$f(i, j) = \|p_i - q_j\| + \min \begin{cases} f(i, j - 1), \\ f(i - 1, j), \\ f(i - 1, j - 1), \end{cases} \quad (1)$$

$$f(0, 0) = 0, f(i, 0) = f(0, j) = \infty. \quad (2)$$

## 2.6 歩容に対するなりすまし

Muaaz らの研究 [7] では、通常の他人受入率に相当する誤りを、意図せず他人と識別されてしまう zero-effort attack と位置づけ、さらに、歩行者の動きを見て意図的にまねる minimal-effort attack に対する耐性を評価した。zero-effort attack では 35 人の被験者を用いて EER=0.13, minimal-effort attack ではアフタースクールの学生 5 人の被験者を用いて同様の条件の下で他人受入率 False Acceptance Rate (FAR)=0 と評価している。

歩容は指紋や虹彩など他の生体認証と異なり、身長などの身体的な特徴と手足の動きである行動的特徴の両方を用いて識別を行うため、他の手法と比べて意図的ななりすましに対して頑強であることが示された。

## 3. 提案手法

本研究では、モーションキャプチャセンサーなどから得られた関節の 3 次元座標を測定し、1 歩分の時系列データの DTW 距離を算出することによって個人識別を行う。提案手法は次の 4 つのステップからなる。

- (1) サイクル切り出し
- (2) 関節座標の相対座標化
- (3) DTW 距離の計算
- (4) 本人識別

### 3.1 1 サイクル切り出し

身体の関節  $l$  の時刻  $t$  における 3 次元空間の絶対座標を  $a_l(t) = (x, y, z)$  とする。ただし、原点はモーションキャプチャセンサーの位置とする。測定期間における絶対座標の時系列データ  $\{a_l(t_1), a_l(t_2), \dots\}$  をスケルトンデータと呼ぶ。

スケルトンデータから歩行の 1 サイクル分を抽出する。まず、時刻  $t$  の左右の足の絶対座標  $a_{LF}(t), a_{RF}(t)$  から、両足の間の距離  $\Delta(t) = \pm \|a_{RF}(t) - a_{LF}(t)\|$  を算出する。右足が前のときは符号を正、左足が前のときは負とする。次に、両足の間の距離  $(\Delta(t_1), \dots, \Delta(t_N))$  の時系列データにフーリエ変換を適用し、全周波数成分の 1/30 の低周波数成分のみを残して、残りを 0 とする。すなわち、ローパスフィルタをかけることでノイズを除去し、そのピーク間の  $N$  個のデータを 1 サイクルとする。

以上の処理を行って求めたフィルタ前後の両足間距離の変化を図 1 に示す。ここで時刻  $t$  は、モーションキャプチャのフレームレートに対応した単位である。たとえば、フレームレート 30 fps のセンサーでは、1/30 [s] の間隔を示




図 1 両足間の距離 (黒) とそのローパスフィルタ後の距離 (赤)  
**Fig. 1** Change of distance between feet (black) and that of low pass filtered (red).

しており、図 1 は約 2.6 秒の変化である。小さく変動し、高周波成分を含んでいる  $\Delta(t)$  (黒色) が、ローパスフィルタにより、ゆるやかな変化の時系列データ (赤色) に変換されていることが分かる。このピーク (時刻 37 と 70) 間のデータを抽出し、それを  $t_1, \dots, t_N$  ( $N = 34$ ) の 1 サイクルの時系列データと正規化する。

### 3.2 関節座標の相対座標化

歩行中の各関節の座標について、身体を中心付近の安定している関節を原点とした相対座標を計算する。4 章の実験では中心関節として、Kinect SDK において SpineMid と呼ばれる脊椎の中心の関節を用いる。

関節  $l$  の時刻  $t$  の絶対座標を  $a_l(t)$ 、中心の関節の絶対座標を  $a_*(t)$  とすると、相対座標は  $r_l(t) = a_l(t) - a_*(t)$  と定める。

### 3.3 DTW 距離の計算

類似度は DTW を用いて定める。本手法では 1 つの関節につき xyz 座標の 3 軸が存在するため、DTW のノルムとして、3 次元ベクトルのユークリッド距離

$$\begin{aligned} \|p_i - q_j\| &= \sqrt{(p_{i,x} - q_{j,x})^2 + (p_{i,y} - q_{j,y})^2 + (p_{i,z} - q_{j,z})^2} \end{aligned}$$

を用いる。

1 サイクルの関節  $l$  の 2 つの時系列データ  $R_l = \langle r_l(t_1), \dots, r_l(t_N) \rangle$  と  $R'_l = \langle r'_l(t_1), \dots, r'_l(t_{N'}) \rangle$  の DTW 距離  $d(R, R')$  を  $R$  と  $R'$  の類似度とする。  $R = R'$  のとき、  $d(R, R') = 0$  である。DTW なので  $N = N'$  である必然性はないが、3.1 節のサイクル切り出しで正規化はされているため、ほぼ同じ長さに揃っている。

複数の部位の DTW 距離を統合する手法は 3.6 節で述べる手法を用いる。

### 3.4 本人識別 (閾値を基にする手法)

$U$  を全ユーザの集合とする. あるユーザ  $u$  の  $c$  個<sup>\*2</sup>の関節からなる, 正規化された相対座標の時系列データ  $(R_1, \dots, R_c)$  を  $\mathbf{R}^{(u)}$  とする. 1 サイクル分の正規化時系列データが  $s$  個分  $\mathbf{R}_1^{(u)}, \dots, \mathbf{R}_s^{(u)}$  与えられたとき, その1つをテンプレート  $\mathbf{R}_*^{(u)}$  とする.

時系列データ  $\mathbf{R}^{(u)}$  と  $\mathbf{R}^{(v)}$  の統合 DTW 距離が  $D(\mathbf{R}^{(u)}, \mathbf{R}^{(v)}) \leq \theta$  であるとき,  $u = v$  と判断する.

