

# モバイル端末の Wi-Fi チャンネル状態情報による混雑推定法の提案

水谷 優秀<sup>1</sup> 内山 彰<sup>1</sup> 村上 友規<sup>2</sup> アベセカラ ヒランタ<sup>2</sup> 東野 輝夫<sup>1</sup>

**概要:** 本研究では、少数の固定基地局に加えてモバイル端末 (スマートフォン) を利用し、モバイル端末と固定基地局間で取得したチャンネル状態情報 (Channel State Information: CSI) に基づき、機械学習によって空間全体の混雑状況を推定する。また、対象空間における詳細な領域ごとの混雑状況を把握するため、フレネルゾーン付近に人がいる場合、CSI が大きく変化することに着目して、フレネルゾーンへ付近の人の通過を検知する。一般に CSI を用いた混雑推定では場所に依存した混雑推定モデルの構築が必要となるが、本研究では場所の変化による影響が少ない特徴量を利用し、モバイル端末による混雑推定を実現する。混雑推定モデルが場所の変化に対して堅牢であることを示すため、実環境でデータを収集し、複数の位置で取得した CSI に対して混雑推定を行った。結果より、0 から 9 人の 3 人刻み 4 段階の混雑推定において、平均正解率 49.5% となり、場所が変化したときの正解率の低下は 15 ポイントに抑えられることが分かった。さらに、複数台で得られた結果を平均することにより、3 台では 62%、5 台では 76% まで正解率が上昇する結果が得られた。また、フレネルゾーン付近の通過検知の平均正解率は 80.0% であった。

## 1. はじめに

ショッピングモールや駅、空港など多くの人が利用する施設において、施設内の場所ごとの混雑状況を詳細に把握できれば、マーケティングや避難誘導への活用が期待できる。これまで人の混雑状況を推定する手法として、カメラを用いたもの [1] や Wi-Fi プローブ情報を用いたもの [2] など様々な手法が提案されているが、カメラを用いた手法では死角が無くなるようカメラの追加設置が必要であったり、プライバシーの侵害が懸念される。また、Wi-Fi プローブ情報を用いた手法では、一人一台端末を所持していることが必要となり、二台の端末を所持している人や、端末を所持していない人が増えるにつれて推定精度が低下するという課題がある。これらに対し、既存設備を利用し混雑状況を推定する目的での追加デバイスが少ない手法として Wi-Fi のチャンネル状態情報 (Channel State Information: CSI) を利用したものが注目されている [3], [4], [5], [6]。

CSI は 802.11n 以降で規定された Multiple-Input and Multiple-Output (MIMO) による通信を実現するために送受信機間で取得される情報であり、デジタル変調の一種である直交周波数分割多重方式 (Orthogonal Frequency Division Multiplexing: OFDM) のサブキャリアごとに、通

信アンテナ間での位相および振幅の変化量を複素数として取得可能である。受信信号強度インジケータ (Received Signal Strength Indicator: RSSI) を用いた混雑推定も提案されている [7]。しかし CSI は RSSI よりも多くの電波状況に関する情報を得ることができるため、CSI を用いた人の高精度な行動センシング [8] や混雑推定が数多く提案されている [3], [4], [5], [6], [9]。これまでの CSI を用いた混雑状況推定の手法では、CSI を取得するために通信を行う送受信機の位置を固定しているため、混雑の推定範囲が送受信機間の電波伝搬に影響を与える領域に限定される。したがって、比較的広いショッピングモールなどで導入する場合には、Wi-Fi 基地局本来の用途以上に多数の基地局を設置する必要があり現実的でない。そこで、本研究では少数の固定基地局に加え、スマートフォンなどのモバイル端末を併用する。これによって、Wi-Fi 基地局は通信のために設置するという本来の目的を失うことなく、対象環境の混雑推定の実現を目指す。

