

電波強度変化に頑健な WiFi 屋内位置推定のための 他環境長期電波強度モデルの適応手法

足立 樹哉^{1,a)} 大野 宇宙^{1,b)} Joseph Korpela^{1,c)} 前川 卓也^{1,d)}

概要 :

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多数の参照点において電波強度情報を収集する必要があるため、各参照点における電波強度の収集は短期間で行われる。そのため、電波強度の時間的なゆらぎにより、位置推定精度が低下する。この問題に対応するために推定環境の参照点ごとに長期間電波情報の取得を行うことが考えられるが、位置推定システムの導入コストを増大させてしまう。そこで本研究では、推定環境以外の環境で取得した長期間電波強度情報を利用して、対象とする環境において新たに長期間電波情報を取得することなく電波強度の長期的なゆらぎに対応した位置推定モデルを構築する手法を提案する。具体的には、対象とする環境の各参照点において、短期間のみ電波強度情報を取得し、その情報と他環境の長期電波強度情報を比較し、電波状況が似ているであろう長期電波強度情報を発見する。そして、その長期電波強度情報を利用して、対象とする環境の擬似的な長期電波強度モデルを構築する。評価実験では複数の環境で長期的に Wi-Fi 電波情報の取得を行い、提案手法を用いて位置推定を行うことで、その有効性を検証した。その結果、提案手法を用いて擬似的な長期モデルを構築することで、長期間電波情報を利用しない手法と比べて位置推定精度が改善されることを確認した。

1. はじめに

近年、自動車や携帯電話、スマートフォンを用いた位置情報提供サービスは必要不可欠なものとなりつつある。例えば、目的地を入力することで、現在いる位置を計測し、その場所から目的地までのルートを案内するナビゲーションサービスが提供されている。このような、屋外における位置情報の提供は主に Global Positioning System (GPS) により行われている。その精度と利便性の高さから屋外における位置情報サービスは広く普及しているが、GPS によって位置情報の提供を行う場合、GPS 衛星からの電波を利用する必要があるため、屋内や地下、超高層ビル街において位置情報を提供することは困難である。

そこで屋内位置推定に関する研究が近年多く行われており、特に、一般的に普及している Wi-Fi を用いた屋内位置推定の研究が活発である。その中でも、最も実現性の高い屋内位置推定の手法に Wi-Fi 電波強度のフィンガー

プリンティングを用いる手法がある。Wi-Fi フィンガープリンティングでは事前に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参照点の位置情報とともに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。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、電波受信端末を携帯するユーザがその現在地の Wi-Fi 受信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。Wi-Fi の電波を用いるこの手法は、第三者が設置している AP を利用するため、超音波などを利用する場合と異なり、新たにインフラを構築する必要がない。また、スマートフォンが急速に普及していることから、サービスの利用者はスマートフォンを電波の受信端末として用いることが可能なため、利用が容易であるというメリットが存在する。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

¹ 大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University

a) adachi.tatsuya@ist.osaka-u.ac

b) oono.hiroshi@ist.osaka-u.ac.jp

c) joseph.korpela@ist.osaka-u.ac.jp

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

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、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ゆらぎが生じる。短期間に収集された電波情報のみではそのようなゆらぎのある電波強度の分布を正しく推定できない。この問題に対処するためには、すべての参照点で長期間の電波情報収集を行う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、推定環境以外の環境において収集した長期間電波強度情報をモデル化に用いることで、時間的な電波強度のゆらぎに対応し、収集コストを抑えた屋内位置推定モデルの構築を行う。

本稿では、第 2 章で関連研究を紹介する。第 3 章において本研究で提案する手法を説明し、第 4 章では実験によって提案手法の有効性を示す。第 5 章において本研究のまとめを行う。

