

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

寺本 京祐¹ 斎藤 隆仁² 池田 大造² 西村 雅史¹ 水野 忠則³
峰野 博史¹

概要: 近年, スマートハウス化に伴った日常行動の推定手法に関する研究が進められている. 行動推定手法の中でも, プライバシーに配慮した Wi-Fi CSI ベースの行動推定手法が研究されており, 屋内における人の動きを CSI のみで推定可能であることが示されている. ただしこれまでの研究では, 座る, 立つといった単純な行動を対象としたものが多く, 日常生活で想定される多岐に渡る複雑な行動を推定することまでは想定していない. 本研究では, 複数の CSI 受信機を用いて日常生活で想定される複雑な行動を推定可能とすることを目標とする. 提案手法では, 複数の CSI 受信機によって収集された CSI に対し, それぞれの CSI データを入力とした LSTM を用いた行動推定を実施し, 各行動推定結果から学習時 F 値を用いることで最終的な行動推定を行う. 一般住宅を模した実験施設での基礎実験の結果, 部屋の推定精度で F 値 0.88, 10 種類の日常行動推定では 70%以上を示す行動とそうでない行動が判別した.

キーワード: CSI, Wi-Fi, 行動推定

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, カメラを用いたものでは, 人が映ることによるプライバシーの問題や, 夜間など暗い場所での行動推定が困難といった課題がある. 一方, センサを用いたものでは, デバイスの着脱が必要となるといった使用者への負担が課題として挙げられる. これらの課題を解決する技術として, Wi-Fi 電波を用いたセンシング技術が注目されている. Wi-Fi 電波は伝搬中に減衰していくため, 通信の距離によって受信電波強度が低下する. また, 室内においては反射や回折など電波が干渉しあうことで, 受信電波強度が変動するフェージングという現象も生じる. このような減衰等の発生する Wi-Fi の電波の変位を分析することで, 人の行動を推定する研究が盛んに行われている. 特に Wi-Fi 無線を用いたセンシング技術では, Wi-Fi の受信電波強度 (Received Signal Strength Indicator: RSSI) を用いた手法と Wi-Fi チャンネル状態情報 (Channel State Information: CSI) を用いた手法がある.

RSSI とは, Wi-Fi 通信におけるデータリンク層で計測される電波強度を示す値のことである. RSSI は, 複数の経路で受信される電波を組み合わせることで表現され, 出力は単一の振幅情報のみである. RSSI を活用した行動検知や屋内測位の研究も多数行われているが, 複数経路からの電波情報を組み合わせた振幅情報のみでは, 詳細な環境変化の影響まで表現されにくく複雑な行動を検知するのは難しい.

一方, CSI は Wi-Fi 通信における物理層で用いられる送受信機間の電波路の状態を表す情報である[1]. CSI は電波

の反射や回折による振幅と位相の変化を複素数の絶対値と偏角で表現している. 電波は直行周波数分解多重 (Orthogonal Frequency Division Multiplexing: OFDM) により異なる周波数を直交させることで一度に複数の情報伝達が可能となる. つまり, 異なる直交する周波数をもつサブキャリアごとに CSI が収集可能となる. X_i と Y_i をそれぞれ i 番目のサブキャリアで得られる M_T 次元の送信ベクトルと M_R の受信ベクトルとすると, 式 1 の関係が得られる.

$$Y_i = H_i X_i + N_i \quad (1)$$

ここで, N_i は M_R 次元のノイズベクトルであり, H_i は i 番目のサブキャリアで得られる, $M_T \times M_R$ 次元の行列であり, 式 2 のような多次元行列として CSI を得る.

$$H_i = \begin{pmatrix} h_{i1} & \cdots & h_{iM_T} \\ \vdots & \ddots & \vdots \\ M_T & \cdots & M_T M_T \end{pmatrix} \quad (2)$$

RSSI ではサブキャリアごとの受信した波形を組み合わせているが, CSI ではサブキャリアごとのデータを多次元行列の形で保持できることから, 経路ごとの物理的な環境変化をより詳細に分析しやすい. そのため, 昨今の研究成果が示すように, 人の詳細な行動を推定する場合は, RSSI よりも CSI の方が優れていると言える.

