

カメラ画像と物体検出アルゴリズムを用いた交通量調査に関する基礎的研究

A Basic study on traffic volume survey using camera images and object detection algorithms

室蘭工業大学 建築社会基盤系学科 ○学生員 瀧本康太(Kota Takimoto)
室蘭工業大学大学院 工学研究科 学生員 高田光太(Kota Takata)
室蘭工業大学大学院 工学研究科 正会員 有村幹治(Mikiharu Arimura)

1. はじめに

我が国では、平常時・災害時を問わない道路の常時観測を目指し、ICTを活用した新道路交通調査体系の構築が進められている。令和三年度における国土交通省の検討会¹⁾では、目視による従来の人手観測を廃止し、AIによる映像解析やトラフィックカウンターに置き換えていく新交通流調査の方針が示された。国外の研究においても深層学習を交通分野に応用する試みは広く行われ、多くの人々が関心を寄せている。

しかし、現在我が国で行われているAIによる交通流解析に関する報告²⁾では、夜間や車種別交通量の精度の低さが指摘されており、供用に至るにはまだ精度不足といえる。そこで、本研究では我が国におけるAIを活用した交通流調査方法の有用性を、現地での人手観測との比較から検証するとともに、その課題点について整理することを目的とする。

2. 既存研究と本研究の位置づけ

交通量観測に物体検出アルゴリズムを使用した先行研究としてはM. FACHRIEら³⁾の研究がある。観測地点に線の描画という形で計測区間を設け、計測線の下流側と、検知した車両の中心との距離を閾値として定義した。この閾値が一定以下となった時、その車両が計測区間を越えたものとして測定するという。従来の追跡機能に頼らない方法で車両数の計測を行った。結果として、4種類の車両に対し一一致度97.72%の高精度での測定を実現するに至った。

Z. KADIMら⁴⁾は、複雑な交通が想定される高速道路環境を対象とした。同一の道路に対し四つの異なる映像角度を用意し、どの角度が適切であるかを検討した。その結果、最高で91.5%の分類精度を得るに至り、リアルタイムでの解析が可能ほどの処理時間に削減した。

Q. Mengら⁵⁾は、フレーム間における車両の軌道が滑らかでない問題に対応すべく、最小二乗法に基づく軌道最適化アルゴリズムを提案した。このアルゴリズムは濃霧、雨天、夜間など異なる気象条件の基、検証と改良が重ねられ、最終的に93%以上の計測精度を得るに至った。

このように、海外では分析能力向上を目的とした様々な研究事例があり、高精度の解析結果を得た研究も存在する。本研究では基礎的な検討を行うため教師信号として、既に構築済みであるベトナムでの車両学習データを用いる。

3. 使用した映像解析アルゴリズムの概要

本研究における交通量調査は、映像内の車両の検出(detection)その車両の測定(counting)という二段階のプロセスからなる。この解析に用いたのはYolov4というアルゴリズムである。作者はA. BOCHKOVSKらであり、前身となったJ. REDMON作成のYolov3を改良する形で公表された。これらアルゴリズムの概要を以下に示す。

3.1 Yolov4⁶⁾

本アルゴリズムは映像内から物体を検出する役割を担う。学習対象と類似した物体を映像内から認識した際、その物体の輪郭を囲うような長方形を描画し、車両を計測の対象として認識することを可能とする。

3.2 deepsort⁷⁾

本アルゴリズムは車両の計測・測定を担う。前述したYolov4内において、検出された物体の動きに対しトラッキング(物体追跡)を行い各物体にIDを割り振ることでその挙動を管理する。

4. 分析対象となる区間の概要

対象区間は2020年に実施された札幌新川IC社会実験での定点映像のうち、交通流の進行方向が直線的であり、検出が比較的容易であることが想定される1定点とする。映像内における交通流をA.B.Cの三つに分け、各領域における総交通量を測定した。

対象時間は記録が存在する9月30日と10月14日の二日において、7時~19時までの約12時間分を対象とした。9月30日の10時40分~10時60分の20分間は映像の欠損のため除いた。

