

歩行中に収集する無線電波強度データに基づく 高精度屋内測位モデル

大森 淳貴^{†1,a)} 須ヶ崎 聖人^{†1,b)} 下坂 正倫^{†1,c)}

概要：無線電波強度を用いた屋内測位は IoT や AR などの分野で需要が高まる一方、測位モデルの構築に要するデータ収集のコストの大きさが問題となっている。そのため歩行中に収集された無線電波強度データの利用によるデータ収集コスト削減を試みる研究も行われていたが、それらは全てのアクセスポイントについてのデータが同時に得られているという仮定に従っていた。しかし、実際はアクセスポイント毎のデータの取得は独立して非同期的に行われており、測位精度の低下の要因となっていた。そこで本論文では歩行中に得られた無線電波強度データの計測時刻の非同期性に着目した、低コストかつ高精度な屋内測位モデルを提案する。具体的には、以下の2つの手順の繰り返しにより実現する。1) アクセスポイント毎に独立に電波強度の空間分布をガウス過程回帰により求め、それに従いデータ取得位置を推定する操作を繰り返し行う。2) 取得位置推定後のデータに対し欠損値をサンプリングにより補完したデータを用いて測位モデルを学習する。また、実際の無線電波強度データを用いた評価により、提案手法の有用性を示した。

キーワード：屋内測位, RSSI, 機械学習

1. 序論

1.1 本研究の背景

IoT や AR の分野などで屋内測位の需要が高まっている [1]。特に Wi-Fi や Bluetooth などの無線電波強度を用いた屋内測位はその精度の高さから注目されている [2][3][4]。

無線電波強度ベースの屋内測位として、Fingerprint と呼ばれる、ある地点において取得された複数のアクセスポイント (AP) からの電波強度 (RSSI, Received Signal Strength Indicator) のベクトルと、取得位置の組を用いる方法が環境情報を使用せず測位が実現出来るという実用性から多く議論されている。Fingerprint を用いた屋内測位は、そのモデル構築にそれぞれの測位対象地点で観測された Fingerprint データを要するが、高精度な測位を実現するためには測位対象環境において満遍なく十分な量の Fingerprint データを収集する必要がある。しかし、データ収集に要する労力や時間等のコストが高いため、屋内測位の導入コストが高く、簡単に測位環境を構築できないことが問題となっている。

これらを解決する取り組みとして、準教師あり学習やクラウドセンシングを用いる手法などが提案されている。しかし、準教師あり学習は測位対象環境中の各測位対象地点で取得されたことが既知である Fingerprint を少なくとも一つ以上必要とし、クラウドセンシングは一人当たりのデータ収集コストを削減するもののデータ収集に要する期間が長いなどの問題を抱えており、データ収集コストの削減という観点においての成果は乏しかった。

また、データ収集自体の労力を下げる取り組みとして、経路アノテーション付きデータからの学習 [5] のように歩行中に収集されたデータを用いる手法も提案されている。この手法においては静止して収集したデータを用いる手法と比較してデータ収集コストを大きく削減することに成功している。その一方、測位精度が低い点が問題であった。

この問題は、歩行中に収集されたデータを用いる既存手法は全ての AP についての電波強度データが同時に得られていると仮定していたことに起因している。しかし実際は電波強度は AP 毎に独立に取得されるため [6]、全て同位置で取得されたとラベリングすると、ほとんどの RSSI が正しい位置と紐づけられていないデータとなる。つまり、間違ったラベリングが行われたデータを用いた学習となるため、測位精度の低下の原因となっていた。すなわち、この歩行中に収集されたデータに対してそれぞれの RSSI ごと

