

# 歩行者デッドレコニングによる 屋内位置推定モデル更新手法の提案

谷内 大祐 前川 卓也

**概要:** Wi-Fi 信号強度を用いた屋内位置推定技術は、すでに普及している Wi-Fi アクセスポイントを利用するため導入コストが抑えられ、また Wi-Fi の信号を受信することができる場所であればどこでも利用できるという点で需要が高まっている。しかし、一般的な屋内位置推定手法である Wi-Fi フィンガープリンティングは、周辺の環境の変化や Wi-Fi アクセスポイントの移動・消滅などにより推定精度が大幅に低下してしまうという問題がある。この問題に対応するためには位置座標ごとの電波の特徴を表す Wi-Fi フィンガープリントを手作業で収集し直す必要があるが、そのコストは膨大である。そこで本研究では、対象とする環境を長時間過ごすユーザの携帯端末から得られたセンサデータを用いてその歩行移動軌跡を推定し、同時に Wi-Fi 信号強度を計測しておくことにより、Wi-Fi 信号強度とそれに対応する屋内位置座標を連続的に生成する。この情報を用いて屋内位置推定モデルを定期的に自動で更新することにより、環境の変化や Wi-Fi アクセスポイントの移動や消滅などによる位置推定精度の低下に対応する。評価実験では、提案手法によってモデルの更新を行うことにより、モデルの更新を行わない手法と比べて位置推定精度の向上が確認できた。また環境変化を意図的に加えた場合でも、位置推定精度の低下は抑えられており、安定した精度で位置推定を行うことができた。

**キーワード:** Wi-Fi フィンガープリンティング, センサ, 歩行者デッドレコニング, パーティクルフィルタ

## Updating Indoor Positioning Model using Pedestrian Dead-Reckoning

TANIUCHI DAISUKE MAEKAWA TAKUYA

**Abstract:** This paper proposes a new method for automatically updating a WiFi indoor positioning model by employing sensor data obtained from the body-worn sensors of a specific user who spends a lot of time in a given environment (e.g., a worker in the environment). In this work, we attempt to track the user with pedestrian dead reckoning techniques, and at the same time we obtain WiFi scan data from a mobile device possessed by the user. With the scan data and the estimated coordinates, we can automatically create a pair consisting of a scan and its corresponding indoor coordinates during the user's daily life, and update signal strength fingerprints by using the information. With this approach, we try to cope with the instability of WiFi based positioning methods caused by changing environmental dynamics, i.e., layout changes and moving or removal of WiFi access points. And so ordinary users who do not wear rich sensors can benefit from the continually updating positioning model.

**Keywords:** Wi-Fi fingerprinting, sensor, pedestrian dead reckoning, particle filter

### 1. はじめに

近年、Wi-Fi による無線 LAN アクセスは企業や一般家

<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, Japan

庭、飲食店や地下鉄の駅にまで普及しており、どこにいても簡単に Wi-Fi の電波を受信できるようになりつつある。一方、大多数の人が携帯端末を所持しており、さまざまなセンサ（加速度センサ、方位センサ、ジャイロセンサなど）が搭載されているものも増えている。それに伴い、Wi-Fi 電波情報やセンサデータを用いて屋内位置推定を行う研究が数多く行われている。屋内位置推定技術の応用は、博物館、病院、ショッピングモールのナビゲーションや病院での高齢者の見守りなど幅広い。最も実現性の高い屋内位置推定手法に Wi-Fi フィンガープリントによる位置推定がある。この手法では、オフライン（学習）フェーズにおいて、あらかじめさまざまな場所（座標）で Wi-Fi の電波情報を観測・記録し、Wi-Fi 屋内位置推定モデルを学習する。電波情報とは各 Wi-Fi アクセスポイント（AP）から受信する電波強度の情報であり、電波は距離によって減衰するため、場所ごとに異なる固有の情報（フィンガープリント）となる。そのため、オンライン（計測）フェーズにおいて、ユーザがその現在地の Wi-Fi 電波情報を用いて位置推定モデルに問い合わせを行うと、その電波情報に対応する位置情報が得られる。しかし、このようなあらかじめ計測した電波情報を用いる手法は、アクセスポイントの移動や消滅、さらには周辺の環境の変化などによりその推定精度が大きく低下してしまう。この問題に対応するには、定期的に手作業で電波情報を収集し直し、位置推定モデルを更新する必要があるが、そのコストは膨大である。

