

明治大学大学院 先端数理科学研究科

2018 年度

修士学位請求論文

深度センサによる歩容特徴量の DTW 距離に基づく
個人識別手法の提案

学位請求者 先端メディアサイエンス専攻
森 駿文

あらまし

近年、不正アクセス防止などのため高度で安全な個人認証の必要性が高まっている。しかし、パスワードなどの記憶情報を用いた古典的な認証方式では、秘密情報をユーザが忘れてしまったり第三者に漏洩してしまう危険性がある。そこで、個人のユニークな生体情報を利用したバイオメトリクスが広まってきている。加えて、バイオメトリクス技術の応用として、カメラやセンサなどを用いて個人を識別・追跡し、マーケティングや防犯などに活用する試みも始まってきている。顧客の追跡や動線を解析し、店舗内の顧客の流れを特定することで商品の配置を変更するなどビッグデータとしての活用も可能であると考えられる。しかし、2017から施行された改正個人情報保護法では、カメラで取得した顔画像は個人識別符号に分類されており、種々のデータ取得の同意やオプトアウトなどのプライバシーに関する配慮を行う必要がある。これらの配慮を欠いて大規模な実験を計画したが大きな批判を受けた例もあった。そこで、本研究では、顔認証に代わる生体認証手法として歩容に注目する。歩容識別手法にはコンピュータビジョンを用いたものやウェアラブルセンサを用いたものなどがある。コンピュータビジョンを用いた方式は他の認証方式と異なり、対象者から離れた位置にいても認証行為が可能であるという特徴があり、広域の監視が期待されている。また離れた位置から観測が可能であるという特徴から、対象者に意識させることなく一方的な観測が可能である。これらの特徴により我々は、歩容情報は既存の認証としての用途だけでなく個人の識別に適していると考えている。個人識別は、求められる精度はさほど高くない代わりにプライバシーに配慮しなければならないなどといった認証と異なる特徴がある。歩容を用いた最新の研究の一つに Muaaz らのものがある。彼らは、スマートフォンから得られる加速度情報に DTW を適用することで個人認証を行う手法を提案している。DTW(Dynamic Time Warping) は時系列データに用いられるパターンマッチング手法であり、2つの時系列データの距離を算出することができる。しかし彼らの手法では、スマートフォンを所持するなど利用者の協力が必要、手足の動きを観測できないため荷物を持つなどの外乱に弱いなどといった問題点がある。歩容には、荷物を持つ、スマートフォンを操作するなどの固有の外乱が存在する。手を大きく振るなどの対象者が意図するもの、カバンを持つ、サンダルを履くなど、意図しないものなど、日常生活では様々な外乱が存在する。歩容を用いて人物追跡を行う際にはそういった外乱を含む場合でも問題なく追跡をする必要があるため、歩容を用いた識別を行ううえで外乱の影響は無視できない。本研究は、深度センサを用いた歩容識別手法を提案し、評価することを目的とする。はじめに、通常の歩行を高精度で識別できる手法を提案し、その手法をもとに、荷物を持つなどの外乱を含む歩行に対しても頑強である手法を提案する。大規模なデータセットを用意し、提案手法の精度を明らかにすることで提案手法の有用性を評価する。

目次

第 1 章	序論	1
1.1	本研究の背景	1
1.2	本研究の目的	3
1.3	本研究の貢献	3
1.4	シンボルの定義	3
1.5	本論文の構成	3
第 2 章	従来研究	6
2.1	RGB カメラを使った歩容認証	6
2.2	深度センサを使った歩容識別・属性推定	6
2.3	加速度, 角度センサーを使った歩容識別手法	7
2.4	DTW を用いた従来研究	8
2.5	歩容からの属性推定	8
第 3 章	統計量を用いた個人識別手法	9
3.1	提案手法	9
3.1.1	サイクル切り出し	9
3.1.2	特徴量の計算	10
3.1.3	統計量の計算	10
3.1.4	識別	11
3.2	評価実験	11
3.2.1	実験目的	11
3.2.2	使用機材	11
3.2.3	実験方法	12
3.2.4	実験結果	13
3.2.5	評価・考察	16
3.2.6	考察	19
3.3	まとめ	19
第 4 章	DTW を用いた個人識別手法	20
4.1	本章の概要	20
4.2	提案手法	20
4.2.1	サイクル切り出し	21

4.2.2	関節座標の相対座標化	21
4.2.3	DTW 距離の計算	22
4.2.4	識別	22
4.3	評価実験	23
4.3.1	実験目的	23
4.3.2	実験方法	23
4.3.3	実験結果	25
4.3.4	考察	30
4.4	まとめ	31
第 5 章	DTW を用いた個人識別におけるフュージョン手法	32
5.1	本章の概要	32
5.2	提案手法	33
5.2.1	特徴量の統合	33
5.3	評価実験	35
5.3.1	実験目的	35
5.3.2	実験方法	35
5.3.3	実験結果	36
5.3.4	考察	43
5.4	まとめ	43
第 6 章	k 近傍による外乱にロバストな個人識別手法	45
6.1	本章の概要	45
6.2	提案手法	45
6.3	評価実験	46
6.3.1	実験目的	46
6.3.2	実験方法	46
6.3.3	実験結果	48
6.3.4	考察	52
6.4	まとめ	54
第 7 章	結論	56
	参考文献	58
	謝辞	59
	研究業績	60

第1章 序論

1.1 本研究の背景

近年、不正アクセス防止などのため高度で安全な個人認証の必要性が高まっている。しかし、パスワードなどの記憶情報を用いた古典的な認証方式では、秘密情報をユーザが忘れてしまったり第三者に漏洩してしまう危険性がある。そこで、個人のユニークな生体情報を利用したバイオメトリクスが広まってきている。

加えて、バイオメトリクス技術の応用として、カメラやセンサなどを用いて個人を識別・追跡し、マーケティングや防犯などに活用する試みも始まってきている。顧客の追跡や動線を解析し、店舗内の顧客の流れを特定することで商品の配置を変更するなどビッグデータとしての活用も可能であると考えられる。しかし、2017から施行された改正個人情報保護法では、カメラで取得した顔画像は個人識別符号に分類されており、種々のデータ取得の取得の同意やオプトアウトなどのプライバシーに関する配慮を行う必要がある。これらの配慮を欠いて大規模な実験を計画したが大きな批判を受けた例もあった [1]。

そこで、本研究では、顔認証に代わる生体認証手法として歩容に注目する。歩容識別手法にはコンピュータビジョンを用いたもの [2] やウェアラブルセンサーを用いたもの [3] などがある。コンピュータビジョンを用いた方式は他の認証方式と異なり、対象者から離れた位置にいても認証行為が可能であるという特徴があり、広域の監視が期待されている。また離れた位置から観測が可能であるという特徴から、対象者に意識させることなく一方的な観測が可能である。これらの特徴により我々は、歩容情報は既存の認証としての用途だけでなく個人の識別に適していると考えている。

個人識別は、求められる精度はさほど高くない代わりにプライバシーに配慮しなければならないなどといった認証と異なる特徴がある。利用者認証とは事前にシステムに登録しておいたユーザ情報と対象者が同一人物であるかを判定することである。これに対して識別とは別時刻の2つの対象が同一であるかを判定することである。認証は主に、システムにログオンする際や建物に入る際などに正当な利用者であることを証明することに使われているが、識別の場合は定点センサを設置しておき、同じ人がいつ何回通ったかなどの統計情報を取得することができる。

この2つの間には次のような差がある。

- 認証は必ず対象者の意思が必要となるため本人の協力はあがるが、識別は対象者の意図と無関係に行われる。識別結果を統計情報として扱う場合は多少の誤差は許容できるため、生体認証ほどの精度は求められない。
- 人物識別においては対象者の意思に関係なく個人の特徴量を取得することになるため、プライバシーへの配慮が必要。

表 1.1: 識別と認証の違い

	人物識別	生体認証
対象者の協力	なし	あり
求められる精度	低い	高い
マッチング人数	$i:j$	$1:j$
プライバシー配慮	必要	不要
オプトアウト可能	必要	不要
攻撃パターン	自分ではない誰かに なりすます	特定の人物に なりすます

- 情報の提供を拒否したい人はオプトアウトできることが望ましい。
- 認証は一人の対象者がテンプレートに登録されている人のうちどれに当てはまるかを特定するという問題なので、テンプレートに登録されている人数を j とすると $1:j$ のマッチングとなる。識別では同時に現れる複数人が、過去にデータベースに登録されたどの人と一致するか、もしくは登録されていない新規の人物であるのかを特定するという問題になる。従って、現在写っている人数を i 、テンプレートに登録されている人数を j とすると、対象は i で、クラスタリング候補は登録されているテンプレート j との $i:j$ のマッチングとなる。そして新規の対象が来た場合は j が増加する。
- 認証の脅威は特定の人物になりすまし、システムを不正利用する攻撃である。識別の脅威は自分がその場にいることを知られたくない人が、誰でもいいので他人になりすます攻撃が考えられる。

以上の人物識別と生体認証の違いについて、表 1.1 にまとめた。

歩容を用いた最新の研究の一つに Muaaz ら [3] のものがある。彼らは、スマートフォンから得られる加速度情報に DTW を適用することで個人認証を行う手法を提案している。DTW(Dynamic Time Warping)[4] は時系列データに用いられるパターンマッチング手法であり、2つの時系列データの距離を算出することができる。しかし、彼らの手法には以下のような問題点がある。

1. 専用アプリをインストールしたスマートフォンを所持していなければならぬため、利用者の協力が不可欠である
2. スマートフォンをポケットに入れてセンシングを行うため手足の動きを観測することが不可能である
3. センサ数が限られるなどの理由から、荷物を持つなどの歩行の外乱に弱い

歩容には、荷物を持つ、スマートフォンを操作するなどの固有の外乱が存在する。手を大きく振るなどの対象者が意図するもの、カバンを持つ、サンダルを履くなど、意図しないものなど、日常生活では様々な外乱が存在する。歩容を用いて人物追跡を行う際にはそういった外乱を含む場合でも問題なく追跡をする必要があるため、歩容を用いた識別を行ううえで外乱の影響は無視できない。

1.2 本研究の目的

本研究では、深度センサなどを用いて外部から観測した歩容の時系列データに対して DTW を適用することで個人識別を行う手法を提案する。外部から観測を行うことで、

1. 利用者の協力が不要であり，無意識のあいだに観測が可能である
2. 手足を含め身体の多数の部位の座標データを収集可能である
3. 複数の部位を効率的に用いることで外乱に頑強な手法となる

という利点がある。

本研究は、深度センサを用いた歩容識別手法を提案し、評価することを目的とする。はじめに、通常の歩行を高精度で識別できる手法を提案し、その手法をもとに、荷物を持つなどの外乱を含む歩行に対しても頑強である手法を提案する。大規模なデータセットを用意し、提案手法の精度を明らかにすることで提案手法の有用性を評価する。

1.3 本研究の貢献

本論文では次のことを明らかにする。

- 歩容の統計量を用いた識別手法における精度
- DTW を用いた識別手法における、各特徴量の識別精度
- DTW を用いた識別手法における、複数特徴量を統合する際の適切な統合手法
- 歩容に固有な問題である、外乱に頑強な歩容識別手法

1.4 シンボルの定義

本論文で使用するシンボルの意味を表 1.2 に示す。

1.5 本論文の構成

本論文は7章で構成される。

第1章では、まず本研究の背景と目的を述べ、次に本研究の概要を示し、その着想と貢献を述べた。

第2章では、本論文を通して使用する基本定義を示し、関連研究の概要を述べる。

第3章では、個人認証と識別・追跡の差異についてまとめ、歩容の特徴量の統計量を用いた個人識別手法を提案し、実験により精度評価を行う。

第4章では、歩行中の手足の動きに対して DTW を適用することにより動的な識別を行う手法を提案、評価する。

表 1.2: 本論文で使用するシンボルの一覧

シンボル	意味
S_i^s	静的距離 i の時系列データ
S_i^d	動的距離 i の時系列データ
S_i^a	動的角度 i の時系列データ
l, m	任意の関節
u, v	任意のユーザ
U	ユーザの集合
U_i	ユーザ ID
N	時系列データの長さ
b	身体を中心付近の, 相対座標の基準となる関節
a_ℓ	関節 ℓ の絶対座標
r_ℓ	関節 b を中心とした関節 ℓ の相対座標
$R_\ell^{(u)}$	ユーザ u の r_ℓ を 1 サイクル分集めた時系列データ
$R_*^{(u)}$	ユーザ u のテンプレートデータ
$W^{(u)}$	ユーザ u の時系列データ R の集合
s	一人あたりのデータの個数
$d(R, R')$	R と R' の DTW 距離
d_ℓ	関節 ℓ におけるテンプレートと対象の DTW 距離
$D_{method}((R_\ell, R_m), (R'_\ell, R'_m))$	関節 ℓ と m , 手法 $method$ を用いたときの統合 DTW 距離
θ	本人と他人を区別する閾値
θ_ℓ^*	ℓ の EER のときの閾値
k_m	マハラノビス距離の次元の数
r	2 特徴量の相関係数
c	統合する特徴量の数
n	実験の被験者数
E_ℓ	関節 ℓ を単体で用いた際の EER
σ_ℓ	他人と比較した関節 ℓ の DTW 距離の標準偏差
k	k -NN において用いる近傍の数
N_k	k -NN において用いる上位 k 個の特徴量の集合

第5章では、4章の手法をもとに、複数特徴量の統合手法について検討し、最適な手法を明らかにする。

第6章では、荷物を持つ、手を大振りするなどの外乱を含む歩行にも頑強な識別手法を提案し、実験によりその眼鏡性を評価する。

第7章では、本研究について結論づける。

第2章 従来研究

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)[5]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のサンプルを図2.1に示す。

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 [6] 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 57% の識別率を達成した。また、Shiraga らは GEINet[2] 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。彼らの実験では、対象者が識別に対して非協力である場合を想定しており、テンプレート画像、テスト画像共にカメラの撮影角度をかえて 55 度、65 度、75 度、85 度と 4 種類のデータを用意し、異なる角度の組み合わせにおいても高精度な識別が可能であることを示した。

