

車両時系列位置情報の逐次適用による車両返却予測手法

佐瀬 凌太^{1,a)} 藤本 まなと^{2,3} 諏訪 博彦^{1,3} 安本 慶一^{1,3}

概要：都市部における様々な移動需要への対応と、化石燃料の消費削減に貢献できるワンウェイカーシェアが近年注目を集めている。このワンウェイカーシェアでは、特定の時間・場所へ車両需要が偏ってしまうことで“車両偏在問題”が発生してしまい、システムの利用効率の低下を招いてしまうことが知られている。この車両偏在は、“車両再配置”による解決が可能である。本研究では、この車両再配置の実現において必要となる車両返却予測を行う手法を提案する。提案手法では、利用者の情報や開始地点・時間といった静的情報に加えて、時系列的に変化する位置情報等の動的情報を取得し、静的情報・動的情報に基づく機械学習モデルを用いた車両返却予測を行う。また、この予測を利用開始時点だけでなく、利用中の一定時間おきに動的情報を更新しながら行うことで、返却予測結果を更新し続ける。提案手法を評価するために行った実世界カーシェアデータを用いた評価実験では、返却ステーション予測において F 値 0.922、返却時間予測においては 39.9 分の平均絶対誤差 (MAE) を達成した。また、どちらの予測においても時系列的に予測精度の改善が行われていることを確認した。さらに、提案手法による返却予測結果のフィードバックによって、ワンウェイカーシェアの利用効率の改善可能性があることが示された。

1. はじめに

近年、都市部におけるサステイナブルな新しいモビリティとしてカーシェアリングサービスが注目を集めている。カーシェアリングサービスの中でも、従来のレンタカーなどでみられた車両を借りた場所と同じ場所に返却を行わなければならないラウンドトリップ型と呼ばれる利用形態とは異なり、借りた場所とは異なる場所に車両を返却することができるようなワンウェイカーシェアリング（以下、ワンウェイカーシェア）が普及している。ワンウェイカーシェアは、都市部における短距離移動需要への柔軟な対応が可能であることに加え、ガソリン消費の低減による CO2 排出量の削減にも期待できる [1], [2]。一方で、ある特定の時間・場所に車両需要が偏る“車両偏在問題”が発生するという課題が存在している。車両偏在問題によってユーザーからの需要を満たすことができない状況が発生すると、システムの利用効率が低下する。この問題の解決策として、車両を配置し直す“車両再配置”がある [3]。この車両再配置を適切に行うには、未来の各ステーションにおける車両需要の予測と、現在利用中のユーザーの車両返却の予測によ



図 1 車両再配置の概念図

る未来の車両配置の予測が必要となる。この車両需要の予測結果と車両返却予測結果に基づく未来の車両配置を比較することで、その差分を埋めるための車両再配置を実施することができるようになる (図 1)。

本研究では、ワンウェイカーシェアにおいて利用開始直後から車両返却予測を行い、その後も利用中に変化していく動的情報を考慮して車両返却予測結果を更新し続けることで、従来手法よりも早く未来の車両配置を予測し、かつ時系列的に予測精度を高めていく手法を提案する。提案手法は、実世界データを用いて評価を行った。評価の結果、返却ステーションの予測においては、全テストデータに対して F 値 0.922 を達成した。また、返却時間の予測においては、39.9 分の平均絶対誤差 (MAE) を達成した。加えて、返却予測結果の時系列的な改善についても評価を行い、利用終了に近づくほど返却ステーション予測・返却時間予測のどちらも予測精度が改善していることが確認された。さらに、提案手法による返却予測結果のフィードバックによって、個人差はあるもののシステムの利用効率の改善可