モバイル端末を用いる際の課題として、位置が変化することが挙げられる。CSI は電波伝搬環境の物理的な変化を鋭敏に捉えるため、端末の位置変化は CSI に影響を及ぼすことが考えられる。しかし CSI を用いた混雑推定に関する先行研究では、いずれも送受信機を固定しているため、位置変化による CSI への影響について報告されていない。そこで、我々はこれまでに端末位置に依存しない混雑特徴量

<sup>1</sup> 大阪大学大学院情報科学研究科

<sup>2</sup> NTT アクセスサービスシステム研究所

の調査を実施し、CSIの分散が有効であることを示している [10]。提案手法では、CSIの分散を特徴量として機械学習により対象領域全体の混雑推定モデルを構築する。さらに、より詳細な領域ごとの混雑推定を実現するため、送受信機間のフレネルゾーン付近を対象とした混雑推定法を設計した。送受信機間のフレネルゾーン付近を人が通過した場合に、CSIが大きく変動することに着目し、ピーク検出に基づきフレネルゾーン付近の通過人数を推定する。

CSIの分散を特徴量とした機械学習では、地点によらず40~60%程度の精度で空間全体の人数を推定した。さらに、同時刻において複数地点で得たCSIに対して同様に機械学習によって混雑推定を行い、その推定結果を平均することで、3地点では62%、5地点では79%の推定精度を達成した。この結果は、複数のモバイル端末でCSIを取得することによって推定精度が向上する可能性を示す。また、フレネルゾーンへの人の検出での正解率は80%となった。

## 2. 関連研究

### 2.1 CSIを用いた混雑推定

CSIを用いて混雑状況を推定するため、室内に設置した送受信機間で得られるCSIを用いた方式がこれまでにいくつか提案されている [3], [4], [5], [6]。文献 [3]ではTransfer Kernel Learning(TKL)を用いることで室内での人数推定を実現しており、0から7人の分類ではおよそ96%の正解率を達成している。また、文献 [4]ではPercentage of nonzero Elements(PEM)という特徴量を定義し、電波の伝搬経路におけるゆらぎの大きさを数値化したうえで、グレイモデルに基づき室内の人数を推定している。これらの既存研究では、いずれもCSI取得のために通信を行う送信機と受信機の両方を固定し、教師あり学習によって人数を推定している。このため、送受信機のいずれかの位置が変化した場合には、改めて教師データを収集する必要がある。文献 [5]では、ある部屋で取得したCSIによる教師データによって作成した学習モデルを別の部屋での人数推定に利用しており、大幅な性能低下は見られないことが報告されているが、送受信機間の位置関係に応じて、混雑推定性能がどのように変化するかは明らかにされていない。

### 2.2 モバイル端末を用いた混雑推定

モバイル端末と固定基地局を用いた混雑状況の推定方式としては、Liら [7]の取り組みが挙げられる。スマートフォンと基地局間で得られるRSSIを用いて室内の人数推定を0人から50人までの10人刻みで実現している。しかし、8m×12mの部屋に31台もの基地局を設置しており、高いコストがかかることが懸念される。これに対して本研究では、モバイル端末と固定基地局間で取得されたCSIを用いて、少数の基地局でも広い範囲を対象とした混雑推定の実現を目指している。

