

修士論文

バス停間の乗客数の相関と日時や天候の影響を考慮した LSTMに基づく乗客数予測手法

山村 竜也

奈良先端科学技術大学院大学

先端科学技術研究科

情報理工学プログラム

主指導教員: 藤川 和利 教授

(情報科学領域)

令和5年3月17日提出

本論文は奈良先端科学技術大学院大学先端科学技術研究科に
修士(工学) 授与の要件として提出した修士論文である。

山村 竜也

審査委員：

藤川 和利 教授	(主指導教員, 情報科学領域)
安本 慶一 教授	(副指導教員, 情報科学領域)
新井 イスマイル 准教授	(副指導教員, 情報科学領域)

バス停間の乗客数の相関と日時や天候の影響を考慮した LSTMに基づく乗客数予測手法*

山村 竜也

内容梗概

利用者にとってバスを利用するか否かの判断材料となる未来のバスの乗客数を誤差が小さくなるように予測することは、バスサービスの品質向上には必要不可欠である。特に、乗客が着席できない程混雑している状況では、混雑していない状況と比較して誤差による影響が大きいため、小さな誤差となる予測が求められる。本研究では、バスの乗客数予測の分野で最も予測誤差が小さいLSTMを用いた手法に存在する2つの課題に取り組むことで、予測誤差の縮小を目指す。1つ目の課題は、連続するバス停間のバス停出発時の乗客数の相関を考慮することである。2つ目の課題は、過去の乗客数、時間帯、曜日、休日か否か、降水量、気温、天気の詳細なデータ全てを使用した予測を実施することである。本研究ではMultiple-IOとK-feature-integratedを組み合わせた手法を提案する。Multiple-IOでは連続するバス停間のバス停出発時の乗客数の相関を考慮できるように1つの路線に存在するバス停全体で1つのモデルを作成する。K-feature-integratedでは先述した全てのデータを同時にモデルへ入力する際に、適切にモデルが学習できるように、前処理として正規化とワンホットエンコーディングを実施する。評価では、兵庫県神戸市で運行されているバスから収集したデータと、気象庁が公開している気象データを使用した。評価した結果、提案手法では既存手法と比較して、乗客が着席できない程混雑している状況において1便先の乗客数予測の平均絶対誤差が2.109人少ない3.602人まで縮小した。

*奈良先端科学技術大学院大学 先端科学技術研究科 修士論文, 令和5年3月17日.

キーワード

高度道路交通システム, バスの乗客数予測, 機械学習, LSTM

Bus ridership prediction with time section, weather, and ridership trend aware multiple LSTM*

Tatsuya Yamamura

Abstract

Predicting bus ridership with high accuracy, which helps users decide to use buses, is essential for improving the quality of bus service. Particularly in conditions where passengers are so crowded that they cannot be seated, the impact of errors is more significant than in uncrowded conditions, so high prediction accuracy is required. This research aims to improve prediction accuracy by addressing two issues in LSTM-based methods, which have high prediction accuracy in bus ridership prediction. The first issue is finding the correlation of ridership between consecutive bus stops. The second issue is to predict using all seven kinds of data, ridership, time of day, day of the week, holiday or not, precipitation, temperature, and weather. In this research, we propose a method that combines Multiple-IO and K-feature-integrated. Multiple-IO is a single model per the entire bus stops present on a single route to consider the correlation of ridership between consecutive bus stops. K-feature-integrated method conducts normalization and one-hot encoding as preprocessing to ensure that the model is appropriately trained when all the above data are input to the model simultaneously. We used data collected from buses operating in Kobe City, Hyogo Prefecture, and meteorological data published by the Japan Meteorological Agency for our evaluation. The evaluation

*Master's Thesis, Graduate School of Science and Technology, Nara Institute of Science and Technology, March 17, 2023.

showed that the proposed method reduced the mean absolute error in ridership prediction in one service ahead to 3.602 passengers, 2.109 passengers less than the existing method in a crowded condition where passengers cannot be seated.

Keywords:

Intelligent Transport Systems, Bus Ridership Prediction, Machine Learning, LSTM

目次

1. はじめに	1
2. 想定するバス路線	4
2.1 バス路線の概要	4
2.2 想定するバスの運行形態	4
2.2.1 運行経路	4
2.2.2 時刻表	5
2.2.3 バスの乗客数データの収集	5
2.3 想定するバス乗客数の傾向	6
2.4 バス路線で実施するバス乗客数予測	6
3. 関連研究と課題	8
3.1 Long Short Term Memory (LSTM)	8
3.2 統計的手法を用いたバスの乗客数予測の研究	10
3.3 LSTMやRNNを用いた手法によるバスの乗客数予測の研究	12
3.4 関連研究の課題	15
4. バス停間の乗客数の相関と日時や天候の影響を考慮したLSTMに基づく乗客数予測手法	17
4.1 提案手法の概要	17
4.2 バス停間の乗客数の相関を考慮するモデル	18
4.2.1 Single-IO	19
4.2.2 Multiple-IO	20
4.3 K-feature-integrated	21
5. 評価	24
5.1 評価で使用するデータセット	24
5.1.1 運行データセットの作成	26
5.1.2 気象データセットの作成	36

5.2	評価方法	37
5.2.1	評価指標とテストデータ	37
5.2.2	比較対象	40
5.3	パラメータチューニング	41
5.3.1	Halyal らの手法におけるパラメータチューニング	43
5.3.2	手法 A~E におけるパラメータチューニング	46
5.4	評価結果	49
5.4.1	十分混雑が発生する便のデータにおける評価結果	49
5.4.2	混雑状態の便のデータにおける評価結果	51
5.4.3	バス停毎の全ての便のデータにおける評価結果	53
5.4.4	混雑状態か空き状態かの分類予測の評価結果	58
6.	考察	61
6.1	乗客数予測における提案手法の優位性	61
6.2	混雑状態か空き状態かの分類の予測における提案手法の優位性	62
6.3	乗客数予測が乱れた日	63
6.4	今後の展望	68
7.	おわりに	69
	謝辞	70
	参考文献	71

目 次

1	インバウンド/アウトバウンド経路のバス運行	2
2	便間の乗客数とバス停間の乗客数	3
3	ループ経路のバス運行	5
4	1 便先の乗客数予測	7
5	RNN の構造	9
6	LSTM の構造	10
7	Ma らの手法におけるフレームワーク	11
8	Halyal らの手法のアーキテクチャ	13
9	提案手法のアーキテクチャ	18
10	Single-IO	19
11	全てのバス停の乗客数データから 1 つの時系列データを作成する 方法	20
12	Multiple-IO	21
13	正規化とワンホットエンコーディングを実施した結果	22
14	説明変数と目的変数のデータ分割処理	23
15	運行データセットの構造と例	24
16	気象データセットの構造と例	25
17	みなと観光バス 21 系統上りのバス路線	26
18	技研トラステム社製乗降客カウントセンサ	26
19	運行データセットの作成	27
20	ノイズデータの補正	28
21	バス停 1 における乗客数の自己相関	29
22	バス停 2 における乗客数の自己相関	29
23	バス停 3 における乗客数の自己相関	29
24	バス停 4 における乗客数の自己相関	30
25	バス停 5 における乗客数の自己相関	30
26	欠損データの補完	31
27	バス停毎の乗客数の箱ひげ図	32

28	バス停1における便番号毎の乗客数の箱ひげ図	32
29	バス停2における便番号毎の乗客数の箱ひげ図	33
30	バス停3における便番号毎の乗客数の箱ひげ図	33
31	バス停4における便番号毎の乗客数の箱ひげ図	34
32	バス停5における便番号毎の乗客数の箱ひげ図	34
33	2022年9月7日のバス停4における乗客数予測の結果	62
34	2022年9月19日のバス停4における乗客数予測の結果	63
35	台風14号の経路図	64
36	台風4号の経路図	65
37	2022年7月5日のバス停4における乗客数予測の結果	65
38	2022年9月17日から2022年9月22日までの1時間毎の気圧と平均風速データ	67
39	2022年7月3日から2022年7月8日までの1時間毎の気圧と平均風速データ	67

目次

1	混雑状態と空き状態と閾値の用語の定義	6
2	関連研究における有効なデータの使用の有無	16
3	運行データセットに含まれる各フィールドの形式	25
4	気象データセットに含まれる各フィールドの形式	25
5	バスの時刻表	35
6	5つのバス停間の乗客数の相関係数	36
7	2021年10月1日から2022年9月30日までの期間の6:00~23:00 の1時間毎の兵庫県神戸市の天気の観測回数	37
8	評価に使用するテストデータの便数	39
9	比較手法一覧	41
10	Halyal らの手法のバス停1におけるパラメータチューニング	44
11	Halyal らの手法のバス停2におけるパラメータチューニング	44

12	Halyal らの手法のバス停3におけるパラメータチューニング	45
13	Halyal らの手法のバス停4におけるパラメータチューニング	45
14	Halyal らの手法のバス停5におけるパラメータチューニング	46
15	手法 A におけるパラメータチューニング	47
16	手法 B におけるパラメータチューニング	47
17	手法 C におけるパラメータチューニング	48
18	手法 D におけるパラメータチューニング	48
19	手法 E におけるパラメータチューニング	49
20	十分混雑が発生する便のデータにおける Halyal らの手法と手法 A と手法 B の評価結果	50
21	十分混雑が発生する便のデータにおける手法 B~E の評価結果 . .	50
22	十分混雑が発生する便のデータにおける過去の平均値手法と Halyal らの手法と手法 E の評価結果	51
23	混雑状態の便のデータにおける Halyal らの手法と手法 A と手法 B の評価結果	52
24	混雑状態の便のデータにおける手法 B~E の評価結果	52
25	混雑状態の便のデータにおける過去の平均値手法と Halyal らの手 法と手法 E の評価結果	53
26	バス停1の全ての便のデータにおける Halyal らの手法と手法 A と 手法 B の評価結果	54
27	バス停2の全ての便のデータにおける Halyal らの手法と手法 A と 手法 B の評価結果	54
28	バス停3の全ての便のデータにおける Halyal らの手法と手法 A と 手法 B の評価結果	54
29	バス停4の全ての便のデータにおける Halyal らの手法と手法 A と 手法 B の評価結果	55
30	バス停5の全ての便のデータにおける Halyal らの手法と手法 A と 手法 B の評価結果	55
31	バス停1の全ての便のデータにおける手法 B~E の評価結果	55

32	バス停2の全ての便のデータにおける手法B~Eの評価結果	56
33	バス停3の全ての便のデータにおける手法B~Eの評価結果	56
34	バス停4の全ての便のデータにおける手法B~Eの評価結果	56
35	バス停5の全ての便のデータにおける手法B~Eの評価結果	57
36	バス停1の全ての便のデータにおける過去の平均値手法と Halyal らの手法と手法Eの評価結果	57
37	バス停2の全ての便のデータにおける過去の平均値手法と Halyal らの手法と手法Eの評価結果	57
38	バス停3の全ての便のデータにおける過去の平均値手法と Halyal らの手法と手法Eの評価結果	58
39	バス停4の全ての便のデータにおける過去の平均値手法と Halyal らの手法と手法Eの評価結果	58
40	バス停5の全ての便のデータにおける過去の平均値手法と Halyal らの手法と手法Eの評価結果	58
41	十分混雑が発生する便のデータにおける Halyal らの手法と手法A と手法Bの分類予測の結果	59
42	十分混雑が発生する便のデータにおける手法B~Eの分類予測の結果	60
43	十分混雑が発生する便のデータにおける過去の平均値手法と Halyal らの手法と手法Eの分類予測の結果	60
44	バス停4における MAE のまとめ	62

1. はじめに

バスの空席数や混雑状況は、人々がバスを利用するか否かの判断に影響を与えることが明らかになっている [1-4]。例えば、Kim らはまだバスに乗車していない利用者にバス車内の混雑状況の情報を与えた場合に、混雑したバスに乗車する利用者が減少する可能性があることを明らかにした [4]。この傾向は、近年の COVID-19 の流行によってより強くなっている [5]。このようにバスの混雑状況がバスの利用者にとって有用な情報となることから、人々に未来のバスの車内人数（以下、乗客数）を提供することは、バスサービスの品質向上において重要なサービスの1つである。

これまでのバスの乗客数予測に関する研究では、過去のバスの乗客数データの曜日や時間帯毎の平均値などを使用した統計的手法や、曜日や時間帯や降水量などの様々なデータを活用する機械学習を用いた手法が用いられてきた。これらの予測手法のうち、後者の方が小さな誤差で乗客数を予測できる [6-8]。後者の中でも特に、データを時系列データとして学習できる Long Short Term Memory (LSTM) を用いた手法が最も小さな誤差で乗客数を予測できる [7,8]。しかし、LSTM を用いた各関連研究の提案手法の予測の平均絶対誤差はそれぞれ、4.46 人 [7]、10.19 人 [9]、14.91 人 [10] という結果となっている。こうした誤差を含む予測結果をバス利用者に提供することは、バスサービスの品質の低下に繋がると懸念されている [11]。バスの乗客数予測に関する研究はこのように多くの研究者らによって取り組まれてきたが、未だバス乗客数の予測誤差を改善する必要がある。

LSTM を用いたバスの乗客数予測に関する関連研究を調査した結果、どのようなデータをどのように学習させるかという特徴量設計に2つの課題が存在するとわかった。1つ目は、連続するバス停間のバス停出発時の乗客数の相関を考慮することである。一般的な日本のバスは、始点から終点まで決められたバス停を時刻表通りに順に経由するインバウンド/アウトバウンド経路で運行されている (図 1)。なお、インバウンドとは都市部と都市郊外を結ぶバスにおける都市方面に向かうバスで、アウトバウンドとは郊外方面に向かうバスである。このような運行形態のバス停では、ある便のバス停出発時の乗客数とその次の便のバス停出発時の乗客数の間（便間の乗客数）に相関があることが知られており（以下、乗

客数とは“バス停出発時の乗客数”を指す), 相関を考慮した予測手法が既に提案されている [8,9]. また, あるバス停の乗客数とその次のバス停の乗客数の間(バス停間の乗客数)にも同様に相関があると考え. この2つの乗客数の相関を同時に考慮できれば, 単に便間の乗客数の相関のみを考慮するよりも小さな誤差で予測できると考える. なお, 便間の乗客数とバス停間の乗客数は図2に示す通りである. 2つ目は, 過去の乗客数, 時間帯, 曜日, 休日か否か(以下, 休日フラグ), 降水量, 気温, 天気の詳細全てを使用した予測を実施することである. 時間帯や曜日, 休日か否かがバスの利用者数に影響を与えることが知られている [12,13]. また, 降水量や気温, 天気もバスの利用者数に影響を与えることが知られている [14-16]. これまでの研究では, これらのデータを部分的に組み合わせて特徴量として用いることは試みられてきた. しかし, 全てを組み合わせ特徴量として用いる試みは, 調査した範囲ではまだない. 本研究では, これら2つの課題に取り組む.




