

推薦論文

# 行動の順序制約を用いた加速度データのラベリング手法

村尾 和哉<sup>1,a)</sup> 鳥居 康幸<sup>2,†1,b)</sup> 寺田 努<sup>1,3,c)</sup> 塚本 昌彦<sup>1,d)</sup>

受付日 2013年4月10日, 採録日 2013年10月9日

**概要:** 携帯端末に内蔵されたセンサや小型の装着可能なセンサを用いて人の動きを認識する技術を行動認識技術と呼び、ユーザに特化したシステムやサービスを提供する基盤技術となっている。行動認識システムを構築するためには、行動情報が付与（ラベリング）されたセンシングデータを用いて事前に行動モデルを作成しておく必要がある。ラベリングする方法として、一般的にはデータ収集中の行動をビデオカメラなどで撮影してセンサデータと手作業で照合したり、紙とペンですべての行動と時刻をメモに記録してセンシングデータと照合するアプローチがとられている。しかし、ビデオ映像を用いた照合は多大な時間を要し、行動のメモは行動が変化するたびに記録しなければならず自然な動作の妨げになる。本論文では、行動が行われた順序の情報のみを用いてラベリング作業を自動化する手法を提案する。行動順序情報はユーザがデータ収集に行った行動を収集の間や収集後に記録して作成する。含まれる情報は行動の順序のみであり、各行動が行われた時刻は含まず、また行われたすべての行動が記録されているとは限らない。評価結果より、7種類の行動を含む15～30分間自由に行動した5名分のデータに対して、77.2%の精度でラベリングでき、得られたラベル付きデータを用いて認識モデルを構築した際の認識精度は、正しくラベル付けしたデータを用いた際と比較して最小6.7%、平均20%の低下であったことを確認した。

キーワード：行動認識, 加速度センサ, ラベリング, 行動順序

## Labeling Method for Acceleration Data Using an Execution Sequence of Activities

KAZUYA MURAO<sup>1,a)</sup> YASUYUKI TORII<sup>2,†1,b)</sup> TSUTOMU TERADA<sup>1,3,c)</sup>  
MASAHIKO TSUKAMOTO<sup>1,d)</sup>

Received: April 10, 2013, Accepted: October 9, 2013

**Abstract:** In the area of activity recognition, many systems using accelerometers have been proposed. Common method for activity recognition requires raw data labeled with ground truth to learn the model. To obtain ground truth, a wearer records his/her activities during data logging through video camera or hand-written memos. However, referring video takes long time and taking memos would interrupt natural activity. We propose a labeling method for activity recognition using an execution sequence of activities. The execution sequence includes activities in performed order, and does not include time stamps. The execution sequence is assumed to be made based on his/her memory after several activities have been done, therefore some activities may not be included in the execution sequence. The proposed method gave a precision of 0.772 for data including seven kinds of activities captured from five subjects. We also confirmed that recognition accuracy for training data labeled with the proposed method dropped by 6.7% (min.) and 20.0% (ave.) compared to that with ground truth.

**Keywords:** activity recognition, accelerometer, labeling, order of activity

<sup>1</sup> 神戸大学大学院工学研究科  
Graduate School of Engineering, Kobe University, Kobe,  
Hyogo 657-8501, Japan

<sup>2</sup> 神戸大学工学部  
Faculty of Engineering, Kobe University, Kobe, Hyogo 657-  
8501, Japan

<sup>3</sup> 科学技術振興機構さきがけ  
PRESTO, Japan Science and Technology Agency, Kawa-  
guchi, Saitama 332-0012, Japan

<sup>†1</sup> 現在, 航空大学校  
Presently with Civil Aviation College

a) murao@eedept.kobe-u.ac.jp

b) 0704350t@stu.kobe-u.ac.jp

c) tsutomu@eedept.kobe-u.ac.jp

d) tuka@kobe-u.ac.jp

## 1. はじめに

マイクロエレクトロニクス技術の発展によるコンピュータの小型化や軽量化により、コンピュータを常時身につけて生活するウェアラブルコンピューティングに注目が集まっている。ウェアラブルコンピューティングの分野では、加速度センサやジャイロセンサ、筋電計 [14] や心電計 [10], GSR (皮膚電気反射) [8], あるいは自作のデバイス [5] といったさまざまな装着型センサを用いてユーザの状態を認識するシステム (行動認識システム) が提案されている [7], [8], [11]. 例として, LifeMinder [8] は食事や歩行, 仕事などの装着者の日常生活の行動を腕時計型デバイスに内蔵された温度センサ, GSR センサ, 加速度センサ, 光電脈波センサ, 地磁気センサを用いて認識し, 運動不足や過労を警告, 生活習慣の改善などのアドバイスをを行う。位置や動作を検出するセンサとしてカメラや GPS, ジャイロ, 地磁気センサなどがあげられるが, これらのセンサは装着性に難があることや精度の低さ, 動きと静止時の方向が同時に取得不可能といった問題点を持つ。一方, 加速度センサは装着部位の動きを検出可能であり, 静止時でも地球の重力を検出することによりその方向を検出可能であるため使い勝手が良い。また, 精度および分解能が高く, 小型で容易に装着可能である。このように既存センサの中では加速度センサが行動認識システムの構築に適している。

行動認識システムの流れは図 1 に示すように, まず, ユーザが装着しているセンサまたは携帯している機器に搭載されているセンサから加速度などのセンシングデータを取得する。取得したデータはユーザが保持している小型コンピュータやスマートフォンに送られ, 体の向きを表す平均値や運動強度を表す分散値, 運動の周期を表すフーリエ係数などの特徴量に変換される。行動を認識するためには, 収集されたデータの特徴量とそれを説明する行動情報 (ラベル) を用いて SVM や HMM などの分類器のモデルを事前に学習しておく。その後, 認識したい未知のデータを特徴量変換し, 学習したモデルと比較することで行動を認識する。

センシングデータにラベルを付与する方法として, センシングデータ採取中の行動をビデオカメラなどで撮影し, 後から動画とセンシングデータの波形を比較して照合する方法や, 紙とペンあるいはスマートフォンで時刻と行動を

メモに記録する方法などがある。動画を用いる手法では動画とセンシングデータを同時に見ながらラベリングが行えるツール [1] が開発されているが, 基本的に手作業であり, 収集したデータの何倍もの時間を要する。メモを用いる手法では, センシングデータ収集中に記録作業を行うため, データに不要なノイズが含まれる。また, 行動するたびに記録しなければならないという煩わしさもある。センサを装着したユーザとは別に記録者がつねに帯同して記録することも考えられるが, 人手を要し, 被験者を常時監視下に置くため, 研究目的の評価実験で正確な行動情報が必要な場合でない限り現実的ではない。無線接続のセンサやスマートフォン内蔵のセンサの登場によってデータの収集は容易になったが, ラベルを付与する作業 (ラベリング作業) は多くの時間と人手を要するため, 行動認識システム構築の障壁となっている。

これに対し, わずかな量のラベル付きデータを用いて残りの大部分のラベルの付いていないデータをラベリングする手法 [2], [4], [13] が提案されている。しかし, ラベルの量が均等に減らされた環境で評価しており, ラベリングを行う頻度が減っただけで, センシングデータ採取中は行動の記録をしなければならず, 根本的な解決には至っていない。

本論文では, ラベリングの負担を軽減する手法を提案する。提案手法ではラベル付けされていないセンシングデータとユーザが行った行動の順序に関する情報 (行動順序情報) を用いる。この行動順序情報はユーザがセンシングデータ収集の合間の休憩中や収集後に, その時点までに行われた行動の順序を記録して作成することを想定している。含まれる情報は行われた行動の順序のみであり, 各行動の時刻情報は含まず, ユーザが行った行動を忘れていることも容易に考えられるため, すべての行動が含まれるとは限らないと想定する。センシングデータを時系列上でセグメンテーションおよびデータ空間上でクラスタリングし, セグメントにクラスタ番号を割り当て, クラスタ番号の順序と行動順序から最も一致する行動の割当てを探索することで, ラベリングを行う。

以降, 2 章で関連研究をあげ, 3 章で提案手法について述べる。4 章で提案手法の評価を行い, 5 章で本論文をまとめる。

## 2. 関連研究

これまでに提案されている行動認識システムの多くは, すべてにラベルが付与されたデータを用いてシステムの学習を行っている。すべてにラベルが付いたデータで行う学習は教師あり学習 ((Full-)Supervised learning) と呼ばれる。

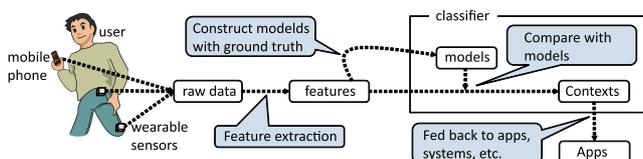


図 1 行動認識システム

Fig. 1 Activity recognition system.

