

推薦論文

スマートフォンの加速度・磁気センサを併用した 鉄道車両の移動状態推定

樋口 雄大^{1,a)} 山口 弘純¹ 東野 輝夫¹

受付日 2015年8月4日, 採録日 2015年12月7日

概要: 本論文では, スマートフォン等のモバイル機器に内蔵された加速度センサと磁気センサとを組み合わせることで, 端末保持者が乗車する電車の移動状態を高精度に検出する手法を提案する. 提案方式では, 磁気センサを用いて鉄道車両の電気系統の動作状況を検出するとともに, 走行状態に応じた特徴的な加速度特性をもとに判定結果を補正することで, 揺れの少ない車両でも高精度な移動状態判定を実現している. 京阪神エリアの複数の鉄道路線においてフィールド実験を実施し, 電車の移動状態の検出精度を, 従来方式と比較して大幅に改善できることを確認した.

キーワード: 停車検出, モバイルセンシング, データ融合

Train Motion Detection Using Accelerometers and Magnetometers in Smartphones

TAKAMASA HIGUCHI^{1,a)} HIROZUMI YAMAGUCHI¹ TERUO HIGASHINO¹

Received: August 4, 2015, Accepted: December 7, 2015

Abstract: In this paper we propose a mobile sensing system to monitor stop-and-go patterns of trains. Our system employs embedded accelerometers and magnetometers in off-the-shelf mobile devices to detect vibration of vehicles and activity of electric motors, respectively. Analyzing the sensor measurements with a light-weight machine learning algorithm, it enables fine-grained, continuous monitoring of trains' motion on the spot. Through field experiments using multiple models of Android smartphones and smart watches, we show that the system can achieve much higher performance than existing solutions.

Keywords: train stop detection, mobile sensing, data fusion

1. はじめに

第5回東京都市圏パーソントリップ調査 [1] によれば, 東京都区部における住民の移動手段の 48% を鉄道への乗車が占めており, また通勤時の鉄道利用率は 79% にものぼる. 慢性的な交通渋滞が社会問題となっている都市部においては, このように, 渋滞の影響を受けにくい鉄道網が, 人々の移動を支える交通インフラの要となっている. スマートフォン等のモバイル端末を通じて, こうした鉄道旅客に対して, より高度な移動支援を行うことができれば, 都市全

体で, 人やモノの移動の効率化が期待できる.

スマートフォンをはじめとするモバイル端末やウェアラブル端末に多様なセンサが搭載されるようになり, ユーザの行動や周囲の状況を端末上できめ細かく認識し, コンテキストに応じた適切なサービスを提供することが可能になりつつある. とりわけ鉄道旅客への移動支援に着目した場合, ユーザが乗車する電車の移動状態は, 高度な状況認識の基礎となる汎用性の高いコンテキスト情報である. 走行・停車の二値の移動状態の時間的な遷移を正確にとらえる要素技術を確立することで, 以下のような, 多様な移動

¹ 大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology,
Osaka University, Suita, Osaka 565-0871, Japan

a) t-higuti@ist.osaka-u.ac.jp

本論文の内容は 2015 年 5 月の MBL 研究会第 75 回研究発表会にて報告され, 同研究会主査により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である.

支援サービスを実現することができる。

- **インフラに依存しない省電力なモバイル端末測位：**GPS や Wi-Fi 測位システム [2], [3], [4], あるいはユーザ自身の入力によって、スマートフォンを持つ乗客の位置情報がある時点において取得できれば、その後は、駅での停車回数を検出することで、スマートフォンの位置を継続的にトラッキングすることができる。これにより、ユーザは、測位インフラへのアクセスが難しい地下鉄区間でもナビゲーション等の位置情報サービスの利用が可能となる [5]。また、加速度センサ等の省電力な内蔵センサを用いて電車の移動状態を検出することで、GPS による連続測位を行う場合と比較して、端末のバッテリー消費を大幅に軽減できる利点もある。
- **遅延状況に基づく柔軟なナビゲーション：**移動状態のトラッキングによりモバイル端末上で省電力に推定された位置情報を、一部の乗客が携帯電話網等を介してクラウドサーバへアップロードすれば、都市全体の鉄道の運行状況をリアルタイムに把握する参加型の公共交通モニタリングシステムが実現できる。こうした即時性の高い遅延情報を考慮して乗換経路を算出することで、乗客の駅での待ち時間を最小化する、利便性の高いナビゲーションサービスが実現できる [6]。また、詳細な運行状況の履歴をデータベースとして蓄積することで、各路線の将来の遅延を予測することも可能になると考えられる。
- **災害時の効率的な群集誘導：**自然災害や設備の故障、事故等によって鉄道の運行に大幅な遅れが発生した場合には、駅に多くの乗客が殺到し、群集事故等の二次災害の危険が高まる。スマートフォンを用いた参加型運行状況モニタリングの仕組みを用いてこうした大幅な遅延や運行の停止を早期に検出することができれば、鉄道会社による公式発表に先駆けて、乗客に対して運行が再開するまで自宅や職場で待機するように呼びかけたり、混雑を避けた代替経路を提示したりするといった効率的な群集誘導を行うことが可能となる。

電車の停車タイミングを検出する技術としては、スマートフォンに内蔵された加速度センサを利用するアプローチが主流である [5], [6]。これらの方式では、走行中に継続的に発生する車両の揺れを加速度センサにより検出することで、ユーザが乗車する電車の移動状態を判別している。しかしながら、近年の車両・軌道技術の発展により、走行にともなう車両の振動は大きく軽減されつつあり、3.4 節で示すとおり、特に新しい鉄道インフラを導入する都市部の路線においては、これらの既存技術によって十分な精度を得ることが難しくなっている。

