

転移学習を用いた Wi-Fi 電波による 屋内日常物の状態推定に関する検討

キム ヘン¹ 尾原 和也¹ 前川 卓也¹ 村上 友規² アベセカラ ヒランタ² 天方 大地¹ 原 隆浩¹

概要: センサ技術・IoT 技術の進展により、実世界から収集されたセンサデータを用いたコンテキスト認識技術が盛んに研究されており、特に普及が著しい Wi-Fi の電波を用いた認識技術が注目を集めている。防犯や屋内のオートメーションへの応用に向けて、Wi-Fi 電波を用いた日常物の状態推定手法が近年研究されているが、従来の手法は教師あり学習の枠組みを用いていた。しかし、部屋内の窓やドアなどの配置、Wi-Fi 送信機と受信機の位置により Wi-Fi 電波の伝搬の仕方は異なるため、観測される Wi-Fi 電波の特徴は環境に大きく依存する。したがって、ある一つの環境のデータで学習された日常物状態推定モデルは、他の環境における推定には利用できない。環境ごとに学習用データを収集するコストは非常に高く、その導入は非現実的である。本研究では、日常物の状態変化前後における、受信機で観測された電波の到来角の環境非依存的な変化を、Domain Adversarial Neural Network (DANN) を用いた転移学習により認識する手法を考案した。提案手法により、ラベルあり学習データの存在しない転移先環境においても、高精度に日常物の状態変化を検出できる。

キーワード: Wi-Fi チャンネル状態情報, 転移学習, 屋内日常物の状態推定

1. はじめに

近年、センサ技術・IoT 技術・人工知能技術の進展により、実世界から収集されたセンサデータを用いたコンテキスト認識技術が盛んに研究されており、医療、防犯、福祉、オートメーションなどの様々な分野での応用が期待されている。その中でも、防犯や屋内のオートメーションへの応用に向けて、ドアや窓といった屋内のオブジェクトの状態を自動的に認識する技術が多く開発されている。従来の手法では、カメラや日常物に添付したセンサなどを利用したものが多いが [1] [2] [3]、プライバシーの問題や各検知対象にセンサを取り付けるコストなどの問題がある。広い環境を対象とする場合や対象物が非常に多い場合、数多くのセンサが必要であるため、導入コストが高くなる。さらに、センサの数が多い場合、電源の供給や、管理、メンテナンスなどのコストも膨大である。そこで、各検知対象にセンサを取り付ける必要のない、Wi-Fi 電波を用いた日常物の状態推定手法が注目を集めている [4]。Wi-Fi 技術は、近年あらゆる場所に浸透しており、家庭や駅、学校などの様々な場所でアクセスポイントが既設されているため、Wi-Fi 電波を用いた屋内日常物の状態推定は低いコストで導入で

きる。

従来の屋内日常物の状態推定手法では、Wi-Fi 電波の伝搬状態を記述するチャンネル状態情報 (Channel State Information: CSI) を抽出し、教師あり学習で認識を行う手法が用いられてきた [4]。しかし、部屋内の窓やドアなどの配置、送信機と受信機の位置により Wi-Fi 電波の伝搬の仕方は異なるため、観測される Wi-Fi 電波の特徴は環境に大きく依存する。したがって、ある一つの環境のデータで学習された日常物状態推定モデルは、他の環境における推定には利用できない。環境ごとに学習用データを収集するコストは非常に高く、その導入は非現実的である。

この問題の解決方法の 1 つとして、環境に非依存な現象や特徴を用いて認識を行うというアプローチが考えられる。Wi-Fi 電波は障害物に当たって反射するため、検知対象となる日常物のドアや窓の開閉状態によって、検知対象の方向からの電波が変化すると考えられる。例えば、ある環境内に Wi-Fi の送信機と受信機、ドアが設置されているとする。そのドアが閉状態に変化したとき、ドア板により反射された電波が受信機により受信される。一方、そのドアが開状態にあるとき、ドア板により反射されていた電波は部屋の外に伝搬していく。そのため、受信機からはそのドア方向から到来する電波は減衰することになる。環境が異なっても変化する電波の到来角が異なるだけであり、ほ

