

# 深層学習を用いた歩行時における スマートフォンの所持位置推定

長谷川 達人<sup>1,a)</sup> 越野 亮<sup>2</sup>

受付日 2015年12月11日, 採録日 2016年7月5日

**概要:** 本研究では, スマートフォン標準搭載のセンサを複合的に用いて DNN (Deep Neural Network) で学習させることで, スマートフォンが利用者の身体上のどの位置に所持されているのかを推定するシステムを開発する. スマートフォンの所持位置が推定できることで, ポケットの中での誤動作防止や, 位置に応じた通知方法の自動変更など, 様々なコンシューマサポートが実現できる. 本研究では, 利用者がスマートフォン所持中に最もとりやすい動きである歩行を対象に, ズボン前ポケット, ズボン後ポケット, 胸ポケット, 内ポケット, ジャケットポケット, 靴, 手という所持位置 7 種類の推定を行う. 被験者 16 人に対して実験を行い, Leave-one-subject-out Cross-Validation (LOSO-CV) で推定精度を評価した結果, 81.7%の精度で所持位置 7 種類を推定し, 胸ポケットと内ポケットを区別しない 6 種類の推定では 86.7%の推定精度を達成した. また, センサを複合的に用いることで推定精度が向上するという点や, 加速度センサの値の扱い方によって推定精度が向上することを明らかにした.

**キーワード:** スマートフォン, 所持位置推定, 機械学習, コンテキストアウェアネス

## Detection of Smartphone Wearing Position in Walking Using Deep Learning

TATSUHITO HASEGAWA<sup>1,a)</sup> MAKOTO KOSHINO<sup>2</sup>

Received: December 11, 2015, Accepted: July 5, 2016

**Abstract:** In this study, we develop a system detecting a smartphone wearing position on the user's body. This system detects the wearing position by DNN (Deep Neural Network) using observed multiple sensor values. If the smartphone wearing position can be detected, it will be applied to some consumer support applications, such as pocket dialing prevention and automatic changing the notification method according to the wearing position. Proposed method detects seven wearing positions such as "in the trousers front pocket", "in the trousers back pocket", "in the chest pocket", "in the inner pocket", "in the jacket pocket", "in the hand", and "in the bag" when the user is walking. We performed an experiment to collect sensor values for 16 participants. As a result of the evaluation by Leave-one-subject-out Cross-Validation (LOSO-CV), proposed method could classify seven positions with 81.7% accuracy. Moreover, in the case that a chest pocket is regarded as the same position with an inner pocket, proposed method could detect six positions with 86.7% accuracy. This paper also describes that using multiple sensors increases the accuracy of detection, and proposed processing method for accelerometer increases the accuracy of detection.

**Keywords:** smartphone, detection of the wearing position, machine learning, context-awareness

<sup>1</sup> 東京医療保健大学医療保健学部医療情報学科  
Division of Healthcare Informatics, Faculty of Healthcare,  
Tokyo Healthcare University, Setagaya, Tokyo 154-8568,  
Japan

<sup>2</sup> 石川工業高等専門学校電子情報工学科  
Department of Electronics and Information Engineering, National Institute of Technology, Ishikawa College, Tsubata,  
Ishikawa 929-0392, Japan

## 1. はじめに

本研究では, スマートフォンの所持位置を推定するシステムを提案する. スマートフォンの所持位置とは, ズボン

<sup>a)</sup> t-hasegawa@thcu.ac.jp

表 1 スマートフォンの所持位置推定の関連研究  
Table 1 Related studies about detecting the smartphone wearing position.

引用	推定する位置	学習手法	使用センサ	被験者の動作	評価方法	被験者数
[1]	手, ポケット (前, 後, ジャケット), ビデオ閲覧, 通話	NB, MLP, LR, J48	加速度, ジャイロ	歩行	10-fold CV	10 人
[2]	手, ズボンポケット, ベルト, 鞆	SVM, J48, Bayesian-Network, LogitBoost	加速度, ジャイロ, 地磁気	歩行	CV	8 人
[3]	上腕, 前腕, ウエスト, 太もも, すね, 頭	GridSearch + SVM	加速度	歩行	CV	25 人
[4]	ポケット (前, 後, ジャケット, 胸), 首, 鞆 (4 種類)	SVM, NB, MLP, J48, RandomSubspace	加速度	歩行	LOSO-CV	20 人
[5]	手, ポケット, 鞆, ベルト	SVM + HMM	加速度	歩行, 直立, 着座	LOSO-CV	12 人
[6]	手, ポケット (前, 後, 胸)	SVM	加速度, ジャイロ	歩行	5-fold CV	4 人

の前ポケットの中や, 手に持っているなどの「スマートフォンが利用者の身体上のどの位置に所持されているのか」と定義する. コンテキストウェアネスの研究分野では, 各種センサを用いて利用者の状況を推定する研究がさかに行われている [7], [8], [9]. これらの研究では各種センサによる観測値を分析することで, 利用者の行動認識を行っているが, センサ値はセンサ自体の所持位置に依存することも知られている [1]. そのため, スマートフォンの所持位置を把握する技術が望まれており, スマートフォンの所持位置推定システムを実現することで, 位置に応じた, より正確な行動認識を実現できると考えられる.

Lopez-Tovar らの調査 [10] によると, 利用者の予定やスマートフォンの所持位置によって通知方法を適切に変更することが望まれている. そのほかにも, タッチパネル式のスマートフォンにおいては, 鞆やポケットの中での誤動作が問題となることがあるが, スマートフォンの所持位置が分かることで, ポケットや鞆の中にある際に誤動作を防止するなどの応用が可能となる. また, Fujinami らの研究 [11] でも提案されているように, ポケットの種類や鞆などの詳細な所持位置が分かると, 格納場所に応じて利用者が気づきやすい音量設定やバイブレーション設定に自動で変更することも可能となる. したがって, スマートフォンの所持位置推定システムを実現することで, 位置に応じたコンシューマサポートが実現できる.

## 2. 関連研究と本研究の位置づけ

### 2.1 関連研究

スマートフォンの所持位置推定の関連研究を表 1 にまとめた. Alanezi らの研究 [1] では, スマートフォンの所持位置によってコンテキスト推定に大きな影響を与えることを示し, 所持位置の推定を行っている. Hoseinitabatabaei らの研究 [2] では, 利用者の向いている方向を高精度に推定するためにスマートフォンの所持位置の推定を行っている. Vahdatpour らの研究 [3] では, 健康や医療のモニタリング時の測定精度を保証するためにセンサ位置の推定を

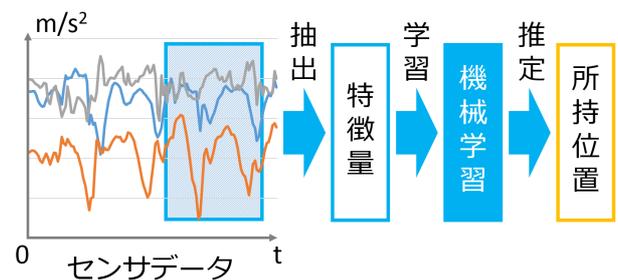


図 1 機械学習による所持位置推定方法

Fig. 1 Detecting a smartphone's wearing position by machine learning.

