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

吉田　龍人[1]・堀井　大輔[1]・菊池　恵和[1]・髙森　真紀子[2]・高森　秀司[1]

[1]正会員　八千代エンジニヤリング(株)　技術創発研究所（〒111-8648 東京都台東区浅草橋 5-20-8）
E-mail: ry-yoshida@yachiyo-eng.co.jp (Corresponding Author)

[2]正会員　八千代エンジニヤリング(株)　社会計画部（〒111-8648 東京都台東区浅草橋 5-20-8）

まちなかの交流・滞在空間創出に向けた取組が展開しており，都市空間の行動観測ニーズが高まる一方で，人手調査はその労力過多が課題であり，負担の少ない手法の開発は重要である．

本研究は，ビデオ動画に AI（深層学習）解析を適用した「人流関連データの自動抽出」を検討したものである．具体的には，先行研究を踏まえ，歩道空間の通行者を歩行者と自転車に区分した検出と，追跡の精度向上に関する検討を行った．結果，歩道空間通行者の詳細な位置及び時間情報の取得を可能とした．また，取得したデータを加工し，歩行者・自転車（3 区分）別，方向別，時間帯別の「通行者数」「速度」「通行位置」の計測と結果の可視化を行った．検討経緯・結果を踏まえ，今後の人流データに基づく都市空間の特徴評価や分析等に資する基礎研究として展望をまとめた．

Key Words: *Pedestrian Flow Analysis，Bicycle，Video Survey，Deep Learning*

1.　はじめに

2020 年に国土交通省から「ストリートデザインガイドライン ver1.0」[1]が公開されるなど，街路などの公共空間を人中心とする空間へと転換する様々な取組が展開されている．取組を行う中で，空間の変化が人々の行動に与える影響を把握することが望まれるが，行動把握のための調査は人手に依存しがちな状況にある [2]．人手による調査では，現地の直接的な観測や，道路上に設置したビデオカメラ映像の目視判別など様々な方法が取られるが，いずれも人がチェックする作業を要するため，多大なコストや人的資源を要する．同時に，コストの制約によって調査地点数や調査日数などが限定されるといった課題がある．

これに対して，近年の技術発展やサービスの多様化に伴って，調査を自動化する様々な手法 [3]が検討されている．中でも，ビデオカメラの映像解析による手法は，一般に普及しているビデオカメラの映像を活用した汎化性の高い手法であることから，上述した公共空間内の行動把握調査の課題解決に資する手法と考える．また，映像から通行者の様々な属性情報等を分析できる可能性もあり，調査データの新たな活用につながることも期待できる．

これまで目視判別で行われてきたビデオ映像の解析を，AI，特に深層学習を活用した自動化を目指す研究事例は複数確認 [4]できる．髙森ら [5]は，ビデオ映像から歩道内の通行者の位置情報等の取得と，その軌跡を可視化する手法を提案し，高コストを課題とする人手調査に対する AI 解析の代替可能性を示した．

一方，髙森ら [5]の研究では，通行者を歩行者と自転車に区分できていない点に課題がある．自転車は都市内交通で一定の分担率を占める重要な移動手段であり，今後，道路空間利活用を展開するにあたり，通行のための空間が限定されることによる，自転車と歩行者の錯綜や接触リスクの影響は検証すべき課題となる．既に山中 [6]によってビデオから取得できる観測量から歩行者および自転車の錯綜現象を指標化し，道路のサービスレベルを推計する手法は提案されているが，ビデオの目視判別によって観測量を取得するため，評価の実施にコストを要する点が課題である．歩行者と自転車の交通状態を簡便に把握可能な手段の開発は，公共空間利活用の計画検討や評価において有意義と考える．

これを受けて，本研究は今後の公共空間利活用の円滑な推進に資する技術として，ビデオカメラ映像をもとに，AI 解析を活用して歩行者と自転車を区分した人流関連データを自動抽出する手法の開発を目的とした．具体的には，一般に公開されている人検出 AI と新たに構築した自転車検出 AI を組み合わせて推論を実施し，物体検出結果に人と自転車の属性情報を付与することで，ビデオカメラ映像から歩行者・自転車別の通行者の軌跡を取得する手法の検討に取り組んだ．

