

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

吉田 拓人^{1,a)} 浦野 健太¹ 青木 俊介^{2,3} 米澤 拓郎¹ 河口 信夫^{1,3}

概要：本稿では、スマートフォンを用いた PDR (Pedestrian Dead Reckoning) のための進行方向推定手法について検討を行う。スマートフォンの頻繁な端末姿勢の変化に対応するため、進行方向推定手法にはセンサ姿勢の変化に対する頑健性が必須となる。そのため、加速度平面成分を用いてセンサ姿勢の変化によらず進行方向を推定できる PCA (Principal Component Analysis) ベースの手法が注目されてきた。しかし、我々は加速度平面成分の空間情報のみでは、歩行者が取り得るあらゆる歩容パターンの認識は困難であると考え、そこで我々は歩容に対する頑健性の向上を目的とし、加速度平面成分の時空間情報を用いて進行方向を推定する NN (Neural Network) ベースの手法を提案する。NN の学習と評価に用いるデータはスマートフォンと測量機器の TOPCON GT1205 を用いて収集する。NN のアーキテクチャとして、CNN (Convolutional Neural Network) と BiLSTM (Bidirectional Long Short-Term Memory) をベースとした 2 つを用意し、評価を行う。評価の結果、CNN が総合的に最も推定精度が高く、歩容に対する頑健性も高いことがわかった。

Direction Estimation Considering Time-Series and Spatial Information of Acceleration

Takuto Yoshida^{1,a)} Kenta Urano¹ Shunsuke Aoki^{2,3} Takuro Yonezawa¹ Nobuo Kawaguchi^{1,3}

1. はじめに

屋内測位技術はナビゲーションや人流解析をはじめとする様々なサービスへの応用が期待されている。PDR (Pedestrian Dead Reckoning) は屋内測位技術の一つであり、慣性センサを用いて人の移動軌跡を推定する。PDR の利点は低消費電力かつインフラが不要な点である。また、高いサンプリングレートで歩行者の移動軌跡を推定できるという特徴を持つ。

現在、研究が行われている PDR は一般的に INS (Strap-down Inertial Navigation System) と SHS (Step and Heading System) の 2 つに大別される [1]。前者の INS は 3 軸

加速度の二回積分によって、3 次元移動軌跡を推定する手法である。INS はセンサノイズに対して敏感であるため、高性能で高価な IMU (Inertial Measurement Unit) を利用するか、ノイズ対策が施された手法を用いることが多い。ノイズ対策の代表的な例として、IMU を足に装着することで位置の補正を行う ZUPT (Zero Velocity Updates) が挙げられる [2], [3], [4]。後者の SHS は歩行者の移動速度と進行方向をそれぞれ推定し、移動軌跡を更新する手法である。移動速度は歩幅推定とステップ検知から推定されるのが一般的である [5], [6]。一方で、進行方向の推定は角速度ベースの手法と PCA (Principal Component Analysis) ベースの手法に分けられる。角速度ベースの手法は一般的には重力方向とされる回転軸に射影した角速度を積分し、逐次進行方向を更新する。この手法は実装がシンプルであることが利点である。しかし、センサの保持方法や歩容などに単純化された仮定がなされているため、歩行者側にいくつか制約を与えることになる。また、時間経過とともに誤差が積分によって蓄積されるため、時間に比例して推定誤差が

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

² 国立情報学研究所
National Institute of Informatics

³ 名古屋大学 未来社会創造機構
Institutes of Innovation for Future Society,
Nagoya University

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

大きくなる。PCA ベースの手法は加速度平面成分の主成分を解析し、進行方向を推定する。人は歩行中、進行方向に対して加速と減速を繰り返しているため、加速度平面成分は進行方向の分散が大きくなる。そのため、加速度平面成分の第一主成分ベクトルが進行方向を示す。この手法は、角速度ベースのようにセンサの保持方法に制約がない。また、進行方向の推定には加速度平面成分の一定区間のセグメントを使用するため、時間とともに誤差は蓄積しない。

