

深層学習を用いた二輪車の転倒に繋がる危険物の検出に関する研究

井上晴可[†]

山田明広[‡]

大阪経済大学情報社会学部[†]

大阪経済大学大学院経営情報研究科[‡]

1. はじめに

近年、自動運転の実用化に向けて自動車には多くの先進技術が搭載、開発されている一方、転倒の特性がある二輪車[1]は普及が遅れている。Webike が実施したアンケート[2]では、「バイクにおける転倒経験の有無」の質問に対して 1,032 人中 97%が転倒経験「あり」と回答している。また、転倒の要因として、立ちゴケ、スリップダウン、オーバーランの順で上位を占めていることがわかった。二輪車の転倒防止の研究[3]では、フライホイールを使用してジャイロ効果を用いた二輪車転倒防止装置の研究開発に取り組んでいるが、装置の後付けや小型化の課題が残る。一方、画像認識技術に着目すると、深層学習により著しく発展している。深層学習は、機械学習の一手法であり、音声認識、画像認識、自然言語処理などの多分野で使用されている。そこで、本研究では、画像認識技術である YOLOv5m(以下、YOLO)、DeepLab および YOLACT を用いて、前方の動画像から走行中の二輪車が転倒する恐れのある危険物を事前に検出する手法を提案する。実証実験の結果、YOLACT は遠方の危険物も高精度に検出できるという知見を得た。

2. 研究概要

本研究の流れを図 1 に示す。走行中のバイクが転倒する要因となる危険物として、障害物および路面状況の 2 つに着目し、落ち葉や枝などが集まっている部分 (以下、ブッシュ)、小石や砂が集まっている部分 (以下、砂利)、マンホールや消火栓 (以下、マンホール)、道路上の穴やデコボコした段差部分 (以下、段差) および水溜まりや水などで濡れている路面 (以下、濡れた路面) の 5 つを検出対象の危険物 (図 2) とする。そして、YOLO、DeepLab および YOLACT の 3 つの画像認識モデルを用いて危険物を検出

する。YOLO は、画像内の物体をバウンディングボックスで囲って検出する手法である。DeepLab は、画像内の対象とする物体をピクセル単位で分類するセマンティックセグメンテーション形式の手法である。YOLACT は、画像内の対象とする物体をインスタンス前景領域マスクおよび各物体インスタンスを区別するインスタンスセグメンテーション形式の手法である。なお、本研究では Google Colaboratory を用いて 3 つの学習モデルを実装する。

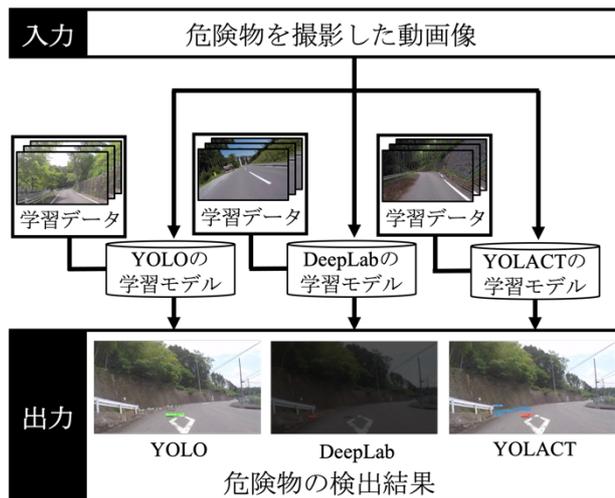


図 1 本研究の流れ

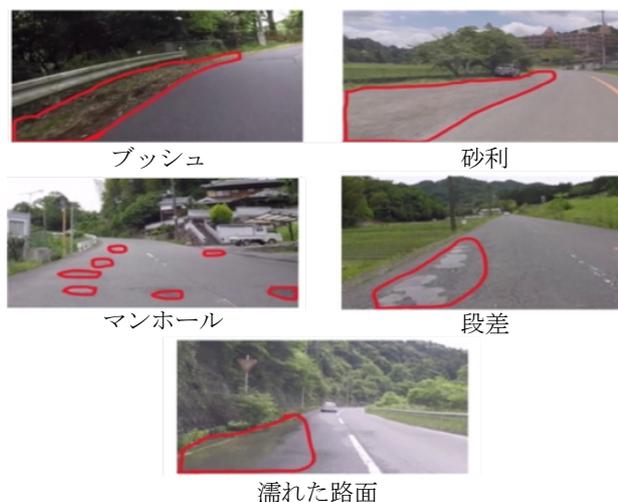


図 2 危険物の例

Research for Detecting Dangerous Objects Leading to Overturning of Motorcycle Using Deep Learning

[†] Haruka Inoue

Faculty of Information Technology and Social Sciences, Osaka University of Economics

