

# ランダムフォレストとルールベース処理を用いた 大規模スマートフォンデータに対する行動認識

浦野 健太<sup>†</sup> 松山 仁<sup>†</sup> 湯木 悠太<sup>†</sup> 野崎 惇登<sup>†</sup> 廣井 慧<sup>†</sup>  
梶 克彦<sup>††</sup> 河川 信夫<sup>†</sup>

<sup>†</sup> 名古屋大学大学院工学研究科 〒464-8603 愛知県名古屋市千種区不老町

<sup>††</sup> 愛知工業大学情報科学部 〒470-0392 愛知県豊田市八草町八千草 1247

E-mail: [†vrano@ucl.nuee.nagoya-u.ac.jp](mailto:†vrano@ucl.nuee.nagoya-u.ac.jp)

**あらまし** スマートフォンの普及で、日々の行動におけるセンサデータを容易に取得できるようになり、行動認識を利用したサービスの登場が期待されている。高精度な行動認識の実現には、大量のデータを用いた機械学習が有効であると考えられる。本研究では、共通の大規模スマートフォンデータセットを用いて行われた SHL Recognition Challenge における我々の提案手法を紹介し、結果を含めて今後の行動認識技術の進歩に対する考察を行う。提案手法は、ランダムフォレストの認識結果にルールベース処理を加えて一貫性を保つものである。コンペティションにおける提案手法は F1 値で 0.852 を記録し、19 チーム中 7 位であった。

**キーワード** 行動認識, SHL データセット, ランダムフォレスト

## Activity Recognition on Large-Scale Smartphone Sensor Dataset using Random Forest and Rule-Based Post Processing

Kenta URANO<sup>†</sup>, Hitoshi MATSUYAMA<sup>†</sup>, Yuta YUKI<sup>†</sup>, Junta NOZAKI<sup>†</sup>, Kei HIROI<sup>†</sup>,

Katsuhiko KAJI<sup>††</sup>, and Nobuo KAWAGUCHI<sup>†</sup>

<sup>†</sup> Grad. Sch. of Engineering, Nagoya University Furo-cho, Chikusa-ku, Nagoya-shi, Aichi, 464-8603 Japan

<sup>††</sup> Faculty of Info. Sci., Aichi Inst. of Tech. 1247 Yachigusa, Yakusa-cho, Toyota-shi, Aichi 470-0392 Japan

E-mail: [†vrano@ucl.nuee.nagoya-u.ac.jp](mailto:†vrano@ucl.nuee.nagoya-u.ac.jp)

**Abstract** Thanks to widely-spreaded smartphones, we can easily acquire the sensor data of our daily activities. To implement an accurate activity recognition, machine learning can be a effective way. In this paper, we introduce our method proposed in a competition called SHL Recognition Challenge. We also discuss what is a key to higher accuracy, including the result of the competition. Proposed method uses a rule-based post-processing on the result of random forest classifier to generate consistent result. Proposed method showed F1 score of 0.852 and became seventh place among 19 teams.

**Key words** Activity Recognition, SHL Dataset, Random Forest

### 1. はじめに

スマートフォンやスマートウォッチなどのスマートデバイスが普及し、様々な種類のセンサデータを長時間継続して取得できるようになった。センサデータを用いたサービスとして、行動認識が考えられる。一日のどの時間帯に何をしていたかを自動的に認識、記録することで運動ログやライフログ、移動履歴の記録が可能になる。しかし、認識対象になる行動は多岐にわ

たり、移動に関する行動だけでも歩く、走る、自転車に乗る、車に乗る、電車に乗るなどが挙げられる。

多数の行動を高精度に認識する研究が行われている一方で、各研究で利用するデータはそれぞれの研究者が集めたものが多く、共通のベースラインとなるデータを用いた比較を行えない。そこで、行動認識のための大規模なデータセットが製作されている。Opportunity データセット [1], [2] では肘や手首、膝などに多数のセンサを取り付け、さらに環境側にもセンサを設置し

て電灯の操作や飲食などを含む日常的な活動のセンサデータを計測している。Human Activity Sensing Consortium<sup>(注1)</sup> (以下 HASC) では、コンソーシアムのメンバでスマートフォンのセンサデータを共有し、主に歩行に関するデータセットを作成している。