¹ 大阪大学大学院情報科学研究科

² NTT アクセスサービスシステム研究所

ば同様の現象が観測されると考えられる。これは環境に非依存的な変化であり、本研究ではこの情報を用いて認識を行う。

近年の多くの Wi-Fi 受信機（アクセスポイント）には Multiple-Input and Multiple-Output (MIMO) 用に複数のアンテナが搭載されており、電波が到来する方向により、それぞれのアンテナに到着するタイミングが異なるため、観測される位相も異なる。Multiple Signal Classification (MUSIC) アルゴリズムを適用することで、この位相差から、到来方向ごとの電波の強度を得ることが可能である。すなわち、電波の到来角 (Angle of Arrival: AoA) を得ることができる。提案手法では、日常物の状態変化前後の AoA を比較することで、日常物の状態変化に関する環境非依存的特徴を抽出したあと、転移学習によりある環境（転移元環境）で取得したラベルあり学習データを用いて異なる環境（転移先環境）での日常物の状態推定を実現する。これにより、転移先環境でラベルあり学習データを収集するコストを削減することを試みる。転移学習を行う既存手法は多く存在するが、Domain Adversarial Neural Network (DANN) は近年パフォーマンスの高さと実装の容易さにより注目が集まっており [5]、本研究は DANN を用いて、転移元環境で得られたラベルありデータの転移学習を行う。

本稿の以降の構成は以下の通りである。まず、2 節にて Wi-Fi CSI の概要や屋内日常物の状態推定に関する関連研究を紹介した後、3 節では Wi-Fi CSI と転移学習を用いて屋内日常物の状態推定を行う提案手法について述べる。4 節では提案手法の検証実験を行い、その結果について報告し、5 節で本稿のまとめを行う。

2. 関連研究

Wi-Fi 電波によるコンテキスト認識は、ユビキタスコンピューティング分野においてこれまでに盛んに研究されてきた。Wi-Fi 電波による屋内日常物の状態変化認識、位置推定、行動認識などの研究が行われてきたが、その多くが Wi-Fi の受信電波強度 (Received Signal Strength Indicator: RSSI) と電波のチャンネル状態情報 CSI を用いている。特に電波の詳細な伝搬情報を得られる CSI は近年注目を集めている。

2.1 CSI を利用したコンテキスト認識

2.1.1 チャンネル状態情報 CSI

近年の多くの Wi-Fi 受信機（アクセスポイント）には MIMO システムが用いられる。MIMO システムでは、送信機と受信機は両方複数のアンテナを持ち、それらを通し通信を行われる。送信機のアンテナを N_t 、受信機のアンテナを N_r とすると、通信路の組み合わせが $N_t N_r$ 個となる。送信ベクトルを \mathbf{x} と受信ベクトル \mathbf{y} とすると、

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{n}$$

となる。 h_{mn} を行列 \mathbf{H} の m 行、 n 列の要素とすると、 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の伝搬状態を表す CSI となる。 h_{mn} は複素数であるため、 $h_{mn} = \|h_{mn}\|e^{j\angle h_{mn}}$ と表すことができる。 $\|h_{mn}\|$ が振幅、 $\angle h_{mn}$ が位相となる。

2.1.2 CSI による屋内日常物の開閉状態変化認識

尾原ら [4] は環境内に市販の Wi-Fi 電波受信機を 1 台ずつ設置し、受信機で観測される Wi-Fi 電波のチャンネル状態情報 CSI 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した。CSI データに対して、ノイズと必要な情報を含む成分を分離するために、独立成分分析 (Independent Component Analysis: ICA) を行った後、畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) と Long-Short-Term Memory (LSTM) から構成するニューラルネットワークを用いて特徴学習と認識を行う。さらに、その認識結果を隠れマルコフモデル (Hidden Markov Model: HMM) を用いて日常物の状態遷移の制約を考慮したデコードを行うことで、高精度の認識率を実現できた。各環境でラベルありの学習データを取得する必要があるが、評価実験ではドアごとに約 100 回の開閉を行った学習データを必要としていた。また、他の研究でも Wi-Fi の CSI を用いた屋内日常物の状態変化の推定は行われているが、どの研究も教師あり学習の枠組みで認識を行っている。一方、本研究は転移学習を用いて対象環境でのラベルありのデータの収集コストを削減する。

2.1.3 CSI を用いた行動認識

Wi-Fi 電波は人間により反射するため、屋内の人の動きによって、Wi-Fi 電波の伝搬状態が変化する。身体部位の動きによって変化したチャンネル状態情報 CSI の振幅と位相を用いて、屋内の人の「横になる」、「転がる」、「歩く」、「走る」、「座る」、「立つ」の 5 つの行動を認識する研究が行われている [6]。他にも、人間のジェスチャー認識や手の動きをトラックする研究などが多く行われている [7] [8]。