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology

² 大阪公立大学
Osaka Metropolitan University

³ 理化学研究所 革新知能統合研究センター (AIP)
RIKEN

a) saze.ryota.sl4@is.naist.jp




図2 車両返却予測の先行研究における課題

性能があることが示された。

2. 関連研究

車両需要の予測に関する先行研究としては、返却ステーション毎の関係性から特徴量を抽出して需要予測を行う手法 [4] や、曜日や天候等の情報から、時系列の特徴を考慮できる Long Short-Term Memory(LSTM) を用いて需要予測を行う手法 [5] が提案されている。さらに、過去の利用データだけでなく、リアルタイムなアプリログデータやステーションデータを用いて車両需要予測を行う手法 [6] も提案されている。

一方で車両返却の予測に関する研究としては、車両の移動軌跡と過去の軌跡データを照合して類似度が高い軌跡を算出し、最終的な返却ステーションを予測する手法 [7] が提案されている。また、リアルタイムな情報を活用した返却予測の手法も提案されており、Liu ら [8] は車の軌跡データやアプリログデータを活用し、15分以内に車両返却が行われる確率、および15分以内に到達可能な各ステーションへの返却確率を算出する手法を提案している。

従来の車両返却予測に関する研究では、リアルタイムな車両データを考慮して車両返却予測を行う研究はあったが、予測対象は15分以内に到達可能なステーションに絞られている。この手法の場合、ユーザーが返却を行うステーションの15分圏内にまで近づかなければ正しい返却予測が行われないということになる(図2)。さらにこの車両返却予測の結果として車両偏在問題の発生が予測された場合においても、車両再配置に割くことができる時間が短くなってしまふ。

3. 提案手法

先行研究での課題の解決のために、我々は、ユーザーの利用開始直後から全てのステーションを対象とした返却予測を行うことでより早い段階で真の返却ステーションを対象とした返却予測を行う。この返却予測を利用中に変化する位置情報・移動方向情報などの動的情報を考慮して更新し続けることで、より精度が高い返却予測結果を取得し続ける。また、カーシェアサービスプラットフォーム上でのユーザーへの返却予測結果フィードバックによる利用率改善の仕組みについても提案する。

表1 返却予測モデルにおける目的変数・説明変数

カラム名	用途	単位
利用時間	目的変数	時間(分)
利用終了ステーション	目的変数	整数
利用開始スロット	説明変数	整数
利用者ID	説明変数	整数
利用開始ステーション	説明変数	整数
曜日	説明変数	整数
経過時間	説明変数	時間(分)
緯度	説明変数	小数
経度	説明変数	小数
移動方向ベクトル	説明変数	小数

3.1 車両時系列位置情報の逐次適用アプローチ

車両の返却予測においては、利用開始時に決定される利用開始時間・利用開始場所・ユーザID等から、ユーザの過去の利用特徴を用いて返却予測を行うことは可能である。しかし、ワンウェイカーシェアにおいては、利用中のユーザの位置情報や移動方向などが時系列的に変わっていく。この変化を反映して車両返却予測に適用することができれば、静的情報のみの返却予測に加えて、予測精度を向上させ、利用開始から時間が経つにつれて予測精度を改善することが可能であると考えた。

提案手法においては、ワンウェイカーシェアから得られる静的情報・動的情報を入力とする機械学習モデルを用いて車両の返却予測を行う。返却予測で得られる具体的な出力は、ユーザが利用を終了し車両を返却するステーションである返却ステーションと、車両が返却される時間である返却時間である。図3に車両返却予測手法の概要図を示す。各返却予測モデルには予測が行われる時刻において得られる動的情報と、その利用における静的情報が同様に入力される。

提案手法では利用中に変化する動的情報を更新しながら一定時間おきに実行される。各返却予測モデルへの入力を更新しながら、利用開始から利用終了までの一定時間おきに返却予測結果を取得し続けることで、利用終了に近づくほど予測精度の改善を行っている。

3.2 返却予測モデル

本節では、提案手法内の返却予測モデルについての詳細について説明する。

3.2.1 説明変数・目的変数

表1に、返却予測モデルへの入力として使用される説明変数及び目的変数を示す。説明変数としては、どちらの予測モデルに関しても同様のものを用いている。返却ステーション予測モデルは利用終了ステーション、返却時間予測モデルは利用時間を目的変数とする。

