

屋内における移動前後の位置指紋と相対位置に基づいて 構成された非線形回帰モデルを利用した位置推定

高山智史^{†1} 梅澤猛^{†1} 大澤範高^{†1}

概要：人の屋内位置推定の手法として、短時間デッドレコニングから得た人の移動による位置の相対変位と、相対変位の前後の複数観測地点で得た電波強度による位置指紋の2つのデータを特徴量とした手法を提案してきた。しかし、これまでの評価では既知の地点の位置指紋情報をもとに、判別分析を用いて位置を推定したため、既知の地点以外の推定は行えなかった。そこで、機械学習によって非線形回帰モデルを構築し、それから位置推定を行うことで、未知の地点に対しても推定が可能な手法を評価した。提案手法の評価として、11m×5mの室内に設置したBluetoothビーコン6個の電波強度を28地点で測定し、取得した位置指紋データに基づいてシミュレーション評価を行うことで、提案手法によって推定した位置の誤差および正答率を求めた。非線形モデルを用いた提案手法によって、単独の位置指紋による推定と比べて、推定誤差はSVM（サポートベクターマシン）で2.51mから2.34mに減少し、RF（ランダムフォレスト）では3.91mから0.80mに減少した。また許容誤差を0.5mとした際の正答率は、SVMで6.62%から13.5%に増加し、RFでは0.74%から66.6%に増加した。

キーワード：屋内位置推定, Bluetooth Low Energy, ビーコン, Support Vector Machine, Random Forest

Indoor Positioning based on Non-linear Regression Model with Location Fingerprints and Relative Position Offset before and after Move

TOMOFUMI TAKAYAMA^{†1} TAKESHI UMEZAWA^{†1} NORITAKA OSAWA^{†1}

1. はじめに

携帯端末を用いた屋内測位手法として、無線を用いた手法やデッドレコニングが利用されている。既存の無線ビーコンを用いた三角測量法では、一般に屋内環境ではマルチパスフェージングの影響を受けるため推定誤差が大きくなるという課題がある。また、デッドレコニングを単独で用いた場合には、移動距離が長くなると誤差の蓄積により推定誤差が大きくなるという課題がある。そこで本研究では、近傍にある複数地点において計測した電波強度と地点間の相対位置の2つを組み合わせた位置指紋に基づく位置推定手法を提案する。

近距離での移動に限定することでデッドレコニングの誤差蓄積を抑えることができ、既設ビーコンを活用して屋内のマルチパスフェージング影響下においても精度よく位置を推定できる位置指紋法と組み合わせることで、互いを補完し位置推定誤差を抑えることが可能であると考えられる。また、複数のビーコンからの電波強度を複数の地点で観測することで、単一地点の位置指紋よりも多くの特徴を持たせることができ、ビーコンの設置数を増やすことなく、推定誤差を抑えることが期待できる。

2. 関連研究

2.1 電波強度を用いた位置指紋法

位置指紋法は、マルチパスフェージングによる局所的なRSSI (Received Signal Strength Indicator) 値の増幅・減衰を、近接する観測点を判別するための特徴として扱うことができるため、特に屋内位置推定に有用であるとされる[1]。小柳らは、スプライン補間を用いることで、RSSI値を測定していない地点にもRSSI値を疑似的に算出して割り当て、未知の地点の推定も可能とする手法[2]を提案している。しかし、RSSI値の推定精度の検証に留まっており、実際に位置を推定した場合について検討が必要である。

また、久保田らは位置指紋を構成するRSSI値に着目し、RSSI値の平均値だけでなく最頻値も特徴量として採用している[3]。代表値により1つの位置指紋を構成してパターンマッチングを行うのではなく、ある1地点において、各ビーコンからの強い相関を示すRSSI値を取得し、それら全ての組み合わせを考慮することで複数の位置指紋を1地点に割り当てている。1地点あたりの特徴量である位置指紋を増やすことで、ビーコンの設置数を抑えつつ、推定誤差の抑制に成功している。

そこで本研究では、特徴量を増やすために相関ではなく、複数地点で観測したRSSI値と観測地点の相対位置を用いることで特徴量を増やし、スプライン補間ではなく非線形

^{†1} 千葉大学大学院融合科学研究科
Graduate School of Advanced Integration Science, Chiba University.

