

LSTMを用いた大規模イベント向け BLE屋内位置推定手法の検討

浦野 健太^{1,a)} 廣井 慧¹ 米澤 拓郎¹ 河口 信夫^{1,2}

概要: 本稿では、移動する BLE タグからのパケットを環境内の複数のスキャナで受信し、受信信号強度をもとに行う BLE 屋内位置推定において、LSTM ベースのニューラルネットワークの利用を試みる。BLE による位置推定では、受信信号強度の不安定さが精度に影響を及ぼす。そこで、Fingerprint や三点測位に代わり、ニューラルネットワークの利用が試みられている。オートエンコーダを利用した受信信号強度のデノイジングや、対応デバイスや周波数が類似する Wi-Fi では CSI を学習させるなどが行われ、精度の改善が報告されている一方で、多数の人が介在する実環境への対応可能性は十分検証されていない。提案手法のニューラルネットワークは全結合層と LSTM 層からなり、受信信号強度の時系列を用いて BLE タグの位置を推定する。受信信号強度に生じるノイズやパケットロスへの対処を行えるよう、時系列を入力してその変化からの位置推定を試みる。ネットワークのトレーニング時は、単純なシミュレーションを用いて生成したデータでの学習の後、実環境で収集したデータで追加の学習を行う。精度評価では、ニューラルネットワークの層の構成を複数用意し、良いと思われる構成を探す。被験者以外に多くの参加者が場内を歩行していた大規模展示会での実験で収集したデータを用い、最も精度の良かった構成では 75 パーセントで誤差 2.44m となった。

Basic Study of BLE Indoor Location Estimation using LSTM for Large-scale Events

1. はじめに

人の位置情報・移動情報や興味関心に関する情報は、目的地までのナビゲーション・適切なタイミングでの情報提示や、マーケティング情報の収集のために重要である。中でも展示会や博覧会などのイベントにおける、来場者がどのブースを訪れたか・会場内をどう移動したかなどの情報は、ブース配置の最適化や、今後のイベントにおけるターゲット層の設定などに利用できる。これらの情報の収集には、来場者の位置を継続してトラッキングする必要がある。

しかし、屋内で開催されるこれらのイベントでは、屋外で一般に利用される GPS は信号が減衰するため精度良く位置を取得できない。そこで、様々な種類の屋内位置推定手法が提案されている [1], [2]。我々はその中でも Bluetooth

Low Energy (BLE) 技術に注目してきた。低消費電力で長期間の動作が可能な BLE 機器の利用で、位置推定に必要な機材のコストを抑えられる。我々は来場者に BLE タグを配布し、会場に設置した BLE スキャナで BLE パケットを収集するデザインを用いて、来場者は受付で BLE タグを受け取るだけでよい位置推定に取り組んできた。位置推定自体は三点測位ベースのアルゴリズムで行ってきた。

BLE を用いた位置推定の取り組みで問題となったのは、不安定な受信信号強度であった。これまで、その対処としてソフトウェア面ではパラメータによって挙動を調整可能にし、ハードウェア面ではタンデム BLE スキャナを構築して高精度化を図ってきた [3]。一方で、Wi-Fi を利用した位置推定では、事前に電波環境のマップを作る Fingerprint が多く用いられてきた [4] が、さらなる高精度化とノイズ耐性の獲得のため、ディープラーニングを用いた手法が提案されている。デノイジングオートエンコーダと既存手法を組み合わせる手法 [5] や、ニューラルネットワークの重みを利用する手法 [6] などがあるが、いずれも精度の改善

¹ 名古屋大学大学院工学研究科
Graduate School of Engineering, Nagoya University

² 名古屋大学未来社会創造機構
Institutes of Innovation for Future Society, Nagoya University

^{a)} vrano@ucl.nuee.nagoya-u.ac.jp

が報告されている。

本稿では、ディープラーニングを用いて BLE 位置推定を行えないかを検討する。今回は、入力として受信信号強度の時系列を与え、位置を出力するエンド・ツー・エンドのニューラルネットワークを考える。これにより、ニューラルネットワークと既存手法を組み合わせた際の、双方のパラメータ調整が不要となり、ニューラルネットワークの学習のみで位置推定までを行える。ニューラルネットワークの構成には様々なものが想定される。本稿では、ノイズ除去・欠損値の補完や、時系列の特徴の検出のために、全結合層・ReLU層・Dropout層からなるユニットと LSTM[7]層を用いるニューラルネットワークを構築する。前段ユニットと LSTM 層の数はそれぞれ可変として、層の数を変化させて位置推定精度を比較し、どのネットワーク構成がより適しているかを調べる。

