

# 屋内空間における係留状態認識

金具浩平<sup>1</sup> 川内菜津美<sup>2</sup> 大槻拓未<sup>2</sup> 西尾信彦<sup>2</sup>

**概要:** 屋内では GPS による測位が困難なため, 代わりとなる屋内手法が多く提案されている. 代表的なものに Wi-Fi や BLE を用いた手法や PDR(Pedestrian Dead Reckoning) がある. Wi-Fi 基地局はセキュリティ上の問題から設置されない場合があり, Wi-Fi, BLE ビーコンはともに設置コストがかかるという問題がある. 一方で PDR は, スマートフォンに内蔵された加速度センサや角速度センサなどを用いて初期位置からの相対的な位置を推定する手法であり, 外部インフラが必要ない. PDR は加速度などを利用するため, 微小な加速度の変化でも歩行したと認識してしまう可能性がある. 例えば, 屋内においてユーザが頻繁に行う「立ち止まる」, 「着席する」, 「離席する」などといった加速度などのセンサ値は変化するが移動は伴わない動作及び状態(以下, 係留状態)で歩行と検知し, 測位誤差が発生する場合がある. 本研究では歩行誤り検知の削減を目的として加速度センサの値の変化を見ることでユーザが係留状態かを判別する. 結果, 正解率はベースラインの精度である 20%を上回り, 正解率は 59.2%となった.

KOHEI KANAGU<sup>1</sup> NATSUMI KAWAUCHI<sup>2</sup> TAKUMI OTSUKI<sup>2</sup> NOBUHIKO NISHIO<sup>2</sup>

## 1. はじめに

屋内における位置情報はナビゲーションやマーケティングに利用できるため, ユーザの位置を推定する手法に注目が集まっている. 屋外ではほとんどの場合 GPS で測位が可能だが, 屋内では GPS からの信号が建物に遮断されるため GPS を用いた測位が困難である. 屋内測位手法の代表的なものに Wi-Fi や BLE を用いた手法や PDR(Pedestrian Dead Reckoning) がある. Wi-Fi や BLE を用いた手法ではユーザが保持するスマートフォン端末で観測した Wi-Fi や BLE ビーコンの情報やその電波強度などから現在位置を推定する, GPS 同様に絶対的な位置を求める手法である. しかし Wi-Fi はセキュリティ上の問題から設置されない場合があり, Wi-Fi, BLE はともに設置コストがかかるという問題がある. 一方で PDR は仕組みが異なり, スマートフォンに内蔵された加速度センサや角速度センサなどを用いて歩行, 進行方向を推定し, 初期位置からの相対的な位置及び歩行軌跡を推定する手法である. スマートフォン単体で測位でき, 特別な外部インフラを整備する必要がないという利点がある. しかし, 加速度センサの値を

測位に利用するため, 加速度の微小な変化により測位誤差が生じる可能性がある. 例えばユーザが頻繁に行う「立ち止まる」, 「着席する」, 「離席する」など移動しない動作及び状態(以下, 係留状態)がある. 係留状態は, 加速度などのセンサ値は変化するが移動は伴わない動作及び状態を意図している. 着席する動作には椅子を引く, 立ち上がるといった動作が含まれ加速度の値が変化するが, これを PDR では歩行として検知してしまう可能性があり, 測位誤差につながる.

本研究では加速度センサや角速度センサの値を用いてユーザが係留状態かその他の状態かを判別する. PDR にも利用される加速度センサや角速度センサから得る値から相関がある歩行コンテキストを機械学習を用いて認識し判別を行うことで, 加速度の値の変化が移動によるものか姿勢の変化などによるものかを判別する. 本手法を PDR に適用することで誤った歩行検知を減らし, 測位誤差の軽減が可能であると考えられる. 現在位置を何度も与えることで測位誤差の軽減は可能だが設備を整える必要があるため PDR の利点が失われてしまう. そこで本手法のように測位誤差の原因を減らすことが必要である.

