

# ラベルの時刻ずれに対応した携帯センサ行動認識手法

戸田隆道<sup>2,a)</sup> 田中翔太<sup>2</sup> 井上創造<sup>2,b)</sup> 上田修功<sup>3</sup>

**概要：**スマートフォン等の携帯センサデバイスを用いた行動認識を行う際には、主に教師あり学習を用いるため、センサ情報と行動の種類を示す行動ラベルが対応付けられた事例データが必要である。しかし、この対応付けは、センサ情報とともに取得された音声や動画を基にアノテーションツールなどを用いて手作業で付けられることが多いため、時刻のずれが生じる可能性がある。本研究では、この時刻ずれに関わらず行動認識において精度よく機械学習をするための手法を提案する。提案手法では、元の行動ラベルを前後にずらしたラベルを複製し、複数のラベルが与えられたマルチラベルの問題として学習を行う。加えて、EM アルゴリズムによって教師データにおける学習を繰り返し行うという手法を提案する。この手法を評価するために、単純ベイズフィルタ分類器を用いて、3種類の行動を判別する行動認識を行った。評価では擬似的に作成された行動のシーケンスデータにおいて行動ラベルをずらしてゆき、提案手法によって精度の改善が成されるのかを検証した。その結果、行動ラベルの時刻がずれている場合であっても、今回の評価で作成された擬似的なシーケンスデータにおいてならば、提案手法を用いて行動認識の精度を最大47.8%向上させることが出来ることを確認できた。

## Training Human Activity Recognition for Labels with Inaccurate Time Stamps

TAKAMICHI TODA<sup>2,a)</sup> SHOTA TANAKA<sup>2</sup> Sozo INOUE<sup>2,b)</sup> NAONORI UEDA<sup>3</sup>

### 1. はじめに

近年、携帯センサデバイスを用いた人間の行動認識 [1][4] の研究が盛んに行われており、スポーツや医療など様々な分野での応用が期待されている。行動認識を行うためには、多くの行動データを収集し、機械学習によって、個人差に影響されない行動特有の特徴を見つけ、認識モデルを作成する必要がある。この際、収集されたデータには「歩行」や「直立」等の行動名のラベルが正確に付いている必要がある。通常の行動認識におけるラベル付は、行動情報の測定と同時にを行う場合と、行動情報計測と同時に映像データ

や音声データを取得しておき、行動情報計測後、その音声データ等を基にアノテーションツールを用いて行われることが多い。どちらの場合においても人の手によって行われるため、感覚の差により行動ラベルの付き方に時刻のずれが生まれ、認識精度が変わってしまったり、認識を行えない場合もある。本研究では、行動認識を行う際、計測した行動情報に対応する行動ラベルに時刻のずれがある場合であっても、高精度な認識を行える手法を提案する。

提案する手法では、時刻のずれがあるラベルデータを基に、機械学習を行い、特徴量における、与えられた各行動の条件付き確率を求める。今回、機械学習における分類器は単純ベイズフィルタを用いた。そしてその条件付き確率を基に行動毎に特徴量を複製する。複製されたデータを再び機械学習し、特徴量における、与えられた各行動の条件付き確率を求める。この行程をEM アルゴリズムによって収束させ、最終的に認識モデルを作成する。

その認識モデルを用いて行動認識を行い、提案手法が有効であるか評価した。その結果、行動ラベルの時刻のずれ

<sup>1</sup> 情報処理学会  
IPSJ, Chiyoda, Tokyo 101-0062, Japan

<sup>2</sup> 九州工業大学  
〒804-8580, 北九州市戸畑区仙水町1-1

<sup>3</sup> 日本電信電話(株)NTTコミュニケーション科学基礎研究所  
〒619-0237 京都府相楽郡精華町光台2-4

<sup>t1</sup> 現在、マルチメディア、分散、協調とモバイルシンポジウム運営委員会

Presently with DICOM2014

a) 5toda6@gmail.com

b) sozo@mns.kyutech.ac.jp

がある教師データで学習を行った場合、提案手法を用いることで、最大で47.8%の精度向上を確認できた。

以下2章で関連研究について述べ、3章で提案手法について述べ、4章で評価方法について述べる。5章で評価の結果とその結果についての考察を述べる。最後に6章でまとめる。