ここで, Wi-Fi 信号を用いた行動推定では, 人が受信機のある部屋とは別の部屋にいる場合や, 人と受信機との距離が長い場合において, 人の行動によって引き起こされる信号の変動が小さくなるという特徴がある. また, 信号の変動が小さくなると, ノイズと行動による変位の区別がつきにくくなるという課題も生じる[2].

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

¹ 静岡大学 情報学部情報科学科

² 株式会社 NTT ドコモ

³ 愛知工業大学情報科学部

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

2.1 加速度センサを用いた手法

加速度センサを搭載したウェアラブル端末を用いた研究は、古くから活発に研究されている。2004年にL. Baoらは、小型のウェアラブル加速度計を体の異なる部位に装着し、加速度やエネルギーなどを用いて、体活動を高精度に推定するアルゴリズムを開発した[3]。推定対象の行動は、歩行などの全身行動や、食事などの軽度の行動、ランニングといった活発な行動を対象としている。また、歩くという行動では、ゆっくり歩くと早く歩くという行動を別でラベル付けしており、一般的な日常行動の高精度な推定を実現している。

加速度センサを用いた手法では、複数利用することで行動の強度レベルの違いに関わらず比較的高精度な行動推定を実現できるが、人の体にセンサを取り付ける必要があり、実生活では装着の煩わしさという課題がある。

2.2 CSIを用いた手法

CSIを用いた研究は、2013年に発表されたJ. XiaoらによるPilot[4]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る。日常生活における行動推定まではされていないものの、CSIを用いて人の行動推定を行える可能性を示している。

また、2015年に発表されたCARM[5]では、CSIの動態と人の移動速度の相関関係を定量化したCSI速度モデルならびに、異なる人体部位の移動速度と人間活動の相関関係を定量化したCSI活動モデルの2つを用いた機械学習によって、歩く、座るといった日常行動推定を実現している。

K. AliらによるWiKey[6]では、フィルタ処理をしたCSIによってキーボードで入力した文字を高精度に推定している。キーボードへ入力する動作は非常に小さいものであるが、微小な動きであっても受信機や送信機の位置関係及びフィルタ処理などの前処理を工夫することで、CSIによって行動推定可能であることが示された。

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[7]。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[8]。ただし、これらの手法で対象とする行動は、ダイニングで食事をする、キッチンで調理をするといった、場所で行動が特定し

やすいといえ、同一の場所で異なる行動を取った場合は特に考慮していないという懸念がある。

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[9]。

2.3 関連研究まとめ

既存研究では、加速度センサやCSIなどのセンシング技術を用いて人の歩く、座るといった基本的な行動を、LSTMなどを用いて高精度に推定できることを示した。しかし、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しきれていないとはいえず、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

3.1 概要

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。学習フェーズでは、収集したCSIへフィルタ処理によるノイズ除去を行い、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、[9]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。最後に受信機ごとに出力される行動ラベルに対し、学習時F値を用いて比較することで最終的な推定結果を決定する。

3.2 CSIの前処理

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。各時刻の各次元においてCSIの振幅値を計算し、 $M_T \times M_R \times N$ 次元の振幅の時系列データを求める。

まず、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。図2に移動平均フィルタ適用前のCSIの波形と、移動平均フィルタ適用後のCSIの波形を示す。フィルタ適用前と比較して常時発生しているノイズ的な変動の減少を確認できる。