2. 関連研究

2.1 Wi-Fi 電波を用いた位置推定手法

Wi-Fi 電波を用いた屋内位置推定手法では到来方向 (TOA : Time of Arrival), 到来時間差 (TODA : Time Difference of Arrival) による位置推定, 到来方向 (AOA : Angle of Arrival) による位置推定, 受信電波強度 (RSSI : Received Signal Strength Indication) による位置推定がそれぞれ提案されている。また、これらを組み合わせた位置推定手法も提案されている [6], [15]。しかし、TOA, TODA による位置推定には、一般的に各 AP 間での時間同期機能が実装されていないことや電波の干渉や反射の影響により精度が大幅に低下するという問題がある。AOA による位置推定では、電波の到達角度が厳密に検出できれば位置推定精度も高くなるが、そのようなセンサが新たに必要となる。また、RSSI を用いた位置推定において、AP からの距離と電波強度減衰の関係から位置推定を行う場合、各 AP の位置を把握することが難しいことや電波強度と距離との関係が環境によって異なるといった問題がある。そこで、近年の Wi-Fi 電波を用いた位置推定では RSSI によるフィンガープリンティングをもとに位置推定が行われている。一般的にフィンガープリントによる位置推定は、オフラインで行われる学習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。学習フェーズでは、屋内環境の複数の参照点において、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位置情報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。

2.2 電波のゆらぎに対応した屋内位置推定に関する研究

フィンガープリンティングを用いた際の受信環境の変化に伴う時間的なゆらぎが存在するため精度が低下するという問題への対応に関する研究を以下で紹介する。S. Chen らは、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 [3]。Y.C. Chen らも、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 [4]。Yin らは、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 電波強度とユーザの端末によって受信した Wi-Fi 電波強度の関係を、回帰分析によって予測する手法を提案している [16]。Pan らは、日々変化する Wi-Fi 電波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、短期間では電波強度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 [12]。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ためコストが大きい。

2.3 位置情報データベースの構築の効率化に関する研究

低コストで位置情報データベースを作成するために、位置情報データベースの構築の効率化に関する研究について紹介する。Jiang らは、生活の中で得られた Wi-Fi 電波強度情報を、加速度データを用いてクラスタリングし、部屋ごとの電波強度のモデルを自動的に学習している [8]。Pulkkinen らは、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 Wi-Fi スキャンデータから、非線形画像を用いて密な Wi-Fi 電波強度マップを作成している [13]。Chai らは、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 Wi-Fi 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 [1]。Wang らは、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 [14]。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 電波強度のゆらぎへの対応は実現できていない．

3. 提案手法

3.1 提案手法の概要

提案手法では，推定環境の参照点で収集した短期間の電波強度情報（短期間データ）に対して，推定環境以外の環境で収集した長期間の電波強度情報（長期間データ）を適応させることによって，推定環境で新たに長期間データの収集を行うことなく時間的な電波強度のゆらぎに対応したモデルを構築する．ただし本研究では，短期間データは計測端末を手に持ち，長期間データは計測端末を設置して収集することを想定する．提案手法の概要を図 1 に示す．

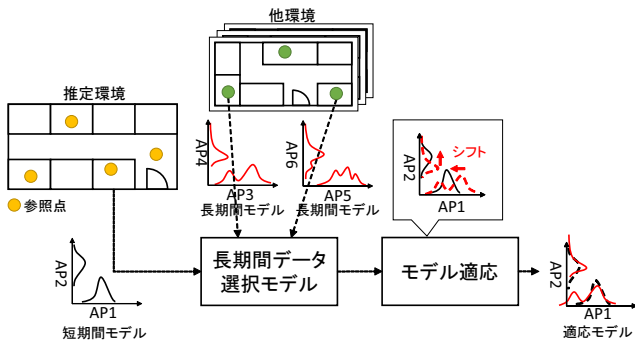


図 1 提案手法の概要 (それぞれのモデルは各 AP 毎の電波強度の分布)

まず，ランキング学習により構築された長期間データ選択モデルを用いて，推定環境の短期間データに適応させる他環境長期間データを選択する．その後，選択した長期間データから学習した長期間モデルを推定環境の短期間データから学習したモデルに対してモデル適応を行うことで，電波の時間的なゆらぎに対応した位置推定モデルを構築する．