^{†1} 現在、東京工業大学
Presently with Tokyo Institute of Technology

a) ohmori@miubiq.cs.titech.ac.jp

b) sugasaki@miubiq.cs.titech.ac.jp

c) simosaka@miubiq.cs.titech.ac.jp

に正しい位置のラベリングを行うことが出来れば、高精度な測位モデルの構築を低データ取得コストで実現出来ると言える。

本研究では、既存手法で問題となっているデータのラベリングの問題に注目した、散布型電波強度取得位置推定に基づく Fingerprint データセット構築と称するアルゴリズムによる高精度な測位モデル構築法を提案する。散布型電波強度取得位置推定とは、歩行中に収集された Fingerprint データに対し、電波強度が AP 毎に独立に取得される点を考慮し、それぞれの Fingerprint に含まれる RSSI の取得位置を AP 毎に独立に推定するアルゴリズムを指す。これにより、正しい位置のアノテーションが行われた Fingerprint データを構築することが出来るため、歩行経路といった曖昧なラベリングがなされたデータからでも高精度な測位モデルの構築を行うことが出来る。

本研究の貢献は以下でまとめられる。

- 無線電波強度が AP 毎に独立して収集されることに着目し、歩行しながら収集することで発生する問題を提起した。
- 歩行中に収集された Fingerprint データに対して AP 毎に独立して RSSI の取得された位置を推定することで、より信頼度の高い位置にラベリングされた Fingerprint データセットの構築を行うアルゴリズムを提案した。
- 実データを用いた実験により、提案手法を用いて構成されたデータセットを用いることで、既存の全ての RSSI を同位置で観測されたと仮定する手法と比べ、高精度な測位が可能になることを確認した。

1.2 関連研究

ここ 20 年にわたって、Wi-Fi の信号強度を用いた測位手法が議論されており [2][3][7][8]、その中でも Fingerprint を用いた屋内測位手法は、環境中の AP の位置など環境の情報を必要としない実用的な測位手法として、多く研究されている [2][3][8]。

これらの研究のうち、無線電波強度の Fingerprint を用いた屋内測位の先駆けとして、Bahl らは k 近接法による手法 [2] を提案した。また、Youssef らの提案した Horus 測位方式 [3] は計算量を抑えながらも高精度な測位モデルの構築を可能にした。

しかしこれらの手法は測位対象環境内全域に満遍なく設定された測位対象地点において静止して収集された Fingerprint データを多数必要とする。このデータ取得に要する時間と労力の観点からデータ収集コストが非常に高いことが問題視されている。

1.2.1 準教師あり学習によるアプローチ

データ取得コストの問題を解決するため、ここ 10 年において準教師あり学習の枠組みを用いた研究がなされてい

る [9][10]。これらの手法は、一部の Fingerprint のみに位置ラベルが付与されたデータセットから、ラベル伝播法を用いることで測位モデルを構築する手法である。

位置情報が付与されていない Fingerprint データを用いることで、全ての Fingerprint に位置情報が付与されているデータを用いる場合よりも手軽に大量のデータ収集を行うことが可能となった。しかし、各メッシュ毎に少なくとも一回ずつ立ち止まって Fingerprint データを収集することが必要であるためデータ収集にかかるコストが削減されたとは言い難い。

1.2.2 クラウドセンシングによるアプローチ

また、データ取得を大衆に行わせることでデータ収集コストを抑える枠組みとして、クラウドセンシングを用いた研究も盛んに行われている [11][5][12]。クラウドセンシングにおけるデータ収集は、何らかのサービスのユーザーに対し測位対象環境内の指定の地点へ誘導するインセンティブを与え、データ収集への協力を仰ぐ等の方法で行われる。

クラウドセンシングを用いることにより、データ収集者一人当たりのデータ収集の負担を削減することに成功した。しかしクラウドセンシングによってラベルありデータを収集するには金銭などによる動機付けが必要であるうえ、ラベル毎に収集されるデータ数の偏りが起こりやすい、逆に総データ収集時間は長くなってしまふ等の問題を抱えている。

1.2.3 経路アノテーション付きデータからの学習

データ取得の大変さ、困難さ自体を下げることを考えた、歩行しながらデータ取得を行う枠組みが近年提案されている。これは、測位対象点上でデータを取得する必要のある既存のデータ収集法の、最も労力を要する原因を排除するものである。すなわち、歩行中に収集されたデータを用いることでデータ収集に要する時間が大幅に削減されるため、データ収集コスト削減の観点において根本的な問題を解決するものであると言える。