2.1.4 CSI を用いた位置推定

Manikanta ら [9] は Wi-Fi の CSI を用いて、受信機への電波の到来角 AoA と電波の飛行時間 (Time of Flight: ToF) をパラメータとするスペクトラムを計算する手法を MUSIC アルゴリズムに基づき開発したこのスペクトラムからターゲットである送信機の距離と方向を計算し、ターゲットの位置推定を行った。Li らは、この手法をさらに発展させ、デバイスフリーに移動ターゲットの位置を推定する手法である Dynamic-MUSIC を開発した [10]。ドップラーシフトにより移動ターゲットに反射した電波の周波数が変化するため、移動ターゲットからの電波と静止障害物からの電波の成分が分離可能となる。そして、移動ターゲットからの到来角 AoA を求めることでデバイスフリー




図 1 ドアの開閉の状態と電波の伝搬の変化

で移動のターゲットの位置推定を実現した。

2.2 RSSI を利用したコンテキスト認識

Heba らは Wi-Fi 電波の受信電波強度 RSSI を利用し、事前の学習が必要ないデバイスフリーのジェスチャー認識手法を開発した [11]。手のジェスチャーにより、観測される Wi-Fi 電波の RSSI の変化は主に「Rising edge」, 「Falling edge」と「Pause」の 3 つの種類に分けられる。この 3 つ種類の変化と観測される RSSI 変化の速さと大きさを抽出することで、手のジェスチャーの認識を行った。

2.3 屋内日常物の開閉状態変化認識

ドアや窓といった日常物の開閉状態を検知するために、加速度センサをはじめ、振動センサ、やスイッチセンサなどの小型センサを用いた手法が多く研究されてきた [2] [3] [12] [13]。しかし、広い環境を対象とする場合や対象物が非常に多い場合、数多くのセンサが必要であるため、電源の供給や、管理、メンテナンスなどのコストが膨大であるという問題がある。

気圧センサを用いた屋内日常物の開閉状態変化認識の研究も行われている。Patel ら [14] は、人間の動きとドアや窓の開閉動作による気流の乱れで気圧の変化が起きるという現象を利用し、エアコンフィルタに設置した気圧センサを用いた認識を行った。Wu ら [15] はスマートフォン内の気圧センサを用いて、ドアの開閉イベントを認識する手法を実現した。

Thilina ら [16] はスマートフォンから発信した音を用いて、ドップラーシフト効果により変化したドアの開閉動作による反射音の周波数を利用し、屋内のドアの開閉イベントの認識を実現した。

3. 提案手法

3.1 提案手法の概要

環境内に Wi-Fi モジュールを搭載した送信機と受信機がそれぞれ 1 つずつ設置されていると想定し、その環境内のドアや窓といった屋内日常物の開閉状態を検知対象とする。

まず提案手法の基本的な考えについて、図 1 を用いて説明する。図 1 のように、Wi-Fi 電波は障害物に当たって反

射するため、検知対象となる日常物のドアや窓の開閉状態によって、検知対象の方向からの電波が変化すると考えられる。特にドアの開状態において、受信機が受信するドアの方向からの到来電波は、閉状態に比べて減衰すると考えられる。環境が異なっても減衰する電波の到来角が変化するだけであり、ほぼ同様の現象が観測されると考えられる。本研究では、このドアの開閉による特定の到来角からの減衰/増加の現象を利用して、環境に依存しない開閉状態推定手法を提案する。

提案手法は、教師あり機械学習を用いるため、学習フェーズと推定フェーズに分けられる。学習フェーズでは、転移元環境（ソースドメイン）で得られたラベルありのデータと、転移先環境（ターゲットドメイン）のラベルなしのデータを用いて、環境に非依存なドアの開閉を推定する推定器を学習する。ここで本研究におけるラベルとは、検知対象となるドア等がどのように状態変化したかを示すラベルであり、「開から閉」への変化か、「閉から開」への変化か、「変化なし」かの 3 つの状態変化のラベルである。ドア等の状態が変化したタイミングでは、「開から閉」もしくは「閉から開」のラベルが付けられており、それ以外は「変化なし」のラベルが付けられている。推定フェーズでは、転移先環境のラベルなしのデータを、学習した推定器を用いて推定する。

