

# ラジオ体操の区切りを利用しない 加速度データの文字列表現と人の動作分析

島 孔介<sup>1,a)</sup> 森山 甲一<sup>1</sup> 武藤 敦子<sup>1</sup> 犬塚 信博<sup>1,b)</sup>

**概要：**私達は普段から歩行や階段昇降など、様々な行動をして生活している。これらの行動には、同じ歩行行動であっても肩を揺らして歩く、足を垂直に下ろすなど、様々な動き方がある。このような人の動き方を分析し、特徴的な動きを発見できれば、人の出身や身長体重などの特徴との統計的な分析への応用が期待できる。本研究は、ラジオ体操を行なった際に手先に生じる加速度データを取得し、そのデータを文字列で表現することで、特徴的な動き方を発見する手法を提案した。また、動き方に応じた人のグループ分けを行い、グループと人の特徴との分析を行なった。しかしながら、この手法はラジオ体操を構成する運動ごとの区切りを利用しており、区切りが明確でない日常行動に対して利用することは難しいため、特徴的な動きが現れるタイミングや、動きの長さに対応できる手法に汎用化を行う必要がある。そこで本論文では、ラジオ体操の運動の区切りや音楽の拍を用いることなく、加速度データから文字列を生成する手法を提案する。

## 1. はじめに

私達は普段から歩行や走行など、様々な行動をして生活している。これらの行動には、例えば歩行であれば足を交互に前に出すなど、根本的な動きが存在する。一方で、歩く際に肩を揺らす、足を前に出す際に地面に対して垂直に足を下ろすなど、根本的な動きとは関係のない動き方がある。これらの動き方には、例えば肩を揺らして歩く場合、後ろ側の足を前に出す際、膝が曲げられず足を浮かすことが難しいため肩を揺らすなどの理由が考えられる。またこのように、人の動き方の違いには、身体的、世代的、地域的、また精神的なものなど、様々な理由が考えられる。人間の行動から加速度などのデータを取得し、理由に対応した動き方を発見することができれば、理由に応じた様々なサービスへの応用が期待できる。

本研究では、ラジオ体操を対象として、動き方に着目した人のグループ分けを行う。ラジオ体操は日本において一般的に知られる体操であり、健康効果も注目されている。加えて、ラジオ体操は決められた12種類の運動を音楽に合わせて行うため、行うべき動き方が明確に決められているにも関わらず、人によって動き方が異なる興味深い対象である。私達はラジオ体操に伴う加速度を分析することで、

似たような動き方をする人達を同グループ、同じ動き方をしない人達を異なるグループとするグループ分けを行なった。その結果として、ラジオ体操の動きに注目することで、人は少なくとも2つのグループに分けることができ、それらは身長や体重、運動の得意不得意などが理由であることを確認した。

本稿では、これまでに提案した加速度の文字列表現を用いた人の動き方の分析手法について、日常行動への応用を視野に入れた手法の汎用化を考える。これまでの手法では、ラジオ体操があらかじめ決められた12種類の運動を音楽に合わせて行うことから、データ中のあるタイミングにおいて、どのような行動をしているかが明確であることを前提に分析を行っていた。しかしながら、日常行動への応用を考えた場合、特定の行動がどのタイミングで現れるか、どの程度の長さで特定の行動を行うかが明確でないため、ラジオ体操に対して作られた手法をそのまま応用することは難しい。そこで本稿では、ラジオ体操に対する手法において前提となっている事項について汎用化を行なった手法を提案し、従来手法と同様の分析を行うことができるかを確かめる。

## 2. 関連研究

人の動作を分析する研究として、本研究の文字列表現と同じく、人の行動から行動素と呼ばれる局所的な動きのパターンの遷移によって動きを表記する研究が行われている。

<sup>1</sup> 名古屋工業大学  
Nagoya Institute of Technology, Nagoya 466-8555, Japan

<sup>a)</sup> k.shima.214@nitech.jp

<sup>b)</sup> inuzuka@nitech.ac.jp

る。植浦らはビデオデータを用いて人間の動きをデータ化し、その特徴列を抽出することで、行動を表現する手法を提案している [2]。Huzs らはクラスタリングを用いて動き方をいくつかのパターンに分け、データをパターン列として表現し、行動認識を行なった [3]。また、Moeslund らは、行動を原始的に記述することは、行動をモデリングする上で重要であると述べている [4]。