図 1: インバウンド/アウトバウンド経路のバス運行




図 2: 便間の乗客数とバス停間の乗客数

本研究による貢献を以下にまとめる。

1. 連続するバス停間の乗客数の相関を考慮するために、1つのバス路線に存在するバス停全体で1つのモデルを作成することが有効であると示した。
2. 過去の乗客数、時間帯、曜日、休日フラグ、降水量、気温、天気データ全てを特徴量とする手法が、これらの特徴量を部分的に組み合わせる手法よりも有効であると示した。

本稿の構成は以下の通りである。第2章では、想定するバス路線を述べる。第3章では、バスの乗客数予測の関連研究と課題を述べる。第4章では、第3章で言及する2つの課題を解決するための提案手法を述べる。第5章では、提案手法の乗客数予測を評価する。第6章では、第5章における評価結果に対する考察を述べる。第7章では本稿をまとめる。

2. 想定するバス路線

本章では、本研究で我々が想定するバス路線を説明する。まず、バス路線の概要を説明する。次に、想定するバスの運行形態、バス乗客数の傾向を述べる。最後に、そのバス路線で実施するバス乗客数予測の想定を示す。

2.1 バス路線の概要

バス路線とは、バスが定期的に運行されることが定められた路線である。バス路線には複数のバス停が存在し、各バス停でバスの利用者が乗降する。バスがどのような経路で運行されるか、バスの運行に時刻表を使用するかは国や地域毎に大きな違いがある。また、バス運営会社によってバスの乗客数データを収集しているかは異なり、バス路線によって乗客数の傾向も異なる。次節以降では想定するバスの運行形態、乗客数の傾向、乗客数予測を説明する。

2.2 想定するバスの運行形態

バスの運行形態は国や地域、バス運営会社毎に異なるが、本節では本研究で想定する運行形態を説明する。

2.2.1 運行経路

一般的に、バスはインバウンド/アウトバウンド経路かループ経路で運行される。なお、インバウンドとは都市部と都市郊外を結ぶバスにおける都市方面に向かうバスで、アウトバウンドとは郊外方面に向かうバスである。インバウンド/アウトバウンド経路とループ経路の両方とも事前に決められたバス停を順に経由して運行される。これらの違いとしては、前者は図 1 に示すように始点と終点が存在する運行である。後者は図 3 に示すように始点や終点が存在しない運行である。一般的に日本のバスは前者の運行が実施されているので、本研究においてもこのようなバス路線を想定する。

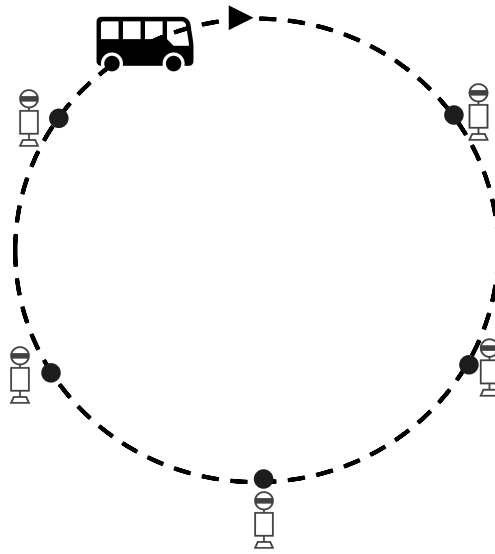


図 3: ループ経路のバス運行

2.2.2 時刻表

一般的に、バスは事前に決められた時刻表通りに運行される形態と、時刻表なしで運行される形態がある。一般的に日本では前者の運行が実施されている。そのため、本研究でも前者の運行が実施されているバス路線を想定する。

2.2.3 バスの乗客数データの収集

乗客数を予測するためには予測モデルを作成する必要がある。予測モデルの作成には予測対象路線の過去の乗客数データが必要である。本章で後述するが、本研究では便番号単位で乗客数を予測する。そのため、便番号単位で乗客数データを収集しているバス路線を想定する。

乗客数データを収集するための方法は、ICカード、乗降客カウントセンサ、運転手によるカウントなどが挙げられる [17]。本論文では乗客数データを収集するための方法の検討はしないため、いずれかの方法で乗客数データを収集しているバス路線を想定する。

2.3 想定するバス乗客数の傾向

第1章で述べたように、乗客数予測の中でもバス車内が混雑している状況の乗客数を予測する必要がある。そのため、乗客数が多いバス路線を想定する。なお、混雑状態と空き状態の閾値、バスの混雑状態、バスの空き状態は、表1に示す通り定義する。閾値は、昨今のCOVID-19の流行も考慮してバス乗車時のソーシャルディスタンスを保つためにこのように定義した。

外的要因の影響を受けずに常に乗客数が乱れないバス路線である場合、予測結果に大きな誤差は発生しない。一方、外的要因の影響を受けて乗客数が乱れるバス路線である場合、予測結果に大きな誤差が発生する。後者の状況で誤差が小さくなるように乗客数を予測することが重要である。そのため、外的要因の影響を受けて乗客数が乱れるバス路線を想定する。

表 1: 混雑状態と空き状態と閾値の用語の定義

用語	定義
閾値	バスにおいて隣に乗客が着席できないと仮定した場合の着席可能座席数
混雑状態	閾値以上の乗客がバス車内にいる状態
空き状態	閾値未満の乗客がバス車内にいる状態

2.4 バス路線で実施するバス乗客数予測

バス利用者にとって、単位時間あたりのバス停毎の利用者数予測の結果より便番号単位の乗客数予測の結果の方が便利である。さらに、便番号単位の乗客数予測の中でも、まずは1便先の乗客数を誤差が小さくなるように予測することが重要だと考える。理由としては、1便先の乗客数予測の誤差が大きい場合、それより先の乗客数予測の誤差はさらに大きくなることが見込まれ、大きな誤差を含む予測結果をバス利用者に提供することで不満の原因となるからである。そのため、本研究では1便先の乗客数予測を想定する（図4）。




図 4: 1 便先の乗客数予測

3. 関連研究と課題

本章では、3.1節で、提案手法において重要となる基礎技術である LSTM を述べ、3.2節で、統計的手法を用いたバスの乗客数予測の研究を述べ、3.3節で、LSTM や Recurrent Neural Network (RNN) を用いたバスの乗客数予測の研究を述べる。その後、3.4節で関連研究の課題について言及する。

3.1 Long Short Term Memory (LSTM)

LSTM はデータの時間的な依存関係を学習できる RNN の拡張である。一般的なニューラルネットワークは、時間的な依存関係のあるデータを用いた学習には適していない。そこで、RNN では時間的な依存関係のあるデータを用いた学習に適合させるため、ニューラルネットワークの中間層に再起的な構造を導入した。しかし、RNN は短期的に依存する時系列データを扱える一方で、長期的に依存する時系列データを扱う際には勾配消失問題が発生した。勾配消失問題とは、ニューラルネットワークを用いた学習をする際に、誤差逆伝播に必要な勾配が非常に小さくなり適切な学習ができない問題である。LSTM ではメモリ、忘却ゲート、入力ゲート、出力ゲートを導入することで、この勾配消失問題を解決した。

RNN の構造を図 5 に示す。RNN は入力値 x_t に対しその 1 つ前のステップからの出力値 h_{t-1} も考慮した学習をする。出力値 h_t は式 (3.1) のように計算する。 x_t は入力ベクトル、 h_t は中間層ベクトル、 b_h はバイアスベクトル、 U_h 、 V_h はパラメータ行列、 σ_c は活性化関数として \tanh をそれぞれ表している。

$$h_t = \sigma_c(U_h x_t + V_h h_{t-1} + b_h) \quad (3.1)$$




図 5: RNN の構造

LSTM の構造を図 6 に示す。LSTM では、RNN を使用した際に生じていた勾配消失問題を解決するために、メモリ、忘却ゲート、入力ゲート、出力ゲートを追加した。忘却ゲート f_t は、過去の状態 c_{t-1} をどの程度維持するかを決定するためのゲートであり、式 (3.2) のように計算する。計算の結果、0 から 1 の間の数値が出力され、0 は完全破棄、1 は完全維持を示す。次に、過去のセル状態 c_{t-1} から新たなセル状態 c_t への更新をする。まず、入力ゲート i_t でどの値を更新するかを式 (3.3) のように計算し、セル状態に含む新たなベクトル \tilde{c}_t を式 (3.4) のように計算する。この 2 つの値、忘却ゲートの値、過去のセル状態を組み合わせる式 (3.5) のように計算し、セル状態を更新する。次に、出力ゲートからの出力値 o_t を式 (3.6) のように計算する。最終的な予測値 h_t を式 (3.7) のように計算する。式 (3.2)~(3.7) において、 x_t は入力ベクトル、 h_{t-1} は 1 つ前のステップからの出力値、 h_t は中間層ベクトル、 $W_f, W_i, W_c, W_o, U_f, U_i, U_c, U_o$ はパラメータ行列、 b_f, b_i, b_c, b_o はバイアスベクトル、 σ_g は活性化関数として sigmoid、 σ_h は活性化関数として tanh をそれぞれ表している。




図 6: LSTM の構造

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \quad (3.2)$$

$$i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \quad (3.3)$$

$$\tilde{c}_t = \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \quad (3.4)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (3.5)$$

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \quad (3.6)$$

$$h_t = o_t \circ \sigma_c(c_t) \quad (3.7)$$

3.2 統計的手法を用いたバスの乗客数予測の研究

本節では統計的手法を用いたバスの乗客数予測の研究を述べる。Ma らは、次の 30 分間でバス路線に存在するバス停を利用する人数（以下、バス路線の利用者数）を予測した [18]。この手法ではバス路線毎に統計的なモデルを作成した。特徴量は過去のバス路線の利用者数データのみである。この手法のフレームワークを図 7 に示す。このフレームワークは以下に示す 4 つの手順で構成される。

1. 過去のバス路線の利用者数データから週、日、時間の時系列データを作成する。それぞれ、 $S_w^n(t)$, $S_d^n(t)$, $S_h^n(t)$ である。
2. 週、日、時間の時系列データに対応する Weekly モデル, Daily モデル, Hourly モデルをそれぞれ作成する。そして、それぞれでバス路線の利用者数を予測する。
3. 遷移確率行列を調整する。
4. 手順2と3で作成したものと、リアルタイムに取得できるバス路線の利用者数データを利用して、次の30分間におけるバス路線の利用者数を予測する。

提案手法, Artificial Neural Network (ANN), Weekly モデル, Daily モデル, Hourly モデルを用いたバス路線の利用者数の予測では, Mean Absolute Error (MAE) がそれぞれ 39 人, 62 人, 60 人, 69 人, 142 人となり, Root Mean Squared Error (RMSE) がそれぞれ 56 人, 79 人, 80 人, 93 人, 193 人となった。MAE と RMSE の両評価指標において提案手法が最も良い結果となった。特に, 提案手法は ANN と比較して MAE を 37.1%, RMSE を 30.0% 縮小させた。

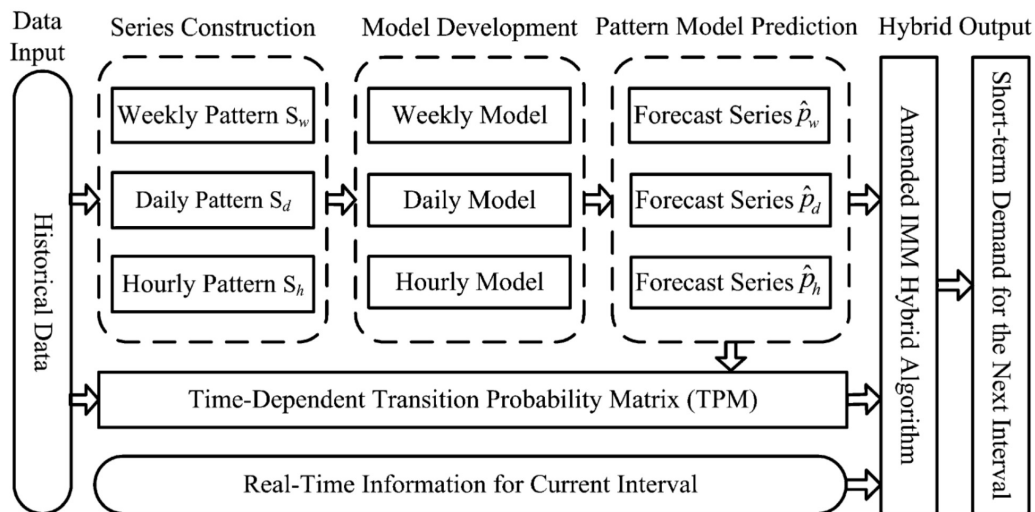


図 7: Ma らの手法におけるフレームワーク (文献 [18] より引用)

Ye らは次の日のバス路線の利用者数を予測した [19]。この手法ではバス路線

毎に Auto Regressive Integrated Moving Average (ARIMA) モデルを作成した。特徴量は過去のバス路線の利用者数データのみである。平日のデータを用いて構築した ARIMA モデルと、全ての日のデータを用いて構築した ARIMA モデルのバス路線の利用者数の予測では、Mean Absolute Percentage Error (MAPE) がそれぞれ 5.72%, 5.56% となった。MAPE において、全ての日のデータを用いて構築した ARIMA モデルが 0.16% 良い結果となった。

Cyril らは次の日のバス路線の利用者数を予測した [20]。この手法では Holt-Winters 法の加法モデル、乗法モデル、減衰型加法モデル、減衰型乗法モデルを用いてバス路線の利用者数を予測した [21]。特徴量は過去のバス路線の利用者数データのみである。Holt-Winters 法の加法モデル、乗法モデル、減衰型加法モデル、減衰型乗法モデルを用いたバス路線の利用者数の予測では、MAPE がそれぞれ 8.57%, 8.30%, 8.55%, 8.29% となった。MAPE において、減衰型乗法モデルが最も良い結果となった。

3.3 LSTM や RNN を用いた手法によるバスの乗客数予測の研究

本節では、LSTM や RNN を用いた手法によるバスの乗客数予測の研究を述べる。Ayman らは次の便における始点から終点までの運行時の最大乗客数を予測した [22]。この手法ではバス路線毎に RNN を用いたモデルを作成した。特徴量として過去の乗客数、時間帯、曜日、降水量、気温データを利用した。手動で設計したモデルと、パラメータを探索した結果に基づいて設計したモデルの最大乗客数の予測では、RMSE がそれぞれ 3.21 人と 3.14 人となった。パラメータを探索した結果に基づいて設計したモデルの予測では、RMSE を 0.07 人縮小した。

Halyal らはバス停毎に次の 15 分間で運行される便における乗客数を予測した [9]。この手法では、図 8 に示すようにバス停毎に LSTM を用いたモデルを作成した。例えば、5 つのバス停で構成されている路線の場合、5 つのモデルが作成される (図 8 において $n = 5$)。特徴量として過去のバスの乗客数データを利用し、ルックバック数は 15 日前までのデータとした。提案手法、季節性のあるナイーブモデル、Seasonal Auto Regressive Integrated Moving Average (SARIMA) モデルを用いて、複数のバス停で乗客数予測を評価した。MAE が、最も乗客数が多いバス

停ではそれぞれ 63.24 人, 111.35 人, 96.21 人となり, 最も乗客数が少ないバス停ではそれぞれ 10.19 人, 14.57 人, 14.54 人となった. また, RMSE が最も乗客数が多いバス停ではそれぞれ 80.14 人, 164.44 人, 145.78 人となり, 最も乗客数が少ないバス停ではそれぞれ 13.49 人, 18.77 人, 18.77 人となった. 特に, 提案手法は SARIMA モデルと比較して, MAE を最も乗客数が多いバス停では 43.21%, 最も乗客数が少ないバス停では 29.92%縮小させ, RMSE を最も乗客数が多いバス停では 45.03%, 最も乗客数が少ないバス停では 28.13%縮小させた.

