

宅内行動推定の精度向上を目指したデータ分析に関する一検討

秋田 浩也^{1,a)} 佐藤 健哉^{1,b)}

概要: 近年 IoT の流れを受けて、宅内データの収集と分析が盛んに行われている。しかし、正確なデータを収集するためには、高価なデバイスが必要になる。今後一般に普及することを考え、導入の容易性に着目した宅内環境を想定し、被験者実験を実施した。被験者実験で収集したデータに対して、行動推定という課題を与え、データ分析を行う。その際に、機械学習や隠れマルコフモデルなどの手法を適用し、精度向上にどう影響するのかを考察する。機械学習は SVM, Random Forest とともに高い精度で行動を推定できた。また、主成分分析により次元を削減してもある程度の精度が維持可能であることも分かった。時系列データの処理として GMM-HMM を適用したが、本実験環境では機械学習の手法に優位性があるという結果となった。実験を通して単一の特徴ベクトルに依存しているわけではないが、重要な特徴が存在することがわかった。

A Study on Data Analysis Aiming at Accuracy Improvement of In-Home Living Activity

AKITA HIROYA^{1,a)} SATO KENYA^{1,b)}

1. はじめに

近年 IoT(Internet of Things) という技術が注目されており、家庭内にセンサーを配置しデータを収集することが可能となってきた。これにより、省エネルギーを目的とした家電制御や高齢者の見守り支援などについても研究が行われている。高齢者の見守り支援などを行うためには、対象者がどのような行動を行っているのかを認識できることが必要不可欠である。現在の行動推定に関する研究はカメラなどを利用した行動認識技術 [1][2] と、センサーデータを利用した行動認識技術 [3] に分けられる。本研究では、プライバシーの観点からセンサーデータを利用した行動推定を選択する。

現在も様々な IoT デバイスが発売されており、今後もその流れは続くと考えられる。しかし、デバイスの導入は段

階的に進むため、それぞれの家庭において存在するデバイスが異なり得られるデータも異なるという問題が起こる。本研究では、導入の容易性という観点から使用するデバイスを選定した。今回の限定した環境において得られたデータから推定精度を向上させるために、データ分析と考察を行った。

2. 関連研究

守谷らは ECHONET Lite 対応家電からの情報を使用して行動推定を行っている [4]。しかし、実験環境で使用しているデバイスは共同研究で提供されたデバイスであり、一般家庭での導入は困難である。また、行動推定の手法には Random Forest 一つを用いて、他の手法との比較考察を行っていない。本研究では、導入容易性という観点から選定したデバイスを使用した環境で、複数の手法を用いてデータの分析を行う。

¹ 同志社大学大学院理工学研究科
Doshisha University Graduate School of Science and Engineering

a) hiroya.akita@nislabs.doshisha.ac.jp

b) ksato@mail.doshisha.ac.jp




図 1 家庭での行動




図 2 使用家電

3. データ収集方法

3.1 事前アンケート

今回実験の対象者は一人暮らしに限定している。一人暮らしの生活の中でどのような行動を行っているのか、どのような家電を使用しているのかを調べるため、事前アンケートを実施した。アンケート結果で上位の行動を図 1 に示す。また、使用者の多い家電を図 2 に示す。

アンケートの結果から、被験者の半数以上が行っている行動を今回推定する行動ラベルに設定した。また、被験者の半数以上が持っている家電を選択し実験に利用することとした。

3.2 実験環境

実験環境は導入容易性を考慮して構築した。導入容易性とは、以下の指標と定義する。

- 一般的な方法で入手可能なデバイスを利用する
- 今回使用したデバイスの情報を表 1 に記す。

表 1 使用デバイス

デバイス名	利用
mybeacon	位置情報推定
iRemocon	温度、湿度、照度情報取得
iPod touch	位置情報推定+加速度センサ

位置情報の取得には BLE(Bluetooth Low Energy) デバイスである mybeacon[5] を利用した。このデバイスは、電池を入れるだけで動作する。今回は部屋の四隅に配置したため、合計で 4 個利用した。beacon の電波を iPod touch で受信し、三角測量を用いて位置を計算している。また、iPod touch から三軸加速度センサの値も取得している。iPod touch で利用している機能はスマートフォンでも代用可能である。現在のスマートフォンの普及率は高く、導入は容易であると考えられる。