行動分析の分野では、杉本らはスマートフォンを用いて人の歩行に伴う加速度を取得し、酔酩状態か否かを認識するための検討を行なっている [5]。卯田らはズボンのポケットに入れたスマートフォンによってリフティング中の加速度を計測し、ボールリフティングにおける習熟度を計測する手法を提案した [6]。Zhu らはラケットを用いたスポーツにおける動きにおいて、ビデオデータを用いた動作分析手法を提案している [7]。Najafi らは日常行動における高齢者の動きを分析する運動学的なモデルを提案した [8]。Rasmussen はルーチンワーク環境と不慣れな環境において、スキルやルール、知識に関する議論を行なっている [9]。Jaouedi らはジェスチャーや急な動き、また動きの速さに注目し、人の動作をビデオデータの認識を用いて分析している [10]。Watanabe はカードゲーム“Old Maid”における人の行動を分析している。この研究では、ジョーカーを持っているかどうかによるカードのシャッフルや頭の動きを動作として着目している [11]。以上とは別に、同一の行動においても人によって動き方が異なることから、歩行動作を分析することで個人認識を行う研究も行われている [12]。

これらの行動分析の研究において、以上に示したように、特定の行動において酔酩状態であるか、習熟度の違い、ジョーカーを持っているかなど、ある要因において動き方が変わるかどうかの研究と、人ごとに動き方が異なることに着目した個人認識に別れている。本研究では、人がある要因を持っているかの二値分類、人を分類する多値分類の中間として、多数の行動を観察し、何種類の動き方が存在するかも不明瞭な対象において、動き方が何種類存在するのか、統計的分析において動きはどのような要因と関連しているのかなどを分析する。

### 3. 従来手法

#### 3.1 文字列生成手法

従来手法は以下に示す手順で加速度データから文字列生成を行う。

- (1) ラジオ体操 1 回分の加速度データ系列  $d_i$  を収集し、件数  $N$  のデータセット  $D = d_1, \dots, d_N$  を用意する。
- (2) 各データをラジオ体操を構成する 13 の運動ごとに分割し、 $d_i = e_1^i, \dots, e_{13}^i$  とする。
- (3) 運動ごとの加速度データ  $e_j^i = (c_1^{i,j}, \dots, c_m^{i,j})$  と  $m$  個の窓に分割する。




図 1 提案手法のイメージ

**Fig. 1** A Conceptual Diagram of Proposed Method; the method divides data to sliding windows and symbolizes windows according to result of k-means clustering. The method coordinates sequence of same symbols to a symbol.

- (4) 各窓データ  $c_k^{i,j}$  について加速度の平均や躍度の平均などの特徴ベクトルを計算する。
- (5) 全ての窓データ  $C = \{c | c \in e, e \in d, d \in D\}$  を (4) の特徴ベクトルを用いてクラスタリングを行う。ここで、 $|C| = n \times 13 \times m$  である。また、 $c \in e, e \in d$  は  $c$  が  $e$  の分割の中に、 $e$  が  $d$  の分割の中にあることをそれぞれ表す。クラスタ中心にはそれぞれアルファベットや記号など 1 文字で名前を与える。
- (6) 各窓データ  $c_k^{i,j}$  について、その窓が属するクラスタ名を与え、それを並べることで運動データを文字列で表記する。

以上で得られた文字列を動作語と呼び、ラジオ体操 1 回分のデータ  $d$  の運動  $i$  に置ける動作語を  $w_i(d)$  と表す。なお、上で述べた手順の (4) で述べた特徴ベクトルには、以下の特徴を用いる。