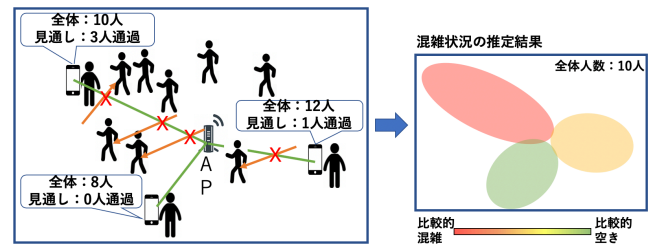


図1 混雑マップ作成概要図

## 3. Channel State Information

無線LAN関連規格IEEE 802.11n以降の規格では、送信機と受信機のそれぞれで複数のアンテナを用いた送受信が行われるMIMOを採用している。また、直交周波数分割多重方式(OFDM)によってデータは複数のサブキャリアに乗せて送られる。CSIでは、このOFDM変調におけるサブキャリアごとの振幅やアンテナ間の位相差を取得することができる。したがって、 $N_{Tx}$ 本の送信アンテナ、 $N_{Rx}$ 本の受信アンテナに対して、サブキャリア数を $S$ とすると、CSIを取得する度に $N_{Tx} * N_{Rx} * S$ 個の振幅および位相差の情報が得られる。これによって、従来用いられてきたRSSIに比べて非常に多くの電波状況に関する情報を得ることができるため、通信性能の向上という本来の目的に加えて、混雑状況推定や人の行動認識への応用が期待されている。

## 4. 提案手法

### 4.1 システム概要

本研究では、多くの人々が利用する施設のフロア全体のリアルタイムの混雑ヒートマップ(以下、混雑マップと呼ぶ)を作成することを目標としている。混雑マップを作成するにあたり、空間全体の人数を推定する手法(混雑推定法)と、送受信機間のフレネルゾーン付近の人の通過を検知する手法(通過検知法)を組み合わせることで、対象領域全体のみならず、詳細な場所ごとの混雑推定を実現する。

例えば、3台のモバイル端末で混雑推定を行った混雑マップは図1のようになる。図1では送信機をWi-Fi基地局、受信機をスマートフォンとして通信を行っている。CSIを取得した端末はそれぞれ、空間全体の人数の推定結果とフレネルゾーンを通過した人数を検知し、サーバに送信する。サーバに集約された推定結果をマップに重ね合わせることで、空間全体の混雑マップが作成される。なお、本研究ではWi-Fiを用いた位置推定法 [8]や歩行者自律航法 [11]などの手法によって、モバイル端末の位置が誤差数mで得られるものと仮定する。また、モバイル端末が移動中の場合、移動によるCSIの変化が非常に大きくなり、混雑推定は困難なため、加速度センサにより静止状態を検知し、混雑推定を行うものとする。

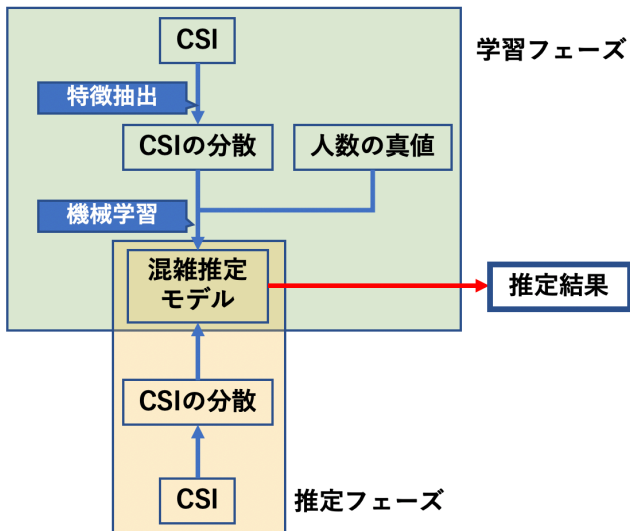


図 2 空間全体の混雑推定フローチャート




図 3 CSI の分散調査環境

表 1 6 地点における CSI の振幅 (分散) と人数

	地点 1	地点 2	地点 3	地点 4	地点 5	地点 6
0 人	0.0076	0.0165	0.0072	0.0026	0.0082	0.0198
1 人	0.0563	0.0754	0.0566	0.0235	0.1925	0.1262
3 人	0.8283	1.2239	0.9595	2.2374	1.7399	1.0172