そこで本研究では、そのような問題に対応できるように Wi-Fi 位置推定モデルを自動で更新する手法を提案する。提案手法では、対象とする環境内を長時間過ごしているユーザの携帯端末から得たセンサデータを用いて、Wi-Fi 電波情報とそれに対応する位置座標を自動的に作成し、その情報を用いて位置推定モデルを定期的に更新する。提案手法では、環境内にその座標が既知の Bluetooth ビーコンをごく少数設置するとする。このビーコンにより、Bluetooth センサを搭載した端末をもつユーザがこのビーコンの座標を通過したことが検知できる。その後、端末に搭載された加速度や方位センサ、ジャイロセンサを用いた歩行軌跡トラッキング手法である歩行者デッドレコニングを行うことで、ユーザの以降の座標を推定する。それと同時に Wi-Fi 電波情報を計測することで、位置座標とその座標における Wi-Fi 電波情報のデータを作成、データベースに登録する。そして、位置推定モデルを自動的に更新する。提案手法の特徴は主に以下の 2 点である。

(1) 提案手法では、ユーザの移動中に Wi-Fi 電波情報を取得することを想定しているため、高いサンプリングレート（短いタイムアウト時間）で Wi-Fi 電波情報を計測する必要がある。したがって、得られた電波情報データにいくつかのアクセスポイントからの電波強度情報が含まれないことがある。（タイムアウト時間内

にそのアクセスポイントからの電波情報が得られない。）このような欠損した電波情報を扱えるような位置推定モデルを設計する。

(2) Wi-Fi アクセスポイントの移動や周辺環境の変化により、電波状況が大きく変化することがある。本研究ではそのような変化を自動的に検知し、その変化に応じて位置推定モデルを学習する。

提案手法の利用シナリオとしては、病院やオフィス、ショッピングモールなどでの利用が考えられる。日常的に勤務している職員らがセンサを搭載した携帯端末を所持していると想定し、職員らが各々の業務や巡回などにおいて屋内を歩き回ることによって自動で位置推定モデルが更新される。それによりセンサを搭載した携帯端末を所持していない人でも、現在地の Wi-Fi 電波情報を基に最新の位置推定モデルを用いて、自身の現在地を推定することができる。

## 2. 屋内位置推定の関連研究

### 2.1 屋内位置推定の効率的な学習に関する研究

低コストな屋内位置推定モデルの構築に関する研究を紹介する。

Jiang ら [1] は、生活の中で得られた WiFi 信号強度情報を、加速度データを用いてクラスタリングし、部屋ごとの信号強度のモデルを自動的に学習している。Pulkkinen ら [2] は、少数の疎なトレーニング用フィンガープリントと、ラベルなしの WiFi スキャンデータから、非線形写像を用いて密な WiFi 信号強度マップを作成している。Chai ら [3] は、少数のトレーニング用フィンガープリントで高精度な位置推定を行うために、ユーザの移動中に連続して得られたラベルなし WiFi スキャン系列を用いている。スキャン系列と隠れマルコフモデルを用いて、フィンガープリント間の電波の変化をモデル化することで、疎なトレーニング用フィンガープリントを補完している。Wang ら [4] は、屋内環境に現れるランドマークを用いて PDR (Pedestrian Dead-Reckoning) の累積誤差を補正する手法を提案している。ランドマークとは、なんらかのセンサの値に特徴をもつ場所である。例えば、エレベータ内では加速度センサに特有の変化が見られるであろうし、磁場が強力な場所なども屋内環境には存在する。これにより、Wi-Fi フィンガープリントが必要ない位置測位を実現している。

