

BLEを用いたバスのリアルタイム乗車人数推定手法の提案と評価

Proposal and Evaluation of a Real-Time Bus Ridership Estimation Method Using BLE

後藤 逸兵^{1*} 上田 健太郎¹ 佐瀬 凌太¹
Ippei Goto¹ Kentaro Ueda¹ Ryota Saze¹
松田 裕貴^{1,2} 諏訪 博彦^{1,2} 安本 慶一^{1,2}
Yuki Matsuda^{1,2} Hirohiko Suwa^{1,2} Keiichi Yasumoto^{1,2}

¹ 奈良先端科学技術大学院大学

¹ Nara Institute of Science and Technology

² 理化学研究所 革新知能統合研究センター

² RIKEN Center for Advanced Intelligence Project

Abstract: Buses are one of the main modes of transportation and have become an integral part of our daily lives. On the other hand, studies have shown that public transportation users are concerned about the level of bus congestion. It has also been shown that passengers may choose to wait for the next bus if they know how crowded the current bus is. In other words, bus congestion, or the number of passengers on a bus, is valuable information. A camera-based method of counting the number of people getting on and off a bus is a possible method of estimating the level of congestion in a bus, but it is difficult to adapt this method to existing buses given the limitations of installation locations, and camera-based methods are not desirable given the privacy of the passengers. Therefore, this paper proposes a method to estimate the number of passengers on a bus by sensing BLE (Bluetooth Low Energy) radio waves emitted from electronic devices such as smartphones that people own, while considering passenger privacy. Experimental data was collected over a six-month period from January to June 2022 with the cooperation of Nara Kotsu Co. In the proposed method, features were created based on the continuity of BLE addresses, frequency of occurrence, interval of occurrence, and magnitude of RSSI, and were trained with regression models such as Ridge regression and LightGBM. The results show that the proposed method can estimate the mean absolute error (MAE), mean absolute percentage error (MAPE), and root mean squared error (RMSE) with an accuracy of 3.69, 5.08, and 0.51 respectively.

1 はじめに

令和元年度の国内輸送機関別の旅客輸送人員をみると、総輸送人員は 311 億 72 百万人であった。その内訳をみると、民鉄は 156 億 17 百万人、JR は 95 億 3 百万人、バスは 45 億 33 百万人の順になっている。つまりバスは我が国の主要な交通機関の一つであると言える。日本だけではなく、世界にも多くのバスの利用者が存在している。実際、欧州諸国では、バスは最も広く利用されている公共交通機関であり、都市部だけでなく、郊外や農村部でも利用されており、バスは低所得者を含むすべての人に教育、雇用、医療へのアクセスを提供し、社会的包摂のために重要な存在となっている。道路を走る 30 台の自家用車をバス 1 台に置き換えることで交通渋滞を緩和することが出来る上、二酸化炭素の排出量を削減も可能である [1]。また、バスは観光客に地元の観光名所や風景を見せるなど、観光産業において大きな役割を担っている。

一方、バスの利用者は、車内の混雑度合いを気にしているという研究結果がある [2, 3]。乗客は、現在のバスの車内の混雑状況を知りたいれば、次のバスを待つことを選択する可能性があることも示されている [2]。さらに、車内の混雑状況の情報（「混んでいる」「普通」「空席あり」など）は、乗客の旅行選択行動に影響を与えることが分かっている [3]。つまり、バスの乗車人数を事前に把握することによって、乗客は混雑を避ける

*連絡先：奈良先端科学技術大学院大学
〒 630-0192 奈良県生駒市高山町 8916 番地-5
E-mail: goto.ippei.gi4@is.naist.jp



図 1: ぐるっとバスのルート (<http://www.nara-access-navi.com/route/> より引用)

