

ニューラルネットワークを用いた大規模イベント向け BLE 屋内位置推定の比較評価

浦野 健太¹ 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、受信信号強度を使う BLE 屋内位置推定において、ニューラルネットワークを用いた手法を考える。無線電波を使う位置推定では、受信信号強度の不安定さが精度に影響する。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おり、精度の改善が報告されている。一方で、多数の人がいる実環境への対応可能性は十分検証されていない。そこで本稿では、(1) 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た位置推定と、(2) ニューラルネットワークによる End-to-end の位置推定を比較し、高精度に推定できる手法を検討する。(1) では、受信信号強度からノイズ除去や欠損値の補完を行い既存手法で位置推定を行う。(2) 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位置推定を行う。ネットワークの学習時は、単純なシミュレーションで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。大規模展示会での実験データでの評価では、デノイジングオートエンコーダと既存手法の組合せは精度で劣り、End-to-end のニューラルネットワークのほうが良い精度で推定を行えた。

Comparison of BLE Indoor Location Estimation Method using Neural Network for Large-scale Events

URANO KENTA¹ HIROI KEI¹ YONEZAWA TAKURO¹ KAWAGUCHI NOBUO^{1,2}

1. 背景

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、来場者の動向—どのブースに訪れたか・会場内をどう移動したか・どこにどれくらい滞在したかなどの情報—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。BLE は小型・低価格の IoT 機器でも利用可能で、低消費電力で長期間の動作が可能になるため、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、受信信号強度に生じるノイズやパケットロスであった。受信信号強度に生じるノイズは精度低下の原因となり、パケットロスは推定自体を行えなくなるため、これらの影響の緩和が課題であった。これまでには、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。出力としてノイズを取り除いた入力信号を構成するデノイジングオートエンコーダを各地点ごとに学習させる手法 [5] や、受信信号強度ではなく Wi-Fi CSI 利用する手法 [6] などがあり、いずれも精度の改善が報告されている。また、BLE を利用する位置推定でもディープラーニングの利用が行われつつあり、デノイジングオートエンコーダを利用する手法 [7] が提案されている。

本稿では、多数の来場者がおり、電波環境が不安定とな

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

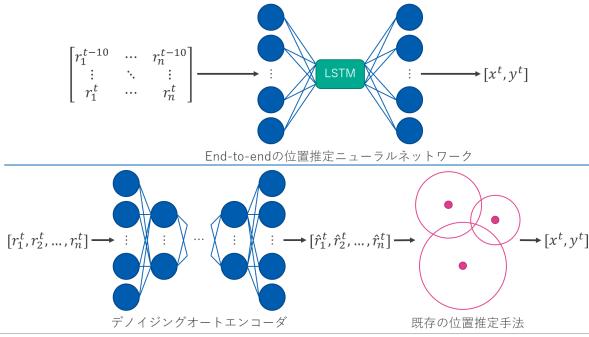


図 1: End-to-end のニューラルネットワークによる位置推定と、デノイジングオートエンコーダと既存手法を組み合わせた位置推定

る大規模展示会の環境におけるディープラーニングを利用した BLE 位置推定として、(1) デノイジングオートエンコーダで補正した受信信号強度を既存手法に入力し、精度の向上を図る位置推定と (2) End-to-end のニューラルネットワークによる受信信号強度からの直接的な位置推定では、どちらが良い精度で推定を行えるかを検討する。図 1 に両者の位置推定の流れを示す。

それぞれのメリットとして以下が挙げられる。(1) では、ニューラルネットワークは受信信号強度の補正にのみ利用されるため、デノイジングオートエンコーダを構成するのみでよく、ネットワーク設計などの労力を減らしつつ既存手法による位置推定を高精度化できる。(2) ではニューラルネットワークを適切に学習させられれば、他の手法との組み合わせによらない直接的な位置推定が可能である。一方、デメリットとしては、(1) ではニューラルネットワークの学習に加えて、既存手法でもパラメータ調整や学習が必要になる点がある。(2) ではニューラルネットワークの設計や損失関数の定義などを適切に行い、学習を十分させないと位置推定の精度が上げられない。

