

GPS 信号情報と Bluetooth 電波情報を用いた IoT 機器の協調的屋内位置推定手法の検討

藤原 真之^{1,a)} 中谷 友哉² 前川 卓也^{2,b)} 原 隆浩^{2,c)}

概要：近年、無線通信機能や様々なセンサを搭載した IoT 機器の普及が見込まれており、屋内に設置されるスマートデバイスの数は今後急増すると考えられている。これらの IoT 機器の位置情報は、複数機器の連携動作や各種センサを用いた位置依存型サービス等に有用である。しかし、環境内のどの座標にどの機器が設置されているかの屋内位置情報を人手で入力することは非常にコストが大きい。また、既存の屋内位置推定手法は、教師あり機械学習を用いて人やオブジェクトの位置座標を推定するものが多く、最も一般的なフィンガープリントを用いた手法では、あらかじめ環境内の様々な場所で電波情報を収集しておく必要があり、そのコストは膨大である。

そこで本研究では、導入コストの低い新たな屋内 IoT 位置推定手法を提案する。提案手法では、IoT 機器が搭載する Bluetooth 電波送受信機の電波情報を用いて互いの機器間の距離を推定し、その情報を用いて、環境内の機器の相対的な位置関係を求める。さらに、環境内の人が携帯するモバイル端末に搭載されている GPS および Bluetooth 電波送受信機を用いることで、推定した相対的な位置関係を環境内のフロアマップにおける座標系に変換する。ただし、屋内環境においては GPS を用いてマップ内の正確な位置座標を推定できない。そのため、モバイル端末が窓際にある場合に該当方角からの GPS 受信信号強度が大きくなることを利用し、環境内のどの方位の壁面 (窓際) に居たのかの情報をアンカーポイントとして変換に用いる。複数の壁面のアンカーポイントを取得することし、その地点で同様に Bluetooth 電波送受信機の電波情報を用いて推定された、IoT 機器とアンカーポイント間の距離を用いて、相対的な位置関係を環境内のフロアマップにおける座標系に変換できる。評価実験では、5 つの実環境において観測されたデータをを用いて提案手法の有効性を確認した。

キーワード：屋内位置推定, IoT, GPS, Bluetooth

1. はじめに

近年、スマートフォンなどの無線通信機能を搭載した端末の普及やモバイルコンピューティング技術の進展により、ナビゲーションやレストランの周辺検索などの位置情報を活用したサービスが広く用いられている。しかし、屋外においては GPS を用いた位置推定手法が広く普及している一方で、屋内においては、様々な手法が提案されているにもかかわらず、導入コストの大きさ等から未だに普及していない。屋内位置情報は、人やオブジェクトの状況・状態を如実に表すものであり、人が携帯するモバイル端末等の

受信電波情報 (Wi-Fi[1], Bluetooth[2], RFID[3], UWB[4], FM 電波 [5]) や様々なセンサ (赤外線 [6], 超音波 [7], 地磁気センサ [8] 等) を用いて屋内位置推定を行う研究が現在も数多く行われている。屋内位置推定技術の応用としては、博物館、病院、ショッピングモール等の屋内でのナビゲーションや病院での高齢者の見守り、近接検知によるコミュニティの分析等幅広い用途が考えられている。

既存の屋内位置推定手法は、教師あり機械学習を用いて人やオブジェクトの位置座標を推定するものが多く、最も一般的な屋内位置推定手法に Wi-Fi や BLE 等のフィンガープリントを用いた屋内位置推定手法がある [1], [9], [10]。この手法では、学習段階において、あらかじめ様々な場所で Wi-Fi (BLE) 受信電波情報 (受信信号強度と Wi-Fi アクセスポイントの MAC アドレス) を観測・記録し、それぞれの場所における固有の電波情報 (信号強度ベクトル) である Wi-Fi (BLE) フィンガープリントを学習する。そして計測段階において、観測された Wi-Fi (BLE) 受信電波

¹ ダイキン工業株式会社
1-1 Nishihitotsuya, Settsu-shi, Osaka-fu 566-8585, Japan

² 大阪大学
1-5 Yamadaoka, Suita-shi, Osaka-fu 565-0871, Japan

a) masayuki.fujiwara@daikin.co.jp

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

c) hara@ist.osaka-u.ac.jp

情報と学習したフィンガープリントを比較することで、その受信電波情報における位置情報を推定する。しかし、このようなフィンガープリントを用いた手法では、あらかじめ様々な場所で電波情報を収集しておく必要があり、そのコストは膨大である。また、ある環境で学習されたフィンガープリントを他の環境に適用することはできない。

