社団法人　電子情報通信学会
THE INSTITUTE OF ELECTRONICS,
INFORMATION AND COMMUNICATION ENGINEERS

信学技報
TECHNICAL REPORT OF IEICE.

BLE 信号を用いた電車車両における混雑度推定手法の検討

田谷　瑛悟[†,††] 金光　勇慈[†,††] 立花　巧樹[†]　中村　優吾[†††] 松田　裕貴[†,††,††††]
諏訪　博彦[†,††] 安本　慶一[†,††]

† 奈良先端科学技術大学院大学
†† 理化学研究所 革新知能統合研究センター（AIP）
††† 九州大学
†††† 国立研究開発法人科学技術振興機構 さきがけ
E-mail: †{taya.eigo.td3,kanamitsu.yuji.ky4,tachibana.koki.ti0,yukimat,h-suwa,yasumoto}@is.naist.jp,
††y-nakamura@ait.kyushu-u.ac.jp

あらまし　電車は人々の移動手段としての役割を果たす重要な移動手段である．近年では，COVID-19 のパンデミックの防止や利用の快適性向上を目的に，車両ごとの混雑度を推定することが求められている．しかしながら乗客のプライバシーを侵害することなく，混雑度を推定することは難しい．これまでに，我々は BLE 信号を用いることでプライバシを保護しつつ，バスの混雑度を推定するシステムを構築，評価してきた．本研究では，近畿日本鉄道株式会社協力のもと，上記のシステムを用いて電車で BLE 信号を収集した．そして，機械学習の回帰モデルを構築して電車の車両ごとの混雑度を推定した結果，MAE が 0.56，MAPE が 0.27 の精度で推定できることが示された．
キーワード　BLE, 電車, 公共交通, 混雑度推定, 機械学習

A Method and Evaluation of Train Congestion Estimation Using BLE Signals

Eigo TAYA[†,††], Yuji KANAMITSU[†,††], Koki TACHIBANA[†], Yugo NAKAMURA[†††], Yuki MATSUDA[†,††,††††], Hirohiko SUWA[†,††], and Keiichi YASUMOTO[†,††]

† Nara Institute of Science and Technology
†† RIKEN Center for Advanced Intelligence Project AIP
††† Kyushu University
†††† JST PRESTO
E-mail: †{taya.eigo.td3,kanamitsu.yuji.ky4,tachibana.koki.ti0,yukimat,h-suwa,yasumoto}@is.naist.jp,
††y-nakamura@ait.kyushu-u.ac.jp

Abstract　Trains play an essential role in transportation in supporting people's lives. In recent years, it has become necessary to estimate the degree of congestion in each train vehicle to prevent the pandemic of COVID-19 and improve passengers' comfort. However, it is difficult to estimate the degree of congestion without violating passengers' privacy. We have developed and evaluated a system to estimate the degree of bus congestion while protecting passengers' privacy by using BLE signals. This paper used the above system to collect BLE signals on a train cooperating with Kintetsu Railway Co., Ltd. The congestion of each train vehicle is then estimated using a machine learning regression model. The results show that the MAE and MAPE can be estimated with an accuracy of 0.56 and 0.27, respectively.
Key words　BLE, Train, Public transportation, Congestion estimation, Machine learning

1. はじめに

多くの都市において通勤や通学などの活動を支える電車は，我々の生活に欠かせない交通手段である．しかしながら，通勤ラッシュや天候による遅延による乗客の増加によって，快適性が損なわれるほどの混雑が発生する場合がある．そのため，多

くの乗客は電車の定時運行性や料金だけでなく，快適性を考慮して乗車する電車を決定することが知られている [1]．そこで，ユーザが快適でないことを理由に利用を取りやめることを防ぐために，事業者は電車の混雑度を収集・提供する必要がある．