<sup>1</sup> 立命館大学情報理工学研究科

<sup>2</sup> 立命館大学情報理工学部

## 2. 関連研究

### 2.1 カメラを用いた手法

カメラを用いた手法 [1] では、カメラからの映像を基にして、ユーザの身体の動きや周りの環境などからコンテキストを認識している。複数台のカメラを活用できるため、広範囲に渡ってコンテキスト認識が可能であり、また既に多くの場所に導入されている防犯カメラを利用すれば、ユーザへの心理的影響を少なくできる。しかしカメラ映像に映っている個人を常に追跡することは困難であるため、認識結果を踏まえたフィードバックを直接行うことは困難である。

### 2.2 RFID を用いた手法

RFID を用いた手法 [2][3] では、予め環境側に設置された RFID タグをユーザが保持する RFID リーダで読み取ることによって、タグの情報から現在位置を推定できる。また、読み取られたタグの順番や電波強度などを基にして、移動していたか滞在していたのかといったコンテキストも認識できる。しかし、RFID は人体による電波減衰などの環境の変化に影響されやすく、また移動や滞在よりも詳細なコンテキストの認識は困難である。

### 2.3 PDR を用いた手法

PDR の測位結果を用いる手法 [4][5][6][7] では、前後左右への歩行や階段の昇り降り、曲がりなどの歩行のコンテキストを環境側の整備なしに認識できる。これらの前後左右に移動するような歩行のコンテキストは、PDR の測位結果から認識できるコンテキストの最小の解像度であると言える。しかし、歩行以外にも、屋内では着席するといった移動を伴わないコンテキストも存在する。これらのコンテキストでは、RFID や PDR 測位結果の手法では分からないコンテキストとなっている。Makita[4] らが提案する PDRplus は、予め定義した 11 種類の歩行動作を腰部に装着したセンサデバイスを用いて判定していた。判定には、教師ありの機械学習アルゴリズムとして AdaBoost を用いており、90% 以上の精度でそれぞれの歩行動作を判定できていた。レストランのキッチンやオフィスビル内の従業員を対象とした評価から、測位誤差を軽減できていたことに加え、移動や滞在を把握できるため、業務改善に活用できると述べていた。センサデバイスを身体に固定しない方法として、Pei[6] らはポケットに入れたスマートフォンを用いて、歩行・走り・静止に加え、急な曲がりや緩やかな曲がりを認識していた。また、Coskun[7] らは、センサデバイスが手持ち・バッグの中・ポケットの中のいずれかであっても、歩行や走り、階段の昇り降りなどの歩行動作を認識していた。これらの研究では、前後左右への歩行や走

り、曲がり方などを認識していたが、本論文の目的である歩行のコンテキスト認識とは異なる。

## 3. 提案手法

PDR においてユーザが頻繁に行う「立ち止まる (停止)」、「着席/離席」、「姿勢の向きの変更」などの移動しない動作 (以下係留状態) を歩行と検知し、測位誤差が発生する可能性があると考えられる。しかし現在の PDR 測位では「歩行状態」と「停止状態」は考慮されているが、「着席/離席」の様な係留状態は考慮されていない。よって本提案手法では、通常の PDR でも認識されている「歩行状態」「停止状態」に加え、係留状態から「着席状態」と「着席動作」、「離席動作」の 5 つの状態を認識することで PDR の精度向上を目指す。

本提案手法の基本的な流れは Training phase と Test phase に分けられる。Training phase では、加速度と角速度を加工して抽出した特徴量を基にして、機械学習を用いてコンテキスト認識モデルを作成する。Test phase では、同様に抽出した特徴量を基にして、コンテキスト認識モデルを用いてコンテキストを判定する。実用の際は予め作成した学習モデルを用いることで、リアルタイムで評価が可能である。なお、ここで用いられる特徴量は PDR にも利用されるセンサ値と同等のものであり、コンテキスト認識をするために別途必要なセンサ類は必要としない。