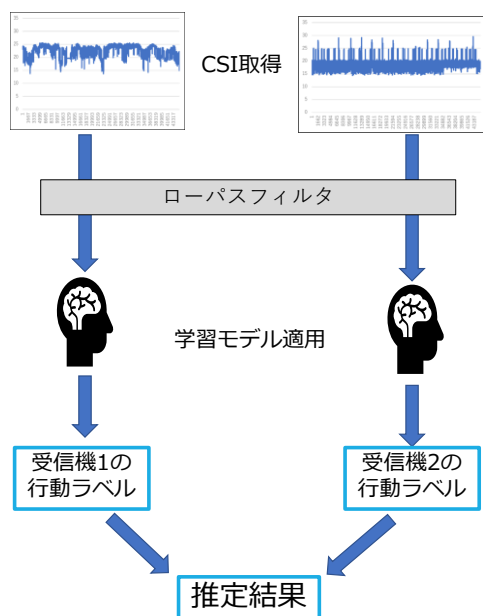


図 1 提案手法の推定フェーズの概要

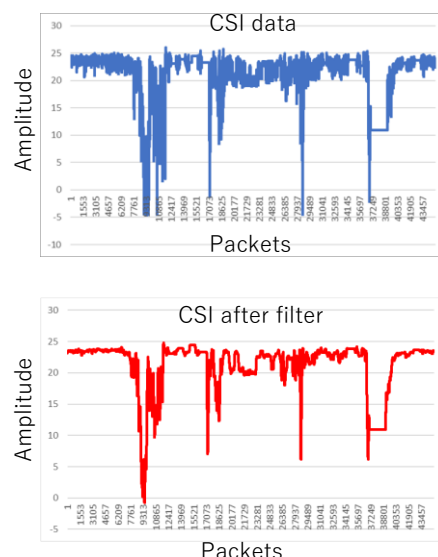


図 2 フィルタ適用前の CSI (上) とフィルタ適用後の CSI (下)

3.3 行動推定モデル作成

フィルタ適用後の CSI は 2000 パケットごとに分割して、LSTM モデルを用いて学習させる。モデルは受信機ごとに 1 つずつ構築することとし、構築されたモデルへは、学習時と推定時で同一の受信機から取得した CSI を入力として使用する。最適化アルゴリズムには Adam を使用し、学習率は 0.0001 として行動推定モデルを構築することとする。

3.4 行動推定結果

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 1

4.1 基礎実験 1 の概要

基礎実験 1 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 3 に基礎実験 1 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

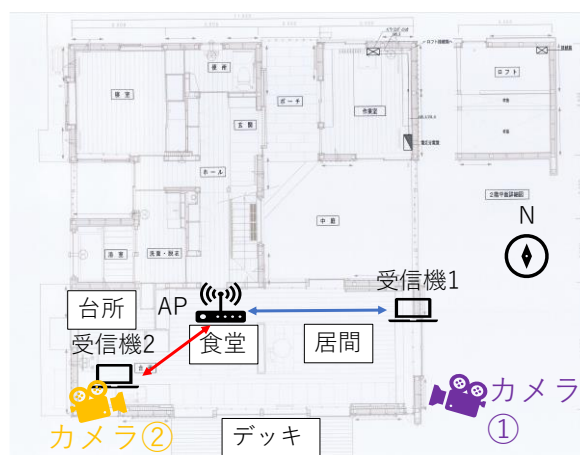


図 3 基礎実験 1 の実験環境

表 1 基礎実験 1 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
台所	台所で歩きまわる、冷蔵庫を開ける
居間	居間で歩く or 椅子に座る
食堂	食堂で歩く or 椅子に座る
デッキ	居間 or 食堂からデッキに出入り


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-253 3DHPL を使用し、受信機は Intel5300 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 CSI 802.11n ツール[10]を用いて、2 台の受信機で同時に収集す

	無人	居間	食堂	デッキ
無人	85.3%	5.5%	4.6%	4.6%
居間	10.1%	83.1%	4.5%	2.2%
食堂	1.0%	1.0%	86.9%	11.1%
デッキ	0.0%	2.0%	3.0%	95.0%


(a) 受信機1の混同行列

	無人	台所	食堂	デッキ
無人	81.3%	8.0%	3.6%	7.1%
台所	2.1%	92.8%	3.1%	2.1%
食堂	1.0%	3.1%	94.8%	1.0%
デッキ	4.2%	1.1%	0.0%	94.7%