## 4.2 混雑推定法

### 4.2.1 概要

空間全体の混雑推定法の概要を図 2 に示す。混雑推定法は学習フェーズと推定フェーズに分けられる。まず、学習フェーズでは送受信機を対象空間の任意の地点で静止させ、CSI と周囲の人数の真値を一定期間収集する。収集した CSI は送受信機の位置変化に伴って特徴が変化するため、CSI を特徴量として混雑推定モデルを作成するとモバイル端末への運用ができない。そこで、提案手法では得られた CSI から場所依存性が低い特徴量として振幅の分散を抽出する。表 1 は図 3 の環境で取得した人数ごとの CSI の分散を示している。この結果より、周囲を歩行する人数が増えるに従って、6 地点全てにおいて分散の値も増加していることがわかる。この調査に基づき、提案手法では機械学習により混雑推定モデルを構築する。

### 4.2.2 特徴量の抽出

CSI では、送信アンテナ数  $N_{Tx}$ 、受信アンテナ数  $N_{Rx}$  に対して、サブキャリア (サブキャリア数  $S$ ) ごとの振幅、位相が取得できる。各サブキャリア、アンテナ組に対して CSI の分散を特徴量として抽出することもできるが、情報が膨大となるため、以下の式によりアンテナ組および全サブキャリアの振幅の平均を求めることで次元数の削減を行った。ここで時刻  $t$  において送信アンテナ  $i$  から受信アンテナ  $j$  に到達するサブキャリア  $k$  の CSI の振幅を  $CSI_{(i,j,k)}^t$ 、時刻  $t$  における CSI の振幅の平均を  $CSI_{mean}^t$  と表す。

$$CSI_{mean}^t = \frac{\sum_{i=1}^{N_{Tx}} \sum_{j=1}^{N_{Rx}} \sum_{k=1}^S CSI_{(i,j,k)}^t}{N_{Tx} \cdot N_{Rx} \cdot S} \quad (1)$$

式 (1) で得られた  $CSI_{mean}^t$  に対し、以下の式により時刻  $t$  から時刻  $t+T$  の分散  $CSI_{var}^t$  を計算した。CSI を 1 秒間に  $f_s$  回取得し、時刻  $t$  から  $t+T$  の  $CSI_{mean}^t$  の平均値を  $\overline{CSI_{mean}^t}$  とすれば、

$$CSI_{var}^t = \frac{1}{f_s \cdot T} \sum_{i=t}^{t+f_s \cdot T} (CSI_{mean}^i - \overline{CSI_{mean}^i})^2 \quad (2)$$

となる。提案手法では  $CSI_{var}^t$  を特徴量として用いる。なお、本研究では振幅のみを特徴量として用いているが、CSI では振幅に加えて位相も得られるため、同様に位相も特徴量として抽出することが可能である。

### 4.2.3 混雑推定モデルの構築

抽出した特徴量に基づき、機械学習により混雑推定モデルの構築を行う。本研究では、機械学習アルゴリズムとして  $k$  近傍法、SVM、決定木、アンサンブル学習の 4 種類をそれぞれ用いる。これらの比較は 5.2.1 節で行う。また、同一空間に存在する  $n$  台の端末によって CSI が取得できた場合には、いくつかの統合方法が考えられるが、本研究では、推定結果の平均を採用する。

## 4.3 通過検知法

フレネルゾーンは無線通信を行う際に、通信品質を保つために確保しなければならない楕円空間であり、このフレネルゾーンを輪切り状にしたフレネル平面の 60% 以上が遮られた状態の部分があると通信品質が下がることが知られている [12]。取得した CSI の一例を図 4 に示す。横軸は時間であり、縦軸はシグナルノイズ比 [db] である。また、図中に示す矢印は、実際に人の通過した時刻を表す。

通過検知法では、フレネルゾーン付近のみから CSI が受ける影響を抽出する必要があるため、以下のようにして CSI に対してフィルタリング処理を行った。フレネルゾーンは 5[GHz] 帯を用いた場合、通信距離 50[m] であってもフレネル半径が 0.5[m] 程度なので、今回の目的である施設内での利用においては高々直径 1[m] と仮定する。人の歩行速度は平均的に時速 5[km] から 6[km] なので、フレネ