3.2.2 返却ステーション予測モデル・返却時間予測モデル

返却ステーション予測モデルは、分類タスクで学習され

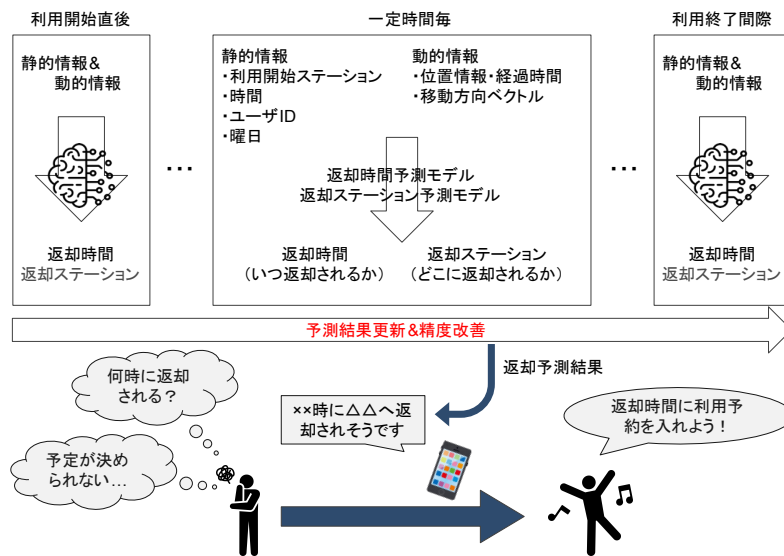


図3 提案手法の概要図

る機械学習モデルであり、返却予測が行われる各時刻においてユーザが車両を返却する確率が高いステーションを利用ステーションとして出力する。一方で返却時間予測モデルは、回帰タスクで学習される機械学習モデルであり、返却予測が行われる各時刻においてユーザが車両利用を開始してから終了するまでにかかると思われる時間を利用時間として出力する。また、実際の車両の返却時刻はこの利用時間と利用開始時間をもとに算出される。

3.3 返却予測結果フィードバックによる利用効率改善

提案手法による車両返却予測は未来の車両配置予測による車両再配置に活用することができるが、返却予測結果自体をユーザにフィードバックすることでカーシェアリングサービスの利用効率を改善できるのではないかと考えた。返却予測結果フィードバックによる利用効率改善においては、動的情報の逐次適用による車両返却予測更新手法によって得られる車両返却予測結果を Web アプリを通してユーザにフィードバックする。ユーザはこの返却予測結果を基に利用予約を行うことができ、車両の返却予測時刻に合わせたスケジュール調整や利用予約が可能となる。

4. 返却予測精度評価実験

本章では、実運用されているカーシェアサービスデータにおける提案手法による返却予測手法がどの程度の予測精度を達成することができるのかを確認すること、および提案手法の核である、時系列的に変化する動的情報を考慮することによって返却予測精度が時系列的に改善されることを確認するために実施した返却予測精度評価実験に関して述べる。

4.1 実験目的

返却予測精度評価実験は、実運用されているカーシェアサービスデータにおける提案手法による返却予測手法がどの程度の予測精度を達成することができるのかを確認することを目的とする。さらに、提案手法の核である、時系列的に変化する動的情報を考慮することによって返却予測精度が利用中の時系列的に改善されるか検証する。

4.2 実験方法

返却予測精度評価実験は、実世界のワンウェイカーシェア運用データから提案手法の機械学習モデルを学習し、運用データの最新月における利用に対して提案手法を適用した状況をシミュレーションした際の予測精度を算出することで実施する。運用データには、奈良先端科学技術大学院大学で運用されているワンウェイカーシェアである NAISMoN^{*1} の運用データを用いて行う。