Kawajiri らによって、経路アノテーションを付与することで歩行しながら収集した Fingerprint を用いて測位モデルの構築を可能にする手法 [8] が提案された。アノテーションされる経路はメッシュの通過順に従って並べられたラベル列であり、その経路の歩行中に収集された Fingerprint の取得位置を経路上に同定した後に測位モデル構築を行うことで誤差がおおよそ 3 m 以内の比較的高精度な測位が可能になることが示されている。

しかし、この枠組みにおいて一回のスキャン中に RSSI が AP 毎に独立して取得されることを考慮していないため、データ収集の際に一回のスキャン中に複数の測位対象点上を通過するような歩行をしてしまうと、それぞれの Fingerprint について一部に誤った位置ラベルが振られてしまうという点が挙げられる。この誤ったラベリングの結




図 1: メッシュの作成方法概観。測位対象環境を分割し、それぞれの区画をメッシュと定義する。

果、一部に誤った位置ラベルが振られた訓練データを用いて測位モデルを構築してしまうため、測位の精度が低くなるという問題を抱えている。

本研究では、歩行しながらデータ取得を行う枠組みにおけるこの問題を解決するため、歩きながら収集したデータの取得位置同定を Fingerprint 毎ではなく AP 毎に行う手法を提案する。これにより、歩行データを用いた測位モデル構築の枠組みの更なる高精度化を目指す。

2. 歩行中に収集された電波強度を用いる屋内測位

2.1 無線電波強度を用いた屋内測位

ある AP $s \in \mathcal{S}$ に対し、端末で取得された RSSI を $x^{(s)}$ 、その取得位置を $\mathbf{y}^{(s)}$ とすると、Fingerprint は $\{(x^{(s)}, \mathbf{y}^{(s)})\}_{s \in \mathcal{S}}$ の形で表される。本研究では、測位の最小単位となる、測位対象環境をグリッド上に分割した各メッシュを測位対象とする。メッシュはそれぞれの位置を表す位置ラベル $l \in \mathcal{L}$ で識別し、位置ラベル l を持つメッシュを m_l と定義する。ここで、 $\mathcal{L}$ はラベル全体の集合である。また、 m_l において取得された RSSI ベクトルを $\mathbf{x}_l$ 、 m_l の代表点の座標を $\mathbf{y}_l$ とする。

RSSI ベクトル $\mathbf{x}_l$ に対して $f(\mathbf{x}_l) = l$ となるような識別モデルを構築することで屋内測位を行う。以降、識別関数 $f: \mathcal{R}^{|\mathcal{S}|} \rightarrow \mathcal{L}$ を以下を満たすラベルを返す関数として定義する。

$$f(\mathbf{x}) = \arg \max_{l \in \mathcal{L}} \mathbf{w}_l^\top \phi(\mathbf{x}). \quad (1)$$

ここで $\mathbf{w}_l$ は m_l に対応したパラメータ、 $\phi(\mathbf{x})$ は RSSI ベクトル $\mathbf{x}$ に関する特徴量である。この特徴量 $\phi(\mathbf{x})$ として、下坂らの手法 [13] に従い、AP s から取得される RSSI $x^{(s)}$ に対し、式 (2) で表されるガウス基底関数を採用する。

$$\{\phi(x^{(s)})\}_k = \frac{-(x^{(s)} - \mu_k)^2}{\sigma^2}. \quad (2)$$

ここで、 μ_k 及び、 σ はハイパーパラメータであり、RSSI の値域を考慮し決定する。屋内測位問題は、式 (1) による測位を高い精度で可能にするパラメータ $\{\mathbf{w}_1, \dots, \mathbf{w}_{|\mathcal{L}|}\}$ を教師付きデータセットを用いて最適化する問題として定義できる。