2019 年 11 月より発生している COVID-19 のパンデミックにより，2021 年 12 月時点で人間社会に対して経済的・衛生的・社会的に深刻な問題を引き起こしている [2]．そのため，人々は他人との接触を抑えて感染拡大の防止に努める必要があるものの，仕事や買い物といった経済活動を維持するために電車の利用は不可欠である．そこで，事前に電車の混雑状況を把握することが出来れば，感染拡大のリスクを抑えつつ，電車を利用することが可能になる．特に，電車は公共交通機関の中でも利用数が多く，混雑する状況が発生しやすいため，電車における混雑度の把握は喫緊の課題となっている．

これまでに我々の研究グループでは，乗客のプライバシー保護と設置コストの低減を目的に，路線バスの混雑度推定システムを提案している [3]．システムではバス内の乗客の携帯端末が発信する BLE 信号を検出し，信号に含まれる Bluetooth Device Address(BD Address) と信号強度を表す RSSI を取得する．そして，得られた BLE 信号の RSSI と路線バス特有の情報（時刻や路線番号など）を用いて，バスの乗客数を推定する．

本研究では，上記のシステムを電車の混雑度を近鉄電車株式会社協力のもと，実際に運行している電車においてデータ収集実験を実施し，車両ごとの混雑度を推定する．そして，電車の混雑度を推定するための機械学習モデルを構築し，モデルの推定精度を確認する実験により得られたデータから混雑度を推定した結果，しきい値で推定する手法で MAE は 7.27, MAPE は 0.27 となった．また，機械学習による推定で MAE は 5.56, MAPE は 0.27 となり，しきい値推定と比較して，乗車人数が多い区間の推定精度が向上していることが確認された．

2. 関 連 研 究

2.1 交通機関における乗車人数の推定

最も単純な乗車人数の推定手段として，カメラを用いたシステムが提案されている [4]〜[6]．たとえば，Song らは監視カメラの映像を用いて通行人数をカウントするシステムを提案している [4]．しかしながら，カメラを用いた推定システムは通行人の顔を記録するために，個人を追跡できる可能性がある．電車のような公共交通機関において，乗客のプライバシーを侵害するような情報を定常的に収集することは好ましくない．

また，Wi-Fi 信号を用いて混雑度を推定する研究が提案されている [7]〜[10]．たとえば，Handte らは Wi-Fi 環境が整備されたバスを対象に，アクセスポイントに接続する乗客の携帯端末の MAC アドレスの数をカウントすることで，乗客人数を推定している．推定の結果，誤差は平均 5.1 人程度だったが，混雑する状況下において精度が低下する傾向が存在する．

加えて，赤外線センサを用いて乗客を検知する手法も提案されている [11]〜[15]．たとえば，Bauer らは空港における人数を検出するために，赤外線センサとマット型圧力センサーを組み合わせたシステムを提案している [11]．しかし，赤外線センサは，信号値の強度変化を検知することで人数をカウントするため，センサ付近で留まる人がいる場合や，大人数が通行する場合に精度が悪くなる傾向がある．電車の場合，上記の状況は頻発するため（例えば，出入り口にもたれかかることや駅での乗り降り），赤外線センサを用いたシステムは適さない．

2.2 BLE 信号を用いた混雑度推定

モバイル端末の普及に伴い，BLE などの無線通信技術を用いた群衆密度の推定についての研究が報告されている [16]〜[20]．梅木らは，人間の数によって大きく変化する RSSI 強度に着目し，観光地の混雑度を推定するシステムを提案している．彼らは BLE 信号を発信する発振器と受信機を観光地に設置し，RSSI の強度分布を観測することで混雑度を「低」「中」「高」三段階で推定している．

一方で Weppner らは，ある環境下を移動するユーザの携帯信号から検出された近傍の BLE 端末数を集計し，群衆密度を推定する手法を提案している [19], [21]．この手法では，ユーザの端末から得られるデータを適切に集約し，新たなセンサを設置することなく混雑度を推定する．しかしながら，上記の手法は推定精度がセンシングに参加するユーザの数に大きく影響するため，ユーザの参加を促す仕組みを必要とする．