回帰モデルを用いることで AP の数を増やすことなく推定精度の向上を目指す。

2.2 デッドレコニング

デッドレコニングには、測位対象区域に新たなインフラを設置する必要がないという長所がある。また携帯端末をユーザの腰部等、重心に近い部位に固定できる場合には、ユーザの進行方向を精度よく推定することができる。しかし、測定距離と測定時間の増加とともに、累積誤差が指数関数状に増加することが確認されている[4]。また、歩行者デッドレコニング (PDR) においては、単にセンサ値から変位を求めるのではなく、ユーザの歩幅と歩数を推定する事で累積誤差の影響を除く手法も検討されているが、衣服や路面状況の違いによりユーザの歩幅の大きさが変化し、推定誤差が大きくなるという課題がある[5]。そこで本研究では、デッドレコニングを短時間のみに限定することで累積誤差の影響を抑える。

3. 提案手法

推定対象区域に M 個のビーコン $B_m (1 \leq m \leq M)$ が設置されているとき、提案手法による位置の推定は事前計測フェーズとモデル構築フェーズ、推定フェーズの 3 段階で行う。

3.1 事前計測フェーズ

計測者は、あらかじめ座標がわかっている観測地点集合 $L = \{L_i | 1 \leq i \leq N\}$ の各点において、携帯端末で受信可能な全ビーコンからの電波の受信信号強度を示す RSSI 値を計測し、受信した複数ビーコンの RSSI 値を要素とするベクトルを収集する。ある地点で計測した B_m の RSSI 値を R_m とすると位置指紋ベクトルは $\mathbf{s} = (R_1, \dots, R_M)$ と表すことができる。地点 L_i において観測した位置指紋ベクトルを \mathbf{s}_i とするとき、地点 L_i で K 回の観測を行ったときの $k (1 \leq k \leq K)$ 回目の観測における位置指紋ベクトルを $\mathbf{s}_{i,k}$ とすると、 L_i におけるすべての観測によって位置指紋集合 $S_i = \{\mathbf{s}_{i,1} \dots \mathbf{s}_{i,K}\}$ を得ることができる。

3.2 モデル構築フェーズ

事前計測フェーズでの観測データから非線形回帰モデルを作成する。地点 P で観測した位置指紋 \mathbf{s}_P と、そこから相対距離 $\mathbf{d}_{PQ} = (d_x, d_y)$ 離れた地点 Q で観測した位置指紋 \mathbf{s}_Q を組み合わせた合成位置指紋 $\mathbf{s}_{PQ} = (\mathbf{s}_P, \mathbf{s}_Q, \mathbf{d}_{PQ})$ を考える (図 1)。これらすべての観測データの組み合わせに対し、合成位置指紋集合 $S_{PQ} = \{\mathbf{s}_{PQ} | P \in L, Q \in L\}$ を基に、回帰モデルを構築する。その際各座標に対し、座標値を目的変数、合成位置指紋 \mathbf{s}_{PQ} を説明変数ベクトルとするモデルを構築する。3 地点以上の位置指紋を合成する場合も、同様の手順でモデルを構築することができる。

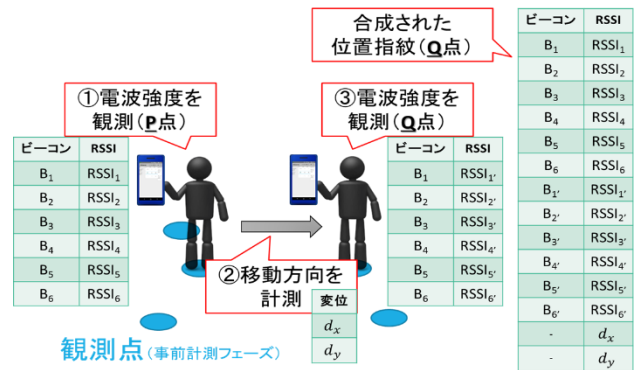


図 1 位置指紋合成のモデル

Figure 1 A model of composite location fingerprints.