ことができる所以ユーザ体験の向上が期待できる。メリットは乗客のみならず、事業会社はバスの乗車人数を計測することで、バスの本数調整、運行時間の変更、路線の最適化など、サービスの品質と信頼性を向上させ、より多くの乗客を公共交通機関に引きつけることができるようになる。このように、バスの乗車人数を推定するシステムは利用者、事業者双方にメリットが存在している。これらの情報を提供するためには、事前にバスの乗車人数を取得する必要がある。現在運行しているすべてのバスの乗車人数を手動で記録することは現実的な方法ではないため、自動的に乗車人数を推定し取得するシステムが必要である。ICカードなどの情報を利用すれば、特定の路線のバス利用者数を把握することは容易に可能であるが、郊外や人口が少ない地域ではICカードシステムが導入されていないことが多い、定期券利用者や現金払いの利用者が含まれないなど、乗車人数の情報としては問題がある。そこで近年のコンピュータの計算能力の向上やコンピュータビジョン技術の進歩に伴い、画像に基づく人物計数法が継続的に提案されている[4, 5, 6]。しかし、設置場所の制約を考えると既存のバスに適応するのは難しい上、乗客のプライバシーを考えるとカメラベースの手法は好ましくない。近年、スマートフォン、タブレット、ウェアラブルデバイスは広く普及しており、それらはすでに豊富なセンサーを備えているため、優れた情報源となる[7]。中でも WiFi や Bluetooth などの無線通信技術が広く採用されており、群集行動や群集密度推定において注目されている[8]。BLE 信号から取得できる Bluetooth デバイス (BD) アドレスはセキュリティの観点から 10 分から 20 分ごとに変更されるため、プライバシー侵害の心配はほとんどない。また、BLE 信号は、特別なセンサーを必要とせず、RaspberryPi などの安価

で軽量なシングルボードコンピューター 1 台で受信でき、設置場所の制限もない。さらに、BLE 信号を受信できる機器がすでにバス上に存在する場合は、ソフトウェアをインストールするだけでシステムを実現が可能である。

そこで本研究では、路線バスの乗客の携帯端末からの BLE 信号を検出し、得られた BLE 信号のアドレス、RSSI を元に特徴量を作成し、機械学習モデルを用いてバスの乗客数を推定する方法について検討する。本手法の妥当性を示すため奈良交通株式会社¹の協力を得て、営業バスを対象としたデータ収集実験を行った。収集したデータから推定した乗客数は平均絶対誤差 (MAE) 3.70、平均絶対割合誤差 (MAPE) 0.51、二乗平均平方根誤差 (RMSE) 5.09 という結果になり、バスの乗客数推定が可能であることが示された。

2 関連研究

2.1 バスの乗客数の推定

バスの乗客数予測に関連した様々な研究が提案されている。Wood らはバスの運行状況 (APC) や気象情報などからリアルタイムに得られるデータを用いて、個々のバスが将来の停留所に到着したときの乗客の占有率を予測するために、従来の線形回帰モデルと機械学習 (ランダムフォレスト) モデルを使用し乗員数の予測を行なった[9]。Irene らはバス路線内の多数の停留所をクラスタに分割し、各クラスタに対して指標平滑化や ARIMA (自己回帰統合移動平均) 等の異なるモデルを当てはめることを提案した。さらに、サポートベクター

¹<https://www.narakotsu.co.jp/>

マシンや RNN などの機械学習法を用いて、予測精度を向上させることを提案している [10]。Liyanage らはスマートカードチケットシステムのデータを元に旅行需要の時間的特性を考慮した LSTM と BiLSTM のディープラーニングモデルを評価を行なった [11]。これらの方法は、バスの移動時間や乗客数を正確に予測することが期待できるものの、過去のトレンドと異なるトレンドや乗客数の一時的な上昇に対応しにくいと考えられる。そこでカメラを用いて乗客数を推定する方法が提案されている [4, 5, 6]。Hsu らは、バスに設置したカメラの映像データの中で乗客を表さないすべてのオブジェクトをフィルタリングし、畳み込みオートエンコーダ (CAE) を用いてバスの乗客数をカウントするシステムを提案している [4]。このようなカメラを用いたシステムは、より正確な乗客数の推定を可能とするが、システムの設置・運用コストが高く、その上プライバシー侵害の恐れがあるため、ローカルバスへの導入は容易ではない。