(1) で利用するオートエンコーダには全結合層を用いてある時刻の受信信号強度を入力し、ノイズを除去し欠損値を補完した受信信号強度を出力させる。組み合わせる既存手法には、三点測位をベースとした手法 [3] を利用する。

(2) で利用する End-to-end のニューラルネットワークには、入力として受信信号強度の時系列を与える、位置を出力させる。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[8] 層を用いるニューラルネットワークを用いる。

これらの手法の精度評価には、実際の展示会で取得したデータを用いる。しかし、事前に十分な学習データの収集を行えない展示会環境を考慮して、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。評価の結果、(1) では既存手法を単体で使うよりも誤差平均、標準偏差ともに悪くなり、(2) では既存手法より誤差平均が優れる一方、標準偏差が大きかった。

以降、2 章では電波を利用する屋内位置推定の既存手法とディープラーニングを用いた手法についてまとめる。3 章では今回比較する (1) デノイジングオートエンコーダと既存手法の組み合わせと (2) End-to-end のニューラルネットワークによる位置推定について述べる。4 章でこれらの推定精度を比較し、最後に 5 章でまとめと今後の課題について述べる。

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 [9] を利用するもの、カメラやレーザスキャナ [10] を利用するもの、超音波 [11] や、RFID[12] や FM[13] 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）でパケットを取り取りし、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 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ので行われる。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)[14] を利用する SpotFi[15] 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 [16] 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。

2.2 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[17] 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がある。そこで、Fingerprint を更新する手法 [18] も研究されている。

2.3 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いる。推定位置の取得には、入力した信号強度と補正された信号強度の差分からトレーニング時の各参照点に対する重みを計算し、重み付き平均を利用するものが多い。

Xiao らの DABIL[7] では BLE を用いた 3 次元位置推定において、ノイズを除去するデノイジングオートエンコーダ [19] を用いている。DABIL では、トレーニング時には受信信号強度を入力とし、各参照点に対応するデノイジングオートエンコーダを学習させる。実際の位置推定では、入力した受信信号強度と、各オートエンコーダによって再構築された受信信号強度の差分から各参照点に対応する座標に加える重みを算出し、重み付き kNN で推定位置を得る。

Wang らの DeepFi[6] では、Wi-Fi の CSI を入力として、制限ボルツマンマシンを重ねた Deep Belief Network を学習し、再構築した CSI を利用して位置推定を行っている。推定位置の出力は重み付き平均で行っており、DABIL と類似するがこちらは計算に利用する参照点の数に制限はない。Abbas らは WiDeep[5] 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ジングオートエンコーダを学習させている。推定では DABIL や DeepFi とほぼ同じアプローチを用いており、入力とニューラルネットワークで再構築された入力を比較して重み付き平均を取って推定位置としている。

これらのディープラーニングベースの位置推定では、既存の三点測位や Fingerprint などより良い精度が報告されている。一方で、推定位置の出力はニューラルネットワークでは行っておらず、ニューラルネットワークの出力を利用して参照点の位置から求めるものとなっている。従って位

置推定はワンショットの推定となっており、時系列情報を利用していない。

我々が対象とする大規模展示会の環境では、十分な量のトレーニングデータの事前取得が難しく、また会期中は多数の人が訪れるためノイズやパケットロスの影響が大きい。そのため、時系列情報を利用した位置推定による精度の向上を図る。本稿では、時系列を利用できる位置推定として次の 2 種類の位置推定のどちらが良いかを検討する。(1) ある時刻の受信信号強度を補正するデノイジングオートエンコーダと既存手法の組合せと (2) 受信信号強度を時系列を入力とする End-to-end の位置推定用ニューラルネットワークである。(1) では既存手法として我々が以前に提案した手法を用い、推定精度が向上するかを検討する。(2) では受信信号強度の時系列をまず全結合層に入力し、その後 LSTM で位置推定を行う。

3. 比較手法

比較する 2 つの位置推定のニューラルネットワークの構成を次に示す。以降では時刻 t においてスキャナ i が観測した受信信号強度を r_i^t で示す。会場内のスキャナの数は N で示す。また、時刻 t での各スキャナの受信信号強度をまとめた \mathbf{R}^t を式(1) で示す。時刻 t_1 から t_2 まで \mathbf{R} を並べたものを式(2) の $\mathbf{R}^{(t_1, t_2)}$ で示す。時刻 t における推定位置は $\hat{\mathbf{P}}^t = [\hat{x}_t, \hat{y}_t]$ で示す。