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 [7] 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。



図 2.1: GEI のサンプル [5]

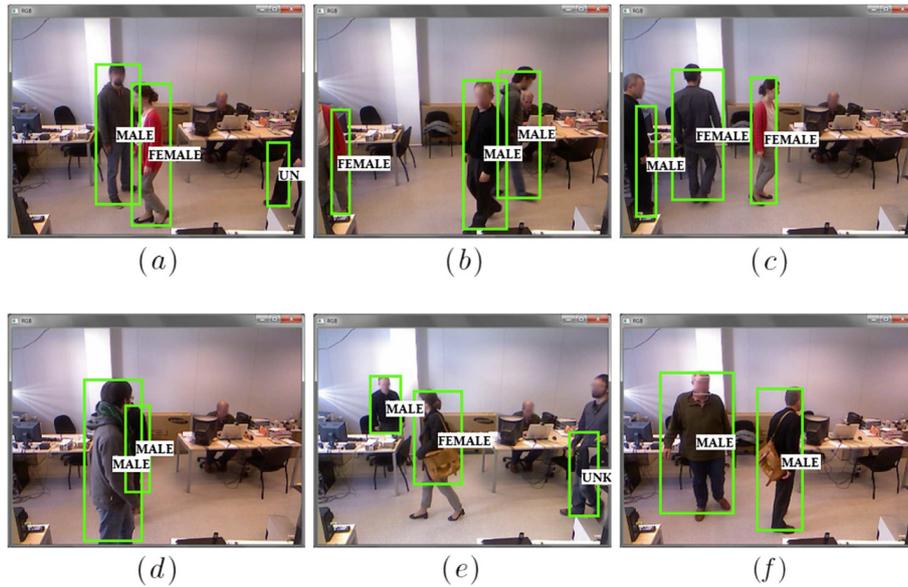


図 2.2: Igual らのリアルタイム性別推定アプリケーション [8]

Igual らは、深度センサを用いた性別推定手法 [8] を提案した。彼らの手法では、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。Igual らは深度センサを用いているため、GEI などの RGB カメラのみを使用する手法と比べて高速な処理が可能であり、リアルタイムな識別を可能とした。Igual らがリアルタイムに性別推定を行っている様子を図 2.2 に示す。

2.3 加速度、角度センサー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 [9] 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。Zhang らは複数の加速度データを組み合わせて行う歩容識別手法を提案した [10]。彼らは身体の異なる 5箇所に付けた加速度センサのデータを組み合わせることにより、実験の結果 rank-1 の精度で 95.8%，EER で 0.022 を達成した。Mondal らは、身体の関節 8箇所 (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人の被験者を用いて，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 [3] 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。本研究の特長的な点は、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。minimal-effort attack の実験の様子を図 2.3 に示す。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

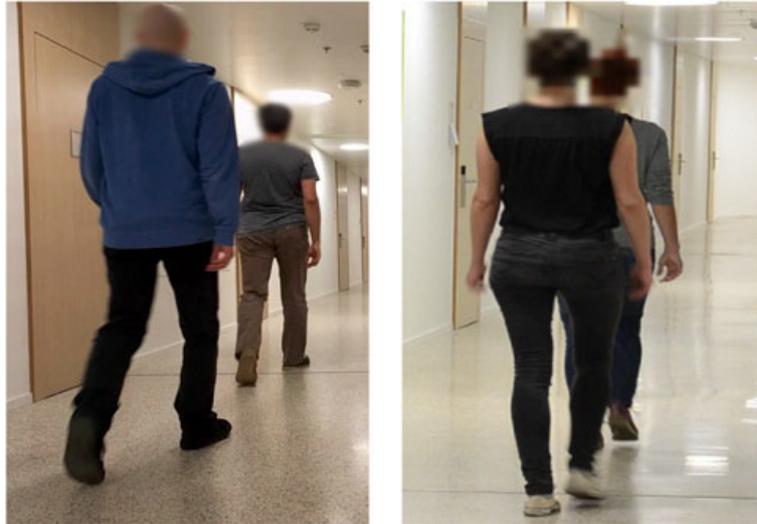


図 2.3: Muaaz らの minimal-effort attack 実験の様子 [3]

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。

2.4 DTW を用いた従来研究

Muaaz らの他にも、DTW を音声認識以外に適用した研究が存在する。Li ら [11] は人体の静電信号を用いて歩容識別を行う手法を提案した。歩行中の身体の静電信号の時系列データに対して DTW を適用することで、実験の結果 87.5% の正解率となった。

Lee ら [12] は、加速度センサとジャイロ스코ープから得られたモーションデータに対して DTW を適用することで手書き文字識別を行う手法を提案した。彼らの手法は、実世界のデータセットを用いた実験により正解率は 91.4% であった。

2.5 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 [13] 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。

第3章 統計量を用いた個人識別手法

3.1 提案手法

本章では、モーションキャプチャセンサなどから得られた関節の3次元座標を測定し、一歩分の時系列データの統計量を算出することによって個人識別を行う手法を提案する。提案手法は次の4つのステップから成る。

1. サイクル抜き出し
2. 特徴量の計算
3. 統計量の計算
4. 識別

3.1.1 サイクル切り出し

収集したデータから1サイクル分を抜き出す。1周期を判別する基準には足首間の距離を用いる。本章では、歩行の1サイクルとは、片方の足が前に出た時刻から再びその足が前に出るまでの間とする。まず足首間の距離の時系列データに対して、2フレームの移動平均を求め平滑化をする。各時点において前後2点との大小を比較しピーク値を求める。1つ目のピークから3つ目のピークまでのフレームを抜き出し、1サイクルとする。1サイクルの例を図3.1に示す。

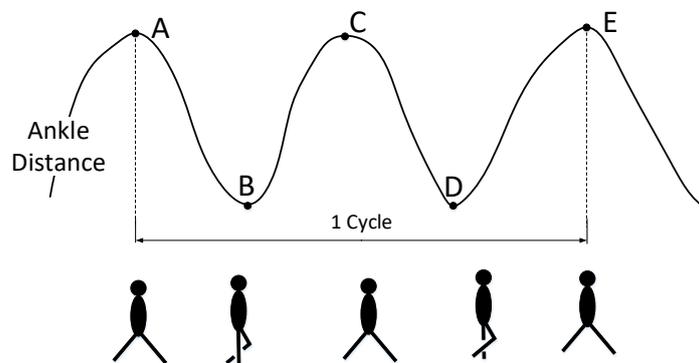


図 3.1: 1 サイクルの例

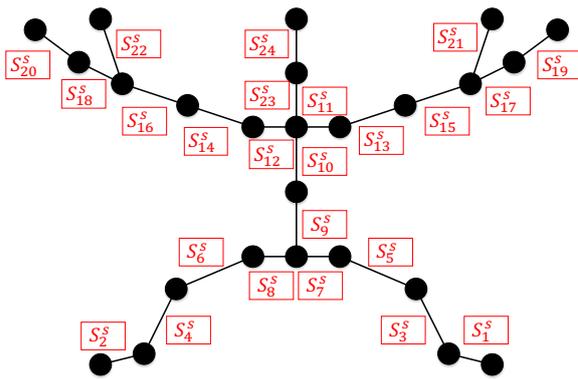


図 3.2: 静的距離の簡略図

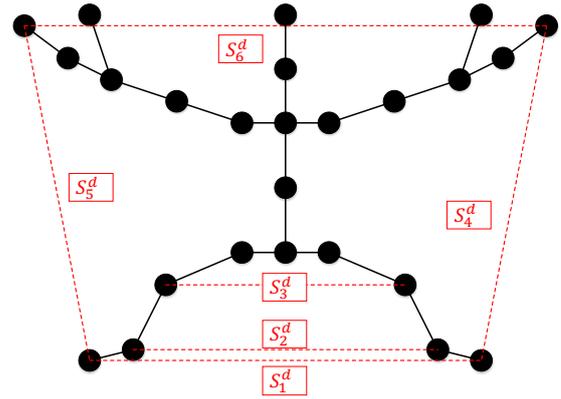


図 3.3: 動的距離の簡略図

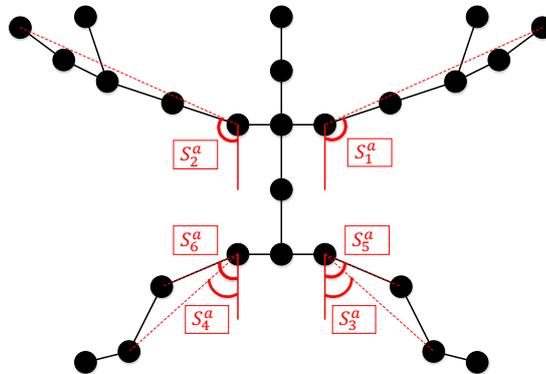


図 3.4: 動的角度の簡略図

3.1.2 特徴量の計算

本章では全部で 36 個の特徴量を用いる。用いる特徴量は、静的距離、動的距離、動的角度の 3 つに分けられる。静的距離は人体の隣接している関節間の距離であり、歩行中に大きく変動はしない特徴量である。静的距離の一覧を図 3.2 に示す。動的距離は歩行中に大きく変動すると考えられる関節同士の距離である。動的距離の一覧を図 3.3 に示す。動的角度は歩行中に周期的に大きく変動すると考えられる腕や足の角度である。ここでの角度とは、対象の 2 つの関節を結ぶ真下に対する角度である。動的角度のリストを図 3.4 に示す。

3.1.3 統計量の計算

3.1.2 節で定義した特徴量を計算し、3.1.1 節で抜き出したそれぞれのサイクル毎に最大値、中央値、平均値の 3 つの統計量を計算する。

3.1.4 識別

対象者 u のサイクル i における, ある特徴量

$$f \in \{S_1^s, \dots, S_{24}^s, S_1^d, \dots, S_6^d, S_1^a, \dots, S_6^a\}$$

の統計値を

$$\mu(f_{u,i}), \text{median}(f_{u,i}), \text{max}(f_{u,i}),$$

閾値を θ とする. 単一の特徴量のみで識別を行う場合は $\mu(f_{u,i})$ と $\mu(f_{v,i'})$ を用いた識別は次のように行う.

$$\text{same}(u, v) = \begin{cases} T & \text{if } |\mu(f_{u,i}) - \mu(f_{v,i'})| \leq \theta \\ F & \text{otherwise} \end{cases}$$

中央値, 最大値についても同様に行う.

複数の特徴量を組み合わせる際はそれぞれの特徴量を要素とするベクトルのユークリッド距離で判断する. 例えば, 2つの特徴量 f と g を用いて識別を行う場合は次のように識別する.

$$\text{same}(i, j) = \begin{cases} T & \text{if } \sqrt{(\mu(f_{u,i}) - \mu(f_{v,i'}))^2 + (\mu(g_{u,i}) - \mu(g_{v,i'}))^2} \leq \theta \\ F & \text{otherwise} \end{cases}$$

中央値, 最大値についても同様に計算を行う. また, 特徴量を3つ以上使う際も同様にユークリッド距離を用いる.

閾値 θ は EER(当誤り率) により求める. FAR(本人拒否率) は誤って本人を他人と識別してしまう割合, FRR(他人受け入れ率) は誤って他人を本人と識別してしまう割合であり, EER は $\text{FAR}(\theta_\ell^*) = \text{FRR}(\theta_\ell^*)$ となる θ_ℓ^* を用いたときのエラー率である.

3.2 評価実験

3.2.1 実験目的

本実験の目的を以下に示す.

- 人物識別に利用可能な歩容に関する特徴量を検討すること
- 使用する特徴量を変えることによりどの程度の識別率になるかを調査すること
- 使用した特徴量の安定性や他人との差異が十分にあるかを調査すること

3.2.2 使用機材

本研究では, センシングのデバイスとして Kinect v2 を使用した. Kinect v2 とは, Microsoft 社から発売されたモーションキャプチャデバイスである. これを用いることでユーザの身体の動きによりゲーム中におけるプレイヤーの操作を行うことを実現した. NUI(Natural User Interface) と呼ばれるインタフェースの一つである.

表 3.1: Kinect v2 のスペック

	スペック
RGB 解像度	1920×1080
RGB データのフレームレート	30fps
深度 解像度	512×424
深度データのフレームレート	30fps
人物領域	6 人
骨格推定	6 人
推定可能な関節	25 個
骨格推定可能距離	0.5～4.5m

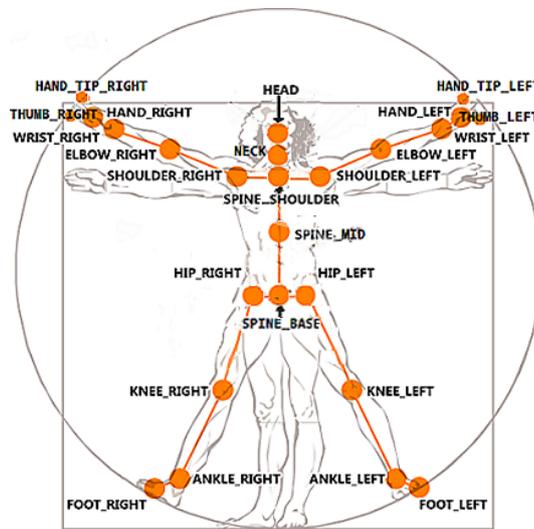


図 3.5: Kinect v2 により認識可能な 25 個の関節 [15]

Kinect には RGB カメラ, 深度センサ, マイクなどが搭載されており, 体の関節の 3 次元座標を推定し, その変化に基づいて人の動きを認識する. 関節の座標データはスケルトンデータと呼ばれており, Kinect SDK を用いて参照することができる. Kinect v2 の仕様は表 3.1[14] の通りである. Kinect v2 により推定できる関節の情報を図 3.5 に示す.

3.2.3 実験方法

本大学の学生, 教員 10 人の被験者の歩行を撮影した. 被験者には図 3.6 のそれぞれの矢印の通りに, それぞれ 2 回ずつ歩いてもらった. 人の被験者にはそれぞれ $U_1 \sim U_{10}$ の ID を振った. 実験条件を表 3.2 に, 被験者の情報を表 3.3 に示す.