(b) 受信機2の混同行列



(c) 受信機1のROCカーブ



(d) 受信機2のROCカーブ

図 4 基礎実験 1 の結果

る。具体的には、受信機から Wi-Fi で ping を 1ms 間隔でアクセスポイントへ送信することで CSI を収集した。

実験環境内において被験者が 15 分間台所、居間、食堂、デッキのいずれかの部屋で留まって、歩き回る、あるいは椅子に座るといった行動を行い、15 分経過後に別の部屋に移動して同様の行動を 2 回繰り返した。収集した CSI を 2000 パケットで 1 データとなるよう分割した際の合計データ数は、受信機 1 で 5468 個、受信機 2 で 5507 個となった。学習時は、実験環境における受信機配置の関係上、受信機 1 では台所の状態変化を検出することが難しく、受信機 2 では居間の状態変化を検出することが難しいと考え、受信機 1 では無人、居間、食堂、デッキの 4 状態、受信機 2 では無人、台所、食堂、デッキの 4 状態の分類とした。また、収集データの内、8 割をトレーニング用、1 割を交差検証用、1 割をテスト用として分割して学習を行った。基礎実験 1 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。

4.2 基礎実験 1 の結果・考察

図 4(a), (b) に受信機ごとの混同行列, (c), (d) に受信機ごとの ROC カーブを示す。AUC は受信機 1 が 0.883, 受信機 2 が 0.907 となり、F 値は受信機 1 が 0.88, 受信機 2 が 0.90 となった。

受信機 1 では、無人状態と居間との間、及び食堂とデッキの間で約 10% の推定誤りが発生している。無人状態と台所での推定誤りの発生原因は、受信機の位置及び行動の場所が関係すると思われる。受信機 1 は、居間の中でも北東側に配置されている。実験時に今の北東側に配置した理由は、この施設では、居間と食堂の間にインテリア調のコンクリート壁があり、アクセスポイントと受信機との間の障害物を避ける目的で北東側に配置することとした。しかし、北東側に配置したことで、居間の北側で行動していたものは CSI へ影響を及ぼされやすかったが、居間の中央部や南側での行動は CSI へ影響が大きくなり、計測データを目視分析しても十分な振幅値の変動とは言い難かった。つまり、居間と無人状態の区別が困難な CSI データであったと考える。食堂とデッキの推定誤りについては、デッキを出入りする際は食堂あるいは居間のどちらかから必ず出入りする必要があるが、食堂側にあるデッキの入り口付近にいる状態と、食堂にいるという状態で区別がつかなかったのではないかと考える。

受信機 2 については、図 4 の (b) を見ると台所、食堂、デッキのいずれも 90% 以上の推定精度であり、受信機 1 と比較すると無人状態での精度がやや低くなってしまっているが、全体的な性能では受信機 1 よりも良いと考えられる。

受信機 1, 受信機 2 ともに高精度に推定ができていたが、

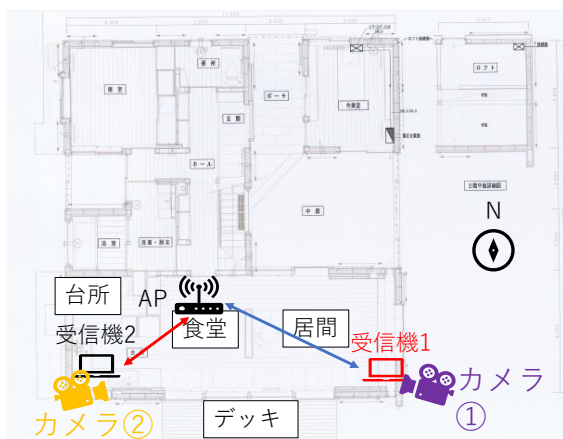


図 5 基礎実験 2 の実験環境

基礎実験 1 では 1 つの部屋ごとに 1 つの行動しか割り当てられていなかった。つまり、同一の部屋で普段とは違う行動が起きていても違いを認識することは難しい。同一の部屋での行動識別ができない場合、例えば食堂で食事をし、寝室で寝ると行動ラベルを付けて学習をした場合に、被験者が寝室で食事をし、その後就寝するという行動をした際に被験者が食事をしていないという誤推定が発生してしまう可能性がある。また、家庭での生活支援システムへの応用を想定した場合に、被験者が病気などで倒れた場合に、システムが検出できない可能性もある。よって、同一の部屋で複数の異なる行動をした場合の推定精度を検証するため、基礎実験 2 を実施することとした。

