

加速度と位置情報を用いたバスの乗客の起立・着席推定

上別縄 祐也¹ 勝間 亮¹

概要: バスの利便性を向上させるには、乗客の状態に応じた高度なサービスを提供することが考えられる。乗客の状態は大きく分けて起立と着席があり、それらを自動で判別することが求められる。本論文では、乗客の所持するスマートフォンで加速度と位置情報を取得することで、起立と着席のどちらの状態であるかを推定する方式を提案する。乗客が受ける揺れの影響はバスの停車や発車時に大きくなる特徴を利用するため、提案手法では GPS を用いてバスの停車・発車した時刻を推定する。次にバスの停車・発車時の揺れを、加速度センサを用いて計測することでバスの乗客の起立・着席の状態を推定する。また、乗客が装着したイヤホンで加速度を取得することで、推定した停車・発車時刻の推定精度の向上を図る。

Standing And Seating Status Estimation for Bus Passengers by Acceleration and Position Data

YUYA KANBETSUNAWA¹ RYO KATSUMA¹

1. はじめに

現在、公共交通機関の代表例として鉄道やバスがある。鉄道に比べてバスは混雑時の乗降者のスムーズさや、加減速などの挙動が安定せず、バスの利便性・安全性の向上を図ることが必要である。そのためには、例えば着席しているかどうかなど、乗客の状態に応じて案内や注意喚起の内容を変更することが求められる。

バスの乗客の姿勢には、大きく分けて起立・着席の2パターンがある。バスの乗客が起立しているのか、着席しているのかを推定することができれば、それぞれの状態にある人に対して違った情報提供を行うことができる。例えば、起立者のスマートフォンに向けた転倒防止の注意喚起、空席への案内をすることや、車内混雑時の整理誘導によるスムーズな降車や空席管理のために着席者に対する降車場の提供要請を行うことが挙げられる。これはバスの利便性・安全性の向上につながる。

バスに乗車している際に乗客が受ける揺れの影響は、乗客が起立しているか、着席しているかによって違いがある。特にバスが停車・発車する際には、加速度が大きく変化するため乗客への揺れの影響が大きく、起立状態・着席状態

で受ける揺れの影響の違いが大きくなると考えられる。したがって、本論文ではバスの停車・発車時刻の前後 s 秒間の加速度を計測することで、乗客が起立、着席のどちらの状態にあるのかを推定する手法を提案する。また、加速度の計測は一般的に普及されているスマートフォンに搭載された加速度センサを用いて行う。

バスの停車・発車時の加速度を計測するためには、バスの停車・発車の時刻が必要となる。バス停車中の時刻は GPS ログを記録することで、同じ位置にいた時刻として得られる。したがって、スマートフォンに搭載された GPS 機能を用いて、停車・発車の時刻を得る。また、乗客のイヤホンで計測した加速度情報を併用することで、GPS の位置情報より得られた停車・発車時刻の補正を行い、より精度を高める。

2. 関連研究

スマートフォンを利用した人の状態、行動を認識するための研究は多い [1][2]。その中でもバスに関する研究において、乗客の携帯電話を利用した手法は多く用いられている。Zhou らは参加型センシングにより、乗客の携帯電話を用いたバス到着時間の予測方法を提案している [3]。携帯電話が接続する基地局の順序を用いて、バスの経路を推定し、位置情報からバス停までの到着時間を推定した。ま

¹ 大阪公立大学
Osaka Metropolitan University

た、携帯電話のマイクを用いて IC カードリーダーの音を検出することで、バスに乗車しているか否かを判定した。結果として、バス停までの到着時間の平均誤差は 80 秒となり、精度の高い推定が行えた。このように、多くの乗客がスマートフォンを所持する前提の研究は多数存在する。本研究も同様の前提とする。

また、加速度センサを用いて人間の行動を認識する手法は様々なところで使用されている。Mathie らは、腰に付けた 3 軸加速度センサを用いた行動分類システムを提案している [4]。まず行動を活動と静止に分類し、活動を歩行、転倒、姿勢の移行、その他として分類を行った。また、静止時の姿勢は座位、立位、横臥に分類した。結果として 97.7% の感度と、98.7% の特異度を達成した。また、Xia らはスマートフォンに搭載された加速度センサと GPS を用いた移動手段分類システムを提案している [5]。移動状態として静止、自転車、電動輸送の 3 つを用意し、静止は長期滞在と短期滞在に分類した。結果として 96.31% の分類正解率を達成した。また、Arif らスマートフォンに搭載された加速度センサを用いた身体活動の分類システムを提案している [6]。身体活動として、歩く、走る、階段を上る、降るの 4 パターンを用意し分類を行った。結果として 99% の分類精度を達成し、行動認識における加速度データの有用性を示している。これらのように、加速度データから高精度で状態認識が可能である反面、加速度にノイズが大きく入る環境では著しく精度が低下する可能性がある。本研究では、振動ノイズが非常に多いバス内での姿勢を推定するため、加速度データにノイズが大きく含まれる可能性が高く、精度を高めることは難しい。よって、ノイズの割合が誤差になる程度の大きな特徴をもつデータが現れる時刻を得ることで、乗車姿勢推定に有効なデータを選別する方針をとる。

