

複数 Wi-Fi 受信機を用いた CSI ベースの日常行動推定の評価

寺本京祐[†] 斎藤隆仁^{††} 池田大造^{††} 西村雅史[†] 水野忠則^{†††} 峰野博史[†]

[†]静岡大学情報学部 ^{††}株式会社 NTT ドコモ ^{†††}愛知工業大学情報科学部

1. はじめに

近年, IoT や AI の発展, スマートハウス化に伴ってセンシング技術や日常行動推定に注目が集まっている. 既存のセンシング技術としては, カメラを用いたものと加速度センサ等を用いたものがある. しかし, カメラやウェアラブルセンサを用いたものでは, プライバシーの問題や, デバイスの着脱といった課題がある. これらの課題を解決する技術として, Wi-Fi 通信を用いたセンシング技術が注目されている. 特に Wi-Fi 通信を用いたセンシング技術では, Wi-Fi チャンネル状態情報 (Channel State Information: CSI) を用いた手法がある.

本研究では CSI ベースの行動推定手法として, 想定する環境内に複数の CSI 受信機を設置し, それぞれの CSI データを用いた深層学習による推定結果から, より複雑な行動を推定可能とする手法を提案する. これにより, より広範囲かつ高精度な行動推定を目指す.

2. 関連研究

CSI を用いた研究は, 2013 年に発表された J. Xiao らによる Pilot [1] がある. ある地点での CSI を Fingerprints としてあらかじめ記録しておくことで, 相関の高い地点を実際の位置と推定するものであり, CSI を用いて人の行動推定を行える可能性を示している.

その後, 時系列を考慮した学習として LSTM を用いた CSI ベースの行動推定手法が発表されている. S. Yousefi らは, 歩く, 走るといった基本的な行動に対し, LSTM による行動推定が最も高精度であることを示した [2]. H. Lee らは, 歩く, トイレに入る, 寝る, 食事をするといった一般住宅における基本的な日常行動に対し, 複数の受信機を設置して CSI を取得し, CNN で特徴量を抽出, LSTM で学習することで高精度な行動推定を実現している [3].

田中らの手法では, 立つ, 座るなど 5 つの基本的な生活行動に対し, CSI と動画を timestamp で同期させて収集し, 動画による自動正解ラベルによって CSI を LSTM で学習させ, 約 75% の精度で行動推定を可能にした [4].

既存研究では日常生活における多様な行動を十分に推定できているとはいえず, スマートハウスや住宅の監視システムなどへの応用を見据えた研究が期待される. 本研究では, 一般住宅における日常生活において想定される多様な行動を対象に, 複数受信機を用いた CSI を LSTM で学習することで, どのような行動が高精度に推定可能なのかについて基礎検討を行った.

3. 提案手法

提案手法は, 学習フェーズと推定フェーズで構成される. 図 1 に提案手法における推定フェーズの流れを示す. Wi-Fi 送信機 (アクセスポイント) 1 台と, 異なる場所に配置された受信機 2 台を利用する. 各受信機は, アクセスポイントから送信された Wi-Fi 信号を同時に収集する. 収集した CSI は $M_T \times M_R \times N$ 次元の複素数の時系列データとして得られる. CSI は振幅と位相が取得できるが, 本手法では CSI の振幅値は使用せずに, 位相値のみを用いるものとする. 各時刻の各次元において CSI の

