Vol.2021-MBL-101 No.12
Vol.2021-ITS-87 No.12
2021/12/7

物体検出手法YOLOで用いる学習データセットのラベル付与方法の変化による自動二輪車検出精度向上の検証

中島 健介[1,a)]　佐久間 尚紀[2]　中安 淳也[2]　木谷 友哉[1,b)]

概要：自動二輪車が被害者となる事故は二輪車が被害者となるケースの方が多く，その原因は加害者側の運転者が二輪車を見落とすことがほとんどを占めている．このような事故を防ぐためには，人間による視認性に頼るだけではなく，高度運転支援システム（ADAS）で使われているようなカメラなどのセンサを用いて二輪車を検知し運転者に知らせる機能が効果的であると考えられる．本研究では四輪車に車載される可視光カメラの映像から，物体検出手法 YOLO を用いて自動二輪車を検出することを考え，その際の検出精度を向上させる方策について検証した．まず物体検出モデルの学習に用いる画像データセットを作成するため，YOLO でよく使われる COCO データセットに含まれる自動二輪車が写った画像 3018 枚を用意した．COCO データセットであらかじめ用意された二輪車を認識するための学習したモデルでは，交通環境にない二輪車も対象にしている．これに対して，二輪車の車体全体が映った各画像に対してフルカウルやアメリカンなどの車種のカテゴリ毎に異なるラベルを付与し，より取りこぼしなく二輪車を検出できるかを検証した．このモデルの他に，車種でカテゴリを分けないシンプルな motorcycle ラベルのみのデータセットも用意した．これらを用いて静止した二輪車を可視光カメラを設置した四輪車で移動し続けながら撮影した映像に対する物体検出を実施し，二輪車を検出できた際の四輪車から二輪車までの距離を計測した．その結果，motorcycle データセットを学習したモデルは COCO データセットを学習したモデルと比較すると検出距離が向上したことが確認できた．一方，車種カテゴリ毎に分けたデータセットにおいて検出距離の向上は確認できなかった．

1. はじめに

警視庁が発表した二輪車の交通死亡事故統計（令和元年中）[1] によれば，令和元年中の東京都内の自動二輪車乗車中の事故類型別交通死亡事故の割合は，単独に次いで右折時が多い結果となっている．同様に過去 5 年平均では単独，右折時に次いで出会い頭が多くなっている．

また，財団法人 交通事故総合分析センターが発行したイタルダ・インフォメーション [2] によると，表 1 に示すように，2010 年における自動二輪車が第 2 当事者で事故類型が出会い頭または右折時事故の場合，第 1 当事者の人的事故要因の 8 割以上は発見の遅れであった．

以上のことから自動二輪車と自動四輪車との事故を減らすためには，四輪ドライバーからの自動二輪車の視認性を上げることが重要であると考える．

一方で近年，センシングデバイスの小型化や低価格化が進み，人の目だけでなく機械を用いることで人の目では視認しにくいものを検出し，ドライバーのサポートを行う先進運転支援システム：ADAS（Advanced Driver-Assistance Systems）とよばれる多数のセンサを用いるシステムの普及が進んでいる．しかし，現状として歩行者や自転車などの検知を行う研究は多いが二輪車を対象としたものは少ない．そこで，可視光カメラの映像に映る自動二輪車を物体検出手法を用いて検知し，ADAS が四輪ドライバーへの二輪車検知を通知することで自動二輪車と四輪車の交通事故が減らせるのではないかと考えた．

本研究では，可視光カメラ映像中の二輪車に対する物体検出において，物体検出モデルの学習に用いる独自の画像データセットを複数用意し，それぞれのデータセットのラベル付与方法を変化させ，モデルの二輪検出性能が向上す

表 1　二輪車の出会い頭または右折時事故の人的要因 [2]

	出会い頭	右折時
発見の遅れ	85%	87%
判断の誤り	10%	12%
操作上の誤り	5%	1%

[1] 静岡大学大学院総合科学技術研究科
Shizuoka University
[2] 静岡大学情報学部情報科学科
Shizuoka University
[a)] k-nakajima@kitanilab.org
[b)] t-kitani@kitanilab.org

ⓒ 2021 Information Processing Society of Japan

るかを検証する．

2. 関連研究

2.1 対向車の運転者からの二輪車の視認性に関する関連研究

文献 [3] では，運転者が事故に関連する対象物を交通環境の中で検出できたかどうかを主に夜間の事故状況を再現して多数ケーススタディをしている．ケーススタディには二輪車が相手のケースについての実験と考察が行なわれており，接近する二輪車のヘッドライトが電柱などで遮られるときにハロを起こしたり 1 つのヘッドライトが 2 つに見えるなどの状況が報告されている．

文献 [4] では，二輪車と四輪車のヘッドライトの被視認性について 6 台の二輪車の実車を用いた検証を行なっている．四輪車のヘッドライトに比べて二輪車のそれの被視認性を定量化した結果著しく低いことが示されている．二輪車に昼間走行灯（デイライト）を装着することで知覚距離を有意に伸ばせることも示している．

文献 [5] では，二輪車の多くのヘッドライトは 1 灯式で四輪車に比べての幅が狭く被視認性が悪いため，9 台の二輪車のヘッドランプのビームパターンを測定して，どの程度の範囲を照らすことができるのかを検証している．

文献 [6] では，夜間の衝突シナリオにおける運転者の応答を評価する方法について述べられている．この研究で得られた結果の主たる内容は，ヘッドライトの照度とドライバーの応答距離を相関四輪車と比較すると著しく低いということがわかる．