2.3 本研究の位置づけ

以上のように，混雑度推定に関する研究は多数存在するが，プライバシー保護や実運用を想定した研究は数少ない．我々の研究グループでは，路線バスを対象に，BLE 信号を用いて乗客のプライバシーを保護し，混雑度推定システムを提案している [3]．本稿では，上記の混雑度推定システムを電車に適用し，乗客のプライバシーを妨げることなく乗車人数を推定することを試みる．実際に運行している車両でデータを収集し，車両ごとの混雑度を推定した結果について報告する．

3. データ収集システム

3.1 システム概要

図 1 に実装したシステムの図を示す．システムはシングルボードコンピュータの Raspberry Pi で実装され，Bluetooth ドングルと GPS モジュール，LTE 通信を可能にする通信モジュールから構成される．

3.1.1 Bluetooth ドングル

乗客のプライバシーの保護と電車の混雑度推定のために，システムは乗客の携帯端末から発生する BLE(Bluetooth Low Energy) 信号を計測する．BLE は，Bluetooth と呼ばれる近距離無線通信規格の中でも，省電力を実現した通信規格である．BLE 機器は他の BLE 機器と接続するために，不特定多数の相手にデータを一方的に通信信号を連続的に発信する．システムに取り付けたドングルは，乗客の BLE 機器が発信する信号に含まれる，機器を識別するための BD アドレスと信号強度を表す RSSI を収集する．なお，信号を収集するために，乗客は移動中に携帯端末の Bluetooth の利用を許可する必要がある．しかし，ワイヤレスイヤホンやスマートウォッチなどの BLE 機器の普及や，コンタクトトレーシング技術の開発に伴って，Bluetooth の利用は一般的になっている．そのため，システムが乗客の人数を推

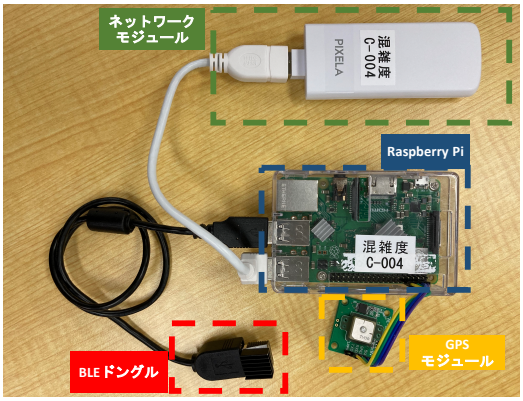

図 1　センシングシステム

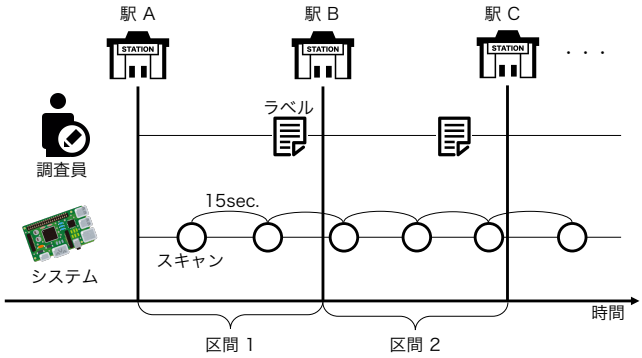

図 2　センシングプロセスの概要

定するために十分な数の信号を収集できることを前提とする．

3.1.2　GPS モジュール

混雑度を推定するために，システムによって収集された BLE データが，どの駅区間で収集されたデータであるか明らかにする必要がある．BLE データと駅区間は，交通機関が定めた運行ダイヤによって対応付けられるが，天候や事故などの外的な要因によって運行ダイヤに乱れが発生する場合がある．ダイヤに乱れが発生すると，BLE データと駅区間を対応付けることが困難になる．そこでシステムは GPS モジュールを用いて，BLE 信号の検出時に位置情報を取得し，列車の走行位置を記録し，ダイヤの乱れが発生しても BLE データと対応付け可能にする．

3.1.3　ネットワークモジュール

我々は遠隔でのシステムの動作確認やリアルタイムな乗車人数を推定するために，システムはインターネットに接続する必要がある．しかし，多くの公共交通機関では，運行している車両に Wi-Fi などの通信環境を備えているわけではない．そこで，USB で取り付け可能なネットワークモジュールを使用し，システムがインターネットに接続可能にする．

