

BLEを用いた路線バスの混雑度推定

金光 勇慈^{1,2} 田谷 瑛悟^{1,2} 立花 巧樹¹ 中村 優吾³ 松田 裕貴^{1,2,4} 諏訪 博彦^{1,2} 安本 慶一^{1,2}

概要：主要な公共交通機関の一つである路線バスにおいて、バス内の混雑情報は現在のコロナ禍の状況を鑑みても非常に有益なものとなりうる。実際に運行している路線バス全ての混雑情報を人手で把握することは非現実的であるため、自動的に混雑情報を把握できるシステムが必要となる。実運用を考えると、乗客のプライバシーを侵害する恐れがなく、設置場所と乗客の安全が確保できるシステム設計が求められる。そこで本研究では、センシングデータとしてBLEを用いることで乗客のプライバシー保護と設置コストの低減を実現した混雑度推定システムを提案する。提案システムは、(1)バス内の乗客の携帯端末から発せられるBLE信号を取得するセンシング機構と、(2)センシング機構で得られたデータからバス内の混雑度を推定する推定機構からなる。提案システムの有効性を評価するために奈良交通株式会社の協力のもと、実際に運行する路線バスにおいてデータ収集実験を行い、機械学習モデルを構築して路線バス内の乗車人数を推定した結果、平均絶対誤差 2.46 人 (誤差率 35.4%) の精度で推定できることを示した。

Estimating Congestion on Route Bus by Using BLE

YUJI KANAMITSU^{1,2} EIGO TAYA^{1,2} KOKI TACHIBANA¹ YUGO NAKAMURA³
YUKI MATSUDA^{1,2,4} HIROHIKO SUWA^{1,2} KEIICHI YASUMOTO^{1,2}

1. はじめに

路線バスは主要な公共交通機関の一つである。路線バス内の混雑情報は現在のコロナ禍の状況を鑑みても非常に有益なものとなりうる。路線バスの事業者は、バス内の混雑情報を把握することで運行本数や運行時間、経路の最適化など事業改善を図ることができると考える。交通系ICカードの情報から路線バス利用者の利用状況を把握することも可能であるが、郊外や過疎地などではICカードを導入していないところも多く、また定期券利用者やICカードを所持していない利用者には対応できないといった問題が存在する。また、路線バスの利用者は、バス内の混雑情報をもとに空いているバスを利用するなど、感染リスクを抑える計画的なバスの利用ができると考える。これらを踏まえると今後、路線バス内のリアルタイムな混雑情報を可視化するサービスや感染リスクをなるべく抑えられるような混雑度を考慮した経路推薦サービス、将来の混雑度を予

測するサービスなどが求められる。

これらのサービスを提供するためには、事前に路線バス内の混雑情報を把握する必要がある。実際に運行している路線バス全ての混雑情報を人手で把握することは非現実的であるため、自動的に混雑情報を把握できるシステムが必要となる。路線バスの混雑を把握するため、カメラを用いて得られた動画データから画像処理を行い乗降者を検出する手法が提案されている [1], [2]。このようなカメラを用いたシステムはより高い精度で乗客を検出できる一方で、乗客のプライバシーを侵害する恐れがあることや天井設置が必要になるなど導入コストが大きいという問題がある。また、物体までの距離データを出力する測域センサを用いて乗降者を検出するシステムが開発されている [3]。計算量の削減を実現したアルゴリズムによって安価なシングルボードコンピュータで高精度な推定を可能としている。しかし、乗客の重なりに弱く極度に混雑している状況では精度が低くなるという課題やデバイスの設置位置に制約があるという課題がある。実際の路線バスに導入するためには、乗客のプライバシー情報を含まないデータの収集とセンシングデバイスの設置コスト低減の主に2つの要件を満たすシ

¹ 奈良先端科学技術大学院大学

² 理化学研究所 革新知能統合研究センター (AIP)

³ 九州大学

⁴ 国立研究開発法人科学技術振興機構 さきがけ

システム設計が求められる。

本研究では、センシングデータとして BLE を用いることで乗客のプライバシー保護と設置コスト低減を実現した混雑度推定システムを提案する。提案システムは、(1) バス内の乗客の携帯端末から発せられる BLE 信号を取得するセンシング機構と、(2) センシング機構で得られたデータからバス内の混雑度を推定する推定機構からなる。センシング機構では、BLE 信号に含まれるデータの内、デバイスを識別するための Bluetooth Device Address (以下、BD アドレスと呼ぶ。) と信号電波強度を表す RSSI を取得する。BD アドレスは、プライバシーを考慮して一定時間間隔で変更される仕様となっているためプライバシーを侵害する恐れは低い。また、BLE は特別なセンサを用いることなく Raspberry Pi のような安価で軽量のシングルボードコンピュータ単体で受信可能であり、設置位置に関する制約も存在しない。さらに、路線バス内にもともと BLE 信号を受信できる機器が存在する場合、ソフトウェアのインストールのみで導入可能である。推定機構は、センシング機構で得られたデータを用いて路線バス内の混雑度を推定する。推定は、得られた BD アドレスの RSSI に閾値を設け閾値以上を満たすアドレスを有効なアドレスとしてその総数を推定値とする方法と、機械学習モデルを用いた推定方法の2種類を検討する。機械学習による推定では、運行時刻や路線番号など路線バス特有の情報を加味したデータセットを構築しモデルの学習を行う。また、それらを含まないデータセットで学習したモデルと性能を比較する。

