

# 深層学習を用いた単一加速度データからの歩行姿勢分類

新川 怜奈<sup>†</sup> 羽山 徹彩<sup>†</sup>

長岡技術科学大学<sup>†</sup>

## 1. はじめに

日常的に悪い歩行姿勢の人は将来的に、様々な運動障害を引き起こす可能性がある。しかしながら、適切な歩行を常に意識して補正することは健康を維持するために有効であるが、骨格のゆがみや筋肉の弱みなどから適切な歩行を維持することが難しくなる。また普段は適切な歩行姿勢であっても、疲労によって適切な歩行姿勢を維持することが困難になる[1]。

これまで、歩行姿勢の測位と推定を目的とした研究では精緻な歩行動作の検出を必要となるため、床圧センサ[2]やモーションキャプチャセンサ[3]など比較的大きな装置が利用されてきた。近年、歩行動作の検出をウェアラブル化するために、複数の小型 3 次元加速度センサを利用したシステムが開発されてきた。例えば、歩行動作の両足の特徴が表れやすい両足首付近の加速度センサの値から、歩行動作の定量的に解析[4]を行ったり、機械学習手法 SVM を用いた歩行診断[5]を行ったり、といった取組みがある。さらに日常的な歩行姿勢検出を容易とするためには、万歩計のような単一のセンサ装置かつ腰回り付近の装着が有用と考えられるものの、両足に関わる歩行動作の特徴がセンサ値に表れ難いため、歩行姿勢検出を大変困難にする。

そこで、我々は単一加速度センサを用いた歩行姿勢補正支援システムの開発に取り組んできた。本研究では歩行姿勢のセンサ値の特徴を自動抽出し高精度な分類を可能にする深層学習をもとに、ベルト付近の単一加速度データから 4 種の歩行姿勢(通常, ガニ股, 内股, すり足)の分類を行う方法を開発し、分類精度 0.97 を達成した。

## 2. システム概要

### 2.1. 加速度センサデバイス

本研究では図 1 のように、小型の 9 軸加速度センサデバイス (3 軸加速度 + 3 軸角速度を含む) を、ベルト上の背中付近に装着させて、歩行中のセンサ値を毎秒約 116 フレームで保存したデータを用いる。そのため、姿勢推定に用いるセンサ値には、3 次元加速度の値、3 次元角速度の値、ヨー角、ピッチ角、ロール角、およびそれらの取得時間の計 10 項目が含まれる。



図 1 本研究で用いる加速度センサデバイス

### 2.2. 歩行姿勢の分類

加速度センサデバイスで得られた 10 項目のデータに対し、深層学習で歩行姿勢を分類する。

分類する歩行姿勢には体に負担を強いる歩行[7]を参考に、股関節の過度な外旋・内旋が原因で膝関節に負担のかかる歩行(ガニ股歩行, 内股歩行), 足関節の過度な底屈が原因で転倒につながる歩行(すり足歩行), および通常歩行の 4 種を扱う。通常, これら歩行姿勢は前後方向について概ね同じ動作であるが、左右方向において、踵やつま先が地面に触れるタイミングに大きな差がみられる。つまり、足首や下肢に加速度センサを付与した場合には両足の軌道が検出でき歩行姿勢を識別し易いが、上半身に単一加速センサを付与した場合には図 2 に示すように、その特徴を掴むのが困難になる。

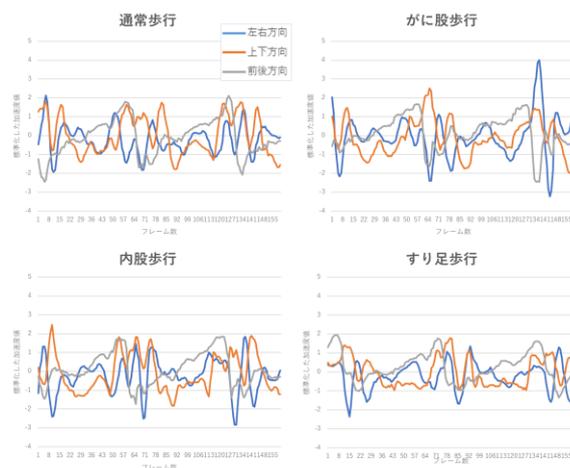


図 2 歩行姿勢ごとの歩行加速度データ(標準化適用後)の例

そのような歩行加速度データに対し、本研究では深層学習のモデルに時系列データの分類で優れた実績のある LSTM[6]を適用する。本研究の LSTM の入力層, 中間層, および出力層は、それ

Walking-posture Classification from Single-acceleration-sensor Data Using Deep Learning

<sup>†</sup>Reina Arakawa, Tessai Hayama, Nagaoka University of Technology

ぞれ“1 サンプルあたりのフレーム数\*センサ値種別数(10 項目)”, “512”, および“分類項目数(4 歩行姿勢)”とする. 学習データには歩行行動のなかで得られた加速度センサの時系列値に対し, 一般的な歩行周期が概ね含まれる 160 フレームを 1 サンプルとして扱う.