2.2 YOLO を用いた道路上の物体検出に関する研究

文献 [7] では，交差点を撮影した動画像から YOLO を用いて交通量と車両走行軌跡の計測を行っている．交差点付近の電柱上部に設置されたカメラで撮影した動画像を利用し，1 フレームごとに YOLO での処理及びトラッキングを行うアルゴリズムを構築することで交通量と車両走行軌跡を計測することができることを確認した．車種別に計測された車両に自動二輪車も含まれているが，自動二輪車だけに特化したチューニングはなされていない．

文献 [8] では，サッカー競技におけるリアルタイム選手識別のため，YOLO を用いてサッカー選手の背番号を認識する手法を提案した．認識するクラスは 1 番から 11 番までの 11 クラスとし，画像枚数は各クラス約 400 枚，合計約 4000 枚で学習を行い，1 番から 11 番まで合計 363 枚の画像で評価を行った．予測の信頼度の閾値 0.3 にすることで画像 1 枚あたり約 0.29 秒，F 値 0.781 の精度で識別が可能であり，識別クラスの細分化による有効性を示した．

2.3 自動二輪車検出に関する研究

文献 [9] では，四輪車後方の車載カメラから自動二輪車を検出，自動二輪車ライダーの人体骨格情報からライダーの姿勢を推定し，そこから自動二輪車の傾きや向きを推定する手法を提案した．提案手法ではまず，車載カメラの画像情報から YOLO により自動二輪車を検出し，人体骨格推定ライブラリ OpenPose[10] により人体スケルトン推定を行い，得られたスケルトン情報に対し人体モデルのテンプレートマッチングを用いて自動二輪車ライダーを推定する．そこから人体スケルトンから得られる関節部を特徴点として，自動二輪車ライダーの三次元モデルと対応する関節座標を比較，自動二輪車ライダーの姿勢角を推定する．実際に自動二輪車を走行させて動画を撮影した実験では，自動二輪車ライダーの大部分が写っている場合には平均誤差が 10° 前後に収まり，自動二輪車ライダーが車体に隠れる場合は平均誤差が約 20° に収まる結果となった．カメラからの YOLO を用いた自動二輪車の検出については多くは触れられていない．

3. 二輪車検知精度のための学習データのカテゴリ分け設計手法

3.1 物体検出手法 YOLO

YOLO とは You Only Look Once の略で，深層学習を利用した物体検出手法である．YOLO は深層学習フレームワーク darknet を使用して実装されており，これらは GitHub[*1] 上でオープンソースとして公開されている．また同サイト上では COCO データセット[*2] で学習済みの物体検出モデルが提供されている．YOLO の特徴は処理が高速な点で，「検出」と「識別」を同時に行っている．以下，YOLO の検出の仕組みについて [11] より引用する．

図 1 のように，YOLO はまず入力画像を S × S のグリッドに分割する（図中左）．次に，それぞれのグリッドに対し B 個のバウンディングボックスと信頼度を推測する（図中中央上）．推測したバウンディングボックスに物体が含まれている確率を $Pr(Object)$ ，推測したバウンディングボックスと正解データとの重なり具合を $IOU^{\text{truth}}_{\text{pred}}$ とすると，信頼度は式 (1) で表される．

$$Pr(Object) \times IOU^{\text{truth}}_{\text{pred}} \tag{1}$$

同時に，それぞれのグリッドで C 個のクラスについて条件付きクラス確率を推測する（図中中央下）．条件付きクラス確率は式 (2) で表される．

$$Pr(Class^{i}|Object) \tag{2}$$

最後に，式 (1) と式 (2) を掛け合わせることにより，最終的な信頼スコアを得る（図中右）．

[*1] https://github.com/AlexeyAB/darknet
[*2] https://cocodataset.org/

$$Pr(Class^i|Object) \times Pr(Object) \times IOU^{\text{truth}}_{\text{pred}} = Pr(Class_i) \times IOU^{\text{truth}}_{\text{pred}} \quad (3)$$

この信頼スコアは，各バウンディングボックスのクラスの予測確率とバウンディングボックスがどれだけ正確に物体を囲えているかを表す．

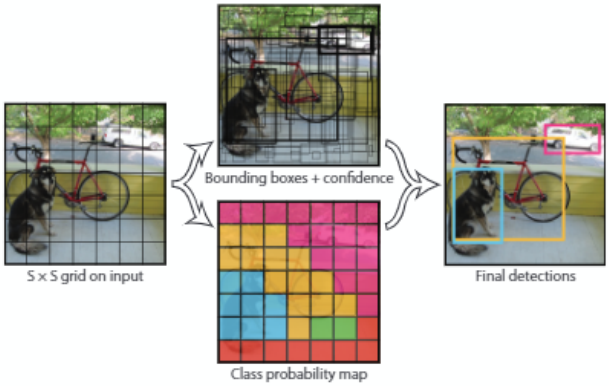

図 1 YOLO における検出の仕組み ([11] より抜粋)

YOLO は mAP63.4%，45fps での検出が可能であり，PASCAL VOC 2007[12] におけるテストで，Fast R-CNN の背景の誤検出が全体の検出の 13.6%であったのに対し，YOLO は 4.75%であった [11]．このように YOLO では背景と物体の区別がしやすいこと，そのネットワーク構成から独自に用意したデータセットでの学習が容易といった特徴がある．本研究の最終目的は，独自に学習したモデルを用いて車載カメラで撮影された道路上の映像をリアルタイムに処理することであるので，物体検出アルゴリズムとして YOLO を採用するのが適していると考えた．

