

深層学習PDRとBLEビーコンを用いたハイブリッド測位

加納 一馬[†] 東浦 圭亮[†] 瀧上 昂希[†] 山口 公平[†] 永田 吉輝[†]
片山 晋[†] 浦野 健太[†] 米澤 拓郎[†] 河口 信夫[†]

† 名古屋大学 大学院工学研究科〒464-8603 愛知県名古屋市千種区不老町

E-mail: †{kazuma,urachan,tacky,kohei,teru,shinsan}@ucl.nuee.nagoya-u.ac.jp,
††{urano,takuro,kawaguti}@nagoya-u.jp

あらまし 様々な産業現場において労働生産性の向上のため人の位置情報のデータ化および利活用が求められている。高精度かつ低コストな屋内測位を実現するには複数の手法を相補的に組み合わせるのが有効である。PDR ベンチマーク標準化委員会はこれらの研究の一環として、スマートフォンのセンサの測定データ、Bluetooth Low Energy (BLE) ビーコンからの受信信号強度データ、正解用の位置・姿勢データからなるデータセットを作成し、測位性能を競う国際競技会である xDR Challenge 2023 を開催した。本研究ではこの競技会を対象として、DualCNN-Transformer モデルによる歩行速度・進行方向推定、マップマッチング、BLE による多辺測量をパーティクルフィルタ上で統合したハイブリッドな測位手法を提案する。xDR Challenge 2023 における評価の結果、提案手法の測位誤差の中央値は 0.59 [m] であり、これは全出場チームの中で最小であった。

キーワード 屋内位置推定、屋内測位、スマートフォン、歩行者自律航法、粒子フィルタ

Hybrid Positioning with Deep-Learning-based PDR and BLE Beacons

Kazuma KANO[†], Keisuke HIGASHIURA[†], Koki TAKIGAMI[†], Kohei YAMAGUCHI[†], Yoshiteru NAGATA[†], Shin KATAYAMA[†], Kenta URANO[†], Takuro YONEZAWA[†], and Nobuo KAWAGUCHI[†]

† Graduate School of Engineering, Nagoya University Furo-cho, Chikusa-ku, Nagoya, Aichi, 464-8603 Japan

E-mail: †{kazuma,urachan,tacky,kohei,teru,shinsan}@ucl.nuee.nagoya-u.ac.jp,
††{urano,takuro,kawaguti}@nagoya-u.jp

Abstract In various industrial settings, there is a growing demand for digitizing and utilizing people's location information to improve labor productivity. Combining multiple methods is a reasonable approach for accurate and economical indoor positioning. As part of these research efforts, PDR Benchmark Standardization Committee created a dataset consisting of measurements from smartphone sensors, received signal strength data from Bluetooth Low Energy (BLE) beacons, and location and orientation data for ground truth. Then, they organized an international competition called xDR Challenge 2023, which assesses positioning performance. This study proposes a hybrid positioning method targeting the competition. It integrates walking speed and heading estimation with DualCNN-Transformer models, map-matching, and multilateration by BLE on particle-filter algorithm. The evaluation results from xDR Challenge 2023 show that the proposed method achieved a median positioning error of 0.59 [m], the smallest among all participating teams.

Key words indoor localization, indoor positioning, smartphone, pedestrian dead reckoning, particle-filter

1. まえがき

少子高齢化の影響もあり、製造業、運輸業、サービス業などあらゆる産業現場において、労働生産性の向上を目的とした

デジタルトランスフォーメーションが求められている。技術やコスト面の課題から完全な自動・無人化は難しい場合も多く、データ分析やロボットなどを活用した人の作業の効率化が必要である。そこで本研究では、ソリューションの一つとして人の

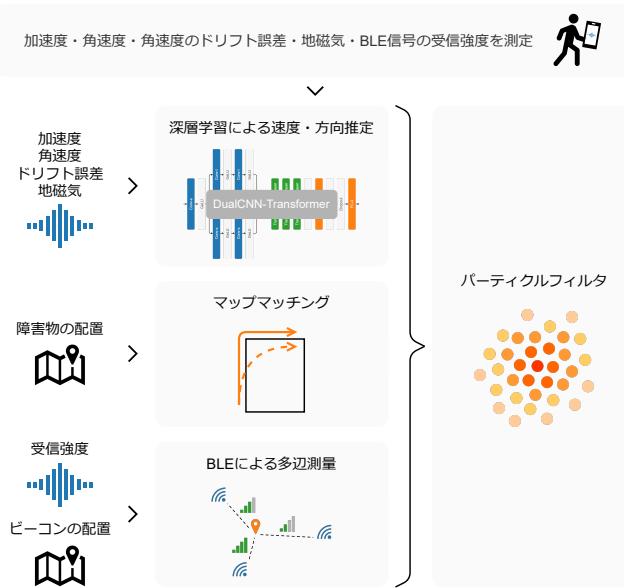


図 1 提案手法の概要

位置情報のデータ化に取り組む。応用例として、労働者の位置情報に基づいた動的なタスク割り当て、自律移動ロボットの協調的な運用、労働者シミュレーションによるレイアウト最適化などが考えられる。

建物内や地下では衛星測位の精度が低下するため、それに代わる様々な屋内測位手法が研究されてきた。環境側のカメラや Light Detection and Ranging (LiDAR) スキャナを用いた手法は高精度であるが、遮蔽物の多い環境には適さずデバイスも比較的高価である。遮蔽物の影響を受けない代表的な測位手法として歩行者自律航法 (PDR: Pedestrian Dead Reckoning) が挙げられる。PDR では、測位対象者が携帯する慣性センサや磁気センサなどの測定データから歩行速度や進行方向を推定し、それらの積分により測位開始時からの相対的な移動軌跡を求める。遮蔽への耐性に加えて低消費電力や高い頻度で位置を推定可能などの利点があり、スマートフォンを用いた測位への応用も期待されている。しかしながら PDR 単体では時間経過で推定位置の誤差が蓄積するため、長時間測位を続けるには別の絶対測位手法と組み合わせて誤差を補正する必要がある。そこで一部の先行研究では Wi-Fi や Bluetooth Low Energy (BLE) などの無線通信技術を用いた手法を PDR と組み合わせて相補的に測位精度を向上させている [1]～[5] が、PDR の頑健性が不十分、測位システムの維持管理にコストがかかるなどの課題があった。