収集したデータに対し, 提案手法を用いた識別を行う.

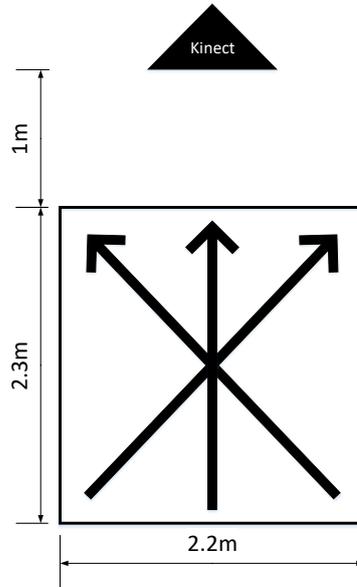


図 3.6: データ収集環境

表 3.2: データ収集の実験条件

項目	値
開始日	2017/08/05
終了日	2017/08/17
人数	10 人
一人あたりの歩行回数	6 回

表 3.3: 被験者の情報

項目	最小	最大
身長	165cm	170cm
年齢	20 歳	51 歳

3.2.4 実験結果

データ収集

収集した各関節の 3 次元座標の時系列データを図 3.7 に示す. 歩行をカメラ方向から見た場合の 5 つの代表的な関節の時系列データである.

サイクル抜き出し

抜き出した 1 サイクルの例を図 3.8 に示す. これはとあるユーザの特徴量 S_2^d の軌跡であり, 生データ (黒点) を平滑化することで赤のようにノイズが除去できていることがわかる.

特徴量の統計量の計算

抽出した特徴量の例として, ある被験者のいくつかのサイクルの S_5^d のデータを表 3.4 に示し, U_6 の S_5^d の特徴抽出方法ごとの分布を図 3.9 に示す. 分布はどの統計量も大差ないが, Median が外れ値の影響を受けていないことがわかる. また, 全被験者の $\mu(S_5^d)$ の分布を図 3.10 に示す.

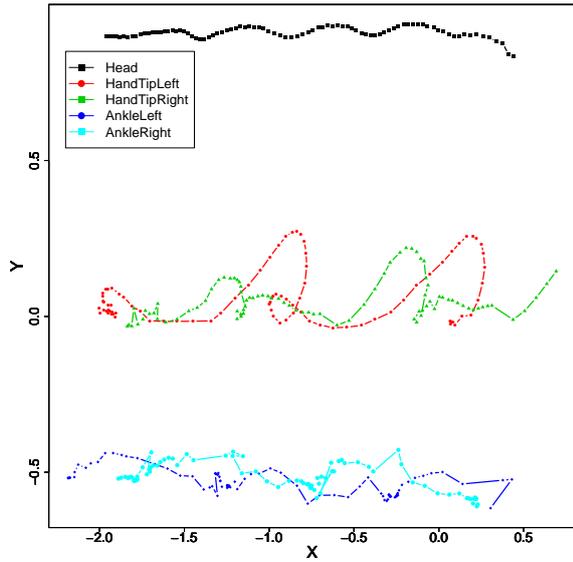


図 3.7: カメラ方向から見た関節の時系列データ

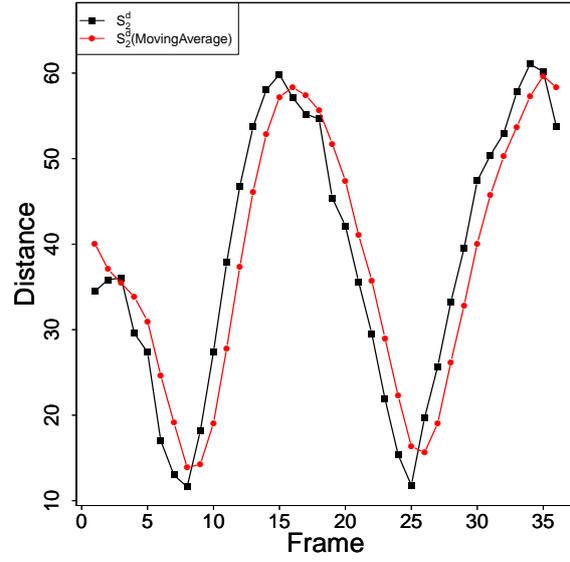


図 3.8: S_2^d の 1 サイクルの例

表 3.4: 特徴量の例

被験者 ID	サイクル	$\mu(S_5^d)$	$median(S_5^d)$	$max(S_5^d)$
U_1	1	65.4	63.9	77.0
U_1	2	62.8	63.0	70.2
U_2	1	76.3	73.1	100.4
U_2	2	75.6	75.3	104.5
U_5	1	62.7	61.6	68.5
U_5	2	60.8	60.8	71.9

識別

例として $\mu(S_5^d)$ について、本人同士で測った距離と他人同士で測った距離のヒストグラムを図 3.11 に示す。

また、閾値を変化させた場合の他人受入率 (FAR) と本人拒否率 (FRR) のトレードオフを示した受信者操作特性 (ROC) 曲線について、図 3.12 に示す。 $\mu(S_6^s), median(S_1^d), max(S_2^d)$ の 3 つの特徴量を示している。この 3 つの特徴量の中では $\mu(S_6^s)$ が最も優れた特徴量である。

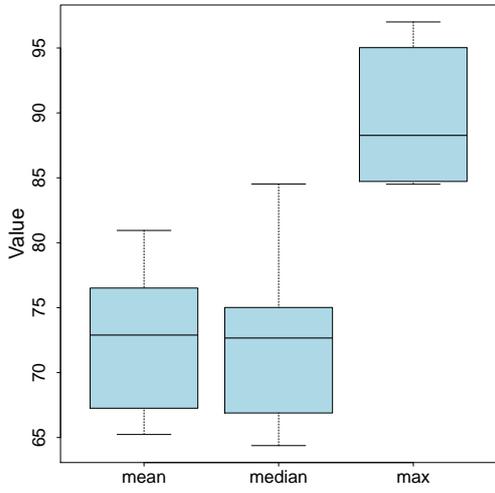


図 3.9: U_6 の S_5^d の統計量分布

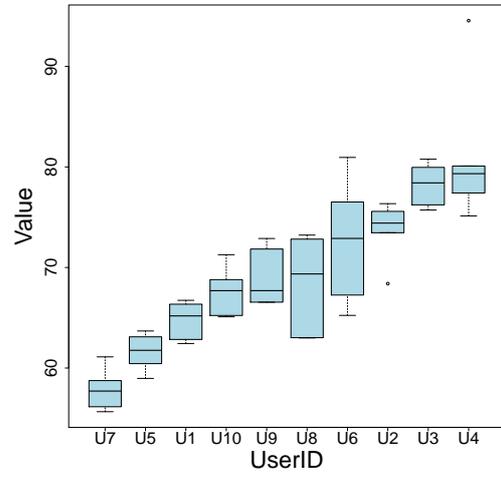


図 3.10: 全被験者の $\mu(S_5^d)$ の分布

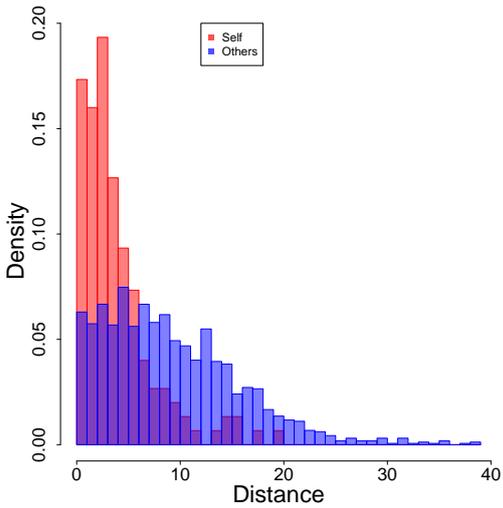


図 3.11: $\mu(S_5^d)$ の本人と他人の距離の比較

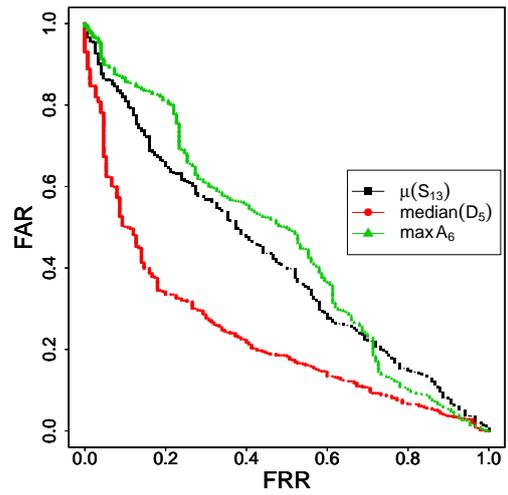


図 3.12: 特徴量 $\mu(S_6^s)$, $median(S_1^d)$, $max(S_2^a)$ の ROC 曲線

表 3.5: EER の Top10 の特徴量

特徴量	分類	特徴量の取り方	EER
$\mu(S_5^d)$	動的距離	平均値	0.29
$\max(S_5^d)$	動的距離	最大値	0.29
$\mu(S_6^s)$	静的距離	平均値	0.30
$\text{median}(S_5^d)$	動的距離	中央値	0.30
$\mu(S_5^s)$	静的距離	平均値	0.31
$\text{median}(S_4^a)$	動的角度	中央値	0.31
$\text{median}(S_5^s)$	静的距離	中央値	0.31
$\text{median}(S_6^s)$	静的距離	中央値	0.31
$\mu(S_4^d)$	動的距離	平均値	0.32
$\mu(S_4^a)$	動的角度	平均値	0.32

3.2.5 評価・考察

特徴量の比較

誤差 EER の値小さい順に上位 10 個の特徴量を表 3.5 に示す。

特徴量の組み合わせ

動的距離と動的角度について、それぞれの特徴量を組み合わせた際の EER を計算した。誤差の小さい順に並べたときの上位 10 個を表 3.6 に、下位 10 個を表 3.7 に示す。

Max の場合の動的距離について、組み合わせる特徴量の数とそのときの EER の関係を図 3.13 に示す。組み合わせる特徴量を増やすことで EER は単調に減少しているが 5 個で頭打ちとなっている。また、Max の動的距離の 6 つの特徴量を全て組み合わせた場合の、本人同士の距離と他人同士の距離のヒストグラムを図 3.14 に示す。

次元削減

例として $S_1^a \sim S_6^a$ を要素とする特徴ベクトルを作成し、それを多次元尺度法 (MDS: Multi-Dimensional Scaling) でマッピングした結果を図 3.15 に示す。

表 3.6: 特徴量を組み合わせた際の EER の上位 10

組み合わせた特徴量	分類	特徴量の取り方	EER
$\mu(S_3^d), \mu(S_5^d)$	動的距離	平均値	0.25
$\mu(S_3^d), \mu(S_4^d), \mu(S_5^d)$	動的距離	平均値	0.25
$\mu(S_2^d), \mu(S_3^d), \mu(S_4^d), \mu(S_5^d)$	動的距離	平均値	0.25
$\mu(S_3^d), \mu(S_4^d), \mu(S_5^d), \mu(S_6^d)$	動的距離	平均値	0.25
$\mu(S_1^d), \mu(S_3^d), \mu(S_4^d), \mu(S_5^d), \mu(S_6^d)$	動的距離	平均値	0.25
$\mu(S_2^d), \mu(S_3^d), \mu(S_4^d), \mu(S_5^d), \mu(S_6^d)$	動的距離	平均値	0.25
$\mu(S_2^d), \mu(S_3^d), \mu(S_5^d)$	動的距離	平均値	0.26
$\mu(S_1^d), \mu(S_2^d), \mu(S_3^d), \mu(S_4^d), \mu(S_5^d)$	動的距離	平均値	0.26
$\mu(S_4^d), \mu(S_5^d), \mu(S_6^d)$	動的距離	平均値	0.26
$\mu(S_1^d), \mu(S_2^d), \mu(S_3^d), \mu(S_4^d), \mu(S_5^d), \mu(S_6^d)$	動的距離	平均値	0.26

表 3.7: 特徴量を組み合わせた際の EER の下位 10 個

組み合わせた特徴量	分類	特徴量の取り方	EER
$\mu(S_6^a)$	動的角度	平均値	0.50
$median(S_6^a)$	動的角度	中央値	0.48
$median(S_5^a), \mu(S_6^a)$	動的角度	平均値	0.47
$median(S_2^a),$	動的角度	中央値	0.47
$median(S_2^a), median(S_3^a)$	動的角度	中央値	0.46
$max(S_5^a)$	動的角度	最大値	0.45
$max(S_5^a),$	動的角度	平均値	0.45
$median(S_2^a), median(S_5^a), median(S_6^a)$	動的角度	中央値	0.45
$median(S_2^a), median(S_6^a)$	動的角度	中央値	0.45
$median(S_1^d)$	動的距離	中央値	0.45