提案システムの有効性を評価するために、奈良交通株式会社の協力のもと、実際に運行している路線バスにおいてデータ収集実験を行った。乗車した路線は、奈良県内の循環バスを含む 39 路線 (重複あり) である。得られたデータの特徴として、時間帯は朝の通勤時間から夜の帰宅時間まで、場所は奈良市内の中心街から南の過疎地まで、乗客層は子供から年配まで幅広く網羅している。データの種類には、BLE 信号に含まれる BD アドレス、RSSI の他、位置情報、時刻情報がある。実験により得られたデータから乗車人数の推定を行った結果、閾値による推定では平均絶対誤差 3.4 人 (誤差率 61.4%)、機械学習による推定では平均絶対誤差 2.46 人 (誤差率 35.4%) を示し、路線バス特有の情報を加味することで精度が大幅に向上することを確認した。

2. 関連研究

人の混雑を推定する研究は数多くある [4], [5], [6], [7], [8]。本章では、特に本研究に関連する BLE を用いた混雑度推定の研究と路線バスにおける乗降者数を推定する研究を紹介する。

2.1 BLE を用いた混雑度推定

BLE を用いて室内外の人の混雑を推定する手法が提案されている。Umeki ら [6] は、人の数によって大きく変化する RSSI 強度の特性に着目し、観光地に設置した BLE デバイスを用いて RSSI の強度分布を観測しリアルタイムに観光地の混雑度を推定するシステムを提案している。観光客に特別な機器を装着させることなく観光地の混雑度を推定することができる一方で、送信機と受信機の 2 つの BLE デバイスを環境に設置する必要がある。また、この手法は混雑度を低、中、高の三段階で推定している。

Weppner ら [7] は、環境中を移動するユーザの携帯端末から検出された近接の BLE 端末数を集約し群衆密度を推定する手法を提案している。また、前川ら [9] は、乗客の持つ携帯端末が受信した近接端末の BLE 信号の RSSI をサーバ上で集約するユーザ参加型センシングによって、鉄道車両が混雑か非混雑かを推定する手法を提案している。これらの手法では、ユーザ参加型センシングによって複数の端末から得られる情報を効果的に融合し、事前にセンサなどを設置することなく混雑度の推定が可能で一方、推定精度はセンシングに参加するユーザの割合に強く依存するという問題がある。

2.2 路線バスの乗降者数の推定

路線バスの乗降者数を推定する手法も提案されている [1], [2]。山田ら [1] は、路線バス内に設置した単一カメラを用いて、高い精度で同一人物のトラッキングを実現している。また、技研トラステム社のバス乗降客カウントセンサ PASSENGER COUNTER [2] では、RGB カメラを用いた乗降者数カウントシステムを開発し、推奨環境下で約 95% の推定精度を達成している。このようなカメラを利用したシステムではより高い精度で乗降者数の推定を実現するが、システムの設置や運用コストは高く、プライバシー侵害の恐れもあるため容易には導入できない。また山田ら [3] は、物体までの距離データを出力する測域センサを利用し、リアルタイムに人体を識別しトラッキングを行う乗降計測システムを提案している。測域センサは一般に高負荷のかかる処理が必要となるが、軽量のアルゴリズムにより安価なシングルボードコンピュータでも動作可能にすることでシステムの導入コストの障壁を低減させ高精度な検出を実現している。しかし、乗客同士の重なりにより非常に混雑している場合には精度が低くなるという課題やセンサの設置位置に制約があるといった課題がある。

2.3 本研究の位置付け

本研究は、実運用を考慮して乗客のプライバシー保護とシステムの設置コスト低減を実現した路線バスの混雑度推定システムを提案する。システムの有効性を評価するにあたり、実際に奈良県内を運行する路線バスを用いてデータ取