本稿では、Sussex Huawei Locomotion (SHL) データセットを用いて、UbiComp/ISWC 2018 (以下 UbiComp 2018) の Human Activity Sensing Corpus and Application (HASCA) 2018 ワークショップ<sup>(注2)</sup>で行われた行動認識のコンペティションである Sussex Huawei Locomotion (SHL) Recognition Challenge における我々の提案手法について述べ、コンペティションの結果を含めて議論する。提案手法は、ランダムフォレストを用いて 3 秒単位で行動認識を行った後に、連続する時間での行動が矛盾しないようルールベースのポストプロセッシングで認識結果を調整し、高精度を狙うものである。

## 2. 関連研究

### 2.1 行動認識

センサデータを用いた行動認識技術は、運動の自動認識や作業記録の自動作成に役立つ。認識は単純な閾値によるものもあれば、機械学習を利用するものも多く、ナイーブベイズや Support Vector Machine (SVM) に加え、近年ではディープラーニングを用いた手法もある。

どのような行動を認識するかも研究によって異なり、鷲澤らの研究 [3] では健康管理や作業モニタリングのため、背筋に複数のセンサを取り付けて直立や猫背などを認識している。細かな動きを認識するものとしては渡邊らのジェスチャ認識研究 [4] がある。この研究では、右手首に取り付けた加速度センサを用い、教師データにない動きを含む加速度データを教師データとうまくマッチングする手法を提案している。

### 2.2 行動認識向け大規模データセット

行動認識向けのデータセットは、センサの取付け位置や、対象の行動などが異なる複数のものがある。1. でも触れたように、Opportunity データセット [1], [2] では、実際の生活に近い環境でセンサデータを収集している。キッチンや冷蔵庫、外出用ドアなどを含む実験環境に、マイクアレイや加速度センサ、電力計などを設置し、被験者の体にも同様にセンサを取り付けて、被験者にシナリオに沿った行動と、より抽象度の高い行動（食事、掃除など）を取らせ、それらを記録している。

一方、HASC ではスマートフォンを用いて歩行データを収集している。データはコンソーシアムのメンバが作成してお互いに共有し、少量のデータ提供で大きなデータセットを得られる。上記の取り組みは HASC Challenge として複数回開催されてコーパスとして公開されているほか、屋内位置推定用の HASC-IPSC データセット [5] や、HASC Challenge のデータをまとめた HASC-PAC データセット [6] も整備されている。データセットに含まれる行動は静止、歩行、スキップ、階段の

表 1 SHL データセットにおける代表的なセンサ  
Table 1 Part of sensor modalities in SHL dataset

種別	取得される内容
加速度	x, y, z (m/s <sup>2</sup> )
角速度	x, y, z (rad/s)
磁気	x, y, z ( $\mu$ T)
端末姿勢	w, x, y, z からなるクォータニオン
重力加速度	x, y, z (m/s <sup>2</sup> )
リニア加速度	x, y, z (m/s <sup>2</sup> )
気圧	(hPa)
Wi-Fi	SSID, RSSI, 周波数および暗号種別
GPS 位置情報	緯度, 経度, 高度, 精度

表 2 トレーニング用データに含まれる各行動クラスの秒数  
Table 2 Duration of each activity class in training data

行動	秒数	行動	秒数
静止	137,984	車	148,649
歩行	131,209	バス	125,296
ラン	41,146	電車	151,023
自転車	125,855	地下鉄	117,437

上り下りなどで、スマートフォンに搭載されるセンサのうち、主に加速度、角速度（ジャイロ）、気圧などのデータで構成されている。

## 3. SHL Recognition Challenge

### 3.1 SHL データセット

SHL データセット<sup>(注3)</sup> [7] は、サセックス大学とファークウェイが共同で作成したデータセットであり、日常生活における以下の 8 種類の移動行動を含む。