MEMS (Micro Electro-Mechanical Systems) 技術の急速な発展に伴い、スマートフォンの IMU を用いた PDR の研究が盛んに行われている。スマートフォンは安価な IMU を用いるため、多くの場合 SHS が採用される。また、日常生活でスマートフォンの保持方法に制約をかけることは困難であるため、進行方向推定には PCA ベース手法が使用される。しかし、PCA ベースの進行方向推定は歩容に対する頑健性が低く、横歩きや後退などの動作時に推定精度が低下するという課題を持つ。PCA ベースの手法は、加速度平面成分の空間情報を分析し、進行方向を推定している。しかし、我々は歩容に対する頑健性を獲得するためには、加速度平面成分の空間情報だけでは不十分であり、加速度平面成分の時系列情報も考慮する必要があると考える。

そこで、我々は加速度の時空間情報を考慮した NN (Neural Network) ベースの進行方向推定手法を提案する。本手法の特徴は、NN を用いて時系列に並んだ加速度平面成分から進行方向ベクトルを End-to-end で推定する点である。提案手法の概要は図 1 に示す。NN の学習、各手法の評価用のデータはスマートフォンと測量機器の TOPCON GT1205 を用いて収集する。データの前処理はリサンプリング、座標変換、加速度平面成分の抽出、ノイズ除去の 4 つを行う。NN のモデルは CNN (Convolutional Neural Network) と BiLSTM (Bidirectional Long Short-Term Memory) をベースとした 2 つを用意した。NN の学習は GT1205 で収集した正解データと予測値の誤差を NN にフィードバックすることによって行う。提案手法の詳細は 3 章で議論する。また、4 章では通常の歩行、横歩き、後退の 3 種類の歩容を用いた評価実験を通じて、提案手法が PCA ベースの手法よりも歩容に対して頑健であることを示す。

2. 関連研究

PDR の多くは INS と SHS の 2 つに大別される [1]。INS は 3 軸加速度の二回積分によって 3 次元位置を更新するため、センサの精度と推定精度が密接に関わる。そのため、航空機などで採用される INS は初めからノイズが少ない高精度センサが使用される。しかし、歩行者向けの INS はセンサに高いコストがかけられず、ノイズを含む安価なセンサを使用するため、発生する位置誤差を補正する必要がある。代表的な補正手法として、ZUPT が挙げられる [2], [3], [4]。ZUPT はセンサを足に装着し、足が地面に