4.2.1 データセット

評価実験で用いるデータセットの収集対象である NAISMoN は、奈良先端科学技術大学院大学で実運用されているワンウェイカーシェアであり、全設置ステーション数3箇所、全車両数3台という運用形態が取られている。本研究では、この設置ステーションは地理的な特徴から学校、駅、研究施設と呼称する。

表2にデータ収集期間中における各ステーションを利用開始・利用終了ステーションとする利用回数の集計を示す。表2より、学校から利用開始、あるいは学校で利用を終えるようなケースが比較的に多いことが分かる。これは NAISMoN が大学によって運営されており学生の利用者が多いことに起因していると考えられる。

^{*1} <https://naist-carshare.github.io/>

表2 各利用開始・終了ステーションでの利用回数

利用開始 \ 利用終了	NAIST	登美ヶ丘駅	けいはんな
NAIST	1208	202	28
登美ヶ丘駅	215	33	13
けいはんな	16	21	24

4.2.2 機械学習モデルの訓練・テストデータ

評価実験の中で使用した返却予測モデルの学習では、データセットの2020年6月から2021年5月までのデータを訓練データ、2021年6月のデータをテストデータとした。また、訓練データの最後月の15日目以降のデータを検証データとして利用している。

4.2.3 機械学習モデルのパラメータ

評価実験での機械学習モデルの選定は、Random Forest や SVM, Light Gradient Boosting Machine (LightGBM) 等の主要な機械学習モデルを用いた場合の返却ステーション予測性能を比較することで実施した。比較されたモデルの中ではLightGBMが最も高い性能を示していた。この結果より、今回の評価実験における返却ステーション予測モデル・返却時間予測モデルはLightGBMをそれぞれ分類タスク・回帰タスクで学習することで作成した。なお、今回の評価実験における提案手法の返却予測を行うインターバルは、5分間に設定している。

4.2.4 評価方法

本実験における返却ステーション予測の精度評価には、分類タスクの評価指標である正解率 (Accuracy), 適合率 (Precision), 再現率 (Recall), F 値 (F-value) を用いた。また、返却時間予測の精度評価には、回帰タスクの評価指標である平均絶対誤差 (MAE), 平均絶対パーセント誤差 (MAPE) を用いた。さらに、返却ステーション予測に関しては正解率、返却時間予測に関しては散布図プロットを用いて時系列的な予測精度の改善についての評価を行った。

4.3 実験結果

返却予測精度評価実験における結果は、初めに返却ステーション予測モデルの評価結果について述べ、その後返却時間予測モデルの評価結果について述べる。

4.3.1 各ステーション毎の返却ステーション予測結果

返却ステーション予測モデルは、全体でF値0.922を達成している。また、表3に返却ステーション予測モデルのテストデータに対する各分類対象クラス毎の評価指標の算出結果を示す。

表3の結果から、返却ステーション予測モデルは学校への返却に関しては高い精度で予測できていることが分かった。一方で、駅に返却する利用に関しては、F値が0.588となり、他のステーションよりも大幅に低い値となっていた。

この原因を確認するために、図4に返却ステーション予

表3 返却ステーション予測モデルの精度

返却ステーション	サンプル数	適合率	再現率	F 値
学校	2398	0.939	0.982	0.960
駅	242	0.781	0.471	0.588
研究施設	266	0.901	0.861	0.884
全体		0.923	0.929	0.922




図4 返却ステーション予測モデルの混同行列




図5 返却ステーション予測における正解率の時系列的变化

測モデルの混同行列を示す。図4から、正解ラベルが駅であるサンプルを学校行きと予測してしまっているケースが多いことが分かった。これが駅へ返却する利用に対する予測精度が落ちている原因であると考えられる。

4.3.2 返却ステーション予測の時系列的变化

図5に返却ステーション予測における正解率の時系列的变化を示す。このグラフは、利用開始から15分以内、利用開始15分後から利用終了15分前、利用終了15分以内に分けた際の正解率の変化を示している。正解率はそれぞれ0.87, 0.94, 0.96となっている。この結果から、返却ステーション予測精度は利用終了に近づくほど高まっていることが分かる。