3.3 推定フェーズ

推定者が持ち歩く携帯端末で、ある地点およびそこから短時の移動した地点の位置指紋を観測する。また、その移動前後の相対変位をデッドレコニングにより推定する。取得したデータからなる合成位置指紋をモデル構築フェーズで構築した推定モデルに適用する事で各座標を推定する。

4. 評価実験

提案手法の有効性を検証するために、実際にビーコンからの RSSI 値を計測し観測点とすることで、屋内の位置を推定した。対象区域は鉄筋コンクリート造り、11m×5m の研究室で、通行人などの移動する障害物は排除した。計測者の影響を排除するためにビーコンは天井に、受信端末はキャスター付きのポールを使用して床面から 185cm の高さに固定して計測を行った。使用したビーコンは Estimote Beacon, 受信端末は Android 5.1 を搭載した Nexus 7 (2013) である。

4.1 推定誤差の評価方法

本稿では、単一地点の位置指紋のみを利用した従来の位置推定 (従来手法) と、2 地点の位置指紋とその相対変位を利用した提案手法 (提案手法) による位置推定誤差の評価を行う。事前観測フェーズにおいて実際に観測した座標と、回帰モデルから推定された座標との距離を位置推定誤差とする。従来手法においても回帰モデルによる評価を行う。

4.2 実験方法

事前計測フェーズでは、Bluetooth ビーコン計 6 個を部屋の四隅及び長辺の midpoint の計 6 ヶ所に配置し、推定対象区域を 1m 間隔の格子状に等間隔に区切った格子の交点 28 地点で RSSI 値の計測を行った (図 2)。この際、大きな障害物のある地点や、部屋の構造上観測不可能な地点は除いた。1 つの観測地点あたり RSSI 値を 10 回計測した。RSSI 値が計測できなかった場合は推定に影響を与えない定数値として -200 を用いた。これは実験全体において観測された

RSSI 値における最小値が-107 であり、この範囲を大きく下回る値を選んだためである。観測地点の座標表現として、本実験では図 2 のように部屋の短辺を x 軸、長辺を y 軸と設定し、ビーコン番号②の設置位置を原点とした。

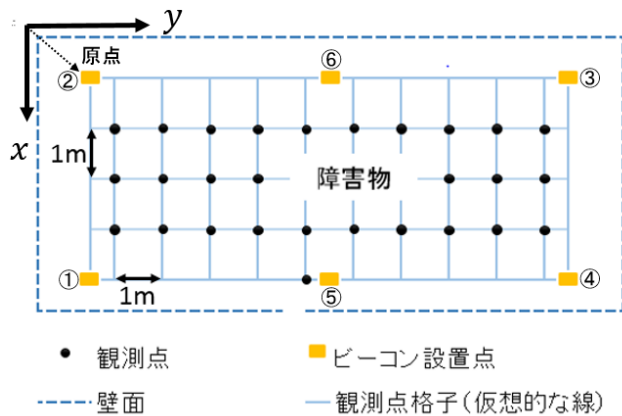


図 2 実験環境と観測点格子

Figure 2 Experiment environment and observation points

モデル構築フェーズでは、下記に示す条件 B を除いて、計測した位置指紋データ 272 件を 3.2 節で述べた P 地点と Q 地点それぞれのデータとし、その 2 つと相対変位を組み合わせた合成位置指紋 73984 件から成る集合を生成した。この合成位置指紋集合を 2 組に分け、機械学習の訓練データとテストデータとし、訓練データを基に回帰モデルを構築した。条件 B では、上記の合成位置指紋のうち 2m 格子の交点上のデータ 26112 件を既知の地点とする訓練データとし、残りの地点のデータ 47872 件を未知の地点とするテストデータとし、同様に回帰モデルを構築した。モデル構築にはサポートベクターマシン (SVM)、およびランダムフォレスト (RF) による回帰分析を利用した。SVM では、非線形カーネルを用いたサポートベクトル回帰 (SVR) によって ϵ を 0.01, σ を 16 に設定しモデルを構築した。RF では、チューニングにより個々の木のサイズの最適値を求めて決定木の数 500 本でモデルを構築した。

推定フェーズとして、モデル構築フェーズで構築した回帰モデルにテストデータを適用する事で、位置推定誤差および正答率を算出した。その際、推定結果と正答値との差が許容誤差以下であれば正答とした。

