

## 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

# Proposal on Person Identification Method using $k$ -Nearest Neighbors of Multiple Gait Features that is Robust against “Smartphone Zombie”

森 駿文\*                      菊池 浩明†  
Takafumi Mori                Hiroaki Kikuchi

あらまし 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ているが、歩きスマホや大きな荷物を持つなどの様々な外乱に対して精度が落ちる課題があった。そこで、我々は Microsoft 社の Kinect から得られる 3次元の時系列データに DTW を適用し、複数の特徴量を組み合わせて  $k$  近傍 ( $k$ -NN) を求め、外乱の影響にロバストな識別手法を提案する。145名の被験者を用いて精度評価を行い、箱を持って歩く、スマートフォンを操作しながら歩く、手足を大きく振るといった 3種類の外乱に対してロバストであることを報告する。

キーワード DTW, 歩容, 人物識別, 生体認証

## 1 はじめに

近年、カメラやセンサなどを用いて個人の特徴を抽出することで識別・追跡し、マーケティングや防犯などに活用する試みが始まっている。中でも、歩容は生活者の取得の抵抗感も少なく、歩行の動線を抽出するような応用には十分な精度があり向いている。その方法には様々なものがあり、未だ研究途上である。たとえば、大塚ら [1] は、深度センサにより得られる情報は個人情報にはならないとしたうえで人流推定実験を行った。また、Muaazら [2] は、スマートフォンの加速度センサのデータに対し DTW を用いる認証を提案している。一方、我々は、深度センサにより得られる歩容の情報から個人識別をする研究を行ってきた [3][4]。

[3] では、深度センサを用いて得られる歩行中の関節の 3次元座標に、音声認識などでよく使われる Dynamic Time Warping (DTW) [5] を適用することで歩容識別を行う手法を提案した。本手法は、深度センサによって得られた関節の座標の時系列データについて、各関節ごとにテンプレートとの DTW を計算し、DTW 距離から成

る多次元ベクトルのユークリッド距離を用いて識別を行う。31名の被験者を用いた実験により、EER が良い順に関節を 5つ統合した際に EER が 0.03 となることを明らかにした。[4] では、[3] をもとに、複数特徴量の統合手法を 6種類提案し、145名の被験者を用いた実験により、EER と標準偏差を用いた結合手法が EER を最小化すること、特徴量の最適統合数は 5 であることなどを明らかにした。しかし、[4] では通常の歩行データのみを用いて精度評価をしていた。歩容を用いた個人識別においては、カバンを持つ、スマートフォンを操作するなどの外乱の考慮をしなければならない。歩きスマホをすると腕が動かなくなるので、腕を動かすテンプレートと DTW でマッチングに失敗してしまう。

そこで、本研究では、[4] をもとに、 $k$  近傍法 ( $k$ -NN) を用いることで、外乱の影響を受けにくい特徴量のみを用いるロバストな識別手法を提案する。上位  $k$  個の近傍だけを用いるので、腕がマッチしなくても他の関節で補償することが期待できる。新たに 111 名分の外乱を含んだ歩容データを用いて実験を行い、提案手法がこれらの外乱にロバストであるかを評価する。

本稿では、2章では関連研究の調査結果を、3章において、 $k$ -NN を用いた識別手法を提案する。145名分の通常歩行、外乱を含む 111名分の歩行データを用いた評

\* 明治大学大学院, 東京都中野区中野 4-21-1, Meiji University, 4-21-1 Nakano, Nakano-ku, Tokyo 164-8525, Japan. cs172059@meiji.ac.jp

† 明治大学, 東京都中野区中野 4-21-1, Meiji University, 4-21-1 Nakano, Nakano-ku, Tokyo 164-8525, Japan. kiken@meiji.ac.jp

備実験を行い、4章にて報告する。最後に、5章で本研究のまとめを行う。

## 2 関連研究

### 2.1 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[6]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[7]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[8]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。

### 2.2 加速度、角度センサーを使った歩容識別手法

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[2]を提案している。Muaazらの手法では、ポケットに入れたAndroid端末の加速度情報を特徴量としており、歩行1サイクル分を1つのテンプレートとし、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]の特長な点は、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、更に、歩行者の動きを見て意図的に真似るminimal-effort attackを導入したところにある。zero-effort attackでは35人の被験者を用いてEER=0.13、minimal-effort attackでは5人の被験者を用いてFAR=0と評価している。本実験に基づき、指紋や虹彩など他の生体認証と比べて、時系列データを用いる歩容による認証は、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。