[‡] Akihiro Yamada

Graduate School of Business Information System, Osaka University of Economics

3. 実証実験

実証実験では、YOLO, DeepLab および YOLACT の3つの画像認識モデルを対象に各モデルに必要な形式の学習データおよび学習モデルを生成し、5つの危険物に対する検出可否を検証する。

3.1 実験内容

本実験では、バイクの前方にGOPRO社HERO4のカメラを設置した。撮影条件を図3の通りに設定し、約150km走行して6時間30分弱の動画を撮影した。なお、3つのモデルでは、動画像から切り出した同一の画像を学習データ、検証データおよび評価データとし、全体で6,130枚の画像データを作成(表1)する。画像データに対してアノテーション作業は、Microsoft社が公開しているVoTT[4]を使用してデータセットを作成する。学習を実施した各モデルの学習所要時間を表2に示す。3つのモデルの検出精度は、評価データに対して正解ラベルを作成し、適合率、再現率およびF値により評価する。

3.2 実験結果と考察

実験結果を表3に示す。各モデルのF値を比較すると、YOLOおよびDeepLabに比べてYOLACTが高かった。DeepLabのF値が低いのは、遠方にある物体の検出に失敗することが要因として考えられる。また、YOLOではブッシュ、DeepLabではマンホール、段差のF値が低くなるのに対してYOLACTではすべての危険物を高精度で検出できた。各モデルの検出結果の一例を図4に示す。この例では、ブッシュ1、マンホール2となるのが正解であり、YOLACTがすべて正しく検出できたことがわかる。これらの結果より、3つのモデルでF値が最大のYOLACTは、遠方の危険物も検出できることがわかった。

4. おわりに

本研究では、YOLO, DeepLab および YOLACT の3つの画像認識モデルを用いて、二輪車にとって転倒の危険がある物体の検出精度を検証した結果、YOLACTが遠方の物体も高精度に検出できることがわかった。YOLOの物体検出手法では、検出対象の形状が不特定なため、検出領域が学習データに依存される課題が残る。今後は、危険物の種類の追加や異なる環境下での学習データを増やして検出精度の向上を図る。

参考文献

- [1] JAF: バイクのASV(先進安全自動車)技術, 入手先 <<https://jaf.or.jp/common/kuruma-qa/category-bike/subcategory-supplies/faq373>> (参照 2023-1-12) .
- [2] Webike: 転倒パターンを知る, 入手先 <https://www.webike.net/campaign/bigmachinexwebike_s3_vol4/> (参照 2023-1-12) .
- [3] 花妹尾大作, 古川修, 長谷川浩志, 間下博: ジャイロ効果を用いた二輪車転倒防止装置の開発, 交通・物流部門大会講演論文集, Vol.26 (2017) .
- [4] Github: VoTT, 入手先 <<https://github.com/microsoft/VoTT>> (参照 2023-1-12) .

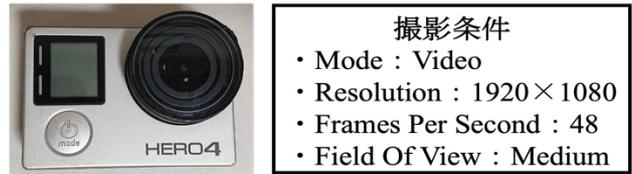


図3 撮影カメラ

表1 使用データ(枚)

危険物	学習用	検証用	評価用
ブッシュ	751	102	88
砂利	1,068	131	129
マンホール	1,182	145	140
段差	1,628	205	216
濡れた路面	275	30	40
全体	4,904	613	613

表2 学習時間

モデル	YOLO	DeepLab	YOLACT
時間	10時間 32分	12時間 58分	10時間 27分

表3 実験結果

危険物	YOLO	DeepLab	YOLACT
ブッシュ	0.591	0.822	0.817
砂利	0.789	0.813	0.836
マンホール	0.819	0.566	0.822
段差	0.882	0.413	0.820
濡れた路面	0.987	0.840	0.947
全体	0.800	0.665	0.829

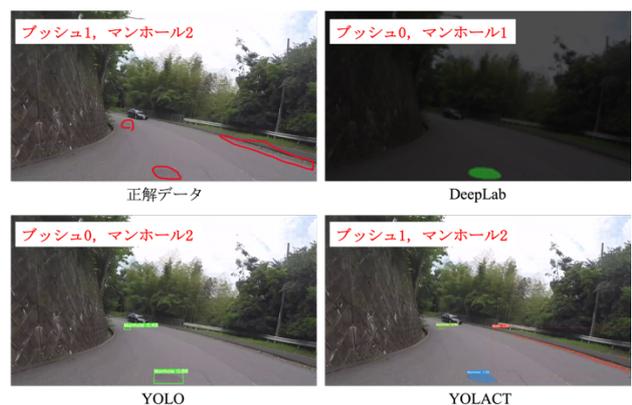


図4 検出結果の例