

市販ネットワークカメラを用いた 多地点での歩行者と自転車の人流観測

伴 和徳¹・小林 栄介²・樹下 晶弘³・三輪 富生⁴・山本 俊行⁵

¹正会員 トヨタテクニカルディベロップメント(株) (〒470-0334 愛知県豊田市花本町井前 1 番地 9)

E-mail: kazunori.ban@mail.toyota-td.jp

²非会員 トヨタテクニカルディベロップメント(株) (〒470-0334 愛知県豊田市花本町井前 1 番地 9)

E-mail: eisuke.kobayashi@mail.toyota-td.jp

³非会員 (株)ナックイメージテクノロジー (〒224-0034 神奈川県横浜市都筑区勝田町 1247)

E-mail: kinoshita.akihiro@camnac.co.jp

⁴正会員 名古屋大学准教授 未来材料・システム研究所 (〒464-8601 愛知県名古屋市千種区不老町)

E-mail: miwa@nagoya-u.jp

⁵正会員 名古屋大学教授 未来材料・システム研究所 (〒464-8601 愛知県名古屋市千種区不老町)

E-mail: yamamoto@civil.nagoya-u.ac.jp (Corresponding Author)

国土交通省が推進している道路交通調査は人の手による調査が廃止され、CCTV 画像を活用した観測に切り替えられている。この新たな道路交通調査体系による常時観測体制を整えるためには車両や歩行者、自転車の検出精度を向上する必要がある。その中で歩行者と自転車の検出精度に特に課題があるため、本研究では名古屋大学内 10 地点にネットワークカメラを設置し、1 か月間に渡り歩行者と自転車の観測を行い、観測画像からリアルタイムで検出する YOLO と Strong Sort を用いた人流計測システムを構築した。そのカウント結果の精度を向上させるため、計測地点毎の対策ではなく全体に適用可能なアルゴリズムを構築して歩行者の計測精度を大きく向上させることができた。この分析と結果を踏まえ、街中への常時観測への適用時の可能性について検証する。

Key Words: CCTV, Pedestrian count, bicycle count, traffic survey,

1. はじめに

AI による画像認識技術の向上により、交通でも様々な場面での活用が期待されている。国土交通省が 5 年に 1 度行っている全国道路・街路交通情勢調査は平成 27 年度まで調査員の手による人で観測が行われていたが、この方式が廃止され CCTV 画像を活用した AI 観測に切り替えられている¹⁾。これは新たな道路交通調査体系による今後の取組として、ビッグデータを活用した時間帯別交通量を詳細に分析し、日常生活での渋滞や事故の対策に充てるだけでなく災害時の社会的誘導を軽減するなどを目的に常時観測体制の実現を目指している²⁾。この CCTV カメラによる交通量の観測では、令和 3 年度に国土交通省が行った精度に関する報告において³⁾、昼間の全車種自動車交通量は精度が高いことが報告され±10%以内の精度を確保した CCTV カメラの割合は約 97%程度

となっているが、自転車や歩行者の精度は約 1%程度と非常に低い結果となっている。

カメラによる人流計測は大西ら⁴⁾が述べているように、一人一人を追跡する方法や群衆の移動としてとらえる方法があるが、本研究では将来街中にカメラを設置し車両や人流を計測することで OD 交通量の更新や渋滞予測、危険個所の抽出に用いることを目的にしている。そのため複数のカメラで長時間同時に計測するシステムを構築し移動手段ごとに分類したカウントを計測する必要があるが、そのような研究はまだそれほど取組まれていない。

そこで本研究では、カメラによる検出精度が低い歩行者と自転車を対象に、名古屋大学内に市販のネットワークカメラを 10 箇所設置し、約 1 か月間継続計測を行った。この計測データを元に、歩行者と自転車の検出精度向上のための検証と課題について考察を行った。

2. 既往研究と本研究の位置付け

AIを用いた画像からのデータ検出について、今井ら⁵⁾は汎用的な学習機や学習モデルの交通量調査への適用可能性に関し、YOLOv3を用いてカメラの設置角度や位置などによって車両検出精度を検証しており、大久保ら⁶⁾は車種別交通量調査へ混合車種データセットを用いることによる認識精度の向上を検証しているが、自転車と歩行者に特化した研究は少ない。