- 静止
- 徒歩
- ランニング（以下、ラン）
- 自転車
- 車
- バス
- 鉄道
- 地下鉄

データの取得はイギリスで行われ、3 人の被験者がそれぞれ 4 台のスマートフォンを携行した。スマートフォンは胴体、バックパック、手首、ズボンのポケットに配置され、専用のアプリケーションでセンサデータを記録した（代表的なものを表 1 に示す）。センサデータは Android で利用可能な API を経由して取得されており、重力やリニア加速度<sup>(注4)</sup>のように他のセンサデータから生成されたデータもある。

### 3.2 Recognition Challenge におけるタスクと評価基準

SHL Recognition Challenge は、UbiComp 2018 で行われた HASCA2018 ワークショップにおけるコンペティションである。参加者は共通のデータを用い、トレーニング用データをも

(注1) : <http://hasc.jp/>

(注2) : <http://hasca2018.hasc.jp/>

(注3) : <http://www.shl-dataset.org/>

(注4) : 重力成分を含まない加速度

表 3 利用するセンサと特徴量

Table 3 Features which are input to random forest

センサ	特徴量
加速度	x, y, z 分散, G に変換し平均
	ノルム 分散, 最大値, 基本周波数, G に変換し平均, 15 サンプル平均の分散
角速度	x, y, z 分散
	ノルム 最大値
磁気	x, y, z 分散
	ノルム 15 サンプル平均の分散
重力加速度	x, y, z G に変換し平均
気圧	分散, 最大値と最小値の差分

とに 3.1 に示した 8 種の行動を識別するアルゴリズムを作成し、テスト用データに対して行動認識を行い、その精度を競った。

トレーニング用・テスト用データは表 1 に示すセンサのうち、Wi-Fi および GPS 位置情報が無いものである。データは 1 人の被験者がズボンのポケットにスマートフォンを入れて収集したもので、1 分単位のフレームに切り出されており、フレーム順をランダムに入れ替えた上で提供された。トレーニング用データは 16310 行、6000 列となっており、1 行は 100Hz で記録されたセンサデータの 1 フレーム (1 分) に対応し、6000 個のサンプルを含む。テストデータは 5698 行、6000 列である。

トレーニング用データには各値がどのクラスに属するかを示すラベルファイル (16310 行、6000 列) が付属しており、各サンプルがどの行動クラスにあたるかを示す。さらにトレーニング用データには各フレームが本来どの順番であったかを示すファイルも付属し、それによってフレームを並べ直すことで本来の時系列を復元できる。テスト用データにはこれらは付属しない。

アルゴリズムの評価は、テスト用データの各サンプルに対する認識結果と、運営側が所持するテスト用データのラベルを比較し、F1 値を算出して行われる。ここでは、各クラスにおける F1 値を計算しそれらの平均値が最終的な順位付けに利用される。

表 2 に、トレーニング用データに各行動がどれだけの時間含まれるかを示す。各クラスの秒数はランを除いて大きな差は見られない。

## 4. 提案手法

この章では SHL Recognition Challenge における我々の提案手法について述べる。我々は、既存の機械学習手法を利用して高精度を目指すため、識別機にランダムフォレストを利用する。提案手法における処理の流れを図 1 に示す。まず、1 分単位のデータをさらに分割し、3 秒のブロックにしてから特徴量を抽出する。次に、ランダムフォレストを用いて 3 秒単位の行動認識を行う。最後に、連続するブロック間での行動が矛盾ないようにポストプロセッシングを行う。

### 4.1 データのブロック分割

与えられたデータは 1 分 (100Hz で 6000 サンプル) 単位の

表 4 グリッドサーチ対象パラメータ

Table 4 Parameter set of grid search

パラメータ	説明	値の範囲
n_estimators	決定木の数	10, 11, 12, ... , <b>28</b>
criterion	分割の評価方式	<b>gini</b> , entropy
max_features	最適な分割を探す際の	<b>sqrt</b> , log2, None <sup>(注5)</sup>
	最大特徴数	

フレームに分割されているが、これをさらに 3 秒 (300 サンプル) のブロックに分割し、以後の認識に利用する。分割は単純に 3 秒ごとに行い、スライド窓は利用しない。したがって、1 フレームからは 20 個の 3 秒ブロックが得られる。

