

電波強度変化を考慮した Wi-Fi屋内位置推定モデルの低コストな構築手法

大野 宇宙 前川 卓也

概要: Wi-Fi の普及により, Wi-Fi 信号強度を用いた屋内位置推定技術がこれまでに多く研究されてきた. 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, 位置推定モデルの学習のために各参照点における電波強度情報の収集を必要とする. しかし, その収集コストを抑えるため各参照点での電波強度情報収集を比較的短期間で行うことから, 時間的に変化する Wi-Fi 信号強度の特性に対応できないという問題があった. 各参照点での電波情報の取得を長期的に行い, その電波強度変化を学習することでこの問題は解決できると考えられるが, そのコストは大きい. そこで本研究では, 特定の少数の参照点でのみ長期的に電波強度情報を収集し, それにより得られた電波変化の統計的情報を, 長期的に電波強度情報を取得していない参照点における電波強度変化のモデル化に用いることで, 収集コストを抑えた屋内位置推定モデルの構築を行う.

キーワード: Wi-Fi フィンガープリンティング, 屋内位置推定, MLLR 適応

Low cost Wi-Fi Indoor Positioning Model for change of scan data

ONO HIROSHI MAEKAWA TAKUYA

Abstract: This paper proposes a new method for constructing a low cost Wi-Fi indoor positioning model. Generally, a Wi-Fi indoor positioning model is built by using scan data observed at each reference point in a short period. However, we cannot deal well with unstable signal strength from Wi-Fi APs when we use such scan data as training data. In addition, we cannot distinguish stable Wi-Fi APs from unstable APs (e.g., mobile APs), which are inappropriate for using as beacon, with such scan data. When an indoor positioning model is built by using scan data at each reference point in a long period, we need not to care about the problems. However, the approach requires a large cost as regards collecting training scan data. In this work, we collect scan data in a long period at only few reference points and complement signal strength models of the other reference points with short-term scan data by utilizing the long-term scan data. That is, a signal strength model of a reference point with long-term scan data is adapted to a model of a reference point with short-term scan data. In addition, we try to distinguish stable Wi-Fi APs with unstable APs from the long-term scan data.

Keywords: Wi-Fi fingerprinting, indoor positioning, MLLR adaptation

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. また, 最も一般的な位置推定手法である GPS が衛星からの電波を利用しており, その電波が屋根などによって遮断される屋内環境では用いることができないということから, Wi-Fi 電波情報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

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, Japan

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場所(参照点)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、参照点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電波情報を計測し位置推定モデルを学習する手法では、その構築コストを抑えるため各参照点での電波情報収集を比較的短期間で行うことが一般的である。しかし、短期間の電波情報収集には以下のような問題が存在する。

- (1) ある Wi-Fi AP から取得される Wi-Fi 電波強度は屋内の同じ位置であったとしても、気温や湿度などの時間的な受信環境の変化によりある程度ばらつきが生じる。短期間の電波情報収集ではそのようなばらつきのある電波強度の分布を正しく推定できない。
- (2) 使用者と共に移動するモバイル AP や、電波強度取得場所から遠方にある安定的に電波を観測できない AP は位置推定に用いるべきではない。しかし、短期間の電波情報の収集ではそのような不安定な AP を特定することができない。そのような不安定な AP を位置推定に用いた場合、推定精度の低下が発生する。

このような問題に対処するためには、全ての参照点において長期的に電波情報を収集することが考えられるが、そのコストは大きい。

そこで本研究では、特定の少数の参照点でのみ長期的に電波情報を収集し、それにより得られた電波変化の統計的情報を、長期的に電波情報を収集していない参照点での電波強度変化のモデル化に用いることで、収集コストを抑えた屋内位置推定モデルの構築を行う。前述の2つの問題に対して、長期的に収集した電波情報を用いて以下のように対応する。

- (1) 長期的に電波情報収集を行った結果から安定して観測できる AP であるかの判別を行い、その AP のみを位置推定に用いることで、不安定な AP による推定精度の低下を抑える。
- (2) 長期間収集した電波強度から学習された位置推定モデルは時間的な電波強度変化に対応している。このモデルを長期的に電波情報収集を行っていない各参照点でのモデルに適用させることで、各参照点のモデルも時間的な電波強度変化に対応させる。

