

# センサ行動認識における機械学習のための 実験室高精度データと現場長時間データの比較

後藤 広樹<sup>1</sup> 武田 紳吾<sup>1</sup> Paula Lago<sup>1</sup> 大北 剛<sup>1</sup> 井上 創造<sup>1</sup>

概要： 近年のスマートフォンやスマートウォッチといったウェアラブルデバイスの普及によって、デバイス内のセンサを用いたデータの収集が容易になり、行動認識が発展している。さらに高精度なセンサとして光学式モーションキャプチャなども開発されている。本稿で扱う行動認識は、人の行動を推定する技術であり、センサデータを利用している。行動認識は社会問題である介護人材不足の解決方法の1つとされ、社会への応用が期待されている。本稿の行動認識では、教師あり機械学習技術を用い、教師データが入力された時に行動認識するための分類モデルを作成する。実験室で得られた高精度なデータを教師データとして扱う場合、その実験室でのデータが現場で得られるデータと類似している必要がある。教師データを社会現場で作成した場合と現場でない大学の実験環境で作成した場合のデータを比較し、行動認識の社会実装の際に発生する実環境と仮想環境の違いを比較する。本稿ではモーションキャプチャのデータ量を減少させることでスマートフォンのデータに対して行動認識を実施した。

## Comparison of High-precision Laboratory Data and Long-term Real Data for Machine Learning of Activity Recognition

HIROKI GOTO<sup>1</sup> SHINGO TAKEDA<sup>1</sup> PAULA LAGO<sup>1</sup> TSUYOSHI OKITA<sup>1</sup> SOZO INOUE<sup>1</sup>

### 1. はじめに

センサ行動認識とはウェアラブルデバイスから得たセンサデータを用いて、人間の行動を推定する技術である。本稿のセンサ行動認識では、教師あり機械学習技術を用い、教師データが入力された時に介護士の行動を推定するための分類モデルを作成する。介護人材不足問題 [1] への解決策として、センサ行動認識を導入する場合には介護スタッフの教師データの収集が必要である。しかし、介護スタッフが教師データの作成をすることは業務を増やすこととなり、問題を悪化させる。そのため教師データは大学などの実験室で短期間で収集され、作成された分類モデルを介護現場で使うことが考えられる。実験室データには認識対象とする行動のセンサデータのみ取得され、現場データは認識対象外の雑多な行動のセンサデータが含まれる。そのため、対象とするデータの種類によって現場での利用に影響を受けるという問題 [2] がある。

本論文はセンサ行動認識における機械学習の教師データである実験室データと現場データの比較をし、現場での利用へ向けたを比較する。

### 2. センサ行動認識

センサ行動認識とは、機械学習技術を用いてセンサデータから人の行動を推定する技術であり、ウェアラブルセンサのデータから「歩いている」「寝ている」「立ち上がる」などという行動を推定する技術である。近年のウェアラブルデバイスの普及によって、デバイス内のセンサを用いたデータの収集が容易になった。また、センサでなく、カメラを用いた行動認識もある [4]。しかし、それは観測対象者以外の情報まで誤って収集してしまうことがあり、プライバシーの問題上使用が制限されやすいため、介護施設を対象としている本研究には不向きである。センサ行動認識の一連の流れを図 1 に示す。