2. 先行研究と本研究の位置付け

動画の人流解析は，動画上の各人物の軌跡を取得することを目的とする．AI 解析を使った軌跡の取得は，「物体検出」と「物体追跡」によって成り立つ．物体検出では物体の存在する位置が Bounding Box と呼ばれる（以降，BBox と呼ぶ）矩形で表現される．**図-1** にて自転車を囲う矩形が BBox の例である．「物体追跡」では各フレームで検出された BBox から同一人物の組み合わせを識別する．物体検出の推論結果と物体追跡を活用して人や車などの移動体の軌跡を取得する技術は，Multi-object Tracking challenge [7]にて様々な手法が検討されている．一方でこれらの技術を使って実際に都市空間における人々の行動特性を評価した事例は少ない．

これに対して髙森ら [5]は物体検出と追跡を活用した AI 人流解析手法を構築するとともに，人手での計測との精度比較結果を示した．人の検出には事前学習済みの公開モデルである openvino toolkit の person-detection-0101 [8]が用いられたが，当モデルでは自転車運転者も検出されることから，歩行者と自転車が混在した通行者の軌跡が取得されていた．さらに目視計測結果との比較の観点から，人手で計測可能な項目のみを計測していた．

本研究は，これらの課題を踏まえて髙森ら [5]が提案した AI 人流解析手法の改良を行ったものである．まず自転車検出モデルを追加し，歩行者・自転車を区分した人流解析を行う方法を検討した．さらに画像の幾何補正を応用して，軌跡データから入手可能でき，今後の人流解析で活用可能と想定する指標を複数設定し，その計測方法の検討と実動画を用いた各指標の計測を試みた．

3. 人流解析の手順

本章では動画の撮影方法，解析に要する自転車検出モデルの構築手順および構築の結果，解析で得た軌跡に基づく人流に関する指標の計測方法を示す．

(1) 動画の撮影

本節では人流解析のベースとなる動画の撮影方法を示す．動画は人の検出に用いる person-detection-0101 が正しく動作するよう撮影する．モデルには 300×300 サイズにリサイズした画像を入力する仕組みとなっており，Full HD 以上の画質のカメラで 2m～3m 程度の高さから，歩道を斜めに見下ろすように撮影した画像で人が概ね検出されることを確認している．フレームレートは軌跡の取得頻度に関わるが，一般的な 30fps で撮影すれば 1 コマ約 0.03 秒となるため人流解析に支障はないと考える．

撮影された動画の例として，本論文の 4 章で解析結果を示す動画のあるフレームを**図-1** に示す．本動画は JR 三鷹駅北側の 35° 42' 13.0" N，139° 33' 38.3" E 付近で撮影されたものである．撮影日時は 2022 年 5 月 18 日(水)の 10 時～16 時である．当該現場の画面中央の手前側にはベンチが設置されており，その背面は防護柵を介して駅前広場に面していることから，ほぼ全ての通行者が左右方向に通り抜ける．撮影実施中は歩道の中央よりやや奥側に白い三角コーンとカフェセットが設置されている．

図-1 解析対象画像および対象画像への自転車検出例

(2) 自転車検出モデルの構築

歩行者・自転車を区分した人流解析の実施に向けて，自転車検出モデルを構築した．本節では，自転車検出モデルの学習手順および結果を示す．

a) 教師画像の作成

教師画像は**図-1** の現場を含んだ計 31 地点の都市部を撮影した Full HD 画質以上の動画を基に作成した．動画はいずれも person-detection-0101 で人が検出されることを確認している．