閾値  $\theta_\ell^*$  は, 次のようにして定まる EER によって定める.  $u$  の時系列データの集合を  $W^{(u)} = \{\mathbf{R}_1^{(u)}, \dots, \mathbf{R}_s^{(u)}\}$  とする. このとき, 本人拒否率 False Rejection Rate (FRR) と FAR は以下のように求める.

$$FRR(\theta, u) = \frac{|\{\mathbf{R}^{(u)} \in W^{(u)} | D(\mathbf{R}^{(u)}, \mathbf{R}_*^{(u)}) > \theta\}|}{|W^{(u)}|} \quad (3)$$

$$FAR(\theta, u) = \frac{|\{\mathbf{R} \in W - W^{(u)} | D(\mathbf{R}, \mathbf{R}_*^{(u)}) \leq \theta\}|}{|W^{(u)}|} \quad (4)$$

ここで,  $W$  は全ユーザの全時系列データの集合である. 全ユーザの平均を  $\theta$  における

$$FRR(\theta) = \frac{1}{|U|} \sum_{u \in U} FRR(\theta, u) \quad (5)$$

$$FAR(\theta) = \frac{1}{|U|} \sum_{u \in U} FAR(\theta, u) \quad (6)$$

とする. これを用いて  $FAR(\theta) = FRR(\theta)$  となる誤差率を EER とし, そのときの閾値を  $\theta_\ell^*$  とする.

### 3.5 本人識別 ( $k$ -NN を用いた手法)

$k$ -NN を用いた識別手法である. 登録されている  $n$  人の  $U$  の全テンプレートの全関節と DTW 距離を計算する. 得られた DTW 距離を関節  $\ell$  の標準偏差  $\sigma_\ell$  で正規化する.  $u$  の全関節データを  $\mathbf{R}^{(u)} = (R_1^{(u)}, \dots, R_{24}^{(u)})$ , テンプレート集合を  $T = \{R_1^{(u_1)}, \dots, R_{24}^{(u_1)}, \dots, R_1^{(u_n)}, \dots, R_{24}^{(u_n)}\}$  とすると, 上位  $k$  個の特徴量の持ち主の多重集合は  $V(\mathbf{R}^{(u)}) =$

$$\left\{ v \in U \mid \frac{d(R_\ell^{(u)}, R_\ell^{(v)})}{\sigma_\ell} \leq \lambda, \ell \in \{1, \dots, 24\}, R_\ell^{(v)} \in T \right\}$$

と定める.  $\lambda$  は  $n$  人分, 24 関節のテンプレートの中で  $\frac{d_\ell}{\sigma_\ell}$  の小さい順から  $k$  位の値とする.  $V(\mathbf{R}^{(u)})$  の中で最も多く含まれているユーザがテストデータの持ち主であるとする.

$k$  の適切な大きさは自明ではなく, 小さすぎるとトラッキングエラーなどの小さなノイズの影響を受けてしまい, 大きすぎると似ている他人のデータが多く近傍に入ってしまうため精度が低下してしまう.

### 3.6 複数特徴量の統合手法

各関節の DTW 距離を統合することで精度の向上が期待

<sup>\*2</sup> たとえば Kinect では 24 個の関節を使えるが, その一部を用いて識別を行う.

できるが, 最適な統合手法は自明ではない. そこで本研究では以下の 6 つの特徴量統合手法を比較する.

(1) 関節ごとの重み付けベクトルのユークリッド距離

- (a) 一様な重み
- (b) DTW 距離の標準偏差 (SD) を用いた重み
- (c) EER を用いた重み
- (d) EER と SD を両方用いた重み

(2) 全関節 DTW 距離の投票

(3) DTW 距離のマハラノビス距離

#### 3.6.1 一様な DTW 距離のベクトルのユークリッド距離

単純に各関節の DTW 距離のベクトルのユークリッド距離を求める手法である. 関節  $\ell$  におけるテンプレートと対象特徴量間の DTW 距離を  $d_\ell$ , 統合後の距離を  $D_{euc}$  とすると, 関節  $\ell$  と  $m$  を統合した距離は  $D_{euc} = \sqrt{d_\ell^2 + d_m^2}$  と定める.  $D_{euc}$  が閾値  $\theta_{euc}$  以下の場合には本人, それ以外の場合には他人と識別する.

#### 3.6.2 EER で重み付けしたベクトルのユークリッド距離

EER が小さい関節は安定して識別に有益であるので, DTW 距離に  $1/EER$  を重み付けする手法である. 関節  $\ell$  と  $m$  の EER  $E_\ell$  と  $E_m$  を統合した距離は,  $D_{eer} = \sqrt{\left(\frac{d_\ell}{E_\ell}\right)^2 + \left(\frac{d_m}{E_m}\right)^2}$  と定める.  $D_{eer}$  が閾値  $\theta_{eer}$  以下の場合には本人, それ以外の場合には他人と識別する.

#### 3.6.3 SD で重み付けしたユークリッド距離

個人差が大きい関節は識別に有益であるという仮定の下で, 各関節ごとに, 他人と比較したときの DTW 距離の標準偏差 SD の逆数を用いて重み付けをする手法である. 関節  $\ell$  と  $m$  の SD  $\sigma_\ell$  と  $\sigma_m$  を統合した距離は  $D_{sd} = \sqrt{\left(\frac{d_\ell}{\sigma_\ell}\right)^2 + \left(\frac{d_m}{\sigma_m}\right)^2}$  と定める.  $D_{sd}$  が閾値  $\theta_{sd}$  以下の場合には本人, それ以外の場合には他人と識別する.