3.2　センシングプロセス

本研究では，運行車両の混雑度を示す指標として，電車が駅から駅に移動する区間の乗客人数を推定する．推定に必要なデータのセンシングと正解データ（乗車人数）のラベル付け手順を図 2 に示す．システムは 15 秒間隔で周辺の BLE 信号を検知し，データサーバに送信する．送信データは，スキャン時刻を表すタイムスタンプや，車両の位置情報を表す緯度経度，そして複数台の端末が発信している BLE 信号の BD アドレスと RSSI を含んでいる（図 3）．また，信号検知に並行して調査員が運行車両に乗車し，通過した区間の名前や運行形態，乗車人数 (正解データ) を記録する（表 1）．なお，システムと調査員は各運行車両に 1 つ，1 人ずつ配備される．

3.3　特徴量抽出

システムが一回のスキャンで得られた BLE データには，車外の端末が発信する信号が含まれている可能性がある．そこで，我々は区間内でスキャンした全てのデータを集約し，2 種類の特徴量を構築する．まず，BLE 端末とシステムが同じ車両に存在する場合，区間内で同じ BD アドレスが複数回検出できると仮定する．1 つの BD 端末から発生する信号の発生頻度 F を次

```
{
  "timestamp": 1628662870,
  "lat": 34.693779,
  "lng": 135.782786,
  "ble": [
        {
            "addr": "72:12:4f:67:44:92",
            "rssi": -54
        },
        {
            "addr": "1a:b0:4f:e5:94:e4",
            "rssi": -87
        },
    ],
}
```

図 3　スキャンデータの例

表 1　正解データの例

Time	出発駅	到着駅	運行種別	車両番号	乗車人数
15:13	近鉄奈良駅	新大宮駅	普通	3	33
15:15	新大宮駅	大和西大寺駅	普通	3	38
15:21	大和西大寺駅	学園前駅	急行	5	47
15:25	学園前駅	生駒駅	急行	5	49
15:32	生駒駅	石切駅	急行	5	38
15:36	石切駅	布施	急行	5	35

式に従って計算する．

$$F(\%) = \frac{n_{detected}}{N_{scan}} \times 100 \tag{1}$$

ここで，N_{scan} は区間の総検出数を表し，$n_{detected}$ は同じ BD アドレスが検出された回数である．また，区間内で i 番目にスキャンしたときの RSSI を $S(i)$ とし，区間の平均信号強度 (RSSI) を式 2 で表す．

$$S_{mean} = \frac{1}{n_{detected}} \sum_{i=1}^{n_{detected}} S(i) \tag{2}$$

我々は，以上の式 1, 2 で求めた値を用いて，一定のしきい値以上の値を持つ BD アドレスの数を区間の特徴量として導入する．

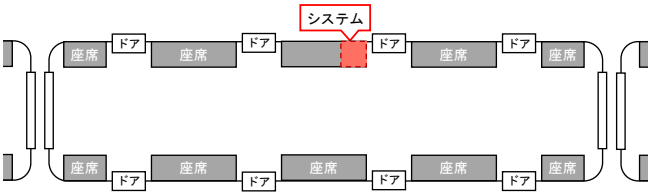

図 4　電車車両内におけるシステムの設置位置

4.　データ収集と推定結果

4.1　実験環境

我々は 3. 章で述べたシステムを用いて，近鉄日本鉄道株式会社協力のもと，実際に運行されている電車で BLE データを収集した．データ収集実験は，2021 年の 8 月 13 日の午後 1 時から午後 7 時まで実施され，1 つの路線で 381 区間（重複有り）のデータを集めた．また，実際の電車で実験するために，(1) 車両からの電源供給がないこと，(2) センシングデバイスを設置できないことの 2 つの制約が存在した．そこで，調査員はデバイスとモバイルバッテリーを持ち運んでデータを収集するとともに，目視で乗客数を確認した．図 4 に示すように，車両の中央に着席し，各車内を見渡しやすい位置にデバイスを設置した．

