

# Wi-Fi チャンネル状態情報を用いた 屋内建具の開閉状態変化の検知手法

尾原 和也<sup>1,a)</sup> 前川 卓也<sup>1</sup> 松下 康之<sup>1</sup>

受付日 2016年4月7日, 採録日 2016年10月4日

**概要:** 近年の Wi-Fi 通信環境の普及により, Wi-Fi 電波を利用した屋内位置推定技術や行動認識技術の研究がさかに行われてきた. 一般に普及している Wi-Fi 技術を用いることで, 安価に位置推定や行動認識システムが構築可能となる. 本研究ではそのような Wi-Fi 技術を用いて, ドアや窓の開閉のような屋内建具の開閉状態変化を検知する手法を実現する. 提案手法は, 人の侵入検知や空調の制御, 高齢者の見守り等への応用が期待される. 本研究では, 環境内に Wi-Fi アクセスポイントと Wi-Fi モジュールを搭載した PC を 1 台ずつ設置し, PC から得られる Wi-Fi 電波の伝搬情報のみを用いることで建具の開閉状態変化を検知する手法を提案する. 本研究では Wi-Fi 電波の伝搬情報として, 各送受信アンテナ間のマルチパス情報が得られる Wi-Fi チャンネル状態情報を利用し, アンサンブル学習と隠れマルコフモデルを用いて各建具の状態の認識を行う. また, 独立成分分析を利用して各建具の状態変化によるチャンネル状態情報への影響を分離することを試みる.

**キーワード:** 建具の開閉状態変化検知, Wi-Fi チャンネル状態情報, 独立成分分析, 隠れマルコフモデル

## State Change Detection Method for Indoor Fixtures Based on Wi-Fi Channel State Information

KAZUYA OHARA<sup>1,a)</sup> TAKUYA MAEKAWA<sup>1</sup> YASUYUKI MATSUSHITA<sup>1</sup>

Received: April 7, 2016, Accepted: October 4, 2016

**Abstract:** Recently, because Wi-Fi technology is widespread, many researchers have attempted to construct indoor positioning systems and activity recognition systems by utilizing Wi-Fi signals. These systems work with already installed wireless communication networks inexpensively. In this study, we try to detect events of indoor fixtures such as door open/close and window open/close events. Our proposed method can be used for implementing such applications as intrusion detection, adaptive HVAC control, and monitoring an independently living elderly person. In this study, we achieve event detection using a commodity Wi-Fi access point and a computer equipped with a commodity Wi-Fi module. Specifically, we detect the events using Wi-Fi channel state information (CSI) that describes the effect of multipath combining ensemble learning and hidden Markov models. Also, we attempt to decompose time-series data that reflect signal changes caused by events of objects in the environment using independent component analysis (ICA).

**Keywords:** detecting state changes of indoor fixture, channel state information, independent component analysis, hidden Markov model

### 1. はじめに

近年の無線通信技術の進展により, 駅や病院, 大学等の

様々な公共施設に Wi-Fi アクセスポイント (AP) が設置され, どこでも高速なインターネットアクセスが可能になりつつある. このような様々な場所に設置された Wi-Fi AP から発信される Wi-Fi 電波を用いて, 屋内位置推定技術や行動認識技術の研究がさかに行われてきた. 一般に普及している Wi-Fi 技術を用いることで, 安価に位置推定や行

<sup>1</sup> 大阪大学大学院情報科学研究科  
Graduate School of Information Science and Technology,  
Osaka University, Suita, Osaka 565-0871, Japan

<sup>a)</sup> ohara.kazuya@ist.osaka-u.ac.jp

動認識システムが構築可能となる。

本研究ではそのような Wi-Fi 技術を用いて、ドアや窓の開閉のような屋内建具の開閉状態変化を検知する手法を実現する。具体的には、ドアや窓等の屋内建具それぞれにセンサを設置せずに、環境（部屋）内に Wi-Fi アクセスポイントと Wi-Fi モジュールを搭載した PC を 1 台ずつ設置し、PC から得られる Wi-Fi 電波の伝搬情報のみを用いることでドアの開閉といった状態変化を検知する手法を提案する。特に本研究では Wi-Fi 電波の伝搬情報として、送受信アンテナ間のマルチパス情報が得られる Wi-Fi チャンネル状態情報（Channel State Information: CSI）を用いる。

建具の状態変化の検知は、人の侵入を検知する防犯システムや空調、照明の制御のようなホームオートメーション、高齢者の見守り等の幅広い分野に応用できる。

Wi-Fi 電波は伝搬損失や反射・回折等のマルチパスの影響によって振幅と位相が変化する。CSI はこれらの影響による電波の振幅と位相の変化をそれぞれ複素数の絶対値と偏角で表す、Wi-Fi 802.11 の物理層から得られる情報である。近年では Intel 5300 等の Network Interface Card (NIC) によって CSI が得られるようになったため、CSI を用いた屋内位置推定、行動認識の研究が多数行われている。

Wi-Fi の規格である 802.11a/g/n では直交周波数分割多重方式（Orthogonal Frequency Division Multiplexing: OFDM）を用いてデータを変調している。OFDM はデータを周波数が異なった複数のサブキャリア（搬送波）に乗せる方法で、それぞれのサブキャリアの周波数は高速フーリエ変換によってそれぞれ分けられるように互いに直交する。さらに、802.11n では複数の送受信アンテナを用いる Multiple Input and Multiple Output (MIMO) という技術が使われている。各サブキャリアは周波数が異なるため、その減衰や反射の仕方が異なり、各送受信アンテナ間では異なった伝搬路によって電波が送られるため、各送受信アンテナ間のサブキャリアごと異なった振幅変化と位相変化が起こる。すなわち CSI は送信アンテナ数を  $M_T$ 、受信アンテナ数を  $M_R$ 、サブキャリア数を  $N$  とすると、 $M_T \times M_R \times N$  次元のデータとして Wi-Fi パケットごとに得られる。Wi-Fi による通信を繰り返し行えば、CSI は高次元の時系列データとなる。これまでの多くの屋内位置推定、行動認識の研究では機械学習を用いたパターン認識を行うことが多いが、高次元データである CSI を利用する場合、次元の呪いの影響を受け、識別性能が低下する。