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

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

3.1 デノイジングオートエンコーダと既存手法の組合せ

\mathbf{R}^t を入力として、ノイズと欠損値を取り除いて理想的な受信信号強度 $\hat{\mathbf{R}}^t$ を出力するデノイジングオートエンコーダを、全結合層、 PReLU[20] 層、 Dropout 層で構成する。PReLU 層は、負の入力 \mathbf{x} に対しても a を学習可能パラメータとして $a\mathbf{x}$ を返すようにした ReLU 層である。また、デノイジングオートエンコーダは欠損値を補完するが、ここでは入力 \mathbf{R}^t が欠損値だけでなくノイズも含むものとして扱う。各層は図 2 のように配置する。図中の Preprocess では欠損値の -100 での穴埋めと +90 の値のシフトを施す。Postprocess では、Preprocess で行われた値シフトを戻すために -90 の値シフトを行う。

デノイジングオートエンコーダは入力された \mathbf{R}^t からノイズを取り除くのみなので、出力された受信信号強度を用いて既存手法による位置推定を行う。組み合わせる手法

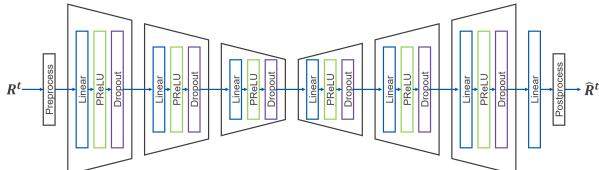


図 2: デノイジングオートエンコーダ

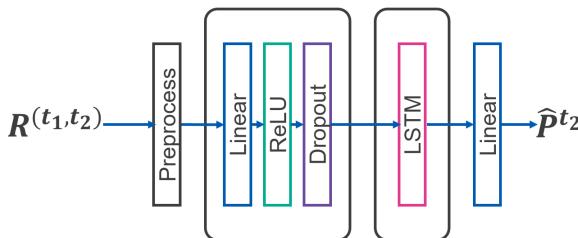


図 3: End-to-end のニューラルネットワーク

には我々が以前に提案した三点測位ベースの手法 [3] を用いる。

3.2 End-to-end のニューラルネットワーク

$R^{(t_1, t_2)}$ を入力として、 \hat{P}^{t_2} の位置を出力するニューラルネットワークを、全結合層、ReLU 層、Dropout 層、LSTM 層で構成する。このニューラルネットワークは構成の検討を行った結果最も精度の良かったもの [21] で、図 3 に示すように層を配置する。前半の全結合層・ReLU 層では入力した $R^{(t_1, t_2)}$ からの欠損値やノイズの除去が期待される。時系列からの特徴抽出は後半の LSTM 層が行う。Preprocess では前節と同様に、 $R^{(t_1, t_2)}$ 内のすべての欠損値を -100 で埋めた後、+90 の値のシフトを施す。

4. 評価

本章では、先に述べた 2 パターンの位置推定手法について、既存手法単体も含めて精度評価を行う。各ニューラルネットワークの実装は Pytorch 0.4.1 で行う。対象とするデータは、日本科学未来館で開催された G 空間 EXPO 2016 における実験で取得されたデータである。

4.1 利用データ

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 4 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、

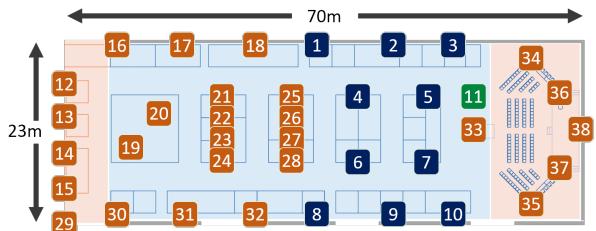


図 4: 対象とする会場と、会場内のスキャナ配置

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として使う R のスキャナ台数は $N = 38$ とする。