2章では関連研究を紹介する。3章において本研究で提案する手法を説明し、4章では実験によって提案手法の有

効性を示す。5章において本研究のまとめを行う。

2. 関連研究

2.1 フィンガープリンティングによる位置推定

フィンガープリンティングは事前いくつかの参照点で計測した Wi-Fi の電波強度の特徴を表すフィンガープリントをデータベースに保存しておき、そのデータベースを用いて位置推定を行う [1]。一般的にフィンガープリンティングによる位置推定は、オフラインで行われる訓練フェーズとオンラインで行われる推定フェーズに分けられる。訓練フェーズでは、屋内環境の参照点において、AP からの Wi-Fi の受信電波強度情報を収集する。そして、その情報を用いて携帯端末がどの参照点にいるのかを決定する分類器を学習する。分類器には決定木や Naive Bayes、SVM、k 近傍法 (kNN) などの様々なモデルが用いられる [2]。各参照点ごとに受信電波強度の特徴をモデル化し、その参照点の位置座標とともにデータベースに保存する。そして推定フェーズでは、座標が未知のテストポイントにおいて Wi-Fi の受信電波強度を計測し、そのデータをサーバあるいはハブの携帯端末に送信する。サーバではテストポイントにおける受信電波強度のデータとデータベース内のモデルとを比較し、参照点の座標を用いてテストポイントの位置座標を計算する。また、フィンガープリンティング位置推定において用いる適切な AP を自動的に発見する研究も行われている。Nishio ら [3] は、単純に各 AP の観測頻度に閾値を用い不適切な AP を検出するのではなく、各 AP に対して観測頻度が閾値以下になる最長の観測期間の長さによって観測頻度に重みづけをすることで、一時的にオンオフの変化する不適切な AP の検出を行っている。

2.2 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 [4] 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 [5] 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 [6] 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 [7] 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，これらの研究では長期的な Wi-Fi 電波状況の変化への対応は実現できていない．

2.3 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 [8] 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，騒音などの環境要素を利用している．Y.C. Chen ら [9] 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 [10] 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 [11] は，日々変化する Wi-Fi 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．

しかしながら，これらの研究ではセンサネットワークなど追加のシステムを必要とする．

2.4 モデル適応に関する研究

モバイル・ユビキタスコンピューティングの研究分野において，モデル適応は限られた適応データしか得られない場合でも有効な適応手法であると考えられ，幅広く研究がなされている．例えば，行動認識のタスクでは，Ohmura らは，maximum-likelihood linear regression (MLLR) や maximum a posteriori (MAP) 適応 [12], [13] を用いて，エンドユーザの少量のセンサデータだけでエンドユーザに適応した行動モデルを構築している [14] ．

3. 提案手法

3.1 提案手法の概要

提案手法では，第 1 章でも述べたように，特定の少数の参照点でのみ長期的に電波情報を収集し，それにより得られた電波変化の統計的情報を，長期的に電波情報を収集していない参照点での電波強度変化のモデル化に用いることで，収集コストを抑えた屋内位置推定モデルの構築を行う．図 1 に，提案手法の概要を示す．ただし，長期間データを取得した参照点を長期参照点とし，短期間みのデータ収集を行う通常の参照点を短期参照点とする．また，短