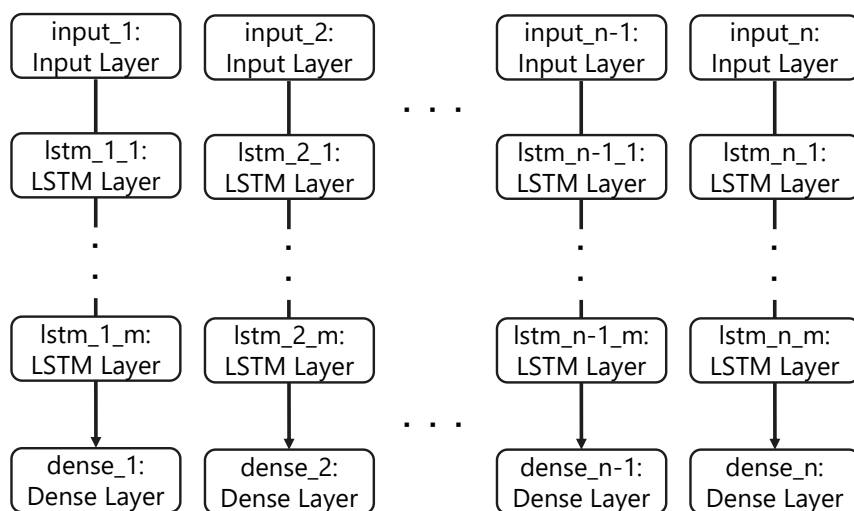


図 8: Halyal らの手法のアーキテクチャ

Han らはバス停毎に次の便の乗客数を予測した [10]. この手法ではバス停毎に LSTM を用いたモデルを作成した. 特徴量として過去のバスの乗客数データを利用した. さらに, 学習時の最適化アルゴリズムとして Nesterov Accelerated Adaptive Moment Estimation (Nadam) と Stochastic Gradient Descent (SGD) を利用した. Nadam を用いたモデル, SGD を用いたモデル, Nadam と SGD の両方を用いたモデルを使用して, 複数のバス停で乗客数予測を評価した. MAE が最も乗客数が多いバス停ではそれぞれ 28.375 人, 25.975 人, 24.628 人となり, 最も乗客数が少ないバス停ではそれぞれ 15.494 人, 15.550 人, 14.913 人となった. また, RMSE が最も乗客数が多いバス停ではそれぞれ 37.848 人, 35.750 人,

33.188 人となり、最も乗客数が少ないバス停ではそれぞれ 20.713 人、21.152 人、19.804 人となった。特に、Nadam と SGD の両方を用いたモデルは SGD を用いたモデルと比較して、MAE を最大で 13.21%、RMSE を最大で 12.31% 縮小させた。

Xu らはバス路線毎に次の 1 時間のバス路線の利用者数を予測した [8]。この手法では路線毎にモデルを作成した。特徴量として過去のバスの乗客数、曜日、天気データを利用した。評価では以下の 4 つの手法を比較した。

- 手法 1. 過去のバス路線の利用者数データだけを特徴量として用いた LSTM で利用者数を予測
- 手法 2. 過去のバス路線の利用者数、曜日、天気データを特徴量として用いた LSTM で利用者数を予測
- 手法 3. 過去のバス路線の利用者数、曜日、天気データを特徴量として用いた SVM で利用者数を予測
- 手法 4. 過去のバス路線の利用者数、曜日、天気データを特徴量として用いた k 近傍法で利用者数を予測

手法 1~4 を用いて 2 つの路線で評価した。RMSE がバス路線 6 ではそれぞれ 194.01 人、182.65 人、188.88 人、202.63 人となり、バス路線 11 では 207.65 人、199.97 人、213.58 人、221.67 人となった。手法 2 が最も誤差が小さくなり、手法 4 と比較すると、RMSE をバス路線 6 で 9.86%、バス路線 11 で 9.80% 縮小させた。

Jiao らはバス路線毎に次の 1 日のバス路線の利用者数を予測した [23]。この手法ではバス路線毎に LSTM を用いたモデルを作成した。特徴量として過去のバスの乗客数、天気、休日フラグ、曜日、時間帯データを利用した。LSTM を用いたモデル、k 近傍法、Xgboost を用いて評価した。MAE がそれぞれ 52.20 人、65.57 人、63.21 人となり、RMSE がそれぞれ 66.17 人、77.81 人、86.32 人となった。特に、LSTM を用いたモデルは Xgboost と比較して、MAE を 17.42%、RMSE を 23.34% 縮小させた。

3.4 関連研究の課題

これまでの節では、統計的手法と LSTM や RNN を用いた手法を説明した。バスの乗客数予測の分野において、LSTM や RNN を用いた手法が最も小さな誤差で乗客数を予測できる [7,8]。しかし、LSTM や RNN を用いた手法による乗客数予測でも誤差が生じており、課題が存在する。そのため、本節では 3.3 節で説明した関連研究にある 2 つの課題を言及する。

1 つ目は連続するバス停間のバス停出発時の乗客数の相関を考慮することである。一般的な日本のバスは、第 2 章で言及したように始点から終点まで決められたバス停を時刻表通りに順に経由して運行されている。このような運行形態のバス停では、便間の乗客数に相関がある [8,9]。また、このような路線内で連続して存在するバス停では、バス停間の乗客数に相関がある。関連研究では便間の乗客数の相関はバス停毎の乗客数の時系列データ入力により考慮している。一方、関連研究では図 8 に示すように、バス停毎にモデルを作成しているためバス停間の乗客数の相関は考慮できていない。そこで、この影響を考慮できるような LSTM を用いた手法を実現することで予測誤差の改善を目指す。

2 つ目は有効なデータ全てを特徴量として使用したバス乗客数予測を実施することである。第 2 章で言及した想定する乗客数予測では、過去のバス乗客数、時間帯、曜日、休日フラグ、降水量、気温、天気的数据が有効な特徴量として利用できる。表 2 に示すように、様々な関連研究でこれらのデータは特徴量として利用されている。各データが特徴量として有効である場合、全てを組み合わせたデータを特徴量として利用することでバスの乗客数予測の誤差を縮小できると考える。

上記 2 つの課題を下記にまとめる。本研究ではこの 2 つの課題に取り組む。

1. 連続するバス停間のバス停出発時の乗客数の相関を考慮する。
2. 過去のバス乗客数、時間帯、曜日、休日フラグ、降水量、気温、天気的数据全てを使用した予測を実施する。

表 2: 関連研究における有効なデータの使用の有無

	乗客数	時間帯	曜日	休日フラグ	降水量	気温	天気
Halyal et al. [9]	✓						
Han et al. [10]	✓						
Ayman et al. [22]	✓	✓	✓		✓	✓	
Xu et al. [8]	✓		✓				✓
Jiao et al. [23]	✓	✓	✓	✓			✓

4. バス停間の乗客数の相関と日時や天候の影響を考慮したLSTMに基づく乗客数予測手法

本章では、前章で説明した2つの課題を解決するための提案手法を述べる。4.1節では提案手法の概要を述べる。4.2節ではバス停間の乗客数の相関を考慮できるように、1つの路線に存在するバス停全体で1つのモデルを作成する方法を述べる。1つの路線に存在するバス停全体で1つのモデルを作成する方法は2種類考えられるので、それぞれについて4.2.1項と4.2.2項で述べる。4.3節では複数種類のデータを同時にモデルへ入力する際に、適切にモデルが学習できるようにするための前処理の方法を述べる。

4.1 提案手法の概要

提案手法のアーキテクチャを図9に示す。1つ目の課題である“連続するバス停間のバス停出発時の乗客数の相関を考慮する”に対しては、バス路線に存在するバス停全体で1つのモデルを作成することで解決する。バス停全体で1つのモデルを作成するには、Single-IOとMultiple-IOの2つが考えられる。これらの内、Multiple-IOが乗客数予測の誤差が小さいと見込めるため、Multiple-IOを1つ目の課題解決のためのモデルとして用いる。2つ目の課題である“過去のバス乗客数、時間帯、曜日、休日フラグ、降水量、気温、天気の詳細データ全てを使用した予測を実施する”に対しては、先述した全てのデータを同時にモデルに入力するK-feature-integratedを用いることで解決する。K-feature-integratedでは適切にモデルが学習できるように、前処理として正規化とワンホットエンコーディングを実施する。K-feature-integratedを用いると、過去の乗客数、便番号、曜日、休日フラグ、降水量、気温、天気データから41次元の特徴量が作成される（本章で後述するが、本研究では時間帯データの代わりに便番号データを利用する）。それぞれの詳細は次節以降で述べる。




図 9: 提案手法のアーキテクチャ

4.2 バス停間の乗客数の相関を考慮するモデル

一般的に、連続するバス停ではあるバス停の乗客数とその次のバス停の乗客数に影響することが考えられる。そのため、連続するバス停間には相関があると考え、特徴量の入力設計ではこれを考慮した方が予測誤差を縮小できると考える。関連研究ではバス停間の相関を考慮することが課題であり、本節ではこの課題を解決するための提案を述べる。

関連研究で示した既存手法では、バス停毎にモデルを作成するためバス停間の乗客数の相関が考慮できていなかった。そこで、モデルは1つのバス路線に存在するバス停全体で1つにすることでバス停間の乗客数の相関を考慮する。バス停全体で1つとなるモデルは Single-IO と Multiple-IO が考えられる。Single-IO はバス停間の乗客数の相関と便間の乗客数の相関を Input 層, Dense 層, LSTM の

積層を1つずつ用いて考慮するモデルである。一方、Multiple-IO はバス停間の乗客数の相関と便間の乗客数の相関を Concatenate 層1つと、Input 層, Dense 層, LSTM の積層を1つの路線に存在するバス停の数だけ用いて考慮するモデルである。これら2つのモデルの詳細は4.2.1項と4.2.2項で述べる。

4.2.1 Single-IO

Single-IO を図10に示す。Single-IO は、入力のための Input 層, 出力のための Dense 層, 入力された時系列データを学習するための LSTM の積層がそれぞれ1つある。Input 層には1つの路線に存在する全てのバス停の乗客数データから作成した1つの時系列データを入力する。入力する時系列データは図11に示すように作成する。Dense 層からは次の便の全てのバス停の乗客数の予測結果を出力する。1つの LSTM の積層で、バス停間の乗客数の相関と便間の乗客数の相関を考慮する必要があり、学習が複雑になる可能性がある。なお、図10における m はチューニングされる値である。




図 10: Single-IO

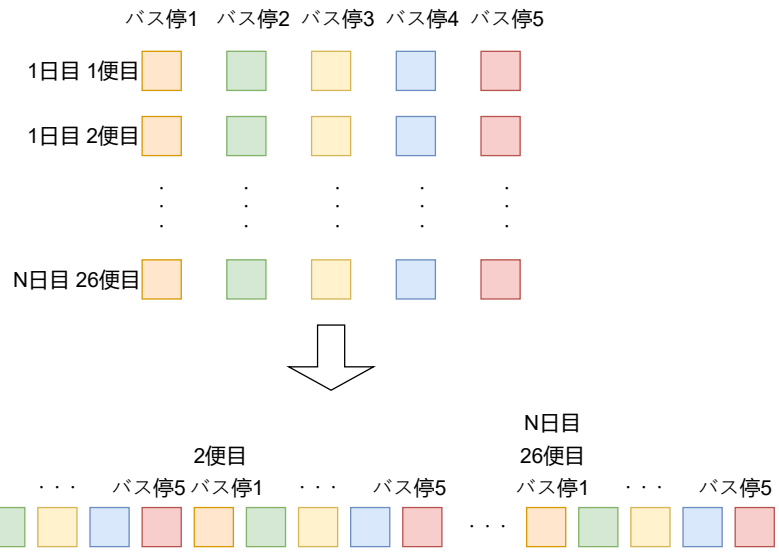


図 11: 全てのバス停の乗客数データから 1 つの時系列データを作成する方法

4.2.2 Multiple-IO

Multiple-IO を図 12 に示す. Multiple-IO は, 学習結果を共有するための Concatenate 層が 1 つと, 入力のための Input 層, 出力のための Dense 層, 入力された時系列データを学習するための LSTM の積層がバス停の数だけある. それぞれの Input 層には各バス停の乗客数の時系列データを入力する. それぞれの Dense 層からは次の便の各バス停の乗客数の予測結果を出力する. それぞれの LSTM の積層では便間の乗客数の相関を考慮し, Concatenate 層では各 LSTM の積層で学習した結果を共有することでバス停間の相関を考慮する. なお, 図 12 における n はバス停の数を表し, m はチューニングされる値である.

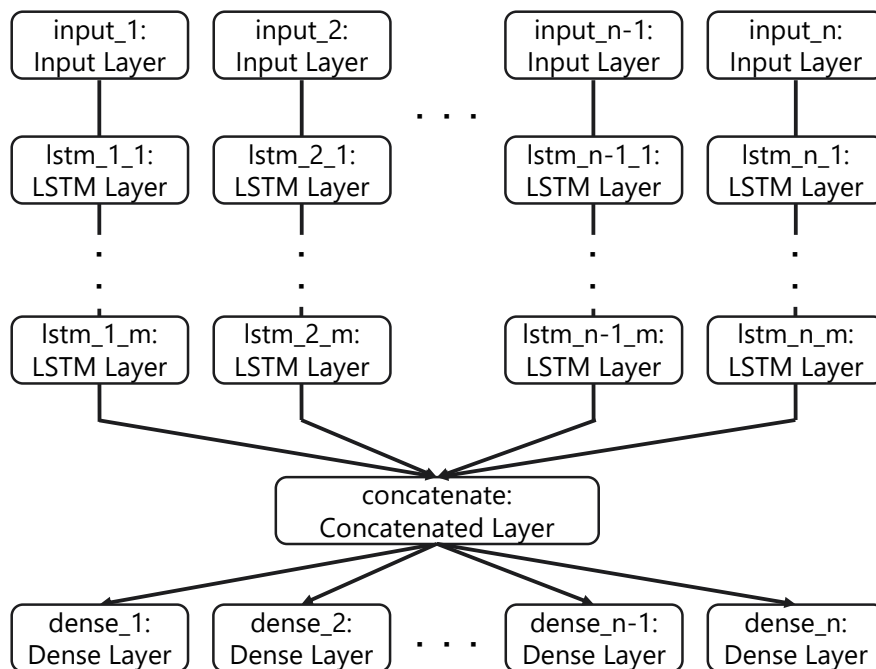


図 12: Multiple-IO

4.3 K-feature-integrated

本研究で想定する乗客数予測では、第3章で言及した関連研究で使用されているデータの内、過去の乗客数、時間帯、曜日、休日フラグ、降水量、気温、天気データが有効な特徴量である。これら全てのデータの特徴量として使用した予測を実施することが課題であった。K-feature-integratedでは、複数種類のデータを同時にモデルへ入力する際に、適切にモデルが学習できるように、前処理として量的変数に対する正規化と質的変数に対するワンホットエンコーディングを実施する。なお、K-feature-integratedの“K”はデータの種類の数を表すため、過去の乗客数、時間帯、曜日、休日フラグ、降水量、気温、天気データを用いる場合は7-feature-integratedとなる。

今回は、過去の乗客数、降水量、気温データは量的変数であるので正規化し、便番号、曜日、休日フラグ、天気データは質的変数であるのでワンホットエンコーディングを実施した。1日に予測対象路線で運行される便数によって便番号でワ

ワンホットエンコーディングされた時の特徴量の次元数は異なる。図 13 は 1 日に 26 便運行される場合を示す。なお、関連研究は便番号ではなく時間帯データを用いていたが、1 時間に 2 便以上運行されるバス路線を考慮して便番号データを用いる。結果として、入力したデータを前処理した特徴量の次元数は 41 次元である。




