

## シミュレーションゲームを用いた赤信号待ち台数予測の検討

### Study on predicting the number of vehicles waiting at red lights using a simulation game

○西澤嶺<sup>1</sup>, 福田卓海<sup>2</sup>, 高橋聖<sup>2</sup>  
 Rei Nishizawa<sup>1</sup>, Takumi Fukuda<sup>2</sup>, Sei Takahashi<sup>2</sup>

Traffic volume is measured using sensors attached to traffic lights to determine traffic demand. Signal control is used to facilitate smooth vehicle operation. The number of vehicles waiting for a red light is an evaluation index for traffic demand at an intersection. If the number of vehicles waiting for a red light can be predicted, appropriate signal control can be implemented. In this paper, we created a realistic urban environment using the simulation game Cities: Skylines, measured the number of vehicles waiting for a red light, and made predictions using GCN and LSTM. As a result, GCN had a lower RMSE than LSTM. Therefore, it can be said that predictions of the number of vehicles waiting for a red light using GCN are highly accurate.

#### 1. はじめに

現代社会における道路交通問題として、渋滞がある。近年、全国的に自動車保有台数は減少傾向にあるが、以前として渋滞問題は解決されていない。

一般的に、ある道路の交通需要を判断する際には、信号機などに取り付けられたセンサなどにより走行する車両を検知し、決められた時間ごとに車両台数を集計し交通需要を判断している。その交通需要に応じて信号機を制御し、車両運行を円滑にしている。交差点における交通需要の評価指標としては、赤信号時における待ち車両数（以下、赤信号待ち台数）がある。赤信号待ち台数が予測できれば、予測結果に応じた信号機の制御が可能となる。

車両運行の円滑化に対して、近年の多くの研究では、街全体を対象とした検討がなされている。寺前らは、Graph Convolutional Networks（以下、GCN）を用いて、高速道路における10分後の渋滞発生を予測し、モデルの精度をConvolutional neural network（以下、CNN）の予測結果と比較している<sup>[1]</sup>。緒方らは、イングランドのオープンデータを用いて、Gradient Boosting Decision Tree（以下、GBDT）とGraph Neural Networks（以下、GNN）を適用し、15～180分先の短時間速度予測を実施している<sup>[2]</sup>。

本稿では、一般道における車両運行の円滑化を図ることを目的とし、次サイクルにおける赤信号待ち台数を予測する手法について比較検討する。シミュレーションゲーム Cities: Skylines を用いて現実世界の街を再現し、交差点における赤信号待ち台数データを取得し、得られたデータを用いて、GCN と Long Short Term Memory（以下、LSTM）で学習した結果について比較した。




Figure1. City model on the simulator

#### 2. 原理

##### 2. 1 信号機パラメータ

信号機パラメータには、サイクル長、青信号スプリット、オフセットの3つの重要な要素がある。サイクル長は、信号表示が一巡する時間である。青信号スプリットは、サイクル長における青信号時間の割合である。オフセットは、信号群の信号表示開始タイミングを決めるパラメータである。本稿では道路網内の特定の1信号機を基準とし、他の信号機のオフセットを決める絶対オフセットを採用する。

##### 2. 2 Graph Convolutional Networks (GCN)

GCNは、近年画像認識などで利用されており、グラフに対してニューラルネットワークを適用させるGNNの一種である。ノードの特徴量（入力データ）とノードごとに定義される出力データとの関係を求めることで相互の関係性を学習することができるモデルである。