- 窓内の加速度のユークリッドノルムの平均
- 窓内の躍度のユークリッドノルムの平均
- 窓を前半と後半に 2 分割し、それぞれの加速度のユークリッドノルムの平均の差
- 窓内に置ける支配的な加速度の向き

窓内における支配的な加速度の向きは、窓内の各軸の加速度の平均の絶対値を計算し、値が最も大きい軸の向きに応じて  $(x, y, z) \in \{(1, 0, 0), (0, 1, 0), (0, 0, 1)\}$  となる特徴量である。また、加速度ノルムの平均、躍度ノルムの平均については  $[0, 1]$ 、窓の前後半での加速度ノルムの平均の差については  $[-0.5, 0.5]$  に正規化して用いる。

### 4. 提案手法

#### 4.1 運動の区切りと拍を利用しない文字列生成

本章では、従来手法の文字列生成手法について、ラジオ体操に伴う加速度に対して用いた前提を除いた文字列生成手法への汎用化を行う。本手法の概要図を図 1 に示す。提案手法は以下の手順にて文字列生成を行う。

- (1) 時系列の3軸加速度データセット  $D = d_1, \dots, d_N$  の各データにおいて、固定長の窓をスライディングすることで窓分割を行う。ここではデータごとの長さが違うことも考慮し、各データの窓数は  $W = w_1, \dots, w_N$  とする。
- (2)  $W_{all} = \sum_{i=1}^N w_i$  個の窓それぞれにおいて、従来手法と同じく特徴ベクトルを算出する。
- (3)  $W_{all}$  個の窓全てについて、特徴ベクトルを座標として k-means 法でクラスタリングを行う。ここで、各クラスタ中心に対して単一の文字を割り当てる。
- (4) クラスタリング結果をもとに窓に対応するクラスタ中心の文字を与え、各データの窓列から文字列を生成する。
- (5) 文字列中に同じ文字が連続して現れる部分を1文字として、最終的な文字列を生成する。

本手法では、ラジオ体操の音楽の拍によって動作のタイミングが揃えられることを前提としておらず、データによってタイミングが異なることに対応するため、窓の開始時点の決定にはスライディングウィンドウを用いる。また、ある動きがどの程度の長さになるかも不明瞭な対象への応用を考慮して、クラスタリングにおいて同じ動き（同じ文字）とされた部分が連続して現れた場合、文字が連続する区間を同じ動きを連続して行なっているとして、1文字で表すこととする。以上で得られたデータ  $d$  の動作語を  $w(d)$  と表す。

#### 4.2 提案手法における癖のルールの再定義

提案手法で得られる動作語はラジオ体操の運動ごとに分けられていないため、分析手法の再定義を行う。まず本研究における癖とは、動作語  $w(d), d \in D$  中に頻出する部分文字列である。ある文字列  $r$  が動作語  $w(d)$  中に少なくとも1回含まれる場合に  $have(w(d), r) = 1$ 、含まれない場合に  $have(w(d), r) = 0$  とし、以下の条件を満たす場合、文字列  $r$  を癖とする。

$$\frac{1}{N} \sum_{i=1}^N have(w(d_i), r) \geq threshold_1 \quad (1)$$

ここで、動作語に含まれる文字はクラスタ中心に対応しており、それぞれ特徴ベクトル  $(u_1, \dots, u_n), (v_1, \dots, v_n)$  を持つ2つの文字  $l_1, l_2$  について、以下のように文字間の距離を定義できる。

$$dist_l(l_1, l_2) = \sqrt{\sum_{i=1}^n (u_i - v_i)^2} \quad (2)$$

これを用いて、文字数  $m$  の2つの文字列  $w_1 = l_1 \dots l_m, w_2 = l'_1 \dots l'_m$  の距離を以下のように定める。

$$dist_w(w_1, w_2) = \frac{1}{m} \sum_{i=1}^m dist_l(l_i, l'_i) \quad (3)$$

また、文字列  $w, w' (|w| > |w'|)$  のように文字列の長さが異なる場合は以下のように定める。

$$dist(w, w') = \min_{s \text{ は } w \text{ の部分文字列}} (dist_w(s, w')) \quad (4)$$

以上で定義した距離を用いて、あるデータ  $d$  の動作語  $w(d)$  と癖  $r$  について、距離に近いほど値が1に近くなる類似度  $sim(w(d), r)$  を以下のように定める。ここで、 $\max(dist)$  は  $dist(w(d), r)$  の最大値である。

$$sim(w(d), r) = \frac{\alpha}{\max(dist)} \left( \frac{\alpha + \max(dist)}{\alpha + dist(w(d), r)} - 1 \right) \quad (5)$$

