

# スマートフォンを用いた歩行者自律航法のための 水平加速度に基づいた歩き方の違いに頑健な進行方向推定

加納 一馬<sup>1,a)</sup> 吉田 拓人<sup>1</sup> 浦野 健太<sup>1</sup> 米澤 拓郎<sup>1</sup> 河口 信夫<sup>1</sup>

受付日 2023年9月6日, 再受付日 2023年12月13日,  
採録日 2024年3月6日

**概要:** 本研究ではスマートフォンを用いた歩行者自律航法 (PDR: Pedestrian Dead Reckoning) による測位のための進行方向推定に取り組む。スマートフォンの保持姿勢の変化に対応するには、加速度などの特徴に基づいてセンサ姿勢と進行方向の関係を考慮する手法が有効である。しかし既存手法には横歩きや後ろ歩きといった歩き方の違いに対する頑健性の不足などの課題がある。そこで我々は深層学習によって水平加速度の多様な時空間的特徴を考慮して進行方向を推定する手法を提案する。提案手法では測定した加速度、重力加速度、回転ベクトルからグローバル座標系における水平加速度を計算し、一定期間の水平加速度を深層学習モデルに入力してその間の平均進行方向を指す単位ベクトルを予測させる。複数の歩き方に対応したデータセットを作成し、Convolutional Neural Network (CNN), Bidirectional Long Short-Term Memory (BiLSTM), DualCNN-LSTM, DualCNN-Transformer の4つのモデルを用いて提案手法の有効性を検証した。その結果、提案手法は既存手法と比べて歩き方に対する頑健性が向上しており、DualCNN-LSTM と DualCNN-Transformer モデルを用いたときに特に高精度であることが分かった。

**キーワード:** 屋内位置推定, 屋内測位, 深層学習, データセット, PDR

## Gait-Robust Heading Estimation Based on Horizontal Acceleration for Pedestrian Dead Reckoning with Smartphones

KAZUMA KANO<sup>1,a)</sup> TAKUTO YOSHIDA<sup>1</sup> KENTA URANO<sup>1</sup> TAKURO YONEZAWA<sup>1</sup> NOBUO KAWAGUCHI<sup>1</sup>

Received: September 6, 2023, Revised: December 13, 2023,  
Accepted: March 6, 2024

**Abstract:** This study tackles heading estimation for positioning with smartphone-based Pedestrian Dead Reckoning (PDR). In dealing with changes in the holding posture of smartphones, it works to consider the relationship between sensor orientation and heading on the basis of features such as acceleration distribution. However, the existing methods lack robustness against gait differences, for example, sideways and backward walking. Therefore, we propose a novel approach considering various spatiotemporal features of horizontal acceleration with deep learning. The proposed method calculates horizontal acceleration in the global coordinate system from measured acceleration, gravitational acceleration, and rotation vector. Then, it inputs the horizontal acceleration over a certain period into a deep neural network model and predicts the unit vector directed to the mean heading during that period. We created a dataset supporting multiple gaits and evaluated the method using four models: Convolutional Neural Network (CNN), Bidirectional Long Short-Term Memory (BiLSTM), DualCNN-LSTM, and DualCNN-Transformer. The result showed that the proposed method improved gait robustness compared to the existing and especially achieved the highest accuracy when using the DualCNN-LSTM and DualCNN-Transformer models.

**Keywords:** indoor localization, indoor positioning, deep learning, dataset, PDR

## 1. はじめに

歩行者自律航法 (PDR: Pedestrian Dead Reckoning) は屋内でも利用可能な人の測位技術の一つであり、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を基に測位開始時からの相対的な移動軌跡を推定する。PDRの利点として低消費電力、環境側の設備が不要、高い頻度で位置を推定可能などが挙げられ、スマートフォンユーザの測位への応用も期待されている。PDR手法の多くは、加速度の二階積分によって三次元の移動軌跡を求める方式と、歩行速度と進行方向をそれぞれ推定し二次元の移動軌跡を求める方式の2つに大別される [1]。スマートフォンに搭載された Micro Electro Mechanical Systems (MEMS) センサを活用する場合は、十分な測定精度が期待できないなどの理由から一般的に後者の方式が用いられる。

歩行速度の推定手法は、ステップ検出と歩幅推定からなる手法 [2], [3] と、歩行速度を直接推定する手法 [4], [5], [6] があり、これらは高い精度での推定が可能になってきている。一方、進行方向の推定手法は、鉛直軸周りのセンサの回転角をそのまま進行方向の変化と見なす手法 [7] と、センサ姿勢と実際の進行方向の関係まで考慮する手法に分けられる。測位中にセンサ姿勢と進行方向の関係が変わると前者の手法は破綻するため、センサの姿勢に応じて座標変換した加速度などの特徴から進行方向を推定する後者の手法が目立ってきた。しかし既存の後者の手法は横歩きや後ろ歩きといった異なる歩き方に対する頑健性に依然として課題がある。歩き方に対する頑健性は複雑な動きが多く見られる産業現場への応用において特に重要である。例えば物流倉庫内における作業員の測位というユースケースについて考えると、作業員は棚に置かれた商品を探しながら横に歩いたりハンドパレットを引いて後方に歩くことも頻繁に想定される。このような現場では進行方向推定の歩き方に対する頑健性が測位精度に直結すると考えられる。

そこで我々はグローバル座標系の水平加速度から進行方向を data-driven に推定する手法を提案する。深層学習によって多様な時空間的特徴を考慮して歩き方に対する頑健性の向上を図る。提案手法の概要を図 1 に示す。まず、スマートフォンで測定した加速度、重力加速度、回転ベクトルからグローバル座標系における水平加速度を計算する。続いて、一定期間のグローバル座標系の水平加速度を深層学習モデルに入力してその間の平均進行方向を指す単位ベクトルを予測させる。本研究では Convolutional Neural Network (CNN), Bidirectional Long Short-Term Memory (BiLSTM), DualCNN-LSTM, DualCNN-Transformer の4つのモデルを扱う。複数の歩き方に対応したデータセッ

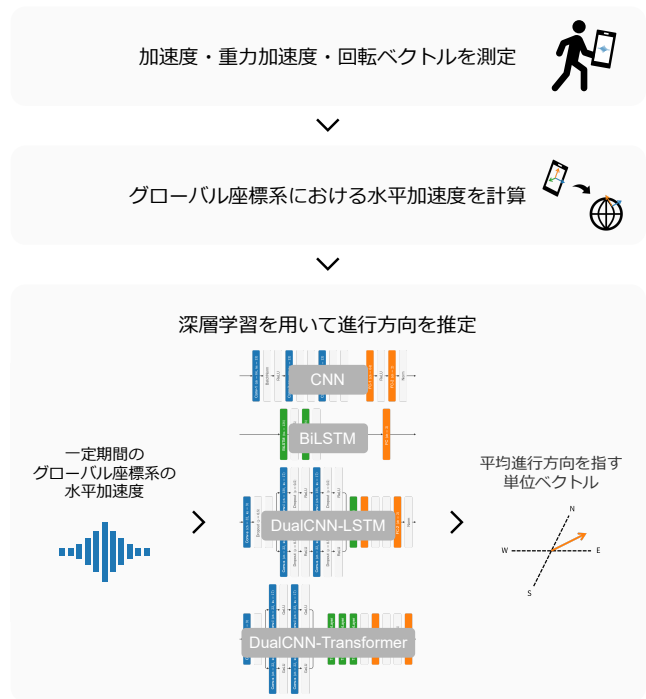


図 1 提案手法の概要

Fig. 1 Overview of proposed method.

トを作成し推定精度を評価したところ、提案手法は既存手法と比べて歩き方に対する頑健性が向上しており、DualCNN-LSTM と DualCNN-Transformer モデルを用いたときに特に高精度であることが分かった。

以降、スマートフォンを用いた PDR の要件や従来手法の課題について 2 章で論じる。次に 3 章で関連研究についてまとめる。続いて、提案手法における水平加速度の導出方法やモデルの構造および学習方法などについて 4 章で詳しく述べる。データセットに含まれる歩行パターンやその収集方法などについては 5 章で説明する。最後に 6 章で提案手法と既存手法の進行方向推定精度や測位システムとしての性能を評価し考察する。我々の知る限り、提案手法はグローバル座標系のデータを深層学習モデルへの入力とした初めての PDR 手法である。また、本研究は横歩きや後ろ歩きなどの歩き方についてラベル付けされた PDR 向けデータセットを作成した初めての研究である。本研究の貢献を以下にまとめる。

- グローバル座標系の水平加速度情報を用いた深層学習による歩き方に頑健な進行方向推定手法を提案。
- グローバル座標系の高精度な位置データを含む複数の歩き方に対応した PDR 向けデータセットを作成。
- 4つの深層学習モデルを用いて推定精度を評価し、歩き方に頑健な推定に有効なモデルの構造を検証。

## 2. 課題と目的

### 2.1 スマートフォンを用いた PDR の要件

PDR 手法の多くは、加速度の二階積分によって三次元

<sup>1</sup> 名古屋大学 大学院工学研究科  
Graduate School of Engineering, Nagoya University  
a) kazuma@ucl.nuee.nagoya-u.ac.jp




図 2 水平加速度の分布と進行方向

Fig. 2 Heading directions and distributions of horizontal acceleration.

の移動軌跡を求める方式と、歩行速度と進行方向をそれぞれ推定し二次元の移動軌跡を求める方式の2つに大別される [1]。前者の方式は高階の積分操作を伴うためセンサの測定誤差の影響を受けやすく、航空機などの慣性航法システムでは高精度なセンサと合わせて用いられている。一方、スマートフォンのセンサは一般的に安価な MEMS として実装されるため、感度誤差やドリフト誤差、ノイズなどを多く含む。PDR での代表的な測定誤差の補正手法として Zero Velocity Update (ZUPT) がある [8], [9]。ZUPT ではセンサを足に装着し、足が接地する時に速度はゼロになるという仮定の下、重力成分を除いた加速度の一步ごと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のは困難であり、スマートフォンを用いた PDR では歩行速度推定と進行方向推定からなる後者の方式が採用されるのが一般的である。

単純な進行方向推定手法として鉛直軸周りのセンサの回転角をそのまま進行方向の角変位と見なす手法が挙げられる [7]。しかしこの仮定はいくつかの制約を強いるため実用性の低下に繋がる。第一に、歩行者から見たセンサの姿勢が変わるとその分だけ実際の進行方向と推定進行方向の間に乖離が生まれるため、センサを身体に固定する必要がある。特にスマートフォンのセンサを活用する場合、歩行者はスマートフォンを手で保持して操作することも想定されるため、センサの姿勢を一定に保ち続けるのは現実的でない。第二に、横歩きや後ろ歩きをしてもセンサの姿勢は変わらないため前歩きと区別できない。これらの点から、スマートフォンを用いた PDR における進行方向推定では、センサ姿勢自体に加えてセンサ姿勢と実際の進行方向の関係も含めて推定する必要があると考える。