しかしながら、これらの研究では Wi-Fi 電波状況の変化への対応は実現できていない。

### 2.2 環境変化に対応した屋内位置推定に関する研究

環境の変化によって Wi-Fi を用いた屋内位置推定の精度が低下してしまう問題への対応に関する研究を紹介する。

S. Chen ら [5] は、位置推定精度を向上させるために、センサネットワークによって得た温度や湿度、騒音などの環

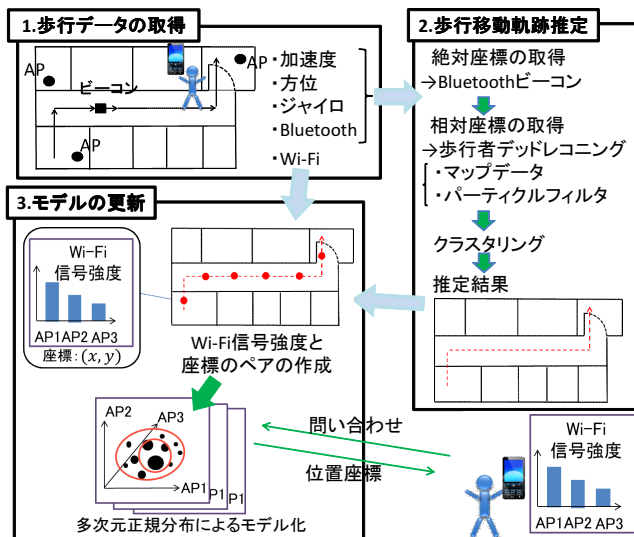


図 1 提案手法の概要  
 Fig. 1 Overview of proposed method

境要素を利用している。Y.C. Chen ら [6] も、センサネットワークから得られた人間や扉、湿度のような環境要素の状態を用いた適応的な位置推定を行っている。Yin ら [7] は、少数の Wi-Fi 受信機を備えた位置座標が既知のノードを環境内に設置し、そのノードによって受信した Wi-Fi 信号強度とユーザの端末によって受信した Wi-Fi 信号強度の関係を、回帰分析によって予測する手法を提案している。Pan ら [8] は、日々変化する WiFi 信号によりフィンガープリントデータベースが劣化する問題に対処するため、短期間では信号が大きく変化しないという仮定を基に、Manifold co-Regularization を用いた半教師あり学習により、フィンガープリントデータベースを更新する手法を提案している。

これらの研究は、主に環境が徐々に変化していくことを想定しており、突然の大きな変化は想定していない。

### 3. Wi-Fi 位置推定モデルの自動更新手法

#### 3.1 概要

提案手法では、1 章で述べたように、ある環境内で日常的に暮らしているユーザの様々なセンサデータを用いて、Wi-Fi 位置推定モデルを自動で更新する。提案手法の概要を図 1 に示す。

まずユーザが腰部に装着した携帯端末によって取得したセンサデータから歩行区間の検出を行う。ユーザが歩行動作を行っているとき、その区間のセンサデータを用いて位置推定モデルの更新を行う。まず、あらかじめ環境内にごく少数設置した Bluetooth ビーコンを用いて、Bluetooth センサを搭載した携帯端末をもつユーザがそのビーコンの座標を通過した時刻を検知する。その後、携帯端末に搭載された加速度や方位センサ、ジャイロセンサを用いて、歩行軌跡トラッキング手法である PDR を行うことで、ユーザの歩行移動軌跡を推定し続ける。それと




図 2 Bluetooth 信号強度  
 Fig. 2 Bluetooth signal strength

同時に Wi-Fi 信号強度を計測することで、位置座標とその座標における Wi-Fi 信号強度情報を連続的に作成・蓄積する。そして、そのデータを用いて位置推定モデルを定期的に更新する。以下にその手順の詳細を説明する。

#### 3.2 歩行区間の検出

ユーザが腰部に装着した携帯端末によって取得した加速度データ・ジャイロデータから、従来の行動認識手法を用いて歩行区間の検出を行う [9][10]。時系列データを用いるため、スライディング時間窓ごとに各軸のセンサデータから平均・分散の FFT 成分の特徴を抽出する。そして、この特徴から構成した特徴ベクトルを C4.5 決定木によって「歩行」と「歩行以外」に分類することで歩行を行っている時刻（区間）を検出する。

#### 3.3 マップデータ・パーティクルフィルタを用いた歩行者デッドレコニングによる屋内位置推定

検出された歩行区間の移動軌跡を、携帯端末に搭載されたセンサから取得した様々なセンサデータによって推定する。その手順を以下で説明する。

##### 3.3.1 Bluetooth のビーコンによる絶対座標の取得

Bluetooth センサを搭載した携帯端末をもつユーザが Bluetooth のビーコンの付近を通過するとき、図 2 のようにビーコンに近付くにつれて受信する Bluetooth の信号強度は大きくなり、離れるにつれて信号強度は小さくなる。この特性を用いて端末がビーコンの座標を通過した時刻を決定する。具体的には、あらかじめ環境内に Bluetooth ビーコンをごく少数設置し、その SSID (Service Set Identifier) と位置座標を登録しておく。ユーザの所持している携帯端末に搭載された Bluetooth センサが、登録されている SSID をもつ Bluetooth 信号を受信し、その信号強度が閾値を超え、かつ極大値を取ったとき、その SSID と対に登録されている位置座標を通過したものとする。

##### 3.3.2 PDR による歩行軌跡の推定

ビーコンにより通過時刻が取得されたあと、以降の歩行軌跡を推定する。具体的には、対象とする環境のマップデータおよびパーティクルフィルタを用いた PDR を行う。以降の説明は、ビーコン通過以降の軌跡推定に関して説明