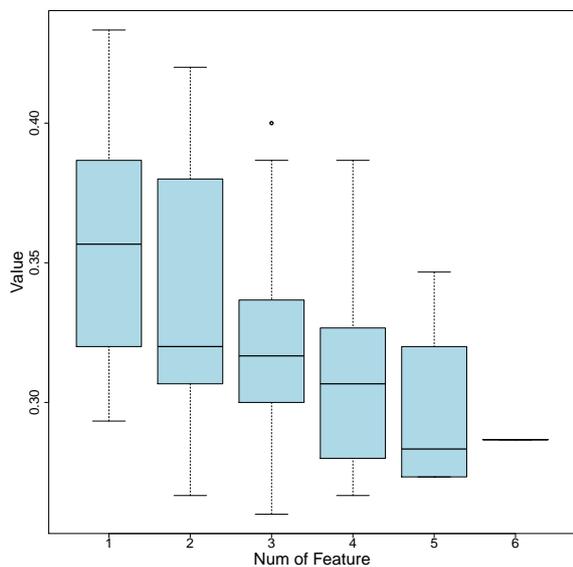


図 3.13: 特徴量の組み合わせ数と EER の関係

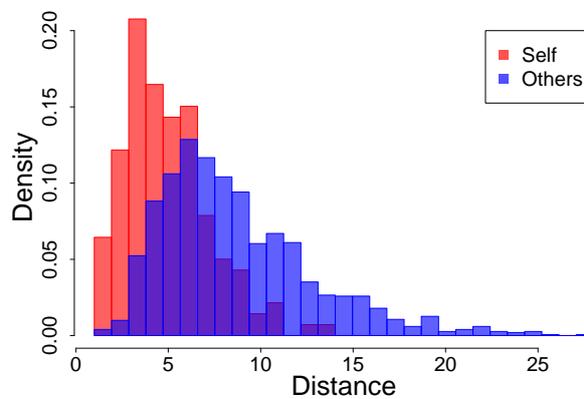


図 3.14: 動的距離 (Max) のときに 6 つの特徴量を全て組み合わせた祭の本人と他人の距離の比較

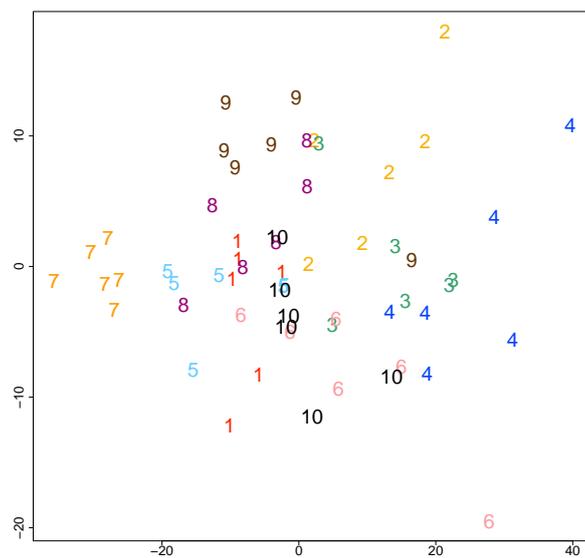


図 3.15: Max の場合の動的距離の MDS

3.2.6 考察

図 3.9 の外れ値の原因は、Kinect の誤測定と考える。なぜならば、Kinect v2 は直接見える部分しかトラッキングできないため、複数人が同時に現れたり、手などの一部が体に隠れるなどが原因で正確な情報が取得できない可能性がある。正確に取得できない関節の座標は推定で補うことができるが、本手法ではその推定値も実測値と同様に扱ってしまったため外れ値が増加したと考えられる。

表 3.5, 表 3.6 において、後処理の最大値が他の平均などよりも悪かったのは、最大値の場合 1 サイクルの中に一つでも外れ値で大きな値があると影響を大きく受けてしまうためである。

表 3.6, 表 3.6 より、動的距離が識別に有効である可能性が高いことがわかる。これは、静的距離は体の大きさの影響を大きく受け、動的角度は動きの大きさの影響を大きく受けるのに対し、動的距離は体の大きさと動きの大きさ両方の影響を受けるのでより個人間の差が大きくなるためであると考えられる。

表 3.7 より、動的角度、特に S_5^g, S_6^g を使用すると EER が大きくなった。これは、人によってかかとや足先を上げる高さにバラつきがあっても、膝を上げる角度は身長の影響も受けにくく、個人差が現れにくいので識別率が低いと考えられる。

3.3 まとめ

本章では、特徴量を提案し Kinect v2 を用いて採取した歩容データから実際に特徴量を抽出する実験を行った。実験の結果提案手法は人物識別に使用できる可能性があることがわかった。また、組み合わせる特徴量を変えることで EER を 0.25 から 0.50 まで変化させることが可能であった。

第4章 DTWを用いた個人識別手法

4.1 本章の概要

3章では、身体のいくつかの2箇所の関節間の距離を特徴量として個人を識別したが、最適の時ですえ0.25の誤差率であった。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、同一人物でも歩く毎に変化する。
- 本質的に静的な特徴量であり、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。

そこで、本章は、これらの問題に対して、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)を導入する。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、3章の統計量の様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ためである。DTWを用いた最新の研究には、Muaazらの[3]が挙げられる。彼らは、スマートフォンの加速度センサのデータに対しDTWを用いることで認証を行っている。そのため、対象者がセンサを所持する必要があるためセンサ数が限られ、また、対象者の協力が不可欠である。スマートフォンなどのセンサはポケットなどに装着することを仮定するため、手の振り方や足の運び方などの特徴を見るができない。本章では、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。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が期待できる。被験者にセンサを装着してもらう必要もなく、負担が小さい。

4.2 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

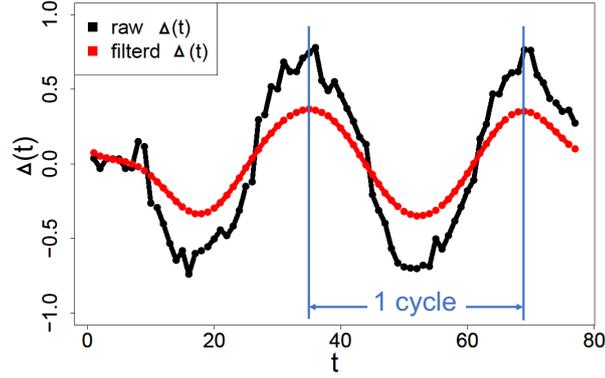


図 4.1: 両足間の距離 (黒) とそのローパスフィルタ後の距離 (赤)

4.2.1 サイクル切り出し

身体の部位 (図 3.5 参照) ℓ の時刻 t における 3 次元空間の絶対座標を $a_\ell(t) = (x, y, z)$ とする。ただし、原点はモーションキャプチャセンサの位置とする。測定時間の絶対座標の時系列データ $\langle a_\ell(t_1), a_\ell(t_2), \dots \rangle$ 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。観測した 2 歩程度の歩行から 1 サイクルを抽出する。

まず、時刻 t の左右の足の絶対座標 $a_{LF}(t), a_{RF}(t)$ から、両足の間の距離を

$$\Delta(t) = \text{sign} \|a_{RF}(t) - a_{LF}(t)\|$$

により計算する。ここで、 sign は $\{+1, -1\}$ の値を取る符号であり、右足が前の状態を正とする。

次に、両足間の距離 $(\Delta(1), \dots, \Delta(n))$ 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 4.1 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。例えば、フレームレート 30fps のセンサでは、 $1/30[s]$ の間隔を示しており、図 4.1 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 $\Delta(t)$ 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) を抽出し、それを (t_1, \dots, t_{35}) の 1 サイクルの時系列データと正規化する。

4.2.2 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。

関節 ℓ の時刻 t の絶対座標を $a_\ell(t)$ 、中心の関節の絶対座標を $a_b(t)$ とすると、相対座標 r は

$$r_\ell(t) = a_\ell(t) - a_b(t)$$

と定める．身体の中心 c は 4.3 章の実験では図 3.5 の SpineMid(脊椎の中心) を用いる．

4.2.3 DTW 距離の計算

類似度は DTW を用いて定める．DTW[4] 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．

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

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

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

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

を用いる．

1 サイクルの関節 ℓ の 2 つの時系列データ $R_\ell = \langle r_\ell(t_1), \dots, r_\ell(t_N) \rangle$ と $R'_\ell = \langle r'_\ell(t_1), \dots, r'_\ell(t_{N'}) \rangle$ 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，4.2.1 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．

複数の部位を用いたときの類似度は，次の様に定める．関節 ℓ と m についての 2 つの時系列データ (R_ℓ, R_m) と (R'_ℓ, R'_m) があるとき，統合 DTW 距離 $D((R_\ell, R_m), (R'_\ell, R'_m))$ は， ℓ と m についての DTW 距離の L2 ノルム (ユークリッド距離)，すなわち， $\sqrt{d(R_\ell, R'_\ell)^2 + d(R_m, R'_m)^2}$ とする．同様に， c 種の関節を統合した場合も， c 次元のユークリッド距離で類似度を定める．(どの c 個の特徴的な関節を定めるかは 4.3 章の実験で述べる．)

4.2.4 識別

U を全ユーザの集合とする．あるユーザ u の c 個の特徴的な関節から成る，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 $D(\mathbf{R}^{(u)}, \mathbf{R}^{(v)}) \leq \theta$ であるとき， $u = v$ と判断する．

閾値 θ_ℓ^* は、次の様にして定まる EER によって定める。 u の時系列データの集合を $W^{(u)} = \{R_1^{(u)}, \dots, R_s^{(u)}\}$ とする。このとき、本人拒否率 FRR と他人拒否率 FAR は以下のように求める。

$$\text{FRR}(\theta, u) = \frac{|\{R^{(u)} \in W^{(u)} | D(R^{(u)}, R_*^{(u)}) > \theta\}|}{|W^{(u)}|}$$

$$\text{FAR}(\theta, u) = \frac{|\{R \in W - W^{(u)} | D(R, R_*^{(u)}) \leq \theta\}|}{|W^{(u)}|}$$

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 θ における $\text{FRR}(\theta)$, $\text{FAR}(\theta)$ を

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

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

とする。 $\text{FAR}(\theta_\ell) = \text{FRR}(\theta_\ell)$ となるときの閾値を θ_ℓ^* とし、そのときの誤差率を EER とする。

4.3 評価実験

4.3.1 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の最適なパラメータ (関節数 c , 上位 c 個の関節, 閾値 θ^*) を同定する。
- 提案手法の基本的な識別精度を明らかにする。
- カバンなどのいくつかの外乱を加えると識別精度がどの程度変化するかを検証する。
- 外乱に対して頑強な関節を明らかにする。

4.3.2 実験方法

実験 1

Kinect v2 を用いて歩行データを収集し、提案手法の識別率を求める。被験者は本研究室の学生、教員である。実験に関する情報を表 4.1 に示す。実験 1 の 31 人の被験者の被験者 ID を $U_1 \sim U_{31}$ とする。

実験 1 は通常の歩行をした場合の実験である。図 4.2 に示す実験環境において、直進歩行中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。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。一人あたり 5 回測定する。

表 4.1: 被験者の情報

項目	実験 1	実験 2
実験日	2018 年 4 月 19 日	2018 年 3 月 26 日
実験開始時刻	12 時 40 分	19 時 00 分
実験終了時刻	14 時 50 分	21 時 15 分
人数	31 人	5 人
男女比	男性 26 人:女性 5 人	男性 5 人
測定回数	5 回 / 人	2 回 / 人 × 外乱
年齢	18~51 歳	21~24 歳
場所	本学教室	本研究室

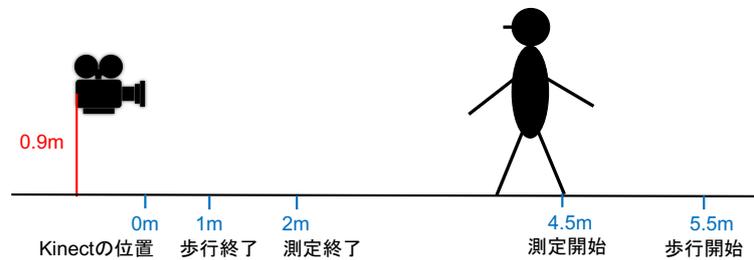


図 4.2: 実験 1 の実験環境

本実験では Kinect から取得した関節座標のうち SpineMid を中心 c とする. c 以外の 24 個の関節それぞれについて c を原点とした相対座標を計算する. それぞれの関節 ℓ について DTW 距離 $d(R_\ell^{(u)}, R_\ell^{(v)})$ を計算し, EER となる閾値 θ_ℓ^* を求める.

24 個の関節を, それぞれの関節毎の EER の低い順に組み合わせる. 組み合わせる数 c と EER の関係を求める.

実験 2

実験 2 は外乱を含む歩行の場合の実験である. カバンを持つ, サンドルを履くなど図 4.3 に示す例を含む 11 種類の外乱を用意し, その外乱下で歩容のスケルトンデータを採取する. 外乱の種類を以下に挙げる.

