

# Wi-Fi チャンネル状態情報を用いた 屋内日常物の状態変化の検知に関する検討

尾原 和也<sup>1</sup> 前川 卓也<sup>1</sup> 松下 康之<sup>1</sup>

概要：ドアや窓の開閉のような屋内日常物の状態変化を検知する手法の研究が盛んに行われている。日常物の状態変化の検知は人の侵入検知や空調の制御、高齢者の見守り等に応用でき、これまでの研究ではドアや窓などの対象物それぞれにセンサを設置することで実現されてきたが、対象物の数に応じたセンサが必要となるため、設置・管理コストが大きくなる。そこで本研究では、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コンピュータを 1 台ずつ設置し、コンピュータで得られる Wi-Fi 電波の伝搬特徴情報のみを用いることで日常物の状態変化を検知する手法を提案する。本研究では Wi-Fi 電波の伝搬特徴として、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用いる。

キーワード：日常物の状態変化検知, Wi-Fi チャンネル状態情報, 隠れマルコフモデル

## 1. はじめに

ドアや窓の開閉のような屋内日常物の状態変化を検知する手法の研究がこれまでに盛んに行われてきた。日常物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。これまでの研究ではドアや窓などのそれぞれの日常物に加速度センサやジャイロセンサ、振動センサ、スイッチセンサを設置し、無線通信によって情報を集約することで実現されてきた [1], [2], [3]。しかし、これらの手法は日常物それぞれにセンサを設置する必要があり、バッテリーの交換やセンサ故障時の取り替え等の点で手間がかかるため、導入・管理コストが大きいという問題がある。

そこで本研究では、ドアや窓等の屋内日常物それぞれにセンサを設置せずに、環境(部屋)内に市販されている Wi-Fi アクセスポイントと Wi-Fi モジュールを搭載したコンピュータを 1 台ずつ設置し、コンピュータから得られる Wi-Fi 電波の伝搬情報のみを用いることで日常物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。CSI は Wi-Fi 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と位相の変化を表す。

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直交する異なった複数のサブキャリア (搬送波) に乗せる方法である。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、CSI を利用する場合、高次元であるため次元の呪いの影響を受ける。

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 [4]。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捉えることが難しくなる。

<sup>1</sup> 大阪大学大学院情報科学研究科

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。対象となる日常物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日常物ごとに行う。

本研究では日常物の時系列的な状態変化を捉えるために、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上で、イベントの時系列性を考慮した認識が可能となる。

## 2. 関連研究

### 2.1 屋内日常物の状態変化検知

各日常物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日常物の状態変化検知の研究は数多く行われてきた [1], [2], [3]。このような手法は日常生活をきめ細やかに観測できるが、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 [5]。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 piezofilm 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。

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 [6]。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、ドアや窓等の日常物の状態変化を検知する。

### 2.2 CSI 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。しかし、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 [7]。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盛んに行われている。

### 2.2.1 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。 $\mathbf{H}_i$  の各要素を  $h_{mn}$  とすると、 $h_{mn}$  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。

$$h_{mn} = |h_{mn}| e^{j\angle h_{mn}} \quad (2)$$

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

### 2.2.2 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 [8]。 [9] 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。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捉えることを試みている [10]。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 [4]。

## 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、各々の日常物が「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、または各々の日常物を「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日常物がどのような状態、もしくは動作中であるか分類し、各日常物の状態変化を検知する。また、日常物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、以下の処理は日常物ごとに行う。

ある1つの日常物に対する提案手法の学習フェーズの




図 1 提案手法の学習フェーズの概要

Fig. 1 Overview of proposed training phase

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ノイズを軽減す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

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．

続いてこれらの時系列データに存在する高周波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．

### 3.3 弱学習器の学習

CSI の各次元の振幅，位相の合わせて  $2 \times M_T \times M_R \times N$  個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．

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．

これら 2 種類の弱学習器を学習するため，1 つの日常物における弱学習器の数は  $4 \times M_T \times M_R \times N$  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

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．

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日常物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 [11] 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．

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る．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 Vitabi アルゴリズム [11] 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る．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．

## 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日常物の配置，Wi-Fi 機器の配置を図 2 に示す．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 [12]．送信




図 2 実験環境

Fig. 2 Experimental environment

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 50Hz 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日常物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, その内 2 分程度部屋内をランダムに歩き回った. また, 各時刻における日常物の状態 (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, 次に挙げる手法を評価する.

**提案手法** 本研究の提案手法.

**HMM を用いない手法** 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 を用いた手法** 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. 前処理した CSI 時系列データに対して PCA を行い, 次元数を  $1/N$  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徴量抽出を行い, C4.5 決定木を用いて分類を行う.

分類精度の評価には, 平均した適合率と再現率, F 値の 3 つの指標を用いる.

#### 4.3 実験結果

提案手法による各環境の分類精度をそれぞれ表 1, 2, 3 に示す. スクリーンと冷蔵庫以外の日常物は, どの環境においても Wi-Fi 機器に近いほど精度が高いことが分かる. このことから日常物が 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. 冷蔵庫の精度が低いのは対象が小さく, 状態変化による電波への影響が小さいためであると考えられる. スクリーンが大きな日常物であるにもかかわらず精度が低いのは, スクリーンは壁に近く, 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.