しかし、[2]では、対象者のスマートフォンから得られる加速度情報を用いた認証を行っているため、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持ってもらう必要があり、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。

一方、本研究では外側からモーションセンサで観測を行うため、利用者の協力は不要、容易に手足を含めた複数の関節の動きを観測可能であり、外乱を含む歩行に対する無意識な識別に対して有効であると考えられる。

### 2.3 DTW

DTW(Dynamic Time Warping)[5]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、長さの異なる2つの時系列データの距離を与える。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 $d(P, Q)$ は $d(P, Q) = f(n_p, n_q)$ と定義する。ここで、 $f(i, j)$ は次の様に再帰的に定める。

$$f(i, j) = \|p_i - q_j\| + \min \begin{cases} f(i, j-1), \\ f(i-1, j), \\ f(i-1, j-1), \end{cases}$$
$$f(0, 0) = 0, f(i, 0) = f(0, j) = \infty.$$

## 3 提案手法

本研究では、モーションキャプチャーセンサなどから得られた関節の3次元座標を測定し、一步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つのステップから成る。

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

1~3は[3][4]と同様である。本稿では4の本人識別手法について記載する。

$k$ -NNを用いた識別手法である。 $U$ を全ユーザの集合、未知のユーザ $u$ の関節 $\ell$ の歩行1周期を $R_\ell^{(u)}$ とする。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 $R^{(u)} = \{R_1^{(u)}, \dots, R_{24}^{(u)}\}$ 、テンプレート集合を $T =$

表 1: 被験者の情報

項目	情報
実験日時	2018年7月26,27,30日 11時00分から7時間
人数	111名
男女比	男性73名:女性38名
年齢	18~70歳
場所	本学体育館

$\{R_1^{(u_1)}, R_2^{(u_2)}, \dots, R_{24}^{(u_n)}\}$  とすると, 上位  $k$  個の特徴量は  $N(R^{(u)}) =$

$$\left\{ v \in U \mid \frac{d(R_\ell^{(u)}, R_\ell^{(v)})}{\sigma_\ell} \leq \frac{d_\ell^k}{\sigma_\ell}, R_\ell^{(u)} \in R^{(u)}, R_\ell^{(v)} \in T \right\}$$

と定める.  $\frac{d_\ell^k}{\sigma_\ell}$  はテンプレートの中で小さい順から  $k$  位の特徴量とする.  $N(R^{(u)})$  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.

## 4 評価実験

### 4.1 実験目的

本実験の目的を以下に示す.

- 箱を持つなどいくつかの外乱を含むデータにおける既存の歩容識別手法の精度を明らかにする.
- 提案手法により外乱を含むデータによりどの程度精度が向上するかを明らかにする.
- 提案手法における, 被験者数と精度の関係を明らかにする.

### 4.2 実験方法

#### 4.2.1 データ収集

本実験においては, 通常歩行のデータは [4] において収集した, 145 名分のものを用いる. 外乱を含む歩行のデータについては, [4] と同様の環境で収集した. 実験に関する情報を表 1 に示す. 1 人につき 1 種類の外乱を含む歩行を 5 回測定し, 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取る. すなわち, 5 個/人  $\times$  111 人 = 555 データを収集した. 被験者は本大学の学生, 職員, 地域の方である.

表 1 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 2 に示す. それぞれの外乱のサンプルを図 1 に示す. 外乱に対する精度の評価では  $k$ -NN を用いる.

#### 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  $s$  とする.  $s$  以外の 24 個の関節それぞれについて  $s$  を原点とした相対座標を計算する.

表 2: 評価する外乱と各被験者数

	外乱	人数
1	大股 & 手大振り	34
2	箱を持つ	38
3	スマートフォンを操作する	39



図 1: 外乱のサンプル

それぞれの関節  $\ell$  について DTW 距離  $d(R_\ell^{(u)}, R_\ell^{(v)})$  を計算し, EER となる閾値  $\theta_\ell^*$  を求める.

#### 4.2.3 特徴量を単体で用いた際の識別精度

これは, Muaaz ら [2] のように, スマートフォンなどの単体のセンサを用いた手法に対応する手法である. 通常歩行の 145 名分のデータが一人あたり 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 111 名分, 一人あたり 5 つ全てをテストデータとする. テンプレートが一人あたり 1 つなため  $k=1$  とする. つまり, それぞれの関節でそれぞれ, 145 個のテンプレートと DTW 距離を計算し, もっとも近いデータのユーザを予測値とする.