4.3 実験条件

実験条件の一覧を表 1 実験条件に示す。

4.3.1 条件 A

提案手法の推定精度を評価するため、ビーコン 6 個を用いて観測した 1m 格子ごとの位置指紋データを利用した際の正答率と RMS 誤差 (平均二乗誤差) を評価した (条件 A-1)。また、2 点間の相対変位が位置推定結果に及ぼす影響を調査するため、相対変位の距離ごとの RMS 誤差の変化を評価した (条件 A-2)。

4.3.2 条件 B

提案手法では回帰モデルを用いているため、未知の地点の推定を可能とする特徴を持つ。そこで 2m 格子の交点のみのデータを用いたモデルを用意し、格子の中点を推定することによって、未知の地点の推定の検証を行う (条件 B)。観測点データのうち、2m 格子の交点上の観測点データのみを用いて合成位置指紋集合を構成し、その半数を訓練データとして構築された 2m 格子モデルから訓練データに使わなかった 2m 格子の合成位置指紋データおよびその 2m 格子の中間点の 1m 格子のテストデータを用いて精度を評価した。

4.3.3 条件 C

提案手法に位置指紋法を用いるメリットとして、ビーコンを適切な位置に設置することによるコスト削減が見込まれる。その可能性を検証するために位置指紋に利用するビーコン数を減らした場合 (条件 C) について評価した。条件 C-1, C-2 では、ビーコンを 1 つ取り除いた場合の推定を行った。部屋の対称性から、部屋の長辺の中点のビーコンを 1 つ除いた場合 (条件 C-1) と、部屋の角のビーコンを 1 つ除いた場合 (条件 C-2) をそれぞれ評価した。さらに、上記の実験から推定に影響の少ないビーコンの位置を考慮し、ビーコン番号①から順に⑤までビーコンの数を徐々に減らしていった場合 (条件 C-3) を検証した。

表 1 実験条件

Table 1 Experimental conditions

項番	実験項目	使用したビーコン数	モデルの格子幅	評価指標
A	提案手法の有効性の評価			
A-1	└ 従来手法との比較	6個	1m	累積正答率 RMS誤差
A-2	└ 相対変位の推定誤差に対する影響	6個	1m	RMS誤差
B	未知の地点の推定	6個	2m	累積正答率 RMS誤差
C	ビーコン数削減			
C-1	└ 部屋の長辺の中点のビーコン	5個	1m	累積正答率 RMS誤差
C-2	└ 部屋の角のビーコン	5個	1m	累積正答率 RMS誤差
C-3	└ ビーコンを徐々に削減	1~6個	1m	累積正答率 RMS誤差

4.4 実験結果


4.4.1 条件 A

従来手法と比較した、ビーコン 6 個を用いて 1m 格子ごとに観測したデータを推定した場合 (条件 A-1) の SVM と RF における許容誤差に対する累積正答率の変化を図 3 に示す。正答率の差が比較的大きく出現した許容誤差 0.5m における累積正答率は、従来手法に比べ、 x 座標では SVM で 26.3pp (パーセントポイント) 向上し 52.4%, RF で 57.6pp 向上し 84.9%, y 座標では SVM で 13.7pp 向上し 25.5%, RF で 72.9pp 向上し 79.2% となった。最良の正答率を得た RF

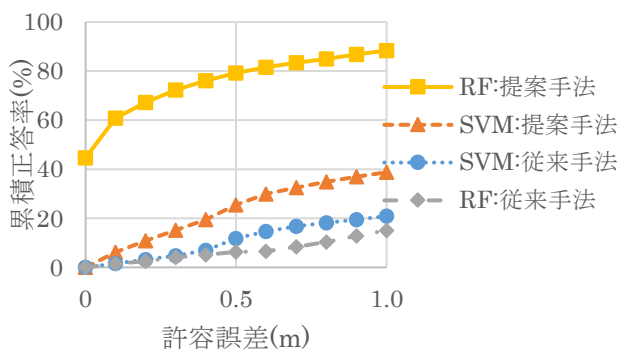
による提案手法において、 x 座標での正答率は許容誤差 0.5m で 84.9%，許容誤差 1.0m で 97.3%， y 座標での正答率は許容誤差 0.5m で 79.2%，許容誤差 1.0m で 88.4% となった。

