

車種別交通量調査への深層学習の応用システムの提案

Proposal to use deep learning network for traffic counting system

大久保順一^{*1}

菅原宏明^{*1}

藤井 純一郎^{*1}

小篠 耕平^{*1}

小早川 悟^{*2}

和田 英之^{*2}

Junichi Okubo

Hiroaki Sugawara

Junichiro Fujii

Kouhei Ozasa

Satoru Kobayakawa

Hideyuki Wada

^{*1} 八千代エンジニアリング株式会社

Yachiyo Engineering, Co., Ltd.

^{*2} 日本大学理工学部

Nihon University

We propose using DNN framework for traffic counting. We use normal video camera instead of specially design for traffic counting system. We also design dataset for traffic counting by mixture picture for each category. We also enhance COCO dataset tools to handle our dataset. Using mixture category dataset we can improve detection.

1. はじめに

交通量観測には道路管理者が設置している交通量常時観測装置の結果を用いる方法、簡易型トラカン(路面設置型、路側設置型など)を設置して交通量を観測する方法、人手により観測する方法、などが存在する。交通量の常時観測装置は支柱等の高さ6mに設置されており、超音波や光ビーコンにより計測するため機器設置の工事が必要となる。さらに、現在実用化されている交通量調査向け画像解析システムにおいても高所から撮影された映像の使用を想定しているものが多い。

本研究では家庭用ビデオカメラと市販の三脚という入手と設置が容易な既存の装置を用いて録画した画像(動画)から、AIを用いて自動で交通量をカウントするための効果的なデータセットの作成方法について明らかにすることを目的とした。

2. 既往研究と本研究

2.1 交通量調査へのAIの応用に関する既往研究

交通調査に関するAIの応用については、例えば国土交通省はETC2.0の活用とAIカメラの活用について検討している。

また、星野らは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た。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[星野 2018]。

岩崎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、車両を囲む矩形の面積から大型車両、小型車両の区別が可能であった。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も明らかになった[岩崎 2015]。

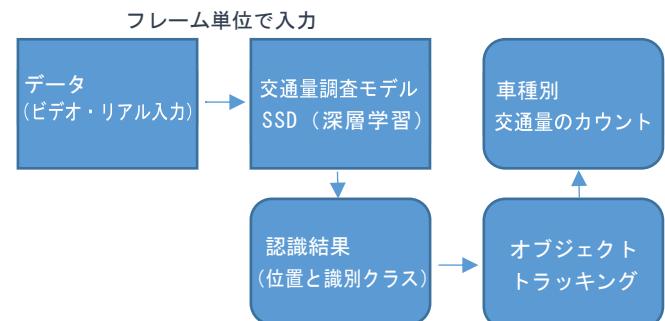
なお、本研究に先立ち、カメラの位置による認識精度の違いについて研究を行った。この研究では撮影高さ別に教師データを作成した上で精度の検証を行い、教師データと読み取り映像

の撮影高さが同じである場合に最も認識精度が良いという結果を得ている[和田 2020]。

2.2 本研究の提案手法

本研究において深層学習として用いたシステムはSSD300である。

これはSSDが1秒間に10フレーム以上認識が可能であること、一般的なオブジェクト分類モデルとして多くの実績があること、また近年のグラフ共通化やグラフコンパイルの手法によりハードウェアに依存せず、エッジ機器での稼働が可能なことの理



由から選定した。入力はビデオデータとしており、録画したデータ、もしくはリアルタイム入力を使うことができる。

図1 深層学習による交通量観測手法

3. 車種別交通量検出モデルの構築

本研究では車種別交通量を検出する必要があり、深層学習の画像認識手法[Weiliu 2016]の一つであるSingle Shot MultiBox Detector(以下、SSD)を適用した。

また検出されたオブジェクトトラッキングアルゴリズムとしてはCentroid Tracking [J.C.Nascimento 1999]を用いた。

3.1 教師画像の作成

教師画像セットは COCO データセットの形式を用いて新たに 12,000 枚、クラス数 7 で作成した。これには COCO 画像は用いていない。

COCO 2014 のデータセットには学習用データが 82,783 枚でありクラス総数は 80、このうち、交通関係には車、人、バイク、バス、自転車、トラックが含まれている。