## 2.2 センサ姿勢と進行方向の関係を考慮した手法の課題

センサ姿勢と進行方向の関係を考慮した進行方向推定における手順の例を以下に示す。

- (a) センサ姿勢を計測または推定。
  - (b) センサ姿勢に応じてセンサの測定データを座標変換。
  - (c) 座標変換後の測定データから進行方向を推定。
- センサ姿勢や進行方向は時刻ごとに独立して計測または推定する場合がある。操作 (a) と (b) でセンサ姿勢の違いを吸収する。操作 (c) では歩行運動に由来する一定期間の加速度などの特徴から進行方向を推定する。厳密には、センサ姿勢の代わりに鉛直軸周りのセンサの向きのみを考慮する場合や、明示的に座標変換せずにセンサの姿勢に起因する成分とセンサ座標系から見た進行方向に起因する成分の和として最終的な進行方向を推定する場合もあるが、センサ姿勢と進行方向の関係を加速度などの特徴に基づいて推定している点においてこれらは本質的に共通している。

歩行運動に由来する加速度の特徴の例として、人は歩行時に進行方向に対して加速と減速を繰り返しているため、加速度の水平成分は進行方向に沿って分布しやすいことが挙げられる。この特性を利用して水平加速度の第 1 主成分や平均ベクトルとして進行方向を推定する手法が提案されてきた [10], [11], [12], [13]。しかしこれらの手法は歩き方に対する頑健性が不十分であり、横歩きや後ろ歩き時には推定精度が著しく低下する。これは歩き方によって特徴の現れ方が異なるためである。前歩き、横歩き、後ろ歩き時における 4 秒間の水平加速度の分布と進行方向の関係の例を図 2 に示す。青色の点は各時刻における水平加速度、橙色の矢印はその間の進行方向を表す。前歩きと比べて横歩きや後ろ歩きでは水平加速度の分布と進行方向の相関が弱くなっており、分布情報だけではこれらの歩き方に対応することが難しいと推察される。

歩き方に対する頑健性を向上させるには多様な特徴を自動的に選定し考慮できる深層学習が有効であると考えられる。深層学習を PDR に応用する研究は近年盛んに行われている [4], [5], [6], [14], [15], [16] が、進行方向推定におけ

る歩き方に対する頑健性については十分に議論されていない。また、歩き方に対する頑健性を評価するには歩き方についてラベル付けされたデータセットが新たに必要となる。加えて、深層学習モデルによる計算は解釈性が低く、どこを改善すればどれだけ性能向上が見込めるかを把握するのが難しいという課題もある。センサ姿勢と進行方向の関係を考慮した進行方向推定は先述した3つまたはそれに相当する操作に分解できるが、先行研究では一般的に座標変換前の測定データをモデルに入力して end-to-end に推定するため各操作で生じる誤差を分離できない。

### 2.3 本研究の目的

本研究ではスマートフォンを用いた PDR のための歩き方に頑健な進行方向推定手法について検討する。深層学習によって水平加速度の多様な時空間的特徴を考慮し頑健性の向上を図る。このとき、あらかじめ水平加速度をスマートフォンの姿勢に応じて座標変換し、座標変換後の水平加速度から進行方向へのマッピングのみをモデルに学習させる。また、様々な歩き方に対応したデータセットを作成し、歩き方に頑健な進行方向推定を実現する上で有効なモデルの構造を明らかにする。

## 3. 関連研究

### 3.1 グローバル座標系の水平加速度に基づいた進行方向推定手法

Deng らは主成分分析 (PCA: Principal Component Analysis) によって得られる水平加速度の第1主成分として進行方向を推定する Rotation Matrix and Principal Component Analysis (RMPCA) を提案した [11]。また、Ban らはノルムが 0.5 [G] 以上である重力成分を除いた加速度は歩行の前後運動に由来するものであると仮定し、そのときの水平加速度の平均ベクトルが指す方向として進行方向を推定した [12], [13]。便宜上、本稿ではこの手法を水平加速度平均法と呼ぶ。どちらの手法でもあらかじめ加速度をセンサの位置を原点としたグローバル座標系に変換する。なお、ここでいうグローバル座標系とは各軸が次のように定義される右手系である。

- x 軸は原点において水平面と平行で東を指す。
- y 軸は原点において水平面と平行で北を指す。
- z 軸は原点において水平面と垂直で上空を指す。

事前のグローバル座標系への変換は姿勢推定と進行方向推定の問題を切り分けるのに役立つだけでなく、時刻ごとに独立して進行方向を推定できるため測位を長時間続けても方向誤差が蓄積しないという利点もある。一方でこれらの既存手法は時系列情報やその他の空間的特徴を考慮できておらず、歩き方に対する頑健性が不十分である。

### 3.2 深層学習を応用した PDR 手法

PDR に深層学習を応用する研究が近年盛んになっている。Chen らは BiLSTM を用いて移動軌跡を求める 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 [14]。BiLSTM は時系列データの扱いを得意とする LSTM を拡張し、過去と未来の両方の情報を活用できるようにしたモデルである。IONet では一定期間のセンサ座標系の加速度と角速度を入力としてその間の移動距離と進行方向の角変位を出力するようにモデルを学習させる。計算中に重力加速度などに相当するいくつかの潜在変数を経由するだろうという考えから、IONet では2層の BiLSTM が重ねられた構造のモデルを採用している。重力加速度は加速度の定常成分として推定できるものの重力方向周りの自由度が残るため、進行方向は角変位の積分として逐次的に推定される。同著者らによって WaveNet を応用した IONet の軽量化も試みられている [15]。Kawaguchi らは早歩きや足踏みなどの移動速度に関する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 [4], [5], [6]。DualCNN-LSTM は互いにカーネルサイズの異なる畳み込み層からなる2つのパスが LSTM に並列に接続された構造になっている。短期的なものから長期的なものまで幅広い特徴を捉えることで、特徴のタイムスケールが異なる [17] 様々な歩容に対応できると考えられる。

### 3.3 深層学習を応用した行動認識手法

PDR と同様に慣性センサなどの測定データの分析を伴う代表的な研究分野として人の動作を認識する Human Activity Recognition (HAR) が挙げられる。HAR に深層学習を応用した研究は多数存在する。Ha らは CNN を用いて複数のセンサで測定した加速度やマルチモーダルなデータから自動車生産ラインや日常生活での動作を分類した [18]。2次元のカーネルによって時間的特徴と異なるセンサ間の空間的特徴を同時に捉えることで精度を向上させている。また、Zhao らは BiLSTM を応用し、通常の LSTM などと比べて分類精度が向上したことを示した [19]。Matsuyama らは LSTM を用いて慣性センサの測定データと骨格位置データから社交ダンスのフィガーを分類し、93.0 [%] の精度を達成した [20], [21]。これは経験豊富なダンサーの分類精度である 93.6 [%] に迫る精度である。Shavit らは自然言語処理や画像認識などの分野において state-of-the-art なモデルである Transformer を HAR に応用し、単純な CNN と比べて分類精度を向上させた [22]。

## 4. 提案手法

スマートフォンを用いた歩き方の違いに頑健な PDR の実現に向けて、グローバル座標系の水平加速度から深層学習によって進行方向を推定する手法を提案する。提案手法

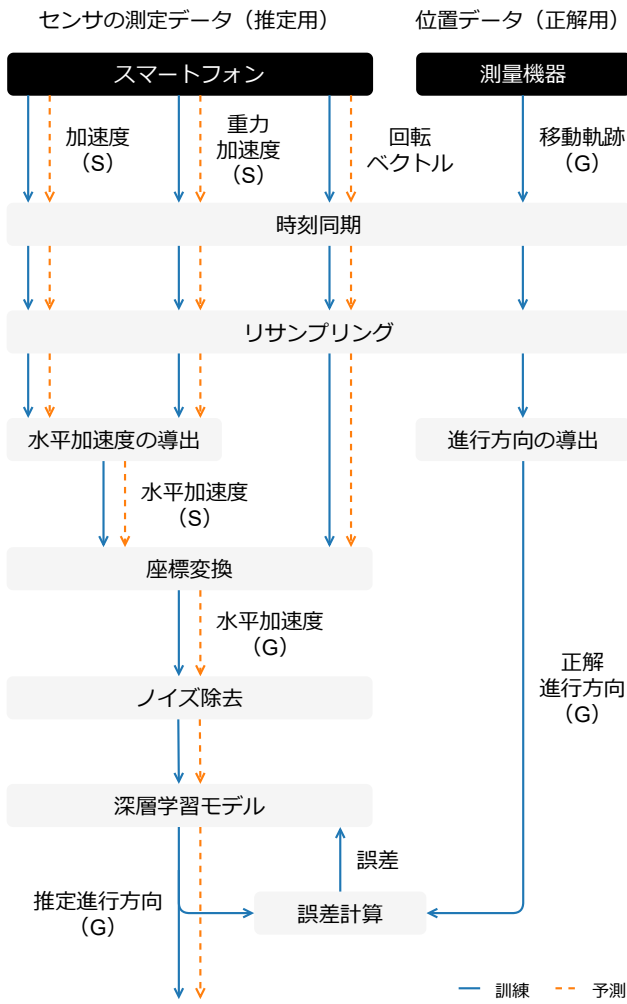


図 3 訓練と予測の流れ

Fig. 3 Flows of training models and predicting headings.