与えられたフレームより短い時間で認識を行う理由は、複数のラベルが含まれる (途中で行動が別の行動に遷移する) フレームがあり、1 分単位での認識を行うと、精度が低下するためである。また、短いブロックに分割したほうがトレーニング時に利用可能な特徴ベクトルの数を増やせるため、精度の向上を期待できる。

### 4.2 特徴量抽出とランダムフォレストによる認識

特徴ベクトルは、表 3 に示すセンサおよび軸、特徴量を用いて作成する。利用するセンサは 5 種類で、与えられた 7 種類のセンサのうち、リニア加速度と端末姿勢は利用しないことにした。リニア加速度の成分は加速度に含まれると考えたためである。また、端末姿勢は同じ行動でも直立するか座るか、端末をどの方向で保持するかに依存してしまうと考えて利用しなかった。

特徴抽出における一部の特別な処理は次のようなものである。結局、ランダムフォレストの入力には 5 種のセンサから抽出した 24 の特徴量で構成する特徴量ベクトルを入力する。

- G に変換し平均：値を  $m/s^2$  から G に変換
- 基本周波数：FFT 後に最大の周波数成分を持つ周波数
- 15 サンプル平均の分散：ブロックをさらに 20 分割しそれぞれ平均を取り、その分散

また、ランダムフォレストのパラメータはグリッドサーチを用いて調整する。対象パラメータは実装に利用した scikit-learn のランダムフォレストのパラメータのうち表 4 に示すもので、最終的に使用したパラメータセットは (n\_estimators, criterion, max\_features) = (28, gini, sqrt) である。

### 4.3 ルールベースのポストプロセッシング

ランダムフォレストの認識結果は、連続する 3 秒ブロックに対して一貫しないことがある。例えば、車とバスや、電車と地下鉄のような行動はセンサの信号が類似するため、同じフレームから切り出した 3 秒ブロックに対する結果が、順に車・バス・バス・車... となることが考えられる。しかし、そのような行動は実際には行えない。そこで、同じフレームから切り出された 20 個の 3 秒ブロックごとに、いくつかの条件をつけてラベルにポストプロセッシングを行う。