### 3.1 Training Phase

提案手法では加速度と角速度を加工して、コンテキスト認識に利用する特徴量とするが、地面に対して水平面の加速度と角速度を基にしているため、センサデバイスの姿勢を推定する必要がある。静止時においては、3 軸加速度の合成値は重力加速度に近似することから、重力方向を基準にして端末の傾きを求めることができるが、ユーザが移動すると移動に伴う加速度が加わるため、重力方向を捉えることは困難である。そのため、水平面に対する端末の傾きをリアルタイムに求める必要がある。そこで、加速度と角速度を組み合わせて傾きを求める Madgwick ら [8] の手法を利用する。Madgwick らは、3D グラフィックスの分野で多用される Quaternion を加速度と角速度から求め、重力方向を捉えられない時は角速度で補完することで、歩行動作による外乱の影響を最小限にした傾きを推定可能にしている。求められた Quaternion を基にして加速度や角速度ベクトルを回転させることで、端末座標系から世界座標系に変換することができるため、水平面の加速度と角速度を求めることができる。特徴量の詳細を表に示す。各特徴量は加速度と角速度から抽出されている値であるため、等価に正規化することが難しい。正規化をうまく行わなければ、特徴量にバイアスがかかってしまい、うまく学習できない場合がある。そこで”区切り間隔”に基づいて量子化する

ることで、疎行列として特徴量を扱う。また、量子化後の行列において一度も値が入らない区分は、学習や評価において計算コストの増加に繋がるため、最小と最大を定義し、学習や評価に有用な区分のみを扱う。これらの特徴量は1秒毎に算出し、学習と評価に利用する。なお、方向変化量は世界座標系に変換した水平面角速度を積分することで求める。

### 3.1.1 コンテキスト認識モデルの作成

コンテキストを認識するためには、予めコンテキスト認識モデルを作成する必要がある。3.1.で述べた特徴量を基にして、機械学習アルゴリズムを用いてコンテキスト認識モデルを作成する。機械学習アルゴリズムは様々なものが存在するが、解決する問題に対して適切なアルゴリズムを選択する必要がある。本論文では教師あり機械学習であるロジスティック回帰での評価を検討する。ロジスティック回帰は、教師ありの機械学習に分類される回帰モデルであり、分類に至った各特徴量の重みが明瞭であるため、有用な特徴量を見出せる特徴がある。

## 3.2 Test Phase

Test phase では、Training phase と同じく 3.1. で述べたように加速度と角速度から特徴量を求める。求めた特徴量を Training phase で作成したコンテキスト認識モデルで評価することで、未知のデータに対するコンテキストを推定する。

## 3.3 着席/離席認識におけるラベル付け

今回の着席/離席認識においてセンサ値に対して 250ms 毎に以下の通りラベル付けを行う。

- 歩行状態
- 停止状態
- 着席状態
- 着席動作
- 離席動作

着席状態は椅子に座ったままの状態を指す。着席動作とは座り始める瞬間の動作を指しており、この動作は1回の着席動作につき約1秒程度存在している。離席動作は座ったまま後ろに下がって立ち上がる様な、着席状態から停止状態や歩行状態など他の状態に移行するまでの間の状態を指す。

## 3.4 有用な特徴量の分析

今回利用する特徴量は表1に示す27種類である。まず、世界座標系に変換した加速度のx, y, z軸それぞれの値と3軸合成値、地面に対して水平面の角速度を積分して求めた方向変化量の絶対値から、2秒毎の平均、標準偏差、最大、最小を求める。これらの値を量子化したスパースなベクトルを特徴量とした。

