

畳み込みニューラルネットワークと HSV 彩度変調を利用した信号機検出

2018SC018 堀圭佑

指導教員：河野浩之

1 交通と道路標識自動認識の現状

近年、自動運転の実現に向けた技術開発が進められている要因の一つとして道路標識の見落としや違反に起因した交通事故が多発していることが挙げられる [1].

そうした中で、道路標識の自動認識を行う技術がさまざまな組織が企業で研究開発が行われている。それらは、ITS（高度道路交通システム）と呼ばれる技術をもちいたもので、無線によって車両が路側設備を認識しているが、莫大な無線機設備の設置および維持費用がかかるなどの多くの課題がある。そこで本研究では無線設備が無い状況でも認識が可能な物体検出による信号機検出に着目する。

2 信号機検出に関連する先行研究

深層学習を使用した物体検出により、対象物の適切な特徴の自動抽出が可能になった。深層学習を利用した物体検出機による道路標識の自動検出および認識の研究は表 1 などがあげられる。

表 1 道路標識の自動認識を行う先行研究

研究者名	検出機	精度改善手法
石田ら [2]	SSD	RGB 色変調
三井ら [3]	YOLOv2	マスク処理
Hasegawa ら [4]	YOLOv2	マルチスケール

Hasegawa らは、信号機も対象とした検出を行った.. CNN ベースの深層学習にロバスト性を持たせるため、マルチスケールと呼ばれる Data Augmentation を用いた。一枚の画像のスケール変更を行うことで、データの増強を施すというものである。彼らの手法では検出率が 80% ほどと低いことが課題として挙げられ、更なる改善の余地があると考えた。

3 信号機検出における精度改善手法

我々の提案として、信号機データセットに対して HSV 彩度調を施しデータを増強させ、それらを入力画像にすることでさらなるロバスト性を持つモデルを構築できると考えた。彩度変調は元画像の鮮やかさのみに作用するため、信号機から大きく外れたデータを生成することなく学習させることが可能である。図 1 は提案する手法のフローである。

物体検出には畳み込みニューラルネットワークを利用したものが開発されており、主に表 2 があげられる。今回は、高速かつ誤検出が少ない YOLOv5 を物体検出器として使用する。YOLOv5 は YOLOv3 を Pytorch に最適化した

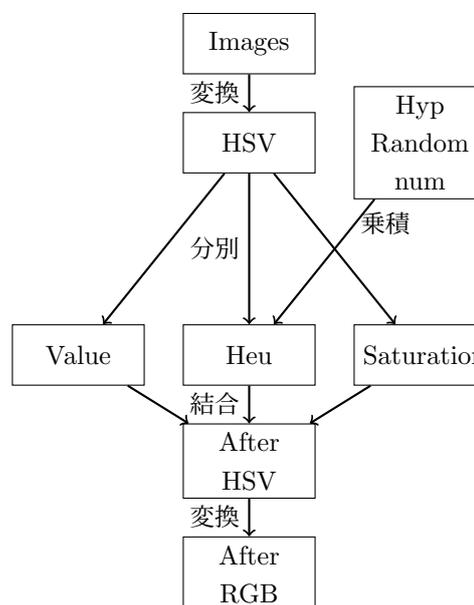


図 1 HSV 彩度変調

改良モデルである。

表 2 物体検出器比較

名称	候補領域検索手法
Faster-RCNN	二段階方式
SSD	一段階方式
YOLO	一段階方式

対象物範囲を座標として記録するアノテーションを行う。今日アノテーションツールとして VOTT や Labelme などが開発されているが、今回は txt 出力可能な Labelimg を使用する。

正解領域に対して、予測領域がどれほどあっているかを示す精度の評価指数に、ジャカード係数 (IoU) を用いる。ここで $Object$ は正解領域 $DetectedBox$ は予測候補領域、 $Object \cap DetectedBox$ は二つが重なる領域である。IoU は次の式で定義される。

$$IoU = \frac{Object \cap DetectedBox}{Object \cup DetectedBox} \quad (1)$$

学習精度の評価には mAP を用いる。 mAP の式は次のとおりである。 $Precision$ は正解度、 $Recall$ は精密度である。

$$mAP = \frac{\int_0^1 Precision(r) dRecall}{\text{総データ数}} \quad (2)$$

4 学習及び信号機検出

ここでは実験について説明する。節 4.1 で実験準備について、節 4.2 では実験結果を説明する。

4.1 実験準備

実験環境として OS は Windows10, GPU は RTX3070, ディストリビューションは Anaconda で実験を行う。

信号機には、青、赤の 2 種類があり、それぞれ青 750 枚、赤 582 枚の合計 1332 枚の画像を用意した。検証用データは節 3 の式 (2) の値の算出に使用される。入力形式は png であり、img サイズは 640×640 である。