一方、本研究では IoT 機器の位置推定手法の導入コストを低減するために、モバイル端末に搭載されている電波送受信機（GPS と Bluetooth）を用いる。特に、環境内の住人や作業員が携帯するモバイル端末に注目し、日常生活や作業中にバックグラウンドで自動的に収集した GPS 衛星情報と Bluetooth 受信信号強度を用いて IoT 機器の位置測位を行うことで、屋内位置推定の導入コストの大幅な低減を可能にする。

本研究では、提案手法の有効性を確認するために、BLE を搭載した空調機器を想定とし、大きさや物の配置等、全く条件の異なる 5 つの実環境で評価を行う。特定の環境に依存しないことを確認するため、1 環境を評価する際に残りの 4 環境を学習データに用いる。

本研究の貢献は以下の 3 つである。

- 導入コストの低い環境非依存の新たな屋内 IoT 機器の位置推定手法の提案
- モバイル端末の GPS 衛星情報と BLE 受信電波情報を用いたアンカーポイントの取得とそれを用いたマップ座標系における IoT 機器の位置推定の実現
- 5 環境の実データを用いた提案手法の有効性の評価

2. IoT 機器の屋内位置推定手法

本研究では、屋内 IoT 機器として Bluetooth (BLE) デバイスを搭載した空調機器を想定する。提案手法では、各 IoT 機器は BLE 信号を発信するとともに、異なる IoT 機器からの BLE 信号強度を収集しているものとする。また、IoT 機器の設置作業員や管理者等がモバイル端末（タブレット等）を携帯し、バックグラウンドで自動的に GPS 衛星情報および各 IoT 機器からの BLE 信号強度を収集していると想定する。加えて、対象とする環境の外形のマップ情報（形状、長さ、壁の方向）は既知であるものとする。

2.1 概要




図 1 提案手法概要

図 1 に提案手法の概要を示す。図中のピンは、モバイル

端末携帯者が環境内を移動した際にバックグラウンドで収集した GPS データを用いて推定したアンカーポイントを表す。また本研究の目的は、図にある IoT 機器（空調機器）の位置を推定することである。提案手法は、IoT 機器の位置を推定するために、GPS 衛星情報から推定されたモバイル端末のおおまかな位置情報を手がかりとする。ただし、屋内環境においては、GPS を用いてモバイル端末の位置を正確には推定できない。そのためモバイル端末が窓際に存在する場合に GPS 受信信号強度が大きくなることを利用する。GPS 衛星情報からモバイル端末が環境内のどの壁面に居たのかを推定し、その情報を IoT 機器のマップ上の座標を求めるアンカーポイントとして用いる。続いて、そのときのモバイル端末と IoT 機器間の距離および IoT 機器間の距離を BLE 信号強度を用いて推定し、それらの距離情報とアンカーポイントを組み合わせることで IoT 機器の位置を推定する。

図 1 に示した通り、本提案手法は大きく分けて「窓際判定」、「壁面分類」、「距離推定」、「位置推定」の 4 つの手順からなる。次節から、それぞれの手法について詳細に説明する。

2.2 窓際判定手法

本節では、GPS 衛星情報を用いてモバイル端末が窓際に存在したタイミングを推定する窓際判定手法を説明する。本研究では、窓際の定義を窓から約 1m 以内としている。

一般的なモバイル端末に搭載されている GPS 受信機では、屋内において GPS 衛星からの信号を大きなノイズなく受信することは難しい。しかし、窓際においてはその限りではなく、屋外で受信する信号強度には劣るものの、窓方向にある衛星からの信号はある程度受信することが可能である。本提案手法では、この性質を利用して、モバイル端末が窓際に存在するか、否かを判定する。窓際における GPS 衛星からの信号は、窓からの距離、各衛星の方位や仰角、周囲の建物の位置によって異なるため、様々な環境の実データを取得し、教師あり機械学習を用いてモバイル端末が窓際に存在するかを判別する。

窓際判定のための分類器には、ランダムフォレスト [14] を用い、以下の特徴量を入力とする。

- 全衛星の最大信号強度
- 各方位ごとの最大信号強度の中央値
- 最大信号強度の衛星が存在する方位の全衛星の信号強度の中央値

各方位ごとの最大信号強度では、図 2 に示すように建物各辺（4 方向）ごとの最大信号強度を持つ衛星を抽出している。本研究では、各辺（4 方向）ごとに左右 45 度方向に存在する衛星の中から抽出することとした。




図2 窓際判定: 建物を真上から見たときの各方位ごとの最大信号強度を持つ衛星の取得

2.3 壁面分類手法

本節では、モバイル端末が窓際に存在したと推定されたタイミングにどの方位の壁面（窓際）に居たのかをGPS衛星情報を用いて推定する手法を説明する。本手法は、モバイル端末がある方位の壁面（窓際）に存在する場合に、その方位に存在するGPS衛星からの信号強度が大きくなるという考えに基づく。そのため窓際判定と同様に各方位ごとの最大信号強度を持つGPS衛星を抽出し、その情報を入力としてどの壁面にいたかを推定する。