センサ行動認識は、過去のデータを学習データとして利用する教師あり学習を用いる。教師あり学習とは、目的変

<sup>1</sup> 九州工業大学

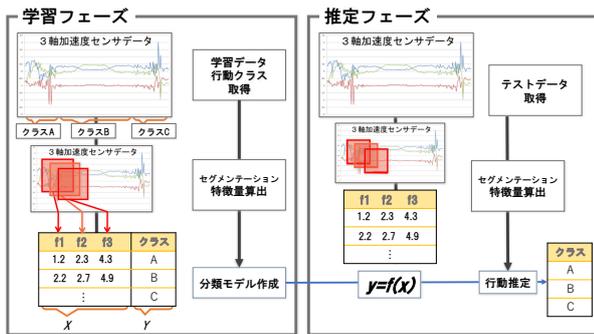


図 1 センサ行動認識のデータ入力から行動推定の出力までの流れ

数である推定する対象の種類  $y_i$  を説明変数であるデータ  $x_i$  が対となったデータセットの集合を学習データとして用いる。教師あり学習の目的は、 $x_i$  が入力された時に  $y_i$  を出力する分類モデル  $y = f(x)$  を作成することである。この分類モデル作成過程を学習フェーズ、分類モデルを適用して対象の種類を推定する過程を推定フェーズとする。センサ行動認識は、行動の種類を高精度で推定することが求められ、一般的に大量のデータが必要とされている。

### 3. 関連研究

我々の先行研究 [5] は介護施設において介護スタッフに介護記録をスマートフォンを通じて記録してもらいながら、行動認識のためのセンサデータと学習のために行動ラベルを同時に取得してクラウドサーバに蓄積し、日々の行動認識を可能とするシステムを4ヶ月使ってもらった結果、介護業務の1つである記録業務の時間を短縮することができた。さらなる時間短縮のために行動認識の精度向上が望まれ、多くのデータの用意が必要となったが、画像やテキストとは違いインターネット上に多くのセンサデータがない。センサデータを収集するにはセンサの数を一定数用意するコストがかかり、コストを下げようとすると比例してセンサの質も下がる。このような機械学習の実用化における問題はよく発生し、重要なテーマであるため機械学習工学 [3] という分野が近年生まれ、研究が盛んになっている。

### 4. 評価実験

機械学習の社会への実用化へ向け、学習データの作成環境が異なる場合の行動認識精度の変化を検証する。介護施設の介護スタッフがスマホやセンサを使用し、介護行動時に生じるセンサデータを収集した。センサデータ収集は2箇所場所で実施し、業務中に実施する行動のうち12行動(表1)を対象とした。

実験の実施場所は、1箇所目を我々の所属する大学の1室とし実験室、2箇所目を長崎県にある介護施設とし現場と呼ぶ。実験に使用したスマホは腕に固定するバンドを利用して左腕に装着した。そのほか先行研究 [5] のセンサ収集システムを利用した。

表 1 12 種類の行動

移動介助	移乗介助	体位交換
移動手引き (前から)	移乗全介助	仰臥位
移動一部介助 (横から)	移乗一部介助 (前から)	右側仰臥位
移動歩行器	移乗一部介助 (横から)	左側仰臥位
移動車椅子		臀部の持ち上げ
		水平移動



図 2 実験室におけるモーションキャプチャでのデータ収集の様子

#### 4.1 実験室における実験

被験者は介護スタッフ9名、期間は3日間、12行動を計測した。計測に使用したセンサはスマートフォン搭載の加速度センサとモーションキャプチャセンサである。スタッフ1名が計測する際には行動の計測者として我々2名以上が同席し、計測および行動のラベルづけをした。モーションキャプチャを利用した計測のため、計測する際の行動範囲を25m<sup>2</sup>の範囲に制限した。

#### 4.2 現場における実験

被験者は42名、期間は45日間、12行動に加え、12行動以外の行動を計測した。ただし12行動以外の行動の行動ラベルは記録されていない。つまり介護スタッフが業務中の行動全てにおいてセンサを装着し、データ収集に協力いただいた。計測に使用したセンサはスマートフォン搭載の加速度センサである。スタッフ1名が計測する際には計測者自身がスマートフォン上のアプリを使用して計測および行動のラベル付けをし、業務のために行動範囲には制限をしなかった。

2箇所における実験に関する情報を表2にまとめた。

#### 4.3 収集データについて

対象行動は12種類の行動であり、大きく3種類に分けられる。本稿では現場のスマートフォンデータと整合させるため、実験室のモーションキャプチャデータは全身のデータを収集したが左肘のデータのみを利用する。しかし武田

表 2 実験室実験と現場実験の概要

	現場データ	実験室データ
収集期間	31 日間	3 日間
収集場所	介護施設	大学研究室
対象人数	42 名 (介護士)	9 名 (介護士)
使用機器	モーションキャプチャ	スマートフォン
記録した行動	12 種類の行動	12 種類の行動 加速度のみの行動