図 2 が今回のシステムのために新たに作成した部分である。



図 2 COCO の拡張の作成

COCO 形式に合わせるように、VoTT を用いたアノテーションを変換するプログラムを作成してこれを用いた。

今回のデータセット作成では次の点を考慮した。広く用いるために、道路交通量センサスで使われる車種区分を考慮して普通貨物、小型貨物、大型乗用、小型乗用、人、自転車、その他二輪の 7 クラスとした。また、様々な用途に合わせて将来拡張可能であること、また、短時間学習が可能であることを目標とした。

本研究ではデータセット作成のために交通量調査を 2 時間行い、4 地点についてビデオの設置高さの違いが 3 種類の合計 12 セットの録画を行い、合計 24 時間分のビデオ画像を録画した。データセットはこれら 12 セットの画像の中から、作業時間を考慮し、6 セットをそれぞれ 1 時間分 2,000 枚で選定し、合計 12,000 枚の画像についてアノテーション作業を行った。この最初に作るデータセットを、本論文では実交通データセットと呼ぶ。

実交通データセットを用いた検出結果については、先の研究 [和田 2020] にて、地点・高さにより、検出率が影響されることがわかった。

実交通データセットをさらに細かく分析すると、例えばアノテーションする静止画像には通常複数台の小型乗用車と 1 台程度の貨物自動車等が含まれることとなり、必然的に実交通量で多い車種区分の台数が多くなっている。

本研究では、この車種別台数の割合が偏っていることが検出率に影響を及ぼしているのではないかという仮説を立て、これの検証を行った。

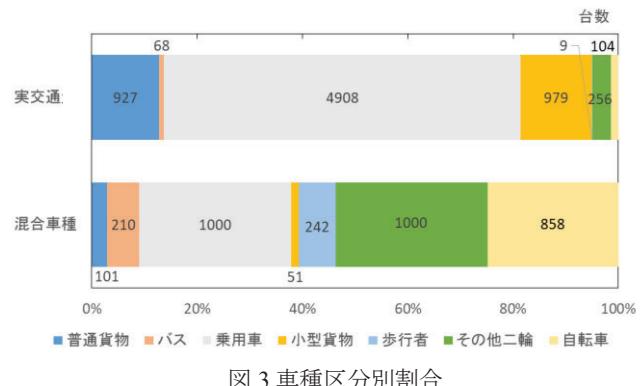
そこで本研究では 6 つの実交通データセットからランダムにデータを抜き出し、車種別のアノテーションの枚数が等しくなるようにデータセットを作成し、これの検出率について研究した。

なお本論文ではこれを混合車種データセットと呼ぶ。

3.2 深層学習モデルの作成

(1) 学習方法

本研究では、先に述べたようにデータセットに含まれる車種区別の台数に着目し、この車種区分の混合比率を変えたものを 3 セット作成し、検出結果がどのように変化するかについての実験を行った。図 3 は準備した中でも最も精度が良かった混合車種の 1 セットについて車種分割合を示したものである。



(2) 学習結果

モデルの学習は 16 万エポックまでを行い、4 万エポック毎での性能を比較した。図 4 は学習過程のグラフである。学習回数を重ねると、損失が減少していることが分かる。