ラベルとして付与する BBox は，運転中の自転車のみを検出する目的で，自転車本体と運転者を含めた．さらに自転車を種別に検出するモデルを構築し，属性情報を踏まえた人流解析を実施する目的で，BBox に車種のラベルを付与した．設定したラベルと収集した教師画像枚数を**表-1** に示す．**表-1** に示すシティサイクルとは一般的な街乗り用の自転車を指し，スポーツサイクルとはクロスバイク，ロードバイクなどの自転車を指す．ただし，これらの呼称は俗称であり，車種を分類する正式な基準を確認できなかったため，本研究では前かごの付いた自転車をシティサイクル，付いていない自転車をスポーツサイクルと定義した．

ラベルは動画内で多数確認された自転車種別により設定しており，ミニベロやキッズサイクルなどを含めたより詳細な自転車種別を区分したデータセットの構築は今後の課題とする．

表-1 アノテーション画像枚数

車種		枚数
シティサイクル	チャイルドシートなし	616
	チャイルドシートあり	588
スポーツサイクル		594

b) 自転車検出モデルの学習

自転車の計 1,798 枚の画像を 8 対 2 の割合で Train と Test に分割し，学習を行った．ベースモデルは人検出モデルに採用されている SSD [9]とした．学習時は 5epoch ごとに Test に対する mAP を算出し，mAP が最大となった時点のモデルを採用した．学習の結果，最大 mAP は 0.763 となった．この結果は，Liu [9]らが示す PASCAL VOC データセットでの mAP と同等であり，十分な精度が得られたと判断した．

(3) 物体検出結果に基づく人流関連指標の計測

本研究で提案する人流解析は，歩行者・自転車別の「軌跡の取得」，「幾何変換による空間解像度の統一」，各軌跡の「移動方向の判定」をベースとし，その結果を基に人流解析に関連する指標の計測を行うものとする．

a) 軌跡の取得

軌跡は歩行者・自転車の検出結果から物体追跡の処理を行い取得する．なお画面奥（遠距離）の検出結果は物体追跡に悪影響を及ぼすことを確認したため，**図-1** の赤線に示す範囲に限定して解析を行った．

本研究ではcentroid tracking [10]とRe-Identification [11]を組み合わせたアルゴリズムによって物体追跡を行った．centroid trackingはフレーム間で物体の移動量が最小となる組み合わせによって追跡を行う処理だが，すれ違い時などに異なる人同士を同一人物の軌跡として追跡する現象が問題となる．これに対し，centorid trackingにRe-Identificationを組み合わせることで人の見た目も考慮した追跡が可能となるため，centroid trackingの誤追跡の影響を低減できる．また，オクルージョン（物体同士が画面上で重なり合って奥の物体の検出精度を低下させる）発生時でも軌跡が取得できるよう，軌跡同士が接近した際は，BYTE [12]と呼ばれるアルゴリズムを適用した．BYTEとは，Confidenceの低下によりBBoxが途中で消失した際に，BBoxが消失した位置付近における低いConfidenceの推論結果を許容する手法である．BYTEを適用することで低いConfidenceでもBBoxを保持することができ，オクルージョン発生時でも途切れることなく軌跡が取得できる．

さらに，person-detection-0101 と自転車検出モデルの 2 つのモデルで推論を実施すると自転車運転者と自転車が 2 重で検出されるため，得られる軌跡も 2 重となる．そこで 2 重となった軌跡のうち，自転車運転者の軌跡を除去する処理を行った．同一の軌跡は自転車および自転車運転者の軌跡に対してフレームごとにユークリッド距離を測り，ユークリッド距離の総和が最も小さくなったものと定義して除去を実施した．

b) 幾何変換による空間解像度の統一

物体検出および物体追跡で得られる軌跡は，画像上の座標で表現される．動画の元の座標空間において，カメラと対象物との距離に応じて空間解像度は変化するため，距離を直接的に計測することは困難である．

そこで本研究では距離の計測のため，幾何変換による空間解像度の統一を行った．幾何変換とは，ある座標をある座標へと写像する画像処理技術で，特に本研究ではHomography Transformation [13]を用いた．変換実施時は実空間上で形状および大きさが既知の範囲を参照し，画像上の対象範囲の形状と大きさを既知の値と対応させる．Homography Transformationは，変換を行う基準点を 4 点確保できれば，形状に制約なく変換が実施できるといったメリットがある．変換前後の各点の対応関係によって，Homography Transformationの変換式である(1)式のパラメータ H が算出でき，オリジナル画像における任意の座標 x，y を実空間の距離と紐づいた x’，y’へと写像することができる．