#### 3.6.4 EER と SD で重み付けしたベクトルのユークリッド距離

3.6.2 項と 3.6.3 項をハイブリッドに組み合わせた手法である. 関節  $\ell$  と  $m$  の EER  $E_\ell, E_m$  と他人との DTW 距離の SD  $\sigma_\ell, \sigma_m$  を統合した距離は  $D_{eer\_sd} = \sqrt{\left(\frac{d_\ell}{E_\ell \sigma_\ell}\right)^2 + \left(\frac{d_m}{E_m \sigma_m}\right)^2}$  と定める.  $D_{eer\_sd}$  が閾値  $\theta_{eer\_sd}$  以下の場合には本人, それ以外の場合には他人と識別する.

#### 3.6.5 投票方式

$c$  個の関節の DTW 距離のうち, DTW 閾値  $\theta$  を下回っている関節の数が閾値  $\theta_t$  個以下の場合には本人, それ以外の場合には他人と識別する.

#### 3.6.6 マハラノビス距離

DTW 距離ベクトルのマハラノビス距離 [18] を用いた手法である. 関節  $\ell$  と  $m$  の DTW 距離の平均値を  $\hat{d}_\ell$  と  $\hat{d}_m$  とするとき, マハラノビス距離  $D_m$  は,

$$D_m^2 = \frac{1}{k_m} \begin{pmatrix} d_\ell & d_m \end{pmatrix} \begin{pmatrix} 1 & r \\ r & 1 \end{pmatrix}^{-1} \begin{pmatrix} d_\ell \\ d_m \end{pmatrix}$$

$$\begin{aligned}
 &= \frac{1}{k_m} \begin{pmatrix} d_\ell & d_m \end{pmatrix} \frac{1}{1-r^2} \begin{pmatrix} 1 & r \\ r & 1 \end{pmatrix}^{-1} \begin{pmatrix} d_\ell \\ d_m \end{pmatrix} \\
 &= \frac{d_\ell^2 - 2rd_\ell d_m + d_m^2}{k_m(1-r^2)}
 \end{aligned}$$

で与えられる．ここで， $k$  は次元の数で， $k = 2$ ， $r$  は  $d_\ell$  と  $d_m$  の相関係数である． $r = 0$  のとき（無相関）， $D_m^2 = (d_\ell^2 + d_m^2)/2$  となり， $D_{euc}$  と等しくなる． $D_m$  が閾値以下の場合には本人，それ以外の場合には他人と識別する．

## 4. 評価実験

### 4.1 実験目的

本実験の目的を以下に示す．

- Kinect から得られるスケルトンデータと DTW を用いた提案識別手法において，各特徴量ごとの精度を明らかにする．
- 複数特徴量の統合手法の精度を評価し，最も有効な手法を明らかにする．
- 統合する特徴量数  $c$  による精度の変化，最適な値を明らかにする．
- 被験者数  $n$  による精度の変化を明らかにする．
- 深度センサから得られる関節の部分集合で識別に有効な関節の最適な組合せを求める．
- 箱を持つなどいくつかの外乱により識別精度がどの程度変化するかを検証する．
- $k$ -NN において，誤差を最小化する  $k$  を明らかにする．

### 4.2 実験方法

#### 4.2.1 データ収集

Kinect v2 を用いて歩行データを収集し，提案手法の精度を求める．実験に関する情報を表 2 に示す．測定環境は図 2 のとおりであり，直進歩行中の時刻  $t$  のスケルトンデータ  $a_1(t), \dots, a_{25}(t)$  を正面から測定する\*3．Kinect は床から 0.9m の位置に水平を向いて固定する．Kinect より 5.5m の離れた位置から歩行を開始し，1m の位置で終了する．歩容の測定は 4.5m 地点から 2m 地点までの区間で行う．1 人について 5 回ずつ測定を行い，各測定について欠損値の少ない 1 歩分のスケルトンデータをとる．すなわち，5 個/人  $\times$  145 人 = 760 データを用いて分析を行う．被験者は本大学の学生，職員，地域の方である．期間 2 における実験の様子を図 3 に示す．

#### 4.2.2 各関節の DTW 距離の算出

本実験では Kinect から取得した関節座標のうち Spine-Mid（脊椎の中心）を中心とする．SpineMid 以外の 24 個の関節それぞれについて SpineMid を原点とした相対座標を計算する．それぞれの関節  $\ell$  について DTW 距離

\*3 測定したデータを，SpineMid を原点とする相対座標に変換するため，特徴量は 24 個となる．

表 2 被験者の情報  
Table 2 Subjects of the experiments.

項目	期間 1	期間 2
実験日時	2018 年 4 月 19 日 12 時 40 分から 2 時間	2018 年 7 月 26, 27, 30 日 11 時 00 分から 7 時間
人数	31 名	114 名
男女比	男性 26 名 女性 5 名	男性 77 名 女性 44 名
年齢	18~51 歳	18~70 歳
場所	本学教室	本学体育館




図 2 実験環境

Fig. 2 Environment of experiment.




図 3 実験風景

Fig. 3 Experimental landscape.

$d(R_\ell^{(u)}, R_\ell^{(v)})$  を計算し，閾値  $\theta_\ell^*$  を求める．

#### 4.2.3 被験者数 $n$ の変化による FAR の変動

生体認証手法の評価をする際は通常，大規模な被験者データを用いる必要がある．本実験では用いるデータの被験者数に限界があるため，評価の信頼性を図るために本実験における被験者数（規模）が精度に及ぼす影響を明らかにする．

瀬戸の著書 [19] によると，一般に信頼度 95% において，誤差  $p$  の照合アルゴリズム評価に必要な最低のテンプレート数と照合用サンプルの組数（照合組数） $N_{min}$  は  $N_{min} \approx 3/p$  と表せる．つまり，1% ( $p=0.01$ ) の精度で評価を行う場合  $N_{min} = 300$  であり，本実験ではそれぞれの総当たりで精度を計算するため必要な人数  $n$  は  $\frac{n(n-1)}{2} > 300$  を解いて 25 人である．実験で用いた被験者数が妥当であることを確かにする必要がある．

$c = 1$  のときの  $D_{euc}$  について， $n$  を 5 から 145 まで，5 ずつ変化させたときのそれぞれの関節ごとの FAR を計算

表 3 評価する外乱と各被験者数

Table 3 Num. of subjects for each of obstacle.

