端末保持状態変化に対応した進行方向推定手法

木下 貴斗[1] 池内 雄一[1] 西尾 信彦[1]

概要：近年, スマートフォンの普及と建物の複雑化により, ナビゲーション等の需要が高まってきている. ナビゲーションを行うには自己位置を正しく推定する必要があり, 屋内においてはスマートフォンのみで実装が可能である PDR(Pedestrian Dead Reckoning) が注目を集めている. 既存の PDR は端末の保持状態が変化することに対応できておらず, 常に一定の保持状態でないと大きな誤差が発生し累積してしまう問題点がある. そこで本研究では, 端末の保持状態が変化する間に発生する角速度による進行方向推定の誤差を抑制し, 進行方向推定の精度を向上させる手法を提案する. 端末の保持状態が変化中か否かを逐次判別するために, 閾値ベースの手法と機械学習ベースの手法を提案する. 端末保持状態変化中と識別された区間においては角度の累積を停止することにより問題の解決を図る. 閾値ベースによる分類では 3 種類のすべての手法で F 値が約 0.5 程度にとどまった. 一方, ランダムフォレストを用いた手法による端末保持状態変化中と分類する際の F 値が約 0.8 となった. また進行方向推定精度についても, 提案したすべての手法において, 誤差 50 度以内で進行方向を推定することができた.

TAKATO KINOSHITA[1] YUICHI IKEUCHI[1] NOBUHIKO NISHIO[1]

1. はじめに

近年, 技術の進歩にともないスマートフォンが急速に普及しており, その利用方法 [1] の一つとして地図やナビゲーションがある. 高層建築物が増加した現代においては, 屋外だけではなく屋内においてもナビゲーションの重要度は高まってきている. ナビゲーションを行うには自己位置を正しく推定する必要があり, 屋内においては Wi-Fi やビーコンを用いた絶対測位手法 [2][3] が考案されている. しかしこれらの手法は, 機器の設置や整備に関するコストが多くかかるため, スマートフォンのみで実装が可能である PDR(Pedestrian Dead Reckoning) が近年注目を集めている. PDR はスマートフォンに内蔵されているセンサ群を用いることで歩行を検知し, 歩幅と進行方向をセンサデータから計算することで, 初期位置からの相対的な自己位置を推定する手法である. しかし, PDR のみを利用した場合, 誤差を較正することができないため移動距離が伸びるほど誤差が累積してしまう問題を抱えている. そのため, Wi-Fi や建物の地図情報を用いて定期的に較正を行う手法 [4] が考案されているが, これらの手法は Wi-Fi の電波マップ (各地点における Wi-Fi 電波の強度を示す地図) や建物の詳細な間取り図を事前に入手する必要があり, 事前準備にかかる労力が大きいという問題がある.

また, 歩行時においてスマートフォンは様々な形で保持されることが予想される. 例えば「手に持っている」,「ポケットに入れている」,「カバンの中に入れている」などがあり, それぞれの動作において端末の姿勢は常に不定となる. さらに,「ポケットから取り出して手に持つ」,「手に持った端末をカバンにしまう」などの保持状態が変化している間は, 歩行とは関係のない加速度や角速度が発生し, PDR の誤差を大きくする要因の一つとなりうる. そこで本研究では, PDR に対し前述のような絶対位置による補正を行わずに, 端末の保持状態が変化する間に発生する角速度による進行方向推定の誤差を抑制し, 進行方向推定の精度を向上させる手法を提案する. 端末の保持状態が変化中かを逐次判別するために, 閾値ベースの手法と機械学習ベースの手法を提案する. 閾値ベースの手法では, 加速度の時間変化量, 加速度の分散, 連続する 2 データ間の分散の差に着目し一定値以上の変化が認められた時に端末保持状態変化中と定義する. 機械学習ベースの手法については教師ありの分類器である J48 決定木とランダムフォレストを使用

[1] 立命館大学 情報理工学部

する．端末保持状態変化中と識別された区間においては角度の累積を停止することにより，端末の保持状態が変化する間に発生する角速度による進行方向推定の誤差の抑制を図る．