行っている. Fujinami らの研究 [4] では, 行動認識などの精度向上を目的とし, 多種類の格納場所を対象にスマートフォンの所持位置推定を行っており, のちに環境センシングシステムに応用している [12]. その他 [5], [6] においても, スマートフォンの所持位置を推定する手法が研究されている.

これらの研究では, 推定する位置の種類や使用する特徴量の種類は異なるものの, 共通して一定区間のセンサデータから機械学習による推定を行っている. システムは加速度センサやジャイロセンサを用いてスマートフォンの動きを観測し, 図 1 のように, 一定長のウィンドウごとに特徴量の抽出を行い, 機械学習によって所持位置を推定している. このような手法を用いる利点は主に 2 つある. 1 つは, 所持位置を知りたいとイベントを発生してから推定するまでのタイムラグが短いという点である. サンプル周波数 50 Hz でウィンドウサイズを 256 サンプルとする場合, 最大で約 5.12 秒の遅延しか発生しない. もう 1 つは, センサを常時稼働しなくてもウィンドウサイズ分のセンサデータを観測するだけで推定ができるため, センサ稼働時間を短くすることができるという点である.

このような推定手法に対して推定精度を向上させる手法や, 歩行時以外に拡張する手法も提案されている. Alanezi らの研究 [1] では, 利用者が歩行状態である場合にのみ機械学習による推定を行い, その他の状態である場合は以前

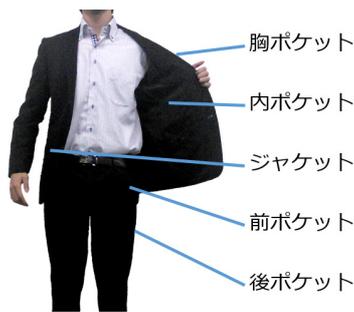


図 2 推定対象とするポケット 5 種類

Fig. 2 Five kinds of pockets our system detects.

の所持位置を引き継ぐという仮定でキャッシュを用いている。Fujinami らの研究 [4] では、連続的に所持位置推定を行う際にごく短期間にだけ所持位置が変更されることはないという仮定から、スムージングによる精度向上を行っている。スムージングでは連続監視した 11 出力から多数決で状態を決定する手法をとっている。Antosa らの研究 [5] では、機械学習による推定結果に対し HMM を用いて推定精度の向上を行っている。

## 2.2 本研究の位置づけ

本研究では、新たな特徴量のとり方と DNN (Deep Neural Network) の応用により、高精度なスマートフォン所持位置推定を実現する。既存研究と同様に、1 日で最も行われる定常動作である歩行に着目し、歩行時の所持位置推定を行う。なお、直立や着座など停止状態においては、スマートフォンの所持位置によってセンサの観測値が大きく変動しないことから、今回推定対象にはせず、河内らの端末格納動作を用いた研究 [13] や、Hwang らのバイブレーションの反響を用いた研究 [14] のように別のアプローチを今後模索していくものとする。推定対象の所持位置は、表 1 の関連研究で多く研究されており重要な所持位置である「ポケット」、「手」、「鞆」とする。なおポケットに関しては様々な種類があるが一般的な正装をモデルに、図 2 に示す「ズボン前ポケット」、「ズボン後ポケット」、「胸ポケット」、「内ポケット」、「ジャケットポケット」の 5 種類を対象とした。手持ちに関しても図 3 のように、歩行時に起こりうる「画面を見る」状態と「手を下げる」状態を対象とし、それらをまとめて「手」と定義している。

これらをふまえ本研究の位置づけは、特徴量のとり方を再考し、かつ DNN を応用することでスマートフォンの所持位置 7 種類の推定精度を向上させるという点である。すなわち、重要な所持位置と考えられる 7 種類の推定課題に対し、提案手法ではスマートフォンの各種センサを用いた特徴量の抽出と、識別モデルに Deep learning を用いることで関連研究に対し識別精度が向上することを示す。前述したキャッシュやスムージング、HMM などの時系列的手法を用いた推定精度向上には焦点を当てない。時系列的

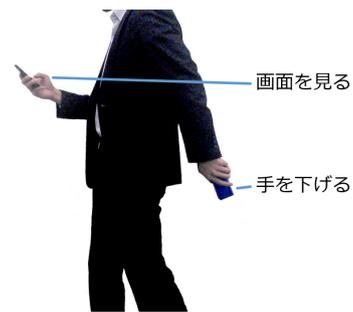


図 3 手に持っているパターン 2 種類

Fig. 3 Two patterns of a smartphone's position in the user's hand.

手法は推定精度の向上につながるが、前段階である機械学習の推定結果が高精度であることにこしたことはなく、むしろ高精度であることを前提とする補正手法である。したがって本研究では、センサの生データから一定のウィンドウの特徴量を抽出し機械学習により状態を推定するという部分の推定精度向上に着目する。ただし、関連研究とは推定する所持位置の種類や、特徴量、評価手法などの前提が異なるため、本研究の対象とする 7 状態識別において既存手法を再現し推定精度を比較することで提案手法の有用性を示す。

## 3. 提案手法

本システムはスマートフォンから観測できるセンサ値を入力とし、リアルタイムなスマートフォンの所持位置を出力する。推定手法の概要は関連研究と同様に図 1 の処理を行い、特徴量の抽出方法と機械学習手法で差別化を図っている。所持位置の推定に影響を及ぼすであろうということから、センサは Android スマートフォンに一般的に搭載されている 4 センサ (加速度センサ、ジャイロセンサ、照度センサ、近接センサ) を観測対象とした。サンプリング周波数は約 50 Hz (Android における SENSOR\_DELAY\_GAME) と設定している。照度センサや近接センサに関しては、端末によってイベント駆動であり、サンプリング周波数が大きく異なる。特徴量の抽出方法や機械学習手法に関しては次節より詳細に説明する。

### 3.1 利用するセンサ

本研究では加速度センサ、ジャイロセンサ、照度センサ、近接センサを利用する。加速度センサは重力成分と加速度成分に分離して用いる。加速度成分は利用者の動きや静止を観測することができ、関連研究でも重力成分を除いて識別が行われている。関連研究では、重力成分は端末の方向に強く影響を受けてしまうことが懸念されるという理由から、重力成分を用いていなかった。しかし、本研究では重力成分は重要であると考え特徴量として採用した。ただし、端末の向きに影響を受けることや利用者の体勢に影響を受



図 4 加速度センサの軸方向  
Fig. 4 Axial direction of the accelerometer.