	外乱	人数
1	大股 & 手大振り	38
2	箱を持つ	38
3	スマートフォンを操作する	39



図 4 外乱のサンプル

Fig. 4 Sample obstacles.

する. 閾値は, FRR が 0.1 になるよう調整する\*4.

#### 4.2.4 統合する関節の数 $c$ の評価

統合する関節の数  $c$  についての変動を確かめるため, 24 個の関節からランダムに  $c$  個を抜き出し, その関節のみを用いて繰り返し EER を計算する.  ${}_{24}C_c$  は  $c$  の値によっては膨大になってしまうため, 最大で 300 組に制限する\*5.

#### 4.2.5 各特徴量統合手法の精度評価

提案手法の 6 つの統合手法の精度を計算する.  $n = 145$  に固定して EER を調べる. 6 つの統合手法のそれぞれについて,  $c = 8$  のとき, ランダムに選んだ関節の組合せをそれぞれ 300 組計算する.

#### 4.2.6 最適な関節の選択

24 個の関節の DTW 距離すべての組に関して相関係数を求める. すべての関節について, 相関係数が最も高い関節を選び, 同じグループとする. 複数の関節が同一グループに属することがあり得る. したがって, 最大で 12 グループ構成されるが, 多くはいくつかのグループに集中するためより少ないグループ数となる.

グループ内で最小の EER を持つ関節をそのグループの代表関節とする. 複数の関節を統合して識別する際にこれらの代表関節を用いる.

#### 4.2.7 外乱に対する精度の評価

表 2 の期間 2 の被験者から, 外乱を含んだ歩行のデータを収集する. 外乱のリストと収集した人数を表 3 に示す. それぞれの外乱のサンプルを図 4 に示す.  $k$ -NN を用いて識別したときの外乱に対する精度を FRR により評価する.

\*4 なお,  $c = 1$  の場合は重み付けベクトルを使用する 4 手法  $D_{euc}$ ,  $D_{eer}$ ,  $D_{sd}$ ,  $D_{eer\_sd}$  では EER は同じ結果となる.

\*5 予備実験を通じて, 300 組で十分であると判断した.




図 5 1 サイクルのスケルトンデータ  $a(t)$  の変化

Fig. 5 Change of skeleton data  $a(t)$  in one cycle.

$k$ -NN を用いることで外乱への耐性が強化されると期待されるが, 複数関節を組み合わせるときは  $k$  によって精度が変化する. そこで, 最適な  $k$  を求めるため  $k$  をいくつか変動させたときの FRR を求める. 通常歩行の 145 名分のデータを 1 人あたり 5 つあるので, ランダムで 1 つをテンプレートデータとし, 残りの 4 つをテストデータとする. 外乱のデータは合計 115 名分, 1 人あたり 5 つすべてをテストデータとする. それぞれの関節を単体で用いたとき, 24 関節すべてを用いたときの FRR を求める. 単体のときは  $k$ -NN の候補に本人のデータが 1 つしかないため近傍の数  $k = 1$  で計算をする.

### 4.3 実験結果

#### 4.3.1 データ収集

収集したスケルトンデータ  $a(t)$  の一部を図 5 に示す. 24 個の関節のうち主要な 11 個 (Head, SpineShoulder, ShoulderRight/Left, HandTipRight/Left, SpineBase, HipRight/Left, FootRight/Left) のみをプロットしている. これは 24 歳男性の歩行であり, 頭を左右に振りながら歩いている特徴が分かる. 本例は,  $t_1, \dots, t_{33}$  の 1.1 秒が 1 サイクルであった.

#### 4.3.2 各関節の DTW 距離の算出

測定したスケルトンデータの時系列データについて, 各関節ごとに DTW 距離を計算した. 例として関節 HandTipLeft の DTW 距離の算出過程を図 6, 図 7 に示す. 赤線が被験者 1, 青線が被験者 2 の HandTipLeft の動きの 3 次元座標の 2 次元のみの軌跡であり, DTW のマッチしている時系列データ間を灰色線で結んでいる. 図 6 は被験者 1 と 2 が同一人物同士で比較した場合. 図 7 は異なる人物間で比較した場合である.

図 6 の本人間の関節の変化は似通っており, 図の灰色線分の総和で与えられる DTW 距離は  $d(R_{HTL}^{(u)}, R_{HTL}^{(u)}) = 0.45$  である. したがって, この青線の例では 1 サイクルが 30 データであり距離の単位は m であるため, 1/30 秒の間に左手の変動は平均 1.5 cm である. それに対して, ユーザ  $u$




図 6 関節 HandTipLeft の DTW 距離 (本人間)  
 $(d(R_{HTL}^{(u)}, R_{HTL}^{(u)})) = 0.45$

Fig. 6 DTW distance of HandTipLeft (genuine)  
 $(d(R_{HTL}^{(u)}, R_{HTL}^{(u)})) = 0.45.$




図 7 関節 HandTipLeft の DTW 距離 (他人間)  
 $(d(R_{HTL}^{(u)}, R_{HTL}^{(v)})) = 12.0$

Fig. 7 DTW distance of HandTipLeft (impostor)  
 $(d(R_{HTL}^{(u)}, R_{HTL}^{(v)})) = 12.0.$




図 8 HandTipLeft の DTW 距離の分布

Fig. 8 Distribution of DTW distance of HandTipLeft.