図 13: 正規化とワンホットエンコーディングを実施した結果

変換した 41 次元の特徴量の時系列をモデルに入力するためには、説明変数と目的変数を設計する必要がある。説明変数と目的変数は図 14 に示すように設計する。図において説明変数は X_i 、目的変数は y_i である。 X_i は Features と Time Sequence の 2 次元データである。 y_i は次の便の乗客数データである。なお、図は Time Sequence が Multiple-IO の場合の時系列データで、ルックバック数が 26 の例を示す。Multiple-IO の場合は、バス停毎に時系列データを作成しているため、このような分割処理をバス停毎に実施し、各 Input 層へ入力する。Single-IO の場合は、全てのバス停で 1 つの時系列データを作成しているため、このような分割処理を 1 回だけ実施し、Input 層へ入力する。




図 14: 説明変数と目的変数のデータ分割処理

5. 評価

本章では、実際のバス路線から収集したデータを用いて、提案手法を評価する。特に、提案手法が2つの課題をそれぞれ解決できたかについて評価する。まず、5.1節では、評価で使用するデータセットについて説明する。その後、評価方法、パラメータチューニングをそれぞれ5.2節、5.3節で述べる。最後に、5.4節では評価結果を示す。

5.1 評価で使用するデータセット

本評価では、実際のバス路線から収集したバス運行データから作成したバス運行データセットと、気象庁が公開する気象データから作成した気象データセットを用いる。バス運行データセットは図15に示すように、6つのフィールドから構成される。6つのフィールドの各形式を表3に示す。また、気象データセットは図16に示すように、4つのフィールドから構成される。4つのフィールドの各形式を表4に示す。これらのデータセットはそれぞれ、2021年10月1日から2022年9月30日までの1年間に収集したバス運行データと、同様の期間の気象データから作成した。5.1.1項と5.1.2項で各データセットの作成に関する詳細を述べる。

日時	便番号	曜日	平日/休日	バス停名	乗客数(人)
2021/10/1 06:40:00	1	金曜日	平日	神戸国際大学前	3
2021/10/1 06:42:00	1	金曜日	平日	ウエストコート7番街前	5
2021/10/1 06:43:00	1	金曜日	平日	六甲アイランド病院前	6
2021/10/1 06:45:00	1	金曜日	平日	神戸ベイシェラトンホテル	14
2021/10/1 07:05:00	1	金曜日	平日	神戸・三宮	4
2021/10/1 07:10:00	2	金曜日	平日	神戸国際大学前	1
			⋮		

図 15: 運行データセットの構造と例

表 3: 運行データセットに含まれる各フィールドの形式

フィールド	型	取りうる値
日時	日付 時刻	2021/10/01 06:40:00 ~ 2022/09/30 22:35:00 (時刻は後述するバスの時刻表の値を取り得る)
便番号	整数	1 以上 26 以下の値
曜日	文字列	月曜日, 火曜日, 水曜日, 木曜日, 金曜日, 土曜日, 日曜日
平日/休日	文字列	平日, 休日
バス停名	文字列	神戸国際大学前, ウェストコート 7 番街前, 六甲アイランド病院前, 神戸ベイシェラトンホテル, 神戸・三宮
乗客数	整数	0 以上の整数値

日時	降水量 (mm)	気温 (°C)	天気
2021/10/1 06:00:00	1.0	25.3	雨
2021/10/1 07:00:00	1.0	25.3	雨
2021/10/1 08:00:00	0.5	25.4	雨
2021/10/1 09:00:00	0.0	25.7	曇
2021/10/1 10:00:00	0.5	25.8	雨
2021/10/1 11:00:00	0.5	26.0	雨
	:		

図 16: 気象データセットの構造と例

表 4: 気象データセットに含まれる各フィールドの形式

フィールド	型	取りうる値
日時	日付 時刻	2021/10/01 06:00:00 ~ 2022/09/30 22:00:00 (時刻は 1 時間毎の値)
降水量	浮動小数点数	0.0 以上の 0.5 刻みの値
気温	浮動小数点数	0.1 刻みの値
天気	文字列	晴, 曇, 雨

5.1.1 運行データセットの作成

本評価では、バス運行データセットの作成に必要な運行データの収集を、第2章で想定するバス路線に該当する、みなと観光バス株式会社が兵庫県神戸市内で運行する神戸国際大学前発新神戸行きの21系統上りのバス路線において実施した。このバス路線は図17に示すような6つのバス停で構成されており、時刻表に従って1日あたり26便運行されている。この路線では図18に示すような乗降客カウントセンサで乗客数データを収集している。この路線は、みなと観光バス株式会社が運営しているバス路線の中で、平均乗客数が比較的多い。また、バス停周囲に、マリナーパーク、公園、教育機関、住宅街、宿泊施設、病院などの外的要因による影響を受けると考えられる施設が複数存在するため乗客数が乱れやすい。



図 17: みなと観光バス 21 系統上りのバス路線



図 18: 技研トラステム社製乗降客カウントセンサ

本評価実験では対象路線の2021年10月1日から2022年9月30日までの1年間の運行データを使用した。運行データセットは以下の3つをもとに図19に示すように作成した¹。なお、予測対象はバス停出発時のバス車内の人数なので、21系統の終点を除いた5つのバス停における乗客数データを使用する。

- バスに設置している車載器から0.5秒毎に収集している日時、緯度、経度、累積乗車人数、累積降車人数のデータ
- みなと観光バス株式会社が運営しているシステムのデータベースに保存されているバスの時刻表データ
- みなと観光バス株式会社が運営しているシステムのデータベースに保存されているバス停の位置データ




図 19: 運行データセットの作成

運行データセットを作成すると、バスの乗客数が負の値のデータが存在していた。この理由は、データ収集に使用した技研トラステム社製乗降客カウントセン

¹Github で公開済み (https://github.com/inet-lab-naist/Minato_bus_ridership_data)

サの精度が95%で、1人の降車を2人とカウントすることがあるためだ。このような負の値となっているノイズデータの割合は1.13%で、値が存在しない欠損データの割合は2.04%だった。ノイズデータに対しては、負の値の乗客数データの0からの差分を計算し、そのバス停以降で到着するバス停の乗客数に差分を加算した。ノイズデータ補正の例を図20に示す。欠損データに対しては、欠損日を除いた2021年10月1日から2022年8月31日までのバスの乗客数の値を、バス停毎に便番号と曜日毎の平均値を算出して適用した。この路線のバス停は、同じ便番号と曜日における乗客数の自己相関が強いため便番号と曜日毎の平均値を欠損値補完に使用した。同じ便番号と曜日における強い自己相関を図21~25に示す。図21~25において、ラグとは時系列データで何便前のデータと比較したかを表している。また、図の薄青色の網掛け部分は、帰無仮説「自己相関が存在しない」の95%信頼区間であり、網掛け部分は自己相関を持たないことを表している。なお、2021年10月1日から2022年8月31日までのデータはテストデータとしては使用しないため、この期間のデータを欠損値補完に使用した。欠損値補完の例を図26に示す。

ノイズデータの補正					
	①	②	③	④	⑤
補正前	2人	4人	5人	-1人	1人
補正值				0-(-1)=+1人	+1人
補正後	2人	4人	5人	0人	2人

図 20: ノイズデータの補正




図 21: バス停 1 における乗客数の自己相関




図 22: バス停 2 における乗客数の自己相関

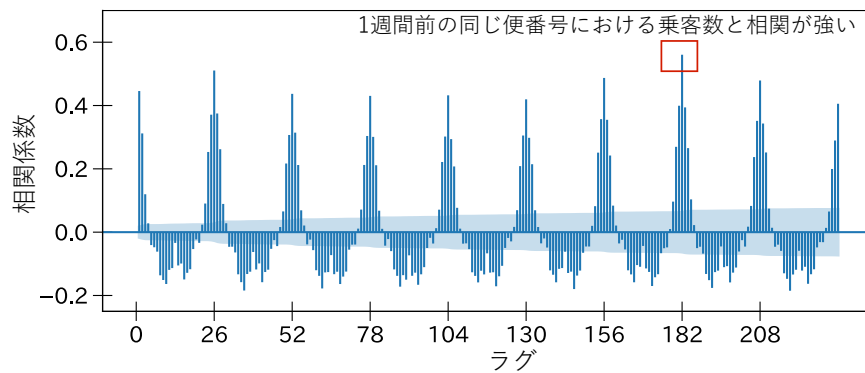


図 23: バス停 3 における乗客数の自己相関




図 24: バス停 4 における乗客数の自己相関




図 25: バス停 5 における乗客数の自己相関

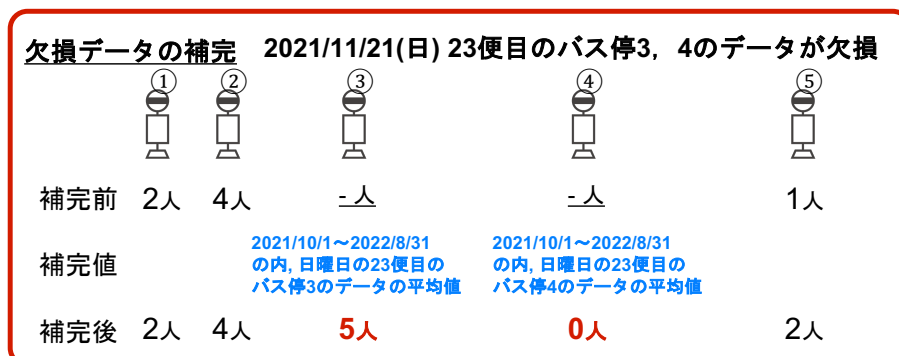


図 26: 欠損データの補完

乗客数データを可視化した結果を図 27~32 に示す。図 27 はバス停毎の乗客数の箱ひげ図である。最も乗客数が多いバス停はバス停 4 で、最も乗客数が少ないバス停はバス停 1 である。また、最も分散が大きいバス停はバス停 4 である。図 28~32 は 5 つのバス停における便番号毎の乗客数の箱ひげ図で、表 5 は便番号とバスの時刻表の対応表である。バス停 1, 5 は図 28, 32 に示す通り、乗客数が少なく便番号間の箱ひげ図に大きな差はない。一方、バス停 2, 3, 4 は図 29~31 に示す通り、3, 4 便目に乗客数のピークがある。




図 27: バス停毎の乗客数の箱ひげ図




図 28: バス停 1 における便番号毎の乗客数の箱ひげ図

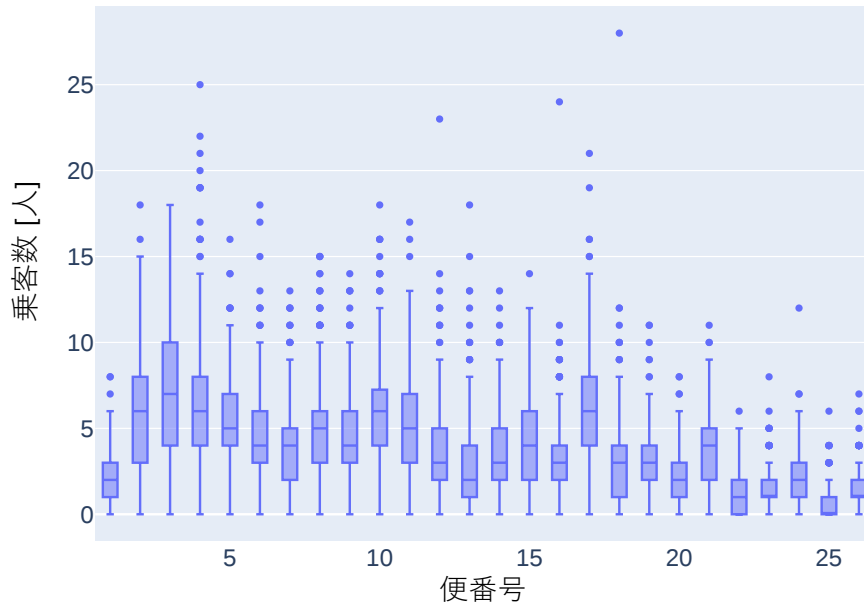


図 29: バス停 2 における便番号毎の乗客数の箱ひげ図

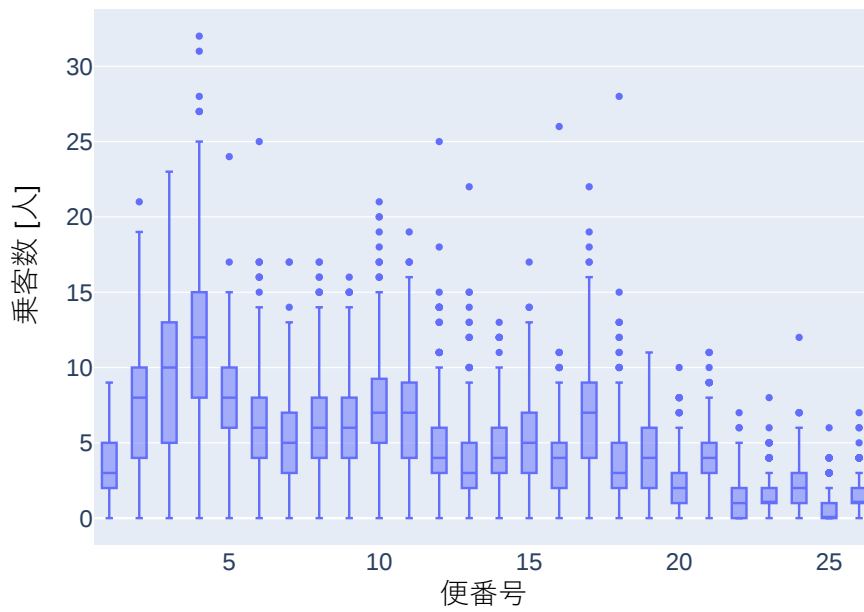


図 30: バス停 3 における便番号毎の乗客数の箱ひげ図




図 31: バス停 4 における便番号毎の乗客数の箱ひげ図




図 32: バス停 5 における便番号毎の乗客数の箱ひげ図

表 5: バスの時刻表

便番号	バス停 1	バス停 2	バス停 3	バス停 4	バス停 5
1	06:40	06:42	06:43	06:45	07:05
2	07:10	07:12	07:13	07:15	07:35
3	07:40	07:42	07:43	07:45	08:05
4	08:10	08:12	08:13	08:15	08:35
5	08:40	08:42	08:43	08:45	09:05
6	09:10	09:12	09:13	09:15	09:35
7	09:40	09:42	09:43	09:45	10:05
8	10:10	10:12	10:13	10:15	10:35
9	10:40	10:42	10:43	10:45	11:05
10	11:40	11:42	11:43	11:45	12:05
11	12:40	12:42	12:43	12:45	13:05
12	13:40	13:42	13:43	13:45	14:05
13	14:40	14:42	14:43	14:45	15:05
14	15:10	15:12	15:13	15:15	15:35
15	16:10	06:42	06:43	06:45	07:05
16	16:40	16:42	16:43	16:45	17:05
17	17:10	17:12	17:13	17:15	17:35
18	17:40	17:42	17:43	17:45	18:05
19	18:10	18:12	18:13	18:15	18:35
20	18:40	18:42	18:43	18:45	19:05
21	19:10	19:12	19:13	19:15	19:35
22	19:40	19:42	19:43	19:45	20:05
23	20:10	20:12	20:13	20:15	20:35
24	20:40	20:42	20:43	20:45	21:05
25	21:10	21:12	21:13	21:15	21:35
26	22:10	22:12	22:13	22:15	22:35

バス停間の乗客数に相関があることを確認するために、相関係数を求めた。バス停間の乗客数の相関係数は表 6 に示す通り、最小値は 0.3104、最大値は 0.9208 であった。そのため、5つのバス停における乗客数は互いに相関があると考えられる。