3.2 学習データのカテゴリ分けの提案

本研究では，独自に作成したバイク画像データセットを用いて YOLO のアルゴリズムによる物体検出モデルを学習する手法を提案する．

COCO データセットは画像内の物体に対し種類ごとのラベルがあらかじめ付与されている画像データセットであり，自動二輪車を含む 80 種類のラベルが付与されている．このデータセットにおいて自動二輪車のラベルが付与された画像を確認すると，図 2 に示すような自動二輪車のミラーのみを撮影した画像など，交通において他車両から見られる自動二輪車とはいえない画像も含まれているのが判明した．このように写る自動二輪車の姿は，車両に搭載される可視光カメラ映像に対して物体検出することを考慮すると，モデルが学習する必要はないと考えた．

そこで提案手法では，まず COCO データセット中の画像で自動二輪車のラベル”motorcycle”が付与された画像に対し，前述の学習に利用しない姿で自動二輪車が写る

図 2 除外する画像の例（COCO データセットより抜粋）

画像を排除したデータセットを作成した．さらにそこから”motorcycle”クラスを自動二輪車のタイプごとに区分してクラス分けしたデータセットを作成した．これらのデータセットを用いて物体検出モデルの学習を行なうことで，認識精度を向上させられるとの仮説を立て検証を行なう．提案手法のキーアイデアのイメージを図 3 に示す．

真のクラスの範囲を緑，誤検出の対象となる自動二輪車に含まれないクラスを青丸，提案手法において検出対象となる自動二輪車のタイプ別のクラスを赤丸とすると，”motorcycle”の枠組みの中でタイプを区分することで真値から外れることはあっても，検出漏れを減らす上で”bicycle”や”buggy”のような自動二輪車でないものの誤検出を減らせるのではないかとの仮説を立てた．

実際の YOLO におけるデータセットの作成イメージを図 4 に示す．本来であれば，ここでは自転車など自動二輪車と誤検出しそうなものも含んだデータセットを作成して比較すべきだが，本研究ではその比較を行わずに基礎検証に留める．

クラス分けする対象となる自動二輪車のタイプは見た目の違いから「フルカウル」，「ネイキッド」，「アメリカン」，「オフロード」，「ビッグスクーター」，「スクーター」，「車種不明もしくは車両の一部」の 7 クラスに分ける．

4. 提案手法の評価実験

4.1 物体検出モデルの作成

4.1.1 学習に使用したデータセット

3.2 節にて提案した手法をもとにデータセットを作成した．学習に使用したデータセットは以下の 3 種類である．

- COCO データセット：自動二輪車のクラス”motorcycle”を含む計 80 クラスのデータセット
- motorcycle データセット：COCO データセットから”motorcycle”を含む画像を抜き出し，前述の学習に利用しない姿で自動二輪車が写る画像を排除した

