

# 深層学習を使った属性情報学習による物体識別の提案

## Attribute learning using deep learning

大久保 順一\*<sup>1</sup> 吉田 龍人\*<sup>1</sup> 都築 幸乃\*<sup>1</sup> 藤井 純一郎\*<sup>1</sup>  
Junichi Okubo Ryuto Yoshida Yukino Tsuzuki Junichiro Fujii

\*<sup>1</sup> 八千代エンジニアリング株式会社  
Yachiyo Engineering Co., Ltd.

Attribute learning is one of necessary function to analyses smart city system. Here we propose to use attribute detection network additionally to detection network using ONNX. Using ONNX we achieve low cost system.

### 1. はじめに

スマートシティの実現にむけて各種要素技術の研究開発が加速されている。中でも車両属性情報の解析については重要度が増している。この中で車両情報の自動取得については、筆者らは Detection ネットワークを用いて車両クラス分類と車両カウントを同時に行うシステムを提案してきた[大久保 2020]。これに加えて高度な交通解析を実現するためには車両のクラス情報以外に、色や社名ロゴなど車両の属性情報を取得することが望まれるが、属性情報の取得は現状人手による判別に頼っており、コストの面などから長時間、大規模での解析が難しい。

本論文では、属性情報の例として色属性をとり上げて、Detection ネットワークに直列で結合された色情報識別ネットワークを用いることで、属性情報解析の可能性について研究を行った。

### 2. 既存研究と本研究のアプローチ

物体識別への色属性情報の影響は過去に様々アプローチで研究されてきた。Fahad らは特定のオブジェクトは特定の色に深い関係にある場合の色情報識別子ベースでの Detection についての研究を行った[Fahad 2012]。また色情報とは適切な色空間上での距離で識別され、色情報識別子で 識別可能とされている。しかしながら、色情報は野外においては天候による太陽光の照射条件で異なり、室内においては天井の研究においても照明条件で異なる特性を持つため難しいとされている[井尻 2011]。

深層学習における色情報識別は、Boyang Su らの研究によると色情報識別子を用いる色情報識別子同等の識別能力を示すことが提示された[Su 2015]。

深層学習という分野では Reza らが、ネットワーク形状を多層分岐することにより Boyang Su らによる研究よりも高い精度となることを示した[Reza 2015]。Abrar らの研究ではマルチタスク学習を使うと一つのネットワークで複数の学習を行うことが可能となり、色情報の取得も可能となる[Abrar 2016]。

近年、深層学習フレームワークおよび ONNX 規格の発展により、フレームワークに依存せずネットワークを動作させることが可能となった[Linux 2019]。色情報は Boyang Su らの研究で示されるように比較的軽量ネットワークでの識別が可能であるので、既存のネットワークの再学習をさせないために、別のモデルを用いて、Detection Network の後で色情報を識別するという試みを行った。

### 3. 本研究の方法

本研究では実用化を前提として軽量デバイスとして Nvidia 社の Jetson Nano を用いて研究を行った。Jetson Nano 上では ONNX 形式を TensorRT 形式に変更したものを実行させた。

本研究のネットワークとしては、前段の Detection Network は YoloX[Ge 2021]を使い、モデルについては既存のモデルをそのまま用いた。後段の色情報識別ネットワークには小型で軽量であるという理由から AlexNet[Krizhevsky 2012]を使った。表-1 に本研究で用いたモデルのパラメータ数と FLOPS を示す。

このように複数のモデルをチェーンしたアーキテクチャを採用することで、将来いろいろな属性についての検出が可能なものとした。

分類は一般的な自動車の色に合わせて white, gray, red, yellow, green, cyan, blue の 8 色とした。道路脇から車道を撮影した動画から車両の箇所だけを切り出し、色別に区分することでデータセットを作成した。最終的に得られた 12471 件の教師データセットによってモデルの学習を行い、256 件の評価データセットで評価を行った。評価データセットの画像を表-2 に例示する。