表 6: 5つのバス停間の乗客数の相関係数

	バス停 1	バス停 2	バス停 3	バス停 4	バス停 5
バス停 1	-	-	-	-	-
バス停 2	0.4678	-	-	-	-
バス停 3	0.3644	0.9208	-	-	-
バス停 4	0.3104	0.7646	0.8339	-	-
バス停 5	0.4011	0.5269	0.5345	0.5942	-

5.1.2 気象データセットの作成

気象データは気象庁が公開しているデータを使用した [24]。前節で作成した運行データセットの期間と場所に合わせ、2021年10月1日から2022年9月30日までの期間の6:00~23:00の1時間毎に取得した兵庫県神戸市の降水量、気温、天気データをもとに気象データセットを作成した。バスの始発便出発が6:40で、最終便到着が22:45であるため、取得対象時間は6:00~23:00とした。取得した天気データの内訳は表 7 に示す通りである。表 7 に示すデータをそのままモデルの学習に使用すると、“しゅう雨または止み間のある雨”、“雨”、“着氷性の雨”、“その他（雨だが分類できないもの）”は、十分なデータ量がないと考える。そのため、取得したデータの内、“しゅう雨または止み間のある雨”、“雨”、“着氷性の雨”、“その他（雨だが分類できないもの）”を“雨”に集約してデータセットを作成した。

表 7: 2021 年 10 月 1 日から 2022 年 9 月 30 日までの期間の 6:00~23:00 の 1 時間毎の兵庫県神戸市の天気観測回数

天気	観測回数
晴	3308
曇	2272
しゅう雨または止み間のある雨	539
雨	12
着氷性の雨	54
その他（雨だが分類できないもの）	13

5.2 評価方法

本評価では提案手法が2つの課題を解決したかを評価する。まず、連続するバス停間のバス停出発時の乗客数の相関を考慮することに対して Single-IO と Multiple-IO を用いたことで解決できたかを評価する。次に、過去のバス乗客数、時間帯、曜日、休日フラグ、降水量、気温、天気の詳細データ全てを使用した予測を実施することに対して K-feature-integrated を用いたことで解決できたかを評価する。5.2.1 項では評価で使用する指標とテストデータ、5.2.2 項では提案手法が課題を解決したかを示すための比較対象を述べる。

5.2.1 評価指標とテストデータ

本評価では提案手法が2つの課題を解決したかを評価する。第1章で言及したように混雑が発生する便で誤差が小さくなるように乗客数を予測することが重要である。そのため、十分混雑が発生する便のデータをテストデータとして用いて2つの課題を解決できたかを評価する。本路線で使用するバスでは第2章で定義した混雑状態か空き状態かの閾値は13である。この閾値においてはバス停4の便番号1~21のデータで十分混雑状態が発生する（図31）。予測誤差を評価する指

標は関連研究で用いられていた MAE と RMSE を採用する。評価指標それぞれの式は、式 (5.1), (5.2) に示す通りである。なお、それぞれの式の N はテストデータ数、 Y_i は実際の乗客数、 \hat{Y}_i は予測乗客数を表す。

$$\text{MAE}(Y, \hat{Y}) = \frac{\sum_{i=1}^N |Y_i - \hat{Y}_i|}{N} \quad (5.1)$$

$$\text{RMSE}(Y, \hat{Y}) = \sqrt{\frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{N}} \quad (5.2)$$

加えて、詳細分析のために3つの評価をする。1つ目が、十分混雑が発生する便のデータの内、混雑状態の便のデータを用いた際の乗客数の予測誤差の評価である。提案手法が十分混雑が発生する便のデータ以外でも有効かを確認するために評価する。このデータにおける評価指標は十分混雑が発生する便のデータと同様に MAE と RMSE を用いる。

2つ目が、バス停毎の全ての便のデータを用いた際の乗客数の予測誤差の評価である。提案手法が十分混雑が発生する便のデータ以外でも有効かを確認するために評価する。このデータにおける評価指標は十分混雑が発生する便のデータと同様に MAE と RMSE を用いる。

3つ目が、混雑が発生する便のデータを用いて混雑状態か空き状態かの分類の予測誤差の評価である。これは乗客数予測よりも簡単なタスクの場合にも提案手法が有効かを確認するために評価する。本評価実験では混雑状態を陽性、空き状態を陰性と定義する。評価指標として正解率 (Accuracy), 適合率 (Precision), 再現率 (Recall), 陰性的中率 (Negative Predictive Value, NPV), 特異率 (Specificity) を採用する。正解率は全予測に対する正答率である。適合率は陽性と予測したデータの内、実際に陽性であるデータの割合である。再現率は実際に陽性であるデータの内、陽性であると予測されたデータの割合である。陰性的中率は陰性と予測したデータの内、実際に陰性であるデータの割合である。特異率は実際に陰性であるデータの内、陰性であると予測されたデータの割合である。それぞれの式を式 (5.3)~(5.7) に示す。それぞれの式における TP は真陽性 (True Positive), TN は真陰性 (True Negative), FP は偽陽性 (False Positive), FN は偽陰性 (False

Negative) を示す。これらの指標の中でも真陽性と真陰性の両方を考慮した指標である正解率が最も重要な指標である。

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{FN} + \text{TN}} \quad (5.3)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (5.4)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (5.5)$$

$$\text{NPV} = \frac{\text{TN}}{\text{TN} + \text{FN}} \quad (5.6)$$

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (5.7)$$

本評価では、学習データを2021年10月1日から2022年7月31日まで、検証データを2022年8月1日から2022年8月31日まで、テストデータを2022年9月1日から2022年9月30日までと分割した。使用するデータは時系列データであるため、データのリーケージを防ぐために学習データ、検証データ、テストデータの期間を適切に定める必要がある。そのため、検証データは学習データの期間よりも後の期間のデータを使用し、テストデータはさらに後の期間のデータを使用した。十分混雑が発生する便のデータ、混雑状態の便のデータ、バス停毎の全ての便のデータのテストデータ便数を表8にまとめる。

表 8: 評価に使用するテストデータの便数

データ	テストデータの便数
十分混雑が発生する便のデータ	624 便 (欠損6便分を除くバス停4の30日間分の便番号1~21のデータ)
混雑状態の便のデータ	238 便 (バス停4で実際に混雑が発生した便のデータ)
全ての便のデータ	バス停毎に773 便 (欠損7便分を除く30日間分の便番号1~26のデータ)

5.2.2 比較対象

本評価では提案手法が2つの課題を解決したかを評価する。連続するバス停間のバス停出発時の乗客数の相関を考慮することに対する評価では、Halyalらの手法、Single-IOを用いた手法（手法A）とMultiple-IOを用いた手法（手法B）を比較する。

次に、過去のバス乗客数、時間帯、曜日、休日フラグ、降水量、気温、天気の詳細データ全てを使用した予測を実施することに対する評価では、Multiple-IOを用いた手法（手法B）、乗客数、便番号、曜日、休日フラグデータから成る4-feature-integratedとMultiple-IOを用いた手法（手法C）、乗客数、降水量、気温、天気データから成る4-feature-integratedとMultiple-IOを用いた手法（手法D）、乗客数、便番号、曜日、休日フラグ、降水量、気温、天気データから成る7-feature-integratedとMultiple-IOを用いた手法（手法E）を比較する。2つ目の課題を解決するためのK-feature-integratedは使用するモデルには着目していない。そのため、Halyalらの手法におけるモデル、Single-IO、Multiple-IOのいずれをモデルとして使用しても評価できる。その中でも、Multiple-IOが最も小さな誤差で乗客数を予測できる見込みがあるので採用する。

最後に、Multiple-IOとK-feature-integratedを組み合わせたことを評価する。評価では、過去の平均値手法、Halyalらの手法、乗客数、便番号、曜日、休日フラグ、降水量、気温、天気データから成る7-feature-integratedとMultiple-IOを用いた手法（手法E）を比較する。過去の平均値手法は第3章で説明した関連研究における比較対象として用いられることが多いため採用した。この手法は乗客パターンが一定の場合であれば優れた予測ができる可能性がある。しかし、外的要因によって乗客数が変動するバス路線では予測誤差が大きくなることが考えられる。

比較手法の一覧と説明を表9にまとめる。これらの手法の中で、言及した2つの課題を解決するための提案手法は手法Eである。

表 9: 比較手法一覧

手法名	詳細
過去の平均値手法	過去の便番号と曜日毎の乗客数データから算出した平均値をもとに乗客数を予測
Halyal らの手法	乗客数データだけを特徴量としてバス停毎にモデルを作成して乗客数を予測
手法 A	乗客数データだけを特徴量として Single-IO を使用して乗客数を予測
手法 B	乗客数データだけを特徴量として Multiple-IO を使用して乗客数を予測
手法 C	乗客数, 便番号, 曜日, 休日フラグデータから成る 4-feature-integrated と Multiple-IO を使用して乗客数を予測
手法 D	乗客数, 降水量, 気温, 天気データから成る 4-feature-integrated と Multiple-IO を使用して乗客数を予測
手法 E (提案手法)	乗客数, 便番号, 曜日, 休日フラグ, 降水量, 気温, 天気データから成る 7-feature-integrated と Multiple-IO を使用して乗客数を予測

5.3 パラメータチューニング

パラメータチューニングとは深層学習モデルを用いる際にパラメータを最適化することである。モデルを適切に学習させるためには適切なパラメータを見つけることが重要である。パラメータチューニングの方法としては大きく分けて Black-Box 最適化と Multi-Fidelity 最適化がある。前者はモデルの結果だけを見てパラメータを最適化する。後者はモデルの学習訓練経過を見ながらパラメータを最適化する。近年は様々な研究で後者が利用されている [25–28]。そのため、本評価実験で実施するパラメータチューニングでは後者に位置する Hyperband を利用した [29]。Hyperband は早期打ち切りと適応的な計算資源割り当てを組み込んだ Random Search である [30]。

前節で説明した 7 つの手法の内、過去の平均値手法以外の手法で深層学習を用いている。そのため、過去の平均値手法以外でパラメータチューニングをした。本節では、それぞれの結果を示す。

チューニングするパラメータを以下に説明する。

Epoch

エポック数である。エポックとはモデルを学習させる際の 1 回の学習のこと

である。例えば、学習用のデータが1万件ある場合、1エポックとはその1万件のデータをモデルに1回学習させることを指す。さらに、今回はMax Epochを200、Early stoppingを15とした。こうすることで、最大200エポックまでで15エポック連続で誤差が大きくなった時点で学習を停止し、過学習を防げる。

Batch size

モデルを学習させる際に1回の学習に用いるデータ数を表す。1回の学習に使用するデータ数を指定することで、学習時の計算量を抑えられる。例えば、Batch sizeを128とした場合、1回の学習で128件のデータを使用する。

Lookback

過去何個分のデータから目的となるデータを予測するかを表す。本評価実験で使用する路線は1日に26便運行している。そのため、日と週という周期性を考え、Single-IOを用いている手法A以外の手法では26と182を候補値と設定する。Single-IOを用いている手法Aでは、5つのバス停の乗客数データから1つの時系列データを作成し、学習させるため130と910を候補値と設定する。

LSTM units

1つのLSTM層に含まれるニューロンの数である。

LSTM layers

LSTM層の数である。図8や図12における m の値のことである。

Learning rate

モデルに1回の訓練でどの程度学習させるかの割合である。ネットワークが訓練データから学習する速度に影響する。Learning rateが大きいとネットワークが訓練データから学習する速度が早くなる一方で、過学習を引き起こしやすくなる。Learning rateが小さいと学習が遅くなる一方で、過学習を引き起こす可能性は低くなる。

Optimizers

モデルの訓練において、重みやバイアスの値を更新するために用いられる最適化アルゴリズムである。損失関数の値を最小化するように重みやバイアスの値を更新する。

Dropout rate

訓練時にランダムにモデルの層から削除されるニューロンの割合を表す。ランダムにモデルの層からニューロンを削除することで過学習を防げる。ドロップアウト率が大きいほど過学習を抑制する効果が強くなる一方で、モデルの学習速度は低下する。

5.3.1 Halyal らの手法におけるパラメータチューニング

表 10~14 に、Halyal らの手法におけるチューニング対象のパラメータ、候補値、結果を示す。損失関数としては MAE を用いている。そのため、結果は訓練データにおいて MAE が最も小さくなる時のパラメータである。Halyal らの手法では路線にあるそれぞれのバス停毎に LSTM を用いたモデルを作成するため、パラメータチューニングもそれぞれのバス停で実施した。本実験で使用するバス路線における評価対象バス停は終点を除いた 5 つのバス停であるため、5 つのパラメータチューニングの結果を示す。

表 10: Halyal らの手法のバス停 1 におけるパラメータチューニング

パラメータ	候補値	結果
Epoch	1~200	37
Batch size	16, 32, 64, 128, 256	32
Lookback	26, 182	26
LSTM units	16, 32, 64, 128, 256	16
LSTM layers	1, 2, 3, 4	3
Learning rate	0.01, 0.001, 0.0001	0.01
Optimizers	Adadelta, Adagrad, Adam, Adamax, Ftrl, Nadam, RMSprop, SGD	RMSprop
Dropout rate	0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9	0.1

表 11: Halyal らの手法のバス停 2 におけるパラメータチューニング

パラメータ	候補値	結果
Epoch	1~200	50
Batch size	16, 32, 64, 128, 256	16
Lookback	26, 182	26
LSTM units	16, 32, 64, 128, 256	128
LSTM layers	1, 2, 3, 4	1
Learning rate	0.01, 0.001, 0.0001	0.01
Optimizers	Adadelta, Adagrad, Adam, Adamax, Ftrl, Nadam, RMSprop, SGD	Adam
Dropout rate	0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9	0.1

表 12: Halyal らの手法のバス停 3 におけるパラメータチューニング

パラメータ	候補値	結果
Epoch	1~200	59
Batch size	16, 32, 64, 128, 256	64
Lookback	26, 182	26
LSTM units	16, 32, 64, 128, 256	64
LSTM layers	1, 2, 3, 4	1
Learning rate	0.01, 0.001, 0.0001	0.01
Optimizers	Adadelata, Adagrad, Adam, Adamax, Ftrl, Nadam, RMSprop, SGD	Nadam
Dropout rate	0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9	0.1

表 13: Halyal らの手法のバス停 4 におけるパラメータチューニング

パラメータ	候補値	結果
Epoch	1~200	51
Batch size	16, 32, 64, 128, 256	64
Lookback	26, 182	26
LSTM units	16, 32, 64, 128, 256	64
LSTM layers	1, 2, 3, 4	1
Learning rate	0.01, 0.001, 0.0001	0.01
Optimizers	Adadelata, Adagrad, Adam, Adamax, Ftrl, Nadam, RMSprop, SGD	Nadam
Dropout rate	0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9	0.1

表 14: Halyal らの手法のバス停 5 におけるパラメータチューニング

パラメータ	候補値	結果
Epoch	1~200	33
Batch size	16, 32, 64, 128, 256	16
Lookback	26, 182	26
LSTM units	16, 32, 64, 128, 256	64
LSTM layers	1, 2, 3, 4	4
Learning rate	0.01, 0.001, 0.0001	0.001
Optimizers	Adadelta, Adagrad, Adam, Adamax, Ftrl, Nadam, RMSprop, SGD	RMSprop
Dropout rate	0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9	0.2

5.3.2 手法 A~E におけるパラメータチューニング

表 15~19 に手法 A~E におけるチューニング対象のパラメータ, 候補値, 結果を示す. 損失関数としては MAE を用いている. そのため, 結果は訓練データにおいて MAE が最も小さくなる時のパラメータである. 手法 A~E は, 路線にある全てのバス停で LSTM を用いたモデルを 1 つ作成するため, パラメータチューニングの結果も 1 つだけとなる.