4.2　評価方法

我々は 4. 1 節で収集したデータを用いて，区間ごとの乗車人数を推定する．推定には，BLE 信号のしきい値による手法と，機械学習の回帰モデルによる手法を適用する．

4.2.1　しきい値による推定

3. 3 節で述べたとおり，各区間で検出した全ての BD アドレスに対して，平均 RSSI S_{mean} と出現頻度 F を計算する．そして，一定のしきい値以上の S_{mean} と F を持つ 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設定する．

4.2.2　回帰モデルを用いた推定

表 2 に機械学習で用いる特徴量を示す．BD アドレスの平均 RSSI や出現頻度は，対象となる BD アドレスが車内に存在することを示す重要な指標になると考える．そこで，S_{mean} と F に対して 5 刻みでしきい値を設定したときの BD アドレス数を特徴量 (ID:1) に加えた．また，システムが収集した区間の移動時間は，平均 RSSI と出現頻度の値に影響を与えると考えられるため，区間ごとのスキャン回数を特徴量に加えた (ID:2)．加えて，電車の運行時刻や運行形態などの情報には，通勤ラッシュや乗り換えといった，混雑度を推定するために重要な情報を含んでいると考えられる．そこで，電車特有の情報を特徴量に含めた (ID:3,4,5,6,7).

本研究では，各データセットごとの結果を比較するために，BLE の特徴量 (ID:1,2) を含むデータセット (TD:Train Dataset) と，全ての特徴量を含むデータセット (TD^+) を構築する．これらのデータセットに対して，回帰モデルのランダムフォレスト (RF) と LightGBM(LGBM) を用いて，1 区間の乗車人数を推定する．推定結果は Leave-one-out cross-validation で評価し，各モデルのハイパーパラメータの調整には Optuna Framework を用いた [22].

表 2　特徴量の一覧

ドメイン	id	特徴量
BLE	1	BD アドレスの数 [1]
	2	区間でのスキャン回数
Train	3	出発時刻
	4	運行形態
	5	出発駅
	6	到着駅
	7	車両番号

[1] しきい値を S_{means} は-30〜-100，F は 0〜100 の範囲で段階的に設定している

4.3　結　　果

4.3.1　しきい値による推定

まず，しきい値を設定せず，区間で得られた BD アドレスの総数を乗車人数としてみなしたときの結果について説明する．図 5 には，縦軸に BD アドレスの総数 (Estimated Value)，横軸に乗車人数 (真値）をプロットしたグラフを示す．なお，グラフ中の青直線は真値と推定値の誤差がないときの理想状態を表す．グラフより，実際の乗車人数に対して BD アドレスの総数は極めて大きいことがわかる．また，区間ごとに真値と推定値の絶対誤差を算出し，全区間の総数で平均した平均絶対誤差 (MAE) と平均絶対誤差率 (MAPE) を求めた．結果として，MAE が 283.98 人，MAPE が 13.67 となった（表 3).

次に BD アドレスの平均 RSSI S_{mean} と出現頻度 F にしきい値を設定して推定した結果を説明する．適切なしきい値を設定したときの MAE と MAPE を表 3 に示し，図 6 に，真値と推定値（有効な BD アドレス数）をプロットしたグラフを示す．ここで，しきい値は経験的に得られた値を設定している．表 3 より，しきい値を用いて推定することで MAE と MAPE が小さくなり，より正確に乗車人数を推定できることがわかる．また，図 6 に，真値と推定値（有効な BD アドレス数）をプロットしたグラフを示す．しきい値なしで推定した結果（図 5）と比べると，より真値に近い推定ができることがわかる．その一方で，真値が 50 人以上の区間において推定精度が低い傾向が確認できる．

4.3.2　回帰モデルによる推定

表 4 に交差検証したときの MAE と MAPE を示す．TD^+ を用いたモデルが最も良いパフォーマンスを達成し，RF の MAE が 5.85 人，MAPE は 0.28，LGBM では MAE が 5.56 人，MAPE が 0.27 となった．図 7 に，TD^+ を用いた LGBM で推定したときの真値と推定値をプロットしたグラフを示し，図 8 に特徴量