すでに提案されているディープラーニングベースの位置推定では、研究室環境や大学の建物での精度評価がされている一方、多くの人が移動している展示会環境で利用可能かは十分検証されていない。そこで、構築したニューラルネットワークの精度評価には、実際の展示会で取得したデータを用いる。しかし、学習データの不足が考えられるため、単純なシミュレーションを用いて初期の学習を行う。距離から計算した受信信号強度にノイズを追加して学習データとする。その後、実際の展示会である G 空間 EXPO2016 で取得した実験データの一部を用いて追加の学習を行い、同実験データのうち精度評価用のデータで位置推定精度を評価する。

2. 関連研究

屋内位置推定手法は、加速度センサやジャイロセンサなどの内界センサ [8] を利用するもの、カメラやレーザスキャナ [9] を利用するもの、超音波 [10] や、RFID [11] や FM [12] などの電波を利用するものなどがあり、それぞれ機材の価格や位置推定精度などが異なる。中でも電波を利用した屋内位置推定手法は、RFID や UWB などの専用機材を用いるものや、Wi-Fi や BLE などスマートフォンや IoT 機器が単体で利用できる通信規格を応用するものなどがある。

ここでは、Wi-Fi もしくは BLE を用いる屋内位置推定手法について、推定アルゴリズム別に紹介する。一般にこれらの位置推定手法では、複数の送受信機（例えばビル内の複数の Wi-Fi 基地局と、人が持つスマートフォン）でパケットをやり取りし、到達までの時間や、受信信号強度をもとに対象の位置を推定する。

2.1 近接度

近接度方式では、最も強い受信信号強度を観測した基地局の設置位置をもとに位置を推定する。この方式では、対象と基地局がごく近く、十分強い信号が観測できるときに

高精度に推定を行える。一方で、基地局が近くにない場合は位置推定ができないため、細かい位置推定の実現には高密度な基地局の設置が必要となる。

Komai ら [13] は BLE タグを利用する位置推定にこの方式を適用し、介護施設において入居者がどの部屋にいるかを推定している。百瀬ら [14] は BLE タグからの近接度に加え、加速度センサ・地磁気センサなどのセンサやマップマッチング、パーティクルフィルタなど複数の手法を組み合わせて高精度な位置推定を行っている。

2.2 時間・距離・方向計算

時間・距離・方向計算方式では、信号の飛行時間や到達時間差、飛来方向、受信信号強度などから対象の位置を推定する。信号の到達時間や時間差の算出は高精度な時刻同期のもとで行われる。また飛来方向の推定には指向性アンテナやアンテナアレイが利用される。飛行時間や飛来方向から推定を行う手法としては、一部の Wi-Fi 機器で利用可能な Channel State Information (CSI)[15] を利用する SpotFi[16] がある。

受信信号強度から位置を推定する際は、距離と信号強度の減衰関係をモデル化して行う。しばしば用いられる三点測位方式では、3つ以上の基地局からの推定距離に基づいて位置を推定する。Wang ら [17] は Bluetooth を利用して位置推定を行っている。しかし、受信信号強度は送受信間に存在する遮蔽物や人体などによってノイズが生じるため、推定距離にも誤差が生じ最終的な推定位置に影響する。

2.3 Fingerprint

Fingerprint 方式は環境中の障害物・天井・壁などによる信号の減衰・反射への対応を行うために利用される。この方式は学習フェーズと推定フェーズに分かれており、学習フェーズでは環境の各点において、観測可能な基地局や基地局の信号強度などを測定しておき、参照用の Fingerprint を作成する。推定フェーズでは、実際に得られた観測可能基地局や信号強度を、学習フェーズで作成した Fingerprint と比較して位置を推定する。この方式では、様々な Fingerprint の表現や、Fingerprint とのマッチング方法が提案 [4] されている。例えば Bahl らの RADAR[18] では、受信信号強度を Fingerprint として採用し、最近傍の点を探す。

この方式の欠点は、基地局の移動や、故障による交換など環境の変化が起きた際に正しく推定を行えないことである。そこで、Fingerprint を更新する手法 [19] も研究されている。

