

# 物体検知アルゴリズムを用いた自転車交通流の検出に関する基礎的研究

## A Basic Study on Detection of Bicycle Traffic Flow Using Object Detection Algorithms

室蘭工業大学 理工学部創造工学科 ○学生員 湯島琉晴(Ryusei Yuzima)  
 室蘭工業大学大学院 工学研究科 学生員 瀧本康太(Kota Takimoto)  
 室蘭工業大学大学院 工学研究科 正会員 有村幹治(Mikiharu Arimura)

### 1. はじめに

我が国では歩行者、自転車及び自動車の安全性向上を目指し、自転車通行空間整備の一環として矢羽根(ブルーレーン)の整備が進められている。北海道札幌市においては「札幌都市部自転車通行位置の明確化の取り組み」に基づき、矢羽根型路面標示の設置が進められている。しかし、現在矢羽根整備効果の調査方法はアンケート調査やビデオカメラ動画の目視観測調査を主としており、汎用性が高い手法にはなっていない。

一方、今日 AI を用いた画像認識技術を利用した自動車交通量解析技術の導入が進んでいる。AI を用いた交通量解析は人手計測と比較したときの低価格性や安定性、年中の運用が可能であり有用性が高い手法といえる。しかし、AI を用いた画像認識技術はその有用性・汎用性の認知度に対し、自動車の交通量解析の運用にのみ留まっているというのが現状である。そこで、本研究では札幌市の矢羽根整備区間を対象として、画像認識技術を用いた整備効果を検証、評価するとともに、画像認識技術を用いた自転車交通量調査における課題点とその解決策について明らかにすることを目的とする。

### 2. 既存研究と本研究の位置づけ

自転車道整備効果の検証に関連した先行研究としては阿部ら<sup>2)</sup>の研究がある。この研究では、岡山市内国道 53 号の自転車道を対象として、ビデオ撮影による交通観測とアンケート調査の結果に基づいて、整備効果を検討している。結果として、自転車道整備前後で自転車と歩行者の平均通行速度が上昇していた。しかし、整備後の自転車道遵守率は 20.9%~49.2%の低い割合にとどまっている。また、アンケート調査の結果では通行空間改善と直接関連する項目の評価が向上している一方で交通処理に関しては、評価意識に十分な改善が見られなかった。

交通量計測に物体、検知アルゴリズムを使用した先行研究としては瀧本ら<sup>3)</sup>の研究がある。札幌新川 IC を対象として現地での人手観測、YOLO による自動計測の値から計測精度を評価し、計測精度低下の発生要因を調査した。この研究から交通の混雑、気象条件、カメラの画角が計測精度低下につながることを確認した。

峯岸ら<sup>4)</sup>は自動車が画面内を垂直に横切るような撮影角度を対象とし解析を行った。反対車線を走行する自動車を除外するため、選定方向側から動画内に写る車両のみを抽出する処理を加え、実用に使用可能なレベルの自動車抽出処理機能を構築した。

このように、日本国内において自動車道整備効果検証

に関連した報告は複数あるが、調査方法として人手観測やアンケートによる検証に留まっている。また、物体検知アルゴリズムを利用した交通量計測の分析能力向上を目的とした研究事例があり、高い精度の解析結果を得た研究も存在する。本研究では物体検知アルゴリズムを使用して、自転車道整備効果の検証を行う。

### 3. 使用したアルゴリズムとデータセット作成の概要

本研究における交通量調査は、映像内の自転車の検出(detection)その自転車の測定(counting)という二段階のプロセスからなる。この解析に用いたのは、Yolov4 アルゴリズムである。また、データセットは Microsoft COCO (Common Object in Context)<sup>5)</sup>の画像データセットを用いたが、自転車の検出精度が低い問題が生じた。そこで、学習済みモデルの機械学習に使用された画像を確認したところ本研究で使用した動画のような日本の都市で撮像されたものは少なく、海外で撮像された画像を多く使用されていた。また、撮像されている自転車についても、国産の自転車とは形状や特徴が異なっていた。

よって、本研究では yolov4<sup>6)</sup>を使用する際にオリジナルのデータセットを作成した。以下にデータセット作成の各工程と使用したアルゴリズムの詳細を記述する。