現地での人手計測による交通流調査の記録が10分刻みであったため、本研究における解析も10分ごとの出力とした。

5. 交通量計測の手法

5.1 カメラ画像の解析方法

映像内の二点を指定し、これを結ぶ線を計測線とする。車両が認識された際、その車両にはIDが割り振られ、輪郭として長方形が描画される。この長方形の中心の座標がこの計測線の座標を越え、なおかつ車両のIDが新規のものであるとき各車両が計測線を通じたときとみなし、通過台数としてカウントするようプログラムを設定した。

また、処理時間の削減を目的として、動画のフレームレートを半分にした動画でも測定を行った結果、計測精度を維持し、結果として分析に必要な時間が半分に削減された。

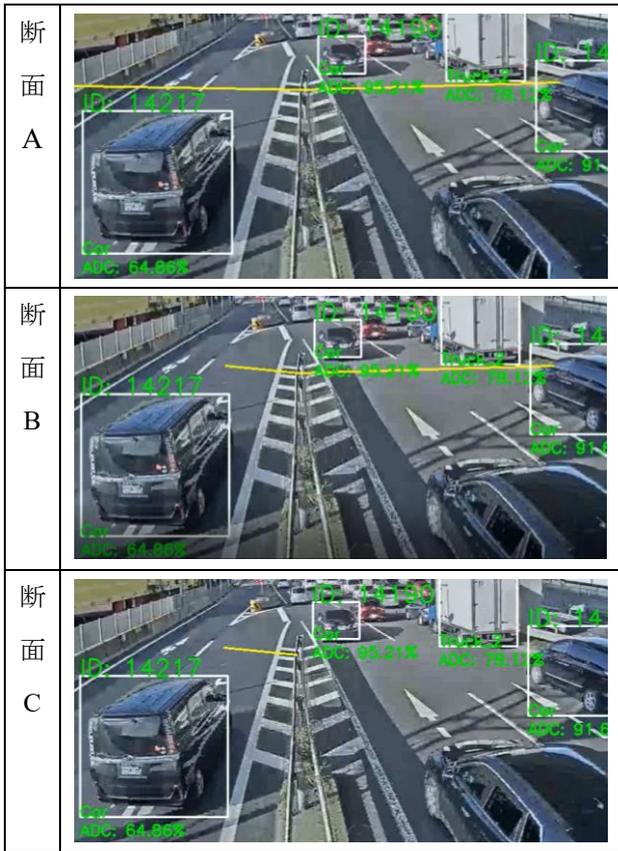


図-1.各断面における解析の様子

5.2 測定精度の評価手法

X 軸を現地による人手計測.Y 軸を Yolov4 による AI 解析として、各断面ごとの総交通量の時間推移を散布図の形で可視化する(図-2)。この時、X と Y の値が一致する時、人手計測と AI 解析の値が一致する理論値のプロットとなる。測定結果の精度を評価する指標として、決定係数、平均二乗誤差平方根(以下、RMSE: Root Mean Squared Error)を使用するが、参考のため、理論値となる関数 $y=x$ に対する各プロットの差に関して、RMSE と同様の方法で指標を算出する。これを F-RMSE (Fact-RMSE) と呼称する。また、車種分類は乗用車と乗用車以外の四輪車、全体の合計の3つとした。

6. 結果とその考察

6.1 解析結果と人出計算の比較

比較結果を示す(図-2, 表-1)。図-2 中のオレンジ線は理論値の $y=x$ 青線は各プロットに対する回帰線を現したものである。また、時間的推移の可視化のため、時間の経過とともに各プロットの色が青から赤に移するように着色した。

図-2, 表-1 から、乗用車は Yolov4 側の過計測が目立つものの、大方予想通りの分類精度を得るに至った。その一方、乗用車以外の大型車両に関しては Yolov4 側の見逃しが著しく、分類精度も決して高いとは言えない。全体合計においては、各プロット値が理論値 $y=x$ の周辺に点在しているが、これは単に上記二つの誤差が打ち消し合っただけの可能性がある。