4.2 各ニューラルネットワークの学習

End-to-end のニューラルネットワーク、デノイジングオートエンコーダの学習では、ともに最初はシミュレーションを行って生成したデータを利用する。これは、我々が対象とする展示会環境では、事前準備に利用できる時間が少なく、十分なトレーニングデータを得られないためである。データの生成は End-to-end のニューラルネットワークの構成の検討時 [21] を同様の方法で行う。ただし、デノイジングオートエンコーダ用のデータの生成では、複数の時刻に渡ったデータを生成する必要はないため、 t_1 にあたる部分のみを利用し、ノイズを足す前の受信信号強度を正解の受信信号強度とする。

シミュレーションデータによる学習では、16 万のデータを生成する。両ニューラルネットワークはともに 200 エポックの学習を行う。End-to-end のニューラルネットワークの学習はバッチサイズ 100、デノイジングオートエンコーダの学習はバッチサイズ 1000 で行う。

シミュレーションデータでの学習後は、実際の実験で得たデータで学習を行う。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いて切り出した 7.8 万のデータを用いる。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う。実際のデータでの学習は 100 エポック行う。End-to-end のニューラルネットワークではバッチサイズ 100、デノイジングオートエンコーダの学習ではバッチサイズ 1000 とする。

学習時の各ニューラルネットワークのパラメータは、End-to-end のニューラルネットワークについては構成検討時と同じものを用いる。デノイジングオートエンコーダについては表 1 に示す。

4.3 推定精度の比較

実際の位置推定に使うデータは G 空間 EXPO2016 で得

表 1: デノイジングオートエンコーダのパラメータ

パラメータ	値
入力時系列の長さ	1(秒)
入力特徴数	38(スキャナ台数と同じ)
全結合層の出力特徴数	19, 9, 5, 5, 9, 19, 38
Dropout の確率	0.3, 0.2, 0.1, 0.1, 0.2, 0.3
損失関数	L1Loss
最適化法	Adagrad

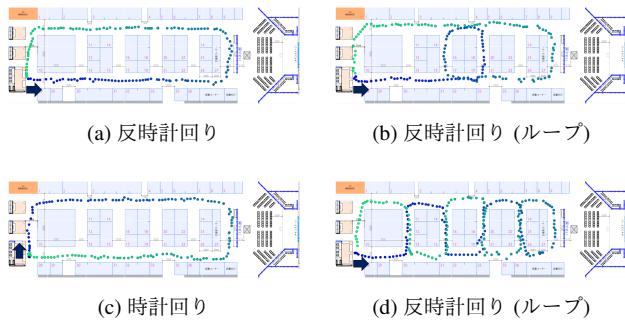


図 5: 精度検証用の経路

表 2: 各手法の誤差の平均・標準偏差

手法	誤差 [m]	
	平均	標準偏差
デノイジングオートエンコーダと三点測位ベースの手法の組合せ	8.41	4.51
End-to-end のニューラルネットワーク	1.94	2.05
三点測位ベースの手法	3.62	1.75

たデータのうち、3人の被験者が歩いた4パターンの経路のものとする。各経路は図5に示すとおりで、被験者は必ず各図で左下にあたる実験受付から歩き、最後に実験受付に戻ってくる。

推定精度の評価は、End-to-end のニューラルネットワーク、デノイジングオートエンコーダと三点測位ベースの手法[3]の組合せ、三点測位ベースの手法単体の3種類について行った。各手法における誤差の平均と標準偏差を表2に示す。表より、最も誤差の平均が小さかったのはEnd-to-end のニューラルネットワークだった。一方、標準偏差では三点測位ベースの手法を単体で使った場合が最も安定しており、デノイジングオートエンコーダと三点測位ベースの手法を組み合わせた場合は誤差、標準偏差ともに大きかった。

4.4 考察

デノイジングオートエンコーダと三点測位の組み合わせで精度が大幅に悪化した原因を検討する。まず、 \mathbf{R}^t に存在する欠損値やノイズの影響を、デノイジングオートエンコーダが取り除けているかを確認する。