1: 日大理工・学部・情報 2: 日大理工・教員・情報

### 3. 方法

本稿では、富山県昭和町周辺の道路形状を Cities: Skylines 上で Figure 1 に示すように再現した。Figure 1 の赤丸は交差点、黒矢印は赤信号待ち台数を測定した道路、アルファベットは交差点番号、数字は道路番号を表している。本研究では、サイクル長を 100 秒、青信号スプリットは 65%、オフセットはオフセット探索シミュレータを用いて最適なオフセットを設定した。測定した赤信号待ち台数は、休日と土日を除いた約 125 日分 (79500 サイクル) である。各モデルによる赤信号待ち台数の予測精度を検証するために、約 125 日分のデータの各サイクルにおける赤信号待ち台数の平均値を基準値とした。基準値に対し、予測手法である GCN と LSTM について予測精度を比較し、有効性を検証した。予測対象の信号機は A、道路は 1 とした。GCN の入力には、Figure 1 の道路が交差点を挟んで他の道路と接触している場合を隣接関係にあるとして、隣接行列を作成したものを用いた。GCN の学習ネットワークは、64 ユニットのグラフ畳み込み層 2 層、Dropout 層 2 層、活性化関数は ReLU とした。LSTM の学習ネットワークは、64 ブロックの LSTM 層を 2 層、64 ユニットの活性化関数 ReLU 全結合層 1 層とした。GCN および LSTM を用いた予測を行うにあたり、予測対象である道路 1 と説明変数とする道路 1~11 との相互相関および自己相関を確認し、極端に相関が低かった道路を除き、説明変数は道路 1, 2, 3, 4, 5, 6, 7, 8, 9 とした。予測精度の評価には Root Mean Squared Error (以下、RMSE) を用いた。学習はエポック数を 100、バッチサイズを 32 とした。また、学習率は可変とし、20 エポック学習精度が向上しなかった場合に学習を終了させた。約 124 日分 (78864 サイクル) を学習データ、約 1 日分 (636 サイクル) をテストデータとした。

### 4. 結果

各モデルによる予測精度を Table 1 に示す。Table 1 より、GCN を用いた予測が最も精度が高いことを確認した。GCN を用いたことで、赤信号待ち台数が存在する交差点における道路の隣接関係を学習できている。赤信号待ち台数は、道路の繋がり方や信号機パラメータなどにより大きく変化するため、道路の隣接関係を学習したことで、高精度に予測ができたと考えられる。GCN を用いた予測結果を横軸をサイクル、縦軸を赤信号待ち台数とし Figure 2 に示す。青線がテストデータ、赤線が予測である。Figure 2 より、GCN を用いた予測は 1 日の赤信号待ち台数の大部分を大きな乖離なく予

Table 1. Comparison of Prediction Results for Each Method

予測方法	RMSE [台]
平均	2.37
LSTM	2.05
GCN	0.48

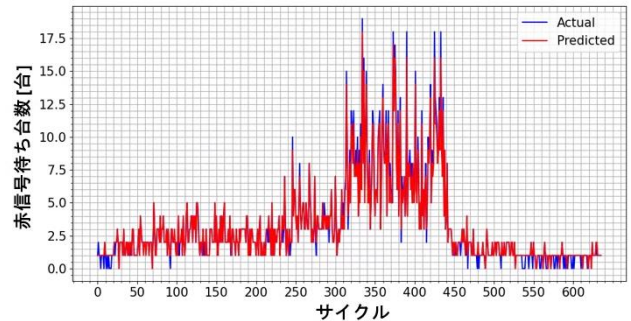


Figure 2. Prediction Results Using GCN

測できているとが確認できる。また、最も赤信号待ち台数の変動が激しい 300~400 サイクル付近の赤信号待ち台数においてもサイクルに対して遅延なく予測できていることが確認できた。したがって、赤信号待ち台数をリアルタイムに測定できる環境において、GCN を用いた予測を行うことで信号機パラメータを制御し、車両運行の円滑化を図ることができると示唆された。

### 5. まとめ

本稿では、一般道における車両運行の円滑化を図るために、次サイクルの赤信号待ち台数を予測することを目的とし、シミュレータで得られたデータを基に GCN と LSTM の精度について比較した。結果より、GCN による予測精度は、LSTM に比べ精度が高いことが確認できた。

今後は、本予測モデルを用いてシミュレータ上の信号機パラメータをリアルタイムに変更することで、車両運行の円滑化の効果を検討する。

### 参考文献

- [1] 寺前智文, 向井理沙, 西海能史, 鈴木健太郎, 小島悠紀子, 廣田敦士, 幡山五郎, 影本義明, 櫻木伸也, 阿部敦, Graph Convolutional Networks を用いた阪神高速道路における交通渋滞発生予測, 第 18 回 ITS シンポジウム, 2020.
- [2] 緒方陸, 宮利行, 菊池恵和, 村野祐太郎, 菅原宏明, 短時間速度予測における gradient boosting decision tree と graph neural network の比較, AI・データサイエンス論文集, Vol. 4, No. 2, pp. 154-162, 2023.