

Wi-Fi RTT と機械学習を用いた位置推定の提案と評価

長沼 慶弥¹ 佐藤 文明^{1,a)}

受付日 2020年5月14日, 採録日 2020年11月5日

概要: 屋外の測位では一般的に GPS が利用されているが, 屋内では衛星からの電波が届かないため GPS による測位は難しい. そのため様々な屋内測位手法が研究されている. 無線 LAN を用いた測位では, 無線 LAN の電波強度をあらかじめ測定し, ベイズ推定で測位する試みがあるが, 電波の特性上精度に課題が残る. 一方で近年, 無線 LAN のラウンドトリップタイムを利用し, 1~2m 以内の精度で距離推定を可能とした IEEE802.11mc が標準化され, スマートフォンでも Android 9 以降から IEEE802.11mc が利用可能になってきた. 本研究では, 電波強度だけではなくアクセスポイントと端末の距離のデータを学習させ, 位置を推定する手法を提案し評価した. 実験では 3 機の無線 LAN アクセスポイントを用意し, 位置推定の評価方法として, ベイズ推定, サポートベクタマシン, k-近傍法を用い比較した. 実験の結果, 学習に電波強度と距離のデータを併用した場合は, それぞれを単独で学習に用いた場合の精度を上回ることを示した.

キーワード: 屋内測位, IEEE802.11mc, ベイズ推定, サポートベクタマシン, k-近傍法

A Proposal and Evaluation of Positioning Method Based on Wi-Fi RTT and Machine-learning

KEIYA NAGANUMA¹ FUMIAKI SATO^{1,a)}

Received: May 14, 2020, Accepted: November 5, 2020

Abstract: GPS is generally used for outdoor positioning, but indoor positioning by GPS is difficult because indoors do not receive radio waves from satellites. Therefore, various indoor positioning methods have been studied. In the position estimation using the wireless LAN, there is an attempt to use the Bayesian estimation by using the radio strength measured in advance, but there remains a problem in the accuracy of the radio wave. On the other hand, in recent years, IEEE802.11mc, which enables distance estimation with accuracy within 1-2m using round-trip time of wireless LAN have been standardized and available on Android 9. In this research, we proposed and evaluated a positioning method based on the machine-learning using not only the radio wave intensity but also the data of the distance between the access point and the terminal. In the experiment, three wireless LAN access points were prepared, and Bayesian estimation, support vector machine, and k-nearest neighbor method were used as the evaluation method for position estimation and comparison was performed. As a result of the experiment, it was shown that the combined use of the radio wave intensity and the distance data for learning exceeds the accuracy when each is used alone for learning.

Keywords: indoor positioning, IEEE802.11mc, bayesian estimation, support vector machine, k-nearest neighbor method

1. はじめに

近年, スマートフォンの普及によって, スマートフォンの位置情報を利用した様々なアプリケーションが提供され

ている. スマートフォンの位置情報を推定する技術としては, 屋外では GPS が標準的に利用されている. しかし, 屋内では GPS 衛星の電波が届かないため, GPS を用いない位置推定技術が提案されている.

Bluetooth ビーコンを用いた手法 [1] は, あらかじめ Bluetooth ビーコンの位置情報を決定しておいて, 端末がビーコンの電波を取得すると, その位置をインターネット経由

¹ 東邦大学
Toho University, Funabashi, Chiba 274-8510, Japan
^{a)} fsato@is.sci.toho-u.ac.jp

で取得するというものである。利用者が店舗に近づいた際に、店舗側からチラシを配信したりすることができる。しかし、自動搬送ロボットのような、より高い精度の位置情報を必要とするアプリケーションに用いることはできない。

AR (Augmented Reality) マーカを用いた位置推定 [2] では、マーカをカメラで撮影して認識すると、マーカを起点とした 3 次元座標系が構築できるため、カメラのマーカに対する位置情報が取得できる。比較的高い精度で位置情報を取得することができるが、マーカがカメラの画角に入るように、マーカの大きさや配置を調整する必要があり、手間がかかるという問題がある。

無線 LAN の電波強度から距離や角度を推定して位置を測定する方法も提案されている [3], [4]。特に、利用者の環境であらかじめ電波強度を測定しておいて、測位時に測定した電波強度と比較して最も整合性のあるポイントを計算する方法が提案されている [5]。また、近年機械学習を位置推定に用いる研究も行われている [6], [7], [8], [9], [10]。これらの研究では、事前に定義された参照地点の電波強度 (RSSI) をあらかじめ測定し機械学習に利用する。そして新しく観測された RSSI から、機械学習アルゴリズムを使って位置を推定するものである。機械学習のアルゴリズムには、決定木 [11], k-近傍 [12], ベイズ推定 [13], サポートベクタマシン [14], ランダムフォレスト [15] などが適用されている。しかし、従来の機械学習を用いた研究の多くは電波強度のみで行われていることが多い。そして、電波が複雑な経路で到達する屋内では、同程度の電波強度を持つ地点が複数生じることがあるため、電波強度のみで推定することには限界がある。