けることが予想されるため、実験時に上下 2 種類の向きでのスマートフォン格納や、画面を見る・見ない 2 種類の手持ち方法で学習データを取得している。照度センサと近接センサは一般的にスマートフォン端末上部に装備されているセンサで、周囲の明るさと物体の近接を検出することができるセンサである。ポケットの中と鞆の中、手持ちの間には照度や物体の近接が識別に役立つと考え採用した。

Android スマートフォン搭載の加速度センサの軸方向は図 4 のとおりである。画面を上にして机上においた場合、Z 軸に重力加速度である 9.8 が観測される。端末の動きを観測するには、重力成分と加速度成分を分離して考えることが望ましい。本システムでは、観測した加速度センサ値に対して式 (1) のローパスフィルタを適用し重力成分を抽出し、加速度センサ値から重力成分を減ずることで加速度成分を抽出する。なお、時刻  $i$  における  $x$  軸センサ値を  $X(i)$ 、 $x$  軸重力成分を  $G_x(i)$  とし、係数  $\alpha$  は 0.05 とした。

$$G_x(i) = \alpha X(i) + (1 - \alpha)G_x(i - 1) \quad (1)$$

本研究の特徴として、上記の重力成分を用いることのみかに加速度の生データを用いることをあげる。関連研究では、重力に関する議論を行わず、加速度センサの生データから特徴量を抽出しているものや、生データから重力を除いて特徴量を抽出するものがある。本研究では加速度成分と重力成分を分離しその両方から特徴量を抽出すると述べた。本研究ではさらに、加速度の生データからも特徴量を抽出することで、分離による情報量の低下を防止する。

### 3.2 特徴量の抽出

図 1 の処理のとおり、まず各センサ値から一定長のウィンドウに区切って特徴量を抽出する。本稿では応答性を考慮した結果、256 サンプルを 1 フレームとして使い、実験用のデータセット生成時にはこれを 10 サンプルずつスライドして特徴量を生成している。

次に、ウィンドウ内のセンサ値から特徴量を計算する。学習時にはこれに正解となるラベルを付与する。実際のデータは停止、歩行、走行などの間に動作の切替え区間が存在する。フレーミングの際にも両状態が混在する区間は

抽出されるが、今回は学習データ、テストデータにそのような複数状態を含むサンプルは対象としない。したがって、運用時に連続的に推定を行う場合、走行から歩行などへ動作を変更した際に最大 1 フレーム分 (256 サンプル=約 5.12 秒) 推定が遅延する可能性がある。

加速度センサを用いた行動認識の関連研究を含め調査した結果、研究によって様々な特徴量が利用されていたため、本研究では、関連研究で使用されていた特徴量を集約し、付録の表 A-1 のすべてを対象とした。特徴量は  $x$ ,  $y$ ,  $z$  軸と、本研究では新たに合力  $r$  (Resultant force) に関しても、それぞれ算出している。対象となるセンサは表 A-1 の右側半分の列に対応しており、○となっている欄の特徴量を算出する。したがって、加速度の生データ (230 次元)、加速度成分 (230 次元)、重力成分 (74 次元)、ジャイロ (230 次元)、照度 (11 次元)、近接 (11 次元) の合計 786 次元を対象としている。次元数が多くなりすぎることによって次元の呪い問題に陥るが、特徴選択や次元圧縮を行う機械学習アルゴリズムを採用することで対応する。

表にある絶対値の平均値とは、元データの絶対値に対し平均を算出するものである。二乗平均平方根とは値の二乗を合計して平方根を算出するものである。第 1 四分位数、中央値、第 3 四分位数は、ウィンドウ内の離散値を昇順に並べ、4 分の 1、2 分の 1、4 分の 3 の位置になる値である。動きの激しさ (Intensity) [15] は、標準サイズを  $n$ 、 $x$  軸センサ値を  $X(i)$  ( $i: 1, 2, 3, \dots, n$ ) とするとき、式 (2) で計算され、センサ値の変動の激しさを定義している。今回タイムインターバルが一定になるため、一部計算を省略している。歪度 (Skewness)、尖度 (Kurtosis) [16] は、同様に標準サイズを  $n$ 、 $x$  軸センサ値  $X(i)$  ( $i: 1, 2, 3, \dots, n$ ) の平均を  $\bar{X}$ 、不偏標準偏差を  $u$  とすると、式 (3)、(4) で計算される。ゼロ交差率 (ZCR) [17] は平均値と観測値が交わった回数の比率である。周波数成分に関しては、256 サンプルを FFT 処理し、全周波数領域、低周波数領域、中周波数領域、高周波数領域で同様の特徴量を算出している。なお、低周波数領域は 0~4.2 Hz、中周波数領域は 4.2~8.4 Hz、高周波数領域は 8.4~12.6 Hz としている。

$$Intensity = \frac{1}{n-1} \sum_{i=1}^{n-1} |X(i) - X(i+1)| \quad (2)$$

$$Skewness = \frac{n}{(n-1)(n-2)} \sum_{i=1}^n \left( \frac{X(i) - \bar{X}}{u} \right)^3 \quad (3)$$

$$Kurtosis = \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{i=1}^n \left( \frac{X(i) - \bar{X}}{u} \right)^4 - \frac{3(n-1)^2}{(n-2)(n-3)} \quad (4)$$

### 3.3 深層学習

近年、深層学習 (Deep Learning) が画像認識や音声認

表 2 被験者 16 人の詳細  
Table 2 Detail of 16 participants.

ID	年齢	性別	利用機種	トップス	ボトムス	靴	鞆	実験環境
A	21	男	Xperia Z3	デニムジャケット	チノパン	スニーカー	ショルダーバッグ	大学屋内
B	21	男	Galaxy Note 3	パーカー	チノパン	スニーカー	リュックサック	大学屋内
C	22	男	Galaxy S2	テラードジャケット	チノパン	スニーカー	リュックサック	大学屋内
D	23	男	Nexus 5	スーツ	スーツ	革靴	ブリーフケース	大学屋内
E	23	男	Nexus 5	スーツ	スーツ	革靴	ブリーフケース	大学屋内
F	23	男	Galaxy S2	スーツ	スーツ	スニーカー	ブリーフケース	大学屋内
G	23	男	Xperia Z3 Compact	テラードジャケット	ジーンズ	スニーカー	リュックサック	大学屋内
H	26	男	Galaxy Note 3	テラードジャケット	ジーンズ	スニーカー	ブリーフケース	大学屋内
I	29	男	Galaxy S2	スーツ	スーツ	革靴	ブリーフケース	屋外 (夜)
J	31	男	Nexus 5x	スーツ	スーツ	革靴	ブリーフケース	大学屋内
K	33	男	Xperia Z3 Compact	テラードジャケット	ジーンズ	スニーカー	リュックサック	大学屋内
L	25	女	Galaxy S2	マウンテンジャケット	ジーンズ	スニーカー	リュックサック	屋外 (夕方)
M	27	女	Galaxy S2	トレンチコート	ジーンズ	ヒール	ショルダーバッグ	駅屋内
N	27	女	Xperia A4	スーツ	スーツ	靴下	バケットバッグ	一般家庭屋内
O	29	女	Galaxy S2	テラードジャケット	スカート	ヒール	ショルダーバッグ	屋外 (夜)
P	36	女	Galaxy S2	白衣	ジーンズ	サンダル	トートバッグ	大学屋内

