

# 高予測精度と低収集コストを実現するための バスプローブデータ収集地点の選定

川谷 卓哉<sup>1,a)</sup> 佐藤 祐大<sup>1,b)</sup> 峯 恒憲<sup>2,c)</sup>

**概要:** 路線バスの運行状況を分析し把握することは、バス輸送サービスの改善に大変有用であるが、リアルタイムもしくはそれに近い状況把握を実施するためには、運行状況把握のためのデバイスの設置コストや通信コストが課題となる。本研究では、路線バスに設置された走行履歴を記録するデバイスから、走行履歴データ（プローブデータ）を吸い上げる路側器の設置台数を1とした時に、予測精度を最も向上させる設置位置問題について考える。実際のプローブデータを利用したシミュレーション実験の結果、最適な設置位置は、必ずしも走行時間の分散の最も大きな箇所と同じにならないことを確認した。

**キーワード:** 公共交通、路線バス、プローブデータ、運行特性、機械学習、移動時間予測

## Selection of bus probe data collection points to achieve high prediction accuracy and low collection cost

KAWATANI TAKUYA<sup>1,a)</sup> SATO YUTA<sup>1,b)</sup> MINE TSUNENORI<sup>2,c)</sup>

### 1. はじめに

路線バスの運行状況を分析することは、バス輸送サービスの改善に大変有用である。これまで、機械学習を用いて、路線バスの所要時間や遅れを予測する研究が数多く行われている。その中で Kawatani ら [1] は、路線バスのあるバス停間の移動時間を予測する時に、精度をよく向上させる特徴量として「予測対象区間の1区間前の移動時間」を利用することで、予測精度を向上させられると提案している。しかし、「予測対象区間の1区間前の移動時間」という特徴量が重要であることはすなわち、予測したい地点・時刻の直前の情報が必要であるが、この情報を得るためには、バスの運行状況を常時、秒単位や分単位で収集し続ける必要

がある。そのためには、収集のための設備を多く設置する必要がある。設備を多くするとコスト増加が避けられない。そこで本研究では、過去の情報、特定の区間の情報を用いて精度よく予測するとともに、バス運行状況を表すプローブデータ収集のコストを小さくすることに挑戦する。具体的には走行履歴データを解析することにより、データ収集コストを小さくしつつ、移動時間の予測精度を高くするために最適な収集地点を求める。そこで、データ収集のために1台の路側器を設置することを考える。予測精度を高くすることができる路側器の設置地点を、統計的解析および機械学習によるシミュレーションで求めることとする。本研究の前提として、一定程度の走行履歴データをすでに取得できていることを想定する。たとえば、既設の路側器が路線上に存在していて、その路側器を介して走行履歴データを取得し、統計的解析や機械学習が可能な程度に蓄積できていることを想定する。あるいは、路側器が無い状態でも、走行履歴データを車載器から手作業で取得して、機械学習モデルを構築できている場合を仮定する。

設置地点の候補として、移動時間の分散が大きい地点を

<sup>1</sup> 九州大学大学院システム情報科学府  
Graduate School of Information Science and Electrical Engineering, Kyushu University

<sup>2</sup> 九州大学大学院システム情報科学研究院  
Faculty of Information Science and Electrical Engineering, Kyushu University

a) kawatani.takuya@m.ait.kyushu-u.ac.jp

b) sato.yuta@m.ait.kyushu-u.ac.jp

c) mine@ait.kyushu-u.ac.jp

採用することが考えられる。実際にその場所に路側器を設置したと仮定した場合に得られる情報をもとに機械学習を行い、予測精度を求めたところ、最適な収集地点は、必ずしも移動時間の分散が最大となる箇所とは同じにならないことが明らかになった。

以下、2節で関連研究を示し、本研究との差異や本研究の特色を述べる。3節で本研究の対象としたバス路線と、利用した走行履歴データについて説明する。4節では、本論文で明らかにすることを問題として定義する。5節ではデータ処理手法と実験手法について示し、6節でシミュレーション結果を説明する。7節で考察を実施し、8節でまとめと今後の課題を述べる。