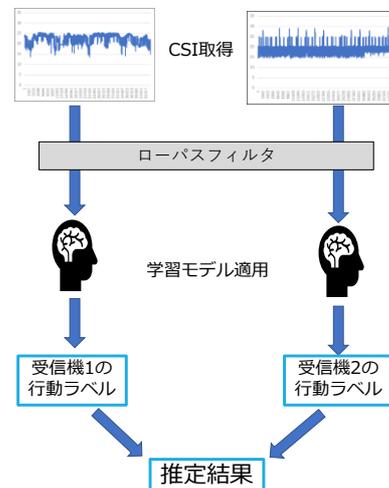


図 1 提案手法の推定フェーズの概要

相値を測定し, $M_T \times M_R \times N$ 次元の位相の時系列データを求める. 学習フェーズでは, 得られた時系列データから, 移動平均フィルタを用いてノイズの除去を行う. その後, 受信機ごとに LSTM で行動推定モデルの作成を行う. アノテーションは, [4] で実現される動画による自動正解ラベルを想定するが, 本稿では議論を容易にするため手動で正確に実施する. 推定フェーズでは, 学習フェーズ同様に 2 つの受信機から同時に CSI を収集し, フィルタ処理を行った後, 作成した受信機ごとの学習モデルで行動推定を実施する. 最後に推定フェーズにおいて, 作成した行動推定モデルを適用し, 受信機ごとに行動ラベルを取得する. 出力された複数の行動ラベルに対し, 学習時 F 値を基に推定結果を決定する. 例えば, 受信機 1 で学習時 F 値 0.7 の入室ラベルとなり, 受信機 2 では学習時 F 値 0.8 の退室ラベルとなった場合, 学習時 F 値が高かった受信機 2 の退室ラベルを最終的な推定結果とする. ただし, 無人状態のラベルのみ例外として, 受信機 1 と受信機 2 がともに無人状態となった場合のみ無人状態を推定結果とする.

4. 基礎実験と結果

基礎実験では, 将来の一般住宅での防犯や独居高齢者の生活支援システムへの応用を想定し, 浜松市環境共生住宅実験施設 (住まいのオープンラボ) にてデータを取得した. 住宅環境内では他の Wi-Fi 通信機器による参照はなく, 住宅内に他の人物がいないこと状況を想定する. 図 2 に基礎実験の実験環境を示す. 受信機を 2 台用いることとし, 受信機 1 は居間に, 受信機 2 は台所に設置し, アクセスポイントはほぼ中央の食堂に設置した. また, 学習時の正解ラベルを正確に付けるために, 2 台のカメラを行動の確認用に設置した. アクセスポイントとして Buffalo WSR-2533DHPL を使用し, 受信機は Intel 5300 無線 LAN モジュールを挿入したノート PC を 2 台使用した. CSI は, Linux CSI802.11n ツール [5] を用いて, 2 台の受信機

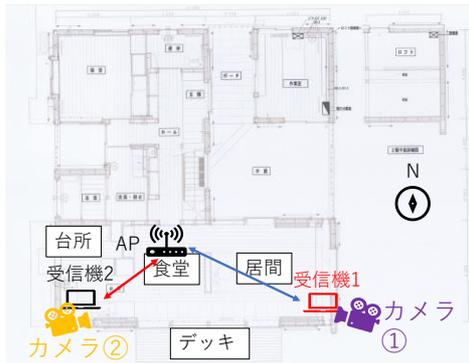


図2 基礎実験の実験環境

表1 基礎実験の収集行動

行動名	内容
無人	どの部屋にも人が居ない状態
入室	居間へ入る
座る	居間の椅子に座る
立つ	居間の椅子から立ち上がる
退室	居間から出る
椅子で静止	居間の椅子に座ったまま静止
食事をする	居間に椅子に座り、食事を取る
パソコンを する	居間の椅子に座り、パソコンを触る
床で転がる	居間の床で寝転がる
デッキ	居間からデッキに出入り

で同時に収集する。具体的には、アクセスポイントからWi-Fi通信でpingを1ms間隔で受信機に送信することでCSIを収集した。

表1に基礎実験で実施した行動一覧を示す。椅子で静止、食事、床で寝転がるについては、居間に入室してから椅子に座った後、約1分間食事等の各行動を実施してから居間を出る、という一連の行動を15回ずつ実施した。デッキの出入りについては、居間からデッキに出入りする行動を1分おきに計15回実施した。ここで、基礎実験における合計データ数は受信機1で5074個、受信機2で4784個となった。基礎実験では、提案手法の学習フェーズにおけるテストの評価結果を示す。また、本研究では比較対象として同様の条件でCSI振幅を用いた学習結果[6]と比較する。

図3(a), (b)に位相を用いた受信機ごとの混同行列を、図3(c), (d)に[6]での振幅を用いた受信機ごとの混同行列を示す。AUCは受信機1が0.691、受信機2が0.463となり、F値は受信機1が0.70、受信機2が0.43となった。

