

M-016

加速度センサを装着した IoT モップによる清掃行動認識 Cleaning Activity Recognition with Mop-Mounted Accelerometers

八重樫 遼¹
Ryo Yaegashi

中山 悠¹
Yu Nakayama

1. はじめに

近年、機械学習技術の著しい発達により、加速度センサ等を用いた人の行動認識に関する研究が盛んになっている。具体的な事例として、スマートフォンに搭載されているセンサを用いた歩行、ランニングといった日常行動の認識[1]や、ウェアラブルセンサによる家事やスポーツに関する行動認識[2]がある。他にも多岐にわたる行動認識技術が開発されている一方、清掃行動に着目した研究は少ない。清潔な環境維持が社会的課題となっている昨今においては、低コストかつ簡易に清掃行動をモニタリングする技術の重要性が高まっていると言える。そこで本論文では、清掃道具に装着した加速度センサを用いた清掃行動認識手法を提案する。具体的な取り組みとして、加速度センサを装着した IoT モップを用いたデータセットを作成し、複数の機械学習アルゴリズムにより精度を比較した。またサンプリング周波数などをパラメタとした評価により、高精度な認識に必要なデータ量を明らかにした。

2. 提案手法

2.1 識別する清掃行動

提案手法は、家庭やオフィスで一般的に用いられるモップに加速度センサを取り付け、得られた加速度データにより清掃行動を認識する。モップは基本的に清掃時に清掃用途にのみ用いられるという特性に着目し、識別対象となる行動を網羅的にリストアップした。すなわち、(a)Wipe: モップを押して歩く拭き掃除、(b)Sweep: ほうきのように用いる掃き掃除、(c)Rub: 特定の箇所に対して行うこすり掃除、(d)Insert: 狭い場所に対して行う差し込み掃除、(e)Other: モップを持って歩くなど非清掃行動、という計 5 種の行動である。各行動の例を図 1 に示す。

2.2 データセットの作成

道具の違いに対する頑健性を担保するため、ダスキン社のスタイルフロア ララ、フリージー、フラットモップ M の 3 種類のモップを使用した。これらのモップの柄の部分に、3 軸加速度センサ MEMSIC MC3630 を搭載した TWELITE CUE を取り付けた(図 2)。サンプリング周波数 100Hz として x, y, z 軸加速度を取得し、160ms ごとに 16 サンプルずつ、IEEE802.15.4 準拠の TWELITE プロトコルで受信側端末に送信し、受信側端末で記録した。パケット再送回数は 9 回と設定した。なお、加速度データを無線転送し、エッジサーバ側で行動推定を行うことで、リアルタイムかつ遠隔での清掃行動モニタリングが可能となる。

加速度データは 20 代男女 5 名の被験者から収集した。一人あたりモップ、行動ごとに 5 分間計測し、合計約 6 時間のデータを収集した。図 3 にデータ収集環境を示す。




図 1 認識する清掃行動例




図 2 使用した IoT モップ




図 3 データ収集環境

2.3 学習方法

特徴量としては、サンプリング周波数 100Hz で取得した 3 軸加速度データを 2 秒分の時間窓で切り分けた 600 次元のベクトルを使用した。なお、TWELITE 通信ではパケットロスが発生する可能性がある。今回作成したデータセットにおいては、パケットロス率が約 0.1%と低かったことから、パケットロスにより失われたデータを欠損値として扱った。この欠損値が切り分け後の時間窓内の 600 次元ベクトル内にあった場合には、そのベクトルを学習やテストに使用しないこととした。

3. 認識精度評価

3.1 アルゴリズムごとの認識精度の比較

¹東京農工大学 大学院 工学府 情報工学専攻
Department of Computer and Information Sciences,
Tokyo University of Agriculture and Technology

表 1 各アルゴリズムによる推定精度

学習 アルゴ リズム	精度	再現率					適合率					F 値				
		Wipe	Sweep	Rub	Insert	Other	Wipe	Sweep	Rub	Insert	Other	Wipe	Sweep	Rub	Insert	Other
DT	0.725	0.900	0.624	0.734	0.734	0.657	0.839	0.653	0.801	0.799	0.637	0.867	0.630	0.750	0.737	0.616
RF	0.837	0.982	0.763	0.886	0.835	0.751	0.918	0.841	0.928	0.856	0.806	0.947	0.782	0.889	0.810	0.737
kNN	0.764	0.997	0.397	0.749	0.795	0.893	0.810	0.999	0.939	0.897	0.627	0.887	0.491	0.794	0.797	0.710
NN	0.845	0.987	0.784	0.884	0.798	0.805	0.873	0.931	0.913	0.873	0.820	0.923	0.830	0.887	0.798	0.773
LSTM	0.858	0.965	0.810	0.884	0.827	0.829	0.901	0.921	0.924	0.877	0.805	0.928	0.849	0.885	0.821	0.793