表 3 学習データとテストデータの組み合わせ

	学習データ	テストデータ
パターン 1	現場スマートフォン	現場スマートフォン
パターン 2	実験室モーションキャプチャ	実験室モーションキャプチャ
パターン 3	実験室モーションキャプチャ	現場スマートフォン
パターン 4	現場スマートフォン	実験室モーションキャプチャ

らの手法を適用するためには作業量が多く、本稿では前処理のできた 2 名分のデータのみを使用する。

#### 4.4 比較手法

行動認識の機械学習アルゴリズムとしては、randomForest を用いる。機械学習時の学習と推定に利用する特徴量は平均値と標準偏差を利用する。また学習データとテストデータを現場のスマートフォンデータもしくは実験室のモーションキャプチャデータにすることで変化する行動認識精度を検証する。

#### 4.5 行動認識精度の比較結果

それぞれのパターンでの行動認識の混合行列 (図 3,4,5,6) を以下に添付する。

```

008 estimate of error rate: 50.9%
Confusion matrix:
  x1 x10 x11 x12 x2 x3 x4 x5 x6 x7 x8 x9 class.error
x1 58 8 0 1 5 17 24 41 10 1 0 1 0.6506024
x10 5 64 1 1 2 18 34 35 18 6 1 0 0.6540541
x11 1 0 0 0 0 1 2 4 0 0 0 0 1.0000000
x12 2 2 0 4 1 7 8 6 2 1 0 0 0.8787879
x2 0 0 0 0 124 1 14 2 1 0 0 0 0.1267606
x3 15 15 1 3 0 118 16 51 15 1 0 5 0.5083333
x4 22 22 0 5 23 17 187 95 17 1 3 0 0.5229592
x5 29 24 2 2 4 45 79 351 23 11 2 2 0.3885017
x6 11 12 1 2 5 11 21 27 62 2 2 1 0.6050955
x7 7 2 0 0 0 8 4 17 11 0 3 0 0.7924528
x8 0 1 0 0 0 0 7 1 4 1 0 1 1.0000000
x9 2 1 0 0 1 8 3 8 4 3 2 3 0.9142857
    
```

図 3 パターン 1 の結果 精度 53.9%

```

Confusion matrix:
  x1 x10 x11 x12 x2 x3 x4 x5 x6 x7 x8 x9 class.error
x1 2 0 0 0 1 0 1 1 1 2 1 0 0 0.7777778
x10 0 2 0 0 1 1 0 2 0 0 0 4 0 0.8000000
x11 0 1 0 1 2 1 1 1 0 1 1 1 1 1.0000000
x12 1 0 2 2 0 0 1 0 0 1 2 1 0.8000000
x2 1 1 0 1 0 0 2 0 0 3 0 2 1.0000000
x3 1 0 1 1 0 5 1 0 0 1 0 0 0.5000000
x4 1 1 0 1 2 0 0 0 0 1 2 3 1.0000000
x5 0 0 0 0 0 0 0 6 3 1 0 0 0.4000000
x6 0 0 0 0 0 0 0 3 6 1 0 0 0.4000000
x7 0 0 0 0 2 2 0 1 0 5 0 1 0.5454545
x8 0 4 1 1 0 0 3 0 0 1 0 0 1.0000000
x9 1 1 1 0 1 0 3 0 0 2 1 0 1.0000000
    
```

図 4 パターン 2 の結果 精度 99.1%

```

pre
cl  x1 x10 x11 x12 x2 x3 x4 x5 x6 x7 x8 x9
x1 1780 0 0 0 0 0 1 0 0 0 0 0
x10 1832 0 0 0 0 0 0 0 0 0 0 0
x11 29 0 0 0 0 0 0 0 0 0 0 0
x12 329 0 0 0 0 0 0 0 0 0 0 0
x2 1616 0 0 0 0 0 0 0 0 0 0 0
x3 2246 0 0 0 0 0 1 0 0 0 0 0
x4 3954 0 0 0 0 0 5 0 0 0 0 0
x5 5829 0 0 0 0 0 3 0 0 0 0 0
x6 1533 0 0 0 0 0 2 0 0 0 0 0
x7 638 0 0 0 0 0 1 0 0 0 0 0
x8 111 0 0 0 0 0 0 0 0 0 0 0
x9 392 0 0 0 0 0 0 0 0 0 0 0
    
```