2.4 ディープラーニング

ディープラーニングを利用する場合は、ニューラルネットワークをノイズ除去や欠損値の補完などの信号強度の補正に利用して位置推定は既存の方式で行う、ニューラル

ネットワークの各ユニットの重みを Fingerprint として扱うなどのアプローチがある。Xiao ら [5] は BLE を用いた位置推定において、ノイズを除去するオートエンコーダ（デノイズングオートエンコーダ）を構成し、位置推定は kNN で行っている。Wang らの DeepFi[6] では、Wi-Fi の CSI を入力として、オートエンコーダを学習し、オートエンコーダの各層の重みを利用して位置推定を行っている。Abbas らは WiDeep[20] において、事前計測を行った点ごとに受信信号強度のデノイズングオートエンコーダを学習させている。推定では各オートエンコーダから入力した実際の信号強度と出力が近いものを探して推定位置の出力を行う。

2.5 既存手法との差異

既存の各手法は本稿が対象とする展示会環境での利用において、それぞれメリットとデメリットが存在する。近接度を用いる場合、特定地点への接近を検出するにはよいが、会場全域で位置推定を行うと、大量の基地局を設置しなければならない。時間・距離・方向の計算では、機材が複雑化する。三点測位は利用に必要なパラメータが少ない一方でパケットロスやノイズの影響を受けやすい。Fingerprint は精度を上げやすいが、展示会の短い準備期間では事前計測が難しい。

ディープラーニングを用いる場合でも、事前計測が困難な問題は同様で、学習に十分なデータを得られない。本稿では、この問題の緩和のために、簡単なシミュレーションで生成したデータを学習で利用する。シミュレーションデータでの学習後は実環境で取得したデータで追加の学習を行う。また既存手法と組み合わせると、ニューラルネットワークと既存手法双方のパラメータを調整する必要が生じるため、本稿ではニューラルネットワークに位置推定まで行わせることとした。

3. ニューラルネットワークの構成

すでに提案されているディープラーニングによる位置推定は、多くの人々が移動している展示会環境で利用可能かどうかは十分検証されていない。そこで今回は、実際にニューラルネットワークを構築して、展示会環境で取得したデータを用いて位置推定精度を検証する。位置推定の精度は、構築するニューラルネットワークの構成によって変化すると考えられるため、本稿では単純な構成から複雑な構成まで層の数を変化させて位置推定精度の変化を行う。

3.1 入出力データ

今回、入力として考えるのは、時刻 t においてスキャナ i が観測した受信信号強度 r_i^t の組 \mathbf{R}^t であり、 N 台のスキャナの場合式 (1) で示される。しかし、対象の位置と移動パターンに応じた特徴を捉えるためには、時系列を利用する




図 1: ネットワーク構成の検討

Fig. 1 Base architecture of the neural network

ほうがよいと考えた。そこで入力として、式 (2) で示される時刻 t_1 から t_2 までの \mathbf{R} を並べた $\mathbf{R}^{(t_1, t_2)}$ を入力とする。

$$\mathbf{R}^t = (r_1^t, r_2^t, \dots, r_N^t) \quad (1)$$

$$\mathbf{R}^{(t_1, t_2)} = \begin{pmatrix} r_1^{t_1} & r_2^{t_1} & \dots & r_N^{t_1} \\ r_1^{t_1+1} & r_2^{(t_1+1)} & \dots & r_N^{(t_1+1)} \\ \vdots & \vdots & \ddots & \vdots \\ r_1^{t_2} & r_2^{t_2} & \dots & r_N^{t_2} \end{pmatrix} \quad (2)$$

出力は、時刻 t における対象の推定位置 $\hat{\mathbf{P}}^t = (\hat{x}^t, \hat{y}^t)$ とする。つまり今回作成するニューラルネットワークは受信信号強度の時系列を受け取り、その最新の時間における位置を推定するエンド・ツー・エンドのニューラルネットワークとなる。

3.2 構成の検討

ニューラルネットワークは前処理から出力まで図 1 のような構造とする。前処理では、 $\mathbf{R}^{(t_1, t_2)}$ に対して欠損値の穴埋めと値のシフトを施す。具体的には欠損値を -100 で埋めた後、すべての値を $+90$ する。ニューラルネットワークは入力側に全結合層・ReLU 層・Dropout 層からなる前段ユニットを 0 個以上配置する。時系列に応じた特徴を捉えるため、LSTM 層を 1 つ以上配置し、その出力値を最後の全結合層で目的の形式にする。