既存の CSI を用いた研究では高次元データに対処するために、異なったサブキャリアや送受信アンテナ間のデータを統合することで次元削減をしている。Ali らは各送受信アンテナ間の  $N$  次元のデータに対して主成分分析（Principal Component Analysis: PCA）を行い、CSI を  $M_T \times M_R$  次元に削減している [1]。Chapre らはサブキャリアごとに  $M_T \times M_R$  次元のデータを加算し、そこから位相と振幅を

抽出している [2]。しかし、このような手法を用いると CSI の各次元のデータの小さな変化をとらえることが難しくなる。CSI を用いたいくつかの研究では Wi-Fi 機器の近く、もしくは送受信機の間にあるものを観測対象としているが、本研究の対象となるドアや窓等の建具は屋内の離れた場所に位置するため、CSI の小さな変化をとらえる必要がある。

そこで、本研究では高次元の時系列データに対処するために、各次元ごとに用意した弱学習器を組み合わせたアンサンブル学習器を用いる。CSI のある 1 次元のデータから抽出した特徴量によって弱学習器を構築し、これらを組み合わせることで強学習器を構築する。これにより、各弱学習器への入力を低次元に抑えた認識が可能となる。このとき、トレーニングデータ内で交差検定を行い、精度の高い弱学習器のみを用いる。対象となる建具によって有効な周波数や伝搬路は異なると考えられるため、各弱学習器の有効性の評価は対象となる建具ごとに行う。

また、弱学習器の入力として通常の CSI データに加え、CSI データに対して独立成分分析（Independent Component Analysis: ICA）を行い、独立な成分に分離したデータも用いる。ICA はブラインド音源分離に使われる手法で、複数の信号源からの信号が混ざったデータが複数の観測器によって観測されるとき、信号が互いに独立であるという仮定を用いて各信号源の信号に分離する手法である。本研究において、各建具の電波状態への影響は独立であると仮定すると、各送受信アンテナの組を観測器と見なすことができ、CSI の  $M_T \times M_R$  次元のデータに対して ICA を行うことで、各建具の利用によって生じた CSI の変化に分離できると考えられる。

本研究では建具の時系列的な状態変化をとらえるために、時系列データの学習に用いられる生成モデルである隠れマルコフモデル（Hidden Markov Model: HMM）をアンサンブル学習器に組み込む。具体的には、精度の高い弱学習器の入力および出力を組み合わせた低次元のデータを HMM の入力とし、HMM の出力を最終的な推定結果とする。これにより、有用な弱学習器の認識結果を統合したうえで、イベントの時系列性を考慮した認識が可能となる。

さらに、状態変化検知の精度を向上させるために、建具の状態に関する事前知識に基づいて構築した文法を利用する。事前知識に基づいて構築した文法とは、たとえばドアの場合、ドアを「開ける動作」は「閉じている状態」からのみ遷移し、「開ける動作」の後は「開いている状態」に必ず遷移するといったものである。各建具に関してこのような文法を作成し、HMM デコーディングに用いる Viterbi アルゴリズムで利用する。文法を利用することの有効性は評価実験の章において検証する。

## 2. 関連研究

### 2.1 屋内建具の開閉状態変化検知

各建具にスイッチセンサやRFIDタグ、振動センサ、加速度センサといった小型のセンサを取り付けた屋内建具の開閉状態変化検知の研究は数多く行われてきた [3], [4], [5]. このような手法は日常生活をきめ細かに観測できるが、バッテリーの交換等の必要があるため、導入・管理コストが大きい。この問題に対処するため、Campbellらはビルの監視を行うためのエナジーハーベスティングセンサを提案している [6]. 提案されたセンサでは、太陽光等で生み出した電力によってピエゾフィルム振動センサが振動を検知したことを伝えるパケットを送出する。このセンサをドアや窓等に設置すると開閉を検知することができる。

気圧計によってドアの開閉を検知する研究も行われている。Patelらは、空調のフィルタに気圧計を設置することでドアの開閉によって起こる気圧の変化を検知している [7]. Wuらは、空調システムが導入されているビルにおいてドアを開いたときに起こる気圧の大きな変化をスマートフォンの気圧計を用いて検知している [8].

ドアにセンサを直接添付しない手法としてShiらは、環境の変化によってFM電波の状態が変化することを用いて、FM電波受信器で「空部屋」、「ドアが開いている」、「人が歩いている」という状況を識別している [9]. 一方で、本研究では、市販されているWi-FiのアクセスポイントとWi-Fiモジュールによって得られるCSIを用いることで、ドアや窓等の建具の開閉状態変化を検知する。

### 2.2 Wi-Fiの受信電波強度を用いたコンテキスト認識

Wi-Fiによる無線LAN通信の普及によって、多くの研究者がWi-Fiの受信電波強度 (Received Signal Strength Indicator: RSSI) を用いた人の行動認識の研究を行っている。SiggらはスマートフォンをWi-Fiの受信器とした行動認識を行っている [10]. 一般的なAndroidスマートフォンは1Hz程度しかRSSIを取得できず、行動認識に利用することが難しいため、Wi-Fiのデバイスドライバを修正し、Wi-FiパケットごとにRSSIを取得できるようにしている。Abdelnasserらはスマートフォン等のWi-Fi機器を胸の前に置くことで呼吸の間隔とパターンを監視し、呼吸停止等の検出を行っている [11].