分類器は、窓際判定と同様にランダムフォレストを用い、新たに以下の特徴量を入力とする。

- 推定したい壁面に対応する各方位ごとの最大信号強度
- 推定したい壁面に対応する各方位ごとの信号強度の中央値

本手法は方位角ごと（壁面ごと）の分類確率を算出するため、方位角ごと（壁面ごと）にone-vs-restの二値分類を行う。これは、反射や回折等によって別の方位からの電波が強く得られる可能性があるためである。そのような場合、複数の壁面に分類される可能性が高くなるため、複数の壁面に分類される確率が同じデータに関しては、アンカーポイントとして使用しないようにする。

特徴量を具体例を用いて説明する。環境が南東、南西、北東、北西の4つの壁面から構成される場合、それぞれの壁面ごとに特徴量を用意する。例として、南東の壁面を判別する場合、「推定したい壁面に対応する各方位ごとの最大信号強度」は、実際には以下の特徴量を入力とする。

- 南東を中心とした左右90度の範囲に存在する衛星の最大信号強度
- 南西を中心とした左右90度の範囲に存在する衛星の最大信号強度
- 北東を中心とした左右90度の範囲に存在する衛星の最大信号強度
- 北西を中心とした左右90度の範囲に存在する衛星の最大信号強度

それぞれの壁面ごとに分類した後、最もその壁面への分類確率が高かった壁面に分類する。

2.4 距離推定手法

本節では、各IoT機器が受信した別の機器からのBLE受信信号強度を用いてIoT機器間の距離の推定を行う。ま




図3 距離推定 (IoT 機器間): ネットワーク構成

た、アンカーポイントの位置でモバイル端末が受信したBLE信号強度の情報をもとにIoT機器とアンカーポイント間の距離を推定を行い、2地点で観測される信号強度ベクトル間の距離のみを用いてアンカーポイント間の距離推定も行う。

本提案手法では、深層学習を用いて回帰によって距離の推定を行う。複数の環境のデータを学習させることで、様々な環境に共通した特徴量を学習させることを目指す。

まず、IoT機器間の距離推定について説明する。理想的な環境において、信号強度は距離の2乗に反比例するため、推定したいIoT機器間の距離は、互いの端末が発するBLE電波の受信信号強度によって計算できる。しかし、実環境では障害物や床および壁の材質、気温等、その他様々な要因により受信信号強度が大きく変化する。そこで、本研究ではコストが低く特定の環境に依存しない距離推定を実現するために、中谷ら[15]が提案している推定手法をもとに距離推定を行う。本手法では、IoT機器間のBLE受信信号強度に加えて、BLE信号強度ベクトル間の距離を入力し、深層学習を用いて直接IoT機器間の物理的距離の推定を行う。本手法では、他の環境で観測された学習データを用いて距離推定を行っているため、特定の環境に依存することなく距離を推定できる。

ここで、BLE信号強度ベクトルとは、距離推定の対象である2端末が受信したその2端末以外のBLE受信信号強度とMACアドレスから構成されるベクトルと定義する。例えば、あるIoT機器によって地点Aで信号強度ベクトル w_i が観測されたとし、別のIoT機器によって地点Bで信号強度ベクトル w_j が観測されたと想定する。このとき、地点AとBの間の物理的な距離を推定するための特徴量として w_i と w_j のベクトル間の距離を用いる。

本手法では、信号強度ベクトル w_i と w_j とのベクトル間距離としてチェビシェフ距離を用いる。チェビシェフ距離は各座標の差の最大値を2地点間の距離とする尺度であり、 w_i と w_j を用いて以下のように表される。

$$\max_{b_n \in \mathcal{A}} |w_i(b_n) - w_j(b_n)| \quad (1)$$

ただし、 $\mathcal{A}$ は w_i かつ w_j に含まれる IoT 機器の集合を表し、 $w_i(b_n)$ は w_i に含まれる他の IoT 機器 b_n からの信号強度を表す。

このチェビシェフ距離と推定したい IoT 機器間の平均受信信号強度の 2 地点平均、最大、最小を距離を出力するニューラルネットワークに入力する。また、時間帯によっても電波の減衰率は多少変化するため、時間帯のデータも入力としている。

図 3 に本手法で用いるニューラルネットワークの構成を示す。本手法では、全結合 4 層のニューラルネットワークを用いる。それぞれの全結合層では活性化関数としてランブ関数（正規化線形関数）を用いている。