提案手法の学習フェーズの概要を図 2 に示す。転移元と転移先それぞれ受信機によりチャンネル状態情報 CSI をパケットごとに取得することを想定する。ただし、転移元のラベルありデータと転移先のラベルなしデータは事前に収集されているものとする。提案手法では、Wi-Fi 信号が安定している時間的に隣接する 2 つの区間のデータを比較して、その区間の間に、環境内のドアなどの日常物にどのような状態変化が発生しているか、もしくは発生していないのかを推定する。そのため、まず転移元および転移先環境の CSI データを用いて、Wi-Fi 電波の伝搬状態が安定している区間を検出する。Wi-Fi 信号が安定していない区間には、歩行者が Wi-Fi 送受信機に近接した際に引き起こされる伝搬状態の大きな変化等が含まれるため、推定には利用しない。

次に、検出された安定区間のウィンドウ内の CSI データを切り出して、到来角変化の計算を行う。そして、時間的に n 秒離れて隣接する 2 つの安定区間のデータを用いそれらの区間で変化した到来角を計算する。

到来角変化計算のフェーズでは、ウィンドウ内の CSI データから Multiple Signal Classification (MUSIC) アルゴリズムを用いて、到来角 (AoA) と電波の飛行時間 (ToF) のスペクトラムをそれぞれ求める。そして、隣接するウィンドウ間でスペクトラムの差分を計算する。転移元で得られたラベルありのスペクトラムの差分と転移先で得られたラベルなしの差分を用いて、転移先の状態変化を認識す

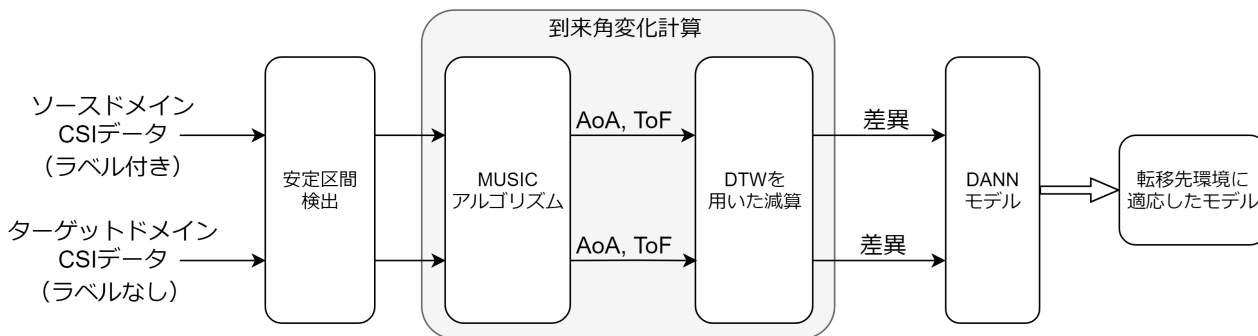


図 2 学習フェーズの概要




図 3 電波が角度 θ で入射するとき、隣接するアンテナ間で $d \sin \theta$ の経路差が生じるため、 $2\pi d(\sin \theta) f/c$ の位相差が生じる

る Domain Adversarial Neural Network (DANN) を学習する。

推定フェーズでは、転移先環境において観測した CSI データに対して転移元と同様の前処理（安定区間検出と差分計算）を行った後、スペクトラムの差分を DANN を用いて認識する。すなわち、スペクトラムの差分が、転移先環境におけるいずれかの日常物の「開から閉」への変化、「閉から開」への変化、「変化なし」のいずれに対応するのかが推定される。ここで、DANN では、環境内のドアや窓を区別して状態変化を推定しない。すなわち、ある環境における、いずれかのドアが開状態もしくは閉状態に変化した（もしくは変化なしか）という推定のみ行う。

3.2 データの取得と安定区間検出

送信機は定期的にパケットを受信機に送信し、受信機は各パケットに関するチャネル状態情報 (CSI) のデータを取得する。本研究で対象とする環境に存在するドア等の日常物の状態変化や環境内の人が移動した際に、Wi-Fi 電波の伝搬状態が大きく変化する。そのため、まずその変化区間を検出して除去する。CSI の各チャンネルの各サブキャリアごとに得られる振幅に対して移動分散を計算し、その移動分散の値がしきい値を超える場合、それを変化区間とする。その後、変化区間以外の区間を安定区間とし、その区間の CSI データを用いて到来角を計算する。