1. 通常 (外乱なし)
2. 大股&手大振り (b-swing)
3. 小股&手小振り (s-swing)
4. ポケットに手を入れる (pocket)
5. 歩きスマホ (phone)



図 4.3: 外乱 (2(大股),4(ポケット),5(スマホ),8(肩掛けカバン),9(傘),10(箱),11(サンダル),12(スーツケース) の例

6. カバンを手に持つ (hand bag)
7. カバンを肩にかける (shoulder bag)
8. リュックを背負う (zack)
9. 傘を持つ (umbrella)
10. 大きな箱を持つ (box)
11. サンダルを履く (sandals)
12. スーツケースを引っ張る (suitcase)

撮影環境を図 4.4 に示す¹。通常歩行をテンプレートとし，11 種類の外乱を含む場合のデータの識別をする。 c 個の関節は実験 1 で求めたものを使用する。

4.3.3 実験結果

データ収集

収集したスケルトンデータ $a(t)$ の一部を図 4.5 に示す。24 個の関節のうち主要な 11 個 (Head, SpineShoulder, ShoulderRight, ShoulderLeft, HandTipRight, HandTipLeft, SpineBase, HipRight,

¹図 4.2 と測定の角度などが異なるのは実験環境の都合の為であり，他意はない。Kinect の座標を変換することで両者の差はないように正規化が可能である。

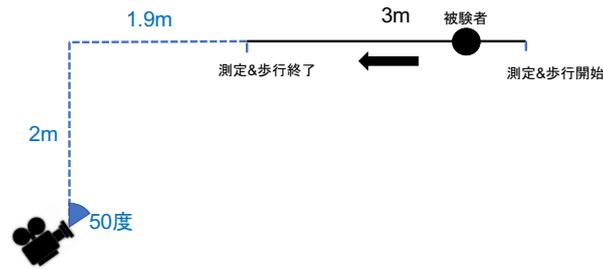


図 4.4: 実験 2 の撮影環境 (平面図)

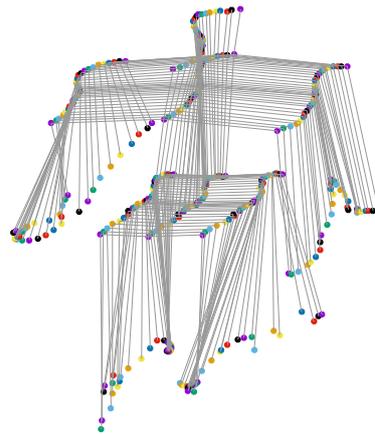


図 4.5: 1 サイクルのスケルトンデータ $a(t)$ の変化

HipLeft, FootRight, FootLeft) 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見てわかる。時間は 1 サイクルに正規化している。本例は、 t_1, \dots, t_{33} の 1.1 秒が 1 サイクルであった。

各関節の DTW 距離の算出

例として関節 HandTipLeft の DTW 距離の算出過程の結果を図 4.6, 図 4.7 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 4.6 は被験者 1 と 2 が同一人物同士で比較した場合。図 4.7 は異なる人物間で比較した場合の図である。

図 4.6 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。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。

31 人の 5 回の歩行について, それぞれの関節毎に総当りで DTW を計算した。例として同人物の歩行と他人の歩行との HandTipLeft(HTL) についての DTW 距離 $d(R_{HTL}^{(u)}, R_{HTL}^{(v)})$ の分布を図 4.8 に,

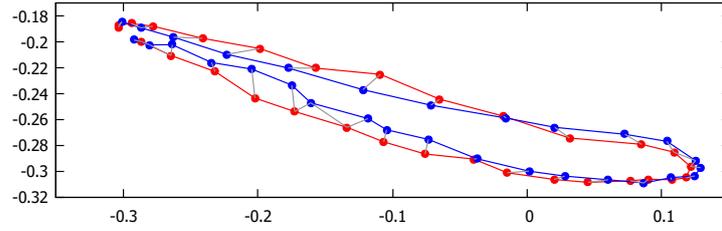


図 4.6: 関節 HandTipLeft の DTW 距離 (本人間) ($d(R_{HTL}^{(u)}, R_{HTL}^{(u)})$)

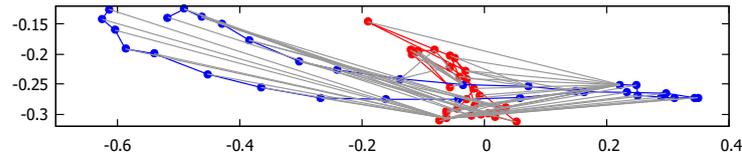


図 4.7: 関節 HandTipLeft の DTW 距離 (他人間) ($d(R_{HTL}^{(u)}, R_{HTL}^{(v)})$)

ShoulderLeft(SL) の分布 $d(R_{SL}^{(u)}, R_{SL}^{(v)})$ を図 4.9 に示す. どちらも本人の変動 (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 θ_ℓ^* であり, 図 4.8 の HTL の関節については $\theta_{HTL}^* = 2.19$ である. HTL, SL 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 をソートして表 4.2 に示す.

表 4.2 から次の観察ができる.

1. 中央値は SpineBase(SB) である. 身体を中心とも一致している.
2. 首 (Neck), 頭 (Head), 肩 (ShoulderRight/Left) は, SB より上位に位置する安定した相対位置を取る.
3. 腕に関する関節 (Elbow, Wrist, Hand) は, 左側が SB より上位に, 右側が下位にある.

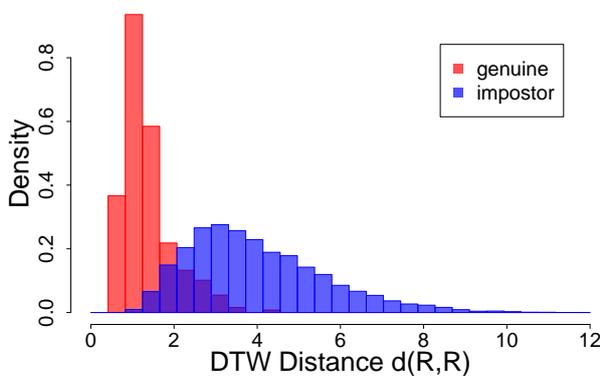


図 4.8: HTL の DTW 距離の分布

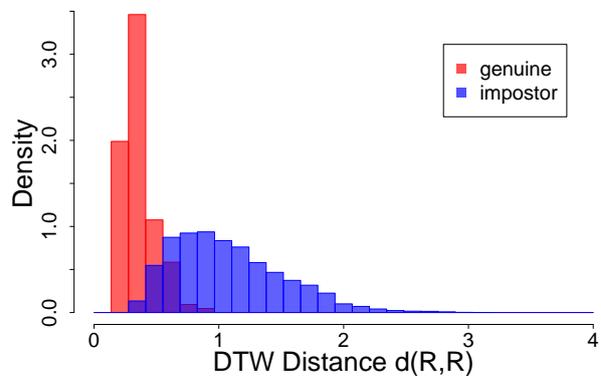


図 4.9: SL の DTW 距離の分布

表 4.2: 24 関節の EER

関節	EER	関節	EER
ElbowLeft	0.076	HandRight	0.124
ShoulderRight	0.081	HipLeft	0.127
ShoulderLeft	0.095	WristRight	0.133
Neck	0.100	HandTipRight	0.133
SpineShoulder	0.100	FootRight	0.144
WristLeft	0.107	KneeRight	0.145
HipRight	0.107	AnkleRight	0.148
HandLeft	0.108	KneeLeft	0.155
Head	0.110	ThumbRight	0.177
HandTipLeft	0.112	ThumLeft	0.187
ElbowRight	0.113	AnkleLeft	0.187
SpineBase	0.123	FootLeft	0.192

4. 足に関する関節 (Foot, Knee, Ankle) は SB より下位に分類される.

統合 DTW 距離の算出

表 4.2 の上位 c 個 ($1 \leq c \leq 10$) を組み合わせた統合 DTW 距離 $D(W^{(u)}, W^{(v)})$ を用いて識別したときの EER を求めた結果を図 4.10 に示す. $c = 5$ までは EER が単調減少し, 最小で 0.036 となった. $c = 6$ 以降はそれを下回ることはなかった. よって, $c = 5$ を最適値とみなし, 表 4.2 の ElbowLeft (EL), ShoulderRight (SR), SL, Neck (NK), SpneShoulder (SS) の関節を以降の実験で用いる.

表 4.2 の上位 5 つの関節を組み合わせた際の ROC カーブを図 4.11 に示す. ここで, $c = 5$ の統合したときの値を Euclid (黒) で, 各部位の識別率も合わせて示している. 図の対角線が EER を表しており, 各部位だけで識別したときよりも, 統合したときに誤差を削減していることが観測できる.

平均的な被験者として U_{31} を選択し, U_{31} 以外の全被験者について U_{31} のテンプレートとの DTW 距離をの箱ひげ図を図 4.12 に示す.

30 人の DTW 距離は四分位数の区間と共に表し, 平均値でソートしている. 数名似通ったユーザもいるが, 概ね識別可能な差が生じていることが分かる.

外乱を含む歩行での DTW 距離

外乱を含む歩容データの DTW 距離 ($d(R_*^{(u)}, R^{(u)})$) を計算した. 外乱ごとの DTW 距離の平均値の一部を表 4.3 に示す. 各関節の中で最も DTW 距離を大きくする外乱に下線を引いた. 11 種類の全ての外乱について, normal よりも DTW 距離を大きくしていることが示されている. 下線が轆かれている箇所が最も多い外乱は box (箱) であるが, 足先 (FootRight/Left) に対しては b-swing (大股) が, 肩 (SR/SL) には suitcase が大きな影響を与えている. 変動の大きさも, 例えば, 左手 (HTL) の

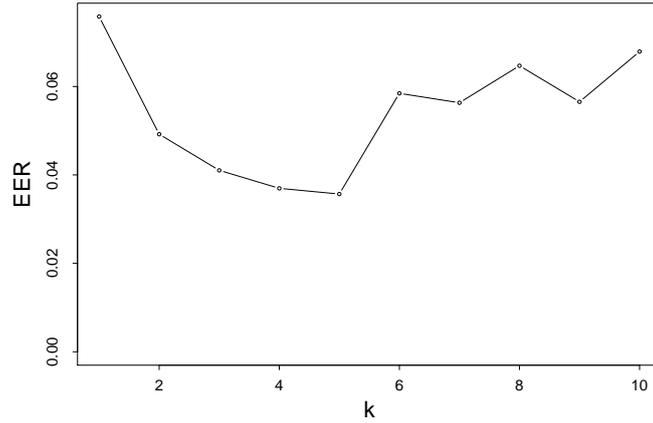


図 4.10: 特徴量を組み合わせた際の EER

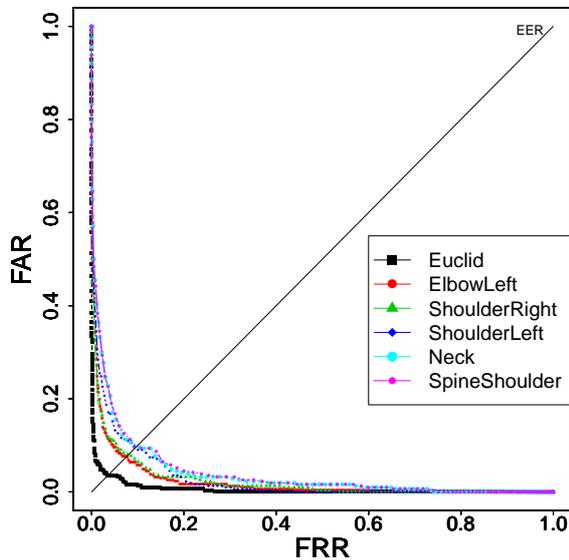


図 4.11: ROC カーブ

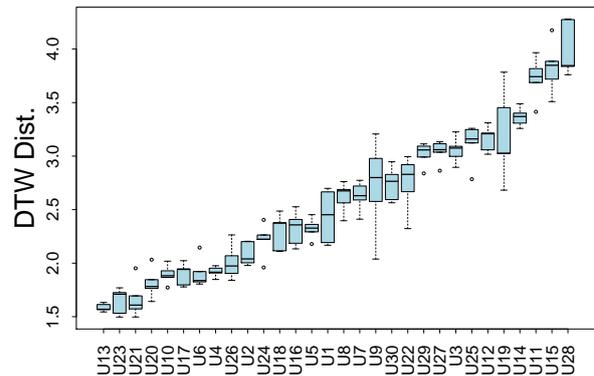


図 4.12: 全被験者の統合 DTW 距離の分布

場合で box は 3.46 から 14.27 に拡大しており、約 4.1 倍になっている。平均すると、normal と比較した box の DTW 距離の差は 1.13 であり、2.95 倍増加している。

例として、外乱ごとの HTL の DTW 距離 $d(R_{*HTL}^{(u)}, R_{HTL}^{(u)})$ の分布を図 4.13 に、SR の分布を図 4.14 に示す。

また、外乱毎の DTW 距離の平均値 $\overline{d(R, R')}$ を図 4.15、関節毎の平均値を図 4.16 に示す。

図 4.15 より、識別精度を最も低下させる外乱は大きな箱 (box) を持つことであった。また図 4.16 より、外乱に頑強な関節は Shoulder や Head, Hip など歩行中に大きく動かない部位であり、中でも最も頑強な特徴量は SpineShoulder であった。

表 4.3: 各関節の外乱毎の DTW 距離 $d(R, R')$ の平均値

	normal	b-swing	s-swing	pocket	phone	hand bag	shoulder bag	zack	umbrella	box	sandals	suitcase
ElbowLeft	1.83	5.41	1.83	3.06	2.36	2.18	1.86	1.88	2.48	<u>5.61</u>	1.68	2.28
ShoulderRight	0.97	1.76	0.99	0.96	1.06	1.31	1.33	1.14	1.12	1.60	0.99	<u>1.63</u>
ShoulderLeft	0.98	1.38	1.00	1.23	1.43	1.44	1.31	1.24	1.03	1.59	1.01	<u>1.71</u>
HipRight	0.95	1.44	1.13	1.11	1.13	1.56	1.62	1.04	1.18	<u>1.89</u>	1.13	1.67
Head	0.92	1.60	1.18	1.20	1.82	1.56	1.74	1.09	1.37	<u>2.57</u>	1.09	1.43
HandTipLeft	3.46	12.85	3.60	8.59	3.90	3.79	3.40	3.29	5.98	<u>14.27</u>	3.44	3.47
ElbowRight	1.84	4.55	2.28	2.92	4.20	3.17	2.76	2.47	3.52	<u>6.90</u>	2.15	5.83
HipLeft	1.09	1.39	1.16	1.14	1.14	1.23	1.50	1.16	1.27	<u>2.21</u>	1.10	1.39
HandTipRight	3.18	9.28	3.84	6.48	20.85	7.76	5.61	4.02	8.19	<u>18.06</u>	3.94	12.50
FootRight	3.31	<u>6.91</u>	4.39	3.48	3.68	3.95	4.12	4.41	4.03	4.46	4.13	4.55
FootLeft	2.96	<u>6.32</u>	3.89	3.15	2.88	3.27	3.21	3.70	3.69	4.14	4.06	3.80

