

Wi-Fi電波を用いたデバイスフリーパッシブ 位置推定モデルの転移手法

尾原 和也¹ 前川 卓也^{1,a)} 岸野 泰恵² 白井 良成² 納谷 太²

受付日 2015年5月8日, 採録日 2015年11月5日

概要: Wi-Fi モジュールを搭載したスマートフォンの普及によって Wi-Fi を用いた屋内位置推定の研究がさかんに行われている。しかし、多くの Wi-Fi を用いた屋内位置推定の研究は位置推定対象のユーザがつねにスマートフォン等の電波受信機を携帯することを前提とするため、ユーザにとって大きな負担となる。一方近年、人体による電波の減衰を利用することでユーザが携帯する受信機を必要としない位置推定手法である、デバイスフリーパッシブ位置推定の研究が行われている。しかし、デバイスフリーパッシブ位置推定では位置推定モデル学習のためにエンドユーザが対象環境の様々な位置において学習データを収集する必要がある。そこで本研究では、異なる環境において得られた位置推定モデルを対象環境にあわせて転移させることで、低コストに対象環境の位置推定モデルを構築する手法を提案する。

キーワード: デバイスフリーパッシブ屋内位置推定, 転移学習, Wi-Fi フィンガープリンティング, パーティクルフィルタ

Transferring Positioning Model for Device-free Passive Positioning Based on Wi-Fi Signals

KAZUYA OHARA¹ TAKUYA MAEKAWA^{1,a)} YASUE KISHINO² YOSHINARI SHIRAI² FUTOSHI NAYA²

Received: May 8, 2015, Accepted: November 5, 2015

Abstract: As the widespread of smartphones that are equipped with Wi-Fi modules, Wi-Fi based indoor positioning techniques have been studied. However, many Wi-Fi indoor positioning methods assume that an end user to be tracked always possesses a signal receiver such as smartphone, and this assumption places a large burden on end users. Recently, to alleviate the burden, device-free indoor positioning techniques, which enable us to locate an end user who does not possess a smartphone based on RSSI attenuation caused by human body, have been studied. However, device-free indoor positioning techniques requires a lot of training data in a target environment. In this study, we propose a device-free positioning method that transfers training data collected in other environments to a target environment in order to reduce a training cost of positioning systems.

Keywords: device-free positioning, transfer learning, Wi-Fi fingerprinting, particle filter

1. はじめに

近年、Wi-Fi による無線 LAN アクセスの普及によって Wi-Fi モジュールの価格が低下しており、Wi-Fi 電波を受

信できるスマートフォン等の携帯端末も大多数の人が所持している。それにともない、Wi-Fi 電波情報をユーザが持つ携帯端末により取得し、屋内にいるユーザの現在位置を推定する研究がさかんに行われている。しかし、この既存の屋内位置推定ではユーザが Wi-Fi 電波を受信できる機器を身に着ける必要があるため、高齢者の見守りやホームオートメーション等、つねにユーザの位置を捕捉し続ける必要があるアプリケーションにおいて、ユーザに大きな負担を強いるという問題がある。

¹ 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

² 日本電信電話株式会社 NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories, NTT Corporation,
Souraku-gun, Kyoto 619-0237, Japan

a) maekawa@ist.osaka-u.ac.jp

一方で、この負担を軽減する屋内位置推定手法であるデバイスフリーパッシブ屋内位置推定に関する研究が近年注目されている。一般的な屋内位置推定が電波発信機と受信機間の距離による Wi-Fi 電波強度の減衰を利用しているのに対し、デバイスフリーパッシブ屋内位置推定は、送受信機間の Wi-Fi 電波がユーザ（人体）に遮られたり、吸収されることで電波強度が減衰することを利用しており、対象とする環境に設置された Wi-Fi 受信機が受信する送信機からの電波強度の変化によってユーザの位置を推定する。そのため、ユーザが機器を身に着ける必要がなく、ユーザに負担をかけない高齢者の見守りやホームオートメーション等が可能となる。

複数の送受信機が環境内に設置された場合、複数の受信機によって取得される電波強度のセットはユーザの位置によって異なる。そのため、この電波強度のセットはユーザの各位置におけるフィンガープリント（固有の電波情報）となる。このようなフィンガープリントを用いてユーザの位置を推定する手法をフィンガープリンティング位置推定と呼ぶ [1]。フィンガープリンティングによる位置推定は機械学習技術を基にしており、ユーザの位置情報（座標）とともに計測した Wi-Fi 電波強度情報からフィンガープリントを作成し、それらを学習データとして屋内位置推定モデルを学習する。推定時には、観測された電波強度を学習済みの屋内位置推定モデルと比較することでユーザの位置を推定する。しかし、屋内位置推定モデルの学習のためには、対象とする環境において、様々な場所で実際にユーザが学習用データを取得する必要がある、導入のコストが大きい。

そこで本研究では、対象とする環境において位置情報が付加された学習データを収集する必要のない屋内位置推定モデル構築手法を提案する。提案手法では異なる環境（転移元の環境）において送受信機の組（リンク）ごとにリンクを結ぶ線分上のユーザの位置と電波強度の関係を表す電波強度のモデルを作成しておき、異なる環境から対象とする環境（転移先の環境）にあわせて電波強度のモデルを転移させることで、対象とする環境の屋内位置推定モデルを構築する。このとき、送受信端末間の距離等の指標が類似しているリンクの電波強度のモデルは、互いに類似しているという仮定を基に、転移元環境のすべてのリンクから転移先環境のリンクと類似したリンクを選び、その電波強度のモデルを転移先のリンクに転移する。

