

# 測域センサにより取得される歩行パターンを 利用した高齢者/若年者弁別手法

坂井 栞<sup>1</sup> 木村 純麗<sup>1</sup> 池田 貴政<sup>2</sup> 野見山 大基<sup>3</sup> 松日楽 信人<sup>2</sup> 加藤 由花<sup>1,a)</sup>

**概要:** 我々はこれまで、測域センサで測定された各人の位置情報を基に、インタフェースロボットの応答制御を行い、挨拶などのコミュニケーションに利用する研究を進めてきた。ここでは、人の腰の高さに設置したセンサで人までの距離を時系列データとして取得し、ある時刻の人の位置を確率分布として推定する手法を用いてきた。本稿では、この手法を拡張し、測定位置を足首に変えることで、人の位置だけではなく、人属性を合わせて推定する手法を提案する。人属性推定としては、高齢者/若年者の弁別を対象に、機械学習アルゴリズムを用いて予測器を構築する。ここでは、「歩幅」「歩速」「歩行加速度」など7種類の歩行データの平均値と標準偏差を特徴量とすることで、単一の測域センサから取得した歩行データのみで、属性弁別が可能であることを示す。

**キーワード:** サービスロボット, LRF, 歩容解析, 年齢分類, サポートベクターマシン

## A Classification Method of Elderly and Young People using Walking Data Obtained from a Laser Range Scanner

SHIORI SAKAI<sup>1</sup> SUMIRE KIMURA<sup>1</sup> TAKAMASA IKEDA<sup>2</sup> DAIKI NOMIYAMA<sup>3</sup> NOBUTO MATSUHIRA<sup>2</sup>  
YUKA KATO<sup>1,a)</sup>

**Abstract:** Until now, we have studied a dialog control method for interface robots based on human location data measured by a laser range scanner as a human-robot interaction scheme. In this method, we have obtained distance data from the sensor at waist level to the target human as time series data, and have estimated the human location at a time as a probability distribution. This paper enhances the scheme and proposes an estimation method of human attributes in addition to their locations by measuring motion data of human legs at the time of walking. As human attributes, we focus on a classification method of elderly and young people, and construct the prediction model by using a machine learning algorithm. In this paper, we also verify that the attribute classification using walking data obtained from a single laser range scanner becomes possible by adopting seven types of features of walking data, such as strides, velocity and acceleration, for the model.

**Keywords:** service robots, LRF, gait data analysis, classification of age, support vector machine

### 1. はじめに

サービスロボット、コミュニケーションロボットの普及に伴い、人とロボットのインタラクションに関する研究に注目が集まっている。家庭や職場、公共施設などで人とロボットが共存する社会では、ロボットが人を含めた環境情報を適切に認識し、状況に応じたサービスを提供すること

<sup>1</sup> 東京女子大学 現代教養学部 数理科学科  
Suginami, Tokyo 167-8585, Japan

<sup>2</sup> 芝浦工業大学 工学部 機械機能工学科  
Koto, Tokyo 135-8548, Japan

<sup>3</sup> 芝浦工業大学 大学院理工学研究科 機械工学専攻  
Koto, Tokyo 135-8548, Japan

a) yuka@lab.twcu.ac.jp

が重要であるためである。ここでは、IoT 関連技術、ビッグデータ解析など、様々な技術の活用が期待されている。一方、サービスロボットの普及には、簡易な仕組みで高度なサービスが提供できる枠組みが必要である。新規にロボットを導入する場合、環境側に新たな設備を必要とせず、ロボット単体でサービスが完結する形が望まれるためである。

このような背景の下、我々はこれまで、単一の測域センサ (Laser Range Finder: LRF) で測定された人の位置情報を基に、インタフェースロボットの応答制御を行い、挨拶などのコミュニケーションに利用する研究を進めてきた [1]。ここでは、ロボットに取り付けた LRF により人の近接を検知し、人の位置に応じてロボットの会話内容を変更するサービスを提供している。高齢者向け公共施設での実験を通し、ロボットの導入が容易でありながら、多くの利用者がロボットとの会話を楽しむサービスの提供が可能であることを検証した。一方、人の位置のみを利用しているため、サービスが単調になり飽きが生じやすいという問題も明らかになった。