3.3 到来角の計算

MUSIC アルゴリズムを用いた到来角推定手法 [10] では、複数の直列している受信アンテナを想定している。ある角度から到来する電波はそれぞれのアンテナで受信されるタイミングが異なるため、それぞれのアンテナで受信した電波の位相が異なるという現象を利用し、AoA を計算する。図 3 のように、受信機に M 個のアンテナが直列していると想定する。電波の到来角 AoA を θ 、アンテナ間隔を d 、電波の周波数を f 、光速を c とする。ある 2 つの隣接するアンテナ間の電波の経路差は $d \sin \theta$ であり、その位相差は $2\pi d(\sin \theta) f/c$ である。これを複素表現すると、 $\phi(\theta) = e^{-j2\pi f d(\sin \theta)/c}$ となる。1 番目のアンテナの位相を基準とし、全てのアンテナの位相を以下のように行列でまとめて表現すると、下記ようになる。

$$\mathbf{a}(\theta) = [1, \phi(\theta), \dots, \phi^{M-1}(\theta)]^T$$

1 番目のアンテナで観測する信号を $s(t)$ とおくとすべてのアンテナで観測される信号は $\mathbf{X}(t) = \mathbf{a}(\theta)s(t) + \mathbf{N}(t)$ と表現される。ここで、 $\mathbf{N}(t)$ はノイズベクトルである。信号が n 個存在する場合、アンテナで観測される信号行列は下記のように変換される。

$$\mathbf{X}(t) = \sum_{i=1}^n \mathbf{a}(\theta_i) s_i(t) + \mathbf{N}(t) = \mathbf{A}\mathbf{S}(t) + \mathbf{N}(t)$$

ここで、 $s_i(t)$ は i 番目の信号、 θ_i は i 番目の信号の AoA である。信号行列 $\mathbf{X}(t)$ の自己相関 $\mathbf{R}_{xx}(t)$ は信号の部分空間とノイズの部分空間の 2 つに分けられる [10]。 $\mathbf{R}_{xx}(t)$ は M 個の固有値を持つ。その中で、最小 $(M-n)$ 個の固有値を持つ固有ベクトルはノイズベクトルに対応し、それ以外の n 個の固有値を持つ固有ベクトルは受信信号に対応する。ノイズの固有ベクトルから構成されるノイズ部分空間は $\mathbf{E}_N = [\mathbf{e}_1, \dots, \mathbf{e}_{M-n}]$ 。MUSIC スペクトラムは

$$P_{MUSIC}(\theta) = \frac{1}{\mathbf{a}^H(\theta) \mathbf{E}_N \mathbf{E}_N^H \mathbf{a}(\theta)}$$

となり、到来角 $\theta_1, \theta_2, \dots, \theta_n$ においてピークを取ることに




図 4 左はドアが閉の状態、右はドア開の状態のスペクトラム

なる。

また、異なる伝搬路では、電波の飛行時間 (ToF) も異なるため、ToF によって位相も異なる。上の式を ToF (τ) にも対応するように拡張すると、拡張した MUSIC スペクトラム [9] は

$$P_{MUSIC}(\theta, \tau) = \frac{1}{\mathbf{a}^H(\theta, \tau) \mathbf{E}_N \mathbf{E}_N^H \mathbf{a}(\theta, \tau)}$$

となる。AoA が $\theta_1, \theta_2, \dots, \theta_n$ かつ ToF が $\tau_1, \tau_2, \dots, \tau_n$ においてピークを取ることになる。したがって、MUSIC アルゴリズムにより、AoA と ToF を変数とするスペクトラム $P(\theta, \tau)$ を求めることができる。図 4 は、ある環境において、ドアが閉状態および開状態でそれぞれ取得したスペクトラムの例である。図に示すとおり、開状態の際は、閉状態に比べて -80 度方向から到来する電波が減衰していることがわかる。

3.4 DTW を用いた差異計算

安定区間における、2つの隣接するウィンドウ間において上記で計算したスペクトラムがどの程度変化したかの差異を計算する。しかし、受信機におけるパケット検出遅延 (Packet Detection Delay: PDD) とサンプリング周波数オフセット (Sampling Frequency Offset: SFO) の影響により、パケットごとに計算される ToF にはずれがあるため、スペクトラム間の直接減算により差異の計算を行うことが不可能である。各パケットの ToF のずれを考慮して減算するために、Dynamic Time Warping (DTW) アルゴリズムを使用する。図 5 に示すように、DTW は 2つの時系列間の距離計算を系列の伸縮を許容して計算するアルゴリズムであり、最も類似している点同士のアライメントを取った上で点同士の距離計算を行う。提案手法では、DTW を用いて 2つのスペクトラムの各時刻のアライメントを取った上で減算を行う。各時刻のデータ点は多次元データ (次元数は AoA の粒度: 181 次元) となるため、DTW における各データ点の距離計算にはユークリッド距離を用いた。