本論文の内容は 2012 年 7 月のマルチメディア, 分散, 協調とモバイル (DICOMO2012) シンポジウム 2012 にて報告され, ユビキタスコンピューティングシステム研究会主査により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である。

これに対して、部分的にしかラベルが付与されていないデータを用いて行う学習は半教師あり学習 (Semi-supervised learning) と呼ばれる。教師あり学習も半教師あり学習も最終的な行動の認識を行う認識器は SVM や HMM など一般的に性能の良いとされているものを使用している。このような認識器は、すべてのデータにラベルが付与されている必要があり、付与されていないデータは一般的に破棄される。そのため、半教師あり学習では、一部のラベル付きデータを用いて残りのラベルがっていないデータのラベリングを行い、すべてのデータにラベルを付与した後、教師あり学習と同じプロセスをとる。ただし、ラベルは推測であるため、必ずしも正しいとは限らない。

本章では、これまでに提案されている半教師あり学習システムを紹介する。文献 [12] は複数の半教師あり学習の手法を行動認識に適用して性能を比較しており、その中でシンプルな手法である Self-training [2] が紹介されている。Self-training は少量のラベル付きデータと大量のラベルなしデータがある場合に、少量のラベル付きデータで認識モデルの構築を行い、そのモデルを用いてラベルなしデータを分類し、分類結果をラベルとして付与する。これによってすべてのデータにラベルが付与され、すべてのデータを用いて認識モデルの再構築を行う。

文献 [13] では、特徴量空間上で類似しているデータや時間空間上で類似しているデータは同じラベルである確率が高いことに着目し、すべてのデータをノード、類似度を枝としたグラフを作成し、特徴量および時間の距離からデータの類似度を計算する。ラベル付きデータと類似度が高いラベルなしデータには同じラベルを与えることでラベルを拡散している。その際には、データを構成する行動の種類の前分布の情報を利用し、拡散するラベルの数が事前分布に従うようにラベリングしている。評価では事前に与えるラベルの間隔を 10 分から 180 分まで変化させてラベリング精度を計測しており、10 分間隔では 90%、180 分間隔では 55% の精度が得られている。10 分間隔は全データ量の 2.5%、180 分間隔は全データ量の 0.1% がラベル付けされていることに相当する。

また、固有空間 (Eigenspace) を利用した研究が提案されている [4]。多次元データの次元数削減手法などに用いられる主成分分析 (PCA) で得られる固有空間は 1 つであるが、Multiple eigenspace algorithm を用いると複数の固有空間を発見でき、加速度などのデータに適用すると各サンプルがどこか 1 つの固有空間に割り当てられる。この固有空間と行動の種類に相関があることに着目し、固有空間のインデックスをデータに付与して SVM を学習し、エラー率から固有空間の統廃合を行う。これに外部から少量のラベル付きデータを与えることで、固有空間のインデックスと行動を関連付けてラベル付けを行う。評価では、ラベル付きデータの割合が 80% の場合に 8 種類の行動の認識率が

88.3% であり、20% で 80.3% となっている。また、ラベル付きデータのみを用いて学習した場合と比較してもこの手法の方が高い性能を示すことが確認されている。

このようにこれまでに多くの半教師あり学習に関する研究が行われており、ラベル付き学習データ量の割合が 20% における精度や、ラベル付けを行った時間間隔が 60 分における精度などを示している。しかし、実際のところ、たとえば、3 時間サンプリングを行い、ラベリング間隔が 10 分で良いとすると 18 回の記録が必要である。特定の行動に偏ってラベル付けをするとラベル付けの頻度が低い行動のラベリング精度が低下するため、3 時間で時間や行動を考えてまんべんなく 18 回も正確な時刻と行動を記録しなければならないことになる。ラベリング間隔が長くてもよいという主張も、その時間間隔でその時刻にラベリングを行わなければならないことを意味しており、システムが決めた時間にラベリングを行わせることはユーザの状態を考慮しておらず現実的ではない。ユーザの行動をインタラプトさせないために、ユーザが記録したいときに記録することも考えられるが、記録できる状況には偏りがあり、行動にまんべんなく記録できるとは考えにくい。また、一連の行動が終わって休憩時にそれまでに行われた行動をラベル付けさせる方法も考えられるが、時刻も正しく思い出しで記録させることは難しい。

本論文では、ユーザが記録した行動情報のうち、ユーザが行った行動の順序情報のみを用いてラベリングを行う。この行動順序情報はユーザが自由な時間に記録することを想定しており、時刻は必要なく、記録に抜けがあっても構わない。

### 3. 提案手法

提案手法は図 2 に示すようにセグメンテーション、クラスタリング、ラベリングの 3 つのフェーズから構成される。セグメンテーションフェーズでは加速度データを時系列上での波形の変化から行動の変化点を発見し、波形を複

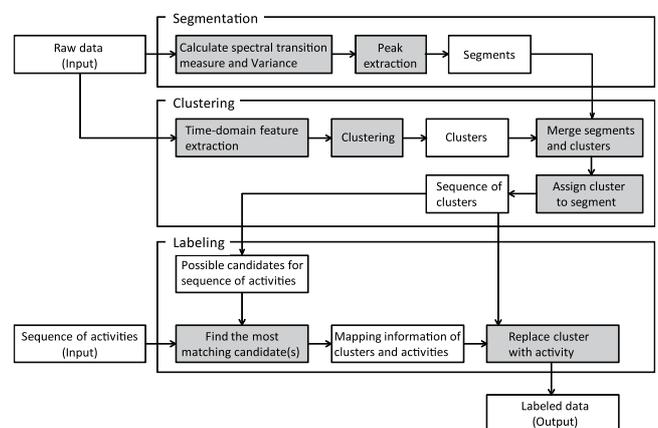


図 2 提案手法の流れ

Fig. 2 Flow of the proposed method.