この問題を解決するために、本稿では、人の位置だけではなく、人属性 (年齢、性別など) を合わせて推定し、その情報を提供サービスに利用することを考える。先行研究では、人の腰の高さに設置した LRF で、LRF から人までの距離を時系列データとして取得し、ベイズフィルタを用いてある時刻の人の位置を確率分布として推定する手法を用いてきたが、この測定位置を足首に変えることで、人属性の推定を試みる [2]。足首の動きを測定すると、「歩幅」「速度」「両足の開度」「進行方向」などの歩容データを取得することが可能になり、これらのデータを分析することで、人の歩行特性による属性分けを行うことが可能になると考えられるためである。

本稿では特に、高齢者向け公共施設へのインタフェースロボット\*1の導入を目的に、単一センサにより、高齢者/若年者の弁別を行う手法を提案する。ここでは、単一の LRF から取得されたデータのみで歩容を推定する機能を実現し、機械学習の一つであるサポートベクターマシン (Support Vector Machine: SVM) を用いてこれらの歩容データから予測器を構築する。本研究の成果は以下の 2 点である。

- 単一の測域センサのみで歩容データを取得する
- 足首移動データのみで高齢者/若年者を弁別する

## 2. 関連研究

本稿では、人の歩行特性 (歩容) から人属性 (具体的には年齢) を推定する手法を提案するが、歩行特性により性別・年齢などの識別を行う研究は、これまでも、生物医学、認知学など様々な分野で精力的に行われてきた。これらの研究成果は、本研究において歩行の特徴量抽出に関する知

見として利用される。ここでは、歩容画像を用いる方法、ニューラルネットによる解析手法、歩行周波数による分類手法などについて説明する。

### 2.1 歩容画像を用いる方法

コンピュータビジョンの分野では、歩容画像を取得し、それを人属性の識別に用いる方法が多く提案されている。歩容画像は、対象者に特殊な装置を付ける必要がなく、簡易にデータが取得できる点に特徴がある。例えば、歩行者のシルエット動画 (30 fps) の時系列データの外形方形から、「歩幅」「歩調」「歩速」「歩行加速度」「歩行の標準偏差」「シルエットの高さ」を抽出し、高齢者 (65~80 歳)、大人 (13~64 歳)、子ども (6~12 歳) の 3 種類に分類する手法が提案されている [3]。ここでは、まず、背景を白に統一したスタジオ内に設けた 3 m の歩行ライン上を 72 人の歩行者に 1 往復ずつ普通に歩いてもらい、この様子を 1 台の固定カメラで撮影する。その後、得られた 144 本の歩行画像を 256 段階の濃淡映像に変換し、シルエット動画を作成する。ここから前述の 6 種類の特徴量を算出し、k 最近傍法により分類を行っている。ここでの認識率は 60~70% である。

歩容画像を用いた研究では、性別識別に関しても多くの研究があり、楕円モデル [4] やスケルトンモデル [5] へのフィッティングを行うことで関節の動きを抽出し性別認識を行うモデルベースの手法や、統計的な人体モデルに基づいて分割した身体の部位の画像による識別 [6]、前方、後方、横方向の複数カメラの画像を用いて方向に依存したモデルフィッティングを行う手法 [7] などが提案されている。

安価で容易にデータを取得できる反面、単一カメラで十分な精度を出すことは難しく、本稿での考察対象に適用する場合には、複数台のカメラの利用や他のセンサとの組合せなどが必要になる。

### 2.2 ニューラルネットワークによる解析手法

本稿と同様、機械学習を用いた弁別手法も多く提案されている。例えば、歩行時加速度データの特徴量とし、ニューラルネットワークにより高齢者と若年者を弁別する手法などがある [8]。ここでは、3 成分 (上下、左右、前後) 3 状態 (平地歩行、階段上り、階段下り) の加速度データを取得し、高齢者 1 名、若年者 1 名によるモデルを作成し、モデルに対する被験者の適合度を比較することで弁別を行っている。加速度データとしては、フィルタを用いて基本歩行周波数 (左右の足の設置間隔を 1/2 周期にもつ正弦波の周波数) のみを取り出して利用している。

基本歩行周波数は、人属性の識別に有効な特徴量であるが、本稿での考察対象では階段の昇り降り状態は観測されないため、本手法をそのまま適用することはできない。また、本手法では、人側に取り付けた加速度センサにより

