

スマートフォンの内蔵センサーを用いた人間活動の分類実験

川島寛隆† 今村誠

†東海大学 情報通信学研究科 情報通信学専攻

概要: 近年、スマートフォンやウェアラブル端末に代表される IoT 機器の普及に伴い、それらに内蔵された加速度センサーやジャイロセンサーから容易に人間の活動情報を収集できるようになった。これらの活動情報は、介護分野においては高齢者の離床などの検知、建築現場では作業員の転倒・落下の検出により事故の早期発見などが期待されている。本論文では、スマートフォンのセンサーデータを用いて人間活動を分類する実験の結果を報告する。分類対象の人間の活動は、立った状態で前後に転倒した場合、立った状態で左右に倒れた場合、椅子に座ろうとした時の転倒した場合、転倒を防ごうとしようとした場合、倒れた際に物にぶつかった場合、失神が原因で倒れた場合の 8 つとした。また、分類に用いる機械学習のアルゴリズムとして、勾配ブースティング木と Deep Convolutional and LSTM Recurrent Neural Networks の分類精度を比較する。

キーワード: IoT, 機械学習, センサーデータ, ニューラルネットワーク

1. はじめに

高齢者の転倒による怪我や工事現場での転倒・落下事故の防止・早期発見などの目的で人間の活動を収集し、分析を行うことが注目を集めている。これらの活動情報は昨今の安価なセンサーの普及やスマートフォンなどの IoT 機器の普及により以前よりも容易に収集ができるようになった。この様なセンサーデータを元にして、様々な動作を分類する多値分類問題における古典的なアプローチは、固定サイズのウィンドウを元に時系列データから特徴量の抽出の後、決定木などを用いて分類を行う。対して畳み込みニューラルネットワークや再帰型ニューラルネットワークなどを組み合わせた手法においては、信号データそのものを直接ネットワークに流し、学習を通して最適な特徴量の抽出を自動で行う。

本実験では、スマートフォンの加速度センサーから得られる情報を元に、複数の転倒を深層ニューラルネットワークと勾配ブースティング木、そして、k 近傍法の 3 種類の分類機を作成し、識別を試み結果報告する。

2. 実験の目的

本実験の目的は、従来ドメイン知識を必要とする生のセンサーデータからの特徴量の抽出を畳み込み層を複数重ね合わせた再帰型ニューラルネットワークを用いることによりそれを自動化し、他の分類手法との優位性を検証することである。実験では、公開データセット[1]を元に作成した学習データを用いて、作成したネットワークと勾配ブースティング木をそれぞれ訓練し分類精度を確認する。

3. 実験の内容

実験で用いたデータセット[1]は、18 歳から 60 歳までの

男女 30 人の被験者が行った 8 つの転倒時のセンサーデータを 3 軸の加速度を記録可能な Bosh BMA220 加速度センサーを用いてサンプリング周波数 50Hz で記録したもので、各加速度センサーの軸ごとに 151 の特徴ベクトルを持つ。表 1 はデータセット内の 8 つのカテゴリのそれぞれのサンプル数を示したものである。

表 1 データセット[1]における転倒データのデータ数

ラベル	カテゴリ	データ数
0	forward	525
1	back	525
2	right	510
3	left	530
4	obstacle	660
5	protection	480
6	chair	430
7	syncope	510
	総数	4,170

カテゴリはそれぞれ、立った状態で前後に転倒した場合、立った状態で左右に倒れた場合、倒れた際に物にぶつかった場合、転倒を防ごうとしようとした場合、椅子に座ろうとした時の転倒した場合、失神が原因で倒れた場合の意味である。このデータセットを被験者番号を元に 7 割を訓練用、3 割を試験用として分割を行なった。

3.1 ネットワークの構成

本実験で用いた Deep Convolutional and LSTM[2]の構成とハイパーパラメータについて報告する。CNN-LSTM アーキテクチャと称されるこのネットワーク構成は、入力データから特徴抽出を行う畳み込み層と時系列データを扱うことに

適した LSTM を組み合わせたものである[3]. この LSTM は系列データを扱うことを目的にした RNN の勾配消失問題を解決する為に考案されたモデルである. このネットワークは図2に示すように4層の1次元畳込み層, 2層の LSTM 層, 1層の全結合層で構成され, 各層のハイパーパラメータはそれぞれ, 畳込み層は活性化関数に ReLU, カーネルサイズ 3, ストライド 1 とした. LSTM は活性化関数を tanh, 再帰計算時に用いる活性化関数を hard sigmoid, ユニット数を 128 とした. ネットワーク全体の重みは Xavier の正規分布からサンプリングした値を用いて初期化した. 訓練回数は 5 回とした.