PDR ベンチマーク標準化委員会はこれらの研究の一環として、測位性能を競う国際競技会である xDR Challenge 2023 を開催した [6]。この競技会では多数の BLE ビーコンが導入された商業施設において、測位対象者が身に付けたスマートフォンのセンサの測定データを基に移動軌跡を推定した。本研究ではこの競技会を対象として、スマートフォンと BLE ビーコンを用いたハイブリッドな測位手法を提案する。提案手法の概要を図 1 に示す。提案手法では、深層学習による歩行速度・進行方向推定、マップマッチング、BLE による多辺測量をパーティクル

フィルタ上で統合する。DualCNN-Transformer モデルを用いて歩行速度と進行方向を歩容や歩行者の違いに対して頑健に推定する。また、フィンガープリントと呼ばれる手法を用いないため電波強度分布の調査や更新が不要である。xDR Challenge 2023 における評価の結果、提案手法の測位誤差の中央値は 0.59 [m] であり、これは全出場チームの中で最小であった。

2. 関連研究

2.1 深層学習を応用した PDR 手法

従来の PDR 手法の多くは、歩容は一定で進行方向は常に前方といった非実用的な制約を前提としていたり、身長などの測位対象者に固有のパラメータに依存している等の課題があった。そこで、深層学習によって歩行速度や進行方向をデータドリブンに推定する研究が近年盛んに行われている。Chen らは Bidirectional Long Short-Term Memory (BiLSTM) を用いて一定期間の加速度と角速度から移動距離と進行方向の角変位を推定する IONet を提案し、従来の PDR 手法と比べて測位精度が向上したことを示した [7]。Herath らは ResNet, LSTM, Temporal Convolutional Network (TCN) を用いて一定期間の加速度、角速度、センサの姿勢情報から歩行速度と進行方向の方位角を推定する RoNIN を提案し、特にスマートフォンをハンドバッグに入れたときのようなセンサの複雑な動きに対する頑健性が向上したことを示した [8]。ただし RoNIN では地磁気に依存することなくセンサの姿勢情報を取得するために、測位開始前と終了後にセンサのキャリブレーション操作を要する。Kawaguchi らは早歩きや足踏みなどの歩容の違いに頑健な歩行速度の推定モデルとして DualCNN-LSTM を提案した [9], [10]。本研究では、DualCNN-LSTM に対して自然言語処理や画像認識などの分野で state-of-the-art なモデルである Transformer を応用した DualCNN-Transformer を用いて、歩行速度と進行方向の角変位および方位角を推定する。

2.2 PDR と Wi-Fi や BLE を組み合わせた手法

Wi-Fi や BLE による測位手法の多くは受信信号強度を表す Received Signal Strength Indicator (RSSI) に基づいており、代表的なものとしてフィンガープリントと多辺測量が挙げられる。フィンガープリントでは事前に調査した RSSI の分布と実際の RSSI を照らし合わせて受信者の位置を求める。比較的高精度であるが、分布の調査と更新に時間や費用がかかり実用性的低下に繋がる。一方、多辺測量では信号の伝搬モデルに基づいてビーコンとの距離を推定し位置を求める。RSSI の分布情報が不要だが、信号の減衰や干渉の影響を受けて測位精度が低下しやすい。一部の先行研究ではフィンガープリントや多辺測量を PDR と組み合わせて相補的に測位精度を向上させている [1]～[5] が、その多くは基礎的な PDR 手法を採用しており歩容や歩行者の違いに対する頑健性が不十分であった。そこで我々はこれまでに、深層学習による歩行速度推定、マップマッチング、BLE による多辺測量を組み合わせた低コストかつ高精度な測位手法について研究してきた [11], [12]。本研究ではさらに深層学習による進行方向推定を適用しきつかの改良を加える。

3. 提案手法

提案手法における位置推定の流れを図 2 に示す。初めに、スマートフォンで測定した加速度、角速度、角速度のドリフト誤差、地磁気を 100 [Hz] にリサンプリングする。続いて、学習済みの速度・角変位推定モデルを用いて歩行速度と進行方向の角変位を推定する。同様に、学習済みの速度・方位角推定モデルを用いて歩行速度と進行方向の方位角を推定する。推定した方位角の信頼性を評価し、それに応じてどちらのモデルの出力を採用するか決定する。その後、パーティクルフィルタを用いて歩行者の位置をトラッキングする。パーティクルフィルタでは、推定した歩行速度と進行方向を基にパーティクルを移動させ、マップマッチングや BLE の多辺測量によって各パーティクルの尤度を計算する。

3.1 深層学習による歩行速度と進行方向の推定

3.1.1 モデルの入出力

速度・角変位推定モデルと速度・方位角推定モデルの 2 つの深層学習モデルを用意する。前者は、一定期間の加速度、角速度、角速度のドリフト誤差を入力として与え、その間の平均歩行速度のスカラーと進行方向の平均角変位（すなわち、単位時間当たりの進行方向の平均変化）を指す単位ベクトルを出力するように学習させる。後者は、一定期間の加速度、角速度、角速度のドリフト誤差、地磁気を入力として与え、その間の平均歩行速度のスカラーと進行方向の平均方位角（すなわち、東を 0 [°]、北を 90 [°]としたときの平均進行方向）を指す単位ベクトルを出力するように学習させる。平均を取ることで正解データに含まれる誤差の影響を軽減する狙いがある。また、進行方向の角変位や方位角を角度のスカラーではなくベクトルとして推定するのは土 180 [°] の境界における不連続性を無くし学習を安定させるためである [13]。ベクトルの x 成分と y 成分はそれぞれ角度の余弦と正弦に相当する。