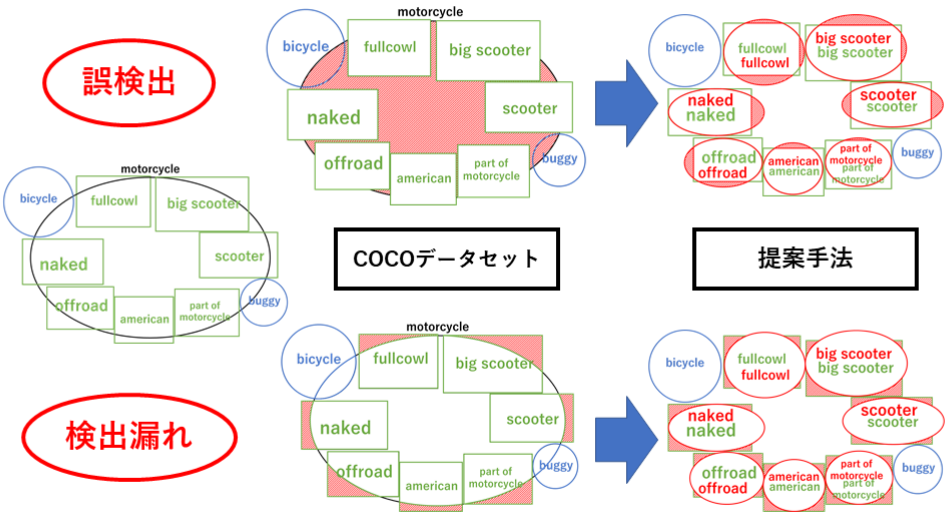

図 3 提案手法イメージ図

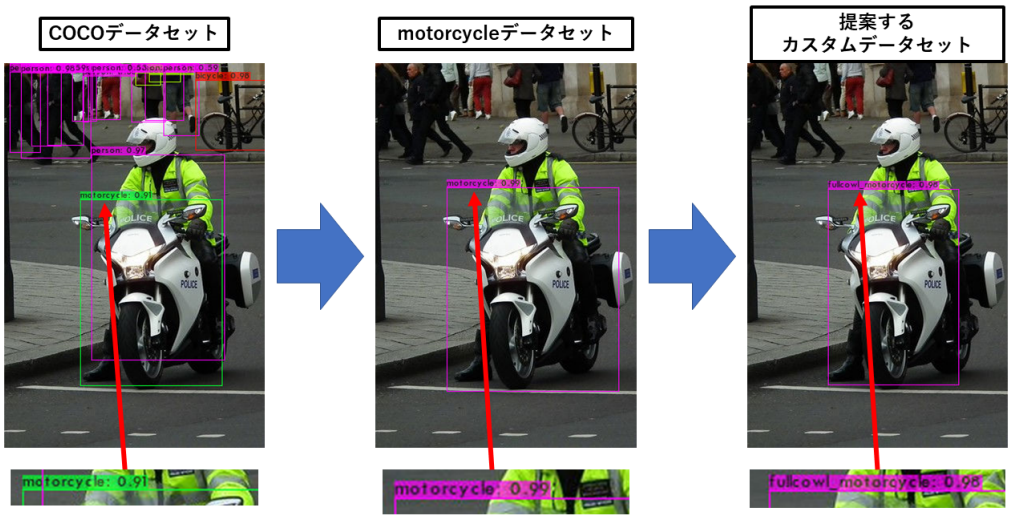

図 4 学習画像へのラベル付与例（COCO データセットより抜粋）

データセット

- カスタムデータセット：motorcycle データセットに対し，さらに詳細なタイプごとへ自動二輪車をクラス分けしたデータセット

カスタムデータセットにおけるクラスは「fullcowl_motorcycle」，「naked_motorcycle」，「american_motorcycle」，「offroad_motorcycle」，「big_scooter」，「scooter」，「part of motorcycle」の 7 つである．

また各データセットに含まれる画像を学習・評価用に 8:2 の割合で分割した．motorcycle，カスタムデータセットの画像枚数は 3018 枚であり，このうち 2415 枚を学習に用いた．

4.1.2 ハイパーパラメータ設定

学習に使用した YOLO のバージョンは YOLOv3-tiny[13] とした．学習回数は深層学習フレームワークである darknet の GitHub を参考にし，識別するクラス数× 2000 回（ただし 6000 回を下回らない）とした．つまり，COCO データセットは 80 クラス× 2000 回=160000 回，motorcycle データセットは 1 クラス× 2000 回=2000 回<6000 回より 6000 回，カスタムデータセットは 7 クラス× 2000 回=14000 回とした．学習率とは一度の学習でモデルの各値をどれだけ変更するかを示したハイパーパラメータの 1 つであり，深層学習における性能に大きく影響する．今回の学習では初期設定のものを利用した．その詳細は，初回から総学習回数× 0.8 回までは 0.001，総学習回数× 0.8 から総学習回数× 0.9 回までは 0.0001，総学習回数× 0.9 から学習終了までは 0.00001 とした．学習回数以外のハイパーパラメータは初期設定のものを利用した．

ⓒ 2021 Information Processing Society of Japan

4.2 物体検出モデルの評価実験

4.2.1 目的

3 種類のデータセットで学習した物体検出モデルを比較し，提案手法により自動二輪車検出率が向上することを示す．

4.2.2 評価方法

各データセットに含まれる画像を学習・評価用に 8:2 の割合で分割し，評価用の画像で各モデルの適合率，再現率，F 値，AP を算出する．COCO データセットで自動二輪車が含まれる画像は 3661 枚であり，このうち 732 枚を評価に用いた．また，motorcycle，カスタムデータセットの画像枚数は 3018 枚であり，このうち 603 枚を評価に用いた．

IoU の閾値を 0.5，信頼スコアの閾値を 0.25 としてモデルの評価を行った．カスタムデータセットについては，自動二輪車を検出することが目的であり，正しく分類分けすることは今回の目的ではないので，図 5 のように評価対象の自動二輪車を違うクラスとして検出していた場合でも TP（TruePositive）としてカウントした．

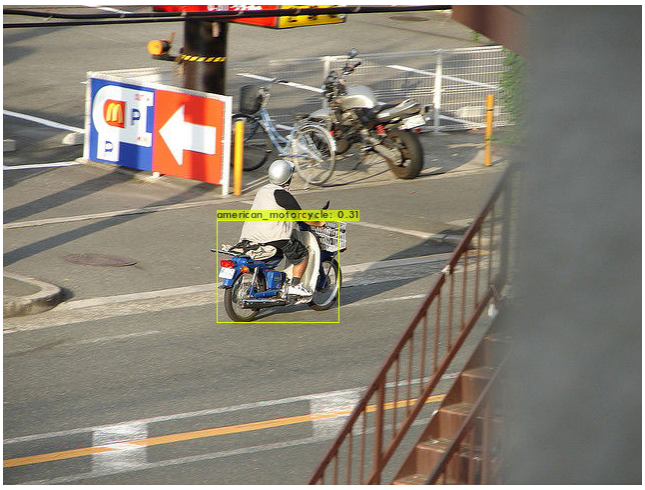

図 5 異なるクラスでも TP とみなす例（COCO データセットより抜粋）

4.2.3 実験結果

評価結果から適合率と再現率が最も高かった二つのみ抜粋して表 2 に示す．なお，COCO データセットは”motorcycle”のクラスの結果のみ抜粋した，

4.2.4 考察

結果から，motorcycle データセットでは COCO データセットに比べ，適合率は 74%から 82%に，再現率は 53%から 65%に向上したことが確認できる．カスタムデータセットでは同様に適合率は 74%から 89%に，再現率は 53%から 64%に向上したことが確認でき，提案手法を用いることで誤検出や検出漏れを減らせたと言える．

カスタムデータセットの誤検出や検出漏れについて考察する．まず誤検出について，図 6 に示すように COCO データセットでは奥に座っている人を”mototrcycle”と誤検出しているが，motorcycle データセットとカスタムデータセットでは検出をしておらず，誤検出を減らせたと言える．