#### 3.1 画像収集

Yolo における学習画像数は一般に 1 クラスあたり 2000 枚程度が目安とされている。そこで、自転車の画像として 2636 枚確保した。自転車の車種の内訳とそれらの台数は表-1 に示す。

##### 収集した自転車画像の車種

- ・ **シティサイクル(ママチャリ)**: 日本における最も一般的で多数を占める日常生活用車種をまとめた。
- ・ **クロスバイク**: 形状の特徴が類似していたため、ロードバイク、マウンテンバイクもまとめた。
- ・ **子供載せ自転車**: 自転車の前方及び後方の部分が特徴的な形状をしていたため、分類した。
- ・ **その他**: 上記にある自転車の形状とは明らかに異なるものをまとめた。

表-1 自転車の車種と台数

	シティ サイクル	クロス バイク	子供載せ自転車	その他
台数	955	1546	487	795

### 3. 2 教師データの作成

収集した全画像に対して教師データの作成を行った。本研究ではグラフィック画像アノテーションツール labelImg<sup>7)</sup>を用いた。画像内にある自転車の部分に対し長方形型の領域を指定することで、画面の左上が始点(X:0, Y:0)となり「項目, X 座標, Y 座標, 長方形の横幅(X)長方形の縦幅(Y)」という形で物体の種類とその座標の情報が保存される。これが教師データとなる。

### 3. 3 Yolov4

本アルゴリズムは映像内から物体を検出する役割を担う。学習対象と類似した物体を映像内から認識した際、BBOX(物体の輪郭を囲うような長方形)を描画し、車両を計測の対象として認識することを可能とする。

### 3. 4 deepsort<sup>9)</sup>

本アルゴリズムは車両の計測・測定を担う。前述した Yolov4 内において、検出された物体の動きに対しトラッキング(物体追跡)を行い各物体にIDを割り振ることによってその挙動を管理する。

## 4. 分析対象となる区間の概要

対象区間は 2018 年に実施された石山通における矢羽根整備前後での定点映像のうち、地点 A と地点 B の 2 地点とし、計 4 種の動画で検証した。図-1 から見てわかる通り地点 A は歩行者目線ほどの高さの画角で、地点 B は建物から見下ろした画角で撮影された動画を使用している。また、映像内における自転車交通流を矢羽根整備前は歩道区間と側道区間、整備後は歩道区間と矢羽根区間の 2 区間に分割した。

<地点 A>南 1 条西 11 丁目の歩道及び車道(図-1)

整備前：2018 年 6 月 14 日 11 時 59 分～16 時 03 分

整備後：2018 年 9 月 19 日 11 時 04 分～15 時 01 分

<地点 B>南 3 西 11 丁目交差点(図-1)

整備前：2018 年 6 月 14 日 13 時 00 分～17 時 06 分

整備後：2018 年 9 月 19 日 12 時 56 分～18 時 56 分

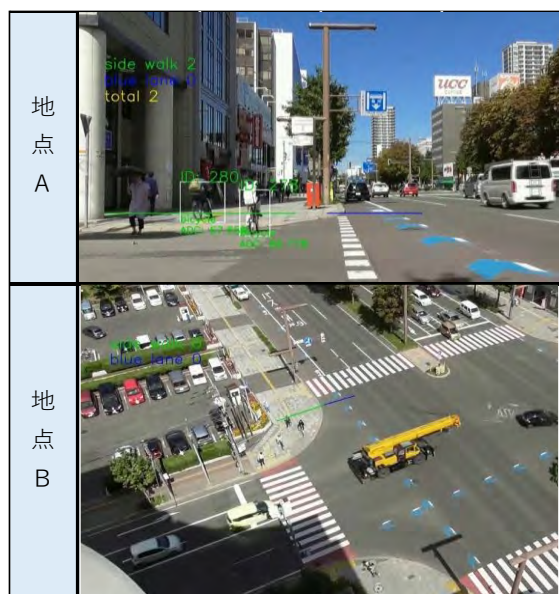


図-1 解析の様子

現地での人手観測による交通流調査の記録が 10 分刻みであったため、本研究における解析も 10 分ごとの出力とした。しかし、使用した動画はちょうど 4 時間ではなかったことから、10 分に満たない出力サンプルが 2 本あるが、サンプル数を確保するため、そのまま使用した。