におけるモデルの訓練と予測の流れを図 3 に示す。訓練フェーズでは青色の実線の矢印で表されたデータフローに従ってモデルを学習させる。まず、スマートフォンで加速度、重力加速度、回転ベクトルを測定し、同時に実際の移動軌跡を測量機器で計測する。続いて、これらのデータの時刻を揃え 100 [Hz] にリサンプリングする。その後、グローバル座標系の水平加速度を計算し、ノイズを除去したものをモデルへの入力とする。モデルが出力した推定進行方向と移動軌跡から求めた正解進行方向の誤差を逆伝播させてモデルを学習させる。予測フェーズでは橙色の点線の矢印で表されたデータフローに従って未知の測定データから進行方向を推定する。本章では水平加速度の導出方法とモデルの構造や学習方法などについて述べる。データの収集や同期の方法についての説明は 5 章に委ねる。

#### 4.1 グローバル座標系の水平加速度の導出

センサ座標系の加速度および重力加速度と回転ベクトルからグローバル座標系の水平加速度を計算する。まず、加速度  $\mathbf{a}^s$  を重力加速度  $\mathbf{g}^s$  へ射影して加速度の鉛直成分  $\mathbf{a}_v^s$

を求める。 $\mathbf{a}^s$  から  $\mathbf{a}_v^s$  を除くことで水平加速度  $\mathbf{a}_h^s$  を得る。添え字  $s$  はセンサ座標系を意味する。

$$\mathbf{a}_v^s = \left( \frac{\mathbf{a}^s \cdot \mathbf{g}^s}{\mathbf{g}^s \cdot \mathbf{g}^s} \right) \mathbf{g}^s \quad (1)$$

$$\mathbf{a}_h^s = \mathbf{a}^s - \mathbf{a}_v^s \quad (2)$$

続いて、回転ベクトルを用いて水平加速度  $\mathbf{a}_h^s$  をグローバル座標系に変換する。回転ベクトルはスマートフォンの位置を原点としたグローバル座標系から見たスマートフォンの姿勢に相当する。センサ座標系の水平加速度  $\mathbf{a}_h^s$  に対して回転ベクトルが表す回転操作  $f$  を行うとグローバル座標系の水平加速度  $\mathbf{a}_h^g$  を与える。添え字  $g$  はグローバル座標系を意味する。

$$\mathbf{a}_h^g = f(\mathbf{a}_h^s) \quad (3)$$

最後に、算出した水平加速度  $\mathbf{a}_h^g$  に標準偏差  $\sigma = 1.1$  のガウシアンフィルタを適用してノイズを除去する。この操作は元の水平加速度  $\mathbf{a}_h^g$  とガウシアンカーネルの時間方向についての畳み込みに相当する。時刻  $t - i$  における元の水平加速度の  $x$  成分と  $y$  成分をそれぞれ  $a_x^{g,t-i}$ ,  $a_y^{g,t-i}$  とおくと、時刻  $t$  におけるフィルタリング後の水平加速度の各成分は式 (4), (5) のように計算される。計算の都合上、本稿ではカーネルの半径  $R$  を 3 に丸めた。  $|i| > 3$  の項については十分小さく無視できる。

$$\hat{a}_x^{g,t} = \frac{1}{\sqrt{2\pi\sigma}} \sum_{i=-R}^R a_x^{g,t-i} \exp\left(-\frac{i^2}{2\sigma^2}\right) \quad (4)$$

$$\hat{a}_y^{g,t} = \frac{1}{\sqrt{2\pi\sigma}} \sum_{i=-R}^R a_y^{g,t-i} \exp\left(-\frac{i^2}{2\sigma^2}\right) \quad (5)$$

## 4.2 進行方向推定モデル

### 4.2.1 モデルの入出力

グローバル座標系の水平加速度から進行方向を推定する深層学習モデルを導入する。加速度の鉛直成分を入力に含めないのは本質的でない特徴が推定に影響を与えるをできるだけ防ぐためである。北方向と東方向に歩く場合で鉛直加速度に現れる傾向は変わらないように、鉛直加速度と進行方向の間に直接的な関係はない。一方で、鉛直加速度は歩行速度と密接な関係にあることが知られている。また、一般に歩行速度は歩き方に強く依存するが、その関係は人によって異なる [17]。よって、鉛直加速度を入力に含めると歩行者や歩行速度が学習データと異なる場合に歩き方の認識機能が低下する可能性があると考えた。

提案手法では、一定期間のグローバル座標系の水平加速度を入力として受け取り、その間の平均進行方向を指す単位ベクトルを出力するようにモデルを学習させる。測量機器で計測した移動軌跡とそこから算出した正解進行方向には少なからず誤差が含まれるが、平均を取ることでその影響を軽減する狙いがある。また、進行方向を角度ではなく

表 1 提案手法と深層学習を応用した主要な参考手法

Table 1 Proposed method and principal reference methods using deep learning.

	対象タスク	モデルの入力	モデルの出力	モデルのアーキテクチャ
提案手法	進行方向推定	グローバル座標系の水平加速度	進行方向	CNN / BiLSTM / DualCNN-LSTM / DualCNN-Transformer
Ha らの手法	行動認識	加速度 / マルチモーダル	クラスごとの確率	CNN
Zhao らの手法	行動認識	加速度と角速度 / マルチモーダル	クラスごとの確率	BiLSTM
IONet	位置推定	加速度と角速度	移動距離と角変位	BiLSTM
Kawaguchi らの手法	歩行速度推定	加速度とそのノルム	歩行速度	DualCNN-LSTM
Shavit らの手法	行動認識	加速度と角速度	クラスごとの確率	TransformerEncoder

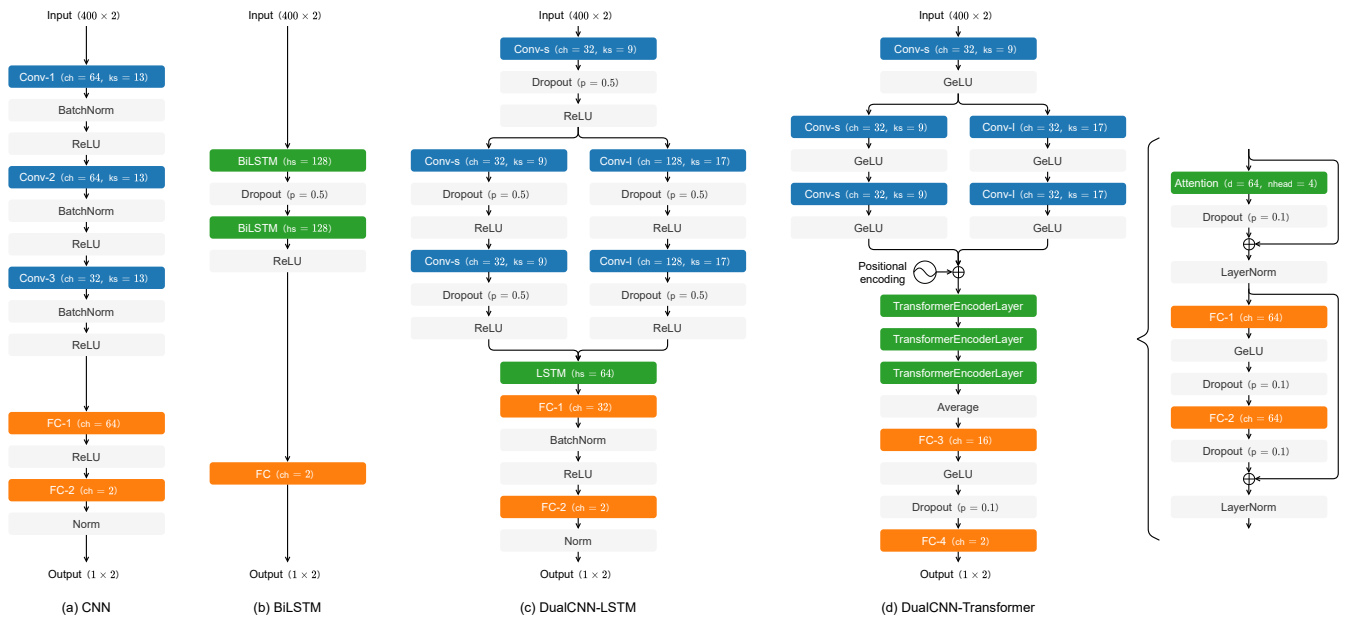


図 4 モデルの構造

Fig. 4 Model architectures.

ベクトルとして推定するのは  $\pm 180^\circ$  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 [23]. 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. 本稿ではモデルへの入力長を経験的に 4 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, 入力サイズは  $400 \times 2$ , 出力サイズは  $1 \times 2$  となる.

#### 4.2.2 モデルの構造

本研究では CNN, BiLSTM, DualCNN-LSTM, DualCNN-Transformer の 4 つのモデルを扱う. 関連研究にもある通り CNN と LSTM はセンサの測定データから時空間的特徴を抽出するための代表的なモデルである. LSTM を拡張したモデルとして BiLSTM, CNN と LSTM を組み合わせたモデルとして DualCNN-LSTM を用いる. CNN は局所的, LSTM は長期的な特徴の抽出に適しており, 各モデルを用いたときの推定精度の評価を通して効果的な特徴のタイムスケールに関する知見を得たいという狙いがある. また, 系列データの分析において state-of-the-art とされている Transformer の構造を持ったモデルも用意する.

モデル設計に際しての主要な参考手法を表 1 にまとめる. CNN については当初 Ha らのモデル [18] を参考にした. しかし我々の提案手法では水平加速度をモデルへの入力とするため, Ha らが想定していた複数のセンサで測定した加速度やマルチモーダルなデータと比べて空間方向の次元数が少なく, 2次元カーネルによる畳み込みが上手く機能しなかった. そこで本研究では 1次元のカーネルを採用した. BiLSTM については Zhao らのモデル [19] や Chen らの IONet で使われたモデル [14] を参考にした. DualCNN-LSTM については Kawaguchi らのモデル [4], [5], [6] を参考にした. Transformer については Shavit らのモデル [22] を参考にした. Shavit らは Transformer のエンコーダに渡す特徴量を抽出するためのバックボーンネットワークとしてカーネルサイズが 1 である pointwise な畳み込み層からなる CNN を用いたが, それを提案手法に適用したところ推定精度が優れなかった. そこで DualCNN-LSTM のようにカーネルサイズの異なる畳み込み層からなる 2つのパスを Transformer のエンコーダに並列に接続したところ精度が向上した. 本稿ではこのモデルを DualCNN-Transformer

表 2 CNN モデルのハイパーパラメータ

Table 2 Hyperparameters of CNN model.

Conv-1	出力チャンネル数	32, <b>64</b> , 128
	カーネルサイズ	3, 7, <b>13</b>
	ストライド	<b>1</b>
	バディン	<b>0</b>
Conv-2	出力チャンネル数	32, <b>64</b> , 128
	カーネルサイズ	3, 7, <b>13</b>
	ストライド	<b>1</b>
	バディン	<b>0</b>
Conv-3	出力チャンネル数	<b>32</b> , 64, 128
	カーネルサイズ	3, 7, <b>13</b>
	ストライド	<b>1</b>
	バディン	<b>0</b>
FC-1	出力チャンネル数	32, <b>64</b> , 128

表 3 BiLSTM モデルのハイパーパラメータ

Table 3 Hyperparameters of BiLSTM model.

BiLSTM	隠れ状態のサイズ	32, 64, <b>128</b>
	層数	<b>2</b> , 3, 4
	ドロップアウト率	0.125, 0.25, <b>0.5</b>

と呼ぶ。

各モデルの構造を図 4 に示す。視認性のため、局所的な特徴抽出を伴う層を青色、長期的な特徴抽出を伴う層を緑色、全結合層を橙色、その他を灰色として色分けしている。CNN モデルでは 1 次元の畳み込み層で抽出した特徴を全結合層で進行方向に変換する。3 層の畳み込み層を直列に重ね、浅い層では短期、深い層では長期の特徴を捉える。バッチ正規化は共変量シフトを抑制し学習の安定化などに寄与する。BiLSTM モデルでは BiLSTM 層で抽出した特徴を全結合層で進行方向に変換する。BiLSTM 層の順方向および逆方向の最後の隠れ状態を結合したものを全結合層への入力とし、データ全体にわたる特徴を伝える。ドロップアウトは過学習を抑制し汎化性能の向上に寄与する。

DualCNN-LSTM モデルでは 1 次元の畳み込み層と LSTM 層で抽出した特徴を全結合層で進行方向に変換する。カーネルサイズの異なる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し、その特徴のデータ全体を通した表れ方を LSTM 層で捉える。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を LSTM 層へ入力する。また、LSTM 層の最後の隠れ状態を 1 層目の全結合層への入力とする。DualCNN-Transformer では 1 次元の畳み込み層と Transformer のエンコーダで抽出した特徴を全結合層で進行方向に変換する。畳み込み層の出力に学習可能な位置埋め込みベクトルを加えたものを Transformer のエンコーダへ入力し、Self-Attention 機構によって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 1 層目の全結合層への入力とする。レイヤー正規化は学習の安定化などに寄

表 4 DualCNN-LSTM モデルのハイパーパラメータ

Table 4 Hyperparameters of DualCNN-LSTM model.