\*1 ロボットとしては、移動機構を持たない、据え置き型のロボットを対象とする。

データを取得しているが、本稿ではロボットに取り付けたセンサで歩容を計測するため、データの生成方法に工夫が必要である。

## 2.3 歩行周波数による分類手法

文献 [8] では、ニューラルネットワークによる弁別手法に加えて、周波数解析による弁別の実験結果が示されている。前節と同様、加速度データの周波数解析を行い、基本歩行周波数（定義は前節と同じ、振幅スペクトルにおいて最も低い周波数に現れるピークの周波数）と加速度振幅（基本歩行周波数の加速度振幅）の加重平均により弁別のしきい値を決定し、このしきい値により高齢者と若年者を弁別している。これは、高齢者はどちらの値も若年者より小さい傾向にあることをモデル化したものであり、本稿でも 5 章において、特徴量の抽出に利用している。

ここでは、しきい値が特徴量の加重平均として一意に決められているが、本稿での提案手法は人の位置を確率分布で推定しているため、モデルの修正が必要になる。

## 2.4 その他の方法

スマートデバイスの普及により、これを歩行データ取得に利用し、高齢者の歩行特性を分析する研究も行われている。例えば、3 軸加速度センサから取得されるデータをもとに、高齢者・視覚障がい者の歩行に焦点を当て、転倒を防ぐための運動療法に利用する研究 [9] などがある。ここでは、iPod touch を用いてデータを取得し、高齢者グループは分岐点検知能力が低くなる傾向にあること、転倒を回避するような歩行をすること、踵から着地しつま先で蹴りあげるような 3 段階加重が見られる歩行をすることなどが報告されている。その他、歩行者の関節部分に装着した点光源の動きから歩行者の属性を判別する研究 [10] もある。点光源の動きに基いて子ども (3~5 歳)、大人 (30~52 歳) の識別を行う手法 [11] や、歩行の際の足と地面との間隔によって青年 (平均 28.4 歳) と高齢者 (平均 69.2 歳) の識別を行う研究 [12] などである。いずれも、計測のための装置を人が装着する必要があるが、本稿での考察対象とは異なる。

本稿と同様、ロボットに搭載された LRF を用いて高齢者の歩容を測定する研究も行われている [13]。ここでは、移動ロボットの後ろを歩く高齢者の足の動きを LRF で取得し、高齢者の健康状態の把握に利用している。ロボットが人を誘導することで比較的長時間のデータ取得を可能にしているが、本稿では、据え置き型のロボットを前提とするため、同様の手法を用いることは難しい。また、データの分析に関しても、健康状態の把握と年齢弁別とで目的が異なる。

## 3. 提案手法

### 3.1 前提条件

提案手法は、高齢者向け公共施設において、据え置き型ロボットに取り付けられた単一の LRF で測定されるデータのみを利用し、高齢者（概ね 60 歳以上）と若年者（それ以外）を弁別するものである。インタフェースロボットの応答制御を行うことを目的とするため、以下の前提条件を仮定する。

- ロボットは、施設の入口付近、受付などに設置する
- ロボットの前を、人が自由に行き来する
- 大部分の人は通常速度で、自然な状態で歩行する
- 人がロボットの前に極端に長時間滞在することはない
- 極端な密集状態になることはない

ここでは、LRF のスキャン範囲（今回の場合は 270°、最大検出距離 10 m）に入った足首データの点群を補足・追跡するため、1 人の歩行データとして、通常 5~10 歩前後のデータが収集される。

### 3.2 手法の概要

前述したとおり、高齢者/若年者の分類には機械学習のモデルを用いる。ここでは、高齢者、若年者とタグ付けされた歩行データを収集し、SVM を使用して予測器を構築する。分類の手順を以下に示す。

**Step 1:** 足首位置データの取得

**Step 2:** 歩行データの生成

**Step 3:** 予測器の構築

LRF から取得されるデータは、LRF から物体までの距離の点群である。Step 1 では、これらの点群から足首を抽出し、2 本の足（以降、それぞれの足を足 1、足 2 と記す）を一組の人として追跡器を割当てる処理を行う。その結果、足 1、足 2、および胴体の位置座標の時系列データが出力される。Step 2 では、この時系列データを用いて、歩行データの特徴量を算出する。本稿では、「歩幅」「歩隔」「足 1 の速度」「足 2 の速度」「胴体の速度」「足 1 の加速度」「足 2 の加速度」の 7 種類を抽出し、一つの歩行軌跡通してこれらの値の平均値、標準偏差を、ここでの特徴量とする。歩行データの定義を **図 1** に示す。Step 3 では、算出された特徴量を入力とし、SVM により予測器を構築する。実サービスでは、この予測器を用いて、属性弁別を行うことになる。