## 2. 関連研究

携帯センサを用いた行動認識手法は、文献[1]以来非常に多くの研究がなされてきたが、教師あり機械学習に基づく場合には、教師情報であるラベル情報の不完全や不正確さが問題となってきた。このため、ラベルありデータだけではなくラベルなしデータも学習に用いる半教師あり学習手法[5]の利用が提案されている[8]。文献[9]では、基本的な半教師あり学習であるSelf-trainingとCo-trainingを用いて、ラベルなしデータにもラベルを与えて行動認識を行っている。文献[6]は、行動認識におけるラベルありおよびラベルなしデータを用いて特徴量を多次元固有空間に射影する関数を生成し、次にラベルありデータについて射影後の空間においてSVMによる教師あり学習を行っている。ラベルなしデータの特徴も学習結果に反映させることが可能となる。これらの研究は不完全なラベルを用いる点では我々と同じであるが、時刻のずれを考慮したものではない。

文献[10]では、**マルチインスタンス学習**、つまり一つのラベルが一つのサンプルに対応するのではなく、一つのラベルが複数のサンプル集合に対応できるような機械学習手法を用いて、全てのデータにラベルが与えられなくともよい学習手法をSVMの改良により提案している。マルチインスタンス学習については文献[12]に紹介されているが、サンプル集合に与えられるラベルはその集合に一つ以上存在するという仮定を持ったものである。

文献[15]では、ラベルの時刻は与えられない代わりに順序のみが与えられた場合にも学習できる行動認識手法を提案している。この手法では、教師なしの手法を用いてセグメンテーション、クラスタリングを行った後、教師あり学習結果とラベルのDPマッチングにより正解ラベルを求める。この手法は行動の時刻が分からず順序のみが分かっている場合には有効だが、我々のように行動ラベルの時刻のずれはあるものの特定の時刻にラベルをつけたい要求には答えることができない。

**マルチラベル学習**は、一つの学習サンプル(以下**サンプル**)に複数のラベルや構造化されたラベルを許容する機械学習のことであり、文献[11]や文献[12]に紹介されているが、我々はその中でも、

- 一つのサンプルにラベルは複数与えられてよいが、その中で真のラベルは1つしかない

という特別な想定を持ったマルチラベル学習に着目する[7]。

この手法は、初期マルチラベル集合が全て確率的に与えられたとして機械学習、つまりモデルパラメータの推定(Mステップ)を行い、そのモデルを用いて今度は学習データのラベルの確率分布を推定する(Eステップ)、というステップを繰り返すEMアルゴリズムである。文献[2]では同様の問題を損失関数の凸計画問題として解いており、映像の人物ラベリングに適用している。我々は文献[7]の手法を利用し、時系列データにおける時刻ずれをこの問題に変換することで解決をはかる。

文献[3]は、文献[7]の手法を自然言語処理で良く用いられる条件付き確率場(CRF)に拡張し、系列データにノイズの乗った、つまり複数のラベル候補が与えられたとしても学習可能な手法を用いている。この研究は文献[7]の手法を系列データに拡張している点では我々と同じだが、我々のようにラベルの時刻のずれを想定しているわけではなく、複数人が1サンプルのデータに複数のラベルが与えられることを想定している点が我々と異なる。

上述したマルチインスタンス学習では通常、文献[7]のように1サンプルに複数のラベルがつくことは仮定していない。しかしながら文献[10]では、経験サンプリングにおいて複数のラベルが与えられた場合についても対応できるように手法を改良している、この際に繰り返しを用いてラベルの無いサンプルにラベルを与えながら収束するやり方は我々と同様である。ただし、文献[7]のように確率的なアプローチではなく決定的なアプローチである。また、ラベルが経験サンプリングにより定期的に与えられるため、我々のように時刻のずれ具合を考慮した手法ではない。

## 3. 提案手法

本節では、時刻がずれている可能性があるデータをマルチラベル問題に変換する方法および、マルチラベル問題の解法、またその中で行われる平滑化について述べる。

### 3.1 入力データのマルチラベル問題への変換

想定する入力データは、携帯センサから得られる加速度などのセンサデータおよびラベルの系列情報である。センサデータは、一般の行動認識手法と同様に、時間窓をとって特徴量ベクトル(以下**特徴量**)を計算するものとする。