ニューラルネットワークの前半部分には、欠損値の推定やデノイズングが期待される。後半の LSTM 層では、時系列からの特徴抽出が期待される。また前半・後半の層数については、実際の位置推定を行って精度良く推定できる層数を探すため、可変とした。

3.3 シミュレーションデータと実データを併用した学習

学習では、実環境で収集するデータ量を抑えるため、シミュレーションデータによる学習と実データでの学習の 2 ステージ構成とする。最初のステージでは、簡単な信号強度シミュレーションを行って生成した信号強度を用いて学習を行う。次のステージでは、実際に取得した信号強度を使って追加の学習を行う。

信号強度シミュレーションでは、対象となるエリアでラ

ランダムに取得した1点と、その点から距離10m以内の別なランダムな点を時刻 t_1 から t_2 の間に移動したと仮定して、各時刻 t での各スキャナとの距離 $\mathbf{d}^t = (d_1^t, d_2^t, \dots, d_N^t)$ から観測されるべき信号強度 \mathbf{R}^t を式(3)で計算する。式(3)における tx と n はそれぞれ送信パワーと減衰定数である。

その後、信号強度に加わるノイズとして、事前に決めた平均と分散を持つ正規分布に従う乱数 \mathbf{n}_N を加え、式(4)のような \mathbf{R}' を得る。さらに、パケットロスに相当する挙動として、入力された信号強度を事前に決めた確率に従って -100 とする関数 f_{loss} を通し、式(5)に例示するような \mathbf{R} を生成する。

$$\mathbf{R}^{t''} = tx - 10n \log_{10} \mathbf{d}^t \quad (3)$$

$$\mathbf{R}' = \mathbf{RSSI}'' + \mathbf{n}_N \quad (4)$$

$$\begin{aligned} \mathbf{R} &= f_{loss}(\mathbf{R}') \\ &= (-100, r_2^t, r_3^t, -100, -100, \dots, r_N^t) \end{aligned} \quad (5)$$

3.4 損失関数

位置推定するにあたって、損失関数を式(6)のように設定した。式中の w_m, w_c, w_r は各項に対する重みであり、関数 f_1 は平均二乗誤差を、 f_2 はコサイン類似度を、 f_3 はReLUをそれぞれ計算する。ただし式(7)および(8)で定義される PD と \widehat{PD} はそれぞれ \mathbf{P}^t と \mathbf{P}^{t-1} の間、 $\widehat{\mathbf{P}}^t$ と \mathbf{P}^{t-1} の間のユークリッド距離とする。

$$\begin{aligned} L(\widehat{\mathbf{P}}^t, \mathbf{P}^{t-1}, \mathbf{P}^t) &= w_m f_1(\widehat{\mathbf{P}}^t, \mathbf{P}^t) \\ &\quad + w_c PD(1 - f_2(\mathbf{P}^t - \mathbf{P}^{t-1}, \widehat{\mathbf{P}}^t - \mathbf{P}^{t-1})) \\ &\quad + w_r f_3(\widehat{PD} - PD) \end{aligned} \quad (6)$$

$$PD = \text{Distance}(\mathbf{P}^t, \mathbf{P}^{t-1}) \quad (7)$$

$$\widehat{PD} = \text{Distance}(\widehat{\mathbf{P}}^t, \mathbf{P}^{t-1}) \quad (8)$$

損失関数の各項の意味合いとしては、第一項は正解位置と推定位置との距離となる。第二項は $t-1$ から正解位置と推定位置がどの方向に動いたかをコサイン類似度で比較し、正解位置の移動距離に応じて重みを変化させる。これは、対象があまり移動していないときには多少移動方向を間違えても許容するが、大きな移動の際には方向を間違えないようにさせる効果を持つ。第三項は実際の移動距離より推定が飛躍する際のみ値が生じる。

4. 構成ごとの位置推定精度の比較

ネットワーク構成として、前半部分を0,1,2,3,4段、LSTM層を1,2層から組み合わせ合わせた合計10パターンの構成について、位置推定精度を比較する。前半部分の段数はどれだけ柔軟に欠損値の推定や信号強度の補正を行うかに対応




図2: 対象とする会場と、会場内のスキャナ配置

Fig. 2 Target area and scanners' location.

表1: ニューラルネットワークのパラメータ

Table 1 Parameters of network.