図 4 取得した CSI




図 6 フィルタリング後の CSI から得た分散




図 5 フィルタリング後の CSI

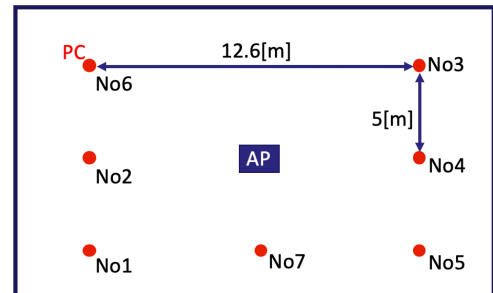


図 7 CSI 取得環境

ルゾーンの中心を横切の場合にかかる時間は高々 1 秒と想定し、CSI の振幅に対して 1[Hz] のローパスフィルタを適用した。また、常に発生するようなノイズも取り除くため 0.5[Hz] のハイパスフィルタも適用している。図 4 の CSI に対してフィルタリング処理を行った結果を図 5 に示す。さらに特徴を目立たせるため、フィルタリング後の CSI から 1 秒ごとの分散を取得した (図 6)。これに対して局所的最大値によるピーク検出を適用することで、人の通過検知を実現する。具体的には、フィルタリング後の時刻  $t$  における CSI を  $C\tilde{S}I^t$  とすれば、式 (3) のようにして  $C\tilde{S}I^t$  が局所的最大値を持つ時刻  $t$  をピークとして検出する。

$$C\tilde{S}I^{t-1} < C\tilde{S}I^t > C\tilde{S}I^{t+1} \quad (3)$$

## 5. 性能評価

### 5.1 実験環境

実験では、送信機に Wi-Fi 基地局 (ELECTOM WRC-1167GHBK-S)、受信機にノート PC (ThinkPad, Let's note)

を用いた。送信アンテナ数は 2 本、受信アンテナ数は 3 本、サブキャリア数は 30 であるため、1 度の通信において  $2 \times 3 \times 30$  次元の CSI が得られる。CSI を取得するため、Linux802.11n CSI Tool<sup>\*1</sup>[13] をノート PC にインストールした。CSI は 5[GHz] 帯の通信を用いてノート PC から ping コマンドを用いることで 10[ms] ごとに取得した。位置による比較を行う目的で、図 7 のように PC を複数台設置して実験を行った。人は 0, 3, 6, 9 人の 4 通りでランダムに歩行している状態の CSI を取得した。ここで、ランダムな歩行とは、壁まで直線的に歩行し、壁に到達すれば自由に方向転換する動作を繰り返すことである。本実験では、図 7 の 7 地点において PC を設置し各人数に対してそれぞれおよそ 5 分間 CSI を取得した。

空間全体の混雑推定法において、まず始めに CSI の取得位

<sup>\*1</sup> <https://dhalperi.github.io/linux-80211n-csitool/installation.html>

表 2 交差検証による学習精度

アルゴリズム	モデルタイプ	精度
決定木	最大分割数 100	59.3%
	最大分割数 20	62.8%
	最大分割数 4	63.4%
SVM	線形 SVM	60.9%
	2 次 SVM	62.4%
	3 次 SVM	46.2%
	カーネルスケール 7.9 ガウス SVM	61.7%
	カーネルスケール 32 ガウス SVM	61.3%
	カーネルスケール 130 ガウス SVM	26.0%
k 近傍法	近傍数 1	57.9%
	近傍数 10	63.4%
	近傍数 100	63.2%
	コサイン k 近傍法	53.1%
	3 次 k 近傍法	63.2%
	重み付き k 近傍法	58.5%
アンサンブル	ブースティング	65.3%
	バギング	60.2%
	部分空間判別	62.3%
	部分空間 k 近傍法	51.9%
	RUBoost 決定木	63.5%

表 3 混同行列

		予測されたクラス			
		0 人	3 人	6 人	9 人
真のクラス	0 人	100%			
	3 人		72%	15%	13%
	6 人		24%	70%	6%
	9 人		36%	44%	20%