ネットワークの学習は、正確距離と推定距離間の平均二乗誤差を最小化するように、バックプロパゲーションを用いてネットワークの学習を行う。重みを初期化するための確率分布としては、He[16] の正規分布を用いた。これは、平均を 0、標準偏差を $\sqrt{2/\text{入力ユニット数}}$ とする切断正規分布である。最適化アルゴリズムには学習率^{*1}を適応的に変化させることが可能な ADAM[17] を用いる。また、過学習を抑制するために Dropout[18] を利用する。さらに、過学習を抑制するためにニューラルネットワーク中の中間出力を正規化することで学習を促進させ過学習を抑制する Batch Normalization[19] を用いた。バッチサイズ 10 でミニバッチ学習を行い、Batch Normalization はそのミニバッチごとに適用される。

また、IoT 機器とアンカーポイント間の距離推定では、モバイル端末が窓際にいると判定されたタイミングに受信した BLE 信号強度のみを用いて距離推定を行うため、IoT 機器間の距離推定とは異なり、2 端末が受信した信号強度ベクトル間の距離を特徴量として用いることはできない。また、モバイル端末は当然固定されておらず、端末の動きにより大きく信号強度が変化する場合が存在する。そのため平均の信号強度に加えて、信号強度の分散を用いることでこれらの問題に対応する。ネットワークの学習は、IoT 機器間の推定と同様に行う。

アンカーポイント間の距離推定では、IoT 機器とアンカーポイント間の距離推定と同様にモバイル端末が窓際と判定されたタイミングに受信した BLE 電波のみを用いて距離推定を行う。ただし、上記 2 つの距離推定とは異なり、互いの端末が発する BLE 電波の受信信号強度を用いることはできない。そのため、ここでは IoT 機器間の距離推定でも用いた 2 地点それぞれで観測される信号強度ベクトル間の距離のみを用いて推定を行う。ネットワークの学習は、IoT 機器間の推定と同様に行う。

^{*1} 学習率:ニューラルネットワークのパラメータを更新する割合を制御するパラメータ




図 4 相対位置推定手法: 概要

2.5 相対位置推定手法

本節では、2.4 節で説明した IoT 機器間の推定距離を用いて、IoT 機器の相対位置座標を求める手法を説明する。

図 4 に示すように相対位置座標の推定は 2 段階で構成され、推定距離から幾何学的に初期値を設定した後、その初期値を基に距離の誤差が最も小さくなるように座標の最適化を行う。このように初期値を設定後に最適化を行う理由としては、最適化の際に局所解に陥らないようにするためである。

2.5.1 初期値設定

ここでは、2.4 節で説明した推定距離から幾何学的に初期値を求める手法について説明する。なお本研究では、位置座標は 2 次元上でのみ考えることを想定しているため、端末の高さ方向は考慮せず、全ての端末が同じ高さであると想定している。

初期値の設定手順は、おおまかに以下の通りである。まず距離推定で用いた信号強度ベクトルが全端末の平均に近い 2 端末を、それぞれ端末 1、端末 2 として選択する。このとき、端末 1 を原点とし、端末 2 が x 軸 ($y=0$) 上の正の位置に存在する相対位置座標を設定する。次に、 $y \geq 0$ という条件で端末 1 と 2 から近い 1 端末を端末 3 として選択する。最後に、端末 1, 2, 3 から近い 1 端末を端末 4 として選択する。このとき、円の交点は 3 点以上存在するため、交点からなる三角形の外周が最も小さくなる 3 点の組み合わせを選択し、その重心を端末 4 とする。この手順を、全ての端末の初期位置が決定されるまで繰り返す。

上記の手順では、初期化に利用する端末の順序によって初期値の結果が変化する場合がある。そのため本研究では、端末の初期化の順序を変えた場合を数十回変更して行い、最適化後の目的関数の値が最も小さい結果を採用する。

2.5.2 座標の最適化

ここでは、幾何学的に設定した初期値をもとに距離の誤差が最も小さくなるように座標の最適化を行う。具体的には、端末の推定座標間の距離と BLE による推定距離との平均二乗誤差 (MSE) が最小となるように最適化を行う。さらに本手法の最適化では、推定距離の大きさにより重み付けを行うことで、信頼できない長距離の推定の重みを低く設定している。

重みを考慮した最適化の目的関数は以下の式で表される。




図5 マップ座標系への変換・当てはめ: 概要

$$\sum_{n,m \in A} w_{n,m} (d(b_n, b_m) - Eu(p_n, p_m))^2 \quad (2)$$

ただし、 $d(b_n, b_m)$ は端末 n と端末 m の BLE による推定距離、 $Eu(p_n, p_m)$ は端末 n と端末 m の推定座標間の距離、 $w_{n,m}$ は重みであり、対応する $d(b_n, b_m)$ の信頼度とする。本手法では、距離が長いほど重み $w_{n,m}$ の値を小さくした。最適化手法には、L-BFGS 法を用いた。