識の分野において高い識別精度を実現している。深層学習は、狭義には様々な定義がなされているが、一般的には多くの層を持ったニューラルネットワークを用いた機械学習手法である。ニューラルネットワークは、Rosenblatt が脳のニューロンの動きをもとに提案したパーセプトロン [18] が起源となり、1986 年、Rumelhart らが誤差逆伝播法 [19] を提案し、3 層を超える MLP (Multilayer Perceptron) の性能を大きく改善した。しかし、層の深い MLP では勾配消失により学習が進まなくなるという課題があった。その後、2006 年に Hinton らが提案した、制限ボルツマンマシンを積み重ねた DAE (Deep Autoencoder) [20] が Deep Learning の始まりとなった。

本研究では、階層型の深層ニューラルネットワーク (DNN) を、スマートフォンの所持位置推定課題に適用することで、推定精度の向上に取り組む。Deep Learning の中には、生データから特徴抽出を含めて学習を行うものも存在するが、本研究では特徴量は前述の手法で抽出し Dropout を用いた DNN を用いて学習を行う。Dropout [21] は深層学習の成功に大きく影響を及ぼしたアルゴリズムであり、各層でいくつかのノードをランダムに消した状態で学習を行うことで、ニューラルネットワークの弱点である過学習を防ぐ手法である。訓練事例ごとに削除するノードがランダムに変わるため、結果的に複数の DNN モデルを学習し、それらの予測結果の幾何平均を利用することで過学習を起りにくくしている。

## 4. 評価実験と考察

### 4.1 実験概要

提案手法による精度評価の実験を行った。被験者は加速度センサ、ジャイロセンサ、照度センサ、近接センサを記

表 3 機械学習アルゴリズムごとの推定精度比較結果

Table 3 Experimental result of the accuracy of detection comparison for each machine learning algorithm.

	J48	SVM	RF	DNN
Accuracy	60.7%	68.0%	73.2%	80.5%

録するアプリケーションを作動させた後、各所持位置にスマートフォンを格納し歩行する。歩行は 1 分程度行い、その間に U ターンやカーブを含んでいる。実験場所が被験者によって異なるため、直進のみの被験者も数名存在する。ただし手の中の場合は、手を下げてスマートフォンを見ずに持っているだけの状態と、歩きスマホのように画面を見ながらの状態の 2 種類 (図 3) を実施する。また、今回重力成分を取り扱うことから各ポケット実施時には、ポケットにスマートフォンを上向きで格納した場合と下向きで格納した場合の 2 種類を実施する。

被験者は表 2 の 16 人である。服装は各自測定時に着用していたものを用いているため、被験者によってはポケットが 5 種類ないこともある。また、機種によっては画面オフ時にジャイロセンサが欠損することもあり、次節以降では格納場所ごとにインスタンス数に若干偏りが生じている。

提案手法の有用性を評価するために、提案手法による推定精度が既存のものよりも向上することを示す。しかし、関連研究では表 1 に示したとおり推定する所持位置や学習手法、使用センサや特徴量、評価方法、被験者数と様々な条件が異なっていることから、関連研究との推定精度の比較は容易ではない。したがって、本研究の対象とする推定課題 (所持位置 7 種類の推定) において、学習手法と使用する特徴量を変動させることで既存手法を再現し、推定精度の差を考察することで、本提案手法の有用性を示す。

表 4 DNN による推定結果

Table 4 The result of detection by DNN.

	front	back	chest	inner	jacket	bag	hand	Precision
front	2772	190	0	18	45	10	0	91.3%
back	231	2606	51	22	12	0	0	89.2%
chest	8	142	2074	693	154	30	0	66.9%
inner	1	31	259	977	222	35	0	64.1%
jacket	102	78	41	343	2328	101	42	76.7%
bag	4	11	32	37	196	2095	97	84.7%
hand	0	1	27	26	11	227	2953	91.0%
Recall	88.9%	85.2%	83.5%	46.2%	78.4%	83.9%	95.5%	81.7%

表 6 胸ポケットと内ポケットを合成した DNN による推定結果

Table 6 The DNN's result of detection combined chest and inner.

	front	back	chest +inner	jacket	bag	hand	Precision
front	2772	190	18	45	10	0	91.3%
back	231	2606	73	12	0	0	89.2%
chest+inner	9	173	4003	376	65	0	86.5%
jacket	102	78	384	2328	101	42	76.7%
bag	4	11	69	196	2095	97	84.7%
hand	0	1	53	11	227	2953	91.0%
Recall	88.9%	85.2%	87.0%	78.4%	83.9%	95.5%	86.7%

評価手法に関しては、自己データを含むすべてのデータから Cross-Validation 評価を行った場合、精度が良くなる事が確認されている [4]。本研究においても同様に高精度を記録した。そのため、自己データを学習させない Leave-one-subject-out Cross-Validation (LOSO-CV) という手法で精度評価を実施した。LOSO-CV は対象者 1 人をテストデータ、残りを学習データとして Cross-Validation を行う評価手法である。なお、評価データは歩行時のデータから各所持位置につき 1 人最大 200 インスタンスをランダムサンプリングしてデータセットを生成した。

#### 4.2 提案手法の推定精度評価

まず、機械学習アルゴリズムごとに標準パラメータで推定精度を比較した (表 3)。使用する特徴量は付録の表 A.1 をすべて用いている。一般的によく用いられるアルゴリズムである J48 [22], Support Vector Machine (SVM) [23], Random Forest (RF) [24] と DNN における推定精度の比較を行った。特徴量数が多いこともあり、提案手法である DNN が 80.5%, 内部で特徴選択を行う RF が 73.2% と高い推定精度となった。

次に、RF と DNN のパラメータチューニングを行った。チューニングを行ったパラメータは、RF では木の数、特徴量選択数、DNN では NN の大きさ、活性化関数の選択、反復回数、入力層のドロップアウト率である。一般的にチューニングは Grid Search で行うことが多いが、最近では

表 5 RF による推定結果

Table 5 The result of detection by RF.