ここで、上記の既存手法の多くは位置推定モデルの入力として、主に電波強度もしくはその平均を用いている。しかし、電波強度は湿度、気温、家具の配置等の様々な環境の要因によって変化するため [2]、電波強度やその平均を基にしたデバイスフリーパッシブ屋内位置推定は実用的でないといわれている。そのため、近年のデバイスフリーパッシブ屋内位置推定の研究では、ユーザがリンクを通過した

際の電波強度の移動分散を利用している [3]。本研究でも同様に電波強度の分散を用いて位置推定を行う。すなわち、リンクごとにユーザがリンクを通過した位置とその際に得られた電波強度の分散値の関係をモデル化する。

2. 関連研究

2.1 Wi-Fi 電波を用いた一般的な屋内位置推定

屋内位置推定は赤外線 [4] や超音波 [5]、RFID (Radio Frequency Identification) [6]、超広帯域無線 [7]、FM 電波 [8]、[9]、Bluetooth [10]、Wi-Fi [1] 等の通信技術を用いて実現されてきた。特に、それらの中でも Wi-Fi 技術は最も普及しているため、多くの研究者が Wi-Fi のアクセスポイント (AP) を利用した屋内位置推定モデルの構築を試みている。Wi-Fi 電波を用いた屋内位置推定の利点は多くの人が所持している Wi-Fi モジュールを搭載したスマートフォンを受信機として利用できる点である。Wi-Fi 電波を用いた屋内位置推定手法の中で最も実用的な手法の 1 つがフィンガープリンティングによる位置推定である。

2.2 デバイスフリーパッシブ屋内位置推定

Wi-Fi 電波を用いた一般的な屋内位置推定ではユーザがつねに受信機を持ち歩く必要があるため、独居高齢者の見守りのようなつねにユーザの位置を捕捉し続けるようなアプリケーションには向いていない。そのため、近年、デバイスフリーパッシブ屋内位置推定技術の研究が注目されている。

Youssef らは学習フェーズにおいて各参照点に人が立った場合の電波強度を環境内に固定された受信機によって収集している。推定フェーズでは、ある電波強度のベクトル s が与えられたときにベイズの定理 $P(l|s) = P(s|l) \cdot \frac{P(l)}{P(s)}$ を用いて条件付確率 $P(l|s)$ が最大となるように人の位置 l を推定する。また条件付確率 $P(s|l)$ のモデル化手法としてガウス分布、ヒストグラム、ガウスカーネルを比較している [11]。さらに、異なる窓幅を持つ時間窓によって移動平均、移動分散を計算し、短時間の変化と長期間の変化を比較することによって環境内の人の位置を検出している [12]。Seifeldin らは上記手法を実環境において評価し、ノードの数やウインドウサイズのような様々なパラメータの影響を調査している [13]。

Xu らはユーザがどの参照点にいるかを決定するために、線形判別分析や非線形判別分析、ユークリッド距離による分類といった分類器を用いている [14]。Deak らは Matlab 内の fastsmooth 関数を実行することで電波強度を平滑化し、信号強度のノイズを除去している [15]。

また、近年の研究では環境の変化に対応するために生の電波強度情報の代わりに電波強度の分散値を用いている [3]。家具等の配置の変化により送受信機間の電波強度が変化した場合でも、電波強度の分散値を計算することに

よって送受信機間の人の通過を検出することができる。

デバイスフリーパッシブ屋内位置推定の既存研究に基づいて、本論文では位置推定モデルの学習時の負担を軽減する転移学習手法を提案する。

2.3 その他のデバイスフリーパッシブ屋内位置推定手法

Wi-Fi 電波以外を用いたデバイスフリーパッシブ屋内位置推定の研究も数多く行われてきた。測域スキャナを用いた位置推定 [16] や、Kinect 等のカメラを用いた位置推定 [17] 等の既存手法は、学習に要する人的、時間的コストは低いが、デバイスが Wi-Fi モジュールと比較して非常に高価であるため、システム導入の価格面のコストが高くなる。本研究では、アプリケーションとして独居高齢者の見守りやホームオートメーション等、一般家庭での利用を想定しているため、システムのコストを考えるうえで価格は重要な要素となる。また、カメラを用いた場合、つねに映像を撮影されることへの嫌悪感やプライバシーの面でも問題がある。

3. 位置推定モデルの転移手法

3.1 想定する環境

本研究で想定する複数の Wi-Fi 電波送受信機を設置した環境の例を図 1 に示す。想定する環境では電波の発信機として Wi-Fi の AP を 1 台設置し、AP から発せられた電波強度情報を取得するための受信機（センサノード）を複数設置する。それぞれの受信機は観測した電波強度情報を AP に転送し、収集された電波強度情報を用いて AP もしくは AP に接続されたコンピュータがユーザの位置を推定する。

3.2 提案手法の概要

提案手法の概要を図 2 に示す。提案手法では以下の手順で屋内位置推定モデルを構築し、位置推定を行う。

- (1) モデル化フェーズ：転移元環境において各リンクを通過したときのリンク上の通過位置と電波強度の分散の関係をモデル化する。本論文ではこの分散と通過位置の関係のモデルを分散モデルと呼ぶ。
- (2) 転移フェーズ：転移元環境で作成した分散モデルを対