3.5 ニューラルネットワークの構造

本研究では、転移先環境 (ターゲットドメイン) でラベルありデータを集めずに、ターゲットドメインの日常物




図 5 左図は 1 次元の 2 つの系列データをタイムスタンプのみで点同士のアライメントを取った例、右図は DTW でアライメントを取った場合の例

の状態推定を行う、Domain Adversarial Neural Network (DANN) を用いて、転移元環境で得られたラベルありデータの転移学習を行う。詳細な DANN のアーキテクチャーを図 6 に示す。DANN は主に 3 つのサブネットワークから構成される。図中の特徴抽出層、状態変化分類器とドメイン分類器の 3 つのサブネットワークに対応し、ドメイン分類器では入力されたデータ (スペクトラムの差分) がどのドメインから得られたかを出力する。例えば、ソースドメインの数が 2 の場合、ターゲットドメインと合わせて 3 クラスの分類器となる。状態変化分類器は入力データが開から開への変化に分類されるか、閉から開への変化に分類されるか状態変化が起っていないかのいずれかを出力する 3 クラス分類器である。

ドメイン分類器の直前に、学習の際の逆伝搬 (バックプロパゲーション) に対して負の係数を乗算することで勾配を逆転する役割を持つ勾配逆転層 (Gradient Reversal Layer) を導入する。勾配逆転層を導入しない場合、通常のネットワークの学習では、出力層の損失 (loss) を小さくするようにネットワークのパラメータが更新される。一方、勾配逆転層を導入する場合、誤差を最小化するための勾配が逆転され、図 6 のネットワークではドメイン分類の誤差が大きくなるようにパラメータが更新される。そのため、勾配逆転層はソースドメインとターゲットドメインの分類性能を低下させる働きをもつ。一方で状態変化の分類性能は向上させるようにネットワークが学習される。すなわち、ネットワークはドメインの分類は失敗するが、状態変化の分類は成功するように学習される。そのようなネットワークの特徴抽出層では、ドメインに依存せずに状態変化を分類できる特徴が抽出される。

3.6 モデルの訓練

ソースドメインとターゲットドメインにおいて観測した CSI データから安定区間における隣接するウィンドウ間の AoA と ToF のスペクトラム (181×100 の 2 次元の行列) を得る。2つのスペクトラムの差異を計算したあと、2次元の行列を 18100 次元のベクトルに変換する。これらのソースドメインとターゲットドメインのベクトルがニューラルネットワークの学習データとなる。ただし、ソースド

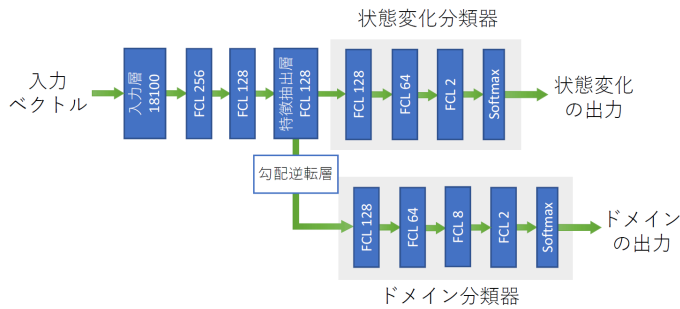


図 6 DANN モデルのアーキテクチャ

メインのベクトルにのみ状態変化のラベルが貼られている。一方、それぞれのベクトルはどのドメインで取得されたかは既知であると想定しているため、ドメインのラベルはソースおよびターゲットドメインの両方のベクトルに対して貼られているものとする。ただし学習する際は、ソースドメインのデータとターゲットドメインのデータの量はランダムサンプリングなどにより揃えるようにする。ターゲットドメインのベクトルには、日常物の状態変化のラベルが存在しないため、そのベクトルを用いてネットワークのパラメータを更新する際は、状態変化分類器のパラメータの更新は行わない。一方で、ソースドメインから得られたベクトルを用いる際には、ネットワークの全パラメータを更新する。状態変化分類器では、実際のラベル（正解）と Softmax 層の出力との交差エントロピーを小さくするように訓練する。一方、ドメイン分類器では、勾配逆転層を利用することで、ドメイン分類の性能を低下させるように、実際の正解ラベルと Softmax 層の出力との交差エントロピーを逆に大きくするように訓練する。学習に用いる勾配法には Adam Optimizer を用いた。