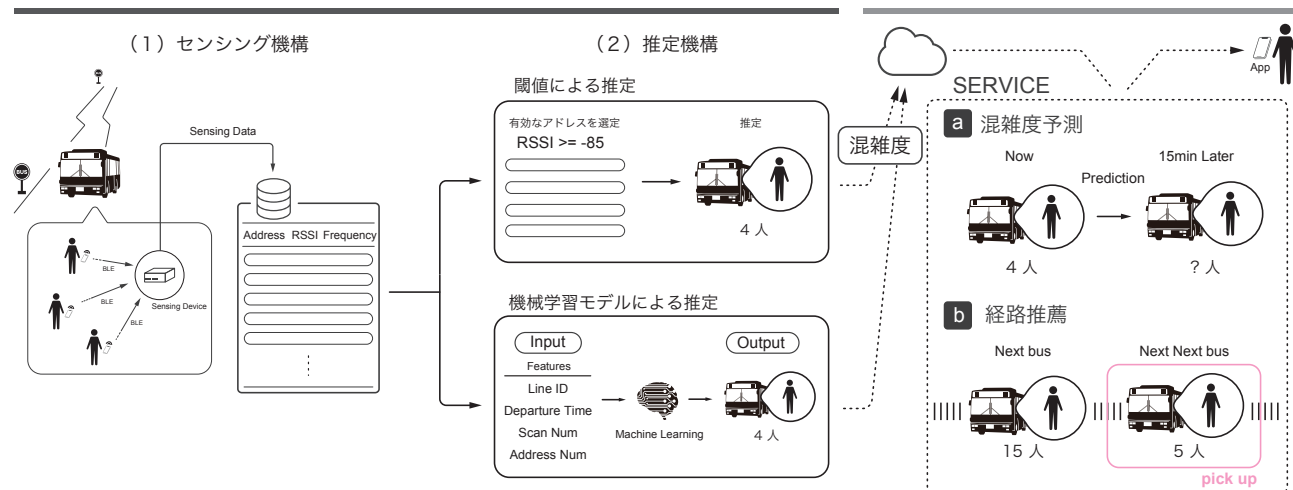


図 1 提案システムの概要図

集実験を行った。これまでも路線バス内の乗客者を検出する研究が行われてきたが、限られた環境や条件下などでの実験に留まり実運用を考慮した研究は少ない。また、利用状況が地域や時間帯によって大きく変化する路線バスに対して、運行時刻や路線番号などの情報を加味した混雑度推定は独自の取り組みと言える。本システムは、特別なセンサを用いることなく Raspberry Pi のような安価で軽量のシングルボードコンピュータ単体で動作させることができる。また、設置位置に関する制約もなく、プライバシーを考慮した設計により運用コストの抑制を実現している。

3. 提案システム

本章では、システム要件を整理したのち、要件を満たすシステムを提案する。

3.1 システム要件

実際に運行する路線バスに導入するためのシステム要件を以下に示す。

実運用のためのシステム要件

- 乗客のプライバシー情報を含まないデータの収集
- センシングデバイスの設置コスト低減

実際に運行するバス内に導入する上で大きな障壁になるのが乗客のプライバシー問題である。これを解決するためには乗客のプライバシー情報を含まないデータの収集が必要となる。カメラを使った推定 [1], [2] では、より高精度な推定が可能一方で顔画像などプライバシー情報が取得される。解決策として、プライバシーデータはサーバへアップロードせず、ローカル上で推定を行った後速やかに破棄することでプライバシー侵害のリスクを抑える方法が考えられる。しかし、天井のようなバス内全体を見通すことができる位置に設置する必要があり、設置コストや運用コストが大きく

なってしまう。このため、乗客の安全と設置場所を確保するためには、プライバシーデータを含まないデータの収集と設置デバイスの小型化、単一化が求められる。また、デバイスの設置位置に制約を設けないシステム設計が求められる。

3.2 提案システムの概要

3.1 節のシステム要件を踏まえ、実運用を考慮した路線バス内の混雑度を推定するシステムを提案する。提案システムの概要を図 1 に示す。提案システムは、(1) 路線バス内のデータを収集するためのセンシング機構と、(2) センシング機構で得られたデータから混雑度を推定する推定機構からなる。また、システムの展望 (もしくはユースケース) として (a) 将来の混雑度予測サービスと (b) 混雑度を考慮した経路推薦サービスを図に示した。

3.3 システム設計

(1) センシング機構

センシング機構では、センシングデータとして乗客の携帯端末から発せられる BLE を利用する。BLE (Bluetooth Low Energy) とは、Bluetooth と呼ばれる近距離無線通信の規格の中で、省電力に特化した通信規格である。BLE を利用したデバイスは、他の BLE デバイスと接続するために常に不特定多数の相手に対してデータを一方向送信するブロードキャスト通信を行う。送信されるデータには、デバイスを識別するための BD アドレス (Bluetooth Device Address) や信号強度を表す RSSI などがある。センシング機構は、乗客の携帯端末から発せられる BLE 信号に含まれるデータのうち、BD アドレスと RSSI を取得する。BD アドレスはプライバシーを考慮し、一定時間間隔でランダムに変更されるという特徴があるため、乗客のプライバシーを