表 15: 手法 A におけるパラメータチューニング

パラメータ	候補値	結果
Epoch	1~200	35
Batch size	16, 32, 64, 128, 256	128
Lookback	130, 910	130
LSTM units	16, 32, 64, 128, 256	64
LSTM layers	1, 2, 3, 4	1
Learning rate	0.01, 0.001, 0.0001	0.001
Optimizers	Adadelta, Adagrad, Adam, Adamax, Ftrl, Nadam, RMSprop, SGD	RMSprop
Dropout rate	0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9	0.1

表 16: 手法 B におけるパラメータチューニング

パラメータ	候補値	結果
Epoch	1~200	67
Batch size	16, 32, 64, 128, 256	16
Lookback	26, 182	26
LSTM units	16, 32, 64, 128, 256	256
LSTM layers	1, 2, 3, 4	2
Learning rate	0.01, 0.001, 0.0001	0.001
Optimizers	Adadelta, Adagrad, Adam, Adamax, Ftrl, Nadam, RMSprop, SGD	RMSprop
Dropout rate	0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9	0.2

表 17: 手法 C におけるパラメータチューニング

パラメータ	候補値	結果
Epoch	1~200	55
Batch size	16, 32, 64, 128, 256	64
Lookback	26, 182	26
LSTM units	16, 32, 64, 128, 256	64
LSTM layers	1, 2, 3, 4	3
Learning rate	0.01, 0.001, 0.0001	0.01
Optimizers	Adadelata, Adagrad, Adam, Adamax, Ftrl, Nadam, RMSprop, SGD	Adamax
Dropout rate	0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9	0.4

表 18: 手法 D におけるパラメータチューニング

パラメータ	候補値	結果
Epoch	1~200	91
Batch size	16, 32, 64, 128, 256	32
Lookback	26, 182	26
LSTM units	16, 32, 64, 128, 256	32
LSTM layers	1, 2, 3, 4	1
Learning rate	0.01, 0.001, 0.0001	0.01
Optimizers	Adadelata, Adagrad, Adam, Adamax, Ftrl, Nadam, RMSprop, SGD	RMSprop
Dropout rate	0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9	0.1

表 19: 手法 E におけるパラメータチューニング

パラメータ	候補値	結果
Epoch	1~200	37
Batch size	16, 32, 64, 128, 256	128
Lookback	26, 182	26
LSTM units	16, 32, 64, 128, 256	64
LSTM layers	1, 2, 3, 4	2
Learning rate	0.01, 0.001, 0.0001	0.001
Optimizers	Adadelta, Adagrad, Adam, Adamax, Ftrl, Nadam, RMSprop, SGD	RMSprop
Dropout rate	0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9	0.4

5.4 評価結果

5.4.1 十分混雑が発生する便のデータにおける評価結果

十分混雑が発生する便のデータであるバス停 4 の便番号 1~21 における乗客数予測の結果を示す。まず、連続するバス停間のバス停出発時の乗客数の相関を考慮することに対する Single-IO と Multiple-IO の評価結果を表 20 に示す。手法 A は Halyal らの手法と比較して MAE を 0.096 人、RMSE を 0.238 人縮小させ、手法 B は Halyal らの手法と比較して MAE を 0.194 人、RMSE を 0.392 人縮小させた。手法 A と手法 B は Halyal らの手法よりも小さな誤差で予測したので、Single-IO と Multiple-IO を用いることで課題を解決した。特に、手法 B は手法 A よりも課題解決のための手法として適切である。一方、誤差の最大値は 3 つの手法で同値となり、大きな誤差の抑制はできない。

次に、過去のバス乗客数、時間帯、曜日、休日フラグ、降水量、気温、天気の詳細データ全てを使用した予測を実施することに対する K-feature-integrated の評価結果を表 21 に示す。手法 C は手法 B と比較して MAE を 0.308 人、RMSE を 0.371 人縮小させ、手法 D は手法 B と比較して MAE を 0.086 人、RMSE を 0.134 人縮小

大させ、手法Eは手法Bと比較してMAEを0.408人、RMSEを0.442人縮小させた。また、手法Eは手法Bと比較して誤差の最大値を5人縮小させた。手法Eは手法B、C、Dよりも小さな誤差で予測したので、全ての有効なデータを使用した7-feature-integratedは有効であるとわかった。一方、手法Dは手法BよりもMAEとRMSEを拡大させたので、気象データである降水量、気温、天気データを使用するだけでは有効ではないことを示した。

次に、Multiple-IOとK-feature-integratedを組み合わせたことの評価結果を表22に示す。手法EはHalyalらの手法と比較してMAEを0.602人、RMSEを0.834人縮小させ、過去の平均値手法と比較してMAEを0.551人、RMSEを0.673人縮小させた。また、手法EはHalyalらの手法よりも誤差の最大値を5人縮小させ、過去の平均値手法よりも3人縮小させた。手法EはHalyalらの手法と過去の平均値手法よりも誤差を小さくしたので、2つの課題解決を組み合わせた提案手法は有効である。

表 20: 十分混雑が発生する便のデータにおける Halyal らの手法と手法 A と手法 B の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
Halyal らの手法	3.902	5.130	0.0	21.0
手法 A	3.806	4.892	0.0	21.0
手法 B	3.708	4.738	0.0	21.0

表 21: 十分混雑が発生する便のデータにおける手法 B～E の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
手法 B	3.708	4.738	0.0	21.0
手法 C	3.400	4.367	0.0	17.0
手法 D	3.794	4.872	0.0	17.0
手法 E	3.300	4.296	0.0	16.0

表 22: 十分混雑が発生する便のデータにおける過去の平均値手法と Halyal らの手法と手法 E の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
過去の平均値手法	3.851	4.969	0.0	19.0
Halyal らの手法	3.902	5.130	0.0	21.0
手法 E (提案手法)	3.300	4.296	0.0	16.0

5.4.2 混雑状態の便のデータにおける評価結果

バス停 4 の便番号 1~21 の中でも混雑状態の便のデータにおける乗客数予測の結果を示す。まず、連続するバス停間のバス停出発時の乗客数の相関を考慮することに対する Single-IO と Multiple-IO の評価結果を表 23 に示す。手法 A は Halyal らの手法と比較して MAE を 0.372 人, RMSE を 0.529 人縮小させ, 手法 B は Halyal らの手法と比較して MAE を 1.224 人, RMSE を 1.297 人縮小させた。手法 A と手法 B は Halyal らの手法よりも小さな誤差で予測したので, Single-IO と Multiple-IO を用いることで課題を解決した。特に, Multiple-IO は Single-IO よりも課題解決のためのモデルとして適切である。一方, 誤差の最大値は 3 つの手法で同値となり, 大きな誤差の抑制はできない。

次に, 過去のバス乗客数, 時間帯, 曜日, 休日フラグ, 降水量, 気温, 天気 of データ全てを使用した予測を実施することに対する K-feature-integrated の評価結果を表 24 に示す。手法 C は手法 B と比較して MAE を 0.318 人, RMSE を 0.419 人縮小させ, 手法 D は手法 B と比較して MAE を 0.016 人, RMSE を 0.001 人拡大させ, 手法 E は手法 B と比較して MAE を 0.865 人, RMSE を 0.931 人縮小させた。また, 手法 E は手法 B と比較して誤差の最大値を 5 人縮小させた。手法 E は手法 B, C, D よりも誤差を小さくしたので, 全ての有効なデータを使用した 7-feature-integrated は有効であるとわかった。一方, 手法 D は手法 B よりも MAE と RMSE を拡大させたので, 気象データである降水量, 気温, 天気データを使用するだけでは有効ではないことを示した。

次に、Multiple-IO と K-feature-integrated を組み合わせたことの評価結果を表 25 に示す。手法 E は Halyal らの手法と比較して MAE を 2.109 人、RMSE を 2.228 人縮小させ、過去の平均値手法と比較して MAE を 1.319 人、RMSE を 1.402 人縮小させた。また、手法 E は Halyal らの手法よりも誤差の最大値を 5 人縮小させ、過去の平均値手法よりも 3 人縮小させた。手法 E は Halyal らの手法と過去の平均値手法よりも誤差を小さくしたので、2 つの課題解決を組み合わせた提案手法は有効である。

混雑状態の便のデータにおける乗客数予測では、十分混雑が発生する便のデータと同様に提案手法が有効である。

表 23: 混雑状態の便のデータにおける Halyal らの手法と手法 A と手法 B の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
Halyal らの手法	5.711	6.953	0.0	21.0
手法 A	5.339	6.424	0.0	21.0
手法 B	4.467	5.656	0.0	21.0

表 24: 混雑状態の便のデータにおける手法 B~E の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
手法 B	4.467	5.656	0.0	21.0
手法 C	4.149	5.237	0.0	17.0
手法 D	4.483	5.657	0.0	17.0
手法 E	3.602	4.725	0.0	16.0

表 25: 混雑状態の便のデータにおける過去の平均値手法と Halyal らの手法と手法 E の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
過去の平均値手法	4.921	6.127	0.0	19.0
Halyal らの手法	5.711	6.953	0.0	21.0
手法 E (提案手法)	3.602	4.725	0.0	16.0

5.4.3 バス停毎の全ての便のデータにおける評価結果

バス停毎の全ての便のデータにおける乗客数予測の結果を示す。まず、連続するバス停間のバス停出発時の乗客数の相関を考慮することに対する Single-IO と Multiple-IO の評価結果を表 26~30 に示す。手法 A と手法 B は Halyal らの手法よりも全てのバス停で MAE と RMSE を縮小させた。手法 A と手法 B は Halyal らの手法よりも小さな誤差で予測したので、Single-IO と Multiple-IO を用いることで課題を解決した。特に、手法 B は手法 A よりも課題解決のための手法として適切である。

次に、過去のバス乗客数、時間帯、曜日、休日フラグ、降水量、気温、天気の詳細データ全てを使用した予測を実施することに対する K-feature-integrated の評価結果を表 31~35 に示す。手法 E は手法 B, C, D よりも全てのバス停で MAE と RMSE を縮小させた。手法 E は手法 B, C, D よりも誤差を小さくしたので、全ての有効なデータを使用した 7-feature-integrated を用いることで課題を解決した。

次に、Multiple-IO と K-feature-integrated を組み合わせたことの評価結果を表 36~40 に示す。手法 E は過去の平均値手法と Halyal らの手法よりも全てのバス停で MAE と RMSE を縮小させた。手法 E は過去の平均値手法と Halyal らの手法よりも誤差を小さくしたので、2つの課題解決を組み合わせた提案手法は有効である。

全ての便のデータにおける乗客数予測では、十分混雑が発生する便のデータと同様に提案手法が有効である。

表 26: バス停 1 の全ての便のデータにおける Halyal らの手法と手法 A と手法 B の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
Halyal らの手法	1.055	1.550	0.0	9.0
手法 A	1.053	1.539	0.0	7.0
手法 B	0.976	1.447	0.0	7.0

表 27: バス停 2 の全ての便のデータにおける Halyal らの手法と手法 A と手法 B の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
Halyal らの手法	2.006	2.684	0.0	13.0
手法 A	1.872	2.607	0.0	13.0
手法 B	1.829	2.519	0.0	13.0

表 28: バス停 3 の全ての便のデータにおける Halyal らの手法と手法 A と手法 B の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
Halyal らの手法	2.267	3.104	0.0	17.0
手法 A	2.187	2.994	0.0	18.0
手法 B	2.136	2.971	0.0	18.0

表 29: バス停4の全ての便のデータにおける Halyal らの手法と手法 A と手法 B の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
Halyal らの手法	3.565	4.767	0.0	21.0
手法 A	3.383	4.485	0.0	21.0
手法 B	3.345	4.375	0.0	21.0

表 30: バス停5の全ての便のデータにおける Halyal らの手法と手法 A と手法 B の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
Halyal らの手法	1.645	2.320	0.0	15.0
手法 A	1.576	2.174	0.0	12.0
手法 B	1.540	2.112	0.0	12.0

表 31: バス停1の全ての便のデータにおける手法 B~E の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
手法 B	0.976	1.447	0.0	7.0
手法 C	0.935	1.378	0.0	7.0
手法 D	0.974	1.435	0.0	7.0
手法 E	0.836	1.186	0.0	7.0

表 32: バス停2の全ての便のデータにおける手法B~Eの評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
手法B	1.829	2.519	0.0	13.0
手法C	1.722	2.427	0.0	12.0
手法D	1.842	2.488	0.0	12.0
手法E	1.612	2.206	0.0	13.0

表 33: バス停3の全ての便のデータにおける手法B~Eの評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
手法B	2.136	2.971	0.0	18.0
手法C	1.974	2.696	0.0	13.0
手法D	2.179	2.953	0.0	15.0
手法E	1.868	2.506	0.0	13.0

表 34: バス停4の全ての便のデータにおける手法B~Eの評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
手法B	3.345	4.375	0.0	21.0
手法C	3.023	4.006	0.0	17.0
手法D	3.295	4.346	0.0	17.0
手法E	2.991	3.816	0.0	16.0

表 35: バス停5の全ての便のデータにおける手法B~Eの評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
手法B	1.540	2.112	0.0	12.0
手法C	1.422	2.020	0.0	12.0
手法D	1.560	2.168	0.0	13.0
手法E	1.321	1.842	0.0	13.0

表 36: バス停1の全ての便のデータにおける過去の平均値手法と Halyal らの手法と手法Eの評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
過去の平均値手法	0.932	1.382	0.0	7.0
Halyal らの手法	1.055	1.550	0.0	9.0
手法E (提案手法)	0.836	1.186	0.0	7.0

表 37: バス停2の全ての便のデータにおける過去の平均値手法と Halyal らの手法と手法Eの評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
過去の平均値手法	1.768	2.476	0.0	13.0
Halyal らの手法	2.006	2.684	0.0	13.0
手法E (提案手法)	1.612	2.206	0.0	13.0

表 38: バス停 3 の全ての便のデータにおける過去の平均値手法と Halyal らの手法と手法 E の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
過去の平均値手法	2.142	2.998	0.0	15.0
Halyal らの手法	2.267	3.104	0.0	17.0
手法 E (提案手法)	1.868	2.506	0.0	13.0

表 39: バス停 4 の全ての便のデータにおける過去の平均値手法と Halyal らの手法と手法 E の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
過去の平均値手法	3.376	4.536	0.0	19.0
Halyal らの手法	3.565	4.767	0.0	21.0
手法 E (提案手法)	2.991	3.816	0.0	16.0

表 40: バス停 5 の全ての便のデータにおける過去の平均値手法と Halyal らの手法と手法 E の評価結果 (単位 [人])

手法名	MAE	RMSE	誤差の最小値	誤差の最大値
過去の平均値手法	1.450	2.038	0.0	13.0
Halyal らの手法	1.645	2.320	0.0	15.0
手法 E (提案手法)	1.321	1.842	0.0	13.0

5.4.4 混雑状態か空き状態かの分類予測の評価結果

十分混雑が発生する便のデータであるバス停 4 の便番号 1~21 における混雑状態か空き状態かの 2 値分類予測の結果を示す。まず、連続するバス停間のバス停

出発時の乗客数の相関を考慮することに対する Single-IO と Multiple-IO の評価結果を表 41 に示す。手法 A と手法 B は Halyal らの手法よりも最も重要な指標である正解率を向上させたので、Single-IO と Multiple-IO を用いることで課題を解決した。特に、手法 B は手法 A よりも課題解決のための手法として適切である。