本論文では、スマートフォン端末に内蔵された加速度センサと磁気センサとを効果的に組み合わせることで、端末保持者が乗車する電車の移動状態を高精度に検出する手法

を提案する。電車の加速時および減速時には、モータやインバータといった車両の電気系統が発する磁気ノイズによって、車内に特徴的な磁場が形成される。提案方式では、磁気センサを用いて走行中の磁場の特徴をとらえ、各時刻において、電車が停車している確率を算出する。また、車両の走行状態に応じた加速度センサの計測値の長期的な変動をもとに、前述の停車確率を補正し、電車の惰行状態（モータへのエネルギー供給を停止し、惰性で走行する状態）が停車状態として誤検出されることを回避する。さらに、車両の停車・発車の瞬間に観測される特徴的な加速度シグネチャを活用して移動状態が切り替わるタイミングを正確に推定することにより、鉄道旅客の高精度なトラッキングを実現している。京阪神エリアの複数の鉄道路線におけるフィールド実験を通じて、電車が駅で停車している期間を 81%の精度で推定できることを確認している。

2. 関連研究

ユーザの状況に応じた利便性の高いモバイルアプリケーションの実現に向けて、モバイル・ウェアラブル機器の内蔵センサを用いた行動認識技術が活発に研究されている [7], [8], [9]。とりわけ、移動モードの推定についてはこれまでに様々な方式が提案されており [10], [11]、ユーザの移動の振舞いをモニタリングするための要素技術という点で、本研究との関連性も高い。文献 [12] では、スマートフォンに内蔵された加速度センサを用いて、端末保持者の移動モードを静止、歩行、バス、電車、地下鉄、トラムの 6 種類に分類する手法を提案している。著者らは、実センサデータの分析を通じて、水平方向の加速度成分が乗り物での移動を検出するための有効な計測量であることを発見し、3 軸加速度センサの計測値を鉛直方向成分と水平方向成分に高い精度で分離するためのアルゴリズムを設計している。文献 [13] では、近年、市販のスマートフォン端末に広く搭載されるようになりつつある気圧センサを利用することで、端末保持方法等に依存しない移動モード推定方式を開発している。これらの先行研究は、ユーザの移動手段を推定の対象としており、鉄道旅客の移動状態の高精度なトラッキングを目指す本研究とは、目的や用途が異なる。なお、こうした移動モード推定技術を用いて、ユーザの鉄道への乗車を検知することで、提案システムによる移動状態のトラッキングを自動的に開始することも可能である。

スマートフォンによるセンシングを通じて、公共交通機関の運行状況をリアルタイムに把握する取り組みも注目を集めている。文献 [14] では、バスの乗客のスマートフォン端末から匿名の現在位置情報を提供してもらうことで、バスの到着時刻を予測するシステムを開発している。消費電力の大きい GPS による測位の代わりに、携帯電話基地局からの受信電波強度の履歴を用いて端末保持者が乗車するバスのルートおよび現在位置を推定することで、

センシングにともなうバッテリー消費の軽減を図っている。EasyTracker [15] は、バスの運転手が持つスマートフォンから、GPSにより計測した位置情報を収集することで、同様のシステムを実現している。これらのシステムを電車の乗客の位置・移動状態のトラッキングへ応用することも原理的には可能ではあるものの、都市部の鉄道網においては、地下鉄路線等、GPS衛星や携帯電話基地局からの信号へ常時アクセスできない環境も多い。環境によらず、継続的なナビゲーションやセンシングを実現するためには、こうした測位インフラに依存しないアプローチが望ましいといえる。これに対し、文献 [5], [6] では、スマートフォンに内蔵された加速度センサを用いて走行中の車両の揺れをとらえることにより、端末単独で、鉄道の移動状態のトラッキングを可能にしている。しかしながら、3.4節で示すとおり、従来の加速度ベースの方式は、車両の構造や軌道の直線性等の条件に依存して大きな誤差が発生するという問題がある。文献 [16] では、電車の移動状態のトラッキングにおける磁気センサの有効性が議論されている。著者らは、電車が駅を発車してから30秒以内に磁束密度のピークが現れるという仮定のもと、磁束密度の正のピーク値を基準として、その直前に観測された負のピークを電車の発車時刻と推定する方式を提案している。しかしながら、同文献では、上記の仮定が成り立たない場合もあることが報告されており、4.2節で示す我々の実験データにおいても、磁束密度と電車の移動状態との間に直接的な関連性は確認できない。

これに対し、本論文では、電車の移動状態に連動したロバストな磁気特徴量を定義するとともに、加速度センサの計測値から抽出した特徴量との組合せにより停車検出の精度を効果的に高めるデータ融合アルゴリズムを設計することで、これらの既存方式の課題を解決し、移動状態の高精度なトラッキングを実現している。また、Androidスマートフォンを用いたフィールド実験により、実環境における提案方式の有用性も確認している。

3. 既存方式の性能分析

既存の停車検出方式の性能特性を調べるため、大阪市営地下鉄の9路線においてスマートフォンを用いた測定実験を行った。本章では、既存方式の概要と実験の詳細、性能評価の指標、ならびに分析の結果について述べる。