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \mathrm{H} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \tag{1}$$

図-2 に実際に幾何変換を実施した例を示す．変換により，斜め視点の画角が俯瞰の画角となった．変換時に用いる基準点には，動画内で一時的に設置したビニールシートを用いた．ビニールシートは短辺 250cm，長辺 340cm であるため，シートの四隅を基準にし，画像上で短辺 250px，340px の長方形になるよう変換をかけた．

また，変換を行うことでカメラレンズの樽型歪曲が顕在化した．より高精度な計測に向けてキャリブレーションを行い歪みを補正することが望ましいが，今後の課題として以降の処理を行った．

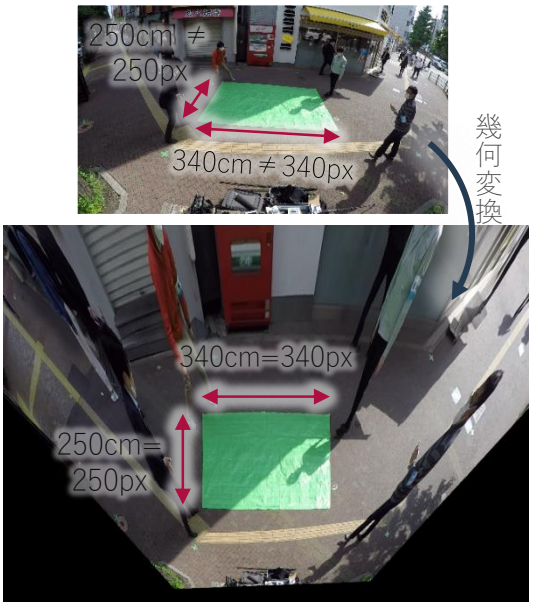

図-2 幾何変換実施例

c) 移動方向の判定

本項では各軌跡の移動方向を判定する方法を示す．本研究では**図-1** の現場の通行状況を考慮して，左右方向のみと定めた．このとき U ターンした通行者の方向も判定できるよう，BBox が初めて出現した位置（以降，In と呼ぶ）と，BBox が消失した位置（以降，Out と呼ぶ）のそれぞれに左右の方向を定義した．

軌跡が極端に短い場合や，In と Out 間のフレーム数が少ない場合は方向不明とした．**図-1** において方向不明とする基準は，元の座標空間における軌跡の横軸方向の最大値と最小値の差分が200px（2m相当）以下の場合か，In と Out 間のフレーム数が 120 フレーム（4 秒）以下の場合とした．なお，方向不明者にはカフェセットの利用者など長期滞在者も含まれていたが，人と誤検知された三角コーンが解析に悪影響を及ぼすため，以降の処理の対象から除外した．このように，対象動画によっては画面上の人以外の物体が長期にわたって誤検知されるリスクがあり，長期滞在者の空間利用実態の調査のためには，誤検知を除去する必要がある．誤検知除去方法の検討は今後の課題とし，本研究では移動中の人物のみを対象として解析を行った．

d) 人流関連指標の計測方法

本項では，人流解析に関すると想定した指標と，その計測方法を示す．本分析結果から算出可能な指標類は多種あるが，本稿では，山中 [6]で使用されるものや既往の調査 [14]を踏まえ，「通行者数」，「時間帯別通行者数」，「通行速度」，「通行位置」とした．

通行者数は，人流解析で出力される ID 別の軌跡の本数から計測する．さらに，録画開始時の実時間と動画のフレームを同期する処理を行うとともに，任意のフレームごとに通行者数を測ることで，時間帯別の通行者数を計測する．

