

CSIを用いたデバイスフリーユーザの位置推定 に関する実験的考察

福島 健¹ 村上 友規² アベセカラ ヒランタ² 猿渡 俊介¹ 渡辺 尚¹

概要: 室内において様々なアプリケーションを実現するためにデバイスフリーユーザの位置を高い精度で推定できる手法が求められている。本稿では、IEEE 802.11ac で規定されている CSI フィードバック情報を基にしたデバイスフリーユーザの位置を推定する CSI (Channel State Information) の学習システムを提案する。提案する CSI 学習システムは既存の Wi-Fi デバイスから送信される CSI フィードバックフレームの取得と 624 個の特徴量の算出を行う。その後、機械学習と算出した 624 個の特徴量を用いてデバイスフリーユーザの位置推定を行う。筆者らはデバイスフリーユーザとアンテナの向きを考慮して 6 つのデータセットを用いた実験を通して位置推定における提案システムの性能を評価した。評価の結果、位置推定における提案システムは 7 つの位置に対してユーザの位置を推定する場合、約 96 % の精度で正しく推定することを示す。また、分散した CSI の値を用いた場合、位置推定の精度が向上することを示す。

1 はじめに

ユーザの位置情報はナビゲーション、AR (Augmented Reality)、ホームオートメーション等で重要な役割を果たすことが予想される。精度の高い位置情報を取得するためにこれまでにカメラ [1]、超音波 [2]、赤外線 [3]、RSSI (Received Signal Strength Indication) [4–6]、CSI [7, 8] 等を利用した様々な屋内でのユーザ、またはデバイスの位置推定手法が提案されてきた。しかしながら、既存の位置測位手法にはそれぞれ問題点が存在する。これらの問題については 2 節にて詳細な説明を行う。

本稿では IEEE 802.11ac で規定されている圧縮されたフィードバック情報を基にした CSI 学習システムを提案する。また、提案する CSI 学習システムを用いたデバイスフリーユーザの位置推定の評価を行う。提案システムはアクセスポイント、端末、キャプチャデバイスを用いて CSI フィードバックフレームから取得できる角度情報を活用する。これによりアクセスポイントや携帯端末の Wi-Fi カードを交換することなく、既存の Wi-Fi デバイスのみで CSI を取得することができる。提案システムを 6 つのデータセットで 7 つの位置推定を正しく行うことができるか評価を行った結果、精度が最も高いモデルの推定精度は約 96% の正答率を達成した。

¹ 大阪大学大学院情報科学研究科

² 日本電信電話株式会社 NTT アクセスサービスシステム研究所

本稿の構成は以下の通りである。2 節では、室内における位置測位に要求される要件と関連研究について説明する。3 節では、IEEE 802.11ac で規定されている圧縮された CSI フィードバック情報を用いた CSI 学習システムを提案する。4 節では提案する CSI 学習システムを用いたデバイスフリーユーザの位置推定の評価結果について述べる。最後に 5 節でまとめとする。

2 関連研究

室内における位置測位は以下の要件を満たす必要がある。

- デバイスフリー
- 安価な配備コスト

ユーザの負担を考慮した場合、デバイスフリーな位置測位の実現が望ましい。もしユーザが室内で位置測位を行うためにデバイスを保持している場合、デバイスのバッテリーの浪費やデバイスの紛失が問題として起こりうるためである。また、目的の場所に位置推定システムを配備する際、コストは低いことや容易に配備できることが望ましい。

室内における位置推定手法として、カメラ [1]、超音波 [2]、赤外線 [3] を用いた手法は高い精度を達成する。しかしながら、これらの手法には以下のような課題が存在する。例えば、配備コストが高い、LoS (Line-of-Sight)

で環境でなければ使用できない、広範囲で利用する場合は多数のセンサーが必要であるといった課題が存在する。

上記の課題を解決するために、無線信号を用いた手法が注目されている [4-18]。無線信号を用いた手法は既存の携帯端末、ラップトップ、またはその他の汎用デバイスを用いるため NLoS (non Line-of-Sight) 環境や広範囲で使用できる。例えば、RSSI を用いた位置推定手法が提案されている [4-6]。RSSI を用いた位置推定手法は既に配備された無線デバイスを利用できるため、導入コストが安価であるという利点を持つ。しかしながら、RSSI を用いた位置推定の精度を向上させることは困難である。なぜなら、RSSI はデバイス毎に固有の誤差が存在する、粒度が粗い等の欠点が存在するためである。