受信機1については、振幅での結果と比較して入室と退室の分類性能が35%前後から60%前後に改善している点もあるが、食事や椅子で静止などの行動が振幅と比較して下がっていることや、座る、立つといった行動の精度が改善されていないことから、全体として位相と振幅の明確な違いは見られなかった。位相での分類性能が上がらない要因として、位相でのノイズ除去が上手くいっていないことが考えられる。今後は位相の波形分析を進めつつ、位相に対して適切なフィルタ処理について検討する予定である。

受信機2については、基礎実験では主に居間での行動を収集していたため、位相と振幅共に各行動の分類性能

	無人	入室	座る	立つ	退室	椅子で静止	食事	パソコン	床で転がる	デッキ
無人	82.4%	3.8%	0.6%	4.4%	1.3%	1.9%	0.0%	1.9%	3.1%	
入室	9.5%	61.9%	9.5%	3.2%	9.5%	1.6%	4.8%	0.0%	0.0%	
座る	20.6%	5.9%	95.3%	0.0%	17.6%	0.0%	17.6%	2.9%	0.0%	
立つ	0.0%	0.0%	50.0%	18.2%	9.1%	9.1%	13.6%	0.0%	0.0%	
退室	5.6%	16.7%	11.1%	2.8%	58.3%	2.8%	0.0%	0.0%	2.8%	
椅子で静止	13.2%	0.0%	7.5%	0.0%	0.0%	67.5%	7.5%	0.0%	3.8%	
食事	4.0%	0.0%	8.0%	0.0%	14.0%	0.0%	82.0%	4.0%	0.0%	
パソコン	0.0%	0.0%	2.9%	0.0%	0.0%	0.0%	0.0%	87.1%	0.0%	
床で転がる	0.0%	0.0%	0.0%	1.9%	5.7%	0.0%	0.0%	92.5%	0.0%	
デッキ	46.7%	13.3%	10.0%	0.0%	0.0%	0.0%	3.3%	0.0%	26.7%	

(a) 受信機1の位相での混同行列

	無人	入室	座る	立つ	退室	椅子で静止	食事	パソコン	床で転がる	デッキ
無人	91.8%	3.2%	0.0%	0.0%	1.3%	0.0%	1.3%	0.0%	0.0%	2.5%
入室	28.6%	55.6%	0.0%	1.6%	3.2%	0.0%	7.9%	0.0%	0.0%	3.2%
座る	25.9%	11.1%	18.5%	14.8%	0.0%	0.0%	14.8%	11.1%	0.0%	3.7%
立つ	12.5%	16.7%	8.3%	16.7%	4.2%	4.2%	37.5%	0.0%	0.0%	0.0%
退室	43.2%	27.0%	5.4%	2.7%	16.2%	0.0%	2.7%	0.0%	0.0%	2.7%
椅子で静止	58.3%	0.0%	0.0%	0.0%	0.0%	4.2%	25.0%	10.4%	2.1%	0.0%
食事	56.3%	0.0%	0.0%	0.0%	0.0%	2.1%	41.7%	0.0%	0.0%	0.0%
パソコン	34.4%	0.0%	0.0%	0.0%	0.0%	0.0%	6.3%	59.4%	0.0%	0.0%
床で転がる	65.0%	3.8%	0.0%	1.9%	0.0%	7.5%	13.2%	0.0%	7.5%	0.0%
デッキ	55.1%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	3.3%

(b) 受信機2の位相での混同行列

	無人	入室	座る	立つ	退室	椅子で静止	食事	パソコン	床で転がる	デッキ
無人	85.0%	5.3%	0.5%	0.0%	2.4%	0.5%	0.0%	1.9%	1.0%	
入室	37.5%	33.3%	4.2%	0.0%	15.3%	1.4%	4.2%	2.8%	0.0%	1.4%
座る	22.9%	11.4%	14.3%	0.0%	2.9%	11.4%	17.1%	5.7%	2.9%	
立つ	14.8%	7.4%	7.4%	7.4%	18.5%	7.4%	7.4%	14.8%	7.4%	
退室	26.9%	13.5%	0.0%	9.6%	36.5%	9.6%	0.0%	1.9%	1.9%	
椅子で静止	61.1%	0.0%	0.0%	0.0%	0.0%	83.7%	0.0%	10.2%	0.0%	
食事	1.8%	0.0%	3.6%	0.0%	0.0%	91.1%	3.6%	10.9%	0.0%	
パソコン	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	100.0%	0.0%	
床で転がる	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	96.4%	0.0%	
デッキ	74.3%	5.7%	0.0%	0.0%	2.9%	0.0%	0.0%	0.0%	0.0%	17.3%