する。まずビーコンが設置された地点を通過したと判定されたとき、ビーコンを設置した座標にパーティクルを生成する。このとき、Bluetooth センサのサンプリングレートの影響などから、取得された通過時刻にはわずかな誤差が生じることが考えられる。この誤差に対応するため、ビーコンの設置座標を平均とする2次元正規分布に従ってパーティクルを複数生成する。そして歩行ステップが検出されるごとに、そのステップの歩幅と進行方向を推定し、それらに応じて次の時刻におけるパーティクルを生成・移動させる。この処理を検出された歩行の終了時刻まで繰り返す。このとき、あらかじめ用意した環境のマップデータと照合し、障害物（壁）に衝突したパーティクルは削除する。以上のようなPDRを実現する際の詳細な処理について以下に説明する。

- ステップの検出

ステップの検出は加速度センサによって行うが、センサの設置（装着）方向に依存しないように3軸加速度の合成値を用いる。1ステップごとに3軸加速度の合成値は重力加速度より小さくなり、その後、重力加速度より大きくなる。この周期性からステップを検出する。

- 歩幅の決定

歩幅には個人差があり、さらに同じ人が歩く場合でも歩幅は常に一定ではない。そこで個人差を考慮して35cm～55cmまでの1cm刻みの20通りを基準の歩幅とするパーティクルを、ビーコンを通過したタイミングで生成する。ステップごとの歩幅は、基準の歩幅から正規分布にしたがって分散させる。

- 進行方向の推定

まずビーコン通過時における進行方向を方位センサによって計測する。このとき、方位センサは屋内に設置された電子機器などによって影響を受けるため、正確な方位は得られない。そこでビーコンを廊下などの進行方向が限られる場所に設置することを想定し、方位センサであらかじめ設定された進行方向のみを判定する。その後の進行方向はジャイロセンサにより得られた角速度を積分することで決定する。ジャイロセンサの出力に含まれる誤差に対応するため、進行方向の角度もパーティクルを用いて正規分布にしたがって分散させる。

以上の処理の詳細に関しては、PDRに関する文献を参照されたい [11], [12]。

そして、歩行の終了時刻において障害物に衝突せずに残ったパーティクル群の、その時刻に対応する位置座標をクラスタリングする。クラスタリングにはX-means法 [13]を用いる。そして、要素数の最も多いクラスタ重心に最も近いパーティクルの軌跡を推定軌跡とする。

### 3.4 Wi-Fi 屋内位置推定モデルの学習と位置推定

上記の方法で推定した屋内位置座標とそれに対応したWi-Fi信号強度データが自動で作成・蓄積される。このWi-Fi信号強度データは、ユーザが歩行中に収集することを想定するため、高いサンプリングレートで収集しており、一部のアクセスポイントからの信号が受信できずに欠損している場合がある。従来のフィンガープリントによる位置推定手法を用いた場合、このような欠損データをうまく扱えない。多くの従来手法では、データベースに格納されている信号データとエンドユーザの端末から（通常のサンプリングレートで）収集された信号データ間の距離を計算する。このとき信号データは、各々のアクセスポイントをベクトルの要素、その受信信号強度をその要素の値とするベクトルで表現される。すなわち、欠損したアクセスポイントに対応する要素の値は0となるため、欠損信号データとそうではない信号データ間のユークリッド距離は、同じ位置座標で得られたものだとしても大きくなってしまふ。そこで本研究では、マップにおける一定の大きさのグリッド内で計測されたWi-Fi信号強度データをまとめ、グリッドごとに信号強度のモデルを学習することで、欠損の問題に対応する。モデルの学習の際には、アクセスポイントごとにWi-Fi信号強度の分布を正規分布により学習するが、分布の平均と分散を求める際には、そのアクセスポイントからの信号強度情報が欠損していないデータのみを用いて計算する。

このモデルを用いて位置推定を行う場合、位置推定を行いたい地点におけるWi-Fi信号強度情報 $x$ を計測し、 $n$ 番目のグリッドのモデルに関して、アクセスポイントごとの信号強度の分布確率の総和 $f(x, n) = \sum_i f_i(x_i, \mu_{i,n}, \sigma_{i,n}^2)$ を計算する。このとき $x$ に含まれるアクセスポイントの信号強度のみに関して総和を計算することで、アクセスポイントが除去された場合に対処する。アクセスポイント $i$ から受信した信号強度 $x_i$ の分布確率は、正規分布の確率密度関数

$$f_i(x_i, \mu_{i,n}, \sigma_{i,n}^2) = \frac{1}{\sqrt{2\pi\sigma_{i,n}^2}} \exp\left(-\frac{(x_i - \mu_{i,n})^2}{2\sigma_{i,n}^2}\right)$$

によって計算する。ここで、 $\mu_{i,n}$ ,  $\sigma_{i,n}^2$ はグリッド $n$ におけるアクセスポイント $i$ からの信号強度の分布の平均と分散である。この $f(x, n)$ のtop-kのグリッドに対応する座標をその総和により重み付け平均した座標が位置推定結果となる。（重みは分布確率の総和に対応）