また、樋口らはスマートフォンに搭載されたセンサを用いて鉄道乗車中の移動状態を検出する手法を提案する中で、鉄道の停車を判定する方法について検討している [7]。加速度センサのみで鉄道の停車を判定しようとした場合、車両速度が一定に達し惰行を行なっている区間が停車と誤判定されてしまう。これを回避するために、鉄道が惰行を行なっているとき磁気特微量の差が小さくなることを用いて停車確率を補正した。しかし、本研究で対象とするバスでは磁気量の変化によって停車を判定することは困難であるため、GPS ログを用いて停車区間を識別した。GPS と加速度センサはスマートフォンに標準搭載されていることが多く、これらを併用した研究も複数存在し [8][9]、現実的な想定である。

また、DTW(Dynamic Time Warping) はデータの解析方法として多くの研究で利用されている。内山らは DTW を用いて視野角の異なるカメラ映像から自車の位置推定を行うシステムについて提案している [10]。入力画像系列から部分系列を抽出し、データベース画像系列との拡張 DP

マッチングを行うことで、大規模なデータベースに対して計算範囲を限定したマッチングを行なった。結果として位置推定精度の向上が確認できた。このように DTW を適用するには特徴的な部分抽出が必要となるため、本研究では停車・発車の時刻を特定することで抽出している。

3. 問題設定

バスに乗客のうち、次に説明する事項を満たす乗客が乗っていることを想定する。乗客は起立しているか、着席しているかの 2 パターンのみに分けられるとする。乗客はスマートフォンをズボンのポケットにいているか、手に持っているかのどちらかであるとする。乗客は常に耳に三軸加速度を計測可能なイヤホン装着しているとする。

バスは信号、バス停などにより停車と発車を十分に含む。また、ずっと地上を走るとし、乗客のスマートフォンで GPS は常に働き、位置情報を取得可能とする。乗客は停車・発車時の揺れに影響を受ける。これを乗客の保持するスマートフォン、及びイヤホンの三軸加速度センサによって $f\text{Hz}$ で計測する。加速度センサで取得する時系列データ A の時刻 0 から n までのデータは $A = \{a_0, a_1, a_2, \dots, a_n\}$ とする。バスに乗車した瞬間の加速度は計測せず、起立もしくは着席の安定した状態をとってから計測を開始する。また、GPS により緯度経度で表される位置情報の時系列データを取得する。GPS の位置時系列データ P の時刻 0 から m までのデータは $P = \{(x_0, y_0), (x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ とする。GPS の計測についても起立もしくは着席の安定した状態をとってから計測を開始する。加速度時系列データの途中で起立着席の状態は変化しないとする。

本研究で対象とする問題の入力はバスの乗客が計測した加速度と位置の時系列データ、出力は起立もしくは着席のいずれかの状態である。その過程でバスの停発車時刻を精度よく推定する。

4. 提案手法

4.1 GPS によるバスの停車・発車時刻の推定

GPS を用いてバス移動中の位置情報を記録し、バスの位置 (x_t, y_t) からバスの移動速度 v_t を 1 秒毎に式 (1) で示す通り求める。

$$v_t = \sqrt{(x_{t+1} - x_t)^2 + (y_{t+1} - y_t)^2} \quad (1)$$

推定した移動速度のうち移動速度 v_t が 0m/s になっている時刻をバスがとまっていた時刻として推定する。図 1 に示すように、バスがとまっていた時刻のうち停車開始時刻を t_i 、発車開始時刻を t_{i+1} として、バスの停発車時刻の時系列データ $\{t_0, t_1, t_2, \dots, t_k\}$ を得る。