2.2 BLE を用いた混雑度推定・人流解析

スマートフォンの普及に伴い、Bluetooth Low Energy (BLE) や Wi-Fi を用いた混雑状況センシングについていくつかの研究が行われている。Lorenz らは大規模空港から提供されたデータを用いて、Wi-Fi と Bluetooth を使用し歩行者流量の推定を行なった [12]。単純にアドレス数を数えるだけではなく、BLE や Wi-Fi の MAC アドレスと RSSI を組み合わせた方法で、より正確なカウンティングを可能とした。梅木らは、人数の多寡によって大きく変化する RSSI 強度に着目し、観光地に設置した BLE デバイスで RSSI 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た [13]。また、Weppner らは、監視環境内を移動する近傍のユーザ携帯型 BLE 端末から検出される移動信号の数を集計することで群集密度を推定する方法を提案している [14, 15]。新たにセンサを設置せずにすむため、コスト面の課題はクリアしているものの、推定精度がセンシングに参加するユーザ数に依存するため、ユーザの閥与を促す仕組みが必要である。徳田らはスマートフォンやノートパソコンから送信される WiFi Probe Request メッセージや BLE 露出通知メッセージの数をカウントすることで、様々な対象地点の人数を正確に推定する自動パラメータ調整器を採用した混雑度計測システムの提案を行なった [16]。BLE を用いた公共交通機関の混雑度推定を行う研究も行われており、金光らはバス、田谷らは電車で乗客の携帯端末から発信される BLE 信号をセンシングデータとして利用したバスの混雑度予測システムの提案をおこなっている [17, 18]。この手法は、乗客のプライバシーを保護し、

設置コストを削減することができる。しかし、これらの研究はバス停間全てのデータを使用して乗客数の予測を行なっているので、リアルタイムな予測とは言えない。

2.3 本研究の立ち位置

このように、乗客数の推定に関する研究は数多く存在するが、プライバシー保護が確保され、かつ交通システムで実用化できるものは少ない。これに対し、本論文では、乗客のプライバシーを保護できる BLE 信号を用いたバス用混雑度推定システムを提案する。先行研究ではデータの期間が 1 日と短い上に、停車位置間全てのデータを使用して乗客数の予測を行なっているので、リアルタイムな予測とは言えない [17, 18]。そのため、交通機関の利用者が乗降する直前に車内的人数を知ることができるシステムとなっている。そこで本研究では、先行研究と比較して長期間である 6 ヶ月分のデータを用いて提案手法の有効性を確認し、バスがバス停を出発してから BLE ビーコンが一定回数スキャンするまでの乗車人数予測を行うことによって事前にバス内的人数を利用者に知らせることができるようなシステムの構築を目指す。

3 実験環境と提案手法

3.1 実験データ

提案手法の有効性を評価するため、奈良交通株式会社の協力のもと、2022 年の 1 月から 6 月まで実際のバスを使ったデータ収集実験を行なった。データ収集はぐるっとバス（図 1）で行われた。ぐるっとバスの座席数は 11、最大乗車定員 35 人である。BLE ビーコンは、バスの前方に設置されており、15 秒間隔で周囲の BLE デバイスのスキャンが行なっている。データの収集自体は午前 7 時から午後 18 時まで行われているが、ぐるっとバスの運行時間は午前 9 時から午後 17 時であるので、収集したデータには運行外のデータも含まれている。奈良交通から提供された各停留所間データセットには、停留所からの出発時刻、BD アドレスの総数、乗客数などが含まれている。乗客数のカウントは奈良交通株式会社が独自の方法でを行っており必ずしも正確とは言えない。そのため、正解ラベルが 35 を超えたデータをノイズデータとして扱っている。BLE データとバス停データの紐付けは、GPS から取得した位置情報、取得時間とともに実験を行なった。

