

# 停留所毎モデルを用いたバス乗降データによる乗客人数予測の評価

青地美桜<sup>1,a)</sup> 白石陽<sup>2,b)</sup>

**概要:** 公共交通機関での移動手段の一つとして、バスが利用されているが、バス利用者はバスの混雑を事前に把握することが困難である。バスの混雑状況を事前に把握することができれば、バス利用者は混雑していないバスを選択し、乗車することが可能となる。そこで本研究では、交通系 IC カードの乗降データを用いてバスの乗客人数を予測する手法を提案する。著者らはこれまで、時間帯や天候の変化に応じて乗客人数が変動することを考慮して、乗客人数予測モデルを作成し、予測精度の評価を行った。先行研究で作成してきた予測モデルは、対象となる路線でバスが通過する停留所すべての乗客人数を一つのモデルで予測する「路線モデル」であった。しかし、複数の路線のデータを使用して予測を行う際には、データが複雑になってしまい、予測精度があまり向上しない問題があった。そこで、複数の路線のデータを使用した際に予測精度が向上する予測モデルを作成する。本稿では、停留所毎の予測モデルを作成する手法で実験を行い、予測モデルの評価を行う。停留所毎モデルは、各停留所に特化したモデルであり、今まで作成していた路線モデルより、停留所ごとの特性を考慮できる可能性がある。実験結果として、乗降車数データを説明変数に加えた停留所毎モデルが最も精度が高い結果となった。

**キーワード:** 交通系 IC カード, 混雑, 公共交通, 路線バス, 乗客人数予測

## 1. はじめに

代表的な公共交通機関の一つとして、バスが挙げられる。バス利用者がバスを快適に利用するには、バスの遅延状況と混雑状況の把握が必要である。遅延状況に関して、既存のバスロケーションシステムがあり、バス利用者はバスロケーションシステムを利用することで、遅延状況を考慮してバスを選択することが可能である。しかし、既存のバスロケーションシステムでは混雑状況を考慮してバスを選択することができない。また、COVID-19 の感染拡大防止の対策として、3 つの密（密閉・密集・密接）を避けるよう呼びかけられている。バスはこの3つの密が発生しやすい状況であるため、事前にバス内の混雑状況を把握できれば、3 つの密を回避しながらバスを利用できる可能性がある。そこで、バス利用時の快適性向上のため、本研究では、乗客人数を予測し、利用者にバスの乗客人数を提示するアプローチを取る。事前に乗車予定のバスの乗客人数を提示することができれば、バス利用時の快適性が高くなると考える。

乗客人数を予測するために、交通系 IC カードの乗降データをから算出した乗客人数を学習データとして使用する。乗客人数は、各停留所で乗車した人数、降車した人数を使用して求めることが可能である。そこで、本研究では、バスの運賃支払いに使用される交通系 IC カードに着目する。交通系 IC カードは、利用時に乗降時刻、乗降停留所等の乗降データを記録する。乗降データからカード利用者が乗降した停留所や時刻が取得することが可能である。よって、ある停留所で乗降した人数を把握できる。算出した乗客人数や、該当する停留所、停留所を通過した日時等を学習さ

せることで、乗車予定のバスの乗客人数の予測が可能になると考える。交通系 IC カードの一つである Suica は、2021 年 3 月時点で 8,589 万枚発行されており、前年度より約 300 万枚増加している[1]。今後さらに、普及率は高くなると考えられるため、乗客人数の予測に活用することは妥当であると考えられる。

そこで、本研究では、バス内の乗客人数予測を行い、利用者の快適性を向上させることを目的とし、交通系 IC カードの乗降データを使用して、バス内の乗客人数を予測する手法を提案する。著者らの先行研究[2]では、バスの運行時間帯と天候を考慮し乗客人数予測モデルの評価を行ってきた。先行研究では、バスの路線ごとに学習モデルを作成する路線モデルを作成していた。しかし、2 路線以上のデータを用いた場合、乗客人数を予測する際に複雑性が増してしまうという問題がある。そこで、停留所毎に乗客人数を予測するモデルを作成し、その予測モデルの評価を行う。ここで、本研究における乗客人数とは、バスに乗車している利用者の人数のことである。また、バスへ乗車する人数、バスから降車する人数を総称して乗降車数とする。

## 2. 関連研究

本研究では、予測モデルを作成する際に必要な乗客人数を、各停留所の乗降車数を用いて算出する。そこで、関連研究として、2.1 節では、乗降車数を推定する研究について述べる。2.2 節では、公共交通機関の混雑状況を予測する研究について述べる。