モデルへの入力長が短すぎると推定に使える情報量が少なくなるうえに正解データに含まれる誤差の影響も大きくなるため学習が難しくなる。一方で、入力長が長いほど測定開始から推定開始までに遅れを生じるのに加えて、歩行者の鋭い動きを追従できなくなる。本稿ではこれらのトレードオフを考慮して入力長を 1 秒間とした。データは 100 [Hz] にリサンプリングされているため、速度・角変位推定モデルの入力サイズは 100×9 、速度・方位角推定モデルの入力サイズは 100×12 となる。また、どちらのモデルも出力サイズは 1×3 である。

3.1.2 モデルの構造

図 3 に示す DualCNN-Transformer を両モデルに用いる。DualCNN-Transformer ではバックボーンネットワークとして互いにカーネルサイズの異なる 1 次元の畳み込み層からなる 2 つのパスで短期と長期の特徴を抽出する。各パスへの入力は共通であり、それらの出力を結合したものに学習可能な位置埋め込みベクトルを加えたものを Transformer のエンコーダへの入力とする。Transformer のエンコーダでは Self-Attention 機構によってデータ全体を通じた位置間の関係を捉える。Transformer のエンコーダの出力を時間方向に平均化したものを全結合層に

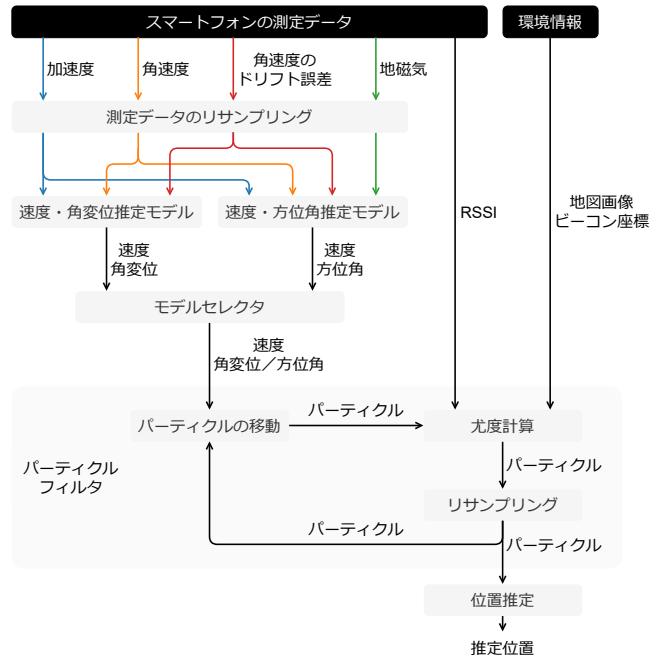


図 2 位置推定の流れ

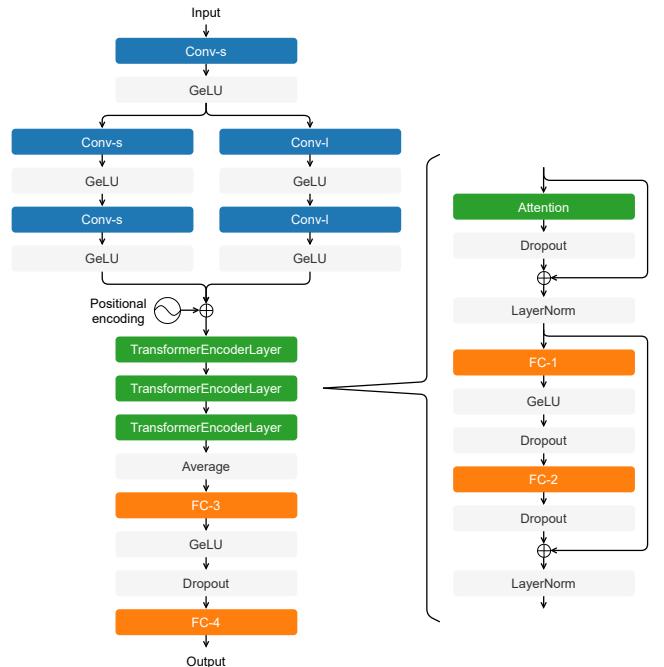


図 3 DualCNN-Transformer の構造

入力し、歩行速度と進行方向の角変位または方位角に変換する。幅広いタイムスケールの特徴を考慮することで様々な歩容や歩行者への適応が期待できる。

3.1.3 モデルの訓練方法とハイパーパラメータ

モデルの訓練時には 10 [Hz] で推定を行い重みを更新する。すなわち入力データを切り出すためのウィンドウを 10 サンプルずつスライドさせる。損失関数には回帰タスクで広く使われる平均二乗誤差 (MSE: Mean Squared Error) を用いる。最適化アルゴリズムには Adam を用い、学習率は 0.001 とする。バッチサイズは 512 とする。最大エポック数を 100 とし、検証誤差

表 1 速度・角変位推定モデルのハイパーパラメータ

| | | |
|----------------------|------------------|---------------------|
| Conv-s | 出力チャネル数 | 16, 32, 48 * |
| | カーネルサイズ | 9 |
| | ストライド | 1 |
| | パディング | 0 |
| Conv-l | 出力チャネル数 | 16, 32, 48 * |
| | カーネルサイズ | 17 |
| | ストライド | 1 |
| | パディング | 0 |
| Transformer エンコーダ | Attention 次元数 | 32, 64, 96 * |
| | Attention ヘッド数 | 4 |
| | Feed-Forward 次元数 | 32 , 64, 96 |
| | ドロップアウト率 | 0.1 |
| FC-3 | 出力チャネル数 | 8, 16, 24 * |
| | ドロップアウト率 | 0.1 |

表 2 速度・方位角推定モデルのハイパーパラメータ

| | | |
|----------------------|------------------|---------------------------|
| Conv-s | 出力チャネル数 | 16, 32 , 48 * |
| | カーネルサイズ | 9 |
| | ストライド | 1 |
| | パディング | 0 |
| Conv-l | 出力チャネル数 | 16, 32 , 48 * |
| | カーネルサイズ | 17 |
| | ストライド | 1 |
| | パディング | 0 |
| Transformer エンコーダ | Attention 次元数 | 32, 64 , 96 * |
| | Attention ヘッド数 | 4 |
| | Feed-Forward 次元数 | 32 , 64, 96 |
| | ドロップアウト率 | 0.1 |
| FC-3 | 出力チャネル数 | 8, 16 , 24 * |
| | ドロップアウト率 | 0.1 |