表 3　しきい値による推定結果

手法	MAE	MAPE
ALL BD Addresses	283.98	13.67
$S_{mean} \geq -50$	9.29	0.33
$S_{mean} \geq -55 \cap F \geq 40$	**7.27**	**0.27**

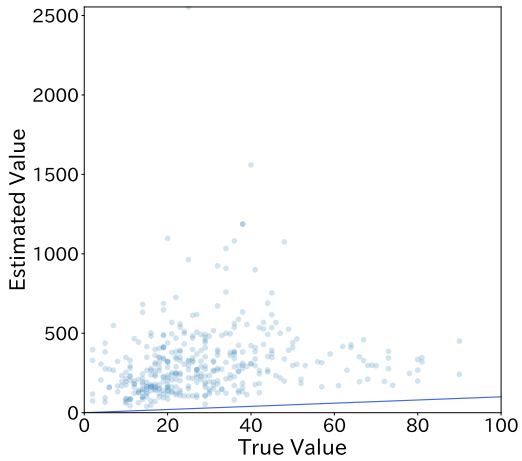

図 5　BD アドレスのカウントによる計測値 vs 真値（実際の乗車人数）

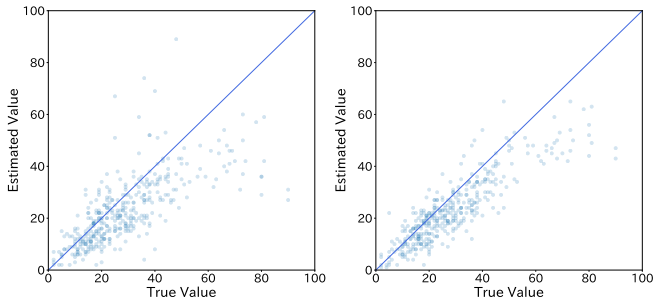

(a) $S_{mean} \geq -50$　　(b) $S_{mean} \geq -55 \cap F \geq 40$

図 6　推定値 (BD アドレスの数) vs 真値 (乗車人数)

表 4　各データセットに対する各モデルの推定精度

	TD		TD$^+$	
モデル	MAE	MAPE	MAE	MAPE
RF	5.96	0.28	5.85	0.28
LGBM	6.07	0.29	**5.56**	**0.27**

の重要度を示す．乗車人数の推定に寄与する特徴量として，特に出現頻度 (add_fre_x) に関する特徴量が最も重要度が高いことが明らかになった．

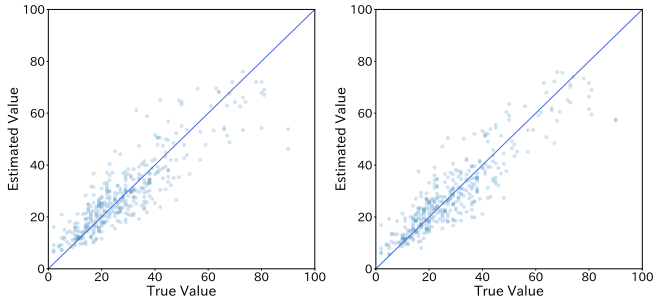

(a) TD　　(b) TD$^+$

図 7　LGBM による推定値 vs 真値（乗車人数）

5. 考　　察

図 5 より，しきい値を設定せずに，区間で検出した BD アドレスの総数は，真値と比べて大幅に超えていることが得られる．原因として，偶然スキャンした端末の信号を含んでいることや，1 人の乗客が複数の端末を所持していることが考えられる．この問題に対して，BLE の信号値の平均 RSSI と出現頻度に適切なしきい値を設定することで，図 6 に示すように推定精度を大幅に向上できた．

一方で，しきい値による推定は，図 6(b) のように，乗車人数が多い区間において推定値が真値下回る傾向が確認できる．これは，乗客の乗り降りや列車の停車に伴って，車両外部の端末信号を含んでいることが考えられる．そこで，車両ごとの乗車人数を推定するために，BLE に関する特徴量の他に電車特有の特徴量を含めることで精度の向上を図った．結果として，MAPE は同一であったものの MAE を 5.56 と精度を向上できた．．また，しきい値による推定では事前に適切な値を設定する必要があるが，回帰モデルを用いた推定では，適切なしきい値を設定する必要がなくなる．