Conv-s	出力チャンネル数	<b>32</b> , 64, 128
	カーネルサイズ	3, 5, <b>9</b> *
	ストライド	<b>1</b>
	バディン	<b>0</b>
Conv-l	ドロップアウト率	0.125, 0.25, <b>0.5</b> *
	出力チャンネル数	32, 64, <b>128</b>
	カーネルサイズ	5, 9, <b>17</b> *
	ストライド	<b>1</b>
LSTM	バディン	<b>0</b>
	ドロップアウト率	0.125, 0.25, <b>0.5</b> *
FC-1	隠れ状態のサイズ	32, <b>64</b> , 128
	出力チャンネル数	<b>32</b> , 64, 128

表 5 DualCNN-Transformer モデルのハイパーパラメータ

Table 5 Hyperparameters of DualCNN-Transformer model.

Conv-s	出力チャンネル数	16, <b>32</b> , 64 *
	カーネルサイズ	3, 5, <b>9</b> *
	ストライド	<b>1</b>
	バディン	<b>0</b>
Conv-l	出力チャンネル数	16, <b>32</b> , 64 *
	カーネルサイズ	5, 9, <b>17</b> *
	ストライド	<b>1</b>
	バディン	<b>0</b>
Transformer エンコーダ	層数	1, 2, <b>3</b>
	Attention 次元数	32, <b>64</b> , 128 *
	Attention ヘッド数	<b>4</b>
	Feed-Forward 次元数	32, <b>64</b> , 128
FC-3	ドロップアウト率	<b>0.1</b>
	出力チャンネル数	8, <b>16</b> , 32 *
	ドロップアウト率	<b>0.1</b>

与する。CNN と DualCNN-LSTM モデルでは 2 層目の全結合層の出力をノルムが 1 になるよう正規化して得られた単位ベクトルを最終的な出力とする。一方、BiLSTM と DualCNN-Transformer モデルでは正規化すると学習が不安定になったため、全結合層の出力をそのまま最終的な出力とする。

#### 4.2.3 ハイパーパラメータと学習方法

本稿では、効果的な特徴のタイムスケールを調べるために、CNN, DualCNN-LSTM, DualCNN-Transformer モデルにおける畳み込み層の受容野がとり得る値の範囲が同程度になるよう、各モデルの畳み込み層の層数を予備実験に基づきつつ手動で決定した。(受容野がとり得る値の範囲がモデル間で異なると、精度の違いに寄与しているのが受容野なのか別の要因なのか特定できないため。)一部のハイパーパラメータは表 2, 表 3, 表 4, 表 5 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。ただし探索空間が広いと、予備実験を通して特に重要だと

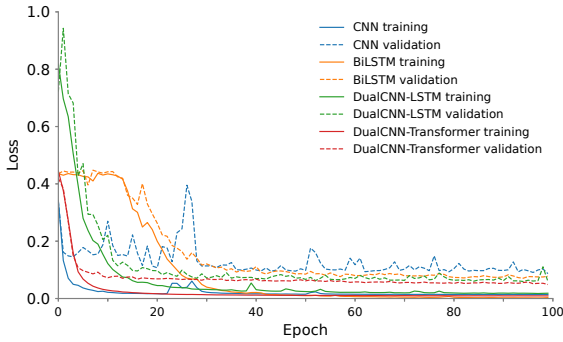


図 5 学習中の損失関数の値の推移

Fig. 5 Loss transitions during training.

見受けられたパラメータのみを対象としており、その他のパラメータについては先行研究に則った。

加えて、いくつかの理由から一部のパラメータの組み合わせに対して制約を設けた。DualCNN-LSTM モデルにおける Conv-s のカーネルサイズ  $ks_{cs}$  およびドロップアウト率  $p_{cs}$ 、Conv-l のカーネルサイズ  $ks_{cl}$  およびドロップアウト率  $p_{cl}$  は次の関係を満たす。

$$2ks_{cs} - 1 = ks_{cl} \quad (6)$$

$$p_{cs} = p_{cl} \quad (7)$$

同様に、DualCNN-Transformer モデルにおける Conv-s の出力チャンネル数  $ch_{cs}$  およびカーネルサイズ  $ks_{cs}$ 、Conv-l の出力チャンネル数  $ch_{cl}$  およびカーネルサイズ  $ks_{cl}$ 、Attention の次元数  $d_{at}$ 、FC-3 の出力チャンネル数  $ch_{fc}$  は次の関係を満たす。

$$2ch_{cs} = 2ch_{cl} = d_{at} = 4ch_{fc} \quad (8)$$

$$2ks_{cs} - 1 = ks_{cl} \quad (9)$$

制約 6, 9 は Kawaguchi らのモデルと同じく DualCNN における 2 つのパスのカーネルサイズの比が 2 倍程度となるよう要請する。制約 7 は探索空間の削減を目的としている。制約 8 について、 $ch_{cs} + ch_{cl} = d_{at}$  の関係はモデルの構造上要求され、 $ch_{cs} = ch_{cl}$  と  $d_{at} = 4ch_{fc}$  の制約は探索空間の削減を目的としてそれぞれ Kawaguchi らと Shavit らが設けた制約に倣ったものである。

訓練フェーズでは 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、検証誤差が最も小さいエポックにおける重みを採用する。このとき、横軸をエポック、縦軸を損失関数の値としてプロットしたものを図 5 に示す。100 エポック目までに損失関数の収束を確認できる。




図 6 測量機器を用いた移動軌跡計測

Fig. 6 Trajectory measurement with surveying instrument.

## 5. データセットの作成

モデルを学習させるにはグローバル座標系の水平加速度を計算するためのセンサの測定データと正解進行方向を求めるための位置データが必要となる。特に歩行速度が小さい場合、位置データに含まれる誤差は正解進行方向の精度に大きく影響する。人の動作や移動に関するデータはこれまでも多く収集されてきた [24], [25], [26], [27], [28] が、様々な歩き方に対応していないのに加えて、位置データの精度やサンプリングレートが不十分であったり、方位情報が失われているなどの課題があった。そこで我々は前歩き、横歩き、後ろ歩きに対応したグローバル座標系の高精度な位置データを含む PDR 向けデータセットを新たに作成した。

### 5.1 データの種類と収集方法

収集したデータを以下にまとめる。提案手法では角速度と地磁気を使わないが PDR ではこれらを用いることも多いため併せて収集した。

- 加速度
- 角速度
- 地磁気
- 重力加速度
- 回転ベクトル
- グローバル座標系の 3 次元位置

位置データを除く 5 種のデータはスマートフォン (Google Pixel 4, Android 10) で測定する。これらのデータはいずれも Android センサフレームワーク<sup>\*1</sup> の API を介して取得でき、センサ座標系で記録されている。なお、重力加速度と回転ベクトルは内部的には加速度に加えて角速度や地磁気を基に計算されている。被験者にはスマートフォンを胸の前辺りに保持するよう指示する。位置データはレーザ式の測量機器 (TOPCON GT-1205<sup>\*2</sup>) で計測する。専用のプリズムと併用した時の測定誤差は数ミリメートル、サ

<sup>\*1</sup> [https://developer.android.com/guide/topics/sensors/sensors\\_overview](https://developer.android.com/guide/topics/sensors/sensors_overview)

<sup>\*2</sup> <https://www.topcon.co.jp/positioning/topcon/products/product/ts00/gt-1200-600-j/>






図 7 歩行パターンの例

Fig. 7 Instances of walking patterns.

ンプリングレートは最大 10 [Hz] である。測量機器を用いて位置データを計測する様子を図 6 に示す。頭頂部にプリズムを固定したヘルメットを被験者に装着してもらい、そのプリズムをトラッキングする。このとき、後視点と呼ばれる別のプリズムを測量機器から見て北方に設置する。本実験で用いた測量機器は自身の位置を原点、後視点の方角を y 軸、上空方向を z 軸とするような左手系で位置を記録するため、x 座標を反転することでグローバル座標系に変換された位置データを取得できる。被験者には事前に設置したマーカに沿って歩くよう指示する。また、歩行開始前と終了後に一回ずつ跳躍してもらおう。レーザの遮蔽を防ぐため実験は開けた屋外で行った。

### 5.2 歩行パターン

被験者は 8 名でいずれも 21 ~ 23 歳の男性である。歩き方は前歩き、右方向の横歩き、左方向の横歩き、後ろ歩きの 4 通りからなる。また、歩行コースの形状は長方形、砂時計型、直線の 3 種からなる。移動軌跡と歩行中の姿勢の例を図 7 に示す。軌跡の色の変化は時間経過を表し、紫色から黄色の順に移動したことを意味する。矢印は回転ベクトルから計算した各時刻における身体の正面の向き（厳密には保持するスマートフォンの向き）を表す。長方形および砂時計型のコースにおいて被験者は単一の歩き方でコースを周回する。長方形のコースにおける周回方向は時計回りと反時計回りの 2 通りある。これらのデータにはコーナリング動作、すなわち歩行中の進行方向の変化が含まれる。例えば図 7(a) は長方形のコースを反時計回りに右方向の横歩きで歩いたときのデータである。一方、直線のコースにおいて被験者は 5 [m] ごとに歩き方を変え、さらに 15 [m] ごとに進行方向を 180 [°] 変える。進行方向に対する身体の向きは移動しながら変える場合とその場に留まりながら変える場合の 2 通りある。移動しながら変える

表 6 歩き方とコース形状ごとの歩行距離 [m]

Table 6 Walking distance [m] for every gait and course shape.

