

車載カメラ映像と周辺の交通量データを用いた交通量予測手法の検討

宇都 翼 谷合 廣紀 入江 英嗣 坂井 修一

東京大学

1. はじめに

一般に交通量とは、ある地点を単位時間当たりを通る車両数のことであり、道路に設置されている感知器によって一定時間間隔で集計されている。交通量は交通状況を把握するための重要な指標であり、交通量を予測して交通制御に利用することで、交通システムの効率化を達成することができる。

交通量予測で高い性能を上げている手法は、グラフ畳み込みネットワーク (GCN) を用いたもので、グラフ上で交通量データに対して畳み込みを行う。しかし、それは感知器のある地点での予測のみを想定している。感知器のない地点の交通量を予測したい場合、GCN をそのまま用いることはできず、その地点の過去の交通量を補完する必要がある。しかし、補完した際のノイズの影響は避けられず、予測の前に補完を挟むのでリアルタイム性に欠ける、といった欠点がある。

そこで本論文では、感知器のない地点の交通量を周囲の地点の交通量を用いて補完なしで予測する手法を提案する。また、新たなモダリティとして車載カメラ映像を用いることについて検証する。

2. 関連研究

2.1. グラフ上での交通量予測

ある交通量の計測地点周辺の車両が次の時刻には周囲の計測地点に伝搬していることを踏まえると、計測地点間には空間的な関係性があり、それは距離が近いほど強い。そこで計測地点をノードとして、計測地点の接続関係をエッジとしたグラフを考えることができる。交通量予測のための STGCN[1] というモデルでは、CNN による時間方向の畳み込み層と GCN によるグラフ畳み込み層からなる ST-Conv というブロックを複数回繰り返すことで、各計測地点の将来の交通量の高精度な予測を可能にしている。

2.2. 交通量補完

交通量は時系列データとして得られるが、感知器の不良や感知器がそもそも設置されていないことが原因で、交通量データが部分的または全体的に欠損している場合がある。交通量データを必要とする手法を利用する際には、その欠損部分を補完する必要がある。交通量補完で高い精度を出しているものに、CT-Gen[2] というものがある。これは、推定したい地点と類似し

た特徴を持つ計測地点を選び出し、選び出された地点の交通量から推定したい地点の交通量を Attention 機構によって推定する手法である。

2.3. 車載カメラ映像の応用例

車載カメラ映像の応用例として、操舵角予測 [3] がある。車載カメラ映像から得られる、操舵角に影響を及ぼす周囲の複雑な環境の情報を入力して予測に利用している。

3. 提案手法

3.1. 周囲の交通量データを用いた手法

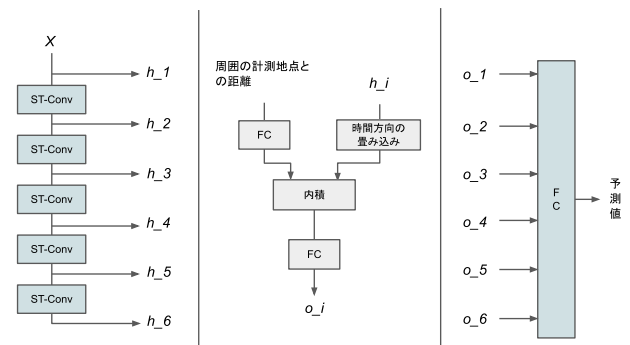


図 1: 周囲の交通量データを用いた手法

図 1 は周囲の交通量データを用いた提案手法のアーキテクチャである。まず計測地点のグラフと特徴行列を作成する。そして図左のように、STGCN[1] の ST-Conv Block に特徴行列を複数回入力して、時間方向と空間方向での畳み込みを繰り返す。それによって得られる最終的な出力と中間出力をそれぞれ図中央のモジュールに入力する。ここでは、交通量を予測したい地点とグラフ上の地点との距離に応じて重み付け和を計算している。最後にそれぞれの出力を、図右のように結合して全結合層に入力して、交通量の予測値を得る。

3.2. 車載カメラ映像を用いた手法

車載カメラ映像をフレームごとに YOLO[4] に入力して、複数のバウンディングボックスを取得する。そのうちラベルが車であるものの数を車載カメラ映像に映る車両台数の推定値とする。また、バウンディングボックスの高さが車両との距離に比例していると考えて、車両との車間距離を推定する。前方と後方の車載カメラ映像に適用して、それぞれの車両台数と車間距離の推定値を車載カメラ映像からの特徴とする。それを走行している地点の車線数や GPS から得られる速度