3.1 既存方式の概要

SubwayPS [5] では、線形加速度の大きさ (magnitude) に対して一定の閾値を設定することで、電車の移動状態を判定している。まず、3軸加速度センサの計測値から重力成分をフィルタリングし、線形加速度 (a_x, a_y, a_z) を得る。このもとで、2秒幅のウィンドウ内における線形加速度の大きさ $a_l = \sqrt{a_x^2 + a_y^2 + a_z^2}$ の平均値があらかじめ定めた閾値 th_{acc} を超える場合は走行中、そうでない場合は停車

中と判定する。このとき、加速度特徴量 a_l が、あらかじめ定めた緩衝期間にわたってつねに th_{acc} を上回る (下回る) 場合のみ、移動状態の推定結果を変化させることで、ユーザの体の動き等に起因するノイズの影響を軽減させている。

Thiagarajan ら [6] は、確率的なアプローチによって電車の移動状態を判定する手法を提案している。この方式では、重力成分のフィルタリングは行わず、3軸加速度センサの計測値の magnitude を1.2秒幅のウィンドウで平滑化したものを特徴量として用いる。これにより得られた加速度特徴量 a をもとに、次式により、電車が走行している確率を求める。

$$p(mov|a) \propto \frac{p(a|mov)}{p(a|mov) + p(a|stop)}. \quad (1)$$

ここで、 $p(a|mov)$ および $p(a|stop)$ は、それぞれ、電車が走行/停車しているときの加速度特徴量 a の確率分布であり、訓練データをもとに構築する。以上により加速度サンプルごとに算出された走行確率を、さらに30秒幅の平均値ウィンドウで平滑化する。このもとで、平滑化後の走行確率の正負のピークがそれぞれ1つの走行期間、停車期間に対応していると想定し、互いに連続するピークの間で、移動状態が切り替わったタイミングを探索する。

3.2 予備実験

既存の停車検出方式の性能を検証するため、大阪市営地下鉄において、Androidスマートフォン (Galaxy Nexus) を用いた予備実験を行った。大阪市営地下鉄は9路線から構成され、そのうち1路線 (南港ポートタウン線) はモノレールにより運行されている。本実験にあたっては、Android OS上で動作する計測アプリケーションを実装し、乗車中の加速度センサおよび磁気センサの計測値を記録した。各被験者は、計測アプリケーションが動作する2台のスマートフォン端末を、それぞれ手持ちおよびズボンのポケットで保持する。また、これらの端末とは別に、専用のアプリケーションが動作するスマートフォン端末を把持し、画面上のボタンをタップすることで、電車が発車・停車したタイミングの正解データを記録する。以上の実験を通じて、120回以上の停車を含むデータセットを構築した。

3.3 性能指標

本論文では、システムが1秒ごとに電車の移動状態を判定すると想定し、各時刻における停車検出の precision (適合率), recall (再現率), および f-measure を性能指標とする。ここで、実際の状態が停車であり、システムも停車と判定した秒数を *True Positive (TP)*, 実際には走行中であるにもかかわらず停車と判定された秒数を *False Positive (FP)*, 実際には停車中であるにもかかわらず走行と判定された秒数を *False Negative (FN)* とする。このもとで、




図 1 SubwayPS による停車検出性能
Fig. 1 Performance of SubwayPS.




図 2 Thiagarajan らの方式による停車検出性能
Fig. 2 Performance of the system proposed by Thiagarajan et al.

precision を $TP/(TP + FP)$, recall を $TP/(TP + FN)$, f-measure を $(2 \times precision \cdot recall)/(precision + recall)$ で定義する.

3.4 既存方式の性能分析

図 1 は、(a) 南港ポートタウン線および (b) 御堂筋線への乗車中に観測された線形加速度の大きさの時間変化 (上図) と、電車の移動状態の時間遷移、ならびに加速度の閾値 th_{acc} を 0.3~0.5 の間で変化させたときの SubwayPS による移動状態の判定結果 (下図) を示したものである。なお、同図では停車状態を High レベル、走行状態を Low レベルで表しており、重力成分のフィルタリングには Android OS の Linear Accelerometer API を利用した。乗車 (a) においては、電車の走行中に比較的大きな揺れが継続的に発生したことから、走行中と停車中とで線形加速度の大きさに明確な違いが表れている。このケースでは、移動状態判定の閾値 th_{acc} を 0.3 に設定することで、電車が駅で停車している時間を正確に検出することができている。一方、乗車 (b) では、走行中と停車中との間で加速度特徴量の差が小さく、 th_{acc} の値によらず移動状態の判定結果に大きな誤差が生じている。特に、 th_{acc} を乗車 (a) における最適パラメータである 0.3 に設定した場合には、乗車中の全区間にわたって走行中と判定されている。ここで、閾値 th_{acc} を $0.05 \text{ m/s}^2 \sim 0.60 \text{ m/s}^2$ の間で変化させ、予備実験で収集したすべての加速度データに対して SubwayPS の停車検出アルゴリズムを適用した場合の停車検出性能を図 1 (c) に示す。閾値を高く設定することで停車の検出率 (recall) を高

めることはできるものの、それに応じて誤検出の発生頻度も増加し、precision が低下するため、f-measure 精度は最大でも 43%にとどまっている。

次に、同じ乗車区間のセンサデータに対して Thiagarajan らの停車検出アルゴリズム [6] を適用した結果を図 2 に示す。縦方向に並んだ 3 つのプロットは、それぞれ、加速度特徴量 a の時間変化、加速度モデルに基づく走行確率 (平滑化後)、および電車の移動状態の正解データと推定結果を表す。なお、本実験においては、予備実験で収集したデータセットの中から、それぞれの乗車に対応するデータを 1 つずつ選択してテストデータとし、残りのデータを加速度モデルを構築するための訓練データとする leave-one-out 方式の交差検証を行った。走行確率に着目すると、それぞれの走行・停車期間において、おおむね正負のピーク値が表れているものの、走行中と停車中の加速度特徴量の差の小ささに起因して、乗車 (b) においては走行中に停車と誤判定されるケースが頻繁に発生している。また、移動状態が切り替わるタイミングを正確に判定することは難しく、移動状態の境界付近で連続的な誤差が生じている。