4.2 加速度データによるバスの停車・発車時刻の補正

GPS ではバスが停車する直前の低速の移動、及びバスが




図 1 停車開始時刻と発車開始時刻

発車した直後の低速の移動を捉えることができず、正確な停車・発車時刻を推定することは困難である。よって、加速度データを用いて停車・発車時刻を補正する。

まず、イヤホンの加速度センサを用いて、バス移動中の加速度を計測し、GPS から推定した停車開始時刻 $\{t_0, t_2, t_4, \dots, t_{2k}\}$ の後 s 秒間の加速度データ、発車開始時刻 $\{t_1, t_3, t_5, \dots, t_{2k+1}\}$ の前 s 秒間の加速度データを収集する。得られた加速度データのうち加速度の最大値が閾値 q を超えていた場合、加速度が最大となる時刻を停車・発車の推定時刻とする。超えていなかった場合は GPS から推定した停車・発車時刻をそのまま用いる。

4.3 加速度の抽出

スマートフォンの加速度センサを用いてバス移動中の加速度を計測し、 t_i の前後 s 秒間の加速度データを収集する。例えば、加速度時系列データ $A = \{a_0, a_1, a_2, \dots, a_n\}$ のうち停車開始時刻 t_i の加速度を a_{t_i} とすると、収集する停発車時の加速度データは、 $A_{t_i} = \{a_{t_i - fs}, \dots, a_{t_i}, \dots, a_{t_i + fs}\}$ となる。データの収集方式として、前後 s 秒間のデータを抽出する対象の時刻 t_i について、以下の三種類を考える。

- k 回分の停車データのみ抽出する場合： $H = \{t_0, t_2, t_4, \dots, t_{2(k-1)}\}$
- k 回分の発車データのみ抽出する場合： $H = \{t_1, t_3, t_5, \dots, t_{2(k-1)+1}\}$
- 停車データと発車データを区別せず k 回分のデータを抽出する場合： $H = \{t_0, t_1, t_2, \dots, t_k\}$

以降、停発車時の加速度データのことを単純にデータと記述する。また、連続する停車 1 データ、発車 1 データ 2 つを合わせて 1 区間とする。連続する 1 区間を 2 つ合わせたもの、3 つ合わせたものをそれぞれ、2 区間、3 区間と呼ぶ。また、停車 1 データ及び発車 1 データのことを 0.5 区間データと呼ぶ。

4.4 姿勢判定方法

本節では、4.3 節で説明した方法にて抽出された加速度時系列データに対して、三種類の姿勢判定方法を説明する。

4.4.1 DTW を用いた判定

まず、収集した加速度時系列データ間の距離を DTW を用いて計算する [11]。2 つのシーケンス間の DTW 距離とは、最適にそれらのシーケンス長を調整した後の距離の和である。停車・発車開始時刻 t_{i_v} , t_{i_w} の前後 s 秒間を抜き出した後のデータを $V = (v_1, v_2, \dots, v_l)$, $W = (w_1, w_2, \dots, w_m)$ とすると、DTW 距離 $D(V, W)$ は以下のように定義される。

$$D(V, W) = f(l, m)$$

$$g(u, j) = v_{\{u\}} - w_{\{j\}} + \min \begin{cases} g(u, j - 1) \\ g(u - 1, j) \\ g(u - 1, j - 1) \end{cases} \quad (2)$$

$$g(0, 0) = 0, g(u, 0) = f(0, j) = \infty$$

$$(u = 1, \dots, l; j = 1, \dots, m)$$

次に起立状態、着席状態の代表データをそれぞれ 1 つ決める。着席状態の代表データの決定方法として、1 つの着席状態のデータに対して、他のすべての着席データとの間の距離を DTW を用いて計算する。このときの距離が最も短いデータの組を短い順に n 番目まで求め、各データが出てきた回数をそれぞれ数える。出てきた回数が最も多かったデータを着席状態の代表データとする。これは各状態のデータに対して大きくはずれたデータを代表データとしないためである。起立状態の代表データも同様にして求める。着席の代表データ P_r 、起立の代表データ Q_r としたとき、すべての i に対して $D(P_r, A_{t_i})$ および $D(Q_r, A_{t_i})$ を計算する。 $D(P_r, A_{t_i}) < D(Q_r, A_{t_i})$ なら A_{t_i} は着席と判定し、そうでないなら A_{t_i} は起立と判定する。

起立時と着席時の加速度データを比較すると、起立時の加速度データには特徴的な大きい値が含まれることがある。よって、1 度でもその特徴的な値を検知できれば起立状態にある可能性が高い。したがって、各 1 区間を構成する停車・発車の 0.5 区間データに起立と判定されたものが 1 つでもあれば 1 区間の場合も起立と判定し、起立と判定されたものが 1 つもない場合は、着席と判定する。同様の判定方法で 2 区間、3 区間の場合も求める。

4.4.2 閾値による判定

加速度値に閾値 r 設定し、すべての $h_i \in H$ の前後 s 秒間の加速度値の中に閾値 r 以上の値が 1 個以上あった場合、起立状態と推定し、なかった場合、着席状態と推定する。

