

BLE 受信状況に基づく バス乗客の体感混雑度推定手法の検討

Estimation of Bus Passengers' Congestion Experience Based on BLE Receipt Status

池永 拓海^{1*} 松田 裕貴^{1,2*} 後藤 逸兵¹ 上田 健太郎¹ 諏訪 博彦^{1,2} 安本 慶一^{1,2}

¹ 奈良先端科学技術大学院大学 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 RIKEN Center for Advanced Intelligence Project

要旨: バスをはじめとする交通機関の情報を正確に推定することは、交通システムの効率化と乗客の快適性の向上に不可欠である。バス車内の情報を推定する既存手法として、乗客の所持するデバイスが発信する BLE 信号情報を用いて、車内人数を推定する手法が提案されている。このアプローチでは、主に車内人数の推定のみ焦点を当てているが、同じ車内人数でも乗客が感じる混雑度はそれぞれ異なるため、各停留所間の体感混雑度を推定することは重要である。本研究では、車内人数の推定で効果が確認されている BLE 信号情報を利用して、乗客の体感混雑度を推定可能かどうかをを評価する。実験の結果、正解率による評価で 0.653 (車内人数), 0.513 (体感混雑度) となり、BLE 信号情報で体感混雑度の大きな傾向を捉えることができるとわかった。

1 はじめに

バスをはじめとする公共交通機関の車内の混雑度を正確に把握することは、交通システムの効率化と乗客の快適性の向上に不可欠である。実際、バス利用者は、車内の混雑状況に関心があるという研究成果があり、バス車内の混雑状況を知ることで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 [1, 2]。そのため、バス車内の混雑状況を取得する必要があるが、運行している全てのバスの乗客を手動で記録することは現実的な方法ではないため、自動的にバス車内人数を推定するシステムが必要である。

バス車内の混雑度を推定する手法として、カメラから得られた動画から画像処理や深層学習を用いて乗客を計測する手法 [3, 4, 5] やバス出入口に赤外線センサを設置してバス利用者の乗り降りを検出する手法 [6] が提案されている。これらの手法は、比較的高い精度で車内人数の推定を可能としているが、バス全台に設置するコストや設置場所に制約があり、乗客の重なり弱く極度に混雑している状況では精度が低くなる課題がある。また、カメラを用いた手法では、乗客のプライバシーを侵害する恐れがある。この問題を解決するために、Bluetooth Low Energy (BLE) を用いた混雑度推定手法が提案されている [7, 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

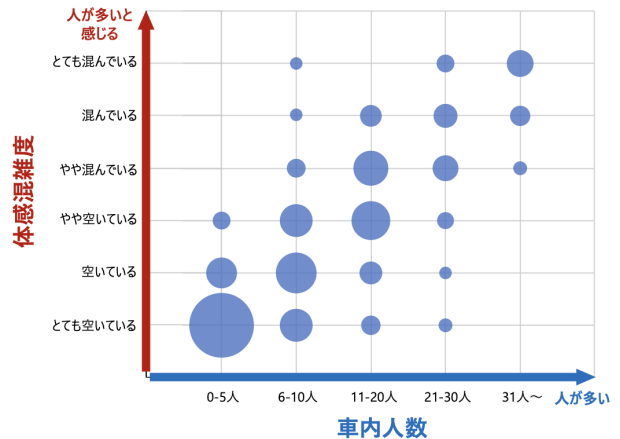


図 1: 車内人数と体感混雑度の関係

るため、プライバシー侵害の心配はほとんどない。また、Raspberry Pi などの安価で軽量なシングルボードコンピュータ 1 台で受信でき、無線通信技術であることから設置場所の制限もないため、BLE を用いた混雑度推定は、プライバシーに考慮したデータ収集と設置コスト低減の実現が可能である。しかし、従来のアプローチでは、主に車内人数の推定のみ焦点を当てているが、図 1 に示すように車内人数と乗客が実際に感じる混雑度である体感混雑度の関係にはばらつきがある。つまり、同じ車内人数でも乗客が感じる混雑度はそれぞれ異なるため、各停留所間の体感混雑度を推定することは重要である。

*共同第一著者, {ikenaga.takumi.ir8, yukimat}@is.naist.jp

そこで本研究では、車内人数の推定において効果が確認されている乗客の携帯端末から得られた BLE 信号情報を利用して、乗客の体感混雑度を推定可能かどうかを評価する。BLE 信号から得られる BD アドレスと RSSI を基に特徴量を作成し、機械学習モデルを用いて体感混雑度を推定することで、より乗客にとって理解しやすい混雑度情報の提供を目指す。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、奈良市内循環線の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学習及び推定を行なった結果、正解率による評価で 0.653 (車内人数)、0.513 (体感混雑度) となった。体感混雑度は個人によって感じ方が異なるものの、BLE 信号情報から体感混雑度の大きな傾向を捉えられることを確認した。