#### 4.2.4 複数特徴量を用いた提案手法の識別精度

24 関節全てを用いて  $k$ -NN を行ったときの精度を求める. 4.2.3 節と同様に, 145 名データのうち 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 111 名分, 一人あたり 5 つ全てをテストデータとする.

#### 4.2.5 既存手法を用いた場合の精度

4.2.3 節と同様に, 145 名データのうち 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 111 名分, 一人あたり 5 つ全てをテストデータとする. [4] で用いた手法の 1 つである, 各特徴量の標準偏差 (SD) で重み付けしたユークリッド距

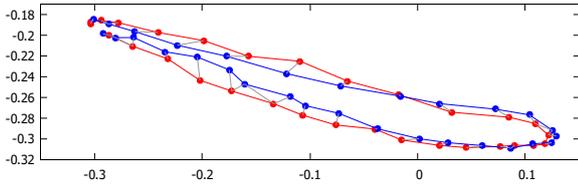


図 2: 関節 HandTipLeft の DTW 距離 (本人間)  $(d(R_{HTL}^{(u)}, R_{HTL}^{(u)})) = 0.45$

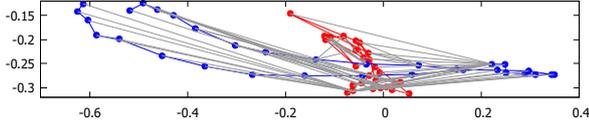


図 3: 関節 HandTipLeft の DTW 距離 (他人間)  $(d(R_{HTL}^{(u)}, R_{HTL}^{(v)})) = 12.0$

離を用いた精度評価を行う。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  $d_\ell$ , その SD を  $\sigma_\ell$  とすると, 関節  $\ell$  と  $m$  を統合した距離は

$$D_{sd} = \sqrt{\left(\frac{d_\ell}{\sigma_\ell}\right)^2 + \left(\frac{d_m}{\sigma_m}\right)^2}$$

により求める。

#### 4.2.6 テンプレート数を変更したときの識別精度

テンプレート数を 1 から 4 まで変更したときの精度を求める。一人あたりの歩行データが 5 つしかないため, 条件を揃えるためにテンプレートがいくつときでもテストデータは一人あたり 1 つに合わせる。

#### 4.2.7 被験者数と精度の関係

被験者数  $n$  を変更したときの FRR を求める。145 名のデータの中からランダムに  $n$  人のユーザサンプリングをして, そのユーザだけを用いた精度評価を行う。

### 4.3 実験結果

#### 4.3.1 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 2, 図 3 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 2 は被験者 1 と 2 が同一人物同士で比較した場合。図 3 は異なる人物間で比較した場合である。

図 2 の本人間の関節の変化は似通っており, 図の灰色線の総和で与えられる DTW 距離は  $d(R_{HTL}^{(u)}, R_{HTL}^{(u)}) =$

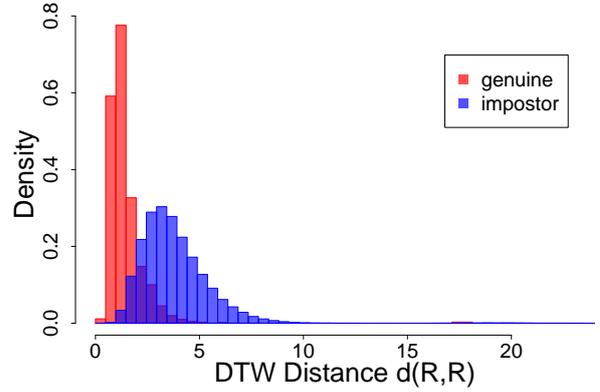


図 4: HTL の DTW 距離の分布

表 3: DTW 距離の統計量

	EER	SD		EER	SD
ElbowL	0.10	0.62	AnkleR	0.13	1.64
ElbowR	0.11	0.64	HandR	0.14	1.59
ShoulderR	0.11	0.38	HipL	0.14	0.34
ShoulderL	0.12	0.40	HandTipR	0.14	1.83
HandL	0.12	1.44	WristR	0.14	1.30
KneeR	0.12	1.08	Head	0.14	0.55
WristL	0.12	1.20	KneeL	0.14	1.14
Neck	0.12	0.31	FootL	0.14	1.80
HandTipL	0.13	1.67	SpineBase	0.14	0.33
SpineShoulder	0.13	0.23	AnkleL	0.14	1.63
HipR	0.13	0.36	ThumbL	0.19	1.48
FootR	0.13	1.79	ThumbR	0.19	1.57