表1 特徴量の詳細

名前	タイプ	説明
acc_avg_x	加速度	x 軸加速度の平均
acc_avg_y	加速度	y 軸加速度の平均
acc_avg_z	加速度	z 軸加速度の平均
acc_avg_syn	加速度	加速度平均 3 軸合成
acc_var_x	加速度	x 軸加速度の分散
acc_var_y	加速度	y 軸加速度の分散
acc_var_z	加速度	z 軸加速度の分散
acc_var_syn	加速度	加速度分散 3 軸合成
acc_sd_x	加速度	x 軸加速度の標準偏差
acc_sd_y	加速度	y 軸加速度の標準偏差
acc_sd_z	加速度	z 軸加速度の標準偏差
acc_sd_syn	加速度	加速度標準偏差 3 軸合成
acc_max_x	加速度	x 軸加速度の最大
acc_max_y	加速度	y 軸加速度の最大
acc_max_z	加速度	z 軸加速度の最大
acc_max_syn	加速度	加速度最大 3 軸合成
acc_min_x	加速度	x 軸加速度の最小
acc_min_y	加速度	y 軸加速度の最小
acc_min_z	加速度	z 軸加速度の最小
acc_min_syn	加速度	加速度最小 3 軸合成
dir_avg	方向変化量	方向変化量平均
dir_var	方向変化量	方向変化量分散
dir_sd	方向変化量	方向変化量標準偏差
dir_max	方向変化量	方向変化量最大
dir_min	方向変化量	方向変化量最小
pre_var	気圧変化量	気圧変化量分散
pre_avg	気圧変化量	気圧変化量標準偏差




図1 有用な特徴量の分析結果

端末から得た加速度と角速度、そして気圧の変化量をコンテキスト認識に利用する特徴量として利用するが、信頼度が低い特徴量を利用してしまうと精度の低減につながってしまう。そこでモデル作成において各特徴量に重みを付けることにより、重み係数が正の値ならばそのラベルらしい特徴量、負の値ならばそのラベルらしくない特徴量と相関付ける。識別対象のラベルと特徴量の相関が低い特徴量は評価に利用せず、相関性が高い特徴量のみを利用することでより精度の高い認識を目指す。分析した特徴量の一覧を図2に示す。それぞれのラベルを判定するモデルにおいて重み係数を濃淡で示しており、淡くなる程らしいラベルだと判定されており、濃くなるほどらしくないラベルだと判定されている。

離席動作において、方向変化量の分散/最大に正解のラベルらしさが表れており、これは立ち上がり時の体の動きに関する方向変化と考えられる。




図 2 実験環境

着席動作は加速度最大 z 軸/方向変化量の最小に正解のラベルらしさが表れており、着席した際の衝撃や方向変化は小さいと考えられる。

着席状態は加速度最小 x 軸に正解のラベルらしさが表れており、反対に速度最大 x 軸と方向変化量の最大は着席らしくない事が表れている。これは通常、着席状態時は体が大きく動くことはないためだと考えられる。

歩行状態は加速度分散 x 軸に正解のラベルらしさが表れており、歩行動作中は足の動きに準じて左右のブレが生じるためだと考えられる。

停止状態は加速度最大 x 軸/y 軸に正解のラベルらしさが表れている。停止状態と着席状態は通常どちらも体の動きが停止しており、最も似通っている状態だと考えられるが、速度最大 x 軸/最小 x 軸において対称的な結果が表れており、この 2 つの特徴量を見ることによって双方の区別が可能である。

## 4. 実験条件

本提案手法では「着席/離席動作」と「着席状態」に着目しているため、被験者にはとある室内の入り口から椅子に向かって歩いてもらい、数秒間着席した後、再び元の位置に戻ってもらった。実験の様子を簡易的に図 2 を 2 回繰り返して得られた 236 サンプルの内、7 割の 165 サンプルを学習に、残りの 3 割である 71 サンプルを評価に利用した。

### 4.1 センサデバイス

センサデバイスは加速度や角速度が取得可能であり、コンテキストを認識するための計算能力が望まれる。しかし特別なセンサデバイスは実利用において現実的ではないため本研究では Android スマートフォンである Nexus5 を利用する。また、センサデバイスを腰や足に固定することは