が最も小さいエポックにおける重みを採用する。各モデルのハイパーパラメータは表 1, 2 に挙げた候補の中からグリッドサーチによって決定した。検証誤差が最も小さくなったパラメータの組み合わせを太字で示す。ただし Conv-s の出力チャネル数 ch_{cs} , Conv-l の出力チャネル数 ch_{cl} , Attention の次元数 d_{at} , FC-3 の出力チャネル数 ch_{fc} に対して次の制約を設けた。

$$2ch_{cs} = 2ch_{cl} = d_{at} = 4ch_{fc} \quad (1)$$

3.1.4 モデルの選択

深層学習を用いた進行方向推定では、前回時刻からの相対的な角変位を逐次的に積分して求める方式 [7], [14] や、現在時刻における絶対的な方位角をステップごとに独立して求める方式 [8], [15] が一般的である。前者の方式では推定を続けるにつれて誤差が蓄積するため、その補正を別の手法に頼る必要がある。一方、後者的方式では誤差が蓄積しないが、推定に地磁気やセンサ姿勢の情報を要する。特に地磁気情報を利用する場合は環境内の残留磁気の影響を受けて推定精度が低下しやすい。

そこで、推定した進行方向の方位角の信頼性に応じて速度・角変位推定モデルと速度・方位角推定モデルのどちらの出力を採用するかを決定する。進行方向は歩行中に連続的に変化する

ため、推定精度が高ければ隣り合う時刻間の推定方位角の差は常に十分小さくなると考えられる。本研究ではこの仮定に基づき、隣り合う時刻間の推定方位角の差を大きい順にソートしたときの上位 0.1 [%] の平均角度の逆数として推定方位角の信頼性を定式化する。すなわち、大きい順にソートされた隣り合う時刻間の推定方位角の差の集合を $\{\Delta\theta^1, \Delta\theta^2, \dots, \Delta\theta^N\}$ とおくと、推定方位角の信頼性 r は次のように計算される。

$$r = \frac{\lfloor \frac{N}{1000} \rfloor}{\sum_{i=1}^{\lfloor \frac{N}{1000} \rfloor} \Delta\theta^i} \quad (2)$$

信頼性 r がある閾値以上の場合は速度・方位角推定モデル、未満の場合は速度・角変位推定モデルの出力を採用する。本稿では経験的に閾値を 2 [/rad] とした。

3.2 パーティクルフィルタによるトラッキング

3.2.1 トラッキングアルゴリズム

推定した歩行速度と進行方向には誤差が含まれるため、PDR 単体では測位を続けるにつれて推定位置と正解位置の間に乖離を生じる。そこで、パーティクルフィルタと呼ばれる確率的なアルゴリズムを用いて絶対測位手法であるマップマッチングや BLE による多辺測量と組み合わせることで、誤った推定位置からの回復機能の獲得を図る。パーティクルフィルタによる移動軌跡推定の手順を以下に示す。

- (1) パーティクルの初期位置および方向を指定.
- (2) 各パーティクルを移動.
- (3) 各パーティクルの尤度を計算.
- (4) パーティクルをリサンプリング.
- (5) 歩行者の位置を推定.
- (6) ステップ 2 に戻る.

時刻 t におけるパーティクル p は二次元位置、方向、尤度からなる固有の状態 $(x^{p,t}, y^{p,t}, \theta^{p,t}, l^{p,t})$ を持つ。ステップ 1 では全パーティクルの初期位置および方向を測位開始時刻における歩行者の位置と身体の前方に合わせる。

ステップ 2 では推定した歩行速度と進行方向に基づいて各パーティクルの位置と方向を更新する。提案手法では一定期間の平均歩行速度と進行方向の平均角変位または平均方位角を出力するようにモデルを学習させるが、ここではそれを中央の時刻における歩行速度と進行方向の角変位または方位角として扱う。また、速度・角変位推定モデルと速度・方位角推定モデルのどちらの出力を用いるかによって処理が異なる。速度・角変位推定モデルの出力を用いる場合、時刻 t における推定歩行速度を v_{pred}^t 、進行方向の推定角変位を ω_{pred}^t とおくと、移動後のパーティクル p の位置 $(x^{p,t}, y^{p,t})$ と方向 $\theta^{p,t}$ は以下のように求まる。 T は位置推定の周期を表す。 σ_{spd} と σ_{hd} はパーティクルの移動距離と方向にどれだけ確率的な拡がりを持たせるかを表すパラメータである。

$$\theta^{p,t} = \theta^{p,t-T} + (\omega_{pred}^t + \alpha) T \quad (3)$$

$$x^{p,t} = x^{p,t-T} + \max(0, v_{pred}^t + \beta) T \cos \theta^{p,t} \quad (4)$$

$$y^{p,t} = y^{p,t-T} + \max(0, v_{pred}^t + \beta) T \sin \theta^{p,t} \quad (5)$$

$$\alpha \sim N(0, \sigma_{hd})$$

$$\beta \sim N(0, v_{pred}^t \sigma_{spd})$$

一方、速度・方位角推定モデルの出力を用いる場合、時刻 t における推定歩行速度を v_{pred}^t 、進行方向の推定方位角を θ_{pred}^t とおくと、移動後のパーティクル p の位置 $(x^{p,t}, y^{p,t})$ と方向 $\theta^{p,t}$ は以下のように求まる。

$$\theta^{p,t} = \theta_{pred}^t + \alpha \quad (6)$$

$$x^{p,t} = x^{p,t-T} + \max(0, v_{pred}^t + \beta) T \cos \theta^{p,t} \quad (7)$$