3.2 長期間データと短期間データの比較検証

短期間データからそのモデル化に用いる適応元長期間データを適切に選択するために，それらの関係について検証する．複数の他環境で収集した AP 毎の長期間データを時分割し，擬似的な短期間データ（仮短期間データ）を生成し，仮短期間データとその抽出元の長期間データを比較した．図 2 に長期間データと仮短期間データの平均を比較したグラフを，図 3 に仮短期データの分散値上位 k % に含まれる仮短期データの生成元の長期データが長期データの分散値上位 i % に含まれる割合を表したグラフを，図 4 に長期間データから生成した混合正規分布 (GMM) と仮短期

間データの対数尤度と長期間データと仮短期間データから生成した GMM の Cauchy-Schwarz divergence の関係を示す [10]．Cauchy-Schwarz divergence は確率分布の差の大きさを測る尺度である．




図 2 長期間データと仮短期間データの平均値の関係




図 3 仮短期データの分散値上位 k % に含まれる仮短期データの生成元の長期データが長期データの分散値上位 i % に含まれる割合




図 4 長期間データと仮短期間データの対数尤度と Cauchy-Schwarz divergence の関係

図 2 から，平均に関しては長期間データと仮短期データに大きな差異は見当たらなかった．相関係数も 0.971 と高い正の相関関係が見られた．また，分散に関しては図 3 に示すように，長期データの分散値が大きい場合は必ずしも仮短期データの分散値が大きくなるはなかったが，仮短期データの分散値が大きい場合は長期データの分散値も大きかった．さらに，図 4 から，尤度の値が大きいほど Cauchy-Schwarz divergence の値は小さくなっている．すなわち，これらの結果から，電波強度の平均値，分散値およ

び尤度を比較することによって、仮短期間データから抽出元の長期間データを選択することはある程度可能であると考えられる。そのため、ある参照点で取得した短期間データのみから同じ参照点で取得されるであろう長期間データに最も類似するものを他環境の長期間データの中から選択することにもこれらの特徴は有効であると考えられる。

3.3 長期間データのモデル化

図5に、あるAPに関して長期的に同じ位置でデータ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5 電波強度のヒストグラム

図5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ゆらぎが生じる[3]。参照点での短期間の電波強度の収集ではそのようなゆらぎのある電波強度の分布を正しく推定できず、位置推定精度の低下が発生する。この問題に対応するためにまず、他環境で長期的に収集したデータ全てを用いて長期間モデルを学習する。この長期間モデルはAPごとに電波情報をそれぞれ学習しモデル化したものであり、長期的に収集された電波情報を用いるため、ゆらぎ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。一方で、対象とする環境では参照点において短期間の電波情報しか収集しておらず、そのようなゆらぎに対応できていない。本研究では、他環境で得られた長期間データを用いて学習された分布を、短期データに適応させることでゆらぎの問題に対応する。図5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で分布を表現する混合正規分布(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[5]。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では、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。

$$LD_k(x) = \sum_{i=1}^M \pi_i \mathcal{N}(x | \mu_i, \sigma_i^2) \quad (1)$$

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^2 は i 番目の正規分布の平均と分散である。

3.4 長期間データ選択モデルの学習

短期間データから適切な長期間データを選択するモデルを学習する。そのために仮短期間データと長期間データを比較することで尤度および1~4次のモーメントの差と比を計算し、これらを長期間データ選択モデルの学習に用いる特徴ベクトルの要素とする。このとき1つの仮短期間データに対して、その生成元および生成元以外の全ての長期間データとそれぞれ比較して特徴ベクトルを構築する。構築された特徴ベクトルに対し、長期間データが仮短期間データの生成元である場合は「Same」、異なる場合は「Different」とラベルを付与する。

次に、構築した特徴ベクトルから、「Same」のラベルが付けられた特徴ベクトルから「Different」のラベルが付けられた特徴ベクトルを減算したベクトルを正例、「Different」のラベルが付けられた特徴ベクトルから「Same」のラベルが付けられた特徴ベクトルを減算したベクトルを負例としpair-wise Ranking SVMの学習データとする[9], [17]。この学習されたpair-wise Ranking SVMは入力した仮短期間データの生成元と考えられる長期間データを高い順位で出力する。