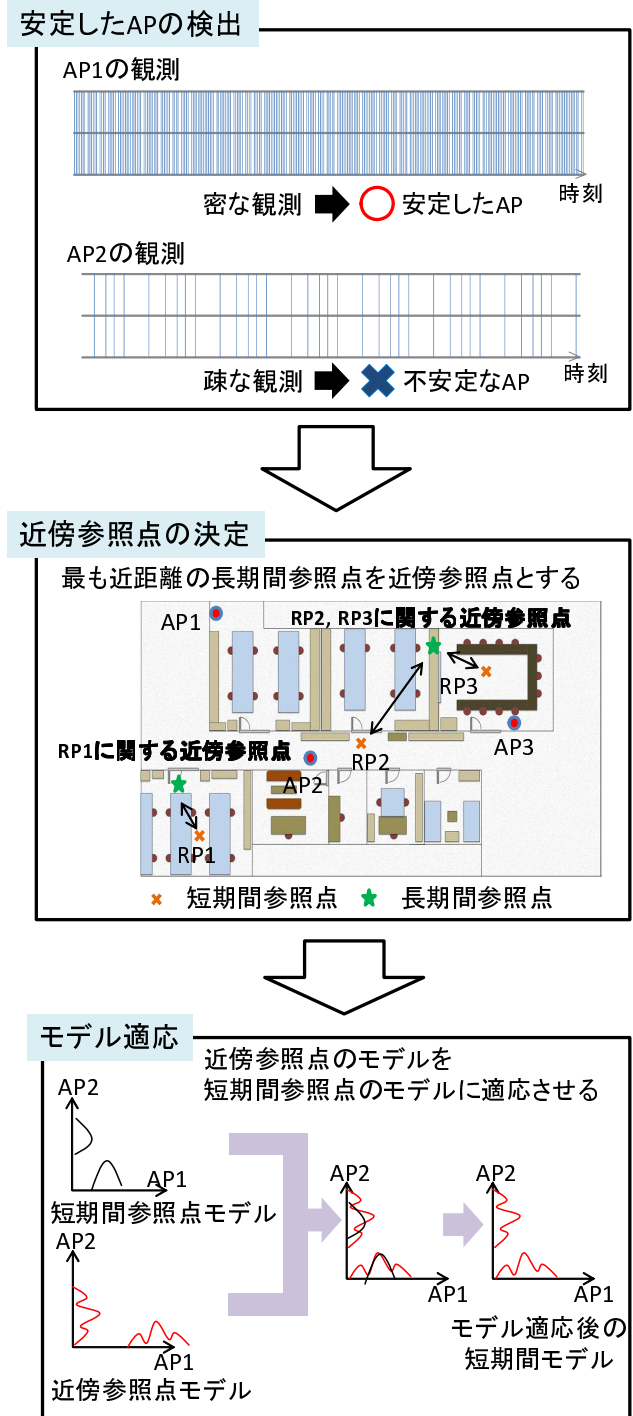


図 1 提案手法の概要

Fig. 1 Outline of proposed method

期参照点に対し最も距離の近い長期参照点を近傍参照点とする．

位置推定に用いる AP に関して，使用者とともに移動するモバイル AP や，電波強度取得場所から遠方にある安定的に電波を観測できない AP を位置推定に用いると推定精度の低下が発生してしまう．そこで，まず長期的に収集した電波変化の統計的情報を用いて，位置推定に用いることのできる安定した AP の検出を行う．以降のモデルの学習，

位置推定は安定した AP のみを用いて行う。各短期参照点に関して、近傍参照点を検出し、その近傍参照点でのモデルを短期参照点にモデル適応させることを考える。長期間電波情報を収集した参照点においては、そのデータを用いることで、気温や湿度などの時間的な電波環境の変化により発生する電波強度のばらつきに対応したモデルを学習できる。このモデルを長期的に電波情報を収集していない参照点でのモデルにモデル適応させることで、そのような参照点でも電波強度のばらつきに対応したモデルを学習できる。以下にその手順の詳細を説明する。

3.2 安定した AP の検出

特定の少数の参照点で長期的に収集した電波情報を用いて安定して観測される AP の検出を行う。具体的には、下の式により計算される AP の観測頻度 F_i が閾値よりも大きい AP を安定した AP と見なす。

$$F_i = \frac{N_i}{N}$$

ただし、 N は長期的に観測を行ったある参照点での全ての電波情報の観測数であり、 N_i は i 番目の AP を含む電波情報の観測回数である。長期的に観測した参照点の全てにおいて、安定した AP の検出を行い、いずれかの参照点で安定した AP であると判断されたものを以降のモデルの学習、位置推定に用いる。

3.3 近傍参照点の決定

短期間しか電波情報を収集していない参照点でのモデルに関して、最も近い距離にある長期間電波情報を収集した点でのモデルを対応付ける。近い距離にある場所では観測される電波情報も類似しているため、このように対応付けを行う。

3.4 モデル適応

図 2 に、ある AP に関して長期的に同じ位置で電波情報の収集を行った観測結果から作成した電波強度ごとの観測頻度のヒストグラムを示す。図 2 に示すように、ある Wi-Fi AP から取得される Wi-Fi 電波強度は屋内の同じ位置で観測されたとしても、気温や湿度などの時間的な受信環境の変化によりある程度ばらつきが生じる [8]。参照点での短期間の電波情報収集ではそのようなばらつきのある電波強度の分布を正しく推定できない。この問題に対応するためにまず、長期的に収集した電波強度情報全てを用いて位置推定モデルを学習する。この位置推定モデルは長期的に収集された電波情報を用いるため、ばらつきのある電波強度の情報を学習することができると考える。このモデルを短期間の電波情報収集しか行っておらず、電波強度のばらつきに対応できていない参照点でのモデルに適応させることで、そのような参照点でのモデルを電波強度のばら