### 3.3 手法の詳細

以下、前節で示した各ステップごとに詳細を説明する。

#### 3.3.1 足首位置データの取得

本稿では、文献 [14] に記される人位置追跡手法と同様の方法で、足首位置データの取得を行う。ここでは、追跡




図 1 歩行データの定義

対象の位置を確率分布として扱い、追跡対象に応じた遷移モデル（人の移動）と、センサデータに基づく観測モデル（LRFにより測定される距離）から、再帰的に追跡対象の状態量に関する確率密度関数を推定する。文献 [14] では、発見した人ごとに追跡器を割り当て対象の位置追跡を行っているが、本稿ではこの過程で算出される足首ごとの位置座標を利用し、これを足首位置データとして取得する。

確率分布の推定には、パーティクルフィルタを用いる。パーティクルフィルタでは、確率分布は標本（パーティクル）の集合として定義され、パーティクルを重みに従ってリサンプリングすることで、事後確率（同じくパーティクルの集合として定義される）が生成される。アルゴリズムを 図 2 に示す。ここでは、人の二次元平面内における位置、姿勢、および速さである  $\mathbf{x}_t = [x_t, y_t, \theta_t, v_t]^T$  を状態量、 $\mathbf{a}_t$  を移動、 $\mathbf{z}_t$  を観測としている。 $\mathcal{X}_t$  は時刻  $t$  におけるパーティクルの集合であり、

$$\mathcal{X}_t := \mathbf{x}_t^{[1]}, \mathbf{x}_t^{[2]}, \dots, \mathbf{x}_t^{[M]}$$

と表現される。各パーティクル  $\mathbf{x}_t^{[m]}$  は、時刻  $t$  における状態の具体的なサンプルであり、このサンプルの集合  $\mathcal{X}_t$  で確率分布を表現する。このアルゴリズムでは、1 ステップ前のパーティクルの集合  $\mathcal{X}_{t-1}$  に、 $\mathbf{a}_t$  と  $\mathbf{z}_t$  を作用させることで一時的なパーティクルの集合  $\tilde{\mathcal{X}}_t$  を構成し、この集合から重み付きサンプリング（リサンプリング）を行うこ

```

1: procedure PARTICLE-FILTER( $\mathcal{X}_{t-1}, \mathbf{a}_t, \mathbf{z}_t$ )
2:    $\tilde{\mathcal{X}}_t = \mathcal{X}_t = \emptyset$ 
3:   for  $m = 1, \dots, M$  do
4:     sample  $\mathbf{x}_t^{[m]} \sim p(\mathbf{x}_t | \mathbf{a}_t, \mathbf{x}_{t-1}^{[m]})$ 
5:      $w_t^{[m]} = p(\mathbf{z}_t | \mathbf{x}_t^{[m]})$ 
6:      $\tilde{\mathcal{X}}_t = \tilde{\mathcal{X}}_t + \langle \mathbf{x}_t^{[m]}, w_t^{[m]} \rangle$ 
7:   end for
8:   for  $m = 1, \dots, M$  do
9:     draw  $i$  with probability  $\propto w_t^{[i]}$ 
10:    add  $\mathbf{x}_t^{[i]}$  to  $\mathcal{X}_t$ 
11:  end for
12:  return  $\mathcal{X}_t$ 
13: end procedure

```

図 2 パーティクルフィルタのアルゴリズム [15].

とで次周期の集合  $\mathcal{X}_t$  を生成している。この枠組みに従って逐次的に位置推定を行うが、遷移モデル  $p(\mathbf{x}_t | \mathbf{a}_t, \mathbf{x}_{t-1}^{[m]})$  と観測モデル  $p(\mathbf{z}_t | \mathbf{x}_t^{[m]})$  は別途与えておく必要がある。以降、それぞれのモデルについて説明する。

まず、遷移モデル（アルゴリズムの 4 行目）を考える。ここでは、人移動を速度にノイズを含む等速直線運動と仮定し、時刻  $t$  における状態量  $\mathbf{x}_t$  を以下の式に従って求める。 $\epsilon_{x,y}$  は速度に対するノイズ（ここでは一様乱数）である。

$$\begin{cases} x_t = x_{t-1} + v_{t-1} \Delta t \cos(\theta_{t-1}) \cdot \epsilon_{x,y} \\ y_t = y_{t-1} + v_{t-1} \Delta t \sin(\theta_{t-1}) \cdot \epsilon_{x,y} \\ \theta_t = \theta_{t-1} \\ v_t = v_{t-1} \end{cases}$$