### 2.1 乗降車数を推定する研究

中島らはドライブレコーダに記録された映像を用いている[3]。この研究では、背景差分法を用いて動体を検出し、それらの輪郭検出を行い、動画フレーム間の乗客の動きから乗降車数を推定している。提案手法の評価を行った結果、

1 公立はこだて未来大学大学院 システム情報科学研究科  
Graduate School of Systems Information Science, Future University Hakodate  
2 公立はこだて未来大学 システム情報科学部  
School of Systems Information Science, Future University Hakodate  
a) g2120001@fun.ac.jp  
b) siraisi@fun.ac.jp

バスの扉を開けた際に差し込む光の変化を誤って認識してしまうことが原因となり、推定精度が低い結果となった。差し込む光は天候によって変化するため、天候が原因で推定精度が低くなってしまふ可能性がある。そのため、カメラを用いて推定を行う場合、天候を考慮する必要があると考えられる。

山田らは、バスの乗降口に測域センサを設置して乗降車数の推定を行っている[4]。測域センサとは、周囲の物体との距離を広範囲で正確に把握することができるセンサである。実際に運行しているバスに測域センサを設置し実証実験を行った結果、高い精度で乗降車数を推定可能であることが示唆されている。しかし、バスの乗降口付近で多数の乗客が密集してしまった場合、密接している乗客を1人と判定してしまい、推定結果との誤差が大きくなってしまふ問題がある。そのため、バスの乗降付近で乗客が密集した場合にも、より正確にバス内の乗客人数を把握する必要があると考える。

これらの研究より、バスに直接機器を設置して乗降車数を推定する場合、バスの状況により誤差が生じてしまふ、十分な精度が得られない可能性が考えられる。

## 2.2 公共交通機関の混雑状況を予測する研究

前川らは、鉄道に乗車している利用者の携帯端末で受信される Bluetooth の RSSI (Received Signal Strength Indicator) 特性を利用し、混雑状況を推定している[5]。この研究では、端末間で観測される RSSI から、端末が同一車両に存在する確率と、端末間で混雑している確率を用いて乗客が所持している全端末の車両内での位置を推定し、その推定結果と端末間の混雑確率を用いて、車両ごとの混雑を推定する。提案手法の評価を行った結果、車両ごとの混雑の有無を F 値 0.75 で推定できることが示されている。しかし、乗客が所持している端末の位置を正確に推定することができなければ、車内の混雑度合いを把握することが困難である。

高松らは、バス内に設置した BLE (Bluetooth Low Energy) 端末から得られる RSSI の減衰特性と、音圧の減衰特性を利用し、混雑状況を推定している[6]。この研究では、混雑状況推定手法として BLE を用いた手法と音を用いた手法の2つを利用する。2つの提案手法でそれぞれ混雑状況を推定した結果、BLE を用いた手法では、乗客の立ち位置を変更しても分類可能であることが示された。音を用いた手法では、詳細な分類は困難だが、マイク近傍が無人であるか、そうでないかを高確率で推定可能であることが示された。しかし、BLE 端末およびマイクの設置箇所によって推定結果が変化してしまう可能性がある。特に、BLE 端末と受信端末との位置関係が重要であるため、様々な環境に対応することが困難である問題がある。

金光らは、BLE とバス内の乗客の携帯端末を用いて、バス内の混雑度を推定している[7]。BLE を用いることで乗客

のプライバシー保護とコスト削減を実現している。結果として、平均絶対誤差が約 2.5 人となった。しかし、バス内が混雑している際には、乗客の BLE 端末からの信号を受信するデバイスの設置位置によっては、正確に乗客の BLE 端末の信号を取得できないという問題がある。

佐藤らは、過去のバス利用者数と天候、人口データを用いて、予測モデルを作成し、翌日のバス利用者数の予測を行っている[8]。天気予報の気温、降水確率、停留所周辺の世帯数、年齢別人口、乗車数、降車数、停留所を通過した人数を学習データとして、予測モデルを作成し、予測を行っている。しかし、この研究では、バスの運行時間帯を考慮していないため、通勤、通学時間等の特定の時間帯で増加するバス利用者数の予測に対して十分な精度が得られていないという問題がある。

## 3. 提案手法

本章では、3.1 節で提案手法について述べる。次に 3.2 節、3.3 節、3.4 節で提案手法のプロセスである学習データの作成、予測モデルの作成、乗客人数の予測について述べる