図 5 パターン 3 の結果 精度 8.8%

```

pre
cl  x1 x10 x11 x12 x2 x3 x4 x5 x6 x7 x8 x9
x1 0 0 0 0 2 0 1 0 0 6 0 0
x10 0 0 0 0 0 0 0 0 0 10 0 0
x11 0 0 0 0 0 0 0 0 0 10 0 0
x12 0 0 0 0 0 0 0 0 0 10 0 0
x2 0 0 0 0 1 0 0 0 0 9 0 0
x3 0 0 0 0 0 0 0 0 0 10 0 0
x4 0 0 0 0 0 0 0 0 0 11 0 0
x5 0 0 0 0 0 0 0 0 0 10 0 0
x6 0 0 0 0 0 0 0 0 0 10 0 0
x7 0 0 0 0 0 2 0 0 0 9 0 0
x8 0 0 0 0 0 0 0 0 0 10 0 0
x9 0 0 0 0 0 0 0 0 0 10 0 0
    
```

図 6 パターン 4 の結果 精度 8.2%

#### 4.6 特徴量の比較結果

モーションキャプチャとスマートフォンのデータの特徴量を図 7,8,9,10 に可視化した。縦軸は頻度、横軸は特徴の値を示している。横軸の値に差があるため 4 つの図に分けた。