次に、観測モデル（アルゴリズムの 5 行目）を考える。まず、背景差分後の LRF によるスキャンデータ（事前に環境データを測定しておき、実観測時に環境データとの差分により対象までの距離を測定した結果）について距離の近い点群をまとめた上で、それらの重心として計算される足首中心位置を用い、パーティクルごとの足の見え方に応じて以下の値を算出する。

$$p_s(\mathbf{z}_t | \mathbf{x}_t) = \begin{cases} \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{d^2}{2\sigma^2}\right) & \text{(両足発見時)} \\ \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{d_{st}^2}{2\sigma^2}\right) & \text{(片足発見時)} \\ 0 & \text{(未発見時)} \end{cases}$$

ここで  $d$  は、発見された二つの足首位置の中心からパーティクルの位置までの距離、 $d_{st}$  は人の通常歩行時の歩幅に相当する定数である（例えば 0.8 [m] など）。さらに、複数人追跡時に異なる人の足首を追跡中の人の足首と勘違いしないために、下記のモデルを追加する。これは、複数の人が同時に同じ領域を占めることはなく、互いに一定の距離を保つという知識を利用したものである。

$$p_r(\mathbf{z}_t | \mathbf{x}_t) = 1 - \exp\left(\frac{-d_{min}^2}{2\sigma^2}\right)$$

$d_{min}$  は、 $\mathbf{x}_{t-1}$  と  $\mathbf{a}_t$  により推定される時刻  $t$  における推定位置を追跡器ごとに計算しておき、対象追跡器のパーティクルとの距離が最小のものを選ぶことで計算する。その結果、他の追跡対象と極端に距離が近いパーティクルの重みが小さく評価される。これらの値を利用し、観測モデルは以下のように定義される。

$$p = p_s \cdot p_r$$

追跡器の割り当て方法については、まず、追跡器が存在しない領域に足首が発見された場合、その足首位置が人の歩幅に相当する距離内に 2 箇所存在する場合はそれらの中心位置に、1 箇所のみ存在する場合はその位置に追跡器を




図 3 処理前の歩行データ.




図 4 処理後の歩行データ.

割当て。また、ある追跡器の周囲に足首位置が観測されない状態が続いた場合、追跡対象の人が消失したと判定し、追跡器を破棄する。

本稿では、以上のように定義された遷移モデルと観測モデルに従い、パーティクルの移動、観測、重み付け、リサンプリングを繰り返すことで、歩行パターン（人ごとの足首データの移動データ）を取得する。

### 3.3.2 歩行データの生成

前節の結果から、タイムスタンプ付きの足 1 の座標  $(x_1, y_1)$ 、および足 2 の座標  $(x_2, y_2)$  が取得できる。これは、単位時間ごとの各足の位置座標なので、そのままでは着地点の位置座標と一致しない。そのため、滞留時間が長い、つまり時間軸方向に観測したときデータが密集している部分のデータを残し、滞留時間が短い、つまりデータがまばらな部分のデータを削除することにより、各足の着地点のデータを生成する。具体的には、観測 1 周期ごとの位置座標の差分を算出し、これが事前に設定したしきい値以下である連続した測定データ列を取得する（これによりデータ密集部を抽出する）。連続データ列の終端判定は、観測 2 周期ごとの位置座標の差分があるしきい値以上であることにより行う（これによりデータが疎な部分を検出する）。このデータ列の中心座標を着地点と推定するが、実際には連続データ数にもしきい値を設け、連続データ区間が続く場合にはそのデータも破棄する処理を組み入れる。処理前の歩行データのイメージを図 3 に、処理後の歩行データのイメージを図 4 に示す。

このデータを使って、歩行における各特徴量を算出する。歩数を  $i$  としたときの、タイムスタンプ付きの足 1 の座標  $(x_1^{(i)}, y_1^{(i)})$ 、足 2 の座標  $(x_2^{(i)}, y_2^{(i)})$ 、これらの重心として計算される胴体の座標  $(x_b^{(i)}, y_b^{(i)})$  を用いて、各値は以下のように算出される。ここで、歩数  $i$  が検出された時刻を  $t_i$  とする。