物体の通行速度は，幾何変換後の座標データを使って，フレーム間のユークリッド距離により計測する．速度の算出式を(2)式に示す．ここで x，y は幾何変換後の BBox の座標，f はフレーム数，n は軌跡のプロット数を表している．なお速度を毎フレームで計測すると，動画のフレーム間で 1px 程度しか変化のない物体の移動量に対して，数 px の物体検出誤差が生じるため，計測誤差が増大する点が課題となる．対応として，一定のフレームごとに平均を取ったxおよびyの値から速度を求めることが妥当と考え，**図-1** の動画にて定性的に物体の移動が確認された 11 フレームごとに速度を計測することとした．

$$\bar{v} = \frac{1}{n}\sum_{i=1}^{n}\frac{\sqrt{(x_{i+1}-x_i)^2+(y_{i+1}-y_i)^2}}{(f_{i+1}-f_i)} \qquad (2)$$

方向別の歩行者・自転車の通行位置の可視化にあたり，2つの方法が考えられる．

【方法 1】各軌跡を直接的に描画した図を作成する方法である．この方法は最も端的に通行位置を可視化するが，長時間の撮影による軌跡データを描画する場合，軌跡同士が重なり，視認性・解釈性の低下が課題となる．

【方法 2】進行方向に対して垂直な方向を通過断面とし，各通行者が通過断面上を通る位置を確率として表現する方法である．**図-2** の幾何補正画像を例とすると，横軸を進行方向，縦軸を通過断面とみなし，縦軸上に通過位置を確率分布として表現する．本手法は進行方向が一次元的な区間以外での適用に課題があるが，出力の視認性・解釈性の高さや，途切れた軌跡が解析精度を低下させない等の特徴がある．

4．計測結果

本章では 3 章に示す手順に従い，**図-1** に示す区間の 6 時間の動画を解析し，人流の傾向を調査した結果を示す．

(1) 通行者数・時間帯別通行者数

通行者数の計測結果を**表-2** に示す．本計測結果では，歩行者・自転車ともに左から右へと通行する人の方が多く「左→右」は「右→左」の概ね 1.5 倍程度となった．

自転車交通量では，シティサイクル（チャイルドシートなし）が最多であるが，チャイルドシートありのシティサイクルも 22%と一定割合を占めることを観測した．

歩行者の方向別の通行者数を 15 分単位で計測した結果を**図-3** に示す．**図-3** よりいずれの方向も歩行者通行量のピークは，正午前後と夕方にある傾向が確認できる．

また，正午前後のピークの山は，方向別で 30 分程度のズレがあり，仮説としては，昼食休憩での往復行動を捉えた可能性などが推察される．

(2) 通行速度

幾何補正を行った位置情報によって，歩行者・自転車の平均速度を計測し，速度分布を算出した結果を**図-4** に示す．なお移動している人のみを対象とする目的で，方向が「右から左」もしくは「左から右」と定義され，「30 秒以内に画面を通り抜けた人」のみの速度を計測した．通行速度は，歩行者が 3.6km/h=100cm/s 付近，自転車は 7.5km/h 付近をピークとする分布となった．また，自転車でも時速 5km 以下が一定数いることが確認された．

表-2 通行者数計測結果

	進行方向		合計	
	左→右	右→左		
歩行者(人)	2,618	1,811	4,429	
シティサイクル チャイルドなし(台)	224	152	376	556
シティサイクル チャイルドあり(台)	72	50	122	
スポーツバイク(台)	37	21	58	
合計	2,951	2,034	4,985	