また、提案手法を用いた推定結果と正答値との総合的なずれを表した RMS 誤差を図 4 に示す。従来手法に比べ、SVM による提案手法において、 x 座標では 0.20m 低減し 0.69m， y 座標では 0.10m 低減し 2.24m， x 座標と y 座標を組み合わせた座標値全体では 0.16m 低減し 2.35m となった。RF による提案手法において、 x 座標では 0.54m 低減し 0.36m， y 座標では 3.08m 低減し 0.71m，座標値全体では 3.11m 低減し 0.80m となった。

さらに、条件 A-1 の実験結果のうち、変位に対する RMS 誤差の変化（条件 A-2）を図 5 に示す。変位のない 0m においては、 x 座標では、SVM で 0.80m，RF では 0.50m となり、 y 座標では、SVM で 2.58m，RF で 0.51m となった。



(i) x 座標



(ii) y 座標

図 3 許容誤差に対する累積正答率の変化 (条件 A-1)
Figure 図 3 Cumulative accuracy rates (Condition A-1)





図 4 RMS 誤差 (条件 A-1)

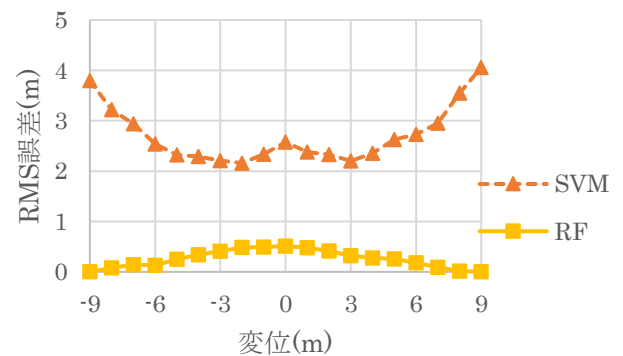
Figure 図 4 RMS errors (Condition A-1)

4.4.2 条件 B

2m 格子を利用した訓練データと同じ地点のテストデータを用いた場合（既知の地点の推定）と、訓練データには含まれない地点のテストデータを用いた場合（未知の地点の推定）の許容誤差ごとの累積正答率の変化を図 6 に示す。既知の地点に比べ、未知の地点では、許容誤差 0.5m において、 x 座標では、SVM で 21.6pp 大きい 41.2%，RF で 27pp 小さい 71.7% となった。 y 座標では、SVM で 20.0pp 小さい 4.15%，RF で 79pp 小さい 20.6% となった。



(i) x 座標



(ii) y 座標

図 5 変位に対する RMS 誤差の変化 (条件 A-2)

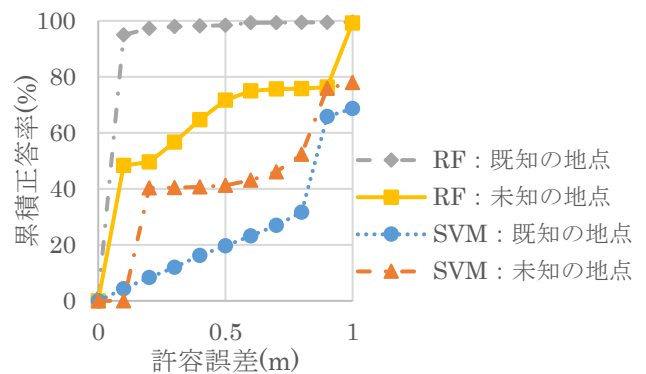
Figure 図 5 RMS errors (Condition A-2).

また、未知の地点を推定した場合と、既知の地点を推定した場合の RMS 誤差を図 7 に示す。既知の地点に比べ、未知の地点では、SVM において、 x 座標では 0.06m 大きい 0.80m、 y 座標では 0.51m 大きい 2.98m、 x 座標と y 座標を組み合わせた座標値全体では 0.47m 大きい 3.09m となった。RF による提案手法において、 x 座標では 0.39m 大きい 0.52m、 y 座標では 1.47m 大きい 1.54m、座標値全体では 1.47m 大きい 1.62m となった。