自転車と歩行者を区分した人流調査については、吉田ら⁷⁾がAI解析により自転車と歩行者を区分した人流データを自動抽出し、追跡も加えることで速度や通行位置の可視化を行っており、31地点の撮影動画を元に学習データを作成している。しかし精度を確保するために学習データを自分で準備するには膨大なデータ量が必要であり、そこから精度を確保する手段を一般化するのは困難である。誰でも入手可能なアルゴリズムを用いて物体検出する方法として、瀧本ら⁸⁾は定点カメラの映像に対しYOLOv4とDeep Sortを用いて交通量調査を行っているが、既存カメラの設置問題やオクルージョンによる影響などから計測誤差が非常に大きい結果となっており、対象も車両のみに限定されている。

このように、学習データを準備せず公開されたアルゴリズムを適用して歩行者や自転車を検出して一定の精度を確保することは難しく、カメラによる人流観測の大きな課題になっている。そこで本研究では、学内に設置し計測したカメラデータから学習データを準備する必要がない公開された学習済モデルを用いて、歩行者と自転車の検出精度として国土交通省の基準から誤差率±10%の確保を目指す。

3. 学内人流計測の概要

(1) 計測の概要

計測場所は名古屋大学構内の道路であり、学内を1/8標準メッシュに分割しVISSIMでのシミュレーション結果よりメッシュ内への移動が多いメッシュを対象に選定した。その各メッシュ内に1か所カメラが設置可能な場所に設置を行った。カメラ設置要件は以下の通り。

- ・学内LANに接続可能
- ・オクルージョン対策の為建物の2Fか3F
- ・電源供給可能
- ・1か月間常設可能

上記条件を満たす9地点に10カメラを設置して計測を行った。計測場所の地図を図-1に示す。



図-1 学内カメラ設置場所

本計測期間は2022/10/24-2022/11/18の平日8:30-17:00で実施し、対象は歩行者と自転車である。計測にあたり名古屋大学 未来社会創造機構 研究倫理委員会の承認(承認番号:2022-30)を受けた。また事前に計測状態の確認とカメラの計測エリアを設定するため、2022/10/17-2022/10/21の間で各地点での事前計測も実施した。

(2) 計測方法

計測カメラは10台とも市販の監視カメラを使用した。そのスペックは以下の通りである。

メーカー: TP-Link

型式: Tapo C310

仕様: Wi-FiとLAN接続が可能

このカメラを選定した理由として、安価で入手しやすく、設定等はスマートフォンから簡易に行うことができ、複数台ネットワークに接続できるので同時計測に適しているためである。このカメラを用いた学内での計測システム構成を図-2に示す。

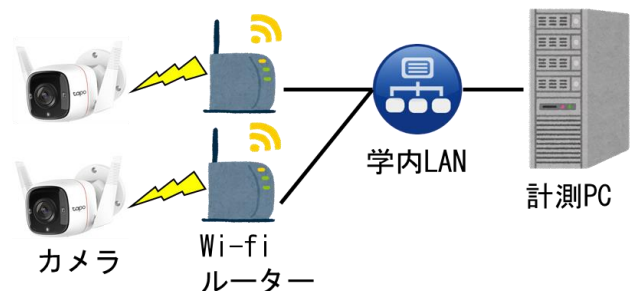


図-2 計測システム構成

カメラを RTSP サーバーモードで動作させ、その画像を研究室側の計測用 PC で受信した。カメラの最大画像サイズは 300 万画素 (2304×1296) であるがカメラの出力設定で FULL HD (1920×1080) に変更して送信している。次にカメラ画像の検出アルゴリズム構成を図-3 に示す。