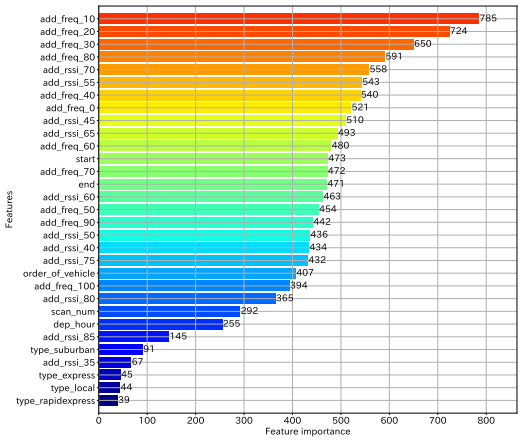

図 8　特徴量重要度

また，TD$^+$ で最も良い精度を示した LGBM の特徴量を図 8 に示す．図より，最も良い精度を示したモデルにおける特徴量の重要度は，10〜30% の比較的小さな頻度値に関する特徴量の値が高いことがわかる．デバイスが BLE 端末の信号を検出するとき，近くの端末の信号は高い RSSI 値・頻度で検知できるが，遠い端末の信号は低い RSSI・少ない頻度でのみ検知できる．そのため，小さい頻度値は，遠い端末の信号の判定に大きく寄与したと考えられる．

6. 結　　論

本稿では，実際に運行している電車から BLE データを収集し，乗客のプライバシーを保護しつつ乗車人数を推定した．車内に存在する端末の数や，複数台の BLE 端末を所持する乗客に対応するため，BLE データにしきい値を設定する推定の手法や，機械学習モデルを用いて乗車人数を推定する手法を適用した．結果として，MAE が約 5.56 人，MAPE が 0.27 の精度で推定できることが明らかになった．

今後の課題としては，追加のデータを収集することが挙げられる．今回の実験環境においては 13 時から 19 時までのデータのみしか存在せず，朝の通勤ラッシュの時間帯を含んでいない．

我々のシステムを実運用化させるにあたり，様々な条件下でのデータを収集し，高い精度を目指す必要があると考える．

また，乗客のプライバシー保護を考慮する必要がある．本研究では BLE のアドレスを用いることで，動画像を用いた混雑推定よりも乗客のプライバシーを保護できることを目指した．しかしながら，BLE データに含まれるアドレスを詳細に解析すると，個人の特定が出来る可能性がある．そのため，特徴量構築が完了次第，収集した BLE データを破棄するといった，よりプライバシーを考慮したシステムの設計が必要となる．

謝　　辞

この研究の一部は，科学技術振興機構（JST）の戦略的創造研究推進事業さきがけ 採択課題番号 JPMJPR2039 の助成を受けて実施されています．また，本研究の実施にあたり，近畿日本鉄道株式会社にご協力を賜りました．ここに感謝の意を申し上げます．

文　　献

[1] D. vanLierop, M.G. Badami, and A.M. El-Geneidy, “What influences satisfaction and loyalty in public transport? a review of the literature,” Transport Reviews, vol.38, no.1, pp.52–72, 2018.

[2] W.H. Organization, “Coronavirus disease (covid-19) pandemic.”. Accessed: 2021-12-01. https://www.who.int/emergencies/diseases/novel-coronavirus-2019

[3] Y. Kanamitsu, E. Taya, K. Tachibana, Y. Nakamura, Y. Matsuda, H. Suwa, and K. Yasumoto, “Estimating congestion in a fixed-route bus by using ble signals,” Sensors, vol.22, no.3, pp.1–15, 2022. https://www.mdpi.com/1424-8220/22/3/881

[4] H. Song, X. Liu, X. Zhang, and J. Hu, “Real-time monitoring for crowd counting using video surveillance and gis,” 2012 2nd International Conference on Remote Sensing, Environment and Transportation EngineeringIEEE, pp.1–4 2012.