一方で、無線 LAN のアクセスポイントまでの距離をラウンドトリップタイム (RTT) で推定する技術 IEEE802.11mc が標準化された [16]。そして、アクセスポイントや端末で IEEE802.11mc が実装されるようになり、位置推定に利用する研究も出てきた [17], [18]。しかし、RTT による距離推定は、ある程度電波の伝搬時間がかかる数十 m 程度の距離では精度も良く安定しているが、10 m 以下の距離では誤差が大きくなり、不安定である。文献 [17] では、MDS (多次元尺度構成法) により誤差を減らして位置推定に適用しているが、電波強度による測位と同程度の精度にとどまっている。

本研究は、RTT によって推定された無線 LAN のアクセスポイントからの端末までの距離と、アクセスポイントからの電波強度を取得し、機械学習によって位置を推定する方法を提案する。電波強度は、アクセスポイントに近い場所では精度が高いが、距離が離れるとマルチパスなどの影響で精度が落ちる。一方で、RTT はアクセスポイントがある程度距離が離れているほうが安定しているという性質がある。これらを組み合わせることで、精度の高い位置推定を目標とする。機械学習に用いるアルゴリズムには、ベ

イズ推定、サポートベクタマシン、k-近傍法を用い、精度の比較を行った。実験の結果、電波強度と RTT による推定距離を両方用いた方法は、それぞれ単独で用いた方法より精度が向上することが分かった。

以下、2 章では関連研究、技術について述べる。3 章では、本研究で提案する手法について述べる。4 章では、評価実験の結果と考察について述べる。5 章は本論文のまとめである。

2. 関連研究

2.1 無線 LAN を用いた位置推定

(1) 三角測量・三辺測量に基づく測位

三角測量は、座標が求まっている 2 点を利用し、対象の座標と既知の 2 点でできる三角形の辺の長さを測り、対象の座標を求める方法である。また既知である基準点が 2 点以上で方向を用いて位置推定を行う方法を Angulation [3], 3 点以上の点で距離を用いて位置を推定する方法を Lateration [4] と呼ぶ。図 1 は Lateration を示す。

(2) シーンアナリシス

シーンアナリシス法 [5] とは、位置推定を行う際、事前に特定の場所とシーンを学習させ、構築された学習データを用いて位置推定を行う手法である。

無線 LAN で利用する場合、各アクセスポイントからの電波強度をそれぞれの測定ポイントで観測し記録していく。図 2 では、16 点の観測ポイントにおいて、各アクセ

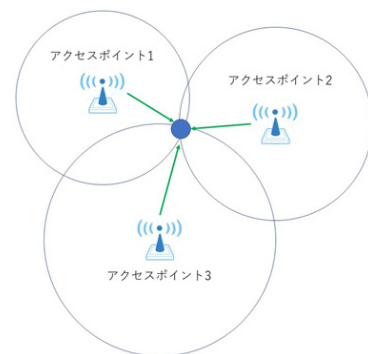


図 1 Lateration 法
Fig. 1 Lateration method.




図 2 シーンアナリシス法
Fig. 2 Scene analysis method.

スポットからの電波強度を測定し、記録する。次に、実際に位置を推定する際、16点のうち、推定したい地点で各アクセスポイントの電波強度を観測し、学習用データと比較することで位置を推定する。また、観測地点と観測地点との間の、事前観測していない位置を推定する際は、無線LANの距離特性を用いて補完させる。

2.2 ベイズ推定を用いた位置推定

伊藤らの研究 [6] では、2.1 節 (1) と (2) の手法を併用し、ベイズの定理を用いて位置推定を行っている。アクセスポイント (AP) と端末が受信する電波強度は位置により変化することを考慮している。位置推定を行う段階として、最初に各地点でシーンを観測し学習させる Survey Phase、次に、位置推定を行う Estimation Phase に分かれている。

Survey Phase では、観測の集合を O とし、各観測 o は、端末が各 AP から観測した電波強度 α と AP の BSSID β の組で構成される (n は AP の数、 m は観測回数)。

$$O = \{o_1, o_2, \dots, o_m\} \quad (1)$$

$$o = \{(\alpha_1, \beta_1), \dots, (\alpha_i, \beta_i), \dots, (\alpha_n, \beta_n)\} \\ i = 1, \dots, n \quad (2)$$