### 3.5 信号強度変化の検出

上述した学習方法では、アクセスポイントの移動や周辺環境の変化により電波状況の急激な変化が起こった時に対処できない。ここでは、それによって起こる信号強度の変化を検出、それに応じてモデルを学習する方法を説明す




図 3 シグモイド関数

Fig. 3 Sigmoid function

る。提案手法により、あるグリッド内において、あるアクセスポイントからの信号強度が定期的に得られる。この時系列データを用いて信号強度の大きな変化を検出する。検出にはベイズ情報量基準 (BIC: Bayesian Information Criterion) を利用する。時系列データに対して一定のサイズのスライディングウィンドウを適用し、ウィンドウ内で BIC を用いて変化を検出する。BIC はモデル選択に用いられる指標の 1 つで、BIC を用いた系列データのセグメント手法が音声認識の分野で用いられている [14]。例えば、系列データ  $s = s_1, s_2, \dots, s_N$  内の変化を検出するとする。  $s$  は、ガウス過程によって、

$$s_n \sim N(\mu, \sigma^2)$$

と表されるとする。ただし、 $\mu$  は平均、 $\sigma^2$  は分散である。変化の検出には次式を用いる [15]。

$$\Delta BIC_t = \frac{N}{2} \log(\sigma^2) - \frac{t}{2} \log(\sigma_1^2) - \frac{N-t}{2} \log(\sigma_2^2) - \lambda \log(N)$$

ただし、 $\sigma_1^2, \sigma_2^2$  はそれぞれ系列データ  $s_1, \dots, s_t, s_t, \dots, s_N$  から推定されたモデル  $M_1, M_2$  の分散である。また  $\sigma^2$  は全データ ( $s_1, s_2, \dots, s_N$ ) から推定されたモデル  $M$  の分散である。時刻  $t$  に信号強度に変化が起こったとき、 $M_1, M_2$  における最大尤度は大きくなる、すなわち分散は小さくなる。そのため、 $\Delta BIC_t$  が最大かつ  $\Delta BIC_t > 0$  となる時刻が変化点として出力される。

次に変化の有無に応じて各信号強度データに対して重み付けを行い、重み付き平均により分布の平均  $\mu_{i,n}$  を計算する。重み付けの方法は以下の 2 種類を用意した。

- シグモイド関数

シグモイド関数  $S(t, c)$  は以下の数式で定義され、図 3 に示されるような関数である。

$$S(t, c) = \frac{1}{1 + e^{-(t-c)}}$$

ただし、 $c$  は検出された変化時刻であり、 $t$  は信号強度を計測した時刻である。

この関数により、環境変化前に計測された信号強度データはその重みを小さくする。

- 忘却関数




図 4 忘却関数 ( $\lambda = 0.9$ )

Fig. 4 Forgetting function ( $\lambda = 0.9$ )



図 5 実験を行ったフロアの見取り図 (29.8m × 16.3m)

Fig. 5 Floor plan of experimental environment (29.8m × 16.3m)

忘却関数  $F(t, u)$  は以下の数式で定義され、図 4 に示されるような関数である。

$$F(t, u) = \lambda^{u-t}$$

ただし、 $\lambda (0 < \lambda \leq 1)$  は忘却係数 [16] であり、 $u$  は現在時刻 (モデルを更新する時刻) である。

変化点が現在時刻から 5 日以内に検出された場合、 $\lambda$  は小さい値 ( $\lambda = 0.7$ ) を採用する。これにより、過去の信号強度データを忘却することができる。また、変化点が検出されなかった場合は、 $\lambda$  は大きい値 ( $\lambda = 0.98$ ) を採用する。これは、信号強度が徐々に変化していった場合にも対応できるようにするためである。

## 4. 評価実験・考察

### 4.1 実験方法

実験用センサデータを取得したフロアの見取り図を図 5 に示す。

あらかじめフロア内に Bluetooth ビーコンを 1 個設置した。次に研究室内の座標が既知の 22 ヶ所のトレーニングポイントで Wi-Fi 信号強度を測定し、Wi-Fi 位置推定モデルを構築した。そして、以降 28 日間にわたって毎日以下の行動を繰り返した。

- (1) 携帯端末 (Google Galaxy Nexus) を実験参加者の腰部に取り付け、フロア内をビーコンの設置された地点を通過するようにランダムに歩き回ってもらう。(毎日 20 回の追加)






図 6  $k$  近傍法と提案手法による位置推定精度の推移 (シナリオ 1)  
Fig. 6 Transition of accuracies related to  $k$ NN and our methods

- (2) 得られたセンサデータを用いて屋内位置推定モデルを更新する.
- (3) 研究室内の 16 か所のテストポイントで Wi-Fi 信号強度を計測し, 上記で更新したモデルによって位置推定を行い, 推定誤差を測定する.