4.4.3 機械学習による判定

Random forest を用いて、着席・起立の推定を行う。特徴量を各データの平均値、最大値、標準偏差とする。Random Forest は学習データからランダムにデータを抽出し決定木を生成する操作を複数回繰り返し、多数の決定木を利用する学習アルゴリズムである。そのため、Random Forest はノイズに強く、交通状況によって生じる特異なデータによる学習への悪影響を防ぐことを期待して用いた。

5. 実験

まず、バス停発車時の加速度データを抽出するために、GPS によるバスの停発車時刻を推定する実験を行う。実際の停発車時刻に対する推定した停発車時刻のずれの秒数を評価する。

次に、起立及び着席状態を判定するため、抽出した加速度データに対して、各判定方法を用いた判定実験を行う。実際の姿勢に対する判定精度を F1 値を評価する。

5.1 実験環境

実験には Xperia X Performance SO-04H 2 台（加速度計測用）と、AirPods 3(加速度計測用), nexus9 1 台（GPS ログ計測用）を使用した。加速度計測については、スマートフォン1台はズボンのポケットに入れ、もう1台は手に持って行なった。GPS 計測には、タブレットを使用し、手に持ったカバンに入れて行った。また、実験を行うバスの路線として、図 2 に示めた南海バスの中百舌鳥駅前[南側]から堺市立総合医療センター北までのエリアを利用した。



図 2 バスの移動経路

5.2 停発車時刻推定の実験

5.2.1 GPS での停車・発車時刻の推定

実際に停車・発車した時刻を記録した値と GPS から推定した停車・発車した時刻とのずれは図 3 のようになった。棒グラフはずれの秒数に対するデータ数、折れ線グラフは全データに対するずれの秒数以内のデータの割合を表している。実際に停車・発車した時刻からずれの秒数の平均は 1.79 秒であり、全データのうち 92%が 3 秒以内、72%が 2 秒以内のずれであった。

5.2.2 停車・発車時刻の補正

まず GPS から推定したバスの停車時刻から 5 秒後まで




図 3 推定した停車・発車時刻と実際の時刻とのずれ

のデータ、5 秒前から発車時刻までを用いて、閾値 q を $0.10 \sim 0.40 m/s^2$ の間で $0.05 m/s^2$ 刻みで変化させて補正を行った場合の実際の停発車時刻とのずれは図 4 のようになった。図 4 の結果から閾値を $2.5 m/s^2$ とする。




図 4 閾値の変化に対する補正した停車・発車時刻と実際の時刻とのずれ

次に GPS から推定したバスの停発車時刻に対して、閾値 $2.5 m/s^2$ を用いて補正を行った。停車時刻推定については、抜き出す秒数を停車推定時刻から 2~7 秒後まで、1 秒刻みで変化させて推定した。また、発車時刻推定については、2~7 秒前から発車推定時刻まで 1 秒刻みで変化させて推定した。実際の停発車時刻とのずれは表 1 のようになった。

表 1 補正した停車・発車時刻と実際の時刻とのずれ

抜き出した秒数	ずれの秒数の平均
2 秒	1.33 秒
3 秒	1.31 秒
4 秒	1.31 秒
5 秒	1.31 秒
6 秒	1.31 秒
7 秒	1.32 秒

表 1 から抜き出す秒数を 3~6 秒間とした場合に GPS で推定した時刻に対して実際の時刻とのずれを 0.48 秒補正することができた。

5.3 起立着席推定の実験

推定した停発車時刻の前後 5 秒間の加速度データに対して、4.4.1 節で述べた DTW を用いた判定方法、4.4.2 節 停車・発車を区別しない場合の (1) 閾値による判定方法、(2) RandomForest による判定方法、4.4.3 節 停車・発車を区別する場合の (1) 閾値による判定方法、(2) RandomForest による判定方法を用いて、起立・着席の姿勢判定を行った。結果として、精度が最大となるデータ数の F1 値は図 5、図 6 のようになった。ポケットで計測した値、手で計測した値の両方で停車のみの加速度データを用いた RandomForest による判定が最も F1 値が高くなった。次に各手法の詳細について述べていく。




図 5 各判定方法に対する推定精度 (ポケットで計測した値)




図 6 各判定方法に対する推定精度 (手で計測した値)

5.3.1 DTW を用いた判定

加速度の停車開始前後 5 秒間もしくは発車開始前後 5 秒間を 0.5 区間と呼び、連続した二つの 0.5 区間のデータを合わせて 1 区間とする。

停車・発車の半区間の起立データ、着席データそれぞれに対して、DTW を用いて距離を求め、距離が最も短い 20 組をそれぞれ算出し、最良の代表データによる姿勢判定を行なった。

