車両追跡における深層学習の応用
Object tracking using ReIdentification

大久保　順一*1　　菅原　宏明*1　　小篠　耕平*1　　岡野　将大*1
Junichi Okubo　　Hiroaki Sugawara　　Kouhei Ozasa　　Masahiro Okano

*1 八千代エンジニヤリング株式会社
Yachiyo Engineering Co., Ltd.

In Smart City planning, vehicle counting is very important task. In this task we propose to use Re-Identification model. Using CNN with cosine similarity we evaluate Re-Identification to replace centroid object tracking. We reached 89% accuracy, which is a little behind using centroid object tracking but it is more simple and have enough room to improve.

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．これに対して弊社では DNN を用いて，専用カメラを用意せずに低い位置から撮影した動画の解析により車種別交通量観測ができるシステムを開発した（システム名 TRAVIC）．

ビデオ解析による方法の中では，フレームトラッキングが車両カウントの正確性にかなりのウエイトを占めている．フレームトラッキングには従来，セントロイドトラッキングを用いたが，大型車両の影に隠れる場合などのオクルージョンで精度を落とすことがわかった．

近年 DNN による ReIdentification の技術が，人物追跡・照合のエリアで大きな成果をあげており，この技術を応用することにより問題が解決できるかどうかの研究を行った．

2. 既往研究と本研究

2.1 ReIdentification モデルの交通流問題への応用の既往研究

DNN の交通流調査への応用研究は，2017 より AI-City Challenge として，毎年コンペティションが開催されて，大きな成果をあげている．AI-City Challenge でのトラック 2 が ReIdentification タスクとなっている．このタスクは複数のカメラで撮られた画像から，複数の地点で同一の車両を特定していくというタスクである．

Hongbo Wang らはこの分野での研究について，5 つの流れで解説を行っている．中でもメトリックスラーニングのカテゴリーが精度も高いものが多く，様々な研究が行われている[Hongbo Wang 17].

Shuting He は人物照合で大きな成果をあげている BoT-BS を用いて，比較的単純なモデルを構築しながら高い精度を上げて研究のベースラインとしている．さらに Shuting He らはこのベースラインの上に MultiTask Learning などの新しい手法を試して大きな成果をあげている[Shuting He 20].

Ratnesh Kumar らも BoT-BS と同様な手法に，顔認識で使われている FaceNet を用いることで成果をあげている[Ratnesh Kumar 19]. これらの手法の特徴は，CNN での最終層の GAP を用いてここから特徴量を引き出し，コサイン距離などを用いて特徴量のメトリックスラーニングを行うところにある．

連絡先：大久保順一，技術創発研究所，〒111-8648 東京都台東区浅草橋 5-20-8，jn-okubo@yachiyo-eng.co.jp

2.2 本研究の提案手法

本研究のベースとなる TRAVIC の手法を示す．

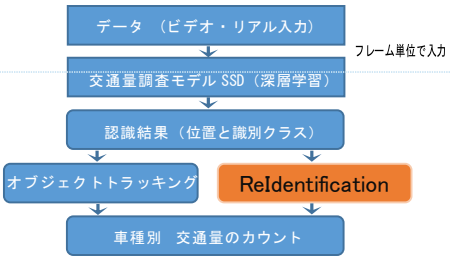

図 1　システム概要

TRAVIC では SSD による車両の位置とクラスをまず提案させ，これをセントロイドトラッキングへの入力値として車両追跡を行い，カウントを実行している．

本研究では，SSD による車両位置の提案はそのままに，セントロイドトラッキングへの入力の代わりに ReIdentification モデルに入力して，車両の追跡を行うことができるかについての検討を行うために，まず車両の画像を入力値として，その特徴量を特徴量ベクターとして出力し，これのコサイン類似度で同一車両かどうかの判定を行う．

3. 実証実験

実証実験は，令和2年度に千葉県習志野市の国道を対象に実施した．この実験では，図 2 の地図上 3 地点での車両の追跡について，ビデオ撮影をし，人手によるビデオの確認により，ベースデータとして，車両の一致情報を作成した．