HSV 色彩変調を組み込んだ YOLOv5, 3 つ目は HSV 色彩変調とデータ拡張を組み込んだ YOLOv5 でそれぞれ学習を行う。またそれぞれを 3 つバッチサイズに変更したのも学習を行うため計 9 回で学習及び検出を行い精度の変化を確認する。精度評価では晴天、悪天候、夜間での青点灯および赤点灯をそれぞれ計 6 枚に対して検証を行う。節 3 で提示した、式 (1) の値をモデル評価に用いて提案手法と、Data Augmentation を行わない YOLOv5 とで比較を行う。また先行研究であるマルチスケールとの比較も行う。

4.2 各手法との検出精度比較

YOLO 単体で最も高い mAp であったのはバッチサイズ 5 で、0.899 であり、提案手法を組み込んだ YOLO で高かったのはバッチサイズ 20 で、0.907、提案手法とデータ拡張を組み合わせたもので高かったのはバッチサイズ 20 で、0.909 であり、HSV 色彩変調とデータ拡張を組み合わせたものが常に最も高い値であった。

図 2 は mAp が最も高かったそれぞれのモデルでの検出結果である。6 枚のすべての画像に対して検出が可能だったものは提案手法にデータ拡張を組み合わせた手法のみであった。また提案手法にデータ拡張を組み合わせたモデルでは、晴天青点灯で 0.83 と他のバッチサイズと 0.01 と均衡し、晴天赤点灯 0.87、悪天候は青点灯赤点灯ともに 0.88、夜間青点灯では 0.68 であり最も高い検出結果となった。

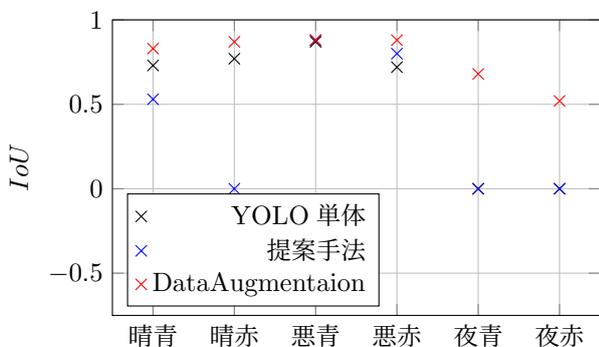


図 2 各手法に対する検出精度比較

図 3 は提案手法にデータ拡張を組み合わせたモデルと先

行研究であるマルチスケールとの比較である。晴れた日の赤点灯、曇りの日青点灯および赤点灯では、それぞれ 0.03 ポイント 0.09 ポイント、0.08 ポイント及ばなかった。一方で晴れた日の青信号では 0.04 ポイント向上し、また夜間画像に対しては Multiscaling では未検出だったものが、青点灯赤点灯それぞれで、0.63, 0.61 で検出可能であった。

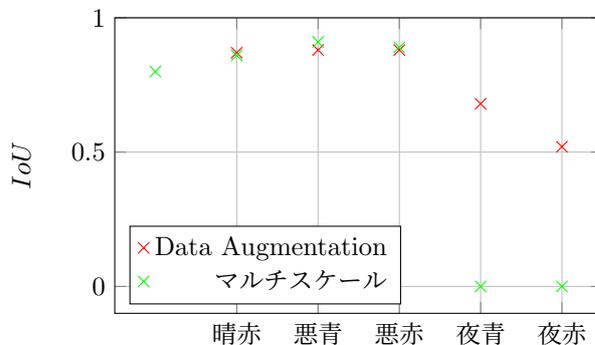


図 3 各手法との検出精度比較

5 まとめ

先行研究であるマルチスケールでは、夜の画像に対して検出ができなかったが、提案手法では検出可能であった。しかしながら検出精度は低いため改善が必要である。

本研究ではすべての状況に対して HSV 彩度変調を施した画像を入力していたが、悪天候や夜間画像に対して学習精度が落ちる傾向にあった。各状況に対して、色改善などの適切な画像処理を行うネットワークを組み込むことで精度向上が期待できる。

参考文献

- [1] 三井住友海上, 事故原因法令別事故件数割合, https://www.ms-ins.com/special/rm_car/accident-data/, 2022 年, 1 月.
- [2] 石田泰之, Mohd Hafiz Hilman bin Mohammad Sofian, 伊東敏夫, “ 全方位カメラを用いた走行環境認識のための信号検出に関する研究.” 自動車技術会議論文集, 52 巻, 3 号. p. 695 - 700, 2021 年.
- [3] 三井悠也, 宮崎棕湖, 吉元佑真, 石田裕太朗, 伊藤太久磨, 通山恭一, 田向権, “ 深層ニューラルネットワークを用いた領域推定と部分テンプレートマッチングによる道路表示検出システム.” 知能と情報, 33 巻, 1 号, p. 566 - 571, 2021 年.
- [4] Ryo Hasegawa, Yutaro Iwaoto, and Yen-Wei Chen, “ Robust Japanese Road Sign Detection and Recognition in Complex Scenes Using Convolutional Neural Networks,” Journal of Image and Graphics, Vol. 8, No. 3, September 2020.