4. 提案方式

4.1 概要

提案システムの概要を図 3 に示す。電車が加速する際には、車両に搭載されたモータやインバータの動作によって、車両全体で大きな磁気ノイズが観測される。また、近年の鉄道システムの多くは、モータを発電機として利用して車輪の回転エネルギーを電力へと変換する回生ブレーキ

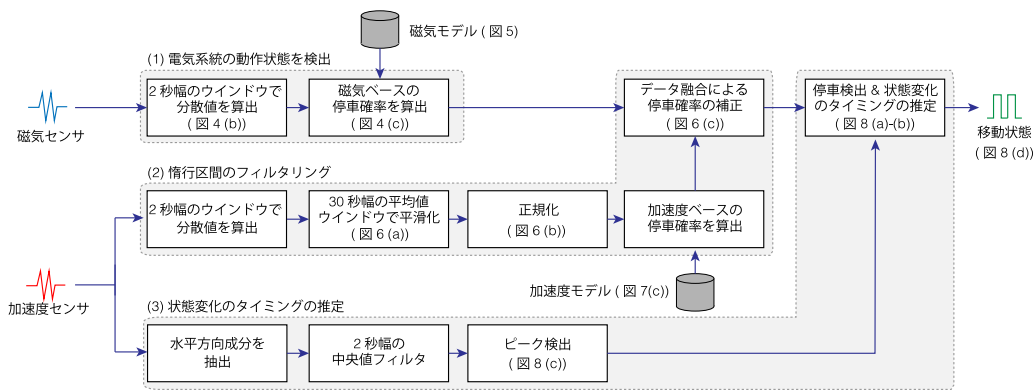


図 3 提案システムの概要
Fig. 3 System overview.

システムを導入しているため、減速時にも、加速時と同様の磁気ノイズが生じる。提案方式では、スマートフォン端末に内蔵された磁気センサを用いてこうした車両の電気系統が発する磁波をとらえることで、各時刻において、ユーザが乗車中の電車が停車している確率（停車確率）を算出する（図 3 内の (1)）。一方、電車の走行時には、一定の速度に達すると、モータへのエネルギー供給を停止し、惰行を行うのが一般的である。電車が走行する軌道上では、線路周辺の金属や架線等によって複雑な磁場が形成されるため、電車が走行している限り、車両内では停車時とは大きく異なる磁気特徴量が観測されるものの、その差は、加減速時と比べると小さくなる。こうした惰行区間が停車と誤判定されることを回避するため、提案方式では、加速度センサの計測値から抽出した車両の揺れの特徴量を用いて前述の停車確率を補正する（同図 (2)）。最後に、補正後の停車確率と、電車の停車・発車の瞬間に観測される典型的な加速度シグネチャをもとに停車の検出、ならびに隣接する走行期間との境界の推定を行う（同図 (3)）。

4.2 車両内の磁場に基づく電気系統の動作状態の検出

提案方式ではまず、磁気センサの計測値をもとに、ユーザが乗車する車両の 1 秒ごとの停車確率を算出する。図 1 (b) および図 2 (b) と同一の乗車区間で観測された 3 軸磁気センサの計測値の大きさ $\sqrt{m_x^2 + m_y^2 + m_z^2}$ の時間遷移を図 4 (a) に示す。ここで、 m_x , m_y , m_z は、それぞれ、端末のローカル座標系における x 軸, y 軸, および z 軸方向の磁束密度 [μT] である。時間の経過にともなって磁束密度は大きく変動しているものの、移動状態との明確な関連性は確認できない。一方、図 4 (b) は、2 秒幅のウィンドウ内における磁束密度の大きさの分散をプロットしたものである。走行中は大きな分散値が頻繁に観測されているのに対し、停車時にはつねに 0 に近い値で推移しており、同図 (a) とは対照的に、車両の移動状態に応じて特徴量に大きな差が表れていることが分かる。ここで、走行中および停車中の磁束密度の分散 m の累積確率分布を図 5 に示す。




図 4 磁気特徴量に基づく停車確率
Fig. 4 Magnetism-based stop probability.

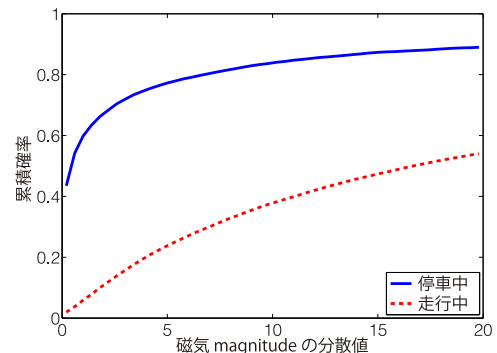


図 5 磁気特徴量 m の累積確率分布
Fig. 5 Cumulative distribution of magnetism-based feature.