侵害する恐れは低い。また、BLE は特別なセンサなどを用いることなくセンシングが可能であるため、バス内にもともと BLE を受信できる機器が存在する場合、センシングデバイスを設置する必要がなくソフトウェアのインストールのみで運用可能である。

(2) 推定機構

推定機構では、センシング機構により得られたデータから路線バス内の混雑度を推定する。本研究では、路線バスの混雑度推定として停留所間（停留所を出発してから次の停留所に到着するまで）の乗車人数を推定することとする。路線バスの乗客の中には、携帯端末を所持していない乗客もいれば複数台所持している乗客もいると考えられる。また、センシング機構で述べたように、BD アドレスは一定時間経過後に変更されるため、同一端末を重複して数えてしまう可能性もある。これらの問題を踏まえると、単純に検出された BD アドレスの数を乗車人数と対応づけることはできない。そこで推定機構では、センシング機構によって得られた BD アドレスの RSSI に閾値を設け閾値以上を満たすアドレスを有効なアドレスとしてその総数を推定値とする閾値を用いた推定や、路線バス特有の情報を加味した機械学習モデルによる推定を行う。

4. データ収集デバイスの実装

本章では、本研究で実装したデータ収集用センシングデバイスについて述べる。

4.1 実装の概要

本研究で提案するシステムは、3.3 節で述べたようにセンシングデータとして乗客の携帯端末から発せられる BLE を利用することで、プライバシーデータを含まないデータの収集と、デバイスの設置コストを抑えるの 2 点を満たすシステム設計となっている。提案システムの有効性を評価するために 5 章で述べるデータ収集実験を行うにあたり、データ収集用センシングデバイスを実装した。

4.2 センシングデバイス

本研究で実装した BLE を受信するためのセンシングデバイスを図 2 に示す。センシングデバイスとして BLE 通信が可能な Raspberry Pi 4 を用いた。位置情報を取得するため、Raspberry Pi に GPS モジュールを搭載する。GPS モジュールは、太陽誘電製の小型高感度 GPS モジュール GYSFDMAXB を使用した GPS 受信機キット [10] を用いた。また、遠隔からシステムが正常に動作しているかどうかを確認するために、取得したデータを逐一サーバ上へ送信する。ここでは、バス内にインターネット環境がなかったため、Raspberry Pi に通信モジュールを搭載した。これらのモジュールは、Raspberry Pi のようなシングルボードコンピュータに同時に接続することができ、センシングデ




図 2 センシングデバイス




図 3 センシングの様子

バイスの小型化が実現されている。センシングデバイスを用いて取得できるデータには、BLE 信号に含まれる BD アドレス、RSSI と取得されたデータの位置情報、時間情報がある。

4.3 センシングアルゴリズム

本研究では、路線バスの混雑度推定として停留所間（停留所を出発してから次の停留所に到着するまで）の乗車人数を推定することとする。停留所は、GPS から得られる位置情報を用いて特定する。センシングの様子を図 3 に示す。本システムは 15 秒間に 1 度周囲の BLE 端末を検知する。路線によっては、停留所間の時間間隔（停留所を出発してから次の停留所を通過するまでにかかる時間）が 1 分未満の場合もあるためここでは 15 秒間隔で検知することとした。ここで停留所間における全検知回数を N_{scan} とする。 N_{scan} 回の検知によって検出された BLE 端末の BD アドレスと RSSI をデータとして保持する。ここで路線バス内の乗客の携帯端末は、複数回検知されると考えられる。そこで、複数回検知された同一 BD アドレスに対し、検知された回数を $n_{detected}$ とおく。 i 番目に検知された時の RSSI を $S(i)$ として、RSSI の平均値 S_{mean} と出現頻度 $F(\%)$ がそれぞれ式 (1)、式 (2) で定義される。

$$S_{mean} = \frac{1}{n_{detected}} \sum_{i=1}^{n_{detected}} S(i) \quad (1)$$

$$F(\%) = \frac{n_{detected}}{N_{scan}} \times 100 \quad (2)$$

これらより、ある停留所間において得られるセンシングデータの一例を表 1 に示す。

表 1 停留所間におけるセンシングデータの一例

BD アドレス	平均 RSSI, S_{mean}	出現頻度, $F(\%)$
00:00:5e:00:53:1a	-78.5	25
00:00:5e:00:53:38	-90.0	100
00:00:5e:00:53:90	-56.4	75
...