	front	back	chest	inner	jacket	bag	hand	Precision
front	2657	381	1	18	182	9	0	81.8%
back	140	2216	136	79	4	0	0	86.1%
chest	18	182	1821	842	136	154	0	57.8%
inner	14	54	289	654	91	10	0	58.8%
jacket	289	226	237	518	2474	212	55	61.7%
bag	0	0	0	5	79	1798	71	92.1%
hand	0	0	0	0	2	315	2966	90.3%
Recall	85.2%	72.4%	73.3%	30.9%	83.4%	72.0%	95.9%	75.4%

表 7 胸ポケットと内ポケットを合成した RF による推定結果

Table 7 The RF's result of detection combined chest and inner.

	front	back	chest +inner	jacket	bag	hand	Precision
front	2657	381	19	182	9	0	81.8%
back	140	2216	215	4	0	0	86.1%
chest+inner	32	236	3606	227	164	0	84.5%
jacket	289	226	755	2474	212	55	61.7%
bag	0	0	5	79	1798	71	92.1%
hand	0	0	0	2	315	2966	90.3%
Recall	85.2%	72.4%	78.4%	83.4%	72.0%	95.9%	81.3%

ランダム探索が有効であるという知見も得られている [25]。今回はランダム探索を行い、ある程度の当たりをつけて網羅的な探索を行い、パラメータのチューニングを行った。最終的に、RF は木の数を 200、特徴量選択数を 12 とし、DNN は隠れ層を 3 層、ノード数を各 (512-512-512)、活性化関数を ReLU [26] (Rectified Linear Unit)、epoch 数を 2,000、入力ドロップアウト率を 0.2 とした。

本研究で提案する手法では、加速度センサから生データ・加速度成分・重力成分とジャイロセンサ、照度センサ、近接センサを用いて特徴量を抽出し、チューニングを施した 3 層の DNN で所持位置 7 種類を識別した。その推定結果の Confusion Matrix を表 4 に示す。比較のため、RF による推定結果の Confusion Matrix を表 5 に示す。まず、全体の推定精度は DNN で 81.7%, RF で 75.4% となり、提案手法が 6.3% 高い精度で推定できている。データセットのリサンプリングや、複数回の試行を行った結果、おおむね、この推定精度に収束していた。ただし、アルゴリズム自体がランダム性を含んでいるため、試行ごとに若干精度に変動があることに注意されたい。

提案手法にはさらに特徴的な結果が得られている。表 4 の胸ポケットと内ポケットに着目すると、内ポケットを胸ポケットと誤る結果が多く見られた。一般的に胸ポケットの位置は内ポケットの位置とほぼ同じであることから識別が困難になったと考えられ、関連研究では内ポケットは推定対象とされていなかった。そこで、胸ポケットと内

表 8 DNN による特徴量ごとの推定精度比較結果 (LA: 加速度成分, GR: 重力成分, RA: 加速度生データ)

Table 8 The comparison of accuracy of detection for each feature by DNN (LA: Linear Acceleration, GR: Gravity Acceleration, RA: Raw Acceleration).

		追加センサ		
		なし	ジャイロ	ジャイロ+照度+近接
加速度センサ	LA	73.5%	79.4%	79.7%
	RA	74.1%	77.9%	78.7%
	LA+GR	76.1%	80.9%	82.5%
	LA+RA	76.8%	80.6%	81.2%
	LA+RA+GR	76.9%	81.2%	81.7%

ポケットを区別しない場合を考えると、表 6、表 7 の結果が得られる。全体の推定精度は DNN で 86.7%、RF で 81.3%であり、両手法ともに推定精度が向上する。

### 4.3 使用センサごとの推定精度

特徴量の増減による推定精度の変動を考察する。多くのセンサを用いた方が識別性能が向上することは容易に想像できるが、本節では改めて推定精度の差を確認する。各センサの生データから抽出する特徴量の種類に関しては付録の表 A.1 を用いる。3.2 節で述べたように、本研究は 4 種類のセンサを用いるが、加速度センサだけは、生データ、分離した加速度成分、分離した重力成分それぞれから特徴量を抽出する。本処理を行うことによる効果を比較するため、加速度センサの処理に対して、そのまま加速度センサのみを用いた場合、ジャイロセンサを併用した場合、ジャイロセンサ・照度センサ・近接センサを併用した場合の組合せにおける推定精度の比較を行った。特徴量に変動があることで最適なチューニングを行うことが望ましいが、すべてのセンサ組合せにおける最適パラメータを求めるには時間がかかりすぎることから、今回は前節で求めた最適なパラメータにおいて、DNN、RF それぞれの使用センサごとの推定精度を比較する。

表 8 は DNN による、表 9 は RF による特徴量ごとの推定精度比較結果である。追加センサに関して、加速度センサのみ (追加センサなし) とジャイロセンサを追加する場合、ジャイロ・照度・近接センサを追加する場合で比較を行ったところ、センサを追加するほどに推定精度が高くなる傾向が見られた。特に、ジャイロセンサを追加する場合は 3~6%ほどの精度改善が見られ、さらに照度・近接センサを追加する場合は 0~2%ほどの精度改善が見られた。

続いて、加速度センサの取扱いに関して、加速度成分のみ (LA) の場合、加速度センサ生データのみ (RA) の場合、加速度成分と重力成分 (LA + GR) の場合、加速度センサ生データと加速度成分 (RA + LA) の場合、3 種類すべて (LA + GR + RA) 用いた場合で比較を行った。表 8、

表 9 RF による特徴量ごとの推定精度比較結果 (LA: 加速度成分, GR: 重力成分, RA: 加速度生データ)

Table 9 The comparison of accuracy of detection for each feature by RF (LA: Linear Acceleration, GR: Gravity Acceleration, RA: Raw Acceleration).

		追加センサ		
		なし	ジャイロ	ジャイロ+照度+近接
加速度センサ	LA	70.5%	72.1%	70.5%
	RA	68.6%	71.1%	72.8%
	LA+GR	73.3%	76.8%	76.1%
	LA+RA	71.4%	74.2%	74.9%
	LA+RA+GR	71.8%	74.3%	75.4%

表 9 の双方より、既存手法で用いられている LA や RA のみを用いるよりも、LA と RA 両方もしくは LA と GR 両方を用いたほうが、推定精度が 2~3%ほど高くなるという結果が得られた。LA, RA, GR すべて併用することで推定精度が 0.5%ほど高くなるという結果も得られた。ただし、一部で LA+GR が最も高い推定精度を記録するという特徴が見られた。重要度の低い特徴量を追加しすぎることによって推定精度が低下している可能性があるが、アルゴリズムの特性上ランダム性を含むことで起こった可能性もある。

以上から、センサは多く追加する方が推定精度が向上するが、照度・近接センサの影響は大きくはないという点、DNN を用いた場合は加速度センサの値を加速度成分と重力成分に分解したうえで、さらに加速度センサの生データも含めたすべてを用いる方が推定精度が高くなるという点を明らかにした。ただし、GR を追加するならば RA を追加しないほうが推定精度が上がる可能性もあることが分かった。