以下では、離散時間 $t$ における特徴量 $\vec{x}_t$ とラベル $y_t$ が、

$$(\vec{x}_t, y_t)$$

と与えられているものとする。ただし $t = 1, 2, \dots, n$ とする。このとき、それぞれの $t$ に対して、以下のようにマルチラベル集合 $S_t$ を生成する。

$$S_t := \{y_{t'} | t - \alpha \leq t' < t + \alpha\}$$

ただし $\alpha$ はパラメータ定数とする。

この式は、与えられたラベルよりも  $\alpha$  だけ時間に幅を持たせてラベルを与えることに相当する。ある時刻  $t$  から見たら、その前後  $\alpha$  以内に与えられたラベルも候補となり、このようなラベルは複数あり得るが、実際には1種類の行動であることをここでは想定するため、文献 [7] と同様のマルチラベル学習の問題となる。

### 3.2 マルチラベル問題の解法

前節でマルチラベル問題に変換された学習データに、文献 [7] の手法を適用する。文献 [7] では KL ダイバージェンスを用いて EM アルゴリズムの定式化がなされているが、ここでは処理の手続きのみを簡潔に述べる。

前節より、以下のようなマルチラベルデータが与えられる。

$$(\vec{x}_t, S_t) \quad t = 1, 2, \dots, n$$

これに対し、以下のような手続きを行う。

- (1)  $t = 1, 2, \dots, n$  に対して、 $S_t$  中のラベルがすべて与えられたと仮定して、単一ラベルの学習データを作成する。つまり、 $S_t = \{y_t^{(1)}, y_t^{(2)}, \dots, y_t^{(m_t)}\}$  に対して

$$(\vec{x}_t, y_t^{(j)}) \quad j = 1, 2, \dots, m$$

を生成する。

- (2) M ステップ: 学習データから機械学習によりモデル  $f$  を得る。
- (3) E ステップ: そのモデル  $f$  を使って、 $t = 1, 2, \dots, n$  における  $\vec{x}_t$  に対して推定を行い、推定ラベルの確率分布  $p(y|t) = f(\vec{x}_t)$  を求める。
- (4) (1) と同様に単一ラベルの学習データを作成する。このとき、推定ラベルの確率分布に比例してサンプル数を増やす。つまり、各  $t$  および各  $y$  に対して、

$$(\vec{x}_t, y) \text{ の個数 } \propto p(y|t)$$

となるようにする。これを次のステップの学習データとする。

- (5) 収束するか変化が非常に小さくなるまで (2)-(4) を繰り返す。

これらは EM アルゴリズムとして定式化されているため、Jensen の不等式により局所解に収束することが示される。

上記の手法を、以下では *EM 法* と呼ぶことにする。EM 法の流れを図 1 にまとめる。また、比較のために、ステップ (3) までを行ったあと、最尤法により行動を推定したものを *Non-EM 法* と呼ぶ。

### 3.3 平滑化

前節のやり方は時系列に特化しない手法だが、時系列を考慮して、前後のラベルを元に平滑化を行うことで、精度向上が期待できる。前節の手続きにおいてステップ (3) の後、

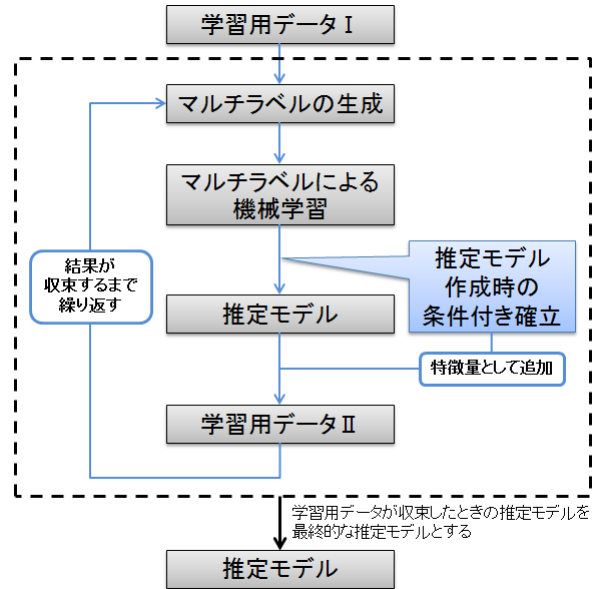


図 1 マルチラベルの解法 (EM 法の流れ)