実際に推定環境で取得した短期間データと全ての他環境長期間データを比較することで、上述の手順で特徴ベクトルを構築し、pair-wise Ranking SVMにより1位と判定された長期間データとその短期間データに適切な長期間データとして選択する。しかし、短期間データと長期間データではWi-Fi電波強度の取得方法が異なるため、短期間データと仮短期間データは同じ位置で収集されたとしてもデータに差異が生じてしまう。そこで、短期間データと仮短期間データの差異を学習するために、あらかじめ、同じ位置でそれぞれの収集方法によりデータを取得し、その差異を補正する線形変換式を、従属変数を仮短期間データの1~4次のモーメント、独立変数を短期間データの1~4次のモーメントとして線形回帰を用いて計算しておく。本研究の評価実験で用いた変換式を以下に示す。

$$avg_{new} = avg_{old} \times 0.9697 + m_{3,old} \times 1.4704 - 5.3042(2)$$

ただし、 avg_{new} は変換後の電波強度の平均であり、 avg_{old} 、 $m_{3,old}$ はそれぞれ変換前の電波強度の平均、歪度である。また、平均以外の要素に関しては、短期間データと仮短期間データとで差異は認められなかったため、線形変換は行わない。

この変換式により短期間データを変換したあと、その変

換した短期間データと他環境長期間データを比較して特徴ベクトルを構築し, pair-wise Ranking SVM により 1 位と判定された長期間データを選択する。

3.5 モデル適応

選択された長期間モデル (GMM) の出力分布を参照点での短期間データの分布に合うようにシフトする。本研究では, 各参照点モデル (正規分布) の平均に, 対応付けられた長期間モデルの混合正規分布の平均が一致するように線形変換を行う。すなわち, 以下の式のように各参照点における短期間モデル (正規分布) の平均に, 長期間データ選択モデルで選択された長期間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 (MLLR 適応) を行う [7], [11]。

$$\hat{\mu} = \mu - (\mu_{MAX\pi} - \tilde{\mu}_{MAX\pi})$$

ただし, μ は選択された長期間モデルの平均, $\mu_{MAX\pi}$ は選択された長期間モデルの混合係数最大となる正規分布の平均, $\tilde{\mu}_{MAX\pi}$ は短期間データの平均である。

上式により, 各参照点での位置推定モデルを電波強度の時間的なゆらぎに対応させる。

3.6 位置推定

既存のフィンガープリンティング技術を基に, 混合正規分布 (GMM) を基にした k 近傍法 (kNN) を分類器として用いる。上述の通り, 各参照点ごとに受信電波強度の特徴は GMM によりモデル化されており, その参照点の位置座標とともに位置情報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位置情報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, 位置情報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。

$$Pos(x) = \frac{\sum_{i=0}^k LD_i(x) \times Pos_i}{\sum_{i=0}^k LD_i(x)} \quad (3)$$

計算の際には, 式 3 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 は受信電波データ, $LD_i(x)$ 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。

4. 評価

4.1 実験データと評価手法

実験環境の見取り図をそれぞれ図 6 に示す。この環境内に環境 1 と環境 2 にはそれぞれ 21 ケ所の参照点を, 環境 3 には 23 ケ所の参照点を設定した。参照点の詳細な位置も