CSI は RSSI と比べて詳細な情報を取得できると考えられている。CSI を用いた室内における位置測定には、フィンガープリントを基にした手法と ToA (Time-of-Arrival)/AoA (Angle-of-Arrival) を基にした手法の 2 つが存在する。フィンガープリントを基にした手法として、PhaseFi [13] や LiFS [7] が存在する。PhaseFi と LiFS では 30 個のサブキャリアを CSITool [19] を用いて取得する。取得した 30 個のサブキャリアを位置推定に利用するデータベースの作成に活用する。LiFS はさらに複数のアクセスポイントを利用して取得したユーザの移動した軌道をデータベース作成時に用いるため、RSSI を用いた手法よりも精度が高い。しかしながら、PhaseFi と LiFS は Intel 5300 Network Interface Cards や USRP (Universal Software Radio Peripherals) のような特殊な無線デバイスを追加導入する必要がある。

ToA/AoA を基にした手法として、Chronos [16] や SpotFi [18] 等が存在する。Chronos は ToA を、SpotFi は AoA を室内における位置測位に利用する。例えば、Chronos では CSI を 35 チャンネル分計測した後それぞれの CSI から伝搬遅延を計測する。それぞれの CSI から算出した伝搬遅延の値を用いて ToA を計測する。しかしながら、ToA/AoA を基にした手法でユーザの位置を推定する場合はユーザ自身が無線デバイスを所持している必要がある。

3 CSI 学習システム

デバイスフリーかつ配備コストが安価な室内における位置推定を実現するために、筆者らは IEEE 802.11ac で規定された CSI フィードバックを用いた CSI 学習システムを設計した。図 1 に提案する CSI 学習システムを用いた位置推定手法における学習と推定の手順を示す。具体的な手順は以下の通りである。1. CSI フィードバックから CSI の抽出; 2. CSI から取得できるビット列を角度情報 ϕ , ψ に変換; 3. 角度情報 ϕ , ψ から $\sin \phi$ と $\cos \phi$,

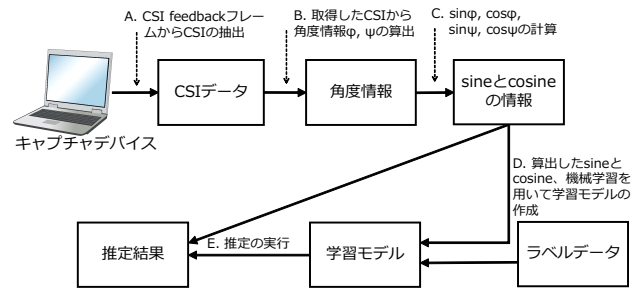


図 1 IEEE 802.11ac で規定された CSI フィードバックを用いた CSI 学習システム

$\sin \psi$ と $\cos \psi$ をそれぞれ算出; 4. 機械学習を用いてデータベースを作成; 5. 推定; 上記の 5 つの手順を用いて学習と推定を行う。

3.1 CSI フィードバックの取得方法

キャプチャデバイスは複数のアクセスポイントと端末間で送信された CSI フィードバックを識別できるため、提案する CSI 学習システムはアクセスポイントと端末の数が増加しても容易に対応できる。加えて、提案する CSI 学習システムでは IEEE 802.11ac で規定されたパケットのみを使用するため、既製品の無線デバイスから CSI を取得することができる。

図 2 に CSI フィードバックを取得するためのシステムの構成を示す。また、図 3 にアクセスポイントと端末間で行われる CSI フィードバックを取得する際のフレームシーケンスを示す。アクセスポイントと端末は IEEE 802.11ac の規格を利用できる。最初に、アクセスポイントは NDPA (Null Data Packet Announcement) と NDP (Null Data Packet) を端末に送信する。NDPA とはチャンネルサウンディングの開始を通知するフレームである。NDP とはチャンネル情報を推定するためのフレームである。端末が NDP を受信した後、端末は CSI フィードバックをアクセスポイントに送信する。CSI フィードバックとは NDP を基に計算された CSI をフィードバックするためのフレームである。最後に、キャプチャデバイスが端末からアクセスポイントに向けて送信される CSI フィードバックをキャプチャする。以上の手順により、CSI フィードバックを取得することができる。NDPA, NDP, CSI フィードバックは IEEE 802.11ac で規定されている。