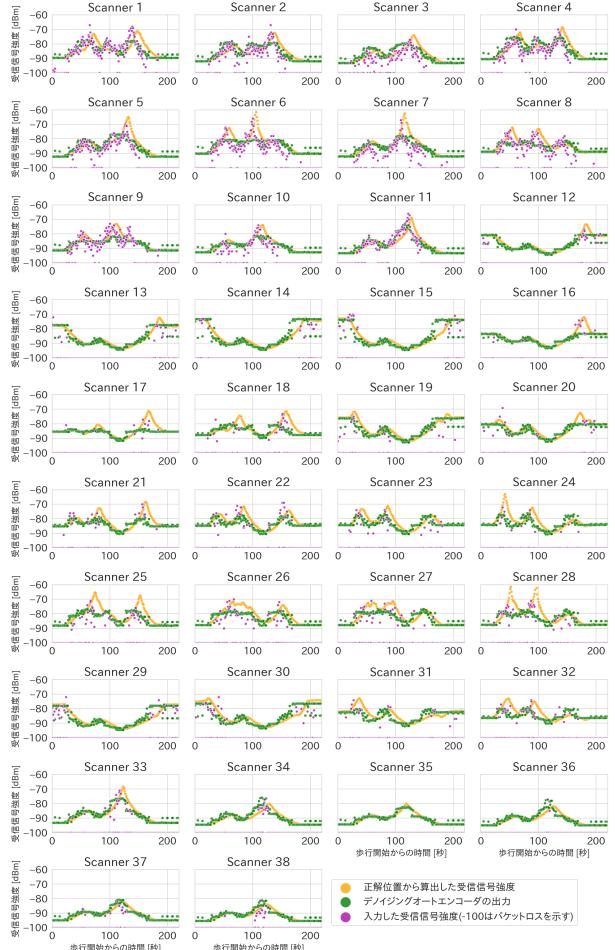


図 6: 受信信号強度(入力・理想・再構築)

ループを含む反時計回りの経路(図7d)において、各スキャナが実際に観測した受信信号強度(=デノイジングオートエンコーダへの入力値)・デノイジングオートエンコーダが输出した受信信号強度・正解位置から計算した理想的な受信信号強度を図6に示す。図より、パケットロスが多いスキャナ12以降では理想に近い受信信号強度を復元できている。一方、どのスキャナにおいても値が大きくなる箇所では出力された値が理想の値に追従できていない。受信信号強度は送受信間の距離に応じて負の対数で変化し、スキャナと被験者の距離が遠くなるほど変化量が小さくなる。そのため、あるスキャナと被験者が近い場合に、他のスキャナにおける小さな変化量から、そのスキャナにおける大きな受信信号強度を再構築することが難しくなり、図のように追従できない箇所が生じた。

デノイジングオートエンコーダの出力を用いて位置推定した結果、各経路における推定経路は図7のようになった。どの経路においても、推定位置が左下の歩行開始位置から会場内の通路を無視して左上に向かい、左上から右下に向かうように出力された。位置推定時に生成される尤度マップの可視化を行ったところ、どの推定結果のどの時間においても、図8のように、会場を縦に横切るように尤度の高

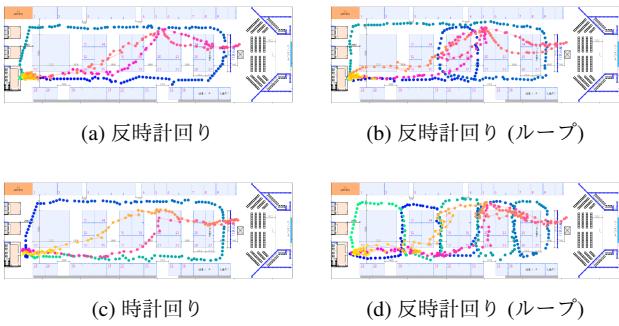


図 7: デノイジングオートエンコーダと三点測位ベースの手法の組み合わせでの推定結果の例（推定経路は歩行開始を桃色で表示し、歩行終了に向けて黄色に色を変化させている）