図 2 電波強度のヒストグラム
 Fig. 2 Histogram of signal strength

つきに対応させる。図 2 に示すように、長期的に観測した電波強度の頻度の分布は複雑であるため、単純な正規分布などではモデル化できない。本研究では、複数の正規分布の重ね合わせ混合正規分布:GMM により長期参照点の分布を表現する。GMM のパラメータの学習には、教師なし最尤学習である、EM アルゴリズムを用いる。EM アルゴリズムとは Expectation Step(E ステップ) と Maximization Step(M ステップ) の反復により、尤度関数の期待値の最大化を行うアルゴリズムである。GMM によって、電波強度のデータ x の参照点 k に対する尤度は以下の式で求められる。

$$LD_k(x) = \sum_{i=1}^M \pi_i \mathcal{N}(x | \mu_i, \Sigma_i)$$

ここで M は GMM に含まれる正規分布の数、 π_i は i 番目の正規分布の混合係数、 μ_i と Σ_i は i 番目の正規分布の平均ベクトルと分散共分散行列である。

以降では具体的なモデル適応の手順を説明する。各短期参照点に関して、対応付けられた近傍参照点でのモデルを適応させる。本研究では、GMM 内のガウス分布の平均を線形変換する MLLR 適応を行う。すなわち、近傍参照点でのモデル (GMM) の出力分布を短期参照点でのデータの分布に合うようにシフトする。適応された分布の平均は以下のようにあらわされる。

$$\hat{\mu} = A\mu + b$$

ここで、 μ は近傍参照点でのモデルの分布の平均ベクトル、 A は $k \times k$ の変換行列、 k は AP の数、 b はバイアスペクトルである。ただし、ある参照点の電波強度を異なる参照点の電波強度に適応する際、異なる AP 間の信号強度に相関はないと考えられるため、 A を単位行列とし、 b のみを用いて適応を行う。また、本研究では簡略化のために、以下の式のように各短期参照点モデル (正規分布) の平均に、対応付けられた近傍参照点モデルの混合係数最大の正規分

布の平均が一致するように線形変換を行う。

$$\hat{\mu}_i = \mu_i - (\mu_{MAX\pi_i} - \tilde{\mu}_{MAX\pi_i})$$

ただし、 μ_i は近傍参照点モデルの i 番目の AP に対する平均、 $\mu_{MAX\pi_i}$ は近傍参照点モデルの混合係数最大となる正規分布の i 番目の AP に対する平均、 $\tilde{\mu}_{MAX\pi_i}$ は短期参照点モデルの i 番目の AP に対する平均である。上式により、近傍参照点でのモデルを短期参照点でのモデルに適應させ、電波強度の時間的なばらつきに対応させる。

3.5 位置推定

既存のフィンガープリンティング技術を基に、端末の位置を推定する。屋内環境の参照点において、アクセスポイントからの Wi-Fi の受信信号強度情報を収集し、混合正規分布 (GMM) を基にした kNN を分類器として用いる。GMM を用いて、各参照点ごとに受信信号強度の特徴をモデル化し、その参照点の位置座標とともにデータベースに保存する。

そして位置推定の際には、座標が未知のテストポイントにおいて Wi-Fi の電波強度を計測し、その電波強度のデータとデータベース内のモデルとを比較し、GMM 尤度をそれぞれの参照点 (GMM) に対して計算する。そして、データベース内の参照点を尤度の降順にソートし、尤度が高いトップ k の参照点の座標を用いてテストポイントの位置座標を計算する。

$$Pos(x) = \frac{\sum_{i=1}^k LD_i(x) \times Pos_i}{\sum_{i=1}^k LD_i(x)} \quad (1)$$