表-1 得られた各パラメータ

	断面	R2	RMSE	F-RMSE
乗用車	A	0.726	59.188	70.207
	B	0.575	48.255	52.478
	C	0.690	13.092	22.422
乗用車以外	A	0.147	50.519	48.429
	B	0.049	37.123	39.289
	C	0.303	12.233	17.820
全体合計	A	0.693	28.441	71.717
	B	0.463	29.354	59.635
	C	0.693	9.313	24.156

6.2 誤差に関する調査

図-2における分布の中で、誤差が顕著であるいくつかの値に注目した。これらの値を記録した各時間帯における解析内容について確認したところ、具体的な誤差の要因がいくつか明らかになった。大きく分けて「車両の種類」によるものと、「誤差交通・撮影状況」によるものがある。

「車両の種類」による要因については、比較的大きな乗用車が大型車両として検出されること、外形が長方形とかけ離れた車両が検出できないこと、大型車両の検出が遅く、大きすぎて計測できないこと、レッカー車に積載された乗用車も検出されること、貨物車の運転席部分を乗用車として検出することなどが挙げられる。

「誤差交通・撮影状況」による要因としては、日にちや時間経過により映像の角度に誤差が生じること、大型車両の陰に隠れた交通流が検出されないこと、暗くなってきた時の検出精度が低下すること、速度が速い車両の計測が間に合わないこと停止している車が稀に複数回計測されることが挙げられる。

