

杖型計測装置による活動量推定手法の改善

Improvement of physical activity estimation using a cane mounted measurement device

吉田貴徳 和田親宗

九州工業大学 大学院生命体工学研究科 人間知能システム工学専攻

E-mail address: yoshida.takanori195@mail.kyutech.jp, wada@brain.kyutech.ac.jp

1. はじめに

人の身体活動の状況を表す指標として活動量があり、厚生労働省により高齢者が健康に過ごすために一週間に必要な活動量が定められている[1]。そのため、もし簡便な方法で日常生活における活動量を把握できれば、定められた活動量と比較することにより、高齢者の健康維持や改善が可能と考える。ここで、高齢者の要支援者の70[%]は日常的に杖を使用している[2]ことから、所属研究室では、杖に付けた計測装置のデータに対して機械学習手法を適用することで、活動量の把握を試みた[3]。その過程で、高齢者による長時間の動作データ収集が難しく、複数動作を連続でおこなった際の活動量推定誤差の大きいことが課題として挙げられた。そこで、本研究では高齢者の動作に近い動作を実現できる高齢者体験キットを用い、長い連続動作時の動作セットの作成を行い、深層学習モデルにより動作識別手法の提案を行う。そして、連続動作時の活動量推定の精度を上げるため、スライディングウィンドウ方式の最適なウィンドウサイズを求めた。また、装置の軽量化のためセンサ数を減らしたときの精度の比較を行った。最後に、得られた結果を用いて、活動量の推定誤差を求めた。

2. 活動量の推定法

杖に2つの慣性センサ (Inertial measurement unite: IMU, ロジカルプロダクト社製, 9 軸ワイヤレスモーションセンサ, サンプル周波数 100[Hz]) を取り付け、それらから得られた 3 軸加速度と 3 軸角速度をもとに深層学習モデルを用いて、5 動作 (歩行, 起立・着座, 昇段, 降段, 直立) の識別を行う。動作の種類ごとに厚生労働省により定められている運動強度[Mets][1][4]を用い、活動量を運動強度[Mets]×時間[h]として求める。杖型計測装置と活動量推定の流れを図 1 に示す。




図 1 杖型計測装置と活動量推定の流れの概要

まず、得られた 3 軸の加速度・角速度のデータに対し、スライディングウィンドウ方式によりセグメント化を行

う。セグメント化されたデータを深層学習モデルに入力し 5 動作を分類する。この際の深層学習モデルとして、過去には KNN を用いていたが、動作識別精度を示す F-measure が最高で 0.72[3]と低かったため変更を行った。今回は、CNN と BiGRU を組み合わせたものを用いることとする。理由は次の通りである。一般に、動作分類を高精度に行うことができる深層学習モデルとして CNN や LSTM が多く用いられている[5][6]。CNN は画像処理などに用いられることが多い深層学習モデルで入力データにカーネルと呼ばれる格子状の数値データを設定したストライドの大きさ毎にずらして掛け合わせていくことにより、IMU の波形の形状的な特徴量を抽出することができる。LSTM は時系列データの学習に用いられることが多い深層学習モデルで、前後間の時系列情報の学習を行いながら長期の時系列情報を保持することで出力の考慮を行うことができ、時間的な前後間の変化の特徴を抽出することができる。また、CNN と LSTM を組み合わせたモデルで高精度に動作の識別を行うことができる[7]。また、LSTM のように時系列上の古いデータから学習するのではなく、時系列上の新しいデータからも学習できる BiGRU を用いて高い精度で動作識別が実現されている[8]。そこで本研究では CNN と BiGRU を組み合わせた深層学習モデルで動作の識別を行う。

3. 実験

所属研究室ではセグメントサイズ 300[sample]のスライディングウィンドウ方式で検証を行っていたが、連続動作時の最適なセグメントサイズが分かっていない。そこで、本研究では、スライディングウィンドウ方式のセグメントサイズを 100[sample], 200[sample], 300[sample]と変化させた場合の、連続動作における、動作識別の精度の比較をおこない最適なウィンドウサイズを求めた。オーバーラップ率はすべて 50[%]とした。

また、IMU センサ数削減のためのセンサ位置ごとの動作識別精度の比較と活動量推定誤差の比較を行った。具体的には、持ち手と杖先の 2 つの IMU を用いるパターンと、持ち手の 1 つの IMU を用いるパターン、杖先の 1 つの IMU を用いるパターンで比較を行った。

実験では 10 名の若年被験者に、高齢者体験キット (三和製作所, 高齢者疑似体験教材) を着用してもらい、5 つの動作を 10 回実施してもらった。そして、被験者ごとの