本研究では、最適化に用いる損失項として式 (3) で定義

されるコスト考慮ヒンジ損失 ξ を用いることとする。

$$\xi(l^*, \mathbf{x}) = \max \left(0, \max_{\tilde{l} \in \mathcal{L} \setminus l^*} H(l^*, \tilde{l}, \mathbf{x}) \right), \quad (3)$$

$$H(l^*, \tilde{l}, \mathbf{x}) = \Delta(l^*, \tilde{l})(1 - \mathbf{w}_{l^*}^\top \phi(\mathbf{x}) + \mathbf{w}_{\tilde{l}}^\top \phi(\mathbf{x})). \quad (4)$$

ここで用いた l^* は RSSI ベクトル $\mathbf{x}$ が実際に取得されたメッシュのラベル、 $\tilde{l}$ は l^* 以外のラベルである。 $\Delta(l_1, l_2)$ は二つのメッシュ l_1, l_2 間の距離であり、ここでは Euclid 距離を用いることとする。

識別による屋内測位では、誤識別されたデータに対して誤識別された距離が長いほど大きな損失を与えることで高い精度の測位が可能になることが知られている [13]。Fingerprint データセット $\mathcal{U} = \{(\mathbf{x}_i, \mathbf{y}_i)\}_{i=1}^{N_{\mathcal{U}}}$ を用いて、コスト考慮ヒンジ損失 [14][15] を用いた目的関数を最小化することによってパラメータ $\{\mathbf{w}_1, \dots, \mathbf{w}_{|\mathcal{L}|}\}$ の最適化を行う。ここで、 $N_{\mathcal{U}}$ は訓練データの総数である。

式 (3) で表されるコスト考慮ヒンジ損失項に対し、過学習を防ぎ特徴量を疎に選択するため ξ に L_1 ノルムによる正則化項を加えることで、以下の目的関数が得られる。

$$\min_{\mathbf{w}} \left(\sum_{n=1}^{N_{\mathcal{U}}} \xi(l_n, \mathbf{x}_n) + \lambda \sum_{l \in \mathcal{L}} \|\mathbf{w}_l\|_1 \right). \quad (5)$$

ここで、 n 番目のデータの RSSI ベクトルを $\mathbf{x}_n$ 、位置ラベルを l_n とした。また、 $\lambda > 0$ は誤差の小ささと正則化のトレードオフを制御するハイパーパラメータである。

なお、最適化手法として FOBOS[16] を用いる。

2.2 歩行中に収集されたデータの定式化と既存手法の問題点

$i \in \{1 \dots N_{\mathcal{U}}\}$ 番目の Fingerprint $\{(x_i^{(s)}, \mathbf{y}_i^{(s)})\}_{s \in \mathcal{S}}$ の取得位置 $\{\mathbf{y}_i^{(s)}\}_{s \in \mathcal{S}}$ は i 番目の歩行経路 ζ_i 上で明示的に取得することができない。

これは、各 AP について RSSI の取得時刻が不明であることに起因する。さらに、図 2 のように i 番目の Fingerprint に含まれる AP $s \in \mathcal{S}$ についての RSSI $x_i^{(s)}$ の取得位置 $\mathbf{y}_i^{(s)} \in \zeta_i$ は AP 毎に独立して取得されるため [6]、取得位置をそれぞれの RSSI 毎にパス上の一点として独立して持つ。

既存手法ではこの問題を考慮せず、図 3 のように全ての AP についての RSSI が同時に取得されている、すなわちある点 $\hat{\mathbf{y}}_i \in \zeta_i$ において全ての $s \in \mathcal{S}$ について $\mathbf{y}_i^{(s)} = \hat{\mathbf{y}}_i$ が成り立つと仮定していた。そのため、それぞれの Fingerprint の各要素について $\epsilon_i^{(s)} = \|\mathbf{y}_i^{(s)} - \hat{\mathbf{y}}_i\|_2$ で表される距離 $\epsilon_i^{(s)}$ 分誤った取得位置ラベルが付与されたデータを用いて測位モデルを学習をしていた。よって、この仮定に従うことが歩行データを用いた場合に測位精度が下がる原因となっていた。