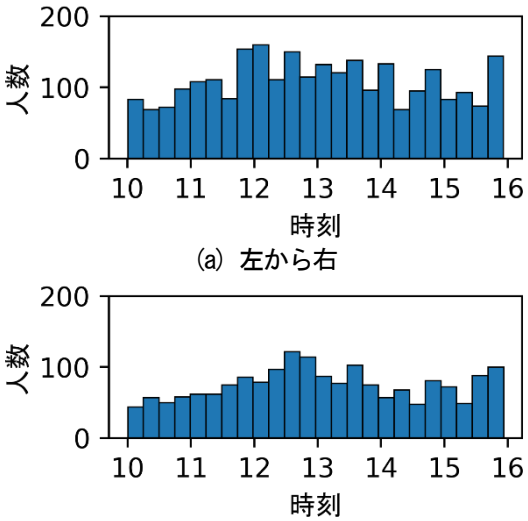

(a) 左から右

(b) 右から左

図-3 時間帯別歩行者数計測結果

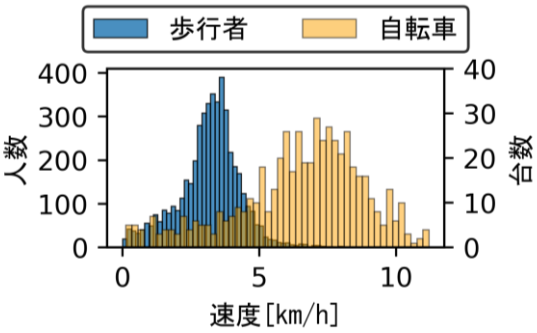

図-4 歩行者・自転車の速度分布

解析結果を確認すると自転車を押して歩く歩行者がしばしば自転車として検出されており，平均よりも遥かに低速で移動する自転車はその影響と推察する．また，方向不明者は除外したにも関わらず 0 に近い通行速度の人物が残った．これらの挙動の要因分析は今後の課題である．

(3) 通行位置

図-5 に対象現場を模した挿絵に左から右へ通行する歩行者の軌跡を表現（**3.(3) d) の方法 1**）した結果を示す．なお挿絵には，点字ブロックと動画撮影中に画面上部に設置されていたカフェセットおよび三角コーンを示している．**図-5** より歩行者がカフェセット側を集中して通行している様子が確認できる．また，**図-6** (a)は，画像の縦軸の通過位置を 10cm メッシュとして確率分布を表現（**3.(3) d) の方法 2**）した結果である．

どちらも主要な動線を表現できているが，相対的な比較としては，地点別の通過（滞在）確率を表現する**図-6** (a)の方が，地点別の通行特性を定量的に解釈する上で有効な可能性があると考える．

図-6 には，歩行者・自転車の方向別の通過割合をそれぞれ表現した．いずれの方向においても歩行者は内側（カフェセット側）を通行し，自転車は比較的外側を通行する傾向が確認できており，歩行者と自転車の通行位地のすみ分け（危険回避や，自転車における「遠回り」への抵抗感の低さ）に係る意識の存在が推察されるなど，直観的な感覚にあう計測結果となっている．

一方，本節の解析結果において，①歩行者・自転車で取得される軌跡の範囲が異なる，②自転車の方向別の計測結果で左端の長さが異なる，③歩行者の結果において左右端付近で放射状に軌跡が割れているといった問題を確認した．①はモデルの特性の違いに起因すると判断する．自転車検出モデルは人検出モデルに比べて Confidence が低い傾向にあり，小さく写った画面奥側は検出漏れが発生する傾向にあった．②は BYTE の影響と推察する．**図-1** の検出対象領域は右側が狭く，左側が広かったため，自転車検出モデルの Confidence が低くなった場合でも左側の検出が維持され，右から左に通行する自転車の軌跡が伸びたものと予測する．③は推論実施時に画像を 300×300 にリサイズした影響と SSD のデフォルトボックスの影響によるものと推察する．なお，割れの形状が放射状であるのは幾何変換の影響であり，変換前の画像では縦方向の縞状に割れが確認されている．Full HD 画像を複数のメッシュに分けて推論することで問題解決する可能性を想定するが，検証は今後の課題である．

(4) 計測結果を踏まえて

本章では，人流解析の要素として「通行者数（時間帯別を含む）」「通行速度」「通行位置」の分析が可能であることを確認した．さらに，作業過程における課題等を整理した．項目によっては従来の人手調査では現実的に集計不可能な粒度の位置・時間情報のデータが取得でき，AI 解析を活用した人流調査の優位点を確認できた．

本研究において，深層学習のアプローチとして自転車検出モデルの精度は検証されたが，人流調査手法として精度検証は未完了であり，AI 等を活用した交通特性の評価・適用に向けた展開では，実データとの比較検証が必須である．

