

深層学習を活用した 多様な車種別交通量計測システムの開発

渡辺 啓太¹・柳沼 秀樹²・寺部 慎太郎³・田中 皓介⁴・康 楠⁵

¹学生非会員 東京理科大学大学院 理工学研究科土木工学専攻 (〒278-8510 千葉県野田市山崎2641)
E-mail:7618538@ed.tus.ac.jp

²正会員 東京理科大学 理工学部土木工学科 (〒278-8510 千葉県野田市山崎2641)
E-mail: yaginuma@rs.noda.tus.ac.jp

³正会員 東京理科大学 理工学部土木工学科 (〒278-8510 千葉県野田市山崎2641)
E-mail: terabe@rs.tus.ac.jp

⁴正会員 東京理科大学嘱託助教 理工学部土木工学科 (〒278-8510 千葉県野田市山崎2641)
E-mail:tanaka.k@rs.tus.ac.jp

⁵正会員 東京理科大学嘱託助教 理工学部土木工学科 (〒278-8510 千葉県野田市山崎2641)
E-mail:kangnan@rs.tus.ac.jp

近年、深層学習などの機械学習理論の発展を背景に、カメラ映像から自動で交通量を計測することが可能である。カメラを設置すれば、必要な期間のデータを人力でのカウントよりも精度良く安価に入手であるため、より一層、施策の検討や評価での利用が想定される。しかしながら、車種などについて、既往データとの整合は取られていない。本研究では、深層学習をベースにカメラ映像のみから多様な車種に対応した交通量計測を実現するシステムを開発する。具体的には、検出精度と処理速度に優れた物体検出モデルであるYOLOを用いて、道路交通センサスの車種分類に対応した車両検出器を構築する。また、構築した検出器にファインチューニングを適用してタクシーやバスなどの様々な車種に対応できることを検証する。くわえて、データの入力条件と検出精度の検証から学習の効率化についても言及し、それらの結果から車種別交通量計測の可能性を示したい。

Key Words : *deep learning, traffic measurement system, image processing, YOLO*

1. はじめに

優良な道路行政サービスを提供するためには、その基礎的な情報として、道路の利用実態の把握が重要である。そのためには、運用コストが低くかつ精度の高い常時交通量の計測が必須となる。

現在、自動車の交通量調査には、調査員の目視による測定方法、ループコイルや超音波による機械的な測定方法がある。しかしながら、これらの方法は作業コストや導入・運用コストが高いという問題がある。また、ナンバープレート調査による計測も検討されているが、昨今のプライバシーに対する意識の高さから、調査に対する過剰な反感が危惧される。近年、機械学習理論とコンピュータ性能の発展を背景に、カメラ映像から自動で交通量を計測することが可能となりつつある。カメラ映像による計測が実現することにより、一定期間の観測デー

タを人力でのカウントで行うよりも高精度かつ安価に入手可能となる、これにより、質の高い交通量データが様々な施策の検討や評価により一層活用が期待される。

これまでに画像処理や深層学習を利用して、画像から精度良く車両検出を行う研究は数多く存在する。しかしながら、既存の統計調査である道路交通センサスと車種等のデータの整合が取れている車両検出器の研究は未だない状況にある。既存データとの整合性する検出器の開発は、これまでの調査との関連性・連続性を考慮すると必須であると思われる。

以上を踏まえ、本研究では、深層学習を援用してカメラ映像のみから多様な車種に対応した交通量計測を実現するシステムを開発する。具体的には、検出精度と検出速度に優れた物体検出モデルであるYOLO (You Only Look Once)²⁾³⁾を用いて、道路交通センサスの車種分類に対応した車両検出器を構築する。

2. 既往研究の整理と本研究の位置付け

(1) 画像処理による車両検出に関する研究の整理

松田ら¹⁾は画像特徴量の一つである HOG (histogram of oriented gradients) と SVM (support vector machine) を用いた交通流量計測システムを開発している。また、背景差分法・YOLOの3つの手法で性能比較を実施して、各手法の特徴を明らかにした。該当手法では、検出精度では YOLO にわずかに劣るものの、計算コストの低さと、夜間の観測等の環境条件による検出精度の低下が少ない点で実用性が見込めると述べている。課題としては車種別の計測が行えないことを挙げている。