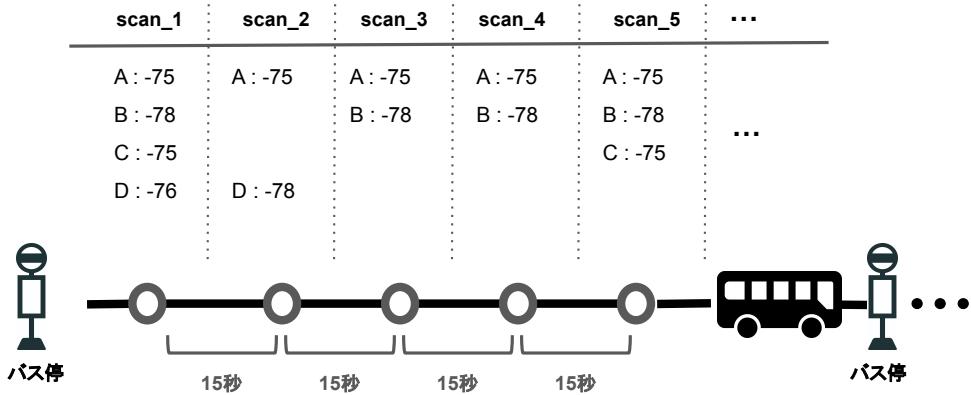


図 2: スキャンのプロセス

BD アドレス	アドレスの出現頻度	RSSI の平均値	最大の出現間隔
A	1	-75	0
B	0.8	-78	1
C	0.2	-75	3
D	0.2	-77	0

表 1: scan_5 地点でのセンシングデータ例

3.2 特徴量抽出

BD アドレスはプライバシー保護のために一般に 10 分から 20 分の間に変更される。そのため過去 10 分までにスキャンされた BLE データが有効であると考えられる。つまり、本研究で使用した BLE ビーコンは 15 秒おきにスキャンが行われるので、過去 40 スキャン分のデータを使用し特徴量を作成することができる。本研究ではこの過去 40 スキャン分を用いて作成した特徴量を、 $window_size = 40$ で作成した特徴量と呼ぶ。 $window_size = 40$ で作成した特徴量は大局的な特量を掴むことができると考えられる。一方、バス停で乗り降りが発生し、新たな BLE アドレスがスキャンされる際に $window_size = 40$ のデータで考えるとその影響は小さくなる。そこで本研究では大局的な $window_size = 40$ に対して局所的な $window_size = 5$ を使用することによってバス停での乗降に対応した特徴量の作成を狙う。

3.2.1 出現頻度

バスは移動を行うので、本システムが 1 回のスキャンで収集する BLE データには、車外の端末からの信号が頻繁に含まれている可能性がある。そのため、BD アドレスの出現頻度を計算することでロバストな特徴量の作成が可能であると考えた。したがって、 $window_size$ の中で、1 台の BD 端末が出現する頻度 F は、以下のように算出される。

$$F = \frac{N_{detected}}{window_size} \quad (1)$$

ここで、 $window_size$ は特徴量を作成する際の幅、 $N_{detected}$ は $window_size$ 内で同じ BD アドレスが検出された回数であり、前述したように $window_size = 5, 40$ を用いている。本研究では出現頻度に閾値を設け、閾値以上のアドレスの数のカウントを行なった。閾値は 0.5, 0.75, 1 の 3 つを用いた。図 2 にスキャンのプロセス例を示し、表 1 に図 2 のスキャンを元に作成した特徴量を示す。 $window_size = 5$ で考えると、アドレス A はバス停から発車後 5 スキャン内で 5 回検出されているので、出現頻度は 1 となる。一方、アドレス D は発車後 2 スキャン目までしか検出されないので出現頻度は 0.4 となる。この場合、アドレス D はバス停付近の車外端末からの信号であったと考えられる。

3.2.2 最大出現間隔 (MAI)

前節でアドレスの出現頻度を計算し、カウントすることでロバストな特徴量を作成した。しかし、図 2 を見ると、アドレス D とアドレス C は出現頻度でみると同じ 0.4 であるが、出現する間隔は異なっている。実際アドレス D はバス停付近の 2 スキャンに出現したのに対して、アドレス C は $scan_1$ 、 $scan_5$ と時間的な間隔をあけて出現している。その場合、同じ出現頻度 0.4 でも後者のアドレスの方がバスの乗客の BD アドレスである可能性が高いと考えられる。つまり、アドレスの

Algorithm 1 Max Appearance Interval (MAI)

Input: Bluetooth Device Address Set S , RSSI History Data $h_{addr,n}$ $addr \in S, n = 1..window_size$