4.3.3 利用時間帯毎の返却時間予測結果

返却時間予測モデルの評価結果は、テストデータ全体に対する平均絶対誤差が39.9分、平均絶対パーセント誤差が44.9%となった。また、図6に利用時間帯毎に分けた平均絶対誤差、平均絶対パーセント誤差を比較した結果を示す。図6の結果から、平均絶対誤差は、120-180分の利用時間である利用に対して約29分と最も小さくなっていた。平均絶対パーセント誤差に関しては、平均絶対誤差と同様に120-180分の利用時間である利用に対して最も小さい20%という値になり、それ以降は20%~40%の間で推移する

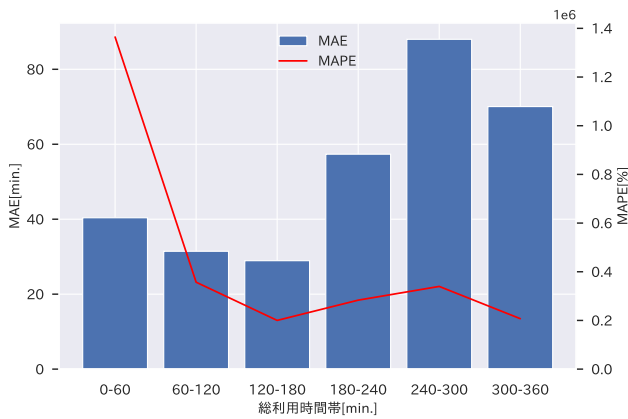


図6 利用時間帯毎の返却時間予測モデルの評価結果




図8 利用開始15分後～終了15分前までの予測結果



図7 利用開始から15分以内の予測結果




図9 利用終了から15分以内の予測結果

という結果となった。

4.3.4 返却時間予測の時系列的变化

図7～9はそれぞれ、返却時間予測モデルに対して利用開始から15分以内、利用開始から15分経過後から利用終了15分前まで、利用終了から15分以内のテストデータに対する利用時間の予測結果の散布図プロットを示している。なお、グラフに示されている直線は、それぞれ誤差15%、30%となる直線を示している。図7～9から、利用終了に近づくにつれて散布図のプロットの中央の対角線に集中していることが分かる。また、図7の傾向から、利用開始直後時点は実際の利用時間より比較的短い時間を予測値として算出するケースが多くなっていた。

5. 返却予測結果フィードバック評価実験

本章では、提案手法による車両返却予測結果をユーザへ提示することで、より効率的な利用を促すことができることを検証するために行った返却予測結果フィードバック評価実験について述べる。

5.1 実験方法

返却予測結果フィードバック評価実験は、NAISMोनの

過去の利用データから実際にあった車両利用状況を再現し、その状況下で車両利用予約を行うというシミュレーションを行った。具体的には、返却予測結果が確認できる状況・できない状況における利用予約行動を、Webアプリケーションを用いたシミュレーションを通して被験者が実施し、利用効率の比較を行った。さらに、シミュレーション実施後にそれに関わる内容の事後アンケートへの回答を依頼した。本実験は5人の被験者（内NAISMोनユーザが3人、非ユーザが2人）を対象に実験を行っている。

5.1.1 実験環境

本実験では、被験者に対して実験の概要・シミュレーションに使用するWebアプリケーションの接続・操作方法を説明するスライド資料（計16ページ）を共有し、その説明を基に被験者が個人で実験に臨む形式で実験を実施した。さらに、Webアプリケーション上でのシミュレーション実施後にWeb上で事後アンケートに回答してもらった。

5.1.2 データセット・機械学習モデル

返却予測結果フィードバック評価実験では、返却予測精度評価実験で用いたものと同様のデータセットを用いる。

返却予測モデルに関しても、返却予測精度評価実験と同様のパラメータで学習した LightGBM を利用する。なお、返却予測結果フィードバック評価実験において再現した車両利用状況は、2021 年 6 月の期間のデータを基にしている。

