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

小篠 耕平[*1]　菅原 宏明[*1]　藤井 純一郎[*1]　大久保 順一[*1]　岡野 将大[*1]
八千代エンジニヤリング株式会社[*1]

近年，道路交通量を自動で計測する方法として設置済みの監視用カメラ等の画像から交通量を読み取るシステムが開発されている．しかし，これらのシステムは高所からの撮影画像を想定しているものが多く，機材設置の制約条件により任意の場所や多地点での調査が難しい．

本研究では，入手・設置が容易な既存の機材で撮影した動画から，深層学習を用いた画像解析による交通量計測手法を実装した交通量自動計測システム TRAVIC を開発し，実際に複数地点で撮影した動画に適用して車種別交通量を計測した．適用結果については目視による計測結果と比較を行い提案手法のロバスト性を検証した．

Proposal of traffic volume measurement method by vehicle type from roadside video by deep learning and verification of robustness

Kohei Ozasa[*1]　Hiroaki Sugawara[*1]　Junichiro Fujii[*1]　Junichi Okubo[*1]　Masahiro Okano[*1]
Yachiyo Engineering Co., Ltd.[*1]

In recent years, as a method for automatically measuring road traffic volume, a system for reading traffic volume from images such as an installed surveillance camera has been developed. However, many of these systems assume images taken from high places, and it is difficult to investigate at any location or at multiple points due to the constraints of equipment installation.

In this research, we proposed a traffic volume measurement method by image analysis using deep learning from videos taken with equipment that is easy to obtain and install.

And applied it to videos actually taken at multiple points for traffic by vehicle type.　The results were compared with the true values to verify the robustness of the proposed method.

Keyword: traffic survey, deep learning, image recognition

1. はじめに

1-1 背景

道路の交通量を把握するには，調査員が目視で計測する方法の他に道路管理者が設置している交通量常時観測装置や簡易型トラカンを用いた機械観測による方法がある．高速道路や直轄国道では機械観測が主流になっている．しかし，これらの機械観測のための装置は高所に設置している場合が多く，設置されていない箇所で新たに調査を行うには設置工事も必要となり，費用も高くなる．また，当然，これらの高所観測手法は装置を設置できる場所が限られてしまう．カメラで撮影した動画を用いた画像認識システムによる交通量計測手法も開発されているが，同じく高所からの撮影を前提としているものが多い．これらのことから生活道路等の細街路をはじめとする高所への機器設置が難しい場所での調査や特定の目的で行うテンポラリーな調査は人手で行うことが一般的となっており，設置が容易な路側からの撮影動画を対象にした交通量自動計測システムの必要性は高いといえよう．

1-2 機械観測に関する既往研究

交通流調査における AI の応用については，例えば国土交通省では ETC2.0 や AI カメラの活用について検討している．星野 [1]らは ETC 車載器の製造時に割り当てられる固有の情報であるワイヤレスコールナンバー（以下 WCN）を用いた生活道路調査の適用可能性についての研究を行っている．WCN 路側観測器を地上から高さ 6m に設置した場合の WCN の取得率は 61.7%，高さ 2m に設置した場合の取得率は 35.0%であり，設置高さによって精度に大きく差が表れている．生活道路における WCN を用いた調査では，機器の設置高さの条件によって設置可能箇所が限られるという課題が明らかになった．

岩﨑 [2]らの研究では，ネットワークカメラを 6m の高さに設置し，画像解析した結果，車両を囲む短形の面積から大型車両，小型車両の区別を可能としている．しかし，大型車両の誤認や車両の影の影響を受けるといった課題が明らかになった．

鈴木ら [3]の研究では多機能ビデオ画像処理システム Traffic Analyzer を開発し，交通量計測が 95%以上という実用上には十分な精度で通過車両を検出することを可能にした．しかし，撮影アングルは陸橋や歩道橋など，車両から垂直な場所が必要であるため，任意の場所での調査が容易に実施できないという課題が残る．

菅原ら [4]の研究では，深層学習による交通量自動計測システムの実現を目指し，市販の三脚で撮影可能な 60cm，110cm，150cm の高さにカメラを設置し，精度を最も向上させることができる撮影高さが 60cm であることを示している．また，車種判別の精度を高めるためには車種別の教師データ数の偏りを小さくすることが有効であることを明らかにしている．