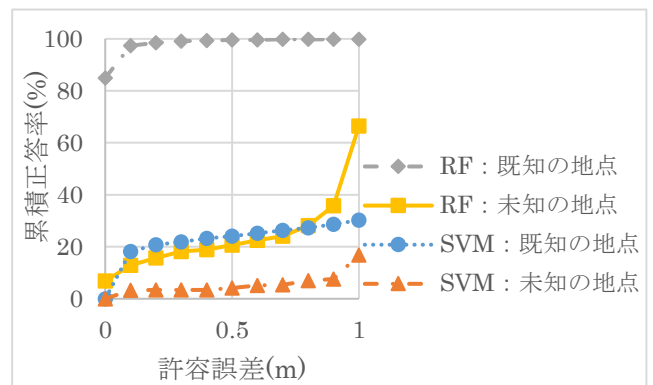
4.4.3 条件 C

条件 C として、推定に使用するビーコンを取り除いた場合の推定を行った。まず、提案手法において、ビーコンを 1 つ取り除いたビーコン 5 個を用いて推定した場合（条件 C-1, C-2）の許容誤差ごとの累積正答率の変化を図 8 に示す。グラフには比較として、ビーコン 6 個を用いて推定した際の提案手法の結果を一緒に載せている。ビーコン 6 個を用いた推定に比べ、部屋の長辺の中点のビーコンを除いた場合は、許容誤差 0.5m において、 x 座標では、SVM で 10.3pp 増加し 62.7%，RF で 3.28pp 減少し 81.6% となった。 y 座標では、SVM で 6.26pp 増加し 31.8%，RF で 3.63pp 減少し 75.6% となった。また、部屋の角のビーコンを除いた場合には、ビーコン 6 個を用いた推定に比べ、 x 座標では、SVM で 7.33pp 増加し 59.7%，RF で 2.09pp 増加し 87.0% となった。 y 座標では、SVM で 8.49pp 増加し 34.0%，RF で 0.78pp 減少し 78.4% となった。

また、部屋の長辺の中点のビーコンを除いた場合と、部屋の角のビーコンを除いた場合の RMS 誤差を図 9 に示す。ビーコン 6 個を用いた場合（条件 A）に比べ、部屋の長辺の中点のビーコンを除いた場合では、SVM において、 x 座標では 0.07m 減少し 0.62m、 y 座標では 0.27m 減少し 1.97m、 x 座標と y 座標を組み合わせた座標値全体では 0.28m 減少し 2.07m となった。RF による提案手法において、 x 座標では 0.07m 増大し 0.43m、 y 座標では 0.18m 増大し 0.89m、座標値全体では 0.19m 増大し 0.98m となった。部屋の角のビーコンを除いた場合には、ビーコン 6 個を用いた場合に比べ、SVM において、 x 座標では 0.06m 減少し 0.63m、 y 座標では 0.37m 減少し 1.87m、 x 座標と y 座標を組み合わせた座標値全体では 0.37m 減少し 1.98m となった。RF による提案手法において、 x 座標では 0.01m 減少し 0.35m、 y 座標では 0.05m 減少し 0.66m、座標値全体では 0.05m 減少し 0.75m となった。



(i) x 座標



(ii) y 座標

図 6 訓練データの観測地点を減らした場合の累積正答率 (条件 B)

Figure 図 6 Cumulative accuracy rates (Condition B)


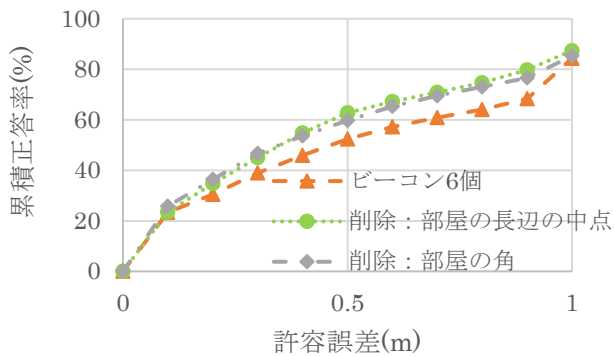



図 7 訓練データの観測地点を減らした場合の RMS 誤差 (条件 B)

Figure 図 7 RMS errors (Condition B)




(i) SVM : x座標



(ii) SVM : y座標




(iii) RF : x座標




(iv) RF : y座標

図 8 ビーコンを1つ取り除いたときの累積正答率 (条件 C-1, C-2)