また、既存手法のように、加速度成分のみを用いた RF では 70.5%、加速度センサの生データを用いた RF で 68.6%、さらにジャイロセンサを併用しても 72.1%の推定精度であるのに対し、提案手法である加速度センサへの処理と DNN を用いた手法では 81.7%の推定精度となっていることから、提案手法では約 10%の推定精度向上が実現できた。同様に、胸ポケットと内ポケットを区別しない場合、加速度成分のみを用いた RF では 76.0%、加速度センサの生データを用いた RF で 75.8%、さらにジャイロセンサを併用して 75.5%であるのに対し、提案手法では 86.7%と、こちらも約 10%の推定精度向上が実現できた。

### 4.4 被験者ごとの推定精度

被験者ごとの推定精度を表 10 にまとめる。DNN の結果に着目すると、7 状態識別の最高精度は A の 97.1%、最低精度は N の 45.9%となった。推定精度が 70%に達しなかった被験者は下線付きの B, N, O の 3 人であるが、B は 6 状態識別で精度が改善され 82.4%となっている。B は

表 10 DNN と RF による被験者ごとの推定精度

Table 10 Accuracy of detection for each participant by DNN and RF (for 7 or 6 positions).

ID	DNN Accuracy		RF Accuracy	
	7 状態	6 状態	7 状態	6 状態
A	97.1%	98.0%	95.2%	98.2%
B	68.1%	82.4%	71.4%	82.4%
C	86.6%	95.7%	88.4%	100.0%
D	83.2%	83.9%	83.1%	90.6%
E	79.8%	80.1%	82.8%	84.6%
F	89.3%	96.1%	68.1%	73.8%
G	95.4%	95.4%	82.3%	82.4%
H	85.8%	88.4%	79.1%	86.5%
I	90.5%	93.3%	66.4%	67.4%
J	81.6%	81.6%	81.6%	81.6%
K	93.1%	93.5%	81.6%	84.6%
L	71.7%	74.1%	74.0%	74.0%
M	95.7%	95.7%	91.9%	91.9%
N	45.9%	58.2%	37.4%	56.6%
O	65.7%	65.7%	52.8%	52.8%
P	71.1%	85.1%	64.2%	82.6%

パーカーを着用しており、胸ポケットの形状が横側から挿入する特殊な形状かつ位置がほぼ内ポケットと同じ高さのため胸と内で誤判定が多かったと考えられる。

6 状態識別でも 70% に達しなかったのは N, O の 2 人であり、ともに女性である。ただ、N は特殊な環境下での実験を行っており、唯一室内で靴を履いていない状態であったこと、女性であるがサイズのあっていない男性物のスーツを着用していたことが推定精度低下の原因であると考えられる。続いて O は唯一スカートを着用しており、前ポケットの形状が一般的なズボンのものよりも大きめとなっていた。誤判定パターンは前ポケットをジャケットと誤るパターンが多く、大きめの前ポケットがジャケットの動きと類似していたことが原因と考えられる。

以上より、多くの被験者に対しては 80% 以上の推定精度を達成しているが、服装によっては推定精度が下がる可能性があることが明らかとなった。特に、サイズの合っていない服を着ている利用者や、ポケットのサイズや形状が一般的な正装と異なる場合、誤判定が多くなることが分かった。しかし、これは学習データに該当する情報が含まれていないことが原因とも考えられるため、今後、そのような服装の学習データを増やすことで改善できる可能性がある。ただしそれによって、本来想定している正装の被験者の推定精度が低下する可能性がある点は注意が必要である。

## 5. おわりに

本研究では、手、胸ポケット、内ポケット、ジャケットポケット、ズボン前ポケット、ズボン後ポケット、鞆というスマートフォンの所持位置 7 種類を、加速度センサ、ジャ

イロセンサ、照度センサ、近接センサを用いて推定するシステムを提案した。提案手法では、観測したセンサの生データを一定のウィンドウで区切って、平均や分散などの様々な特徴量を抽出し、機械学習によって所持位置の推定を行う。スマートフォンがどの位置にあるかが分かることで、利用者の行動認識研究の精度向上につながる可能性があり、その所持位置に応じた通知方法の変更や誤動作の防止など操作性改善への応用も期待できる。

提案手法として、新たな特徴量の組合せと、DNN による学習を用いて推定を行う手法を提案した。その結果、16 人の被験者に対する LO-SO-CV による評価で、81.7% の推定結果を達成し、既存手法よりも推定精度を改善することに成功した。また、胸ポケットと内ポケットは位置が近いことから、同じ場所であると仮定した場合、提案手法で 86.7% の推定精度を達成した。

得られた知見は大きく分けて 3 点である。1 点目は、あたり前ではあるがセンサを増やすことで推定精度が向上するという点である。加速度センサだけでなくジャイロセンサ、照度センサ、近接センサを併用することで推定精度が向上した。2 点目は、加速度センサに関して、加速度成分のみを取り扱う場合よりも、加速度成分と重力成分を併用するもしくは加速度センサの生データを用いるほうが推定精度が高く、生データと加速度成分、重力成分すべて併用することでさらに推定精度が高くなるという点である。3 点目は DNN を用いることで、より高精度に歩行時のスマートフォンの所持位置を推定できるという点である。

本研究にはさらなる発展可能性がある。まず、今回の実験では被験者 16 人のデータセットでの実験となったが、それに対して所持位置 7 種類の識別では 81.7%、6 種類の識別では 86.7% という高精度な推定を実現できた。今後被験者数、サンプル数を増やし、DNN のパラメータを改善することで、さらなる精度の向上が見込めるだろう。また、本研究では一定長のウィンドウから生成できる特徴量からの所持位置識別という点にこだわって推定精度の検討を行ってきた。すなわち、本手法に加えて、関連研究で提案されている時系列に従ってスムージングを行い精度を改善する手法 [4] や、HMM を用いて精度を改善する手法 [5] を併用することで、さらなる精度の向上が見込めるだろう。

議論の余地がある点を今後の課題として 3 点述べる。1 点目は、照度センサ、近接センサによる影響に関する考察が必要であるという点である。今回、関連研究になかった照度、近接の 2 センサを追加して実験を行った。実験は夕方～夜間にかけて屋内外で行われ、暗闇の中や室内灯の灯る屋内で行われた結果を含んでいる。特に照度はこのような環境に左右されやすいことが懸念されるため、様々な状況を学習データに含めなくてはならないという点が課題とされる。2 点目は、特徴量ごとの有効度合いが不透明な点である。DNN を用いた手法を採用したため、すべての特

微量からのニューラルネットワークを構成しており、どの特徴量が有意に働くのかという点が不透明になってしまふ。この点は改善が難しいが、網羅的に様々なパターンを試すことで、最適な特徴量の組合せが発見できる可能性がある。3点目は、停止状態や歩行以外の動作への対応である。今回利用者が最も行きやすい定常的な動作である歩行を対象にして実験を行ったが、特に停止状態に関しては歩行と同様に起こりやすい状態である。しかし本手法では停止状態においてセンサ値が変動しにくいことから識別が困難であるため、別途手法を併用して停止状態における所持位置推定も実現していきたい。