本研究の貢献は，これまでの研究において PDR に課せられた「端末保持状態の固定」という制約をなくし，より実用性を高めたことである．

2. 関連研究

本章では，既存の PDR を用いた自己位置推定と，その際の進行方向推定の精度向上を目的とした研究について紹介する．

2.1 角速度累積法

星ら [5] はスマートフォンに内蔵されたセンサ群のうち加速度センサとジャイロセンサのみを用いて，端末の様々な保持状態に対して頑強な進行方向推定手法を提案した．端末で得られた角速度から回転行列を逐次算出し，それをもとに端末座標系の角速度データを世界座標系に変換する．歩行者の進行方向が，世界座標系における Z 軸 (鉛直上向きを正とする軸) 周りの回転量を累積したものと一致することから世界座標系における Z 軸まわりの角速度を累積していくことで進行方向を推定する手法を提案した．この手法による複数回の試行の結果，「手持ち」状態における進行方向推定誤差の平均値が 11.8 度，「手振り」状態が 18.2 度，「胸ポケット」が 24.9 度，「ズボンポケット」が 15.0 度，「カバン」が 15.4 度であったと述べている．この研究ではあくまで同じ保持状態を継続している間のみでしか検証がされていない．そのため，端末をポケットから取り出す，鞄の中に入れるといった行動により誤推定をする可能性がある．

2.2 Multi-Mode PDR

Tian ら [6] は，保持状態の変化による PDR への影響を低減するため，「TRANS 状態」という状態を定義して処理を変更する MultiMode-PDR を提案した．「手振り状態」，「手持ち状態」，「ズボンポケット状態」の 3 状態 (定常状態と呼ぶ) と，それらの状態間を遷移する状態「TRANS 状態」の 4 状態からなる有限オートマトンを定義した．定常状態では角速度の y 軸と z 軸に閾値を設けて，閾値を超えた変化がみられると TRANS 状態に遷移する．TRANS 状態においては重力加速度を監視し，定常状態のうちどの状態に遷移するかを決定する．この研究において，TRANS 状態に誤って推定された割合が 1.89%，状態遷移が検出されなかった割合が 7.55%であったと述べている．この研究では，遷移動作の識別に角速度の 2 軸しか利用していないため，加速度を利用したり機械学習を用いたりすることにより識別精度を向上できる可能性があると考えられる．

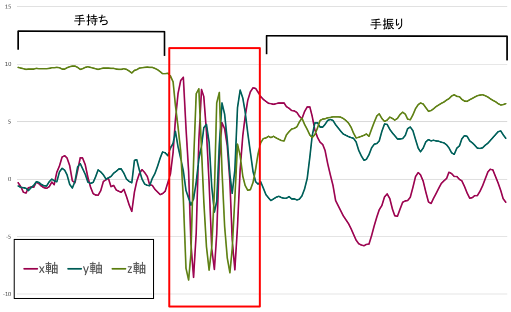

図 1　端末座標系における加速度のグラフ．横軸は時間，赤枠が保持状態を変化させている区間

3. 提案手法

本章では，第 1 章にて述べた問題点を解決するための提案手法を説明する．3.1 節では提案手法の概要を説明する．3.2 節では加速度データの様々な時系列変化に着目した閾値ベースの手法について，3.3 節では教師ありの分類器を用いた機械学習ベースの手法についてそれぞれ説明する．

3.1 概要

スマートフォンに搭載された慣性センサを用いて，加速度と角速度を収集する．サンプリングレートは約 100Hz である．PDR の既存手法 [5][7] において進行方向推定は，端末座標系で取得された角速度データを世界座標系に変換し，その Z 軸成分を時間積分することによって実装しており，本研究もその手法に則している．金具ら [7] の手法を参考にし，座標変換はクォータニオンを用いて行う．3.2 節，3.3 節にて述べる手法を用いて端末保持状態変化中と識別された区間は角度の累積を停止する．

端末保持状態変化中とは，歩行者と端末の相対的な位置や姿勢が変化することを指す．本研究では端末の保持状態として「手持ち」「手振り」「ズボンポケット」「カバン」「電話」の 5 状態を定義し，これらの保持状態間を遷移する動作 (例えば，手持ちから電話に出る，ズボンポケットから取り出してカバンに移すなど) を端末保持状態変化中と定義する．