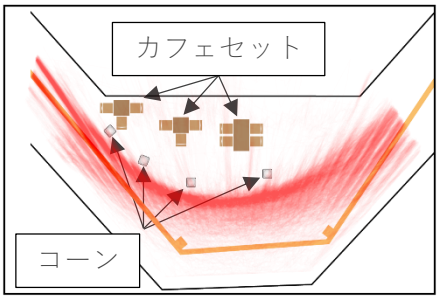

図-5 左から右に通行する歩行者の軌跡

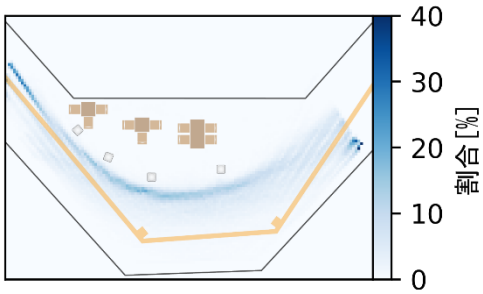

(a) 歩行者 左から右

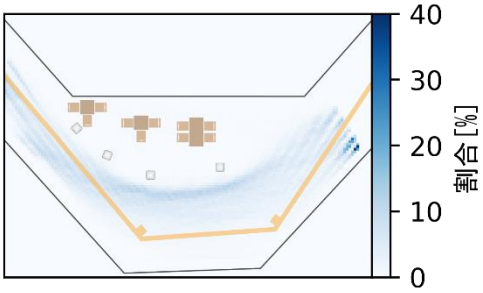

(b) 歩行者 右から左

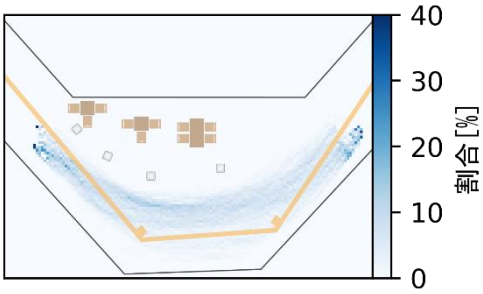

(c) 自転車 左から右

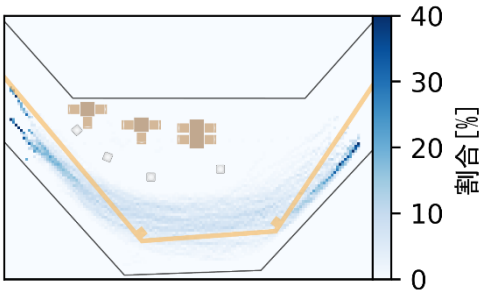

(d) 自転車 右から左

図-6 通過位置の確率分布

5. おわりに

(1) 検討成果

本稿では，一定の（汎化性の高い）条件で撮影した動画をもとに，AI 解析を適用することで，歩道空間内の交通特性（「通行者数」「時間帯別通行者数」「通行速度」「歩行位置」）を簡便に分析可能な手法を開発した．

- 通行者について，歩行者と自転車（３区分）を区分しての分析を可能とした．
- 幾何変換を適用し，軌跡の座標情報を正規化したことで，距離と速度の算出を可能とした．
- 軌跡（通過・滞在箇所）の結果の可視化において，確率分布の表現を提案し，解釈性等の可能性を確認した．
- 副次的な結果として，長時間の撮影データに対する分析が可能なことを確認し，人手調査における時間の制約条件（調査の実現性）の解消の可能性を提示した．

(2) 課題と今後の展望

作業過程に確認された課題は，適宜検証等を進める．また，分析結果と実データとの比較検証については，実務適用に向けた必達事項と捉え，今後対応を進めたい．

また，本稿では交通特性指標として 4 項目を計測したが，デジタル化した人流の生データは，1 ピクセル・1 フレーム単位の位置情報と時間情報であり，その加工性の高さを生かした表現や都市空間の特徴分析への展開を図りたい．