### 2.3 CSIを用いたコンテキスト認識

RSSIの値は反射等のマルチパスの影響で変化しやすく、パケットごとに統合された実数のスカラー値であるため、RSSIから伝搬路の状態を正確に計測するのは難しいとされている [12]. 一方で、CSIは1つのパケットから多次元のデータが得られ、各送受信アンテナで得られた各サブキャリアの振幅と位相の情報を含んだデータであるため、

RSSIより詳細な環境の情報が得られ、CSIを用いた行動認識の研究がさかんに行われている。

#### 2.3.1 Wi-Fiチャンネル状態情報

CSIはWi-Fi通信における物理層で抽出される送受信機間の伝搬路の状態を表す情報として知られている。CSIは送信された電波の伝搬損失や反射・回折等のマルチパスの影響による振幅変化、位相変化を表し、OFDMにおける互いに直交した異なる周波数を持つサブキャリアごとに得られる。 $\mathbf{X}_i$ と $\mathbf{Y}_i$ 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 $M_R$ 次元の受信ベクトルとするとそれらの関係は次式で表せる。

$$\mathbf{Y}_i = \mathbf{H}_i \mathbf{X}_i + \mathbf{N}_i \quad (1)$$

ここで $\mathbf{N}_i$ は $M_R$ 次元のノイズベクトルであり、 $\mathbf{H}_i$ は*i*番目のサブキャリアで得られる $M_T \times M_R$ 次元の行列である。 $\mathbf{H}_i$ は*i*番目のサブキャリアで得られるCSIであり、次式で表せる。

$$\mathbf{H}_i = \begin{bmatrix} h_{11} & h_{12} & \cdots & h_{1M_T} \\ h_{21} & h_{22} & \cdots & h_{2M_T} \\ \vdots & \vdots & \ddots & \vdots \\ h_{M_R1} & h_{M_R2} & \cdots & h_{M_R M_T} \end{bmatrix} \quad (2)$$

ここで $h_{mn}$ は*m*番目の受信アンテナと*n*番目の送信アンテナ間の伝搬路におけるCSIの値である。 $h_{mn}$ は複素数であり、次式で表される。

$$h_{mn} = |h_{mn}| e^{j\angle h_{mn}} \quad (3)$$

$|h_{mn}|$ はCSIの振幅であり、 $\angle h_{mn}$ はCSIの位相である。

#### 2.3.2 CSIを利用した行動認識

WangらはCSIを入力とする多クラスSVMによって単純な行動を識別している [13]. 文献 [14] では、CSIの変化と人の動く速度の関係をモデル化し、人の部位ごとの速度と行動との関係のモデルをHMMによって構築している。

CSIを用いた高齢者見守りの研究として転倒検知の研究が多く行われている。WiFallでは、CSIの時間的変化を用いて様々な環境で転倒検知を行っている [15]. Anti-Fallでは、転倒時と転倒に似た行動におけるCSIの位相と振幅の違いからそれらを識別している [16].

Liuらは呼吸のリズムと関連のあるパターンをCSIから抽出することで、呼吸等のユーザの睡眠情報をとらえることを試みている [17]. Aliらはキーストロークにおいて、CSIの時系列データから各キーを入力したときの特徴を抽出することによってどのキーが押されたかを識別している [1].

### 2.4 既存研究の問題点

上で述べた既存研究の手法と問題点を表1に示す。

表 1 既存研究の問題点

Table 1 Problem of related research.

手法	センサ	処理方法	問題点・本研究との差異
Campbell et al [6]	振動センサ	n/a	建具ごとセンサが必要
Patel et al [7]	気圧センサ	ドア開閉の気圧変化検知	ドアの開閉のみを検知
Shi et al [9]	FM 電波	電波強度の変化検知	USRP モニタが必要
Sigg et al [10]	Wi-Fi RSSI	電波強度の統計量	ジェスチャを認識
Abdelnasser et al [11]	Wi-Fi RSSI	電波強度の変化検知	呼吸を認識
Wang et al [14]	Wi-Fi CSI	PCA による雑音除去	伝搬路や周波数依存の情報が失われる
WiFall [15]	Wi-Fi CSI	サブキャリアで平均	周波数依存の情報が失われる
Anti-Fall [16]	Wi-Fi CSI	位相と振幅の違い	環境変化の影響が大きい
Liu et al [17]	Wi-Fi CSI	繰り返されるパターン抽出	建具の操作にはパターンがない
Ali et al [1]	Wi-Fi CSI	PCA による雑音除去	伝搬路や周波数依存の情報が失われる

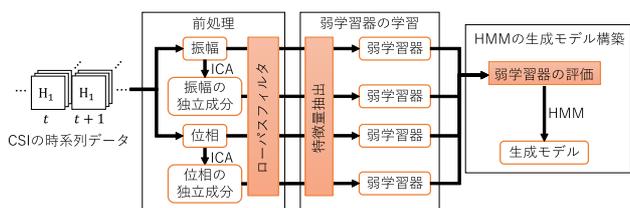


図 1 提案手法の学習フェーズの概要

Fig. 1 Overview of proposed training phase.

### 3. 提案手法

#### 3.1 提案手法の概要

提案手法は教師あり機械学習を基にするため、学習フェーズと推定フェーズで構成される。学習フェーズでは、各々の建具が「開いている状態（開状態）」、「閉じている状態（閉状態）」のいずれの状態であるか、または各々の建具を「開ける動作（開動作）」、「閉める動作（閉動作）」のいずれの動作中であるかというラベルが付加された CSI データから分類器を学習する。推定フェーズでは、ある時刻において各建具がどのような状態、もしくは動作中であるか分類し、各建具の状態変化を検知する。また、建具によって有効な周波数や伝搬路は異なると考えられるため、以下の処理は建具ごとに行う。

ある 1 つの建具に対する提案手法の学習フェーズの概要を図 1 に示す。提案手法の学習フェーズは前処理、弱学習器の学習、HMM 生成モデル構築に分かれている。前処理では、CSI の時系列データから振幅と位相を抽出し、それぞれに対して ICA を行い独立成分に分離する。さらにノイズを軽減させるためにローパスフィルタをかける。弱学習器の学習では、CSI の各次元の振幅、位相、振幅の独立成分、位相の独立成分それぞれに対して、特徴量を抽出し、識別モデルである弱学習器からなるアンサンブル学習器を学習する。HMM 生成モデル構築では、トレーニングデータによってそれぞれの弱学習器を評価し、精度が高い弱学習器の入力と出力を入力とする生成モデルである HMM を構築する。

提案手法の推定フェーズでは、学習フェーズと同様の前処理を行い、学習された精度が高い弱学習器の入力と出力を用いて HMM によって分類する。

#### 3.2 前処理

前処理では CSI の時系列データから振幅と位相の抽出、ICA による独立成分の分離、ローパスフィルタによるノイズ軽減を行う。

##### 3.2.1 振幅と位相の抽出

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  $\|h_{mn}\|$  と位相  $\angle h_{mn}$  を計算し、 $M_T \times M_R \times N$  次元の振幅の時系列データと位相の時系列データを求める。