数のセグメントに分割する。クラスタリングフェーズでは加速度データの特徴量空間上の分布から複数のクラスタに分類する。最後にラベリングフェーズでは得られたセグメンテーション結果とクラスタリング結果を統合して1つのセグメントに1つのクラスタ番号を割り当て、クラスタ番号の時系列変化と与えられた行動順序を比較してクラスタ番号に行動ラベルを割り当てる。可能な割当てパターンは複数通り存在するため、すべてのパターンのうち最も行動順序に合致しているものをラベリング結果として出力する。本章では、各フェーズについて詳しく説明する。

本論文ではユーザは左手首、腰、右足首の3カ所に3軸加速度センサを装着し、7種類の行動（座る、立つ、横になる、歩く、走る、階段を上る、階段を下りる）を含むデータをラベリングする環境を想定する。ユーザは上記7種類の行動から選択してスマートフォンなどで行動情報を記録する。ただし、提案手法では対象とする行動数が既知であればよいため、想定する行動セットにユーザが任意のラベルを追加することも可能である。サンプリング周波数は100 Hzである。

### 3.1 セグメンテーション

セグメンテーションフェーズでは時系列上での行動の変化点を発見し、行動の変化がある部分で加速度波形を分割して複数のセグメントを得ることを目的とする。本論文では、音声認識における音素セグメンテーションの基本的な手法として用いられているスペクトル遷移度のピーク検出による音素セグメンテーション手法を用いる [3], [15]。具体的には、次式に従い加速度データ  $X = (x_1, x_2, \dots, x_T)$  のスペクトル遷移度 (STM: spectral transition measure)  $G_t (t = 1, \dots, T)$  を求める。ただし、 $x_t$  は時刻  $t$  における加速度ベクトルであるが、簡単のためセグメンテーションの説明に用いる加速度データは1次元 (1軸) とする。 $T$  は加速度データのサンプル数である。

$$G_t = \frac{\sum_{i=1}^p a_{i,t}^2}{p} \quad (1)$$

ここで、 $a_{i,t}$  は周波数特徴量の変化率

$$a_{i,t} = \frac{\sum_{n=-M}^M C_{i,t+n} \cdot n}{\sum_{n=-M}^M n^2}, \quad (2)$$

$p$  は周波数特徴量の次元数、 $M$  は周波数特徴量の変化率をみる幅であり、本論文では  $p = 10$ ,  $M = 1$  とした。また、 $C_{i,t}$  は時刻  $t-w$  から  $t$  までの加速度データ  $X' = (x_{t-w}, \dots, x_t)$  から抽出した周波数領域での特徴量 (周波数特徴量) の  $i$  次係数 ( $1 \leq i \leq p$ ) であり、本論文ではケプストラム係数を用いる。ケプストラムとは、異なるスペクトル帯における変化の度合いに関する情報であり、原波形  $\rightarrow$  FFT  $\rightarrow$  abs  $\rightarrow$  log  $\rightarrow$  位相アンラッピング  $\rightarrow$  逆 FFT によって得られた値の実数部分である。ウィンドウサイズ  $w$  の値は運動の1

周期が含まれる大きさ以上である必要があるが、大きすぎると遅延が生じるため、本論文では  $w = 256$  とし、これは2.56秒に相当する。ウィンドウのスライディング幅は1サンプルとした。

加速度波形のスペクトル遷移度  $G_t$  は、同じ行動が継続している間は値が小さく、行動の変化点において高いピークを示す。このピークの頂点において波形を分割する。 $0 < t < T$  において  $(G_t - G_{t-1} > 0)$  かつ  $(G_t - G_{t+1} > 0)$  を満たすすべての波形の頂点  $p_t$  を抽出し、 $p_t > \alpha$  を満たす頂点が現れている時刻  $t$  において波形を分割する。 $\alpha$  の値が大きいと、抽出されるピーク数が少なく、セグメンテーション間隔が大きくなるため、行動の変化点で波形が分割されない場合がある。一方、 $\alpha$  の値が小さいと、抽出されるピーク数が多く、セグメンテーション間隔が小さくなるため、行動が変化していない点でも波形が分割される場合がある。本論文では次節で述べるクラスタリング結果に従って類似したセグメントを統合するアプローチをとるため、セグメンテーションフェーズでは行動の変化点で波形が分割されないことがないように  $\alpha$  の値を設定し、予備実験の結果から  $\alpha = 5$  とした。

しかしながら、スペクトル遷移度は波形が変化し続けている状況での波形の変化点を発見する手法であり、座っている状態から立っている状態のように静止状態から静止状態に変化する場合にはスペクトル遷移度に大きなピークが現れずセグメントに分割できない場合があることを確認した。そこで、静止状態間の行動変化点を発見するために分散の変化を用いる。

$$\mu_t = \frac{\sum_{i=t-w}^t x_i}{w} \quad (3)$$

$$\sigma_t^2 = \frac{\sum_{i=t-w}^t (x_i - \mu_t)^2}{w} \quad (4)$$

ここで、 $\mu_t$  および  $\sigma_t^2$  は時刻  $t$  における加速度データ  $X'$  の平均および分散である。静止時は  $\sigma_t^2$  の値はほぼ0をとり、動きがあると大きな値をとるため、 $((\sigma_{t-1}^2 < 1000)$  かつ  $(\sigma_t^2 \geq 1000))$  または  $((\sigma_{t-1}^2 \geq 1000)$  かつ  $(\sigma_t^2 < 1000))$  となる時刻  $t$  において波形を分割する。分散値の変化だけでは運動中の行動変化は検出できないため、スペクトル遷移度と併用することで、本論文で想定するすべての行動に対して変化点を検出できると考えている。

これまでの説明は1軸の加速度波形で行ったが、実際には1個のセンサは3軸で構成されており、それらを複数個使用する場面が考えられる。加速度データが多次元の場合は、各軸に対して上記の手順で変化点を探し、それらの論理和を全体の変化点としてすべての軸の波形をセグメントに分割する。そのため、セグメントの開始点および長さはすべての軸に対して同一である。

このようにして、加速度波形を時系列上で複数のセグメントに分割することで各加速度データにセグメント番号を

付与し，セグメント番号列  $Segment = (s_1, \dots, s_T)$  を得る．本論文ではセグメントの境界点は若い番号のセグメントに属するものとする．セグメンテーション終了時点では波形が複数の部分波形に分割されただけで，各セグメント内で行われている行動や，セグメント間の類似度などの情報は得られていない．

### 3.2 クラスタリング

クラスタリングフェーズでは加速度データを特徴量空間上でクラスタリングを行う．その後，セグメント内のデータのクラスタ番号の構成から各セグメントに1つのクラスタ番号を割り当て，セグメント番号列をクラスタ番号列に変換する．

本論文では，行動認識で一般的に用いられる特徴量である移動平均値と移動分散値に変換した後，クラスタリング手法の1つである混合正規分布の確率密度推定に基づくクラスタリング手法 (EM クラスタリング) [6] で各データにクラスタ番号を付与した．具体的には，加速度データ  $X = (x_1, x_2, \dots, x_T)$  を特徴量  $F = (f_1, f_2, \dots, f_T)$  に変換する．ただし， $x_t$  は時刻  $t$  における  $d$  次元の加速度ベクトル， $f_t$  は時刻  $t$  における特徴量ベクトルで，各軸から式 (3) および式 (4) に従い平均と分散を抽出しているため次元数は  $2d$  である．特徴量  $f_t$  ( $1 \leq t \leq T$ ) をクラスタリングした結果  $K$  個のクラスタを得る．そして，センサデータごとのクラスタのインデックス番号の系列であるクラスタ番号系列  $c_t \in \{1, \dots, K\}$  ( $1 \leq t \leq T$ ) を得る．EM クラスタリングではデータが  $K$  個の混合正規分布から生成されると仮定し，混合正規分布の平均，分散，混合度を EM アルゴリズムを用いて求め，各データがどの正規分布に属するかを判定することでクラスタリングを行う．まず，クラスタ数  $K = 1$  として 10-fold cross-validation で尤度  $I(K = 1)$  を求める．本論文では尤度としてベイズ情報量基準 (BIC) を用いた．そして， $K$  を1ずつ増加させ， $I(K = i) > I(K = i - 1)$  となった時点で，クラスタ数を  $K = i - 1$  として終了する．クラスタリング手法は EM クラスタリングのほかにも存在するが，提案手法はデータに7種類以外の想定していない行動が含まれる場合にも対応するため，含まれる行動の種類は未知である．そのため，クラスタ数を事前に与えなくてもよく，データの分布も考慮してクラスタリングできる EM クラスタリングを採用した．

特徴量空間におけるクラスタリングは時系列を考慮していないため，時系列上にクラスタ番号をプロットすると波形の凸部分と凹部分が別のクラスタに割り当てられるなどの原因により図 3 に示すように同じ行動を継続している最中でもクラスタ番号が変化する．ただし，図 3 中の Ground truth は真の行動ラベルであり，縦軸の番号は表 1 に示す行動番号と対応する．そこで，セグメント内のデー

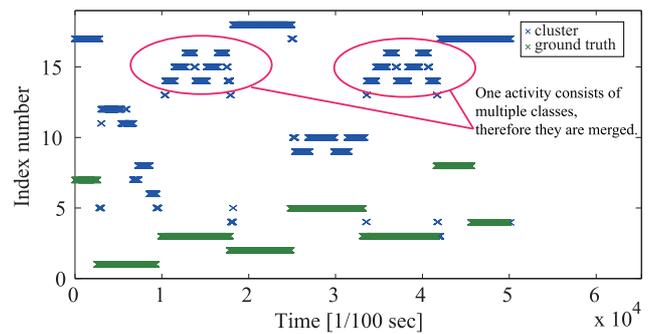


図 3 クラスタの例

Fig. 3 Example of clusters.