計算の際には、式 1 のように、 k 個の参照点の尤度を重みとした重み付き平均を用いる。ただし、 x は受信信号データ、 $LD_i(x)$ は x の参照点 i に対する尤度、 Pos_i は参照点 i の座標である。さらに、Wi-Fi 信号の揺らぎによる計測誤差を低減するため、本研究では短時間に複数回式 1 を用いて位置の推定を行い (実装では 1 秒おきに 5 回)、その平均座標を最終的な推定位置とする。

4. 評価実験

提案手法の有効性を示すため評価実験を行った。まず、実験環境と行った実験に関して説明する。そして、それぞれの実験での結果を示し、それらについて考察を行う。

4.1 実験環境、実験内容

評価実験では、4 台の携帯端末 Google Nexus One (いずれも HTC 製のスマートフォン) を実験データ収集の際のクライアントとして使用した。Nexus One は Wi-Fi センサを搭載しており、OS として Android を使用している。1 台を参照点での短期間のデータ収集および評価用テストデータの収集に用い、残りの 3 台を長期間のデータ収集に

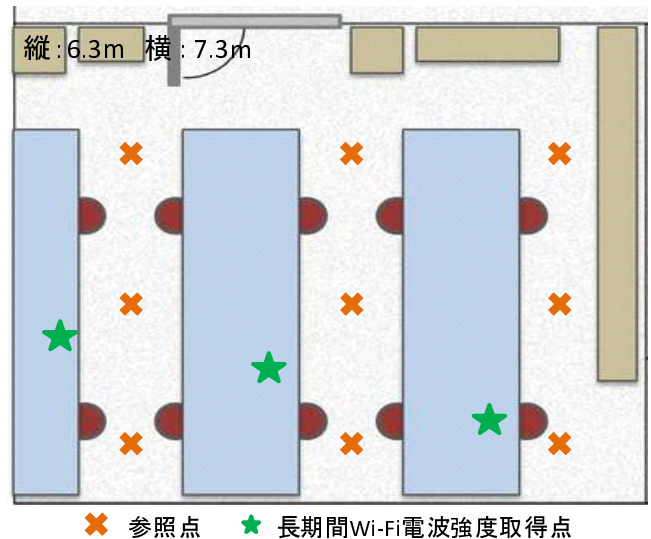


図 3 実験環境の見取り図

Fig. 3 Floor plan of experimental environment

用いた。図 3 に実験環境の見取り図を示す。この環境内に 9 ヶ所の参照点を設定した。参照点の詳細な位置も図 3 に示す。各参照点では、Nexus One を使用して環境内の全アクセスポイントからの Wi-Fi の受信信号強度データを 1 分間ずつ収集した (1 秒ごとに付近のアクセスポイントからの Wi-Fi の電波強度をスキャンした)。この参照点での収集を日を変え、3 回行った。この 3 回分のデータをそれぞれトレーニング用とテスト用に分け、位置推定を行った。3 回分のデータに対して、1 回分をトレーニングに、1 回分をテストデータに用いて、全 6 通りの組み合わせで実験を行った。また、長期間のデータ収集は 3 か所で行った。その詳細な位置も図 3 に示す。長期間のデータは Nexus One を使用して、2 週間分のデータを収集した (1 分ごとに付近のアクセスポイントからの Wi-Fi の電波強度をスキャンした)。

このようにして取得された実験用データを用いて、提案手法の効果を検証する。まず、安定した AP の検出による推定精度の向上を確認するために、観測された全ての AP を使用して位置推定を行った場合や恣意的に使用する AP を選択した場合と比較する。次に、モデル適應により電波強度の時間的なばらつきに対応できるかどうかの確認を行った。

4.2 実験結果:安定した AP の検出

図 4 に実験環境内での、AP の観測頻度のヒストグラムを示す。図 4 に示すように、安定的に観測できない AP が多く見られるため、安定した AP の検出が位置推定に重要であると考えられる。この実験では、観測頻度に対する閾値として 0.5, 0.7, 0.9 を用いて安定した AP の検出を行った。そして、検出された AP のみを利用して、モデル適應を行わずに位置推定を行った。また、手動で実験環境のフロア