	長方形	砂時計型	直線	小計
前歩き	2273	426	880	3580
右方向の横歩き	1122	0	440	1562
左方向の横歩き	1049	0	440	1489
後ろ歩き	1032	0	880	1912
小計	5476	426	2641	

場合はそのためのコース区間を追加で 1 [m] ずつ設ける。これらのデータには歩行中または停止中の歩き方の変化と 180 [°] の進行方向の変化が含まれる。例えば図 7(c) は下記の順で遷移したときのデータである。

- (1) 5 [m] を前歩き。
- (2) 1 [m] を移動している間に身体の向きを変更。
- (3) 5 [m] を右方向の横歩き。
- (4) 1 [m] を移動している間に身体の向きを変更。
- (5) 5 [m] を前歩き。
- (6) 5 [m] を後ろ歩き。
- (7) 1 [m] を移動している間に身体の向きを変更。
- (8) 5 [m] を左方向の横歩き。
- (9) 1 [m] を移動している間に身体の向きを変更。
- (10) 5 [m] を後ろ歩き。

合計の歩行距離は 8543 [m]、記録時間は 120 分であった。歩き方とコース形状ごとの歩行距離の内訳を表 6 にまとめる。

### 5.3 データの同期

スマートフォンで測定した加速度などのデータと測量機器で計測した位置データを同期する。初めに図 8 に示すように、歩行前後の跳躍動作に起因する加速度のノルムの極小と位置の z 座標の極大を基準にして時刻を揃える。続いて線形補間によって両者を 100 [Hz] にリサンプリングする。跳躍部分のデータは同期後に切り落とし、モデルの学

表 7 各サブセットに含まれる被験者ごとの歩行距離 [m]  
Table 7 Walking distance [m] for every subject in each subset.

	A	B	C	D	E	F	G	H	全体
学習用	383	426	2156	289	403	398	391	392	4838
検証用	385	0	1302	0	134	132	130	131	2215
テスト用	0	441	518	0	135	135	129	130	1488




図 8 加速度のノルムと位置の  $z$  座標の極値検出による時刻同期  
Fig. 8 Synchronization based on valley of acceleration norm and peak of prism height.

習や予測には使用しない。また、回転ベクトルと位置データはそれぞれスマートフォンと測量機器の位置を原点としたグローバル座標系を参照するが、これらの座標系は近似的に平行とみなす。

## 6. 評価

歩き方に対する頑健性を検証するため、5章で作成したデータセットを用いて提案手法の進行方向推定精度をモデルごとに評価する。提案手法と同じグローバル座標系の水平加速度に基づいた手法である RMPCA[11] および水平加速度平均法 [12], [13] と、深層学習を応用した手法である IONet[14] についても併せて評価し比較する。また、提案手法による進行方向推定と Kawaguchi らの手法 [4], [5], [6] による歩行速度推定を組み合わせることで測位システムとしての性能を示す。

### 6.1 進行方向推定精度の評価

#### 6.1.1 評価実験の条件

提案手法、RMPCA、水平加速度平均法、IONet について進行方向の推定精度を評価する。初めにデータセットを学習用、検証用、テスト用の3つのサブセットに分割した。異なるサブセット間で歩き方、コース形状、長方形のコースにおける周回方向、直線のコースにおける身体の変え方ができるだけ偏らないよう本実験では手動で分割した。ただし砂時計型のコースのデータについては数が少なく分割が困難であったため全て学習用とした。各サブセッ

トに含まれる被験者ごとの歩行距離を表 7 にまとめる。続いて学習用と検証用のサブセットを用いてグリッドサーチを行いハイパーパラメータを決定した。提案手法と IONet では学習用のサブセットでモデルを学習させ、検証用のサブセットに対する誤差が最も小さくなったパラメータを採用した。一方、RMPCA と水平加速度平均法ではモデルの学習が不要なため、学習用と検証用を合わせたサブセット全体に対する誤差を基にパラメータを決定した。最後に、テスト用のサブセットに対して 100 [Hz] で推定を行い、その結果を評価する。

提案手法では一定期間の平均進行方向を出力するようにモデルを学習させるが、評価時にはそれを中央の時刻における推定進行方向として扱う。IONet の実装は公開されていないため元論文に基づいた我々の実装を用いる。IONet では推定した角変位を積分して逐次的に進行方向を求めるため、この際の初期方向として正解値を与える。進行方向推定精度の評価指標には余弦と正弦の MSE を用いる。MSE の値  $e$  は全ての時刻  $1 \leq i \leq N$  で推定進行方向  $\hat{\theta}^i$  と正解進行方向  $\theta^i$  が一致するとき最小値 0 をとり  $180 [^\circ]$  異なるときに最大値 2 をとる。

$$e = \frac{1}{2N} \sum_{i=1}^N \left( \left( \cos(\hat{\theta}^i) - \cos(\theta^i) \right)^2 + \left( \sin(\hat{\theta}^i) - \sin(\theta^i) \right)^2 \right) \quad (10)$$

#### 6.1.2 結果

テストデータ全体を通したコース形状と歩き方ごとの MSE を表 8 にまとめる。参考として、カーネル密度推定により求めた誤差の分布密度を図 9 に示す。また、一部のテストデータに対する推定進行方向を図 10 に示す。なお、各モデルを用いたときの提案手法による推定結果を左側、各比較手法による推定結果を右側に表示している。さらに、このときの正解移動軌跡から算出した歩行速度と推定進行方向を基に生成した移動軌跡を図 11 に示す。以降、表 8 に基づいて歩行パターンごとに結果を分析する。長方形のコースの前歩きについては、IONet を除いて MSE が 0.1 ~ 0.25 程度であり概ね正しく推定できていた。特に CNN モデルの提案手法が最も高精度であった。長方形のコースの横歩きについては、提案手法と水平加速度平均法では MSE が 0.1 ~ 0.2 程度に抑えられており、特に DualCNN-LSTM モデルの提案手法が最も高精度で

表 8 歩行パターンごとの進行方向の余弦と正弦の MSE  
Table 8 MSE of heading cosine and sine for each walking pattern.

提案手法	長方形			直線	全体
	前歩き	横歩き	後ろ歩き		
CNN	<b>0.08</b>	0.21	0.32	0.09	0.11
BiLSTM	0.24	0.14	0.34	0.09	0.12
DualCNN-LSTM	0.21	<b>0.10</b>	0.17	<b>0.07</b>	<b>0.09</b>
DualCNN-Transformer	0.15	0.12	<b>0.14</b>	0.08	<b>0.09</b>
RMPCA	0.18	0.93	1.56	0.67	0.69
水平加速度平均法	0.24	0.23	1.52	0.33	0.37
IONet	1.05	0.82	1.30	1.06	1.04

あった。一方、RMPCA では MSE が 0.93 となり前歩き時と比べて精度が大きく低下した。長方形のコースの後ろ歩きについては、DualCNN-Transformer モデルの提案手法の MSE が 0.14 と最も小さく、次点で DualCNN-LSTM モデルの提案手法が 0.17、CNN と BiLSTM モデルの提案手法が 0.3 程度であった。RMPCA と水平加速度平均法の MSE は 1.5 より大きくなり進行方向を正しく推定できなかった。直線のコースについては、提案手法ではいずれのモデルを用いたときも MSE が 0.1 以下であり、歩行中や停止中の歩き方の変化に対して頑健に追従できていた。特に DualCNN-LSTM モデルの提案手法が最も高精度であった。一方、RMPCA と水平加速度平均法では様々な歩き方に対応できなかった。テストデータ全体を通して最も精度が高かったのは DualCNN-LSTM と DualCNN-Transformer モデルを用いたときの提案手法であった。IONet は本実験の条件下では上手く働かなかった。

6.1.3 考察

まず、提案手法の評価結果を基に、深層学習モデルの構造が推定精度や頑健性に与える影響について考察する。CNN モデルの提案手法は前歩きのデータに対して非常に高精度であったが後ろ歩きではあまり安定しなかった。本実験で用いたデータに最も多く含まれる歩き方である前歩きに対して過剰に最適化されている可能性がある。また、歩き方によって特徴のタイムスケールは異なると考えられるが、今回のモデルでは後ろ歩きの特徴のタイムスケールに十分に対応できていない可能性がある。3 層目の畳み込み層の受容野は 37 であり 0.37 秒間ごとの特徴を組み合わせることで進行方向を推定しているといえる。層数を増やしたりストライドを大きくして受容野を拡げることで横歩きや後ろ歩きについてもさらに精度が向上する可能性がある。BiLSTM モデルの提案手法はどの歩き方でもある程度正しく推定できていたが、他モデルの提案手法と比べると精度が低かった。畳み込み層で特徴を抽出する過程がないため、入力データに含まれる局所的な特徴を十分捉えきれていない可能性がある。DualCNN-LSTM モデルの提案手法は全体的に高精度であり歩き方に頑健に推定できて

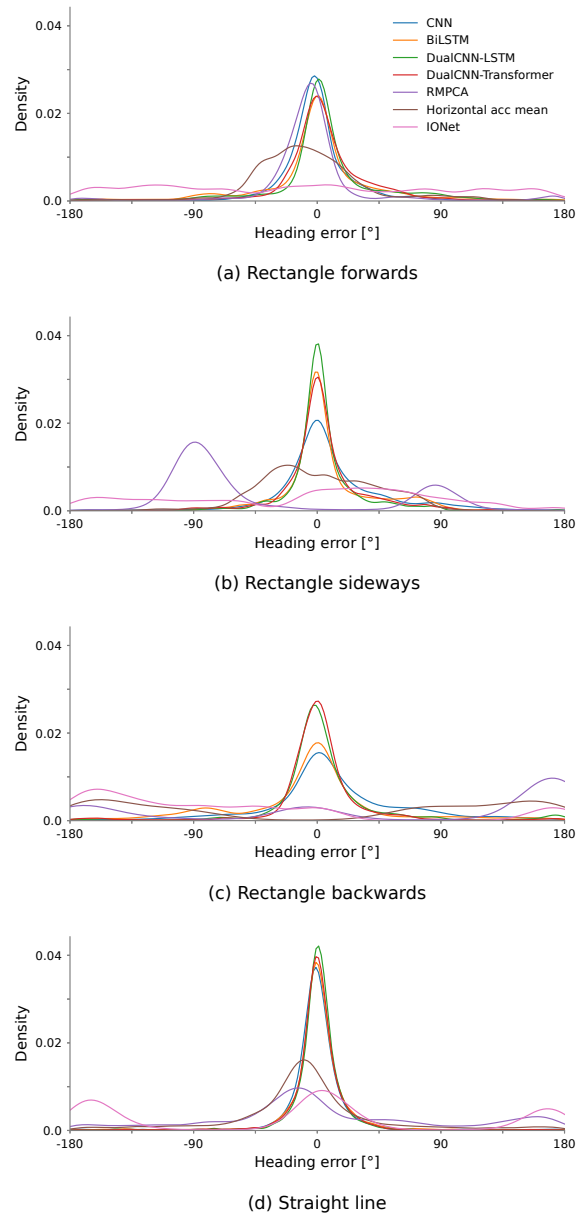


図 9 歩行パターンごとの方向誤差の分布密度  
Fig. 9 Distribution density of heading errors for each walking pattern.