0.5 区間、1 区間、2 区間、3 区間に対して起立・着席の推定を行い、Precision, Recall, F1 値を計算した結果を表 2、表 3 に示す。ポケットで計測した値については、2 区間ごとに判定したとき最も高い判定精度が得られた。手で計測した値に対する推定精度については、2 区間において、

表 2 起立着席推定精度 (DTW, ポケット計測)

区間数	状態	Precision	Recall	F-measure
0.5 区間	着席	0.65	0.91	0.76
	起立	0.86	0.52	0.65
1 区間	着席	0.78	0.82	0.80
	起立	0.82	0.78	0.80
2 区間	着席	1.00	0.68	0.81
	起立	0.77	1.00	0.87
3 区間	着席	1.00	0.56	0.72
	起立	0.71	1.00	0.83

表 3 起立着席推定精度 (DTW, 手計測)

区間数	状態	Precision	Recall	F-measure
0.5 区間	着席	0.61	0.83	0.70
	起立	0.75	0.48	0.59
1 区間	着席	0.74	0.74	0.74
	起立	0.73	0.73	0.73
2 区間	着席	0.92	0.60	0.73
	起立	0.73	0.96	0.83
3 区間	着席	0.78	0.41	0.54
	起立	0.67	0.91	0.77

起立の精度は他の区間に比べて高くなったが、着席の精度の変化は小さかった。

5.3.2 停車・発車を区別しない場合の状態推定

(1) 閾値による判定

まず、ポケットで計測した加速度、手で計測した加速度の半区間における加速度の最大値の平均を表 4 に示す。ポケットで計測した値では、着席時に比べて起立時の加速度が大きいが、手で計測した値では起立時と着席時の加速度の違いが小さくなった。これは、人が揺れに逆らおうとして、揺れの影響が軽減されるためであると考えられる。

表 4 停発車時の加速度の最大値の平均

姿勢	着席	起立
ポケット	2.15m/s ²	5.80m/s ²
手	2.24m/s ²	3.14m/s ²

次に閾値 r を 1 から 5 まで 0.1 刻みで変化させて、1 区間毎のデータにおける起立・着席のデータに対する正解数を示したグラフを図 7、図 8 に示す。図 7 からポケットで計測した値の閾値は 3.6、図 8 から手で計測した値の閾値は 3.0 とする。

同様に、0.5 区間、2 区間、3 区間においても閾値を定めると 0.5 区間における閾値 r はポケット計測で 2.5、手計測で 2.4 となった。2 区間における閾値 r はポケット計測で 4.3、手計測で 3.5 となった。3 区間における閾値 r はポケット計測で 4.3、手計測で 3.5 となった。

得られた閾値を用いて起立・着席の推定を行った。Precision, Recall, F1 値を表 5、表 6 に示す。




図 7 ポケットで計測したデータ




図 8 手で計測したデータ

表 5 起立着席推定精度 (停発車混同, 閾値, ポケット計測)

区間数	状態	Precision	Recall	F-measure
0.5 区間	着席	0.65	0.76	0.70
	起立	0.75	0.65	0.69
1 区間	着席	0.73	0.79	0.76
	起立	0.79	0.73	0.76
2 区間	着席	0.84	0.92	0.88
	起立	0.92	0.85	0.88
3 区間	着席	0.86	0.86	0.86
	起立	0.88	0.88	0.88

表 6 起立着席推定精度 (停発車混同, 閾値, 手計測)

区間数	状態	Precision	Recall	F-measure
0.5 区間	着席	0.63	0.71	0.67
	起立	0.70	0.62	0.65
1 区間	着席	0.72	0.72	0.72
	起立	0.73	0.73	0.73
2 区間	着席	0.67	0.80	0.73
	起立	0.76	0.62	0.68
3 区間	着席	0.74	0.74	0.74
	起立	0.75	0.75	0.75

ポケットで計測した値については、DTW による判定と同様に 2 区間ごとに判定したとき、最も精度が高くなった。手で計測した値については、どの区間においても高い判定精度は得られなかった。また、ポケットの加速度データでは使用する区間が多くなるにつれて F1 値が増加傾向にあり、精度が高くなることが分かった。一方で、手の加速度データは区間による F1

値の大きな変化は見られなかった。

(2) RandomForest を用いた判定

停車・発車それぞれ半区間と、1 区間、2 区間、3 区間データに対して、10 交差検証にて起立・着席判定を行なった結果を表 7、表 8 に示す。ポケットで計測

表 7 起立着席推定精度 (停発車混同, RandomForest, ポケット計測)