### 3. 評価実験

#### 3.1. 実験概要

深層学習を用いた単一加速度センサデータの歩行姿勢の分類方法を評価した. そのために, 歩行姿勢のデータセットを作成し, 分類精度をもとに SVM を用いた従来手法[5]と比較した.

学習用データセット作成には, 20 代男性 6 名の参加者に対し, 歩行姿勢訓練を行った後, 屋内の約 25 メートル直線通路において, デバイスを装着し, 歩行姿勢ごとに 3 往復してデータを収集した. そのうち, 各参加者のはじめの 2 往復分を学習データとし, 残り 1 往復分をテストデータとした. 1 データサンプルは 160 フレーム(約 1.38 秒)のセンサ値とし, データセットは 1 フレームずつスライドさせることで作成された. データセットの内訳を表 1 に示す.

表 1: 機械学習用データセットのサンプル数

	通常	がに股	内股	すり足	合計
学習データ	27,161	29,655	30,400	31,810	119,026
テストデータ	13,515	14,400	15,310	16,460	59,685

比較手法では SVM を用いた歩行姿勢の分類方法[5]を参考に, 各サンプルデータの 160 フレームのセンサデータ値に対し主成分分析を行い, 累積寄与率 0.80 以上となる主成分スコア 112 次元を特徴量として用いた.

#### 3.2. 結果と考察

深層学習および SVM を用いた単一加速度センサ値の歩行姿勢の分類精度を, 表 2 に示す. また深層学習および SVM を用いた分類における歩行姿勢ごとの正誤内訳数について, それぞれ表 3 および表 4 に示す.

深層学習による分類では表 2 に示すように, 加速度データ (ACC), 加速度と角加速度の組合せデータ (ACC+GYRO), および 10 項目すべてのデータ (ALL) に対し, それぞれ 0.95, 0.97, および 0.96 であった. 一方, SVM による分類では ACC, ACC+GYRO, および ALL に対し, それぞれ 0.75, 0.88, および 0.93 であった. そのため, 深層学習で加速度と角速度の組合せデータを用いた歩行姿勢の分類方法が, 最も良い結果が得られる

ことがわかった.

次に, 歩行姿勢の分類項目ごとの正誤内訳について確認した. ガニ股歩行については, 深層学習を用いた場合には 0.99 と高精度で分類できるものの, SVM では精度 0.85 と誤分類が多かった. また両学習法を用いた場合でも内股歩行の検出が他の分類項目と比べ, 一番困難であったが, 特に SVM を用いた検出精度は 0.55 と深層学習 0.94 に比べ, 非常に低い結果であった. そのため, 深層学習を用いた単一加速度センサの歩行姿勢分類では今回の SVM を用いた特徴よりも, 有意な特徴が得られていたと考えられる.

表 2: 深層学習, SVM を用いた歩行姿勢の分類精度

	深層学習 (LSTM)	SVM
ACC	0.95	0.75
ACC + GYRO	0.97	0.88
ALL	0.96	0.93

表 3: 深層学習を用いた分類における正誤内訳数

	通常	ガニ股	内股	すり足
通常	12911	145	216	243
ガニ股	42	14289	64	5
内股	613	66	14431	200
すり足	159	229	175	15897

表 4: SVM を用いた分類における正誤内訳数

	通常	ガニ股	内股	すり足
通常	9771	446	1962	1336
ガニ股	346	12186	1133	735
内股	1066	1884	8376	3984
すり足	1150	370	339	14601

#### 謝辞

本研究の成果の一部は科研費(基盤研究 (C) 19K12264)の助成を受けたものである.

#### 参考文献

- [1] 泉: “健康づくりのためのウォーキング (運動)”, 大同生命厚生事業団 (2008).
- [2] 祝原ら: “歩行時立脚期の足圧分析によるポスチェアウォーキングの特性の検討”, 日本ウォーキング学会ウォーキング研究, vol. 20, pp49-54 (2016).
- [3] 和田ら: “多視点カメラによる屋外での歩行者のモーションキャプチャ”, 情報処理学会 研究報告グラフィクスと CAD(CG), 2010-CG-141, No. 8, pp. 1-6 (2010).
- [4] 堀ら: “ウェアラブルセンサを用いた足首軌道推定と歩行分析と歩行システム”, 第 28 回自立分散システム・シンポジウム資料, pp203-208 (2016).
- [5] 橋口ら: “足首軌道データに基づくパーキンソン病の早期診断システム”, 第 28 回自立分散システム・シンポジウム資料, pp155-158 (2016).
- [6] S.Hochreiter et al.: “Long short-term memory”. Neural Computation 9 (8), pp. 1735-1780 (1997).
- [7] ノイマン: “観察による歩行分析”, 医学書院 (2005).