- 歩幅 [mm] :

$$st^{(i)} = |x_1^{(i)} - x_2^{(i)}|$$

- 歩隔 [mm] :

$$sw^{(i)} = |y_1^{(i)} - y_2^{(i)}|$$

- 足 1 の速度 [mm/s] :

$$v_1^{(i)} = \frac{\sqrt{(x_1^{(i)} - x_1^{(i-1)})^2 + (y_1^{(i)} - y_1^{(i-1)})^2}}{t_i - t_{i-1}}$$

- 足 2 の速度 [mm/s] :

$$v_2^{(i)} = \frac{\sqrt{(x_2^{(i)} - x_2^{(i-1)})^2 + (y_2^{(i)} - y_2^{(i-1)})^2}}{t_i - t_{i-1}}$$

- 胴体の速度 [mm/s] :

$$v_b^{(i)} = \frac{\sqrt{(x_b^{(i)} - x_b^{(i-1)})^2 + (y_b^{(i)} - y_b^{(i-1)})^2}}{t_i - t_{i-1}}$$

- 足 1 の加速度 [mm/s<sup>2</sup>] :

$$a_1^{(i)} = \frac{v_1^{(i)} - v_1^{(i-1)}}{t_i - t_{i-1}}$$

- 足 2 の加速度 [mm/s<sup>2</sup>] :

$$a_2^{(i)} = \frac{v_2^{(i)} - v_2^{(i-1)}}{t_i - t_{i-1}}$$

### 3.3.3 予測器の構築

前項で定義した 7 種類の特徴量の、一つの歩行軌跡通しでの平均値、標準偏差を算出し、これらのデータと属性値（高齢者/若年者）を組にして予測器の学習を行う。

## 4. 実験

### 4.1 実験の方法

提案手法を検証するため、属性ごとに歩行データを生成し、予測器を構築する。ここでは、床から 15cm の高さに LRF を設置し、被験者に自然な状態で自由に歩いてもらったときの足首位置データを取得し、その結果から歩行データを生成する。被験者は、高齢者 15 名、若年者 10 名の合

計 25 名であり、そのうちランダムに選択した高齢者 6 名、若年者 6 名のデータを訓練データとして予測器を構築し、残りをテストデータとしてモデルの評価を行う。

特徴量としては、算出した全ての平均値、標準偏差のうち、いくつかを組み合わせて利用する。具体的には、「歩幅の平均値 ( $st\_ave$ )」「歩幅の標準偏差 ( $st\_std$ )」「歩幅の平均値 ( $sw\_ave$ )」「歩幅の標準偏差 ( $sw\_std$ )」「足 1 速度の平均値 ( $v_1\_ave$ )」「足 1 速度の標準偏差 ( $v_1\_std$ )」「足 2 速度の平均値 ( $v_2\_ave$ )」「足 2 速度の標準偏差 ( $v_2\_std$ )」「胴体速度の平均値 ( $v_b\_ave$ )」「胴体速度の標準偏差 ( $v_b\_std$ )」「足 1 加速度の平均値 ( $a_1\_ave$ )」「足 1 加速度の標準偏差 ( $a_1\_std$ )」「足 2 加速度の平均値 ( $a_2\_ave$ )」「足 2 加速度の標準偏差 ( $a_2\_std$ )」の 14 種類から、以下の 3 パターンを選択して用いた。

- 実験 1: 加速度以外を用いる

$st\_ave, st\_std, sw\_ave, sw\_std, v_1\_ave, v_1\_std, v_2\_ave, v_2\_std, v_b\_ave, v_b\_std$

- 実験 2: 標準偏差のみを用いる

$st\_std, sw\_std, v_1\_std, v_2\_std, v_b\_std, a_1\_std, a_2\_std$

- 実験 3: 14 種類全てを用いる

$st\_ave, st\_std, sw\_ave, sw\_std, v_1\_ave, v_1\_std, v_2\_ave, v_2\_std, v_b\_ave, v_b\_std, a_1\_ave, a_1\_std, a_2\_ave, a_2\_std$

なお、予測器の構築には、Python の機械学習ライブラリ scikit-learn の svm.SVC 関数を利用し、RBF カーネル (ガウシアンカーネル) の SVM により予測モデルを構築した。パラメータ値は全てデフォルト値とした。

## 4.2 実験の結果

テストデータを用いて予測器を評価した結果を **表 1 - 表 3** に示す。一番 F 値の高かった実験 2 では、適合率、再現率ともに 90% を超えており、構築した予測器により適切な弁別がなされていることがわかる。