$$y^{p,t} = y^{p,t-T} + \max(0, v_{pred}^t + \beta) T \sin \theta^{p,t} \quad (8)$$

$$\alpha \sim N(0, \sigma_{hd})$$

$$\beta \sim N(0, v_{pred}^t \sigma_{spd})$$

ステップ 3 ではマップマッチングや BLE による多辺測量に基づいて各パーティクルの尤度を計算する。BLE の RSSI 情報を利用できる場合、パーティクル p の尤度 $l^{p,t}$ はマップマッチング尤度 $l_{mm}^{p,t}$ と BLE 尤度 $l_{ble}^{p,t}$ の和として与えられる。RSSI 情報を利用できない場合、尤度 $l^{p,t}$ はマップマッチング尤度 $l_{mm}^{p,t}$ と一致する。マップマッチング尤度と BLE 尤度の計算方法については 3.2.2 節と 3.2.3 節で説明する。

$$l^{p,t} = \begin{cases} l_{mm}^{p,t} + l_{ble}^{p,t} & \text{if RSSI is available} \\ l_{mm}^{p,t} & \text{if RSSI is not available} \end{cases} \quad (9)$$

ステップ 4 では計算した尤度に応じてパーティクルをリサンプリングする。まず、パーティクルの尤度が負の値である場合はその尤度を 0 とする。次に、全パーティクルを並べて、一定の累積尤度ごとに重複を許して取り出す。このとき、リサンプリング前後でパーティクル数が等しくなるように取り出す間隔を定める。尤度が高いパーティクルほどより多く複製されやすい。

ステップ 5 では歩行者の位置 (x_{pdst}^t, y_{pdst}^t) をリサンプリング後の全パーティクルの重心として推定する。 N_{ptcl} はパーティクル数を表す。

$$x_{pdst}^t = \frac{\sum_p x^{p,t}}{N_{ptcl}} \quad (10)$$

$$y_{pdst}^t = \frac{\sum_p y^{p,t}}{N_{ptcl}} \quad (11)$$

最後にステップ 6 で時刻 t を更新してステップ 2 に戻る。以上の手順を繰り返して歩行者の位置をトラッキングする。

$$t := t + T \quad (12)$$

3.2.2 マップマッチングによる尤度の計算

壁などの障害物上を通過するパーティクルの尤度を低くして不自然なパーティクルの移動を制限する。時刻 t におけるパーティクル p のマップマッチング尤度 $l_{mm}^{p,t}$ は以下の条件のいずれかを満たす場合に 0.1、いずれも満たさない場合に 1 をとする。

- なお、障害物のレイアウト情報は地図画像から取得できる。
- (A) 時刻 $t - T$ においてパーティクル p が障害物上に位置する
- (B) 時刻 t においてパーティクル p が障害物上に位置する
- (C) 時刻 $t - T$ と時刻 t におけるパーティクル p の位置を結ぶ線分上に障害物が存在する

$$l_{mm}^{p,t} = \begin{cases} 0.1 & \text{if } A \vee B \vee C \\ 1 & \text{if } \neg A \wedge \neg B \wedge \neg C \end{cases} \quad (13)$$

3.2.3 BLE による尤度の計算

BLE の RSSI 情報を利用できる場合は、それを基に正しい位置にいる可能性が高いパーティクルの尤度を相対的に高くする。パーティクル p の BLE 尤度 $l_{ble}^{p,t}$ は、信号強度重み $w_{str}^{b,t}$ 、距離尤度 $l_{dist}^{b,p,t}$ 、非検出尤度 $l_{miss}^{b,p,t}$ から求まる。まず、ビーコン b からの信号の RSSI を $r^{b,t}$ とおくと、信号強度重み $w_{str}^{b,t}$ は式 (14) より計算される。 R_{max} は最大 RSSI に相当するパラメータである。RSSI が大きいほど信号強度重みも大きくなり、RSSI が R_{max} 以上のときに最大値 1 をとする。

$$w_{str}^{b,t} = \exp(-\max(0, R_{max} - r^{b,t})) \quad (14)$$

次に、ビーコン b の設置位置を $(x_{bcn}^b, y_{bcn}^b, z_{bcn}^b)$ とおくと、距離尤度 $l_{dist}^{b,p,t}$ は以下のように計算される。 $d_{est}^{b,t}$ はフリスの伝達公式に基づいて推定した歩行者とビーコン b 間の水平距離である。 P_{tx} はビーコンの送信強度を表し、本稿では公称値である -76 [dBm] とする。 E はセンサの床からの高度を表す。本稿ではセンサを腰に装着したときのデータを用いるため $E = 1$ [m] とする。 C_{at} は環境の減衰定数に相当するパラメータである。一方、 $d_{true}^{b,p,t}$ はパーティクル p とビーコン b 間の実際の水平距離である。 σ_{dist} は推定距離の誤差をどれだけ許容するかを表すパラメータであり、 P は標準偏差が σ_{dist} の正規分布に従う確率密度関数である。 $d_{est}^{b,t}$ と $d_{true}^{b,p,t}$ の差が小さいほど距離尤度は大きくなり、2つの距離が一致するときに最大となる。

$$d_{est}^{b,t} = \sqrt{\max\left(0, 10^{\frac{P_{tx}-r^{b,t}}{5C_{at}}} - (z_{bcn}^b - E)^2\right)} \quad (15)$$

$$d_{true}^{b,p,t} = \sqrt{(x_{bcn}^b - x^{p,t})^2 + (y_{bcn}^b - y^{p,t})^2} \quad (16)$$

$$l_{dist}^{b,p,t} = P(d_{est}^{b,t} - d_{true}^{b,p,t}) \quad (17)$$

$$P \sim N(0, \sigma_{dist})$$

また、時刻 t におけるビーコン b についての非検出尤度 $l_{miss}^{b,p,t}$ は式 (18) より計算される。時刻 $t - \frac{W}{2}$ から $t + \frac{W}{2}$ の間にビーコンからの信号を受信しているまたはパーティクルとビーコン間の距離が R_{dtct} 以上の場合、非検出尤度は最大値 0 をとする。ビーコンからの信号を受信していないかつパーティクルとビーコン間の距離が R_{dtct} 未満の場合、非検出尤度は負の値をとり、パーティクルとビーコン間の距離が短いほど非検出尤度は小さくなる。 W は RSSI 情報を切り出すためのウィンドウの長さを表す。 R_{dtct} はビーコンの位置を中心とした信号の検出が期待される範囲円の半径に相当するパラメータである。