Figure 8 Cumulative accuracy rates (Conditions C-1 and C-2)



(i) SVM




(ii) RF

図 9 ビーコンを1つ取り除いたときの RMS 誤差 (条件 C-1, C-2)


Figure 9 RMS errors (Conditions C-1 and C-2)

次に、先ほどの実験から得られた知見を基に、ビーコンの数を徐々に減らした場合 (条件 C-3) の許容誤差ごとの累積正答率の変化を図 10 に示す. 許容誤差 0.5m における累積正答率は, x座標で最も正答率が高かったのは RF によるビーコン 5 個を移用した推定で 86.9%, y座標では RF によるビーコン 4 個を利用した推定で 84.3% となった.


さらにビーコンの数を徐々に減らした場合の RMS 誤差を図 11 に示す. 最も良い結果となった RF によるビーコン 5 個を利用した推定では, x座標で 0.35m, y座標で 0.66m, 座標値全体では 0.75m となった.




(i) SVM : x座標



(ii) SVM : y座標




(iii) RF : x座標




(iv) RF : y座標

図 10 ビーコンを複数取り除いたときの累積正答率 (条件 C-3)

Figure 図 10 Cumulative accuracy rates (Condition C-3)



(i) SVM



(ii) RF

図 11 ビーコンを複数取り除いたときの RMS 誤差 (条件 C-3)

Figure 図 11 RMS errors (Condition C-3)

4.5 考察

4.5.1 従来手法との比較

図 3 から、2 地点の位置指紋を用いた提案手法では、単一地点の位置指紋を用いた従来手法と比較して正答率が向上していることがわかる。回帰分析による推定では、特に RF の正答率の改善が顕著に現れている。特に許容誤差 1m においては、x 座標、y 座標どちらも正答率約 90% を示しており、従来の推定精度を大きく上回る結果となった。図 4 から RF を用いた場合に RMS 誤差が大きく抑えられており、正答値とのずれが総合的に低減できていることがわかる。これは、訓練データやテストデータに部屋の構造に基づく欠損値があることと、RF の欠損値やノイズに強い特徴が上手く合致したためであると考えられる。しかし、後述する、モデル構築に使っていない地点データを使うと誤差が大きくなることから、RF で過学習が生じているのではないかと考えられる。また、x 座標の累積正答率の増加が y 座標に比べて大きいのは、今回の実験で利用した x 座標の範囲が、y 座標の範囲の半分以下であり、同じデータ数を割り振ったときに単位長あたりのデータ量が異なってしまったためであると考えられる。

図 5 を見ると、変位の絶対値が大きくなるにつれ、SVM

では RMS 誤差が次第に大きくなっているが、RF では逆に RMS 誤差が徐々に小さくなっている。変位ごとの RMS 誤差を抑えることに成功したことが、SVM に比べ、RF を用いた場合の正答率が勝っていた要因の 1 つであったと考えられる。

逆に今後より多くのデータによって検証すべき点として、 y 座標の RF を用いた提案手法における許容誤差 0m での値が 0% でない点があげられる。学習データとテストデータで同じ位置指紋ベクトルはなかったが、類似性が影響した可能性も考えられるので、今後検証を行う必要がある。

4.5.2 訓練データの観測地点を減らした場合の推定

図 6 から特に RF では、モデル構築に利用した地点を推定した場合には正答率が 100% に近いが、モデル構築に利用しなかった地点の推定では誤差が大きくなっている。モデルが訓練データに沿い過ぎた、汎化性の低いものとなってしまったためにこのようなことが起こったと考えられ、過学習が生じているのではないかと考えられる。今後は学習木を少なくするなど、過学習を抑制できるようにした検証が必要である。また、5.4.1 項より、モデル構築に利用した地点の推定結果として、SVM による提案手法を用いた推定が、SVM と RF 両方の従来手法の推定結果を上回っていることから、2m 格子に対しても同様の結果が得られると考えられる。これを考慮すると、RF を用いたモデル構築に利用しなかった地点を推定した場合にも、SVM の推定結果と同程度かそれ以上の結果となったため、ビーコンを減らしたり、観測地点を減らした場合にも RF を用いた提案手法が有効であると考えられる。