図 4 AP の観測頻度のヒストグラム
 Fig. 4 Histogram of observation frequency

内に設置された AP のみを恣意的に用いた場合との比較も行った。各位置推定において、用いた AP 数を表 1 に、平均推定誤差を図 5 に示す。図 5 に示すように、閾値を用いて安定した AP の検出を行った場合、すべての AP を用いた場合に比べて 15cm 程度の推定精度の改善が見られた。また、閾値を厳しく設定することで、より安定した AP のみを利用すると、さらに精度が向上した。また、恣意的に AP を限定した場合、推定精度が低下した。この手法では、利用した AP 数は 8 個であり、閾値を用いて安定した AP を検出した場合と同程度の数であったが、同じフロアに設置された AP を恣意的に選択しても、必ずしも高い精度を得られる保証がないことがわかる。また、上下の階のフロアに存在する AP であったとしても、安定して取得される AP もあることが確認され、安定した AP の検出には観測頻度への閾値を設定することが有効であると考えられる。

4.3 実験結果:モデル適応

次に、閾値により安定した AP を検出した後に、モデル適応を行うことで推定精度が向上するかの確認を行った。それぞれの閾値での場合に関する結果を図 6 に示す。図 6 に示されるように、いずれの場合もモデル適応を行うことで 10cm 程度の推定精度改善が見られた。これにより、長期間のデータから学習されたモデルを、モデル適応することで電波強度の時間的な変化に対応できることが確認できた。全体として、提案手法を用いることで 20cm 以上の精度改善が見られたことから、この提案手法の有効性が示された。

表 1 各手法において利用した AP の数

Table 1 Number of APs used in each method

	全て	閾値 0.5	閾値 0.7	閾値 0.9	フロア内
AP 数	74	11	10	7	8

平均推定誤差(cm)




図 5 実験結果:安定した AP の検出
 Fig. 5 Result of detection of stable APs

平均推定誤差(cm)




図 6 実験結果:モデル適応
 Fig. 6 Result of model adaptation

5. おわりに

本研究では、特定の少数箇所でのみ長期間電波情報を収集し、その情報を利用することで低コストでの電波強度の時間的な変化に対応した屋内位置推定モデルの構築手法を提案した。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、位置推定モデルの学習を短期間の電波情報で行うために、利用する AP に不安定な AP が含まれ、さらには電波強度の時間的な変化にも対応できない。そこで本研究では、特定の少数の参照点でのみ長期的に電波強度情報を収集し、安定した AP を検出するとともに、その情報から学習されたモデルを各参照点でのモデルにモデル適応を行い、位置推定モデルを構築する。

評価実験では、安定した AP の検出による推定精度の改善を確認した後、モデル適応により時間的な電波強度変化に対応し、推定精度が改善することを確認した。全体として、既存手法であるフィンガープリンティングを用いた場合と比較して、30cm 程度の推定精度の改善を確認し、提案手法の有効性を示した。

謝辞

本研究の一部は、研究成果最適展開支援事業（A-STEP）
フィジビリティスタディステージ探索タイプ（課題番
号：AS251Z02124H，研究責任者：前川卓也）の支援によ
り行った。

参考文献

- [1] Kaemarungsi, K.: Modeling of indoor positioning systems based on location fingerprinting (2013).
- [2] Chaudhuri, K., Sanghi, D. and Bhagwat, P.: Location determination of a mobile device using IEEE 802.11b access point signals, *IEEE Wireless Communications & Networking Conference (WCNC)*, pp. 1987–1992 (2003).
- [3] Nishio, N., Fukuzaki, Y. and Azumi, T.: Detecting wi-fi base station behavior inappropriate for positioning method in participatory sensing logs, *UbiComp(Adjunct Publication) 2013*, pp. 665–672 (2013).
- [4] 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).
- [5] 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).
- [6] 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).
- [7] 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).
- [8] 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).
- [9] 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).
- [10] 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).
- [11] 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).
- [12] Gauvain, J. and Lee, C.: Maximum a posteriori estimation for multivariate gaussian mixture observations

- of markov chains, *IEEE Trans. on Speech and Audio Processing*, Vol. 2(2), pp. 291–298 (2002).
- [13] Leggetter, C. and Woodland, P.: Maximum likelihood linear regression for speaker adaptation of continuous density hidden Markov models, *Computer Speech & Language*, Vol. 9(2), pp. 171–185 (1995).
 - [14] Ohmura, R., Hashida, N. and Imai, M.: Preliminary evaluation of personal adaptation techniques in accelerometerbased activity recognition, *In Int'l Symo. on Wearable Computers: Late Breaking Results* (2009).