3.7 推定フェーズ

推定フェーズでは、ターゲットドメインで観測した CSI データから安定区間のウィンドウ内の AoA と ToF のスペクトラム (181 × 100 の 2 次元のデータ) を得る。2 つのスペクトラムの差異を計算したあと、2 次元の行列を 18100 次元のベクトルに変換する。このターゲットドメインのベクトルがニューラルネットワークのテストデータとなる。検知対象がどのように状態変化 (開→閉か、閉→開か、変化なしか) をするかを表す確率が状態変化分類器の Softmax 層により出力される。出力される確率のうち、最大となる確率に対応するクラスが、推定される状態変化となる。変化なしと推定された場合は、現在の状態は、前回に推定された状態変化の推定結果に基づき決定される。例えば、前回の結果が「開→閉」だった場合は、現在の状態は「閉」となる。ただし、転移先環境に複数の検知対象がある場合は、DANN は対象 (ドア等) を限定した出力は行わない。




図 7 実験室の配置

4. 検証実験

4.1 データセット

本検証実験で使用した部屋、送信機、受信機 1、受信機 2、日常物の窓 1、2 とドアの配置を図 7 に示す。送信機と受信機は共に Intel 5300 NIC Wi-Fi モジュールを搭載した PC である。実験の際は送信機からパケットを約 3000 Hz で受信機に送信するように設定した。本検証実験では、ドアを認識対象とし、2 つの窓の状態の違いおよび受信機の位置を転移学習の対象とする。例えば窓 1 が開状態、窓 2 が閉状態にあるとき、窓 1 が閉状態、窓 2 が閉状態にあるときは、電波の伝搬が大きく異なるため、本実験ではこれは異なるドメインとし、転移学習を行う。窓 1 と 2 の開閉状態におけるドメインの定義を表 1 に示す。同様に、受信機の位置が異なると、電波の伝搬も大きく異なるため、異なるドメインとみなす。日常物の窓 1、窓 2 とドアにはそれぞれ 2 種類の状態があるため、8 つの組み合わせがあり、各組み合わせ (状況) ごとに 2 つの受信機から約 15 秒間の CSI データを取得した。これを 1 セットとし、合計 4 セットのデータを取得した。セット 1~3 を学習データ、セット 4 をテストデータとして利用する。なお、正解ラベルを付与するために、日常物の開閉状態をウェブカメラで撮影した。

表 1 窓の開閉状態間の転移におけるドメインの定義

ドメイン名	窓 2	窓 1
D0	閉	閉
D1	閉	開
D2	開	閉
D3	開	開

4.2 評価方法

本検証実験では、まず各ドメインの初期状態として、ドアが閉じている状態を考える。そして、初期状態に得られたスペクトラムと、任意のタイミングで得られたスペクトラムの差異を計算し、閉状態から開状態に変化したか、変化していないかの 2 値分類を行う。すなわち、図 6 の状態




図 8 窓の開閉状態間の転移におけるドアの状態の認識率




図 9 受信機間転移後のドアの状態の認識率

変化の出力は 2 クラスのいずれかとなる。評価指標としては、スペクトラムのペアごとに行った推定の正解率を用いる。

セット 1~3 のソースドメインとターゲットドメインからは各 300 個のスペクトラムのペアから差異を抽出し分類を行う。

4.3 実験結果

4.3.1 窓の開閉状態間の転移

受信機 1 において、ターゲットドメインにおけるドアの開閉の認識率を図 8 に示す。有効性を確認するために、受信機 1 において、ドメイン D0 からドメイン D1 へ、ドメイン D0 からドメイン D2 へ、ドメイン D0 からドメイン D3 へ、ドメイン D1 からドメイン D0 へ、ドメイン D1 からドメイン D2 へ、ドメイン D1 からドメイン D3 へ、ドメイン D2 からドメイン D3 への適応をそれぞれ検証した。Train on Source はソースドメインからのラベルありデータのみを学習した場合、Train on Target はターゲットドメインからのラベルありデータのみを学習した場合、DANN はドメイン適応した場合の結果である。実験結果から、ドメイン適応により、ソースドメインのみの学習に比べて、ドアの開閉の認識精度が向上しており、提案手法の有効性が確認できた。