## 2. 関連研究

従来より、路線バスの走行記録データ（プローブデータ）を用いた、バス運行所要時間の予測は広く行われてきた。内村ら [2] は、GPS による位置情報が記録されるバスロケーションシステムのデータを用いた、バス停間所要時間予測手法を提案している。また、今井ら [3] は、重回帰分析とカルマンフィルタモデルを用いて、高精度でバス運行状況を予測する手法を提案実証している。内村らの研究と今井らの研究では、ともに予測を実施する際に必須な入力情報として、リアルタイムな運行状況の入力が欠かせないことを示唆している。Bai らの研究 [4] においても、過去の運行履歴をもとに機械学習モデルを作成して、基礎となる移動時間予測値を算出する一方、最終的な予測結果の精度を高くするためには、リアルタイムな情報により予測値を動的に補正することが必要であることを示した。山口らの研究 [5]、および川谷らの研究 [1]、[6] においても、予測精度を高くするために必要な情報として、リアルタイムなバスの移動時間情報が重要であるとの結果を得た。

しかし、リアルタイムな情報を取得するためには、設備に対するコストや通信にかかるコストが大きくなる。岡村ら [8] は、とりわけ地方の路線バス事業者にとって、ランニングコストが大きくなるバスロケーションシステムの導入が困難であることを指摘している。低コストなバス走行履歴データの収集手法として、玉田ら [9] は、スマートフォンにアプリケーションを搭載したものをバス車両に車載機として設置して、バスの位置情報と運行便情報を毎分サーバに送信蓄積するシステムを提案し、実際にサービスを実施している。玉田らのシステムでは、データ通信を行うにあたり、定期的に一定のコストが発生することは避けられない。また、同システムを構築した伊藤ら [10] は、スマートフォンがハードウェアとして、熱や衝撃に対する信頼性をどの程度持つかを懸念点として示している。

これらを踏まえて、本研究では、バスの位置情報を得るために必要なコストを抑え、リアルタイムな情報がない状況においても、過去の情報と機械学習手法を用いて、高精

表 1 走行記録データの書式

項目	概要	例
ID	車両を識別する数字	11
走行時刻	位置情報が記録された日時	2019/05/21 11:58:15
緯度	度数法・小数点なし	3360033
経度	度数法・小数点なし	13021238
速度	車両の速度 (km/h)	37

表 2 九州大学線の運行本数の変化

日時	平日	土曜	日祝
2019.04.01 改正	444	204	174
2019.10.01 改正	366	167	157
2020.04.01 改正	361	162	152

度なバス停間移動時間を予測するために必要な、運行情報の取得箇所選定手法を検討する。

## 3. 利用したデータ

本研究では、昭和自動車株式会社（本社：佐賀県唐津市）が運行している、路線バス車両 42 台の走行記録データを用いた。走行記録データには、車両識別用 ID、走行時刻、緯度、経度、速度が記録されている。データ形式を表 1 に示す。走行記録データは、距離約 200m ごとに記録される。これとは別に、急ブレーキや急ハンドルなどの挙動が発生した場合は、挙動履歴データとして随時記録される。

走行記録データは 2019 年 2 月から 2021 年 3 月現在に至るまで継続して蓄積されている。本研究に利用したデータは、2019 年 4 月 1 日から 2020 年 3 月 31 日までの 1 年間分である。

路線バス車両は、九州大学線で運行されている。九州大学線は、福岡市西区の九大学研都市駅から九州大学伊都キャンパスまでの約 4km を結ぶ路線である。当路線の運行ルートは 3 つに大別される。本研究に用いたデータの期間における、ルート概要を図 1 に示す。

2019 年度の九州大学線の運行本数は表 2 の通りである。位置情報履歴数の合計は 14,293,440 件、バスの起点から終点までの走行を 1 運行として数えた場合の運行シーケンス数は 170,841 件であった。

走行記録データおよび挙動履歴データは、現在、九大学研都市駅付近と九州大学伊都キャンパス構内入口の 2 箇所に設置されている路側器によって収集されている。

## 4. 問題設定

本研究で解決する問題を次のように定義する。路線の起点 O から終点 D までの区間 O-D 間に、バス停が  $B_1, B_2, \dots, B_{N-1}, B_N$  と設置されているとする。この区間中に走行記録データを収集するための路側器 1 台を設置する地点 A を定める。移動時間の予測精度を高くすることができる地点 A の候補を見出す手法を検討する。

著者らは、地点 A の候補として、バス停間の移動時間  $t$




図 1 昭和自動車九州大学線路線図 (2019年4月1日現在)