区間数	状態	Precision	Recall	F-measure
0.5 区間	着席	0.64	0.73	0.68
	起立	0.71	0.61	0.65
1 区間	着席	0.67	0.83	0.74
	起立	0.79	0.60	0.68
2 区間	着席	0.71	0.83	0.77
	起立	0.81	0.68	0.74
3 区間	着席	0.74	0.83	0.78
	起立	0.78	0.72	0.76

表 8 起立着席推定精度 (停発車混同, RandomForest, 手計測)

区間数	状態	Precision	Recall	F-measure
0.5 区間	着席	0.66	0.62	0.64
	起立	0.66	0.69	0.67
1 区間	着席	0.65	0.60	0.63
	起立	0.64	0.69	0.67
2 区間	着席	0.65	0.68	0.67
	起立	0.68	0.65	0.67
3 区間	着席	0.64	0.64	0.64
	起立	0.65	0.65	0.65

した値、手で計測した値の両方において閾値による判定、DTW による判定に比べて精度が落ちることが分かった。また、他の 2 手法と同様にポケットで計測したデータでは多区間を用いることで精度が上がるが、手で計測したデータでは区間を増加させても精度に大きな変化がないことが分かった。

5.3.3 停車・発車を区別する場合の状態推定

(1) 閾値による判定

加速度の停車開始前後 5 秒間を停車データは発車開始前後 5 秒間を発車データと呼び、連続した i 個の停車データ及び、連続した i 個の発車データを i データとする。停車・発車を区別しない場合と同様に閾値 r を決定した。1 データにおけるポケットで計測した値に対する閾値は停車時が 2.5、発車時が 2.4、手で計測した値に対する閾値は停車時が 2.5、発車時が 2.2 となった。同様にして 2 データ、3 データに対して閾値を求めると、2 データにおけるポケットで計測した値に対する閾値は停車時が 3.1、発車時が 2.5、手で計測した値に対する閾値は停車時が 3.0、発車時が 2.7 となった。また、3 データにおけるポケットで計測した値に対する閾値は停車時が 3.4、発車時が 4.0、手で計

測した値に対する閾値は停車時が3.2, 発車時が3.2となった.

得られた閾値を用いて起立・着席の推定を行った. Precision, Recall, F1 値を表9, 表10に示す. 表9,

表9 起立着席推定精度 (停発車区別, 閾値, ポケット計測)

データ数	停発車	状態	Precision	Recall	F-measure
1 データ	停車	着席	0.73	0.79	0.76
		起立	0.79	0.73	0.76
		発車	0.59	0.67	0.63
2 データ	停車	着席	0.76	0.83	0.79
		起立	0.82	0.76	0.79
		発車	0.70	0.56	0.62
3 データ	停車	着席	0.80	0.91	0.85
		起立	0.90	0.79	0.84
		発車	0.63	0.86	0.73
		起立	0.81	0.54	0.69

表10 起立着席推定精度 (停発車区別, 閾値, 手計測)

データ数	停発車	状態	Precision	Recall	F-measure
1 データ	停車	着席	0.74	0.80	0.77
		起立	0.79	0.73	0.76
		発車	0.65	0.60	0.63
2 データ	停車	着席	0.72	0.75	0.73
		起立	0.75	0.72	0.73
		発車	0.57	0.54	0.55
3 データ	停車	着席	0.71	0.74	0.72
		起立	0.74	0.71	0.72
		発車	0.52	0.61	0.56
		起立	0.55	0.46	0.50

表10から発車時のデータに比べて停車時のデータの方が有用であるとわかった. また, 表5, 表6との比較から, 停車時のみのデータを用いた場合と停車・発車を区別せずに判定を行った場合では, データ数を増やした場合, 同程度の判定精度となった.

(2) RandomForest を用いた判定

停車・発車それぞれの1データ, 2データ, 3データに対して, 10 交差検証にて起立・着席判定を行なった結果を表11, 表12に示す. 表11, 表12から閾値による判定と同様に, 発車時のデータに比べて停車時のデータの方が有用であることがわかった. また, データ数を増加させることで, ポケットで計測した値では0.89, 手で計測した値では0.88と, 停車・発車を区別しない場合と比べて高いF値を達成できた.