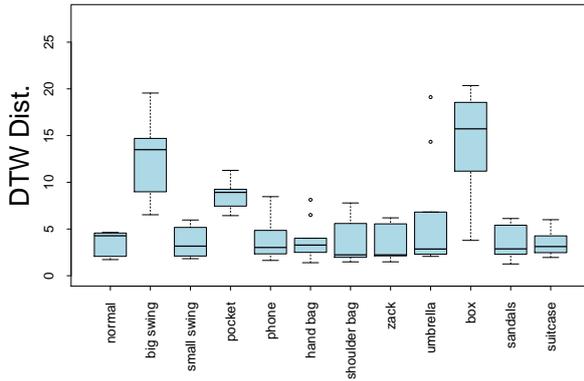


図 4.13: $d(R_{HTL}^{(u)}, R_{HTL}^{(u)})$ の分布

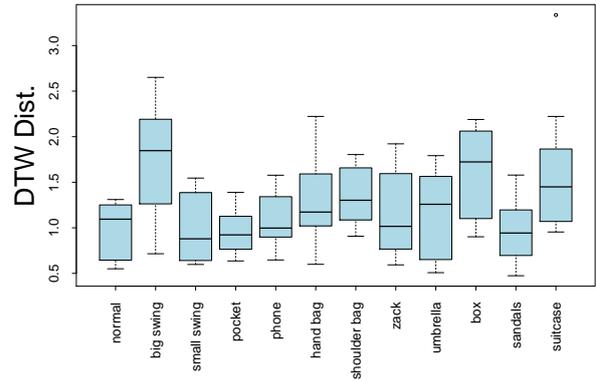


図 4.14: $d(R_{SR}^{(u)}, R_{SR}^{(u)})$ の分布

4.3.4 考察

実験 1 について、足や手などの変動が激しい関節よりも肩や首など、比較的分動の少ない関節の方が EER が低くなった。これは、他人との距離は小さいがそれ以上に本人内の変動が小さく安定していることがあげられる。DTW により詳細に識別を行ったので、ほぼ動かないと考えられる肩や首などの関節も小さいながら周期的な動きをしていると考えられる。

表 4.2 より、上半身の関節は右側よりも左側の方が EER が低くなる傾向がみられた。これは、図 4.7 の赤線の被験者の様に、左手をほとんど振らない被験者が数名いたことが原因である。手の振り幅が少ない場合、肩などと同様に本人の変動が少なくなり特徴量が安定するため EER が低くなったと考えられる。

図 4.10 について、 $c = 5$ までは特徴量の次元が増えることにより他人との差異が大きくなるため FAR が単調減少していたが、 $c = 6$ 以降は特徴量の次元が増えすぎることによって本人内の再現性が低下して FRR が増大するので、結果として EER が増大したと考えられる。

外乱について、大腿&手大振りと大きな箱を持ったときが特に DTW 距離が大きくなっていた。また、関節毎に見た場合それにより大きな影響を受ける手や腕の DTW が大きくなる傾向となった。外乱毎の特徴としては、大腿で歩く、大きな箱を持つなど日常的にあまり現れない外乱においては識別率が悪化する結果となったが、カバンを持つ、スニーカーの代わりにサンダルを履くなど日常的に頻繁に現れる外乱に対しては提案システムはある程度頑強であるといえる。従って、多様な外乱に影響されずに正確に個人を識別するためには、SpineShoulder などの変動の少ない関節を統合して DTW

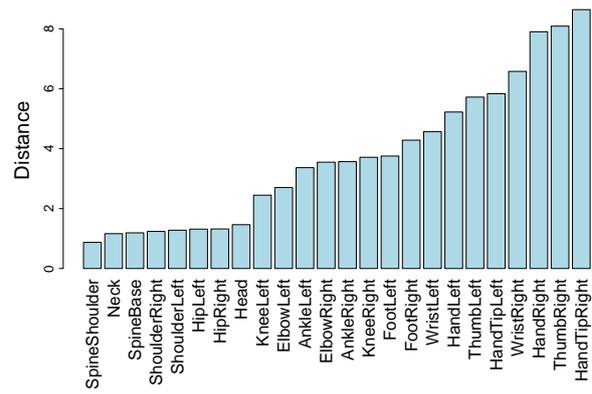
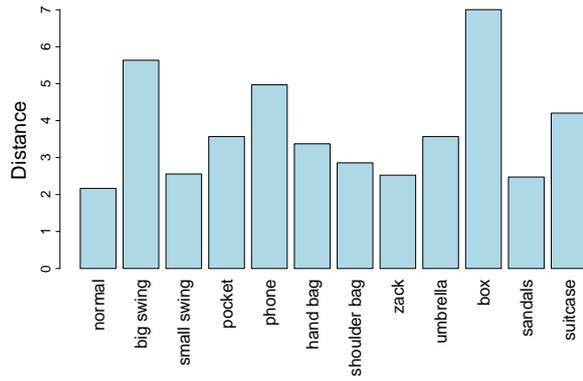


図 4.15: 外乱ごとの DTW 距離 $d(R^{(u)}, R'^{(u)})$ の平均
 図 4.16: 関節ごとの DTW 距離 $d(R^{(u)}, R'^{(u)})$ の平均

を適用すればよいことを主張する。

4.4 まとめ

本章では、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 を適用することで個人識別を行う手法を提案した。実験の結果、ElbowLeft, ShoulderRight, ShoulderLeft, Neck, SpineShoulder の 5 つの関節を組み合わせることで、31 人の被験者を用いた実験において EER を最低で 0.036 まで下げることができた。3 章の 0.25 や Muaaz ら [3] の 0.13 を大きく下回る結果である。

提案システムを用いて、外乱を含む歩容データの DTW 距離の変化を検証した。実験の結果、肩などの変動の少ない部分が外乱の影響を受けにくいことが判明した。

第5章 DTWを用いた個人識別におけるフュージョン手法

5.1 本章の概要

4章では、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)[4] を適用することで歩容識別を行う手法を提案した。しかし、4章の手法では、複数の関節の特徴量が与えられたとき、各関節の DTW 距離を等しく扱い、単純に同じ重みの要素の多次元ベクトルを用いて統合していた。それゆえ、それぞれの関節ごとに変動の大きさが異なっているため、変動の激しい部位が全体の精度を支配してしまう点が問題であった。例えば、腰 (HipLeft/Right) の振り方には特徴的な要素があるにもかかわらず、その DTW 距離の平均は約 0.8(m/歩) であり、これは腕 (HandTipLeft/Right) の 3.7(m/歩) の約 1/4、足 (FootLeft/Right) の 4.0(m/歩) の約 1/5 の大きさしかなく、識別にはほとんど効いていなかった。そのため、異なる関節を組み合わせても、5個までしか精度 (EER) を向上させることが出来ないういた。

そこで、本研究では、各関節の分布や統計量を考慮し、歩容識別に適した特徴量のフュージョン (統合) 手法を探求する。本稿では、次の結合手法を評価する。

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 (4章の手法)
- (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] の手法の変種)

3. DTW 距離のマハラノビス距離

ここで、我々の興味は次の通りである。

- どの統合手法が精度を高めるか。
- いくつの関節を統合するのが最適であるか。どの関節が識別に適しているか。
- 歩容の多様性はどれくらいか。何人の被験者で評価すれば十分であるか。

これらの質問に答えるために、145名の被験者の歩容データを測定し、識別精度を求める実験を行う。

5.2 提案手法

本手法は以下の4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. 各関節の DTW 距離の計算
4. 複数特徴量の統合
5. 本人識別

ステップ1~3, 5は4.2節と同様であるため, 本章では4の複数特徴量の統合手法について記載する.

5.2.1 特徴量の統合

各関節の DTW 距離を統合することで精度の向上が期待できるが, 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 (4章の手法)
 - (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] の手法の変種)
3. DTW 距離のマハラノビス距離

一様な DTW 距離のベクトルのユークリッド距離

4章で用いていた, 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 l におけるテンプレートと対象特徴量間の DTW 距離を d_l , 統合後の距離を D_{euc} とすると, 関節 l と m を統合した距離は

$$D_{euc} = \sqrt{d_l^2 + d_m^2}$$

と定める. D_{euc} が閾値 θ^* 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.

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い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 ℓ と m の EER E_ℓ と E_m を統合した距離 D_{eer} 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 θ^* 以下の場合は本人、それ以外の場合は他人と識別する。

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 ℓ と m の SD σ_ℓ と σ_m を統合した距離 D_{sd} 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 θ^* 以下の場合は本人、それ以外の場合は他人と識別する。

EER と SD で重み付けしたベクトルのユークリッド距離

5.2.1 節と 5.2.1 をハイブリッドに組み合わせた手法である。関節 ℓ と m の EER E_ℓ, E_m と他人との DTW 距離の SD σ_ℓ, σ_m を統合した距離 D_{eer-sd} 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 θ^* 以下の場合は本人、それ以外の場合は他人と識別する。

投票方式

Muaaz らの先行研究 [3] で提案されていた手法である。 c 個の関節の DTW 距離のうち、DTW 閾値 θ を下回っている関節の数が閾値 θ^* 個以下の場合は本人、それ以外の場合は他人と識別する。

マハラノビス距離 [16]

DTW 距離ベクトルのマハラノビス距離を用いた手法である。 k_m は次元の数で $k_m = 2$ 、 r は d_ℓ と d_m の相関係数とするとマハラノビス距離 D_m は

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

表 5.1: 被験者の情報

項目	値
実験日	2018年7月26,27,30日
実験時刻	11時00分から7時間
人数	114名
男女比	男性77名:女性44名
測定回数	5回/人
年齢	18~70歳
場所	本学体育館



図 5.1: 実験風景

で与えられる. $r = 0$ 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.

5.3 評価実験

5.3.1 実験目的

本実験の目的を以下に示す.

1. Kinect から得られるスケルトンデータに DTW を適用する識別手法において, 複数特徴量の統合方法による識別精度を評価し, 提案手法の中で最も識別に有効な統合手法を明らかにする.
2. 結合する特徴数 c による精度の変化, 最適な値を明らかにする.
3. 被験者数 n による精度の変化を明らかにする.
4. 深度センサから得られる関節のなかで, 少ない数で識別に有効な関節の最適な組み合わせを求める.

5.3.2 実験方法

データ収集手法

4.3.2 節で用いたデータの他に, 追加で 114 名の歩行データを収集する. Kinect V2 を用いて, 図 4.2 と同様の環境で測定を行う. 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取る. 被験者は大学のロビーで募集した学生, 職員, 地域の方である. 実験に関する情報を表 5.1 に示し, 実験の様子を図 5.1 に示す. 本実験では 145 名の被験者を用いる.

各特徴量統合手法の精度比較

提案手法の6つの手法を用いて精度を計算する。 $n = 145$ に固定して EER を調べる。このとき、閾値は $FAR = FRR$ となるときの θ^* を用いて、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み合わせをそれぞれ300組計算した。ベンチマークとして、今回収集したデータを用いて4章の手法を適用した際の EER を求める。

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 を計算した。 ${}_{24}C_c$ は c の値によっては膨大になってしまうため、最大で300組に制限をした。

被験者数 n の変化による FAR の変動

本実験では、合計145名の被験者を集めた。この被験者からいくつかの部分集合を求めて FAR を評価することで、被験者数(規模)が精度に及ぼす影響を明らかにする。 $c = 1$ 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 を計算する。最大このときの閾値は、FRRが0.1になるよう調整したときのものを使用する。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。

最適な関節の選択

24個の関節の DTW 距離全ての組に関して相関係数を求める。全ての関節において、相関係数が最も高い関節が同じグループに属するようにクラスタリングをして、グループ内の代表的な関節のみを用いて識別を行う。

5.3.3 実験結果

測定データの統計量

測定したスケルトンデータの時系列データについて、各フレームごとに SpineBase を原点とした相対座標に変換し、各関節ごとに DTW 距離を計算した。各関節ごとの EER, DTW 距離の平均値, 標準偏差を表5.2に示す。表5.2の統計量は全て、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。

各関節ごとの平均値, SD の相関を図5.2に示す。平均値と SD の間に相関係数0.99の強い正の相関がみえる。平均値2.0を境として、右上の動的な関節群と、左下の静的な関節群の2つに分かれている。WristRight と WristLeft のように、左右の関節はほぼ同一の平均値で分布している。

表 5.2: DTW 距離の統計量

	EER	Mean	SD		EER	Mean	SD
ElbowLeft	0.10	1.76	0.62	AnkleRight	0.13	3.33	1.64
ElbowRight	0.11	1.73	0.64	HandRight	0.14	3.28	1.59
ShoulderRight	0.11	0.95	0.38	HipLeft	0.14	0.83	0.34
ShoulderLeft	0.12	0.99	0.40	HandTipRight	0.14	3.70	1.83
HandLeft	0.12	3.31	1.44	WristRight	0.14	2.79	1.30
KneeRight	0.12	2.39	1.08	Head	0.14	1.35	0.55
WristLeft	0.12	2.80	1.20	KneeLeft	0.14	2.42	1.14
Neck	0.12	0.76	0.31	FootLeft	0.14	4.03	1.80
HandTipLeft	0.13	3.77	1.67	SpineBase	0.14	0.80	0.33
SpineShoulder	0.13	0.57	0.23	AnkleLeft	0.14	3.31	1.63
HipRight	0.13	0.88	0.36	ThumbLeft	0.19	3.84	1.48
FootRight	0.13	4.03	1.79	ThumbRight	0.19	3.79	1.57

各結合手法の精度

D_{euc} と D_{eer_sd} , 本人同士, 他人同士の結合結果のヒストグラムを図 5.3, 図 5.4 に示す. 図 5.3 の D_{euc} と比べて図 5.4 の D_{eer_sd} では他人間が混在して分布しており, それゆえ誤差を上げていることが観測される.

$c = 8$ 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 5.5 に示す. 分布が左側に寄っている方が識別率が高いことを表している., この場合は D_{eer_sd} が最も有効な手法である.