象とする環境に転移する。このとき、対象とする環境のリンクと類似すると考えられる転移元のリンクを見つけ、転移を行う。

- (3) 学習フェーズ：転移したモデルから対象とする環境におけるリンクを通過したときに得られる分散を算出し、対象とする環境において位置推定モデルを構築する。
- (4) 推定フェーズ：学習した位置推定モデルによって位置推定を行い、パーティクルフィルタによってユーザをトラッキングする。

以降の節でそれぞれのフェーズについて詳しく説明する。

ここで、転移先環境における屋内位置推定モデルの構築に必要な情報を以下にまとめる。

- AP と受信機の位置を含めた転移元と転移先の環境の間取り図（壁のレイアウト）
- 位置情報（ユーザの歩行軌跡）が付加された転移元環境で観測された電波強度情報
- ユーザが転移先環境をランダムに歩行した際の位置情報が付加されていない電波強度情報
- 転移元環境と転移先環境で人が環境内にいないときの電波強度情報

一方、既存手法では、対象とする環境の「間取り図」と「位置情報（ユーザの歩行軌跡）が付加された電波強度情報」を必要とする。後者の情報の取得にはユーザが自身の位置座標をカメラ等を用いて記録しながら歩行する必要があるため取得が困難である。撮影した映像を視聴しながら位置座標をコンピュータに入力する作業は、映像の記録時間以上の時間を要する。提案手法では、この情報の代わりに、「転移元環境と転移先環境で人が環境内にいないときの電波強度情報」と「ユーザが転移先環境内をランダムに歩行した際の位置情報が付加されていない電波強度情報」を用いる。人が環境内にいないときの電波強度情報は人による煩雑な入力作業が必要ないため、低コストに取得できる。また、位置情報が付加されていない電波強度情報は、ランダムに環境内を歩きまわるだけで容易に取得できる。

3.3 モデル化フェーズ

モデル化フェーズでは転移元環境においてリンクごとに電波強度の分散値と人が通過したリンク上の位置との関係をモデル化する。まず、モデル化に用いる分散の値の計算




図 1 想定する環境

Fig. 1 Assumed environment.




図 2 提案手法の概要

Fig. 2 Overview of proposed method.




図 3 3m 離れた機器間の各位置 (0.5m 間隔) を通過したときの分散値

Fig. 3 RSSI variance values when a person passed each position between transmitter and receiver.




図 4 壁が存在する場合の分散値

Fig. 4 RSSI variance values at passing when there is a wall between transmitter and receiver.

方法を説明する. Wi-Fi 電波はあらゆる場所で利用されているため, 環境の外に設置されたアクセスポイントからの電波による干渉の影響を受ける. また, そのほかにも電波は気温や湿度等の様々な要因で大きく揺らぐことがある. そのため, 電波強度の時系列データを 0.1 秒ごとに平均して求めた移動平均を用いることで, ゆらぎの影響を緩和する. そして, 電波強度の分散値としては 1 秒の幅を持つ窓ごとに移動平均の分散値を求め, 0.1 秒ずつ窓をずらすことで移動分散を求める.

事前実験において機器の間を 50cm 間隔で通過したときに得られた分散値を図 3 に示す. 送受信機間の様々な位置を通過した場合, その分散値は送受信機の近くを通過するほど大きくなる. そのため, 分散モデルには送受信機の位置で分散値が局所的に最大となるモデルを用いる. また, 壁が送受信機間に存在する場合に機器の間を 50cm 間隔で通過したとき得られた分散値を図 4 に示す. 壁が送受信機間に存在するときは, 壁で区切られた領域ごとに電波強度の分散の特徴が大きく変わり, 同様に送受信機もしくは壁の近くを通過するほど分散値が大きくなる. そのため, 壁で区切られた領域 (サブリンク) ごとに分散モデルを作成する (図 4 の場合 2 つのサブリンク).

電波強度の分散値とサブリンクを通過した位置との関係を表現するモデルとして式 (1) で定義される混合数 2 の混合ガウス関数を用いる. 混合ガウス関数モデルの概形を図 5 に示す. 人が送受信機の近くを通過したときに分散値はより大きくなるため, これらのガウス関数は送受信機の位置で最大となる.




図 5 ガウス関数によるモデル化

Fig. 5 Modeling with Gaussian function.




図 6 ガンベル関数によるモデル化

Fig. 6 Modeling with Gumbel function.

$$v(x) = \begin{cases} 0 & x < 0, x > l, \\ a_1 \exp\left(-\frac{x^2}{2b_1^2}\right) + a_2 \exp\left(-\frac{(x-l)^2}{2b_2^2}\right) & \text{otherwise,} \end{cases} \quad (1)$$

ここで x はサブリンクの片端から人がサブリンクを通過した位置までの距離 [m] であり, $v(x)$ は人がサブリンクを通過したときに得られる電波強度の分散であり, l はサブリンクの長さ (送受信機もしくは壁間の距離) である. パラメータ a_1, b_1, a_2, b_2 は, 学習データにおけるサブリンク通過時の位置 x と対応する分散値 $v(x)$ を用いて Levenberg-Marquardt 法 [18] による最小二乗近似を行うことで求める.