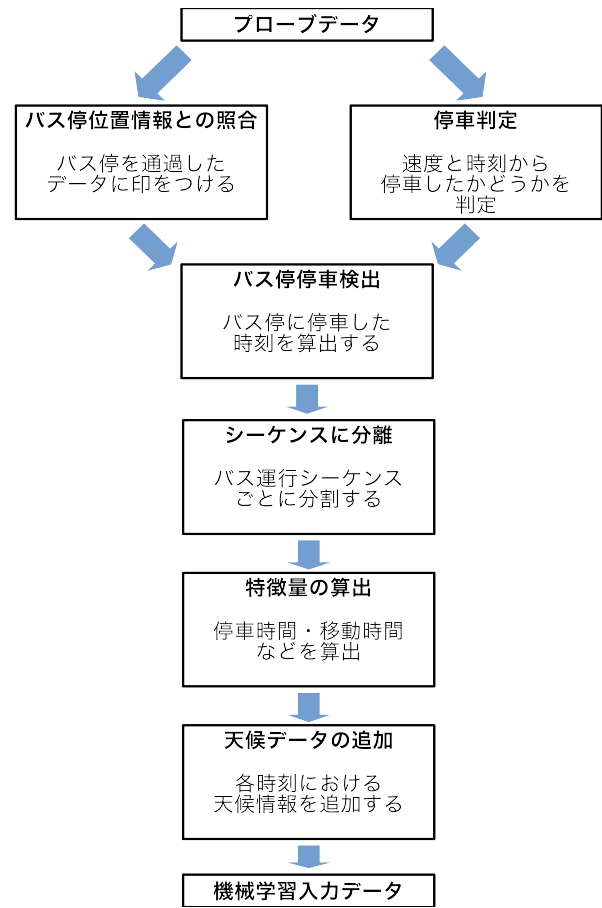


図 2 特徴量算出手順の概略

の分散が大きい区間を検討した。その根拠は、バスの遅延が発生するところは、バス運行便による移動時間の変動が大きいところであると考えたからである。本研究では移動時間の変動が大きい区間の情報を予測の際の特徴量として加えると、精度が向上するという仮説を立てた。

## 5. 実験手法

### 5.1 走行記録データからのバス停間移動時間算出手法

本研究で用いた走行記録データの特性として、速度9km/h未満で走行、または停止したことが記録されない点が挙げられる。そのため、データからは停止したことを直接に確認することができない。また、走行記録データにはバス停を通過、もしくはバス停に停車したことを示す情報が存在しない。これらの課題を解決するために、次に述べる手法でデータから停車情報、およびバス停の通過情報を算出した。さらに、これらの算出情報からバス停間の移動時間を求めた。処理手順概略を図2に示す。

まず、元データの位置情報は日本測地系で記録されているため、世界測地系に変換した。次に、変換後の走行記録データとバス停の座標を照合して、バス停の近傍を通過したかどうかを求めた。ここで、位置情報のずれにより、本来通過しているはずのバス停の通過情報が記録されないことがある。これを解決するため、バス停の通過時刻をバス

停間の距離により補完する処理を実施した。

このようにして得られたデータから、各バス停に停車、もしくは通過した時刻を求めた。簡略化のため、1シーケンス中に、各バス停について、通過情報が1件現れた場合はその時刻を通過時刻とし、複数件現れた場合は、その中で最も早い時刻を到着時刻、最も遅い時刻を出発時刻とみなした。その上で、あるバス停Aの出発時刻 $t_A$ とあるバス停Bへの到着時刻 $t_B$ の差、 $t_B - t_A$ をバス停A-B間の移動時間とした。

### 5.2 統計的解析

次に、各バス停間の移動時間について、基本統計量を求めた。統計量算出にあたり、次の基準から逸脱した値を外れ値として除去した。まず、位置情報取得がうまくいかなかったなどの理由で、走行時刻とバス停間の距離から算出した移動速度が60km/hを超えていると算出された移動時間の値を除去した。次に、移動時間が極めて長くなっているデータを選別する基準として、基本統計量から求めた標準偏差 $\sigma$ を用いた。平均値から3 $\sigma$ 分より大きく離れた値を除去した。