表 1 行動番号と行動の対応

Table 1 Activity number and activity.

Index number	Activity
1	Sit
2	Stand
3	Lie
4	Walk
5	Run
6	Upstairs
7	Downstairs

タのクラスタ番号の構成をもとに，同一行動由来と考えられるクラスタを統合し，各セグメントに1つのクラスタ番号を割り当てる．

初めに，1つのセグメント内に複数のクラスタ番号のデータが存在する場合には，両者は同じ行動のデータであると判断しクラスタ番号を統合することを考える．たとえば，図 3 の例では，右から3番目の行動 (行動番号 3) のデータにはクラスタ番号 14, 15, 16 が割り当てられており，同じ行動番号 3 である5番目の行動も同様のクラスタ構成となっている．このような場合に，クラスタ番号 15 と 16 を 14 に再割り当てすることでクラスタを統合する．具体的にはセグメント内のクラスタ番号共起度を単語の共起回数から関連度を求める手法である COSINE [9] を応用した次式に従い算出する．

$$I(x, y) = \frac{\sum_{S=1}^{N_S} \sqrt{f_{S_x} \cdot f_{S_y}}}{\sqrt{f_x \cdot f_y}} \quad (5)$$

ただし， $I(x, y)$  はクラスタ番号  $x$  とクラスタ番号  $y$  の共起度， $f_{S_x}$  はセグメント  $S$  内のクラスタ番号  $x$  のサンプル数， $f_x$  は全体でのクラスタ番号  $x$  のサンプル数， $N_S$  はセグメント数である．同一セグメント内に存在する2個のクラスタの共起度は1に近く，同じセグメントに存在しない2個のクラスタの共起度は0に近い値をとる．この共起度が  $\beta$  を超えるクラスタを統合する．予備実験の結果より  $\beta = 0.4$  とした．クラスタ統合後，各セグメントを構成するデータのクラスタ番号の割合を計算し，最も高い割合を示すクラスタ番号をそのセグメントに割り当てる．最後

に、同じクラスタ番号のセグメントが連続している場合はそれらを1つのセグメントに統合して、セグメントのクラスタ変化列  $SegmentCluster = (SC_1, \dots, SC_{N'_S})$  を得る。ただし、 $N'_S$  は統合後のセグメント数とする。

クラスタリング終了時点ではセグメント単位でのクラスタ番号の時系列変化が得られており、クラスタ番号が同じセグメントでは同じ行動を行っていると考えられるが、それが何の行動かは不明である。次節で説明するラベリングでクラスタ番号と行動の対応付けを行う。

### 3.3 ラベリング

ラベリングフェーズではセグメントのクラスタ変化列とユーザが記録した行動順序からクラスタ番号と行動を対応付けて各データに行動ラベルを付与する。統合後のクラスタ数を  $m$  とし、認識対象とする行動数を  $n$  とすると、対応付けの組合せは以下の通りである。ただし、 $n$  は事前に想定している行動の数であり、本論文では7種類の行動セットを想定しているため  $n = 7$  である。

$$\begin{aligned} & {}_n P_m && (m \leq n) \\ & {}_m P_m / {}_{m-n} P_{m-n} && (m > n) \end{aligned} \quad (6)$$

クラスタ数が認識対象とする行動数以下の場合、 $n$  個の行動から  $m$  個を選ぶ順列となる。一方、クラスタ数が認識対象とする行動数より多い場合、余分な  $m - n$  個のクラスタには行動不明ラベルを付与する。 $n$  種類の行動と  $m - n$  種類の行動不明ラベルの順列は  ${}_m P_m$  となるが、行動不明ラベルどうしは区別しないため  $m - n$  個のラベルの順列  ${}_{m-n} P_{m-n}$  で除している。行動不明ラベルを採用する理由は、クラスタ数が行動数より多い原因として、1つの行動が複数のクラスタに割り当てられる場合と、想定していない行動が含まれて、それにクラスタが割り当てられる場合があげられるが、事前にそれらを判別できない。そのため本論文では、行動ラベルの重複を許して無理にラベル付けを行うよりも、行動不明ラベルを付与してラベリングを行わないアプローチをとっている。

式 (6) から得られる各組合せの行動順序の候補 (予測行動順序候補)  $PredictedSequence = (PS_1, \dots, PS_i, \dots, PS_{N'_S})$  を、ユーザが記録した行動順序 (記録行動順序)  $RecordedSequence = (RS_1, \dots, RS_j, \dots, RS_{N_R})$  との距離から評価する。 $N_R$  は記録行動順序の長さである。距離の計算には以下に示す文字列比較手法の1つであるDP (動的計画法: Dynamic programming) マッチングを用いる。 $N'_S \times N_R$  行列  $d_{ij}$  は不一致時のペナルティであり、 $PS_i = RS_j$  であれば  $d_{ij} = 0$ ,  $PS_i \neq RS_j$  であれば  $d_{ij} = 1$  とする。

#### (1) Initialization:

$$\begin{aligned} Cost(0, 0) &= 0 \\ Cost(i, 0) &= \infty \text{ for } i = 1, \dots, N'_S \end{aligned}$$

$$Cost(0, j) = \infty \text{ for } j = 1, \dots, N_R$$

#### (2) Cost calculation:

Do for  $i = 1, 2, \dots, N'_S$   
Do for  $j = 1, 2, \dots, N_R$

$$Cost(i, j) = \min \begin{cases} Cost(i-1, j-1) + d_{ij} \\ Cost(i-1, j) + d_{i,j} * 2 \\ Cost(i, j-1) + d_{ij}/2 \end{cases} \quad (7)$$

#### (3) Output:

Return  $Cost(N'_S, N_R)$

ここで、式 (7) の  $Cost(i, j)$  の計算においてペナルティ  $d_{ij}$  の係数が異なることについて述べる。真の行動変化数を  $N$  とすると、提案手法は真の行動変化点では波形を分割するようにパラメータ調整を行っているため  $N'_S > N$  となる可能性が高い。一方、行動順序は実際に行われた行動のうち記憶していたものであり、誤って余計な行動を記録することも考えられるが、意識せずに見逃す事象の方が多いと考えられるため  $N_R < N$  となる可能性が高く、予測行動順序候補が成長する経路は必然的に発生するためペナルティを半分としている。同様に、正解行動順序のみが成長する経路はユーザのつけた記録を無視する経路であるためペナルティを2倍としている。ただし、ユーザのつけた記録が誤っており、その記録を無視した方が全体として都合が良い場合は、ユーザの記録を無視する予測行動順序候補が選択される。

出力された  $Cost(N'_S, N_R)$  が予測行動順序候補の距離であり、小さいほど正解行動順序と近いことを意味する。すべての予測行動順序候補のうち距離が最小となる割当てに従って、入力データの各セグメント入力に属するデータにラベリングを行う。採取したデータが短い場合やユーザが記録した正解行動順序に抜けがある場合は、距離が最小となる割当てが複数存在する。この点に関しては次章の評価実験において言及する。

最後に、行動情報が誤りを含む場合について述べる。ユーザが「A → B」という行動変化を「A → C」と誤って記録したり、「A → C → B」と行っていない行動を挿入して記録すると、誤った予測行動順序候補の距離が小さくなって、最終的に選出されやすくなり、ラベリング精度が低下する。しかし、特定の行動を何度も同様に誤って記録することは起こりにくく、データ収集量を増やせば他の部分で出現する行動が正しく記録されて相対的に誤りの割合が低下するため、ユーザの行動記録の誤っている箇所を無視する行動割当てが選出される。また、提案手法は微小な変化も検出することで真の行動変化点では波形を分割するように設計しているが、セグメンテーションの誤りによって本来2つの行動であるにもかかわらず1つのセグメントとして検出された場合はそのセグメントには1種類の行動ラベルしか割り当てられないため、片方の行動のラベリング精度は低下

表 2 評価用データ

Table 2 Data for evaluation.