Output: Max Appearance Interval $MAI_{addr}, addr \in S$

```
1: for each address  $S_{addr}$  do
2:   initialization; appearance_intervals
3:   for  $n = 1$  to  $window\_size$  do
4:     if  $h_{addr,n} = 0$ ; then
         interval += 1;
5:     else
         appearance_intervals append interval;
         interval = 0;
6:   end if
7: end for
8:  $MAI_{addr} = \max(\text{appearance}_\text{intervals})$ 
9: end for
```

出現する間隔も一つの重要な特徴量であると考えられる。各スキャンごとの最大出現間隔 (MAI) をアルゴリズム 1 に示す。本研究では MAI の閾値に関するパラメータ $time_window = 5$ では、2, 3 を $time_window = 40$ では 8, 18, 28, 38 を使用し、閾値以上の BD アドレスをカウントし特徴量として作成した。

3.2.3 平均 RSSI

RSSI の閾値を適切に選択することで、車外デバイスのフィルタリングをすることが可能である。そこで、 $window_size$ 内での平均 RSSI は以下のように算出される。

$$RSSI_mean = \frac{1}{N_{detected}} \sum_{i=1}^{N_{detected}} S(i) \quad (2)$$

ここで $N_{detected}$ とは $window_size$ 内であるアドレスが観測された数である。しかし、アンテナやデバイスによって RF 特性が異なるので、ビーコン/デバイスが互いに同一でない限り、位置が同じでも RSSI の読み取り値が同じになることは期待できないため最適かつ絶対的な閾値を見つけることは困難である。そこで閾値として -75, -70, -65 の 3 つを用いた。

3.2.4 路線情報

全ての人が BLE デバイスを持っているわけではなく、人によっては複数個持っている可能性もある。路線情報を使用することで BLE データのみを使用した場合と比べて、より正確な推定が可能であると考えられる。本研究では路線情報としてバス停名、曜日、時間、土地利

用詳細メッシュデータ²を使用した。土地利用詳細メッシュデータとは土地利用の状況について、3 次メッシュ 1/20 細分区画 (50m メッシュ) 每に、各利用区分 (田、その他の農用地、森林、荒地、建物用地、幹線交通用地、湖沼、河川等) を整備したものである。

3.3 分析モデルと評価方法

前述の特徴量を用いた乗客数推定モデルを構築し、評価を行う。train データには 1 月から 3 月のものを使用し、test データに 4 月から 6 月のものを使用した。乗客数の予測は、バス停に着いてから 5 スキャンでおこなった。当然バス停間に 5 スキャン分のデータが含まれていない場合もあるので、その場合は存在するデータのみで評価を行っている。使用する機械学習モデルは、RR (Ridge Regression), LGBMR (LightGBM Regressor) [19], ENS (LGBMR と RR のアンサンブルモデル) の 3 種類を用い、各モデルのハイパーパラメータは Optuna [20] にて最適化したものを利用した。アンサンブルの方法は RR と LGBMR の予測結果に対して 0.5 を掛け足し合わせている。評価指標には MAE (MeanAbsoluteError), MAPE (Mean Absolute Percentage Error), RMSE (Root Mean Squared Error) を使用した。ただし、本実験で使用する乗客数の正解データに 0 が含まれているため、MAPE を計算する際に 0 除算が生じてしまうので、乗客数の正解データとモデルの予測に 1 を足すことで 0 除算を回避している。

4 結果

結果を表 2 に示す。全ての指標においてアンサンブルモデルが比較的高い性能を示す結果となった。各バス停の scan_3 地点について LGBMR で予測を行なった結果 (正解ラベルと予測結果の散布図) を図 3 に示す。散布図を見ると人数のおおまかな傾向は捉えれていることがわかる。しかし、正解ラベルが大きい (乗車人が多い) 場合には人数を少なく見積もってしまう傾向が見て取れる。これは、信号の減衰に問題がある。Bluetooth の送信周波数である 2.4GHz では、人体の吸収係数が高く、車内が混雑した環境では、人体によって信号が減衰し、一部の端末からの信号が検出できないことが想定される。特に、今回の実験では、車内の前方付近に端末を設置したため、車内後方の乗客の端末を検出することが困難となっていると考えられる scan 回数で考えると scan_2, 3 が比較的高い性能を示している。直感的にはスキャン回数が増える (バス停から離れ