図 4 データ収集エリア

5. データ収集実験

5.1 実験概要

提案手法の有効性を評価するために、奈良交通株式会社の協力の下、2020年12月21日に実際に運行している路線バスを利用してデータ収集実験を行った。データの収集エリアを図4に青線で示す。データを収集した路線は奈良県内の、循環バスを含む計39路線（重複あり）である。路線バスは、通勤ラッシュや帰宅ラッシュなど時間帯によって乗客数の特徴が現れると考えられる。そこで、様々な時間帯のデータを収集するため、朝の7時から夜の7時の間で実験を行った。実際に運行している路線バスで実験を行うため、実験に以下3つの制約が与えられた。(1)バスから電源が供給できない、(2)受信デバイスを設置することができない、(3)正解データ（実際の乗客数）は与えられない。そこで実験者は、モバイルバッテリーと共にセンシングデバイスを車内に持ちこみデータを収集するとともに、正解データを取得するため目視で車内の人数を確認し

設置位置




図 5 センシングデバイスの設置位置

表 2 学研奈良登美ヶ丘駅～高の原駅区間の測定結果

出発時刻	出発停留所	アドレス総数	乗車人数
08:52	学研奈良登美ヶ丘駅	25	4
08:54	北登美ヶ丘一丁目	25	4
08:55	東登美ヶ丘四丁目	25	5
08:56	東登美ヶ丘五丁目	25	6
08:57	東登美ヶ丘六丁目	51	7
08:58	東登美ヶ丘六丁目東	104	8
09:00	押熊・神功	75	11
09:02	精華桜が丘三丁目	40	15
09:03	兜台三丁目	44	15
09:04	兜台二丁目	51	15
09:05	兜台一丁目西	21	15
09:05	兜台一丁目	78	15

た。そのため、実験者は車内全体の様子が把握しやすいバスの後方に座った。よって、センシングデバイスの設置位置は実験者の乗車位置と一致する（図5）。

5.2 実験結果

データを収集した39路線の中から実験結果の一部として、学研奈良登美ヶ丘駅～高の原駅の路線区間の測定結果を表2に示す。ここでアドレス総数は、4.3節で述べたセンシングデータのBDアドレスの総数を表す。計39路線から合計662の停留所間データが得られた。各停留所間データには、停留所の出発時刻、BDアドレスの総数、実際に乗車していた人数が含まれる。

次に得られた662の生データに対して、縦軸にBDアドレス総数（測定値）、横軸に乗車人数（真値）をプロットしたグラフを図6に示す。グラフ中の青直線 ($y = x$) は、真値と推定値の誤差がないときの理想状態を表している。このグラフからわかるように、各停留所間において得られたBDアドレスの総数と実際の乗車人数は大きくかけ離れていることがわかる。これは、乗客の所持する携帯端末以外に、路線バス外の人の携帯端末を受信していることや、街中に存在するBLE端末の信号を受信していることが要因として考えられる。また、乗客の中には複数台のBLE端末を所持している人も多いため、単純に得られたアドレスの総数を乗車人数として推定することは難しいとわかる。そこで本研究は、推定機構において、得られたBDアドレスに対してRSSIや出現頻度に閾値を定めることによって




図 6 測定値と真値のプロット (生データ)

そのアドレスが有効かどうかを判定する閾値推定や機械学習モデルを用いた推定を行う。

6. 推定と評価

本章では、提案システムの(2)推定機構による路線バス内の乗車人数の推定について述べる。

6.1 閾値による推定

5.2節からわかるように、路線バス内の乗車人数の推定において、単純にセンシング機構で得られたセンシングデータのBDアドレスの総数を乗車人数として推定することは難しい。そこで、得られたBDアドレスの平均RSSIと出現頻度に閾値を設けることで、そのアドレスが有効かどうかを判定し、有効であったアドレスの総数を乗車人数として推定する手法を検討する。

はじめに、BDアドレスの平均RSSIに閾値を設ける。各停留所間において、平均RSSIがある一定値以上のBDアドレスを有効なアドレスとし、そのアドレスの総数を推定値とする。真値と推定値の絶対誤差を算出し、全停留所間で平均した平均絶対誤差(MAE, Mean Absolute Error)と平均絶対誤差率(MAPE, Mean Absolute Percentage Error)を求める。MAEが最も小さくなるような平均RSSIの閾値を選んだ結果、閾値が74のとき平均絶対誤差3.9人、平均誤差率77.3%を示した(表3)。図7(a)に生データ(図6)と同様に縦軸に推定値(有効なアドレスの総数)、横軸に真値(乗車人数)をプロットした図を示す。推定値が図6と比べて真値に近づいていることがわかる。

次に、BDアドレスの平均RSSIと出現頻度Fにそれぞれ閾値を設ける。平均RSSIと出現頻度の閾値条件を同時

表 3 閾値推定の結果

METHOD	MAE	MAPE
ALL	75.8	2182.5
RSSI \geq -74	3.9	77.3
RSSI \geq -80, F \geq 40%	3.4	61.4