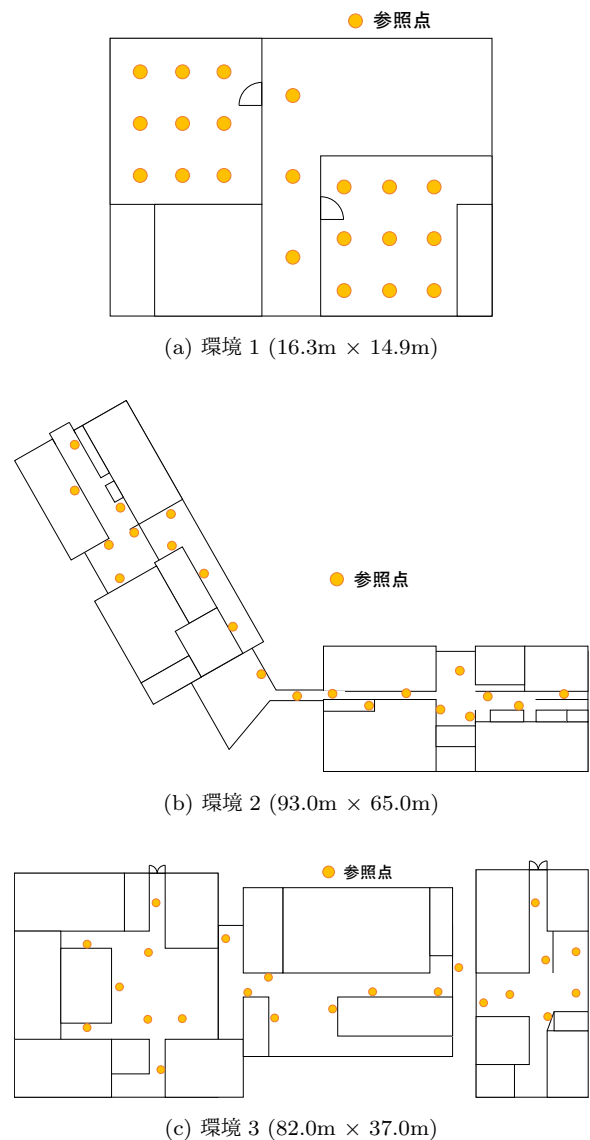


図 6 実験環境の見取り図

それぞれ図 6 に示す。携帯端末 Google Nexus One (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。各参照点では, それぞれの実験環境ごとに同じ Nexus One を使用して環境内の全 AP からの Wi-Fi の受信電波強度を 1 分間ずつ収集した (1 秒ごとに付近の AP からの Wi-Fi の電波強度をスキャンした)。総観測 AP 数は環境 1, 2, 3 でそれぞれ 26, 165, 123 であった。テストデータも参照点と同じ場所, 同じ条件での Wi-Fi 電波強度を数日おきに, 環境 1 においては 27 回, 環境 2 および環境 3 においては 21 回収集したものをを用いた。使用する他環境の長期間データは, 環境 1 において行う位置推定実験では推定環境以外の 7 つの環境の計 11 ケ所の点で, 環境 2 および環境 3 で行う位置推定実験では推定環境以外の 8 つの環境の計 16 ケ所の点で Nexus One を用いて, 2 週間分のデータを収集した (1

分ごとに付近の AP からの Wi-Fi の電波強度をスキャンした). 使用する他環境の長期間データの総 AP 数は, 環境 1 では 63, 環境 2 および環境 3 では 103 であった.

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. 比較手法として, 他環境の長期間データを使用せず推定環境で取得した短期間データのみを使用して位置推定を行う従来手法と, 適応させる他環境の長期間データをランダムに選択して位置推定を行う手法を用意した. これらの手法により位置推定を行い, 推定誤差を測定する. また位置推定は, k 近傍法 ($k = 3$) によって行った.

4.2 位置推定精度の評価

複数の環境において実際に Wi-Fi 電波情報の取得を行い, 提案手法を用いて位置推定を行うことで, その有効性を検証した.

4.2.1 結果・考察

それぞれの実験環境における位置推定精度の結果を図 7 に, 経過日数による位置推定精度の変化を図 8 に示す. 図 7 に示すように, 提案手法を用いて位置推定を行った場合, 長期間データを使用せず短期間データのみを使用する手法を用いて位置推定を行った場合と比べて, 平均推定誤差が, 環境 1 においては約 45cm, 環境 2 においては約 50cm, 環境 3 においては約 26cm の改善が見られた. さらに, 平均推定誤差の推移に関して, 短期間データのみを用いた手法は経過日数に応じて徐々に平均推定誤差が低下している. これは, 日が経過するにつれて電波情報の取得環境が徐々に変化していることが原因であると考えられる. それに対して, 提案手法では 50 日以上経過しても平均推定誤差が短期間データのみを使用した手法と比べて位置推定精度の低下は抑えられている. すなわち, 他環境において長期的に収集したデータを用いて時間的なゆらぎに対応した長期間モデルを学習する提案手法を用いることで, 収集コストを抑えた精度の高い位置推定を行うことができることが確認できた. また, 適応させる長期間データをランダムに選択した場合に比べて, どの実験環境においても位置推定精度に大幅な改善が見られた. この結果から, 提案手法における長期間データの選択方法の有効性を確認できた.