5.1.3 シミュレーション用アプリケーション

返却予測結果フィードバック評価実験では、Web アプリケーションを通したワンウェイカーシェアの利用予約シミュレーションを実施する。図 10 にシミュレーションを実施する Web アプリケーション画面を示す。このシミュレーションでは、2021 年 6 月における 3 つの時間帯の利用状況（以下、シチュエーション）を再現する。そして、各状況において利用を開始したいユーザ（被験者）が存在することを仮定し、そのユーザが返却予測結果を確認できる場合とそうでない場合においてどの程度利用効率が変化するかを評価する。

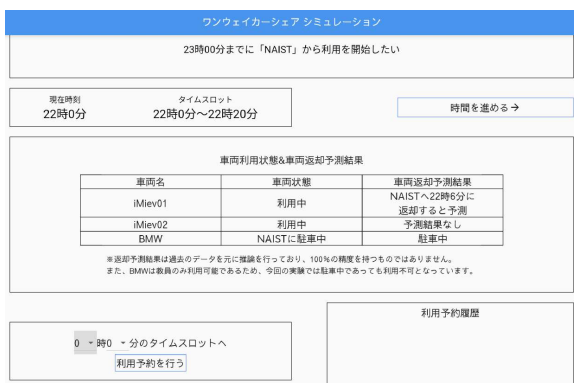


図 10 シミュレーション画面

5.1.4 評価方法

返却予測結果フィードバック評価実験における評価は、利用効率による定量評価、アンケート調査による訂正評価を行った。なお利用効率は、被験者が利用予約を成功させるために必要となった利用予約回数の逆数として定義している（式 (1)）。

$$\text{利用効率} = \frac{\text{利用予約成功数}}{\text{利用予約回数}} \quad (1)$$

返却予測結果フィードバック評価実験においては、利用中の車両の返却予測結果を被験者が確認し、その情報を基により少ない利用予約回数で利用予約を成功させることによって、返却予測結果が提示された状況の方が利用効率が高くなるのが期待される。

5.2 実験結果

返却予測結果フィードバック評価実験における結果は、初めにシミュレーション結果に基づく定量的評価、その後アンケート結果に基づく定性的評価について述べる。

5.2.1 シミュレーション結果に基づく定量的評価

返却予測結果フィードバック評価実験の定量的な評価結果として、図 11~15 に被験者毎の各シチュエーションにおける利用効率算出結果を示す。3 つあるシチュエーションとチュートリアルについてそれぞれ返却予測結果の表示あり・なしでシミュレーションを実施したため、1 人のユーザについて 8 つの利用効率算出結果が表示されている。なお、横軸ラベルは「(シチュエーション番号).(予測結果表示ある・なし)」というフォーマットで記載されている。シチュエーション番号が 0 であるものがチュートリアルである。例えば、シチュエーション 1 を予測結果表示ありで実施した結果は「1_withPred」というラベルとなる。

図から、返却予測結果のフィードバックによる利用効率改善には個人差が見られる結果となった。図 11, 15 においては返却予測結果が表示されている場合の方が利用効率が向上しているシチュエーションが見受けられた。しかし、図 12, 13 においては、返却予測結果が表示されている場合の方が利用効率が低下しているシチュエーションが見受けられた。さらに、図 12 ではシチュエーション 1 と 3、図 13 ではシチュエーション 2 で利用効率が低下しており、シチュエーション番号の類似性は見られなかった。

5.2.2 アンケート結果に基づく定性的評価

返却予測結果フィードバック評価実験の定性的な評価結果として、図 16, 17 にアンケート調査結果を示す。なお、図 16 は「はい」、「いいえ」の 2 つの選択肢から選ぶ回答方式、図 17 は 1~5 の 5 段階選択 (5 が「非常にそう思う」) の解答方式となっている。各グラフのキャプションは、アンケート内での質問項目を示している。図 16 の結果から、シミュレーションを実施した被験者の 80 % が車両返却予測による利用効率改善の意義を理解できていることが分かる。また、図 17 の結果から、被験者の半数以上が車両返却予測結果のフィードバックによって利用予約が行いやすくなったと感じていることが分かる。