### 3.1 提案手法の流れ

以下に本研究の提案手法の流れを示す。

- ① 学習データの作成
- ② 予測モデルの作成
- ③ 乗客人数の予測

まず、交通系 IC カードの乗降データや天候データを用いて、学習データを作成する (①)。

次に、①で作成した学習データを用いて、乗客人数予測モデルを作成する (②)。本稿で作成するモデルは路線モデルと停留所毎モデルの2つである。

最後に②で作成した予測モデルを用いて乗客人数の予測を行う (③)。

以降の節で提案手法の流れの詳細を述べる。

### 3.2 学習データの作成

本節では提案手法の流れ①の学習データの作成について述べる。学習データには、交通系 IC カードの乗降データ、乗客人数、天候データを使用する。以降の項で各データについて詳細を述べる。

#### 3.2.1 交通系 IC カードの乗降データ

本研究では、バスの運行を把握するために、交通系 IC カードの乗降データを用いる。交通系 IC カードの乗降データは、カード利用者がバス乗降車時に交通系 IC カードを使用すると記録されるデータである。表 1 に交通系 IC カードの乗降データのうち、本研究で使用するデータを示す。

表 1 交通系 IC カードの乗降データの内容

データ名	内容
乗車日時	バスに乗車した日時
乗車停留所番号	乗車した停留所に割り振られている番号
乗車停留所名	乗車した停留所名
降車日時	バスから降車した日時
降車停留所番号	降車した停留所に割り振られている番号
降車停留所名	降車した停留所名
車両番号	利用したバス車両の番号
路線番号	利用した路線に割り振られている番号
路線名	利用した路線名

乗車日時および降車日時は、カード利用者がバスに乗車およびバスから降車した日付と時刻が記録されている。乗車停留所番号および降車停留所番号は、カード利用者がバスに乗車およびバスから降車した停留所の番号が記録されている。停留所番号とは、停留所を一意に特定することができるように、バス会社が定義した番号のことである。乗車停留所名および降車停留所名は、カード利用者がバスへ乗車および降車した停留所の名称が記録されている。車両番号は、カード利用者が乗車したバスの車両番号が記録されている。路線番号は、カード利用者が乗車した路線番号が記録されている。路線番号とは、バス路線を一意に特定することができるように、バス会社が定義している番号のことである。路線名は、カード利用者が乗車したバスの路線名が記録されている。

また、交通系 IC カードの乗降データに加えて、バスの運行実績データを用いる。停留所で乗降した利用者が存在する場合、交通系 IC カードの乗降データから乗降時刻を抽出できるが、利用者の乗降が発生しない場合は停留所を通過した時刻を把握することができない。バスの運行実績データには、バスが停留所を実際に通過した時刻のデータや、計画時刻のデータが記録されている。バスの運行実績データと乗降データ内の乗降日時を関連付けることで、乗降車が発生していない場合にも、その停留所を通過した時点の時刻を把握することが可能である。

### 3.2.2 乗客人数の算出

本研究では、乗客人数を目的変数として予測モデルを作成して予測を行う。そのために学習データとして乗客人数データを用いる。しかし、交通系 IC カードの乗降データには、乗客人数のデータは記録されていないため、乗降データを用いて乗客人数を算出する必要がある。停留所  $N$  でバスへ乗車する人数を  $x_N$ 、バスから降車する人数を  $y_N$ 、停留

所  $N$  の一つ前の停留所である停留所  $N-1$  までの乗客人数を  $P_{N-1}$  とするとき、停留所  $N$  における乗客人数  $P_N$  を求める式を式 (1) に示す。

$$P_N = x_N + (P_{N-1} - y_N) \quad (1)$$

### 3.2.3 天候データ

本研究では、バス利用時の天候がバスの乗客人数に影響すると考え、バス運行時の天候データを使用する。天候データには天気の情報、気温、降水量、降雪量、風速等のデータが記録されている。本研究では、記録されているデータのうち、天気の情報、降水量を用いる。

天候データを使用する理由として、悪天候時の通勤・通学手段を変更する可能性がある。例えば、晴れている日に自転車で通勤・通学をしているが、雨が降った日はバスに乗車するような場合である。このような場合、悪天候時にはバスの乗客人数が増加することが考えられる。また、台風等の外出することが困難な天候の場合、乗客人数が減少することが考えられる。前川らは、乗降客数を用いてバスの到着時刻予測を行うために、まず、バスの乗降客数データを分析している[9]。分析結果として、悪天候時に乗降人数が変化することが示唆されている。