端末の推定候補状態の集合を C とし、端末は C のいずれかに存在すると仮定する。 c は端末の座標 x, y の組である (l は推定対象の数)。

$$C = \{c_1, c_2, \dots, c_l\} \quad (3)$$

$$c_j = (x_j, y_j) \quad j = 1, 2, \dots, l \quad (4)$$

(1), (2) から確率分布は以下の式になる。

$$P(\alpha | \beta, c_j) = \frac{\text{状態 } c_j \text{ で } \beta \text{ から } \alpha \text{ が観測された回数}}{\text{状態 } c_j \text{ で } \beta \text{ が観測された回数}} \quad (5)$$

Estimation Phase では、Survey Phase とは別に AP からのシーンを観測し AP の集合として記録する。このとき、ある地点での受信した電波強度の平均 $aveapv$ を計算し、閾値を設け、閾値の最小 $THmin$ と最大 $THmax$ の範囲にある電波強度の平均値をテストデータ R とする。

$$R = \{r: r \in AP, THmax > aveapv > THmin\} \quad (6)$$

次に確率生成モデルと c_j の事後確率を以下の式に示す。

$$P(o | c_j) = \prod_{i=1}^n P(\alpha_i | \beta_i, c_j) \quad (7)$$

$$P(c_j | o_1, \dots, o_m) = \frac{\prod_{k=1}^m P(O_k | c_j)}{\sum_{t=1}^l \prod_{k=1}^m P(O_k | C_t)} \quad (8)$$

式 (7), (8) を用いて計算し、最も確率が高い位置を端末の推定位置とする。実験は図 3 のように廊下で位置推定を実施している。各観測地点との距離は 1m である。

しかし、この研究では、電波強度におけるフェージングが発生した場合、精度が劣化してしまうという課題がある。




図 3 文献 [6] の実験環境
Fig. 3 Experiment environment of Ref. [6].

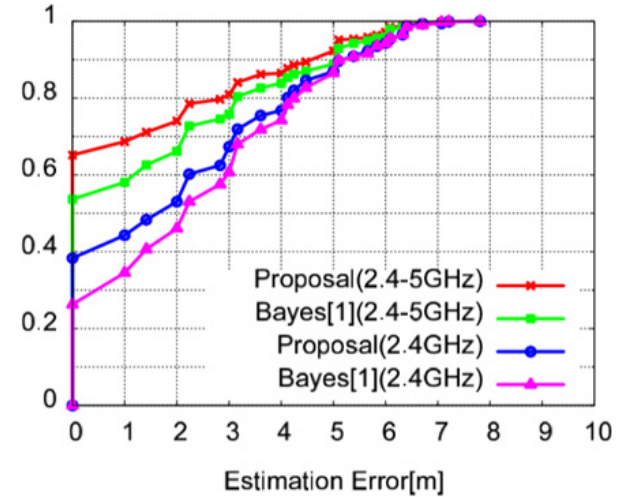


図 4 文献 [7] の端末特性を考慮した位置推定結果
Fig. 4 Position estimation result considering terminal characteristics of Ref. [7].

2.3 端末特性を考慮した位置推定

石原らの研究 [7] では、文献 [6] で行われた研究の課題であるフェージングに対応することを目的としている。事前観測時に、式 (1) のほかに、電波 β_1 以外の電波 β_i の電波強度 α_i ($\neq \alpha_1$) の比を $\gamma_i = \alpha_i - \alpha_1$ と定め、以下の式で計算する。

$$P(\gamma_i | \beta_1, \beta_i, c_j) \\ = \frac{\text{地点 } c_j \text{ で } \gamma_i \text{ を観測した回数}}{\text{地点 } c_j \text{ で電波 } \beta_1 \text{ と } \beta_i \text{ を同時に観測した回数}} \quad (9)$$

また、確率的生成モデルは式 (5), 式 (9) から以下の式 (10) のようになる。ここで d_k は、観測したデータ o_k のうち、電波強度が -80 dBm を下回った場合、テストデータから除外したデータ構成になっている。

$$P(d_k | c_j) \\ = \prod_{i=1}^n P(\alpha_i | \beta_i, C_j) \cdot \prod_{i=1}^n P(r_i | \beta_1, \beta_i, C_j) \quad (10)$$

電波強度の比を用いることで、文献 [5] で行われた研究結果より、精度が高くなることを示した。図 4 は、横軸が推定誤差であり、縦軸は実験結果の累積出現確率である。電波強度の比を用いた場合とそうでない場合、また 1 種類の周波数を用いた場合と 2 種類の周波数を用いた場合で、計 4 種類の評価を行っている。2 種類の周波数を用いた場合で、電波強度の比を用いた提案方式は最も良い結果となっ




図 5 FTM シーケンス
Fig. 5 FTM sequence.