以上で得られた癖と動作語の類似度を用いて、同一のデータに現れやすい癖の組について考える。2つの癖  $r, r'$  について、共起性を示す値  $COC(r, r')$  を以下のように再定義する。

$$COC(r, r') = \frac{\frac{1}{D_1} \sum_{d \in D_1} sim(w(d), r')}{\frac{1}{D_2} \sum_{d \in D_2} sim(w(d), r')} \quad (6)$$

$$D_1 = \{d \mid have(w(d), r) = 1\} \quad (7)$$

$$D_2 = \{d \mid have(w(d), r) = 0\} \quad (8)$$

この値があらかじめ与えた閾値を超える場合に、2つの癖  $r, r'$  は同一のデータに共起しやすい癖の組とし、 $R = r \rightarrow r'$  と表す。

次に、2つの癖の組  $R_1, R_2$  の間の関係を表す値  $REL(R_1, R_2)$  を以下のように示す。ここで、各癖の組は  $R_1 = r \rightarrow r', R_2 = s \rightarrow s'$  とする。

$$REL(R_1, R_2) = \frac{\sum_{d \in D} \max\{sim(w(d), s), sim(w(d), s')\}}{|D|} \quad (9)$$

$$D = \{d \mid have(w(d), r) = have(w(d), r') = 1\} \quad (10)$$

#### 4.3 人やデータのグループ分け

4.2節で述べたルール間の関係  $REL$  を用いて、癖の組のグループ分けを行い、その結果を用いて人やデータのグループ分けを行う。まず、[Shima et al. 2018] の手法を用いて癖の組のグループ分けを行う。ここで得られる癖の組のグループ分け結果は、同一グループ内の癖の組同士で  $REL$  の値が大きく、異なるグループに属する癖の組同士で  $REL$  の値が0に近くなるグループ分けである。

次にデータとグループ間の関係を調べる。データ  $d$  と癖の組  $R = r \rightarrow r'$  について、 $have(w(d), r) = have(w(d), r') = 1$  を満たすとき、 $have(w(d), R) = 1$  と表す。このとき、データ  $d$  がグループの集合  $G = \{g_1, \dots, g_n\}$  の内、どのグループに属しているかを以下のように定める。なお、 $g \in G$  は癖の組の集合である。

$$group(d) = \arg \max_{g \in G} \frac{\sum_{R \in g} have(w(d), R)}{|g|} \quad (11)$$

人のグループは、式11の結果を元に、同一人物のデータのグループ中で多数決によって決定する。




図 2 スマートフォンの持ち方と対応する 3 軸

Fig. 2 Grasping a Smartphone and Accelerometer Axis

## 5. 実験

ここでは、ラジオ体操に伴う手先の加速度について、従来手法と提案手法のそれぞれで文字列を生成し、[Shima 2018]の手法を用いて動き方と人の特徴との関係を分析する。

### 5.1 加速度データの条件

実験では、21 歳から 25 歳までの名古屋工業大学の男子学生 11 人に両手に 1 つずつスマートフォンを図 2 のように把持してもらい、ラジオ体操 1 回につき 2 件の手先の加速度データを取得した。また、1 人あたりラジオ体操を 2 回行ってもらい、1 人につき 4 件のデータを取得し、計 44 件のデータを取得した。データの取得には Nexus 5 を用い、取得した加速度データを一定周期にするため、50Hz にダウンサンプリングを行なった。