6. 考察

6.1 返却ステーション予測

返却ステーション予測モデルに関しては、F 値 0.922 と




図 11 NAISMOn ユーザ 1




図 12 NAISMoN ユーザ 2




図 13 NAISMoN ユーザ 3




図 14 非 NAISMoN ユーザ 1




図 15 非 NAISMoN ユーザ 2

いう高い値を達成していた。これはサンプル数が多い学校を返却ステーションとする利用に対する予測精度が高いことが理由であると考えられる。一方で、表 3 に示すように、一部のステーションに対してのみ予測精度が落ちるという問題も確認されている。この問題に対して図 4 を併せて見




図 16 車両返却予測結果を提示することの意義や意味は理解できましたか？




図 17 車両返却予測結果が見えることで、利用予約が行いやすいと思えましたか？

ると、予測精度が落ちている駅行きの利用は学校行きの利用であると判断されているケースが多いことが分かる。この原因分析のためにテストデータ中の駅行きの利用に対する予測結果とその予測が行われた位置の関係をプロットしたが、予測が行われる位置による正誤の偏りは見られなかった。今後さらにその他の特徴量等の影響を詳しく調査していく必要がある。

6.2 返却時間予測

返却時間予測モデルはテストデータ全体に対する平均絶対誤差が約 40 分となった。また、図 6 に示す結果から、返却時間予測においては 60-180 分の利用時間帯に対する平均絶対誤差が約 30 分と他の時間帯と比べて小さいという結果になっていた。これらの平均絶対誤差を NAISMoN の 20 分を 1 スロットとしたタイムスロットに換算すると、それぞれ 2 スロット、1.5 スロット程となった。この予測精度が車両再配置・ユーザの利用効率改善においてどの程度の効果が得られるかについては、返却予測結果フィードバック評価実験の考察を述べる 6.4 節で議論する。

6.3 返却予測結果の時系列的改善

図 5 の結果より、返却ステーション予測モデルの予測精度は時系列的に改善されていることが分かる。実際の数値としては利用開始 15 分以内の範囲での正解率が約 88%、利用終了 15 分以内の範囲での正解率が約 96%となっていた。この結果より、返却ステーション予測モデルは 8%程の予測精度の改善を行っており、時系列的な動的情報の変化を考慮することは返却ステーションの予測において有効であると言える。また、図 7~9 について、誤差範囲内毎のプロットの割合を比較したものを表 4 に示す。表 4 から、返却時間予測モデルに関しても返却ステーションと同様に予測精度の時系列的改善を行うことができていることが確

表4 各誤差の範囲にある返却時間予測結果プロットの割合の比較

予測タイミング	± 15%以内	± 30%以内	± 30%以上
利用開始から 15 分以内	0.166	0.34	0.494
利用開始 15 分後～終了 15 分前	0.371	0.595	0.034
利用終了から 15 分以内	0.372	0.591	0.037

認でき、動的情報の考慮が返却時間予測において有効であると言える。また、利用開始 15 分後～終了 15 分前と利用終了から 15 分以内に関しては類似した割合となっているが、他の予測タイミングのと比べて時間幅が大きくなっているため、より細かくタイミング毎に分けた上で比較を行う必要がある。

6.4 返却予測結果フィードバック

図 11～15 の結果から、提案した返却予測結果のフィードバックは、ユーザ毎の利用予約行動の特徴に依存するが、利用効率を改善できることが分かった。一方で、返却予測結果のフィードバックが行われない状況よりも利用効率が低下していたケースに関しては、返却予測精度が十分でないことで正しい返却時間をフィードバックすることができず、ユーザに誤った利用予約を促してしまったことが考えられる。