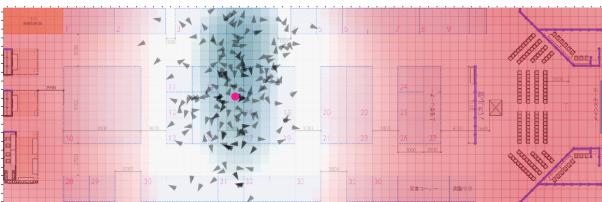


図 8: 三点測位ベースの手法にデノイジングオートエンコーダの出力を入れた際の尤度マップの例（青が尤度の高い領域、矢印はパーティクル、推定位置は桃色の点）

い領域が作られていた。このようになった原因として、デノイジングオートエンコーダによって欠損値が推定された結果、尤度マップの生成に使われる受信信号強度が多くなり、各スキャナが作った尤度マップを加算して最終的な尤度マップを作った際に広い領域が高い尤度となったことが考えられる。

図 9 に、利用可能な受信信号強度が 3 つ、6 つの場合に尤度が高くなる領域がどれくらいの広さになるかを模式的に示す。利用可能な受信信号強度が多いほど、スキャナ単位の尤度マップの重畠で得られる領域が広がっていくため、図 8 のような結果が生じたと考えられる。デノイジングオートエンコーダと組み合わせた手法は、もともとパケットロスとノイズが多い環境に耐えて精度を上げられるように設計していたため、欠損値の補完がされると逆に推定をうまく行えなかった。したがって、単にデノイジングオートエンコーダが output する受信信号強度を input すれば即座に精度が向上するわけではなく、位置推定部分を設計し直す必要がある。

5. まとめ

本稿では、ディープラーニングを BLE ベースの屋内位置推定で利用するにあたり、ニューラルネットワークに補正させた受信信号強度を既存手法で利用する場合と、位置推定をすべてニューラルネットワークに行わせる場合のどちらが精度良く位置推定を行えるかを検証した。ニューラル

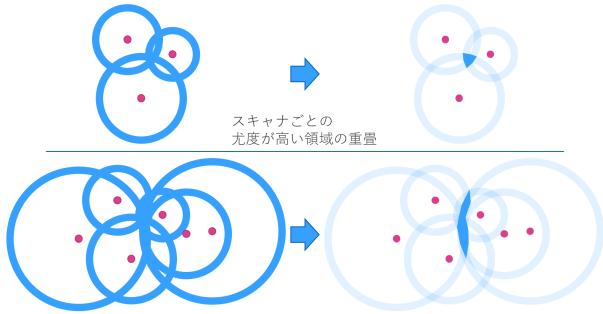


図 9: 利用可能な受信信号強度の多寡による尤度マップの面積の模式図

ネットワークによる受信信号強度の補正では、デノイジングオートエンコーダを用いて欠損値の推定とノイズの除去を試みた。End-to-end で位置推定を行うニューラルネットワークでは、全結合層と LSTM 層を用いた構成に対して、受信信号強度の時系列を入力して位置を出力させた。

各手法を比較したところ、推定精度では End-to-end のニューラルネットワークがもっともよく、デノイジングオートエンコーダと既存手法の組合せがもっとも悪かった。デノイジングオートエンコーダによる受信信号強度の補正是、大きな受信信号強度が観測されるべき部分で誤差を生じたもののある程度行えた一方で、組み合わせた既存の三点測位ベースの位置推定ではうまく推定が行えなかった。今回組み合わせた既存手法はもともとノイズが多くパケットロスが発生しやすい環境に合わせて設計されているため、デノイジングオートエンコーダが output した値からうまく位置推定を行えるように改修を加える必要がある。パケットロスやノイズの影響を取り除いた受信信号強度の恩恵が得られるのは Fingerprint を利用する場合であるため、組み合わせる手法手法を変更する場合は、関連研究 [6], [7] でも利用されているデノイジングオートエンコーダ+Fingerprint の設計がよいと思われる。

End-to-end のニューラルネットワークでは、誤差の標準偏差が既存手法単体より大きくなっているものの、平均の誤差では良好な結果であった。今後はこれを改良しつつ、より少ないデータ収集で推定を行える、環境が変わっても再学習を必要としないような手法での位置推定を目指す。