Subject	# activity	Duration [sec]	Ground truth
A	19	875	Stand→Walk→Sit→Stand→Walk→Undefined (put on shoes)→Walk→Stand→Up→Stand→Down→Up→Stand→Run→Stand→Lie→Sit→Walk→Sit
B	60	1,695	Stand→Walk→Stand→Walk Undefined(put on shoes)→Walk→Stand→Walk→Up→Stand→Down→Run→Stand→Down→Sit→Down→Walk→Run→Stand→Walk→Up→Walk→Stand→Walk→Up→Down→Sit→Up→Walk→Stand→Up→Walk→Run→Up→Walk→Stand→Walk→Up→Down→Sit→Walk→Run→Down→Undefined→Walk→Up→Sit→Up→Walk→Up→Walk→Undefined→Sit→Lie→Undefined→Stand→Walk→Sit
C	16	885	Stand→Walk→Down→Walk→Up→Stand→Walk→Run→Undefined→Run→Walk→Up→Sit→Walk→Lie→Sit
D	55	1,531	Walk→Down→Walk→Stand→Walk→Stand→Walk→Stand→Walk→Run→Walk→Run→Up→Walk→Sit→Lie→Walk→Sit→Walk→Down→Walk→Run→Walk→Up→Walk→Stand→Walk→Down→Walk→Run→Sit→Lie→Sit→Walk→Up→Stand→Down→Walk→Up→Walk→Sit→Lie→Sit→Walk→Down→Walk→Down→Walk→Up→Walk→Sit→Walk→Sit→Walk→Stand
E	30	852	Walk→Undefined (put on shoes)→Walk→Down→Walk→Stand→Walk→Down→Walk→Run→Sit→Walk→Up→Walk→Lie→Walk→Up→Walk→Stand→Walk→Up→Walk→Stand→Up→Walk→Undefined (put off shoes)→Walk→Sit→Lie→Walk

すると考えられる。

#### 4. 評価

本章では提案手法のラベリング性能の評価を行う。

##### 4.1 評価環境

評価では左手首、腰、右足首の3カ所に3軸無線加速度センサ（ワイヤレステクノロジー社製 WAA-010）、背部にデータ収集用タブレット（マウスコンピュータ社製 Lu-vPad WN701）、頭部に正解行動記録用ウェアラブルカメラ（SONY 社製 HDR-AS15）を装着した5名の被験者から7種類の行動（座る、立つ、横になる、歩く、走る、階段を上る、階段を下りる）のデータを採取した。加速度データのサンプリング周波数は100Hzである。

具体的なデータ収集方法を説明する。実験主催者は被験者に対して、行動のデータを収集する実験であり、前述の7種類の行動をしてもらうように伝えている。ただし、行動の順序や継続時間は自由であり、同じ行動を何回行っても構わないが、いずれの行動も最低1回は行うとする。終了のタイミングも被験者に任せており、7種類の行動のデータが集まったと思う時点で自由に終了してよい。データ採取中は実験主催者は帯同せず、被験者に装着したウェアラブルカメラで実験の様子を撮影している。

行動の記録は、筆者らが作成したAndroidアプリを用いて行った。アプリには7種類の行動および[Delete]、[OK]、[Finish]が書かれたボタンが配置されており、被験者は現時点までに行った行動を順番に入力する。入力を間違えた場合は[Delete]ボタンで削除できる。入力後に[OK]ボタ

ンを押すと、その時点の時刻と行動順序が保存される。被験者にはこの作業を、被験者の任意のタイミングで行ってもらうように指示した。すべての入力が終わると[Finish]ボタンを押すことで、一連の行動順序を実験主催者にメール送信される。

データ収集終了後、実験主催者は被験者から加速度データおよびウェアラブルカメラの動画を回収し、ウェアラブルカメラの映像をもとに手作業で加速度データに正解の行動情報を付与する。被験者は自由に行動しているため、7種類以外の行動も含まれており、それらの行動は行動番号-1として「その他」ラベルを付与した。

採取したデータを表2に示す。Ground truthは正解の行動である。表中の行動数は行われた行動の延べ回数である。継続時間はセンシングを開始してから、最後の行動の記録を終了してアプリの[Finish]ボタンを押した時刻までの時間である。スタート地点は筆者らの研究室であり、建物の7階に位置している。被験者は研究室室内を移動したり、建物内の廊下や階段通って建物外に出て、屋外を移動した。

また、被験者の行動記録を表3に示す。時刻は記録時に[OK]ボタンを押した時刻、行動列は入力した行動順序である。たとえば、被験者Aの1行目では開始379秒の時点で、それまでの行動としてSit→Stand→Walkを入力したことを意味している。ただし、記録された時刻の情報は本論文の評価では用いていない。表2の正解行動と表3の行動記録を比較すると、行動記録には抜けがあることが分かる。これは、歩くや立つといった頻出する行動や継続時間が数秒程度の行動は被験者がそれらの行動をしたとい

表 3 被験者が記録した行動順序

Table 3 Sequence of activity that subjects recorded.

Subject	Time [sec]	Sequence of activities
A	379	Sit→Stand→Walk
	562	Up→Stand→Down→Up→Stand
	875	Run→Lie→Sit→Walk→Sit
	126	Walk→Stand→Walk→Stand
	180	Walk→Up→Stand
B	279	Down→Run→Stand
	368	Down→Sit
	481	Down→Walk→Run
	662	Walk→Up→Walk→Stand
	763	Walk→Up→Down→Sit
	917	Up→Walk→Stand
	1,037	Up→Run→Up→Walk→Stand
	1,197	Walk→Up→Down→Sit
	1,308	Walk→Run→Down→Sit→Lie
	1,591	Walk→Up→Sit→Up→Walk →Up→Walk→Sit
1,695	Lie→Stand→Walk→Sit	
C	259	Stand→Walk→Down
	494	Walk→Run
	696	Walk→Up→Sit
	885	Walk→Lie
	142	Walk→Down→Walk→Stand
D	369	Walk→Run→Up→Sit→Walk→Lie
	509	Walk→Sit→Walk→Down→Walk
	735	Run→Walk→Up→Walk→Stand →Walk→Down
	980	Walk→Run→Sit→Lie→Sit
	1,167	Walk→Up→Walk→Stand→Walk →Down→Walk
E	1,313	Walk→Up→Walk→Sit→Lie→Sit
	1,423	Walk→Down→Walk→Down →Walk→Up
	1,531	Walk→Stand→Walk→Stand →Walk→Stand
	333	Walk→Down→Walk→Stand →Walk→Down→Walk→Run→Sit
	706	Walk→Up→Walk→Lie→Walk →Run→Walk→Up→Walk→Stand
852	Up→Walk→Sit→Lie→Walk→Sit	

う意識がなく、記録されなかったためと考えられる。

## 4.2 結果と考察

### 4.2.1 クラスタリングとセグメンテーションの評価

被験者 A のデータに対して提案手法を適用した際の加速度波形、スペクトル遷移度、分散値、セグメンテーションとクラスタリングの結果、統合後のセグメントとクラスタリングの結果を図 4 に示す。加速度波形 (図 4(a)) から得られたスペクトル遷移度 (図 4(b)) が行動の変化点でピークを示していることが分かる。得られたスペクトル