ている。しかし、2m の推定誤差を見込んでも、80%以下の出現確率にとどまっている。たとえば、屋内で部屋の前までナビゲーションをしようとする場合、電波強度による位置推定ではまだ十分な精度が得られていない。

2.4 Wi-Fi RTT (Round Trip Time)

ここでは、本研究で利用する無線 LAN 規格である IEEE802.11mc の概要を述べる。

IEEE802.11mc は、アクセスポイントと端末の距離を計測する FTM (Fine Timing Measurement) が用いられている。この技術は、高解像度で時刻を記録する機構が必要であるが、近年安価で高精度なタイマが開発されたことから、実用化された。

FTM のメッセージシーケンスを図 5 に示す。処理の流れは以下ようになる [8]。

1. 端末より FTM を開始するため FTM Request (Fine Timing Measurement Request frame) をアクセスポイントに投げる。
2. アクセスポイントは、リクエストを受け取ると、端末に Ack を返す。通常 10 ms 以内に、FTM (Fine Timing Measurement frame) を、 $ToD = 0$ 、 $ToA = 0$ のパラメータで送信する。このとき FTM フレームを送信した時刻 $T = t1.1$ を記録する。時刻の単位は ps (ピコ秒) である。
3. 端末は、受け取った FTM フレームに対して、Ack を返し、フレームを受信した時刻 $T = t2.1$ と Ack 返信した時刻 $T = t3.1$ を記録する。
4. アクセスポイントは、Ack を受信し、その時刻 $T = t4.1$ を記録する。
5. アクセスポイントは、FTM フレームを $ToD = t1.1$ 、 $ToA = t4.1$ のパラメータで送信し、このときの時刻 $T = t2.1$ を記録する。

6. 端末は、FTM フレームに対して、Ack を返し、受信した時刻 $T = t2.2$ と、Ack を返信した時刻 $T = t4.2$ を記録する。

7. アクセスポイントは、Ack を受信し、その時刻 $T = t4.2$ を記録する。

1~7 のシーケンスが完了すると以下の計算により Round Trip Time (RTT) が求められる。

$$RTT = (t4.1 - t1.1) - (t3.1 - t2.1) \quad (11)$$

ここで、推定距離 D は、光速を c としたとき、以下の計算式で求まる。

$$D = RTT \times c/2 \quad (12)$$

なお、複数回 FTM フレームのやりとりが繰り返された場合、その平均をとる。なお、FTM は、 $t1$ 、 $t4$ を含むため、必ず 2 回以上に設定する必要がある。

3. 提案方式

3.1 目的とアプローチ

本研究では、2 章で述べたシーンアナリシス法に基づき、機械学習を利用することによって位置推定を行う。従来の、Wi-Fi-RTT による距離データあるいは電波強度を単体で用いるのに比べて、両者を併用して学習することにより、高精度な位置推定を可能とすることを目的とする。

機械学習の入力となる観測データ O は、先行研究と同様に定義する。

$$O = \{o_1, o_2, \dots, o_m\} \quad (13)$$

となる。ここで、 m は観測回数である。そして、1 つの観測データは、

$$o = \{(s_1, d_1), (s_2, d_2), \dots, (s_i, d_i), \dots, (s_n, d_n)\} \quad i = 1, \dots, n \quad (14)$$

ここで、 s_i は i 番目のアクセスポイントからの電波強度、 d_i は Wi-Fi-RTT による推定距離を表す。 n はアクセスポイント数である。

また、推定する位置は、

$$C = \{c_1, c_2, \dots, c_l\} \quad (15)$$

である。 l は推定位置の個数である。

これらの学習データをベイズ推定、サポートベクタマシン、k-近傍法による機械学習を使った位置推定アルゴリズムに適用し、精度を評価する。

3.2 本研究での位置推定手法

(1) ベイズ推定

本研究で用いたのは、ガウシアンナイーブベイズである。

ナイーブベイズ推定の確率モデルは、

$$\begin{aligned}
 P(c_i | o_1, o_2, \dots, o_m) &\propto P(c_i, o_1, o_2, \dots, o_m) \\
 &= P(c_i)P(o_1, o_2, \dots, o_m | c_i) = P(c_i) \prod_{n=1}^m P(o_n | c_i)
 \end{aligned}
 \tag{16}$$

となる。確率モデルから分類器は以下のように表す。

$$\begin{aligned}
 \hat{y} = \operatorname{argmax}_{i \in \{1, \dots, l\}} &\left[P(c_i) \prod_{n=1}^m P(o_n | c_i) \right] \\
 (\hat{y} = \{1, \dots, l\})
 \end{aligned}
 \tag{17}$$

ここで、 $P(o_n | c_i)$ は尤度、 $P(c_i)$ は事前確率である。この尤度について、統計的な分布を仮定するが、以下のガウス分布を用いる。

$$P(x_i | y_i) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_i - \mu_y)^2}{2\sigma_y^2}\right)
 \tag{18}$$