### 5.2 加速度データのダウンサンプリング

スマートフォンで加速度データを取得する場合、スマートフォンは根幹となるソフトウェアの優先度が高いことにより、必ずしも一定周期でデータが取得できるとは限らない。また、センサの特性などにより、高周波のノイズが入る可能性が考えられる。そこで本研究では、次の式を用いてデータのダウンサンプリングを行なった。なお、元データ  $d$  がサンプリングされた各点の時間を  $T = (t_1, \dots, t_N)$ 、ダウンサンプリングされたデータ  $\hat{d}$  の各点の時間を  $\hat{T} = (\hat{t}_1, \dots, \hat{t}_M)$  とする。

$$\hat{d}(\hat{t}_i) = \frac{\sum_{j=1}^N \{d(t_{j+1})f_i(t_{j+1}) + d(t_j)f_i(t_j)\}(t_{j+1} - t_j)}{\sum_{j=1}^N \{f_i(t_{j+1}) + f_i(t_j)\}(t_{j+1} - t_j)} \quad (12)$$

ここで、 $f_i(t)$  は平均を  $\hat{t}_i$ 、標準偏差をサンプリング周期の 3 倍とする正規分布である。すなわち、時刻  $\hat{t}_i$  を中心として  $\hat{t}_{i-1} \leq t \leq \hat{t}_{i+1}$  の範囲を面積の 99% とした正規分布を元データにカーネルとしてかけ、その平均がデータ  $\hat{d}$  の時刻  $\hat{t}_i$  におけるデータとして得られる。

### 5.3 その他の実験条件

[Shima 2018] の手法を用いて分析する際の閾値やパラ

表 1 実験で用いた閾値やパラメータ

Table 1 The Experimental Parameters and Thresholds

| 文字列 $r$ の頻度 [%] | 癖 $r, r'$ の共起性 | 癖の組 $R_1, R_2$ の関係 |
|-----------------|----------------|--------------------|
| 20              | 8              | 0.25               |
| 運動の分割数          | 提案手法の窓幅 [ms]   | 窓のスライド幅 [ms]       |
| 32              | 400            | 40                 |
| クラスタ中心数         | パラメータ $\alpha$ |                    |
| 26              | 0.001          |                    |

表 2 人の特徴を取得するアンケートの項目と値の型

Table 2 Human Characteristics from Questionnaire. A sample is sampled with a case of Radio Gymnastic Exercises

| 特徴      | 値   | 特徴       | 値               |
|---------|-----|----------|-----------------|
| 身長      | 整数  | 天気       | 文字列             |
| 体重      | 整数  | 体感温度     | {1, 2, 3, 3, 5} |
| BMI 指数  | 小数  | 体調       | {1, 2, 3, 3, 5} |
| 年齢      | 整数  | ラジオ体操の習熟 | {1, 2, 3, 3, 5} |
| 出身      | 文字列 | 運動が得意か   | {1, 2, 3, 3, 5} |
| 起きた時刻   | 整数  | 好きなスポーツ  | 文字列             |
| データ取得時刻 | 整数  |          |                 |

メータは、従来手法と提案手法で同一の値とした。ある部分文字列  $r$  が動作語  $w(d \in D)$  中に頻出すると判断するための閾値、2 つの癖  $r, r'$  において共起性が高いことを示す値  $COC(r, r')$  の閾値、癖の組  $R_1, R_2$  の関係を示す値  $REL(R_1, R_2)$  において、排他的とする閾値を表 1 に示す。また、従来手法における 1 つの運動の窓分割数、提案手法における窓幅と窓のスライド幅も表 1 に示す。従来手法は加速度データを運動ごとに分割し、運動ごとの加速度データを定数個に分割するため、運動ごとによって窓幅に若干の違いがあるが、約 400 ~ 450[ms] 程度であるため、提案手法における窓幅は 400[ms] とし、スライド幅はその 1/10 の 40[ms] とした。表 1 のクラスタ中心数は、文字列生成に用いる k-means 法におけるクラスタ中心数であり、文字の種類を意味する。また、 $\alpha$  は式 (5) におけるパラメータである。