トレーニングポイントとテストポイントの位置は図 5 のようになっている.

位置推定は提案手法と 3.4 節で説明したベクトルを用いた距離計算を基にした  $k$  近傍法 ( $k$ NN:  $k$ -Nearest Neighbor algorithm) によって行った ( $k = 3$ ). 提案手法の有効性を示すため, 以下の 3 つのシナリオで位置推定精度を評価した.

シナリオ 1 得られたセンサデータを何も手を加えずに用いた場合

シナリオ 2 15 日目にフロア内のある 1 つのアクセスポイントからの Wi-Fi 信号を仮想的に取り除いた場合

シナリオ 3 外壁への工事等で, 信号の透過度が低下した場合を想定し, 15 日目以降, フロア外のアクセスポイントからの Wi-Fi 信号を仮想的に平均 15dBm 減衰させた場合 (実際の観測と既存研究 [17], [18] を基に 15dBm と設定した)

## 4.2 結果: シナリオ 1 – 環境変化なし

### 4.2.1 提案手法の評価

$k$  近傍法と提案手法による位置推定精度の推移を図 6 に示す. 提案手法による位置推定の精度は初期の段階では不安定だったが, データが十分に収集された後では, 安定して高い精度で位置推定が行えている. 具体的には, 提案手法の 10 日目以降の平均推定誤差は  $2.08m$  であった. これは  $k$  近傍法による位置推定精度 (平均推定誤差  $2.69m$ ) を大きく上回っている.

提案手法による位置推定精度とデータベースに蓄積されたスキャンデータ数の推移を図 7 に示す. スキャンデータ数が 1000 近くになると提案手法の位置推定精度は安定していることが分かる. 提案手法では歩行データを用いるこ




図 7 Wi-Fi スキャン数と提案手法による位置推定精度の推移  
Fig. 7 Transitions of Wi-Fi scans in database and accuracies of our method

とによって環境内に密なトレーニングポイントを自動的に設置することができる. その結果, 位置推定精度が向上したと考えられる.

また, 提案手法で行った PDR の平均推定誤差は  $1.63m$  だった. (実験中に撮影したビデオ映像から計算した.) これは  $k$  近傍法の平均推定誤差よりも大幅に小さく, 提案手法による位置推定精度の向上に十分寄与できるものと考えられる. さらに, PDR によって誤差が無く歩行軌跡の推定が行えた想定した場合, 提案手法の平均推定誤差は  $2.29m$  だった. (実験中に撮影したビデオ映像から正確な歩行軌跡を決定・使用した.) この値は提案手法による平均推定誤差の下限値と考えることができるが, 実際に行った実験における提案手法の平均推定誤差を上回っていた. これは, 携帯端末が Wi-Fi スキャンを記録する時のサンプリングレートを  $1Hz$  としており, スキャンデータのタイムスタンプに平均して  $0.5$  秒程度の誤差が発生するため, それが悪影響を及ぼしているためと考えられる.

### 4.2.2 欠損データへの対処の有効性

ここでは提案手法における欠損データへの対処の有効性を評価する. 提案手法において, 欠損データへの対処を行わず, データベースに蓄積される Wi-Fi スキャンをそのまま用いて  $k$  近傍法を行った場合の位置推定精度の推移も, 図 6 に示している (Wi-Fi スキャン追加). その推定精度は既存の  $k$  近傍法よりも低く, 蓄積された欠損データをそのまま用いるだけでは逆に位置推定の精度を低下させてしまうことが確認された.

### 4.2.3 位置推定モデルの継続的更新の有効性

提案手法によって位置推定モデルを継続的に更新することの有効性を評価するため, 位置推定精度が安定した後 (10 日目以降), 位置推定モデルの更新を中止した. 図 8 にその位置推定精度の推移を示す. この手法の位置推定精度は提案手法に比べて徐々に低下している. これは電波環境が毎日徐々に変化しているために起こるものと考えられる. したがって, 提案手法を用いて位置推定モデルを毎日更新することにより, 安定した位置推定精度を保持できると考えられる.