### 参考文献

- [1] Alanezi, K. and Mishra, S.: Design, implementation and evaluation of a smartphone position discovery service for accurate context sensing, Vol.44, pp.307–323 (2015).
- [2] Hoseinitabatabaei, S.A., Gluhak, A. and Tafazolli, R.: Towards a position and orientation independent approach for pervasive observation of user direction with mobile phones, *Pervasive and Mobile Computing*, Vol.17, No.A, pp.23–42 (2015).
- [3] Vahdatpour, A., Amini, N. and Sarrafzadeh, M.: On-body device localization for health and medical monitoring applications, *Proc. IEEE International Conference on Pervasive Computing and Communications (PerCom2011)*, pp.37–44 (2011).
- [4] Fujinami, K. and Kouchi, S.: Recognizing a mobile phone's storing position as a context of a device and a user, *Proc. 9th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services (MobiQuitous2012)*, pp.76–88 (2012).
- [5] Antosa, S.A. and Albertb, M.V.K.P.K.: Hand, belt, pocket or bag: Practical activity tracking with mobile phones, *Journal of Neuroscience Methods*, Vol.231, No.15, pp.22–30 (2014).
- [6] Shi, Y., Shi, Y. and Liu, J.: A rotation based method for detecting on-body positions of mobile devices, *Proc. 13th international conference on Ubiquitous computing (UbiComp2011)*, pp.559–560 (2011).
- [7] Kobayashi, A., Muramatsu, S., Kamisaka, D., Watanabe, T., Minamikawa, A., Iwamoto, T. and Yokoyama, H.: Shaka: User Movement Estimation Considering Reliability, Power Saving, and Latency Using Mobile Phone, *IEICE Trans. Information and Systems*, Vol.E94-D, No.6, pp.1153–1163 (2011).
- [8] Ouchi, K. and Doi, M.: Indoor-outdoor Activity Recognition by a Smartphone, *Proc. 2012 ACM Conference on Ubiquitous Computing (UbiComp2012)*, pp.600–601 (2012).
- [9] 米田圭佑, 望月祐洋, 西尾信彦: 気圧センシング技術を用いた行動認識手法, 情報処理学会論文誌, Vol.56, No.1, pp.260–272 (2015).
- [10] Lopez-Tovar, H., Charalambous, A. and Dowell, J.: Managing Smartphone Interruptions Through Adaptive Modes and Modulation of Notifications, *Proc. 20th International Conference on Intelligent User Interfaces (IUI2015)*, pp.296–299 (2015).
- [11] Fujinami, K., Jin, C. and Kouchi, S.: Tracking On-body Location of a Mobile Phone, *Proc. 14th Annual IEEE International Symposium on Wearable Comput-*
- [12] Fujinami, K., Xue, Y., Murata, S. and Hosokawai, S.: A Human-Probe System that Considers On-body Position of a Mobile Phone with Sensors, *Proc. 1st International Conference on Distributed, Ambient and Pervasive Interactions (DAPI2013)*, pp.99–108 (2013).
- [13] 河内智志, 藤波香織: 携帯電話の格納場所連続監視手法—歩行時および格納動作時判定処理の文脈的併用, 情報処理学会研究報告 (UBI), Vol.2013, No.19, pp.1–8 (2013).
- [14] Hwang, S. and Wohn, K.: VibroFactor: Low-cost Placement-aware Technique Using Vibration Echoes on Mobile Devices, *Proc. Companion Publication of International Conference on Intelligent User Interfaces Companion (IUI2013)*, pp.73–74 (2013).
- [15] Györbíró, N., Fábíán, A. and Hományi, G.: An Activity Recognition System for Mobile Phones, *Mobile Networks and Applications*, Vol.14, No.1, pp.82–91 (2009).
- [16] Altun, K. and Barshan, B.: Human Activity Recognition Using Inertial/Magnetic Sensor Units, *Human Behavior Understanding*, Vol.6219, pp.38–11 (2010).
- [17] Yang, J.: Toward Physical Activity Diary: Motion Recognition Using Simple Acceleration Features with Mobile Phones, *Proc. 1st International Workshop on Interactive Multimedia for Consumer Electronics*, pp.1–10 (2009).
- [18] Rosenblatt, F.: The perceptron: A probabilistic model for information storage and organization in the brain, *Psychological Review*, Vol.65, No.6, pp.386–408 (1958).
- [19] Rumelhart, D.E., Hinton, G.E. and Williams, R.J.: Learning representations by back-propagating errors, *Nature*, Vol.323, pp.533–536 (1986).
- [20] Hinton, G.E. and Salakhutdinov, R.: Reducing the dimensionality of data with neural networks, *Science*, Vol.313, pp.504–507 (2006).
- [21] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R.: Dropout: A simple way to prevent neural networks from overfitting, *The Journal of Machine Learning Research*, Vol.15, No.1, pp.1929–1958 (2014).
- [22] Quinlan, J.R.: *C4.5: Programs for Machine Learning* (1993).
- [23] Cortes, C. and Vapnik, V.: Support-vector networks, *Machine Learning*, Vol.20, pp.273–297 (1995).
- [24] Breiman, L.: Random forests, *Machine Learning*, Vol.45, pp.5–32 (2001).
- [25] Bergstra, J. and Bengio, Y.: Random search for hyperparameter optimization, *The Journal of Machine Learning Research*, Vol.13, No.1, pp.281–305 (2012).
- [26] Nair, V. and Hinton, G.E.: Rectified Linear Units Improve Restricted Boltzmann Machines, *Proc. 27th International Conference on Machine Learning (ICML2010)*, pp.807–814 (2010).
- [27] Atallah, L., Lo, B., King, R. and Yang, G.-Z.: Sensor placement for activity detection using wearable accelerometers, *Proc. 2010 International Conference on Body Sensor Networks (BSN2010)*, pp.24–29 (2010).

### 付 録

本研究で利用した特徴量の一覧を表 A.1 に示す。

本研究のデータセットを用いて追試を希望される方は、筆頭著者までご連絡ください。個別に対応いたします。

表 A.1 センサごとの 1 フレームから抽出する特徴量

Table A.1 Feature vectors extracted from one frame of sensor values for each sensor.