3.2 閾値ベースの提案手法

図 1 は，端末座標系における加速度データの時系列変化である．端末の保持状態が一定の間はほぼ一定の値をとり続けるが，保持状態が変化している間は前者と比べて大きな変化がみられる．この特徴に着目し，ローパスフィルタを適用し，ステップノイズとホワイトノイズを除去したのち 3 種類の閾値を設定する．

3.2.1 過去 0.2 秒間における最大値と最小値の差

ウィンドウ幅 0.2 [s] のスライディングウィンドウ方式を採用し，ウィンドウ内の最大値と最小値の差を求める．**図 2**

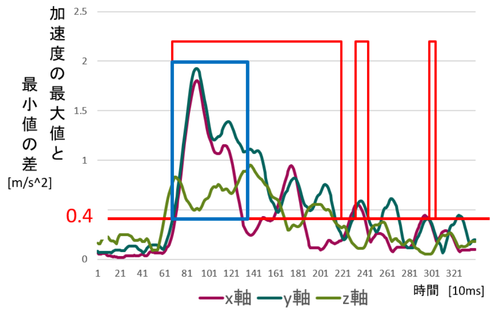

図 2 幅 0.2[s] のウィンドウ内における最大値と最小値の差のグラフ．青枠は実際に端末の保持状態を変化させた区間，赤枠内が端末保持状態変化中と識別される区間

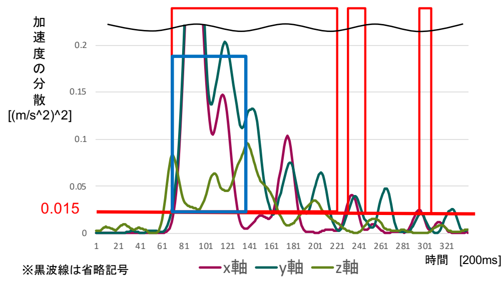

図 3 幅 0.2[s] のウィンドウ内における分散のグラフ．青枠は実際に端末の保持状態を変化させた区間，赤枠内が端末保持状態変化中と識別される区間

はそのグラフである．端末の保持状態が一定の間は 0 に近い値をとるが，端末保持状態変化中は大きな値をとることがわかる．また，図中青枠の直後または青枠内において転回をすることを本研究では想定していないため，今回は端末保持状態変化中の区間を正しく識別する閾値を設定することが目標となる．ただし，手振り状態においてもある程度の変化がみられるため，手振り状態と端末保持状態変化中を正しく識別する必要がある．複数回の試行から，手振り状態においては主に 1 軸のみが大きく変動するのに対し，端末保持状態変化中は少なくとも 2 軸以上が大きく変動することが分かった．事前実験の結果から，今回は x, y, z 軸のうちいずれか 2 軸以上が閾値 0.4 [m/s^2] を上回った区間を端末保持状態変化中と設定した．この手法は以降，max-min と呼ぶ．

3.2.2 過去 0.2 秒間における分散

ウィンドウ幅 0.2 [s] のスライディングウィンドウ方式を採用し，ウィンドウ内の加速度の分散を求める．**図 3** はそのグラフである．こちらも端末の保持状態が一定の間は 0 に近い値をとるが，端末保持状態変化中は大きな値をとることがわかる．この手法においても事前実験の結果から，3.2.1 節と同様に，3 軸のうちどれか 2 軸以上が閾値 0.015 [$(m/s^2)^2$] を上回った区間を端末保持状態変化中と設定した．この手法は以降，variance と呼ぶ．

3.2.3 連続する二つの分散の差の絶対値

すべての t [s] において，3.2.2 節にて求めた時刻 t における分散と，t-1 における分散の差の絶対値を求める．**図 4** はそのグラフである．こちらも端末の保持状態が一定の間は 0 に近い値をとるが，端末保持状態変化中は大きな値をとることがわかる．この手法においても事前実験の結果から，3.2.1 節と同様に，3 軸のうちどれか 2 軸以上が閾値 0.002 [$(m/s^2)^2$] を上回った区間を端末保持状態変化中と設定した．この手法は以降 d_variance と呼ぶ．