次に、過去のバス乗客数、時間帯、曜日、休日フラグ、降水量、気温、天気の詳細データ全てを使用した予測を実施することに対する K-feature-integrated の評価結果を表 42 に示す。手法 E は手法 B, C, D よりも最も重要な指標である正解率を向上させたので、全ての有効なデータを使用した 7-feature-integrated は有効であるとわかった。

次に、Multiple-IO と K-feature-integrated を組み合わせたことの評価結果を表 43 に示す。手法 E が正解率が最も高いので 2 つの課題解決を組み合わせた提案手法は有効である。

乗客数予測よりも簡単なタスクである混雑状態の便のデータにおける分類予測では、乗客数予測と同様に提案手法が有効である。

表 41: 十分混雑が発生する便のデータにおける Halyal らの手法と手法 A と手法 B の分類予測の結果 (単位 [%])

手法名	正解率	適合率	再現率	陰性的中率	特異率
Halyal らの手法	76.04	64.74	43.91	89.78	78.92
手法 A	77.34	68.67	44.78	91.26	79.45
手法 B	78.52	65.55	59.57	86.62	83.36

表 42: 十分混雑が発生する便のデータにおける手法 B~E の分類予測の結果 (単位 [%])

手法名	正解率	適合率	再現率	陰性的中率	特異率
手法 B	78.52	65.55	59.57	86.62	83.36
手法 C	79.56	67.98	60.00	87.92	83.72
手法 D	77.21	64.55	53.04	87.55	81.35
手法 E	80.08	65.46	70.87	84.01	87.09

表 43: 十分混雑が発生する便のデータにおける過去の平均値手法と Halyal らの手法と手法 E の分類予測の結果 (単位 [%])

手法名	正解率	適合率	再現率	陰性的中率	特異率
過去の平均値手法	74.09	56.13	61.74	79.37	82.91
Halyal らの手法	76.04	64.74	43.91	89.78	78.92
手法 E (提案手法)	80.08	65.46	70.87	84.01	87.09

6. 考察

本章では、6.1 節で乗客数予測における提案手法の優位性を、6.2 節で混雑状態か空き状態かの分類の予測における提案手法の優位性を、6.3 節で提案手法において乗客数予測が乱れた日を考察する。最後に、6.4 節で考察を踏まえた上での今後の展望を述べる。

6.1 乗客数予測における提案手法の優位性

5.4.1～5.4.3 項の結果を考察する。十分混雑が発生する便のデータ、混雑状態の便のデータ、全ての便のデータそれぞれを用いた予測誤差にどの程度の差があるかを確認するため、各データに対して過去の平均値手法、Halyal らの手法と手法 E の乗客数予測を MAE で評価した結果を表 44 にまとめた。全ての便のデータと十分混雑が発生する便のデータで評価した結果を比較すると、MAE の拡大は過去の平均値手法では 0.475 人、Halyal らの手法では 0.337 人、手法 E では 0.309 人となり、各手法間で大きな差はない。一方、十分混雑が発生する便のデータと混雑状態の便のデータを比較すると、MAE の拡大は過去の平均値手法では 1.070 人、Halyal らの手法では 1.809 人、手法 E では 0.302 人となり、各手法間で大きな差が出た。そのため、手法 E は混雑状態における MAE の拡大を他の手法よりは抑制できる。

さらに、図 33 には混雑状態における予測結果の例を示す。テストデータとして使用した 2022 年 9 月の中で最も混雑状態の便が発生したのは 9 月 7 日であった。この日は 26 便中 12 便で混雑状態が発生した。手法 E と Halyal らの手法の混雑状態の便のデータに対する予測値を比較すると、2 便目、17 便目と 18 便目以外の 9 便では手法 E の方が予測誤差が小さい。そのため、提案手法である手法 E は混雑状態で Halyal らの手法より有効である。

表 44: バス停 4 における MAE のまとめ (単位 [人])

使用データ	過去の平均値手法	Halyal らの手法	手法 E (提案手法)
全ての便のデータ	3.376	3.565	2.991
十分混雑が発生する便のデータ	3.851	3.902	3.300
混雑状態の便のデータ	4.921	5.711	3.602




図 33: 2022 年 9 月 7 日のバス停 4 における乗客数予測の結果

6.2 混雑状態か空き状態かの分類の予測における提案手法の優位性

5.4.4 項の結果に対する考察をする。手法 E と Halyal らの手法を比較すると、正解率、適合率、再現率と特異率は向上したが、陰性的中率は低下した。

評価結果を比較すると、提案手法である手法 E は Halyal らの手法よりも正解率が高いため、提案手法は有効である。一方、陰性的中率は Halyal らの手法の方が高い。そのため、空き状態と判断した中で正しかった割合が重要となる予測では、手法 E よりも Halyal らの手法の方が有効である。

6.3 乗客数予測が乱れた日

本節では提案手法の中でも予測誤差が大きくなっている日を考察する。テストデータとして使用した2022年9月の中で、予測誤差が大きくなっている便が多い日付は9月19日であった。

この日は、図34に示すように、1日に運行している全ての便において乗客数が10人未満であった。今回使用した2021年10月1日から2022年9月30日までのデータの中で、1日に運行されている全ての便において乗客数が10人未満となっているデータはこの日だけだった。そのため、この日は何らかの外的要因によって通常よりも乗客数が少なくなったと考えた。この外的要因として台風の接近が考えられる。この日は図35に示すように、日本列島に台風14号が接近し、兵庫県神戸市では9月19日0時25分に暴風警報が発表され、9月20日0時58分まで警報が継続していた[31]。また、兵庫県内のJR在来線では、19日午後2時から順次運転が見合わされた[32]。なお、文献[31]より図35に関する説明を抜粋する。“経路上の「○」は傍らに記した日の午前9時、「●」は午後9時の位置で、「→」は台風の消滅を示す。経路の実線は台風、破線は熱帯低気圧と温帯低気圧の期間を示す。”




図 34: 2022年9月19日のバス停4における乗客数予測の結果

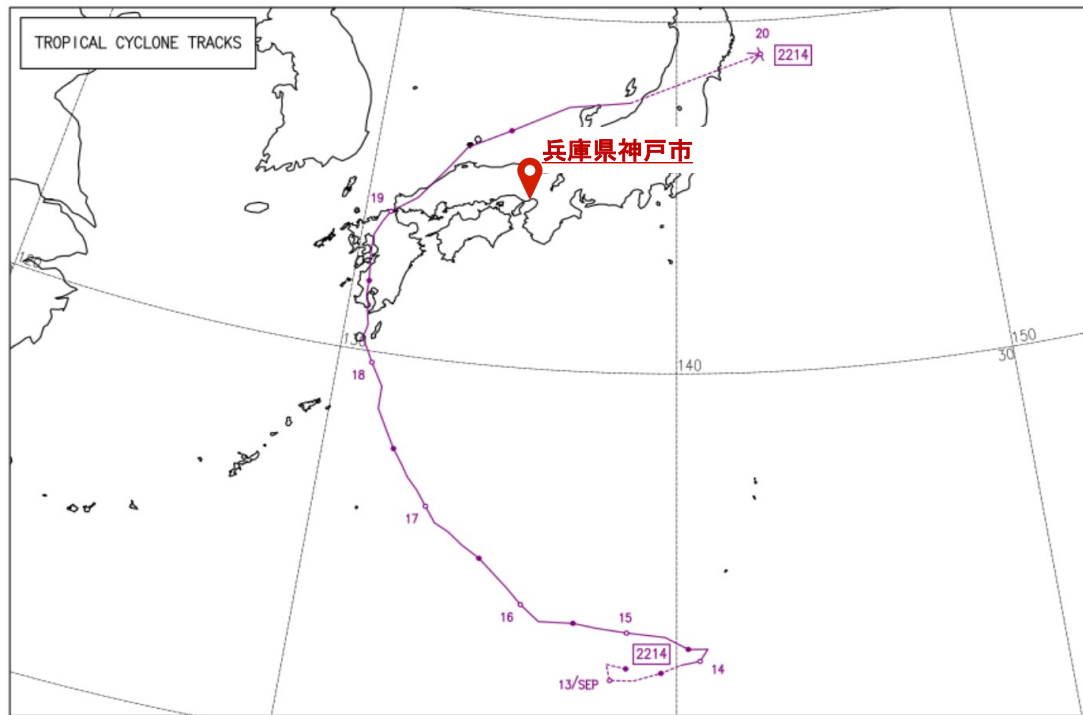


図 35: 台風 14 号の経路図 (文献 [31] より引用)

今回使用した 2021 年 10 月 1 日から 2022 年 9 月 30 日までの期間で兵庫県神戸市に台風が接近した例として、台風 14 号以外に台風 4 号が挙げられる。しかし、図 36 に示すように、台風 4 号は兵庫県神戸市を通過する前に、7 月 5 日の 5 時から温帯低気圧に変化する兆候を見せ、7 月 5 日の 9 時に九州で温帯低気圧となった (記号の説明は図 35 と同様)。その後、温帯低気圧として兵庫県神戸市を通過した。この日の乗客数データと過去の乗客数データの平均値を図 37 に示す。なお、2022 年 7 月 5 日はテストデータとしては使用していないため、手法 E や Halyal らの手法などを用いた予測は実施していない。この日の乗客数は台風 14 号の日と同様に少なくなると考えたが、今回使用したデータの期間で最も乗客数が多い日となった。

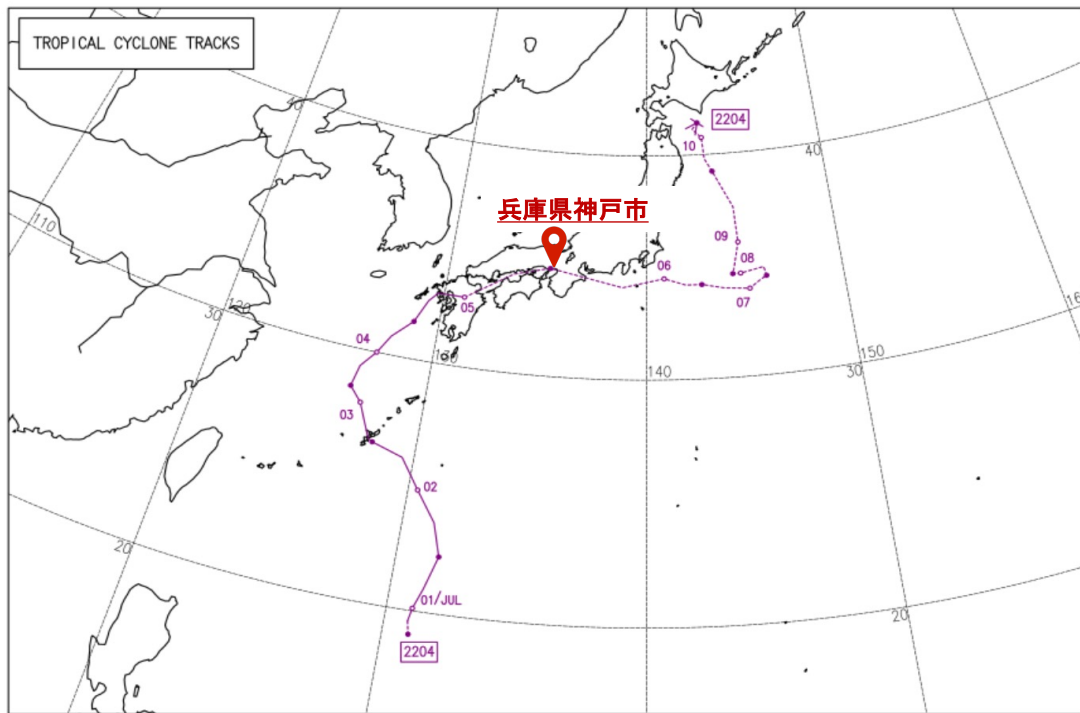


図 36: 台風 4 号の経路図 (文献 [31] より引用)




図 37: 2022 年 7 月 5 日のバス停 4 における乗客数予測の結果

結果として、今回使用したデータの中で、台風14号が接近した2022年9月19日は乗客数が最少となり、台風4号が接近した2022年7月5日は乗客数が最多となった。台風14号が接近した日の乗客数が最少となったのは、この日が敬老の日で祝日であったことと、暴風警報が発表されていたことが理由だと考える。祝日は、通勤や通学が目的でバスを利用する人よりも、買い物やレジャーが目的でバスを利用する人が多くなる [33]。しかし、この日は暴風警報が発表されていたことにより、普段よりも買い物やレジャーが目的でバスを利用している人が少なかったと考える。

一方、台風4号が接近した日の乗客数が最多となったのは、この日が平日であったことと、兵庫県神戸市に到達する前に温帯低気圧に変化したことが理由だと考える。平日は、通勤や通学が目的でバスを利用する人が多くなる [33]。さらに、温帯低気圧に変化したものの、普段は徒歩や自転車で通勤や通学している人が、バスを利用したと考える。

台風14号が接近した2022年9月19日のデータを含む2022年9月17日から2022年9月21日までの1時間毎の気圧と平均風速データの遷移を図38に示す。また、台風4号が接近した2022年7月5日のデータを含む2022年7月3日から2022年7月7日までの1時間毎の気圧と平均風速データの遷移を図39に示す。図38を見ると、台風14号が兵庫県神戸市に接近した9月19日は、他の日と比べると極端に気圧が下がっている。平均風速は17日や18日に比べると、弱くなっている。また、図39を見ると、台風4号が兵庫県神戸市に接近した7月5日は、他の日と比べると気圧が下がっている。平均風速は午前中は強いが午後からは弱くなっている。これらの結果より、台風が最も兵庫県神戸市に接近した9月19日と7月5日の気圧は他の日よりも下がっている点が共通している。しかし、兵庫県神戸市を台風として通過した9月19日は気圧が985hPa近くまで下がっており、温帯低気圧として通過した9月5日は気圧が1000hPaとなっており、下がり方に大きな違いがある。そのため、台風接近時の乗客数に関するデータが少ないため十分な分析は出来ていないが、気圧データが有効な特徴量になるのではないかと考える。

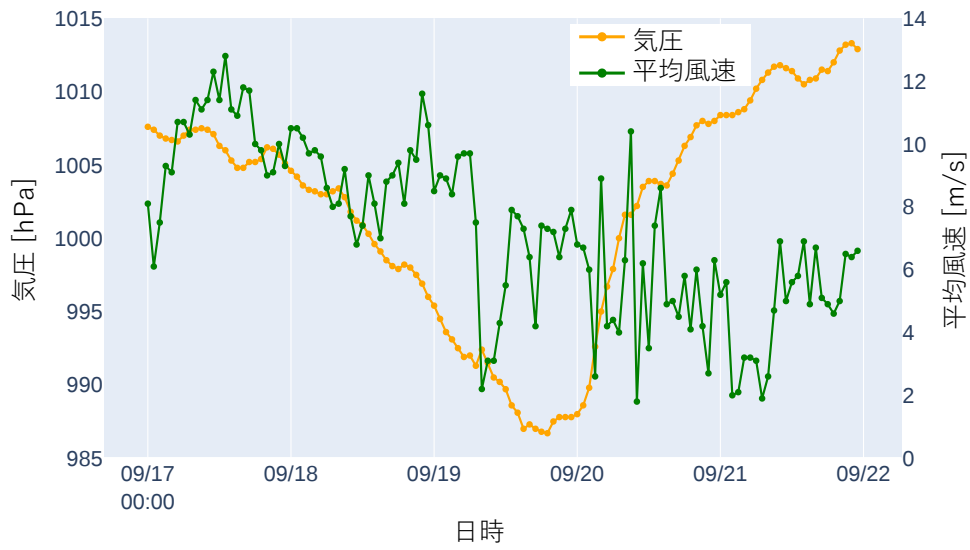


図 38: 2022 年 9 月 17 日から 2022 年 9 月 22 日までの 1 時間毎の気圧と平均風速データ




図 39: 2022 年 7 月 3 日から 2022 年 7 月 8 日までの 1 時間毎の気圧と平均風速データ

6.4 今後の展望

今後の展望は3つある。1つ目が複数のバス路線で乗客数予測を評価することである。本研究では1つのバス路線だけでしか評価できていない。そのため、Multiple-IO と過去の乗客数、便番号、曜日、休日フラグ、降水量、気温、天気データを使用した K-feature-integrated を組み合わせた提案手法が、他のバス路線でも有効であることを示す必要があると考える。