2 関連研究

2.1 バスの混雑度推定

バスの混雑度推定に関連した様々な研究が提案されている。Wood らは運行状況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、個々のバスが停留所に到達した時の乗客の占有率を推定するために、線形回帰モデルと機械学習モデルを用いて乗客数の予測を行った [9]。Roncoli らは車両の位置をリアルタイムで提供する AVL システムのデータと停留所での乗降者数を自動でカウントする APC システムのデータを組み合わせて、カルマンフィルタで車内の混雑度の推定を行なった。これらの手法は、バスの移動時間や混雑度を正確に予測することが期待できるものの、路線内に APC システムを備えた車両が必要であり、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、カメラを用いて混雑度を推定する手法が提案されている [3, 4, 5]。Hsu らは、バス車内に設置したカメラの映像データの中で、乗客を表さない全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を用いて乗客数をカウントするシステムを提案している [5]。カメラを用いたシステムは、正確な乗客数の推定を可能とするが、設置や運用のコストが高く、プライバシー侵害の恐れがあるため、路線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

スマートフォンの普及に伴い、ユーザ参加型センシングと BLE を組み合わせた混雑度推定についていくつか研究が行われている。Weppner らは監視環境内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 [10, 11]。前川らは、鉄道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、鉄道車両の混雑度を推定する手法を提案している。これらの手法は、新たにセンサを設置する必要がないため、コスト面の課題はクリアしているものの、推定精度が参加するユーザ数に依存するため、ユーザの関与を促す仕組みが必要である。

安価なシングルボードコンピュータを用いて 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。Longo らは、Raspberry Pi を用いて Wi-Fi と BLE の両方をセンシングし、研究室や大講義室などの大学内の特性が異なる空間の占有率をそれぞれ推定する手法を提案した [12]。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、金光らや後藤らはバス、田谷らは電車で乗客の携帯端末から発信される BLE 信号を基に特徴量を作成し、機械学習モデルを用いて混雑度推定システムの提案を行っている [7, 8, 13]。これらの手法は、プライバシーの侵害や設置コスト及び設置位置の制約の問題を軽減しつつ、混雑度推定を行うことを可能としている。しかし、センシング対象空間にいる人数の推定に焦点を当てており、実際に人々が感じる混雑度を推定していないという課題がある。

2.3 本研究の位置付け

バスの混雑度推定に関する研究は数多く存在するが、その多くが車内人数の推定に焦点を当てており、乗客の体感混雑度の推定に焦点を当てた研究はない。先行研究では、車両内の人数を推定しているが [7, 8, 13]、図 1 に示したように車内人数と体感混雑度の関係にはばらつきがある。そこで本研究では、プライバシー保護が可能で、交通システムで実用化可能な BLE 信号を用いたバス乗客の体感混雑度推定システムを提案する。バス車載器に搭載されている BLE デバイスを用いて乗客の携帯端末から発信される BLE 信号をセンシングして車内人数及び体感混雑度を推定することで、よりバス利用者にとって理解しやすい混雑度の情報を提供できることを目指す。

3 提案手法

3.1 データ収集

提案手法の有効性を検証するため、奈良交通株式会社の協力のもと、2023 年 3 月 24 日から 27 日の合計 4 日間で実際のバスを使ったデータ収集実験を行った。

¹<https://www.narakotsu.co.jp/>



図 2: 奈良交通バス奈良市内循環線

(奈良交通株式会社 Web サイト <https://www.narakotsu.co.jp/nara-travel/pdf/city-map.pdf> から引用)




図 3: BLE スキャナの設置位置

データ収集は、奈良市内循環線 (図 2) のバス前方の運転手座席横 (図 3) に実装された公共交通機関向け BLE スキャナ 10 台 (図 4) によって周囲の BLE デバイスのデータを収集した。そして、一般市民合計 48 名に実験協力を依頼して、BLE スキャナが搭載されたバスの車内人数と体感混雑度について回答してもらった。車内人数は 4000 件、体感混雑度は 6597 件のバス停留サンプルを収集した。表 1 にそれぞれの回答項目とその内訳を示す。