## 5. 交通量計測の手法

### 5. 1 カメラ画像の解析方法

映像内の 2 点を指定し、これを結ぶ線を計測線とする。計測線を歩道区間と側道区間、矢羽根区間に 1 本ずつ描画する。自転車が認識された際、その自転車には ID が割り振られ、輪郭として長方形が描画される。この長方形の中心の座標がこの計測線の座標を越え、なおかつ自転車の ID が新規のものであるとき各自転車が計測線を通過したとみなし、通過台数としてカウントするようプログラムを設定した。

また、処理時間の削減を目的として、動画のフレームレートを半分にした動画でも測定を行った結果、計測精度を維持し、分析に必要な時間が半分に削減された。

### 5. 2 測定精度の評価手法

X 軸を使用した動画から目視による人手計測、Y 軸を Yolov4 による AI 解析として、各区間の総交通量の時間推移を散布図の形で可視化する。(図-2)この時、X と Y の値が一致する時、人手計測と AI 解析の値が一致する理論値のプロットとなる。測定結果の精度を評価する指標として、決定係数、平均二乗誤差平方根(以下、RMSE: Root Mean Squared Error)を使用する。

## 6. 測定精度の結果とその考察

### 6. 1 解析結果と人出計算の比較

比較結果を示す。(図-2、表-2)図-2 中のオレンジ線は理論値の  $y=x$  青線は各プロットに対する回帰線を現したものである。

地点 A は歩道区間と全体合計は高い検出精度を示した。一方で矢羽根区間に関しては、歩道区間、全体合計の精度と比較して低い結果を得た(図-2、表-2)。

また、地点 B を解析したところ自転車を 1 台も検出することができなかった。そのため、地点 B のパラメータは省略する。

### 6. 2 地点 A における計測誤差の要因

地点 A における誤差要因を以下のように分類する。

#### (a) データセットによる要因

- ① 画面から向かって左端を通過する自転車を検出することができない。(図-3)
- ② キャリーケースを引く歩行者や車いす、ベビーカーなども誤って計測してしまう。(図-3)
- ③ 歩行者が押し歩く自転車も誤って計測してしまう。
- ④ 自転車をトラッキングする過程で割り当てられた ID が変化してしまうことによって、別の自転車として検出し、計測結果に誤差が生じる。
- ⑤ 子供載せ自転車を検出できない時がある。

(b) 撮影地点, 画角による要因

- ① 歩行者・自動車と自転車が画面上で重なってしまうことによって検出できない。
  - ② 画面に対して真横方向に通り抜ける, 自転車も計測してしまう。
  - ③ BBOX が先に触れたほうを計測するようにプログラムされているため, 計測線を通じた後に別の区間に移動してしまう自転車の対応ができない。
- 以上が主な誤差発生 の 要因として挙げられる。



図-3 誤差発生の様子

また, 歩道区間と全体合計を比較して計測精度が著しく低い結果が得られた要因として, そもそも矢羽根区間を通過する自転車の台数が少ないことで, 1台の誤差による影響が大きく反映されてしまったことが考えられる。

6.3 地点Bにおける未検出の要因

地点Bにおいて自転車で検出できなかった要因は, 広角で撮影した画像データが不足していたことが挙げられる。地点Aで撮影された動画のような画角や至近距離で撮影された画像を多く使用したが, 地点Bのような高所や遠距離から撮影された画像をデータセットに十分に取得することができなかつたため, 広角で撮影された動画の自転車検出に対応できなかったと推定される。また, この課題は「データセットによる要因」「撮影地点, 画角による要因」の両方に分類されると考えられる。