1-3 目的

本研究では，場所を問わず簡易に交通量を自動計測できるシステムの構築を目的に，機器設置が容易な路側から市販のハンディカメラで撮影した動画を活用して交通量を自動計測するシステム TRAVIC を開発する（図 1）．そして TRAVIC を実際に複数地点で撮影した動画に適用して車種別交通量を計測する．計測結果については目視による計測結果と比較を行い提案手法のロバスト性が確保されているかの検証を行う．

図 1－路側撮影動画からの交通量自動計測システム TRAVIC の概要

2. 車種別交通量計測手法

本研究にでは図 2 に示す手順で交通量の自動計測を行った．詳細について以下に示す．

2-1 入力データ

入力対象の動画品質は一般的なビデオカメラで撮影が可能な「1280×720pix，30fps」とした．撮影方法は菅原ら [4]を参考に路面高さ 60cm 程度から道路に向かって 30 度の入射角で車両前方から撮影することとした（図 3～5）．路側からの撮影動画を行うため，対象道路は片側 1 車線道路となる．

2-2 車種別車両検出モデル

動画の画像解析を行う際は解析対象の画像数が膨大になることから処理速度が重要となる．TRAVIC の車両検出モデルには Weiliu[5]を参考に深層学習の画像認識手法の一つであり 1 秒間に 10 フレーム以上認識が可能な Single Shot MultiBox Detector（以下 SSD）を適用した．SSD はオブジェクト分類モデルとして多くの実績があり，エッジ機器での稼働もできるためリアルタイム処理への拡張も可能となる．

2-3 教師データ

「全国道路・街路交通情勢調査」において採用されている自動車類 4 車種区分を含む 7 クラス（乗用車・バス・普通貨物・小型貨物・自転車・その他二輪・歩行者）に対応した教師データを作成した．

教師データの作成にあたっては先に示した撮影方法で実際に撮影した計 10 地点の動画を用いた。表 1 に作成した教師データ数およびその割合を示す．ここで，車種別の教師データ数ついては偏った学習を避けるために，菅原ら [4]を参考に車種別のデータ数に極力偏りが生じないようにして作成した．なお，教師データとする一つの画像の中に複数車両が同時に映り込むため，データ数は一致していない．

2-3 車両のカウント判定

車両のカウント判定は，検出した車両をセントロイドトラッキングにより追跡し，追跡車両が任意に設定したエリアに画面右から侵入した車両をカウントすることとした．

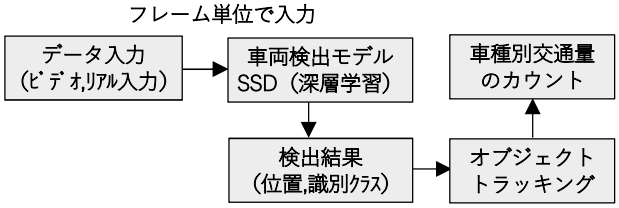

図 2－深層学習による交通量観測手法の手順

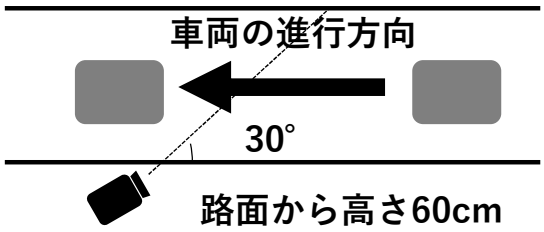

図 3－入力対象動画の撮影方法

図 4－入力対象動画の撮影方法

図 5－入力動画のイメージ

表 1－教師データ数

車種	データ数	割合
乗用車	1,661	19%
バス	1,096	12%
小型貨物	1,111	13%
普通貨物	16,00	18%
自転車	1,109	12%
その他二輪	1,109	13%
歩行者	1,169	13%
合計	8,855	100%