##### 3.2.2 ICA による独立成分の分離

ICA は信号源の情報を用いずに、複数の信号源からの信号が混ざったデータを信号が互いに独立であるという仮定を用いて各信号源の信号に分離する手法である。ICA では、時刻  $t$  の信号源からの信号ベクトルを  $s(t) = [s_1(t), s_2(t), \dots, s_M(t)]^T$ 、観測された信号ベクトルを  $x(t) = [x_1(t), x_2(t), \dots, x_M(t)]^T$  としたとき、 $x(t)$  が  $s(t)$  の線形和

$$x(t) = \mathbf{A}s(t) \tag{4}$$

で表されるモデルを想定する。 $\mathbf{A}$  は  $M \times M$  次元の混合行列である。このとき、ICA の目的は  $\mathbf{A}$  に関する情報を持たずに、次式で表される分離行列  $\mathbf{W}$  を計算することで  $s(t)$  を求めることである。

$$s(t) = \mathbf{W}x(t) \tag{5}$$

$\mathbf{W}$  を計算するために  $s(t)$  の各要素は統計的に互いに独立であることを仮定する。本研究において、各建具による Wi-Fi 電波の反射を信号源と見なし、各送受信アンテナの組を観測器と見なす。また、複数の建具が同時に利用されることは少ないため、上記の仮定は満たされると考えられる。本研究では  $\mathbf{W}$  を計算するために FastICA [18] を用

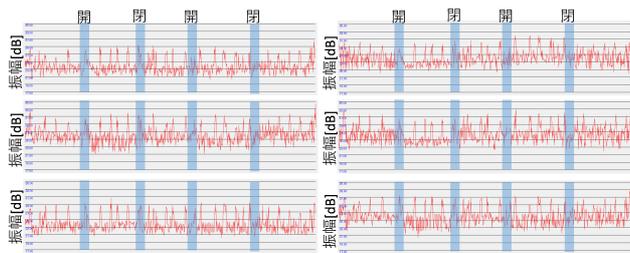


図 2 ドアを開閉したときの CSI のあるサブキャリアにおける振幅の時系列データ

Fig. 2 CSI amplitude time-series for a certain subcarrier obtained when we open and close door.

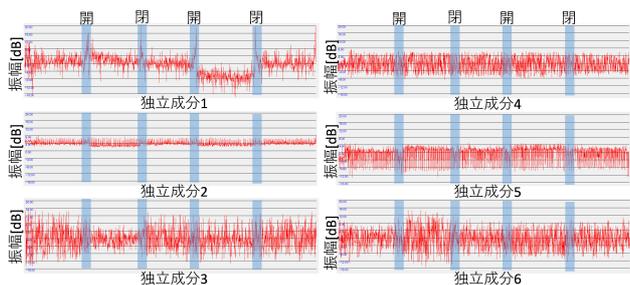


図 3 ドアを開閉したときの CSI のあるサブキャリアにおける振幅の独立成分の時系列データ

Fig. 3 Independent component time-series of CSI amplitude for a certain subcarrier obtained when we open and close door.

いる。

提案手法では、建具ごとに  $\mathbf{W}$  を計算するため、注目している建具の「開動作」と「閉動作」とラベル付けされた区間の振幅、もしくは位相の時系列データをトレーニングデータから抽出し、サブキャリアごとに  $M_T \times M_R$  次元のデータに対して FastICA を行い、 $\mathbf{W}$  を計算する。 $\mathbf{W}$  を利用して CSI の振幅、位相の時系列データを独立成分に分離する。

ドアを開閉したときのあるサブキャリアの振幅の時系列データと ICA による独立成分の分離を行った時系列データの例をそれぞれ図 2 と図 3 に示す。送信アンテナ数  $M_T = 2$ 、受信アンテナ数  $M_R = 3$  であるため、6 次元の時系列データが示されている。図 2 ではどの時系列データもドアを開閉したときに大きな変化が見られないが、図 3 の独立成分 1 では開閉時に大きな変化が見られる。

### 3.2.3 ローパスフィルタによるノイズ軽減

振幅と位相の抽出、独立成分の分離によって求めた時系列データには図 2 や図 3 で見られるように高周波のノイズが存在する。そこで、このノイズを軽減するために、時系列データに対して移動平均を行うことでローパスフィルタ処理を行う。

移動平均フィルタは下式で表され、 $W$  が移動平均の窓幅を示す。

$$y[t] = \frac{1}{W} \sum_{w=0}^{W-1} x[t-w] \quad (6)$$

ここで  $x[t]$  は時刻  $t$  における元のデータであり、 $y[t]$  は移動平均後のデータである。本研究で対象とする現象は建具の操作であり、各建具の操作にかかる時間は数秒であるため、1 Hz 程度の周波数より高周波な成分が減衰するようなフィルタを用いた。具体的には、CSI を取得したサンプリングレート 30 Hz に対して、 $W = 10$  を用いており、そのときのゲインが  $-3$  dB になるカットオフ周波数は約 1.5 Hz となる。

## 3.3 弱学習器の学習

弱学習器の学習では、CSI の各次元の振幅、位相、振幅の独立成分、位相の独立成分の合わせて  $4 \times M_T \times M_R \times N$  個の時系列データに対して、それぞれ特徴量を抽出し、各々の特徴量を入力として識別モデルの弱学習器を学習する。

### 3.3.1 特徴量抽出

CSI の各次元の振幅、位相、振幅の独立成分、位相の独立成分の時系列データを窓幅 1 秒、オーバーラップ 50% の時間窓で区切り、各時間窓内で特徴量を計算する。特徴量には窓内のデータの分散、尖度、歪度、最大値、最小値、最大値と最小値の差を用い、6 次元の特徴ベクトルを作成する。