図 3 実験環境:パターン 1




図 4 実験環境:パターン 2

温度、湿度、照度は iRemocon[6] を使用し取得した。経済産業省は「JSCA 国際標準化 WG スマートハウス標準化検討会」にて ECHONET-Lite 家電を推奨しており、今後も ECHONET-Lite 対応家電が増えると考えられる。ECHONET-Lite 対応家電は、エアーコントローラ（エアコン）や一般照明に、温度、湿度、照度を取得するプロパティが用意されており、値を取得可能である。故に、家にエアコンや一般照明があれば、ECHONET-Lite 規格を用いて情報が容易に取得可能である。

また、今回は実験環境を 2 パターン用意した。パターン 1 を図 3 にパターン 2 を図 4 に示す。既存研究では、同じ実験環境で測定したものが多い。しかし、今後実用を考えた際に、同じ家具の配置であることは稀である。今回の研究では、行動測定の分類器が異なる家具の配置でもどの程度のロバスト性を持つのかを測定するため、パターンを二つ用意して測定した。

3.3 実装システム

実装システムの仕組みを図 5 に示す。実装システムは REST 形式でデータのやり取りを行う。位置情報の計算は、三角測量でビーコンの電波強度から算出している。また、今回使用した環境の詳細情報を表 2 に示す。

3.4 実験ストーリー

今回実施した実験のストーリーについて記述する。まず、被験者は一人暮らしをしている人に限定した。そして、家




図 5 実装システム

表 2 使用デバイス詳細

iPod touch	OS	iOS9.3.5
	使用言語	swift2.2
	開発環境	Xcode 7.3
サーバー	メモリ	2GB
	CPU	コア 1
mongoDB	バージョン	2.6.3

での 2 時間の行動を記録してもらい、1 時間に短縮して実験室で同じ行動を再現してもらった。家での行動を記録する際に、同じ行動で時間が埋まるのを防ぐため、被験者には「外出」「料理」「食事」「睡眠」「読書」「仕事、勉強 (PC 使用)」から 4～5 個は必ず行うようにと指示をした。

4. データ分析

4.1 使用データ

今回使用したデータ一覧を以下に示す。

「TV との距離」「冷蔵庫との距離」「パソコンとの距離」「キッチンとの距離」「換気扇との距離」「エアコンとの距離」「炊飯器との距離」「電子レンジとの距離」「机との距離」「ベッドとの距離」「テレビの使用状態」「冷蔵庫の使用状態」「パソコンの使用状態」「キッチンの使用状態」「換気扇の使用状態」「エアコンの使用状態」「炊飯器の使用状態」「電子レンジの使用状態」「加速度 X,Y,Z」「温度」「湿度」「照度」「エリア」

位置情報今回の実験環境では BLE のビーコンは Wifi のと同じ 2.4GHz 帯を使用しているため、電波干渉の発生が予想される。実験環境で観測された Wifi 電波強度の一部を図 6 に示す。図 6 を見ると、時刻によって電波強度が大幅に変化している部分が存在することがわかる。また、今回の環境では、31 個もの Wifi の電波が観測された。

取得データを整理すると、位置情報の計算ができないデータが多く存在することが分かった。これはビーコンの電波強度から距離を算出するが、今回の実験環境を超える距離が計算された場合は、NaN としているためである。今回の実験では全体の 10 パーセントのデータが位置を計算できていなかった。通常のデータ分析では外れ値は除去するが、今回は外れ値としては扱わず、学習用データとして使用した。




図 6 Wifi 電波強度の遷移

また、位置情報は計測誤差が大きいので、A から F のエリアでの判定を行っている。今回は家電の配置を変えた場合も考慮するため、家電との相対位置を「near」「middle」「far」として計測している。サンプリングは 1 秒間隔で行っている。

4.2 行動ラベル

今回設定した行動ラベルの一覧を以下に記載する。

「テレビ視聴」「勉強 (PC 使用)」「外出」「食事」「その他」「料理」「読書」

4.3 行動推定

取得したデータに対して複数の学習方法を用いて行動推定を行った。今回使用した学習方法は svm, random forest を python の sklearn を用いて推定した。

4.3.1 SVM(Support Vector Machine)

SVM で行動指定を実施した結果を以下に示す。推定結果の混合行列は、図 7 と図 8 である。今回オープンテストでは、学習データ 6 割、テストデータ 4 割で推定を行っている。オープンテストの詳細な結果は表 4 に示す。また、主成分分析を用いて次元数を削減したデータについて SVM を利用した結果を図 9 に示す。