データ形式は表 1 のとおり，車両を矩形で切り取った PNG 画像と，その車両の車両 ID 及びカメラ ID を付与して作成した．

データの車両クラス別の割合については、図 3 に示す．

表 1

ビデオ撮影	車両 ID 合計（台）	画像合計（枚）
地点 1	150	628
地点 2	150	600
地点 3	60	270

コメントの追加 [A1]:

コメントの追加 [A2R1]:

図 2 実験地

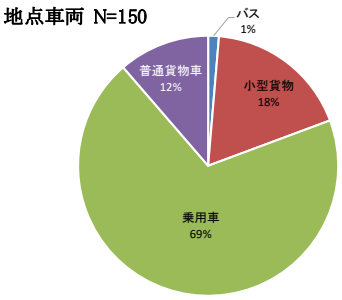

図 3 車種別割合

3.1 深層学習の構築

深層学習は Hao Luo らによって開発された BoT-BS を用いた [Hao Luo 19]. Bot-BS は ResNet からの転移学習を使い，最終層に BNNeck と呼ばれる層を加えることに triplet loss による学習を可能としている．本研究では，このベースライン ネットワークによる精度比較実験を行った．BNNeck では Center loss や，マルチタスク学習などもサポートしているが，今回はベースラインの性能を検証するという観点から使用していない．

本研究でのデータセットは Ai-City Track2 のデータセットを参考として，実証実験において得られたデータから 150 台，1280 枚の教師データを作成してこのデータにおいて実験を行った．

3.2 深層学習の精度

次に今回採用した深層学習についての精度について述べる．

学習は図 4 のとおり 20 エポック行い，5 エポック毎に認識率の評価を行い学習の精度を確認した．

(1) 精度評価

精度評価は，実際の交通量調査の動画の中から，3 地点を取り 2 地点を学習させて最後の 1 地点での認識率を確認することで行った．

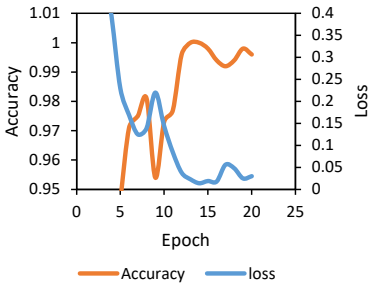

図 4 学習曲線

4. 結論

4.1 考察

本実験の結果を CMC 法にて測定した結果の認識率は 89% を示し，セントロイドトラッキングを用いた場合の 95%よりも低い値となった．AI-city のデータの場合は 80 エポックで性能を発揮するが今回の実験データでは 15 エポックでピーク性能に達した．AI-City チャレンジでは 5 万枚のデータから学習させていることと比較すると，今回はデータ数が十分でなかったことが要因として考えられる．

今回の性能評価では AI-City Track2 に準じた評価を行ったが実際に交通量カウントに組み込む場合は，フレーム間での車両画像の比較を行う必要がある．このような場合には，1 フレームでの対象となるオブジェクト数は少ないので，有利なものになるのではと予想される．これは今回の性能評価はフレーム間での連続性が保証されていない異なる地点での評価を行ったという理由からである．

4.2 課題

実用精度(95%)まで高めていくためには，今後データセットを拡充させて大規模データセットでの学習を進めていくことで，さらに高い精度のモデル構築を目指す．また TRAVIC に対しての組み込みによる車両カウントの精度についても研究を進めていきたい．

参考文献

[Hongbo Wang 17] Hongbo Wang, Jiaying Hou, and Na Chen, A Survey of Vehicle Re-identification Based on Deep Learning, IEEE 2017

[Shuting He 20] Shuting He, Hao Luo, Weihua Chen, Miao Zhang, Yuqi Zhang, Fan Wang, Hao Li, Wei Jiang, Multi-Domain Learn-ing and Identity Mining for Vehicle Re-Identification, CVPR 2020

[Ratnesh Kumar 19] Ratnesh Kumar, Edwin Weill, Farzin Aghdasi, Parthasara-thy Sriram, Vehicle Re-Identification: an Efficient Baseline Using Triplet Embedding ,NVidia 2019

[Hao Luo 19] Hao Luo, Youzhi Gu, Xingyu Liao, Shenqi Lai, Wei Jiang, Bag of Tricks and A Strong Baseline for Deep Person Re-identification, IEEE 2019