図 2: あるスキャン実行中の歩行経路と実際のデータ取得位置の例。ここでは AP 1～AP 4 について、それぞれ RSSI $x^{(1)} \sim x^{(4)}$ が図で示された位置で得られたとしている。




図 3: 従来手法によるデータ取得位置推定。全ての AP についての RSSI が同一地点で得られると仮定し取得位置を推定する。




図 4: 散布型電波強度取得位置推定。それぞれの AP について RSSI の取得位置を独立に推定する。




図 5: 散布型電波強度取得位置推定に基づく Fingerprint データセット構築法の手続きの概観。赤枠で囲われた部分が提案手法に関わる部分である。

3. 散布型電波強度取得位置推定に基づく Fingerprint データセット構築法

2.2 章で述べた通り、既存手法における問題は、 i 番目の Fingerprint に含まれる AP $s \in S$ についての RSSI $x_i^{(s)}$ の取得位置 $y_i^{(s)}$ が全ての AP について同一、すなわちある点 $\hat{y} \in \zeta_i$ において全ての $s \in S$ について $y_i^{(s)} = \hat{y}$ が成り立つと仮定していたことであつた。すなわち、各 AP s についての Fingerprint i に含まれる RSSI $x_i^{(s)}$ の取得位置 $y_i^{(s)}$ を他の AP $s' \in S \setminus s$ と独立に推定することでこの問題は解決される。

図 4 で示した通り、AP 毎に独立に RSSI の取得位置を推定することで、全ての AP について RSSI の取得位置が同一であると仮定する場合 (図 3) と比較して、AP 毎にまばらな取得位置に対して柔軟な推定が可能である。

この方法を取り入れた、歩行中に収集された Fingerprint データを用いた屋内測位モデル構築のためのデータセット構築手法である散布型電波強度取得位置推定に基づく Fingerprint データセット構築法を提案する。散布型電波強度取得位置推定に基づく Fingerprint データセット構築法は、主に以下の二つの手続きから成る。

- (1) 各 AP s についての RSSI ベクトル $\{x_i^{(s)}\}_{i \in \{1 \dots N\}}$ と歩行経路 $\{\zeta_i\}_{i \in \{1 \dots N\}}$ を用いて取得位置 $\{y_i^{(s)}\}_{i \in \{1 \dots N\}}$ を推定する。
- (2) (1) における取得位置の推定結果に基づく測位モデルの学習に用いることのできる Fingerprint データセット構築に際し、適宜不足した RSSI データの補完を行う。この手続きにより、Fingerprint 毎の RSSI の取得位置推定を各 AP に対して独立に行い、かつ測位モデルの学習に用いることのできる形式のデータセットの構築が可能となる。

3.1 散布型電波強度取得位置推定

まず取得された Fingerprint からある AP s に対応する RSSI を抽出し、その集合を $X^{(s)} = \{x_1^{(s)}, \dots, x_N^{(s)}\}$ とする。 $X^{(s)}$ の各要素 $x_i^{(s)}$ の推定取得位置 $\hat{y}_i^{(s)}$ を i 番目の Fingerprint 取得中の歩行経路 ζ_i の端点とする。 AP s についての RSSI の推定取得位置の集合を $\hat{Y}^{(s)} = \{\hat{y}_1^{(s)}, \dots, \hat{y}_N^{(s)}\}$

その後、ブロック化ギブスサンプリング [17] によって各 RSSI の取得位置の推定を行う。

各反復操作のはじめに、 $X^{(s)}$ に含まれる要素の添字の集合を N_k 個の集合に分割し、 k 番目の集合を $\mathcal{G}_k$ とする。 ある $i \in \mathcal{G}_k$ について、推定取得位置 $\hat{y}_i(s)$ は添字が $\mathcal{G}_k$ に含まれない RSSI とその推定取得位置を用いたガウス過程回帰により定まる条件付き分布を用いたサンプリングにより更新される。 この時、 i 番目の Fingerprint の AP s についての RSSI $x_i^{(s)}$ の推定取得位置 $\hat{y}_i^{(s)}$ の更新は式 (6) で表される。

$$\hat{y}_i^{(s)} \sim p(\mathbf{y} | x_i^{(s)}, \zeta_i, X^{(s)} \setminus x_{i \in \mathcal{G}_k}^{(s)}, \hat{Y}^{(s)} \setminus \hat{y}_{i \in \mathcal{G}_k}^{(s)}, \boldsymbol{\theta}). \quad (6)$$