5.3.4 加速度の計測データからランダムに抽出したデータに対する推定

停車・発車の特徴的な加速度変化を用いることの有用性を示すため, 計測したデータから無作為に10秒間(停車・発車時の加速度データ抽出と同じ秒数)抽出した値に対し

表11 起立着席推定精度 (停発車区別, RandomForest, ポケット計測)

データ数	停発車	状態	Precision	Recall	F-measure
1 データ	停車	着席	0.64	0.75	0.69
		起立	0.71	0.60	0.65
		発車	0.58	0.54	0.56
2 データ	停車	着席	0.75	0.78	0.77
		起立	0.79	0.76	0.78
		発車	0.87	0.87	0.87
3 データ	停車	着席	0.84	0.96	0.89
		起立	0.95	0.83	0.89
		発車	0.87	0.91	0.89
		起立	0.91	0.88	0.89

表12 起立着席推定精度 (停発車区別, RandomForest, 手計測)

データ数	停発車	状態	Precision	Recall	F-measure
1 データ	停車	着席	0.68	0.58	0.63
		起立	0.62	0.72	0.67
		発車	0.60	0.58	0.59
2 データ	停車	着席	0.85	0.96	0.90
		起立	0.96	0.85	0.90
		発車	0.68	0.71	0.70
3 データ	停車	着席	0.87	0.87	0.87
		起立	0.88	0.88	0.88
		発車	0.68	0.83	0.75
		起立	0.80	0.64	0.71

てDTWを用いた推定, 閾値による判定, RandomForestを用いた判定を行った.

(1) DTW による判定

停車・発車時の加速度データに対する判定と同様に1データ, 2データ, 3データに対して起立・着席の推定を行い, Precision, Recall, F1 値を計算した結果を表13, 表14に示す.

表13 起立着席推定精度 (ランダム抽出, DTW, ポケット計測)

データ数	状態	Precision	Recall	F-measure
1 データ	着席	0.53	0.91	0.67
	起立	0.67	0.17	0.28
2 データ	着席	0.56	0.82	0.67
	起立	0.67	0.36	0.47
3 データ	着席	0.58	0.71	0.64
	起立	0.63	0.48	0.54

表14 起立着席推定精度 (ランダム抽出, DTW, 手計測)

データ数	状態	Precision	Recall	F-measure
1 データ	着席	0.46	0.26	0.33
	起立	0.48	0.70	0.57
2 データ	着席	0.40	0.09	0.15
	起立	0.49	0.86	0.62
3 データ	着席	1.00	0.05	0.09
	起立	0.51	1.00	0.68

表13, 表14と表2, 表3との比較から, 停車・発車時のデータを抽出した場合の方が大幅に判定精度が上

がっていることがわかる。特に手で計測した値に関しては、無作為抽出したデータでは、ほとんどのデータを起立と判定しており、起立・着席の区別ができていない。

(2) 閾値による判定

停車・発車時の加速度データに対する判定と同様に閾値 r を決定した。1 データの場合、ポケットで計測した値の閾値は 2.0、手で計測した値の閾値は 2.0、2 データの場合、ポケットで計測した値の閾値は 3.0、手で計測した値の閾値は 2.9、3 データの場合、ポケットで計測した値の閾値は 4.1、手で計測した値の閾値は 4.0 となった。得られた閾値を用いて起立・着席の推定を行った。Precision, Recall, F1 値を表 15, 表 16 に示す。

表 15 起立着席推定精度 (ランダム抽出, 閾値, ポケット計測)

データ数	状態	Precision	Recall	F-measure
1 データ	着席	0.52	0.58	0.55
	起立	0.52	0.46	0.49
2 データ	着席	0.52	0.57	0.54
	起立	0.52	0.48	0.50
3 データ	着席	0.52	0.55	0.53
	起立	0.52	0.50	0.51

表 16 起立着席推定精度 (ランダム抽出, 閾値, 手計測)

データ数	状態	Precision	Recall	F-measure
1 データ	着席	0.58	0.58	0.58
	起立	0.58	0.58	0.58
2 データ	着席	0.55	0.52	0.53
	起立	0.54	0.57	0.55
3 データ	着席	0.53	0.45	0.49
	起立	0.52	0.59	0.55

表 15, 表 16 から、ポケットで計測した値、手で計測した値の両方で判定精度が約 50% となっており、起立・着席を区別できていないことがわかる。また、データ数を増加させても判定精度の向上は見られなかった。

(3) RandomForest を用いた判定

停車・発車時の加速度データに対する判定と同様に 1 データ, 2 データ, 3 データに対して起立・着席判定を行なった結果を表 17, 表 18 に示す。表 17 から、ポ

表 17 起立着席推定精度 (ランダム抽出, RandomForest, ポケット計測)

データ数	状態	Precision	Recall	F-measure
1 データ	着席	0.74	0.71	0.72
	起立	0.72	0.75	0.74
2 データ	着席	0.80	0.67	0.73
	起立	0.71	0.83	0.77
3 データ	着席	0.80	0.67	0.73
	起立	0.71	0.83	0.77