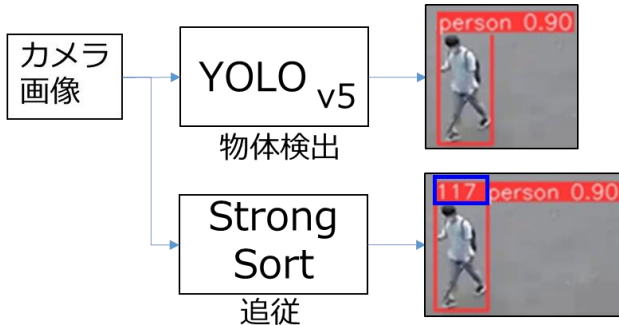


図-3 カメラ画像検出アルゴリズム

画像検出には YOLO⁹⁾ の v5 を用いた。使用したモデルは YOLO5x6 であり、これはカメラ画像サイズに近い 1280 の中で最も精度が高く、COCO¹⁰⁾ で学習済みのモデルであるため、自前でモデルを学習する必要がないという利点がある。また歩行者、自転車をカウントするために Strong Sort¹¹⁾ を用いた。Strong Sort は YOLO で検出した物体の存在を矩形で示す Bounding Box を使用してトラッキングを行う機械学習モデルである。これにより検出した物体に個別 ID を付与することで重複カウントを回避できる。計測時間は 1 秒単位でカウントを行った。

(3) 計測エリア

各計測地点で歩行者と自転車をカウントする計測エリアをそれぞれ設定した。例として地点⑨の計測エリアを図-4 に示す。



図-4 地点⑨の計測エリア

青い枠の中が計測エリアで、枠線に Bounding Box が接した時点で物体が認識される。また、事前計測により駐輪場の自転車やボールなどの静止物を誤認識することが分かっている。そのため非計測領域を設けており、黄色

いエリアが自転車を計測しないエリアである。このエリアでは自転車は検出せず歩行者のみ検出するように設定を行った。ピンクのエリアは静止物であり検出不可エリアとして設定した。また青い枠に歩行者の足だけが掛かるような状態で検出された場合精度が低くなるため、検出エリア外より奥で認識された Bounding Box は計測しないように処理している。

4. 計測結果

1 か月間の本計測を行った結果について述べる。まず全体の人の行動傾向を確認し、その後計測精度を確認し、値が大きすぎていない箇所について検証と対策を行った。

(1) 人流変化の動向

計測した 1 秒ごとのカウントを 30 分単位に集約し傾向を分析した。その代表点として計測地点②の歩行者と自転車の数を図-5 に示す。

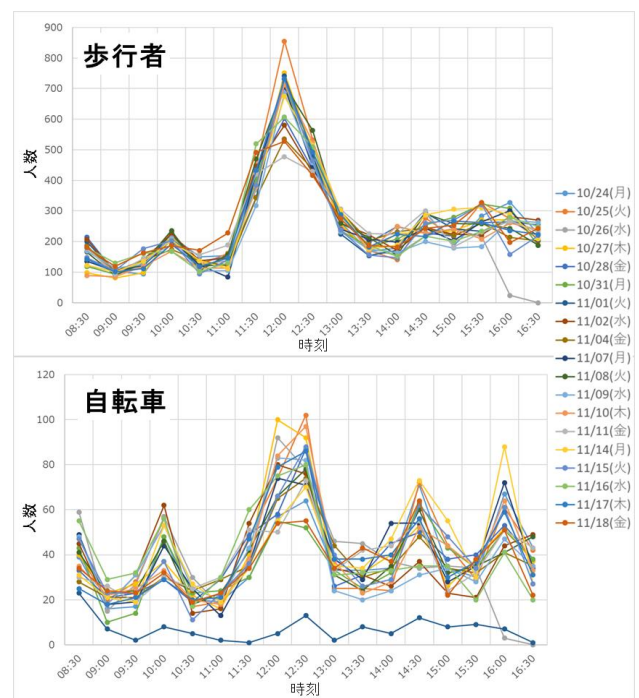


図-5 地点②で計測データ

計測地点②は食堂のすぐ近くの為、11 時半から 12 時半の間に急激に人が増えており、また授業の切替時間帯で増減する傾向が見られる。自転車では 11/1 が極端に低くなっているのは、この日が雨天だったことが原因であると想定する。これらの結果から、人流変化の傾向は捉えられていると考えられる。

2) データ精度検証

次にカウントしたデータと実際の人数との精度比較を

行った。計測データと比較するための真値は目視で確認し、全 10 拠点で 10/25、11/1、11/17 の 3 日間、それぞれ朝(9:00 台)、昼(12:00 台)、夕(16:00 台)の時間帯で歩行者と自転車を別々にカウントを行った。それぞれの計測人数を表-1 に示す。

表-1 データ精度検証用母数 (人)