2.6 マップ座標系への変換・当てはめ手法

ここでは、2.5 節で推定された相対位置座標を 2.2 節と 2.3 節で推定されたアンカーポイントを用いてマップ座標系に変換する手法について説明する。このマップ座標系への変換・当てはめでは、2.4 節で推定した IoT 機器とアンカーポイント間の推定距離を用いて 2.5.2 節と同様に推定距離と座標間距離の誤差が最小となるように最適化を行う。

まず本手法では、相対位置座標は維持した状態で、IoT 機器とアンカーポイント間の推定距離と推定座標間の距離が最小となるように座標の最適化を行う。図 5 にマップ座標系への変換・当てはめの概要を示す。最適化手法は基本的に 2.5.2 節と同様だが、最適化の際の初期値を、相対位置座標の重心とマップの重心が一致するように設定する点、最適化する変数として個々の端末ではなく、回転行列や平行移動行列を設定する点、および 2.5.2 節と比較して、信頼性の低いアンカーポイントからの距離を使用するため、最適化の際の重みを非常に小さい値に設定する点で異なる。

また、相対位置座標は反転する場合も考えられる。そのため反転した場合と、反転しない場合それぞれで最適化を行い、最適化後の目的関数の値がより小さい方を採用する。

本手法では、マップ座標系への変換・当てはめ後、さらに精度の高い位置推定を実現させるために、アンカーポイントを含めて相対位置座標の最適化を再度行うこととした。この際、アンカーポイントが壁面上に存在するという制約条件と IoT 機器がマップ内に存在するという制約条件を追加している。その他の変数は、2.5.2 節と同様の設定を用いる。

3. 評価実験

3.1 データセット

本研究で用いる GPS および BLE データは一般的なオフィスビル（用途：事務所ビル、構造：S 造、階数：7 階、竣工：1998 年 4 月）および大学内の 3 つの建物（大阪大学共創イノベーション棟^{*2}、大阪大学コンベンションセンター^{*3}、大阪大学センテラスサロン^{*4}）で取得した。

オフィスビルでは、IoT 機器として BLE 等を搭載した空調機器を想定しているため、1F、2F の天井裏に IoT 機器を設置し、データの収集を行った。その他の環境では、床面や椅子等の上に置いて収集した。この際、同じ環境では高さを合わせて機器の設置を行った。

表 3.1 は、実験環境についてまとめたものである。「サイズ」は各環境において収集したフロアの大きさを表す。「IoT 機器設置数」は各環境において BLE データを収集するために設置した IoT 機器の数を表す。「GPS 収集地点数」は各環境においてスマートフォンを用いて GPS データを収集した地点の数を表す。

本研究では、IoT 機器に Bluetooth (BLE) 電波送受信機を搭載した Raspberry Pi 3 を使用した。各 IoT 機器は、機器間の距離が 1.5m 以上は離れるよう設置した。各 IoT 機器は BLE 信号を周囲に発信するとともに、他の IoT 機器からの BLE 信号を収集する。BLE 信号は約 100ms 間隔で送信し、BLE 信号強度、BD アドレス、時刻のデータを収集する。安定した信号強度を用いるため、10 分間の平均信号強度を用いる。

また本研究では、各環境の各地点において、Nexus 6P を用いて静止した状態で約 1 分間 GPS と BLE データの収集を行った。その際、収集地点の座標を記録し、その座標を正確座標とする。収集地点において、窓から 1m 以内の地点を正解のアンカーポイントとして扱い、どの方位の壁面上にあるかのラベル付けを行った。2 地点間の距離は、各座標間のユークリッド距離を正解データとして用いる。GPS 衛星情報は NMEA 0183 と呼ばれる規格で扱う。1 秒ごとにデータを収集し、GPS 衛星ごとの衛星番号 (PRN)、衛星仰角、衛星方位角、信号強度 (S/N 比=C/No) を取得した。

本研究では、各環境の外形のマップ情報は事前に与えられているものとしているため、各環境において、サイズ、形状、壁面の方位に関する情報をマップデータから取得している。

3.2 評価方法

「leave-one-environment-out」交差検定を用いて評価を

^{*2} 大阪大学共創イノベーション棟:オフィス棟

^{*3} 大阪大学コンベンションセンター:カンファレンスホール

^{*4} 大阪大学センテラスサロン:多目的ホール

表 1 実験環境の概要

環境	サイズ (縦 × 横)	IoT 機器 設置数	GPS 収集 地点数	IoT 機器 床面からの高さ
オフィスビル 1F	19.2 × 19.2m	13	87	2.6m (天井裏)
オフィスビル 2F	19.2 × 19.2m	11	81	2.6m (天井裏)
共創イノベーション棟 7F	26.8 × 17.5m	13	87	0.0m
コンベンションセンター 3F	37.6 × 31.9m	13	38	0.0m
センテラスサロン	22.2 × 26.2m	13	59	0.7m




