

深層学習を用いた複数交差点における車両停止状況の判定手法の検討

名城大学 学生会員 ○石黒 祥梧
 名城大学 学生会員 葛西 裕介
 名城大学 正会員 松本 幸正

1. はじめに

5G 通信モバイルサービスが 2019 年 4 月にアメリカ 4 都市で開始され、今後も拡大していくと考えられる。これにより、交通分野においても、V2V/V2I 通信で得られるビッグデータの活用が加速すると考えられる。車両の走行データや周辺環境に応じた車両への情報提供も可能になり、交通流の円滑化につながると考えられる。

本研究では、交通流円滑化のための車両への情報提供あるいは車両挙動の制御を想定し、今後取得可能になると考えられる交通ビッグデータを用いて、複数の信号交差点における各車両の総停止回数と停止時間を事前に判定するための手法を検討する。

2. 深層学習を用いた車両停止状況の判定手法

本研究では交通流シミュレーションの結果から得られるデータを交通ビッグデータとみなし、これらを用いて、各車両の停止状況の事前判定を行う。現在速度を維持して走行し続けた場合に信号交差点に到達した際の信号点灯色から判定される停止・通過を理論値とし、判定手法として、Neural Network (NN)と、時系列データの予測に適した深層学習である Long Short-Term Memory (LSTM)を用いる。特に、LSTMは隠れ層にループ構造が備わっており、過去のデータを保持し、次の層へ伝播する仕組みとなっており、長期・短期の時系列データに対して効率よく学習することが可能である。

3. 交通流シミュレーションの概要

図-1は、本研究のシミュレーションに用いるコース概要を示している。このコースには4つの信号交差点が存在し、5つの区間に別れ、車線数は片側2車線となっている。各信号サイクルは青時間が80秒、黄色時間が4秒、赤時間が86秒となっており、オフセットは0である。

判定を行う車両は、信号交差点0通過直後の地点を始点、交差点4通過直後の地点を終点とした一方向のみを対象とする。区間の距離は、それぞれ、交

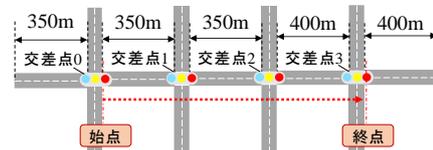


図-1 シミュレーションのコース概要

表-1 交通ビッグデータの構成要素

| | 構成要素 | 単位 | 停止回数 | 停止時間 |
|---------------------------------------|---------------------------------------|---------------------|------|------|
| 各ステップ | シミュレーション時間 | sec. | ○ | ○ |
| | 発生から現在地点までの走行距離 | m | ○ | ○ |
| | 前方車両との車間距離 | m | ○ | ○ |
| | 加減速度 | m/sec. ² | ○ | ○ |
| | 現在速度 | km/h | ○ | ○ |
| | 走行しているレーン番号 | 1, 2 | ○ | ○ |
| | 前方信号交差点までの距離 | m | ○ | ○ |
| | 現在レーンにおける自転車と信号交差点間の前方車両台数 | 台 | ○ | ○ |
| | 信号交差点1の青残り時間 | sec. | ○ | ○ |
| | 現在速度を維持して走行し、無停止で到達した場合の信号交差点1の到達予想時間 | sec. | | ○ |
| 現在速度を維持して走行し、無停止で到達した場合の信号交差点2の到達予想時間 | sec. | | ○ | |
| 現在速度を維持して走行し、無停止で到達した場合の信号交差点3の到達予想時間 | sec. | | ○ | |
| 固定 | 各車両の希望速度 | km/h | ○ | ○ |
| | 1 サイクル前の区間別の交通密度 | km/台 | | ○ |
| 判定 | 信号交差点ごとの左折率 | | | ○ |
| | 総停止回数 | | | |
| | 停止時間 | | | |