特徴量名称	軸	生加速度	加速度	重力	ジャイロ	照度	近接
平均値	x,y,z,r	○	○	○	○	○	○
絶対値の平均値	x,y,z,r	○	○	○	○	-	-
標準偏差	x,y,z,r	○	○	○	○	○	○
絶対値の標準偏差	x,y,z,r	○	○	○	○	-	-
最小値	x,y,z,r	○	○	○	○	○	○
最大値	x,y,z,r	○	○	○	○	○	○
二乗平均平方根 [27]	x,y,z,r	○	○	○	○	○	○
第 1 四分位数	x,y,z,r	○	○	○	○	○	○
中央値	x,y,z,r	○	○	○	○	○	○
第 3 四分位数	x,y,z,r	○	○	○	○	○	○
四分位範囲	x,y,z,r	○	○	○	○	○	○
軸間の相関係数	x-y,y-z,z-x	○	○	○	○	-	-
軸間の絶対値の相関係数	x-y,y-z,z-x	○	○	○	○	-	-
フレーム内の初期値	x,y,z,r	○	○	○	○	○	○
フレーム内の最終値	x,y,z,r	○	○	○	○	○	○
動きの激しさ [15]	x,y,z,r	○	○	○	○	-	-
歪度 [16]	x,y,z,r	○	○	○	○	-	-
尖度 [16]	x,y,z,r	○	○	○	○	-	-
ゼロ交差率 [17]	x,y,z,r	○	○	○	○	-	-
周波数パワースペクトルの最大値	x,y,z,r	○	○	-	○	-	-
周波数パワースペクトルが最大の周波数	x,y,z,r	○	○	-	○	-	-
周波数パワースペクトルの 2 番目に大きい値	x,y,z,r	○	○	-	○	-	-
周波数パワースペクトルが 2 番目に大きい時の周波数	x,y,z,r	○	○	-	○	-	-
周波数パワースペクトルの標準偏差	x,y,z,r	○	○	-	○	-	-
周波数パワースペクトルの第 1 四分位数	x,y,z,r	○	○	-	○	-	-
周波数パワースペクトルの中央値	x,y,z,r	○	○	-	○	-	-
周波数パワースペクトルの第 3 四分位数	x,y,z,r	○	○	-	○	-	-
周波数パワースペクトルの四分位範囲	x,y,z,r	○	○	-	○	-	-
周波数パワースペクトルの各軸の相関係数	x-y,y-z,z-x	○	○	-	○	-	-
低周波領域の周波数パワースペクトルの最大値	x,y,z,r	○	○	-	○	-	-
低周波領域の周波数パワースペクトルが最大の周波数	x,y,z,r	○	○	-	○	-	-
低周波領域の周波数パワースペクトルの 2 番目に大きい値	x,y,z,r	○	○	-	○	-	-
低周波領域の周波数パワースペクトルが 2 番目に大きい時の周波数	x,y,z,r	○	○	-	○	-	-
低周波領域の周波数パワースペクトルの標準偏差	x,y,z,r	○	○	-	○	-	-
低周波領域の周波数パワースペクトルの第 1 四分位数	x,y,z,r	○	○	-	○	-	-
低周波領域の周波数パワースペクトルの中央値	x,y,z,r	○	○	-	○	-	-
低周波領域の周波数パワースペクトルの第 3 四分位数	x,y,z,r	○	○	-	○	-	-
低周波領域の周波数パワースペクトルの四分位範囲	x,y,z,r	○	○	-	○	-	-
低周波領域の周波数パワースペクトルの各軸の相関係数	x-y,y-z,z-x	○	○	-	○	-	-
中周波領域の周波数パワースペクトルの最大値	x,y,z,r	○	○	-	○	-	-
中周波領域の周波数パワースペクトルが最大の周波数	x,y,z,r	○	○	-	○	-	-
中周波領域の周波数パワースペクトルの 2 番目に大きい値	x,y,z,r	○	○	-	○	-	-
中周波領域の周波数パワースペクトルが 2 番目に大きい時の周波数	x,y,z,r	○	○	-	○	-	-
中周波領域の周波数パワースペクトルの標準偏差	x,y,z,r	○	○	-	○	-	-
中周波領域の周波数パワースペクトルの第 1 四分位数	x,y,z,r	○	○	-	○	-	-
中周波領域の周波数パワースペクトルの中央値	x,y,z,r	○	○	-	○	-	-
中周波領域の周波数パワースペクトルの第 3 四分位数	x,y,z,r	○	○	-	○	-	-
中周波領域の周波数パワースペクトルの四分位範囲	x,y,z,r	○	○	-	○	-	-
中周波領域の周波数パワースペクトルの各軸の相関係数	x-y,y-z,z-x	○	○	-	○	-	-
高周波領域の周波数パワースペクトルの最大値	x,y,z,r	○	○	-	○	-	-
高周波領域の周波数パワースペクトルが最大の周波数	x,y,z,r	○	○	-	○	-	-
高周波領域の周波数パワースペクトルの 2 番目に大きい値	x,y,z,r	○	○	-	○	-	-
高周波領域の周波数パワースペクトルが 2 番目に大きい時の周波数	x,y,z,r	○	○	-	○	-	-
高周波領域の周波数パワースペクトルの標準偏差	x,y,z,r	○	○	-	○	-	-
高周波領域の周波数パワースペクトルの第 1 四分位数	x,y,z,r	○	○	-	○	-	-
高周波領域の周波数パワースペクトルの中央値	x,y,z,r	○	○	-	○	-	-
高周波領域の周波数パワースペクトルの第 3 四分位数	x,y,z,r	○	○	-	○	-	-
高周波領域の周波数パワースペクトルの四分位範囲	x,y,z,r	○	○	-	○	-	-
高周波領域の周波数パワースペクトルの各軸の相関係数	x-y,y-z,z-x	○	○	-	○	-	-
特徴量の合計次元数		230	230	74	230	11	11

※生加速度は、加速度成分と重力成分を分離する前のセンサ生データを示す。

※軸列は生加速度、加速度、重力、ジャイロのみを対象としており、r は x, y, z の合力 (Resultant force) を示す。

※照度、近接は軸がなく、元データは 1 次元であり、それぞれ [0~120000], [0,1] を値域とする。

※低周波領域: 0-4.2 Hz, 中周波領域: 4.2-8.4 Hz, 高周波領域: 8.4-12.6 Hz としている。



長谷川 達人 (正会員)

2009年石川工業高等専門学校電子情報工学科卒業。2011年金沢大学工学部情報システム工学科卒業。同年株式会社富士通北陸システムズ入社。2014年より東京医療保健大学医療情報学科助手。2015年金沢大学大学院自然科学研究科博士後期課程修了。博士(工学)。専門はコンテキストウェアネスと教育工学。IEEE 会員。



越野 亮 (正会員)

2002年金沢大学大学院博士前期課程修了。同年富士通株式会社入社。2003年石川工業高等専門学校電子情報工学科助手。2004年金沢大学大学院博士後期課程修了。博士(工学)。現在、石川工業高等専門学校電子情報工学科准教授。専門はスマートフォンとライフログ。電子情報通信学会、人工知能学会、日本知能情報ファジィ学会、日本経営工学会等各会員。