### 5.3 機械学習

移動時間予測には、機械学習手法のうち、勾配ブースティ

ング決定木 (GBDT) を用いた。この手法は、Yamaguchi ら [6] や Kawatani, Sato らの研究 [1], [7] において、また著者らも事前研究において、その有用性を確認している。予測精度の評価指標には、MAE (平均絶対誤差)、および MAAPE (Mean Arctangent Absolute Percentage Error) [11] を利用した。MAE は路線バスの運行所要時間を予測する先行研究において、予測精度を検証する指標として広く用いられている。また、MAAPE は MAPE (平均絶対パーセント誤差) を改良した指標であり、予測精度を検証するのに有用である。本研究では、MAAPE を主に用いた。以下に、MAE と MAAPE の定義を数式で示す。ここで、 $n$  はデータ数、 $y_i$  は実際のバス停間移動時間、 $\hat{y}_i$  は機械学習によって予測されたバス停間移動時間である。

$$MAE = \frac{1}{n} \sum_{i=0}^{n-1} |y_i - \hat{y}_i|$$

$$MAAPE = \frac{100}{n} \sum_{i=0}^{n-1} \arctan \left( \left| \frac{y_i - \hat{y}_i}{y_i} \right| \right)$$

機械学習器に対して次の特徴量を加えて、バス路線の起点から終点まで、つまり九大学研都市駅から九州大学伊都キャンパス (九大総合グラウンドバス停) までの運行所要時間を予測した。

- 運行日時 (年・月・日・時)
- 天候
- あるバス停間 1 区間の移動時間

ここで、運行日時は、起点バス停 (九大学研都市駅バス停) を出発した日付時刻を示す。また、天候は、福岡管区気象台において 1 時間ごとに観測されている天候をカテゴリ変数として扱ったものを加えた。あるバス停間 1 区間の移動時間は、1 つのシーケンスについて各バス停間の移動に要した時間、すなわち 5.1 節に示した  $t_B - t_A$  である。これを 1 区間ずつ入れ替える形で特徴量として用いた。

また、GBDT 手法では、各特徴量が予測にどのような影響を与えたかについて、その寄与度を示す Feature Importance という指標が得られる。この指標を算出して、予測精度との関係を調査した。今回用いた GBDT ライブラリは、CatBoost である [7]。CatBoost では、Feature Importance として PredictionValuesChange という値を算出する [12]。この値は、ある特徴量の変化が出力結果に与えた影響度をスコア化し、そのスコアの合計が 100 となるように正規化したものである。

## 6. 実験結果

各バス停間の移動時間の分散を求めた結果のうち、紙面の都合上、移動時間の分散の値が大きかった区間上位 5 区間を表 3, 表 4, 表 5 に示す。いずれの場合においても、九大ビッグオレンジバス停から九大理学部バス停までの

区間において、移動時間の分散がきわめて大きな値を示している。当該区間の時刻表上の所要時間は 1 分、バス停間の距離は約 350m である。この区間において極端な値を除去しきれていない原因は、もともときわめて大きな外れ値が存在していたため、外れ値除去前の標準偏差  $\sigma$  の値が大きくなっていたことにあると考えられる。さらに、既設のデータ収集路側器の設置位置も考慮し、九州大学伊都キャンパス構内のバス停間については候補から除外した。これらを踏まえて、移動時間の分散が大きい区間として、表 6 の区間を見出した。

表 6 に示す 6 区間に共通する特性として、区間の距離が長いこと、区間の途中に待ち時間の長い信号交差点が存在することが挙げられる。

ここで、上記の区間の移動時間情報を用いて機械学習を行い、起点から終点までのバス運行所要時間を予測したとき、その移動時間情報を用いない場合と比べてどのように予測精度が変化するか、また、それ以外の区間の移動時間情報を用いたときの予測精度の変化を調べた結果を表 7, 表 8, 表 9 に示す。

これらの表を見ると、移動時間の分散が大きい区間 6 区間を加えた場合において、必ずしも予測精度の改善度が最大になるとは限らないことがわかった。各路線ごとに見ていくと、学園通経由においては、移動時間の分散が最も大きい、九大学研都市駅バス停から元岡郵便局前バス停までの区間の移動時間を特徴量として加えたとき、予測精度が最も大きく改善した。その一方で、周船寺経由については、移動時間の分散が大きい区間 2 区間をそれぞれ特徴量として加えたときの予測精度の改善度より、分散が必ずしも大きいとはいえない 1 区間を特徴量として加えたときのほうが、予測精度をより改善させる効果があった。横浜西経由においても同様に、分散の大きさが上位ではない区間の移動時間を特徴量として加えたときのほうが、予測精度がより改善した。