置に依存すると考えられる式 (1) によって求めた  $CSI_{mean}$  を用いた場合の推定精度について、No1 の PC で取得した  $CSI_{mean}$  からモデルを構築し、No2~No7 (No5 は異常により CSI の取得に失敗したので除く) で得られた  $CSI_{mean}$  に適用した時の評価を行った。次に、今回位置に依存しない特徴量として採用した  $CSI_{var}$  で構築した混雑推定モデルの評価を同様にを行った。 $CSI_{var}$  は式 (2) における  $T$  を 10 とし、1 データあたり 10 秒分の分散を計算した。本実験では、観測値を増加する目的で  $CSI_{mean}$ ,  $CSI_{var}$  を 10 秒分ごとに切り分け混雑推定モデルへの入力としている。また、複数のモデルにおいて推定結果の平均をとった時の精度の変化についても評価した。通過検知法では同様に No1~No7 で取得した合計 1200 秒分の CSI に対してピーク検知を行い、カメラ撮影による真値とにより評価を行った。

## 5.2 実験結果

### 5.2.1 機械学習アルゴリズムの比較

決定木, SVM, k 近傍法, アンサンブル学習の 4 種のアルゴリズム, 計 20 種のモデルタイプにおいて, 式 (2) で求めた  $CSI_{var}$  を特徴量としてモデル構築を行った。分類するクラスは, 0, 3, 6, 9 人の 4 クラスである。それぞれの

表 4 場所変更時の混雑推定の正解率

	No1(交差検証)	No2	No3	No4	No6	No7
$CSI_{mean}$	98.8%	26.3%	76.5%	18.7%	31.8%	22.1%
$CSI_{var}$	64.0%	56.9%	51.3%	42.0%	46.0%	51.3%

モデルに対して 10 分割交差検証を行った結果を表 2 に示す。カーネルスケール 130 のガウス SVM, 3 次 SVM は他のモデルに対して精度が低くなっているが, それ以外においてはいずれも 50~65%程度の精度となっている。カーネルスケール 130 の粗いガウス SVM では全てのテストデータに対し 6 人と予測しており, 精度が 26.0%となっているが, カーネルスケール 32 の中程度のガウス SVM では精度が 61.3%まで向上している。この結果より, カーネルスケールは 130 では今回の分類は行えず, 32 程度に狭めることが必要であることがわかった。もっとも精度の高いアンサンブル学習のブースティングは AdaBoost を用いており, モデルタイプは決定木, 最大分割数 20, 学習器の数 30, 学習率 0.1 である。以降の評価ではこのモデルを利用することとした。

このモデルを No2 に適用した検証結果の混同行列を表 3 に示す。この結果から, 真のクラスが 0,3,6 人に限定すると 70%を超える正解率となることがわかる。しかし, 真のクラスが 9 人の場合では 6 人と 3 人に誤る推定となることが多く, 正解率が 20%と極端に下がっている。これは, 周囲の環境変化が増加するにつれて, CSI 全体的にノイズが増加し, CSI の変化が相対的に小さくなることから, ある一定以上の周囲の変化が捉えられない問題によるものである。今回の結果から,  $10 \times 12.6[m^2]$  の空間を歩行する環境において, CSI の振幅の分散のみを用いた推定では, 9 人以上の分類は難しいと考えられる。

### 5.2.2 混雑推定性能

No1 で構築した混雑推定モデルに No2~No7 で取得した CSI から計算した  $CSI_{mean}$  を入力として検証した正解率は, 表 4 の上段の通りであり, 平均 35.1%である。また,  $CSI_{var}$  を入力として検証した正解率は, 表 4 の下段であり, 平均 49.5%となった。

$CSI_{mean}$  を特徴量とした混雑推定モデルでは, 混雑推定モデルの学習データとした No1 での 10 分割交差検証による正解率は 98.8%であった。No1 での正解率のみ非常に高く, その他の地点における結果にはばらつきが見られる。このことから, No1 に過剰適合していると考えられ, モバイル端末を用いた推定には適していないといえる。