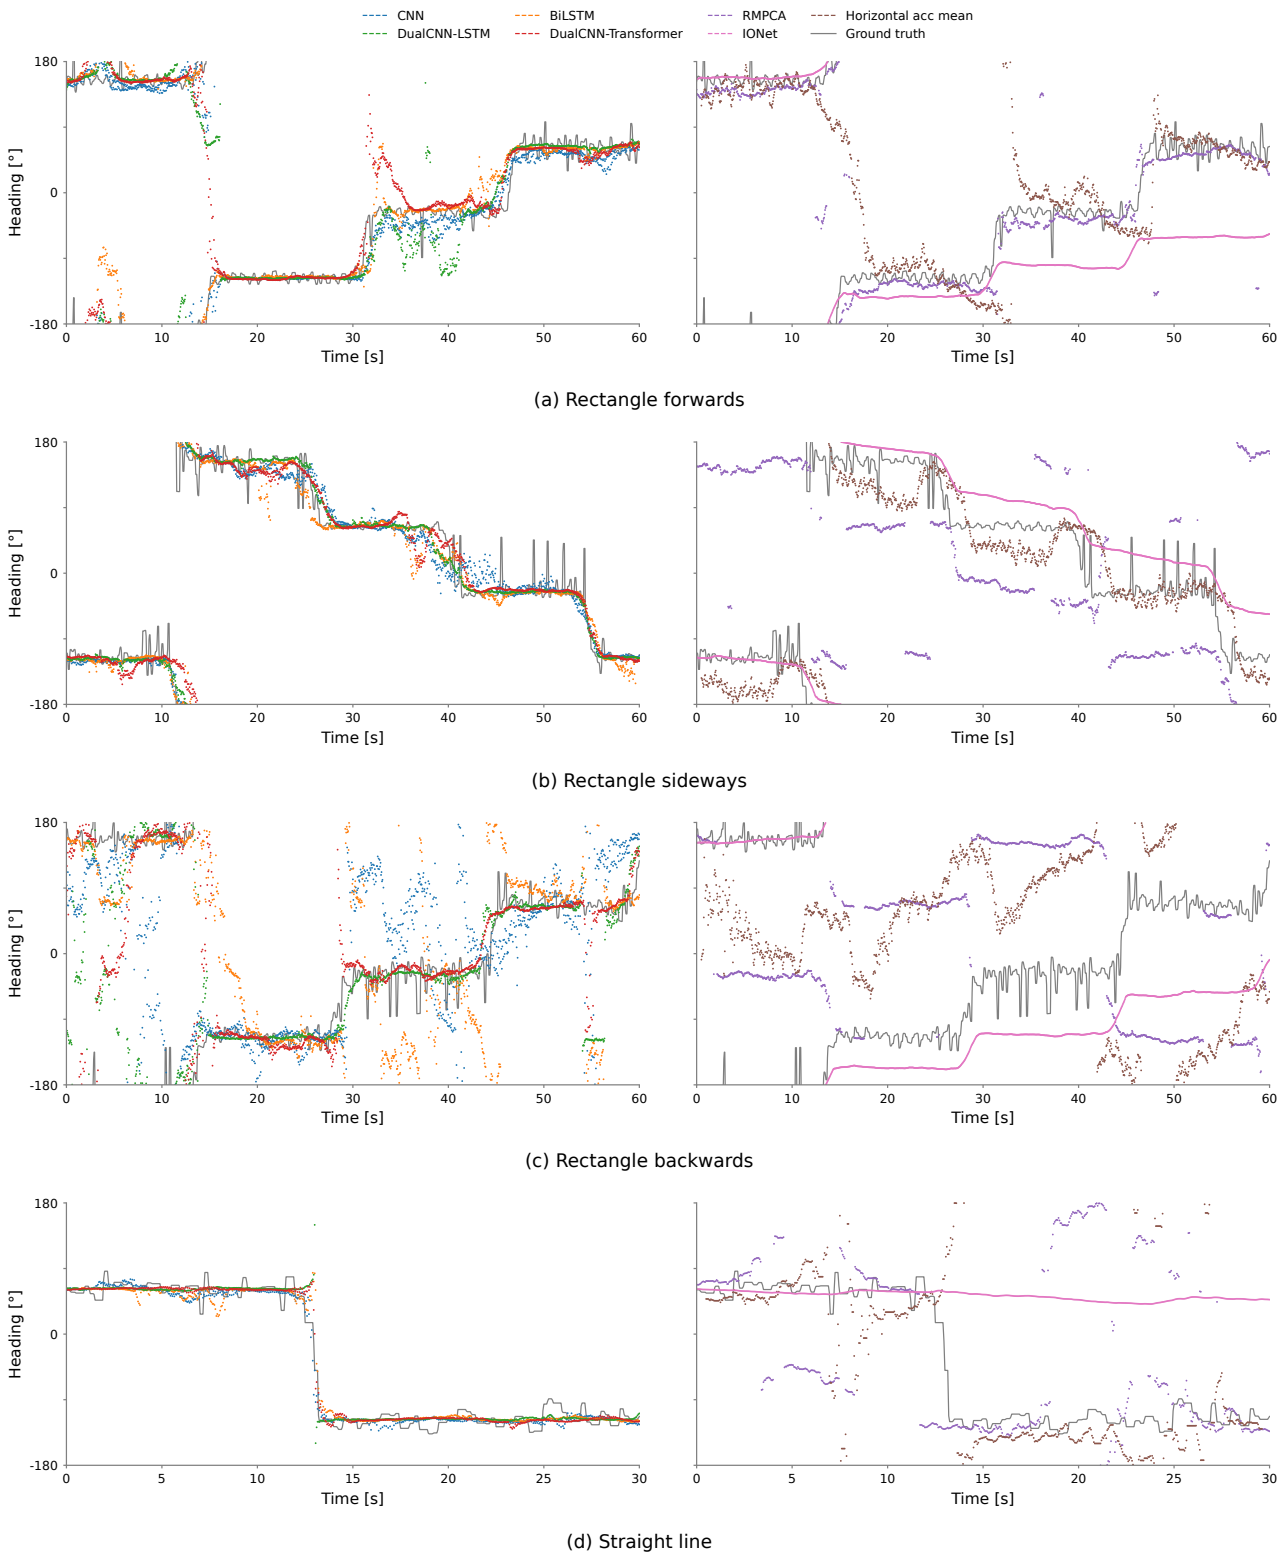


図 10 推定進行方向の例

Fig. 10 Instances of estimated headings.

いた。カーネルサイズの異なる畳み込み層と LSTM 層によって様々なタイムスケールの特徴を上手く捉えられていると考えられる。DualCNN-Transformer モデルの提案手法も歩き方に頑健に推定できており、データ全体を通した精度は DualCNN-LSTM モデルと同程度であった。なお、

畳み込み層のチャンネル数が少ない分、重みパラメータ数は DualCNN-LSTM モデルの半分以下に抑えられていた。以上のことから、CNN などが得意とする局所的な特徴の抽出は進行方向の推定精度の底上げに重要であると同時に、LSTM や Transformer などが得意とする長期に渡る特徴の

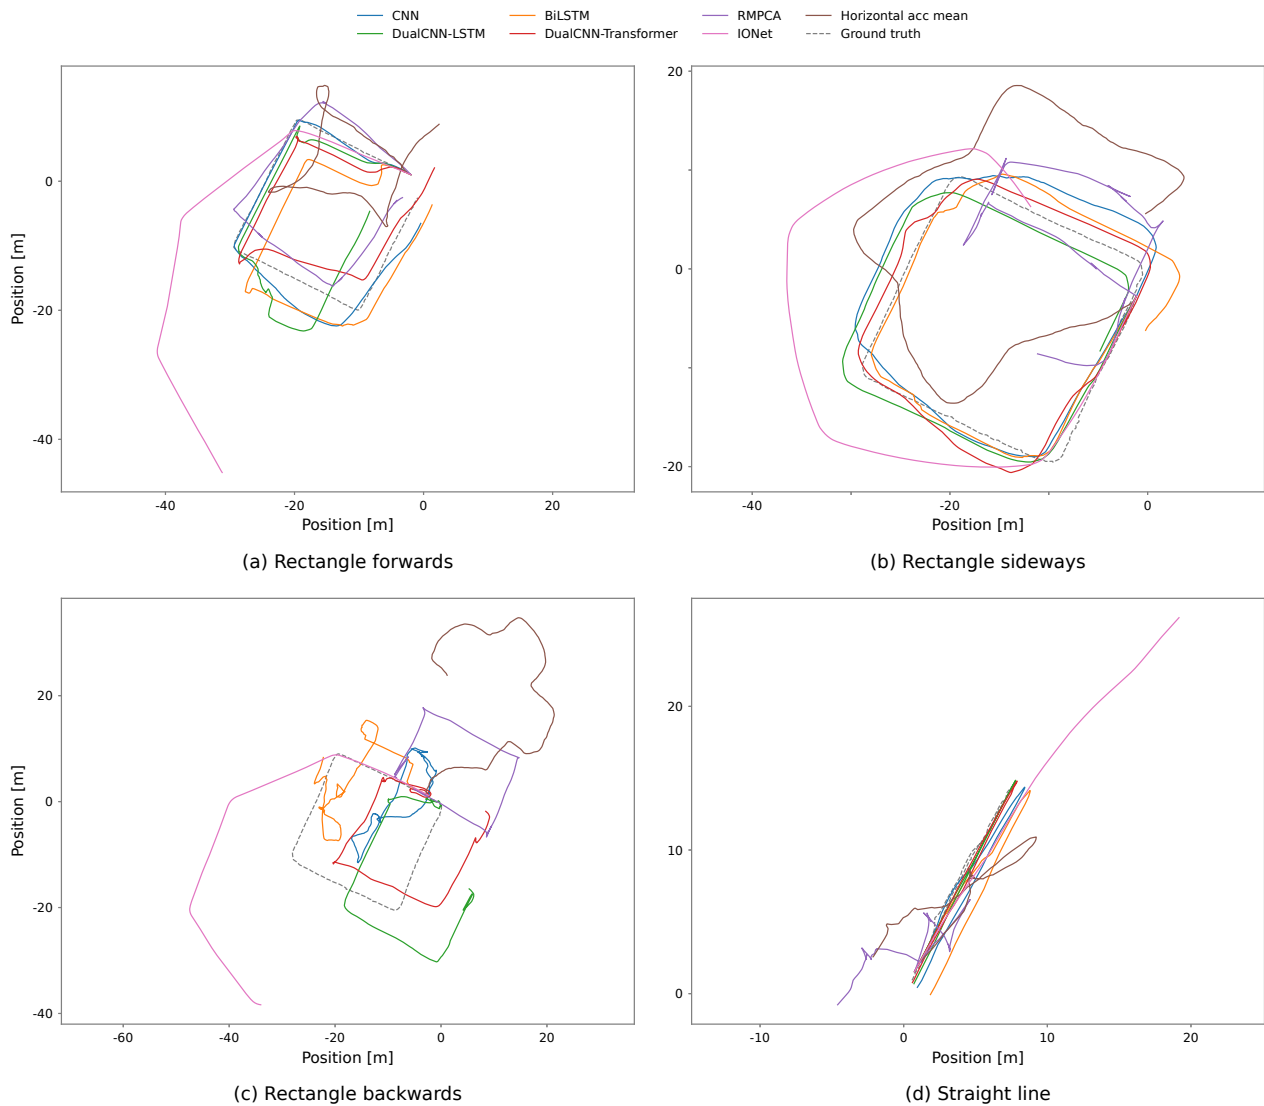


図 11 正解歩行速度と推定進行方向を基に生成した移動軌跡の例  
 Fig. 11 Instances of trajectories generated from estimated headings and actual walking speeds.