各結果を比較してみると、実験 1 と実験 3 の結果より、特徴量としての加速度の重要性が読み取れる。また、実験 2 と実験 3 の結果より、年齢弁別には、平均値より標準偏差 (ばらつき) の影響が大きいことも推察できる。2 章で示した関連研究からも、年齢により歩行データにばらつきが出ること、加速度変動が大きくなることなどが報告されており、それらを反映した結果になっている。

以上の結果より、適切な特徴量を生成することで、単一の測域センサのみで、高齢者/若年者の弁別が可能であることがわかった。また、特徴量としては、加速度データ、および各種データの標準偏差が重要であることがわかった。

## 5. 考察

提案手法では、各特徴量に対し、一つの歩行軌跡を通しての平均値、標準偏差を算出し、モデル構築に利用した。一方、2 章で言及した文献 [8] に示されるように、歩容では

時系列データの解析にも意味があり、特に、基本歩行周波数の利用は有効であると考えられる。そこで、今回の実験と並行し、高齢者 27 名、若年者 24 名の合計 51 名の被験者を対象に、文献 [8] に示される弁別しきい値を算出する実験を行った。算出の流れを以下に示す。

### Step 1: 加速度時系列データの算出

胴体速度の時系列データ  $v_b(t)$  から単位時間あたりの変化量を計算し、属性ごとの加速度時系列データ  $a(t)$  を算出する

### Step 2: フーリエ変換

$a(t)$  の離散フーリエ変換を行い、振幅スペクトル

$$A(f) = \sum_{t=0}^{N-1} a(t) \exp\left(-\frac{2\pi i f t}{N}\right)$$

を算出する

### Step 3: 基本歩行周波数、加速度振幅の算出

$A(f)$  において最も低い周波数に現れるピークの周波数 (基本歩行周波数)  $z_1$  と、そのときの振幅スペクトル (加速度振幅)  $z_2$  を算出する

### Step 4: しきい値の算出

弁別のためのしきい値を、以下の式に従って算出する。添字  $O$  が高齢者弁別のしきい値、添字  $Y$  が若年者弁別のしきい値である。この間の値を取った場合は弁別不能と判断する。ここで  $i = 1, 2$  である

$$\theta_i^O = (z_i^Y + 2z_i^O)/3$$

$$\theta_i^Y = (2z_i^Y + z_i^O)/3$$

データを分析したところ、高齢者の  $A(f)$  が最大であるときの周波数  $z_1$  は 14,  $A(f)$  の最大値  $z_2$  は  $6.98E+04$  であり、若年者の  $A(f)$  が最大であるときの周波数  $z_1$  は 27,  $A(f)$  の最大値  $z_2$  は  $7.00E+04$  であった。これらの結果が

表 1 モデルの評価結果 (実験 1)

属性	適合率	再現率	F 値	サンプル数
高齢者	1.00	0.56	0.71	9
若年者	0.50	1.00	0.67	4
平均	0.85	0.69	0.70	13

表 2 モデルの評価結果 (実験 2)

属性	適合率	再現率	F 値	サンプル数
高齢者	1.00	0.89	0.94	9
若年者	0.80	1.00	0.89	4
平均	0.94	0.92	0.93	13

表 3 モデルの評価結果 (実験 3)

属性	適合率	再現率	F 値	サンプル数
高齢者	1.00	0.78	0.88	9
若年者	0.67	1.00	0.80	4
平均	0.90	0.85	0.85	13

ら、しきい値として、 $\theta_1^O = 18.3$ ,  $\theta_2^O = 69900$ ,  $\theta_1^Y = 22.7$ ,  $\theta_2^Y = 69900$  が得られた。今後、より詳細な分析が必要であるが、基本歩行周波数は若年者の方が小さく、特徴量として有効であると考えられる。

## 6. おわりに

本稿では、LRF で測定される人の足首移動データから、SVM を用いて高齢者/若年者を弁別する手法を提案した。ここでは、「歩幅」「歩隔」「足1の速度」「足2の速度」「胴体の速度」「足1の加速度」「足2の加速度」の各データに対し、一つの歩行軌跡を通しての平均値、標準偏差を求め、これらのデータを特徴量として予測器を構築した。実際に、25名分のデータからランダムに選択した12名分のデータで予測器を構築し、残り13名分のデータでモデルの評価を行ったところ、80~90%の精度で、高齢者/若年者の弁別が可能であることがわかった。特に、特徴量として、加速度データ、ばらつき度合いを考慮することで、弁別性能が向上することを示した。