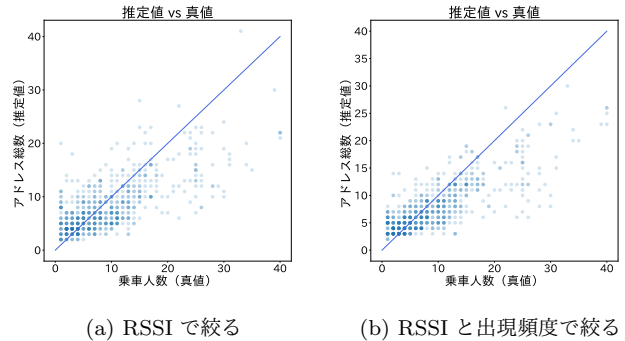


図 7 推定値と真値のプロット (閾値による推定)

に満たすアドレスを有効なアドレスとし、その総数を推定値とする。MAEが最も小さくなるような閾値をそれぞれ選んだ結果、平均RSSIの閾値が-80、出現頻度の閾値が40%のとき平均絶対誤差3.4人、平均誤差率61.4%を示した(表3)。図7(b)に推定値と真値をプロットした図を示す。RSSIと出現頻度のそれぞれに閾値を設けることで精度は上がったものの、閾値による推定手法では観測値が真値より下回っているデータに対応できず十分な性能が得られていない。

6.2 機械学習モデルによる推定

路線バスの運行時刻や路線番号などのデータには、通勤ラッシュや帰宅ラッシュ、市街地や郊外など、混雑度を推定する上で重要な情報が内在していると考えられる。そこで本研究では、これら路線バス特有の情報を加味した機械学習モデルによる推定を提案する。全停留所間データ662件のそれぞれについて特徴量19次元を与える。各特徴量に関しては表4を参照されたい。アドレスのRSSIや出現頻度は、そのアドレスの有効性を評価する上で重要な指標になると考える。そこで、段階的に閾値を設定したときの各アドレスの総数を特徴量に加える。ここで、手法による結果の比較を行うため、路線バス特有の特徴量(特徴量ID: 17/18/19)を含まないデータセットをND(Narabus Dataset)とし、全ての特徴量を含むデータセットをND⁺としデータセットを2種類構築する。

学習モデルとしてSVM(Support Vector Machine)、RF(Random Forest)、XGB(XGBoost)の3種類を採用し、各モデルごとに学習を行い評価する。モデルの評価には3分割交差検証を用いた。閾値による推定と同様に、評価指標としてMAEとMAPEを算出した結果を表5に示す。全ての機械学習モデルにおいて、路線バス特有の特徴量を

表 4 特徴量一覧

ID	NAME	DESCRIPTION
1	アドレス数 0	アドレス総数
2	アドレス数 1	出現頻度 10%以上のアドレス総数
3	アドレス数 2	出現頻度 20%以上のアドレス総数
4	アドレス数 3	出現頻度 30%以上のアドレス総数
5	アドレス数 4	出現頻度 40%以上のアドレス総数
6	アドレス数 5	出現頻度 50%以上のアドレス総数
7	アドレス数 6	出現頻度 60%以上のアドレス総数
8	アドレス数 7	出現頻度 70%以上のアドレス総数
9	アドレス数 8	出現頻度 80%以上のアドレス総数
10	アドレス数 9	出現頻度 90%以上のアドレス総数
11	アドレス数 10	出現頻度 100%以上のアドレス総数
12	アドレス数 11	RSSI-70 以上のアドレス総数
13	アドレス数 12	RSSI-75 以上のアドレス総数
14	アドレス数 13	RSSI-80 以上のアドレス総数
15	アドレス数 14	RSSI-85 以上のアドレス総数
16	アドレス数 15	RSSI-90 以上のアドレス総数
17	出発時刻	停留所の出発時刻
18	路線番号	路線番号
19	スキャン回数	停留所間にスキャンされた回数

表 5 各データセットに対するモデルの性能評価

MODEL	ND		ND ⁺	
	MAE	MAPE	MAE	MAPE
SVM	3.21	59.7	2.71	46.0
RF	2.93	61.4	2.44	45.8
XGB	2.91	56.1	2.46	35.4

含むデータセット ND⁺ を入力として用いることで性能が向上することを確認した。モデルの中では、XGB が誤差率 35.4%と最もよい精度を示した。

7. 考察

本章では、各推定手法による推定結果および将来展望について考察する。

7.1 閾値による推定

図 6 の生データを見ると、真値が 20 人以下のとき、ほとんどの停留所間データで真値を上回る数のアドレスを取得していることがわかる。原因の一つとして、5.2 節で述べたように路線バス外の BLE 端末の信号を受信していることが考えられる。これに対しては BD アドレスの平均 RSSI と出現頻度に適切な閾値を設け、有効なアドレスを選定することで図 7 に見られるように誤差を大きく減らすことができた。