4.3.2 受信機間転移後の認識率

次に、異なる位置にある受信機間の転移について検証する。受信機 1 のドメイン D0, D1, D2, D3 をソースドメイン、受信機 2 の各ドメインをターゲットドメインとするときのドアの開閉の認識率を図 9 に示す。いずれの場合でも提案手法により、ドアの開閉の推定精度が向上していることが分かる。しかし、All Domains → D2 の場合の精度がほとんど向上していなかった。D2 の認識率は、ターゲットドメインで学習した場合でも 0.445 であり、これ以上の向上は困難であると考えられる。

5. おわりに

本研究では、DANN を用いた転移学習によりラベルあり学習データの存在しない転移先環境においても、日常物の状態変化を推定する手法を提案した。検証実験により、提案手法を用いることでラベルが存在しない環境においても高い精度で状態変化を認識可能であることを確認した。今回は環境内に人が存在しない際のみを用いて検証したが、今後は人がいる環境で取得されたデータを用いた検証を行う予定である。

参考文献

- [1] Yang, X., Tian, Y., Yi, C. and Arditi, A.: Context-based indoor object detection as an aid to blind persons accessing unfamiliar environments, *Proceedings of the 18th ACM international conference on Multimedia*, ACM, pp. 1087–1090 (2010).
- [2] Philipose, M., Fishkin, K. P., Perkowitz, M., Patterson, D. J., Fox, D., Kautz, H. and Hahnel, D.: Inferring activities from interactions with objects, *IEEE pervasive computing*, Vol. 3, No. 4, pp. 50–57 (2004).
- [3] Tapia, E. M., Intille, S. S. and Larson, K.: Activity recognition in the home using simple and ubiquitous sensors, *International conference on pervasive computing*, Springer, pp. 158–175 (2004).
- [4] Ohara, K., Maekawa, T. and Matsushita, Y.: Detecting state changes of indoor everyday objects using Wi-Fi channel state information, *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Tech-*

- nologies*, Vol. 1, No. 3, p. 88 (2017).
- [5] Ganin, Y., Ustinova, E., Ajakan, H., Germain, P., Larochelle, H., Laviolette, F., Marchand, M. and Lempitsky, V.: Domain-adversarial training of neural networks, *The Journal of Machine Learning Research*, Vol. 17, No. 1, pp. 2096–2030 (2016).
 - [6] Yousefi, S., Narui, H., Dayal, S., Ermon, S. and Valaee, S.: A Survey of Human Activity Recognition Using WiFi CSI, *arXiv preprint arXiv:1708.07129* (2017).
 - [7] 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).
 - [8] 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).
 - [9] Kotaru, M., Joshi, K., Bharadia, D. and Katti, S.: Spotfi: Decimeter level localization using wifi, *ACM SIGCOMM Computer Communication Review*, Vol. 45, No. 4, ACM, pp. 269–282 (2015).
 - [10] Li, X., Li, S., Zhang, D., Xiong, J., Wang, Y. and Mei, H.: Dynamic-music: accurate device-free indoor localization, *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, ACM, pp. 196–207 (2016).
 - [11] Abdelnasser, H., Youssef, M. and Harras, K. A.: Wigest: A ubiquitous wifi-based gesture recognition system, *Computer Communications (INFOCOM), 2015 IEEE Conference on*, IEEE, pp. 1472–1480 (2015).
 - [12] 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).
 - [13] Maekawa, T., Yanagisawa, Y., Kishino, Y., Kamei, K., Sakurai, Y. and Okadome, T.: Object-blog system for environment-generated content, *IEEE Pervasive Computing*, Vol. 7, No. 4 (2008).
 - [14] 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, *International Conference on Pervasive Computing*, Springer, pp. 1–18 (2008).
 - [15] Wu, M., Pathak, P. H. and Mohapatra, P.: Monitoring building door events using barometer sensor in smartphones, *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, ACM, pp. 319–323 (2015).
 - [16] Dissanayake, T., Maekawa, T., Daichi, A. and Hara, T.: Detecting Door Events Using a Smartphone via Active Sound Sensing, *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies (IMWUT)*, Vol. 2, No. 160 (2018).