(2) サポートベクタマシン

サポートベクタマシンで用いた入力データは、ベイズ推定で用いた観測データと同様に、3台のアクセスポイントからの電波強度と推定距離としている。また、サポートベクタマシンは基本的には2クラスの分類に用いるアルゴリズムであるが、これを組み合わせて多クラスの分類に用いることができる。

組み合わせ方の1つとしては、One-versus-the-rest という、ある特定のクラスに入るか、他の $K - 1$ 個のクラスのどれかに入るかの2クラス分類問題を解く分類器を K 個利用する方法がある。また、One-versus-one というある特定のクラスに入るか、また別の特定のクラスに入るかの2クラス分類問題を解く分類器を $K(K - 1)/2$ 個利用する方法がある。Scikit-learn は内部的に One-versus-one を用いており、本研究でもこれを用いている。カーネルなどのパラメータは、特に変更せずデフォルトの設定で用いる。

(3) k-近傍法

観測データの周辺にある学習データで、ユークリッド距離が近い k 個の学習データの中で、最も多いクラスに分類する手法である。シンプルであり、計算速度が速い。

4. 評価実験

4.1 実験条件

3台のアクセスポイントを用意し、1m 間隔で設定された観測地点での各アクセスポイントからの電波強度と推定距離(シーン)をそれぞれ500回観測する。このうち、400件のデータは学習用データであり、残りの100件をテスト用データとした。テスト用データは、500件からランダムに選択されるようにした。シーン1回を観測する間隔は0.1秒とし、学習用に40秒、テスト用に10秒間分のデータを用いることとなる。こうして得られたデータを用い、機械学習によって位置を推定して精度を比較していく。

また、電波強度と推定距離のデータ取得は、Android 端末

表 1 実験機材

Table 1 Experimental equipment.

アクセスポイント	Google Wi-Fi × 3台 (IEEE802.11mc 対応、2.4GHz/5GHz デュアルバンド)
測定端末	Google Pixel3 × 1台 (Android バージョン 10)




図 6 実験環境

Fig. 6 Experiment environment.

のアプリケーションによって実施し、そのデータの平均化は行っていない。推定距離の取得は、Android の Wi-Fi-RTT の API を使っている。3台の無線 LAN のアクセスポイントは2.4GHz 帯のチャンネル 1, 6, 11 を用いている。表 1 に実験に用いた機材を示す。

本研究では、機械学習のデータ処理には、機械学習用ライブラリである Scikit-learn [19] を用いた。Scikit-learn は、様々な分類、回帰、クラスタリングアルゴリズムを備えたオープンソース機械学習ライブラリである。なお、サポートベクタマシンのハイパーパラメータでのチューニングは実施しておらず、Scikit-learn のデフォルトの値を用いた。Scikit-learn のデフォルトでは RBF カーネルを使用して、 $C = 1.0$, $\gamma = 1/\text{特徴数}$ となる。

本研究で想定するアプリケーションの1つとしては、屋内で展示物や研究室の入り口の位置などを識別して、適切な案内をするとともに解説などを提示する屋内ナビゲーションを考えている。したがって、誤差は1m 以内程度で測位できることが望ましい。

4.2 実験環境

測位実験の場所として、東邦大学習志野キャンパスの理学部3号館の講義室305で行った。図6は、観測地点、アクセスポイントを示し、観測を行う地点を地点0から地点41の42点とした。また、間隔は1mとし、講義室の寸法は幅約9.12m、横10.0mである。アクセスポイントを設置した高さは110cm、端末も同様に110cm。端末はつねに一定方向を向いた状態で観測を行う。端末を設置する角度については考慮しない。




図 7 RTT による推定距離 (1 から 10m)

Fig. 7 Estimated distance by RTT (1 to 10m).




図 8 RTT による推定距離 (10 から 20m)

Fig. 8 Estimated distance by RTT (10 to 20m).

また、アクセスポイントと観測地点との距離を最低でも 1.3m 離れた。アクセスポイントと観測地点との距離を置く必要については 4.3 節で説明する。

4.3 予備実験

測位実験を行う前に、Wi-Fi RTT の位置精度について調査を行った。図 7、図 8、図 9 はアクセスポイントと端末の距離を 1m から 80m まで、Wi-Fi - RTT で推定したものである。測定誤差とばらつきを見やすくするために、長距離、中距離、短距離での測定結果を分けて図示した。また予備実験では、アクセスポイントと端末との間には障害物はなく、アクセスポイントの高さは地面から 10cm、端末の位置は 120cm、アクセスポイントに対して、端末は背面を向けた状態で、端末の設置した角度については考慮しない。50m 以降の計測では、屋外でほぼ同様の条件で行った。

図の中の点線は、正解の値である。また、箱ひげ図のバーの上端から下端が測定データの範囲 (レンジ) であり、箱の上端は、測定結果の上位 25% の値、箱の中央線は上位




図 9 RTT による推定距離 (20 から 80m)

Fig. 9 Estimated distance by RTT (20 to 80m).