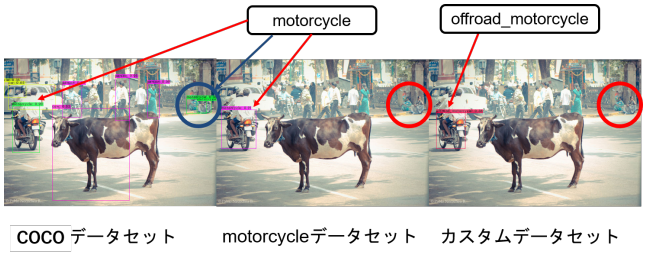

図 6 提案手法により誤検出を減らせている例（COCO データセットより抜粋）

しかし，図 7 に示すように，motorcycle データセットやカスタムデータセットでも人や自転車を誤検出している画像があった．原因について，人の誤検出は学習画像において人も含んだ矩形で学習されているものがいくつかあるためだと考える．また自転車の誤検出は図 8 に示すような形が自転車に似た自動二輪車もデータセットに含まれていたためだと考える．カスタムデータセットに”bicycle”のクラスも追加すべきか今後検討が必要である．

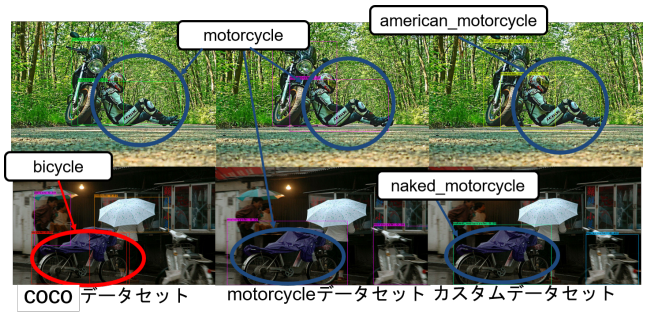

図 7 提案手法における誤検出の例（COCO データセットより抜粋）

図 8 自転車に似た自動二輪車（COCO データセットより抜粋）

次に検出漏れについて，結果からもわかる通り提案手法では検出漏れは減らせていたと考えるが，図 9 のように遠い場所で小さく映った自動二輪車や車体がカメラに対して

表 2　モデル評価結果

	物体検出モデル	指標が最大となった時の学習回数	適合率 (%)	再現率 (%)	F 値	AP (%)
適合率最大時	COCO データセット	75000	74	47	0.57	53
	motorcycle データセット	4000	82	54	0.65	70
	カスタムデータセット	1000	89	16	0.27	88
再現率最大時 (※)	COCO データセット	147000	67	53	0.59	55
	motorcycle データセット	5000	74	65	0.69	72
	カスタムデータセット	9000	79	64	0.70	81

※この時，すべてのモデルにおいて F 値も最大

縦向きになっている画像では検出漏れが多く確認できた．遠い場所の自動二輪車については，認識に有効な画像内のピクセル数が少ないためだと考える．縦向きのケースでは，横向きに映っている場合と比べてタイヤやフレームが映らないことが多く，自動二輪車の特徴が損なわれることが原因だと考えられる．また，全般的な検出漏れについて，カスタムデータセットでは自動二輪車に対して七つのクラスが割り当てられているので，他二つのデータセットと比べてクラス一つあたりの学習画像枚数が少なかったことが検出漏れにつながったのではないかと考えられる．カスタムデータセットにおいて各クラスの学習画像枚数を増加させ，さらなる検証が必要である．

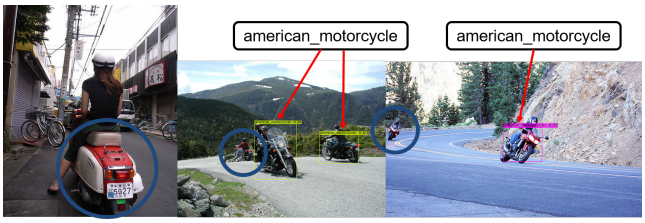

図 9　提案手法における検出漏れの例（COCO データセットより抜粋）

5. 提案手法における自動二輪車検出距離評価実験

5.1 実験の目的

車載カメラ映像を想定した動画に対し，物体検出モデルを用いた自動二輪車の物体検出を行う．このときモデルが二輪車を検出した際に，どれほどの距離から検出したかを計測する．そして提案手法を適用することで検出距離が向上するかを検証する．

5.2 目標

自動四輪車が一般道を時速 50km で走行する際の停止距離が 33m であるので，これより長距離での二輪車検出が可能ならば実使用が可能な性能であると考えられる．よって今回目標とする検出距離は 33m とする．

5.3 実験方法

一般財団法人 日本自動車研究所（JARI）の試験場にて，四輪車に車載された赤外線カメラによる自動二輪車撮影実験を行った．

撮影手順の概要を示す．動画撮影用のカメラを搭載した四輪車は，100m 離れたところにライダーが乗車したまま静止した自動二輪車に向かって時速 10km 弱で近づいていき，車載カメラに自動二輪車が写らなくなったところで停止した．また四輪車と二輪車の距離を計測するため，自動二輪車の撮影と同時に運転席側扉付近に設置したカメラを用いて，四輪車がある車線に沿って敷かれたメジャーを撮影した．二輪車及び四輪車のヘッドライトはロービームで点灯させた．

メジャーを撮影した動画からの距離算出は次のように行った．まず，メジャー動画から目視で 5m，10m，...，と 5m おきに現在のフレームを確認し，5m を 5m 間のフレーム数× 1 フレームあたりの時間で除算して 1 フレームあたりの距離を算出する．そこから 5m 間は等速であると仮定し線形補完することで距離を算出した．5m おきのフレームの確認は目視で行ったので有効数字は 1m とする．

5.3.1 使用機材

実験で使用した機材を表 3 に示す．

車載カメラは図 10 に示すように，ボンネットとルーフ上に設置し，ボンネットには地面から約 85cm でフロント先端部に，ルーフ上には地面から約 150cm でフロント先端部からレンズまで 220cm の位置に取り付けた．