なお、ここで用いた ζ_i は i 番目の Fingerprint 取得中の歩行経路、 $\boldsymbol{\theta}$ はガウス過程回帰に用いるガウスカーネルのパラメータである。 上記の操作を一定回数繰り返すことで取得位置を推定する。

この手法により、各 RSSI についての取得位置の推定誤差は、推定取得位置を $\hat{y}_i^{(s)}$ 、真の取得位置を $\mathbf{y}_i^{(s)}$ として $\epsilon_i^{(s)} = \|\hat{y}_i^{(s)} - \mathbf{y}_i^{(s)}\|_2$ で表すことが出来る。 本節の AP 毎に独立な取得位置推定は、2.2 章で述べた全ての AP について同一地点で RSSI が取得されたと仮定する場合と比較し、それぞれの AP について $\sum_i \epsilon_i^{(s)}$ を最小化することでモデルの測位精度を向上する取り組みであると言える。

ただし、ブロック化ギブスサンプリングの適用後は一般に RSSI の推定取得位置が一点に定まらず、AP 毎の RSSI の取得位置が歩行経路上に”散布”された状態である。 測位モデルの学習においては各測位点上における全 AP についての RSSI を特徴量変換して用いる必要があり、すなわち全てのメッシュ上に全ての AP についての RSSI がそれぞれ少なくとも一回以上取得されていなければならない。

しかし、散布型電波強度取得位置推定後は必ずしもこの要件を満たしていない。 よって、それぞれの RSSI の推定結果に合わせて RSSI を補完することで Fingerprint を構成する必要がある。

3.2 不足 RSSI データの補完

取得位置推定結果を用いて測位モデルの学習に用いることのできる Fingerprint データセットを構築するため、各測位点上における各 AP についての RSSI データが一つ以上存在するという要件を満たすため、適宜 RSSI データの補完が必要である。 そこで取得位置推定結果に基づいて各 AP についてガウス過程回帰を行うことで測位対象環境全




図 6: 実験環境

体における RSSI の分布を求め、その分布からのサンプリングによってデータの補完を行う。

AP s について、メッシュ m_l における取得 RSSI 値 $\hat{x}_l^{(s)}$ を補完する際は、式 (7) で表される通り、取得 RSSI データ集合 $X^{(s)} = \{x_1^{(s)}, \dots, x_N^{(s)}\}$ とその推定取得位置 $\hat{Y}^{(s)} = \{\hat{y}_1^{(s)}, \dots, \hat{y}_N^{(s)}\}$ を用いたガウス過程回帰により求めた m_l の代表点 $\mathbf{y}_l$ における RSSI の条件付き分布からサンプリングした値で補完を行う。

$$\hat{x}_l^{(s)} \sim p(x | \mathbf{y}_l^{(s)}, X^{(s)}, \hat{Y}^{(s)}, \boldsymbol{\theta}). \quad (7)$$

こうして生成された、RSSI ベクトル $\mathbf{x} \in \mathcal{R}^{|\mathcal{S}|}$ と単一の取得位置 $\mathbf{y}_l \in \mathcal{L}$ が紐づいたデータセット $\{(\mathbf{x}_1, \mathbf{y}_1), \dots, (\mathbf{x}_N, \mathbf{y}_N)\}$ を用いて測位モデルの構築を行う。