表 18 起立着席推定精度 (ランダム抽出, RandomForest, 手計測)

データ数	状態	Precision	Recall	F-measure
1 データ	着席	0.55	0.46	0.50
	起立	0.54	0.63	0.58
2 データ	着席	0.61	0.46	0.52
	起立	0.57	0.71	0.63
3 データ	着席	0.55	0.50	0.52
	起立	0.54	0.58	0.56

ケットで計測した値に関しては、他の判定方法に比べて判定精度が高くなっているが、停車・発車時の加速度を用いた場合と比べると判定精度は低い。また、表 18 から、手で計測した値に関しては、起立と着席を区別できていないことがわかる。

以上の 3 つの判定方法の結果から、停車・発車時の加速度を抽出した場合と無作為に抽出した場合を比べて、どの判定方法に対しても、停車・発車時の加速度を抽出した場合の方が判定精度が高く、停車・発車時の加速度データを用いることが有用であるとわかった。

6. まとめ

本稿では、まず GPS を用いてバスの位置情報を計測し、停車・発車の推定を行った。また、加速度センサによって、バスの停車・発車時に受ける乗客の揺れを計測することで、停車・発車時刻の補正を行った。補正により実際の停車・発車の時刻との誤差を約 0.5 秒縮めることが出来た。次にバスの停車・発車時の加速度データによって、バスの乗客の起立・着席の状態を推定した。ポケットで計測した値に比べて、手で計測した値は、起立と着席での違いが小さいことがわかった。判定方法別にみると、停車・発車を区別しない場合、閾値を用いた判定では、ポケットで計測した値において約 88% の判定精度を達成できたが、手で計測した値においては高い精度は得られなかった。停車・発車を区別する場合、Random Forest による判定で停車のみのデータを用いることで、ポケットで計測した値、手で計測した値の両方で約 89% の判定精度を達成できた。

参考文献

- [1] Muhammad Arif, Mohsin Bilal, Ahmed Kattan, and S.Iqbal Ahamed: "Better Physical Activity Classification using Smartphone Acceleration Sensor", *Journal of Medical Systems* 38, Article number: 95 (2014).
- [2] Kangjae Lee, and Mei-Po Kwan: "Physical activity classification in free-living conditions using smartphone accelerometer data and exploration of predicted results," *Computers, Environment and Urban Systems*, pp. 124–131 (2018).
- [3] Pengfei Zhou, Yuanqing Zheng, and Mo Li, "How Long to Wait?: Predicting Bus Arrival Time with Mobile Phone based Participatory Sensing", *The 10th International Conference on Mobile Systems, Applications, and Services*, pp.379–392 (2012).
- [4] M.J.Mathie, B.G.Celler, N.H.Lovell,

- A.C.F.Coster, "Classification of basic daily movements using a triaxial accelerometer" *Medical and Biological Engineering and Computing*, pp. 679-687 (2004).
- [5] Hao Xia, Yanyou Qiao, Jun Jian, Yuanfei Chang, "Using Smart Phone Sensors to Detect Transportation Modes" *Sensors*, pp. 20843-20865 (2014).
- [6] Muhammad Arif, Mohsin Bilal, Ahmed Kattan, S labal Ahamed, "Better physical activity classification using smartphone acceleration sensor" *Mathematics, Statistics and Computer Science, Faculty Research and Publications*, (2019).
- [7] 樋口雄大, 山口弘純, 東野輝夫, "スマートフォン内蔵センサを用いた鉄道乗車コンテキストの推定" 研究報告モバイルコンピューティングとパーベイシブシステム (MBL), pp.1-8 (2015).
- [8] Tao Feng, and Harry J.P.Timmermans: "Transportation mode recognition using GPS and accelerometer data," *Transportation Research Part C: Emerging Technologies*, pp. 118-130 (2013).
- [9] Bryan D. Martin, Vittorio Addona, Julian Wolfson, Gediminas Adomavicius and Yingling Fan: "Methods for Real-Time Prediction of the Mode of Travel Using Smartphone-Based GPS and Accelerometer Data," *Sensors*, 17, issue 9, p. 2058 (2017).
- [10] 内山寛之, 出口大輔, 高橋友和, 井手一郎, 村瀬洋, "拡張 DP マッチングを用いた視野角の異なるカメラ映像間の時空間対応付けによる自転車位置推定" 電子情報通信学会論文誌, Vol. J93 - D No. 12 (2010).
- [11] 櫻井 保志, Faloutsos Christos, and 山室 雅司: "ダイナミックタイムワーピング距離に基づくストリーム処理," 電子情報通信学会論文誌. D, 情報・システム, 92(3), pp. 338-350 (2009).