	10/25		11/1		11/17	
	歩行者	自転車	歩行者	自転車	歩行者	自転車
①	135	7	121	0	147	9
②	485	375	500	95	488	359
③	2,309	347	1,630	56	2,074	331
④	679	15	350	5	793	41
⑤	1,997	319	1,943	68	1,998	321
⑥	1,037	253	229※	17※	997	250
⑦	1,277	395	1,275	121	1,234	441
⑧	1,005	458	1,031	118	969	484
⑨	808	438	790	125	984	463
⑩	512	145	580	64	562	151
合計	10,244	2,752	8,449	699	10,236	2,850

11/1 の地点⑥については機器トラブルにより朝から昼過ぎまで計測できていないため 16 時台のデータのみ以降の分析に用いる。これら表-1 の計測値と目視カウント値の比較を図-6 に示す。

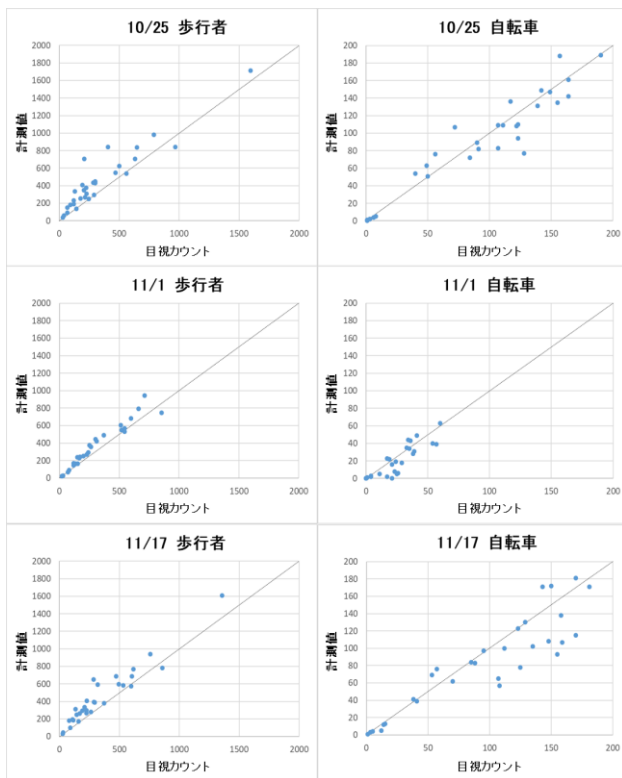


図-6 計測値と観測値の比較

図-6 より、歩行者、自転車ともに日によってカウントのバラつきが大きいことが分かる。そこで誤差が大きい点に着目して解析を行った。

3) 歩行者と自転車の二重カウント除去 (対策 a)

まず最初に、自転車交通量が多い 4 地点で目視カウントの歩行者と自転車を足し合わせた結果と計測した歩行者数を比較すると高い相関(0.90)が見られた。その結果を図-7 に示す。




図-7 計測値と観測値の比較

これより歩行者カウント数は自転車と運転者を別々に検出し歩行者としている可能性があるため、歩行者数を超過してカウントされる傾向があることが分かった。そのため集計時にこの二重カウントを除去する必要がある。

そこで歩行者と自転車の Bounding Box の重なりから歩行者の重複カウントを排除するために、IoU (Intersection over Union) を使用した。IoU は物体検出で画像の重なりを割合で表す指標であり、その値が大きいほど画像の重なりが大きいことを示す。式(1)と図-8 に IoU について示す。

$$IoU = \frac{\text{Intersection面積}}{\text{Union面積}} \quad (1)$$




図-8 歩行者と自転車の重なりと IoU

計測データより、複数のサンプルを確認しサイクリストと判定する閾値を 0.15 以上と設定した。その結果を図-9 に示す。




図-9 対策 a 実施結果

図より、11/1 は雨だったため自転車の総数自体が少なかったことによりそれほど効果は出ていないが、それ以外の日では改善していることが分かる。

4) 静止物誤認識識別アルゴリズム (対策 b)