また本論文では, 歪度を持ったガンベル分布を基にしたガンベル関数の混合関数を混合ガウス関数の代わりに用いてモデル化し評価実験において比較を行う. このモデルは式 (2) で定義され, その概形を図 6 に示す.

$$v(x) = \begin{cases} 0 & x < 0, x > l, \\ a_1 \exp\left(-\frac{x}{b_1}\right) \exp\left[-\exp\left(-\frac{x}{b_1}\right)\right] + a_2 \exp\left(-\frac{x-l}{b_2}\right) \exp\left[-\exp\left(-\frac{x-l}{b_2}\right)\right] & \text{otherwise,} \end{cases} \quad (2)$$

上記のパラメトリックなモデルに加えて, ノンパラメトリックなモデルについても比較を行う. このモデルでは転移元環境における学習データを用いて転移先での分散を線形補間によって直接計算する. 詳細は以降で説明する.

3.4 転移フェーズ

転移フェーズでは, 電波 (分散モデル) の特徴が転移先のサブリンクと類似していると考えられる転移元環境のサブリンクを選択する. その後, 選択された転移元のサブリンクの分散モデルを転移先のサブリンクの分散モデルへと転移させる.

3.4.1 転移元のサブリンクの選択

転移元のサブリンクの選択手順を以下に示す. 転移元のすべてのサブリンクから, 選択の候補となるサブリンクを以下の手順で絞り込んでいく.

- (1) 転移先のサブリンクとサブリンクの両端が同じ転移元のサブリンクを選択する. たとえば, 転移先のサブリ

リンクの両端が受信機と壁であった場合、転移元の環境のサブリンクの中から両端が受信機と壁であるサブリンクを選択する。

- (2) 上記で選択された転移元のサブリンクのうち転移先のサブリンクと、送受信機間にある壁の数が同数のサブリンクを選択する。壁の数の情報は間取り図から得られる。
- (3) 選択された転移元のサブリンクから分散モデルが転移先のサブリンクの分散モデルと類似していると考えられるサブリンクを以下に示すサブリンク間の非類似度を表す3つの基準に従って上位 k 個を選択する。

- **通過時の分散**：2つのサブリンクにおいて、人がサブリンクを何度もランダムに通過した際に得られる分散値の分布が類似している場合、それらのサブリンクが持つ分散モデルも類似していると考えられる。そのため、ユーザがランダムに環境を歩きまわった際に取得したユーザの位置情報が付与されていないデータから、サブリンク通過時の分散値の分布を求め、比較する。このデータはエンドユーザにも比較的取得が容易である。

人がサブリンクを通過するとき分散が大きくなることを利用し、外れ値検知手法を用いて、位置情報が付加されていない電波強度情報から、通過に対応する分散の値を検出する。そして、転移元のサブリンクと転移先のサブリンクにおいて外れ値と判定された通過に対応する分散値の分布間の距離をKLダイバージェンスにより求め、基準の1つとして用いる。外れ値を検出するために、まず電波強度の移動分散の対数を取り、平均・分散を求める。この平均・分散をパラメータとする正規分布において上位5%となる値を外れ値と見なし、通過時の分散とする。この値は、事前実験において良好な結果を得たものを用いた。

- **サブリンクの長さ**：長さが近いサブリンクは、類似した分散モデルを持つと考えられる。そこで転移元のサブリンクと転移先のサブリンクの長さの差の絶対値を基準の1つとして用いる。
- **電波強度**：人が環境内にいないときに得られる電波強度の分布が近いものは、リンク上の障害物が類似していると考えられる。そこで転移元の環境で人が環境内にいないときに得られた電波強度の分布と転移先の環境で人が環境内にいないときに得られた電波強度の分布間の距離を上記のKLダイバージェンスにより求め、指標の1つとして用いる。

上記の3つの基準をそれぞれ標準化した値を要素とする3次元のベクトルのユークリッド距離を求め、 k 近傍法(k NN)によって最も距離が小さい k 個のサブリンクを選択する。

3.4.2 分散モデルの転移

上記の方法で転移先の1つのサブリンクに対して k 個の転移元のサブリンクを選択することができる。転移元の k 個の分散モデルのパラメータ(たとえば a_1 等)を k NNで利用したベクトルのユークリッド距離の逆数で重み付き平均することで転移先のサブリンクにおける分散モデルのパラメータを求める。ただし転移後の分散モデル(式(1)や(2))におけるサブリンクの長さ l の値には転移先のサブリンクの長さを用いる。このモデルにより、転移先のサブリンク上の任意の位置を通過した際の分散を計算できる。

ノンパラメトリックによるモデル化では、選択された k 個のサブリンクにおいて得られた学習データを用いて転移先サブリンク上の任意の位置を通過した際の分散値を直接計算する。選択されたそれぞれの転移元のサブリンクにおいて x での分散値を内挿によって求める(内挿ができない場合は外挿によって分散値を求める)。そして、 k NNで求めたベクトルのユークリッド距離の逆数に対応した重みを用いて、それぞれの選択された転移元のサブリンクにおいて計算された x を通過したときの分散値の重み付き平均を計算する。

3.5 学習フェーズ

学習フェーズでは通過判定モデルと位置推定モデルの学習を行う。通過判定モデルはある時刻における電波強度の分散からあるリンクをユーザが通過したかどうかを判定するモデルであり、位置推定モデルは通過判定時にリンク上の通過位置を推定するモデルである。