(青) と異なる  $v$  (赤) との間では、どのように時間軸を変化させても手の振りの小さい  $v$  と大きい  $u$  との間には大きな差が生じる。  $d(R_{HTL}^{(u)}, R_{HTL}^{(v)}) = 12.0$  であった。

例として 31 人 5 回の歩行の HandTipLeft について DTW 距離  $d(R_{HTL}^{(u)}, R_{HTL}^{(v)})$  の同一人物間と異なる人物間の分布を図 8 に示す。本人の変動 (赤) は他人との距離 (青) よりも短く、分散も小さい傾向が観察できる。この 2 つの分布が離れているほど、識別に適している関節である。図で濃く表示される面積が FAR と FRR の和を表す。2 つの分布で囲まれるエリアに対して、交点から x 軸に垂線を引いたとき、分割される 2 つのエリアが同面積になる DTW 距離が  $\theta_c^*$  であり、図 8 の HandTipLeft の関節については  $\theta_{HTL}^* = 2.19$  である。HandTipLeft 以外の他の部位についてもほぼ同様の分布をしていた。こうして求めた関節ごとの EER とその標準偏差を EER でソートして表 4 に示す。この標準偏差は本人同士の DTW 距離と他人同士の DTW 距離の両方を含んでいる。

表 4 DTW 距離の統計量

Table 4 Statistics of DTW distances.

	EER	SD		EER	SD
ElbowLeft	0.10	0.62	AnkleRight	0.13	1.64
ElbowRight	0.11	0.64	HandRight	0.14	1.59
ShoulderRight	0.11	0.38	HipLeft	0.14	0.34
ShoulderLeft	0.12	0.40	HandTipRight	0.14	1.83
HandLeft	0.12	1.44	WristRight	0.14	1.30
KneeRight	0.12	1.08	Head	0.14	0.55
WristLeft	0.12	1.20	KneeLeft	0.14	1.14
Neck	0.12	0.31	FootLeft	0.14	1.80
HandTipLeft	0.13	1.67	SpineBase	0.14	0.33
SpineShoulder	0.13	0.23	AnkleLeft	0.14	1.63
HipRight	0.13	0.36	ThumbLeft	0.19	1.48
FootRight	0.13	1.79	ThumbRight	0.19	1.57




図 9 EER で重み付けする方式の EER の分布

Fig. 9 Distribution of EER of the scheme weighted by EER of feature.

#### 4.3.3 統合する関節の数 $c$ の評価

統合する関節を増やすとどの統合手法においても誤差は小さくなる。代表的な手法として EER で重み付けする方式における、 $c$  を変更したときの EER の分布を図 9 に示す。投票方式は増減を繰り返しているが不安定ながら減少していく傾向を示した。また、6 手法すべてにおいて、 $c$  の増加にともない分散もおおむね減少している。

6 つの統合手法について、結合特徴量数  $c$  についての EER の平均値を表 5 と図 10 に示す。表 5 では各  $c$  について、最小の EER に下線を引いている。ほぼすべての  $c$  において、SD と EER で重み付けする方式の EER が最小であった。

#### 4.3.4 被験者数 $n$ の変化による EER の変動

各  $n$  において、145 名の被験者からランダムに  $n$  人サンプリングを 30 回行い、各サンプルを用いた場合の 24 個の関節ごとに FAR を計算した。24 関節のそれぞれのサンプリングごとの平均 FAR の分布を図 11 に示す。

図 11 より、FAR の平均値は  $n > 10$  で  $0.189 \pm 0.005$  の範囲で安定している。FAR の標準偏差は  $n$  に対して単調に減少した。



表 5 結合特徴量の数  $c$  に対する 6 手法の EER の平均値

Table 5 Average of EER of six methods for the number of combined feature quantities  $c$ .

$c$	$D_{euc}$	$D_{eer}$	$D_{sd}$	$D_{eer\_sd}$	Voting	$D_m$
1	0.136	0.136	0.136	0.136	0.134	0.210
10	0.087	0.082	0.063	0.061	0.066	0.093
20	0.082	0.078	0.058	0.056	0.058	0.074
24	0.077	0.080	0.060	0.054	0.055	0.070
平均	0.091	0.087	0.068	0.066	0.077	0.096




図 10 結合特徴量数  $c$  に対する 6 手法の EER の変化

Fig. 10 Change of EER of six methods wrt. num. of features.




図 11 被験者数  $n$  を変更したときの FAR の分布

Fig. 11 FARs wrt. num. of subjects  $n$ .

4.3.5 各統合手法の精度比較

$D_{eer\_sd}$  の本人同士, 他人同士の結合結果のヒストグラムを図 12 に示す. 図 8 と比べて, 図 12 の方が赤と青の重なり部分の面積が小さくなっており, 識別精度が上がっていることが分かる.

$c = 8$  のときの 6 手法について,  $c$  個の関節の組み合わせをランダムにそれぞれ 300 組評価したときの各手法の EER の累積分布を図 13 に示す. 分布が左側に寄っている方が誤差が小さいことを表している. この場合は EER, SD で重み付けする手法が最も有効である.

例として, Head, ElbowLeft, ElbowRight, FootLeft, FootRight の 5 つの関節単体の ROC カーブとこの 5 関節を組み合わせたときの ROC カーブを図 14 に示す. どの統合手法を用いた場合も, 単体の関節を特徴量としたとき




図 12  $c = 8$  のときの  $D_{eer\_sd}$  のヒストグラム

Fig. 12 Histogram of  $D_{eer\_sd}$  ( $c = 8$ ).




図 13 統合手法の EER の累積分布 ( $c = 8$ )

Fig. 13 Cumulative distribution of EER ( $c = 8$ ).