[5] H. Takayanagi, T. Sano, and H. Watanabe, “A study on the pedestrian occupied territory in the crossing flow: The analysis with pedestrian territory model,” Journal of Architecture and Planning (Transactions of AIJ), vol.66, no.549, pp.185–191, 2001.

[6] H. Su, H. Yang, and S. Zheng, “The large-scale crowd density estimation based on effective region feature extraction method,” Asian Conference on Computer VisionSpringer, pp.302–313 2010.

[7] M. Handte, S. Foell, S. Wagner, G. Kortuem, and P.J. Marrón, “An internet-of-things enabled connected navigation system for urban bus riders,” IEEE internet of things journal, vol.3, no.5, pp.735–744, 2016.

[8] S. Jackson, A. Lesani, and L. Miranda-Moreno, “Toward a wifi system for traffic monitoring in different transportation facilities,” 2014.

[9] A. Hidayat, S. Terabe, and H. Yaginuma, “Wifi scanner technologies for obtaining travel data about circulator bus passengers: case study in obuse, nagano prefecture, japan,” Transportation Research Record, vol.2672, no.45, pp.45–54, 2018.

[10] A. Hidayat, S. Terabe, and H. Yaginuma, “Estimating bus passenger volume based on a wi-fi scanner survey,” Transportation Research Interdisciplinary Perspectives, vol.6, p.100142, 2020. https://www.sciencedirect.com/science/article/pii/S2590198220300531

[11] D. Bauer, M. Ray, and S. Seer, “Simple sensors used for measuring service times and counting pedestrians: strengths and weaknesses,” Transportation research record, vol.2214, no.1, pp.77–84, 2011.

[12] H.-b. Qian and H. Han, “The applications and methods of pedestrian automated detection,” 2010 International Conference on Measuring Technology and Mechatronics Automation, vol.3, pp.806–809, 2010.

[13] H. Yang, K. Ozbay, and A. Bartin, “Investigating the performance of automatic counting sensors for pedestrian traffic data collection,” 2010.

[14] R. Greene-Roesel, M.C. Diogenes, D.R. Ragland, and L.A. Lindau, “Effectiveness of a commercially available automated pedestrian counting device in urban environments: Comparison with manual counts,” 2008.

[15] U. Scheunert, H. Cramer, B. Fardi, and G. Wanielik, “Multi sensor based tracking of pedestrians: a survey of suitable movement models,” IEEE Intelligent Vehicles Symposium, 2004, pp.774–778, 2004.

[16] L. Schauer, M. Werner, and P. Marcus, “Estimating crowd densities and pedestrian flows using wi-fi and bluetooth,” Proceedings of the 11th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services, p.171–177, MOBIQUITOUS ’14, ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), Brussels, BEL, 2014. https://doi.org/10.4108/icst.mobiquitous.2014.257870

[17] A. Lesani and L. Miranda-Moreno, “Development and testing of a real-time wifi-bluetooth system for pedestrian network monitoring, classification, and data extrapolation,” IEEE Transactions on Intelligent Transportation Systems, vol.20, no.4, pp.1484–1496, 2018.

[18] K. Umeki, Y. Nakamura, M. Fujimoto, Y. Arakawa, and K. Yasumoto, “Real-time congestion estimation in sightseeing spots with ble devices,” 2018 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)IEEE, pp.430–432 2018.

[19] J. Weppner and P. Lukowicz, “Bluetooth based collaborative crowd density estimation with mobile phones,” 2013 IEEE international conference on pervasive computing and communications (PerCom)IEEE, pp.193–200 2013.

[20] V. Kostakos, T. Camacho, and C. Mantero, “Towards proximity-based passenger sensing on public transport buses,” Personal and ubiquitous computing, vol.17, no.8, pp.1807–1816, 2013.

[21] J. Weppner and P. Lukowicz, “Collaborative crowd density estimation with mobile phones,” 2011.

[22] T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama, “Optuna: A next-generation hyperparameter optimization framework,” Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, p.2623–2631, KDD ’19, Association for Computing Machinery, New York, NY, USA, 2019.