表 3 フィルタのハイパーパラメータ

| モデル BLE の RSSI 情報 | 速度・角変位 | | 速度・方位角 | |
|--------------------------------------|--------|------|--------|------|
| | 有 | 無 | 有 | 無 |
| 位置推定周期 T [s] | | | 0.1 | |
| 速度標準偏差 σ_{spd} | 1 | 0.5 | 2 | 1.5 |
| 方向標準偏差 σ_{hd} [rad/s] / [rad] | 0.3 | | 0.5 | |
| パーティクル数 N_{ptcl} | 1024 | 2048 | 1024 | 2048 |
| 最大 RSSI R_{max} [dBm] | -70 | — | -70 | — |
| 減衰定数 C_{at} | 2 | — | 2 | — |
| 距離誤差標準偏差 σ_{dist} [m] | 2 | — | 2 | — |
| ウィンドウサイズ W [s] | 1 | — | 1 | — |
| 検出半径 R_{dtct} [m] | 1 | — | 1 | — |

$$l_{miss}^{b,p,t} = \begin{cases} 0 & \text{if } b \text{ is detected} \vee d_{true} \geq R_{dtct} \\ -\exp(-d_{true}^{b,p,t}) & \text{if } b \text{ is missed} \wedge d_{true} < R_{dtct} \end{cases} \quad (18)$$

最後に、時刻 $t - \frac{W}{2}$ から $t + \frac{W}{2}$ の間に信号を受信したビーコンの集合を B とおくと、時刻 t におけるパーティクル p の BLE 尤度 $l_{ble}^{p,t}$ は全てのビーコン $b \in B$ についての信号強度重み $w_{str}^{b,t}$ と距離尤度 $l_{dist}^{b,p,t}$ の積和と非検出尤度 $l_{miss}^{b,p,t}$ の和の平均として与えられる。

$$l_{ble}^{p,t} = \frac{1}{2} \sum_{b \in B} w_{str}^{b,t} l_{dist}^{b,p,t} + \frac{1}{2} \sum_{b \in B} l_{miss}^{b,p,t} \quad (19)$$

3.2.4 フィルタのハイパーパラメータ

モデルの選択と BLE の RSSI 情報の有無によってパラメータの組み合わせが異なる。条件ごとのパラメータの組み合わせを表 3 にまとめる。RSSI 情報を利用する場合は 1 つのパーティクル当たりの計算量が多くなる。我々の実装では、その分パーティクル数を半分にすることで全体の計算時間は RSSI 情報を利用しない場合と同程度になった。

4. 競技会

4.1 競技会の概要

PDR ベンチマーク標準化委員会は屋内環境における測位性能を競う国際競技会を過去 6 回に渡り開催してきた [16], [17]。国際会議 IPIN 2023 における競技会トラックの 1 つとして併催された xDR Challenge 2023 では、高速道路のサービスエリア内の 3 つのフロアにおいて 4 名の歩行者の二次元移動軌跡を推定した。フロアには発信頻度が 10 [Hz], 強度が -76 [dBm] の BLE ビーコン (Aplix 製 MyBeacon^(注1)) が合計で 97 個設置されており、被験者はその中を 1 回当たり 10 分以内で歩き回る。このとき、スマートフォン (SHARP 製 AQUOS sense6) が入ったウエストポーチを腰回りに装着し、加速度、角速度、角速度のドリフト誤差、地磁気、BLE の RSSI を測定する。同時に、手持ち式の LiDAR スキャナ (GeoSLAM 製 ZEB-Horizon^(注2)) を用いて正解データ用の三次元位置と姿勢

を計測する。

競技会の参加者は事前に提供される訓練データセットを用いて測位システムを較正でき、最後に未知の本番データに対する測位結果を提出する。訓練データセットと本番データの記録時間はそれぞれ 131 分、28 分である。本番データには訓練データセットに含まれない被験者のデータも含まれる。なお、本番では測位開始時および終了時の二点のみ正解位置と姿勢が与えられる。また、9 つある本番データのうち 6 つでは BLE の RSSI 情報が与えられるが、残りの 3 つでは与えられない。

4.2 評価指標

xDR Challenge 2023 では表 4 に挙げた 5 つの指標に基づいて測位システムとしての性能を総合的に評価する。Circular Error (CE) は位置精度を測るための指標であり、正解位置を中心としたときに 50 [%] の確率で推定位置を含むような円の半径 (すなわち、位置誤差の中央値) を表す。Circular Accuracy (CA) は位置正確度を測るための指標であり、正解位置姿勢から見た推定位置の分布密度が最も高い位置までの距離を表す。Error Accumulation Gradient (EAG) は位置誤差の累積速度を測るための指標であり、正解位置が与えられた最近傍時刻との時間差に対する位置誤差の比の中央値に相当する [18]。Velocity Error (VE) は速度精度を測るための指標であり、推定位置の移動速度と正解歩行速度の誤差の中央値に相当する。Requirement for Obstacle Avoidance (ROA) は推定移動軌跡のうち通行可能な領域上の地点が占める割合を表す。表 4 に示した計算式に従って各指標の値を 0 から 100 の範囲に正規化した後、同じく表 4 に示した重みで加重平均をとったものを最終的な評価点とする。