ユーザにとって負担となると考えられるため、上着の左胸ポケットに入れていることを想定して実験を行なった。

## 5. 評価と考察

5 つのコンテキストを認識するため、ベースラインの精度は 20% となる。本実験の正解率は 59.2% と、いずれの状態認識の結果もベースラインを超えた結果となった。離席動作の判定結果は高く、他の動作とは類似しない独特の動きであると考えられる。着席状態の精度は高く、停止状態の精度が低くなったが、この 2 つの状態は本質的には類似した状態であると考えられるため、状態遷移を適用することでさらなる精度向上を望む事ができると考えられる。

対して歩行状態の判定ミスが目立つが、これは今回は係留状態である着席/離席判定に重きを置いてウィンドウ幅を 250ms という 1 秒に満たない間隔で設定して判定を行ったことにより、歩行特有の動きが表れ辛くなったためだと考えられる。これは歩行を考慮した 1 秒毎に求めた特徴量を追加することで精度向上の可能性が考えられる。また、着席動作にも歩行状態や停止状態への判定ミスが目立つ。今回の実験では着席時の衝撃や椅子を引く動作などの複数の動きを含めて 1 つの着席動作のラベルを付けたため部分的な停止や、歩行する際の歩みの衝撃に類似した部分があることが原因だと考えられる。これはラベルの区間の定義を改善する必要があると考えられる。

それぞれのラベル毎の評価を表 5 に示す。着席状態と離席動作の F 値はそれぞれ 0.74 と 0.78 と精度が高いが、着席動作は 0.33 と精度が低い結果となった。

表 2 推定結果 [サンプル数]

	停止状態	歩行状態	着席状態	着席動作	離席動作
停止状態	7	0	5	3	1
歩行状態	5	4	3	2	0
着席状態	2	1	20	1	1
着席動作	1	1	0	2	0
離席動作	2	0	1	0	9

表 3 推定結果の F 値

停止状態	0.42
歩行状態	0.40
着席状態	0.74
着席動作	0.33
離席動作	0.78

### 5.1 状態遷移

ロジスティック回帰によって認識した状態認識の結果を PDR に適用する際、認識されたそれぞれの状態は何らかの別の状態を経由していると考えられる。例えば本提案手法に

表 4 状態遷移を考慮した推定結果 [サンプル数]

	停止状態	歩行状態	着席状態	着席動作	離席動作
停止状態	7	0		3	
歩行状態	5	4		2	
着席状態			20		1
着席動作			0	2	
離席動作	2	0			9




図 3 不可能な遷移を含む状態遷移

表 5 状態遷移を考慮した推定結果の F 値

停止状態	0.58
歩行状態	0.53
着席状態	0.98
着席動作	0.44
離席動作	0.86




図 4 不可能な遷移を取り除いた状態遷移

において「着席状態」と認識された場合、「着席動作」を経由して「着席状態」と認識されることが考えられ、「離席動作」と認識された場合は「着席状態」を経由していると考えられる。反対に、今回の場合では「着席動作」を経由せずに「着席状態」に遷移しているような認識結果が表れれば、どちらかの認識に誤りがあると考えられる。よって状態遷移を考慮することで、さらなる精度向上を見込む事ができると考える。状態遷移の例を図 3, 4 に示す。

PDR 適用時に状態遷移を考慮した場合の結果を表??, ??に示す。表における空欄はその状態において遷移しない状態であるため、推定される事はないこととしている。正解率は 67.9%と状態遷移を考慮しない場合に比べて全体的に精度が向上したことが確認できた。

## 6. まとめと今後

本研究では屋内測位手法の 1 つである PDR 測位におい

て、係留状態を認識することにより、測位誤差を低減する手法を提案した。「着席/離席動作」や「着席状態」などの係留状態は日常生活を送る上で人が頻繁に行う動作や状態であり、屋内環境における位置情報はナビゲーションやマーケティングなどユーザの位置を推定する手法に注目が集まっている現在において、考慮すべき状態・動作であると考えられる。収集したセンサ値に対して 250ms 毎にラベルを付与し、全 236 サンプルの内、7 割を学習に、残りの 3 割を評価に利用した。また、ロジステック回帰を用いてモデルを作成した際、重み係数を算出してラベルとの相関を調べることで、有用な特徴量を探し出し、よりらしい特徴量を評価に利用した。