次に、時間帯による差分に着目し差が大きい地点の確認を行った。その結果、地点⑨は雨であった11/1を除いて朝に歩行者の誤差が大きいことが分かった (図-10)。



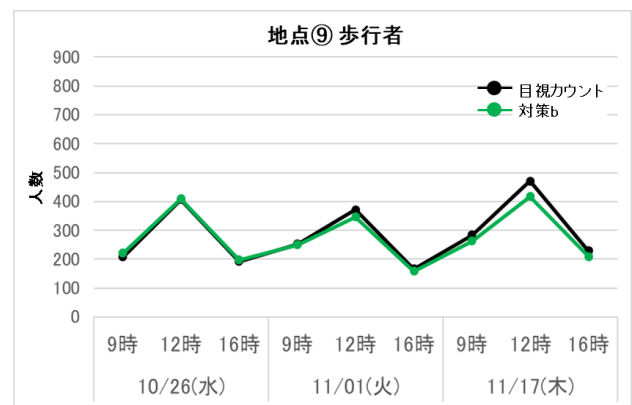


図-10 地点⑨のカウン比較

地点⑨は東側道路が伸びる方向を計測しており朝日との関連性を確認しながら計測動画を解析した。その結果マスクしている静止物の影が伸びることで人と誤認識している可能性を考え、単なるマスク処理だけでなく静止物か動体かを判別し除去する対策アルゴリズムを検討した。計測データには YOLO と Strong Sort 結果から Frame ID や物体を識別するための識別 ID、位置情報などを含んだトラッキングログが出力されている。また別途新規 ID をカウントした人流計測ログのみをトラッキングログから抽出している。このトラッキングログから静止物の数を割り出し人流計測ログからその数を引いて静止物を除去している。まず、トラッキングログから識別 ID ごとに最も大きい Bounding Box を抽出し、そのサイズを基準値として各オブジェクトの移動距離 x, y を求める。その式を式(2)に示す。

$$\begin{aligned} \text{diff}_x &< \max_x \times \alpha \\ \text{diff}_y &< \max_y \times \beta \end{aligned} \quad (2)$$

ここで、 $\text{diff}_x, \text{diff}_y$ は歩行者などの移動物体の検出範囲であり、静止物であれば範囲が小さくなるはずである。 \max_x, \max_y は最大 Bounding Box サイズ、 α と β は各係数を表す。式(2)両方を満たしている場合を静止物と判定しカウント数から除去した。その結果を図-11 に示す。






図-11 地点⑨の静止物除去結果

対策 b を適用した結果、大幅に差があった歩行者のカウンタ数が補正され、自転車にも影響が出ない結果になった。これにより静止物の影等が誤認識の原因になっていたことが解消された。このアルゴリズムを全拠点に適用しその比較を行った結果を図-12 に示す。

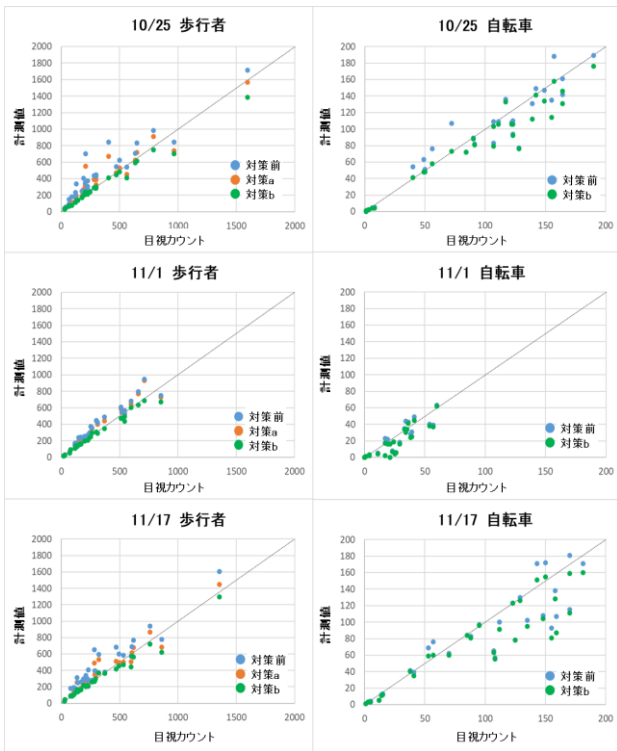


図-12 対策 b 適用結果

全体的に過大検出部分がなくなり目視カウント結果に近づく結果となった。但し、静止物の影響として除去できたものが本当に静止物かどうかの検証までは行っていない。また自転車に関しては過少検出方向になっている。