抽出も歩き方に対する頑健性の向上に一定の有効性が見られた。

次に、各比較手法について考察する。RMPCA は前歩き  
 のデータに対しては十分な精度で推定できていたが、横歩  
 きや後ろ歩きでは精度が大きく低下した。図 9(b)(c) より  
 横歩きでは約  $\pm 90^\circ$ 、後ろ歩きでは約  $\pm 180^\circ$  の誤差  
 を生じる傾向が見られる。水平加速度の主成分ベクトルは  
 進行方向よりも身体の前後方向と強く結びついていると考  
 えられる。水平加速度平均法も前歩きと横歩きのデータに  
 対してはおおまかに推定できていたが、後ろ歩きでは精度  
 が大きく低下した。また、コーナリング動作に注目すると、  
 図 10(a) の 15 [s] 辺りと図 11(a) のように逆回りの旋回と  
 して推定される事例も散見された。コーナリング時の推定  
 進行方向が乱れやすい原因の一つとして時系列情報を活用  
 していないことが考えられる。水平加速度平均法では入力  
 データ内の順番を考慮していないため進行方向の変化を捉

えるのが難しいと推察される。IONet は図 10 や図 11 の例  
 のように、進行方向の変化が少ない区間においては正確に  
 追従していたものの、コーナリング動作の度に誤差が増大  
 していた。主な原因として、IONet では推定した角変位を  
 積分して逐次的に進行方向を求めるため測位を続けるにつ  
 れて方向誤差が蓄積することが挙げられる。角変位を実際  
 よりも小さく推定する傾向が見られることから、進行方向  
 の変化時のデータの割合を増やすことで精度が向上する可  
 能性がある。また、直線のコースに含まれる約  $\pm 180^\circ$  ]  
 の進行方向の変化を検出できないケースが多く見られた。  
 これは  $\pm 180^\circ$  ] の境界付近の学習が上手く進まなかった  
 ためであると考えられる。この問題は提案手法などと同様  
 に角変位をベクトルとして出力するよう学習させることで  
 改善される可能性がある。

本実験を通して、提案手法は同じグローバル座標系の  
 水平加速度に基づいた手法である RMPCA や水平加速度

表 9 歩行パターンごとの PIEM の値 [m/s]  
Table 9 PIEM value [m/s] for each walking pattern.

	長方形			直線	全体
	前歩き	横歩き	後ろ歩き		
DualCNN-LSTM モデルの提案手法+ Kawaguchi らの手法	0.14	<b>0.06</b>	0.23	<b>0.03</b>	0.13
DualCNN-Transformer モデルの提案手法+ Kawaguchi らの手法	<b>0.09</b>	0.11	<b>0.12</b>	0.04	<b>0.10</b>
IONet	0.28	0.29	0.35	0.61	0.32

平均法と比べて歩き方に対する頑健性が向上していることを確認できた。中でも DualCNN-LSTM と DualCNN-Transformer モデルは特に有効であり、幅広いタイムスケールの特徴を考慮する重要性を検証できた。また、姿勢推定と進行方向推定を切り分け可能、初期方向が不要な点の他に、誤差の蓄積がなく長時間の測位にも適している、180 [°] の進行方向の変化にも強い点などにおいて、同じく深層学習を応用した手法である IONet に対する優位性を確認できた。一方で、前歩きのデータに対する推定精度は既存手法と大差なく、改善の余地も見られた。

## 6.2 測位精度の評価

### 6.2.1 評価実験の条件

DualCNN-LSTM と DualCNN-Transformer モデルを用いたときの提案手法による進行方向推定と Kawaguchi らの手法による歩行速度推定を組み合わせる測位を行う。ベースライン手法として IONet を用いる。ただし、進行方向推定精度の評価実験では IONet のモデルの出力のうち角変位のみを用いて進行方向を推定したが、本実験では移動距離も用いて位置を推定する。提案手法と IONet については 6.1 節と同一のモデルを用いる。Kawaguchi らの手法についても同様にモデルを学習させハイパーパラメータを決定した。テストデータに対して 100 [Hz] で測位を行い、その結果を評価する。その際、初期位置または初期方向には正解値を与える。測位精度の評価には Path Independent Evaluation Metric (PIEM) [29] を用いる。PIEM は相対測位システムの性能を評価するための 4 つの指標を設けているが、本実験ではそのうち測位精度についての指標を用いる。この指標では測位時間の長さの影響を軽減するため単位時間あたりに生じる位置誤差を量る。指標の値は横軸を測位開始時刻からの経過時間、縦軸を各時刻における位置誤差としてプロットしたときの原点を通る近似直線の傾きとして定義される。すなわち、 $i$  番目の時刻における経過時間を  $T^i$ 、推定位置を  $(\hat{x}^i, \hat{y}^i)$ 、正解位置を  $(x^i, y^i)$  とおくと、指標の値  $v$  は式 (11), (12) のように求まる。

$$e^i = \sqrt{(\hat{x}^i - x^i)^2 + (\hat{y}^i - y^i)^2} \quad (11)$$

$$v = \operatorname{argmin}_a \sum_i |e^i - aT^i| \quad (12)$$

$$= \frac{\sum_i e^i T^i}{\sum_i T^i}$$

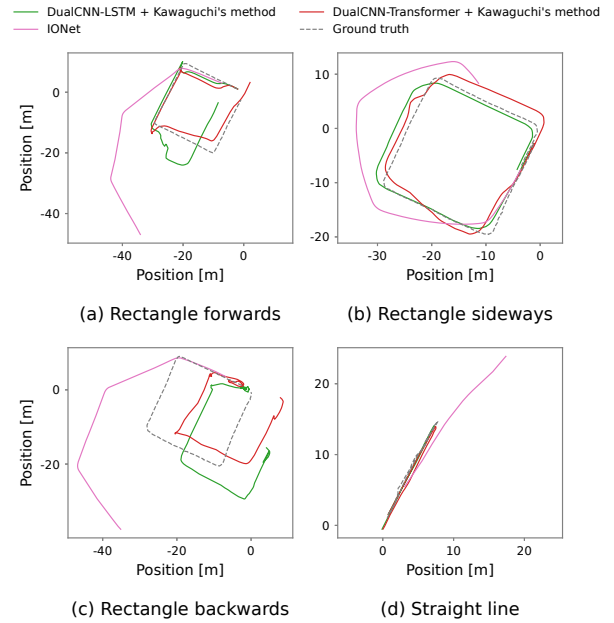


図 12 推定移動軌跡の例

Fig. 12 Instances of estimated trajectories.

### 6.2.2 結果と考察

テストデータ全体を通したコース形状と歩き方ごとの PIEM の値を表 9 にまとめる。また、図 10 や図 11 と同じデータに対する推定移動軌跡を図 12 に示す。なお、テストデータ全体を通した正解歩行速度の平均値は 1.21 [m/s] であるのに対し、Kawaguchi らの手法と IONet による推定歩行速度の平均値はそれぞれ 1.22, 1.19 [m/s] であった。表 9 より、提案手法と Kawaguchi らの手法の組み合わせは全ての歩行パターンにおいて IONet よりも PIEM の値が小さく高精度であることが分かる。図 11 と図 12 を比較すると移動軌跡の形状にさほど顕著な違いは認められず、進行方向の推定精度が測位精度に強く影響したと考えられる。

## 6.3 汎化性能の評価

### 6.3.1 評価実験の条件

学習データと異なる歩行者および歩行パターンに対する汎化性能を測るためのデータを追加で収集した。追加データの被験者は 1 名であり、5 章で作成したデータセットの被験者には含まれない。歩行コースは一辺の長さが約 20 [m] である正方形の四辺とその正方形に内接するランダムな線分からなる。被験者には歩き方を無作為に変化させる

表 10 追加データにおける進行方向の余弦と正弦の MSE

Table 10 MSE of heading cosine and sine for additional data.

提案手法	DualCNN-LSTM	0.14
	DualCNN-Transformer	0.19
	RMPCA	0.46
	水平加速度平均法	0.36

よう指示する。合計の歩行距離は 286 [m] であった。なお、使用するスマートフォンとその保持方法は 5 章で作成したデータセットと同様である。

収集した追加データを用いて DualCNN-LSTM と DualCNN-Transformer モデルの提案手法の進行方向推定精度を評価する。参考として、モデルの学習を伴わない手法である RMPCA と水平加速度平均法についても併せて評価する。提案手法については 6.1, 6.2 節と同一のモデルを用いる。RMPCA と水平加速度平均法については 6.1 節と同一のパラメータを用いる。

### 6.3.2 結果と考察

追加データにおける進行方向の余弦と正弦の MSE を表 10 にまとめる。提案手法の MSE は 0.2 を下回っており、RMPCA や水平加速度平均法と比べて高精度であった。提案手法は学習データと異なる歩行者および歩行パターンに対してもある程度機能しているといえる。しかし表 8 と比べると、特に DualCNN-Transformer モデルの精度の低下が見受けられた。本研究では歩き方についてのラベル付きデータセットを作成するために被験者の歩行パターンを事前に指定したが、それゆえにデータセットに含まれる歩行パターンが限られている。より多くの歩行者および歩行パターンのデータを使ったモデルの学習により汎化性能が向上すると考えられる。

## 7. おわりに

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した。スマートフォンの保持姿勢の変化に対応するにはセンサ姿勢と進行方向の関係を考慮した手法が有効だが、既存手法には歩き方に対する頑健性や計算の解釈性などの課題があった。そこで我々は加速度、重力加速度、回転ベクトルから計算したグローバル座標系の水平加速度を深層学習モデルに入力して進行方向を推定する手法を提案した。また、歩き方に対する頑健性を検証するため、前歩き、横歩き、後ろ歩きに対応したグローバル座標系の高精度な位置データを含む PDR 向けデータセットを作成した。CNN, BiLSTM, DualCNN-LSTM, DualCNN-Transformer の 4 つのモデルを用意し、RMPCA, 水平加速度平均法, IONet と併せて進行方向の推定精度を評価したところ、提案手法は既存手法と比べて歩き方の違いや変化に対する頑健性が向上しており、特に幅広いタイムスケールの特徴を考慮できる DualCNN-LSTM と

DualCNN-Transformer モデルが有効であることが分かった。さらに、IONet と比較して測位システムとしての性能も向上していることを示した。本研究は、横歩きや後ろ歩きが想定される産業現場などにおける人の位置のデータ化、ひいてはデジタルトランスフォーメーションを促進するものである。さらなる推定精度の向上とデータセットの拡充は今後の課題である。