4. 実験

本実験においては、真のデータ取得位置に対する散布型電波強度推定の精度を評価するため、取得位置が既知であるデータを用いて、以下の二つの実験を行った。

- (1) 散布型電波強度取得位置推定による RSSI 取得位置推定精度を評価するため、各メッシュ上で静止して収集した RSSI $\mathbf{x}_i$ に対してその取得位置を擬似的な経路 ζ_i として与え、AP 毎に取得位置 $\hat{y}_i^{(s)}$ を推定した。この実験を、RSSI 取得位置推定実験とする。
- (2) 散布型電波強度取得位置推定に基づく Fingerprint データセット構築法の有用性を評価するため、(1) と同様のデータを用いて本手法に従って測位モデルを構築しその精度を評価した。この実験を、測位精度評価実験とする。

4.1 実験環境

大学構内の 10 階建てビルの 4 階フロアのうち $17\text{m} \times 10\text{m}$ のオフィス、 $2\text{m} \times 28\text{m}$ の廊下、 $5\text{m} \times 5\text{m}$ のオープンスペースから成る部分を実験対象環境とした (図 6)。データ収集はカートに乗せた 10 台の Nexus5 を用いて測位対象環境上の各メッシュ上で静止して行った。すなわち、収集されたデータにおいて各 Fingerprint の取得位置は既知である。上記のデータ収集を同日に二回行い、合計で 20 周分のデータを収集した。これらを訓練データとテストデー

タに分け、各モデルの評価を行った。

4.2 比較手法

測位モデルの精度評価に際し、以下の三手法を実装した。

- (1) TruePosition: Fingerprint と既知である真の取得位置を用いて測位モデルの学習を行う。これは従来通りのデータ収集コストが高いが精度が高い手法である。
- (2) EndOfPath: 各 Fingerprint に対して、その取得位置を真の取得位置を含む擬似的な経路として与え、推定取得位置を経路の終点として測位モデルを構築する。これは、歩行データを用いる既存手法において一般的に採用される手法である。
- (3) PredictEach: 各 Fingerprint に対して、その取得位置を真の取得位置を含む擬似的な経路として与え、3章で述べた散布型電波強度取得位置推定に基づく Fingerprint データセット構築法に従って測位モデルを構築する。

なお、上記全ての手法のモデル設計において、2章で定義したガウス特徴量に対し、ハイパーパラメータとして $\mu = [-80, -70, -60, -50, -40, -30, -20]$, $\sigma = 2.0$ を共通して用いた。

また、評価メトリックとしてテストデータそれぞれについての真の取得位置と推定取得位置のユークリッド距離で定義される測位誤差の平均および累積分布関数 (CDF) を用いる。

4.3 実験結果

4.3.1 RSSI 取得位置推定実験

ある AP について、散布型電波強度取得位置推定アルゴリズムによる推定取得位置と真の取得位置の誤差を各イテレーション毎にまとめた結果は図7のようになった。この結果より、取得位置推定アルゴリズムによって初期位置と比較し平均 0.15m 程度真の取得位置に近い位置に推定されたことが読み取れる。

4.3.2 測位誤差評価実験

PredictEach, EndOfPath, TruePosition の各手法について測位モデルの精度を比較した結果は図8, 図9のようになった。図8に示した通り、各手法の平均測位誤差は EndOfPath は 2.7m, PredictEach は 2.3m, TruePosition は 1.6m となった。

PredictEach は EndOfPath と比較して平均測位誤差が 0.4m 程度減少しており、TruePosition と比較した誤差は 0.7m であることから、PredictEach は EndOfPath の結果と比較して測位精度が有意に上回り、理想的な設定である TruePosition に近い測位精度が得られたと言える。

図9に示した測位誤差の CDF から、PredictEach は EndOfPath と比較して誤差の大きな測位の誤りが全体的




図7: データ取得位置推定誤差




図8: 測位誤差平均の棒グラフ




図9: 測位誤差の CDF

に減少しており, TruePosition に近い結果が得られていることが読み取れる。

5. 結論

無線電波強度ベースの屋内測位にかかるデータ収集のコストを削減するため歩行しながら収集したデータを用いる手法について, 測位精度改善のための提案を行った。

既存手法では無線電波強度が AP 毎に独立して取得される点に注目しておらず, 歩行中に収集したデータについてはその取得位置が AP 毎に異なることが考慮されていなかった。本論文ではその特性を考慮した, 散布型電波強度取得位置推定に基づく Fingerprint データセット構築法を提案した。また, 実データを用いた実験により, 無線電波強度が AP 毎に独立して非同期に取得されているという仮定に従うことで測位モデルの精度が向上することを確認, 本論文の主張の有意性を示した。将来課題として, 実際に歩行しながら収集したデータを用いた場合においても精度が向上することを確認することなどが挙げられる。