パラメータ	値	備考
入力時系列の長さ	10	(秒)
入力特徴数	38	スキャナ台数と同じ
Dropoutの確率	0.3	全Dropout層で共通
LSTM隠れ層の次元	64	
損失関数の重み	1, 10, 5	順に w_m, w_c, w_r
最適化法	Adagrad	

し、LSTM層の数は1層だと単なる時系列の変化を捉え、2層だと時系列が変化する度合いを捉える。前半の各全結合層は、入力された特徴数を2倍にして出力するように設定した。ニューラルネットワークのパラメータ類は表1に示す。また、ニューラルネットワークの実装はPyTorch 0.4.1で行った。

利用データ

日本科学未来館で開催されたG空間EXPO2016において我々が行った実験で得たデータを位置推定に利用する。G空間EXPOは地理空間情報の利用推進を目的として開催されており、2016年は3日間でのべ19138名が訪れた。実験ではのべ260名(関係者含む)の被験者に、BLEタグの入ったネームホルダを首から下げてもらい、正解位置取得用のUWBタグを取り付けたサンバイザーを着用してもらった状態で、自由に会場内を見てもらった。

対象となる会場、およびスキャナの配置は図2に示す。図において、番号付きの四角はスキャナの位置とその番号を表している。またスキャナ1から11は1台に複数のBluetoothアダプタを備えるタンデムBLEスキャナ[3]で、それ以外は1台に1つのアダプタを備える通常のスキャナである。このデータに合わせて、ニューラルネットの入力 \mathbf{R} のスキャナ台数は $N=38$ とした。

シミュレーションデータによる学習では、16万のデータを生成し、バッチサイズ100で20エポック学習を行った。シミュレーション時の \mathbf{R} 生成用パラメータは表2に示す。実際の実験データでの学習は、被験者のべ260名のうち、精度検証用のデータの被験者・取得日と重複しない20被験者分のデータからスライド幅1秒のスライド窓を用

表 2: シミュレーションのパラメータ

Table 2 Parameters of simulation.

パラメータ	値	備考
送信パワー t_x	-59	実際の BLE タグの設定値
減衰定数 att	2.0	信号はあまり反射せずに飛行
ノイズ n_N の平均	-5	
ノイズ n_N の標準偏差	4	
パケットロス率	0.85	全スキャナで共通

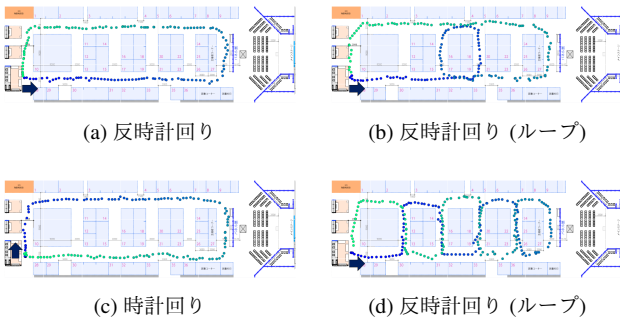


図 3: 精度検証用の経路

Fig. 3 Paths for testing.

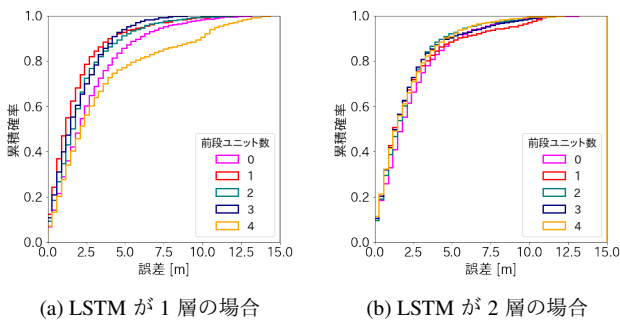


図 4: ネットワーク構成ごとの累積誤差分布

Fig. 4 Cumulative error distribution.

いて切り出した 7.8 万のデータを用いた。実際のデータでは、BLE タグが 10Hz でパケットを送信していたため、1 秒単位のデータにする際は 1 秒間での最大の受信信号強度を抽出する前処理を追加で行った。実際のデータでの学習はバッチサイズ 100 で 100 エポック行った。

実際の位置推定は、4 パターンの経路を歩いた 3 名の被験者のデータを用いて行った。経路は図 3 に示すとおりで、被験者はどの経路でも必ず図で左下に設置された実験受付から歩き、最後に実験受付に戻ってくる。