[Shima 2018] の手法では、本論文で述べた手法で得られた動作語を用いてデータを 2 つのグループに分け、グループを目的変数、人の特徴を説明変数として決定木学習を行うことで関係を分析する。ここで用いる人の特徴は、ラジオ体操のデータを取得した際にアンケートを用いて、表 2 に示す特徴を計 22 件取得した。このとき加速度データは両手に 1 つずつスマートフォンを把持していることで 2 件のデータが得られているため、アンケート 1 件を 2 件に複製し、それぞれに右手、左手のデータのグループ分け結果を目的変数として対応づけた。決定木学習には、機械学習用ソフトウェア Weka を用い、J48, Random Forest の 2 手法で 10 分割交差検証を行なった。




図 3 従来手法

Fig. 3 Heat Map of Rate of that Motion Word Using Previous Method Includes Members in Each Groups.




図 4 提案手法

Fig. 4 Heat Map of Rate of that Motion Word Using Previous Method Includes Members in Each Grpuos.

表 3 各手法で生成された動作語によるグループ分け結果の一致度

Table 3 Kappa Coefficient Between Grouping Result by Motion Words Using Previous Method and Proposed Method

|       | 人のグループ分け | データのグループ分け |
|-------|----------|------------|
| カッパ係数 | 0.633    | 0.566      |

## 5.4 実験結果

### 5.4.1 データのグループ分け結果

従来手法と提案手法それぞれで生成された動作語を用いたグループ分けについて、結果がどの程度一致しているかを調べた。まず、各データがグループ中の癖の組をどの程度含んでいるかの割合をヒートマップとして表したものを図 3, 図 4 に示す。図のヒートマップは割合が 0 に近いほど赤く、1 に近いほど白に近くなるものである。従来手法の図 3 からは、どちらのグループに属しているかが明確に分からないデータが多いが、提案手法の図 4 では、従来手法よりも明確にデータがどちらかのグループに属していることが分かる結果が得られた。

さらに、表 3 に各手法での動作語を用いた人のグループ分け、データのグループ分け結果を比較した際のカッパ係数を示す。カッパ係数は  $[-1, 1]$  の値を取り、一致度が高いほど 1 に近くなる値である。表 3 の結果から、各手法の動作語を用いてグループ分けを行なった結果は約 80% 一致していることが分かった。

表 4 従来手法と提案手法の動作語を用いたグループの分類結果

Table 4 Result of Group Classifying; the Classifying Uses Characteristics of Table 2 as Explanatory Values and Grouping Result as Target Values.

|           | 従来手法  |              | 提案手法  |               |
|-----------|-------|--------------|-------|---------------|
|           | J48   | Random Fores | J48   | Random Forest |
| TP rate   | 0.773 | 0.773        | 0.750 | 0.818         |
| FP rate   | 0.278 | 0.278        | 0.293 | 0.194         |
| Precision | 0.773 | 0.773        | 0.748 | 0.818         |
| Recall    | 0.773 | 0.773        | 0.750 | 0.818         |
| F 値       | 0.773 | 0.773        | 0.745 | 0.818         |

### 5.4.2 人の特徴と動き方の関係分析結果

10 分割交差検証の結果の F 値が高いほど人の特徴がデータのグループを説明できているとし、従来手法と提案手法での J48, Random Forest による TP rate, FP rate, Precision, Recall, F 値を表 4 に示す。

表 4 から、提案手法はラジオ体操に専用化された手法により得られた動作語を用いた分析と同等の分類精度を得られていることがわかる。これにより提案手法は、分析を行う上では有用な動作語が生成できていると言える。しかしながら、提案手法で得られた動作語が従来手法により得られた動作語と文字列の意味的に同様のものが得られていることを確かめる必要がある。これについては、動作語の各文字がクラスタ中心としての座標を持っていることから、文字間の距離や類似度が定義できるため、物理的に距離の近い文字列となっているかを確かめることが可能であるが、これは今後の課題とする。

