

交差点におけるオクルージョンを考慮した車両の物体追跡手法の研究

八千代エンジニアリング株式会社 正会員 ○堀井 大輔, 菅原 宏明, 菊池 恵和
八千代エンジニアリング株式会社 非会員 大久保 順一, 岡野 将大

1. はじめに

近年, ETC2.0 プローブ情報の活用で代表されるように, 道路交通分野においてもビッグデータを用いた解析の重要性が高まっている. また, 国土交通省では, 単路部における CCTV カメラを用いた AI 解析が行われているほか, 令和3年度以降の全国道路・街路交通情勢調査では, 単路部における人手調査を廃止し, AI 等による自動計測に切り替えることが発表された.

既に単路部では誤差 5%程度で車種別交通量計測が可能な AI システム[1]も存在するが, 交差点部ではオクルージョン (対象物体の一部又は全てが遮蔽される状態) が発生しやすく, 交通量の自動計測の難易度は高いとされている. 一方, 道路交通分野における情報のデジタル化及び, 調査の省力化の潮流から, 交差点部における AI 等を用いた自動計測化への期待は高い.

本研究では, オクルージョン対処技術を複合的に適用した手法を提案し, 交差点における方向別交通量の自動計測の精度向上を試みた.

2. 既往研究

複数の物体を同時に追跡する技術である Multiple Object Tracking (MOT) は, 1980 年代後半に提案され, 近年では深層学習を取り入れることで精度を高めた手法も多く提案されている. MOT の代表的な手法である SORT[2]は, 物体検出に AI モデルを使用し, フレーム間の物体の関連付けにはカルマンフィルタ (KF) を用いており, 追跡中の物体の予測状態と検出された矩形の IoU を基に, フレーム間のマッチングを行っている. オクルージョンへの対応として, カルマンフィルタの予測状態を観測状態として扱う手法が提示されているが, 長時間の補間は難しい. DeepSORT [3]は SORT のロジックをベースに, 物体の見た目を考慮した MOT である. 検出された矩形の特徴量ベクトルを CNN (畳み込みニューラルネットワーク) から求め, その類似度を基にマッチングを行う. このような手法は, 長時間のオクルージョン後のマッチングも可能とするが, オクルージョン前後で物体の見た目が異なるとマッチングされ

キーワード AI, 深層学習, MOT, 交差点, 交通量, オクルージョン

連絡先 〒111-8648 東京都台東区浅草橋 5-20-8 CS タワー 3F 技術創発研究所 TEL 03-5822-6570




図1 部分的及び, 完全なオクルージョンのイメージ



図2 BYTE の適用例 (奥側の車両の軌跡が検出信頼度の低い矩形によって補間され, 軌跡の欠損が防止されている状況)

ない等の課題もある. なお, 特徴量ベクトルの類似度を基にしたマッチング手法は, 多地点における車両追跡の研究[4]にも用いられている.

部分的なオクルージョンに対しては, 矩形の検出信頼度の閾値を下げることで検出漏れを回避できるが, 誤検知が増加する. この課題に対して Zhang ら[5]は BYTE アルゴリズムを提案し, 人流の MOT で高い精度を実現した. BYTE は検出信頼度の閾値を 2 種類設定し, 信頼度の低い矩形を追跡軌跡の補間にのみ使用することで, 誤検出の発生を抑えつつ, 検出漏れの発生を防ぐ.

3. 本研究

本研究では, オクルージョンを部分的及び, 完全な状況 (図1) に分けて考え, それぞれに対して, 有効と考えられる対処手法を複合的に適用することで, 交差点における方向別交通量計測の精度向上を試みた. なお, フレーム間の物体のマッチングには SORT[2]の手法を基本とし, 通過台数カウントには, 事前に定義した軌跡情報と, 物体追跡の結果をマッチングする Trajectory-based な手法を採用した.

3.1 部分的なオクルージョン

前述の BYTE アルゴリズム[4]を適用し, 部分的なオクルージョンにおける未検出を防止した (図2).