ここで、機械学習器が予測するにあたって、どの特徴量が予測に大きな影響を及ぼしたかを、Feature Importance の指標を用いて観察した。その結果を表 10, 表 11, 表 12 に示す。なお、紙面の都合上、Feature Importance の値が大きい順に上位 5 件のみを示す。

Feature Importance を観察すると、重要度が高い値を示している区間の移動時間を特徴量として加えたときに、精度がよく改善していた。また、学園通経由と周船寺経由については、重要度が上位の値として、運行時間のうち、何時に起点バス停を出発したかという特徴量が出ていた。

## 7. 考察

### 7.1 予測精度をよく改善する区間と移動時間の分散との関係

予測精度を改善するために、機械学習器に加える特徴量

表 3 移動時間に関する統計量（学園通経由）

始点	着点	N	最小値	平均値	中央値	最大値	分散 $\sigma^2$	標準偏差 $\sigma$
九大ビッグオレンジ	九大理学部	7631	21	51.93	42	6426	17174.40	131.05
九大学研都市駅	元岡郵便局前	15968	117	358.00	353	820	3553.16	59.61
西消防署元岡出張所前	九大ビッグオレンジ	12329	35	77.55	71	494	946.26	30.76
元岡小学校前	産学連携交流センター	16501	65	139.52	139	237	838.29	28.95
九大船舶・航空実験棟	九大総合グラウンド	13325	16	27.42	23	773	756.87	27.51

表 4 移動時間に関する統計量（周船寺経由）

始点	着点	N	最小値	平均値	中央値	最大値	分散 $\sigma^2$	標準偏差 $\sigma$
九大ビッグオレンジ	九大理学部	4839	21	75.30	38	30060	750103.00	866.09
九大船舶・航空実験棟	九大総合グラウンド	7101	16	33.77	24	2094	2140.29	46.26
九大学研都市駅	北原	7228	46	120.47	117	251	1492.57	38.63
元岡農協前	九大東ゲート	7187	173	303.08	302	440	1173.73	34.26
周船寺	泉	7291	62	128.31	122	240	1076.77	32.81

として、どのバス停区間の移動時間情報を用いるとよいかを決定する指標として、各バス停区間の移動時間の分散を求めた。移動時間の分散が大きい区間は、運行便によって移動時間の差が大きいことを意味する。移動時間の差が大きいことはバスの遅延に関係が深いと考えた。しかし、実際には、予測精度をよく改善する区間は、必ずしも移動時間の分散が大きい区間であるとは限らなかった。各バス停区間の移動時間の分散と、最終的にバスの起点から終点までの移動時間との関係について、相関を調査するなど、指標として適切であるかどうかをさらに検討する必要がある。

## 7.2 予測精度をよく改善する区間と Feature Importance との関係

どの特徴量が予測精度の向上に寄与していたかを、Feature Importance の値によって比較した結果、Feature Importance の値が大きい区間は、予測精度の改善に大きく貢献していることがわかった。しかし、ルートによっては、各 Feature Importance の値に大きな差が見られない状況もあった。また、各区間の移動時間以外の特徴量として、運行時間帯の情報が出現していた。これについては後の 7.5 で議論する。

## 7.3 Feature Importance を常に求めることが可能か

予測精度と移動時間の分散、および Feature Importance との関係を観察した結果、両者を比較した場合には、地点選定に Feature Importance の値を参考として用いることが有用であると考えられる。しかし、Feature Importance の値を得るためには、まず走行履歴データを収集した上で特徴量を抽出し、機械学習のモデル構築を実施する必要がある。機械学習のモデル構築には一般的に大きな計算機資源を必要とする。計算機資源が限られている状況下では、統計的解析により路側器の設置地点を選定できたほうがよい。したがって、機械学習によるシミュレーションが実施できなくても利用可能な、統計的指標を検討する必要は依

然として存在すると考えられる。

## 7.4 路側器の最適な設置位置

本研究で対象としている九州大学線は、大きく 3 つのルートに大別される。路側器を 1 台だけ設置する場合は、今回求めた各ルートにおけるバス停間での予測精度向上の度合いだけでなく、全てのルートを含めた総合的な予測精度の向上を図っていくことが大事だと考える。本研究により、各ルートにおいて予測精度を最も向上させる設置位置の候補を調べることができた。しかし、各ルート独自の区間に路側器を設置した場合は、他のルートについてはその恩恵を受けることができない。