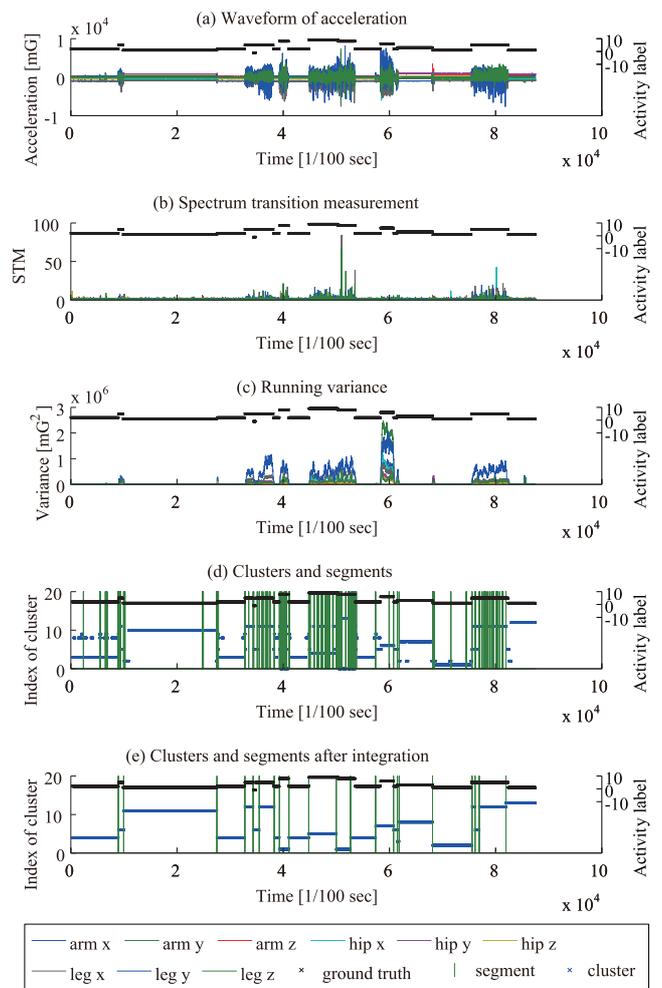


図 4 提案手法の処理において得られる波形

Fig. 4 Waveforms obtained through the proposed method.

遷移度および分散値 (図 4(c)) の変化に基づいてセグメントに分割した結果と特徴量空間でクラスタリングした結果を図 4(d) に示す。この段階では細かいセグメントに分割され、同一セグメント内に複数のクラスタのデータが存在しているが、提案する統合手法によって図 4(e) に示すように、行動の変化点に対応するようにセグメントが統合され、セグメントに 1 つのクラスタ番号を割り当てている。各図に示す正解の行動と比較すると、クラスタ番号の変化のタイミングと正解行動の変化のタイミングがおおよそ一致していることが分かる。

各被験者のデータに対するセグメンテーションおよびクラスタリングの結果の詳細を表 4 に示す。スペクトル遷移度および分散値に基づくセグメンテーションによって各被験者の加速度データはそれぞれ 51 個, 173 個, 71 個, 173 個, 86 個のセグメントに分割されており、実際の行動数よりも多いことが分かる。これは、スペクトル遷移度は波形のスペクトルが時間変化する点でピークを示すため、立っている間に足を動かしたり、歩行中に足が地面に引っかかりたりするとその点が検出されてしまうためである。また、クラスタ数を見ると、14 個, 18 個, 26 個, 20 個, 26

表 4 セグメンテーションおよびクラスタリング結果  
Table 4 Results for segmentation and clustering.

Subject	# segment	# cluster	# segment after integration	# cluster after integration	Sequence of cluster
A	51	14	22	11	[4 6 11 4 12 6 12 4 1 4 5 1 4 7 6 3 8 2 12 6 12 13]
B	173	18	73	12	[1 5 1 5 7 5 7 5 1 7 3 7 1 6 9 1 6 7 5 8 5 6 7 3 9 1 5 9 7 3 9 3 1 5 1 7 6 2 5 2 7 1 5 7 9 7 3 7 6 5 2 5 9 4 6 5 16 3 7 5 7 3 7 3 7 3 5 12 5 14 5 7 2]
C	71	26	16	10	[7 5 2 5 15 5 25 21 4 5 3 15 1 5 15 8]
D	173	20	64	13	[2 3 2 8 2 3 2 8 2 4 20 8 20 2 8 7 13 7 8 2 7 2 8 2 4 19 8 1 11 1 20 1 3 1 8 1 11 8 11 18 7 6 7 8 1 8 15 8 3 8 1 7 6 7 1 8 1 8 1 15 1 3 8 3]
E	86	26	39	14	[12 16 1 7 1 14 1 7 16 1 16 11 8 18 2 16 17 16 6 3 16 22 18 14 16 17 16 1 16 12 14 15 17 16 1 3 14 3 1]

個のクラスタに分割されている。これは定義されていない行動を行ったデータがクラスタを確保したり、同じ行動でも足の角度や振舞いの変化で異なるクラスタに割り当てられたためと考えられる。クラスタリングは教師なしでデータの分布からのみ分割するか否かを判断するため、同じ行動でもデータが空間的に離れていることが原因で異なるクラスタに割り当てられる。1つの継続している行動が複数のクラスタに分割される場合は、セグメント内のクラスタ番号の共起度からクラスタ番号を統合することで、セグメント数を22個、73個、16個、64個、39個と実際の行動数に近い数で分割するようになっている。また、クラスタ数は11個、12個、10個、13個、14個となり、行動の種類に近い値になっている。最終的な統合後セグメントに割り当てられたクラスタ番号の変化を見ると、被験者Aではクラスタ番号4が4個あるが、これはそれぞれのセグメントでは同じ行動が行われていると考えられる。

4.2.2 ラベリング精度

表5に提案手法によるラベリングのPrecisionとRecallを示す。正解行動順序と予測行動順序候補の比較から得られる、ラベルの割当てパターン数は被験者A, B, C, D, Eでそれぞれ3個、1個、3個、1個、3個であった。候補が複数の場合は、データにラベルが付与された割合が最も大きい候補を選択する。これは入力データのうち定義されていない行動の量は比較的少ないためである。PrecisionとRecallは次式に従い求める。

$$Precision(i) = \frac{\# \text{ true positive labeled with } i}{\# \text{ samples labeled with } i} \quad (8)$$

$$Recall(i) = \frac{\# \text{ true positive labeled with } i}{\# \text{ samples of activity } i} \quad (9)$$

Precisionは付与した1個のラベルが正しい割合を、Recallは1個の入力データが正しくラベル付けされる割合を示す。ラベリング精度は与えたラベルが正解している割合で評価する必要があるため、本節ではPrecisionで議論する。

結果より、被験者A, C, Dの平均ラベリング精度 (Pre-

表 5 ラベリング精度

Table 5 Labeling accuracy.