実交通データセットと、混合車種データセットでの対比で見ると混合車種データセットの場合に損失の収束が早く発生し、その後は過学習していることが推察される。

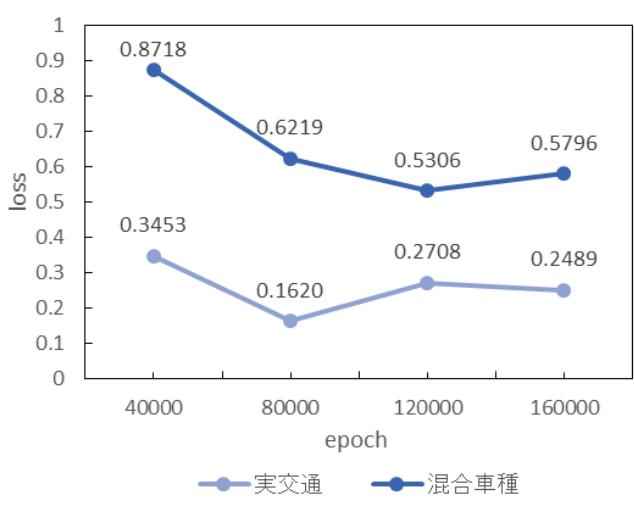


図 4 学習過程

(3) 精度評価

作成したモデルの精度評価は、各地点からミックスした画像によるデータセットを作成して行った。

精度評価は IoU が 0.5 以上のものを正解とした。図 5 は検出領域の正解率 (total AP) と検出領域と検出車種の両方の正解率 (detection AP) を示している。検出領域の正解率については、混合車種データセットと実交通データセットについて両方とも高い認識率を示す。図 6 は認識結果の画像である。赤い枠がアノテーションを緑の枠が認識結果を示す。

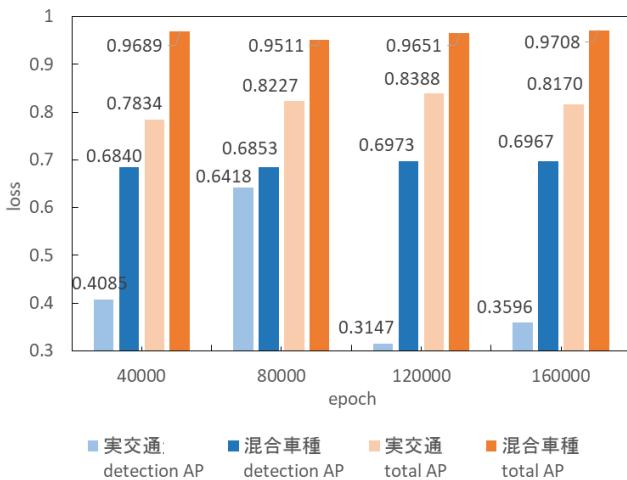


図 5 精度グラフ



図 6 認識結果

これに対して、検出車種の正解率は混合車種データセットの方が高い。また実交通データセットを使うと80,000エポック以後過学習により認識率が急速に低下をする。これは実交通データセットを用いると過学習が起こるためと考えられる。

このように検出率についても混合車種データセットが優位であることが示されている。検出率のエラーについて細かく調べていくと、小型貨物車と小型乗用車の割合が高い。これは、小型貨物車と小型乗用車については同じ形状でナンバー取得が違うことにより、車種判別が異なることが発生しているためである。

4. 最後に

4.1 結論

本研究では、簡易な手法で撮影した画像を用いて AI による車種別の交通量カウントのための効果的なデータセットの作成方法について検討した。混合車種データセットを用いることで、より高い精度の認識結果を得られることが示された。

4.2 課題

本文でも述べたように、通常のデータセットと混合データセットの両者において小型貨物と小型乗用についての判別エラー

が多く、これは、この 2 車種の車両形状が同じである場合があるためである。今後はナンバープレートの情報を読み取り、複合識別を行う手法について研究する予定である。

参考文献

[星野 2018] 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. pp. I_817-I_826, 2018.

[岩崎 2015] 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, 濱戸口恵: 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.

[和田 2020] 和田英之, 小早川悟: 画像認証システムを使用した交通調査のための画像データの収集手法に関する研究, 令和 2 年卒業研究, 日本大学交通システム工学科, 2020.

[Weiliu 2016] Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, Alexander C. Berg: SSD:Single Shot MultiBox Detector, arXiv:1511.02325. 2016

[J.C.Nascimento 1999] J.C.Nascimento, A.J.Abrantes, J.S.Marques: An algorithm for centroid-based tracking of moving object, IEEE. 1999