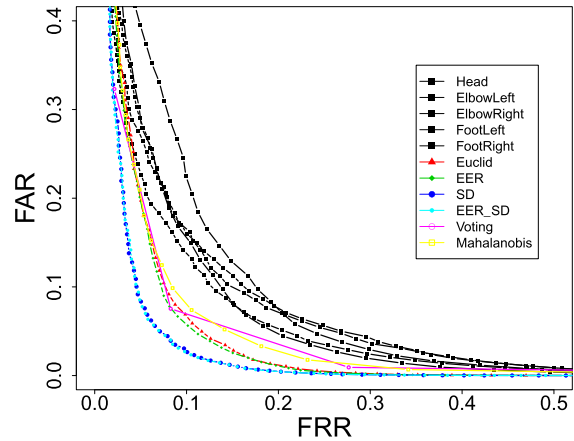


図 14 単体の特徴量 (黒) と統合方式 (カラー) の ROC カーブ

Fig. 14 ROC curves of errors of single and combined features.

表 6 代表関節を用いた際の EER

Table 6 EER with the representative joints.

	$D_{euc}$	$D_{eer}$	$D_{sd}$	$D_{eer\_sd}$	Voting	$D_m$
EER	0.083	0.075	0.048	0.049	0.061	0.086

より EER は小さくなった. SD で重み付けしたもの, SD と EER で重み付けしたものが最も誤差が小さい.

4.3.6 最適な関節の選択

それぞれの関節間の相関係数を用いた多次元尺度構成法 Multi Dimensional Scaling (MDS) のプロットを図 15 に

表 7 独立した関節のグループ  
Table 7 Independent groups of joints.

グループ	関節								代表
1	WristL	HandL	HandTipL	ThumbL	<u>ElbowL</u>				ElbowL
2	HandR	HandTipR	<u>ElbowR</u>	WristR	ThumbR				ElbowR
3	FootL	AnkleL	KneeL	<u>KneeR</u>					KneeR
4	AnkleR	<u>FootR</u>							FootR
5	HipR	SpineBase	ShoulderL	ShoulderR	Head	<u>Neck</u>	SpineShoulder	HipL	Neck

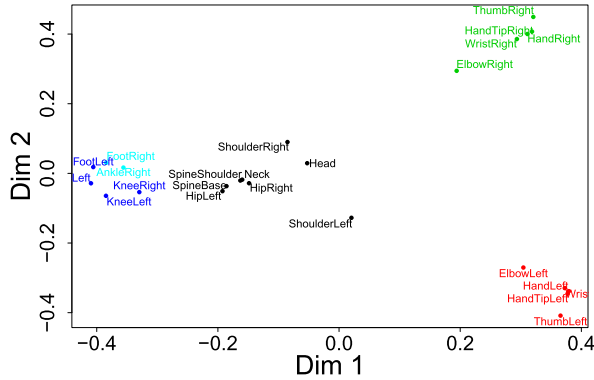


図 15 相関係数の MDS プロット

Fig. 15 MDS plot of correlation coefficients.

表 8 24 関節すべてを用いた際の外乱ごとの FRR

Table 8 FRR for each disturbance when using all 24 joints.

	$k = 20$	$k = 30$	$k = 40$	$k = 50$
normal	0.16	0.13	0.12	0.11
big	0.74	0.72	0.71	0.72
box	0.78	0.78	0.78	0.78
phone	0.54	0.54	0.52	0.55
mean	0.69	0.68	0.67	0.68

示す。相関係数が最も高い関節同士をグルーピングした結果を表 7 に示す。一番右の列に示す代表関節は、グループ内で EER が最も低いものである。おおむね、1：左手、2：右手、3：左足、4：右足、5：その他変動の少ない部位、の 5 グループに分かれているが、グループ 3 の KneeRight だけは左足との相関よりも KneeLeft との相関が強かったため左足グループに分類されている。

代表関節を用いた際の各統合手法の EER を表 6 に示す。SD で正規化したものが最もエラー率が低くなった。

#### 4.3.7 外乱に対する精度の評価

$k$ -NN を用いて 24 関節すべてを用いて識別したときの FRR を表 8 に示す。 $k$ -NN の近傍の数  $k$  については、 $k = 20, 30, 40, 50$  の 4 パターンを評価した。 $k$  を変更しても FRR の変動はそれほど大きくないが、big, box, phone の 3 つの外乱の平均値では  $k = 40$  のときが最小であった。

特徴量を単体 ( $k = 1$ ) で用いたときと  $k$ -NN ( $k = 40$ ) を用いて 24 関節を統合したときの FRR の比較を表 9 に示す。左の 9 列はそれぞれの特徴量を単体で用いたときの値である。外乱ごとの FRR 最小関節 (下線) を列 best に

抜粋した。列  $k$ -NN は複数特徴量を統合したときの値を示す。best と  $k$ -NN を比較すると、通常歩行およびすべての外乱において  $k$ -NN により複数特徴量を統合した方が FRR が小さい。平均すると、特徴量単体で用いたときは最小で FRR は 0.73 であったが、複数特徴量を統合することで 0.67 まで減少した。すなわち、提案方式 ( $k$ -NN) が外乱に対してロバストであることが示された。

#### 4.4 考察

図 10 において、 $D_{sd}$  を用いた場合、 $D_{euc}$  よりもつねに EER が小さくなった。全関節に一樣なユークリッド距離では、特徴量ごとに大きさが異なっていたため値の大きな特徴量に引っ張られていた。これに対して、SD の逆数を重みとすることで、すべての特徴量の値がほぼ公平に扱われるため、誤差率 EER を低下させる効果が生じたと考えられる。

表 5 の各  $c$  の EER の平均値を比較すると、 $D_{eer\_sd}$  を用いた場合は  $D_{sd}$  よりも平均 3.7% 低い。これは、SD によって各特徴量の値がほぼ等しくなるように正規化された後に、EER が小さい、つまり、識別に有効な関節の重みが大きくなったからである。