ポストプロセッシングは、次に示すルールに従って行う。ルールは基本的に多数決であり、(1) から順に評価していく。ルール

(注5) : None 指定時は入力データの特徴数が max\_features として扱われる

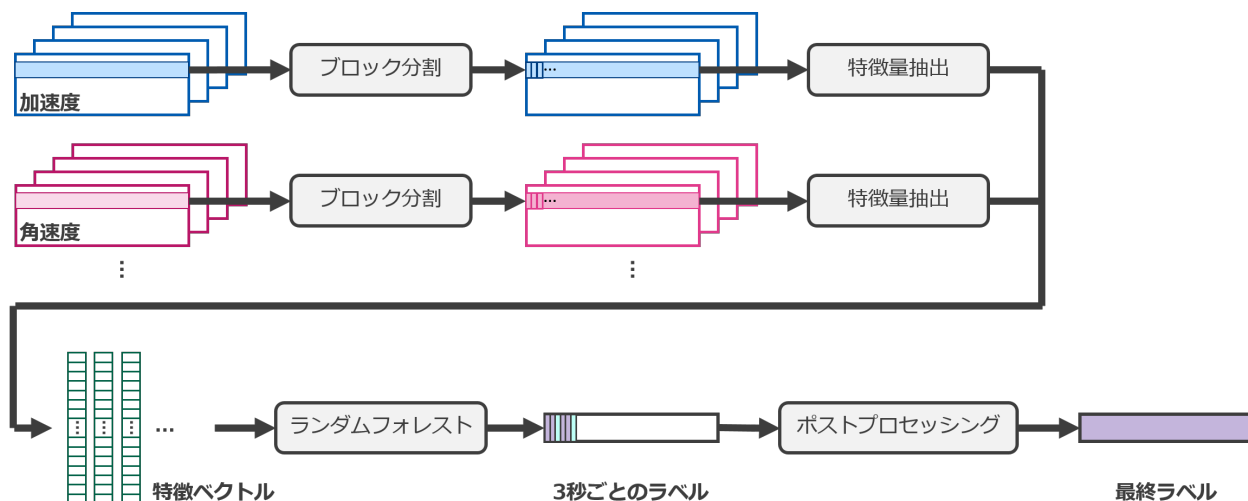


図 1 データ処理の流れ

Fig. 1 Overview of data processing

表 5 ポストプロセッシングを行う前の混同行列

Table 5 Confusion matrix before applying the post-processing

	認識結果 (%)							
	静止	歩行	ラン	自転車	車	バス	電車	地下鉄
実際のラベル 静止	<b>86</b>	1	0	2	1	4	3	2
歩行	3	<b>93</b>	0	1	0	1	0	1
ラン	1	2	<b>96</b>	1	0	0	0	0
自転車	3	2	0	<b>92</b>	1	2	0	0
車	1	1	0	1	<b>92</b>	3	2	1
バス	4	1	0	2	6	<b>83</b>	3	2
電車	3	1	0	1	2	3	<b>80</b>	11
地下鉄	3	1	0	1	1	3	15	<b>76</b>

(2) と (3) は信号が類似する行動をひとつに統一するためのものである。ルール (4) が適用されると、20 ブロック内に 2 つの行動が現れる。これは途中で行動が遷移する場合に対応する。

(1) 登場頻度で 1 位のラベルの登場回数が 15 回以上の場合、20 ブロックすべてをそのラベルで置き換える

(2) 登場頻度で 1 位、2 位のラベルがともに「自転車・車・バス・電車・地下鉄」の中にある場合、20 ブロックすべてを登場頻度 1 位のラベルで置き換える

(3) 登場頻度で 1 位、2 位のラベルがともに「自転車・徒歩」の中にある場合、20 ブロックすべてを登場頻度 1 位のラベルで置き換える

(4) 以上のどれにも該当しない場合、登場頻度で 3 位以下のラベルを 1 位のラベルで上書きする

#### 4.4 別チームの提案手法

今回の SHL Recognition Challenge では、1 チームが 2 つの異なる手法を提出できたため、我々は既存の機械学習手法を利用した手法 (本稿) に加え、ディープラーニングを利用した手法 [8] も提案した。この手法は、複数の畳み込み層と LSTM 層から構成される DeepConvLSTM [9] を 2 つ並列させた構造のモデルを採用している。並列する 2 つのネットワー

表 6 ポストプロセッシングを行った後の混同行列

Table 6 Confusion matrix after applying the post-processing

	認識結果 (%)							
	静止	歩行	ラン	自転車	車	バス	電車	地下鉄
実際のラベル 静止	<b>93</b>	1	0	2	0	2	1	1
歩行	2	<b>97</b>	0	0	0	0	0	0
ラン	0	0	<b>99</b>	0	1	0	0	0
自転車	2	1	0	<b>96</b>	0	0	0	0
車	0	1	0	0	<b>97</b>	1	0	0
バス	1	2	0	0	3	<b>92</b>	1	0
電車	1	0	0	0	0	0	<b>92</b>	5
地下鉄	1	1	0	0	0	1	10	<b>88</b>

ク、global-ConvLSTM と local-ConvLSTM は異なる入力層パラメータを持ち、それぞれ長時間の特徴と短時間の特徴を捉える役割をはたす。

ネットワークへの入力には 3 軸リニア加速度、3 軸角速度、3 軸重力加速度、気圧の合計 10 軸とし、重力加速度は単位を  $m/s^2$  から G に変換、気圧は直前の値からの差分をとる前処理を施している。こちらの手法では、前処理を施した 1 分間のセンサーデータをそのまま入力し、学習モデルの出力についてポストプロセッシングは行わない。

## 5. 評価・コンペティション結果と考察

### 5.1 評価

コンペティション時点ではテスト用データに対するラベルは提供されていなかったため、評価はトレーニング用データの一部を利用して行うこととした。16310 行あるトレーニング用データのうち、前方 80% にあたる 13048 行をトレーニングセットに、残り 20% にあたる 3262 行をバリデーションセットにあてて、バリデーションセットに対して混同行列および F1 値を算出した。