以下の式で平滑化を行う。各時刻  $t$  において  $y_{t-1} = y_{t+1}$  ならば、

$$y_t \leftarrow y_{t-1}$$

とする。つまり、前後のラベルが一致すれば、その時刻のラベルも同じものとする。

ただしこの平滑化手法には問題がある。この平滑化の手法ではラベルの前後のみしか考慮しないため、誤った認識結果が 2 つ以上並んでいる場合は平滑化が行われない。手法についての説明を可視化したものを図 2 に示す。




図 2 平滑化について

次節の評価においては、この平滑化を行った場合と行っていない場合を比較する。

## 4. 評価

教師データの行動ラベルの時刻がずれていた場合、提案手法を用いることで、正確なラベルに基づく認識に近い認識ができるかを調べるために評価実験を行った。3 種類の

行動からなるデータセットを結合し、人工的なシーケンスデータを作成した。そのシーケンスデータを用いて行動認識を行い、その正解率を評価した。解析の為にプログラムは統計解析ソフト R で作成し、機械学習の分類器は単純ベイズフィルタを用いた。

#### 4.1 データセット

HASC Challenge<sup>\*1</sup>[13][14]において測定された3種類の行動データを結合し、擬似的なシーケンスデータを作成し、これを使用した。使用したデータは、成人男性の直立、歩行、走行の3種類の行動の3軸加速度データである。結合した順番は直立、歩行、走行である。実験用のデータは10人分(10ファイル)あり、さらにそれぞれ5回分のデータを持っている。つまり各行動毎に50ファイル存在する。各行動の時間は20秒間である。データの詳細を表1に示す。

表1 測定データ詳細

被験者	20代男性
人数	10人
測定場所	野外(アスファルト)
各測定回数	5回
測定機器	ipod touch(第4世代)
測定データ	3軸加速度
取り付け位置	右ポケット
周波数	100Hz
行動の種類	直立, 歩行, 走行
各行動の時間	20秒

#### 4.2 特徴量抽出

第4.1節のデータから特徴量を抽出した。使用する値は3軸加速度の合成値で、幅2秒の時間窓を取り、時間窓内の平均値、分散値、エネルギーを特徴量とした。時間窓は時間軸に平行に0.5秒ずつずらした。データから得た特徴量の詳細をまとめたものを表2に示す。

表2 特徴量詳細

加速度	3軸の合成値
時間窓幅	2秒
時間窓ずらし幅	0.5秒
特徴量	時間窓毎の平均, 分散, エネルギー

3軸を合成した理由は、測定時の端末の取り付け位置が固定されていないためである。

#### 4.3 評価方法

提案手法の有用性を評価するために、以下の3種類の場合について、行動ラベルの時刻がずれた教師データを用いて機械学習を行い、推定モデルを作成した際の認識精度の

変化を比較した。

- **Naive 法**

既存の単純ベイズフィルタ分類器を用いた機械学習による行動認識。

- **Non-EM 法**

第3.2節で述べた提案手法に従って、行動ラベルを前後にずらしてラベルを複製した上で各行動における条件付き確率を特徴量に追加し、機械学習を行う。

- **EM 法**

Non-EM 法と同様に提案手法に基づき機械学習を行う。ただし結果が収束するまで提案手法を繰り返す。

##### 4.3.1 評価データ

第4.1節で述べたデータセットにおいて、各行動50ファイルからランダムに1つずつ選択し、3種類の行動を結合させ人工的なシーケンスデータを作成し、これをテストデータとした。そして残りの49ファイル×3行動分を1つに結合させ、人工的なシーケンスデータとし、これを学習データとした。

ここでデータをランダムに選択するため、機械学習による認識精度に問題はないか、行動ラベルの時刻がずれていない正解のラベルを与えた場合において既存の手法による機械学習を行うことで確認した。単純ベイズフィルタ分類器を用いて作成した学習データから推定モデルを生成し、テストデータに適用させ、3種類の行動の認識精度を調べた。100回試行し、認識の平均正解率と標準偏差を取ったところ、平均正解率98.2(%)、標準偏差5.3となり、評価を行う上で問題ないと判断した。

##### 4.3.2 行動ラベルのずれ

第1章で述べたとおり、行動認識を行う際のラベル付は人の手によって行われるため時刻のずれが生じてしまう。今回の評価実験ではこの時刻のずれを意図的に発生させ、時刻のずれの大きさによる認識精度の低下、及び提案手法によるその改善度合を確認する。