3.2 ビット列を角度情報 ϕ , ψ への変換

1 つの CSI フィードバックフレームには 52 個のサブキャリアが含まれている。それぞれのサブキャリアには異なる圧縮された角度情報 ϕ と ψ が含まれている。 ϕ はアンテナ毎の位相の差を表す。また、 ψ はアンテナ間の振幅の比を表す。式 (1) と式 (2) はそれぞれ ϕ rad と ϕ




図 2 CSI 学習システムの構成

図 3 CSI を取得するためのフレームシーケンス

表 1 CSI フィードバック行列の大きさと取得できる角度情報の関係 [20]

行列の大きさ	関係 [20]	
	角度情報の数	取得できる角度情報
2 × 1	2	ϕ_{11}, ψ_{21}
2 × 2	2	ϕ_{11}, ψ_{21}
3 × 1	4	$\phi_{11}, \phi_{21}, \psi_{21}, \psi_{31}$
3 × 2	6	$\phi_{11}, \phi_{21}, \psi_{21}, \psi_{31}, \phi_{22}, \psi_{32}$
3 × 3	6	$\phi_{11}, \phi_{21}, \psi_{21}, \psi_{31}, \phi_{22}, \psi_{32}$
4 × 1	6	$\phi_{11}, \phi_{21}, \phi_{31}, \psi_{21}, \psi_{31}, \psi_{41}$
...

rad の値を示す [20].

$$\phi = \frac{k\pi}{2^{b_\phi-1}} + \frac{\pi}{2^{b_\phi}} \quad (1)$$

$$\psi = \frac{k\pi}{2^{b_\psi+1}} + \frac{\pi}{2^{b_\psi+2}} \quad (2)$$

$$k = 0, 1, \dots, 2^{b_\psi} - 1$$

k は ϕ と ψ の分解能を示す。 b_ϕ と b_ψ はそれぞれ ϕ と ψ のビット数を示す。 b_ϕ と b_ψ は CSI フィードバックの MIMO (Multiple-Input Multiple-Output) コントロールが SU (Single-User) と MU (Multi-User) のどちらであるかによって決定する。提案する CSI 学習システムは SU タイプのフィードバックを用いる。フィードバックタイプが SU の場合、 (b_ϕ, b_ψ) は (4, 2), または (6, 4) のどちらかである。本稿で提案する CSI システムでは $(b_\phi, b_\psi) = (6, 4)$ である。 ϕ と ψ が示す値の範囲は、それぞれ $\frac{\pi}{64} \leq \phi \leq \frac{127\pi}{64}$ と $\frac{\pi}{32} \leq \psi \leq \frac{31\pi}{64}$ である。

提案する CSI 学習システムでは、312 個の角度情報を取得できる。 ϕ と ψ の数は CSI フィードバック行列の大きさ ($N_r \times N_c$) によって変化する。 N_r は CSI フィードバック行列の列の値を示す。また、 N_c は CSI フィードバック行列の行の値を示す。表 1 に CSI フィードバック行列の大きさと取得できる角度情報の関係を示す。本稿で提案する CSI 学習システムでは $N_r = 4, N_c = 1$ であるため、CSI フィードバック行列の大きさは 4×1 である。表 1 から、提案する CSI 学習システムは 1 つのサブキャリアから角度情報 $\phi_{11}, \phi_{21}, \phi_{31}, \psi_{21}, \psi_{31}, \psi_{41}$ を取得することができる。すなわち、1 つの CSI フィードバックフレームから $52 \times 6 = 312$ 個の角度情報を取得することができる。

3.3 $\sin \phi$ と $\cos \phi, \sin \psi$ と $\cos \psi$ の計算

ϕ と ψ の単位は rad であるため、提案する CSI 学習システムでは取得できた角度情報をそのまま機械学習には利用しない。例えば、角度情報 $2\pi - 0.1$ rad と 0.1 rad は CSI 上では極めて近い特徴を示すはずであるが、単純な rad の比較を行った場合に離れた特徴を示すことになる。



図 4 本実験で利用するアクセスポイント

ϕ と ψ の不連続性を解消するために、提案する CSI 学習システムでは ϕ と ψ をそれぞれ $\sin \phi$ と $\cos \phi, \sin \psi$ と $\cos \psi$ へ変換する。すなわち、312 個の角度情報から 624 個の特徴量が取得できる。