累積確率での評価

各ネットワーク構成における正解位置と推定位置の誤差を累積確率としてプロットしたものを図 4 に示す。図 4a は LSTM 層が 1 つのもの、図 4b は LSTM 層が 2 つのものにそれぞれ対応する。また、各ネットワーク構成で累積確率が 0.5, 0.75, 0.9 になったときの誤差を表 3 に示す。

図 4a では、前段ユニット数が 0 のときと 4 のときに性

表 3: 累積確率 0.5, 0.75, 0.9 の点での誤差

Table 3 Error at cumulative probability of 0.5, 0.75, 0.9

前段ユニット数	LSTM 層の数	各累積確率での誤差 [m]		
		P=0.5	p=0.75	p=0.9
0	1	2.19	3.83	6.15
1		1.30	2.44	4.26
2		1.80	2.88	4.94
3		1.60	3.07	4.39
4		2.36	4.59	10.1
0	2	1.87	3.37	5.70
1		1.48	2.97	5.70
2		1.66	2.93	4.62
3		1.51	2.85	4.95
4		1.56	3.02	4.83

能が劣っていた。最も良かったのは前段ユニット数が 1 のときであった。図 4b では、前段ユニットの数にかかわらずあまり性能は変化しなかった。この傾向は表 3 からわかる。表より前段ユニット数が 1 で、LSTM 層が 1 層の設定が累積確率 0.5, 0.75, 0.9 の各点において最も小さい誤差を達成した。次点で良かったのは前段ユニット数が 3 で、LSTM 層が 1 層のものであったが、前段ユニット数が 0 または 4 で LSTM 層が 1 層のものを除けばどのネットワーク構成にも精度に大きな差はない。したがってよりシンプルなモデルである、前段ユニット数が 1 で、LSTM 層が 1 層のネットワーク構成がよいと思われる。

実際のプロット・平均誤差での評価

正解位置と推定位置がどのように違うかを確認するため、推定誤差が小さかった (前段ユニット数, LSTM 層の数) = (1,1), (2,2) と、推定誤差が大きかった (4,1), (0,2) について、正解位置と推定位置を会場地図にプロットしたものを図 5 に示す。図内の各点は、橙色の点がニューラルネットワークの出力した点を、紫色の点が実際の被験者の位置を示す。

最も精度が良かった構成の推定結果を示す図 5a では、実際の経路からばらつきは生じるものの、推定点はおおむね経路に沿って分布している。一方前段ユニット数が 2 で LSTM 層が 2 層の場合の結果である図 5b では、図 5a と比較して実際の経路上に来る点が多いものの、推定点が集まっている場所が存在する。

精度が悪かった例の図 5c では、会場内左側の点が正解位置とは異なる場所に推定されていた。また、図 5d は最も精度が良かった図 5a と似たような出力となったものの、実験受付周辺で点が収束しなかった。

推定点がどれくらいばらついているかを調べるため、各ネットワーク構成において誤差の平均と標準偏差を調べると表 4 のようになった。表より、ほぼすべてのネットワーク構成で誤差の標準偏差が 2m を超えており、推定そのものがあまり安定していないことがわかった。安定した推定