2つ目が数便先や数日先の乗客数予測を評価することである。本研究では、まずは1便先の乗客数を誤差が小さくなるように予測することが重要であると考え、1便先の乗客数予測を評価した。しかし、バス利用者に提供する予測結果を考えると、1便先だけではなく数便先や数日先の乗客数予測の結果が必要となる。そのため、今後は数便先や数日先の乗客数予測を評価する必要があると考える。

3つ目が今回新たに発見した改善点である、台風の接近がバスの乗客数に影響を与えることに取り組むことである。台風に関するデータを特徴量として考慮することで、乗客数予測の誤差を縮小できると考える。

7. おわりに

利用者にとってバスを利用するか否かの判断材料となる未来のバスの乗客数を誤差が小さくなるように予測することは、バスサービスの品質向上には必要不可欠である。特に、乗客が着席できない程混雑している状況では、混雑していない状況と比較して誤差による影響が大きいいため、小さな誤差となる予測が求められる。本研究では、バスの乗客数予測の分野で最も小さな誤差で乗客数を予測できる LSTM を用いた手法に存在する 2 つの課題に取り組むことで、予測誤差の改善を目指した。1 つ目の課題は、連続するバス停間のバス停出発時の乗客数の相関を考慮することである。2 つ目の課題は、過去の乗客数、時間帯、曜日、休日か否か、降水量、気温、天気の詳細全てを使用した予測を実施することである。本研究では Multiple-IO と K-feature-integrated を組み合わせた手法を提案した。Multiple-IO では連続するバス停間のバス停出発時の乗客数の相関を考慮できるように 1 つの路線に存在するバス停全体で 1 つのモデルを作成する。K-feature-integrated では先述した全てのデータを同時にモデルへ入力する際に、適切にモデルが学習できるように、前処理として正規化とワンホットエンコーディングを実施する。評価では、兵庫県神戸市で運行されているバスから収集したデータと、気象庁が公開している気象データを使用した。評価した結果、1 つ目の課題に対する Multiple-IO と 2 つ目の課題に対する K-feature-integrated はそれぞれ有効であると示した。特に、Multiple-IO と K-feature-integrated を組み合わせた提案手法では既存手法と比較して、乗客が着席できない程混雑している状況において 1 便先の乗客数予測の平均絶対誤差が 2.109 人少ない 3.602 人まで縮小した。そのため、組み合わせた手法も有効であると示した。今後の展望として、複数のバス路線で乗客数予測を評価すること、数便先や数日先の乗客数予測を評価すること、今回新たに発見した台風の接近がバスの乗客数に影響を与える点に取り組むことが挙げられる。

謝辞

主指導教員であり、研究の実用性や新規性の観点を中心に研究指導を頂きました本学情報基盤システム学研究室の藤川和利教授に心から感謝いたします。副指導教員であり、研究の方向性についての的確なご助言を頂きました本学ユビキタスコンピューティングシステム研究室の安本慶一教授に心から感謝いたします。副指導教員であり、実際に研究を進めていく上での様々なサポートを頂きました本学情報基盤システム学研究室の新井イスマイル准教授に心から感謝いたします。国内・国際学会へ論文を提出する際には、何度も何度も論文添削にご尽力を頂き、感謝しております。研究についてのご助言やご指導だけではなく、学内システムやネットワークの運用方法など様々な側面において熱心にご指導頂きました本学情報基盤システム学研究室の垣内正年助教に心から感謝いたします。実際に研究を進めていく上で様々なサポートを頂きました本学情報基盤システム学研究室の遠藤新助教に心から感謝いたします。国内・国際学会へ論文を提出する際には、文章全体の章構成や文章表現に関する多くのご助言を頂き、感謝しております。様々な面から研究活動の支援を頂きました本学総合情報基盤センターの辻元理恵女史に心から感謝いたします。研究活動での様々なご助言を頂きました本学情報基盤システム学研究室の大平氏に心から感謝いたします。ネットワーク機器の扱い方などのご指導を頂きました本学情報基盤システム学研究室の桂氏に心から感謝いたします。研究で使用するデータを提供して頂きましたみなと観光バス株式会社の皆様に心から感謝いたします。そして、2年間の博士前期課程を共に過ごした本学情報基盤システム学研究室同期の福田君、松永君、丹羽君、1年間を共に過ごした本学情報基盤システム学研究室の眞田君、人見君に心から感謝いたします。

最後に、経済面や生活面において多大な支援を頂きました家族に心から感謝いたします。

参考文献

- [1] Eneko Echaniz, Rubén Cordera, Andrés Rodríguez, Soledad Nogués, Pierluigi Coppola, and Luigi Dell’Olio. Spatial and temporal variation of user satisfaction in public transport systems. *Transport Policy*, Vol. 117, pp. 88–97, January 2022. DOI: 10.1016/j.tranpol.2022.01.003.
- [2] Stephen Stradling, Michael Carreno, Tom Rye, and Allyson Noble. Passenger perceptions and the ideal urban bus journey experience. *Transport Policy*, Vol. 14, No. 4, pp. 283–292, July 2007. DOI: 10.1016/j.tranpol.2007.02.003.
- [3] Charles Atombo and Tina Dzigbordi Wemegah. Indicators for commuter’s satisfaction and usage of high occupancy public bus transport service in Ghana. *Transportation Research Interdisciplinary Perspectives*, Vol. 11, p. 100458, September 2021. DOI: 10.1016/j.trip.2021.100458.
- [4] Joon-Ki Kim, Backjin Lee, and Sungho Oh. Passenger choice models for analysis of impacts of real-time bus information on crowdedness. *Transportation Research Record*, Vol. 2112, No. 1, pp. 119–126, January 2009. DOI: 10.3141/2112-15.
- [5] Alessio D. Marra, Linghang Sun, and Francesco Corman. The impact of COVID-19 pandemic on public transport usage and route choice: Evidences from a long-term tracking study in urban area. *Transport Policy*, Vol. 116, pp. 258–268, February 2022. DOI: 10.1016/j.tranpol.2021.12.009.
- [6] Ziyulong Wang, Adam J. Pel, Trivik Verma, Panchamy Krishnakumari, Peter van Brakel, and Niels van Oort. Effectiveness of trip planner data in predicting short-term bus ridership. *Transportation Research Part C: Emerging Technologies*, Vol. 142, p. 103790, September 2022. DOI: 10.1016/j.trc.2022.103790.

- [7] Qi Ouyang, Yongbo Lv, Jihui Ma, and Jing Li. An LSTM-based method considering history and real-time data for passenger flow prediction. *Applied Sciences*, Vol. 10, No. 11, p. 3788, May 2020. DOI: 10.3390/app10113788.
- [8] Yingying Xu and Kezhong Jin. An LSTM approach for predicting the short-time passenger flow of urban bus. In *Proceedings of 2021 2nd International Conference on Artificial Intelligence in Electronics Engineering*, pp. 35–40. Association for Computing Machinery, January 2021. DOI: 10.1145/3460268.3460274.
- [9] Shivaraj Halyal, Raviraj H. Mulangi, and M.M. Harsha. Forecasting public transit passenger demand: with neural networks using APC data. *Case Studies on Transport Policy*, Vol. 10, No. 2, pp. 965–975, June 2022. DOI: 10.1016/j.cstp.2022.03.011.
- [10] Yong Han, Cheng Wang, Yibin Ren, Shukang Wang, Huangcheng Zheng, and Ge Chen. Short-term prediction of bus passenger flow based on a hybrid optimized LSTM network. *ISPRS International Journal of Geo-Information*, Vol. 8, No. 9, p. 366, August 2019. DOI: 10.3390/ijgi8090366.
- [11] 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, December 2021. DOI: 10.1080/23249935.2020.1809547.
- [12] Patroklos Samaras, Anestis Fachantidis, Grigorios Tsoumakas, and Ioannis Vlahavas. A prediction model of passenger demand using AVL and APC data from a bus fleet. In *Proceedings of the 19th Panhellenic Conference on Informatics*, pp. 129–134. ACM, October 2015. DOI: 10.1145/2801948.2801984.
- [13] Leticia Monje, Ramón A. Carrasco, Carlos Rosado, and Manuel Sánchez-Montañés. Deep learning XAI for bus passenger forecasting: A use case

- in spain. *Mathematics*, Vol. 10, No. 9, p. 1428, April 2022. DOI: 10.3390/math10091428.
- [14] Meng Zhou, Donggen Wang, Qingquan Li, Yang Yue, Wei Tu, and Rui Cao. Impacts of weather on public transport ridership: Results from mining data from different sources. *Transportation Research Part C: Emerging Technologies*, Vol. 75, pp. 17–29, February 2017. DOI: 10.1016/j.trc.2016.12.001.
- [15] Victor Stover and Edward McCormack. The impact of weather on bus ridership in pierce county, washington. *Journal of Public Transportation*, Vol. 15, pp. 95–110, March 2012. DOI: 10.5038/2375-0901.15.1.6.
- [16] Ming Wei, Yan Liu, Thomas Sigler, Xiaoyang Liu, and Jonathan Corcoran. The influence of weather conditions on adult transit ridership in the subtropics. *Transportation Research Part A: Policy and Practice*, Vol. 125, pp. 106–118, July 2019. DOI: 10.1016/j.tra.2019.05.003.
- [17] 国土交通省. Ict を活用した事業評価 報告書 概要版. <https://www.tb.mlit.go.jp/kyushu/content/000033047.pdf>. (Accessed on 2023-01-25).
- [18] Zhenliang Ma, Jianping Xing, Mahmoud Mesbah, and Luis Ferreira. Predicting short-term bus passenger demand using a pattern hybrid approach. *Transportation Research Part C: Emerging Technologies*, Vol. 39, pp. 148–163, February 2014. DOI: 10.1016/j.trc.2013.12.008.
- [19] Yinna Ye, Li Chen, and Feng Xue. Passenger flow prediction in bus transportation system using ARIMA models with big data. In *Proceedings of 2019 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery (CyberC)*, pp. 436–443. IEEE, October 2019. DOI: 10.1109/CyberC.2019.00081.
- [20] Anila Cyril, Raviraj H. Mulangi, and Varghese George. Bus passenger demand modelling using time-series techniques- big data analytics. *The*

- Open Transportation Journal*, Vol. 13, No. 1, pp. 41–47, May 2019. DOI: 10.2174/1874447801913010041.
- [21] Chatfield Chris. The holt-winters forecasting procedure. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, Vol. 27, No. 3, pp. 264–279, May 1978. DOI: 10.2307/2347162.
- [22] Afiya Ayman, Juan Martinez, Philip Pugliese, Abhishek Dubey, and Aron Laszka. Neural architecture and feature search for predicting the ridership of public transportation routes. In *Proceedings of 2022 IEEE International Conference on Smart Computing (SMARTCOMP)*, pp. 56–61. IEEE, June 2022. DOI: 10.1109/SMARTCOMP55677.2022.00023.
- [23] Feng Jiao, Lei Huang, Rongjia Song, and Haifeng Huang. An improved STL-LSTM model for daily bus passenger flow prediction during the COVID-19 pandemic. *Sensors*, Vol. 21, No. 17, p. 5950, September 2021. DOI: 10.3390/s21175950.
- [24] 国土交通省気象庁. 過去の気象データ. <https://www.data.jma.go.jp/obd/stats/etrn/index.php>. (Accessed on 2023-01-25).
- [25] Aanshi Bhardwaj, Venu Mangat, and Renu Vig. Hyperband tuned deep neural network with well posed stacked sparse AutoEncoder for detection of DDoS attacks in cloud. *IEEE Access*, Vol. 8, pp. 181916–181929, October 2020. DOI: 10.1109/ACCESS.2020.3028690.
- [26] Paulo Lacerda, Bruno Barros, Célio Albuquerque, and Aura Conci. Hyperparameter optimization for COVID-19 pneumonia diagnosis based on chest CT. *Sensors*, Vol. 21, No. 6, p. 2174, March 2021. DOI: 10.3390/s21062174.
- [27] Ameer Tamoor Khan, Abdul Rehman Khan, Shuai Li, Sunila Bakhsh, Aamir Mehmood, and Jahan Zaib. Optimally configured gated recurrent unit using hyperband for the long-term forecasting of photovoltaic

- plant. *Renewable Energy Focus*, Vol. 39, pp. 49–58, December 2021. DOI: 10.1016/j.ref.2021.07.002.
- [28] Bruno Barros, Paulo Lacerda, Célio Albuquerque, and Aura Conci. Pulmonary COVID-19: Learning spatiotemporal features combining CNN and LSTM networks for lung ultrasound video classification. *Sensors*, Vol. 21, No. 16, p. 5486, August 2021. DOI: 10.3390/s21165486.
- [29] Lisha Li, Kevin Jamieson, Giulia DeSalvo, Afshin Rostamizadeh, and Ameet Talwalkar. Hyperband: A novel bandit-based approach to hyperparameter optimization. *Journal of Machine Learning Research*, Vol. 18, pp. 1–52, January 2017. DOI: 10.48550/arXiv.1603.06560.
- [30] Klaus Greff, Rupesh Kumar Srivastava, Jan Koutník, Bas R. Steunebrink, and Jürgen Schmidhuber. LSTM: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, Vol. 28, No. 10, pp. 2222–2232, October 2017. DOI: 10.1109/TNNLS.2016.2582924.
- [31] 国土交通省気象庁. 過去の台風経路図. https://www.data.jma.go.jp/yoho/typhoon/route_map/bstv2022.html. (Accessed on 2023-01-25).
- [32] 神戸新聞 NEXT. 兵庫県内のJR在来線、19日に計画運休 20日朝も続く見込み 台風14号で. <https://www.kobe-np.co.jp/news/sougou/202209/0015650281.shtml>. (Accessed on 2023-01-25).
- [33] 国土交通省都市局都市計画課都市計画調査室. 都市における人の動きとそ
の変化. <https://www.mlit.go.jp/common/001223976.pdf>. (Accessed on 2023-01-25).

業績一覧

国際会議

Tatsuya Yamamura, Ismail Arai, Arata Endo, Masatoshi Kakiuchi, Kazutoshi Fujikawa. Bus Ridership Prediction with Time Section, Weather, and Ridership Trend Aware Multiple LSTM. *Pervasive Context-Aware Smart Cities and Intelligent Transportation Systems (PerAwareCity)*, March 2023.

国内会議

山村 竜也, 新井 イスマイル, 遠藤 新, 垣内 正年, 藤川 和利. 同一便と同一バス停における乗客数の変動特性を考慮した LSTM による路線バス乗客数予測. マルチメディア, 分散, 協調とモバイルシンポジウム 2022 論文集, pp.766–773, July 2022.