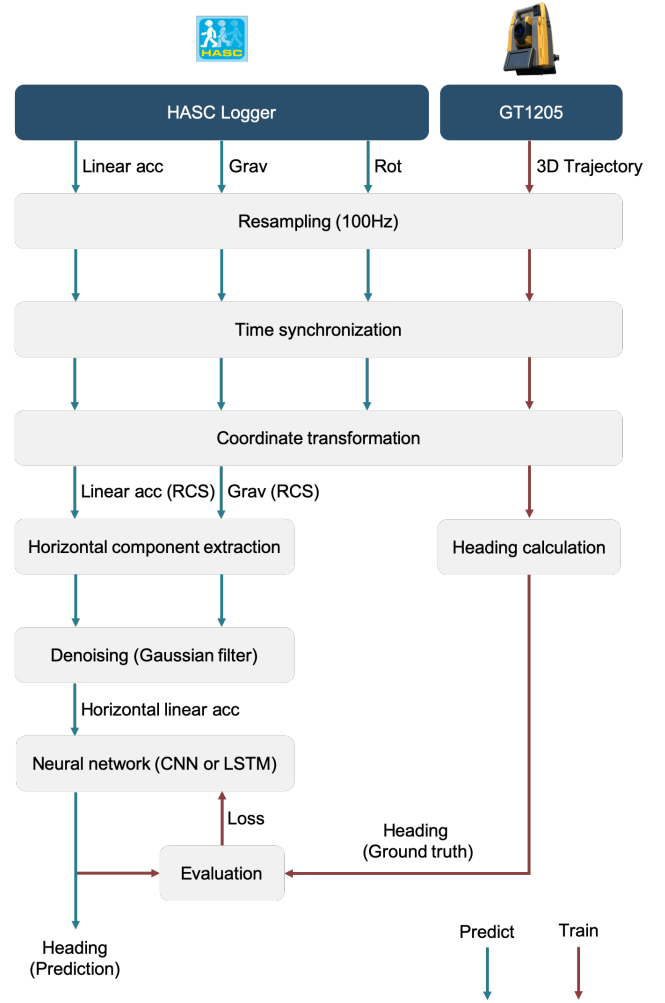


図 1 提案手法の概要

設置した時に速度がゼロになることを利用して、一步の間の加速度の積分値がゼロとなるように修正する。しかし、日常生活でスマートフォンを足に装着することは困難であるため、スマートフォンを用いた PDR では一般的に INS は採用されない。

SHS は歩行者の移動速度と進行方向をそれぞれ推定し、移動軌跡を更新する。移動速度は加速度を用いた歩幅推定とステップ検知から推定される [5], [6]。一方で、進行方向の推定は角速度ベースの手法と PCA ベースの手法に分けられる。角速度ベースの手法は歩行時の回転軸を重力方向 \mathbf{g} と仮定し、式 (1) に従い、角速度 ω を重力方向に射影、式 (2) に従い、射影した角速度 ω_z を積分し、逐次進行方向 h を更新する [7]。

$$\omega_z = \frac{\omega \cdot \mathbf{g}}{|\mathbf{g}|} \quad (1)$$

$$h = \sum -\omega_z dt \quad (2)$$

しかし、この手法は歩行者側にいくつかの制約を与えるため、実用上不便な点がある。例えば、歩行中にセンサを回転させると歩行者が進行方向を変えたことと誤認識するため、




図 2 加速度平面成分の分布と進行方向の関係

歩行中はセンサを体のどこかに固定する必要がある。反対に、歩行者が横歩きや後退を行う場合、センサは回転しないため、歩行者の進行方向は変化していないと誤認識される。つまり、歩行者の進行方向は体に対して、常に一方である必要がある。また、時間経過とともに蓄積される累積誤差も課題の一つである。

それゆえ、スマートフォンを用いた PDR の多くは PCA ベースの進行方向推定を採用する [8], [9], [10], [11]。PCA ベースの手法は一定セグメントの加速度平面成分の主成分を分析し進行方向を推定する。人は歩行中、図 2 に示すように進行方向に対して加速と減速を繰り返しているため、加速度平面成分は進行方向の分散が大きくなる。そのため、加速度平面成分を PCA した結果得られる第一主成分ベクトルが進行方向を示す。Deng らが提案する RMPCA[10] は回転ベクトルを用いて、あらかじめ基準座標系に変換した加速度を用いるため、センサの保持方法の制約を緩和させている。また、進行方向の推定は一定区間のセグメントごとに独立しているため、角速度ベースのように時間とともに誤差が累積しない。

しかし、PCA ベースの手法は歩容に対する頑健性が低く、横歩きや後退などの歩容に対しては推定精度が低下する。歩容による推定精度低下の原因は横歩きや後退では加速度平面成分に加速と減速を繰り返す特徴が明確に表れないことが原因であると考えられる。このことから、我々は歩容に頑健な進行方向推定を実現するためには、加速度平面成分の空間情報だけでは情報が不十分であり、空間情報に加えて時系列変化のパターンも考慮する必要があると考える。

そこで、我々は加速度の時空間情報を考慮した NN ベースの進行方向推定手法を提案する。近年、NN を用いた PDR の研究は盛んに行われており [12], [13]、歩容に対する頑健性が向上するという結果も報告されている [14], [15]。本提案手法では Chen らの手法 [12] を参考とし、CNN と BiLSTM をベースとした 2 つのモデルを用意した。提案手法の詳細については、本稿の 3 章で議論する。