3.3 機械学習ベースの提案手法

本研究は「端末保持状態が変化しているか否かを識別する」ことが重要である．これは 2 クラスの分類を行うことと同義であるため，機械学習を用いた分類も検討する．本研究では教師ありの分類器として，WEKA[8] にて用意されている J48 決定木 [9] とランダムフォレスト [10] を使用する．J48 決定木は，C4.5 アルゴリズムに基づいた教師ありの分類アルゴリズムである．ランダムフォレストは複数の決定木の結果から多数決で出力を決定する教師ありの分類アルゴリズムである．

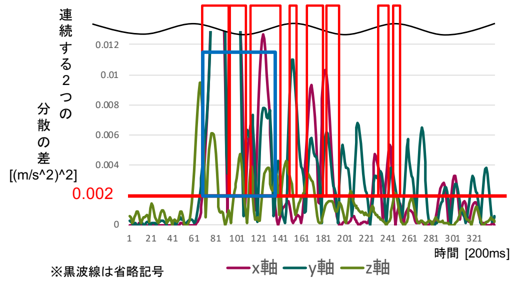

図 4 連続する二つの分散の差の絶対値のグラフ．青枠は実際に端末の保持状態を変化させた区間，赤枠内が端末保持状態変化中と識別される区間

本研究では，端末保持位置が一定である状態を「walking」，端末保持位置が一定ではなく，端末保持状態が変化している状態を「changing」，端末保持位置は一定ではないが端末保持状態は一定である状態を「swinging」としてラベルを付ける．手振り状態は walking として分類されるべきであるが，changing として分類される可能性が高いと判断し，新たに手振り状態だけのクラスラベルを用意した．swinging と walking に分類されたときは角度を累積し，changing と分類されたときのみ角度の累積を停止する．

与える特徴量は加速度の生データ，ローパス処理を施した加速度，3.2.1 節にて求めた最大値と最小値の差，3.2.2 節にて求めた分散，3.2.3 節にて求めた分散の差，ローパス処理を施した角速度の 6 種について各 3 軸の計 18 個である．教師データは walking 24941 データ，swinging 8254 データ，changing 6485 データを用意した．

図 5　実験の経路

図 6　被験者の様子．図は手持ち状態

4. 評価

本章では, 第 3 章で述べた提案手法の有用性を評価する. 4.1 節では実験の内容について述べ, 4.2 節では各手法による端末保持状態変化中の期間の識別精度と進行方向の推定精度について評価を行う.

4.1 実験

実験は立命館大学クリエーションコアの 5 階にて行った．android studio にて実装したアプリケーションがインストールされた Pixel 3a を 2 台用意した．(以後, この Pixel 3a を端末と呼ぶ)

図 5 は実験に使用した経路であり, 矢印のように反時計回りに一周する．被験者は**図 6** のように首から端末を一つさげ, もう一つを手に保持して, 好きなタイミングで五種類の保持状態から一つ選んで歩く．歩行の様子を動画で撮影し, 保持状態変化中か否かを記録しラベル付けをする．つけられたラベルをもとに, 推定された状態が正しいかを識別精度として算出する．また, 首からさげた端末で計測された進行方向を真値とし, 手に保持した端末で計測された進行方向との差を進行方向の推定精度として算出する.

4.2 評価

4.2.1 閾値ベースの手法による識別精度に関する評価

10 回の試行における, それぞれの手法の適合率, 再現率, 正解率, F 値をまとめたものを**表 1** に示す．また, 10 件の結果の中から無作為に選んだ 1 件について, max-min による分類, variance による分類, d_variance による分類結果の混同行列をそれぞれ**表 2**, **表 3**, **表 4** に示す.

閾値ベースの手法は 3 種類とも, F 値が 5 割程度にとどまった．max-min と variance については再現率は 6 割程度であるが, 適合率が 5 割を下回る結果となった．d_variance については再現率も適合率も同程度となった．FALSE NEGATIVE (保持状態を変化させたにもかかわらず, 変えていないと識別されること) を減らし, 再現率を高くすることができたといえるが, 適合率が低くなってしまったために全体の精度としてはそこまで高くない結果となった.