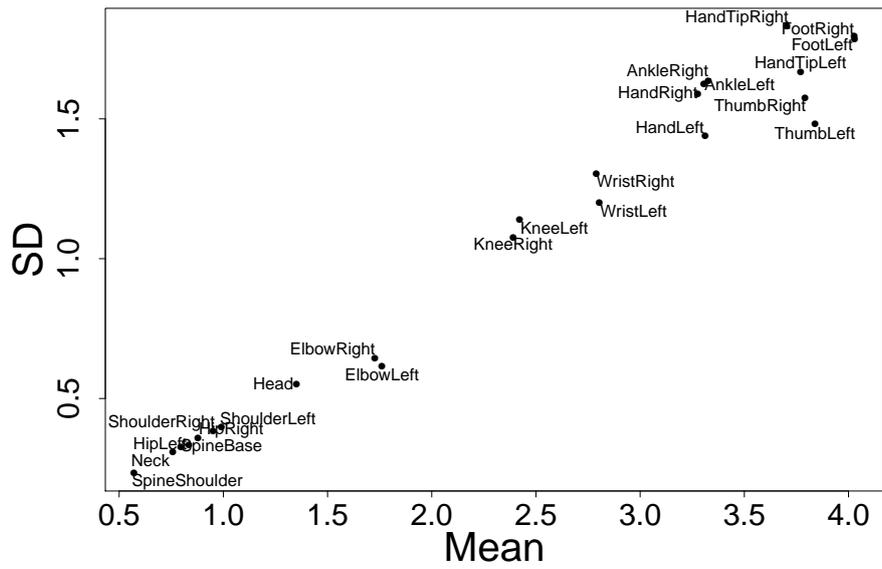


図 5.2: 各関節の平均値, SD による散布図

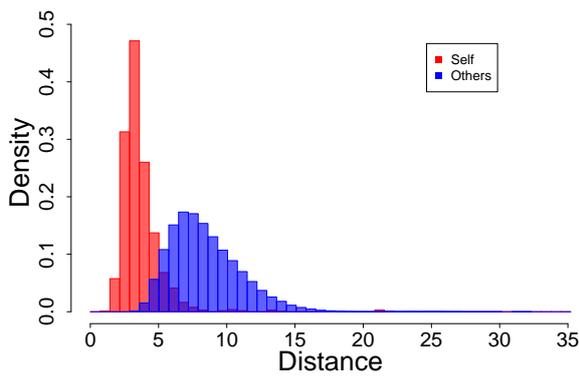


図 5.3: $c = 8$ のときの D_m のヒストグラム

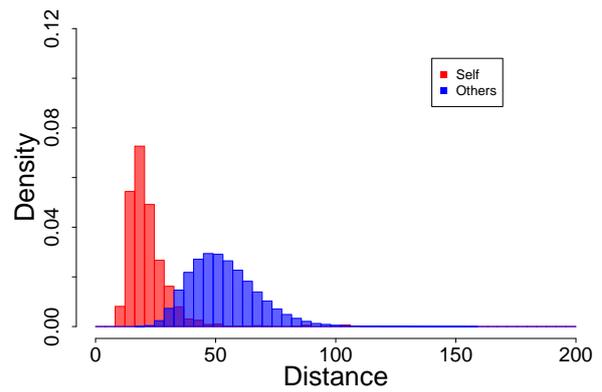


図 5.4: $c = 8$ のときの D_{eer_sd} のヒストグラム

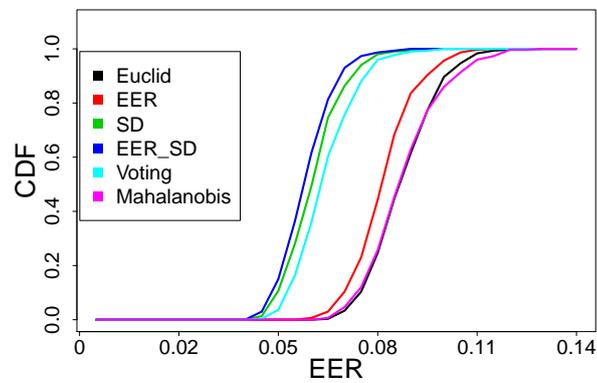


図 5.5: 結合手法の EER の累積分布 ($c = 8$)

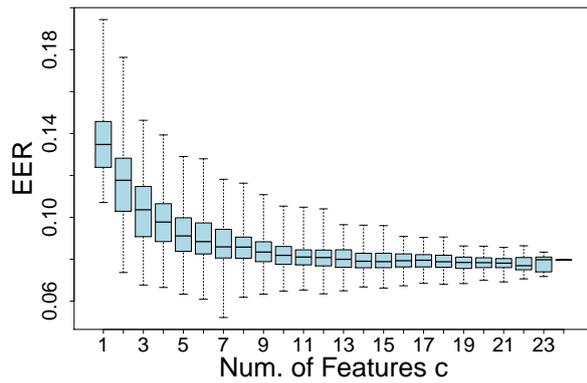


図 5.6: 特徴量数 c を変更したときの D_{eer} の EER の分布

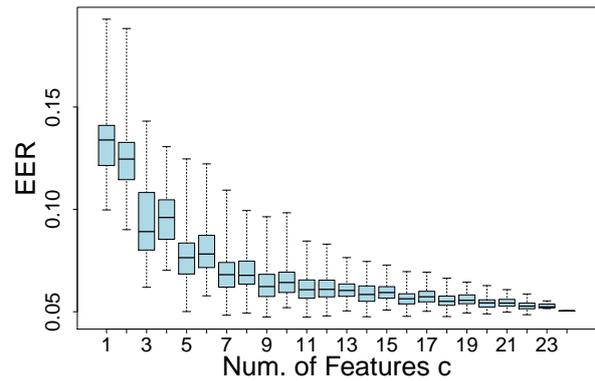


図 5.7: c を変更したとき投票方式の EER の分布

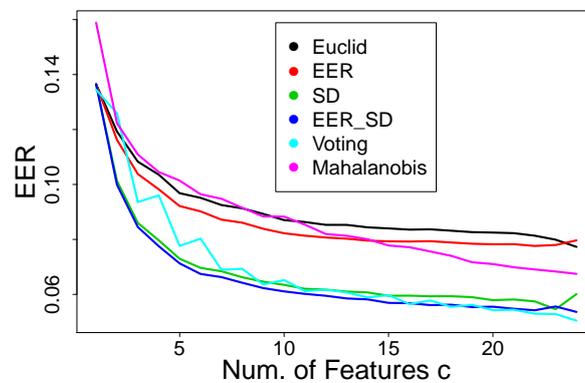


図 5.8: 結合特徴量の数 c に対する 6 手法の EER の変化

統合する関節の数 c の評価

c を変更したときの D_{eer} の EER の分布を図 5.6 に、投票方式の EER の分布を図 5.7 に示す。投票以外の 5 手法は図 5.6 と同様に平均値が単調減少した。投票方式も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となった。また、6 手法全てにおいて、 c の増加に伴い多少不安定ではあるが分散も減少している。

6 つの結合手法について、結合特徴量 c についての EER の平均値の分布を表 5.3 と図 5.8 に示す。表 5.3 では各 c について、最小の EER に下線を引いている。ほぼ全ての c において、 D_{eer_sd} の EER が最小であった。

表 5.3: 結合特徴量の数 c に対する 6 手法の EER の平均値

c	D_{euc}	D_{eer}	D_{sd}	D_{eer_sd}	Voting	D_m
1	0.136	0.136	0.136	0.136	<u>0.134</u>	0.210
2	0.119	0.116	0.101	<u>0.100</u>	0.143	0.136
3	0.108	0.104	0.086	<u>0.084</u>	0.162	0.124
4	0.104	0.098	0.080	<u>0.078</u>	0.097	0.116
5	0.097	0.092	0.073	<u>0.071</u>	0.109	0.105
6	0.095	0.090	0.070	<u>0.067</u>	0.080	0.102
7	0.093	0.087	0.068	<u>0.066</u>	0.086	0.103
8	0.091	0.086	0.066	<u>0.064</u>	0.069	0.098
9	0.089	0.084	0.065	<u>0.062</u>	0.074	0.094
10	0.087	0.082	0.063	<u>0.061</u>	0.066	0.093
11	0.086	0.081	0.062	<u>0.060</u>	0.068	0.092
12	0.085	0.081	0.062	<u>0.059</u>	0.064	0.089
13	0.085	0.080	0.061	<u>0.059</u>	0.064	0.086
14	0.084	0.080	0.061	<u>0.058</u>	0.064	0.084
15	0.084	0.079	0.059	<u>0.057</u>	0.060	0.083
16	0.084	0.079	0.060	<u>0.057</u>	0.062	0.081
17	0.084	0.079	0.059	<u>0.056</u>	0.058	0.080
18	0.083	0.079	0.059	<u>0.056</u>	0.060	0.077
19	0.083	0.078	0.059	<u>0.055</u>	0.056	0.075
20	0.082	0.078	0.058	<u>0.056</u>	0.058	0.074
21	0.082	0.078	0.058	0.055	<u>0.054</u>	0.074
22	0.081	0.078	0.057	<u>0.054</u>	0.056	0.074
23	0.080	0.078	0.055	0.056	<u>0.053</u>	0.073
24	0.077	0.080	0.060	<u>0.054</u>	0.055	0.070
平均	0.091	0.087	0.068	<u>0.066</u>	0.077	0.096

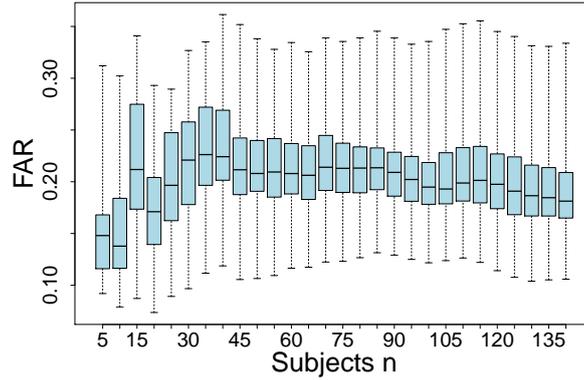


図 5.9: 被験者数 n と FAR の関係

被験者数 n の変化による EER の変動

被験者数 n と FAR の関係を図 5.9 に示す。 $n \leq 45$ までは FAR は不安定ながら増加していたが、 $n = 45$ をピークとしてゆるやかに減少していく。 4.3 節での被験者数は 31 名であったが、この結果では最も変動の大きなサイズのサンプリングである。

最適な関節の選択

24 個の関節と最も相関係数が高くなった関節を表 5.4 に示す。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 5.5 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。概ね、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、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。

表 5.4: 各関節と最も相関の高い関節対

関節	相関係数最上位	相関係数
AnkleLeft	FootLeft	0.901
SpineBase	SpineShoulder	0.973
WristLeft	HandLeft	0.983
ElbowLeft	WristLeft	0.877
WristRight	HandRight	0.989
KneeRight	KneeLeft	0.787
HipLeft	SpineBase	0.959
Neck	SpineShoulder	0.999
Head	Neck	0.591
HandTipRight	HandRight	0.995
HandTipLeft	HandLeft	0.991
FootLeft	AnkleLeft	0.901
SpineShoulder	Neck	0.999
KneeLeft	AnkleLeft	0.807
ShoulderRight	HipLeft	0.667
FootRight	AnkleRight	0.878
HandLeft	HandTipLeft	0.991
HipRight	SpineBase	0.954
ElbowRight	WristRight	0.832
AnkleRight	FootRight	0.878
ShoulderLeft	HipRight	0.731
HandRight	HandTipRight	0.995
ThumbLeft	HandLeft	0.825
ThumbRight	HandTipRight	0.897

表 5.5: 関節のグループ

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

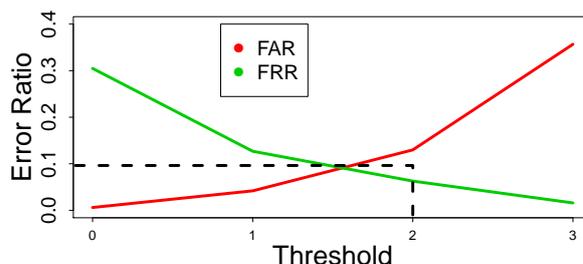
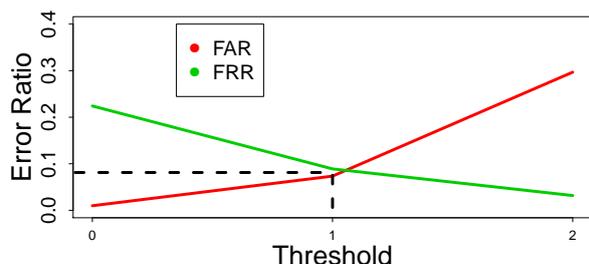


図 5.10: $c = 3$ のときの投票方式の FAR, FRR の分布
 図 5.11: $c = 4$ のときの投票方式の FAR, FRR の分布

5.3.4 考察

図 5.7 において, n が偶数の際は EER が低くなって, 奇数のときは大きくなるという不安定な EER が観測された. これは, 投票方式の閾値 θ^* が整数しか取れないことが原因である. $c = 3$ と $c = 4$ のときの投票方式の FAR, FRR のグラフを図 5.10 と図 5.11 に示す. $c = 3$ のときは $EER = 0.081$, $c = 4$ のときは $EER = 0.096$ である. c が偶数の場合は図 5.10 のように FAR と FRR のクロスポイントに近い位置に閾値があるが, c が奇数の場合は図 5.11 のように閾値とクロスポイントの位置に大きなズレが生じてしまう. EER はクロスポイントに最も近い閾値の FAR と FRR の平均により求めているが, 線の傾きが一定でないためクロスポイントから離れるほど値が大きくなってしまふ. したがって, 投票方式の EER だけ n と EER の関係が不安定になったと考えられる.

図 5.8 において, D_{sd} を用いた場合, D_{euc} よりも常に EER が小さくなった. 4 章で用いていた一般的な Euclid 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. そこで SD の逆数を重みとして掛けることで, すべての特徴量の値がほぼ等しくなり公平に扱われるため, EER が低下したと考えられる.

図 5.8 において投票方式が D_{euc} よりも EER が小さくなった原因は, 個数という平等な尺度に正規化されることでどの特徴量も等しく扱われたためだと考えられる.

表 5.3 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 5.8 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.

図 5.9 において, $n \geq 45$ では FAR が減少していった. これは, n を増やすと, 誤って本人と識別されてしまう似通った人物よりも, きちんと他人と判別できる, DTW 距離の大きな人物の方が増加するからであると考えられる. $n \geq 45$ では FAR の平均値はほぼ安定して減少していることから, n は 45 以上あれば提案手法の精度評価が十分行えるといえる.