図 10 より、 $c$  は 6 以上ではほぼ変化が見られないため、 $c = 5$  が適切であると考えられる。本実験では 24 個の特徴量を用いたが、それらの中には独立でないものもあると考えられる。たとえば、右手の指と右手首など、動きの似通った関節を組み合わせても精度はさほど向上しない。表 7 のように、関節の独立性は 5 つのグループに分けられるため、6 つ以上の関節を統合しても精度の向上が頭打ちになったと考えられる。また、本実験で用いた Kinect による関節のトラッキングでは、赤外線を吸収する黒色の服を着ているなどの理由でエラーが頻繁に生じた。それゆえ、用いる特徴量を増やすことでトラッキングエラーが起こる確率も上がり、精度が向上しない原因の 1 つになっていると考える。

図 11 より、 $n$  は 10 以上で平均値が収束していた。4.2.3 項より、信頼度 95% で誤差 1% のときの必要な被験者は 25 人、0.1% で 78 人である。したがって、本実験結果は、0.1% の誤差の範囲で信頼できる結果であると考えられる。なお、エラーの主な原因は Kinect のトラッキングエラーであり、ある程度の FAR の分散は避けられないと考える。

表 9 特徴量単体のときの FRR  
Table 9 FRR of single features.

	Neck	Shoul.R	ElbowR	WristR	HandR	HipR	KneeR	FootR	SpineShoul.	best $k = 1$	$k$ -NN $k = 40$
normal	0.57	0.47	<u>0.33</u>	0.45	0.46	0.53	0.42	0.52	0.57	0.33	0.12
big	0.81	0.87	0.94	0.92	0.92	0.83	<u>0.78</u>	0.87	0.80	0.78	0.71
box	0.93	0.97	1.00	0.98	1.00	1.00	0.88	<u>0.82</u>	0.94	0.82	0.78
phone	0.82	0.92	0.99	0.96	0.94	0.85	<u>0.60</u>	0.74	0.83	0.60	0.52
mean	0.85	0.92	0.98	0.95	0.95	0.89	0.75	0.81	0.86	0.73	0.67

外乱に対する  $k$ -NN を用いた手法でも複数の特徴量を用いることで精度が向上した。これは、正規化した DTW 距離でソートし、上位のデータのみを用いることで、手など外乱に対して大きな影響を受けてしまう関節ではなく、膝など、外乱を含んでいても比較的安定して識別が可能な関節を用いて認証が行えたからである。

### 5. リアルワールドでの応用

本研究で提案した歩容識別手法は対象者の協力を必要とせずに識別を行うことが可能である。本手法を用いることで、建物などの複数の箇所に設置したセンサから観測した歩容が同一人物のものかを識別することができ、それぞれの対象者の動線推定が可能となる。店舗や建物などで観測した動線を人流情報としてマーケティングなどに活用することや、街で犯罪者の追跡など、防犯や犯罪捜査などに応用できる。

また、本研究では歩きスマホなどをしていても通常歩行と同じように識別する手法を提案したが、この手法を応用することで歩きスマホをしている人やスーツケースなどの荷物を持っている人などの判別も遠距離から可能となる可能性がある。これは、顔画像やウェアラブルデバイスなどを用いてもできない、歩容ならではの応用である。先行研究 [9], [14] では歩容から性別推定をしているが、同様に年齢などを推定できる可能性もある。それらを組み合わせることでより多くの情報を取得することが可能となる。

本実験では計算を簡素にするために Kinect を用いて被験者の歩行を真正面から撮影したが、本手法を用いる際は正面から撮影する必要はないことに注意されたい。なぜならば、Kinect で測定されるのは 3 次元の時系列データであるので、側面や斜め上から撮影したデータからでもアフィン変換などを用いて座標軸を変換することで同様に識別ができるからである。それゆえに様々な利用シーンに応用できると考える。

\*6 本実験で求めた FRR はテンプレートが登録されている人数に依存する定義になっており、 $n = 145$  人中、最も近いデータのみ本人と判断している。したがって、一様な確率で識別したときの誤り確率 (FRR) は  $(1 - \frac{1}{145}) \approx 0.99$  であり、提案手法の 0.67 はそれを大きく下回っている。

### 6. おわりに

本研究では、深度センサなどにより得られた 3 次元の関節の時系列データに対して DTW 距離を算出し、結果を統合して個人識別を行う手法を提案した。145 名の被験者を用いて精度評価を行い、両肘、右膝、右足、首などの 5 個の関節の動きの特徴量を統合することで EER=0.048 で個人を識別することを示した。これは、ウェアラブルセンサを用いた最新の Muaaz らの研究で達成した EER=0.13 よりも小さな値である。本実験では、最大 24 個の関節の動きを使うことができたが、関節の中には右掌と右ひじのように相関が高いものがあり、個人を識別するに冗長である。また、箱を持つ、スマートフォンを操作するなどの外乱を含むデータに対して提案手法の精度を検証した。複数の特徴量を組み合わせることで、従来の単体のセンサを用いる手法では FRR が 0.73 に増大したのに対して、平均で 0.67 の FRR となり、従来手法よりも外乱に対しても頑強な手法である\*6。