3.5.1 通過判定モデルの学習

転移先の環境のサブリンクをユーザが通過したかどうかを判定する通過判定モデルをサブリンクごとに学習する。具体的には、転移元のサブリンクを「通過した」ときと「通過していない」ときの分散値を学習データとして、分散値から「通過した」と「通過していない」の2クラス分類を行うSVMを学習する。転移先のリンクにおいて、ある時刻に観測された分散値をSVMの入力とし、「通過した」クラスに分類された場合、その時刻にユーザがそのサブリンクを通過したと判定し、「通過していない」クラスに分類された場合はその時刻にそのサブリンクを通過していないと判定する。

3.5.2 屋内位置推定モデルの学習

転移先環境において各サブリンク上に一定間隔で参照点として仮想の通過位置を設定し、転移された分散モデルを用いて参照点を通過した場合に得られるであろう電波強度の分散値をそれぞれ算出する。この分散値を参照点を通過した際のフィンガープリントとして、各サブリンクごとに屋内位置推定モデルを学習する。各サブリンクの位置推定モデルは、ユーザのサブリンク上の位置を k NNを用いて推定する。

3.6 推定フェーズ

推定フェーズでは、まず屋内位置推定モデルによってユーザの位置を推定し、その推定座標に基づき、非線形システムの状態の推定に利用されるパーティクルフィルタ [19] を用いてユーザをトラッキングする。

パーティクルフィルタのアルゴリズムはサンプリング、重み計算、リサンプリングの3つのステップによって構成される。サンプリングでは前時刻 $t-1$ におけるパーティクルから新しいパーティクルを生成し、移動モデルに基づいて移動させる。重み計算では時刻 t における観測を用い、尤度関数に基づいて各パーティクルの重みを計算する。本研究において、観測は屋内位置推定モデルによって推定された座標に対応する。基本的にはパーティクルが観測に近いほどパーティクルの重みは大きくなる。リサンプリングでは重みが大きなパーティクルを優先的に再サンプリングする。上記の手順を1秒のスライディング時間窓ごとに繰り返し行う。ただし、屋内位置推定モデルによってユーザの位置座標を推定する際は時間窓内の移動分散値のうち、最大の分散を用いる。

3.6.1 サンプリング

サンプリングでは移動モデルによって時刻 $t-1$ の各パーティクルから p 個の新しいパーティクルを生成する。移動モデルは2変量正規分布を用い、この2変量正規分布に基づく正規乱数によって新しいパーティクルを生成する。2変量正規分布の平均は時刻 $t-1$ において各パーティクルが持つ速度によって等速直線運動により移動した時刻 t における各パーティクルの座標である。2変量正規分布の標準偏差は上記平均の座標と時刻 $t-1$ におけるパーティクルの座標の距離であり、共分散は0とした。ここで、大きい p を用いることで、より数多くの予測（パーティクル）を生成できるため、予測精度は高くなるが、計算時間も増大する。

3.6.2 重み計算

重み計算では時刻 t における観測を基に各パーティクルの重みを計算する。時刻 t において通過判定モデルによって通過と判定されたとき、屋内位置推定モデルによって推定されたユーザの位置座標を観測とする。そのため、重み計算は通過判定モデルの2クラスSVMで分類することによって「通過した」と分類されたときのみ実行される。

観測は次のように求められる。時刻 t において、あるサブリンクの通過判定モデルによって通過が検知された場合、 t において得られた電波強度の分散値と、そのサブリンク上の各フィンガープリントの分散値との差を求める。2峰性を持つ分散モデルから、特定の分散値をとる通過位置は2カ所ある可能性があるため、最も分散値の差の絶対値が小さいフィンガープリントを2つ選び、それぞれの通過位置座標を t における推定座標とする。通過判定モデルはサブリンクごとに用意するため、ある時刻におけるそれ

ぞれのサブリンクの分散値から、サブリンクごとに用意したSVMを用いて通過判定を行う。その結果、複数のサブリンクにおいて同時刻に通過判定が行われた場合、推定座標はさらに複数存在する。それぞれの推定座標にはフィンガープリントの分散値の差の絶対値の逆数に応じた重みをつける。

パーティクルの重みは尤度関数によって与えられる。パーティクルの座標 $\mathbf{x}$ における重み計算に用いる尤度関数には以下の2変量正規分布の確率密度関数を用いる。

$$L(\mathbf{x}) = \frac{1}{2\pi\sqrt{|S|}} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T S^{-1}(\mathbf{x} - \boldsymbol{\mu})\right)$$

ただし、 $\boldsymbol{\mu}$ は位置推定モデルによって推定された座標、 S は分散共分散行列を表す。分散共分散行列には分散が1、共分散が0である単位行列 $S = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$ を用いる。各パーティクルの重みはパーティクルの位置座標における尤度関数の確率密度によって求める。ただし、時刻 t において推定座標は2つ以上存在する場合があるため、それぞれの推定座標に与えられた重みを用いて、各推定座標の尤度関数から得られたパーティクルの重みを重み付き平均し、そのパーティクルの重みとする。その後、全パーティクルの重みの合計が1となるように重みを正規化する。

3.6.3 リサンプリング

リサンプリングでは重みの大きなパーティクルをランダム性を持たせて優先的に r 個を再サンプリングする。パーティクルはそれぞれがユーザの位置を表し、パーティクルの分布はユーザの存在位置の確率分布を表すため、 r が大きければより複雑な分布を表現できる。そして時刻 t におけるユーザの推定座標をパーティクルの重み付き平均によって求める。

4. 評価実験

4.1 実験方法

図7に示す4つの環境で評価実験を行った。本実験では受信機としてWi-Fiモジュールを接続した小型コンピュータ Raspberry Pi を使用した。

また、発信機としてはWi-FiのAPを用い、これに受信機とは異なる1台のRaspberry Piを有線LANで接続することで電波発信の制御を行った。上記の受信機を10台、発




図7 実験環境

Fig. 7 Experimental environment.