3.4 機械学習を用いた学習モデルの作成

提案する CSI 学習モデルは算出された $\sin \phi$ と $\cos \phi, \sin \psi$ と $\cos \psi$ の値にラベルデータを加えた値を用いて学習モデルを作成する。ラベルデータには、空間内における人数、室内の温度、ドアが開いている/閉じている等の様々な状態を数値として入力することができる。例えば、4 節ではデバイスフリーユーザの位置をラベルデータとして使用している。

加えて、どの機械学習を利用するか自由に選択することができる。例えば、4 節では K-Nearest Neighbors, Random Forest, Support Vector Machine を使用している。

3.5 デバイスフリーユーザの位置推定

提案する CSI 学習システムは取得できた CSI から人の位置を表すラベルの値を推定する。例えば、4 節ではデバイスフリーユーザの位置を K-Nearest Neighbors, Random Forest, Support Vector Machine を用いて推定する。

4 室内における位置推定の実験的評価

4.1 実験における設定

筆者らはデバイスフリーユーザの位置推定に対する直接波と間接波の影響、並びに人の動作の影響を評価するために、以下の 6 つのデータセットを用いて評価を行っ

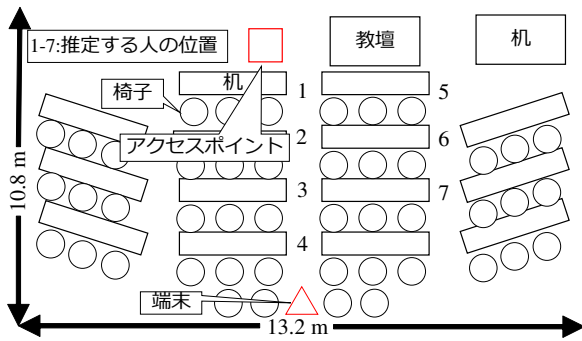


図 5 実験を行う環境

表 2 実験におけるパラメータ

パラメータ	説明
キャプチャ時間	1 分間
CSI feedback 間隔	平均 10 ミリ秒
チャンネル周波数	5.2 GHz
機械学習	K-Nearest Neighbor Random Forest Support Vector Machine

た. 図 4 に本実験で使用するアクセスポイントを示す. 筆者らはアクセスポイントのアンテナが立っている状態だと端末はアクセスポイントから送信される直接波を容易に受信できると想定している. また, アクセスポイントのアンテナが寝ている状態だと端末はアクセスポイントから送信される間接波を容易に受信できると想定している. 6つのデータセットは以下のとおりである.

- 4つ全てのアンテナを立てており, デバイスフリーユーザは図 5 における 7つの位置で立ったまま静止している状態 (four upright staying),
- 4つ全てのアンテナを立てており, デバイスフリーユーザは図 5 における 7つの位置で足踏みしている状態 (four upright walking),
- 4つ全てのアンテナを寝かせており, デバイスフリーユーザは図 5 における 7つの位置で立ったまま静止している状態 (four laid staying),
- 4つ全てのアンテナを寝かせており, デバイスフリーユーザは図 5 における 7つの位置で足踏みしている状態 (four laid walking),
- 2本のアンテナを立てせ残りの 2本は寝かせており, デバイスフリーユーザは図 5 における 7つの位置で立ったまま静止している状態 (two upright two laid staying),
- 2本のアンテナを立てせ残りの 2本は寝かせており, デバイスフリーユーザは図 5 における 7つの位置で足踏みしている状態 (two upright two laid walking).

表 3 表 4-表 9 の平均正答率

位置推定におけるデータセット	K-Nearest Neighbor	Random Forest	Support Vector Machine
four upright staying	21	20	33
four upright walking	53	62	69
four laid staying	53	53	50
four laid walking	63	66	61
two upright two laid staying	66	39	55
two upright two laid walking	88	89	96