謝辞 有益な助言をいただいた静岡大学創造科学技術大学院西垣正勝教授、同大木哲史講師に感謝いたします。

### 参考文献

- [1] 脇 一史, 森 駿文, 菊池浩明: CNN を用いた顔認証システムの開発と追跡停止に対する評価, 情報処理学会第 80 回全国大会, Vol.3, pp.543–544 (2018).
- [2] 森 駿文, 菊池浩明: 歩容データの DTW 距離に基づく個人識別手法の提案と外乱に対する評価, マルチメディア, 分散, 協調とモバイルシンポジウム (DICOMO2018), pp.672–680 (2018).
- [3] 森 駿文, 菊池浩明: 歩容データの DTW 距離に基づく個人識別における複数部位のフュージョン手法, コンピュータセキュリティシンポジウム (CSS2018), pp.1–8 (2018).
- [4] 森 駿文, 菊池浩明: 複数の歩容特徴量の  $k$  近傍による「歩きスマホ」にロバストな個人識別手法の提案, 暗号と情報セキュリティシンポジウム (SCIS2019), pp.1–7 (2019).
- [5] Mori, T. and Kikuchi, H.: Person Tracking Based on Gait Features from Depth Sensors, *The 21st International Conference on Network-Based Information Systems (NBIS-2018)*, Vol.22, pp.743–751 (2018).
- [6] Han, J. and Bhanu, B.: Individual Recognition Using Gait Energy Image, *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol.28, No.2, pp.316–322 (2006).
- [7] Muaaz, M. and Mayrhofer, R.: Smartphone-Based Gait

- Recognition: From Authentication to Imitation, *IEEE Trans. Mobile Computing*, Vol.16, No.11, pp.3209–3221 (2017).
- [8] Rokanujjaman, M., Hossain, M.A. and Hossin, M.A.: Part-based gait identification using fusion technique, *2014 International Conference on Informatics, Electronics Vision (ICIEV)*, pp.1–5 (2014).
- [9] Li, X., Maybank, S.J., Yan, S., Tao, D. and Xu, D.: Gait Components and Their Application to Gender Recognition, *IEEE Trans. Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, Vol.38, No.2, pp.145–155 (2008).
- [10] Bakchy, S.C., Islam, M.R. and Sayeed, A.: Human identification on the basis of gait analysis using Kohonen self-organizing mapping technique, *2016 2nd International Conference on Electrical, Computer Telecommunication Engineering (ICECTE)*, pp.1–4 (2016).
- [11] Shiraga, K., Makihara, Y., Muramatsu, D., Echigo, T. and Yagi, Y.: GEINet: View-invariant gait recognition using a convolutional neural network, *2016 International Conference on Biometrics (ICB)*, pp.1–8 (2016).
- [12] 村松大吾, 榎原 靖, 八木康史: 任意視点変換モデルを用いた歩容認証における変換視点の考察, 信学技報 (Proceedings of Biometrics Workshop BioX2013-14), pp.52–55 (2013).
- [13] Preis, J., Kessel, M., Werner, M. and Linnhoff-Popien, C.: Gait Recognition with Kinect, *Proc. 1st Workshop on Kinect in Pervasive Computing* (2012).
- [14] Igual, L., Lapedriza, A. and Borràs, R.: Robust gait-based gender classification using depth cameras, *EURASIP Journal on Image and Video Processing*, Vol.2013, No.1, pp.1–11 (2013).
- [15] 渡辺一樹, 長友 誠, 油田健太郎, 岡崎直宣, 朴 美娘: スマートフォンとウェアラブル端末の加速度センサを用いたスマートロックにおける歩行認証, コンピュータセキュリティシンポジウム (CSS2018), pp.173–178 (2018).
- [16] 橋口裕徳, 堀 宏有, 廣部祐樹, 沢田裕之, 稲葉 彰, 織茂智之, 三宅美博: 歩行軌道データに基づくパーキンソン病の早期診断システム, 第 28 回自律分散システム・シンポジウム, pp.155–158 (2016).
- [17] Berndt, D.J. and Clifford, J.: Using Dynamic Time Warping to Find Patterns in Time Series, *KDD Workshop* (1994).
- [18] Mahalanobis, P.C.: On the generalized distance in statistics, *Proc. National Institute of Sciences (Calcutta)*, Vol.2, pp.49–55 (1936).
- [19] 瀬戸洋一: サイバーセキュリティにおける生体認証技術, 共立出版株式会社 (2002).

において研究室内の記憶装置などで保管すること。ただし、研究目的が達成したら削除することとする。



森 駿文

2017 年東京電機大学理工学部理工学科卒業。2019 年明治大学大学院先端数理科学研究科博士前期課程修了。現在、ヤフー株式会社所属。



池 浩明 (正会員)

1988 年明治大学工学部電子通信工学科卒業。1990 年同大学院博士前期課程修了。1994 年同博士 (工学)。1990 年 (株) 富士通研究所入社。1994 年東海大学工学部電気工学科助手。1995 年同専任講師。1999 年同助教授, 2006 年同情報理工学部情報メディア学科教授。1997 年カーネギーメロン大学計算機科学学部客員研究員。2013 年明治大学総合数理学部先端メディアサイエンス学科教授。2016 年同大学院先端数理科学研究科長。WIDE プロジェクト暗号メールシステム FJPEM の開発, 認証実用化実験協議会 (ICAT), IPA 独創情報技術育成事業等に従事。暗号プロトコル, ネットワークセキュリティ, ファジィ論理, プライバシー保護データマイニング等に興味を持つ。1990 年日本ファジィ学会奨励賞, 1993 年情報処理学会奨励賞, 1996 年 SCIS 論文賞, 2010 年度, 2017 年度情報処理学会 JIP Outstanding Paper Award。2013 年 IEEE AINA Best Paper Award。2014 年情報セキュリティ文化賞。電子情報通信学会, 日本知能情報ファジィ学会, IEEE, ACM 各会員。本会フェロー。

## 付 録

### A.1 同意書の記載内容

- (1) 歩行情報の識別の評価実験を行う研究目的で、以下の情報を取得し、解析すること。
  - 歩行の動画データ (深度, 軌跡)
  - 基本情報 (氏名, 年齢, 性別, 身長, 連絡先)
- (2) 本研究で行った解析データを、本人を特定できないように加工して、学術論文などに出版すること。
- (3) 取得したデータを、十分な安全管理措置 (氏名は削除し、仮の ID に置換える) のうえ、研究の実施期間に