また, 環境 1 における提案手法によるドアの各クラスの

表 1 提案手法による環境 1 の分類精度

Table 1 Classification accuracy for proposed method in environment 1

	適合率	再現率	F 値
ドア	0.721	0.760	0.737
窓 1	0.743	0.845	0.785
ブラインド 1	0.857	0.894	0.862
窓 2	0.565	0.643	0.597
ブラインド 2	0.775	0.781	0.764
スクリーン	0.385	0.417	0.390
平均	0.674	0.723	0.689

表 2 提案手法による環境 2 の分類精度

Table 2 Classification accuracy for proposed method in environment 2

	適合率	再現率	F 値
ドア	0.564	0.61	0.58
窓	0.845	0.915	0.875
ブラインド	0.715	0.775	0.709
ロッカー 1	0.74	0.71	0.713
ロッカー 2	0.728	0.74	0.733
平均	0.718	0.750	0.722

表 3 提案手法による環境 3 の分類精度

Table 3 Classification accuracy for proposed method in environment 3

	適合率	再現率	F 値
ロッカー 1	0.721	0.769	0.733
ロッカー 2	0.572	0.621	0.586
ロッカー 3	0.509	0.589	0.528
冷蔵庫	0.308	0.388	0.296
平均	0.528	0.592	0.536

表 4 提案手法による環境 1 のドアに対する分類精度

Table 4 Classification accuracy for proposed method related to door in environment 1

	適合率	再現率	F 値
開動作	0.523	0.576	0.548
閉動作	0.521	0.674	0.588
開状態	0.923	0.865	0.893
閉状態	0.916	0.924	0.920

分類精度を表 4 に示す. 表 4 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誤りになってしまう, 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

表 5 各手法による分類精度

Table 5 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	0.674	0.723	0.689	0.718	0.750	0.722	0.528	0.592	0.536
HMM を用いない手法	0.616	0.639	0.618	0.553	0.593	0.559	0.435	0.485	0.429
PCA を用いる手法	0.328	0.338	0.292	0.363	0.363	0.327	0.305	0.305	0.258

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。

各手法の分類精度を表5に示す。表5から、HMMを用いない手法は7%から18%程度の精度低下が見られた。この結果から、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精度の向上が見られた。PCAを用いたCSIの次元削減では180次元を6次元に削減することができるが、日常物の状態変化によるCSIの小さな変化を捉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日常物の状態変化を捉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。

## 5. 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日常物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。

謝辞 本研究の一部はJST CRESTの助成を受けて行われたものです。

## 参考文献

- [1] Philipose, M., Fishkin, K. P., Perkowski, 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).
- [2] Tapia, E. M., Intille, S. S. and Larson, K.: Activity recognition in the home using simple and ubiquitous sensors, *Proceedings of Pervasive* (2004).
- [3] Van Kasteren, T., Noulas, A., Englebienne, G. and Kröse, B.: Accurate activity recognition in a home setting, *Proceedings of the 10th International Conference on Ubiquitous Computing, ACM*, pp. 1–9 (2008).
- [4] Ali, K., Liu, A. X., Wang, W. and Shahzad, M.: Keystroke recognition using wifi signals, *Proceedings of the 21st Annual International Conference on Mobile Computing and Networking, ACM*, pp. 90–102 (2015).
- [5] Campbell, B. and Dutta, P.: An energy-harvesting sensor architecture and toolkit for building monitoring and event detection, *Proceedings of the 1st ACM Conference on Embedded Systems for Energy-Efficient Buildings, ACM*, pp. 100–109 (2014).
- [6] Shi, S., Sigg, S. and Ji, Y.: Passive detection of situations from ambient fm-radio signals, *Proceedings of the 2012 ACM Conference on Ubiquitous Computing, ACM*, pp. 1049–1053 (2012).
- [7] Wu, K., Xiao, J., Yi, Y., Chen, D., Luo, X. and Ni, L. M.: CSI-based indoor localization, *IEEE Transactions on Parallel and Distributed Systems*, Vol. 24, No. 7, pp. 1300–1309 (2013).
- [8] 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).
- [9] Wang, W., Liu, A. X., Shahzad, M., Ling, K. and Lu, S.: Understanding and modeling of wifi signal based human activity recognition, *Proceedings of the 21st Annual International Conference on Mobile Computing and Networking, ACM*, pp. 65–76 (2015).
- [10] Liu, X., Cao, J., Tang, S. and Wen, J.: Wi-Sleep: Contactless sleep monitoring via WiFi signals, *Proceedings of IEEE Real-Time Systems Symposium (RTSS)*, pp. 346–355 (2014).
- [11] Rabiner, L. R.: A tutorial on hidden Markov models and selected applications in speech recognition, *Proceedings of the IEEE*, Vol. 77, No. 2, pp. 257–286 (1989).
- [12] 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).