図 6 全環境における絶対位置推定結果

行う。この交差検定では、1 環境で得られた GPS および BLE データをテストデータとして、残りの環境で得られたデータを学習データとして用いる。ただし、本研究ではオフィスビル 1F (2F) の推定の際には、オフィスビル 2F (1F) のデータは使用していない。これは、本研究では特定の環境に依存しない手法を目指すためである。

位置推定の評価指標として、推定位置と平均位置の平均・最大誤差 (ユークリッド距離)、距離推定の評価指標として、推定距離と正解距離の平均絶対誤差 (MAE) を用いる。

提案手法の有効性を検証するための比較手法として、最適化前の初期値を全て原点し、相対位置座標を維持せずに自由に座標の最適化を行う手法を用いた。

3.3 IoT 機器の絶対位置推定結果

図 6 に IoT 機器の絶対位置値推定結果を示す。環境「オ 1」はオフィスビル 1F, 「オ 2」はオフィスビル 2F, 「共」は共創イノベーション 7F, 「コ」はコンベンションセンター 3F, 「セ」はセンテラスサロンにおける結果をそれぞれ表す。

本研究では、それぞれの環境において、マップ座標系への変換・当てはめで用いるアンカーポイントを窓際判定の分類確率上位 5, 7, 10 件にした場合それぞれで評価を行い、最も精度の高い場合の結果を提案手法の結果とする。また、本提案手法では、最適化の際の重みは IoT 機器間の推定距離において、推定距離が 10m 未満の場合は 1.0, 10~15m の場合は 0.8, 15m 以上の場合は 0.6 に設定した。IoT 機器とアンカーポイント間の推定距離においては、IoT 機器間の推定距離の重みの 1/10, すなわち推定距離が 10m 未満の場合は 0.1, 10~15m の場合は 0.08, 15m 以上の場合は 0.06 に設定した。比較手法では、全ての重みが 1.0 と




図 7 オフィスビル 1F における絶対位置推定結果. IoT 機器の平均誤差 1.93m, 最大誤差 2.84m

設定されている。

図から全ての環境において比較手法よりも精度が向上していることが確認でき、初期値設定、重み設定、当てはめの際の回転等が有効であることがわかる。広い環境であるコンベンションセンターを除いて、全ての環境において平均位置誤差は約 2~3m 程度であり推定精度が高いことがわかる。本研究では IoT 機器として空調機器を想定しているが、一般的な空調機器は 4m 以上は離れており、特に空調機器と同様に天井裏に IoT 機器を設置したオフィスビル 1F, 2F では平均誤差 2m 程度、最大誤差 3~5m を実現しており、十分な精度を実現していると言える。事前にサイトサーベイを行う Wi-Fi を用いた位置推定手法の誤差も約 2~3m 程度であると言われており、事前にサイトサーベイを必要としない本提案手法は非常に高い精度を達成していると言える。

図 7 に例としてオフィスビル 1F における絶対位置推定結果をマップ上にプロットしたものを示す。赤色の点が IoT 機器の推定位置、青色の点が IoT 機器の正解位置、黄色の点がアンカーポイントの推定位置、紫色の点がアンカーポイントの実際の取得位置を表す。IoT 機器とアンカーポイントにはそれぞれ 1 番から通し番号が振られており、図の推定位置と正解位置の番号は対応している。

IoT 機器の相対的な位置座標は正解の位置座標をよく再現できており、IoT 機器の位置座標の入れ替わりは起こっておらず、正確な位置推定を実現できていることがわかる。アンカーポイントの推定結果を見ると、窓際判定によ

りほとんどの場所で窓際に近い点が選ばれていることがわかる。少し窓際から離れた 75 番がアンカーポイントと判別されているが、これは、そのポイントがある部屋には複数の大きな窓が存在しているため、マルチパスフェージング等により信号強度が通常よりも強く観測されたからであると考えられる。また、マップの左右の方向にはアンカーポイントが存在しない。これは、左側の壁面には窓が存在しない、かつ右の壁面側には建物が存在し、GPS 電波が大きく乱れているためである。

3.4 窓際判定結果

本節では窓際判定の結果について検証する。本研究では、窓際から 1m 以内の地点を窓際と定義し、分類確率 0.30 以上を満たす分類確率上位 5, 7, 10 件のポイントをアンカーポイントとして選択した場合を評価する。ただし、マップ座標系への当てはめを行うには、複数の異なる壁面のアンカーポイントが必要なため、分類確率上位 k 件を選択する際に特定の壁面のアンカーポイント数が $k/2$ 件より多くならないように選択する。

表 2 に各環境における窓際判定の正解率 (accuracy) を示す。表の括弧内は正解数と窓際判定数を表す。表からアンカーポイント数が 5, 7, 10 すべての場合で、5 環境の平均正解率が約 70% 程度と高い精度で推定できていることがわかる。