また，AI 解析による人流のデジタルデータ化は，作業コストの低減に留まるものではなく，そもそもの観測・分析対象の拡大と昇華（例えば常時観測と常時分析）に繋がる基礎技術と捉えている．スマートシティ等の取組も念頭に，今後の適用に向けて研究開発を進めたい．

謝辞：本研究で活用したビデオデータは，武蔵野市都市整備部まちづくり推進課の全面的なご協力により撮影したものであり，また，ビデオ調査データの利用についてもご快諾を賜りました．ここに記し，謝意を表します．

参考文献

1) 国土交通省：ストリートデザインガイドライン ver2.0，2021.
2) 国土交通省：まちなかの居心地の良さを測る指標（案），2020.
3) 国土交通省：まちの活性化を測る歩行者量調査のガイドライン，2018.
4) 例えば今井龍一，山本雄平，姜文渊，神谷大介，中原匡哉，安藤祐輝：頭部に着目した歩行者交通量調査に関する研究，土木学会論文集F3，2022年78巻2号，pp.82-92，2022.
5) 髙森真紀子，大久保順一，藤井純一郎：都市空間での人流解析における深層学習の応用，AI・データサイエンス論文集，2巻 J2 号，pp.113-120，2021.
6) 山中英生：交錯指標による自転車・歩行者混合交通のサービスレベル評価方法と分離必要度の分析，土木学会論文集D3，68巻1号，pp.49-58，2012.
7) P. Dendorfer, A. Osep, A. Milan, K. Schindler, D. Cremers, I. Reid, S. Roth, and L. Leal-Taixe: Motchallenge: A benchmark for single-camera multiple target tracking, IJCV, vol. 129, no. 4, pp.845-881, 2021.
8) Intel OpenVino TOOLKIT：person-detection-0101，2021，https://docs.openvino.ai/2020.4/omz_models_intel_person_detection_0101_description_person_detection_0101.html，(参照-2022/09/26).
9) W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed., C.Y. Fu, and A.C. Berg : SSD:Single Shot MultiBox Detector, arXiv:1515.02325, 2016.
10) J.C. Nascimento, A.J. Abrantes, and J.S. Marques: An algorithm for centroid-based tracking of moving object, 1999 IEEE International Conference on Acoustics, Speech, and Signal Processing., 1999.
11) H. Wang, H. Du, Y. Zhao, and J. Yan：A Comprehensive Overview of Person Re-Identification Approaches., IEEE Access, Vol.8, pp. 45556 – 45583, 2020.
12) Y.Zhang, P.Sun, Y.Jiang, D.Yu, F.Weng, Z.Yuan, P.Luo, W.Liu,and X.Wang, ByteTrack: Multi-Object Tracking by Associating Every Detection Box, arXiv:2110.06864, 2021.
13) Q.T.Luong, O.D.Faugeras: The Fundamental matrix: theory, algorithms, and stability analysis, International Journal of Computer Vision, vol.17, no.1,p.3,1996.
14) 柴田久：大分 昭和通り･交差点四隅広場のリボーンプロジェクト プロジェクトレポート，2018，http://www.tec.fukuoka-u.ac.jp/tc/labo/keikan/works/project/pj%20report/reborn_pj%20report.pdf，(参照-2022/09/26).

(Received September 30, 2022)

TRAFFIC SURVEY METHOD TARGETING PEDESTRIANS AND BICYCLES BY VIDEO ANALYSIS BASED ON DEEP LEARNING

Ryuto YOSHIDA, Daisuke HORII, Yoshikazu KIKUCHI, Makiko TAKAMORI and Shuji TAKAMORI

There are demands for surveying people's behavior in public space. However, survey relied on manpower has issues about workload and it is necessary to reduce the cost of survey. This study aim to develop a traffic survey method targeting pedestrians and bicycles by automatic video analysis using deep learning. We are able to obtain detailed trajectories of pedestrians and bicycles separately. Through trajectory data processing, “Number of passersby”, “Velocity”, and “Trajectory” can be measured and visualized by pedestrians/bicycles, by direction, and by time period. In conclusion, outlook for the future is shown about this method that evaluates characteristics in public space.