### 3.3.2 弱学習器の学習

特徴抽出によって作成した各時系列データの特徴ベクトルごとに識別モデルの弱学習器を学習する。弱学習器には C4.5 決定木を用いる。「開状態」、「閉状態」のときの特徴ベクトルの数は「開動作」、「閉動作」のときの特徴ベクトルの数よりはるかに多いため、「開状態」、「閉状態」のときの特徴ベクトルをサブサンプリングすることで特徴ベクトルの数を合わせる。

また、上記の決定木による弱学習器に加えて、CSI の各時系列データの波形を直接比較することで分類を行う弱学習器を学習する。波形を比較するための弱学習器にはユークリッド距離に基づく k-nearest neighbor (kNN) 探索を用いる。ここで図 3 の独立成分 1 の時系列データから、2 回目の「開動作」の後に直流成分が変化していることが分かる。このような変化は同じ部屋内の別の物体の状態が変化した際等にも見られた。そこで、特徴抽出に用いた時間窓で平均を求め、時系列データから平均を減算することで、直流成分の影響を緩和する。

これら 2 種類の弱学習器を学習するため、1 つの建具における弱学習器の数は  $8 \times M_T \times M_R \times N$  となる。それぞれの弱学習器は、入力データが「開状態」、「閉状態」、「開動作」、「閉動作」の各クラスに分類される確率（クラス分類確率）を出力する。

### 3.4 HMM 生成モデル構築

HMM 生成モデル構築では、トレーニングデータの交差検定によってそれぞれの弱学習器を評価し、精度が高い弱学習器の入力と出力を HMM の入力とする。

#### 3.4.1 弱学習器の評価

図 3 において独立成分 1 以外の成分は建具の状態変化をとらえるのに有用でない成分であるといえる。このように多くの弱学習器は建具の状態変化をとらえるのに有用でないため、トレーニングデータの交差検定により各弱学習器の精度を求め、生成モデル構築には精度が高い有用な弱学習器のみを用いる。弱学習器の精度の評価は各クラスで平均した F 値によって行い、F 値が 0.25 以上の弱学習器を有用な弱学習器とする。

#### 3.4.2 生成モデルの構築

有用と判定された弱学習器の入力である特徴ベクトルと出力であるクラス分類確率を連結して構築したベクトルを HMM の入力とする。このとき、PCA を用いてさらに入力の次元を削減する。本研究では、PCA を用いて 100 次元にまで削減する。

100 次元に削減した特徴ベクトルを建具の動作と状態ごと用意した left-to-right の HMM の出力（観測）とし、Baum-Welch アルゴリズム [19] によって各 HMM のパラメータを学習する。HMM の出力分布には Gaussian Mixture Model (GMM) を用い、HMM の状態数はトレーニングデータの交差検定によって、最も精度が高い値を用いる。

### 3.5 推定フェーズ

推定フェーズでは、まず学習フェーズと同様の前処理、特徴抽出を行う。ただし学習フェーズで計算した分離行列を用いて独立成分の分離を行う。

続いて学習フェーズにおいて有用だと判定された学習済みの弱学習器に対してテストデータの特徴ベクトルを入力し、各時間窓におけるクラス分類確率を求め、そして各時間窓の特徴ベクトルとクラス分類確率を連結して構築したベクトルを 100 次元に削減する。そして、学習済みの HMM に対して Viterbi アルゴリズム [19] を適用し、テストデータにおける最も尤度の高くなる HMM 内/間の状態遷移系列を求め、推定された各時刻の HMM に対応するクラスが、動作・状態の推定結果となる。

#### 3.5.1 文法を用いた HMM デコーディング

本研究で用いる HMM は建具の動作および状態のクラスごと用意されるため、Viterbi アルゴリズムはそれらをまたいだ状態遷移を求め、すなわち、あるクラスに対応する HMM の最後の状態から別のクラスに対応する HMM の最初の状態に遷移する。ここで、建具の事前知識を用いて以下のような文法によって HMM 間の遷移を制限する。

… → 「開状態」 → 「閉動作」 → 「閉状態」 → 「開動作」 → 「開状態」 → …

これにより、たとえば「開動作」から「閉状態」等の起こりえない遷移を制限できる。

## 4. 評価実験

### 4.1 データセット

本実験では 3 つの実環境においてデータを取得した。実験を行った 3 つの環境と状態変化を推定する建具の配置、Wi-Fi 機器の配置を図 4 に示す。環境 1 と環境 2 ではよく使われるドアや窓といった建具の状態変化の推定を試みる。環境 1 のスクリーンは引き下げ式のものであり、引き下げられた状態を開状態とした。環境 3 では類似したデータが得られると考えられる隣接したロッカーの状態変化を識別することを試みる。環境に設置する Wi-Fi 送信機には Buffalo WXR-2533DHP のアクセスポイント (AP) を用い、受信機には Intel 5300 NIC を搭載した PC を用いる。CSI データを取得するために PC に Halperin らによって改造された NIC のデバイスドライバをインストールする [20]。送信アンテナ数は  $M_T = 2$ 、受信アンテナ数は  $M_R = 3$ 、サブキャリア数は  $N = 30$  である。Wi-Fi の UDP パケットを AP から 30 Hz 程度で送信し、CSI を取得する。

各環境において、被験者はそれぞれの建具をランダムな順番で 3 回ずつ開閉し、これを 10 セッション行った。各セッションはおよそ 10 分間であり、人の動きによるノイズをデータに加えるため、そのうち 2 分程度部屋内をランダムに歩き回った。また、各時刻における建具の状態（正答）を取得するために、ビデオによる撮影を行った。

### 4.2 評価方法

評価方法として、Leave-One-Session-Out 交差検定を用いて、次にあげる手法を評価する。

**提案手法** 本研究の提案手法。構成を ICA + 弱学習器 + 文法 + HMM とする。

**弱学習器 + 文法 + HMM** ICA による独立成分の分離を行わずに CSI の振幅と位相のみを用いる手法。

**ICA + 弱学習器 + HMM** HMM デコーディング時に建具の状態に関する事前知識に基づいた文法を用い

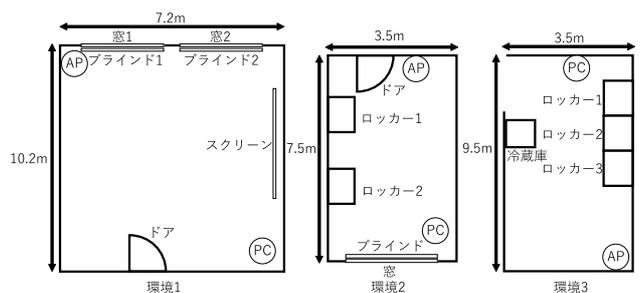


図 4 実験環境

Fig. 4 Experimental environment.