3.5 壁面分類結果

本節では壁面分類の結果について検証する。本提案手法では、実際に窓際でない点に関しては、壁面分類の正解が存在しないために考慮せず、窓際判定において正しく分類された地点のみに対して壁面分類結果を検証する。また、窓際判定と同様に窓際判定において分類確率 0.30 以上を満たす分類確率上位 5, 7, 10 件のアンカーポイントを選択した場合に対して検証する。

表 3 に各環境における壁面分類の正解率を示す。表の括弧内は正解数と正解の窓際判定数を表す。表から壁面分類においても表からアンカーポイント数が 5, 7, 10 すべての場合で、5 環境の平均正解率は 90% 以上と高い精度で推定できていることがわかる。

3.6 距離推定結果

本節では距離推定の結果について検証する。

表 4 から特にオフィスビル 1F, オフィスビル 2F, 共創イノベーション棟 7F における IoT 機器関連の平均絶対誤差は 2.0m 程度と非常に小さく、対象とする環境のデータを学習に使用しないにもかかわらず、高い精度で推定できていることがわかる。

一方、コンベンションセンター 3F とセンテラスサロンにおける結果が他の環境に比べて少し悪い。これは、環境

の大きさや障害物の有無、材質等の違いによる信号強度の減衰率の違いが主な原因である。コンベンションセンター 3F やセンテラスサロンは、環境が広く遮蔽物も少ないため、天井裏に設置したオフィスビルの環境に比べて、信号の減衰率が少なく、距離が実際よりも短く推定されたと推測される。

4. 結論

4.1 本論文のまとめ

本研究では、導入コストの低い環境非依存の新たな屋内 IoT 位置推定手法の提案を行った。既存の一般的な屋内位置推定手法は、あらかじめ屋内環境のサイトサーベイを行い、その環境の信号強度マップなどを作成しておく必要があるため、その導入コストは非常に大きい。そこで本研究では、モバイル端末の GPS および Bluetooth 電波送受信機を用いることで、事前のサイトサーベイの必要がなく、特定の環境に依存しない手法を提案した。

提案手法は、主に窓際判定、壁面分類、距離推定、位置推定の 4 ステップで構成される。窓際判定では、モバイル端末携帯者が環境内を歩き回った際にバックグラウンドで収集した GPS 衛星情報を用いて、モバイル端末が窓際に存在したタイミングを推定する。そして壁面分類において、モバイル端末が窓際に存在したタイミングにどの方位の壁面 (窓際) に居たのかを窓際判定と同様に GPS 衛星情報を用いて推定する。一方距離推定では、IoT 機器間の距離を各 IoT 機器が受信した他の機器からの BLE 信号強度を用いて推定を行う。位置推定では、アンカーポイントの位置、IoT 機器間の距離、IoT 機器とアンカーポイント間の距離の情報を用いて IoT 機器の位置を推定する。

本研究では、提案手法の有効性を検証するために 5 環境の実データを用いて評価を行った。評価実験から、全ての環境において比較手法よりも精度が向上していることが確認できた。特に、空調機器を想定して天井裏に IoT 機器を設置した環境においては、事前にサイトサーベイを行う Wi-Fi を用いた位置推定手法に匹敵する誤差 2m 程度の位置推定精度を達成した。

4.2 今後の研究課題

本研究では、環境に非依存の手法を提案したが、環境の違いによる信号強度の減衰率の違いが原因で、一部の環境では推定がうまくいかなかった。そのため本研究では、静止した場合の GPS データのみを用いてアンカーポイントを予測したが、今後の研究では、歩行時のデータも加えることで、端末の移動距離をもとに減衰率を調整することを検討している。また、本研究では位置推定の際に高さ方向は考慮しなかった。そこで今後の研究では、気圧センサを用いて、高さ方向を考慮した位置推定を行うことを検討している。

表 2 各環境における窓際判定の正解率 [%] (括弧内は正解数/窓際判定数)

分類確率 上位 k 件	オ 1	オ 2	共	コ	セ	平均
5	80.0 (4/5)	80.0 (4/5)	80.0 (4/5)	60.0 (3/5)	80.0 (4/5)	76.0
7	71.4 (5/7)	85.7 (6/7)	85.7 (6/7)	57.1 (4/7)	71.4 (5/7)	74.3
10	50.0 (5/10)	80.0 (8/10)	80.0 (8/10)	55.6 (5/9)	70.0 (7/10)	67.1

表 3 各環境における壁面分類の正解率 [%] (括弧内は正解数/正解の窓際判定数)