3.2 特徴量抽出

本システムは 15 秒おきに周囲の BLE デバイスをスキャンする。各停留所間におけるスキャン回数を N_{scan}

表 1: 車内人数と体感混雑度の内訳

| 車内人数 | | 体感混雑度 | |
|---------|------|---------------|------|
| 項目 | 件数 | 項目 | 件数 |
| 0-5 人 | 1930 | とても空いていると感じる | 2809 |
| 6-10 人 | 934 | 空いていると感じる | 1405 |
| 11-20 人 | 795 | やや空いていると感じる | 1148 |
| 21-30 人 | 195 | やや混雑していると感じる | 748 |
| 31 人以上 | 146 | 混雑していると感じる | 277 |
| | | とても混雑していると感じる | 211 |

とし、 N_{scan} 回のスキャンによって検出された BLE デバイスの BD アドレスと RSSI を保持し、混雑度推定を正確に行うために有効な特徴量を作成する。

3.2.1 出現頻度

1 回のスキャンで取得する BLE データには、バス車外からの信号が頻繁に含まれている。そこで、BD アドレスの出現頻度を計算し、出現頻度でフィルタリングすることでバス車内と車外のアドレスを区別できると考える。各停留所間で、1 つの BD アドレスが出現する頻度 F は以下のように計算される。

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

ここで、 $N_{detected}$ は各停留所間で同じ BD アドレスが検出された回数である。本手法では、出現頻度に關



図 4: 公共交通機関向け BLE スキャナ

値を設け、閾値以上の BD アドレス数のカウントを行い特徴量とする。

3.2.2 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。各停留所間での平均 RSSI は以下のように算出される。

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

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、ビーコンとデバイスが互いに同一でない限り、位置が同じでも RSSI の値が同じになることは期待できないため、絶対的な RSSI の閾値を見つけることは困難である。そこで本手法では、前節の出現頻度によって車内と判定されたアドレスの平均 RSSI を閾値に設定し、閾値以上の RSSI を持つアドレスのカウントを行い特徴量とする。

3.2.3 差分と変化率

前節で出現頻度及び平均 RSSI を計算し閾値を設けてカウントすることで、車内 BLE デバイス数を表す特徴量を作成した。停留所では、バス利用者の乗降が発生するため、停留所間での車内 BLE デバイス数の差分

を計算することで推定に有効な特徴量を作成できると考える。また、単に差分を取るだけでなく、停留所間での相対的変化率を計算することで、体感混雑度に有効な特徴量を作成できると考える。車内人数が 0 人から 10 人に増えた時と 30 人から 40 人に増えた時では、同じ 10 人の変化でも、乗客が感じる混雑度に違いが出ると考える。各停留所間での差分 $DIFF$ 及び相対的変化率 RC は以下のように算出される。

$$DIFF = InAddr_{current} - InAddr_{previous} \quad (3)$$

$$RC = \frac{InAddr_{current} - InAddr_{previous}}{InAddr_{previous} + 1} \quad (4)$$

ここで、 $InAddr_{current}$ は現在の停留所での車内 BLE デバイス数、 $InAddr_{previous}$ は 1 つ前の停留所での車内 BLE デバイス数を表し、前節で紹介した車内 BLE デバイス数を表す特徴量からそれぞれ計算される。また RC の分母は 0 除算を防ぐために 1 を足している。

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。そこで、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ことがわかっている [7, 8]。そこで、本研究では路線情報として停留所名、時間、路線名を利用する。

4 実験

4.1 分析モデルと評価

実験では、先行研究である金光ら [7] の特徴量、提案手法の特徴量から差分と変化率を抜いた提案手法（差分/変化率なし）、提案手法（ALL）の 3 種類の特徴量を用いて車内人数及び体感混雑度推定モデルを構築し、評価を行う。出現頻度の閾値は、0.5 から 1.0 の間で 0.1 刻みの値を用いた。使用する機械学習モデルは、SVM (Support Vector Machine)、RF (Random Forest)、LightGBM [14] の 3 種類を採用し、各モデルごとに学習と評価を行う。評価は 10 分割交差検証を行い、各モデルのハイパーパラメータは Optuna [15] にて最適化したものを使用した。評価指標には、正解率と F 値を使用した。

4.2 結果

車内人数の推定結果を表 2、体感混雑度の推定結果を表 3 に示す。表より提案手法の特徴量が有効であり、




図 5: 車内人数の混同行列




図 6: 体感混雑度の混同行列

表 2: 車内人数の推定結果

| モデル | 金光ら [7] | | 提案手法 (差分/変化率なし) | | 提案手法 (ALL) | |
|----------|---------|-------|-----------------|-------|--------------|--------------|
| | 正解率 | F 値 | 正解率 | F 値 | 正解率 | F 値 |
| SVM | 0.572 | 0.388 | 0.588 | 0.395 | 0.642 | 0.492 |
| RF | 0.595 | 0.425 | 0.638 | 0.499 | 0.649 | 0.516 |
| LightGBM | 0.599 | 0.454 | 0.640 | 0.528 | 0.653 | 0.530 |