図 8  $k$  近傍法と 10 日目以降にデータベースの更新を中止する手法による位置推定精度の推移

Fig. 8 Transitions of accuracies related to  $k$ NN and our methods when we stop updating database after the 10th day




図 9  $k$  近傍法と提案手法による位置推定精度の推移 (シナリオ 2)  
 Fig. 9 Transitions of accuracies related to  $k$ NN and our methods when we remove one AP at 15th day

#### 4.3 結果：シナリオ 2 - アクセスポイントの削除

図 9 に 15 日目でフロア内のあるアクセスポイントを仮想的に取り除いた場合の、 $k$  近傍法と提案手法による位置推定精度の推移を示す。 $k$  近傍法による平均推定誤差はアクセスポイントの除去以降で平均して  $3.16m$  であった。これはシナリオ 1 (図 6) の場合と比較して  $0.53m$  悪化していた。一方、提案手法による平均推定誤差はアクセスポイントの除去以降で平均して  $2.31m$  であった。これはシナリオ 1 の場合と比較しても  $0.23m$  の悪化に抑えられていた。この位置推定精度の低下は、 $k$  近傍法と提案手法、どちらにおいても位置推定に利用できる情報量が減少しているため、妥当なものである。しかし、提案手法では  $k$  近傍法と比較して、位置推定精度の低下を抑えられている。これは提案手法ではテストデータ (Wi-Fi スキャン) に含まれていないアクセスポイントを考慮せずに位置推定を行うためと考えられる。

#### 4.4 結果：シナリオ 3 - 信号強度の減衰

図 10 に、15 日目以降に、フロア外のアクセスポイントからの Wi-Fi 信号を仮想的に平均  $15dBm$  減衰させた場合の  $k$  近傍法と提案手法による位置推定精度の推移を示す。ここで、図 10 の“提案手法”では環境変化の検出は行って




図 10  $k$  近傍法と提案手法による位置推定精度の推移 (シナリオ 3)  
 Fig. 10 Transitions of accuracies related to  $k$ NN and our methods when we reduce signal strength after 15th day

いない。減衰後、 $k$  近傍法による平均推定誤差は大きく増加 (約  $0.6m$ ) した。フロア外の定常的に電波が受信できるアクセスポイント数 (5) はフロア内のアクセスポイント数 (17) と比べてかなり少なかったにもかかわらず、大きな影響が見られた。減衰直後は“提案手法”による平均推定誤差も増加したが、新しいデータが歩行者によって徐々にアップロードされるにつれて、位置推定精度も徐々に向上していった。

図 10 の“提案手法 (シグモイド関数)”では環境変化の検出を行い、シグモイド関数によって信号強度データの重みを変化させている。複数のアクセスポイントからの信号を減衰させたにも関わらず、“提案手法 (シグモイド関数)”による平均推定誤差は、“提案手法”と比べて、減衰直後もあまり増加していない。これは環境変化を検出することにより、変化に応じてアクセスポイントからの信号強度の特徴を学習したためと考える。また、仮想的に減衰させたアクセスポイント以外にも、強度が変化したアクセスポイントを検出することができていた。例えば、実験期間中にフロア内の金属製の棚の位置が変わったため、その棚の付近に存在するアクセスポイントからの信号強度が約  $25dBm$  減衰していたが、提案手法ではその変化も検出できていた。

図 10 の“提案手法 (忘却関数)”では忘却関数によって信号強度データの重みを変化させた。この手法も信号強度の減衰による位置推定精度の減少を軽減していたが、環境変化が起こった日の位置推定精度は“提案手法 (シグモイド関数)”よりも劣っていた。これは“提案手法 (シグモイド関数)”が環境変化以前の観測データの重みを、図 3 のように極端に小さくするためであると考えられる。一方、“提案手法 (忘却関数)”では忘却係数  $\lambda$  に大きな値 ( $\lambda = 0.98$ ) を用いることによって、信号強度が徐々に変化した場合でも対応できるように設計している。しかし、図 10 に示す通りあまり効果が表れていないように見える。この手法では新しい Wi-Fi スキャンが次々とデータベースにアップロードされ、位置推定モデルのパラメータも環境変化にしたがっ

て徐々に更新される。そのため、忘却関数の効果が大きくは表れなかったと考える。

## 5. おわりに

本研究では、ユーザの所持する携帯端末に搭載されたさまざまなセンサによって Wi-Fi 位置推定モデルを自動で更新する手法を提案した。既存の位置推定手法である Wi-Fi フィンガープリンティングでは環境の変化や Wi-Fi アクセスポイントの移動や消滅などが起こると正しく位置推定を行えないという問題がある。そこで提案手法では、ある環境内で長時間過ごしているユーザのセンサデータによって歩行移動軌跡を推定し、同時に Wi-Fi 信号強度を計測することにより、連続的に Wi-Fi 信号強度と座標のペアを自動で作成する。そして、作成されたデータを用いてモデルを定期的に自動で更新することで、電波環境の変化に対応する。