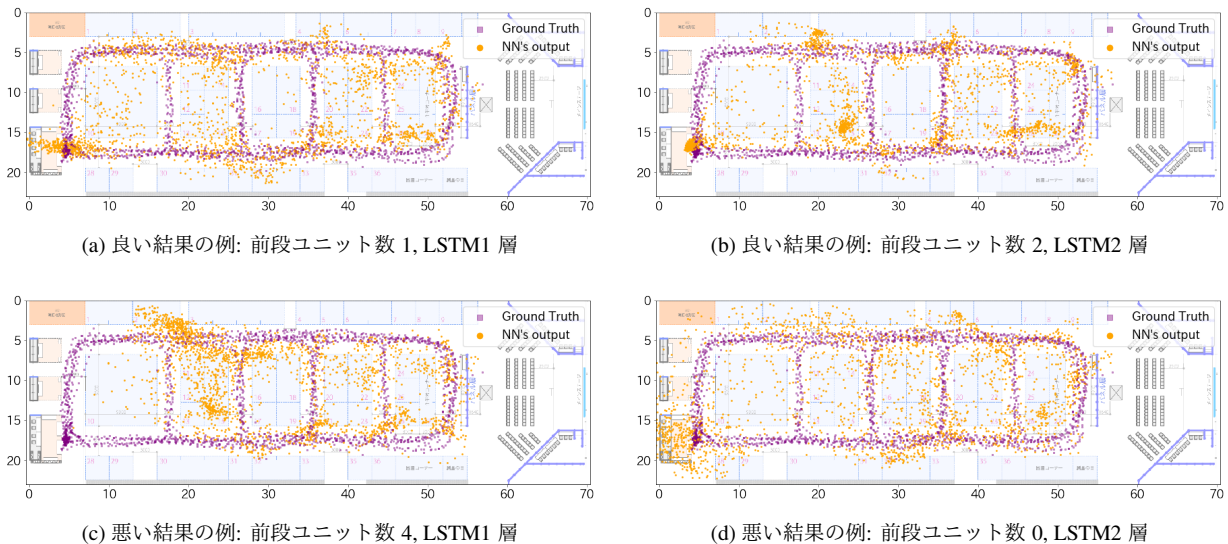


図 5: 推定点の分布

Fig. 5 Distribution of estimated points.

表 4: 誤差の平均と標準偏差

Table 4 Mean error and standard deviation of error.

前段ユニット数	LSTM 層の数	平均 [m]	標準偏差 [m]
0	1	2.83	2.47
1		1.94	2.05
2		2.27	2.05
3		2.07	1.74
4		3.62	3.52
0	2	2.53	2.38
1		2.39	2.56
2		2.20	2.11
3		2.22	2.27
4		2.20	2.19

表 5: 以前の手法との誤差の比較

Table 5 Comparison with [3].

手法	平均 [m]	標準偏差 [m]
三点測位ベース [3]	3.62	1.75
提案手法	1.94	2.05

を行うには、今回検討しなかった変更が必要と思われる。例えば LSTM 層の前の部分をデノイズングオートエンコーダ構造として、LSTM 層はノイズを取り除いて再構築された受信信号強度の系列で位置推定する、推定した受信信号強度も出力できるようにして損失関数の項として利用するなどである。

過去の推定結果との比較

我々が以前に提案した手法 [3] と手法の特徴、精度を比較した表を表 5 に示す。表より、提案手法は誤差の平均では改善しているものの、標準偏差が悪化している。これは以前に提案した手法ではパーティクルフィルタを利用し、1 秒前の推定位置の情報を利用して推定位置を安定させているためである。今回の提案手法では、ニューラルネットワークは受信信号強度の時系列を入力とするものの、前回の推定位置は直接利用していない。そこで、推定位置の系列に対してカルマンフィルタや平滑化などを適用するか、ニューラルネットワークの入力に前回の推定位置を加える

などの変更が必要だと思われる。

5. おわりに

本稿では、移動型 BLE タグと固定型 BLE スキャナを利用する BLE 屋内位置推定について、ニューラルネットワークによる位置推定を試みた。ニューラルネットワークは入力として各スキャナで観測した受信信号強度の時系列を受け取り、最新の時刻における推定位置を出力する。簡単な構成から複雑な構成までを変更して位置推定精度を比較するため、全結合層・ReLU 層・Dropout 層からなる前段ユニットと、LSTM 層を組み合わせる構成を基本に、それらの数を変更可能とした。構成パターンとして、前段ユニットは 0 から 4 段、LSTM 層は 1 層または 2 層の合計 10 パターンについて位置推定精度を比較した。学習では、実際の展示会環境で取得したデータだけでは十分でないと考えられたため、簡単なシミュレーションを用いて生成したデータも利用した。

推定結果では、一部の構成で明らかに精度が悪かったものの、ほぼすべてのネットワーク構成で平均 2m 程度の精度だとわかった。したがって、よりシンプルな構成である全結合層・LeRU 層・Dropout 層・LSTM 層・全結合層からなる構成で位置推定が行えるといえる。

一方で、ほぼすべての構成で正解位置と推定位置の誤差の標準偏差が 2m を超えており、安定して推定できているとはいえない。今後はオートエンコーダ構造を前半に採用

する, 受信信号強度も出力に加えて損失として利用するなどの工夫が必要である.

謝辞 本研究は G 空間 EXPO2016 屋内測位× IoT 実証実験実行委員会の協力, および JSPS 科研費 JP17H01762 の支援を受けたものです.