表 1 CNN のハイパーパラメータの候補

Conv1	kernel size	3, 6, 9 , 12
	output channels	8 , 16, 32
Conv2	kernel size	3, 6, 9 , 12
	output channels	8, 16 , 32
FC	hidden size	16, 32 , 64

表 2 BiLSTM のハイパーパラメータの候補

num layers	2 , 3
hidden size	16, 32 , 64, 128
dropout	0, 0.25, 0.50

3. 加速度平面成分の時空間情報を考慮した進行方向推定

本章では加速度平面成分の時空間情報を考慮した進行方向推定手法について説明する。本提案手法の特徴は回帰モデルとして NN を用いる点である。今回は NN モデルとして CNN と BiLSTM をベースとした 2 つを用意し、それぞれで検証を行う。図 3 は CNN ベースのモデルと BiLSTM ベースのモデルを示す。2 つのモデルは時系列に並んだ加速度平面成分から歩行者の進行方向を End-to-end で推定する。CNN ベースは畳み込み層で特徴抽出を行い、全結合層で進行方向を推定する。また、途中に挿入されているバッチ正規化や活性化関数 ReLU は学習の安定化に寄与する。各層のハイパーパラメータは表 1 に示した候補からグリッドサーチによって決定する。BiLSTM ベースは 2 層の BiLSTM 層で特徴抽出を行い、全結合層で進行方向を推定する。Dropout 層は学習の安定化に寄与する。各層のハイパーパラメータは表 2 に示した候補からグリッドサーチによって決定する。入力データと出力データの形式は CNN ベースと BiLSTM ベースで共通である。入力は 4 秒間分の加速度平面成分 (400×2 次元)、出力はその区間における進行方向の平均を示す単位ベクトル (2 次元) である。この時、出力を角度で表現しないのは、円周期の問題があるためである [16]。例えば、同じ 10 度の誤差でも、真の方位が 5 度の場合、355 度の予測値の MSE は 122500 であるのに対し、25 度の予測値の MSE は 400 度となる。この評価の方法は NN の最適化を妨げる可能性が高い。

次にモデルの学習方法について説明する。損失関数には回帰問題で一般的に用いられる MSE (Mean Squared Error) を、最適化アルゴリズムには Adam[17] を用いる。データセットは訓練用 (2595.14m)、検証用 (2022.92m)、評価用 (927.99m) の 3 つに分ける。このとき、通常の歩行、横歩き、後退の歩容がそれぞれ均等になるように配分する。図 4 はバッチサイズ 512、学習率 0.0001、エポック数 500 で学習させた際の検証誤差である。評価では、500 エポックの間に検証誤差が最小となったタイミングのモデルを用いる。