0.45 である。従って, 1 周期が 30 フレーム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  $1.5cm$  である。それに対して, ユーザ  $u$  (青) と異なる  $v$  (赤) との間では, どの様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。

例として同人物と他人の歩行との HandTipLeft (HTL) についての DTW 距離  $d(R_{HTL}^{(u)}, R_{HTL}^{(v)})$  の 31 人の 5 回の歩行の分布を図 4 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。両者が同面積になる DTW 距離が  $\theta_\ell^*$  であり, 図 4 の HTL の関節については  $\theta_{HTL}^* = 2.19$  である。HTL 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毎の EER とその標準偏差を EER でソートして表 3 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: 特徴量を単体で用いた際の FRR

	normal	big	box	phone
SpineBase	0.60	0.80	0.94	0.82
Neck	0.57	0.78	0.93	0.82
Head	0.59	0.78	0.97	0.95
ShoulderLeft	0.45	0.85	1.00	0.89
ElbowLeft	0.35	0.91	0.98	0.85
WristLeft	0.45	0.95	1.00	0.90
HandLeft	0.43	0.95	0.98	0.88
ShoulderRight	0.47	0.86	0.97	0.92
ElbowRight	<u>0.33</u>	0.93	1.00	0.99
WristRight	0.45	0.91	0.98	0.96
HandRight	0.46	0.91	1.00	0.94
HipLeft	0.55	0.76	0.96	0.79
KneeLeft	0.44	0.84	0.84	0.62
AnkleLeft	0.52	0.88	0.83	0.64
FootLeft	0.52	0.82	0.84	0.66
HipRight	0.53	0.81	1.00	0.85
KneeRight	0.42	<u>0.75</u>	0.88	<u>0.60</u>
AnkleRight	0.49	0.82	0.85	0.69
FootRight	0.52	0.86	<u>0.82</u>	0.74
SpineShoulder	0.57	0.78	0.94	0.83
HandTipLeft	0.42	0.95	0.99	0.88
ThumbLeft	0.64	0.95	1.00	0.97
HandTipRight	0.47	0.89	1.00	0.93
ThumbRight	0.69	0.94	0.99	0.95
平均	0.50	0.86	0.95	0.84

#### 4.3.2 特徴量を単体で用いた際の識別精度

特徴量を単体で用いた際の FRR を表 4 に示す。すべての関節において外乱が加わることで FRR が悪化した。各外乱ごとに最も FRR が小さいところに下線を引いた。

#### 4.3.3 複数特徴量を用いた提案手法の識別精度

提案手法において、 $k$  を 10 から 500 まで変化させたときの FRR を表 5 に示す。各外乱において最も FRR が小さい部分に下線を引いた。通常歩行に関しては既存手法よりもわずかに FRR が大きくなったが、外乱を含む歩行に関しては単体時、既存手法を下回る結果となった。

通常歩行と箱を持った場合について、 $k = 40$  の  $k$ -NN において最上位になった関節と最上位になった回数を表 6 に示す。通常歩行では手や足の関節が多く採用されていたが、箱を持った場合は足や、頭などの静的な関節が多く採用された。これにより、提案手法は表 4 で FRR が小さな関節、つまり、外乱の影響をあまり受けてない

表 5: 提案手法の FRR

$k$	normal	big	box	phone
10	0.21	0.77	0.80	0.56
20	0.16	0.71	0.78	0.54
30	0.13	0.69	0.78	0.54
40	0.12	0.67	0.78	<u>0.52</u>
50	0.11	0.69	0.78	0.55
60	0.11	0.67	0.81	0.54
70	0.11	0.68	<u>0.79</u>	0.55
80	0.10	0.65	0.81	0.55
90	0.11	0.63	0.81	0.55
100	0.11	<u>0.61</u>	0.84	0.56
200	<u>0.08</u>	0.65	0.85	0.61
300	0.09	0.70	0.89	0.54
400	0.09	0.71	0.87	0.55
500	0.10	0.74	0.88	0.59

関節の動きを用いて識別を行っていることがわかる。表 6 の採用回数を円の大きさと表したものを図 5 に示す。円が大きい方が採用回数が多い。通常歩行では手足、頭に効果的な関節が集中していたが、箱を持つことで足、頭のみを用いるようになったことがわかる。円が大きい方が採用回数が多いことを表している。