²https://nlftp.mlit.go.jp/ksj/gml/datalist/KsjTmplt-L03-b-c-v3_1.html

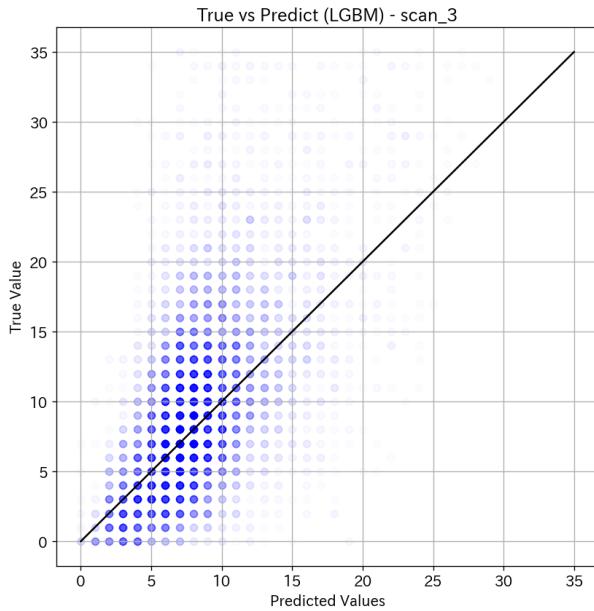


図 3: scan_3 地点での結果

る)について、モデルの精度は向上するように思えるが、今回の結果ではそのような傾向は見られなかった。

5 おわりに

本研究では、乗客のプライバシー保護と導入コスト削減のために、人々が持つスマートフォンなどの電子機器から発されるBLE信号をセンシングデータとして利用したバス路線の混雑度推定システムを提案し評価を行なった。結果として、路線情報、BLE信号のアドレス、RSSIを元に作成した特徴量を使用したモデルで、一定の乗客数の推定が可能であることが示された。しかし、混雑時でも乗客のBLE端末を正確に取得できない、といった課題が浮き彫りになった。これらの課題をふまえ、より有効な特徴量抽出、センシング方法について模索し実際に運用可能なモデルの作成を目指す。

謝辞

本研究の一部は、JST さきがけ (JPMJPR2039) の助成を受けて行われたものです。

参考文献

- [1] IEA (International Energy Agency). *Changes in transport behaviour during the Covid-19 crisis.* 2020. <https://www.iea.org/articles/changes-in-transport-behaviour-during-the-covid-19-crisis>

表 2: 実験結果

スキャン	モデル	MAE	RMSE	MAPE
1	RR	3.82	5.27	0.54
	LGBMR	3.76	5.22	0.51
	ENS	3.70	5.09	0.54
2	RR	3.82	5.28	0.54
	LGBMR	3.73	5.20	0.51
	ENS	3.69	5.08	0.54
3	RR	3.83	5.31	0.54
	LGBMR	3.73	5.19	0.51
	ENS	3.69	5.08	0.54
4	RR	3.83	5.28	0.54
	LGBMR	3.76	5.23	0.51
	ENS	3.70	5.10	0.54
5	RR	3.84	5.30	0.54
	LGBMR	3.78	5.27	0.51
	ENS	3.72	5.14	0.54

nges-in-transport-behaviour-during-the-covid-19-crisis.

- [2] Shi An Duo Zhang Fan Wu, Xiaowei Hu. "Exploring Passengers' Travel Behaviors Based on Elaboration Likelihood Model under the Impact of Intelligent Bus Information". *Journal of Advanced Transportation*, Vol. 2019, p. 12, 2019.
- [3] Arkadiusz Drabicki, Rafał Kucharski, Oded Cats, and Andrzej Szarata. Modelling the effects of real-time crowding information in urban public transport systems. *Transportmetrica A: Transport Science*, Vol. 17, No. 4, pp. 675–713, 2021.
- [4] Ya-Wen Hsu, Yen-Wei Chen, and Jau-Woei Perng. Estimation of the Number of Passengers in a Bus Using Deep Learning. *Sensors*, Vol. 20, No. 8:2178, 2020.
- [5] Guojin Liu, Zhenzhi Yin, Yunjian Jia, and Yulai Xie. Passenger Flow Estimation Based on Convolutional Neural Network in Public Transportation System. *Knowledge-Based Systems*, Vol. 123, No. C, pp. 102–115, 2017.
- [6] Tao Yang, Yanning Zhang, Dapei Shao, and Ying Li. Clustering method for counting passengers getting in a bus with single camera. *Optical Engineering*, Vol. 49, No. 3, p. 037203, 2010.
- [7] Andrea Capponi, Claudio Fiandrino, Burak Kantarci, Luca Foschini, Dzmitry Kliazovich, and Pascal Bouvry. A Survey on Mobile Crowdsensing Systems:

- Challenges, Solutions, and Opportunities. *IEEE Communications Surveys Tutorials*, Vol. 21, No. 3, pp. 2419–2465, 2019.
- [8] Adriana Draghici and Maarten Van Steen. A Survey of Techniques for Automatically Sensing the Behavior of a Crowd. *ACM Comput. Surv.*, Vol. 51, No. 1, pp. 1–40, 2018.
- [9] Jonathan Wood, Zhengyao Yu, and Vikash V. Gayah. Development and evaluation of frameworks for real-time bus passenger occupancy prediction. *International Journal of Transportation Science and Technology*, pp. 1–15, 2022. In Press.
- [10] Irene Mariñas-Collado, Ana E. Sipols, M. Teresa Santos-Martín, and Elisa Frutos-Bernal. Clustering and Forecasting Urban Bus Passenger Demand with a Combination of Time Series Models. *Mathematics*, Vol. 10, No. 15, 2022.
- [11] Sohani Liyanage, Rusul Abduljabbar, Hussein Dia, and Pei-Wei Tsai. AI-based neural network models for bus passenger demand forecasting using smart card data. *Journal of Urban Management*, Vol. 11, No. 3, pp. 365–380, 2022.
- [12] Lorenz Schauer, Martin Werner, and Philipp Marcus. Estimating Crowd Densities and Pedestrian Flows Using Wi-Fi and Bluetooth. In *11th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, MobiQ-
uitous '14, 11 2014.
- [13] 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 '18 Workshops, pp. 430–432, 2018.
- [14] 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 '13, pp. 193–200, 2013.
- [15] Jens Weppner and Paul Lukowicz. Collaborative Crowd Density Estimation with Mobile Phones. In *Proc. of ACM PhoneSense*, 2011.
- [16] Akira Tokuda, Yutaka Arakawa, Shigeru Takano, and Shigemi Ishida. Automatic Parameter Adjustment for Hybrid WiFi and BLE-based Congestion Measurement. In *2021 Thirteenth International Conference on Mobile Computing and Ubiquitous Network*, ICMU '21, pp. 1–6, 2021.
- [17] Yuji Kanamitsu, Eigo Taya, Koki Tachibana, Yugo Nakamura, Yuki Matsuda, Hirohiko Suwa, and Keiichi Yasumoto. Estimating Congestion in a Fixed-Route Bus by Using BLE Signals. *Sensors*, Vol. 22, No. 3:881, pp. 1–15, 2022.
- [18] Eigo Taya, Yuji Kanamitsu, Koki Tachibana, Yugo Nakamura, Yuki Matsuda, Hirohiko Suwa, and Keiichi Yasumoto. Estimating Congestion in Train Cars by Using BLE Signals. In *2022 2nd Workshop on Data-Driven and Intelligent Cyber-Physical Systems for Smart Cities Workshop*, DI-CPS '22, pp. 1–7, 2022.
- [19] Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, Wei Chen, Weidong Ma, Qiwei Ye, and Tie-Yan Liu. LightGBM: A Highly Efficient Gradient Boosting Decision Tree. In *Proceedings of the 31st International Conference on Neural Information Processing Systems*, NIPS '17, pp. 3149–3157, 2017.
- [20] Takuya Akiba, Shotaro Sano, Toshihiko Yanase, Takeru Ohta, and Masanori Koyama. Optuna: A Next-Generation Hyperparameter Optimization Framework. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery Data Mining*, KDD '19, pp. 2623–2631, 2019.