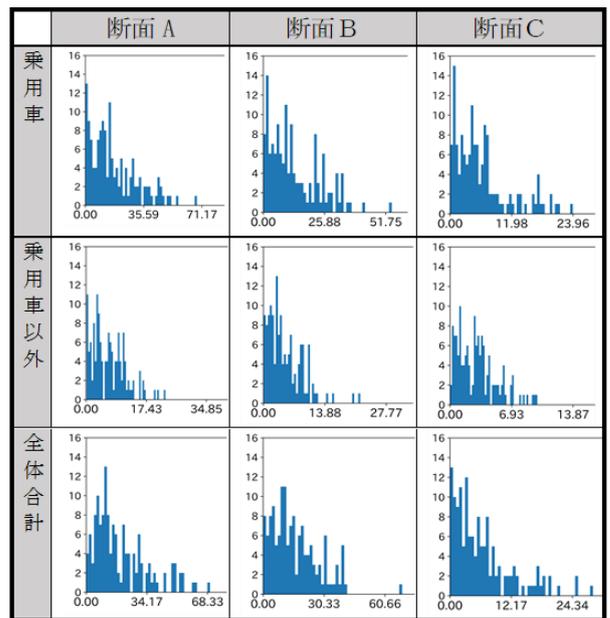


図-3 絶対値を取った誤差の分布

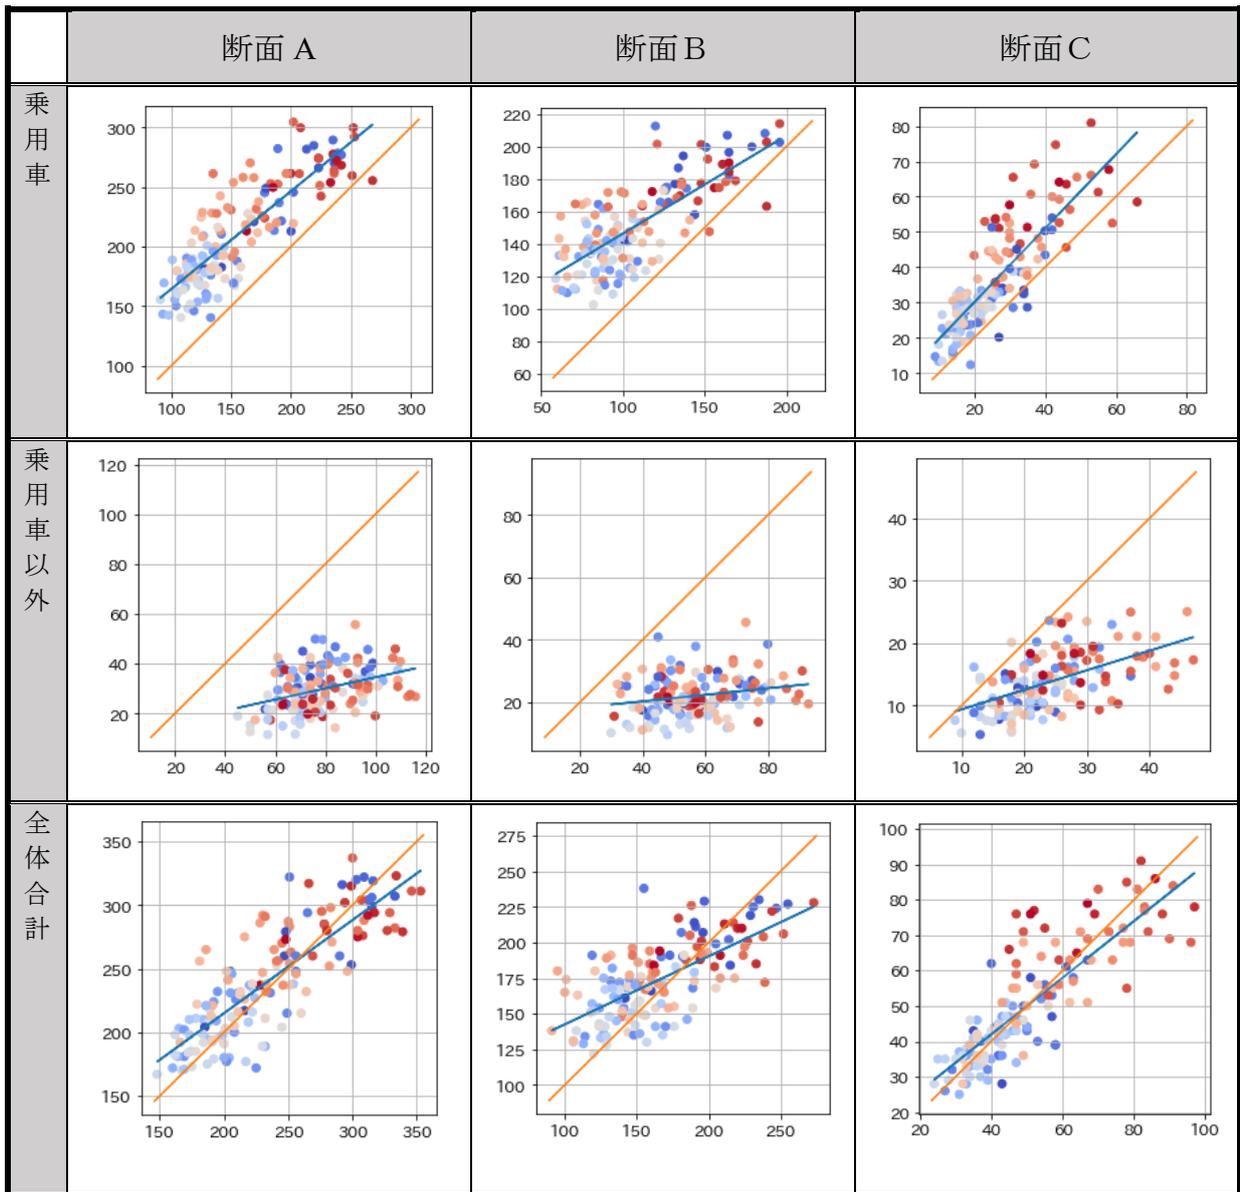


図-2 各断面における10分ごとの総交通量比較
 X軸：現地による人手計測 Y軸：Yolov4によるAI解析 サンプル数=142



表-2 誤差の最大値と発生日時の対応

断面	乗用車			乗用車以外			全体合計		
	A	B	C	A	B	C	A	B	C
AME	68.13	54.318	23.901	22.99	21.878	9.841	69.668	69.221	28.419
日時	①10/14 16:50~17:00	②9/30 8:10~8:20	③9/30 18:00~18:10	④9/30 15:40~15:50	④9/30 15:40~15:50	⑤10/14 9:10~9:20	②9/30 8:10~8:20	②9/30 8:10~8:20	③9/30 18:00~18:10