4.3 使用する他環境長期間データの収集期間と位置推定精度の関係

提案手法では, 各参照点の位置推定モデルを電波強度の時間的なゆらぎに対応するために, 長期間収集電波強度から電波強度の時間的なゆらぎに対応した長期間モデルを学習し, そのモデルを各参照点に適応する. ここでは, 電波強度の時間的なゆらぎに対応した長期間モデルの学習に必要な期間を検証する. そのために, 本実験環境において, 2 週間取得した長期間データの中から長期間モデルの学習



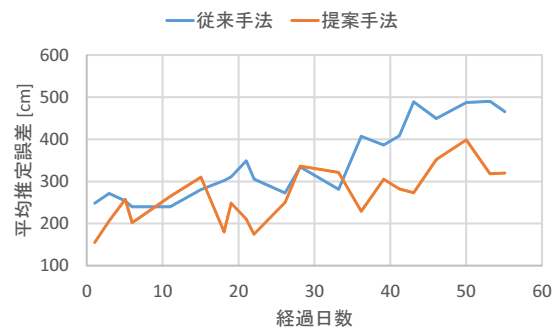



図 7 平均推定誤差



(a) 環境 1



(b) 環境 2



(c) 環境 3

図 8 経過日数による平均推定誤差の推移

に用いるデータ量を 1 日分, 3 日分, 7 日分, 10 日分, 14 日分と変化させ, 位置推定を行った. 従来手法とそれぞれの日数分のデータを用いた提案手法の平均推定誤差を比較


した結果を図9に示す。

4.3.1 実験方法


2週間取得した長期間データの中から長期間モデルの学習に用いるデータ量を1日分, 3日分, 7日分, 10日分, 14日分と変化させ, 位置推定を行った。

4.3.2 結果・考察


各実験環境における結果をそれぞれ図9に示す。環境1に関しては14日分の長期間データを用いたときに最も推定精度が高くなったが, 3日分の長期間データを用いた時の平均推定誤差も14日分の長期間データを用いた時とほぼ同じ推定精度であった。一方, 環境2, 3においては14日分の長期間データを用いた時よりも3日分の長期間データを用いた時のほうが推定精度は高くなった。これは, 長過ぎる期間のデータを用いると収集環境に特化した複雑な形状の電波強度分布となり, 推定環境の参照点における信号強度分布にフィットしなかったためと考えられる。



(a) 環境 1



(b) 環境 2



(c) 環境 3

図9 使用する長期間データの量と位置推定精度の関係

4.4 使用する他環境長期間データの量と位置推定精度の関係

前節の実験では, 環境1においては7つの他環境で取得した計63, 環境2および環境3においては8つの他環境で取得した計103の長期間データを用いた。その結果, 提案手法を用いることで, 位置推定精度の改善を行うことができた。しかし, コスト削減のためには用意する他環境長期間データはより少ないほうが望ましい。そこで, 本実験では, 用いる他環境長期間データの数を減らして位置推定を行うことで, 本実験環境ではどの程度の数の他環境長期間データを必要とするのか検証した。

4.4.1 実験方法

使用する長期間データの数を全体の20%, 40%, 60%, 80%と変化させ, それぞれ前節の実験と同じ条件で提案手法を用いて位置推定を行った。長期間データは3日分と14日分のものを用いた。使用する他環境長期間データをランダムに選択し, 提案手法を用いて位置推定を行うという操作を30回ずつ行い, 平均推定誤差を測定する。