※○は判定項目別の使用データ

差点0の手前の区間から350m, 350m, 350m, 400m, 400mとなっている。シミュレーションは計6時間となっており、車両は、コースを構成する全流入路からそれぞれ発生し、1時間ごとに1,000台, 1,500台, 1,000台, 1,500台, 1,000台, 1,500台の順で変化する。シミュレーション時間内に始点から終点までを9,078台の車両が通過し、走行データを0.2秒間隔の時系列データとして取得した。

4. 複数交差点における停止状況の判定手法比較

4.1 判定で用いる交通ビッグデータの概要

表-1は、シミュレーションにより作成したビッグデータの構成要素一覧を表す。本研究では、始点から終点までの総停止回数と停止時間による停止状況の事前判定を行うこととする。総停止回数の事前判定における入力データには、走行距離や加減速度といった自転車の走行データや各信号の青残り時間や前方車両台数とし、停止時間の事前判定では、そ

これらのデータに加えて、現在速度を維持して走行した場合の信号到達予想時間や密度、交差点ごとの左折率を用いる。本研究では、情報提供の位置を交差点手前から300mの位置と仮定し、信号交差点1の300m手前付近のデータを用いて、終点までの車両の停止状況を事前に判定する。

4.2 複数交差点における停止状況の判定手法

本研究における各車両の停止状況の判定手法は、理論値、NN、LSTMを用いる。NNにおける隠れ層は10とする。LSTMでは隠れ層を300、エポックを30、初期学習率を0.0001とする。LSTMは、時系列データにおける深層学習が可能なモデルであるため、車両ごとに300m付近の3地点のデータを用いて各車両の総停止回数と停止時間を事前判定する。

4.3 総停止回数の事前判定結果の評価

図-2は、横軸に反復回数、縦軸にLSTMの学習状況を示した図である。この図より、約20回の反復回数を過ぎると精度が約70%を上回り、収束していることがわかる。図-3は、総停止回数の事前判定結果を理論値、NN、LSTMのそれぞれにおいて示した図である。これらの図より、理論値と比較して、NNとLSTMにおける総停止回数の事前判定精度が高いことがわかる。NNとLSTMにおいては、事前の判定精度が全体で70%を超えていることがわかる。

4.4 停止時間区分の事前判定結果の評価

今回、停止時間の判定を行う際に、車両ごとの1交差点における停止時間を算出し、信号交差点でのDelay Level of Service¹⁾の状態を3区分し、事前判定を行った。表-2に1交差点あたりの停止時間区分を表す。

図-4は、横軸に反復回数、縦軸にLSTMの学習状況を示した図である。この図より、およそ20回の反復回数を経過すると約90%で収束していることがわかる。図-5は、1交差点あたりの停止時間の事前判定結果を理論値、NN、LSTMのそれぞれにおいて示した図である。これらの図より、理論値と比べ、NNとLSTMにおける停止回数の判定精度が高いことがわかる。NNでは、全体の判定精度が約87%、LSTMでは、約88%となった。理論値では、全区分において、判定精度が低くなっている。