3. 2 完全なオクルージョン (短時間)

完全なオクルージョンが短時間 (0.1 秒未満) の場合、追跡軌跡のカルマンフィルタによる予測状態を検出された矩形として軌跡を補間した。

3. 3 完全なオクルージョン (長時間)

完全なオクルージョンが長時間 (0.1 秒以上) 発生した場合、矩形の特徴量ベクトルを CNN から求め、オクルージョン前後の追跡軌跡と検出矩形の類似度を判定した。また、オクルージョン前後で複数の追跡軌跡が発生した場合、追跡軌跡を構成する矩形の特徴量ベクトルを用いて、追跡軌跡間の類似度の判定を行い、刹那的な矩形の見目の違いに対処した。結合後に軌跡の欠損があるフレームについては、矩形を線形補間した。

4. 実験内容

令和4年1月に東京都中央区のオクルージョンが発生しやすい交差点 (流入部片側4車線, 流出部3車線) において撮影した映像 (図3) に対して、3. に示した手法の有効性の検証を行った。検証用システムの構築には、Intel 社の OpenVINO ツールキットを使用し、AI モデルは同社の学習済みモデルを使用した。検出器は MobileNetV2 をバックボーンとした SSD (vehicle-detection-0202)、矩形の特徴量ベクトルの抽出には Omni-Scale Network (vehicle-reid-0001) を採用した。

5. 結果・考察

撮影動画5分間における精度検証の結果を表1に示す。カウント対象の軌跡は、図3の手前側に流出する直進車、左折車及び、手前側から流入する右折車とした。表1中の BYTE, KF, CNN は3.1~3.3の手法をそれぞれ適用したモデル、B+K+C は3.1~3.3全てを適用したモデルである。評価指標には Precision (真陽性/モデルがカウントした台数)、Recall (真陽性/実際通過した台数) 及び、F1 値 (Precision と Recall の調和平均) を採用した。直進と右左折で車両の挙動の特徴が異なるため、カウント結果は分けて整理した。

直線及び、右左折の両方において、B+K+C モデルの精度が最も高く (直線: F1 値 = 0.94, 右左折: F1 = 0.88)、本研究の提案手法の有効性が示せた。なお、全てのモデルにおいて直線部の精度が高い理由は、追跡軌跡を形成する矩形の数が少ない場合でもカウントが可能となるような通過台数カウント手法 (Trajectory-based) を用いたためである。



図3 実験対象の交差点

表1 精度検証結果 (太文字: 各指標で最も良い値)

| | | BYTE | KF | CNN | B+K+C |
|-----|-----------|----------------------|------------------------|------------------------|------------------------|
| 直進 | Precision | 0.92 (79/86) | 0.94 (79/84) | 0.99 (69/70) | 0.94 (82/87) |
| | Recall | 0.92 (79/86) | 0.92 (79/86) | 0.80 (69/86) | 0.95 (82/86) |
| | F1 | 0.92 | 0.93 | 0.88 | 0.94 |
| 右左折 | Precision | 1.00 (9/9) | 1.00 (10/10) | 0.93 (14/15) | 0.94 (15/16) |
| | Recall | 0.50 (9/18) | 0.56 (10/18) | 0.78 (14/18) | 0.83 (15/18) |
| | F1 | 0.67 | 0.72 | 0.85 | 0.88 |

6. 最後に

本研究では、交差点におけるオクルージョンを考慮した車両のトラッキング手法を提案し、その有効性を示した。今回の結果から、カメラを複数台用いることで、交差点内全ての軌跡を捕捉が可能であることが示唆された。交差点内の車両の軌跡情報と、他の情報 (e.g., 歩行者) を組み合わせることで、従来の人手計測では難しかった新しい分析が今後可能になると考える。

なお、本手法では、車両がオクルージョンによって低信頼度の矩形しか検知しない場合、追跡軌跡を形成することはできないため、今後は複数のカメラを同期させた手法の検証等、それら課題にも取り組んでいきたい。また、今回の AI モデルは既存の学習済みモデルを採用したため、日本の車両に最適化した AI モデルを作成することで、更なる検出精度の向上が期待される。

参考文献

- [1] 小篠 耕平, 菅原 宏明, 藤井 純一郎, 大久保 順一, 岡野 将大: 深層学習による路側撮影動画からの車種別交通量計測手法の提案およびロバスト性の検証第, 18 回 ITS シンポジウム, 2020.
- [2] A. Bewley, Z. Ge, L. Ott, F. Ramos, and B. Upcroft, "Simple Online and Realtime Tracking," 2016 IEEE International Conference on Image Processing (ICIP)
- [3] N. Wojke, A. Bewley, and D. Paulus, "Simple Online and Realtime Tracking with a Deep Association Metric," arXiv:1703.07402 [cs], 2017.
- [4] 大久保 順一, 小篠 耕平, 岡野 将大, 菅原 宏明. 車両追跡における深層学習の応用, 2021 年度人工知能学会全国大会 (第35回), 2021
- [5] Y. Zhang et al., "ByteTrack: Multi-Object Tracking by Associating Every Detection Box," arXiv:2110.06864 [cs], 2021