7. 計測誤差の対策

7.1 「データセットによる要因」

次に, データセットによる要因の対策について, 主に2つの対策案をここに挙げる。1つ目は, データセットの作成時点で様々な画角で撮影された自転車を収集することである。その中でも高所から撮影されたものや遠距離にある自転車は距離的な要因で映像内では自転車の特徴を捉えにくいので, 広角から撮影された自転車の画像を多く集め, 学習させることが重要だと考えられる。2つ目は「車いす」「自転車を押す歩行者」などクラスを追加して学習を実行し, 自転車と差別化することである。本研究で作成したデータセットは自転車のみで作成した。これに起因して自転車に特徴が似通っている車いすやベビーカーなども誤検出したと考えられる。よって, 新たにクラスを追加して学習させることにより誤検出を減らすことができると考えられる。

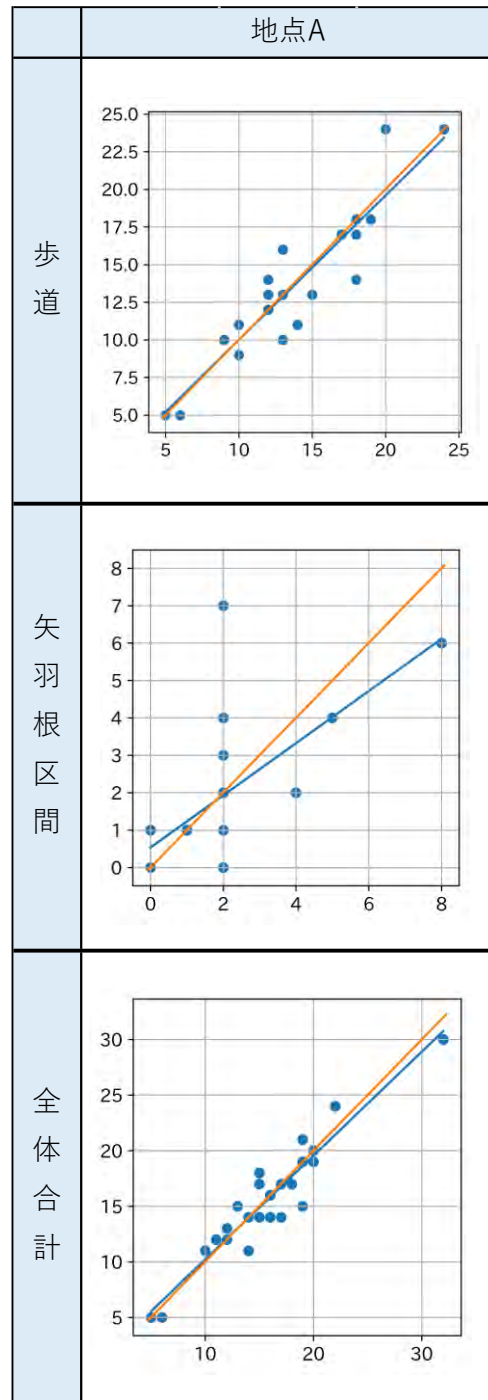


図-2 各区間の自転車交通量比較  
X軸: 人手計測 Y軸: Yolov4によるAI解析  
サンプル数=25

表-2 各区間のパラメータ

	区間	R2	RMSE
地点A	歩道	0.838	1.833
	矢羽根	0.486	1.414
	全体合計	0.896	1.72

## 7.2 「撮影地点、画角による要因」

撮影地点、画角による要因への対策は、学習したアルゴリズムの得意な画角の地点で撮影・計測を行うことである。本研究において地点 A と地点 B のように低所と高所の画角に分類して計測を行ったが、明らかな検出精度の差が生じた。地点 A の画面右側から画面左側の大通りに向けて道が通っていることにより、大通りへの合流を図る自動車やそのまま通り抜ける自転車によって計測に誤差が生じている。したがって、これらの諸条件をクリアした画角の動画を使用することで、より高い精度での計測が可能になると考えられる。

## 8. Yolov4 による矢羽根整備効果検証

### 8.1 矢羽根整備前後における矢羽根の遵守状況

表-3 は地点 A における矢羽根利用の遵守状況を、4 時間分の合計で示した結果である。地点 A の映像内における各計測区間を通過した自転車総数のうち、側道区間および、矢羽根区間のみを通過した自転車台数の割合を「自転車道遵守率」と定義した。