(2) 深層学習を用いた複数種の車両分類に関する研究の整理

金野²⁾らは、東南アジア特有の交通モードである LAMAT (Locally Adapted, Modified, and Advanced Transport) 利用実態を明瞭にするため、R-CNN (Region with CNN) の方法論を基にした複数分類可能な車両検出器の構築を行った。具体的には、カスケード分類器と CNN の双方を用いて、bicycle, motorcycle, car, jeepney, taxi, tricycle, truck の7種の検出を試み、各200枚の画像データを学習に使用して、Google Earth 画像と現地撮影画像に対して検出結果を確認した。Google Earth による検出結果は、非車体の検出の発生は見受けられなかったが、未検出の車両も約半数ほど生じた。現地撮影画像では車両検出率は高いが、非車体の誤検出が多いという結果となった。また欠損検出が行われる場合も多いことが確認できた。

(3) 本研究の位置付け

道路行政の指針となる重要な調査の一つとして道路交通センサス³⁾がある。この調査は、全国の道路と道路利用の実態を捉えて、将来の道路整備の方向を明らかにするために、全国の道路状況、交通量、旅行速度、自動車運行の出発地・目的地、運行目的等を明らかにするものである。しかしながら、5年に1度かつ特定日を対象とした調査であるため、必ずしも道路行政ニーズに合致したデータが取得できるとは限らないという課題がある。この調査をカメラ映像で実施することが可能となれば、半永久的かつ自動的な計測が可能となるため、現場のニーズに適したデータを入手しやすくなる。これにより、実際の道路状況をより一層反映した政策の実施が期待される。道路交通センサスに対応した車両検出器の開発は意義があると言えよう。

既往研究として検出速度が早いモデルや、複数車種の分類が可能なモデルはあるが、我が国の主要な交通量データに対応した複数分類可能な車両検出モデルは未だ存

在しない。そこで本研究では、道路交通センサスの中でも一般交通量調査に焦点を当てて、その車両区分に対応した車両検出器の開発し、カメラ映像のみによる一般交通量調査の実用可能性の検討を目的とする。また近年、物体検出モデルに関する研究が盛んであり、SSD⁴⁾や Faster R-CNN⁵⁾など、既往研究が数多く発表されている。その中でも、交通量計測を行う際の実用性を考慮して、検出速度に優れ、検出率も高いモデルである YOLO を採用する。YOLO を援用した交通量計測の研究はまだ進んでいないため、本論では本検出器の適用性について明らかにしていく。

3. YOLO による車両検出モデルの構築

(1) 車種の分類

道路交通センサスの一般交通量調査での自動車類の分類は、ナンバープレートの形状・塗色・分類番号によるのを原則として、乗用車・小型貨物車・バス・普通貨物車の4車種に分けられている(表-1)。本研究ではこの4車種の検出を行っていく。

(2) データセットの概要

車両検出モデルを構築するにあたり、外見的な特徴が認識しやすい推測されるバス車両から検出器の構築を行うこととする。データセットとして、スマートフォンで撮影した 640×850 画素の写真 180 枚を回転・座標移動・コントラストの変更・左右反転をランダムに行い 40 倍に拡大した 7200 枚を用意した。そのうち9割を学習用、1割をテスト用とする。また、YOLO による学習では、バウンディングボックスと呼ばれる長方形の矩形領域で検出するため、各画像に画像内の物体の位置座標をラベル付けするアノテーション作業を行った。

表-1 車種分類

種別	内容
乗用車	ナンバー5 (黄と黒のプレート) ナンバー3, 8 (小型プレート) ナンバー3, 5, 7
小型貨物車	ナンバー4 (黄と黒のプレート) ナンバー3, 6 (小型プレート) ナンバー4, 6
バス	ナンバー2
普通貨物車	ナンバー1 ナンバー8, 9, 0



図-1 データセット例

(3) YOLO モデルの構築

本研究では YOLO モデルの中で最新のものである YOLOv3 を援用する。モデルを構築するにあたり、フレームワークとして darknet を使用する。また、YOLO での学習の際には、学習パラメータの初期重みを適切に設定する必要がある。この値は既往研究で公開されているものを利用する。