## 3.3 予測モデルの作成

本節では提案手法の流れ②の作成する予測モデルについて述べる。以降の項で、先行研究[2]で作成していた路線モデル、新たに作成する停留所毎モデルについて詳細を述べる。

### 3.3.1 路線モデル

路線モデルは、乗客人数を予測する際に、対象としている路線でバスが通過しているすべての停留所の乗客人数を予測するモデルである。著者らの先行研究[2]では、この路線モデルを採用し、精度評価を行ってきた。このモデルは、路線すべての停留所のデータを学習するため、前の停留所での乗客人数を考慮することができると考える。しかし、複数の路線のデータを学習データとして使用して予測モデルを作成する際、異なる路線の乗客人数データと、予測したい路線の乗客人数データの関係が複雑になってしまい、予測精度が向上しない問題がある。

### 3.3.2 停留所毎モデル

停留所毎モデルは、乗客人数を予測する際に、対象としている路線でバスが通過している1つの停留所の乗客人数を予測するモデルである。このモデルは、対象とする路線の1つの停留所のデータを学習するため、路線モデルでの問題であった、学習データの複雑性を解決できると考える。しかし、停留所1つに特化させることで、路線モデルの利

点であった。前の停留所の乗車人数を考慮することができない。よって、説明変数に乗車人数データ、降車人数データを用いる。乗車人数データ、降車人数データを用いることで、停留所での人の流れを把握することができる。説明変数については 3.4.1 項で詳細に述べる。

### 3.4 乗車人数の予測

本節では提案手法の流れ③の乗車人数の予測について述べる。以降の項で、予測モデルを作成する際に必要である説明変数の検討、学習アルゴリズムの検討について述べる。

#### 3.4.1 説明変数の検討

予測モデルの精度を向上させるために、説明変数を検討する必要がある。本研究で使用する予測モデルごとの説明変数を表 2 に示す。

表 2 説明変数の一覧

説明変数	データの内容	路線モデル	停留所毎モデル
運行日時	運行時の日時	○	○
曜日	運行時の曜日	○	○
停留所番号	停留所に割り振られている番号	○	×
路線番号	路線に割り振られている番号	○	○
時間帯	あらかじめ定義した時間帯区分	○	○
降雨の有無	運行時の降雨の有無	○	○
降水量	運行時の降水量	○	○
乗車人数	乗車した人数	×	○
降車人数	降車した人数	×	○

本稿では、新たに乗車人数データ、降車人数データを追加する。著者らの先行研究[2]では、乗車人数データと降車人数データ以外のデータを説明変数として使用している。本稿で行う実験では、3.3.2 項で述べた停留所毎モデルを作成する。その際に、路線モデルでは考慮できていた前の停留所での人の流れを考慮できなくなり、予測精度に影響を与えると考える。そこで、その停留所での人の流れがわかるように、乗車人数データと降車人数データを用いることで、乗車人数のみではわからない特徴を考慮することが可能であると考えられる。

乗車人数データ、降車人数データ以外の表 2 の説明変数の詳細を述べる。停留所番号、運行日時、曜日を用いることで、ある運行時間の各停留所の乗車人数を予測すること

ができる。時間帯データは、定義した時間区分にあてはまる時間帯カテゴリに分類したものである。時間帯データを用いることで、バスの運行時間帯による乗車人数の違いを考慮することができる。天候データは、降雨の有無、降水量データを用いる。降雨の有無は気象庁が公開しているデータから、降雨の有無を判別し、2 値のデータを作成する。降水量データは気象庁が記録している数値を用いる。降雨の有無、降水量データを用いることで、天候の悪化の程度を把握することが可能であり、悪天候時の乗車人数の増減を考慮することができる。

#### 3.4.2 学習アルゴリズムの検討

本研究では、ランダムフォレストを用いる。ランダムフォレストは決定木を弱学習器とするアンサンブル学習アルゴリズムである。複数の決定木を用いて、それぞれの決定木の結果を補うことで高い予測性能を得ることができる[10]。ランダムフォレストの利点の一つとして、未知のデータに対する汎化性能が高いことが挙げられる。バスの乗車人数を予測する際には、イベントの発生、天候の悪化等で乗車人数が通常の状態から増減することが考えられる。そのため、ランダムフォレストを用いることで、乗車人数を予測した際の誤差を小さくすることが可能であると考えられる。また、先行研究[2]では、ランダムフォレスト、一般化線形モデル、一般化加法モデルの 3 種類を比較した実験を行ったが、ランダムフォレストを用いた際の予測モデルが最も精度が高かったため、今回も採用する。