5. 結果と考察

5.1 評価結果

xDR Challenge 2023 に出場した 7 チームのうち上位 3 チームの本番データに対する平均評価点を表 5 にまとめる。全チームの中で指標の値（評価点とは異なる）が最も優れていたものを太字で示す。提案手法の CE は 0.59 [m], CA は 0.25 [m], EAG は 0.012 [m/s], VE は 0.065 [m/s], ROA は 0.97 であった。総合評価点は全チームの中で 2 番目に高かった。参考として、一部の本番データに対する推定移動軌跡を図 4 に示す。緑色の点線は PDR 単体、橙色の実線はハイブリッドな提案手法を表す。また、左は BLE の RSSI 情報が与えられ速度・角変位推定モデルを用いたとき、中央は RSSI 情報が与えられず速度・角変位推定モデルを用いたとき、右は RSSI 情報が与えられず速度・方位角推定モデルを用いたときの軌跡である。

5.2 考察

提案手法は全ての指標において全チームの中で 1 番目または 2 番目に優れていた唯一の手法であり、高精度かつ自然な移動軌跡を推定できていた。特に、絶対的な位置精度に関する指標である CE と相対的な位置精度に関する指標である EAG は最も優れており、絶対測位手法であるマップマッチングや多辺測量と相対測位手法である PDR を上手く組み合わせているといえる。手法 A と比べて僅かに総合評価点が低くなった原因の 1

(注1) : <https://www.aplix.co.jp/mybeacon/>

(注2) : <https://geoslam.com/solutions/zeb-horizon/>

表 4 評価指標

| | 最低評価時の指標値 | 最高評価時の指標値 | 正規化の計算式 | 重み |
|------------------------------------|-----------|------------------|------------------------------------|------|
| Circular error [m] | $v >= 30$ | $0 <= v <= 1$ | $100 - \frac{100}{29}(v - 1)$ | 0.25 |
| Circular accuracy [m] | $v >= 10$ | $v = 0$ | $100 - 10v$ | 0.20 |
| Error accumulation gradient [m/s] | $v >= 2$ | $0 <= v <= 0.05$ | $100 - \frac{100}{1.95}(v - 0.05)$ | 0.25 |
| Velocity error [m/s] | $v >= 2$ | $0 <= v <= 0.1$ | $100 - \frac{100}{1.9}(v - 0.1)$ | 0.15 |
| Requirement for obstacle avoidance | $v = 0$ | $v = 1$ | $100v$ | 0.15 |

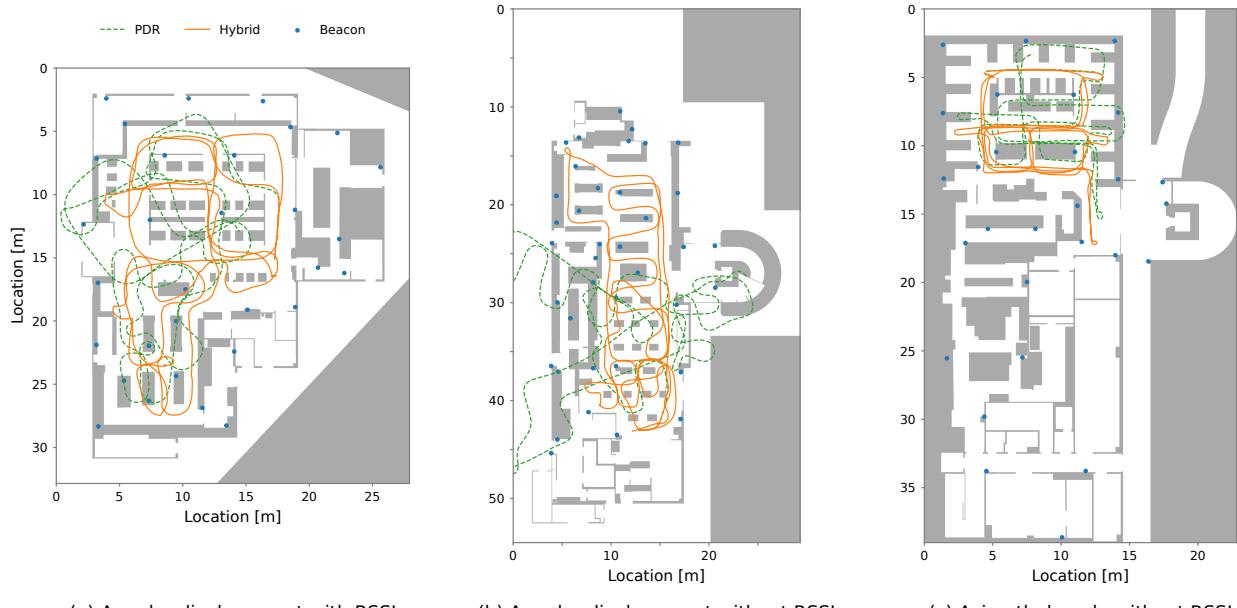


図 4 推定移動軌跡の例

表 5 上位 3 チームの評価点

| | CE | CA | EAG | VE | ROA | 総計 |
|------|---------------|--------------|---------------|-------|--------------|-------|
| 手法 A | 100.00 | 97.93 | 100.00 | 99.71 | 99.62 | 99.37 |
| 提案手法 | 100.00 | 97.51 | 100.00 | 99.97 | 97.41 | 99.11 |
| 手法 B | 96.11 | 92.18 | 98.85 | 97.96 | 92.60 | 95.98 |

つとして、推定移動軌跡が障害物上を通過しないように補正する仕組みの欠如が考えられる。提案手法では障害物上を通過するパーティクルの尤度を低くしてマップマッチングを実現したが、最終的な推定位置は全パーティクルの重心として求められるため必ずしも通行可能エリアのみを通るわけではない。実際、最も ROA が優れていた手法 A もパーティクルフィルタを用いたハイブリッドな手法であるが、パーティクルフィルタによる推定結果を基に後から大域的最適化を行う点で異なる。xDR Challenge 2023 のように非リアルタイムな測位を対象とする場合は、推定移動軌跡の補正や大域的最適化によりさらに測位性能が向上する余地があると考える。

6. むすび

本研究では低コストかつ高精度な屋内測位システムを目指して、深層学習による歩行速度・進行方向推定、マップマッチング、BLE による多辺測量をパーティクルフィルタ上で統合