図 1 Deep Convolutional and LSTM Recurrent Neural Networks

3.2 k 近傍法

利用したデータセットでは, k 近傍法を用いた分類を行う方法が例示されている[4]. このアルゴリズムは, 分類時, 学習データとの距離を計算し, 近傍の k 個の点がどちらに含まれるか多数決を行い分類する手法である. これに従い, ハイパーパラメータ $k=1$ とし実験を行う.

4. 実験結果

表 2 に各モデルを用いた時のそれぞれのカテゴリにおける行動検知の分類精度を示す. また, 表 3 はモデルのごとの全体精度である. ここで, kNN は k 近傍法, GBT は勾配ブースティング木の意味である. 8 カテゴリに対して平均 151 個のデータが含まれた試験用データを用いて評価を行った.

Category	kNN		GBT		CNN-LSTM	
	正解数	正答率	正解数	正答率	正解数	正答率
Forward	95	0.546	114	0.655	91	0.522
Right	79	0.541	72	0.493	73	0.500
Back	52	0.363	31	0.216	70	0.489
obstacle	137	0.717	123	0.644	139	0.728
protect	64	0.489	49	0.374	74	0.565
chair	57	0.471	45	0.372	35	0.289
syncope	25	0.166	31	0.205	29	0.192
left	71	0.455	49	0.314	55	0.352

表 2 モデル毎の正解数と分類精度(試験用データ数 1,213)

モデル	分類精度
kNN	0.481
GBT	0.425
CNN-LSTM	0.472

表 3 モデル毎の全体精度

5. 考察

3 つの分類器全てで分類精度が 50%を下回る結果となった. k 近傍法での分類精度は, 例示されている分類精度 43.66%を若干上回る結果[5]となったが, それ以外の分類器の精度は kNN を下回るものとなった. 考えられる原因の一つに使用したデータ自体の総数が分類するカテゴリ数に対して少なかったこと, そして各転倒時のセンサデータ間の差異が小さかった事が挙げられる. 類似のデータセット[6]では, 歩行時や静止時など比較的大きな枠組みでラベル分けを行っているが, 今回用いたデータは転倒のみに限定しており, モデルが差異をうまく抽出出来なかったと思われる. 今後の課題は, このようなデータ数が少ない場合やデータ間の差異が小さい場合においても, 高い分類精度を実現できるようセンサデータにおける CNN の転移学習やデータに適したネットワーク構造の自動探索法などを検討することである.

参考文献

- [1] Daniela Micucci, Marco Mobilio, Paolo Napoletano, “UniMiB SHAR: A Dataset for Human Activity Recognition Using Acceleration Data from Smartphones”, <http://www.sal.disco.unimib.it/technologies/unimib-shar/>
- [2] Francisco Javier Ordóñez, Daniel Roggen” Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition”, pp.8 (2016)
- [3] Jason Brownlee, “Deep Learning for Time Series Forecasting”, pp 513, 2018
- [4] Daniela Micucci, Marco Mobilio, Paolo Napoletano, “UniMiB SHAR: A Dataset for Human Activity Recognition Using Acceleration Data from Smartphones”, pp.12 (2017)
- [5] Daniela Micucci, Marco Mobilio, Paolo Napoletano, “UniMiB SHAR: A Dataset for Human Activity Recognition Using Acceleration Data from Smartphones”, pp.15 (2017)
- [6] Davide Anguita, Alessandro Ghio, Luca Oneto, Xavier Parra and Jorge L. Reyes-Ortiz. A Public Domain Dataset for Human Activity Recognition Using Smartphones. 21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, ESANN 2013. Bruges, Belgium 24-26 April, <https://archive.ics.uci.edu/ml/datasets/human+activity+recognition+using+smartphones> (2013).