50% の値、箱の下端の線は下位 25% の値を示す。測定回数は 1 測定ポイントあたり 80 回である。

図 7 から図 9 が示すように、アクセスポイントと端末の距離が近い場合、測定結果にばらつきが大きくなり、精度が低い。一方でアクセスポイントから離れるほど、誤差の範囲が狭くなるのが分かる。よって、位置推定で Wi-Fi RTT を用いる際は、なるべく端末をアクセスポイントから遠ざける必要がある。図 7 よりマイナス値をとらない 2.5m 以上が理想である。本研究では、講義室の広さと観測点の数を考慮した結果、最低でも 1.3m の距離をとって行うこととした。

4.4 測位実験結果

(1) 機械学習による測位評価と比較

評価方法は、機械学習によって推定された地点の正しい推定割合と、実際の推定地点との距離を誤差として計算する。このようにして得られた結果から、正答率、平均誤差を算出し比較する。

図 10 と図 11 は位置推定に各地点あたり 100 件のテストデータで行った結果の正答率と平均推定誤差である。また、k-近傍法の k の値については RSSI (電波強度) と推定距離を学習に用いたときは $k = 1$ 、RSSI のみを学習に用いたときは $k = 42$ 、推定距離のみを学習に用いたときは $k = 3$ で行った。これらは 4.4 節 (2) で述べる k を変えた実験結果から適切と思われる値を用いている。

図 10 から、電波強度 RSSI と推定距離の両方を学習に利用した結果は、電波強度のみを学習に使った場合や、推定距離のみを学習に使った場合より高い精度で推定できることが分かる。

図 11 から、ベイズを用いた手法と k-近傍法を用いた手法は全体を通して、低い誤差であることが分かる。しかし、サポートベクタマシンでは推定距離のみを学習に使った場合の平均誤差を超える結果となった。これは、サポートベクタマシンのパラメータチューニングが不足している可能




図 10 正答率
Fig. 10 Correct estimation rate.




図 13 累積出現確率 (サポートベクタマシン)
Fig. 13 Cumulative probability (Support vector machine).

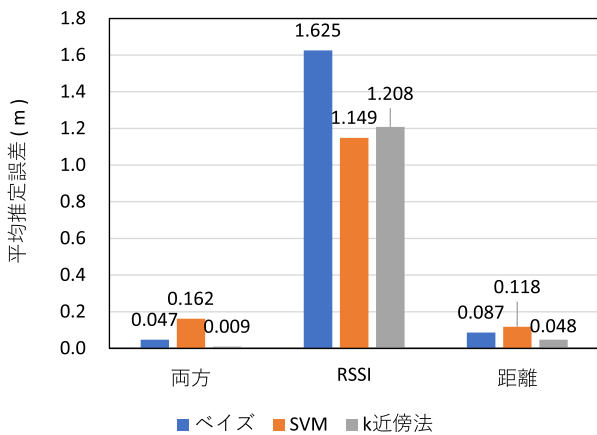


図 11 平均推定誤差
Fig. 11 Mean error distance.

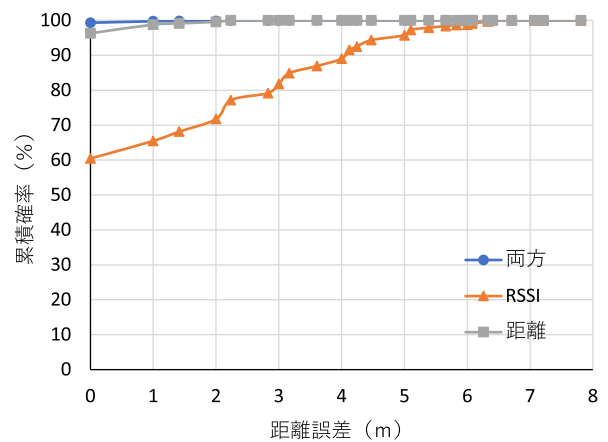


図 14 累積出現確率 (k-近傍法)
Fig. 14 Cumulative probability (k-nearest neighbor method).




図 12 累積出現確率 (ベイズ推定)
Fig. 12 Cumulative probability (Bayesian estimation).