表 3: 体感混雑度の推定結果

| モデル | 金光ら [7] | | 提案手法 (差分/変化率なし) | | 提案手法 (ALL) | |
|----------|---------|-------|-----------------|-------|--------------|--------------|
| | 正解率 | F 値 | 正解率 | F 値 | 正解率 | F 値 |
| SVM | 0.470 | 0.258 | 0.476 | 0.276 | 0.501 | 0.322 |
| RF | 0.487 | 0.316 | 0.508 | 0.355 | 0.512 | 0.361 |
| LightGBM | 0.492 | 0.331 | 0.506 | 0.367 | 0.513 | 0.374 |

差分と変化率の特徴量が車内人数と体感混雑度の推定どちらにも有効であることがわかった。また、全ての指標において LightGBM が比較的高い性能を示す結果となった。LightGBM の推定による車内人数の混同行列を図 5、体感混雑度の混同行列を図 6 に示す。混同行列を見ると車内人数及び体感混雑度の大きな傾向は捉えることができているとわかる。しかし、車内人数では「6-10人」と「21-30人」と推定精度が低いことが見て取れる。この原因として、車内後方の BLE デバイスを適切に検出できていないことが挙げられる。特に、今回の実験では、車内前方にある車載器内部に BLE センシングデバイスが設置されているため、車内前方付近の車外デバイスを検出しやすくなっており、逆に車内後方の車内デバイスを適切に検出できていないと考えられる。また、車内が混雑した状況では、人体によって信号が減衰するため、より車内後方のデバイスを検出しづらくなっていると考えられる。また、体感混雑度の推定では、「とても空いていると感じる」と「とて

も混雑していると感じる」以外の推定精度がばらける結果となった。これは、同じ車内人数でも人によっては「やや混雑している」と感じ、また別の人では「混雑している」と感じる人がいるためであると考えられる。よって、BLE 信号情報では大まかな体感混雑度の傾向は捉えられるものの、正確に体感混雑度を推定するには、環境センサのデータなど、体感に影響を与える想定される別の手がかりが必要であると考えられる。

5 おわりに

本研究では、バス乗客の携帯端末から得られた BLE 信号情報を利用して、従来の車内人数の推定に加えて、乗客の体感混雑度を推定するシステムを提案し、評価を行った。結果として、車内人数と体感混雑度それぞれ大まかな傾向を捉えることが可能なモデルを構築することができた。しかし、バス前方付近の車外デバイスのフィルタリングとバス後方の車内デバイスの検出が

正確にできないといった課題が明らかとなった。また、体感混雑度をより正確に推定するには、BLE データに加えて他の手がかりとなるデータの必要性が示唆された。これらの課題を踏まえ、より有効な特徴量抽出や体感混雑度の正確な推定に必要なセンサ（気温、湿度、照度等）や情報（出身地域や性格）を模索し、実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) および JST 共創の場形成支援プログラム (JPMJPF2115) の助成を受けたものである。

参考文献

- [1] Fan Wu, Xiaowei Hu, Shi An, Duo Zhang, et al. Exploring passengers' travel behaviors based on elaboration likelihood model under the impact of intelligent bus information. *Journal of Advanced Transportation*, Vol. 2019, No. 9095279, 2019.
- [2] Oded Cats Arkadiusz Drabicki, Rafał Kucharski 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.
- [3] 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.
- [4] 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, pp. 102–115, 2017.
- [5] 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, p. 2178, 2020.
- [6] Ivano Pinna and Bruno Dalla Chiara. Automatic passenger counting and vehicle load monitoring. *Ingegneria Ferroviaria*, Vol. 65, pp. 101–138, 02 2010.
- [7] 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, p. 881, 2022.
- [8] 後藤逸兵, 上田健太郎, 佐瀬亮太, 松田裕貴, 諏訪博彦, 安本慶一. 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. 人工知能学会第二種研究会資料, Vol. 2023, No. SAI-046, p. 05, 2023.
- [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] 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.
- [11] Jens Weppner and Paul Lukowicz. Collaborative Crowd Density Estimation with Mobile Phones. In *Proc. of ACM PhoneSense*, 2011.
- [12] Edoardo Longo, Alessandro EC Redondi, and Matteo Cesana. Accurate occupancy estimation with wifi and bluetooth/ble packet capture. *Computer Networks*, Vol. 163, p. 106876, 2019.
- [13] 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.
- [14] 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.
- [15] 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*, pp. 2623–2631, 2019.