5. 基礎実験 2

5.1 基礎実験 2 の概要

基礎実験 2 では、基礎実験 1 をベースとして居間での行動に焦点を当てて実験を実施した。図 5 に実験環境を示す。ここで、基礎実験 2 では、受信機 1 を北東側ではなく南東側に設置し、居間の中央部での様々な行動による CSI 変化の影響を収集しやすくなるよう意識した。その他の計測条件は、基礎実験 1 と同様である。

表 2 に基礎実験 2 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 2 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。また、基礎実験 1 と同様に、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。

表 2 基礎実験 2 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

5.2 基礎実験 2 の結果・考察

図 6(a), (b) に受信機ごとの混同行列, (c), (d) に受信機ごとの ROC カーブを示す。AUC は受信機 1 が 0.689, 受信機 2 が 0.436 となり、F 値は受信機 1 が 0.68, 受信機 2 が 0.42 となった。

受信機 1 では、入室、座る、立つ、退室の精度が 50% を下回っており、いずれかのクラスに推定誤りが偏っている訳でもないため、これら行動の CSI の特徴を上手く学習できていないことが想定される。特徴抽出が上手くできていない要因として、各サブキャリアで CSI の変動パターンに類似性が低くなっていることが考えられる。図 7 に、受信機 1 で収集された入室から座る、立つ、退室までを記録した CSI から抽出した 10 個のサブキャリア波形を示す。目視では、サブキャリアごとに振幅値が大きく異なっており、各サブキャリア同士の波形パターンの類似度が低いように見える。そこで、時系列データ同士の距離や類似度を測る際によく利用される DTW (Dynamic Time Warping) を用いて波形同志の類似度を算出し比較した。DTW の算出は、各行動で 1 分間記録した CSI のうち、10 個のサブキャリア分のデータを抽出し DTW を求めた。ただし、入室、座る、立つ、退室は一つの行動が短時間なものであるため、入室から退室までの一連の流れとして記録した CSI で DTW を算出している。

表 3 に各行動の DTW を示す。ほとんどの行動は、DTW の値は 17 万から 20 万までの範囲であるが、入室から退室までの行動のみ DTW が 23 万と大きい値となっており、他の行動と比較して類似度が低いことがわかる。よって、サブキャリアごとの波形パターンが、他の行動と比較して大きく異なることから、入室、座る、立つ、退室の精度が低くなってしまったと考える。サブキャリアごとの波形パターンに大きな違いが生じる原因については、今後詳細分析を進めていく予定である。


デッキからの出入りについては、半分以上が無人状態と

	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	88.0%	5.3%	0.5%	0.0%	2.4%	0.5%	0.0%	0.5%	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%	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%	7.4%
退室	26.9%	13.5%	0.0%	9.6%	36.5%	9.6%	0.0%	0.0%	1.9%	1.9%
椅子で静止	6.1%	0.0%	0.0%	0.0%	0.0%	83.7%	0.0%	10.2%	0.0%	0.0%
食事	1.8%	0.0%	3.6%	0.0%	0.0%	9.1%	70.9%	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%	0.0%
床で転がる	0.0%	0.0%	0.0%	0.0%	3.4%	0.0%	0.0%	0.0%	96.6%	0.0%
デッキ	74.3%	5.7%	0.0%	0.0%	2.9%	0.0%	0.0%	0.0%	0.0%	17.1%


(a) 受信機1の混同行列
 ROC Curves

	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	95.6%	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	55.6%	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%	0.0%	2.7%	0.0%	0.0%
椅子で静止	89.6%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	10.4%	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%	62.5%	0.0%	0.0%
床で転がる	79.2%	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%