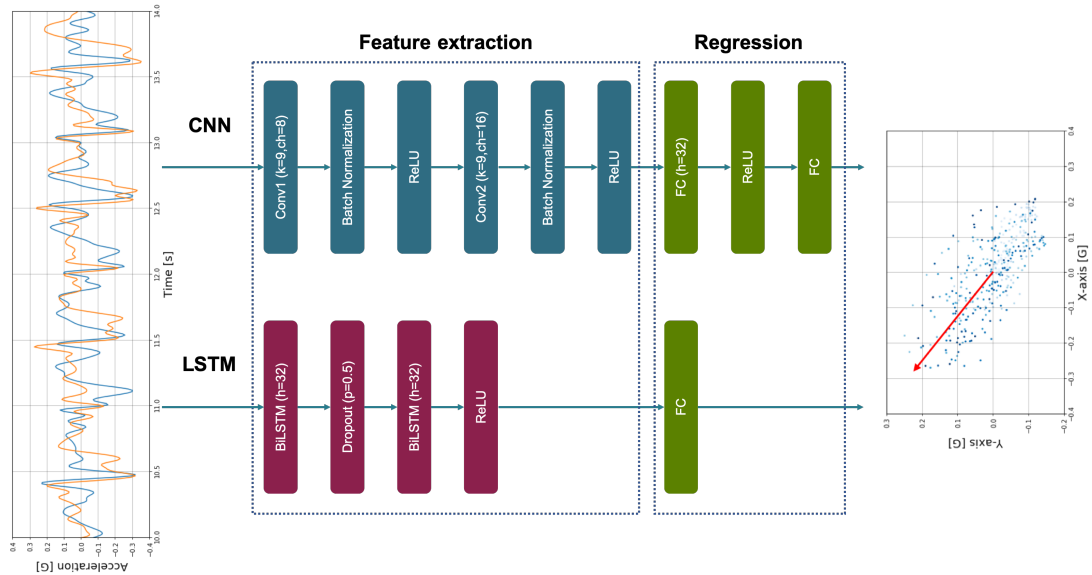


図 3 ニューラルネットワークを用いた進行方向推定




図 4 CNN と BiLSTM の検証誤差



図 5 GT1205 を用いた正解移動軌跡の計測

4. 評価

本章では、提案手法の評価を行う。はじめに NN の学習、手法の評価に用いるデータの収集方法について、続いて収集したデータの前処理の方法について説明する。最後に提案手法である 2 つの NN モデルと既存手法の PCA の進行方向推定精度を算出し、考察を行う。

4.1 データ収集

NN の学習、手法の評価にはスマートフォンから収集した慣性データと歩行者の正解移動軌跡が必要である。慣性データの収集には行動センシングデータ収集サポートツールである HASC Logger[18] を用い、デバイスは Google Pixel4 を使用する。HASC Logger を用いて収集するデータは線形加速度、重力加速度、回転ベクトルである。歩行者の正解移動軌跡の収集には測量機器である GT1205 を使用する。GT1205 はレーザー光を用いて移動する対象の三次元座標を計測する。サンプリングレートは最大 10Hz、精度は専用の反射プリズムを用いて誤差数 mm を実現できる。図 5 は実際の計測の様子を示す。専用の反射プリズムは被験者の頭上にヘルメットで固定する。GT1205 は歩行者の被験者の頭上に設置してある反射プリズムをトラッキングし、正解移動軌跡を記録する。被験者の人数は 4 人、

歩容は通常の歩行と横歩きと後退の 3 種類、記録した移動距離は合計で 5637.89m である。

HASC Logger で収集した慣性データと GT1205 で収集した移動経路データをデータセットとして利用するためには、座標と時刻の同期が必要となる。HASC Logger で収集した回転ベクトルの基準座標系は、Y 軸が北を、X 軸が東を指している。つまり、GT1205 の基準座標系も地磁気を基準とすることによって、HASC Logger との座標同期が実現できる。そこで、GT1205 の基準座標を決める後視点を GT1205 本体から見て北の方角に設置する。時刻同期は被験者が計測のスタートとゴールで跳躍することで実現できる。図 6 は HASC Logger で収集した 3 軸加速度のノルムと GT1205 で収集した Z 軸座標を並べたグラフである。HASC Logger 側は、3 軸加速度のノルムの極小値となる箇所がスタートとゴールの時刻である。一方で、GT1205 は Z 軸座標が極大値となる箇所がスタートとゴールの時刻である。

4.2 データの前処理

我々はデータの前処理として、リサンプリング、座標変換、加速度平面成分の抽出、ノイズ除去の 4 つを行う。はじめに、慣性データと移動経路データを近傍補完法を用い




図 6 3 軸加速度のノルムと Z 軸座標の波形を用いた時刻同期

て、全てのデータを 100Hz ヘアアップサンプリングする。続いて、座標変換を行い慣性データと移動経路データの座標同期を行う。慣性データの座標系は右手系、移動経路データは左手系なので、移動経路データの X 軸と Y 軸を入れ替えることで右手系に揃える。また、HASC Logger で収集した線形加速度と重力加速度はデバイス座標系であるため、回転ベクトルを用いてデバイス座標系を地磁気を基準とした座標系に変換する。続いて、式 (3) に従い、線形加速度 \mathbf{l} と重力加速度 \mathbf{g} から線形加速度の垂直成分 \mathbf{l}_v を計算、式 (4) に従い、垂直成分を線形加速度から引くことにより平面成分 \mathbf{l}_h を抽出する [19]。