モデル構築に利用しなかった地点の推定精度が、モデル構築に利用した地点の推定精度を下回ると予想していたが、 x 座標の SVM による推定では前者の推定精度が後者を上回る結果となった。原因として、ビーコンから離れた地点では電波伝搬損失の影響が大きく現れたためではないかと考えられるが、今後より多くのデータを用いて検証する必要がある。

4.5.3 ビーコン数を削減した際の推定

図 8 から、ビーコンを 1 個取り除いた場合でも、ほぼ同程度の精度で推定できていることが確認できる。図 9 から、最も推定誤差を抑えることができた RF による推定を見ると、部屋の角のビーコンを取り除く方が有効であると考えられる。また、SVM による x , y 座標の推定と RF による x 座標の推定では、ビーコンを 1 個取り除いた場合の推定が、ビーコンを 6 個使用した場合に比べ若干精度が上回る結果となった。このことからビーコンの数が多ければ精度が良くなるとは限らないと考えられる。

ビーコンの数がどの程度推定精度に影響を与えるかを調べたところ、図 10, 図 11 から、SVM による推定ではビーコンの数が少ないほど良い結果となり、2 個を利用した場合に最も良い数値を示した。RF による推定ではビーコンの

数がある程度あった方が良い結果となり、5 個を利用した場合に最も良い値を示した。また RF においては、座標値全体を見るとビーコンを 4 個以上設置した場合は一定の精度で安定しているのがわかる。これらから提案手法による推定では、SVM では部屋の長辺の midpoint 付近にビーコンを設置するのが最も適しているのではないかと考えられ、RF ではある程度ビーコンを設置するのが適していると考えられる。より適切なビーコンの設置場所の知見を得るために、異なる条件下での検証が今後の課題として挙げられる。

5. まとめ

本研究では、動経路上の複数地点において観測した位置指紋情報と、短時間デッドレコニングにより推定した観測点間の相対位置関係を基に位置推定を行う手法を提案した。2 地点での RSSI 値を利用した場合の有効性を検証し、許容誤差を 0.5m としたときの正答率では、既存手法と比較して、 x 座標では SVM で 26.3pp (パーセントポイント) 向上し 52.4%, RF で 57.6pp 向上し 84.9%, y 座標では SVM で 13.7pp 向上し 25.5%, RF で 72.9pp 向上し 79.2% となり提案手法の有効性が示された。また、訓練データの観測地点を減らした場合と、設置するビーコンを減らした場合にも精度が保てるかどうかをそれぞれ評価した結果、観測地点をある程度減らしたり、ビーコンをある程度減らしても精度の維持が可能という示唆が得られた。

実験全体を通して、RF による提案手法を用いた推定で、過学習によると思われる過度な精度向上が見られたことから、今後は過学習の影響の可能性を排除した条件で評価する必要がある。また、本稿では扱わなかった提案手法におけるデッドレコニング精度の影響について調査することも課題として挙げられる。

参考文献

- [1] 横田山都, 廣安知之, 三木光範, 横内久猛, 吉見真聡. WLAN の RSSI 分布を用いた室内位置推定手法の提案と利用. 第 24 回人工知能学会全国大会. no.3C2-2, pp.1-4.
- [2] 小柳健吾, 吉田博哉. 位置指紋法における電波強度マップ構築の効率化検討. 第 76 回全国大会講演論文集. 2014(1), pp.179-180.
- [3] 久保田真一郎, 石丸正人, 杉谷賢一. 相関ルールにより生成された FingerPrint を利用した無線 LAN 位置推定手法の検討. 情報処理学会研究報告 インターネットと運用技術 (IOT). vol.2013-IOT-20, no.39, pp.1-4.
- [4] 金岡諒, 柏木幸俊, 荒川豊, 戸辺義人. 屋内高精度位置測位に向けたデッドレコニングの累積誤差補正モデル. 情報処理学会第 77 回全国大会講演論文集. vol.2015, no.1, pp.293-294.
- [5] 三宅孝幸, 新井イスマイル. 時間帯と同行者の状況変化に追従した歩幅推定手法の提案と評価. 情報処理学会研究報告モバイルコンピューティングとユビキタス通信 (MBL). vol.2013-MBL-65.