学習に用いるデータは49ファイルの行動データを3行動分結合した擬似的シーケンスデータであり、1つのファイルの行動時間が約20秒であるため、980秒の行動×3種類の約2940秒のシーケンスデータということになる。このデータにおける行動ラベルを75秒単位で合計10回ずらしてゆき、認識精度の変化をNaive 法, Non-EM 法, EM 法において比較した。

##### 4.3.3 平滑化の適用

第3.3節で述べた平滑化の手法をNaive 法, Non-EM 法, EM 法に置いてそれぞれ適応し、適応しなかった場合と比較して認識精度がどれほど変化するか確認した。

\*1 <http://hasc.jp/>

## 4.4 結果

評価実験の結果を、縦軸に正解率(%), 横軸にずらし幅(75秒単位)をとってグラフをにすると図3のようになる. ここでx軸が0(時刻のずれが0)の場合は正しいラベルが与えられた場合である.




図3 ずらし幅毎の正解率の推移

以上の結果より, 行動ラベルの時刻がずれていると認識精度は下がるが, 提案手法を用いれば認識精度の低下を緩和し, 時刻のずれが大きい場合においても高精度な行動認識が可能となることがわかる. 行動ラベルの時刻のずれが450秒である時, 既存の手法であるNaiveに比べて提案手法を用いたEMでは47.8%もの精度向上が見られる. また, わずかではあるが, 行動ラベルの時刻のずれ幅が小さい場合は平滑化を行うことにより認識精度が改善されていることがわかる. 平滑化による認識精度改善の変化を表3に示す. 表3における手法は紙面の都合上省略したものを示している. Na → Naive法, No → Non-EM法, EM → EM法であり, -sがついたものが平滑化手法を適用した場合である.

表3 平滑化による認識精度の変化 (%)

ずれ	Na	Na-s	No	No-s	EM	EM-s
75 (s)	100	100	100	100	100	100
150 (s)	100	100	100	100	100	100
225 (s)	99.1	100	100	100	100	100
300 (s)	92.8	92.8	100	100	100	100
375 (s)	55	55.9	91.9	93.7	99.1	100
450 (s)	47.7	47.7	62.2	63.1	95.5	96.4
525 (s)	39.6	38.7	51.4	53.2	83.8	84.7
600 (s)	34.2	33.3	36	35.1	48.6	47.7
675 (s)	33.3	33.3	33.3	33.3	34.2	33.3
750 (s)	33.3	33.3	33.3	33.3	33.3	33.3

### 4.4.1 EM アルゴリズムによる精度の改善

今回の評価実験において, EM アルゴリズムによって精度がどのように収束していくのかを調べた. 変化をまとめたを表4に示す. 表の各値は各場合における行動認識の正解率 (%) である.

表4 EM アルゴリズムによる精度の変化 (%)

ずれ\繰り返し	0回	1回	2回	3回	4回	5回
75 (s)	100	100	100	100	100	100
150 (s)	100	100	100	100	100	100
225 (s)	99.1	100	100	100	100	100
300 (s)	92.8	100	100	100	100	100
375 (s)	55	91.9	99	99.1	99.1	99.1
450 (s)	47.7	62.2	95.5	95.5	95.5	95.5
525 (s)	39.6	51.4	84.7	83.8	83.8	83.8
600 (s)	34.2	36	36	42.3	48.6	48.6
675 (s)	33.3	33.3	33.3	33.3	33.3	34.2
750 (s)	33.3	33.3	33.3	33.3	33.3	33.3

表4において, 繰り返し回数0回がNaive法による認識, 繰り返し回数1回がNon-EM法による認識を示している. 今回の実験ではEMアルゴリズムは5回繰り返されたが, 故意に6回目の学習を行った場合, 認識された行動ラベルのデータから, 5回目まではほぼ正常に認識されていた走行の行動ラベルが消失してしまった.

## 5. 考察

提案手法によって, 行動ラベルの時刻がずれていた場合においても, 正しいラベルを与えたに場合に近い精度で行動認識を行うことが出来ることがわかった. 本節では評価実験の結果とその結果を踏まえた上での今後の課題を考察する.

### 5.1 平滑化

実験により, 平滑化を行うことで認識精度を向上させることが出来ることがわかったが, 今回提案した平滑化の手法では不十分であることがわかった. 図2に示すように今回提案した平滑化手法ではラベルの前後のみしか考慮しないため, 誤った認識結果が2つ以上並んでいる場合は平滑化が行われない. つまり精度が良くない場合, 誤った認識結果は2つ以上並んでいることが多いということである. そのため今回の実験では平滑化による精度向上は微々たるものであったと考える.