そのため、最終的に路側器を設置する位置を選定するには、複数ルートの予測精度を総合的に改善するか、あるいは 1 つのルートに絞って予測精度を改善するか、その点に着目した指標づくりや議論が必要となる。

## 7.5 運行時間帯の重要性

本研究の機械学習によるシミュレーション結果として、移動時間予測に重要な特徴量の中に、バスの運行時間帯の情報が出てきたルートがあった。たとえば、あるルートの移動時間予測にあたり、各バス停区間の移動時間よりも運行時間帯のほうが有用な場合、そのルートに路側器を設置せず、別のルートに路側器を設置して予測精度改善を目指すことが考えられる。前節も含め、総合的に選定するための指標を定める必要がある。

## 8. まとめと今後の課題

本研究において、プローブデータを収集する路側器を 1 台設置するとき、最適な設置位置を統計的解析と機械学習によるシミュレーションで求めた。その結果、最適な設置位置は、必ずしもバス停間移動時間の分散の最も大きな箇所と同じにはならないことを確認した。また、機械学習によるシミュレーションを実施し、予測精度を最も向上さ

表 5 移動時間に関する統計量 (横浜西経由)

始点	着点	N	最小値	平均値	中央値	最大値	分散 $\sigma^2$	標準偏差 $\sigma$
九大ビッグオレンジ	九大理学部	5166	21	46.69	37	5107	15978.00	126.40
九大船舶・航空実験棟	九大総合グラウンド	7371	16	35.38	25	2000	2938.32	54.21
九大学研都市駅	舞鶴高校入口	5914	75	181.60	177	338	2184.71	46.74
元岡小学校前	九大東ゲート	7379	155	311.38	307	501	2022.06	44.97
九大中央図書館	九大ビッグオレンジ	7351	20	64.17	60	1140	1254.43	35.42

表 6 移動時間の分散が大きい区間

路線	区間
学園通経由	九大学研都市駅→元岡郵便局前
周船寺経由	九大学研都市駅→北原
周船寺経由	周船寺→泉
周船寺経由	元岡農協前→九大東ゲート
横浜西経由	九大学研都市駅→舞鶴高校入口
横浜西経由	元岡小学校前→九大東ゲート

表 7 指定区間の移動時間を加えた場合の予測精度 (学園通経由)

区間	MAE [s]	MAAPE
(どの区間も加えない)	109.658	9.421%
九大学研都市駅 → 元岡郵便局前	95.024	7.839%
元岡郵便局前 → 元岡小学校前	107.003	8.920%
元岡小学校前 → 産学連携交流センター	101.990	8.254%
産学連携交流センター → 西消防署元岡出張所前	102.886	8.424%
西消防署元岡出張所前 → 九大ビッグオレンジ	99.763	8.288%

表 8 指定区間の移動時間を加えた場合の予測精度 (周船寺経由)

区間	MAE [s]	MAAPE
(どの区間も加えない)	136.279	6.901%
九大学研都市駅 → 北原	132.429	6.679%
北原 → 山崎	132.967	6.648%
山崎 → 周船寺東口	133.237	6.670%
周船寺東口 → 周船寺	141.245	7.028%
周船寺 → 泉	134.386	6.780%
泉 → 富士見	134.135	6.726%
富士見 → たろう保育園前	136.395	6.839%
たろう保育園前 → 元岡農協前	135.378	6.818%
元岡農協前 → 九大東ゲート	135.814	6.685%

表 9 指定区間の移動時間を加えた場合の予測精度 (横浜西経由)

区間	MAE [s]	MAAPE
(どの区間も加えない)	132.868	6.583%
九大学研都市駅 → 舞鶴高校入口	131.209	6.506%
舞鶴高校入口 → 横浜西	140.576	7.060%
横浜西 → 工芸会ワークセンター	134.161	6.637%
工芸会ワークセンター → 玄洋高校	131.363	6.545%
玄洋高校 → 今出	128.479	6.298%
今出 → 元岡郵便局前	134.474	6.648%
元岡郵便局前 → 元岡小学校前	137.818	6.894%
元岡小学校前 → 九大東ゲート	127.446	6.190%