表 3 SVM による行動認識結果

行動ラベル	サンプル数	適合率	再現率	F 値
勉強	8432	0.9716	0.9967	0.9840
食事	4001	0.9680	0.9408	0.9542
外出	3785	0.9986	1.0	0.9993
読書	3856	0.9869	0.9980	0.9927
テレビ視聴	3074	0.9949	0.9714	0.9830
料理	1523	0.9884	0.9868	0.9876
その他	4002	0.9281	0.9100	0.9190
正答率	97.480%			

4.3.2 Random Forest

Random Forest で行動推定を実施した結果を以下に示

表 4 Random Forest による行動認識結果

行動ラベル	サンプル数	適合率	再現率	F 値
勉強	8432	0.9844	0.9889	0.9867
食事	4001	0.9624	0.9624	0.9624
外出	3785	0.9912	1.0	0.9955
読書	3856	0.9908	0.9914	0.9911
テレビ視聴	3074	0.9789	0.9797	0.9793
料理	1523	0.9950	0.9934	0.9942
その他	4002	0.9602	0.9421	0.9510
正答率	97.977%			




図 7 SVM: クローズドテストでの混合行列




図 8 SVM: オープンテストでの混合行列




図 9 SVM: 主成分削減による推定精度の遷移

す。推定結果の混合行列は、図 10 と図 11 である。今回オープンテストでは、学習データ 6 割、テストデータ 4 割で推定を行っている。オープンテストの詳細な結果は表 4




図 10 Random Forest: クローズドテストでの混合行列




図 11 Random Forest: オープンテストでの混合行列

に示す。

また、主成分分析を用いて次元数を削減したデータについて Random Forest を利用した結果を図 12 に示す。

4.3.3 サブ行動ラベルを含めた行動推定

上記に示したメインとなる 7 個の行動ラベル以外にサブ




図 12 Random Forest: 主成分削減による推定精度の遷移




図 14 Random Forest: 行動サブラベルを用いた推定

示す。

表 6 GMM-HMM による行動ラベルの推定正答率

行動ラベル	認識正答率
勉強	65.970%
食事	10.182%
外出	1.269%
読書	95.222%
テレビ視聴	43.876%
料理	97.689%
その他	25.337%




図 13 SVM: 行動サブラベルを用いた推定

ラベルとしてもデータを収集した。サブ行動ラベルを含めたラベルの一覧を以下に示す。「テレビ視聴」「勉強 (PC 使用)」「外出」「食事」「その他」「料理」「読書」「皿洗い」「掃除」「休憩」「移動」「歯磨き」「洗顔」

SVM, Random Forest 両方のオープンテストの正答率を表 5 に、混合行列を図 13 と図 14 に示す。

表 5 サブ行動ラベルの推定正答率

手法	認識正答率
SVM	97.183%
Random Forest	96.764%

4.3.4 GMM-HMM

既存研究では時系列を考慮しない機械学習を用いている場合が多い。しかし、現実のデータでは時系列データとして存在しているので、時系列の情報を保持した行動推定のために、GMM-HMM を選択した。前後の状態を含めて GMM-HMM の学習を行い、それぞれの行動ラベルごとに推定を行なった。内部状態数は 3 状態としている。また、今回はクローズドテストのみを実施した。結果を表 6 に

5. 考察

今回は環境を 2 パターン用意して実験した。しかし、家電の位置や部屋の位置情報は推定制度には直接影響しないことが分かった。複数の特徴ベクトルの組み合わせで学習を行っており、単一の特徴ベクトルに依存しているわけではないことがわかる。

今回は 20 を超える Wifi アクセスポイントの環境下で実験を行った。ビーコンによる位置推定は全体の 10 パーセントも正常に計算ができていなかった。しかし、集合住宅では複数の Wifi アクセスポイントが混在する環境が想定されるため、位置情報の計算精度の低さは考慮すべきである。本実験のように 20 を超える特徴ベクトルを用意しないと高い精度の推定を行うことは困難と考えられる。

次に、SVM の混合行列をみると、97% で推定出来ている。ただし、その他の行動ラベルの推定精度が他と比べて低いことがわかる。それぞれの特徴ベクトルのラベルごとの分散を出力した結果、その他の行動ラベルの分散が最も高い結果となった。つまり、その他の行動ラベルは広範囲に分布していることがわかる。その他の行動には、歯磨き、