今後平滑化を行う方法として, 平滑化範囲の拡大を考えている. 前後のラベルを考慮し, 平滑化させる中心のラベルの範囲を, 前後のラベルの長さに対応させて広げる. どの程度広げるかは今後精度を比較しながら検討する.

### 5.2 EM アルゴリズムの繰り返し

今回の実験ではEMアルゴリズムの繰り返し回数は5回

であったが、4.4.1 節における EM アルゴリズムの収束状況を見てみると、3 回目以降の繰り返しではあまり精度の向上が見られない。今回は約 3000 秒の行動データであり、特徴量も 3 種類だけであったが、さらに長時間のデータであったり、特徴量が増えることで機械学習の時間は増大する。そのため、解析作業を円滑に進める為、しきい値をさらに低く設定する必要があると考える。どの程度の値が適切か今後調べてゆく。

また今回の実験で、故意に EM アルゴリズムによる学習を必要以上に行った場合、認識された行動ラベルのデータから「走行」の行動ラベルが消失してしまった。これは過学習によるものだと考えており、このような場合も考慮したアルゴリズムを作成する必要がある。

### 5.3 データの種類

現在は提案手法の評価の為、理想的な行動データとして 3 種類の行動を結合した擬似的なシーケンスデータによって行動認識を行っているが、より実用的な行動認識においても提案手法が有用であることを証明するため、今後は多様なデータにおいて提案手法による精度改善を検証していく必要がある。現在考えられる方向性は以下の 3 種類である。

- **行動の種類を増やす**

評価に使用している行動は 3 種類だけであるが、行動認識の研究においてはさらにたくさんの行動の種類を扱っているため、認識する行動を増やしていく必要がある。現時点で追加する行動として考えている者は、スキップ、階段を上る、階段を下りる、の 3 種類である。

行動を増やして実験を行う際には特徴量の取り方を考慮しなくてはならない。行動が増えるほど、似た特徴を持つ行動が出てくるため、それらを区別できる適切な特徴量を設定する必要があるためである。

- **実際に連続して測定されたシーケンスデータを用いる**

今回使用したシーケンスデータは 3 種類の行動データを結合させた擬似的なものである。実際の行動認識では行動の変わり目など、別に考慮すべき点があるため精度も変化すると考えられる。そのため実際に連続して計測されたシーケンスデータによる実験が必要である。

- **行動ラベルの時刻のずれ方を変化させる**

第 4.3.2 節で述べたように、今回の実験では、図 4 のようにデータ全体において行動ラベルが並行移動した場合のみの評価であったが、実際にラベル付を行った場合は図 5 に挙げられる様に不規則な時刻のずれ方をする場合が多い。このようなラベルの時刻のずれでの評価も行っていく必要がある。




図 4 今回評価したラベルの時刻のずれ方




図 5 多様なラベルの時刻のずれ方の例

## 6. まとめ

本稿では、スマートフォン等の携帯センサデバイスを用いた行動認識を行う際に、行動名のラベルが時刻的にずれていた場合であっても、高精度な認識を行う手法を提案し、条件付き確率を基に各行動の特徴量を複成し、EM アルゴリズムによって収束させる方法を示した。

評価実験により、「歩行」「直立」「走行」の 3 種類の行動において、行動ラベルの時刻がずれていた場合であっても、提案手法によって高精度の行動認識を行うことが出来ることがわかった。また EM アルゴリズムによって、行動認識の精度が高くなっていくことを確認することが出来た。しかし評価実験において、EM アルゴリズムによる機械学習の繰り返しが処理時間を大幅に増やしていたため、今後は収束のしきい値を考える。

また行動認識の精度を向上させる方法として、平滑化の手法を提案したが、今回の手法では大幅な精度向上は見られなかったため、別の手法を検討する。

今回は HASC Challenge2013 の行動データを結合した擬似的なシーケンスデータを用いたが、今後は実際に連続して測定された行動データや、行動の種類を増やすなどして認識の応用を広げてゆく。

また我々は熊本にある済生会熊本病院と連携し、1 年間にわたり大規模な行動データの収集実験を行っており、約 7,400 時間の実際の看護活動と、ラベル付けした 41 の行動