$$\mathbf{l}_v = \left(\frac{\mathbf{l} \cdot \mathbf{g}}{\mathbf{g} \cdot \mathbf{g}} \right) \mathbf{g} \quad (3)$$

$$\mathbf{l}_h = \mathbf{l} - \mathbf{l}_v \quad (4)$$

最後に、加速度平面成分 \mathbf{l}_h に含まれるノイズを除去するために、ガウシアンフィルタを適用する。

4.3 評価結果

評価指標には [16] で用いられる式 (5) の評価式を用いる。評価式の値は推定進行方向の誤差を表すため、値が小さいほど推定精度は高い。式 (5) の θ_i は正解進行方向の角度を示し、 $\hat{\theta}_i$ は推定進行方向の角度を示す。

$$\text{HeadingLoss} = \frac{1}{2N} \sum_{i=1}^N \left(\left(\sin(\theta_i) - \sin(\hat{\theta}_i) \right)^2 + \left(\cos(\theta_i) - \cos(\hat{\theta}_i) \right)^2 \right) \quad (5)$$

図 7 は CNN と BiLSTM と PCA ベースの手法を歩容ごとに評価した結果である。全歩容で評価を行った結果、CNN が最も推定精度が高く誤差は 0.197、続いて BiLSTM が 0.458、PCA は 0.66 となった。通常の前進歩行で評価を行った結果は PCA が最も推定精度が高く誤差は 0.079、続いて CNN が 0.179、BiLSTM は 0.197 となった。横歩きで評価を行った結果は CNN が最も推定精度が高く誤差は 0.22、続いて BiLSTM が 0.363、最も精度が低い PCA は CNN の 3.5 約倍の 0.802 となった。後退で評価を行った結果は CNN が最も推定精度が高く誤差は 0.189、続い




図 7 歩容ごとの進行方向推定の評価結果

て BiLSTM が 1.159、最も精度が低い PCA は CNN の約 8 倍の 1.541 となった。以上の結果より、CNN が総合的に最も推定精度が高く、歩容に対する頑健性も高いことがわかった。

図 8 は前進時の推定進行方向を示す。どの手法も正解データを追従できているが、進行方向が変化するタイミングに焦点を当てると、CNN と BiLSTM よりも PCA の方が正確に追従できていることがわかる。例えば、グラフの 35 秒と 105 秒付近の CNN と PCA の結果を比較すると CNN は推定値が大きく下ぶれしているのに対して、PCA は正確に追従できている。その結果は図 11 の推定経路にも反映されており、経路の各コーナーで PCA と CNN の間に精度の差が出ている。

図 9 は横歩き時の推定進行方向を示す。CNN のみがある程度正解データの追従している。BiLSTM は 30 秒から 50 秒、90 秒から 110 秒などの一部の区間で 60 度から 90 度ほどの誤差がある。一方で、PCA は進行方向の変化の特徴は捉えられているものの、ほとんどの区間で定常的に 90 度の誤差が生じている。この結果より、横歩きの際も体正面方向に加速度の変動が生じており、PCA は体の正面方向が進行方向であると誤認識していると考察される。図 12 は横歩き時の推定経路を示す。一見、PCA の経路が最も正確に見えるが、スタートから 60 秒後に通過する地点を見比べると PCA の推定した経路と正解経路は 90 度ずれていることがわかる。