信機を1台、それぞれの環境に図7のように設置した。APに有線LAN接続したRaspberry PiがUDP通信を行うことでAPからWi-Fiパケットを送出した。そして、受信機のWi-Fiモジュールを用いてWi-Fiパケットをスニフリングし、APからのパケットを取得することで電波強度情報（受信時刻と受信電波強度）を観測した。この電波強度情報のサンプリングレートはおよそ1.5 KHzとなった。

それぞれの環境で位置を手動で記録しながら20分間歩行をし、そのときの各受信機で観測される電波強度を記録した。また、人が環境内にいないときに各受信機で観測される電波強度も10分間記録した。さらに、位置情報が付加されていない環境内をランダムに歩行したときのデータおよびテスト用データもそれぞれ10分間記録した。このようなデータを用いて、3環境を転移元環境、1環境を対象環境とする交差検定を行った。位置推定精度は1秒ごとに被験者の実際の位置座標と推定座標の絶対誤差を求めることで評価した。以降では特に記述がない限り、転移元として選択するサブリンク数を $k=2$ 、通過時分散を求める時間窓幅を $w=1$ [sec]とする。また、1つのパーティクルから新たに生成されるパーティクル数を $p=10$ 、リサンプリング時に保持するパーティクル数を $r=1000$ とする。これらの値は、事前実験において結果が良好で、処理が実時間でできるものを用いた。

本研究では、転移を用いて導入コストを軽減したうえで、高い位置推定精度を達成することを目指す。そこで以下の比較手法を用いて評価を行う。

教師あり学習 通過判定モデルと屋内位置推定モデルを対象とする環境と同環境で取得した学習用データから構築する。この手法は高い導入コストを要するが、推定精度は高くなる。位置推定誤差の下限値を求めるために用いる。

ランダム選択 分散モデルの転移において、転移元のサブリンクをランダムに k 個選択する。分散モデルにはガウス関数によって近似したものを用いる。これは、本研究で提案する類似したサブリンクを発見する手法の有用性を検証するために用いる。

4.2 実験結果・考察

4.2.1 推定誤差

提案した3つのモデル化による提案手法と比較手法を用いて位置推定を行った。各々の環境を対象とする環境とした場合の平均絶対誤差を表1に示す。また、教師あり学習、提案手法のガウス関数近似によるモデル化、ランダム選択の3つの手法の累積分布関数を図8に示す。

同環境で取得した学習データを用いる「教師あり学習」と比較すると「ランダム選択」は72 cmの精度低下が見られるのに対し、提案手法のガウス関数近似は21 cm、ガンベル関数近似は60 cm、ノンパラメトリックは39 cmの精

表1 各手法による平均絶対誤差 [m]

Table 1 Average distance error [m] for each method.

	環境1	環境2	環境3	環境4	avg.
教師あり学習	1.78	1.40	1.74	1.61	1.63
ガウス関数近似	2.06	1.50	1.87	1.90	1.84
ガンベル関数近似	2.81	1.76	2.17	2.20	2.23
ノンパラメトリック	2.29	1.64	1.96	2.18	2.02
ランダム選択	2.31	1.96	2.62	2.51	2.35




図8 各手法の累積分布関数

Fig. 8 Cumulative distribution functions of distance errors for each method.




図9 転移元として選択するサブリンク数による精度の変化

Fig. 9 Transition of accuracy when we change the number of selected source sub-links.

度低下であり、ガウス関数を用いることで最も精度低下を抑えられた。ガウス関数の精度が良かった理由は、ガンベル関数よりも分散値へのフィッティングが良く、ノンパラメトリックと比べ、近似を行うことで分散値に含まれるノイズを軽減できたためであると考えられる。

また、累積分布関数からも提案手法と「ランダム選択」は大きな精度の差が見られ、提案手法は「教師あり学習」に近い精度を達成していることが分かる。以上のことから提案手法による屋内位置推定モデル転移学習の有効性が確認された。

4.2.2 転移元のサブリンク数の影響

転移フェーズにおいて、転移元として選択するサブリンク数 k を変更した場合の各モデルにおける全環境の平均絶対誤差の変化を図9に示す。各モデル化において最も精度




図 10 転移元の選択基準を変えたときの位置推定誤差

Fig. 10 Average distance errors when we change criteria to select source model.