クラスに分類した 5,964 個の行動データを保有している。医療の場で看護師の行動を認識し、業務の効率化を目的に行動認識の研究がなされているが、長時間かつ大量のデータであるので、ラベル付が不十分である。このデータセットにおいても提案手法を利用する方法を考慮しながら研究を進める。

## 謝辞

本研究の一部は、最先端研究開発支援プログラム「超巨大データベース時代に向けた最高速データベースエンジンの開発と当該エンジンを核とする戦略的社会サービスの実証・評価(中心研究者:喜連川優)」、基盤研究(A)「人間行動理解のための装着型センサによる大規模データベースの構築(研究代表者:河口信夫)」および基盤研究(B)「物理層と意味層の2階層からなるセンサコンテキスト推定技術(研究代表者:井上創造)」による。

## 参考文献

- [1] Ling Bao and Stephen S. Intille. Activity recognition from user-annotated acceleration data. In Alois Ferscha and Friedemann Mattern, editors, *Pervasive Computing*, Vol. 3001 of *Lecture Notes in Computer Science*, pp. 1–17. Springer Berlin Heidelberg, 2004.
- [2] Timothee Cour, Ben Sapp, and Ben Taskar. Learning from partial labels. *The Journal of Machine Learning Research*, Vol. 12, pp. 1501–1536, 2011.
- [3] Mark Dredze, Partha Pratim Talukdar, and Koby Crammer. Sequence learning from data with multiple labels. In *Workshop Co-Chairs*, p. 39. Citeseer, 2009.
- [4] Moore A.J., Tilbury N., Church J., Farrington, J. and P.D.: Wearable Biometric. Sensor badge and sensor jacket for context awareness. In *Proceedings of the Third International Symposium on Wearable Computers*, pp. 107–113, 1999.
- [5] Yves Grandvalet, Yoshua Bengio, et al. Semi-supervised learning by entropy minimization. In *NIPS*, Vol. 17, pp. 529–536, 2004.
- [6] T. Huynh and B. Schiele. Towards less supervision in activity recognition from wearable sensors. In *Wearable Computers, 2006 10th IEEE International Symposium on*, pp. 3–10, Oct 2006.
- [7] Rong Jin and Zoubin Ghahramani. Learning with multiple labels. In *Advances in neural information processing systems*, pp. 897–904, 2002.
- [8] M. Stikic, D. Larlus, S. Ebert, and B. Schiele. Weakly supervised recognition of daily life activities with wearable sensors. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, Vol. 33, No. 12, pp. 2521–2537, Dec 2011.
- [9] M. Stikic, K. Van Laerhoven, and B. Schiele. Exploring semi-supervised and active learning for activity recognition. In *Wearable Computers, 2008. ISWC 2008. 12th IEEE International Symposium on*, pp. 81–88, Sept 2008.
- [10] Maja Stikic and Bernt Schiele. Activity recognition from sparsely labeled data using multi-instance learning. In Tanzeem Choudhury, Aaron Quigley, Thomas Strang, and Koji Sugiuma, editors, *Location and Context Awareness*, Vol. 5561 of *Lecture Notes in Computer Science*, pp. 156–173. Springer Berlin Heidelberg, 2009.
- [11] Grigorios Tsoumakakis and Ioannis Katakis. Multi-label classification: An overview. *International Journal of Data Warehousing and Mining (IJDWM)*, Vol. 3, No. 3, pp. 1–13, 2007.
- [12] Zhi-Hua Zhou, Min-Ling Zhang, Sheng-Jun Huang, and Yu-Feng Li. Multi-instance multi-label learning. *Artificial Intelligence*, Vol. 176, No. 1, pp. 2291–2320, 2012.
- [13] Kawaguchi, N., Ogawa, N., Iwasaki, Y., Kaji, K., Terada, T., Murao, K., Inoue, S., Kawahara, Y., Sumi, Y. and Nishio, N. HASC Challenge: Gathering Large Scale Human Activity Corpus for the Real-World Activity Understandings. *Proc of ACM AH 2011 2010*, pp. 271–275, 2011.
- [14] 河口信夫. 人間行動理解のための装着型センサによる大規模データベース構築にむけて. マルチメディア、分散、協調とモバイル (DICOMO) シンポジウム論文集. 2010, pp. 579–582, 2010.
- [15] 村尾和哉, 鳥居康幸, 寺田努, 塚本昌彦. 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. 情報処理学会論文誌, Vol. 55, No. 1, pp. 519–530, Jan 2014.