表 1　閾値ベースによる各手法の F 値

	再現率	適合率	正解率	F 値
max-min	0.604	0.477	0.830	0.530
variance	0.639	0.448	0.815	0.523
d_variance	0.547	0.522	0.846	0.531

※試行 10 回の平均値

表 2　max-min による 2 クラス分類の混同行列

		実際 walking	実際 changing
推測	walking	4167	315
	changing	613	504

表 3　variance による 2 クラス分類の混同行列

		実際 walking	実際 changing
推測	walking	4017	281
	changing	763	538

表 4　d_variance による 2 クラス分類の混同行列

		実際 walking	実際 changing
推測	walking	4317	358
	changing	463	461

4.2.2 機械学習ベースの手法による識別精度に関する評価

10 回の試行における, それぞれのアルゴリズムによる分類の F 値を**表 5** に示す．また, 10 件の結果の中から無作為に選んだ 1 件について, ランダムフォレストによる分類の混同行列を**表 6** に, J48 による分類の混同行列を**表 7** に示す.

表 5 より, ランダムフォレストによる分類の方が, 端末保持状態変化中の識別精度が良いことがわかる．F 値はランダムフォレストで約 0.8 であり, 高い精度で識別ができていることがわかる．この精度の差は主に changing と walking(または swinging) との切り替わりの識別精度が直結している．複数の決定木の結果から多数決で出力を決定

するランダムフォレストの特徴が効果的に作用したものと考えられる．

表 5　機械学習ベースによる各手法の F 値

	walking	changing	swinging
ランダムフォレスト	0.956	0.796	0.984
J48	0.931	0.725	0.978

※試行 10 回の平均値

表 6　ランダムフォレストによる 3 クラス分類の混同行列

		実際		
		walking	changing	swinging
推測	walking	3614	158	0
	changing	140	639	0
	swinging	11	22	1015

表 7　J48 による 3 クラス分類の混同行列

		実際		
		walking	changing	swinging
推測	walking	3455	172	0
	changing	304	629	1
	swinging	6	18	1014

4.2.3　進行方向推定精度に関する評価

本節では，各手法による進行方向の推定精度について評価する．被験者の首に提げた端末にて計測された進行方向の推定値を真値とし，手に保持された端末で推定された進行方向の推定値との誤差を算出する．誤差は各タイムスタンプにおける真値と推定値の差とする．10 回の試行における，各手法による推定値の誤差の最大値，平均，標準偏差について，10 回の試行の平均値を**表 8** に示す．また，10 件の試行の中から無作為に選択した 1 件について，実際の進行方向推定結果のグラフを**図 7** に示す．

補正なしの場合は保持状態が変化した際に大きな誤差が発生しているが，提案したどの手法においても誤差を抑制することができている．最も推定精度が高かったのは variance で，次いで max-min，ランダムフォレストという結果になった．すべての手法において進行方向の推定誤差が 50 度以内に収まっており，提案した手法の有用性を示せたといえる．

すべての手法に共通する誤差の主な原因として，端末保持状態が一定の際にもわずかに揺れると進行方向が大きく変化してしまうことがあり，その誤差が累積してしまったことが考えられる．また，転回の際の特徴量の変化を端末保持状態変化中として誤認識してしまい誤差が発生したことも考えられる．

表 8　各手法による進行方向推定の誤差

	補正なし	max-min	variance	d_variance	Random Forest	J48
誤差最大	139.44	33.44	30.56	45.83	33.99	40.87
誤差平均	46.33	9.87	7.97	11.92	11.17	11.78
誤差標準偏差	44.04	7.37	6.34	11.25	8.93	10.47