図 10　カメラ設置位置

表 3　実験で使用した機材

機材の種類	設置位置	用途	製品名	個数
RGB カメラ	四輪車	二輪車の撮影	GoPro HERO9 Black	2
RGB カメラ	四輪車	距離計測用メジャーの撮影	insta360	1
四輪車	-	-	MAZDA AXELA	1
自動二輪車	-	撮影対象（中型二輪車）	SUZUKI V-Strom250	1
原付	-	撮影対象（原付スクーター）	SUZUKI Let's4 pallet	1

5.3.2　実験環境

実験環境として約 16 万平方メートルの敷地に, 雨, 霧, 日照等の環境条件を再現可能な屋内施設「特異環境試験場」, 様々な交差点形状を再現可能な「多目的市街路」にて実験を行った．環境条件として以下の 4 つの条件を設定した．

- 屋内: 特異環境試験場内において，天井照明を点灯した環境
- 霧: 特異環境試験場内において，天井照明を点灯し，さらに霧を発生させた環境
- 日照: 特異環境試験場内において，天井照明を点灯し，さらに撮影車両と同一車線上を日照装置で照らした環境
- 屋外: 多目的市外路において，天気は晴天の環境

5.3.3　実験構図

先の項で説明した環境において, 四輪車に車載された可視光カメラでそれぞれ 4 つの構図を撮影した．撮影した構図は図 11 に示すように，自動二輪車が四輪車と同じ車線の前方で停止している構図「追従」，自動二輪車が四輪車の対向車線で停止している構図「対向」，交差点において四輪車の右手側で自動二輪車が停止している構図「右から」，交差点において四輪車の左手側で自動二輪車が停止している構図「左から」の 4 つである．

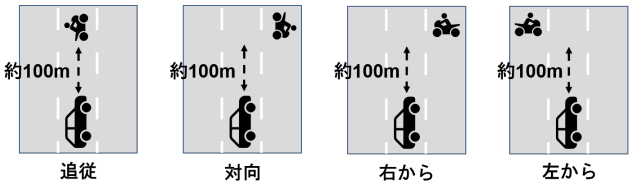

図 11　撮影構図

5.4　評価方法

5.4.1　検出距離の判定基準

検出距離について，最初に 9 フレーム連続で二輪車が検出されたときの，1 フレーム目における二輪車と四輪車の距離を検出距離とする．

5.4.2　使用した物体検出モデル

この評価においては 4.1.1 において作成したデータセットを用いて，YOLOv4-tiny[14] を用いて作成したモデルを評価に使用する．学習時のパラメータについては 4.1.2 と同様である．

5.5　実験結果

V-Strorm 250 に対する検出結果について，ボンネットのカメラ映像に検出をかけた結果を表 4，ルーフのカメラ映像に検出をかけた結果を表 5 に示す．また，Let's 4 に対する検出結果について，ボンネットのカメラ映像に検出をかけた結果を表 6，ルーフのカメラ映像に検出をかけた結果を表 7 に示す．表中の検出距離は車載カメラから自動二輪車までの距離，信頼スコアはクラスの予測の正確さであり，YOLO での検出時の信頼スコアの閾値は 0.25 とした．また数値が記入されていない箇所については，9 フレーム連続での二輪車検出が無かったことを意味する．

5.6　考察

5.6.1　学習に使用したデータセットによる差

データセット間を比較すると，構図や環境条件によらず motorcycle データセットで学習したモデルによる検出距離が大きい傾向があることが確認できる．一方でカスタムデータセットで学習したモデルの検出距離は，他のモデルと比較して検出距離が大きいとはいえない．3.2 節で述べたように学習に利用しない姿で自動二輪車が写る画像を排除することは，二輪車の検出距離を向上させることは可能であるが，それをさらに車種カテゴリに細分化することで検出距離を向上させることはできないと考えられる．

5.6.2　カメラ設置場所による検出距離の差

構図やモデルによって数 m の差が出ているものもあるが，今回の結果からはどちらの方が明確に検出距離が伸びたということはいえない．ただし，ルーフに設置したカメラ映像の問題点として，図 12 に示すようにボンネットに設置したカメラを誤検出していた．公道を走行する際にこのようなカメラは取り付けられていないが，誤検出の可能性を少しでも減らすことを考慮すると車載カメラは余計なものが映りこまないようにする配慮が必要だと考えられる．

5.6.3　構図による差

ルーフに設置したカメラ映像において屋内の環境条件下にある V-Strorm 250 に対する検出結果を図 13 に示す．このグラフから，右から・左からと追従・対向の構図間で検出距離に差があることが確認できる．その理由として，まず学習に用いた画像において，二輪車が写る角度に偏りがあったということが考えられる．また同じ距離において二輪車の前後よりも左右の姿の方が，画像中に占めるピクセ

ⓒ 2021 Information Processing Society of Japan

表 4　V-Strorm 250 に対する検出結果（ボンネット）

環境条件	撮影構図	COCO データセット		motorcycle データセット		カスタムデータセット	
		検出距離 [m]	信頼スコア	検出距離 [m]	信頼スコア	検出距離 [m]	信頼スコア
屋内	追従	-	-	-	-	10	0.37
	対向	13	0.36	14	0.36	12	0.31
	右から	16	0.32	25	0.27	22	0.34
	左から	18	0.28	21	0.33	14	0.33
霧	追従	13	0.35	21	0.3	17	0.34
	対向	-	-	9	0.57	8	0.68
	右から	-	-	-	-	-	-
	左から	8	0.42	19	0.26	9	0.51
日照	追従	-	-	-	-	-	-
	対向	11	0.48	15	0.26	12	0.55
	右から	21	0.21	25	0.27	22	0.31
	左から	12	0.36	15	0.37	11	0.47
屋外	追従	11	0.28	15	0.37	11	0.37
	対向	14	0.29	18	0.31	14	0.29
	右から	26	0.32	28	0.28	27	0.28
	左から	19	0.39	19	0.34	19	0.28