#### 4.3.4 既存手法を用いた場合の精度

[4] の既存手法を用いたときと、例として表 5 の  $k = 40$  の FRR の比較を表 7 に示す。既存手法は、ElbowLeft, ElbowRight, KneeRight, FootRight, Neck の 5 つを組み合わせたものである。通常歩行においては提案手法は既存手法をよりも FRR は悪化した。外乱を含む歩行では 3 種全てにおいて提案手法は既存手法を下回る結果となった。

#### 4.3.5 テンプレート数を変更したときの識別精度

$k = 40$  において、テンプレート数を 1 から 4 まで変化させたときの FRR を表 8 に示す。各外乱において最も FRR が小さい部分に下線を引いた。全ての外乱において、テンプレート数が 3 つのときに最も FRR が小さくなった。テンプレート数が 1 のときの結果が表 5 の  $k = 40$  の結果と異なるのはテンプレート数が異なるためである。

#### 4.3.6 被験者数と精度の関係

被験者数  $n$  を 5 から 145 まで、10 ずつ変えたときの FRR の箱ひげ図を図 6 に示す。被験者  $n$  人のサンプリングはランダムであり、それぞれの  $n$  あたり 5 パターンサンプリングした結果である。

表 6:  $k$ -NN において最上位になった関節とその回数

normal		box	
関節	採用回数	関節	採用回数
HandR	100	AnkleL	87
HandTipR	89	AnkleR	57
AnkleR	82	Head	17
AnkleL	78	KneeL	11
Head	52	ShoulderL	4
KneeL	45	HipL	4
HandTipL	33	KneeR	4
HandL	30	FootR	4
KneeR	17	FootL	3
WristR	13	SpineBase	2
WristL	8	ShoulderR	2
SpineBase	7	Neck	0
HipR	6	ElbowL	0
HipL	5	WristL	0
ShoulderR	4	HandL	0
SpineShoulder	4	ElbowR	0
ShoulderL	3	WristR	0
Neck	2	HandR	0
ElbowL	1	HipR	0
FootR	1	SpineShoulder	0
ElbowR	0	HandTipL	0
FootL	0	ThumbL	0
ThumbL	0	HandTipR	0
ThumbR	0	ThumbR	0

#### 4.4 考察

表 4, 表 6 より, 単体で用いた際の FRR が小さくなった関節と  $k$ -NN により最上位になった関節は, 共に脚部の関節が多かったが, 例えば表 4 の box で一番 FRR が小さかった FootRight は表 6 では 8 位であるなど, 順位は必ずしも一致しなかった. この原因としては, 正規化が完全でないことが考えられる. これを示すために, 通常歩行と箱を持った歩行における, SD で正規化された各関節の DTW 距離の平均値を表 9 に示す. 箱を持った場合に通常歩行と比較して DTW 距離が  $\sigma$  の増加分について, 関節群が大きく足系 (feet), 胴体系 (body), 腕系 (hand) の 3 つに分類される. 箱を持った歩行では AnkleL/R が最も平均が小さくなったため,  $k$ -NN で最上位になることが多くなった. [4] では通常歩行のデータのみを用いて精度評価をしていたので SD による正規化は効果的であったが, 外乱を含む歩行においては正規化の手法を工夫する必要があると考える.

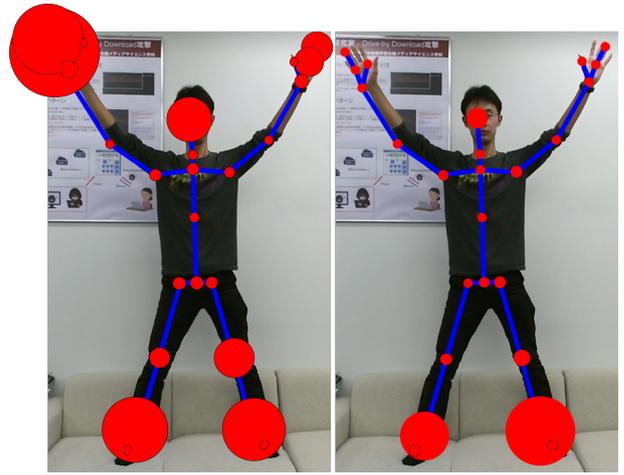


図 5:  $k$ -NN において最上位になった関節の分布 (左: normal, 右: box)

表 7: 既存手法と提案手法の FRR

	normal	big	box	phone
既存手法 ( $c = 5$ )	0.07	0.73	0.99	0.88
提案手法 ( $k = 40$ )	0.12	0.67	0.78	0.52

表 7 より, 提案手法は 3 つの外乱に対してロバストであることが示された. ただし, 通常歩行の場合は提案手法よりも既存手法の方が精度がよいという結果になった. この原因は,  $k$ -NN において採用する特徴量を, 単純に DTW 距離が小さい順にソートしていることが挙げられると考えられる. 通常歩行における精度を向上させるには, 正規化の手法を工夫するなど, 識別に有効な特徴量を効率的に抽出する必要がある.