洗顔、休憩、移動などの複数の行動が含まれるため、冗長に学習しようとした結果、誤分類率が上がっているのだと考えられる。次に、Random Forest の結果についてみる。SVM よりも全体的に推定精度が高いことがわかる。今回のデータには家電のオン・オフといった質的線数となるデータが含まれており、特徴ベクトルごとに分類する決定木の方が相性がいい。これは、SVM におけるスケーリングの問題が Random Forest には存在しないことが関係していると考えられる。また、Random Forest では、特徴ベクトルの重要度も出力可能である。今回の実験環境では、「PC の状態」「加速度センサ」「照度」が特に重要な特徴として出力された。ただ、上記の3つの特徴ベクトルのみで推定すると SVM だと 84%, Random Forest では 93% の認識結果となった。ここから、単一の特徴ベクトルに依存しているわけではないが、重要な特徴ベクトルは存在するということがわかる。しかし、他の特徴ベクトルが分類の邪魔をしているというわけではなく、組み合わせでさらに精度の向上につながるという結果となった。

次に主成分分析をした結果についてみる。SVM では Random Forest に比べて主成分を削減したときの推定精度の下がり方が顕著である。今回 SVM ではガウシアンカーネルを用いて無限次元に変換しているが、データ削減によりクラスの特徴が失われるため、高次元に飛ばしてもうまく推定ができなかったと考えられる。Random Forest は決定木を使用しているため、非線形の決定境界を引くことが可能である。木の深さを深くすれば、非常に複雑な決定境界を引くことができるので、次元を削減しても制度が保たれていると考えられる。主成分分析で次元数を削減してもある程度までは推定制度が維持できているため、今後 IoT デバイスの普及により、エッジからクラウドにデータを送信する際にデータ量の削減が見込める。また、生データではないので匿名化するという役割も持つ。

最後に GMM-HMM について述べる。機械学習と比較すると著しく精度が低い。初期のガウス分布の平均をランダムな値に設定したことが起因していると考えられる。GMM-HMM では初期値が推定の精度に大きく影響するため、データから適切な初期値を設定する必要がある。また、GMM-HMM では正解データでしか学習を行わない。他の機械学習は正解データと不正解データを用いて学習を行うので、他の機械学習の手法と比較して、今回のケースでは時系列処置が生かせない結果となった。

6. まとめと今後の課題

本研究では、導入容易性という観点を導入し実験環境を構築した。実験環境で取得したデータに対して行動推定というタスクを課し、データの分析を行った。SVM と Random Forest の手法を実施しそれぞれの推定結果の違いを考察した。また、時系列データの処理として GMM-HMM を

適用し考察した。今回の実験で、被験者は行動と行動の境に「移動」を行うことが多いということがわかった。推定精度を向上させるために、「移動」を行動の境目とするようなモデル化を行うことで、宅内行動推定の精度向上が見込める。また、今後より効率的な推定を考えるとき、時系列データの場合は、極端に推定結果が変わるということはないので、わかりやすいデータには粗い分類器を、難しいデータには細かい分類器を適用することで全体的な推定の効率を上げられると考えている。

謝辞 本研究の一部は JSPS 科研費 26540038 の助成を受けたものである。

参考文献

- [1] S. Hongeng, R. Nevatia, and F. Bremond: Video-based event recognition: activity representation and probabilistic recognition methods, Computer Vision and Image Understanding, pp. 129162, (2004-11).
- [2] L. Ballan, M. Bertini, A. Del Bimbo, L. Seidenari, and G. Serra: Event detection and recognition for semantic annotation of video, Multimedia tools and applications, pp. 279302, (2011-1).
- [3] Ming-Je Tsai, Chao-Lin Wu, Sipun Kumar Pradhan, Yifei Xie, Ting-Ying Li, Li-Chen Fu, and Yi-Chong Zeng: Context-aware Activity Prediction using Human Behavior Pattern in Real Smart Home Environments, IEEE International Conference on Automation Science and Engineering (CASE), pp. 168-173, (2016-8).
- [4] 守谷一希, 中川愛梨, 諏訪博彦, 藤本まなと, 荒川豊, 木村亜紀, 三木智子, 安本 慶一: ECHONET Lite 対応家電を用いた宅内行動データの収集と分析, マルチメディア, 分散, 協調とモバイル (DICOMO2016) シンポジウム論文集, pp.1449-1457, (2016-7).
- [5] Aplix: MyBeacon, <https://mybeacon-store.stores.jp/>, (参照 2017-7).
- [6] GLAMO INC: iRemocon <http://i-remocon.com/>, (参照 2017-7).