表 5　V-Strorm 250 に対する検出結果 (ルーフ)

環境条件	撮影構図	COCO データセット		motorcycle データセット		カスタムデータセット	
		検出距離 (m)	信頼スコア	検出距離 (m)	信頼スコア	検出距離 (m)	信頼スコア
屋内	追従	15	0.27	14	0.31	12	0.47
	対向	15	0.32	16	0.25	14	0.37
	右から	27	0.36	31	0.28	22	0.27
	左から	20	0.39	20	0.27	23	0.3
霧	追従	-	-	19	0.33	14	0.3
	対向	7	0.65	7	0.34	5	0.94
	右から	-	-	15	0.45	-	-
	左から	-	-	14	0.37	7	0.4
日照	追従	-	-	-	-	-	-
	対向	15	0.25	18	0.41	14	0.27
	右から	28	0.29	33	0.25	19	0.27
	左から	12	0.31	20	0.27	11	0.29
屋外	追従	10	0.31	12	0.27	12	0.27
	対向	12	0.28	17	0.4	17	0.27
	右から	26	0.29	33	0.25	24	0.72
	左から	23	0.26	29	0.34	17	0.33

図 12　ルーフに設置したカメラ映像における誤検出例

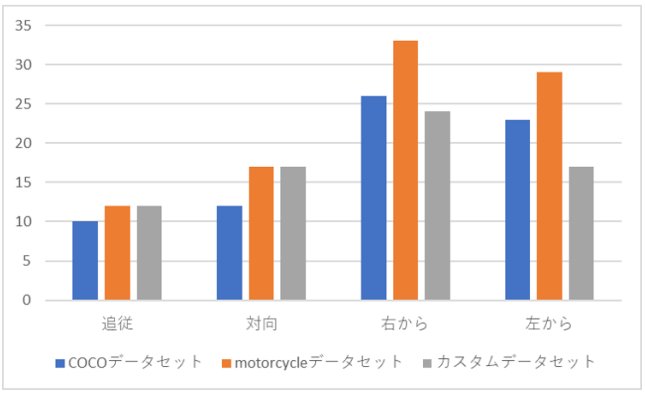

図 13　屋外環境下で撮影したルーフカメラ映像における各構図の V-Strorm 250 に対する検出距離

ル数が多いため，右から・左からの構図の方が検出距離が伸びたことが考えられる．

5.6.4　9 フレーム連続で二輪車検出ができなかった条件について

結果から，日照の環境条件下の追従の構図においては全て 9 フレーム連続で二輪車を検出できていないことが確認できる．また霧の環境条件下の右からの構図においても，9 フレーム連続での二輪車検出が困難であることが確認できる．前者については，図 14 に示すように，日照装置と

表 6　Let's 4 に対する検出結果（ボンネット）

環境条件	撮影構図	COCO データセット		motorcycle データセット		カスタムデータセット	
		検出距離 [m]	信頼スコア	検出距離 [m]	信頼スコア	検出距離 [m]	信頼スコア
屋内	追従	-	-	-	-	-	-
	対向	10	0.29	13	0.26	12	0.35
	右から	11	0.33	18	0.31	13	0.27
	左から	11	0.57	11	0.5	12	0.82
霧	追従	8	0.53	16	0.35	14	0.37
	対向	7	0.34	12	0.49	9	0.48
	右から	-	-	-	-	-	-
	左から	6	0.27	11	0.29	5	0.43
日照	追従	-	-	-	-	-	-
	対向	10	0.37	14	0.28	12	0.5
	右から	18	0.57	21	0.25	13	0.41
	左から	9	0.37	10	0.31	8	0.4
屋外	追従	13	0.27	17	0.33	17	0.32
	対向	11	0.42	12	0.28	12	0.42
	右から	17	0.44	17	0.47	12	0.36
	左から	16	0.35	24	0.27	17	0.27

表 7　Let's 4 に対する検出結果（ルーフ）

環境条件	撮影構図	COCO データセット		motorcycle データセット		カスタムデータセット	
		検出距離 [m]	信頼スコア	検出距離 [m]	信頼スコア	検出距離 [m]	信頼スコア
屋内	追従	-	-	12	35	12	0.25
	対向	9	0.68	13	0.63	11	0.38
	右から	14	0.36	22	0.26	27	0.4
	左から	10	0.46	20	0.3	19	0.43
霧	追従	-	-	15	0.38	13	0.39
	対向	10	0.3	10	0.36	3	0.66
	右から	-	-	-	-	-	-
	左から	-	-	10	0.34	5	0.72
日照	追従	-	-	-	-	-	-
	対向	11	0.31	17	0.25	13	0.32
	右から	13	0.3	28	0.3	23	0.29
	左から	8	0.26	19	0.33	9	0.65
屋外	追従	-	-	17	0.43	14	0.26
	対向	12	0.28	14	0.31	11	0.25
	右から	16	0.27	18	0.36	15	0.44
	左から	13	0.3	39	0.33	14	0.28