6.2 誤差に関する考察

車種別による誤差の傾向を調査するため、各断面、各車種に対して絶対値をとった最大の誤差（以下、AME：Absolute Maximum Error）が、どの時間帯のものであるかを調べた(図-3、表-2)。AMEが発生した日時は共通している場合がある。乗用車と全体合計についてAMEが発生した時間帯はB,C断面において共通しており、乗用車以外と全体合計において、AMEが発生した日時はA,C断面において共通している。しかし乗用車と乗用以外の間においては、AMEにおける発生日時の共通は見取れなかった。これらから、大きな誤差の発生する要因は、車種によって個別か、与えうる影響の程度が異なるものと考えられる。

「車両の種類」に分類される誤差の多くは、学習させた車両データに起因するものと考えられる。特に重機や大型貨物は、外形が長方形からかけ離れた車両が多く、これが乗用車以外の四輪車の著しい見逃しに繋がっていたと考えられる。「交通・撮影状況」の誤差に関しては、カメラの設置時の位置によって解決が可能なものが多いと考えられるため、同じような誤差を生まないために、念入りな下準備が今後求められる。

7. まとめ

本研究では、日本国内における映像の自動解析による交通量調査の有用性の検討を目的とした。簡易的な交通流において、機械学習アルゴリズムによる測定と現地での人出測定との比較を行った結果、カメラの設置場所、事前学習データなど、AIによる交通量調査を効果的に行うための留意点について明らかとなった。また本研究では対象とはしなかったが、夜間・ライトの影響・冬季などの状況において、どのようなコンディションを確保する必要があるのかなど、他の課題点も多く存在する。

しかし、人手測定と比較したときの低価格性や安定性、年中の運用が可能であることなどAIによる交通調査が非常に有用であることは明らかである。今後も実用的運用へ向け更なる研究を重ねていきたい。

参考文献

- 1) 道路：ICTを活用した新道路交通調査体系検討会 - 国土交通省 (mlit.go.jp)
<https://www.mlit.go.jp/road/ir/ir-council/ict/index.html>
- 2) CCTVカメラ(AI解析)の精度に関する報告
<https://www.mlit.go.jp/road/ir/ircouncil/ict/pdf05/02.pdf>
- 3) Muhammad Fachrie : A Simple Vehicle Counting System Using Deep Learning with YOLOv3 Model
https://www.researchgate.net/publication/341075968_A_Simple_Vehicle_Counting_System_Using_Deep_Learning_with_YOLOv3_Model
- 4) Zulaikha Kadim . Khairunnisa Mohd. Johari. Den Fairol. Yuen Shang Li and Hock Woon Hon: Real-time vehicle counting in complex scene for traffic flow estimation using multi-level

convolutional neural network

<https://www.accentjournals.org/paperInfo.php?journalPaperId=1273>

- 5) Qiao Meng . Huansheng Song. Yu'an Zhang . Xiangqing Zhang .Gang Li.and Yanni Yang : Video-Based Vehicle Counting for Expressway: A Novel Approach Based on Vehicle Detection and Correlation-Matched Tracking Using Image Data from PTZ Cameras
<https://www.hindawi.com/journals/mpe/2020/1969408/>
- 6) Alexey Bochkovskiy. Chien-Yao Wang. Hong-Yuan Mark Liao : YOLOv4: Optimal Speed and Accuracy of ObjectDetection
<https://arxiv.org/abs/2004.10934>
- 7) Nicolai Wojke. Alex Bewley. Dietrich Paulus: Simple Online and Realtime Tracking with a Deep Association Metric
<https://arxiv.org/abs/1703.07402>