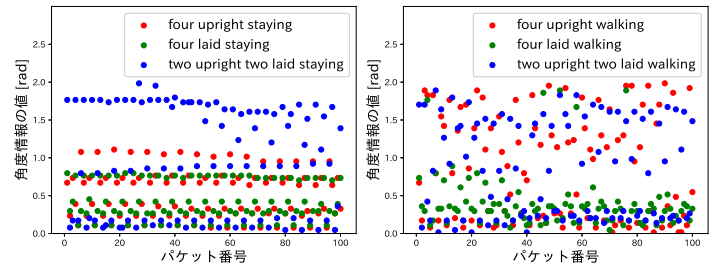


図 6 ユーザが静止している場合の ϕ_{11} 図 7 ユーザが動いている場合の ϕ_{11}

表 2 に本実験におけるパラメータを示す. CSI の取得は 1 分間行い, その間の CSI フィードバックの間隔は平均で 10 ミリ秒である. 提案する CSI 学習システムは 1 つのデータセットに約 1400 個の CSI フィードバックパケットを利用できる. チャンネル周波数は 5.2GHz を利用する. 機械学習には K-Nearest Neighbor, Random Forest, Support Vector Machine の 3 つの手法を利用する.

図 5 に本実験の環境を示す. 図 5 の赤い四角部分がアクセスポイントの位置を示している. また, 図 5 の赤い三角部分が端末の位置を示す. 実験場所は NTT 横須賀 R&D センター 1 階で行った. 図 5 内の数字は学習したデバイスフリーユーザの位置を示す. 実験環境の大きさは 10.8 m × 13.2 m である.

4.2 結果

表 3 に 6 つのデータセット, 3 つの機械学習方式を用いた際のデバイスフリーユーザの位置推定の平均精度を示す. 表 4-表 9 は 6 つのデータセットを用いた際のデバイスフリーユーザの位置推定結果を示す. また, 表 4-表 9 における列と行はそれぞれデバイスフリーユーザの実際の位置と推定結果の位置を示す. 表内の数字の単位はパーセントである.

表 4-表 9 の結果から, 以下の事がわかる. 1 つ目に, two upright two laid walking では Support Vector Machine を用いた場合が最も精度が良いことがわかる.

2 つ目にデバイスフリーユーザが動いている時のデータセットを用いた推定がデバイスフリーユーザが静止している時のデータセットを用いた推定に比べて精度が良

表 4 混合行列:four upright staying の位置推定結果

	K-Nearest Neighbor							Random Forest							Support Vector Machine						
	1	2	3	4	5	6	7	1	2	3	4	5	6	7	1	2	3	4	5	6	7
1	68	5	0	22	3	2	0	70	0	0	30	0	0	0	73	0	0	27	0	0	0
2	3	62	33	1	1	0	0	2	52	28	17	0	0	0	23	70	7	0	0	0	0
3	1	27	4	68	0	0	0	88	4	5	3	0	0	0	1	0	0	99	0	0	0
4	3	49	33	15	0	0	0	72	3	12	13	0	0	0	11	0	4	85	0	0	0
5	0	85	3	12	0	0	0	34	46	20	0	0	0	0	0	0	0	100	0	0	0
6	0	47	28	25	0	0	0	22	37	41	0	0	0	0	0	0	0	100	0	0	0
7	0	97	0	3	0	0	0	32	39	29	0	0	0	0	0	0	0	100	0	0	0

表 5 混合行列:four upright walking の位置推定結果

	K-Nearest Neighbor							Random Forest							Support Vector Machine						
	1	2	3	4	5	6	7	1	2	3	4	5	6	7	1	2	3	4	5	6	7
1	31	0	0	5	22	19	23	38	0	0	8	20	17	17	38	0	0	8	5	11	38
2	31	69	0	0	0	0	0	13	87	0	0	0	0	0	1	99	0	0	0	0	0
3	2	9	44	1	20	10	14	3	9	43	4	17	7	17	2	9	44	4	14	2	25
4	1	4	29	33	14	9	10	1	5	6	57	15	4	12	1	3	7	59	6	1	23
5	0	0	0	0	81	1	18	0	0	0	0	83	0	17	0	0	0	0	95	0	5
6	0	0	0	0	11	65	24	0	0	0	0	16	63	21	0	0	0	0	9	67	24
7	0	0	0	0	27	22	51	0	0	0	0	18	20	62	1	0	0	0	8	11	80

いことがわかる。表 9 は two upright two laid walking の混合行列である。また、表 8 は two upright two laid staying の混合行列である。表 8 から、ユーザが静止しているときのデータセットは図 5 における 5, 6, 7 のようなアクセスポイントの端末間に位置していない場所の推定を行う場合に精度が悪くなることわかる。