が高いサブリンク数とそのときの平均絶対誤差は、ガウス関数近似によるモデル化ではサブリンク数が6のときで誤差が1.71 m、ガンベル関数近似によるモデル化ではサブリンク数が8のときで誤差が1.85 m、ノンパラメトリックによるモデル化ではサブリンク数が2のときで誤差が2.02 mであった。ガウス関数近似によるモデル化は転移元として選択するサブリンク数が増えるにつれ平均絶対誤差が低下し、サブリンク数が7のときに増加した後、横ばいとなる。ガンベル関数近似によるモデル化も転移元として選択するサブリンク数が増えるにつれ平均絶対誤差が小さくなる。ノンパラメトリックによるモデル化は転移元として選択するサブリンク数が増えるにつれ平均絶対誤差が大きくなる。パラメトリックなモデル化において、転移元として選択するサブリンク数を増やすと精度が高くなる理由としては、データ量が少ない、通過時分散に外れ値が含まれる等の原因によりパラメータに大きな誤差を持つ転移元分散モデルが存在するためと考える。転移に用いるサブリンク数を増やすことで、その影響を緩和できる。ノンパラメトリックによるモデル化において、転移元として選択するサブリンク数を増やすと精度が低下する理由としては、モデルの形状はリンク上の通過位置に依存し、サブリンク数が増えることで真の分布形状が異なるサブリンクを多く含んでしまうためであると考える。

4.2.3 サブリンク間の類似度の基準

転移フェーズにおいて、転移元のサブリンクと転移先のサブリンクの類似度計算に用いる基準の組合せを変更した場合の平均絶対誤差を図 10 に示す。類似度計算の基準はサブリンクの長さ（長さ）、人が環境内にいないときに得られる電波強度の分布（強度）、サブリンクをランダムに通過したときの分散の分布（分散）である。また、どの基準も用いない場合は転移元の環境からランダムにサブリンクを選択し、転移に用いるとする。

この結果から、長さと通過時分散のみを用いた際にガウス関数近似を行った場合が最も良い精度となっていることが分かる。この結果をより詳細に分析する。この結果は、




図 11 「すべて」と「長さ&分散」を用いたときの転移元のサブリンク数による推移

Fig. 11 Transition of accuracy using a criteria of “All” or “Length and Variance” when we change the number of selected source sub-links.

$k = 2$ のときに得られた結果であるが、サブリンク間の類似度の基準として「すべて」を用いる場合と「長さ」と「分散」のみを用いる場合の転移元として選択するサブリンク数を変化させたときの平均絶対誤差の推移を図 11 に示す。この図から転移元として選択するサブリンク数が増えるにつれ、「すべて」を用いたときの誤差が小さくなり、「長さ」と「分散」のみを用いたときより誤差が小さくなるのが分かる。「すべて」において用いられている「人がいないときの受信電波強度」は温度や湿度、家具の配置等の変化によって同じ環境であっても大きく分布が変化することがある。そのため、転移元のサブリンク数が少ないときは、その変化に大きく影響され、転移した分散モデルと転移先での実際の分散モデルとの誤差が大きくなったと考える。一方、転移元のサブリンク数が多いときはその変化の影響が平均化により小さくなるため、「人がいないときの受信電波強度」を用いている「すべて」の精度が高くなったと考える。

また、本実験において提案手法による全環境の平均絶対誤差が最小となった条件は、ガウス関数近似によるモデル化を行い、基準としてサブリンクの長さ、人が環境内にいないときの電波強度の分布、通過分散の分布のすべてを用い、転移元として $k = 6$ のサブリンクを選択した場合の 1.71 m であった。これは同環境で取得した学習データを用いる教師あり学習の 1.63 m という全環境の平均絶対誤差と比べ 8 cm の差しかなく、t 検定でも有意水準が 0.05 の場合、誤差の平均に有意差なしという結果になったため、同環境での学習と同程度の精度で位置推定できていると考える。

4.2.4 受信機の数の影響

環境内に設置する受信機の数を実験的に減少させた場合の各手法の平均絶対誤差の変化を図 12 に示す。

受信機数を減らすとすべての手法において精度が低下することが分かる。精度が低下する割合はどの手法も同程度であることから、受信機数の影響は転移の方法には無




図 12 受信機の数による精度の変化

Fig. 12 Transition of accuracy when we change the number of receivers.

関係であると考ええる。

5. おわりに

本研究では他環境の学習データを用いることで対象とする環境において低コストに屋内位置推定モデル構築する手法を提案した。一般にデバイスフリーパッシブ屋内位置推定は、屋内位置推定モデルを学習するために対象とする環境において、様々な場所でユーザが学習用データを取得する必要があるため、システムの導入にかかるコストが大きいという問題がある。そこで本研究では、対象とする環境において位置情報が付加された学習データを計測することなく、異なる環境から対象とする環境に分散モデルを転移させることで、対象とする環境の屋内位置推定モデルを構築する。

評価実験では、4つの環境において提案手法による屋内位置推定モデルの構築を行い、それぞれの環境で歩行をトラッキングすることで評価を行った。その結果、同環境で取得した電波強度情報を学習データとした比較手法とほぼ同様の精度を達成することができ、提案手法の有効性を示した。