停車中には 80% に近い割合で磁気特徴量が 5.0 未満となっているのに対し、走行中には、特徴量が広い範囲に分布しており、前述の分散値 m が電車の移動状態を判別するための有効な特徴量であると結論づけられる。

磁束密度の分散値 m が得られたとき、その時刻に電車が停車している確率は、図 5 の経験的な特徴量分布をもとに、次式により算出することができる。

$$p(\text{stop}|m) \stackrel{\text{def}}{=} \frac{p(m|\text{stop})}{p(m|\text{stop}) + p(m|\text{mov})} \tag{2}$$

式 (2) により算出した磁気ベースの停車確率の時間遷移を図 4 (c) に示す。停車中には、停車確率が 1.0 に近い値で推移しているのに対し、走行中には、相対的に低い確率値

となっている．一方で，惰行時には，停車確率が一時的に高くなるケースが見られることから，次節で述べるアルゴリズムによって，加速度特徴量をもとに停車確率を補正することで，停車の誤検出を回避する．

4.3 加速度センシングによる惰行区間のフィルタリング

走行中の振動の特性は車両の構造や軌道の直線性等に依存して大きく異なるものの，一般に，走行中には，加速度計測値の分散が停車中と比べて高くなる傾向がある．提案方式では，加速度センサの計測値の長期的な変動をもとに，惰行に起因する走行中の停車確率の上昇を抑制する．

予備実験で収集したすべての加速度データについて，2秒幅のウィンドウごとに加速度の大きさの分散を算出し，その累積確率分布を求めた結果を図7(a)に示す．電車の移動状態を問わず，ほとんどのケースで分散値は1.0未満となっており，電車の揺れに起因する加速度の変化の多くはこの範囲に集中していると考えられる．そこで，提案方式では，1.0以上の分散値を，ユーザの体の動き等に起因するノイズと見なしてフィルタリングする．

また，フィルタリング後の分散値に対して，30秒幅の平均値フィルタを適用することで，車両内でのユーザの体の動きに起因する一時的な加速度ノイズの影響をさらに軽減させる．平均値フィルタによる平滑化後の加速度の分散値の時間遷移を図6(a)に示す．走行期間および停車期間に，




図6 惰行区間のフィルタリング
Fig. 6 Fusion of acceleration-based feature.




図7 加速度特徴量の累積確率分布：(a) 加速度 magnitude の分散，(b) 平滑化後，(c) 正規化後

Fig. 7 Cumulative distributions of acceleration-based features.

平滑化後の分散値がそれぞれ正負のピークをとる傾向はあるものの，ピーク値そのものは，同一路線に乗車する間にも大きく変化している．このため，平滑化後の分散値を直接，移動状態推定のための特徴量として利用する方法では十分な判定性能が得られない．

これに対し，提案方式では，Algorithm 1 に示すアルゴリズムにより，直近のピーク値を基準として平滑化後の分散値を0~1の値に正規化することで，こうしたピーク値の変動が移動状態の判定性能に与える影響を軽減させる．ここで，図6(a)の分散値に対して正規化アルゴリズムを適用した結果を同図(b)に示す．正規化の結果，走行中には多くのケースで加速度特徴量 (\bar{a} と表す) が0.5~1.0程度の高い水準で推移しており，車両や走行区間等に依存した揺れ方の違いが効果的に吸収されていることが分かる．ここで，正規化を行う前後の加速度特徴量の累積確率分布を，それぞれ図7(b)および図7(c)に示す．正規化後には，停車時と走行時における特徴量の分布の差がより大きくなっており，移動判定のための特徴量としての有用性が向上している．

磁気特徴量 m と加速度特徴量 \bar{a} が互いに確率的に独立であると仮定し，ナイーブベイズモデル [17] を適用すると，これらの2つの特徴量から導出される停車確率は

Algorithm 1 加速度特徴量の正規化

```

1: Initialize  $max\_var$  and  $min\_var$  by pre-defined parameters
2: for each smoothed acceleration sample  $a$  do
3:   find peaks in smoothed acceleration variance
4:   if positive peak is detected then
5:      $max\_var \leftarrow$  peak value
6:   end if
7:   if negative peak is detected then
8:      $min\_var \leftarrow$  peak value
9:   end if
10:   $\bar{a} \leftarrow \min(\max\{0, (a - min\_var) / (max\_var - min\_var)\}, 1)$ 
11: end for
    
```





図 8 状態境界の推定

Fig. 8 Estimating state boundaries.

$$p(stop|m, \bar{a}) \stackrel{\text{def}}{=} \frac{p(m|stop)p(\bar{a}|stop)}{p(m|stop)p(a|stop) + p(m|mov)p(\bar{a}|mov)} \quad (3)$$

で与えられる．提案方式では，このモデルを用いて，前節の式 (2) で算出した停車確率を次のように更新する．

$$p(stop) \stackrel{\text{def}}{=} \min(p(stop|m), p(stop|m, \bar{a})). \quad (4)$$

車両の構造や軌道の形状によっては，走行中であるにもかかわらず，車両の揺れがきわめて小さく，加速度特徴量が低い値で推移する場合がある．こうしたケースでは，本来は抑制すべき走行中の停車確率が式 (3) による更新でむしろ増大し，誤検出の増加の原因となる可能性がある．式 (4) のように，磁気特徴量に基づく停車確率を $p(stop)$ の上限とすることで，こうした誤検出の発生を回避している．

4.4 停車の検出と状態境界の推定

各時刻における停車確率 $p(stop)$ を 30 秒幅の平均値ウィンドウで平滑化すると，図 8(a) のように，それぞれの停車期間内に正のピークが現れる．提案方式では，各ピークが 1 回の停車期間に対応すると想定し，隣接する走行期間との境界を推定する．