分類確率 上位 k 件	オ 1	オ 2	共	コ	セ	平均
5	100.0 (4/4)	100.0 (4/4)	100.0 (4/4)	100.0 (3/3)	100.0 (4/4)	100.0
7	100.0 (5/5)	100.0 (6/6)	83.3 (5/6)	100.0 (4/4)	100.0 (5/5)	96.7
10	100.0 (5/5)	87.5 (7/8)	87.5 (7/8)	100.0 (5/5)	85.7 (6/7)	92.1

表 4 各環境における距離推定結果 (MAE [m])

距離推定対象	オ 1	オ 2	共	コ	セ	平均
IoT 機器	1.94	2.01	2.15	2.72	3.36	2.44
IoT 機器 -アンカー間	1.76	1.91	2.77	3.83	4.49	2.95
アンカー間	3.98	3.37	4.47	2.14	6.19	4.03

謝辞 本研究を進めるにあたり、惜しみないご支援をいただきました大阪大学・Di-CHiLD 事務局の皆様深く御礼申し上げます。

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 2005*, pp. 116–133 (2005).
- [2] Wang, Y., Yang, X., Zhao, Y., Liu, Y. and Cuthbert, L.: Bluetooth positioning using RSSI and triangulation methods, *IEEE Consumer Communications and Networking Conference (CCNC 2013)*, pp. 837–842 (2013).
- [3] Ni, L. M., Liu, Y., Lau, Y. C. and Patil, A. P.: LAND-MARC: indoor location sensing using active RFID, *Proceedings of the First IEEE International Conference on Pervasive Computing and Communications, 2003. (PerCom 2003)*, pp. 407–415 (online), DOI: 10.1109/PERCOM.2003.1192765 (2003).
- [4] Ingram, S. J., Harmer, D. and Quinlan, M.: Ultra-WideBand indoor positioning systems and their use in emergencies, *PLANS 2004. Position Location and Navigation Symposium (IEEE Cat. No.04CH37556)*, pp. 706–715 (online), DOI: 10.1109/PLANS.2004.1309063 (2004).
- [5] Krumm, J., Cermak, G. and Horvitz, E.: Rightspot: A novel sense of location for a smart personal object, *UbiComp 2003*, pp. 36–43 (2003).
- [6] Want, R., Hopper, A., Falcão, V. and Gibbons, J.: The active badge location system, *ACM Transactions on Information Systems (TOIS)*, Vol. 10, No. 1, pp. 91–102 (1992).
- [7] Priyantha, N. B., Chakraborty, A. and Balakrishnan, H.: The cricket location-support system, *MobiCom 2000*, pp. 32–43 (2000).
- [8] Grand, E. L. and Thrun, S.: 3-Axis magnetic field mapping and fusion for indoor localization, *2012 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI)*, pp. 358–364 (online), DOI: 10.1109/MFI.2012.6343024 (2012).
- [9] Liu, H., Darabi, H., Banerjee, P. and Liu, J.: Survey of wireless indoor positioning techniques and systems, *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, Vol. 37, No. 6, pp. 1067–1080 (2007).
- [10] Gu, Y., Lo, A. and Niemegeers, I.: A survey of indoor positioning systems for wireless personal networks, *IEEE Communications Surveys & Tutorials*, Vol. 11, No. 1, pp. 13–32 (2009).
- [11] Taniuchi, D. and Maekawa, T.: Automatic Update of Indoor Location Fingerprints with Pedestrian Dead Reckoning, *ACM Transactions on Embedded Computing Systems (TECS)*, Vol. 14, No. 2, pp. 27:1–27:23 (2015).
- [12] Chai, X. and Yang, Q.: Reducing the calibration effort for location estimation using unlabeled samples, *PerCom 2005*, pp. 95–104 (2005).
- [13] Pulkkinen, T., Roos, T. and Myllymäki, P.: Semi-supervised learning for WLAN positioning, *ICANN 2011*, pp. 355–362 (2011).
- [14] Breiman, L.: Random forests, *Machine learning*, Vol. 45, No. 1, pp. 5–32 (2001).
- [15] Nakatani, T., Maekawa, T., Shirakawa, M. and Hara, T.: Estimating the Physical Distance Between Two Locations with Wi-Fi Received Signal Strength Information Using Obstacle-aware Approach, *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 2, No. 3, pp. 130:1–130:26 (online), DOI: 10.1145/3264940 (2018).
- [16] He, K., Zhang, X., Ren, S. and Sun, J.: Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification, *CoRR*, Vol. abs/1502.01852 (online), available from <http://arxiv.org/abs/1502.01852> (2015).
- [17] Kingma, D. and Ba, J.: Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980* (2014).
- [18] Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R.: Dropout: a simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, Vol. 15, No. 1, pp. 1929–1958 (2014).
- [19] Ioffe, S. and Szegedy, C.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *CoRR*, Vol. abs/1502.03167 (online), available from <http://arxiv.org/abs/1502.03167> (2015).