一方で、生データの真値が 20 人以上のデータでは、検出されたアドレス数が真値を下回る傾向が見られる。これは、路線バス内が混雑している状況では、BLE が人やものに遮断され伝搬されにくくなり、BLE をうまく検出できなかったと推測する。また、実験の制約上センシングデバイスをバス後方に設置したため、前に乗車する乗客の端末を

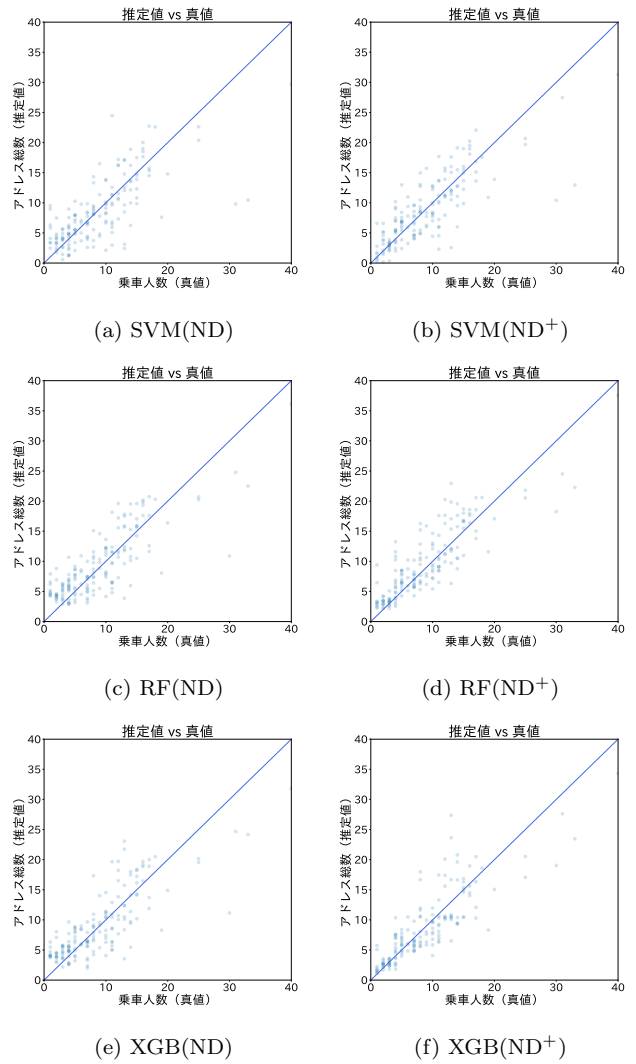


図 8 推定値と真値のプロット (機械学習モデルによる推定)

検知しきれなかったと考える。解決策として、センシングデバイスをバス中央に設置したり、デバイスを 2 つ用いて前方と後方に設置する方法が考えられるが、デバイスの設置位置に制約を課すことになり導入コストが上がってしまうというジレンマがある。

7.2 機械学習モデルによる推定

本研究では、前述の問題に対し機械学習モデルにアドレス総数の他、時間情報や路線情報など路線バス特有の情報を与えることで精度の向上を図った。性能評価の結果、最も良い精度を示したモデルで誤差率 35.4%を示し、閾値による推定と比べ大幅に精度を向上させることができた。図 8(f) から図 7(b) と比べて真値が 20 人以上のときの誤差が減少していることがわかる。

次に、混雑している状況に対して評価を見直す。例えば、真値が 1 人で推定値が 3 人であった場合、誤差率は 200%を示し平均絶対誤差率の値に大きく寄与することがある。しかし、実際に運用するケースでは 1 人を 3 人と推定す

ることはさほど大きな問題ではない。そこで、機械学習による推定の性能評価において、真値が10人以上のデータのみで改めて平均絶対誤差と平均絶対誤差率を算出した結果、データセットND⁺においてSVMはMAE3.6人、MAPE24.1%、RFはMAE3.2人、MAPE22.4%、XGBはMAE3.7人、MAPE25.7%を示した。これらより、路線バスが混雑している状況下でも精度を落とすことなく推定できることを確認した。