性も考えられる。

また、図 12、図 13、図 14 に各機械学習で推定された地点と実際の地点との誤差と、累積出現確率を示す。累積出現確率とは、実験結果においてある誤差を許容したときの、実験結果が含まれる割合である。少ない誤差の範囲に多くの実験結果が含まれば、精度が高いことになる。

図 12 から図 14 では、電波強度と推定距離を併用した

学習が高い精度を持ち、実験結果の 95%以上は誤差 1m 以内に収まることが分かる。サポートベクタマシンについては、1m から 5m の誤差を許容した場合は、実験結果の出現確率が推定距離のみを用いた方法のほうがわずかに良くなっている。

(2) k の数値に関する評価

k -近傍法は、 k と評価用テストデータ量によって結果が異なる性質がある。評価用テストデータが少ない場合は、取得時間が短くて済むが、ノイズの影響が平均化されないため精度が低下することが予想される。一般に k を大きくすればノイズを軽減できるが、逆にクラス間の境界が明確にならず精度が低下することもある。したがって、適切な k を選定することは簡単ではなくヒューリスティクスが用いられる場合もあるが、今回は実験により決定する。図 15、図 16、図 17、図 18 は 1 地点あたり 100 件、50 件、20 件、10 件の評価用テストデータを用いたときの、 k と正答率の関係を示した。

図 15 から図 18 より、電波強度と推定距離を併用して学習した場合と、推定距離のみで学習した場合は、 k が増えるにつれて正答率が低下することが分かる。一方で電




図 15 k-近傍法の正答率 (評価用テストデータ 100 件/地点)
 Fig. 15 Correct estimation rate of k-nearest neighbor method (test data 100 items/point).




図 18 k-近傍法の正答率 (評価用テストデータ 10 件/地点)
 Fig. 18 Correct estimation rate of k-nearest neighbor method (test data 10 items/point).




図 16 k-近傍法の正答率 (評価用テストデータ 50 件/地点)
 Fig. 16 Correct estimation rate of k-nearest neighbor method (test data 50 items/point).




図 17 k-近傍法の正答率 (評価用テストデータ 20 件/地点)
 Fig. 17 Correct estimation rate of k-nearest neighbor method (test data 20 items/point).

波強度のみで学習した場合、ある程度 k の値が高くなければ精度が低い。特に評価用テストデータが 10 件/地点のとき、 k の数値が増加するにつれゆっくりと精度が上がっていることが分かる。したがって、電波強度のみによる測位

では、評価用テストデータが少ない場合 k-近傍法ではある程度大きい k を選択する必要がある。

5. まとめ

本研究では、IEEE802.11mc に基づくアクセスポイントからの推定距離と電波強度を使って機械学習によって位置推定を行う方法を提案し評価した。位置推定では、特定の地点の状態をあらかじめ学習し、観測データからどの地点かを推定するシーンアナリシス法を用いた。機械学習のアルゴリズムでは、ベイズ推定、サポートベクタマシン、k-近傍法を評価した。実験では 1m 間隔の 42 地点の観測点で評価した結果、正解率はベイズの手法では、約 96.7%、サポートベクタマシンでは、約 95.0%、k-近傍法では、約 99.3% という結果になった。これらは、電波強度やアクセスポイントからの推定距離を単独で学習に用いた場合に比べて高い精度となっており、提案手法の有効性が確認できた。一方で、平均誤差は、アクセスポイントからの推定距離と電波強度を使って機械学習アルゴリズムに k-近傍法を使った場合が最も小さかった。サポートベクタマシンについては、推定距離のみで学習した場合より併用した方式が大きくなった。

これらから、Wi-Fi RTT による推定距離と電波強度を併用した提案方式は、正解率と平均誤差において位置推定精度を向上させることができた。

また、k-近傍法において k と評価用テストデータのサイズを変えたときの測位精度への影響も評価した。評価用テストデータが少ないと、ノイズの影響が平均化されないため、精度が低下することが予想される。実験から、評価用テストデータが少ない場合、特にノイズが大きい RSSI のみによる測位では k の値を大きくすべきであることが分かった。

また、今回の実験はベイズもしくは k-近傍法による測位が優れていたが、サポートベクタマシンについては、パラ

メータを細かくチューニングすることで精度を向上させる余地があると考えられる。今後の課題として、サポートベクタマシンのパラメータのチューニングも行って評価していく。今回の実験では、42の地点で行い、その間隔は1mとした。しかし観測地点と観測地点との間の位置推定はできていない。今後の課題として、任意の中間点の位置推定を行う方法の検討がある。また、今回はアクセスポイントの数を3台として実験したが、先行研究ではより多くのアクセスポイントを使っている研究もある。アクセスポイントの台数を変えて評価することも今後の課題である。また、シーンアナリシス法の学習コストを軽減するために、誤差分布を考慮した学習方法の最適化も今後検討する。

謝辞 本研究の一部はJSPS科研費19H04101の助成を受けたものである。また、本研究の一部は東北大学電気通信研究所共同プロジェクト研究により実施されたものである。