表-3 から、地点 A における矢羽根整備後の自転車道遵守率は 13.2% であることが確認された。整備前と比較して約 7% 上昇したが、岡山での自転車道整備後の自転車道遵守率と比較しても低い結果となった。

### 8.2 地点 A における低自転車道遵守率の要因

地点 A において自転車道遵守率が低い要因として以下のことが挙げられる。

- ① 路上停車している車が自転車通行の障害になっている。
- ② 映像内の交差点で左折しようとする車を回避するために、歩道区間に移動している。

これらの共通している状況は矢羽根上に自動車が存在していることである。よって、矢羽根上に停車している自動車が自転車道遵守率向上の障害になっており、そのような自動車の対策を講じることで自転車道遵守率向上につながると考えられる。

表-3 矢羽根整備前後の遵守状況

地点 A	整備前			整備後		
	総自転車通行台数	側道通行台数	自転車道遵守率	総自転車通行台数	矢羽根通行台数	自転車道遵守率
	233	15	6.4%	318	42	13.2%

## 9. まとめ

本研究では、日本国内における映像の自動解析による自転車交通量調査の有用性の検討を目的に、簡易的な交通流において機械学習アルゴリズムによる測定と人出測定との比較を行い、測定誤差の発生要因とその対策について明らかにすることを目的として調査を行った。結果、自転車交通量の自動解析において留意すべき点を定量的

な解析と目視により明らかにした。

自転車交通量の画像解析で留意すべき基礎的事項としては、

- ・ データセットの作成において、自転車を様々な画角から撮影したものを使用する。特に、高所や、遠距離から撮影した動画から自転車を検出する際は特徴を捉えることが困難になるため、重点的に収集し、学習させる必要がある事
- ・ 撮影地点やカメラの設置位置を選定する際に自動車などの要因が少ない地点での検証を採用する事

が挙げられる。AI を用いた自動解析を自転車交通量調査に導入する場合、データセットの作成、撮影場所、カメラの画角などといった環境構築を徹底することが重要である。

これに加えて、学習させたアルゴリズムを用いて札幌市の矢羽根整備効果の検証を行いその課題点について述べた。結果として、矢羽根整備を行ったことで、自転車交通流を一部歩道区間から矢羽根区間に移動していることが確認されたが、全体としてまだ利用率が低いことが確認された。その要因として矢羽根上に自動車が停車し、自転車の交通を妨げていることが挙げられ、その対策を講じる必要性を示した。

今後の展望として、本研究では対象としなかった夜間や雨天時における AI を用いた自転車交通量調査の基礎研究や矢羽根整備効果の検証が挙げられる。

今後も自転車交通量調査の実用的運用に向け更なる研究を重ねていきたい。

## 参考文献

- 1) 札幌市建設局：札幌都市部自転車通行位置の明確化の取り組み。＜自転車通行位置の明確化／札幌市 (city.sapporo.jp)＞2022 年 12 月 9 日アクセス。
- 2) 阿部宏史, 崎大樹, 岩元浩二, 富田修一：岡山市国道 53 号における自転車道整備効果の検証。土木計画学研究・論文集, Vol26, no.4, pp.647-654.
- 3) 瀧本康太, 高田光太, 有村幹治：カメラ画像と物体検知アルゴリズムを用いた交通量調査における基礎的研究。第 66 回土木計画学発表会・講演集。
- 4) 峯岸朋弥, 吉田享子：物体検知・識別器による自動車交通量調査システムの試作と評価, 専修ネットワーク&インフォメーション, Vol.28, pp.53-58, 2020.
- 5) COCO - Common Objects in Context <https://cocodataset.org/>
- 6) Alexey Bochkovskiy, Chien-Yao Wang, Hong-Yuan Mark Liao : YOLOv4 Optimal Speed and Accuracy of ObjectDetection
- 7) Heatex : labelImg <https://github.com/heartexlabs/labelImg> <https://arxiv.org/abs/2004.10934>
- 8) Nicolai Wojke, Alex Bewley, Dietrich Paulus : Simple Online and Realtime Tracking with a Deep Association Metric <https://arxiv.org/abs/1703.07402>