3 つ目にアンテナの向きが重要であることがわかる。すなわち、two upright two laid walking の精度は four upright と four laid よりも良いことがわかる。表 5 は four upright walking の混合行列である。また、表 7 は four laid walking の混合行列である。four upright walking と four laid walking はいずれの場所においても誤差が発生しているが、two upright two laid walking だとどの場所においても高い精度で推定が可能であることがわかる。

上記の通りアンテナ 2 本を立たせ、残り 2 本を寝かせ、かつユーザが動いている場合にデバイスフリーユーザの推定精度が向上した。このことから、分散した CSI の値が機械学習を用いた推定精度を向上させることがわかる。

アンテナ 2 本を立たせ、残り 2 本のアンテナを寝かせかつユーザが動いている時に CSI の値が分散しているかどうかを確認するために ϕ_{11} の時間変動による値の変化を確かめる。図 6 と図 7 はそれぞれ図 5 の 1 の位置においてユーザが図 5 の 1 にて静止している時に取得した ϕ_{11} の値とユーザが図 5 の 1 にて動いている時に取得した ϕ_{11} の値を示す。横軸は CSI フィードバックパケット

の番号を示す。また、縦軸は CSI フィードバックパケットから算出できた角度情報の値を示す。

図 6 と図 7 から以下の 2 つのことが分かる。1 つ目に、ユーザが動いている時の角度情報の値はユーザが静止している時の角度情報と比べて変動していることがわかる。2 つ目に、two upright two laid のデータセット内の角度情報は four upright datasets と four laid datasets 内の角度情報に比べて変動していることがわかる。PhaseFi [13] や PADS [14] では位置推定に線形変換を用いているため、安定した CSI を取得することで位置推定の精度が向上すると述べられている。しかしながら、本研究では既存の研究とは異なる傾向を示した。

5 まとめ

本稿では IEEE 802.11ac で規定された CSI フィードバックフレーム意を用いた CSI 学習システムを提案した。筆者らが提案した CSI 学習システムは既存の Wi-Fi デバイスのみ利用で実装することができる。提案した CSI 学習システムは圧縮された 6 つの角度情報をデバイスフリーユーザの位置推定に活用する。筆者らは提案した CSI 学習システムをアクセスポイントのアンテナの向きとデバイスフリーユーザの動作を考慮した 6 つのデータセットを用いて評価した。評価の結果から 6 つのデータセットを用いた位置推定の中で two-upright two-laid を用いた位置推定が最も推定精度が高かった。ユーザが動いている時のデータセットを用いた位置推定はユーザが

表 6 混合行列:four laid staying の位置推定結果

	K-Nearest Neighbor							Random Forest							Support Vector Machine						
	1	2	3	4	5	6	7	1	2	3	4	5	6	7	1	2	3	4	5	6	7
1	71	6	22	1	0	0	0	66	12	11	11	0	0	0	55	23	19	3	0	0	0
2	14	33	15	36	0	1	1	17	36	25	22	0	0	0	8	39	36	15	0	0	2
3	0	0	81	19	0	0	0	0	0	95	5	0	0	0	0	0	76	23	0	0	1
4	5	11	6	73	0	2	3	9	8	10	72	0	0	1	0	13	7	76	0	0	4
5	5	8	0	0	26	22	39	15	10	0	0	18	27	30	7	23	0	0	14	32	24
6	3	8	0	0	3	61	25	4	4	0	0	6	53	33	2	12	0	0	3	63	20
7	14	20	0	6	5	29	26	19	17	1	7	4	22	30	9	27	1	6	2	28	27

表 7 混合行列:four laid walking の位置推定結果

	K-Nearest Neighbor							Random Forest							Support Vector Machine						
	1	2	3	4	5	6	7	1	2	3	4	5	6	7	1	2	3	4	5	6	7
1	92	5	1	1	0	1	0	95	3	1	1	0	0	0	88	2	6	3	0	1	0
2	13	50	16	2	5	5	9	11	56	16	4	6	4	13	5	35	21	3	7	2	27
3	8	10	60	6	5	6	5	8	11	66	0	7	4	4	6	8	71	3	6	1	5
4	1	5	16	69	3	4	2	3	4	24	63	2	2	2	0	2	26	66	1	4	1
5	0	0	0	0	62	9	29	0	0	0	0	60	13	27	0	0	1	0	52	29	18
6	2	12	3	1	11	50	21	5	12	2	2	13	54	12	2	11	7	3	15	50	12
7	0	0	0	22	6	11	61	0	2	0	21	4	8	65	0	0	0	24	1	7	68