謝辞 本研究の一部は JSPS 科研費 26730047 の助成を受けて行われたものです。

参考文献

- [1] LaMarca, A., Chawathe, Y., Consolvo, S., Hightower, J., Smith, I., Scott, J., Sohn, T., Howard, J., Hughes, J., Potter, F., et al.: Place lab: Device positioning using radio beacons in the wild, *Pervasive computing*, pp.116–133, Springer (2005).
- [2] Chen, Y.-C., Chiang, J.-R., Chu, H.-h., Huang, P. and Tsui, A.W.: Sensor-assisted wi-fi indoor location system for adapting to environmental dynamics, *The 8th ACM International Symposium on Modeling, Analysis and Simulation of Wireless and Mobile Systems*, pp.118–125 (2005).
- [3] Paul, S.A., Wan, A.E., Adenwala, F., Schafermeyer, E., Preiser, N., Kaye, J. and Jacobs, G.P.: MobileRF: A robust device-free tracking system based on a hybrid neural network HMM classifier, *The 2014 ACM International Joint Conference on Pervasive and Ubiquitous Com-*

- puting*, pp.159–170 (2014).
- [4] Want, R., Hopper, A., Falcao, V. and Gibbons, J.: The active badge location system, *ACM Trans. Information Systems (TOIS)*, Vol.10, No.1, pp.91–102 (1992).
- [5] Priyantha, N.B., Chakraborty, A. and Balakrishnan, H.: The cricket location-support system, *The 6th Annual International Conference on Mobile Computing and Networking*, pp.32–43 (2000).
- [6] Ni, L.M., Liu, Y., Lau, Y.C. and Patil, A.P.: LANDMARC: Indoor location sensing using active RFID, *Wireless Networks*, Vol.10, No.6, pp.701–710 (2004).
- [7] Sahinoglu, Z., Gezici, S. and Guvenc, I.: *Ultra-wideband positioning systems*, Cambridge, New York (2008).
- [8] Krumm, J., Cermak, G. and Horvitz, E.: Rightspot: A novel sense of location for a smart personal object, *UbiComp 2003*, pp.36–43 (2003).
- [9] Popleteev, A., Osmani, V. and Mayora, O.: Investigation of indoor localization with ambient FM radio stations, *PerCom 2012*, pp.171–179 (2012).
- [10] Wang, Y., Yang, X., Zhao, Y., Liu, Y. and Cuthbert, L.: Bluetooth positioning using RSSI and triangulation methods, *Consumer Communications and Networking Conference (CCNC)*, pp.837–842 (2013).
- [11] Kosba, A.E., Abdelkader, A. and Youssef, M.: Analysis of a device-free passive tracking system in typical wireless environments, *International Conference on New Technologies, Mobility and Security (NTMS)*, pp.1–5 (2009).
- [12] Youssef, M., Mah, M. and Agrawala, A.: Challenges: Device-free passive localization for wireless environments, *The 13th Annual ACM International Conference on Mobile Computing and Networking*, pp.222–229 (2007).
- [13] 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 Trans. Mobile Computing*, Vol.12, No.7, pp.1321–1334 (2013).
- [14] Xu, C., Firner, B., Zhang, Y., Howard, R., Li, J. and Lin, X.: Improving rf-based device-free passive localization in cluttered indoor environments through probabilistic classification methods, *The 11th International Conference on Information Processing in Sensor Networks*, pp.209–220 (2012).
- [15] Deak, G., Curran, K., Condell, J. and Londonderry, U.: Device-free passive localization using RSSI-based wireless network nodes, *The 11th annual Symposium on the Convergence of Telecommunications, Networking and Broadcasting*, pp.241–246 (2010).
- [16] Arras, K.O. and Tomatis, N.: Improving robustness and precision in mobile robot localization by using laser range finding and monocular vision, *1999 3rd European Workshop on Advanced Mobile Robots, 1999(Eurobot'99)*, pp.177–185, IEEE (1999).
- [17] Biswas, J. and Veloso, M.: Depth camera based indoor mobile robot localization and navigation, *2012 IEEE International Conference on Robotics and Automation (ICRA)*, pp.1697–1702, IEEE (2012).
- [18] Moré, J.J.: The Levenberg-Marquardt algorithm: Implementation and theory, *Numerical Analysis*, pp.105–116, Springer (1978).
- [19] Crisan, D. and Doucet, A.: A survey of convergence results on particle filtering methods for practitioners, *IEEE Trans. Signal Processing*, Vol.50, No.3, pp.736–746 (2002).



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．屋内位置推定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．



岸野 泰恵 (正会員)

平成 14 年大阪大学工学部卒業．平成 16 年同大学大学院情報科学研究科博士前期課程修了．平成 19 年同研究科博士後期課程修了，日本電信電話株式会社入社．博士（情報科学）．ユビキタスコンピューティング，センサネットワークに関する研究に従事．ACM 会員．



白井 良成 (正会員)

平成 10 年慶應義塾大学環境情報学部卒業．平成 12 年同大学大学院政策・メディア研究科修士課程修了．同年日本電信電話株式会社入社．博士（工学）．HCI，センサネットワークの研究に従事．ヒューマンインタフェース学会，日本バーチャルリアリティ学会各会員．



納谷 太

平成 4 年慶應義塾大学理工学部電気工学科卒業．平成 6 年同大学大学院修士課程修了．博士（工学）．平成 6 年日本電信電話株式会社入社．平成 15 年より 6 年間 ATR メディア情報科学研究所，同知識科学研究所出向．コミュニ

ケーションロボット，パターン認識，センサネットワーク，データマイニング等の研究に従事．現在，NTT コミュニケーション科学基礎研究所主幹研究員．電子情報通信学会，計測自動制御学会，IEEE 各会員．