(c) 受信機1の振幅での混同行列[6]

	無人	入室	座る	立つ	退室	椅子で静止	食事	パソコン	床で転がる	デッキ
無人	95.0%	3.2%	0.0%	0.0%	0.6%	0.0%	0.0%	0.0%	0.6%	0.0%
入室	39.7%	39.7%	1.6%	0.0%	11.1%	0.0%	1.6%	6.3%	0.0%	0.0%
座る	55.8%	11.1%	0.0%	0.0%	3.7%	11.1%	3.7%	14.8%	0.0%	0.0%
立つ	50.0%	4.2%	0.0%	12.5%	4.2%	12.5%	4.2%	12.5%	0.0%	0.0%
退室	64.9%	24.3%	0.0%	0.0%	8.1%	0.0%	2.7%	0.0%	0.0%	0.0%
椅子で静止	79.0%	0.0%	0.0%	0.0%	0.0%	0.0%	10.4%	0.0%	0.0%	0.0%
食事	93.8%	0.0%	0.0%	0.0%	0.0%	0.0%	2.1%	4.2%	0.0%	0.0%
パソコン	37.5%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	82.5%	0.0%	0.0%
床で転がる	75.2%	1.9%	0.0%	0.0%	1.9%	1.9%	0.0%	0.0%	15.1%	0.0%
デッキ	100.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%

(d) 受信機2の振幅での混同行列[6]

図3 基礎実験の結果

は低いが、無人状態での分類が多いことから、居間での行動が受信機2には影響をあまり及ぼさないことが確認できた。つまり、台所での行動推定は、受信機2のCSIデータから高精度に実施できる可能性があると考えられる。

5. おわりに

本研究では、一般住宅における日常生活において想定される多様な行動を対象に、複数受信機を用いたCSIをLSTMで学習することで、どのような行動が高精度に推定可能なのかについて基礎検討を行った。基礎実験では、一部の行動で精度が低くなっていたが、日常生活で想定される様々な複数の行動を推定できる可能性を確認できた。

今後、推定フェーズでの評価を行いつつ、居間以外の台所や食堂での行動推定、提案手法における学習器やフィルタ処理の検討を進め、日常生活で想定される様々な複数の行動を高精度に推定できるよう研究を進めていく。

謝辞

本研究の一部は、JST 創発的研究支援事業 (JPMJFR201B) の支援を受けたものである。また、実験環境の支援をいただいた浜松市住まいの研究会と浜松市環境部環境政策課の方々に感謝の意を表す。

参考文献

- [1] Jiang Xiao, et al.: Pilot: Passive Device-Free Indoor Localization Using Channel State Information, IEEE 33rd International Conference on Distributed Computing Systems, pp.236-245 (2013)
- [2] Siamak Yousefi, et al.: A Survey on Behavior Recognition Using WiFi Channel State Information, IEEE Communications Magazine, Vol. 55, pp.98-104 (2017).
- [3] Hoonyong Lee, et al.: Fine-grained occupant activity monitoring with Wi-Fi channel state information: Practical implementation of multiple receiver settings, Advanced Engineering Informatics, Vol.46 (2020).
- [4] 田中悠貴, 石坂拓海, 斎藤隆仁, 池田大造, 峰野博史, “動画による正解ラベルを用いたCSIベース行動認識の検討,” 第83回情報処理学会全国大会 (2021).
- [5] Daniel Halperin, et al.: Tool release: gathering 802.11n traces with channel state information, ACM SIGCOMM Computer Communication Review, Vol. 41, pp. 53-53 (2011).
- [6] 寺本京祐, 斎藤隆仁, 池田大造, 西村雅史, 水野忠則, 峰野博史, “複数受信機を用いたCSIベースの日常行動推定に関する検討,” 第33回CDS研究発表会 (2022).