ポストプロセッシングによる精度の変化を検証するために、表 5 にポストプロセッシングを行う前の混同行列を、表 6 に

表 7 テスト用データに対する提案手法の混同行列 ([10] より)

Table 7 Confusion matrix on test data (from [10])

		認識結果 (%)							
		静止	歩行	ラン	自転車	車	バス	電車	地下鉄
実際のラベル	静止	<b>93</b>	2	0	0	1	1	1	1
	歩行	2	<b>93</b>	0	4	0	0	0	0
	ラン	0	3	<b>94</b>	2	0	0	0	0
	自転車	1	0	0	<b>98</b>	0	0	0	0
	車	1	0	0	0	<b>89</b>	9	0	0
	バス	4	1	0	0	9	<b>84</b>	0	1
	電車	7	0	0	0	1	8	<b>58</b>	25
	地下鉄	2	0	0	0	0	0	21	<b>77</b>

ポストプロセッシングを行った後の混同行列を示す。F1 値は、ポストプロセッシングを行わない場合 0.879 で、行った場合は 0.942 であった。

表 5 より、ポストプロセッシングを行う前は、静止・車・バス・電車・地下鉄で誤認識が多く発生しており、これらの行動を正しく認識することが難しいとわかる。また、特に電車と地下鉄では多くの誤認識が発生している。ポストプロセッシングにより、これらの誤認識は減少し、より正確に行動認識を行っている様子がわかる。

## 5.2 コンペティション結果

コンペティション結果は Ubicomp 2018 の HASCA2018 ワークショップで発表 [10] された。結果のグラフを図 2 に示す。17 チームから 19 の予測結果が提出 (1 チームは 2 手法まで提出が可能で、我々と別の 1 チームが 2 つ提出) され、うち 11 件が既存の機械学習手法を使ったもので、8 件がディープラーニングを使ったものであった。

図 2 を見てもわかるように、テスト用データで F1 値が 0.9 を超えたものは 2 件のみで、多くのチームがオーバーフィッティングしていた。また、既存の機械学習とディープラーニングで精度に大きな差はなかった。行動認識を行う際のウィンドウサイズや、ポストプロセッシングの有無はチームごとに戦略が分かれた。

オーバーフィッティング以外に多くのチームに見られた傾向は、①車・バスの誤認識や、電車・地下鉄の誤認識、②2 クラスを含むフレームの認識であった。①について、総評 [10] においては、認識精度が一番低かったクラスとして電車が挙げられており、次に地下鉄が続く。また静止・車・バスも認識精度が低かった。これらの行動は、歩行・ラン・自転車と比べてセンサの値が似ており、効果的に認識できなかったと考えられる。

特に②については、2 クラスを含む (行動の遷移を含む) フレームのみで認識を行うと多くのチームで数 % から 20% 程度の性能低下が起きた。図 3 に遷移のあるフレームの有無でどう精度が変化するかを示す。1 分単位で認識を行うものや、1 分より短い単位のポストプロセッシングを行わないものは大きく性能を下げる結果となった。

我々の提出結果はテスト用データに対して 0.852 の F1 値を記録し、19 チーム中 7 位であった。テスト用データに対する提

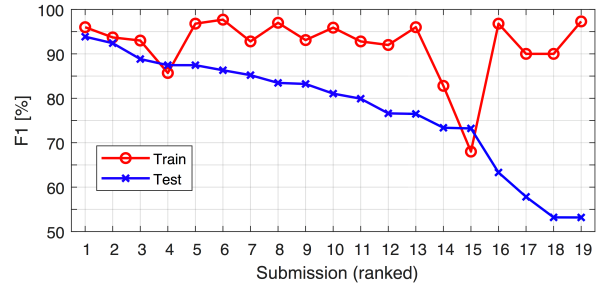


図 2 順位表 (テスト用データに対する F1 値でソート; [10] より)

Fig. 2 Ranking (sorted by F1 score on test data; from [10])