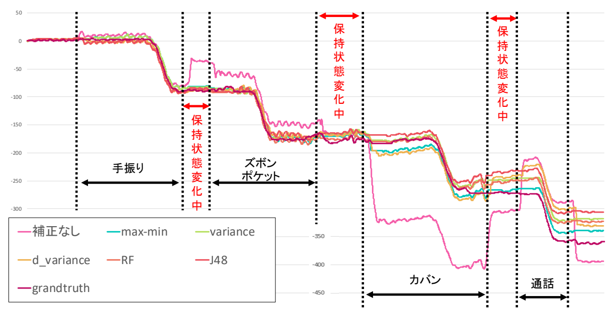

図 7　進行方向推定結果

5.　結論

5.1　まとめ

本研究では，PDR における進行方向推定をより実用的にすることを目的とし，端末保持状態を変化させると正しい進行方向が算出できない課題を解決した．端末の保持状態が変化している間，加速度に特徴的な変化が現れることに着目し，三種類の閾値を設けて識別を試みた．また，一定の保持状態で歩行している「walking」，端末の保持状態を変化させながら歩行している「changing」，端末を持った手を振りながら歩いている「swinging」の 3 種類のクラスを用意し，18 種類の特徴量をもとに分類する教師あり学習アルゴリズム 2 種類による識別も試みた．結果として，閾値ベースの手法では max-min が，機械学習ベースの手法ではランダムフォレストが最も高い精度で端末保持状態変化中を識別でき，進行方向推定の誤差の累積を抑制することが可能であることがわかった．

5.2　今後の課題

本節では本研究で達成できなかった，今後解決すべき課題について述べる．

5.2.1　進行方向推定に関する課題

本手法は，端末の保持状態が変化している間は角度の累積を停止することで進行方向推定値への影響を抑制するものである．しかし，端末の保持状態を変えながら進行方向を変化させると，進行方向の変化が正しく取得できず誤差の原因となりえる．考えられる解決策としては，世界座標系に変換した加速度を利用することが挙げられる．人間が歩行をする際，進行方向ベクトルと平行な軸において最も加速度の振幅が大きくなる．この軸と世界座標系との関係が算出できればこの軸のベクトルを信頼できる進行方向ベクトルとして補正が可能であると考えられる．

5.2.2　歩数や歩幅に関する課題

PDR はセンサ群から得られるデータをもとに，ステップ

を検知し, 進行方向と歩幅を推定することで相対的な位置を推定する手法である．今回は進行方向のみに焦点を当てて研究を進めたが, PDR への適応を考慮すると歩数や歩幅についても対応が必要であると考えられる．

参考文献

[1] MMD 研究所. 2018 年版：スマートフォン利用者実態調査. https://mmdlabo.jp/investigation/detail_1760.html. 2020 年 1 月 24 日閲覧.

[2] Bisio Igor, Sciarrone Andrea, Bedogni Luca, and Bononi Luciano. WiFi meets Barometer: Smartphone-based 3D Indoor Positioning Method. 2018 IEEE International Conference on Communications (ICC), 2018

[3] Song Wook, Lee HwaMin, Lee Seung-Hyun, Choi Min-Hyung, and Hong Min. Implementation of Android Application for Indoor Positioning System with Estimote BLE Beacons. Journal of Internet Technology, Vol. 19, No. 3, pp. 871-878, 2018

[4] 吉見駿, 村尾和哉, 望月祐洋, 西尾信彦. マップマッチングを用いた PDR 軌跡補正. 研究報告ユビキタスコンピューティングシステム (UBI), Vol. 2014-UBI-44, No. 20, pp. 1-8, 2014

[5] 星尚志, 藤井雅弘, 羽多野裕之, 伊藤篤, 渡辺裕. スマートフォンを用いた歩行者デッドレコニングのための進行方向推定に関する研究. 情報処理学会論文誌, Vol. 57, No. 1, pp. 25-33, 2016.

[6] Qinglin Tian and Kevin I-Kai Wang. A Multi-Mode Dead Reckoning System for Pedestrian Tracking Using Smartphones;. IEEE SENSOR JOURNAL, Vol. 16, No. 7, pp. 2079-2093, 2016

[7] Kanagu K, Tsubouchi K and Nishio N. Colorful PDR: Colorizing PDR with shopping context in walking. International Conference on Indoor Positioning and Indoor Navigation, pp. 1-8, 2017

[8] Univercity of Waikato. WEKA. https://www.cs.waikato.ac.nz/ml/weka/. 2020 年 1 月 24 日閲覧.

[9] Bhargava Neeraj, Girja Sharma, Ritu Bhargava, and Manish Mathuria. Decision Tree Analysis on J48 Algorithm for Data Mining. International Jounal of Advanced Research in Computer Science and Software Engineering, Vol. 3, No. 6, pp. 1114-1119, 2013

[10] N.Venkatesan and G.Priya. Study of Random Forest Algorithm with implementation using Weka. International Jounal of innovative Research in Computer Science and Software Engineering, Vol. 1, No. 6, pp. 156-162, 2015