静止している時のデータセットを用いた位置推定よりも精度が高く、また、分散した CSI の値がデバイスフリーユーザの位置推定精度を向上させることがわかった。

謝辞

本研究は JSPS 科研費 (JP16H01718, JP17KT0042), NTT アクセスサービスシステム研究所の支援の下で行った。

参考文献

[1] Chaquet, J. M., Carmona, E. J. and Fernández-Caballero, A.: A Survey of Video Datasets for Human Action and Activity Recognition, *Computer Vision and Image Understanding*, Vol. 117, No. 6, pp. 633–659 (2013).

[2] Minami, M., Fukuju, Y., Hirasawa, K., Yokoyama, S., Mizumachi, M., Morikawa, H. and Aoyama, T.: DOLPHIN: A practical approach for implementing a fully distributed indoor ultrasonic positioning system, *Proceedings of the International Conference on Ubiquitous computing (ACM UbiComp'04)*, Berlin, Heidelberg, pp. 347–365 (2004).

[3] Kemper, J. and Hauschildt, D.: Passive infrared localization with a probability hypothesis density filter, *Proceedings of the IEEE Workshop on Positioning Navigation and Communication (IEEE WPNC'10)*, Dresden, Germany, pp. 68–76 (2010).

[4] Seifeldin, M., Saeed, A., Kosba, A. E., El-Keyi, A. and Youssef, M.: Nuzzer: A Large-Scale Device-Free Passive Localization System for Wireless Environments, *IEEE Transactions on Mobile Computing*, Vol. 12, No. 7, pp. 1321–1334 (2013).

[5] Wang, J., Xie, B., Fang, D., Chen, X., Liu, C., Xing,

T. and Nie, W.: Accurate device-free localization with little human cost, *Proceedings of the 1st International Workshop on Experiences with the Design and Implementation of Smart Objects (Smart Objects'15)*, New York, NY, USA, pp. 55–60 (2015).

[6] Youssef, M., Mah, M. and Agrawala, A.: Challenges: device-free passive localization for wireless environments, *Proceedings of the 13th annual ACM International Conference on Mobile Computing (ACM MobiCom'07)*, New York, NY, USA, pp. 222–229 (2007).

[7] Wang, J., Jiang, H., Xiong, J., Jamieson, K., Chen, X., Fang, D. and Xie, B.: LiFS: low human-effort, device-free localization with fine-grained subcarrier information, *Proceedings of the 22nd Annual International Conference on Mobile Computing and Networking (ACM MobiCom'16)*, New York, NY, USA, pp. 243–256 (2016).

[8] Yang, W., Gong, L., Man, D., Lv, J., Cai, H., Zhou, X. and Yang, Z.: Enhancing the performance of indoor device-free passive localization, *International Journal of Distributed Sensor Networks*, Vol. 11, No. 11, p. 256162 (2015).

[9] Fadel, A., Zachary, K. and Dina, K.: Multi-Person Localization via RF Body Reflections, *Proceedings of the 12th USENIX Symposium on Networked Systems Design and Implementation (USENIX NSDI'15)*, Oakland, CA, pp. 279–292 (2015).

[10] Wei, T. and Zhang, X.: mTrack: High-Precision Passive Tracking Using Millimeter Wave Radios, *Proceedings of the 21st Annual International Conference on Mobile Computing and Networking (ACM MobiCom'15)*, New York, NY, USA, pp. 117–129 (2015).

[11] Joshi, K., Bharadia, D., Kotaru, M. and Katti, S.: WiVideo: Fine-grained Device-free Motion Tracing using RF Backscatter, *Proceedings of the 12th USENIX*