表 2 提案手法による環境 1 の分類精度

Table 2 Classification accuracy for proposed method in environment 1.

	適合率	再現率	F 値
ドア	0.778	0.834	0.800
窓 1	0.826	0.871	0.848
ブラインド 1	0.849	0.914	0.873
窓 2	0.688	0.726	0.706
ブラインド 2	0.805	0.862	0.829
スクリーン	0.323	0.358	0.320
平均	0.712	0.761	0.729

表 3 提案手法による環境 2 の分類精度

Table 3 Classification accuracy for proposed method in environment 2.

	適合率	再現率	F 値
ドア	0.696	0.710	0.702
窓	0.929	0.945	0.937
ブラインド	0.749	0.834	0.775
ロッカー 1	0.864	0.851	0.857
ロッカー 2	0.950	0.932	0.941
平均	0.838	0.854	0.842

表 4 提案手法による環境 3 の分類精度

Table 4 Classification accuracy for proposed method in environment 3.

	適合率	再現率	F 値
ロッカー 1	0.859	0.865	0.862
ロッカー 2	0.787	0.759	0.772
ロッカー 3	0.621	0.634	0.626
冷蔵庫	0.352	0.440	0.370
平均	0.655	0.675	0.658

ず、「開状態」、「閉状態」、「開動作」、「閉動作」間の状態遷移確率が等確率である手法。

**弱学習器 + HMM ICA** による独立成分の分離と建具の状態に関する事前知識に基づいた文法を用いない手法。  
**ICA + 弱学習器 HMM** を用いずに、有用な弱学習器の出力の多数決によって分類を行う手法。

**PCA** を用いる既存手法 PCA を用いて CSI の時系列データの次元を削減する既存の手法 [1]。CSI から抽出した振幅や位相のサブキャリアの要素に対して PCA を行い、 $M_T \times M_R \times N$  次元の振幅や位相の時系列データを  $M_T \times M_R$  次元に削減する。この時系列データに対し、提案手法と同様の特微量抽出を行い、C4.5 決定木を用いて分類を行う。

これらの手法によって本研究で提案する ICA による独立成分の分離と建具の状態に関する事前知識に基づいた文法、HMM と弱学習器を組み合わせた生成モデルの有用性について調査する。推定精度の評価には、平均適合率 (precision) と再現率 (recall), F 値 (F-measure) の 3 つの指標を用いる。

### 4.3 実験結果

#### 4.3.1 提案手法の分類精度

提案手法による各環境の分類精度をそれぞれ表 2, 表 3, 表 4 に示す。結果から、スクリーンと冷蔵庫以外は 70% から 90% 程度の高い精度で分類できていることが分かる。環境 3 の隣り合ったロッカー 1 とロッカー 2, ロッカー 3 の精度を見ると Wi-Fi 機器に近いほど精度が高いことが分かる。Wi-Fi 機器から離れるにつれ、観測される電波の変化が小さくなると考えられる。

また、環境 1 における提案手法による窓 1 の各クラスの分類精度と、ある分類結果の時間推移の例をそれぞれ表 5 と図 5 に示す。表 5 から状態を示すクラスの「開状態」、「閉状態」のほうが動作を示すクラスの「開動作」、「閉動作」より精度が高いことが分かる。これは図 5 から分かるように、動作の時間は状態の時間と比べてはるかに短いため、動作と推定される時刻が正答と少しでもずれると認識

表 5 提案手法による環境 1 の窓 1 に対する分類精度

Table 5 Classification accuracy for proposed method related to window 1 in environment 1.

	適合率	再現率	F 値
開動作	0.800	0.863	0.830
閉動作	0.724	0.813	0.766
開状態	0.820	0.871	0.845
閉状態	0.961	0.937	0.949

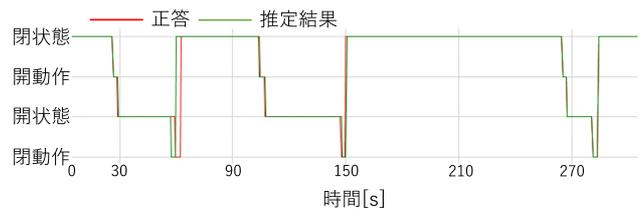


図 5 提案手法による窓 1 の分類結果の時間推移

Fig. 5 Outputs of proposed method related to window 1.

誤りになってしまい、小さな誤りでも精度の数値に大きく影響してしまうためである。しかし、状態を示すクラスの精度に注目すると 90% 程度の精度が実現できており、状態の変化をほぼ正しく認識できている。

環境 1 における提案手法による各建具の認識結果の混合行列を図 6 に示す。図 6 から、ドア、窓 1, ブラインド 1, 窓 2, ブラインド 2 の分類結果は良好であるが、スクリーンの分類結果が悪いことが分かる。スクリーンは大きな建具であるにもかかわらず精度が低いのは、スクリーンが壁に近く、またスクリーンと壁で Wi-Fi 電波の反射の特性が大きく変化しないため、スクリーンを操作しても CSI への影響が小さかったからだと考えられる。

#### 4.3.2 ICA と文法、生成モデルの効果

評価方法の節であげた各手法の分類精度を表 6 に示す。表 6 から、ICA を用いない「弱学習器 + 文法 + HMM」は提案手法と比べ、0.5% から 3% の精度低下が見られ、文法を用いない「ICA + 弱学習器 + HMM」は 3% から 10% 程度の精度低下が見られた。ICA と文法をともに用いない「弱学習器 + HMM」は 4% から 12% の精度低下が見られ、

表 6 各手法による分類精度

Table 6 Classification accuracy for each method.