図 10 は後退時の推定進行方向を示す。後退においては、CNN のみがある程度正解データの傾向を捉えている一方で、BiLSTM と PCA は追従できていない。PCA は進行方向の変化の特徴は捉えられているものの、ほとんどの区間で定常的に 180 度の誤差が生じている。この結果より、横歩きの際と同様に、後退の際も PCA は体の正面方向が進行方向であると誤認識していると考察される。図 13 は後退時の推定経路を示す。CNN は正解経路の概形をある程度追従できているのに対し、BiLSTM と PCA は大きく経路を外れている。

以上の結果より、CNN の歩容に対する頑健性の高さが示された。一方で、CNN の通常の前進歩行における進行方向変化時の推定精度の改善、横歩きと後退時における推定精度のベースラインの向上は今後の課題となる。




図 8 前進時の進行方向推定




図 9 横歩き時の進行方向推定

5. まとめ

本稿では、スマートフォンを用いた PDR のための進行方向推定手法について検討を行なった。スマートフォンを用いた PDR では端末姿勢の変化に対して頑健な進行方向推定手法が必要であり、PCA ベースの手法が注目されてきた。しかし、PCA ベースの手法は歩容に対する頑健性が低く、その改善が課題があった。我々は加速度平面成分の空間情報を分析する PCA ベースのアプローチでは、歩行者が取り得るあらゆる歩容パターンの認識は困難であると考え、加速度平面成分の時空間情報を用いて進行方向を推定する NN (Neural Network) ベースの手法を提案した。NN のモデルとして CNN と BiLSTM をベースとした 2 つのモデルを提案し、PCA と評価実験を行った。学習と評価に用いるデータは Hasc Logger と GT1205 を利用して収集した。評価の結果、CNN の推定精度が総合的に最も高く、歩容に対する頑健性にも優れていることがわかった。

提案手法の課題として、通常の前進歩行における進行方向変化時の推定精度の改善、横歩きと後退における推定精度の改善が挙げられた。今後の作業は、より多様な被験者、経路、歩容、端末保持位置の学習データの収集を行い、NN ベースのモデルの学習と評価を行う予定である。この学習と評価によって、提案手法の推定精度のベースラインを向上させるとともに、手法の強みと弱みをより明確にすることが目的である。

謝辞

本研究の一部は、科研費基盤研究 B (17H01762)、AMED 委託研究 (20he0622042h0001) の支援を受けています。

参考文献

- [1] Robert Harle. A survey of indoor inertial positioning systems for pedestrians. *IEEE Communications Surveys Tutorials*, Vol. 15, No. 3, pp. 1281–1293, 2013.
- [2] S Godha and G Lachapelle. Foot mounted inertial system for pedestrian navigation. *Measurement Science and Technology*, Vol. 19, No. 7, p. 075202, may 2008.
- [3] Wenchao Zhang, Xianghong Li, Dongyan Wei, Xinchun Ji, and Hong Yuan. A foot-mounted pdr system based on imu/ekf+hmm+zupt+zaru+hdr+compass algorithm. In *2017 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1–5, 2017.
- [4] A.R. Jiménez, F. Seco, J.C. Prieto, and J. Guevara. Indoor pedestrian navigation using an ins/ekf framework for yaw drift reduction and a foot-mounted imu. In *2010 7th Workshop on Positioning, Navigation and Communication*, pp. 135–143, 2010.
- [5] Moustafa Alzantot and Moustafa Youssef. Uptime: Ubiquitous pedestrian tracking using mobile phones. In *2012 IEEE Wireless Communications and Networking Conference (WCNC)*, pp. 3204–3209, 2012.
- [6] Jin Li, Qing Wang, Xiao Liu, Shun Cao, and Feng Liu. A pedestrian dead reckoning system integrating low-cost mems inertial sensors and gps receiver. *Journal of Engineering Science and Technology Review*, Vol. 7, pp. 197–203, 04 2014.
- [7] Wonho Kang and Youngnam Han. Smartpdr: Smartphone-based pedestrian dead reckoning for indoor localization. *IEEE Sensors Journal*, Vol. 15, No. 5, pp. 2906–2916, 2015.
- [8] Kai Kunze, Paul Lukowicz, Kurt Partridge, and Bo Begole. Which way am i facing: Inferring horizontal device orientation from an accelerometer signal. In *2009 International Symposium on Wearable Computers*, pp. 149–150, 2009.
- [9] Kai Kunze, Paul Lukowicz, Kurt Partridge, and Bo Begole. Which way am i facing: Inferring horizontal device orientation from an accelerometer signal. In *2009 International Symposium on Wearable Computers*, pp. 149–150, 2009.