本研究の結論は以下の2点である。

- 足首の移動データを用いることと、取得した移動データから着地点の位置座標を推定することで、単一の測域センサのみで歩行特性の取得を可能にした
- 加速度データ、各データの標準偏差を用いることで、足首移動データのみで高齢者と若年者の弁別を実現した

今後、基本歩行周波数など、時系列データとしての特徴量をモデルに組み込んでいく予定である。また、今回はあらかじめ取得しておいたデータを利用してオフラインで属性の分類を行ったが、今後、オンラインでの弁別手法への拡張を検討していく。さらに、高齢者/若年者のみではなく、子どもの弁別、性別識別等への手法の展開も行う。

**謝辞** 本研究の一部は、JSPS 科研費 15K00137 の助成を受けたものである。

## 参考文献

- [1] 野見山大基, 折笠登志彦, 松日楽信人, 山本大介, 佐野雅仁: 人の移動に伴うインタフェースロボットの対面応答制御法の開発, ロボティクス・メカトロニクス講演会, pp. 2A1-M05 (2014).
- [2] 池田貴政, 野見山大基, 松日楽信人, 新井初見, 木村純麗, 坂井 栞, 藪井えりか, 山崎友希, 加藤由花: 歩行パターンを利用した人検出 RT コンポーネント, 計測自動制御学会 SI 講演会, pp. 102-6 (2015).
- [3] 深山 篤, 澤木美奈子, 村瀬 洋, 萩田紀博: 歩行動作特性からの年齢層の推定, 信学論, Vol. J84-D-II, No. 7, pp. 1522-1526 (2001).
- [4] Lee, L. and Grimson, W.: Gait Analysis for Recognition and Classification, *Proc. 5th IEEE Conf. on Face and Gesture Recognition*, Vol. 1, pp. 155-161 (2002).
- [5] Yoo, J., Hwang, D. and Nixon, M.: Gender Classification in Human Gait using Support Vector Machine, *Advanced Concepts for Intelligent Vision Systems*, pp. 138-145

- (2006).
- [6] Li, X., Maybank, S., Yan, S., Tao, D. and Xu, D.: Gait Components and Their Application to Gender Recognition, *IEEE Trans. Syst. Man Cybern., C: Appl.*, Vol. 38, No. 2, pp. 145-155 (2008).
- [7] Huang, G. and Wang, Y.: Gender Classification Based on Fusion of Multi-View Gait Sequences, *Proc. 8th Asian Conf. on Computer Vision*, Vol. 1.1, pp. 462-471 (2007).
- [8] 森田良文, 各務弘憲, 鶴飼裕之, 神藤 久: ニューラルネットに基づく歩行時加速度データの高齢者/若年者弁別, 信学論, Vol. J.88-D-II, No. 2, pp. 427-435 (2005).
- [9] 田口健斗, 矢入郁子, 岡田遼太郎, 岩澤有祐: スマートデバイスを用いた高齢者・障害者の歩行分析と行動推定, 人工知能学会全国大会, pp. 3J4-2 (2014).
- [10] Kozlowski, L. and Cutting, J.: Recognizing the Sex of a Walker from a Dynamic Point-Light Display, *Perception and Psychophysics*, Vol. 21, No. 6, pp. 575-580 (1977).
- [11] Davis, J.: Visual Categorization of Children and Adult Walking Styles, *Proc. Int. Conf. on Audio and Video-based Biometric Person Authentication*, pp. 295-300 (2001).
- [12] Begg, R.: Support Vector Machines for Automated Gait Classification, *IEEE Trans. on Biomedical Engineering*, Vol. 52, No. 5, pp. 828-838 (2005).
- [13] Yoroazu, A. and Takahashi, M.: Development of Gait Measurement Robot Using Laser Range Sensor for Evaluating Long-distance Walking Ability in the Elderly, *Proc. IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS2015)*, pp. 4888-4893 (2015).
- [14] 野口博史, 山田隆基, 森 武俊, 佐藤和正: 大量の人移動計測データに基づく移動ロボットの人回避経路計画, 日本ロボット学会誌, Vol. 30, No. 7, pp. 684-694 (2012).
- [15] Thrun, S., Burgard, W. and Fox, D.: 確率ロボティクス (訳: 上田隆一), マイナビ (2007).