5) 補正後の結果

計測値に対して対策 a と対策 b を実施した結果を決定係数と RMSE を用いて比較した結果を表-2 に示す。

表-2 対策実行時の決定係数と RMSE 比較

		計測値		対策a		対策b	
		R^2	RMSE	R^2	RMSE	R^2	RMSE
10/25	歩行者	0.88	164.28	0.91	103.82	0.98	69.16
	自転車	0.91	17.31			0.94	18.09
11/1	歩行者	0.93	85.02	0.94	70.84	0.98	45.18
	自転車	0.77	10.10			0.78	10.62
11/17	歩行者	0.92	137.31	0.94	78.78	0.97	58.49
	自転車	0.82	26.87			0.83	29.97

歩行者については計測値に対して対策を行ったことで決定係数、RMSE ともに大幅に改善していることが分かるが自転車にはあまり効果が見られなかった。

次に国土交通省が指標としていた誤差率±10%以内の検証を行った。計測値と対策 a, b で比較を行った結果を図-13 に示す。

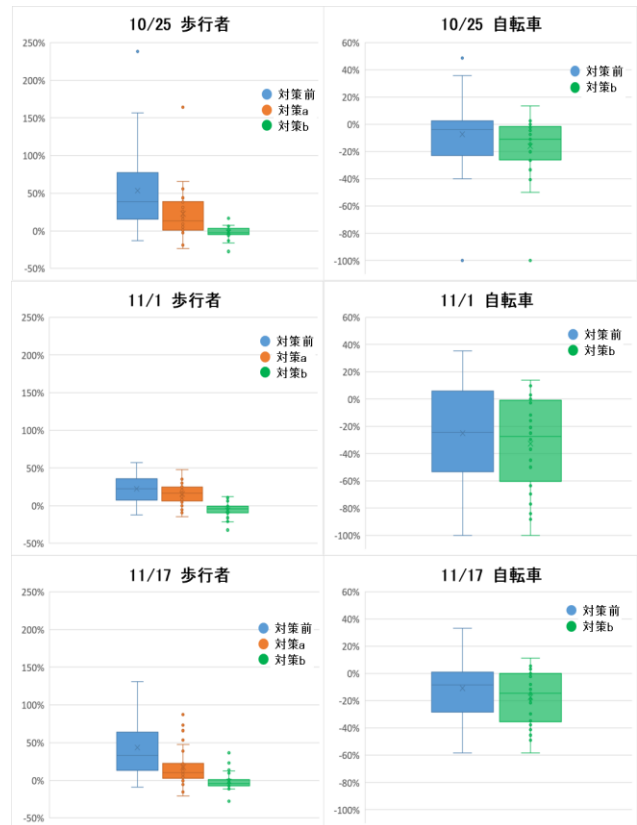


図-13 誤差率比較結果

歩行者に関しては対策を行うことで中央値の誤差率が 0% に近づき、幅も小さくなっていることが分かる。一方自転車に対してはあまり効果がなく過少カウント傾向になっている。10 の観測地点、3 つの時間帯での誤差率が ±10% 以下に収まっている割合を表-3 に示す。

表-3 補正前後での誤差率±10%以下の地点割合比較

	対策前	対策後
歩行者	18.3%	75.0%
自転車	30.0%	38.6%

歩行者では約 8 割の地点と時間帯で±10%以内に収まる結果となった。残りの地点と時間帯では過少カウントされている部分があり、今後これらの確認と対策方法を検討していく。また自転車で精度向上があまり見られなかった原因として、自転車は母数が少なく特に雨の日は 1 時間に 5 台以下の地点が複数あり、1 台カウント差が出ると高い誤差率となって現れるためである。さらに、自転車は場所によってはかなりの高速で検出エリアの端を瞬だけ通過するものもあり検出が困難な状態であったことが考えられる。よって自転車はなるべく長く検出エリアに映っている状態を計測時に検討する必要がある。