被験者の左胸ポケットに端末を入れ、実験を行なった結果全体の正解率は 59.2%とベースラインである 20%を超える精度が表れた。中でも離席動作と着席状態の精度は高く、それぞれ F 値は 0.74 と 0.78 という結果となった。対して着席動作の判定ミスが目立ち、ラベルの区間の定義を改善する必要が感じられた。また、PDR 適用時に状態の遷移を考慮した場合の正解率は 67.9%とさらなる精度向上が見られた。今後として、まず着席/離席判定の精度向上が望まれる。今回はロジステック回帰を用いて機械学習を行なったが、他の機械学習アルゴリズムも試す必要があると考える。また、今回は着席/離席判定に重きをおいて 250ms 毎に判定を行なったが、これが原因で歩行状態の認識における精度が低くなってしまったと考えられるため、各状態毎に最適なウィンドウ幅の設定が必要だと考えられる。

さらに、認識結果を PDR に適用する際、それぞれの状態は何らかの別の状態を経由して発生すると考えられる。現在は状態の遷移を考慮していないため、歩行状態から着席動作を経由せず着席状態へと遷移するなど、現実には起こり得ない遷移が行われている可能性がある。よって不可能な遷移を取り除いた状態遷移を考慮することにより、さらなる精度向上を望む事ができると考えられる。

また、今回は PDR 適用時に状態遷移を考慮することで



精度の向上が見られたが、状態認識時に状態遷移を導入することによりさらに状態認識の精度の向上が見込めると考えられる。

## 参考文献

- [1] Z. J. Zha, H. Zhang, M. Wang, H. Luan, and T. S. Chua. Detecting group activities with multi-camera context. *IEEE Transactions on Circuits and Systems for Video Technology*, Vol. 23, No. 5, pp. 856{869, May 2013.
- [2] Z. Li, K. Ishibashi, K. Takai, and K. Yada. Shop area visit ratio, stay time, and sales outcomes: In-depth analysis based on recorded data. In *2015 2nd Asia-Pacific World Congress on Computer Science and Engineering (APWC on CSE)*, pp. 1{7, Dec 2015.
- [3] Y. Zuo and K. Yada. Using bayesian network for purchase behavior prediction from recorded data. In *2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pp. 2262{2267, Oct 2014.
- [4] Koji Makita, Masakatsu Kouroggi, Tomoya Ishikawa, Takashi Okuma, and Takeshi Kurata. *PDRplus: Human Behaviour Sensing Method for Service Field Analysis*, pp. 25{30. Springer Japan, Tokyo, 2014.
- [5] M. Kouroggi and T. Kurata. A method of pedestrian dead reckoning for smart-phones using frequency domain analysis on patterns of acceleration and angular velocity. In *2014 IEEE/ION Position, Location and Navigation Symposium - PLANS 2014*, pp. 164{168, May 2014.
- [6] Ling Pei, Robert Guinness, Ruizhi Chen, Jingbin Liu, Heidi Kuusniemi, Yuwei Chen, Liang Chen, and Jyrki Kaistinen. Human behavior cognition using smart-phone sensors. *Sensors*, Vol. 13, No. 2, pp. 1402{1424, 2013.
- [7] D. Coskun, O. D. Incel, and A. Ozgovde. Phone position/placement detection using accelerometer: Impact on activity recognition. In *2015 IEEE Tenth International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP)*, pp. 1{6, April 2015.
- [8] S. O. H. Madgwick, A. J. L. Harrison, and R. Vaidyanathan. Estimation of imu and marg orientation using a gradient descent algorithm. In *2011 IEEE International Conference on Rehabilitation Robotics*, pp. 1{7, June 2011.