

けるシェアサイクル利用台数の変化量 (bike_change) を目的変数として設定した。予測モデルの説明変数としては、以下の6項目を用いている：

利用可能台数 (num_bikes_available)、空きドック数 (num_docks_available)、気温 (temperature)、湿度 (humidity)、時間帯 (hour_of_day)、曜日 (weekday)。

これらのデータを前処理後、訓練データとテストデータに分割し、ランダムフォレスト回帰器を用いて予測モデルを構築した。モデルの性能はテストデータに対する平均絶対誤差 (MAE) および決定係数 (R^2) により評価し、高い予測精度が確認された。さらに、特定のステーションについては、1週間分の実測データとモデルによる予測値をグラフ化し、時間帯や天候条件が利用台数に与える影響を視覚的に分析した。

A	B	C	D	E	F	G	H	I	J	K	L	M
station_id	hour	num_bikes	num_docks	lat	lon	temperature	humidity	weather	next_bikes	bike_change	hour_of_day	weekday
10402	2024/6/21 1:00	0	1	35.61569	139.6996	22.70833	80.45833	Clear	0	0	1	4
10402	2024/6/21 2:00	0	1	35.61569	139.6996	22.55417	81	Clear	0	0	2	4
10402	2024/6/21 3:00	0	1	35.61569	139.6996	22.45417	80.54167	Patchy rain	0	0	3	4
10402	2024/6/21 4:00	0	1	35.61569	139.6996	22.44583	79.54167	Partly cloudy	0	0	4	4
10402	2024/6/21 5:00	0	1	35.61569	139.6996	22.6375	77.625	Partly cloudy	0	0	5	4
10402	2024/6/21 6:00	0	1	35.61569	139.6996	22.89167	73.70833	Cloudy	0	0	6	4
10402	2024/6/21 7:00	0	1	35.61569	139.6996	22.90833	67.79167	Overcast	0	0	7	4
10402	2024/6/21 8:00	0	1	35.61569	139.6996	22.57083	63.54167	Patchy rain	1	1	8	4
10402	2024/6/21 9:00	1	1	35.61569	139.6996	22.11667	63.01667	Patchy rain	0	-1	9	4
10402	2024/6/21 10:00	0	1	35.61569	139.6996	22.12917	61.33333	Patchy rain	0	0	10	4
10402	2024/6/21 11:00	0	2	35.61569	139.6996	22.58333	55.625	Partly cloudy	0	0	11	4
10402	2024/6/21 12:00	0	2	35.61569	139.6996	23.075	54.45833	Sunny	0	0	12	4
10402	2024/6/21 13:00	0	2	35.61569	139.6996	23.72083	54.54167	Sunny	0	0	13	4
10402	2024/6/21 14:00	0	2	35.61569	139.6996	24.28333	54	Sunny	0	0	14	4
10402	2024/6/21 15:00	0	2	35.61569	139.6996	24.54583	54	Sunny	0	0	15	4
10402	2024/6/21 16:00	0	2	35.61569	139.6996	24.6	54	Sunny	0	0	16	4
10402	2024/6/21 17:00	0	2	35.61569	139.6996	24.41667	55.375	Sunny	0	0	17	4
10402	2024/6/21 18:00	0	2	35.61569	139.6996	23.925	57.91667	Sunny	0	0	18	4
10402	2024/6/21 19:00	0	2	35.61569	139.6996	23.41667	59.91667	Clear	0	0	19	4
10402	2024/6/21 20:00	0	2	35.61569	139.6996	23.0625	61	Clear	0	0	20	4
10402	2024/6/21 21:00	0	2	35.61569	139.6996	22.67083	61.45833	Clear	0	0	21	4

図3 モデルで使用されるデータの例

5. 実験と結果

構築されたモデルにおいて、平均絶対誤差 (MAE) は全体で良好な値を示し、特に時間帯や天候変化による利用傾向の変動を正確に捉えることができた。さらに、決定係数 (R^2) も高い値を記録しており、モデルが説明変数による利用台数変化の分散を十分に説明していることが確認された。

また、過去の実測のデータと予測データを比較すると、予測値は実際の測定値と高い相関関係を示しており、モデルの実用性が裏付けられている。最後に、天気予報によって得られる今後7日間の気象データを用い、各時間帯ごとの各駅の車両データ予測も可能となっている。各ステーションにおける R^2 は可視化アプリ上に表示される。

本研究では、構築した予測モデルの妥当性を検証するため、ある特定のシェアサイクルステーションにおける実際の利用データと予測データを時間軸に沿って比較した。実測値と予測値の比較結果と R^2 の1例を図4に示す。



図4 実際のデータと予測データの比較データ画像

構築した予測モデルの精度を評価するため、平均絶対誤差 (MAE) の時間的推移を可視化した。MAE の変動状況

は図5に示す通りであり、小さい値で安定していることから、モデルが一貫して良好な予測性能を維持していることが確認できる。



図5 平均絶対誤差データ

天気予報データを活用することで、将来の利用動向に対する予測精度を検証した。未来7日間の各時間帯における各ステーションのシェアサイクル利用台数の予測結果の1例を図6に示す。

シェアサイクル一週間の需要予測




図6 未来7日の車両需要の予測データ

6. まとめと今後の課題

本研究では、品川区を中心とするシェアサイクルシステムにおける需給ギャップの定量化を通じて、需要予測を目的としたモデルを構築した。構築したモデルは、主に過去の車両利用状況と天候のデータを用いて学習評価を行った。全体として予測性能は良好であり、多くの時間帯において実際の変動と高い一致を示した。一方で、一部の急激な変動が見られる時間帯では、予測誤差がやや大きくなる傾向があり、今後の改善余地が確認された。

現時点では、過去データに依存した静的な予測に基づいているが、実運用においてはリアルタイムデータに即応した動的な最適化が求められる。特に、交通状況や天候の急変に応じた自転車の再配置、さらにはユーザー行動の変化を反映した需要予測が重要な課題となる。

参考文献

- [1] 国土交通省. “シェアサイクルに関する現状と課題”. 国土交通省. 2019. <https://www.mlit.go.jp/road/ir-ir-council/sharecycle/pdf01/03.pdf>, (2023-12-17).
- [2] Sun D., Zhou J., Wan F. et al. Optimization of bike-sharing parking spot layout based on usage requirements[J]. International Journal of Modeling, Simulation, and Scientific Computing, 2020, 11(01): 2050007.
- [3] Lu Y., Luo D., Pan W. Improved Algorithm Used for Demand Prediction and Scheduling Optimization of Shared Bicycles[J]. "U.P.B. Sci. Bull., Series C, Vol. 84, Iss. 2, 2022.
- [4] 公共交通オープンデータ協議会. <https://ckan.odpt.org/dataset/?tags=%E3%83%90%E3%82%A4%E3%82%AF%E3%82%B7%E3%82%A7%E3%82%A2-bikeshare>, (2023-12-17).