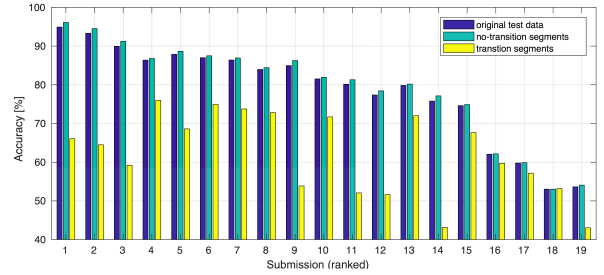


図 3 行動の遷移があるフレームの有無による精度変化 ([10] より)

Fig. 3 Performance comparison: with or without the frames which contain activity transition (from [10])

案手法の混同行列は表 7 に示す。また、ディープラーニングを使った我々の研究室の別チーム [8] の結果は 0.832 の F1 値で 9 位であった。それぞれ既存の機械学習手法、ディープラーニングを用いる手法において 4 位の結果であった。

## 5.3 議論・考察

我々の手法もコンペティションの他の参加者と同じように、トレーニングデータに大きくオーバーフィッティングしていた。トレーニング用データの一部を手法の評価に利用する際に、単純にトレーニング用データの最初の 80% で学習を行い、残りの 20% で評価を行ったが、クロスバリデーションを行い、性能をより正しく評価するべきであった。

表 6 と表 7 を比較すると、バス・電車・地下鉄で大きく性能が落ちていることがわかる。特に電車のデータを正しく電車と認識できず、地下鉄に誤って分類する傾向が強い。地下鉄のデータも同様に、誤って電車に分類する傾向が見てとれる。

また、第 4 位のチーム [11] では、トレーニング用データがランダムな順序になっていたために生じたバイアスについて触れている。これは、ランダムな順序のまま識別器のトレーニングと検証を行うと、本来の時系列で近くにあったデータがトレーニングと検証の両方に入ってしまう、実際の性能より良い性能に見えるものである。この影響の軽減には、トレーニング用データの時系列を復元し、それを用いてトレーニングと検証を行う必要がある。

公開されたテスト用データのラベルから算出した、各行動がどれだけの時間含まれていたかを表 8 に示す。トレーニング用データとテスト用データで、各行動クラスが全体に対しどれだけの割合で含まれていたかを表 9 に示す。表 9 より、トレーニ

表 8 テスト用データに含まれる各行動クラスの秒数

Table 8 Duration of each activity class in test data

行動	秒数	行動	秒数
静止	57,892	車	76,611
歩行	43,626	バス	53,886
ラン	20,304	電車	38,882
自転車	30,730	地下鉄	19,950

表 9 トレーニング用・テスト用データでの各行動クラスの割合 (%)

Table 9 Percentage of each activity class in training and test data

ファイル	静止	歩行	ラン	自転車	車	バス	電車	地下鉄
トレーニング	14.1	13.4	4.20	12.9	15.2	12.8	15.4	12.0
テスト	17.0	12.8	5.94	8.99	22.4	15.8	11.4	5.83

ング用データとテスト用データでは各行動クラスの割合が異なり、車や地下鉄では差が大きい。しかし、どちらのデータにおいてもクラス間の不均衡が生じているため、サンプル数の調整や誤答時のペナルティなどで学習を調整する必要がある。

## 6. おわりに

本稿では、SHL Recognition Challenge における行動認識手法について述べ、コンペティション結果と、それについての議論を行った。我々の提案手法はデータを与えられた粒度より細かい 3 秒単位で分割し、ランダムフォレストを用いて認識した後に、行動の時間的な制約を利用してポストプロセッシングを行うものであった。ポストプロセッシングの有無で精度は大きく変化し、F1 値で 0.879 から 0.942 まで改善された。

提案手法はコンペティション 7 位の結果を獲得した。コンペティションに参加した他チームでもポストプロセッシングは利用されており、効果的に認識精度の向上に寄与した。一方、我々を含め多くのチームがオーバーフィッティングする傾向であり、クロスバリデーションの適切な適用や、データの時系列に対する慎重な取り扱いによって性能を適切に評価する必要性も明らかとなった。