さらに、利用効率の低下が確認されたケースは NAISMoN ユーザのみで発生していることから、現状のモデルによる返却予測結果のフィードバックでは、NAISMoN ユーザが普段の利用予約で用いている各自の経験則に基づく返却予測よりも精度が悪くなるケースが存在すると考えられる。このことから、返却予測モデルの予測精度は、全てのユーザの利用効率を改善するという目的で考えると不十分であると考えられる。

今後は返却予測モデルの精度改善を図るとともに、より多人数の NAISMoN ユーザを対象とした返却予測結果フィードバック評価実験を実施し、フィードバックの影響について分析を深めていく予定である。

7. おわりに

本研究では、ワンウェイカーシェアにおける車両偏在問題解決のための車両再配置に必要な車両返却予測手法を提案した。提案手法では、ユーザの車両利用開始時に決定される静的情報に加えて、リアルタイムな車両の位置情報・移動方向情報等の動的情報を考慮して返却予測を行い、車両が利用中の間にその予測結果を更新し続けるものである。評価実験を行った結果、提案手法は返却ステーション予測ではテストデータ全体の各クラスに対する F 値のミクロ平均として約 0.922 という高い値となった。また、返却時間予測ではテストデータ全体に対する平均絶対誤差が約 39.9 分となった。さらに、返却ステーション予測モデル・返却時間予測モデルのどちらにおいても時系列的な予測精度の改善が確認されており、提案手法における動的情報の

考慮が有効に働いていることが確認できている。提案手法を用いた車両返却予測結果のユーザへのフィードバックに関しても、シミュレーションを通じた実験を行い、個人差はあるものの、利用効率の改善を促すことができる可能性が示された。一方で、今後はさらに返却予測精度の向上を図るとともに、より大規模でステーション配置が変わった状況であっても同様の結果が得られるかどうかを調査する必要がある。

参考文献

- [1] Patrícia Baptista, Sandra Melo, and Catarina Rolim. Energy, environmental and mobility impacts of car-sharing systems. empirical results from lisbon, portugal. *Procedia-Social and Behavioral Sciences*, Vol. 111, pp. 28–37, 2014.
- [2] Andrea Chicco and Marco Diana. Air emissions impacts of modal diversion patterns induced by one-way car sharing: A case study from the city of turin. *Transportation Research Part D: Transport and Environment*, Vol. 91, p. 102685, 2021.
- [3] Diana Jorge, Goncalo HA Correia, and Cynthia Barnhart. Comparing optimal relocation operations with simulated relocation policies in one-way carsharing systems. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 15, No. 4, pp. 1667–1675, 2014.
- [4] Man Luo, Bowen Du, Konstantin Klemmer, Hongming Zhu, Hakan Ferhatosmanoglu, and Hongkai Wen. D3p: Data-driven demand prediction for fast expanding electric vehicle sharing systems. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol. 4, No. 1, pp. 1–21, 2020.
- [5] Daben Yu, Zongping Li, Qinglun Zhong, Yi Ai, and Wei Chen. Demand management of station-based car sharing system based on deep learning forecasting. *Journal of Advanced Transportation*, Vol. 2020, , 2020.
- [6] Ling Wang, Hao Zhong, Wanjing Ma, Yugao Zhong, and Lei Wang. Multi-source data-driven prediction for the dynamic pickup demand of one-way carsharing systems. *Transportmetrica B: Transport Dynamics*, Vol. 8, No. 1, pp. 90–107, 2020.
- [7] Lei Wang, Yugao Zhong, and Wanjing Ma. Gps-data-driven dynamic destination prediction for on-demand one-way car-sharing system. *IET Intelligent Transport Systems*, Vol. 12, No. 10, pp. 1291–1299, 2018.
- [8] Dongbo Liu, Jian Lu, and Wanjing Ma. Real-time return demand prediction based on multisource data of one-way car-sharing systems. *Journal of Advanced Transportation*, Vol. 2021, , 2021.