4. YOLO による車両検出モデルの構築

(1) 精度評価指標

YOLO による物体検出の精度評価の指標として IoU (Intersection over Union) を用いる。これはモデルが検出した領域と画像内物体との重なり具合の割合を表す値であり、 $0 \leq IoU \leq 1$ の範囲をとり、1 に近いほど高い精度で検出できていることを示す。実際に物体があるところをモデルが検出した面積である TP(True Positive)、物体がないところをモデルが検出しなかった面積 TN(True Negative)、実際に物体があるところを検出できなかった面積 FN(False Negative) で表される。

$$IoU = \frac{TP}{TP + FP + FN} \quad (1)$$

(2) 学習度合評価指標

モデルの学習度合の評価指標として損失関数の平均 (平均損失) を用いる。この値は 0 に近くほど学習が良好であることを示す。既往研究では、3.0 以下であることが望ましいとしている。

(3) モデル学習の結果

今回のモデルでは 5000~25000 回の計算回数で学習を行った。今回のデータセットでは 21000 回の計算回数で最も学習が進み、平均損失は 3.0 であった。この計算回数周辺でテストデータでの検出精度も高いということが確認できた (図-2)。

(4) 検出精度の検証

学習させたモデルで車両検出を行う。検出結果を確認するために、新たに 10 枚のバス車両が映った画像を用意した (図-3)。検出の際の閾値は 50%以上とした。検出結果を表-2 に示す。検出結果として、最も損失平均が低く学習が進んだモデルが検出結果もまた良好であった。さらに、学習回数と検出・誤検出の関係性をみる。初めは、学習回数を重ねるほど検出精度が上昇するが、一定の検出精度を越えると誤検出が上昇する。その後、検出精度が上昇して誤検出が減少する。そして、最後には検

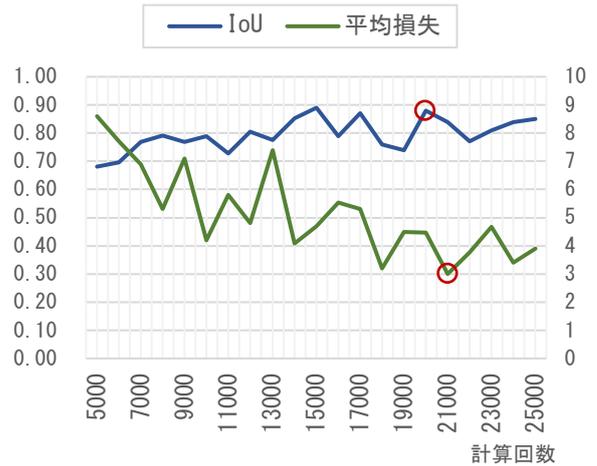


図-2 計算回数による精度と学習度合の変化



図-3 検出結果確認用画像データ

表-2 学習回数と検出精度

学習回数(回)	検出枚数(枚)	誤検出枚数(枚)	学習回数(回)	検出枚数(枚)	誤検出枚数(枚)
5000	2	0	16000	7	3
6000	4	0	17000	7	2
7000	3	0	18000	8	2
8000	5	1	19000	7	1
9000	3	0	20000	8	0
10000	3	1	21000	10	0
11000	1	0	22000	6	0
12000	5	1	23000	8	1
13000	6	2	24000	9	1
14000	5	1	25000	8	1
15000	9	2			

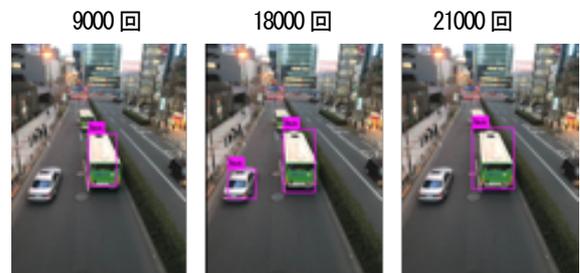


図-4 学習回数による検出精度の比較

出精度が減少する傾向が確認された。図-4 に学習回数の異なるモデルでの同一画像の検出結果からこの現象が見られた例を示す。

(5) 考察

今回構築したモデルはバス車両のみの検出ではあるが、漏れや誤検出なく検出することができた。(表-2) この結果から、YOLO の車両検出器としての適応性は極めて高いと考えられる。また、高精度の検出には適切な学習回数が重要であることが示された。適切な学習回数の見極めには平均損失の値が密接に関係していることが示唆される。