5. おわりに

本研究では、複数交差点における各車両の停止状況を自車の走行データと周辺環境のデータを用い

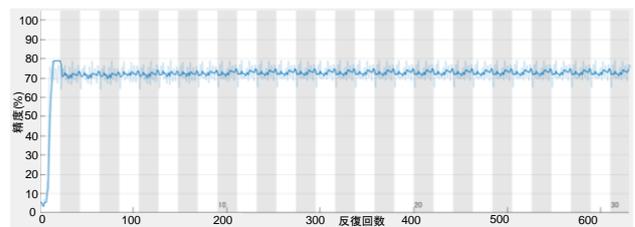


図-2 総停止回数判定の LSTM 学習状況

| 実停止回数 | 理論値による判定結果 | | | | NNによる判定結果 | | | | LSTMによる判定結果 | | | |
|-------|------------|-------|-------|---------|-----------|-------|-------|---------|-------------|-------|------|---------|
| | 1回 | 2回 | 3回 | 予測総停止回数 | 1回 | 2回 | 3回 | 予測総停止回数 | 1回 | 2回 | 3回 | 予測総停止回数 |
| 1 | 173 | 172 | 545 | 19.4% | 56 | 29 | 1 | 65.1% | 23 | 157 | 0 | 12.8% |
| 2 | 499 | 343 | 1,627 | 13.9% | 499 | 343 | 7 | 81.5% | 3 | 496 | 0 | 99.4% |
| 3 | 22 | 14 | 58 | 61.7% | 22 | 14 | 58 | 33.3% | 0 | 14 | 0 | 0.0% |
| 総計 | 24.9% | 64.8% | 2.6% | 16.6% | 57.7% | 87.2% | 11.1% | 77.1% | 88.5% | 73.7% | NaN% | 74.2% |

図-3 手法別の総停止回数の判定予測結果の比較

表-2 停止時間区分表

| 停止時間(sec.) | 交通状態 | 停止時間区分 |
|------------|----------------------|--------|
| 0-10 | 遅延なし | ほとんど |
| 10-20 | 僅かな遅延 | 遅延なし |
| 20-35 | 許容可能な遅延 | 遅延 |
| 35-55 | 許容可能な遅延, 場合により、さらに遅延 | |
| 55-80 | 大きく遅延 | 大きく遅延 |
| 80- | 渋滞 | |

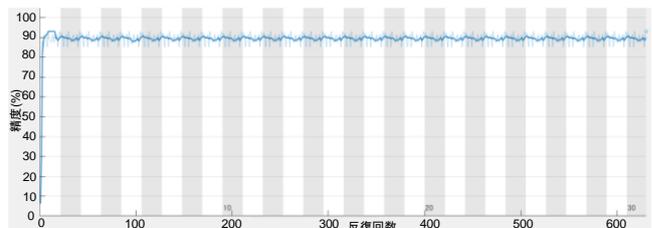


図-4 1交差点あたり停止時間判定の LSTM 学習状況

| 実停止時間 | 理論値による判定結果 | | | | NNによる判定結果 | | | | LSTMによる判定結果 | | | |
|----------|------------|-------|-------|--------|-----------|-------|-------|--------|-------------|-------|-------|--------|
| | ほとんど遅延なし | 遅延 | 大きく遅延 | 予測停止時間 | ほとんど遅延なし | 遅延 | 大きく遅延 | 予測停止時間 | ほとんど遅延なし | 遅延 | 大きく遅延 | 予測停止時間 |
| ほとんど遅延なし | 327 | 14 | 0 | 95.9% | 303 | 41 | 3 | 12.8% | 1 | 75 | 0 | 1.3% |
| 遅延 | 1,099 | 1,569 | 409 | 51.0% | 1 | 0 | 1 | 0.0% | 0 | 614 | 0 | 100% |
| 大きく遅延 | 0 | 25 | 10 | 28.6% | 0 | 0 | 0 | NaN% | 0 | 9 | 0 | 0.0% |
| 総計 | 22.9% | 97.6% | 2.4% | 55.2% | 88.5% | 73.7% | NaN% | 86.8% | 100% | 88.0% | NaN% | 88.0% |

図-5 手法別の停止時間区分の判定予測結果の比較

て、事前に判定した。

その結果、総停止回数の事前判定において、NNとLSTMが高い判定精度となった。一方、理論値の値は低い精度となり、前方車両台数といった周辺環境データが考慮されていないことがその原因と考えられる。停止時間区分の事前判定において、深層学習によるLSTMが停止時間区分の事前判定を行う際の有用な手法であることがわかった。

謝辞

本研究は、科学研究費補助金・基盤研究(C)(19K04660)を受けた研究成果の一部である。ここに記して、謝意を表す。

参考文献

- 1) Federal Highway Administration Research and Technology.: Signalized Intersections: Informational Guide, Retrieved December 24, 2019, <https://www.fhwa.dot.gov/publications/research/safety/04091/04091.pdf>, pp.146-147,2004.