一方,  $CSI_{var}$  を特徴量とした混雑推定モデルにおいては, 先と同様に No1 で取得した CSI から抽出した特徴量によってモデルを構築し 10 分割交差検証を行ったところ正解率は 64.0%であった。No2~No7 における正解率は平均して 49.5%であり, No1 での検証結果から 15 ポイントほどの低下に抑えられた。 $CSI_{mean}$  では, CSI に壁からの反射など, 位置に依存した情報が含まれているが, CSI




図 8 複数台の平均による精度

の取得間隔 0.01 秒と比べて非常に長い 10 秒間の CSI の分散を利用することで、その影響が失われ、精度の低下が抑制されたと考えられる。しかし、情報量が減少することにより、これまで提案されている固定端末の CSI を用いた混雑推定のような 95% を超える精度 [3] は達成されていない。

### 5.2.3 複数台利用時の混雑推定性能

1~5 台の PC での混雑推定結果の平均値による正解率の比較を行った。検証は 0, 3, 6, 9 人の 4 パターンで各 100 個のテストデータを用いた。1 台の推定結果は No2 の PC のみ用い、2 台の推定結果では No2 と No3 の推定結果の平均を、5 台の推定結果では No2, 3, 4, 6, 7 それぞれの混雑推定結果の平均による正解率を評価している。例えば、5 台での推定結果が (3 人, 3 人, 6 人, 6 人, 3 人) のとき平均は 4.2 人となり、今回ラベルとした 0, 3, 6, 9 人の中で最も近い 3 人を推定結果としている。また、小数第一位で四捨五入しているため、例えば推定結果が 4.5 人の場合は 5 人となり、推定結果は 6 人としている。同時に推定する台数が増えるにつれて正解率が上がっており、5 台同時に推定した際には 76% まで正解率の向上が見られた (図 8)。推定精度が 100% である 0 人の推定は、複数端末用いた場合でも 100% であるので全体の正解率の向上には貢献しない。しかし、1 台での推定で 70% 程度の正解率である 3 人と 6 人の分類では、 $n$  台の端末を用いると  $n$  台全てが不正解となる確率が  $n$  の増加に伴って減少するので、正解率は上昇する。

### 5.2.4 通過検知の性能

No5 を除く No1~No7 の 6 台に対し、それぞれ 9 人の歩行 200 秒、のべ 1200 秒の CSI を検証データとした。カメラ映像と照らし合わせ、人のフレネルゾーン通過と通過検知のタイミングが 2 秒差以内のとき正解とした。

その結果、通過人数の真値は 220 回であり、検出数は 176 回であった。また、人が通過した際にピークが検出されなかったのは 44 回、人が通過していないがピークが検出されたのは 57 回であった。人が通過した際にピークが検出されない主な原因としては、複数人が同時に通過した場合であり、今回は 1 秒間の CSI に対して分散を用いたため、

ピークが連続し一つのピークを形成したことであると考えられる。この問題において、分散の時間幅を狭めることで 2 人とみなすことができると考えられるが、同一人物を 2 人と検知する問題とのトレードオフにあり、今後検討する必要がある。人が通過していないがピークが検出された主な原因としては、人が基地局や端末の近くを通ったが通過はしていない場合であった。この問題については、第二フレネルゾーンにおける人の影響を考慮することで精度の改善が見込まれる。

## 6. おわりに

本稿では、モバイル端末を用いた CSI による混雑推定法の提案、評価を行った。これまでの固定端末同士の CSI による混雑推定とは異なり、モバイル端末を用いた本手法では、様々な地点で CSI を取得し、混雑推定に用いることができる。これによって、電波伝搬の環境内の人の分布をより詳細に把握することが可能となる。提案手法は、空間全体の混雑推定と、フレネルゾーン付近の人の通過検知法により構成される。空間全体の混雑推定では、位置変化による精度低下を防ぐため、CSI の分散を特徴量として採用した。また、3 台のモバイル端末による推定結果の平均をとることで、1 台では 49% であった推定精度を 76% まで向上させることに成功した。通過検知法では、CSI の分散に対してピーク検出を用いることで、80% の精度で人の通過を検知した。