## 4. 実験および考察

本章では、3.3.1 項で述べた路線モデル、3.3.2 項で述べた停留所毎モデルを比較し、評価を行う。以降の節で実験に用いたデータ、作成した予測モデル、実験結果および考察を述べる。使用した言語は R ver.3.6.1 である。

### 4.1 実験に用いたデータ

本実験で使用するバスの路線データを表 3 に示す。使用したデータの期間は 2019 年 4 月から 2019 年 10 月である。天候データは気象庁が公開しているデータ[11]を用いる。天候データ内にある天気データは 3 時間毎に記録されているため、天気が記録されていない時間が存在する。本実験では、天気が記録されていない時刻のデータを直前に記録された天気データを用いて補間する。例えば、6 時に天気が記録されている場合、7 時と 8 時は 6 時の天気データを用いる。天候データは、2019 年 4 月から 10 月の期間で、バスが運行している 6 時から 21 時のデータを使用する。対象としている地点は函館である。

表3 実験に用いた乗降データの一覧

路線	停留所数
路線 A	48
路線 B	33
路線 C	30
路線 D	51

#### 4.2 作成する予測モデル

本実験では、路線モデルと停留所毎モデルを作成する。また、路線数によって精度が変化する可能性もあるため、1路線、2路線、4路線分のデータを用いて予測モデルを作成する。さらに、停留所毎モデルで説明変数に採用した乗車人数データ、降車人数データが、路線モデルにも適用できる可能性が考えられるため、それぞれ説明変数に採用したモデルと不採用のモデルを作成する。作成するモデルを表4に示す。表4の「路線」は路線モデルを表しており、先行研究[2]で作成していた予測モデルである。「停留所毎」は停留所毎モデルを表しており、本稿で新たに作成する予測モデルを示している。

表4 作成する乗客人数予測モデル

モデル名	乗降車数データの有無	作成するモデル	路線数	データ量
2-1	なし	路線	1	12,684
2-2	なし	路線	2	20,300
2-3	なし	路線	4	37,785
2-4	なし	停留所毎	1	1,812
2-5	なし	停留所毎	2	2,900
2-6	なし	停留所毎	4	5,600
2-7	あり	路線	1	12,684
2-8	あり	路線	2	20,300
2-9	あり	路線	4	37,785
2-10	あり	停留所毎	1	1,812
2-11	あり	停留所毎	2	2,900
2-12	あり	停留所毎	4	5,600

#### 4.3 実験結果

作成した予測モデルの評価結果を述べる。表5に各予測モデルのRMSE (Root Mean Square Error, RMSE) を示す。また、各予測モデルを使用して予測した値と実際の乗客人数と比較したグラフを図1、図2、図3、図4に示す。グラフの縦軸は乗客人数、グラフの横軸は停留所を示している。図1、図2、図3、図4のグラフは、朝に運行していたバスのデータを使用した。

表5 作成した予測モデルの精度評価

モデル	RMSE(人)	モデル	RMSE(人)
2-1	3.32	2-7	3.18
2-2	3.51	2-8	3.35
2-3	3.34	2-9	3.28
2-4	3.12	2-10	2.63
2-5	3.33	2-11	2.91
2-6	3.36	2-12	3.02




図1 予測値と実際の乗客人数との比較(モデル2-1~2-3)




図2 予測値と実際の乗客人数との比較(モデル2-4~2-6)




図3 予測値と実際の乗客人数との比較(モデル2-7~2-9)




図 4 予測値と実際の乗客人数との比較  
 (モデル 2-10～2-12)