ここで，図 8(a) に示した停車確率の時間遷移において，各時刻を中心とする 40 秒幅のウィンドウを考え，その前半と後半の停車確率の平均値の差を算出した結果を同図 (b) に示す．この結果から，停車区間の終点および始点付近で，停車確率の変化量がそれぞれ正負のピークをとっていることが確認できる．

また，予備実験で収集したデータセットを詳細に分析した結果，電車の停車・発車の瞬間には，水平方向の加速度成分にピークが現れることが分かった．図 6(c) は，加速度センサの計測値に対して文献 [12] のアルゴリズムを適用することで重力ベクトルを算出し，これと直交する水平方向の加速度成分の大きさをプロットしたものである．ほぼすべての停車期間の境界において，図内のマーカーで示した水平方向加速度のピークが検出されている．

そこで，停車期間の始点（終点）の探索においては，まず，停車確率の変化量が負（正）のピーク値をとる時刻を

境界の初期解とする．続いて，初期解を中心とする前後 15 秒間のウィンドウ内に含まれる水平方向加速度のピークをすべて求め，状態境界の候補とする．最後に，これらのピーク時刻の中で，停車確率の変化量が最大となるような時刻を求め，それを状態境界の推定値とする．なお，ウィンドウ内に水平方向加速度のピーク値が 1 つも検出されない場合には，前述の初期解を最終的な推定値とする．

以上の手順により推定された移動状態の推定結果を図 8(d) に示す．3.4 節で示した加速度ベースの停車検出システムとは対照的に，ユーザが乗車する電車の移動状態を秒単位の粒度で正確に判別できていることが分かる．

一般に，ウィンドウサイズを大きくして特徴量の平滑化の度合いを強めるほど，車両の移動に起因しない偶発的な加速度および磁気ノイズの影響を抑え，車両の移動状態をロバストに検出することが可能になる．その一方で，ウィンドウサイズを大きくし過ぎると，移動状態の変化が検出されるまでの遅延時間が增大するため，パラメータの決定にあたっては，推定のロバスト性と移動状態の変化への追従性との合理的な均衡点を見つける必要がある．本論文では，3.2 節の予備実験で収集したデータセットのもとでウィンドウ幅を変化させながら停車検出精度を繰り返し評価し，f-measure が最大となる組合せ（30 秒幅の平均値ウィンドウおよび 40 秒幅の差分ウィンドウ）を採用した．

5. 性能評価

5.1 フィールド実験

提案システムの性能を評価するため，京阪神エリアの 16 の鉄道路線においてフィールド実験を行い，様々な条件下で，スマートフォン端末による加速度・磁気の計測データを収集した．本実験では，計 6 名の被験者が Galaxy Nexus, Galaxy Note II (SamSung), ZenFone 5 (ASUSTeK) のいずれかのスマートフォン端末を手持ちまたはズボンのポケットに保持し，電車に乗車した．このとき，予備実験と同様に，センサデータ収集用の端末とは別のスマートフォン端末で，電車の発車・停車のタイミングの正解データを記録するものとした．各被験者は，起立状態で乗車するか座席に座るかを自由に選択するとし，アノテーションの簡単化のため，電車を降りるまでの間は，同じ姿勢（起立/着席）を維持するものとした．以上の実験を通じて，計 386 回の停車を含むデータセットを構築し，提案システムによる停車検出性能をオフライン分析により評価した．

5.2 既存方式との性能比較

提案方式 (Proposed (fusion))，ならびに 3.1 節で示した既存方式 (SubwayPS [5], Thiagarajan et al. [6]) による停車検出性能を図 9 に示す．同図では，提案方式において，加速度情報に基づく惰行区間のフィルタリングを行わない場合 (Proposed (mag)) の性能もあわせ




図 9 既存方式との性能比較
Fig. 9 Performance comparison.




図 10 端末姿勢・ユーザ姿勢の影響
Fig. 10 Performance with various device poses.

て示している．なお，SubwayPSにおける移動判定の閾値 th_{acc} は，図 1(c) のパラメータ分析で f-measure が最大となる 0.35 とし，提案方式および Thiagarajan et al. については，3.4 節と同様に，leave-one-out 方式による交差検証を行った．

SubwayPS および Thiagarajan et al. では，70～80%程度の recall が実現される一方で，停車の誤検出が頻繁に発生し，precision はそれぞれ 30%，31%となっている．これは，走行中と停車中の加速度特徴量の差が十分でないことに起因している．一方，Proposed (mag) では，車両内の磁場の特性をもとに移動状態の判定モデルを構築することで，precision 72%，recall 82%の高精度な移動状態判定が実現されている．加えて，加速度特徴量に基づく惰行区間のフィルタリングを行うことにより，同等の recall を維持しつつ，precision を 80%まで改善できることが分かった．

また，移動状態の推定結果の系列をもとにスマートフォンユーザが乗車する電車の現在位置を追跡するためには，発車・停車のタイミングだけでなく，停車の回数を正確に検出できることが求められる．提案方式において，各駅で停車が 1 回のみ検出された割合と，停車中と推定された期間の中に実際に駅での停車が 1 回のみ含まれている割合を評価した結果，それぞれ 91%，99%となり，停車回数の正確さという観点でも，高い性能を実現できることを確認している．

提案方式は，加速度センサで計測した車両の揺れの特徴を停車確率に反映させることで，車内の磁場の変動が相対的に小さくなる惰行中に停車の誤検出が発生することを回避している．前述の実験結果は，提案したデータ融合アルゴリズムが停車検出の precision を効果的に改善できることを示しているが，一方で，電車が信号や駅の周辺において低速で惰行する場合等，車両の揺れと車内の磁場の変動が同時に弱まる状況では，惰行区間のフィルタリングに失敗する傾向がある．また，駅での停車中に，近接する線路で他の電車が加減速を行った結果，それらの隣接車両が発する磁気が停車中の車両内へと伝搬し，一時的に走行状態と誤判定される現象も確認している．こうしたノイズの影