	Subject A (96.3% labeled)		Subject B (94.1% labeled)		Subject C (86.3% labeled)	
	Precision	Recall	Precision	Recall	Precision	Recall
Sit	0.923	0.171	0.588	0.735	0.477	0.481
Stand	0.963	0.921	0.950	0.784	0.994	0.883
Lie	0.211	0.995	0.851	0.785	0.0696	0.0193
Walk	0.982	0.763	0.892	0.572	0.953	0.854
Run	0.723	0.997	0.770	0.736	0.935	0.777
Up	0.913	0.828	0.640	0.901	1.00	0.900
Down	0.987	0.941	0.994	0.912	0.928	0.939
Ave.	0.815	0.802	0.812	0.775	0.768	0.693

	Subject D (63.4% labeled)		Subject E (94.8% labeled)		Overall (87.0% labeled)	
	Precision	Recall	Precision	Recall	Precision	Recall
Sit	0.770	0.776	1.00	0.584	0.752	0.549
Stand	0.541	0.977	0.734	0.516	0.836	0.816
Lie	1.00	0.487	0.406	0.444	0.508	0.546
Walk	0.678	0.407	0.934	0.532	0.888	0.626
Run	0.881	0.327	0.466	0.0770	0.759	0.583
Up	0.914	0.284	0.942	0.594	0.882	0.701
Down	0.00720	0.0311	0.986	0.933	0.780	0.751
Ave.	0.684	0.470	0.781	0.526	0.772	0.653

cision)は0.815, 0.768, 0.684であるが、被験者AのLie, 被験者CのSit, Lie, 被験者DのDownが低くなっている。これは被験者AとCが収集したデータは表2に示すように、比較的短く、1種類の行動が2回程度しか実行されていないためであると考えられる。提案手法の性質上、セグメンテーションやクラスタリングのミスは起こりうるため、分割されるべき行動が同じセグメントに入っていたり、1つの行動が2つのセグメントに分かれたり、同じ行動をしているセグメントが別のクラスタだったりすることが発生する。実施される行動の回数が少ないと、予測行動順序候補と正解行動順序の距離計算において、ミスの影

響が相対的に大きくなり、誤った答えが誘導されやすくなる。また、被験者 D は 3 段程度の階段を複数回通過しており、通過時間は 2 秒程度と短いため特徴量として表れにくく、その前後の Walk と連結して正しくセグメンテーションおよびクラスタリングが行えなかった。しかし、被験者 D はその階段の通過を Down として記録したため、Walk が Down としてラベリングされ、Precision が大幅に低下した。

一方、被験者 B の平均ラベリング精度 (Precision) は 0.812 であり、Sit と Up が若干低いが、被験者 A, C, D と比較してもすべての行動において高い精度 (Precision) を示している。これは被験者 B が採取したデータが被験者 A, C の約 2 倍あり、セグメンテーションやクラスタリングのミスがあったとしても行動数が多いため、その影響は小さくなる。つまり、長い行動列においてユーザのつけた行動順序につつまが合うようにセグメンテーションやクラスタリングのミスが起こりうる確率は低くなるためであるといえる。たとえば 2 回発生した Walk のうち 1 回に検出ミスが起こることは考えられる。4 倍の長さのデータに対してもミスの発生率は変わらないとすると 4 回ミスが発生することになるが、Walk が 8 回行われて、発生した 4 回のミスがすべて Walk に対するものであることは起こりにくい。被験者 E は波形が安定しており、行動記録も Ground truth とほぼ同じであったため高い精度 (Precision) を示したと考えられる。

この結果から、行った行動数が多く、極端に短い行動を含まなければ高いラベリング精度 (Precision) が得られ、平均で全体の 87.0% のデータに対して 77.2% の精度 (Precision) でラベリングできることが分かった。

また、ユーザの行動記録には行った行動が記録されない「削除」、行っていない行動を記録する「追加」、行った行動の種類を誤って記録する「置換」の 3 種類の記録ミスが考えられる。そこでこれらの記録ミスがラベリング精度に与える影響を調査するために、Ground truth から抽出した行動記録に対して、行動記録数の 0%, 10%, 20%, 30% が削除、追加、置換された行動記録を用いてラベリング精度 (Precision) を評価した。5 名の各被験者のラベリング精度 (Precision) の平均値を図 5 に示す。削除、追加、置換の位置、追加した行動、および置換後の行動は無作為に決定した。結果より、記録ミスの量が増加するに従いラベリング精度 (Precision) が低下している。また、誤りの種類に着目すると「減少」は「増加」および「置換」と比較して精度 (Precision) の低下は緩やかであり、これは本論文がユーザの記録は実際よりも少ないという想定に基づいてシステム設計されており、記録の減少に対して耐性があることを示している。記録ミスが 30% では行動情報が無作為に記録したものに近くなり、誤りの種類によらず結果が収束している。

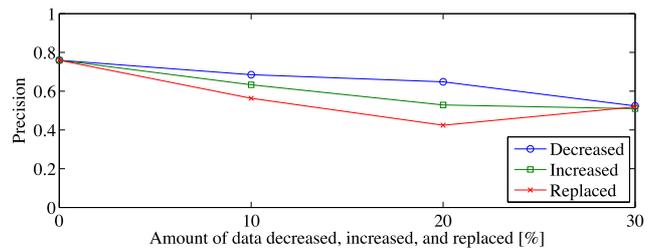


図 5 ユーザの行動記録に誤りが含まれる場合のラベリング精度 (Precision)

Fig. 5 Labeling accuracy (precision) for activity sequence including errors.

結果的にラベリング作業に要するユーザの負担について既存手法と比較する。文献 [13] では提案手法と同程度のラベリング精度を得るには約 10 分に 1 回の行動記録が必要である。これに対して提案手法では採取した行動記録から約 3 分に 1 回であり、この値は 1 つの行動の継続時間に依存するため単純に比較できないが、記録の頻度では既存手法に比べてやや劣る。しかしながら、既存手法では走ったり階段を下っている最中も含めてすべての行動にまんべんなく記録しなければならない。対して、提案手法は行った行動をユーザの好きなタイミングでまとめて記録できるため、既存手法よりもユーザへの負担は小さいと考える。

#### 4.2.3 認識精度

最後に、提案手法によってラベル付けされたデータを用いて認識モデルを構築して行動を認識した結果を示す。比較手法として、最大でどの程度の性能が得られるかのベースラインを示すために、データ収集中のビデオ映像をもとに手作業で付与した正解の行動でラベル付けした場合でも評価した。評価では、4.1 節で採取したデータを用いて各被験者ごとに 5-fold cross-validation で認識精度を評価した。認識アルゴリズムにはサポートベクタマシンを用いた。提案手法の評価では学習データとして提案手法でラベリングしたデータのみを使用し、行動不明ラベルのデータは除いている。比較手法の評価では学習データとして Ground truth でラベリングしたデータのみを使用し、想定されていない行動のデータは除いている。比較手法および提案手法の認識精度 (F 値) を表 6 および表 7 にそれぞれ示す。結果より、比較手法では正しい情報でラベル付けされているため、高い性能を示していることが分かる。一方、提案手法では被験者 A および C の Sit と Lie が低い精度を示しているが、ラベリング時に Sit が Lie とラベリングされており、これはラベリング精度の結果と一致している。また、被験者 D の Down も低い精度を示しているが、これもラベリング精度の結果と一致している。被験者 B および E はすべての行動において高い精度を示しており、この 2 人の平均認識精度 (F 値) は 0.828、5 人の平均認識精度 (F 値) は 0.738 となり、正解の行動をラベルとして用いた場合と比較してそれぞれ 0.109 ポイント、0.200 ポイントの

表 6 正しい行動情報でラベル付けした教師データを用いた際の認識精度 (F 値)

Table 6 Recognition accuracy (F-measure) for training data labeled with ground truth.

	Subject					Overall
	A	B	C	D	E	
Sit	0.992	0.979	0.993	0.956	0.979	0.980
Stand	0.980	0.956	0.956	0.889	0.978	0.952
Lie	0.991	0.981	0.996	0.995	0.993	0.991
Walk	0.926	0.893	0.911	0.941	0.894	0.913
Run	0.985	0.955	0.983	0.958	0.856	0.947
Up	0.908	0.896	0.929	0.859	0.958	0.910
Down	0.912	0.889	0.917	0.729	0.907	0.871
Ave.	0.956	0.936	0.955	0.904	0.938	0.938

表 7 提案手法でラベル付けした教師データを用いた際の認識精度 (F 値)

Table 7 Recognition accuracy (F-measure) for training data labeled with the proposed method.