学習は Nvidia T4 を搭載したクラウドインスタンスで実行し、30 epoch の学習に約 1 時間を要した。

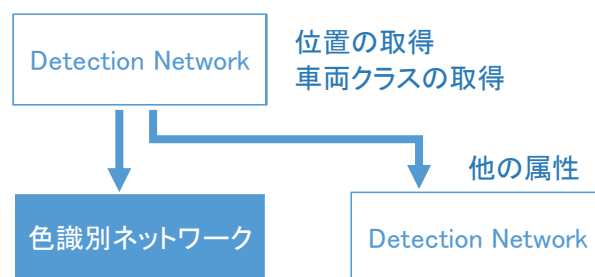


図-1 ネットワーク構成

表-1 使用モデルのパラメータ数および FLOPS

	パラメータ数(M)	FPS(G)
YOLOX	54.2	155
AlexNet	57.0	127

#### 4. 結果

表-2 に学習したモデルの分類精度を評価した結果を示す。結果については、データセットがインバランスであった為、クラスによる偏りを見せるが、最低でも 8 割を超えるおおむね良好な精度を示した。

今回のネットワークは表-1 に示すように元ネットワークとほぼ同等のネットワークを用いることによって、精度を確保することができた。

#### 5. 考察









本論文に示す通り、軽量なネットワークを用いることで、色属性情報を取得することは可能である。今後の深層学習の実用化に向けてのひとつの方法として着目して良いというように考える。

軽量なネットワークの利点は、学習にかかるコストが少なく、また実行時のコストも低い。目的別に軽量なネットワークを使うことで、本来の調査を細かく行うことが簡易にできるようになると考える。今後は車両のロゴなどの商業情報の解析やトラックの運送業者別情報など様々な属性を調査ごとに低いコストでモデルを作成することで、可能とすることに研究を継続していきたい。

#### 参考文献

- [Abrar 2016] Abrar H. Abdunabi, Gang Wang, Jiwen Lu, Kui Jia: Multi-task CNN Model for Attribute Prediction, arXiv: 1601.00400, 2016.
- [Fahad 2012] Fahad S. Khan, Rao Muhammad Anwer, Joost van de Weijer, Andrew D. Bagdanov, Maria Vanrell, Antonio M. Lopez: Color attributes for object detection, CVPR, 2012.
- [Ge 2021] Zheng Ge, Songtao Liu, Feng Wang, Zeming Li, Jian Sun: YOLOX: Exceeding YOLO Series in 2021, arXiv: 2107.08430, 2021.
- [Krizhevsky 2012] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton: ImageNet Classification with Deep Convolutional Neural Networks, NIPS, 2012.
- [Linux 2019] The Linux Foundation®: Open Neural Network Exchange, ONNX, 2019.
- [Reza 2015] Reza F. Rachmadi, I Ketut E. Purnama: Vehicle Color Recognition using Convolutional Neural Network, arXiv:1510.07391, 2015.
- [Su 2015] Boyang Su, Jie Shao, Jianying Zhou, Xiaoteng Zhang, Lin Mei: Vehicle Color Recognition in The Surveillance with Deep Convolutional Neural Networks, Atlantis Press, 2015.
- [井尻 2011] 井尻 善久, 川西 康友, 美濃 導彦: 視野を共有しない複数カメラ間での人物照合, 電子情報通信学会技術研究報告, 2011.
- [大久保 2020] 大久保 順一, 菅原 宏明, 藤井 純一郎, 小篠 耕平: 車種別交通量調査における物体追跡法の改良, AI・データサイエンス論文集, 2020.

表-1 分類精度評価結果

クラス		Accuracy
white		29/32=90.7%
gray		26/32=81.3%
black		28/32=87.5%
red		32/32=100%
yellow		31/32=96.9%
green		32/32=100%
cyan		31/32=96.9%
blue		28/32=87.5%
平均	—	237/256=92.6%