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 の助成を受けたものです。

参考文献

- [1] Hui Liu, Houshang Darabi, Pat Banerjee, and Jing Liu. 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] Yanying Gu, Anthony Lo, and Ignas Niemegeers. 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] Suining He and Shueng-Han Gary Chan. Wi-Fi Fingerprint-based Indoor Positioning: Recent Advances and Comparisons. *IEEE Communications Surveys Tutorials*, Vol. 18, No. 1, pp. 466–490, 2016.
- [5] Moustafa Abbas, Moustafa Elhamshary, Hamada Rizk, Marwan Torki, and Moustafa Youssef. WiDeep: WiFi-based Accurate and Robust Indoor Localization System using Deep Learning. In *17th IEEE International Conference on Pervasive Computing and Communications (PerCom 2019)*, pp. 232–241, 2019.
- [6] Xuyu Wang, Lingjun Gao, Shiwen Mao, and Santosh Pandey. DeepFi: Deep Learning for Indoor Fingerprinting using Channel State Information. In *IEEE Wireless Communications and Networking Conference (WCNC)*, pp. 1666–1671, 2015.
- [7] Chao Xiao, Daiqin Yang, Zhenhong Chen, and Guang Tan. 3-D BLE Indoor Localization Based on Denoising Autoencoder. *IEEE Access*, Vol. 5, pp. 12751–12760, 2017.
- [8] Sepp Hochreiter and Jürgen Schmidhuber. Long Short-term Memory. *Neural Computation*, Vol. 9, pp. 1735–1780, 12 1997.
- [9] Stéphane Beauregard and Harald Haas. Pedestrian Dead Reckoning: A Basis for Personal Positioning. In *3rd Workshop on Positioning, Navigation and Communication*, pp. 27–35, 2006.
- [10] 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.
- [11] Mike Hazas and Andy Hopper. Broadband Ultrasonic Location Systems for Improved Indoor Positioning. *IEEE Transactions on Mobile Computing*, Vol. 5, No. 5, pp. 536–547, 2006.
- [12] L. M. Ni, Yunhao Liu, Yiu Cho Lau, and A. P. Patil. LAND-MARC: Indoor Location Sensing using Active RFID. In *1st IEEE International Conference on Pervasive Computing and Communications (PerCom 2003)*, pp. 407–415, 2003.
- [13] Yin Chen, Dimitrios Lymberopoulos, Jie Liu, and Bodhi Priyantha. FM-based Indoor Localization. In *10th International Conference on Mobile Systems, Applications, and Services, MobiSys '12*, pp. 169–182, 2012.
- [14] Daniel Halperin, Wenjun Hu, Anmol Sheth, and David Wetherall. Tool Release: Gathering 802.11N Traces with Channel State Information. *SIGCOMM Computer Communication Review*, Vol. 41, No. 1, pp. 53–53, January 2011.
- [15] Manikanta Kotaru, Kiran Joshi, Dinesh Bharadwaj, and Sachin Katti. SpotFi: Decimeter Level Localization using WiFi. In *2015 ACM Conference on Special Interest Group on Data Communication, SIGCOMM '15*, pp. 269–282, 2015.
- [16] Yapeng Wang, Xu Yang, Yutian Zhao, Yue Liu, and Laurie Cuthbert. Bluetooth Positioning Using RSSI and Triangulation Methods. In *IEEE 10th Consumer Communications and Networking Conference (CCNC)*, pp. 837–842, 2013.
- [17] Paramvir Bahl and Venkata N Padmanabhan. RADAR: An In-building RF-based User Location and Tracking System. In *19th Annual Joint Conference of the IEEE Computer and Communications Societies (INFOCOM 2000)*, pp. 775–784, 2000.
- [18] Ngewi Fet, Marcus Handte, and Pedro José Marrón. Autonomous Signal Source Displacement Detection and Recalibration of Fingerprinting-based Indoor Localization Systems. In *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1–8, 2017.
- [19] Pascal Vincent, Hugo Larochelle, Yoshua Bengio, and Pierre-Antoine Manzagol. Extracting and Composing Robust Features with Denoising Autoencoders. In *25th International Conference on Machine Learning, ICML '08*, pp. 1096–1103, 2008.
- [20] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. *2015 IEEE International Conference on Computer Vision (ICCV)*, pp. 1026–1034, 2015.
- [21] 浦野健太, 廣井慧, 米澤拓郎, 河口信夫. 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. 第 91 回 MBL 研究会, 2019.