と合わせて GRU に入力し、その地点の先の交通量を予測する。

4. 実験結果

4.1. 周囲の交通量データを用いた手法について

実験では、JARTIC[5] で公開されているもののうち、東京駅周辺のおよそ 260 地点の交通量の計測地点を使用した。そのうちランダムに選んだ 70 地点を交通量が未知の地点とし (図 2 の赤いポイント)、さらに 50 地点、10 地点、10 地点に分割し、それぞれ学習用、検証用、テスト用の地点とした。残りの計測地点 (図 2 の青いポイント) をノードとして、計測地点間の接続関係をエッジとするグラフを作成した。具体的には、緯度経度から計測地点間の直線距離を求め、値が 1500m 以内であればそれらは重みが距離のエッジでつながっているとした。交通量データに関しては、2022 年の 9/1~9/30 の 9 時~19 時のデータを 2 時間分ずつ切り出して、合計 3600 個の入力データを取得した。そのうち 9/1~9/20 を学習用に、9/21~9/25 を検証用に、9/26~9/30 をテスト用にそれぞれ分割した。それぞれの正解データは、30 分後の交通量とした。評価指標として、MAPE と RMSE を用いる。比較手法として、提案手法で中間出力を使用しない場合を用いた。また、距離に応じた重み付き平均と CT-Gen によって予測したい地点の交通量をそれぞれ補完した後に STGCN を適用する場合とも比較した。その結果を表 1 に示す。




図 2: 4.1 節での交通量計測地点 (青: ノード, 赤: 予測地点)

表 1: 周囲の交通量データを用いた手法の実験結果

| 手法 | MAPE | RMSE |
|--------------------------|-----------|-----------|
| random | 66.804 | 42.243 |
| weighted average + STGCN | 48.595749 | 24.961840 |
| CT-Gen + STGCN | 50.713236 | 26.399100 |
| 中間出力を使用しない場合 | 50.843533 | 26.683860 |
| 提案手法 | 46.148830 | 26.540976 |

提案手法は MAPE に関してはどの比較手法よりも良い数値を出した一方、RMSE に関してはデータを補完後に STGCN に入力する手法より劣った。しかし交通量を交通状況の把握に用いる際には、実際の交通量が

多い場合に大きな誤差が出ることよりも、実際の交通量が小さい場合に大きな誤差が出るの方が影響が大きくなってしまふことを考えると、RMSE が最も小さい提案手法が最も良い性能の手法である。

4.2. 車載カメラ映像を用いた手法について

都内の計測地点を多く通るように走行ルートを決め、3 日間走行して車載カメラ映像を取得した。車両が計測地点を通る時刻の前後 30 秒の映像を切り取っていくことで合計約 400 地点の入力データを取得し、訓練用、検証用、テスト用に 3:1:1 になるようにランダムに分割した。また、それぞれの正解データは、車両が計測地点を通った時刻の次の計測時刻の交通量とした。学習結果を表 2 に示す。

表 2: 車載カメラ映像を用いた手法の実験結果

| 手法 | MAPE | RMSE |
|--------|---------|--------|
| random | 66.804 | 42.243 |
| 提案手法 | 62.6786 | 30.777 |

MAPE を見ると、提案手法の値とランダムな値を予測値とした場合とあまり差が見られず、交通量をほとんど予測できていないことが分かる。この手法では、交通量を予測するための十分な情報を映像から得られていないと考えられる。

5. 今後の課題

周囲の交通量を用いる場合については、周囲の計測地点との関係性をよりよく利用する手法を考えて予測精度を上げることを課題とする。一方車載カメラ映像を用いた手法に関しては、交通量予測のための特徴抽出の方法を考えると同時に、そもそも車載カメラ映像が交通量予測に適したデータであるかを検証していく必要がある。

謝辞

本論文の研究は一部、トヨタ自動車株式会社との共同研究「CAN と画像の連携による大規模データ活用技術の研究」による。

参考文献

- [1] Bing Yu, Haoteng Yin and Zhanxing Zhu, "Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting," 2017
- [2] Xiuwen Yi, Zhewen Duan, Ting Li, Tianrui Li, Junbo Zhang, and Yu Zheng, "CityTraffic: Modeling Citywide Traffic via Neural Memorization and Generalization Approach," In Proceedings of the 28th ACM International Conference on Information and Knowledge Management (CIKM '19), 2019
- [3] Noshwan Ijaz and Yuehua Wang, "Automatic Steering Angle and Direction Prediction for Autonomous Driving Using Deep Learning," 2021 International Symposium on Computer Science and Intelligent Controls (ISCSIC), 2021
- [4] Joseph Redmon, Santosh Divvala, Ross Girshick and Ali Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
- [5] 公益財団法人 日本道路交通情報センター, 一般道の「断面交通量情報」, <https://www.jartic.or.jp/service/opendata/> (参照: 2022/11/15)