	環境 1			環境 2			環境 3		
	適合率	再現率	F 値	適合率	再現率	F 値	適合率	再現率	F 値
提案手法	0.712	0.761	0.729	0.838	0.854	0.842	0.655	0.675	0.658
弱学習器 + 文法 + HMM	0.712	0.750	0.725	0.816	0.820	0.814	0.628	0.646	0.630
ICA + 弱学習器 + HMM	0.690	0.738	0.701	0.747	0.759	0.742	0.556	0.622	0.566
弱学習器 + HMM	0.674	0.723	0.689	0.718	0.750	0.722	0.528	0.592	0.536
ICA + 弱学習器	0.616	0.639	0.618	0.553	0.593	0.559	0.435	0.485	0.429
PCA を用いる既存手法	0.328	0.338	0.292	0.363	0.363	0.327	0.305	0.305	0.258

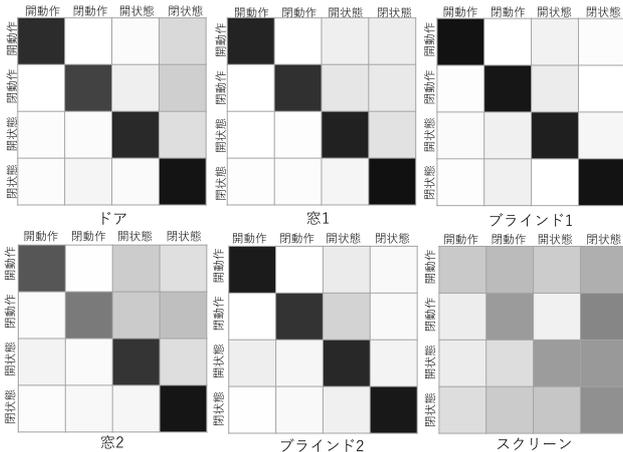


図 6 提案手法による環境 1 の混合行列

Fig. 6 Confusion matrix for proposed method in environment 1.

HMM を用いない「ICA + 弱学習器」は 10% から 30% 程度の精度低下が見られた。この結果から、ICA による独立成分の分離と建具の事前知識を利用した文法による効果がそれぞれ確認され、それらを合わせることで同様の効果があることが分かった。また、弱学習器の結果を時間的な連続性を考慮する HMM を用いて併合することで大きな精度の向上が見られた。

PCA を用いた既存の CSI の次元削減手法では 180 次元を 6 次元に削減することができるが、建具の状態変化による CSI の小さな変化をとらえることが難しくなり、精度が低くなってしまったと考えられる。一方、提案手法で用いている多数の弱学習器を用いる方法は建具の状態変化をとらえやすい次元削減前の時系列データを用いることができるため、高い精度が実現できたと考えられる。

#### 4.4 環境内の被験者数の影響

環境内の被験者数による精度への影響を調査するため、2 人の被験者による追加実験を行った。環境 3 において 1 人の被験者が環境内をランダムに歩き回り、その間にもう 1 人の被験者が建具をランダムな順番で開閉するという実験を行った。以下の 3 つの条件で提案手法を評価する。  
 トレーニング 1 人, テスト 1 人    トレーニングデータ, テ

表 7 環境内の人数による推定精度の変化

Table 7 Difference of classification accuracy by the number of participants in environment 3.

トレーニング	テスト	適合率	再現率	F 値
1 人	1 人	0.655	0.675	0.658
1 人	2 人	0.474	0.362	0.356
2 人	2 人	0.635	0.640	0.610

ストデータとともに環境内に 1 人しかいない場合  
 トレーニング 1 人, テスト 2 人    トレーニングデータとして環境内に 1 人しかいない場合を用い、環境内に 2 人いるデータをテストする場合  
 トレーニング 2 人, テスト 2 人    トレーニングデータ, テストデータとともに環境内に 2 人いる場合

各データセットにおける推定精度を表 7 に示す。表 7 ではトレーニングデータとテストデータで環境内にいる人数が一致していない場合は大きく精度が低下してしまっているが、同じ人数である場合は環境内に 2 人の被験者がいても精度低下は 5% 程度である。この結果から、環境内に複数人いる場合はその人数がいる状況で取得した学習データを追加で用意する必要があるが、同人数で取得したデータを用いれば大幅な精度低下は見られないことが分かる。これは環境内にいる人数によって CSI が大きく変化してしまうためであると考えられる。しかし、本研究では見守り等のアプリケーションを想定しているため、学習データを収集する際の人数のパターンは少ないと考える。

## 5. 考察

### 5.1 外部要因による外乱・干渉

提案手法は、Wi-Fi チャンネル状態情報を利用しており、他の同一周波数機器の影響を受ける。近年では Wi-Fi AP は至るところに存在するため、提案手法はそれらの AP からの影響を受ける。評価環境では、周囲に存在する平均 12 個の AP から電波が観測されていたため、現実的な環境での評価が行えていたと考える。周辺に存在する AP の数の精度への影響に関する調査は今後の課題である。

### 5.2 状態の変則的な遷移

提案手法では機械学習手法を基にしており、さらにあら

はじめ用意した状態遷移の定義を文法として用いている。そのため、たとえば学習データに存在しないような利用のされ方がテストデータに含まれた場合、そのような利用を正しく認識できないことが考えられる。これは機械学習等の事前知識を用いる本手法の制約ではあるが、提案手法では生成モデルである HMM を用いているため、そのような想定されていないデータの生起をモデルに対する尤度から検知できると考える。たとえば、ドアが破壊されて開けられた場合にその異常を検知して、見守りのアプリケーションの場合は遠隔家族に通知することが可能となる。

## 6. おわりに

本研究では、市販されている Wi-Fi 機器で取得できる Wi-Fi 電波の伝搬情報である CSI を用いて、ドアや窓の開閉といった屋内建具の状態変化を検知する手法を提案した。CSI は高次元の時系列データであるため、各次元ごとに用意した弱学習器を組み合わせたアンサンブル学習器を構築することで次元削減を行った。また、ICA による CSI の独立成分を弱学習器の入力に加えることで、各建具の利用によって生じた CSI の変化に分離することを試みた。さらに弱学習器の入力と出力を HMM の入力とし、建具の事前知識に基づいた文法によって状態遷移に制限を設けることで精度を改善した。