参考文献

- [1] Han, D. e. a.: Building a practical Wi-Fi-based indoor navigation system, *IEEE Pervasive Computing*, Vol. 13, No. 2, pp. 72–79 (2014).
- [2] Bahl, P. and Padmanabhan, V. N.: RADAR: An in-building RF-based user location and tracking system, *INFOCOM 2000. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies. Proceedings. IEEE*, Vol. 2, Ieee, pp. 775–784 (2000).
- [3] Youssef, M. and Agrawala, A.: The Horus WLAN location determination system, *Proceedings of the 3rd international conference on Mobile systems, applications, and services*, pp. 205–218 (2005).
- [4] Sugano, M. e. a.: Indoor Localization System using RSSI Measurement of Wireless Sensor Network based on Zig-Bee Standard., *Wireless and Optical Communications*, pp. 1–6 (2006).
- [5] Kawajiri, R., Shimosaka, M. and Kashima, H.: Steered crowdsensing: Incentive design towards quality-oriented place-centric crowdsensing, *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp. 691–701 (2014).
- [6] 小西勇介, 中尾敏康ほか: WiFi 測位のためのアクセスポイントスキャン高速化方式, *MBL*, Vol. 2011, pp. 1–8 (2011).
- [7] Tuta, J. and Juric, M. B.: Non-fingerprint indoor Wi-Fi based localization using PSO algorithms, *PICACSA 2015*, p. 97 (2015).
- [8] Kawajiri, R. e. a.: Frustratingly simplified deployment in WLAN localization by learning from route annotation, *Asian Conference on Machine Learning*, pp. 191–204 (2012).
- [9] Kashima, H. e. a.: A semi-supervised approach to indoor location estimation (2011).
- [10] Liu, S., Luo, H. and Zou, S.: A low-cost and accurate indoor localization algorithm using label propagation based semi-supervised learning, *Mobile Ad-hoc and Sensor Networks, 2009. MSN'09. 5th International Conference on*, pp. 108–111 (2009).
- [11] Azizyan, M., Constandache, I. and Roy Choudhury, R.: SurroundSense: mobile phone localization via ambience fingerprinting, *Proceedings of the 15th annual international conference on Mobile computing and networking*, pp. 261–272 (2009).
- [12] Jung, S.-H. and Han, D.: Automated Construction and Maintenance of Wi-Fi Radio Maps for Crowdsourcing-Based Indoor Positioning Systems, *IEEE Access*, Vol. 6, pp. 1764–1777 (2018).
- [13] 下坂正倫: 最大マージンワイヤレス D センサ位置推定, 第 15 回ロボティクスシンポジウム予稿集吉野, 奈良県, March, pp. 520–526 (2010).
- [14] Sen, P. and Getoor, L.: Cost-sensitive learning with conditional markov networks, *Data Mining and Knowledge Discovery*, Vol. 17, pp. 136–163 (2008).
- [15] Tsochantaridis, I. e. a.: Large margin methods for structured and interdependent output variables, *Journal of machine learning research*, Vol. 6, pp. 1453–1484 (2005).
- [16] Duchi, J. and Singer, Y.: Efficient online and batch learning using forward backward splitting, *Journal of Machine Learning Research*, Vol. 10, pp. 2899–2934 (2009).
- [17] Jensen, C. S., Kong, A. and Kjaerulff, U.: Blocking Gibbs sampling in very large probabilistic expert systems, *International Journal of Human Computer Studies*, Vol. 42, No. 6, pp. 647–666 (1995).