響を軽減させるためには，駅間の距離や時刻表情報から移動所要時間および駅での停車時間の想定値を算出し，それらに比べて極端に短い走行期間/停車期間をノイズとして除去することが効果的であると考えられる．こうした事後処理によるさらなる精度向上は，今後の課題とする．

5.3 端末保持方法・ユーザ姿勢の影響

異なる端末保持方法(手持ち/ポケット)とユーザ姿勢(起立/着席)を組み合わせた 4 通りの測定条件のもとで，提案方式の性能を比較した結果を図 10 に示す．いずれの測定条件のもとでも，およそ 80%の f-measure 精度が実現されており，これらの要因が提案方式の性能に与える影響は限定的であるといえる．提案方式が移動状態の判定に用いる車両内の磁場の計測値は，端末を持つユーザの体による信号の減衰や，ユーザの体の動きに起因する端末の動きノイズの影響を受けにくい．この性質が，端末・ユーザ姿勢に依存しないロバストな移動状態推定を可能にしている．一方，惰行区間のフィルタリングに用いる加速度特徴量は，前述の動きノイズにより一定の影響を受ける可能性があるが，4.3 節で述べた特徴量の時間的な平滑化と正規化により，その影響は最小限に抑えられている．

5.4 車両タイプの影響

鉄道の車両は，モータを搭載する電動車と非搭載の付随車に分類され，これらを一定の比率で連結することで 1 本の電車が編成されるのが一般的である．モータやインバータから生じる磁気信号は距離に応じて減衰するため，電動車と付随車とでは，車内で観測される磁気特徴量の性質が異なる可能性がある．車両タイプが提案方式の性能に与える影響を検証するため，大阪市営地下鉄谷町線において，追加実験を行った．本実験では，複数の実験参加者が，Galaxy Nexus を手に把持した状態で異なるタイプの車両へ同時に乗車し，前述の計測アプリケーションにより，加速度・磁気センサの計測値を収集する．以上の実験を繰り返すことにより，109 回の停車を含む独立なデータセットを構築した．ここで，電動車および付随車における磁気特




図 11 車両タイプの影響

Fig. 11 Feature distributions in different types of cars.




図 12 ウェアラブル端末による移動状態センシング

Fig. 12 Performance with wearable devices.

微量の分布を図 11 に示す。停車中には電気系統が動作しないため、磁気特微量の分布は、車両タイプによらず、ほぼ一致している。走行中は、磁気の発生源となる電気系統からの距離が相対的に大きくなる付随車において、磁気特微量がやや小さくなる傾向があるものの、近隣の電動車から発生する磁波によって、停車中と比較してはるかに大きい磁気特微量が観測されている。停車検出の f-measure 精度はいずれの車両タイプでも 84% となり、車両タイプによらず同等の性能が得られることを確認している。

5.5 ウェアラブル端末への適用可能性

近年普及が進みつつあるウェアラブル端末にも、スマートフォン端末と同様、加速度センサおよび磁気センサが標準的に搭載されている。提案方式のウェアラブル端末への適用可能性を検証するため、Android Wear OS 上で動作するセンサデータ収集アプリケーションを実装し、腕時計型ウェアラブル端末 Sony SmartWatch3 を用いた計測実験を行った。大阪市営地下鉄谷町線への乗車中に観測されたセンサデータに対して提案方式を適用した結果を図 12 に示す。デバイスの保持方法やユーザの姿勢の影響を受けにくいロバストな特微量を用いることにより、装着型のデバイスにおいても、スマートフォン端末と同等の高精度な移動状態推定が実現されていることが確認できる。

6. まとめと今後の課題

本論文では、スマートフォン端末に内蔵された加速度センサと磁気センサとを組み合わせて、端末保持者が乗車する電車の移動状態を高精度に検出する手法を提案した。磁気センサを用いて車両の電気系統の動作状況をとらえるとともに、走行時ならびに停車時に観測される特徴的

な加速度特性をもとに判定結果を補正することで、揺れの少ない車両でも高精度な移動状態判定を実現している。京阪神エリアの複数の鉄道路線におけるフィールド実験を通じて、列車の移動状態を precision 80%, recall 82% の精度で検出できることを示した。

スマートフォンを持つ乗客の初期位置を、GPS、Wi-Fi 測位、ユーザ入力等の方法で取得することができれば、その後は、提案方式により駅での停車回数および停車時刻を高精度に検出することで、地上・地下路線を問わず、その乗客の位置を継続的かつ省電力に追跡することが可能となる。これにより、1 章で例示したような、旅行者ナビゲーションや参加型運行状況モニタリング等の移動支援サービスの可用性を高める効果が期待される。

一方、移動状態の検出精度が近隣の線路を走行する他の電車の影響等により一時的に低下しうることを考えれば、乗客の位置を長時間にわたって正確に追跡し続けるためには、停車の誤検出および検出漏れに対して頑健なトラッキングアルゴリズムの検討が必要であるといえる。また、5.2 節で議論したように、走行時間・停車時間の長さに基づく誤差の補正を行うことで、移動状態の検出精度そのもののさらなる改善を図ることも有効である。本研究の今後の展開として、これらの技術課題に取り組んでいく予定である。

