

## 1. はじめに

日本の渋滞損失は依然として増加傾向にあり、渋滞が引き起こす速度低下は経済損失や環境への負荷を生み出すことから渋滞対策が大きな課題となっている。渋滞対策の検討時には、交通シミュレーションによりその効果や影響を評価することが有効である。しかし、従来の交通シミュレーションでは、多くのパラメータ設定が必要でありそのデータの取得方法が問題点として指摘されている。交通シミュレーションには、数理モデルによる追従車両挙動モデルが実装されており、パラメータ設定によっては追突などの非現実的な挙動を引き起こすなど、従来の交通シミュレーションでは渋滞再現に課題が残る。一方、近年では微細で大量のデータを取得することが可能となり、深層学習などの技術が発達したことからデータ駆動型のモデリングが可能となりつつある。本研究では、深層学習によってより高精度な追従車両挙動モデルの構築を目指す。

## 2. 使用データおよび対象区間

阪神高速道路が提供する Zen Traffic Data(ZTD)<sup>1)</sup>を使用する。これは、画像センシングを活用し、走行映像から対象区間を走行する全車両の0.1秒単位の運転挙動を車両軌跡データとしてデータ化したものである。ZTDには、時系列で各車両の位置や速度等が記録されている。阪神高速11号池田線(大阪方面)塚本合流付近の車線変更禁止区間の追越車線を対象区間とし、7:00~8:00の約1時間分のうち約20分間のデータを使用する。



図1 研究対象区間

## 3. データセット概要

本研究では細かい車両の動きをとらえるために0.1秒ごとのデータを学習させる。対象車両の加速度に影響を

及ぼすとして、表に示すように前方10台、後方3台の車両情報と道路線形情報として勾配と曲率を加えて各モデルのデータセットとした。なお、各モデルに与える正解データは1秒後の加速度とする。また、データセット内の欠損値や他のデータとかけ離れた値を外れ値として除去した。深層学習では、元データの値の大きさの差をなくし予測ミスを防ぐ目的で正規化を施す。

$$\text{正規化: } x'_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (i = 1 \dots n) \quad \text{式(1)}$$

## 4. 機械学習及び深層学習概要

機械学習の手法の一つであるランダムフォレストを用いて学習データの重要度を算出する。重要度の結果から前方車両5台目以降のデータは予測に重要でないことが明らかとなったことから、深層学習では前方車両を5台に限定したデータセットを各モデルに適合する形状に整形し学習を行う。深層学習には、DNNモデル・LSTMモデル・1次元CNNモデル・2次元CNNモデルを採用した。なお、対象とする車種は十分なデータ数を確保できた小型車両とする。DNNモデルには1次元配列、LSTM・1次元CNNモデルには2次元配列、2次元CNNモデルには3次元配列を与える。2次元配列では時系列情報、3次元配列では時系列情報に加えて空間的な情報をモデルに学習させる。時系列情報としては3秒前からのデータを与える。各手法によって構築したモデルの分析結果から、どのようなデータ・深層学習手法を用いれば高精度な追従車両挙動モデルを構築できるか明らかにする。本研究では、1秒後の加速度という連続値を予測するため回帰に区分される。回帰分析の精度を評価するために、評価指標としてはRMSE・MAEを用いる。これらは実測値と予測値の誤差の平均をとり、値が小さいほどモデルの性能が良いと判断できる。また、Loss Plot(損失関数の推移)とyyplot(予測値と実測値の分布)を図示し、視覚的にモデルの予測精度を評価する。Loss Plotでは過学習の有無、yyplotでは対角線上にプロットが分布しているか確認する。

### 5. モデルの予測結果

本研究では4つの深層学習手法によって追従車両挙動モデルを構築した。各モデルのデータセットの構成と各評価指標の結果を以下に示す。また、各モデルの `yyplot` を以下に図示する。結果から LSTM モデルにおいて RMSE・MAE の値が最も小さく、予測の誤差が抑えられていることが分かる。また、LSTM モデルの `yyplot` において対角線上にプロットが分布しており、低・高加速度帯で高精度の予測が可能であることを示している。

### 6. 今後の展望と課題


本研究では LSTM モデルの予測精度が最も良いと結論付けたが、学習データの内容やモデルの構造を工夫することで LSTM 以外のモデルにおいても精度の向上が期待できる。また、1次元配列に比べて、2・3次元配列のように時系列的な要因を構造化することの重要性が明らかとなった。モデルの移転性の課題として、異なる時間帯や区間の予測精度についても検証する必要がある。

説明変数 $X_1$	説明変数 $X_2$	...	説明変数 $X_i$

1次元配列

時刻	説明変数 $X_1$	説明変数 $X_2$	...	説明変数 $X_i$
t-n				
...				
t-1				
t				

2次元配列



3次元配列

図2 学習データ形状

表1 DNNモデル採用データセット

車両情報	データ内容
対象車両	速度
	前方車両との車間距離・相対速度
	0.5秒～3秒前(0.5秒刻み)からの速度変化・加速度変化・走行距離
	50m先の曲率
1～10台目前方車両	速度
	前方車両との車間距離・相対速度
	0.5秒～3秒前(0.5秒刻み)からの速度変化・加速度変化・走行距離
	50m先の曲率
1～3台目後方車両	速度
	前方車両との車間距離・相対速度
	0.5秒～3秒前(0.5秒刻み)からの速度変化・加速度変化・走行距離
	50m先の曲率

表2 LSTM・1次元CNNモデル採用データセット


車両情報	データ内容
対象車両	速度
	前方車両との車間距離・相対速度
	50m先の曲率
	前後50mの縦断勾配の平均
1～10台目前方車両	速度
	前方車両との車間距離・相対速度
1～3台目後方車両	速度
	前方車両との車間距離・相対速度

表3 2次元CNNモデル採用データセット

車両情報	データ内容
対象車両	速度
	前方車両との車間距離・相対速度
	50m先の曲率
	前後50mの縦断勾配の平均
1～10台目前方車両	速度
	前方車両との車間距離・相対速度
	50m先の曲率
	前後50mの縦断勾配の平均
1～3台目後方車両	速度
	前方車両との車間距離・相対速度
	50m先の曲率
	前後50mの縦断勾配の平均


表4 データセット構成と評価指標の結果

	DNN	LSTM	1DCNN	2DCNN
訓練データ	244684	225883	225883	227140
テストデータ	61171	56471	56471	56786
前方車両台数	5	5	5	5
後方車両台数	3	3	3	3
<code>yyplot</code> の傾き	0.6526	0.9059	0.6123	0.8618
RMSE	0.0304	0.0173	0.0300	0.0183
MAE	0.0232	0.0130	0.0229	0.0139



DNNモデル

LSTMモデル



1次元CNNモデル

2次元CNNモデル

図3 各モデルの `yyplot` の結果

#### 【参考文献】

- 1) 阪神高速道路, Zen Traffic Data: <https://zen-traffic-data.net>