(b) 受信機2の混同行列
 ROC Curves



(c) 受信機1のROCカーブ



(d) 受信機2のROCカーブ

図 6 基礎実験 2 の結果




図 7 受信機 1 から収集した CSI

表 3 各行動の DTW と平均取得パケット数

行動名	DTW の値	平均パケット数
無人	187930.613	522packets/sec
入室から退室	236170.252	454packets/sec
椅子で静止	195787.249	502packets/sec
食事	178659.075	513packets/sec
パソコン	182126.624	495packets/sec
床で転がる	179846.955	520packets/sec
デッキ	174402.811	341packets/sec

推定されてしまっている。無人状態と推定されてしまう要因として、CSI 取得に用いている ping の通信が遅延していることが考えられる。本実験では、CSI 取得のために毎秒 1000 パケットずつ ping を送信しているため、毎秒 1000 パケットほどの CSI データが収集されることが想定される。しかし、表 3 の平均取得パケット数を見ると、デッキの 1 秒間の平均パケット数は 340 パケットほどしか取れておらず、デッキのドアを開ける時に通信が乱れてしまい、CSI が上手く取れていなかったため、無人状態と区別がつかなく

なってしまったと考える。パケット数が少なくなってしまう原因を調査しつつ、ping の応答時間から通信や計測が不安定な状況の CSI データを除去するような仕組みを実装することで、分類性能を向上させられると考える。

受信機 2 については、基礎実験 2 では主に居間での行動を収集していたため、各行動の分類性能は低いですが、ほぼ全ての行動時に無人状態での分類になっていることから、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 C

SI 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。

6. 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。部屋別における 5 種類の行動を分類した基礎実験では、全ての行動で 80%以上の精度を実現できることを確認した。また、同一の部屋でより現実的な 10 種類の行動を分類する基礎実験では、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、居間以外で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] IEEE Computer Society: Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) Specification (2012).
- [2] Hao Wang, Daqing Zhang, Yasha Wang, Junyi Ma, Yuxiang Wang, Shengjie Li, RT-fall: a real-time and contactless fall detection system with commodity WiFi devices, *IEEE Trans. Mob. Computing*, vol.16, pp.511-526 (2017).
- [3] Ling Bao, Stephen S. Intille, Activity Recognition from User-Annotated Acceleration Data, *Pervasive Computing*, pp.1-17 (2004).
- [4] Jiang Xiao, Kaishun Wu, Youweh Yi, Lu Wang, Lionel M. Ni, Pilot: Passive Device-Free Indoor Localization Using Channel State Information, *IEEE 33rd International Conference on Distributed Computing Systems*, pp.236-245(2013)
- [5] Wei Wang, Alex X. Liu, Muhammad Shahzad, Kang Ling, Sanglu Lu, Understanding and Modeling of WiFi Signal based Human Activity Recognition, *Proceedings of the 21st Annual International Conference on Mobile Computing and Networking*, pp.65-76 (2015).
- [6] Kamran Ali, Alex X. Liu, Wei Wang, Muhammad Shahzad, Keystroke Recognition Using WiFi Signals, *Proc*

- eedings of the 21st Annual International Conference on Mobile Computing and Networking*, pp.90-102 (2015).
- [7] Siamak Yousefi, Hirokazu Narui, Sankalp Dayal, Stefano Ermon, Shahrokh Valaei, A Survey on Behavior Recognition Using WiFi Channel State Information, *IEEE Communications Magazine*, Vol.55, pp.98-104 (2017).
- [8] Hoonyong Lee, Changbum R Ahn, Nakjung Choi, Fine-grained occupant activity monitoring with Wi-Fi channel state information: Practical implementation of multiple receiver settings, *Advanced Engineering Informatics*, Vol. 46 (2020).
- [9] 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).
- [10] Daniel Halperin, Wenjin Hu, Anmol Sheth, David Weatherall, Tool release: gathering 802.11n traces with channel state information, *ACM SIGCOMM Computer Communications Review*, Vol.41, pp.53-53(2011).