二輪車が同一車線にあることが原因だと考えられる．

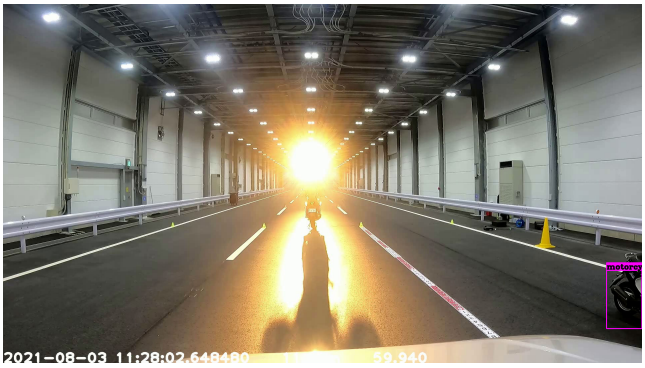

図 14　日照装置によるカメラ映像への影響

また後者については図 15 で示すように，右からの構図は他の構図と比較すると 1 車線分カメラから遠い位置に二輪車が存在するため，カメラで撮影する際により強く霧の影響を受けることが考えられる．

図 15　右からの構図の二輪車位置

6. まとめと今後の課題

本研究では, 物体検出手法 YOLO を用いて識別するクラスを自動二輪車に限定したデータセット, そこから自動二輪車をタイプ分けしたデータセットを学習することで, カ

ⓒ 2021 Information Processing Society of Japan

メラからの自動二輪車検出率を向上させる手法を提案し検証を行った.

モデルの評価実験の結果, 識別するクラスを自動二輪車に限定したデータセットでは従来の YOLO のデータセットに比べ, 適合率は 74%から 82%に, 再現率は 53%から 65%に向上することが確認できた. また, そこから自動二輪車をタイプ分けしたデータセットによる学習モデルでは, 適合率は 74%から 89%に, 再現率は 53%から 64%に向上することが確認できた.

検出距離把握実験の結果からは, 識別するクラスを”motorcycle”一つに限定することで自動二輪車を検出できる距離が伸び，一部の条件下では目標である検出距離 33m を達成することが可能な物体検出モデルが作成できた．一方,”motorcycle”クラスをさらに細分化しても検出できる距離は改善されないことを確認した.

今後の課題として，まず学習に用いる画像を増やすことが挙げられる．また，5 節において検出距離によるモデル評価を行ったが，検出距離を判断する基準を 9 フレーム連続とし，信頼スコアの閾値を 0.25 とした．この評価基準の妥当性について検討する必要がある．

謝辞 本研究は 2019〜2021 年度 JARI 委託研究「ITS/AD 環境における二輪車課題の抽出と対応検討」による支援を受けたものです。

参考文献

[1] 警視庁：二輪車の交通死亡事故統計（2020 年中）入手先 ⟨https://www.keishicho.metro.tokyo.lg.jp/kotsu/jikoboshi/nirinsha/2rin_jiko.html⟩ (2021.10.27).
[2] 財団法人 交通事故総合分析センター：イタルダ・インフォメーション 二輪車事故の特徴 –見落としに注意–, , No. 91, Nov (2011)
[3] E. Klein and G. Stephens: *Visibility Study - Methodologies and Reconstruction*, Future Transportation Technology Conference & Exposition, SAE International (1992).
[4] N. Haferkemper, J.H. Sprute, C. Schiller, and T.Q. Khanh: *The Effect of LED Daytime Running Lights on Motorcycle Conspicuity and Detection Distance Estimation - Latest Test Results*, SAE 2010 World Congress & Exhibition, (2010).
[5] G. de Paula Brito, J.A.F. Borges, and G.F.G. Nogueira: *Analysis of Blind Areas in Different Categories of Vehicles Considering the Evolution of Projects and Legislation*, 23rd SAE Brasil International Congress and Display, (2014).
[6] W.T. Neale, N. Mckelvey, D. Pentecost, and D. Koch: *Motorcycle Headlamp Distribution Comparison*, WCX World Congress Experience, SAE International, (2018).
[7] 中島 浩平, 岩崎 洋一郎, 竹原 洋志, 宮田 俊彦, 倉本 俊昌, 北島 俊孝, 瀬戸口 恵：物体検出アルゴリズム YOLOv3 を用いた交通量と車両走行軌跡の自動計測，電気関係学会九州支部連合大会講演論文集, Vol. 2019, pp. 61-62.
[8] 梶原 弘一郎, 大城 英裕, 行天 啓二, 高見 利也: 背番号認識への物体認識型深層学習の適用，電気関係学会九州支部連合大会講演論文集, Vol. 2018, pp. 165-166.
[9] 出水 利治, 中村 嘉隆, 稲村 浩, 木谷 友哉: 後方二輪車挙動把握のための人体スケルトン検出を用いた二輪車姿勢推定手法, 情報処理学会研究報告, Vol. 2019-ITS-77, No. 7, pp. 1–6, May 2019.
[10] Tomas Shimon, Shih-En Wei, Yaser Sheikh, “OpenPose: Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields”, IEEE Transaction on Pattern Analysis and Machine Intelligence, Vol. 34, Issue 7, pp. 1444–1450, Dec. 2018.
[11] Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi, “You Only Look Once: Unified, Real-Time Object Detection”, arXiv:1506.02640 [cs.CV], 9 May 2016.
[12] Everingham, M. and Van Gool, L. and Williams, C. K. I. and Winn, J. and Zisserman, A., “The PASCAL Visual Object Classes Challenge 2007 (VOC2007) Results”, http://www.pascal-network.org/challenges/VOC/voc2007/workshop/index.html (2021/11/10)
[13] Joseph Redmon, Ali Farhadi, “YOLOv3: An Incremental Improvement” , arXiv:1804.02767 [cs.CV], 8 April 2018.
[14] Chien-Yao Wang, Alexey Bochkovskiy, Hong-Yuan Mark Liao, “Scaled-YOLOv4: Scaling Cross Stage Partial Network” , arXiv:2011.08036 [cs.CV], 16 Nov 2020.

ⓒ 2021 Information Processing Society of Japan