	Subject					Overall
	A	B	C	D	E	
Sit	0.287	0.901	0.477	0.788	0.735	0.638
Stand	0.946	0.943	0.931	0.695	0.943	0.892
Lie	0.346	0.893	0.00889	0.662	0.686	0.519
Walk	0.882	0.749	0.922	0.485	0.885	0.785
Run	0.769	0.937	0.981	0.957	0.593	0.847
Up	0.897	0.755	0.925	0.429	0.713	0.744
Down	0.899	0.902	0.934	0.0196	0.955	0.742
Ave.	0.718	0.869	0.740	0.577	0.787	0.738

低下であった。

## 5. まとめ

本論文ではユーザが行った行動の順序に関する情報を用いて自動的に加速度データのラベリングを行う手法を提案した。評価結果より、7種類の行動を含む15~30分の自由な行動のデータに対して、入力データの87.0%にラベルを付与し、ラベルの正解率 (Precision) は77.2%であった。また、提案手法でラベル付けしたデータを教師データとして認識モデルを学習した場合の認識精度のF値は0.738であった。結果の良かった2名に被験者に着目すると認識精度のF値は0.828であった。実際に実験中の映像をもとにラベル付したデータを用いた場合のF値は0.938であり、この結果と比較しても提案手法を用いた場合、得られたラベルは真のラベルと比較して認識精度 (F 値) の低下は約0.1であったことを確認した。行動順序情報は時刻情報を含んでいないため、ある時点においてそれまでの行動の一部を記録するだけでよく、従来のデータ採取中に行動情報を記録する手法と比較しても収集が容易である。また、ユーザが行動認識を意識せずに記録したTwitterやFacebookなどのソーシャルメディアなどから行動を自動

的に抽出する手法が提案されており [15]、今後はそのような手法と統合して、データのラベリングだけでなく一日の行動分布や時間ごとの行動を可視化するシステムを構築する予定である。

謝辞 本研究の一部は、科学研究費補助金基盤 (A) (23240014)、基盤 (A) (23240010) および若手 (B) (24700066) の支援によるものである。また、本研究は一部、独立行政法人情報通信研究機構 (NICT) の委託研究「情報通信・エネルギー統合技術の研究開発」によるものである。ここに記して謝意を表す。

## 参考文献

- [1] ATR-Promotions: SyncPlay, available from <http://www.atr-p.com/SyncPlay.html>.
- [2] Chapelle, O., Schölkopf, B. and Zien, A.: *Semi-Supervised Learning*, *Adaptive computation and machine learning*, MIT Press (2006).
- [3] Dusan, S. and Rabiner, L.R.: On the Relation between Maximum Spectral Transition Positions and Phone Boundaries, *9th International Conference on Spoken Language Processing (INTERSPEECH 2006 - IC-SLP)*, pp.645-648 (2006).
- [4] Huynh, T. and Schiele, B.: Towards Less Supervision in Activity Recognition from Wearable Sensors, *Tenth International Symposium on Wearable Computers (ISWC 2006)*, pp.3-10 (2006).
- [5] Laerhoven, K.V. and Gellersen, H.W.: Spine versus Porcupine: A Study in Distributed Wearable Activity Recognition, *International Symposium on Wearable Computers (ISWC 2004)*, pp.142-149 (2004).
- [6] McLachlan, G.J. and Krishnan, T.: *The EM Algorithm and Extensions*, *John Wiley and Sons* (1997).
- [7] Naya, F., Ohmura, R., Takayanagi, F., Noma, H. and Kogure, K.: Workers' Routine Activity Recognition using Body Movement and Location Information, *International Symposium on Wearable Computers (ISWC 2006)*, pp.105-108 (2006).
- [8] Ouchi, K., Suzuki, T. and Doi, M.: LifeMinder: A wearable Healthcare Support System Using User's Context, *International Workshop on Smart Appliances and Wearable Computing (IWSAWC 2002)*, pp.791-792 (2002).
- [9] Peat, H.J. and Willett, P.: The Limitations of Term Co-Occurrence Data for Query Expansion in Document Retrieval Systems, *Journal of the American Society for Information Science*, Vol.42, No.5, pp.378-383 (1991).
- [10] Shen, C.L., Kao, T., Huang, C.T. and Lee, J.H.: Wearable Band Using a Fabric-Based Sensor for Exercise ECG Monitoring, *International Symposium on Wearable Computers (ISWC 2006)*, pp.143-144 (2006).
- [11] Stiefmeier, T., Ogris, G., Junker, H., Lukowicz, P. and Tröster, G.: Combining Motion Sensors and Ultrasonic Hands Tracking for Continuous Activity Recognition in a Maintenance Scenario, *International Symposium on Wearable Computers (ISWC 2006)*, pp.97-104 (2006).
- [12] Stikic, M., Laerhoven, K.V. and Schiele, B.: Exploring Semi-Supervised and Active Learning for Activity Recognition, *International Symposium on Wearable Computers (ISWC 2008)*, pp.81-88 (2008).
- [13] Stikic, M., Larlus, D. and Schiele, B.: Multi-Graph Based Semi-Supervised Learning for Activity Recogni-

tion, *International Symposium on Wearable Computers (ISWC 2009)* (2009).

- [14] Toda, M., Akita, J., Sakurazawa, S., Yanagihara, K., Kunita, M. and Iwata, K.: Wearable Biomedical Monitoring System Using TextileNet, *International Symposium on Wearable Computers (ISWC 2006)*, pp.119-120 (2006).
- [15] 大村 廉, 橋田尚幸, 今井倫太: 加速度データ自動セグメンテーションに基づく行動認識手法の性能評価, 情報処理学会研究報告 (ユビキタスコンピューティングシステム研究会 2010-UBI-27), No.11, pp.1-7 (2010).

### 推薦文

加速度センサを用いた行動認識に関する研究は多く行われており, 本研究はその際に問題となる加速度データに対するラベリング作業を効率化する方式を提案している.

(ユビキタスコンピューティングシステム研究会主査 椎尾一郎)



村尾 和哉 (正会員)

2006年大阪大学工学部電子情報エネルギー工学科卒業. 2008年同大学院情報科学研究科博士前期課程修了. 2008年独国ダルムシュタット工科大学訪問研究員. 2009年より独立行政法人日本学術振興会特別研究員DC2.

2010年大阪大学大学院情報科学研究科博士後期課程修了. 同年より独立行政法人日本学術振興会特別研究員PD. 2011年より神戸大学大学院工学研究科学術推進研究員. 2011年神戸大学大学院工学研究科助教. 現在に至る. 博士(情報科学). ウェアラブルコンピューティング, ユビキタスコンピューティングの研究に従事. IEEE等, 3学会の会員.



鳥居 康幸

2012年神戸大学工学部電気電子工学科卒業. 同年住友化学(株)入社. 同年独立行政法人航空大学校入学. 現在に至る. 在学中, 行動認識技術に興味を持つ.



寺田 努 (正会員)

1997年大阪大学工学部情報システム工学科卒業. 1999年同大学院工学研究科博士前期課程修了. 2000年同大学院工学研究科博士後期課程退学. 同年より大阪大学サイバーメディアセンター助手. 2005年より同講師.

2007年神戸大学大学院工学研究科准教授. 現在に至る. 2004年より特定非営利活動法人ウェアラブルコンピュータ研究開発機構理事, 2005年には同機構事務局長を兼務. 2004年には英国ランカスター大学客員研究員, 2010年より科学技術振興機構さきがけ研究員を兼務. 博士(工学). ウェアラブルコンピューティング, ユビキタスコンピューティングの研究に従事. IEEE, 電子情報通信学会等, 5学会の会員.



塚本 昌彦 (正会員)

1987年京都大学工学部数理工学科卒業. 1989年同大学院工学研究科修士課程修了. 同年シャープ(株)入社. 1995年大阪大学大学院工学研究科情報システム工学専攻講師, 1996年同専攻助教授, 2002年同大学院情報科学研究科マルチメディア工学専攻助教授, 2004年神戸大学電気電子工学科教授となり, 現在に至る. 2004年より特定非営利活動法人ウェアラブルコンピュータ研究開発機構理事長を兼務. 工学博士. ウェアラブルコンピューティングとユビキタスコンピューティングの研究に従事. ACM, IEEE等, 8学会の会員.