コンペティションの開催で、多くの研究者がそれぞれ異なる戦略で同じ挑戦を行った。その結果、行動認識技術の発展に対して、何が効果的であったか・何に気をつけるべきかなどの知見が蓄積されたといえる。

今後の課題としては、提出された各手法の要点を組み合わせ、より高精度な行動認識の実現が考えられる。また、今回のコンペティションでは 1 人のセンサデータしか与えられなかったため、複数人のデータを用いて人に依存しにくい認識を行う必要がある。

## 文 献

[1] D. Roggen, A. Calatroni, M. Rossi, T. Holleczeck, K. Föörster, G. Tröörster, P. Lukowicz, D. Bannach, G. Pirkel, A. Ferscha, J. Doppler, C. Holzmann, M. Kurz, G. Holl, R. Chavarriaga, H. Sagha, H. Bayati, M. Creatura, and J. d. R. Millán. Collecting complex activity datasets in highly rich networked sensor environments. In *2010 Seventh International Conference on Networked Sensing Sys-*

*tems (INSS)*, pp. 233–240, 2010.

- [2] P. Lukowicz, G. Pirkel, D. Bannach, F. Wagner, A. Calatroni, K. Foerster, T. Holleczeck, M. Rossi, D. Roggen, G. Troester, J. Doppler, C. Holzmann, A. Riener, A. Ferscha, and R. Chavarriaga. Recording a complex, multi modal activity data set for context recognition. In *23th International Conference on Architecture of Computing Systems 2010*, pp. 1–6, 2010.
- [3] 鷺澤史歩, 中田康之, 猪又明大, 柳沼義典. 小型のウェアラブルセンサを用いた姿勢計測. マルチメディア, 分散, 協調とモバイルシンポジウム (DICO2014), 2014.
- [4] 渡邊光, 村尾和哉, 望月祐洋, 西尾信彦. 加速度センサを用いたジェスチャ認識における連続動作の認識手法. マルチメディア, 分散, 協調とモバイルシンポジウム (DICO2016), 2016.
- [5] K. Kaji, H. Watanabe, R. Ban, and N. Kawaguchi. HASC-IPSC: Indoor Pedestrian Sensing Corpus with a Balance of Gender and Age for Indoor Positioning and Floor-plan Generation Researches. In *International Workshop on Human Activity Sensing Corpus and Applications (HASCA2013)*, UbiComp '13 Adjunct, pp. 605–610, 2013.
- [6] H. Ichino, K. Kaji, K. Sakurada, K. Hiroi, and N. Kawaguchi. HASC-PAC2016: Large Scale Human Pedestrian Activity Corpus and Its Baseline Recognition. In *International Workshop on Human Activity Sensing Corpus and Applications (HASCA2016)*, UbiComp '16, pp. 705–714, 2016.
- [7] H. Gjoreski, M. Ciliberto, F. J. Ordoñez Morales, D. Roggen, S. Mekki, and S. Valentin. A Versatile Annotated Dataset for Multimodal Locomotion Analytics with Mobile Devices. In *the 15th ACM Conference on Embedded Network Sensor Systems*, Vol. 4 of *SenSys '17*, pp. 61:1–61:2, 2017.
- [8] Y. Yuki, J. Nozaki, K. Hiroi, K. Kaji, and N. Kawaguchi. Activity Recognition using Dual-ConvLSTM Extracting Local and Global Features for SHL Recognition Challenge. In *International Workshop on Human Activity Sensing Corpus and Applications (HASCA2018)*. ACM, 2018.
- [9] F. J. Ordóñez, D. Roggen. Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition. *Sensors*, Vol. 16, No. 1, 2016.
- [10] L. Wang, H. Gjoreski, K. Murao, T. Okita, and D. Roggen. Summary of the Sussex-Huawei Locomotion-Transportation Recognition Challenge. In *International Workshop on Human Activity Sensing Corpus and Applications (HASCA2018)*, 2018.
- [11] P. Widhalm, M. Leodolter, and N. Brändle. Top In The Lab, Flop In The Field? Evaluation Of A Sensor-based Travel Activity Classifier With The SHL Dataset. In *International Workshop on Human Activity Sensing Corpus and Applications (HASCA2018)*, 2018.