Leave-One-Out 法で深層学習モデルの学習を行い精度の比較を行った。

4. 結果と考察

ウィンドウサイズの比較では3つのウィンドウサイズで検定を行った。検定には5動作ごとの F-measure を指標として用いた。有意差が見られた起立・着座と降段の F-measure の値を表1に示す。

表1 起立・着座と降段の F-measure

	起立・着座[F-measure]	降段[F-measure]
100[sample]	0.69±0.14	0.81±0.07
200[sample]	0.80±0.16	0.91±0.07
300[sample]	0.86±0.12	0.93±0.06

*: p<0.05

検定の結果として起立・着座においてはウィンドウサイズが100[sample]と300[sample]の間に有意差が見られた。また降段においてはウィンドウサイズが100[sample]と200[sample]の間と、100[sample]と300[sample]の間に有意差が見られた。これらの結果から5動作を最も高精度に識別するためにはウィンドウサイズ300[sample]が最適と考える。

また、IMU センサ位置の比較結果として動作識別精度を表2に示す。有意差検定の結果、センサ位置による識別精度に差は見られなかった。このことより1つのIMUで動作識別が可能であると考えられる。

表2 IMU の設置位置ごとの動作識別精度

	Accuracy[%]
持ち手と杖先	0.91±0.06
持ち手	0.94±0.05
杖先	0.92±0.06

最後に、以上の結果を踏まえて、ウィンドウサイズが300[sample]、IMUの位置が持ち手あるいは杖先の場合のパターンの時の真値との活動量推定誤差の比較を行う。比較には5動作ごとにおける被験者10人の活動量推定誤差の平均値を使用した。センサ位置が持ち手と杖先の場合の5動作ごとの活動量推定誤差と5動作を平均したときの活動量推定誤差を表3に示す。BodyMedia FIT や ActiGraph などの8種類の市販の活動量計の活動量推定誤差が最も小さいもので9.30[%]であるのに対し、提案を行った杖型装置はそれよりも高い精度で活動量の推定を行うことができた[9]。

表3 センサ位置ごとの動作ごとの誤差と平均の誤差

	活動量推定誤差[%]	
	持ち手	杖先
歩行	6.07	4.57
起立・着座	1.77×10	1.23×10
昇段	1.94×10	5.99
降段	8.74	4.19
直立	1.93×10	9.36
平均	1.43×10	7.37

5. おわりに

本研究ではIMUを取り付けた杖型計測装置で活動量の推定を行うシステムの実現に向けて、最適なIMUのデータセグメントサイズやセンサの位置の検討や活動量推定精度の評価を行った。評価実験の結果、ウィンドウサイズは300[sample]が最適で、センサ位置による精度の有意差は見られないことが分かった。また活動量推定誤差は7.37[%]となった。今後は活動量誤差の低減を含め、荷物を持って歩行を行っている際や坂で歩行を行っている際などのより細かな動作分類を行うことで、より高精度に活動量の推定を行うことができる手法の確立を目指す。

参考文献

- [1] 厚生労働省, "健康づくりのための身体活動基準2013"
- [2] Sara M Bradley et al., "Geriatric assistive devices" Am Fam Physician, 2011, Vol.84, pp.405-411
- [3] Toshiyuki Terukina et al., "Activity Recognition using Instrumented Cane with Force Sensor and Inertial Measurement Unit for Elderly People", 7th International Symposium on Applied Engineering and Sciences (SAES2019), BM-113, 1page, 2019/11/12.
- [4] 上村さと美 et al., "起立運動を用いた運動負荷法の生理的運動強度.理学療法科学", 26 巻, 1 号, pp.89-93, 2011
- [5] Andrey Ignatov et al., "Real-time human activity recognition from accelerometer data using Convolutional Neural Networks", Applied Soft Computing, 2018, Vol.62, pp.915-922
- [6] Yuwen Chen et al., "LSTM Networks for Mobile Human Activity Recognition", International Conference on Artificial Intelligence, 2016, pp.50-53
- [7] Ohoud Nafea et al., "Sensor-Based Human Activity Recognition with Spatio-Temporal Deep Learning", sensors, 2021, Vol.21
- [8] Saedeh Abbaspour et al., "A Comparative Analysis of Hybrid Deep Learning Models for Human Activity Recognition", sensors, 2020, Vol.20
- [9] Nelson MB et al., "Validity of Consumer-Based Physical Activity Monitors for Specific Activity Types", Med Sci Sports Exerc, 2016, pp.1619-28