謝辞 本研究の一部は JST CREST および JSPS 科研費 JP26730047 の助成を受けたものです。

## 参考文献

- [1] Ali, K., Liu, A.X., Wang, W. and Shahzad, M.: Keystroke recognition using wifi signals, *Proc. 21st Annual International Conference on Mobile Computing and Networking*, ACM, pp.90–102 (2015).
- [2] Chapre, Y., Ignjatovic, A., Seneviratne, A. and Jha, S.: CSI-MIMO: An efficient Wi-Fi fingerprinting using Channel State Information with MIMO, *Pervasive and Mobile Computing*, Vol.23, pp.89–103 (2015).
- [3] Philipose, M., Fishkin, K.P., Perkowitz, M., Patterson, D.J., Fox, D., Kautz, H. and Hähnel, D.: Inferring activities from interactions with objects, *Pervasive Computing*, IEEE, Vol.3, No.4, pp.50–57 (2004).
- [4] Tapia, E.M., Intille, S.S. and Larson, K.: *Activity recognition in the home using simple and ubiquitous sensors*, Pervasive (2004).
- [5] Van Kasteren, T., Noulas, A., Englebienne, G. and Kröse, B.: Accurate activity recognition in a home setting, *Proc. 10th International Conference on Ubiquitous Computing*, ACM, pp.1–9 (2008).
- [6] Campbell, B. and Dutta, P.: An energy-harvesting sensor architecture and toolkit for building monitoring and event detection, *Proc. 1st ACM Conference on Embedded Systems for Energy-Efficient Buildings*, ACM, pp.100–109 (2014).
- [7] Patel, S.N., Reynolds, M.S. and Abowd, G.D.: Detecting human movement by differential air pressure sensing in HVAC system ductwork: An exploration in infrastructure mediated sensing, *Pervasive Computing*, pp.1–18, Springer (2008).
- [8] Wu, M., Pathak, P.H. and Mohapatra, P.: Monitoring building door events using barometer sensor in smartphones, *Proc. 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, ACM, pp.319–323 (2015).
- [9] Shi, S., Sigg, S. and Ji, Y.: Passive detection of situations from ambient fm-radio signals, *Proc. 2012 ACM Conference on Ubiquitous Computing*, ACM, pp.1049–1053 (2012).
- [10] Sigg, S., Blanke, U. and Troster, G.: The telepathic phone: Frictionless activity recognition from wifi-rssi, *IEEE International Conference on Pervasive Computing and Communications (PerCom)*, IEEE, pp.148–155 (2014).
- [11] Abdelnasser, H., Harras, K.A. and Youssef, M.: Ubibreathe: A ubiquitous non-invasive wifi-based breathing estimator, *arXiv preprint arXiv:1505.02388* (2015).
- [12] Wu, K., Xiao, J., Yi, Y., Chen, D., Luo, X. and Ni, L.M.: CSI-based indoor localization, *IEEE Trans. Parallel and Distributed Systems*, Vol.24, No.7, pp.1300–1309 (2013).
- [13] Wang, Y., Jiang, X., Cao, R. and Wang, X.: Robust Indoor Human Activity Recognition Using Wireless Signals, *Sensors*, Vol.15, No.7, pp.17195–17208 (2015).
- [14] Wang, W., Liu, A.X., Shahzad, M., Ling, K. and Lu, S.: Understanding and modeling of wifi signal based human activity recognition, *Proc. 21st Annual International Conference on Mobile Computing and Networking*, ACM, pp.65–76 (2015).
- [15] Han, C., Wu, K., Wang, Y. and Ni, L.M.: WiFall: Device-free fall detection by wireless networks, *INFOCOM, 2014 Proceedings IEEE*, IEEE, pp.271–279 (2014).
- [16] Zhang, D., Wang, H., Wang, Y. and Ma, J.: Anti-fall: A Non-intrusive and Real-Time Fall Detector Leveraging CSI from Commodity WiFi Devices, *Inclusive Smart Cities and e-Health*, pp.181–193, Springer (2015).
- [17] Liu, X., Cao, J., Tang, S. and Wen, J.: Wi-Sleep: Contactless sleep monitoring via WiFi signals, *Real-Time Systems Symposium (RTSS), 2014 IEEE*, IEEE, pp.346–355 (2014).
- [18] Hyvärinen, A.: Fast and robust fixed-point algorithms for independent component analysis, *IEEE Trans. Neural Networks*, Vol.10, No.3, pp.626–634 (1999).
- [19] Rabiner, L.R.: A tutorial on hidden Markov models and selected applications in speech recognition, *Proc. IEEE*, Vol.77, No.2, pp.257–286 (1989).
- [20] Halperin, D., Hu, W., Sheth, A. and Wetherall, D.: Tool release: gathering 802.11 n traces with channel state information, *ACM SIGCOMM Computer Communication Review*, Vol.41, No.1, pp.53–53 (2011).



尾原 和也 (学生会員)

平成 27 年大阪大学工学部電子情報工学科卒業、同大学大学院情報科学研究科マルチメディア工学専攻博士前期課程入学。コンテキスト認識に関する研究に従事。



前川 卓也 (正会員)

平成 15 年大阪大学大学院工学部電子情報エネルギー工学科卒業。平成 18 年同大学大学院情報科学研究科博士後期課程修了。同年日本電信電話株式会社入社。平成 24 年 4 月より大阪大学大学院情報科学研究科准教授。平成 25 年 8~10 月スイス連邦工科大学ローザンヌ校招聘教授。博士 (情報科学)。本会平成 22 年度山下記念研究賞, 日本データベース学会平成 25 年度上林奨励賞等受賞。ACM, IEEE, 電気学会, 日本データベース学会各会員。



松下 康之

平成 10 年東京大学工学部卒業。平成 15 年同大学大学院工学系研究科電子情報工学博士後期課程修了。同年 Microsoft Corp. に入社し Microsoft Research Asia の Visual Computing Group に研究員として勤務。2015 年 4 月より大阪大学情報科学研究科教授, 現在に至る。コンピュータビジョン・機械学習・最適化の研究に興味を持つ。