5.4 まとめ

5 章の深度センサを用いた歩容識別手法において, 複数特徴量の統合手法を 6 つ提案し, 145 名の被験者を用いて精度評価を行った. 実験により, 統計的に最も EER が低くなるのは EER と SD を用

いて重み付けをする D_{eer_sd} であること，統合する特徴量の数 c については5が適切であること，被験者数 n は45名以上であれば適切な精度評価が行えることを明らかにした．

特徴量をグループ化し，その代表関節 ElbowLeft/Right, KneeRight, FootRight, Neck を用いて識別を行うことで，先行研究より EER を20%低下させることができた．

第6章 k 近傍による外乱にロバストな個人識別手法

6.1 本章の概要

5章では、4章をもとに、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、5章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、5章をもとに、 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。

6.2 提案手法

本章では、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4章、5章と同様であるため、本章では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 ℓ 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 ℓ の標準偏差 σ_ℓ 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 $T = \{R_1^{(u_1)}, R_2^{(u_2)}, \dots, R_{24}^{(u_n)}\}$ とすると、上位 k 個の特徴量は

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

表 6.1: 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

表 6.2: 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

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. $N_k(R^{(u)})$ 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.

6.3 評価実験

6.3.1 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.

6.3.2 実験方法

データ収集

通常歩行については, 4.3.2 節, 5.3.2 節で収集した 145 名のものを用いる. 外乱を含むデータについては, 5.3.2 節の環境で収集した. 実験に関する情報を表 6.1 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. 外乱のリストと収集した人数を表 6.2 に示し, それぞれの外乱のサンプルを図 6.1 に示す.

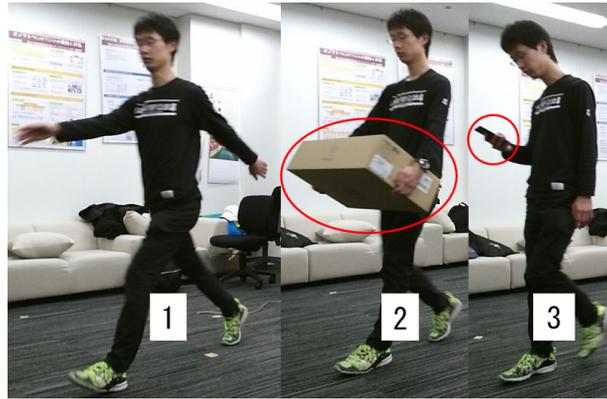


図 6.1: 外乱のサンプル

特徴量を単体で用いた際の識別精度

これは, Muaaz ら [3] 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.

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. 6.3.2 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.

既存手法を用いた場合の精度

6.3.2 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. 5 章で用いた手法の 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離を用いた精度評価を行う. 関節 l におけるテンプレートと対象特徴量間の DTW 距離を d_l , その SD を σ_l とすると, 関節 l と m を統合した距離は

$$D_{sd} = \sqrt{\left(\frac{d_l}{\sigma_l}\right)^2 + \left(\frac{d_m}{\sigma_m}\right)^2}$$

により求める.

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のときでもテストデータは一人あたり1つに合わせる。

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。

6.3.3 実験結果

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 6.3 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。

表 6.3: 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

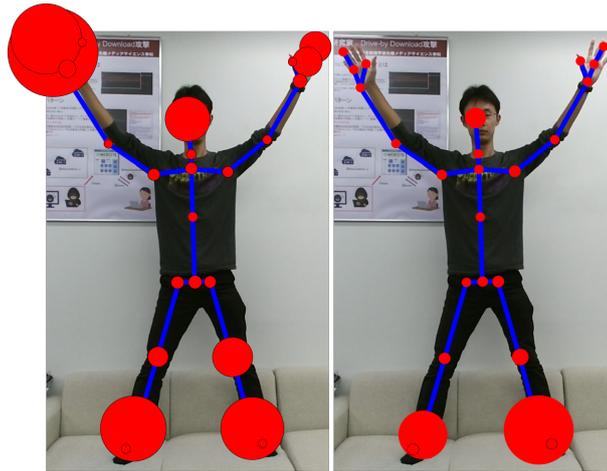


図 6.2: k -NN において最上位になった関節の分布 (左: normal, 右: box)

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 6.4 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 6.5 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 6.3 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 6.5 の採用回数を円の大きさと表したものを図 6.2 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。

表 6.4: 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	<u>0.78</u>	0.54
30	0.13	0.69	<u>0.78</u>	0.54
40	0.12	0.67	<u>0.78</u>	<u>0.52</u>
50	0.11	0.69	<u>0.78</u>	0.55
60	0.11	0.67	0.81	0.54
70	0.11	0.68	0.79	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

表 6.5: 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

表 6.6: 既存手法と提案手法の FRR

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

表 6.7: $k = 40$ 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>

既存手法を用いた場合の精度

5の手法を用いたとき、例として表 6.4 の $k = 40$ の FRR の比較を表 6.6 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 は悪化したが、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。

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 6.7 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 6.4 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。

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 6.3 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。

6.3.4 考察

表 6.3, 表 6.5 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 6.3 の box で一番 FRR が小さかった FootRight は表 6.5 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、例として各外乱ごとの FootRight と HandTipRight の正規化

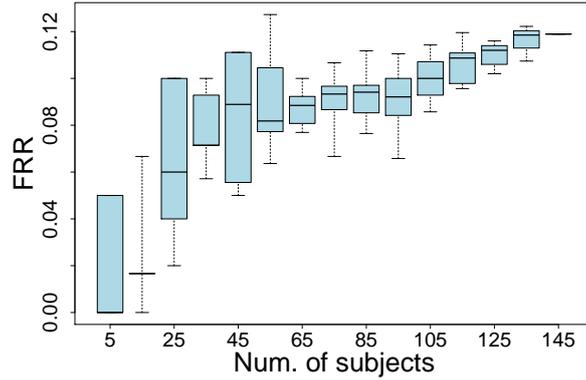


図 6.3: 被験者数と精度の関係

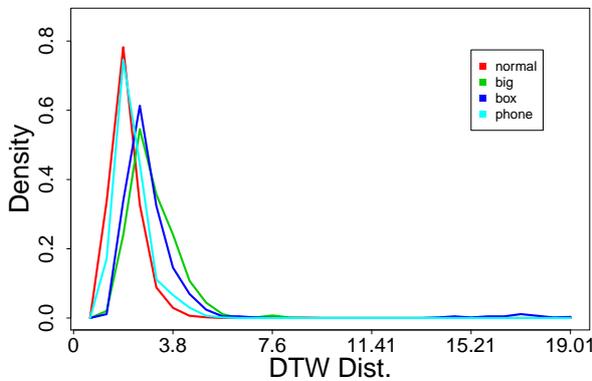


図 6.4: 正規化前の FootRight の DTW 距離の分布

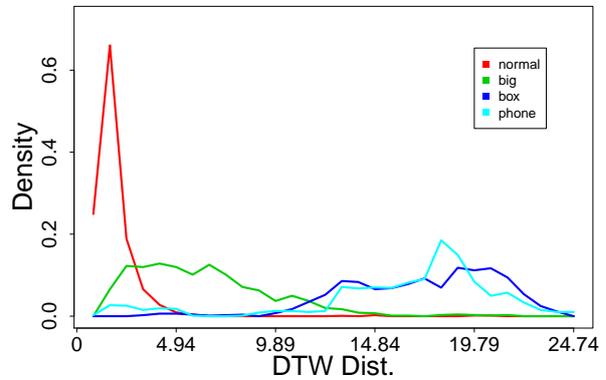


図 6.5: 正規化前の HandTipRight の DTW 距離の分布

前の DTW 距離のヒストグラムを図 6.4 と図 6.5 に示す。FootRight は外乱を加えても分布がほとんど変わらなかったが、HandTipRight は外乱を含む場合平均も分散も大きくなってしまった。

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 6.8 に示す。箱を持った場合に通常歩行と比較して DTW 距離が σ 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。5 章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。

表 6.6 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。

6.4 まとめ

本章では、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るロバスト性は低いと考えられる。

表 6.8: 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

第7章 結論

本論文では、歩容を用いた新たな人物識別手法を提案し、精度評価を行った。提案手法では、深度センサから得られる25個の関節の動きを用いることにより、DTWを用いて身体の動きの距離を計算することで識別を行う。

統計量を用いた識別手法では特徴量の解像度が小さく、また、本人内の安定性も高くないため、10人の被験者を用いてEER=0.25とエラー率が高くなってしまった。身体の各関節の動きに対してDTWを適用することで、145人の被験者を用いて最小でEER=0.10まで下がることを示した。複数の特徴量を統合することでEERは減少していくが、5つ程度で頭打ちになり、それ以上組み合わせてもEERはさほど変化しないことを示した。通常歩行における適切な統合手法は各特徴量の標準偏差の逆数とEERの逆数で重み付けをしたユークリッド距離を用いることであり、平均で重み付けしないユークリッド距離よりもEERが25%小さくなった。外乱を含む歩行における適切な統合手法はk-NNであった。重み付けしたユークリッド距離ではFRRは最大で0.99まで上昇してしまったが、k-NNでは最大で0.79まで抑えることができた。

以上の結果より、本論文で提案した歩容識別手法は既存手法よりも頑強であり、外部センサを用いて個人の識別・追跡を行うにあたり有用であることが示された。

参考文献

- [1] Tim Hornyak. Osaka train station set for large face-recognition study — pcworld. <https://www.pcworld.com/article/2094660/osaka-train-station-set-for-large-facerecognition-study.html>, 2014. accessed September 25, 2018.
- [2] Kohei Shiraga, Yasushi Makihara, Daigo Muramatsu, Tomio Echigo, and Yasushi Yagi. Geinet: View-invariant gait recognition using a convolutional neural network. In *2016 International Conference on Biometrics (ICB)*, pp. 1–8, 06 2016.
- [3] 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.
- [4] Donald J. Berndt and James Clifford. Using dynamic time warping to find patterns in time series. In *KDD Workshop*, 1994.
- [5] Ju Han and Bir Bhanu. Individual recognition using gait energy image. *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol. 28, No. 2, pp. 316–322, February 2006.
- [6] Md. Rabiul Islam Sagor Chandro Bakchy and Abu Sayeed. Human identification on the basis of gait analysis using kohonen self-organizing mapping technique. In *2016 2nd International Conference on Electrical, Computer Telecommunication Engineering (ICECTE)*, pp. 1–4, 2016.
- [7] Johannes Preis, Moritz Kessel, Martin Werner, and Claudia Linnhoff-Popien. Gait recognition with kinect. In *Proceedings of the First Workshop on Kinect in Pervasive Computing*, 01 2012.
- [8] Laura Igual, Àgata Lapedriza, and Ricard Borràs. Robust gait-based gender classification using depth cameras. *EURASIP Journal on Image and Video Processing*, Vol. 2013, No. 1, pp. 1–11, Jan 2013.
- [9] 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.
- [10] Yuting Zhang, Gang Pan, Kui Jia, Minlong Lu, Yueming Wang, and Zhaohui Wu. Accelerometer-based gait recognition by sparse representation of signature points with clusters. *IEEE Trans. on Cybernetics*, Vol. 45, pp. 1864–1875, 2015.

- [11] Mengxuan Li, Xi Chen, Shanshan Tian, Yifei Wang, and Pengfei Li. Research of gait recognition based on human electrostatic signal. *2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC)*, pp. 1812–1817, May 2018.
- [12] Wei-Han Lee, Jorge Ortiz, Bongjun Ko, and Ruby Lee. Inferring smartphone users’ handwritten patterns by using motion sensors. *4th International Conference on Information Systems Security and Privacy*, pp. 139–148, 01 2018.
- [13] 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.
- [14] Microsoft. Kinect ハードウェア - microsoft developer. <https://developer.microsoft.com/ja-jp/windows/kinect/hardware>, 2014. accessed August 10, 2017.
- [15] Microsoft. Jointtype enumeration - msdn - microsoft. <https://msdn.microsoft.com/ja-jp/library/microsoft.kinect.jointtype.aspx>, 2014. accessed August 10, 2017.
- [16] P. C. Mahalanobis. On the generalized distance in statistics. *Proceedings of the National Institute of Sciences (Calcutta)*, Vol. 2, pp. 49–55, 1936.

謝辞

本論文は筆者が明治大学大学院先端数理科学研究科先端メディアサイエンス専攻博士前期課程に在学中の研究成果をまとめたものである。本研究を遂行するにあたり多くの方々から多大なる御指導と御援助を賜りました。

特に、本論文を完成に導いていただき、また研究にかかわらず私を導いてくださった明治大学総合数理学部先端メディアサイエンス学科 菊池浩明教授に深く感謝申し上げます。

合同ゼミにおいて何度も有益なご討論をしていただき、ご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，静岡大学情報学部情報科学科講師 大木哲史先生，東京電機大学理工学部理工学科情報システムデザイン学系助教 稲村勝樹先生に心から感謝致します。

さらに、2年間共に楽しみ、苦しみ、励まし合い、ときには研究に対して有益な意見を与えてくれた明治大学菊池研究室の皆様，様々な研究会においてご意見，ご助言をくださった方々に感謝致します。

最後に、ここまで育ててくださり，博士前期課程に進学する機会を与えてくださった両親に厚く感謝致します。

研究業績

国際会議 (査読あり)

1. Takafumi Mori, Hiroaki Kikuchi, “Person Tracking Based on Gait Features from Depth Sensors”, *The 21st International Conference on Network-Based Information Systems (NBIS-2018)*, pp.743-751, 2018.
2. Takafumi Mori, Hiroaki Kikuchi, “Person Identification based on DTW Distance of Gait sequence”, *5th International Conference on Information Systems Security and Privacy*, 2019.

学会発表 (査読なし)

1. 森 駿文, 菊池 浩明, “深度センサによる歩容特徴量を用いた個人識別・追跡方式の提案”, コンピュータセキュリティシンポジウム (*CSS 2017*), pp.972-979, 2017.
2. 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, 7W-03, 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 (*DICOMO 2018*), 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 (*CSS 2017*), pp.1-8, 2018.
5. 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 (*SCIS 2019*), pp.1-8, 2019.
6. 三好 駿, 森 駿文, 菊池 浩明, “歩容データからの性別暴露リスクについて”, 情報処理学会第 81 回全国大会, 2ZA-01, 2019.