せる区間と、Feature Importance の値との関係を調査した。その結果、予測精度を最も向上させる区間は、Feature

表 10 Feature Importance (学園通経由)

ID	特徴量	重要度
1	d_1to32	21.230604
2	date_hour	17.100325
3	d_42to51	15.108698
4	d_53to54	8.483754
5	d_34to40	7.590674

表 11 Feature Importance (周船寺経由)

ID	特徴量	重要度
1	date_hour	8.931596
2	d_6to8	7.978679
3	d_12to14	7.138210
4	d_20to45	6.661279
5	d_10to12	6.604671

表 12 Feature Importance (横浜西経由)

ID	特徴量	重要度
1	d_58to60	22.477077
2	d_28to30	18.473698
3	d_54to56	9.147737
4	d_51to53	7.609912
5	d_30to32	7.356160

Importance の値も大きいことを確認した。

今後、逆方向となる九州大学伊都キャンパスから九大学研都市駅方面への運行状況や予測精度向上に最適な路側器の設置位置を調査し、総合的に最適な設置位置を求めたい。

謝辞 本研究の一部は JSPS 科研費 JP19KK0257 の助成を受けた。本研究にあたり、昭和自動車株式会社には、バスの走行記録データ取得の実証実験に協力を頂き、データ分析の許可を頂いた。感謝申し上げる。

#### 参考文献

- [1] T. Kawatani, T. Yamaguchi, Y. Sato, R. Maita, T. Mine, *Prediction of bus travel time over intervals between pairs of adjacent bus stops using city bus probe data*, 第 18 回 ITS シンポジウム 2020, (2020).
- [2] 内村圭一, 成松裕介, 衛藤旭秀, 胡振程: バスロケーション情報を用いたバス停間所要時間予測, 国際交通安全学会誌 Vol.32 No.3(2007).
- [3] 今井瞳, 廣井慧, 河口信夫: 複数事業者の路線バス運行実績データに基づく到着時刻予測モデルの提案と精度検証, 情報処理学会研究報告 Vol.2017-ITS-71 No.23(2017).
- [4] C. Bai, Z. Peng, Q. Lu, J. Sun, *Dynamic Bus Travel Time Prediction Models on Road with Multiple Bus Routes*, Computational Intelligence and Neuroscience

- Vol. 2015, 432389 (2015).
- [5] T. Yamaguchi, M. As, and T. Mine, *Prediction of bus delay over intervals on a various kinds of routes using bus probe data*, in The 5th IEEE/ACM International Conference on Big Data Computing, Applications and Technologies (BDCAT 2018), pp. 97–106 (2018).
  - [6] T. Yamaguchi, R. Maita, T. Kawatani, T. Mine, *Prediction of travel time over intervals between two bus stops using bus probe data*, Proceedings of 17th ITS Symposium 2019, (2019).
  - [7] Yuta Sato, Takuya Kawatani, Tsunenori Mine: *Influence of Weather Features to Determine Sudden Braking*, International Journal of Intelligent Transportation Systems Research, <https://doi.org/10.1007/s13177-021-00253-6>(2020).
  - [8] 岡村健志, 永原三博, 菊池豊, 熊谷靖彦, 中川敏正: 地方部でのバス案内システム「chi-bus」の適用, 土木計画学研究・論文集講演集 Vol.41(2010).
  - [9] 玉田匡, 伊藤昌毅, 川村尚生, 菅原一孔: バスの遅れ予測を目的とする, バスロケーションシステムから得た走行データの分析, 第12回情報科学技術フォーラム M-036 第4分冊 pp.413–418(2013).
  - [10] 伊藤昌毅, 川村尚生, 菅原一孔: スマートフォンを利用したバスロケーションシステムの開発, 電子情報通信学会論文誌 D Vol. J96–D No.10 pp.2327–2339(2013).
  - [11] S. Kim, H. Kim, *A new metric of absolute percentage error for intermittent demand forecasts*, International Journal of Forecasting, Vol. 32, Issue 3, pp. 669–679, (2016).
  - [12] Yandex CatBoost : Feature Importance - CatBoost Documentation(online), [https://catboost.ai/docs/concepts/output-data\\_feature-analysis\\_feature-importance.html?lang=en](https://catboost.ai/docs/concepts/output-data_feature-analysis_feature-importance.html?lang=en) (2021.04.17).