5. まとめ

本研究では、歩行者と自転車の検出精度を向上させるため名古屋大学内 10 カ所に市販ネットワークカメラを設置し 1 か月間計測を実施した。その計測画像をリアルタイムで検出し、YOLOv5 と Strong Sort を用いて通過人数をカウントし精度解析を行った。カウント精度向上のために、1 地点のみの限定的な対策ではなく全地点に適用できるアルゴリズムを開発することで、国土交通省が指標としている誤差率±10%以内に入る地点を歩行者では 75.0%、自転車では 38.6%実現した。特に歩行者では±10%を満たす地点が約 2.4 倍増加した。自転車については精度向上は微増であったが、検出エリアの形状の設定方法によって一定程度の精度向上が考えられるため、検出エリアと自転車の検出精度の関係性を分析することで対策を講じていく。また今後進行方向についても分析を行い、移動方向の推定も合わせて行うアルゴリズムを構築する。

今後の展望として、今回大学内のみで実施した計測方法とアルゴリズムをベースにまずは街の狭いエリアから適用し歩行者と自転車を含めた新たな道路調査体系の基本である常時観測システムの構築を行う。そこに交通流シミュレーションを組み合わせることで観測と予測を両立し、平常時の渋滞対策や災害時の避難経路と組み合わせ実環境へ適用する。この仕組みを新たなスマートシテ

ィ向けデジタルツインとしての構築を目指し、引き続きアルゴリズム向上と実証実験を重ねながら研究開発を進める。

参考文献

- 1) 国土交通省：令和 3 年度全国道路・街路交通情勢調査の実施について，2021
<https://www.mlit.go.jp/road/ir/ir-council/ict/pdf05/01.pdf>
- 2) 国土交通省：新たな道路調査体系による今後の取組，2022
<https://www.mlit.go.jp/road/ir/ir-council/ict/pdf06/01.pdf>
- 3) 国土交通省：CCTV カメラ（AI 解析）の精度に関する報告，2021
<https://www.mlit.go.jp/road/ir/ir-council/ict/pdf05/02.pdf>
- 4) 大西正輝，山下倫央：カメラによる人流計測とシミュレーションによる人流解析に関する研究動向について，日本知能情報ファジィ学会誌，Vol.28，No.6，pp.187-193，2016.
- 5) 今井 龍一，神谷 大介，山本 雄平，田中 成典，，中原 匡哉，，中畑 光貴：汎用的な深層学習器を用いた交通量調査手法に関する基礎的研究，土木学会論文集 F3，2019 年 75 巻 2 号，pp.150-159，2019.
- 6) 大久保純一，菅原宏明，藤井純一郎，小篠耕平，小早川悟，和田英之：車種別交通量調査への深層学習の応用システムの提案，第 34 回人工知能学会全国大会・講演集
- 7) 吉田龍人，堀井大輔，菊池恵和，高森真紀子，高森秀司：動画の AI 解析による歩行者と自転車を区分した人流調査，第 66 回土木計画学研究発表会・講演集
- 8) 瀧本康太，高田光太，有村幹治：カメラ画像と物体検出アルゴリズムを用いた交通量調査に関する基礎的研究，第 66 回土木計画学研究発表会・講演集
- 9) YOLOv5
<https://github.com/ultralytics/yolov5/tree/v5.0>
- 10) COCO - Common Objects in Context
<https://cocodataset.org/>
- 11) Strong Sort
<https://github.com/dyhBUPT/StrongSORT>

(Received ????, 2023)
(Accepted ????, 2023)

MULTIPOINT OBSERVATION OF PEDESTRIANS AND BICYCLES USING COMMERCIALY AVAILABLE NETWORK CAMERAS

Kazunori BAN, Eisuke KOBAYASHI, Akihiro KINOSHITA, Tomio MIWA
and Toshiyuki YAMAMOTO

The road traffic survey promoted by the Ministry of Land, Infrastructure, Transport and Tourism has abolished manual surveys and switched to observation using CCTV images. It is necessary to improve the

detection accuracy of vehicles, pedestrians, and bicycles in order to establish a constant observation system based on this new road traffic survey system. Among them, there is a particular problem in the detection accuracy of pedestrians and bicycles, so in this research, network cameras were installed at 10 points in Nagoya University campus and pedestrians and bicycles were observed for one month. Then, we constructed a people flow counting system using YOLO and Strong Sort, which detect in real time from the observed images. In order to improve the accuracy of the counting results, we were able to greatly improve the accuracy of pedestrian measurement by constructing an algorithm that can be applied to the whole rather than taking measures for each measurement area. Based on the analysis and results of the above, we will verify the possibility of applying it to continuous observation in the city.