図 10 後退時の進行方向推定




図 11 前進時の推定経路




図 12 横歩き時の推定経路




図 13 後退時の推定経路

- [10] Zhi-An Deng, Guofeng Wang, Ying Hu, and Di Wu. Heading estimation for indoor pedestrian navigation using a smartphone in the pocket. *Sensors*, Vol. 15, No. 9, pp. 21518–21536, 2015.
- [11] Ryoji Ban, Katsuhiko Kaji, Kei Hiroi, and Nobuo Kawaguchi. Indoor positioning method integrating pedestrian dead reckoning with magnetic field and wifi fingerprints. In *2015 Eighth International Conference on Mobile Computing and Ubiquitous Networking (ICMU)*, pp. 167–172, 2015.
- [12] Changhao Chen, Xiaoxuan Lu, Andrew Markham, and Niki Trigoni. Ionet: Learning to cure the curse of drift in inertial odometry. *CoRR*, Vol. abs/1802.02209, , 2018.
- [13] Hang Yan, Sachini Herath, and Yasutaka Furukawa. Ronin: Robust neural inertial navigation in the wild: Benchmark, evaluations, and new methods. *CoRR*, Vol. abs/1905.12853, , 2019.
- [14] Takuto Yoshida, Junto Nozaki, Kenta Urano, Kei Hiroi, Takuro Yonezawa, and Nobuo Kawaguchi. Gait dependency of smartphone walking speed estimation using deep learning (poster). In *Proceedings of the 17th Annual International Conference on Mobile Systems, Applications, and Services, MobiSys '19*, p. 641–642, New York, NY, USA, 2019. Association for Computing Machinery.
- [15] Nobuo Kawaguchi, Junto Nozaki, Takuto Yoshida, Kei Hiroi, Takuro Yonezawa, and Katsuhiko Kaji. End-to-end walking speed estimation method for smartphone PDR using dualcnn-lstm. In Francesco Potortì, Valérie Renaudin, Kyle O’Keefe, and Filippo Palumbo, editors, *Short Paper Proceedings of the Tenth International Conference on Indoor Positioning and Indoor Navigation - Work-in-Progress Papers (IPIN-WiP 2019) co-located with the Tenth International Conference on Indoor Positioning and Indoor Navigation (IPIN 2019), Pisa, Italy, September 30th - October 3rd, 2019*, Vol. 2498 of *CEUR Workshop Proceedings*, pp. 463–470. CEUR-WS.org, 2019.
- [16] Qu Wang, Haiyong Luo, Langlang Ye, Aidong Men, Fang Zhao, Yan Huang, and Changhai Ou. Pedestrian heading estimation based on spatial transformer networks and hierarchical lstm. *IEEE Access*, Vol. 7, pp. 162309–162322, 2019.
- [17] Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *CoRR*, Vol. abs/1412.6980, , 2014.
- [18] Katsuhiko Kaji, Hodaka Watanabe, Ryoji Ban, and Nobuo Kawaguchi. Hasc-ipsc: Indoor pedestrian sensing corpus with a balance of gender and age for indoor positioning and floor-plan generation researches. In *Proceedings of the 2013 ACM Conference on Pervasive and Ubiquitous Computing Adjunct Publication, UbiComp '13 Adjunct*, p. 605–610, New York, NY, USA, 2013. Association for Computing Machinery.
- [19] D. Mizell. Using gravity to estimate accelerometer orientation. In *Seventh IEEE International Symposium on Wearable Computers, 2003. Proceedings.*, pp. 252–253, 2003.