4.4.2 結果・考察

従来手法とそれぞれの日数分のデータを用いた提案手法の平均推定誤差の比較を行った結果を図10に示す。図10に示すように, 環境1, 3においては, 3日分の長期間データを用いた場合に, 全体の20%以上の長期間データを用いても推定誤差がほとんど低下しなくなっている。一方, 環境2においては, 3日分, 14日分ともにすべての長期間データを用いた時に最も推定精度が高くなった。環境1, 2, 3で観測されたAP数はそれぞれ26, 165, 123であり, 環境2のAPの数が最も多い。環境2に関して, 十分な数の長期間モデルを用意できなかったため, 環境2ではすべての長期間モデルを用いた時が最も精度が高くなったと考えられる。

5. おわりに

本研究では, 推定環境以外の環境で取得した長期間電波情報を利用することで, 低コストで電波強度の時間的なゆらぎに対応した屋内位置推定モデルを構築する手法を提案した。

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, 電波強度の時間的なゆらぎに対応できない。そこで本研究では, 他環境で長期的に収集した電波強度情報の中から推定環境の各参照点での電波情報に適切な電波強度情報を選択し, それから構築される電波強度の時間的なゆらぎを学習したモデルを各参照点で短期間に収集された電波強度に適応することで, コストを抑えて電波強度の時間的なゆらぎに対応した位置推定モデルを構築する。

評価実験では, 3つの屋内環境において実際にWi-Fi電波情報の取得を行い, 提案手法を用いて位置推定を行う




図 10 使用する長期間データの量と位置推定精度の関係

ことで、その有効性を検証した。その結果、Wi-Fi フィンガープリンティングを用いた屋内位置推定において、提案手法を用いて各参照点でのモデルを Wi-Fi 電波強度の時間的なゆらぎに対応させることで、高い位置推定精度が達成されることを確認した。

参考文献

[1] 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).

[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] 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).

[4] Chen, Y.-C., Chiang, J.-R., Chu, H.-h., Huang, P. and Tsui, A. W.: Sensor-assisted wi-fi indoor location sys-

tem 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).

[5] Dempster, A. P., Laird, N. M. and Rubin, D. B.: Maximum likelihood from incomplete data via the EM algorithm, *Journal of the royal statistical society. Series B (methodological)*, pp. 1–38 (1977).

[6] Deng, P. and Fan, P.: An aoa assisted toa positioning system, *In Communication Technology Proceedings, 2000*, Vol. 2, IEEE, pp. 1501–1504 (2000).

[7] Gauvain, J.-L. and Lee, C.-H.: Maximum a posteriori estimation for multivariate Gaussian mixture observations of Markov chains, *Speech and audio processing, IEEE transactions on*, Vol. 2, No. 2, pp. 291–298 (1994).

[8] 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).

[9] Joachims, T.: Optimizing search engines using click-through data, *Proceedings of the eighth ACM SIGKDD international conference on Knowledge discovery and data mining*, ACM, pp. 133–142 (2002).

[10] Kampa, K., Hasanbelliu, E. and Principe, J. C.: Closed-form Cauchy-Schwarz PDF divergence for mixture of Gaussians, *Neural Networks (IJCNN), The 2011 International Joint Conference on*, IEEE, pp. 2578–2585 (2011).

[11] Leggetter, C. J. and Woodland, P. C.: Maximum likelihood linear regression for speaker adaptation of continuous density hidden Markov models, *Computer Speech & Language*, Vol. 9, No. 2, pp. 171–185 (1995).

[12] 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).

[13] 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).

[14] 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).

[15] Wann, C. D., Yeh, Y. J. and Hsueh, C. S.: Hybrid tdoa/aoa indoor positioning and tracking using extended kalman filters, *In Vehicular Technology Conference, 2006*, Vol. 3, pp. 1058–1062 (2006).

[16] 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).

[17] 小山聡, マニングクリストファー.D: 異なる例からの素性の組合せを用いたペアサイズ分類器の学習, *人工知能学会論文誌*, Vol. 20, pp. 105–116 (2005).