評価実験では、提案手法によって、(1) 複数のアクセスポイントからの信号強度が徐々に変化した場合、(2) 複数のアクセスポイントが取り除かれた場合、(3) 複数のアクセスポイントからの信号強度が突然変化した場合、の3種類の電波環境の変化に対応できることが確認できた。

## 参考文献

- [1] Jiang, Y., Pan, X., Li, K., Lv, Q., Dick, R. P., Hannigan, M. and Shang, L.: ARIEL: Automatic wi-fi based room fingerprinting for indoor localization, *Proc. of the 2012 ACM Conference on Ubiquitous Computing (UbiComp '12)*, pp. 441–450 (2012).
- [2] Pulkkinen, T., Roos, T. and Myllymäki, P.: Semi-supervised Learning for WLAN Positioning, *Proc. of the 21st International Conference on Artificial Neural Networks and Machine Learning (ICANN 2011)*, Vol. 6791, pp. 355–362 (2011).
- [3] Chai, X. and Yang, Q.: Reducing the calibration effort for location estimation using unlabeled samples, *Proc. of Third IEEE International Conference on Pervasive Computing and Communications (PerCom 2005)*, pp. 95–104 (2005).
- [4] Wang, H., Sen, S., Elgohary, A., Farid, M., Youssef, M. and Choudhury, R. R.: Unsupervised indoor localization, *Proc. of the 10th International Conference on Mobile Systems, Applications and Services (MobiSys '12)*, pp. 197–210 (2012).
- [5] Chen, S., Chen, Y. and Trappe, W.: Exploiting environmental properties for wireless localization and location aware applications, *Proc. of Sixth Annual IEEE International Conference on Pervasive Computing and Communications (PerCom 2008)*, pp. 90–99 (2008).
- [6] 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, *Proc. of the 8th ACM International Symposium on Modeling, Analysis and Simulation of Wireless and Mobile Systems (MSWiM '05)*, pp. 118–125 (2005).
- [7] Yin, J., Yang, Q. and Ni, L.: Adaptive temporal radio maps for indoor location estimation, *Proc. of Third IEEE International Conference on Pervasive Computing and Communications (PerCom 2005)*, pp. 85–94 (2005).
- [8] Pan, S. J., Kwok, J. T., Yang, Q. and Pan, J. J.: Adaptive localization in a dynamic WiFi environment through multi-view learning, *Proc. of the 22nd National Conference on Artificial Intelligence (AAAI '07)*, Vol. 2, pp. 1108–1113 (2007).
- [9] Bao, L. and Intille, S.: Activity Recognition from User-Annotated Acceleration Data, *Proc. of Second International Conference on Pervasive Computing (PerCom 2004)*, pp. 1–17 (2004).
- [10] Maekawa, T. and Watanabe, S.: Unsupervised Activity Recognition with User's Physical Characteristics Data, *Proc. of the 15th Annual International Symposium on Wearable Computers (ISWC 2011)*, pp. 89–96 (2011).
- [11] Woodman, O. and Harle, R.: Pedestrian localisation for indoor environments, *Proc. of the 10th International Conference on Ubiquitous Computing (UbiComp '08)*, pp. 114–123 (2008).
- [12] Gafurov, D., Helkala, K. and Söndrol, T.: Biometric gait authentication using accelerometer sensor, Vol. 1, No. 7, pp. 51–59 (2006).
- [13] Pelleg, D., Moore, A. et al.: X-means: Extending k-means with efficient estimation of the number of clusters, *Proc. of the Seventeenth International Conference on Machine Learning (ICML 2000)*, pp. 727–734 (2000).
- [14] 山野貴一郎, 伊藤克亘: 1ZD-8 音響ライフログへのアノテーションのための話者と場所の自動分類 (位置・コンテキスト推定 (1), 学生セッション, ネットワーク, 情報処理学会創立 50 周年記念), Vol. 72, No. 3, 一般社団法人情報処理学会 (2010).
- [15] Chen, S. and Gopalakrishnan, P.: Speaker, Environment And Channel Change Detection And Clustering Via The Bayesian Information Criterion, *Proc. of the DARPA Broadcast News Transcription and Understanding Workshop*, pp. 127–132 (1998).
- [16] Markovitch, S. and Scott, P. D.: The role of forgetting in learning, *Proc. of the Fifth International Conference on Machine Learning (ICML 1988)*, pp. 459–465 (1988).
- [17] Stein, J. C.: Indoor radio WLAN performance part II: Range performance in a dense office environment, *Inter-sil Corporation* (1998).
- [18] Jardosh, A. P., Belding-Royer, E. M., Almeroth, K. C. and Suri, S.: Real-world environment models for mobile network evaluation, Vol. 23, pp. 622–632 (2005).