## 6. おわりに

本研究では、ラジオ体操を行なった際の手先に生じる加速度から生成した動作語を用いて人の動き方と人の特徴との関係を分析する手法において、動作語生成の日常行動への応用を考えた汎用化を行なった。提案手法は、時系列の 3 軸加速度データから、ラジオ体操の運動の区切りや音楽の拍を用いることなく動作語を生成することができ、実験では、従来手法と提案手法において、データのグループ分け結果のうち 80% が同一となることが確認でき、さらに提案手法のグループ分け結果が従来手法のグループ分け結果より視覚的により明らかな結果が得られた。また、従来のラジオ体操に専用化された手法による結果と同様の結果を得ることができた。

今後の課題や方針として、動作語に含まれる文字が持つクラスタ中心としての座標を用いて、従来手法によって生成された動作語と提案手法により生成された動作語の間で物理的に近い意味を持っているかの分析が必要である。また、実際に歩行などの日常行動に対して提案手法を用いて動作語生成を行い、人が持つ特徴との関係を調べる必要がある。

## 参考文献

- [1] K. Shima, K. Moriyama, A. Mutoh and N. Inuzuka: Physical and Behavioral Characterization of Human Groups Classified Using Symbolic Pattern Analysis, in *Procedia Computer Science* (proceedings of KES2018), vol. 126, pp. 1206-1215 (2018).
- [2] 植浦総一郎, 岩井儀雄, 谷内田正彦: 準教師有りクラスターリングによる行動素抽出, 情処研報, CVIM-163, No. 36, pp. 29-36 (2008).
- [3] Z. L. Huza, A. M. Wallace, P. R. Green: Human Activity Recognition with Action Primitives, in *Proc. 2007 IEEE Int'l Conf. Advanced Video and Signal-based Surveillance* (AVSS 2007), pp. 330-335 (2007).
- [4] T. B. Moeslund, A. Hilton, V. Kruger and L. Sigal: Learning Action Primitives, in *Visual Analysis of Humans*, Springer, ch. 17, pp. 333-353 (2011).
- [5] 杉本広大, 平嶋崇大, 前川卓也: スマートフォン慣性センサを用いた酩酊状態の歩行検出に関する検討, 情処研報, UBI-44, No. 18, pp. 1-7 (2014).
- [6] 卯田駿介, 馬場哲晃, 串山久美子: スマートフォンを用いたボールリフティングスキル自動評価手法の検討情処研報, MUS-106, No. 15, pp. 1-5 (2015).
- [7] G. Zhu, Q. Huang, C. Xu, L. Xing, W. Gao and H. Yao: Human Behavior Analysis for Highlight Ranking in Broadcast Racket Sports Video, in *2007 IEEE Transactions on Multimedia*, vol. 9, pp. 1167-1182 (2007).
- [8] B. Najafi, K. Aminian, A. P. Ionescu, F. Loew, C. J. Bula and P. Robert: Ambulatory System for Human Motion Analysis Using a Kinematic Sensor: Monitoring of Daily Physical Activity in the Elderly, in *2003 IEEE Transactions on Biomedical Engineering*, vol. 50, pp. 711-723 (2003).
- [9] J. Rasmussen: Skills, Rules, and Knowledge; Signals, Signs, and Symbols, and Other Distinctions in Human Performance Models, in *1983 IEEE Transactions on Systems, Man, and Cybernetics*, vol. 13, pp. 257-266 (1983).
- [10] N. Jaouedi, N. Boujnah, O. Htiwich, M. S. Bouhlel: Human Action Recognition to Human Behavior Analysis, in *Proc. 2017 IEEE Int'l Conf. Science of Electronics, Technologies of Information and Telecommunications* (SETIT 2016), pp. 263-266 (2016).
- [11] E. Watanabe: Analysis of Behaviors by Players in "Old Maid" (in Japanese), in *IPSJ SIG Technical Report, Entertainment Computing* (2015-EC-36), pp. 1-6 (2015).
- [12] 今野慎介, 中村嘉隆, 白石陽, 高橋修: ウェアラブルセンサを用いた歩行動作による本人認証法の検討, 情処研報, UBI-45, No. 25, pp. 1-8 (2015).