表 8 混合行列:two upright two laid staying の位置推定結果

	K-Nearest Neighbor							Random Forest							Support Vector Machine						
	1	2	3	4	5	6	7	1	2	3	4	5	6	7	1	2	3	4	5	6	7
1	100	0	0	0	0	0	0	92	8	0	0	0	0	0	100	0	0	0	0	0	0
2	80	18	2	0	0	0	0	80	18	2	0	0	0	0	24	64	2	0	0	0	0
3	0	43	57	0	0	0	0	0	43	57	0	0	0	0	0	0	44	56	0	0	0
4	0	0	0	100	0	0	0	0	0	0	100	0	0	0	0	0	0	100	0	0	0
5	0	0	0	16	84	0	0	0	0	0	100	0	0	0	0	0	0	100	0	0	0
6	0	0	0	51	0	0	49	50	0	5	45	0	0	0	0	0	0	100	0	0	0
7	0	0	0	0	0	0	100	0	0	38	32	0	0	30	0	0	21	0	0	0	79

表 9 混合行列:two upright two laid walking の位置推定結果

	K-Nearest Neighbor							Random Forest							Support Vector Machine						
	1	2	3	4	5	6	7	1	2	3	4	5	6	7	1	2	3	4	5	6	7
1	80	1	15	0	0	0	0	82	6	10	2	0	0	0	91	0	9	0	0	0	0
2	1	87	12	0	0	0	0	1	87	12	0	0	0	0	1	99	2	0	0	0	0
3	5	0	91	4	0	0	0	5	0	91	4	0	0	0	0	0	100	0	0	0	0
4	0	1	3	96	0	0	0	0	1	3	96	0	0	0	0	0	7	93	0	0	0
5	0	0	0	0	89	9	2	0	0	0	0	89	9	2	0	0	0	0	97	3	0
6	0	0	0	0	16	82	2	0	0	0	0	16	82	2	0	0	0	0	2	89	9
7	0	0	0	0	4	0	96	0	0	0	0	4	0	96	0	0	0	0	4	0	96

Symposium on Networked Systems Design and Implementation (USENIX NSDI'15), Oakland, CA, pp. 189–204 (2015).

[12] J. Min, P., C. Ki, A., Y. S, S., Peng, S. and M. Taeg, L.: Accurate and Reliable Human Localization Using Composite Particle/FIR Filtering, *IEEE Transactions on Human-Machine Systems*, Vol. 47, No. 3, pp. 332–342 (2017).

[13] Xuyu, W., Lingjun, G. and Shiwen, M.: CSI-Based Fingerprinting for Indoor Localization: A Deep Learning Approach, *IEEE Transactions on Vehicular Technology*, Vol. 66, No. 1, pp. 763–776 (2017).

[14] Qian, K., Wu, C., Yang, Z., Liu, Y. and Zhou, Z.: PADS: Passive detection of moving targets with dynamic speed using PHY layer information, *Proceedings of the 2014 20th IEEE International Conference on Parallel and Distributed Systems (IEEE IC-PADS'14)*, Hsinchu, Taiwan, pp. 1–8 (2014).

[15] Gao, R., Wang, H., Wu, D., Niu, K., Yi, E. and Zhang, D.: A Model Based Decimeter-scale Device-free Localization System Using COTS Wi-fi Devices, *Proceedings of the 2017 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2017 ACM International Symposium on Wearable Computers (ACM Ubicomp'17)*, New York, NY, USA, pp. 241–244 (2017).

[16] Vasisht, D., Kumar, S. and Katabi, D.: Decimeter-Level Localization with a Single WiFi Access Point., *Proceedings of the USENIX Symposium on Networked Systems Design and Implementation (USENIX NSDI'16)*, Santa Clara, CA, pp. 165–178 (2016).

[17] Gong, W. and Liu, J.: SiFi: Pushing the Limit of Time-Based WiFi Localization Using a Single Commodity Access Point, *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies (ACM IMWUT'18)*, Vol. 2, No. 1, p. 10 (2018).

[18] Kotaru, M., Joshi, K., Bharadia, D. and Katti, S.: SpotFi: Decimeter Level Localization Using WiFi, *Proceedings of the ACM Conference on Special Interest Group on Data Communication (ACM SIGCOMM'15)*, New York, NY, USA, pp. 269–282 (2015).

[19] Daniel, H., Wenjun, H., Anmol, S. and David, W.: Linux 802.11n CSI Tool, <https://dhalperi.github.io/linux-80211n-csitol/>.

[20] IEEE: IEEE Standard for Information technology–Telecommunications and information exchange between systems Local and metropolitan area networks–Specific requirements - Part 11: Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) Specifications, *IEEE Std 802.11-2016 (Revision of IEEE Std 802.11-2012)*, pp. 1–3534 (2016).