今後の方針として、実際に混雑マップの作成を行うとともに、CSI の位相を用いたさらなる精度の向上について検討を進める予定である。

## 参考文献

- [1] Davies, A. C., Yin, J. H. and Velastin, S. A.: Crowd monitoring using image processing, *Electronics & Communication Engineering Journal*, Vol. 7, No. 1, pp. 37–47 (1995).
- [2] Di Luzio, A., Mei, A. and Stefa, J.: Mind your probes: De-anonymization of large crowds through smartphone WiFi probe requests, *IEEE INFOCOM 2016-The 35th Annual IEEE International Conference on Computer Communications*, IEEE, pp. 1–9 (2016).
- [3] Zou, H., Zhou, Y., Yang, J., Gu, W., Xie, L. and Spanos, C.: Freecount: Device-free crowd counting with commodity wifi, *GLOBECOM 2017-2017 IEEE Global Communications Conference*, IEEE, pp. 1–6 (2017).
- [4] Xi, W., Zhao, J., Li, X.-Y., Zhao, K., Tang, S., Liu, X. and Jiang, Z.: Electronic frog eye: Counting crowd using wifi, *Infocom, 2014 proceedings IEEE*, IEEE, pp. 361–369 (2014).
- [5] Di Domenico, S., De Sanctis, M., Cianca, E. and Bianchi, G.: A trained-once crowd counting method using differential wifi channel state information, *Proceedings of the 3rd International Workshop on Physical Analytics*, ACM, pp. 37–42 (2016).
- [6] Cheng, Y.-K. and Chang, R. Y.: Device-Free Indoor People Counting Using Wi-Fi Channel State Informa-

- tion for Internet of Things, *GLOBECOM 2017-2017 IEEE Global Communications Conference*, IEEE, pp. 1–6 (2017).
- [7] Li, H., Chan, E. C., Guo, X., Xiao, J., Wu, K. and Ni, L. M.: Wi-counter: smartphone-based people counter using crowdsourced wi-fi signal data, *IEEE Transactions on Human-Machine Systems*, Vol. 45, No. 4, pp. 442–452 (2015).
- [8] Yang, Z., Wu, C. and Liu, Y.: Locating in fingerprint space: wireless indoor localization with little human intervention, *Proceedings of the 18th annual international conference on Mobile computing and networking*, ACM, pp. 269–280 (2012).
- [9] Yousefi, S., Narui, H., Dayal, S., Ermon, S. and Valaee, S.: A Survey on Behavior Recognition Using WiFi Channel State Information, *IEEE Communications Magazine*, Vol. 55, No. 10, pp. 98–104 (online), DOI: 10.1109/MCOM.2017.1700082 (2017).
- [10] 水谷優秀, 内山彰, 東野輝夫, 村上友規ほか: モバイル端末の Wi-Fi チャンネル状態情報を用いた混雑状況推定の検討, 研究報告高度交通システムとスマートコミュニケーション (ITS), Vol. 2018, No. 2, pp. 1–4 (2018).
- [11] Beauregard, S. and Haas, H.: Pedestrian dead reckoning: A basis for personal positioning, *Proceedings of the 3rd Workshop on Positioning, Navigation and Communication*, pp. 27–35 (2006).
- [12] 伊藤優希, 岩井誠人, 笹岡秀一: 室内環境におけるフレネルゾーンに基づく人体遮蔽損失特性の評価, 電子情報通信学会論文誌 B, Vol. 101, No. 9, pp. 696–705 (2018).
- [13] Halperin, D., Hu, W., Sheth, A. and Wetherall, D.: Tool Release: Gathering 802.11N Traces with Channel State Information, *SIGCOMM Comput. Commun. Rev.*, Vol. 41, No. 1, pp. 53–53 (online), DOI: 10.1145/1925861.1925870 (2011).