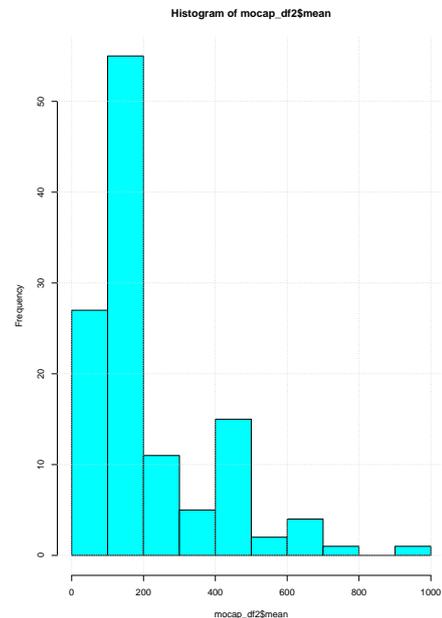


図 7 モーションキャプチャデータの平均

#### 4.7 考察

それぞれの特徴量が異なる値を取っていたため行動認識結果も自明の結果となった。パターン 2 においては非常に高精度だが、これは過学習によるものだと考える。今後今

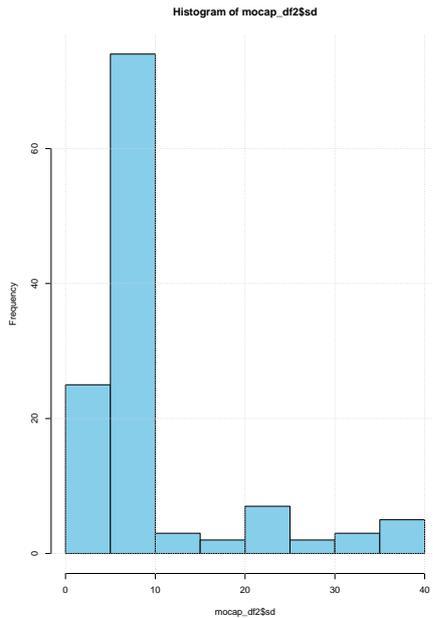


図 8 モーションキャプチャデータの標準偏差

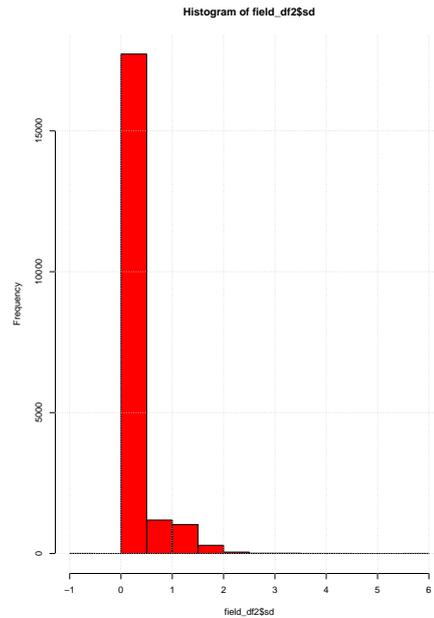


図 10 スマートフォンデータの標準偏差

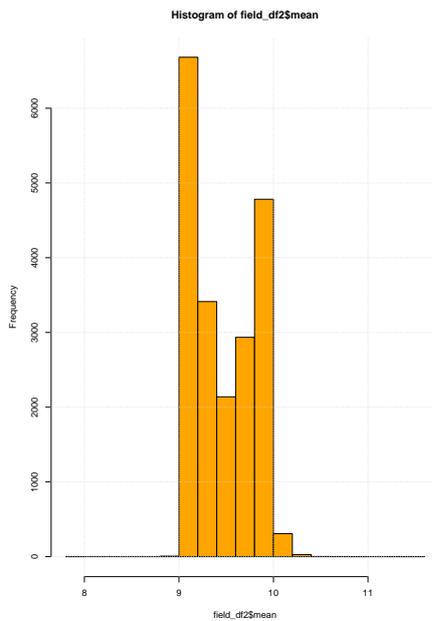


図 9 スマートフォンデータの平均

回使用しなかった残りの7名分のモーションキャプチャデータと比較する必要がある。

## 5. おわりに

本稿ではモーションキャプチャのセンサデータ量を減少させることでスマートフォンのセンサデータ量に近づけ、行動認識を行なったが、優れない結果となった。そのためモーションキャプチャのセンサデータ量を減らさずに行動認識する手法を今後研究する。また実験室と現場で被験者の行動に差異が生じる可能性もあり、その差異についても検証する。

## 謝辞

本研究の一部は、文部科学省地域イノベーション・エコシステム形式プログラム「IoTによるアクティブシニア活躍都市基盤開発事業」による。実験に積極的に協力いただいた株式会社富士データシステム、社会福祉法人平成会 介護老人福祉施設 プライエム横尾の皆様および、実験に協力いただいた井上創造研究室の学生の皆様に感謝いたします。

## 参考文献

- [1] 厚生労働省:2025年に向けた介護人材にかかる需給推計(確定値)について, <http://www.mhlw.go.jp/stf/houdou/0000088998.html>(2019.05.13)
- [2] Natarajan A, Angarita G, Gaiser E, Malison R, Ganesan D, Marlin BM, "Domain Adaptation Methods for Improving Lab-to-field Generalization of Cocaine Detection using Wearable ECG", Proc ACM Int Conf Ubiquitous Comput, vol.2016, pp.875-885,(2016).
- [3] 日本ソフトウェア科学会機械学習工学研究会:機械学習工学研究会(オンライン),<https://sites.google.com/view/sig-mlse/>(2019.05.15).
- [4] 勝手美紗, 内海ゆづ子, 黄瀬浩一:物体と動き特徴を用いた行動認識, 電子情報通信学会技術研究報告.PRMU, パターン認識・メディア理解, Vol.111, No.430, pp125-126(2012)
- [5] 井上創造, 房前悟, 相馬功, 柴田智広:IoT行動認識技術の実用化とオープンイノベーションへの取り組み, 計測と制御, Vol.58, No.2, pp.84-88(2019)
- [6] 武田紳吾, Paula Lago, 大北 剛, 井上 創造, "センサ行動認識のための機械学習を用いた加速度データシミュレーション", SOFT 九州支部学術講演会, pp.49-50, (2018).