#### 5 おわりに

本研究では, 深度センサを用いて複数の関節の動きを取得した歩容識別手法において,  $k$ -NN を適用することにより外乱にロバストな手法を提案し, 145 名の被験者を用いて精度評価を行った. 実験により, 既存手法では, 外乱を含む場合最大で FRR=0.99 にまで誤差率が上昇してしまうこと, 提案手法を用いることで最大で 0.79 まで抑えられること, テンプレート数を増やすことで 3 つまでは精度が向上すること, 被験者数を増やすことで FRR が徐々に上昇していくことなどを示した.

本提案手法では, 外乱を含むデータにおいては, 外乱の影響が少ないと考えられる部位のみを用いることで既存手法よりも高い精度での識別が可能となった. 箱を持つ, スマートフォンを操作するなどの日常的に起こりやすい外乱は影響を受けにくい関節も存在していると考えられるが, 全身の関節に影響を与えるような外乱に対す

表 8:  $k = 40$  でテンプレート数を変更したときの FRR

	normal	big	box	phone
1	0.10	0.74	0.77	0.42
2	0.06	0.71	0.82	0.42
3	<u>0.03</u>	<u>0.65</u>	<u>0.74</u>	<u>0.34</u>
4	<u>0.03</u>	0.74	0.79	<u>0.34</u>

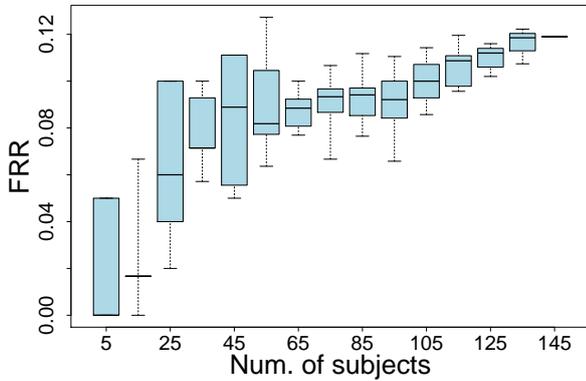


図 6: 被験者数と精度の関係

るロバスト性は低いと考えられる。今後は、そういった更に大きな影響を及ぼす外乱に対しても頑強な手法を調査することなどが課題として挙げられる。

## 参考文献

- [1] 大塚孝信, 西田智裕, 柴田大地, 伊藤孝行. プライバシに配慮した深度センサ式人流計測システムの試作と実装. 第 32 回人工知能学会全国大会, pp. 1–4, 2018.
- [2] Muhammad Muaaz and René Mayrhofer. Smartphone-based gait recognition: From authentication to imitation. *IEEE Trans. on Mobile Computing*, Vol. 16, No. 11, pp. 3209–3221, 2017.
- [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 (DI-COMO2018), pp. 672–680, 2018.
- [4] 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.
- [5] Donald J. Berndt and James Clifford. Using dynamic time warping to find patterns in time series. In *KDD Workshop*, 1994.

表 9: SD で正規化された各関節の DTW 距離の平均値

group	joint	normal	box
feet	AnkleLeft	0.76	1.33
	AnkleRight	0.74	1.37
	FootLeft	0.96	1.51
	FootRight	0.97	1.59
	KneeLeft	0.81	1.87
	KneeRight	0.80	2.00
body	Head	0.94	3.20
	HipRight	0.95	3.92
	ShoulderLeft	0.96	4.08
	SpineBase	0.98	4.11
	Neck	0.95	4.13
	SpineShoulder	0.95	4.14
	HipLeft	0.99	4.17
	ShoulderRight	0.96	4.33
hand	HandTipRight	0.80	9.20
	HandRight	0.81	9.67
	ThumbRight	1.32	9.96
	WristRight	0.88	10.28
	HandTipLeft	0.87	10.61
	ThumbLeft	1.39	10.90
	HandLeft	0.87	11.07
	ElbowRight	1.03	11.20
ElbowLeft	1.12	11.25	
WristLeft	0.93	11.58	