参考文献

- [1] 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).
- [2] Gu, Y., Lo, A. and Niemegeers, I.: A Survey of Indoor Positioning Systems for Wireless Personal Networks, *Communications Surveys & Tutorials, IEEE*, Vol. 11, No. 1, pp. 13–32 (2009).
- [3] 浦野健太, 廣井慧, 梶克彦, 河口信夫: 配布型 BLE タグとタンデムスキャナを用いた屋内位置推定手法, 情報処理学会論文誌, Vol. 60, No. 1, pp. 58–75 (2019).
- [4] He, S. and Chan, S.-H. G.: Wi-Fi Fingerprint-Based Indoor Positioning: Recent Advances and Comparisons, *IEEE Communications Surveys Tutorials*, Vol. 18, No. 1, pp. 466–490 (2016).
- [5] Xiao, C., Yang, D., Chen, Z. and Tan, G.: 3-D BLE Indoor Localization Based on Denoising Autoencoder, *IEEE Access*, Vol. 5, pp. 12751–12760 (2017).
- [6] Wang, X., Gao, L., Mao, S. and Pandey, S.: DeepFi: Deep Learning for Indoor Fingerprinting using Channel State Information, *IEEE Wireless Communications and Networking Conference (WCNC)*, pp. 1666–1671 (2015).
- [7] Hochreiter, S. and Schmidhuber, J.: Long Short-term Memory, *Neural Computation*, Vol. 9, pp. 1735–1780 (1997).
- [8] Beauregard, S. and Haas, H.: Pedestrian Dead Reckoning: A Basis for Personal Positioning, *3rd Workshop on Positioning, Navigation and Communication*, pp. 27–35 (2006).
- [9] 和田悠佑, 山口弘純, 東野輝夫: レーザレンジスキャナと Wi-Fi Fingerprint を併用した歩行者の位置推定手法の提案, 情報処理学会研究報告 (2013).
- [10] Hazas, M. and Hopper, A.: Broadband Ultrasonic Location Systems for Improved Indoor Positioning, *IEEE Transactions on Mobile Computing*, Vol. 5, No. 5, pp. 536–547 (2006).
- [11] Ni, L. M., Liu, Y., Lau, Y. C. and Patil, A. P.: LANDMARC: Indoor Location Sensing using Active RFID, *1st IEEE International Conference on Pervasive Computing and Communications (PerCom 2003)*, pp. 407–415 (2003).
- [12] Chen, Y., Lymberopoulos, D., Liu, J. and Priyantha, B.: FM-based Indoor Localization, *10th International Conference on Mobile Systems, Applications, and Services, MobiSys '12*, pp. 169–182 (2012).
- [13] Komai, K., Fujimoto, M., Arakawa, Y., Suwa, H., Kashimoto, Y. and Yasumoto, K.: Beacon-Based Multi-Person Activity Monitoring System for Day Care Center, *IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pp. 1–6 (2016).
- [14] 百瀬凌也, 新田知之, 柳澤政生, 戸川望: 近接度を用いたパーティクルフィルタによる高精度屋内位置測位手法, マルチメディア, 分散, 協調とモバイル (DICOMO2017) シンポジウム, pp. 514–522 (2017).
- [15] Halperin, D., Hu, W., Sheth, A. and Wetherall, D.: Tool Release: Gathering 802.11N Traces with Channel State Information, *SIGCOMM Computer Communication Review*, Vol. 41, No. 1, pp. 53–53 (2011).
- [16] Kotaru, M., Joshi, K., Bharadia, D. and Katti, S.: SpotFi: Decimeter Level Localization using WiFi, *2015 ACM Conference on Special Interest Group on Data Communication, SIGCOMM '15*, pp. 269–282 (2015).
- [17] Wang, Y., Yang, X., Zhao, Y., Liu, Y. and Cuthbert, L.: Bluetooth Positioning Using RSSI and Triangulation Methods, *IEEE 10th Consumer Communications and Networking Conference (CCNC)*, pp. 837–842 (2013).
- [18] Bahl, P. and Padmanabhan, V. N.: RADAR: An In-building RF-based User Location and Tracking System, *19th Annual Joint Conference of the IEEE Computer and Communications Societies (INFOCOM 2000)*, pp. 775–784 (2000).
- [19] Fet, N., Handte, M. and Marrón, P. J.: Autonomous Signal Source Displacement Detection and Recalibration of Fingerprinting-based Indoor Localization Systems, *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1–8 (2017).
- [20] Abbas, M., Elhamshary, M., Rizk, H., Torki, M. and Youssef, M.: WiDeep: WiFi-based Accurate and Robust Indoor Localization System using Deep Learning, *17th IEEE International Conference on Pervasive Computing and Communications (PerCom 2019)*, pp. 232–241 (2019).