実用性を考慮した検出速度に関して、本モデルでは検出速度は21fpsであった。松田¹⁾らのHOG特徴とSVMを用いた画像処理による手法が24~26fpsであることを踏まえると、リアルタイムとまでは言えないが、十分に実用的な処理速度が保たれていると考えられる。

5. まとめと今後の課題

本研究では、交通センサスの車種データに対応した検出器としてのYOLOの適用性について明らかにした。検出精度は良好であり、車種検出に対しても有効な方法論であることを確認した。また、学習性能についても若干の検証を行い、適切な計算回数で得られたモデルを利用することが望ましい。

今後の課題として、今回の結果から得た知見に基づき、残りの3車種を検出することが挙げられる。具体的には、本研究で構築したモデルを転移学習することによって、効率的な学習が可能となると考えられる。また、日照や天候などの環境条件を考慮した学習が必要となる。

参考文献

1) 松田 宏文, 蒔苗 耕司: HOG特徴とSVMを用いた交通流量

計測システムの開発と評価, 土木学会論文集F3(土木情報学), Vol. 73, No. 2, I_347-I_355, 2017.

- 2) Redmon, J. and Farhadi, A.: YOLO9000: Better, Faster, Stronger, in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017.
- 3) Redmon, J. and Farhadi, A YOLOv3: An Incremental Improvement, arXiv:1804.02767, 2018
- 4) 金野 貴紘, 荒井 勇輝, 屋井 鉄雄: R-CNNによる途上国を対象とした車両検出方法に関する研究, 土木学会論文集D3(土木計画学), Vol.74, No.3, 193-202, 2018.
- 5) 道路交通センサスについて: http://www.mlit.go.jp/kisha/kisha05/06/060901_2/02.pdf, 最終閲覧 2019.9
- 6) 一般交通量調査について: <https://www.mlit.go.jp/road/census/h22-1/data/kasyorep.pdf>, 最終閲覧 2019.9
- 7) Liu, W. and Anguelov, D, SSD: Single Shot MultiBox Detector, arXiv:1512.02325v5, 2016
- 8) Ren, S. and He, K, Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, arXiv:1506.01497v3, 2016
- 9) 鈴木一史, 中村英樹: 交通流解析のためのビデオ画像処理システム TrafficAnalyzerの開発と性能検証, 土木学会論文集D, Vol. 62, No. 3, pp. 276-287, 2006.
- 10) 荒井 勇輝, 屋井 鉄雄: 深層学習による車両検出ツールを用いた tricycle の分布把握に関する研究, 第 58 回土木計画学研究発表会・講演集 No.48, CD-ROM, 2018.
安藤 正幸, 形屋 陽一郎: ディープラーニングを活用した OD 交通量と経路調査方法の基礎研究, 土木計画学研究・講演集, No.212, CD-ROM, 2018.

(2019.10.4 受付)

DEVELOPMENT OF TRAFFIC MEASUREMENT SYSTEM FOR VARIOUS TYPES OF VEHICLES USING DEEP LEARNING

Keita WATANABE, Hideki YAGINUMA, Shintaro TERABE,
Nan KANG and Kosuke TANAKA

Recently, the development of deep learning and machine learning has made it possible to measure traffic volume from camera images. By installing and measuring the camera, it becomes easier to acquire data than manual measurement. However, in previous studies, vehicle types did not match existing traffic data. In this study, we will use YOLO, which is an object detection model with excellent detection accuracy and processing speed, to construct a vehicle detector that corresponds to the vehicle classification of road traffic census. In addition, apply transfer learning to the built detectors to make sure they can be used for taxis and buses. In addition, we explain the efficiency of learning by verifying input conditions and detection accuracy, and show the possibility of measuring traffic volume by automobile types from these results.