3. 車種別交通量計測結果

交通量計測精度の検証は教師データに用いていない 3 地点の動画を用いた．動画時間は，地点 A が 2 時間，地点 B と地点 C は 1 時間である．

表 2 に各動画に対して目視で計測した台数（真値）をと TRAVIC で自動計測した台数およびその比を示す. 図 6 には実際に計測している状況を示している。

各地点について全車種の合計値を見ると地点 A では目視 1496 台に対して TRAVIC では 1465 台となっており目視に対する精度は 98%である．地点 B では目視 554 台に対して TRAVIC では 546 台と 99%，地点 C では目視 737 台に対して TRAVIC では 716 台と 97%の精度で計測できている. このうち, 自動車類を小型・大型に分類してみたときの精度は小型車では 98～102%，大型車では 90～116%の精度で計測できている．さらに「全国道路・街路交通情勢調査」において採用されている 4 車種区分を含む 6 車種分類で見てもおおよそ±10%程度の誤差以内に収まっていることが分かる．ただし，すべての地点で自転車の精度が 70%程度と悪くなっている．詳細を確認したところ自転車複数台が重なりながら通過している際に検出できていないことが確認できた（図 7）．また地点 B については小型貨物の精度が悪くなっているが，これはナンバープレート情報でのみ判別できる車両（例えば小型バンは乗用車の車両も小型貨物の車両も存在する）が多く存在することが要因の一つである（図 7）．

表 2－交通量計測結果

			地点A:2時間			地点B:1時間			地点C:1時間		
			目視	TRAVIC	比（TRAVIC／目視）	目視	TRAVIC	比（TRAVIC／目視）	目視	TRAVIC	比（TRAVIC／目視）
全車種			1496	1465	98%	554	546	99%	737	716	97%
小型			1159	1152	99%	450	442	98%	544	554	102%
大型			188	186	99%	55	64	116%	63	57	90%
内訳	自動車類	乗用車	944	957	101%	316	338	107%	375	381	102%
		バス	14	14	100%	17	17	100%	20	20	100%
		小型貨物	215	195	91%	134	104	78%	169	173	102%
		普通貨物	174	172	99%	38	47	124%	43	37	86%
	バイク		100	92	92%	23	23	100%	29	33	114%
	自転車		49	35	71%	26	17	65%	101	72	71%

＜地点 A＞　＜地点 B＞　＜地点 C＞

図 6－交通量計測状況

＜自転車の検出漏れ＞　＜乗用車と小型貨物の車種判別間違い＞

図 7－計測誤差要因

4. まとめと今後の課題

本研究では簡易な手法で撮影した動画から深層学習による交通量自動計測システム TRAVIC を開発し，複数地点の動画を対象に計測精度を確認した．結果は全車種合計では数%以内，車種別に見たときも自動車類についてはおおよそ±10%以内の精度で交通量が計測できることが確認できた．

今後の課題として自転車の精度を向上させるための自転車を中心とした教師データの拡充が挙げられる．また，小型バン等の複数の車種に分類される可能性のある車種の判別を正確に行うためにはナンバープレート情報を読み取り，複合識別を行うことで可能となる．さらに，ナンバープレート情報の認識が可能になれば生活道路の抜け道利用など交通流動の把握や特定施設の滞在時間や商圏調査等への活用も期待できる．そのため，現在は低位置からの撮影によりナンバープレートも認識可能な動画の特徴を活かして，車両検出と同時にナンバープレート情報を認識する機能を開発中である．

参考文献

1) 星野一輝，小嶋文，市本哲也，鈴木達也，上田透，片山賢治，久保田尚 : WCN を用いた生活道路調査の適用可能性に関する研究，土木学会論文集 D3，Vol.74，No.5，I_817-I_826，2018.
2) 岩崎洋一郎, 永村幸大, 中宮俊幸, 岩本祥二郎, 宮田俊彦, 倉本俊昌, 北島俊孝, 瀬戸口恵: 交通量調査自動化のためのネットワークカメラを用いた交通流計測手法，電気関係学会九州支部連合大会講演論文集，pp.19-20，2015.
3) 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 Traffic Analyzer の開発と性能検証，土木学会論文集，Vol.62，pp.276-287，2006.
4) 菅原宏明, 小篠耕平, 藤井純一郎, 大久保順一, 小早川悟：路側に設置した簡易撮影機器の動画による交通量自動計測に関する基礎的研究，第 40 回交通工学研究発表会論文集，2020.
5) Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, Alexander C. Berg : SSD:Single Shot MultiBox Detector, 2016.