#### 4.4 考察

表 5 より、乗降車数データを使用していない場合の停留所毎モデル (モデル 2-4, 2-5, 2-6) と路線モデル (モデル 2-1, 2-2, 2-3) では RMSE はどちらもほぼ同じ値だが、乗降車数データを使用している場合の停留所毎モデル (モデル 2-10, 2-11, 2-12) のほうが RMSE の値が低いことがわかる。これは各停留所のデータのみを使用し、その停留所に特化したことと、乗降車数データを用いることで、より人の流れをモデルに反映できたことが挙げられる。また、乗降車数データを使用していないモデルの予測結果である図 1, 図 2 と乗降車数データを使用しているモデルの予測結果である図 3, 図 4 では、乗降車数データを使用しているモデルの予測結果である図 3, 図 4 のほうが比較的良好な結果であると言える。本研究では、実際の乗客人数より多い人数が予測されることは問題がないと考えている。理由として、例えば実際の乗客人数が 3 人、予測の値が 5 人となった場合に、利用者は混雑していると思ってしまうが、利用者のバス快適性には影響がないためである。しかし、乗客人数を少なく予測した場合は、予測した状況と、路線バス内の実際の状況が異なってしまうため、本研究の目的である、「利用者の快適性を向上させること」が達成されないと考える。以上のことを踏まえると、実際の乗客人数との比較でも、停留所毎モデルの使用と、モデル作成時に乗降車数データを使用することが有用であることが示唆された。

#### 5. まとめ

本研究では、利用者の快適性を向上させることを目的とし、交通系 IC カードデータの乗降データ、天候データを用いて乗車予定バスの乗客人数を予測する手法を提案した。提案手法では、交通系 IC カードの乗降データや天候データから作成した学習データを用いて予測モデルを作成し、予測モデルを用いて乗客人数を予測する。本稿では、新たな予測モデル作成手法として、停留所毎モデルを提案し、今

まで著者らが作成していた路線モデルとの比較を行った。また、停留所毎モデルを作成する際に乗降車数データを使用することが有用である可能性があると考えたため、乗降車数データを使用して予測モデルを作成した。結果として、停留所毎モデルでかつ乗降車数データを使用することで、予測精度が向上することが示唆された。

今後の課題として、さらに予測精度を向上させるために必要なデータ量の再検討を行う。現在は運行している時点での天気のみ参照しているが、人の流れを考慮する場合、乗車するより前の天候や、天気予報の情報等でも乗客人数に影響を与えると考える。よって、朝における降雨の有無や、天気予報のデータを追加して予測モデルを作成し、その精度を評価する予定である。また引き続き、2 路線以上のデータを用いた際の予測モデルの作成手法の検討を進める。

**謝辞** 本研究の実験に用いた交通系 IC カードデータおよび運行実績データは函館バス株式会社の協力によるものである。ここに深く感謝の意を表する。

#### 参考文献

- [1] “ファクトシート：JR 東日本”, JR 東日本, <https://www.jreast.co.jp/investor/factsheet/>. (参照 2021-11-01).
- [2] 青地美桜, 白石陽, “利用者の乗降データを用いたバス乗客人数予測モデルの評価”, 情報処理学会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.2020-ITS-83, No.13, pp.1-8 (2020)
- [3] 中島颯人, 新井イスマイル, 藤川和利, “バス車載ドライブレコーダを用いた背景差分方による乗降客数推定手法の評価”, 情報処理学会マルチメディア, 分散, 協調とモバイルシンポジウム 2018 論文集, Vol.2018, pp.43-48 (2018).
- [4] 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”, 情報処理学会論文誌, Vol.60, No.3, pp.934-944 (2019).
- [5] 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).
- [6] 高松将也, 伊達伸之輔, 岩本健嗣, 松本三千人, “CroW: バス車内における混雑状況推定システム”, 情報処理学会マルチメディア通信と分散処理研究報告(DPS), No.14, pp.1-7 (2015).
- [7] 金光勇慈, 田谷瑛悟, 立花巧樹, 中村優吾, 松田裕貴, 諏訪博彦, 安本慶一, “BLE を用いた路線バスの混雑度推定”, 情報処理学会マルチメディア, 分散協調とモバイルシンポジウム 2021 論文集, No.2021, No.1, pp.62-69 (2021).
- [8] 佐藤孝大, 大場みち子, “バスの到着時刻予測モデルの開発と移動手段提案システムの検討”, 情報処理学会研究報告情報システムと社会環境(IS), No.7, pp.1-7 (2018).
- [9] 前川裕一, 林夏美, 牧野友哉, 白石陽, “バス到着時刻予測におけるバス運行所要時間データと乗降客数データの活用”, 情報処理学会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.2013, No.6, pp.165-171 (2013).
- [10] 波部奇, “ランダムフォレスト”, 情報処理学会研究報告コンピュータビジョンとイメージメディア(CVIM), Vol.2012-CVIM-182, No.31, pp.1-8 (2012).
- [11] “過去の気象データ・ダウンロード”, 国土交通省 気象庁, <https://www.data.jma.go.jp/gmd/risk/obsdl/>. (参照 2019-12-09)