7.3 システムの展望

我々は、提案システムによって路線バス内の混雑度の推定が実現されると、事業者や利用者になたな価値をWebアプリやスマートフォンアプリを介して提供できると考える。例えば、路線バスの利用状況の把握・解析やリアルタイムな混雑状況の可視化、将来の混雑度予測、混雑を考慮した経路推薦などのサービスが考えられる。事業者は、路線バスの利用情報の把握・解析により運行本数や運行時間、経路の最適化など事業改善に貢献できると考える。利用者は、リアルタイムな混雑情報や将来の混雑予測を把握することで、新型コロナウイルスの感染リスクを考慮した計画的な利用が可能となる。さらに、混雑状況の把握によって他人との接触を抑えたより安心で快適な交通経路を利用者に推薦することで利用満足度を高めることができると考える [11]。

8. おわりに

本研究では、実際に運行している路線バスに導入することを考慮し、乗客のプライバシーの保護と設置コストの低減のためにセンシングデータとしてBLEを用いた路線バスの混雑度推定システムを提案した。複数台のBLEデバイスを所持する乗客やデバイスを所持していない乗客に対応するため、BLE信号の有効性を検討する閾値推定や、地域によって変わる乗客者層などの路線バス特有の情報を加味した機械学習モデルの構築を行った。本システムはRaspberry Piのような安価で軽量のシングルボードコンピュータ単体で構成されている。また、路線バス内にもともとBLEを受信する機器が存在する場合、ソフトウェアのインストールのみで導入が可能である。設置位置に制約を課すことなく導入できるといった利点もある。実際に運行している路線バスでデータ収集実験を行い提案システムの有効性を評価した結果、平均絶対誤差2.5人で乗車人数を推定できることを示した。

今後の課題として、混雑している状況下でも乗客のBLE端末を正確に取得できるシステム設計があげられる。実運用を考慮するとセンシングデバイスの設置位置に制約を与えない方法が望ましい。解決方法の一つとして、乗客が携帯するスマートフォンをセンシングデバイスとして用いる参加型センシングの方法が考えられる。また、新たに実際

に運行している路線バスでデータ収集実験を計画しており、得られるデータから新たなモデルの構築を行い精度の向上を試みる。

謝辞 データ収集にあたり、奈良交通株式会社様に協力していただいた。ここに記し感謝申し上げます。

参考文献

- [1] 山田遊馬, 廣森聡仁, 山口弘純, 東野輝夫. 路線バスにおけるカメラ画像を用いたod計測システムの提案. 研究報告高度交通システムとスマートコミュニティ (ITS), Vol. 2019, No. 18, pp. 1-8, 2019.
- [2] 技研トラステム. passenger counter. http://www.trastem.co.jp/product/passenger_counter.html. (Accessed on 04/10/2021).
- [3] 山田遊馬, 廣森聡仁, 山口弘純, 東野輝夫. 測域センサを利用した高精度な路線バス乗降計測システム. 第25回マルチメディア通信と分散処理ワークショップ論文集, Vol. 2017, pp. 24-32, 2017.
- [4] Pravein Govindan Kannan, Seshadri Padmanabha Venkatagiri, Mun Choon Chan, Akhihebbal L Ananda, and Li-Shiuan Peh. Low cost crowd counting using audio tones. In *Proceedings of the 10th ACM Conference on Embedded Network Sensor Systems*, pp. 155-168, 2012.
- [5] Antoni B Chan, Zhang-Sheng John Liang, and Nuno Vasconcelos. Privacy preserving crowd monitoring: Counting people without people models or tracking. In *2008 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1-7. IEEE, 2008.
- [6] Kazuhito Umeki, Yugo Nakamura, Manato Fujimoto, Yutaka Arakawa, and Keiichi Yasumoto. Real-time congestion estimation in sightseeing spots with ble devices. In *2018 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pp. 430-432. IEEE, 2018.
- [7] Jens Weppner and Paul Lukowicz. Bluetooth based collaborative crowd density estimation with mobile phones. In *2013 IEEE international conference on pervasive computing and communications (PerCom)*, pp. 193-200. IEEE, 2013.
- [8] Hongquan Song, Xuejun Liu, Xingguo Zhang, and Jiawei Hu. Real-time monitoring for crowd counting using video surveillance and gis. In *2012 2nd International Conference on Remote Sensing, Environment and Transportation Engineering*, pp. 1-4. IEEE, 2012.
- [9] 前川勇樹, 内山彰, 山口弘純, 東野輝夫. 鉄道におけるbluetooth rssi特性を用いた乗車車両および混雑の推定手法. 情報処理学会論文誌, Vol. 55, No. 6, pp. 1614-1624, 2014.
- [10] Gps受信キット1pps出力付き「みちびき」3機受信対応. <https://akizukidenshi.com/catalog/g/gK-09991/>.
- [11] 田谷瑛悟, 松田裕貴, 諏訪博彦, 安本慶一. 交通機関利用における接触を回避するための経路推薦手法の検討. 2020年度情報処理学会関西支部支部大会講演論文集, Vol. 2020, , 2020.