**謝辞** 本研究の一部は JSPS 科研費 (JP22K18422), NEDO 委託研究 (JPNP23003, JPNP23025), NICT 委託研究 (222C01, 22609), JST CREST (JPMJCR21F2), トラスコ中山株式会社の支援を受けています。

## 参考文献

- [1] Harle, R.: A Survey of Indoor Inertial Positioning Systems for Pedestrians, *IEEE Communications Surveys & Tutorials*, Vol. 15, No. 3, pp. 1281–1293 (online), DOI: 10.1109/SURV.2012.121912.00075 (2013).
- [2] Alzantot, M. and Youssef, M.: UPTIME: Ubiquitous pedestrian tracking using mobile phones, *2012 IEEE Wireless Communications and Networking Conference (WCNC)*, pp. 3204–3209 (online), DOI: 10.1109/WCNC.2012.6214359 (2012).
- [3] Klein, I. and Asraf, O.: StepNet-Deep Learning Approaches for Step Length Estimation, *IEEE Access*, Vol. 8, pp. 85706–85713 (online), DOI: 10.1109/ACCESS.2020.2993534 (2020).
- [4] Yoshida, T., Nozaki, J., Urano, K., Hiroi, K., Yonezawa, T. and Kawaguchi, N.: Gait Dependency of Smartphone Walking Speed Estimation Using Deep Learning (Poster), *Proceedings of the 17th Annual International Conference on Mobile Systems, Applications, and Services, MobiSys '19*, New York, NY, USA, Association for Computing Machinery, pp. 641–642 (online), DOI: 10.1145/3307334.3328667 (2019).
- [5] 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).
- [6] Kawaguchi, N., Nozaki, J., Yoshida, T., Hiroi, K., Yonezawa, T. and Kaji, K.: End-to-end walking speed estimation method for smartphone PDR using DualCNN-LSTM., *IPIN (Short Papers/Work-in-Progress Papers)*, pp. 463–470 (2019).
- [7] Kang, W. and Han, Y.: SmartPDR: Smartphone-Based Pedestrian Dead Reckoning for Indoor Localization, *IEEE Sensors Journal*, Vol. 15, No. 5, pp. 2906–2916 (online), DOI: 10.1109/JSEN.2014.2382568 (2015).
- [8] Jiménez, A., Seco, F., Prieto, J. and Guevara, J.: Indoor pedestrian navigation using an INS/EKF framework for yaw drift reduction and a foot-mounted IMU, *2010 7th Workshop on Positioning, Navigation and Communication*, pp. 135–143 (online), DOI: 10.1109/WPNC.2010.5649300 (2010).
- [9] Zhang, W., Li, X., Wei, D., Ji, X. and Yuan, H.: A foot-mounted PDR system based on IMU/EKF+HMM+ZUPT+ZARU+HDR+compass algorithm, *2017 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1–5 (online), DOI: 10.1109/IPIN.2017.8115916 (2017).
- [10] Kunze, K., Lukowicz, P., Partridge, K. and Begole, B.:

- Which Way Am I Facing: Inferring Horizontal Device Orientation from an Accelerometer Signal, *2009 International Symposium on Wearable Computers*, pp. 149-150 (online), DOI: 10.1109/ISWC.2009.33 (2009).
- [11] Deng, Z.-A., Wang, G., Hu, Y. and Wu, D.: Heading Estimation for Indoor Pedestrian Navigation Using a Smartphone in the Pocket, *Sensors*, Vol. 15, No. 9, pp. 21518-21536 (online), DOI: 10.3390/s150921518 (2015).
- [12] 坂 涼司, 梶 克彦, 河口信夫: 磁気とWiFi電波強度を含んだマップ情報に歩行者デッドレコニングを併用した屋内位置推定手法, 電子情報通信学会技術研究報告; 信学技報, Vol. 113, No. 399, pp. 23-28 (2014).
- [13] Ban, R., Kaji, K., Hiroi, K. and Kawaguchi, N.: Indoor positioning method integrating pedestrian Dead Reckoning with magnetic field and WiFi fingerprints, *2015 Eighth International Conference on Mobile Computing and Ubiquitous Networking (ICMU)*, pp. 167-172 (online), DOI: 10.1109/ICMU.2015.7061061 (2015).
- [14] Chen, C., Lu, X., Markham, A. and Trigoni, N.: IONet: Learning to Cure the Curse of Drift in Inertial Odometry, *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 32, No. 1 (online), DOI: 10.1609/aaai.v32i1.12102 (2018).
- [15] Chen, C., Zhao, P., Lu, C. X., Wang, W., Markham, A. and Trigoni, N.: Deep-Learning-Based Pedestrian Inertial Navigation: Methods, Data Set, and On-Device Inference, *IEEE Internet of Things Journal*, Vol. 7, No. 5, pp. 4431-4441 (online), DOI: 10.1109/JIOT.2020.2966773 (2020).
- [16] Herath, S., Yan, H. and Furukawa, Y.: RoNIN: Robust Neural Inertial Navigation in the Wild: Benchmark, Evaluations, & New Methods, *2020 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 3146-3152 (online), DOI: 10.1109/ICRA40945.2020.9196860 (2020).
- [17] 藤澤宏幸, 吉田忠義, 小野部純, 武田涼子, 有末伊織, 西澤 哲: 若年健常者における後ろ歩きの速度制御に関する研究, 理学療法学, Vol. 37, No. 1, pp. 17-21 (オンライン), DOI: 10.15063/rigaku.KJ00006203364 (2010).
- [18] Ha, S., Yun, J.-M. and Choi, S.: Multi-modal Convolutional Neural Networks for Activity Recognition, *2015 IEEE International Conference on Systems, Man, and Cybernetics*, pp. 3017-3022 (online), DOI: 10.1109/SMC.2015.525 (2015).
- [19] Zhao, Y., Yang, R., Chevalier, G., Xu, X. and Zhang, Z.: Deep Residual Bidir-LSTM for Human Activity Recognition Using Wearable Sensors, *Mathematical Problems in Engineering*, Vol. 2018, p. 7316954 (2018).
- [20] 松山 仁, 浦野健太, 廣井 慧, 梶 克彦, 米澤拓郎, 河口信夫: 社交ダンスの動作特性を考慮したマルチモーダルセンサによるダンスフィガー認識, 情報処理学会論文誌, Vol. 61, No. 10, pp. 1591-1604 (2020).
- [21] Matsuyama, H., Aoki, S., Yonezawa, T., Hiroi, K., Kaji, K. and Kawaguchi, N.: Deep Learning for Ballroom Dance Recognition: A Temporal and Trajectory-Aware Classification Model With Three-Dimensional Pose Estimation and Wearable Sensing, *IEEE Sensors Journal*, Vol. 21, No. 22, pp. 25437-25448 (online), DOI: 10.1109/JSEN.2021.3098744 (2021).
- [22] Shavit, Y. and Klein, I.: Boosting Inertial-Based Human Activity Recognition With Transformers, *IEEE Access*, Vol. 9, pp. 53540-53547 (online), DOI: 10.1109/ACCESS.2021.3070646 (2021).
- [23] Wang, Q., Luo, H., Ye, L., Men, A., Zhao, F., Huang, Y. and Ou, C.: Pedestrian Heading Estimation Based on Spatial Transformer Networks and Hierarchical LSTM, *IEEE Access*, Vol. 7, pp. 162309-162322 (online), DOI: 10.1109/ACCESS.2019.2950728 (2019).
- [24] Kaji, K., Watanabe, H., Ban, R. and Kawaguchi, N.: HASC-IPSC: Indoor Pedestrian Sensing Corpus with a Balance of Gender and Age for Indoor Positioning and Floor-Plan Generation Researches, *Proceedings of the 2013 ACM Conference on Pervasive and Ubiquitous Computing Adjunct Publication, UbiComp '13 Adjunct*, New York, NY, USA, Association for Computing Machinery, pp. 605-610 (online), DOI: 10.1145/2494091.2495981 (2013).
- [25] 梶 克彦, 渡辺穂高, 坂 涼司, 河口信夫: HASC-IPSC: 屋内歩行センシングコーパス, 研究報告ユビキタスコンビューティングシステム (UBI), Vol. 2014, No. 41, pp. 1-8 (2014).
- [26] Kaji, K., Abe, M., Wang, W., Hiroi, K. and Kawaguchi, N.: UbiComp/ISWC 2015 PDR Challenge Corpus, *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct*, UbiComp '16, New York, NY, USA, Association for Computing Machinery, pp. 696-704 (online), DOI: 10.1145/2968219.2968276 (2016).
- [27] Chen, C., Zhao, P., Lu, C. X., Wang, W., Markham, A. and Trigoni, N.: Oxiod: The dataset for deep inertial odometry, *arXiv preprint arXiv:1809.07491* (2018).
- [28] Ichikari, R., Shimomura, R., Kourogi, M., Okuma, T. and Kurata, T.: Review of PDR Challenge in Warehouse Picking and Advancing to xDR Challenge, *2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1-8 (online), DOI: 10.1109/IPIN.2018.8533831 (2018).
- [29] Abe, M., Kaji, K., Hiroi, K. and Kawaguchi, N.: PIEM: Path Independent Evaluation Metric for Relative Localization, *2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1-8 (online), DOI: 10.1109/IPIN.2016.7743587 (2016).


**加納 一馬** (学生会員)

2022年名古屋大学工学部電気電子情報工学科卒業。同年4月より同大学大学院工学研究科情報・通信工学専攻修士課程学生。屋内位置推定, 行動認識, 深層学習に関する研究に従事。

**吉田 拓人**


2020年名古屋大学工学部電気電子情報工学科卒業。2022年同大学大学院工学研究科情報・通信工学専攻修士課程修了。屋内位置推定, 行動認識, 機械学習に関する研究に従事。






**浦野 健太** (正会員)

2016年名古屋大学工学部電気電子・情報工学科卒業。2018年に同大学大学院修士課程、2021年に博士課程を修了。同年より同大学院助教。博士(工学)。屋内位置推定、実世界データモデリング、生体信号のエンターテインメント利用に関する研究に従事。



**米澤 拓郎** (正会員)

2010年慶應義塾大学大学院政策・メディア研究科後期課程博士号取得後、同大学院特任助教、特任講師、特任准教授を経て、2019年より名古屋大学大学院工学研究科准教授。主に、ユビキタスコンピューティングシステム、ヒューマンコンピュータインタラクション、センサネットワーク等の研究に従事。ACM, IEICE, IEEE 各会員。



**河口 信夫** (正会員)

1990年名古屋大学工学部電気電子工学科卒業。1995年同大学大学院工学研究科情報工学専攻博士課程満了。同年同大学工学部助手、同大学講師、准教授を経て、2009年より同大学大学院工学研究科教授。NPO 位置推定サービス研究機構 Lisra 代表理事。モバイルコミュニケーション、ユビキタスコンピューティング、行動センシングの研究に従事。博士(工学)。ACM, IEEE, 人工知能学会, 日本ソフトウェア科学会, 電子情報通信学会, 日本音響学会各会員。本会シニア会員。