まず高精度な行動認識を実現する手法を明確化するため、機械学習アルゴリズムごとの推定精度を比較した。具体的には、決定木(DT)、ランダムフォレスト(RF)、k 最近傍法(kNN)、4 層ニューラルネットワーク(NN)、Long Short-Term Memory(LSTM)の 5 種類のアルゴリズムを用いた。DT に関しては、決定分岐の最大数を 100 とした。RF は決定分岐の最大数を 100 にし、100 本の木で構成されるよう設定した。アンサンブル学習としては、アダブーストを採用した。また、kNN に関しては、最近傍の数を 5 に設定し、距離の計算にはユークリッド距離を用いた。NN に関しては、第 1 隠れ層のニューロン数を 100、第 2 隠れ層のニューロン数を 6 とした。LSTM に関しては、LSTM 層の数を 100 に設定した。NN、LSTM 共に、バッチサイズは 256、エポックは 100 とし、ソルバは Adam ソルバ、損失関数に交差エントロピー誤差を採用した。

上記の各機械学習アルゴリズムを用いて清掃行動推定を行った結果を表 1 に示す。なお、人による動きの違いに対する頑健性を考慮し、被験者 5 人のうち 1 人をテストデータに、残り 4 人を学習データに用いる 5 パターンの交差検定を行い、結果を平均した値である。表 1 から、LSTM が最も精度が高く、約 8 割 5 分の正答率を達成していることが分かる。これは、LSTM が時系列データの特徴量として学習するため、時系列データに関する分類や回帰を得意とすることに起因すると考えられる。アルゴリズムの性質上、LSTM や NN は学習データの量に応じて性能が向上すると考えられるので、さらなる精度の向上が見込まれる。一方、精度が低かったのは DT や kNN である。これは特徴量に対して決定分岐の数が少ないことや特徴量次元数が大きいことによって、十分に分類できていないためであると考えられる。RF に関しては、複数の DT を作成しその分類結果を統合することで行動を推定しているため、単純な DT よりも高い精度を記録している。これらの機械学習アルゴリズムでより認識精度を達成するためには、決定分岐の最大数や距離の計算方法といったハイパーパラメータを最適化することが考えられる。

3.2 高い認識精度を実現するパラメタ

次に、高精度な清掃行動認識に必要なデータ量を明らかにするため、パラメタによる認識精度の違いを評価した。アルゴリズムとしては、最も高い精度を記録した LSTM を採用した。サンプリング周波数を 10, 20, 50, 100Hz、時間窓を 0.5, 1.0, 1.5, 2.0 秒に変更し、各組み合わせで得られる異なる次元のベクトルを特徴量とした。その他のパラメタについては、先の評価と同じものを用いた。パラメタを変更して清掃行動推定を行った際の精度を図 4 に示す。この結果は表 1 と同様の平均値である。図 4 から、サンプリング周波数 100Hz、時間窓 2.0 秒の場合に最も高い精度を達成していることが分かる。また、サンプリ

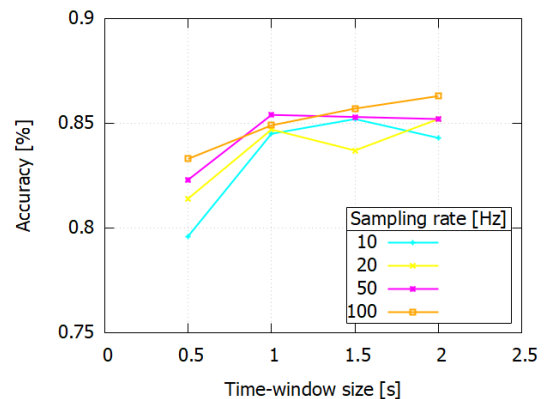


図 4 各パラメタの組み合わせによる推定精度

ング周波数 50 Hz 以上、かつ時間窓 1.0 秒以上であれば 8 割 5 分の精度を維持できる。時間窓が 0.5 秒のときに精度が低下する原因としては、短い時間の中に各清掃行動の特徴が現れづらいことが考えられる。

4. まとめ

本論文では、加速度センサを装着した IoT モップを用いた清掃行動の認識手法を提案した。時系列データの特徴量として学習する LSTM の採用により、約 8 割 5 分の精度を達成した。また、精度を維持可能なデータ量を明らかにした。これは、IoT モップの省電力化による長期にわたる持続的なモニタリングの実現に寄与する。今後の課題として、データセット作成に参加した被験者の属性が類似していることや、パケットロスによる欠損値への対応が挙げられる。今後は、様々な属性を含んだ大規模なデータセットの収集、および欠損値に対する頑健性の向上を検討していきたい。

謝辞

本研究の一部は、LNest Grant, DUSKIN CO., LTD, JST ACT-I (JPMJPR18UL) の支援を受けて行われた。

参考文献

- [1] A. Anjum and M. U. Ilyas, "Activity recognition using smartphone sensors," 2013 IEEE 10th Consumer Communications and Networking Conference (CCNC), 2013, pp. 914-919, doi: 10.1109/CCNC.2013.6488584.
- [2] Y. Hsu, S. Yang, H. Chang and H. Lai, "Human Daily and Sport Activity Recognition Using a Wearable Inertial Sensor Network," in IEEE Access, vol. 6, pp. 31715-31728, 2018, doi: 10.1109/ACCESS.2018.2839766.