参考文献

- [1] Liu, D. and Hsieh, C.: Study of Indoor exhibitions using BEACON's Mobile Navigation, *2018 IEEE International Conference on Advanced Manufacturing (ICAM)*, pp.335–337 (2018).
- [2] Sato, F. and Koshizen, T.: Electric Wheel Chair Control by AR Marker Detection and Object Recognition from Smartphone Image, *26th ITS World Congress, AP-TP1972* (Oct. 2019).
- [3] Iwasaki, Y., Kawaguchi, N. and Inagaki, Y.: Design, Implementation and Evaluations of a Direction Based: Service System for Both Indoor and Outdoor, *International Symposium on Ubiquitous Computing Systems (UCS2004)*, pp.7–14 (2004).
- [4] Shchekotov, M.: Indoor localization methods based on wi-fi lateration and signal strength data collection, *17th Conference of Open Innovations Association (FRUCT)*, pp.186–191 (2015).
- [5] Bahl, P. and Padmanabhan, V.N.: RADAR: An in-building RF-based user location and tracking system, *Proc. IEEE INFOCOM 2000 Conference on Computer Communications*, pp.775–784 (2000).
- [6] 伊藤誠悟, 河口信夫: アクセスポイントの選択を考慮したベイズ推定による無線LANハイブリッド位置推定手法とその応用, *電気学会論文誌C電子・情報・システム部門誌*, Vol.126, No.10, pp.1213–1222 (2006).
- [7] 石原拓哉, 内匠 逸, 打矢隆弘: 端末特性を考慮したベイズの定理による5GHz帯無線LAN位置推定に関する研究, *情報処理学会第75回全国大会* (2013).
- [8] Salamah, A.H., Tamazin, M., Sharkas, M.A. and Khedr, M.: An enhanced WiFi indoor localization system based on machine learning, *2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp.1–8, DOI: 10.1109/IPIN.2016.7743586 (2016).
- [9] Bozkurt, S., Elibol, G., Gunal, S. and Yayan, U.: A comparative study on machine learning algorithms for indoor positioning, *2015 International Symposium on Innovations in Intelligent Systems and Applications (INISTA)*, pp.1–8, DOI: 10.1109/INISTA.2015.7276725 (2015).
- [10] Nowicki, M. and Wietrzykowski, J.: Low-Effort Place Recognition with WiFi Fingerprints Using Deep Learning, *Automation 2017, ICA 2017, Advances in Intelligent Systems and Computing*, Szewczyk, R., Zieliński, C. and Kaliczyńska, M. (Eds.), Vol.550, Springer, Cham (2017).
- [11] Breiman, L., Friedman, J., Olshen, R. and Stone, C.: *Classification and Regression Trees*, Wadsworth Int. Group (1984).
- [12] Shakhnarovich, G., Darrell, T. and Indyk, P.: *Nearest-Neighbor Methods in Learning and Vision: Theory and Practice (Neural Information Processing)*, The MIT Press (2005).
- [13] 上田修功: ベイズ学習 [I] 統計的学習の基礎, *電子情報通信学会誌*, Vol.85, No.4, pp.265–271 (2002).
- [14] Tsochantaridis, I., Joachims, T., Hofmann, T. and Altun, Y.: Large Margin Methods for Structured and Interdependent Output Variables, *The Journal of Machine Learning Research*, Vol.6, No.9, pp.1453–1484 (2005).
- [15] Breiman, L.: Random forests, *Machine Learning*, 45, pp.5–32 (2001).
- [16] Malkos, S. and Andrew, H.: Enhanced WiFi Ranging with Round Trip Time (RTT) Measurements, *Proc. 27th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2014)*, pp.108–116 (2014).
- [17] Yan, S., Luo, H., Zhao, F., Shao, W., Li, Z. and Crivello, A.: Wi-Fi RTT based indoor positioning with dynamic weighted multidimensional scaling, *2019 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp.1–8, DOI: 10.1109/IPIN.2019.8911783 (2019).
- [18] Jathe, N., Lütjen, M. and Freitag, M.: Indoor Positioning in Car Parks by using Wi-Fi Round-Trip-Time to support Finished Vehicle Logistics on Port Terminals, *IFAC-PapersOnLine*, Vol.52, No.13, pp.857–862 (2019).
- [19] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. and Duchesnay, E.: Scikit-learn: Machine Learning in Python, *Journal of Machine Learning Research*, Vol.12, pp.2825–2830 (2011).



長沼 慶弥

2019年東邦大学理学部情報科学科卒業。同年クオリカ株式会社入社。ネットワーク、分散システムの開発に従事。



佐藤 文明 (正会員)

1984年岩手大学工学部電気工学科卒業。1986年東北大学大学院工学研究科博士前期課程修了。同年三菱電機株式会社入社。1995年より2005年まで静岡大学工学部および情報学部准教授，および教授。2005年10月より東

邦大学理学部教授，現在に至る。モバイルコンピューティング，アドホックネットワーク，P2Pコンピューティング，分散処理，通信ソフトウェアに関する研究に従事。博士（工学）。電子情報通信学会，IEEE，ACM各会員。