したハイブリッドな測位手法を提案した。様々な歩容や歩行者に対応するため、幅広いタイムスケールの特徴を考慮できる DualCNN-Transformer を採用した。また、推定方位角の信頼性を定式化し、速度・角変位推定モデルと速度・方位角推定モデルを使い分けた。電波強度分布を要するフィンガープリントは用いずに、マップマッチングと多辺測量によって PDR の蓄積誤差を補正した。xDR Challenge 2023 における評価の結果、提案手法は全ての指標で高い水準にあり、特に位置精度に関する指標である CE と EAG は全出場チームの中で最も優れていた。一方で、推定移動軌跡が障害物上を通過しないようにするなどの改善の余地も見られた。

謝辞 本研究の一部は JSPS 科研費 (JP22K18422), NEDO 委託研究 (JPNP23003), NICT 委託研究 (22609), トランク中山株式会社の支援を受けています。

文 献

- [1] K. Huang, K. He, and X. Du, “A hybrid method to improve the ble-based indoor positioning in a dense bluetooth environment,” Sensors, vol.19, no.2, pp.1–15, 2019. <https://www.mdpi.com/1424-8220/19/2/424>
- [2] S. Traini, L. Sciallo, A. Trotta, and M. Di Felice, “Practical indoor localization via smartphone sensor data fusion techniques: A performance study,” 2019 16th IEEE Annual Consumer Communications & Networking Conference (CCNC), pp.1–7, 2019.
- [3] A. Poulose and D.S. Han, “Indoor localization using pdr

- with wi-fi weighted path loss algorithm,” 2019 International Conference on Information and Communication Technology Convergence (ICTC), pp.689–693, 2019.
- [4] T.-M.T. Dinh, N.-S. Duong, and K. Sandrasegaran, “Smartphone-based indoor positioning using ble ibeacon and reliable lightweight fingerprint map,” IEEE Sensors Journal, vol.20, no.17, pp.10283–10294, 2020.
 - [5] T.-M.T. Dinh, N.-S. Duong, and Q.-T. Nguyen, “Developing a novel real-time indoor positioning system based on ble beacons and smartphone sensors,” IEEE Sensors Journal, vol.21, no.20, pp.23055–23068, 2021.
 - [6] PDR ベンチマーク標準化委員会, “xdr challenge 2023 ~pdr and ble with lidar based gt~,” 産業技術総合研究所, <https://unit.aist.go.jp/harc/xDR-Challenge-2023/>, Oct. 2023.
 - [7] C. Chen, X. Lu, A. Markham, and N. Trigoni, “Ionet: Learning to cure the curse of drift in inertial odometry,” Proceedings of the AAAI Conference on Artificial Intelligence, vol.32, no.1, pp.6468–6476, April 2018. <https://ojs.aaai.org/index.php/AAAI/article/view/12102>
 - [8] S. Herath, H. Yan, and Y. Furukawa, “Ronin: Robust neural inertial navigation in the wild: Benchmark, evaluations, & new methods,” 2020 IEEE International Conference on Robotics and Automation (ICRA), pp.3146–3152, 2020.
 - [9] 吉田拓人, 野崎惇登, 廣井 慧, 梶 克彦, 米澤拓郎, 河口信夫, “歩容に頑健な pdr のための深層学習を用いた歩行速度推定手法,” 研究報告高齢社会デザイン (ASD), vol.2019, no.3, pp.1–7, 2019.
 - [10] N. Kawaguchi, J. Nozaki, T. Yoshida, K. Hiroi, T. Yonezawa, and K. Kaji, “End-to-end walking speed estimation method for smartphone pdr using dualcnn-lstm.,” IPIN (Short Papers/Work-in-Progress Papers), pp.463–470, 2019.
 - [11] K. Kano, T. Yoshida, N. Hayashida, Y. Asai, H. Matsuyama, S. Katayama, K. Urano, T. Yonezawa, and N. Kawaguchi, “Smartphone localization with solar-powered ble beacons in warehouse,” Distributed, Ambient and Pervasive Interactions. Smart Environments, Ecosystems, and Cities, pp.291–310, 2022.
 - [12] 加納一馬, 吉田拓人, 林田望海, 片山 晋, 松山 仁, 浦野健太, 米澤拓郎, 河口信夫, “物流倉庫におけるソーラー式 ble ビーコンと pdr を用いたハイブリッド測位,” マルチメディア, 分散, 協調とモバイルシンポジウム 2022 論文集, 第 2022 卷, pp.842–851, July 2022.
 - [13] Q. Wang, H. Luo, L. Ye, A. Men, F. Zhao, Y. Huang, and C. Ou, “Pedestrian heading estimation based on spatial transformer networks and hierarchical lstm,” IEEE Access, vol.7, pp.162309–162322, 2019.
 - [14] 吉田拓人, 廣井 慧, 米澤拓郎, 河口信夫, “歩容に頑健な pdr のための深層学習を用いた進行方向推定手法,” 研究報告ユビキタス コンピューティングシステム (UBI), vol.2020, no.7, pp.1–8, Feb. 2020.
 - [15] 吉田拓人, 浦野健太, 青木俊介, 米澤拓郎, 河口信夫, “加速度 の時空間情報を考慮した進行方向推定手法の検討,” マルチメディア, 分散協調とモバイルシンポジウム 2021 論文集, 第 2021 卷, pp.893–899, June 2021.
 - [16] R. Ichikari, K. Kaji, R. Shimomura, M. Kourogi, T. Okuma, and T. Kurata, “Off-site indoor localization competitions based on measured data in a warehouse,” Sensors, vol.19, no.4, pp.1–29, 2019. <https://www.mdpi.com/1424-8220/19/4/763>
 - [17] F. Potortì, et al., “Off-line evaluation of indoor positioning systems in different scenarios: The experiences from ipin 2020 competition,” IEEE Sensors Journal, vol.22, no.6, pp.5011–5054, 2022.
 - [18] M. Abe, K. Kaji, K. Hiroi, and N. Kawaguchi, “Piem: Path independent evaluation metric for relative localization,” 2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN), pp.1–8, 2016.