謝辞 本研究の一部は、JSPS 科研費 26220001 の助成を受けたものです。

参考文献

- [1] Tokyo Urban Area Traffic Plan Meeting: The 5th Tokyo urban area person trip survey, available from <http://www.tokyo-pt.jp/>.
- [2] Youssef, M. and Agrawala, A.: The Horus WLAN location determination system, *Proc. 3rd International Conference on Mobile Systems, Application, and Services (MobiSys '05)*, pp.205–218 (2005).
- [3] LaMarca, A. et al.: Place Lab: Device Positioning Using Radio Beacons in the Wild, *Pervasive Computing*, Vol.3468, pp.116–133 (2005).
- [4] Kawaguchi, N., Yano, M., Ishida, S., Sasaki, T., Iwasaki, Y., Sugiki, K. and Matsubara, S.: Underground Positioning: Subway Information System Using WiFi Location Technology, *Proc. MDM*, pp.371–372 (2009).
- [5] Stockx, T., Hecht, B. and Schöning, J.: SubwayPS: Towards Smartphone Positioning in Underground Public Transportation Systems, *Proc. SIGSPATIAL*, pp.93–102 (2014).
- [6] Thiagarajan, A., Biagioni, J., Gerlich, T. and Eriksson, J.: Cooperative Transit Tracking Using Smart-phones, *Proc. SenSys*, pp.85–98 (2010).
- [7] Lane, N.D., Miluzzo, E., Lu, H., Peebles, D., Choudhury, T. and Campbell, A.T.: A Survey of Mobile Phone Sensing, *Comm. Mag.*, Vol.48, No.9, pp.140–150 (2010).
- [8] Kealy, M., Zhou, G., Xing, G., Wu, J. and Pyles, A.: PBN: Towards Practical Activity Recognition Using Smartphone-based Body Sensor Networks, *Proc. SenSys*, pp.246–259 (2011).

- [9] Bulling, A., Blanke, U. and Schiele, B.: A Tutorial on Human Activity Recognition Using Body-worn Inertial Sensors, *ACM Comput. Surv.*, Vol.46, No.3, pp.33:1–33:33 (2014).
- [10] Reddy, S., Mun, M., Burke, J., Estrin, D., Hansen, M. and Srivastava, M.: Using Mobile Phones to Determine Transportation Modes, *ACM Trans. Sen. Netw.*, Vol.6, No.2, pp.13:1–13:27 (2010).
- [11] Stenneth, L., Wolfson, O., Yu, P.S. and Xu, B.: Transportation Mode Detection Using Mobile Phones and GIS Information, *Proc. ACM SIGSPATIAL GIS*, pp.54–63 (2011).
- [12] Hemminki, S., Nurmi, P. and Tarkoma, S.: Accelerometer-based Transportation Mode Detection on Smartphones, *Proc. SenSys*, pp.13:1–13:14 (2013).
- [13] Sankaran, K., Zhu, M., Guo, X.F., Ananda, A.L., Chan, M.C. and Peh, L.-S.: Using Mobile Phone Barometer for Low-power Transportation Context Detection, *Proc. SenSys*, pp.191–205 (2014).
- [14] Zhou, P., Zheng, Y. and Li, M.: How Long to Wait?: Predicting Bus Arrival Time with Mobile Phone Based Participatory Sensing, *Proc. MobiSys*, pp.379–392 (2012).
- [15] Biagioni, J., Gerlich, T., Merrifield, T. and Eriksson, J.: EasyTracker: Automatic Transit Tracking, Mapping, and Arrival Time Prediction Using Smartphones, *Proc. SenSys*, pp.68–81 (2011).
- [16] Lee, G. and Han, D.: Subway Train Stop Detection using Magnetometer Sensing Data, *Proc. IPSN* (2014).
- [17] Murphy, K.P.: *Machine Learning: A Probabilistic Perspective*, MIT Press (2012).

推薦文

スマートフォンが搭載する加速度センサと磁気センサを組み合わせ、電車の発車・停車時刻等を正確に推定する方法を提案しており、様々な状況で提案手法の有効性を実証している質の高い研究となっている。MBL 第 75 回研究発表会の評価において当該論文を優秀論文とし、推薦論文とする投票が多数あり、運営委員の審議において推薦論文とする旨、了承された。

(モバイルコンピューティングとパーベイシブシステム
研究会主査 稲村 浩)



樋口 雄大 (正会員)

平成 22 年大阪大学基礎工学部情報科学科卒業。平成 26 年同大学大学院情報科学研究科博士後期課程修了。同年より同大学院情報科学研究科特任助教。博士(情報科学)。モバイル・パーベイシブコンピューティングに関する

研究に従事。IEEE 会員。



山口 弘純 (正会員)

平成 6 年大阪大学基礎工学部情報工学科卒業。平成 10 年同大学大学院基礎工学研究科博士後期課程修了。同年オタワ大学客員研究員。平成 11 年大阪大学大学院基礎工学研究科助手。平成 14 年同大学院情報科学研究科助手。

平成 19 年より同大学院情報科学研究科准教授。博士(工学)。モバイルコンピューティング等に関する研究に従事。IEEE, 電子情報通信学会各会員。



東野 輝夫 (正会員)

昭和 54 年大阪大学基礎工学部情報工学科卒業。昭和 59 年同大学大学院基礎工学研究科博士後期課程修了。同年同大学助手。現在、同大学大学院情報科学研究科教授。博士(工学)。分散システム、通信プロトコル、モバイル

コンピューティング等の研究に従事。電子情報通信学会、ACM 各会員。IEEE Senior Member, 本会フェロー。