

A I 画像解析及び自転車プローブデータを用いた自転車動向調査

田中 彩音¹・図師 友広²

¹近畿地方整備局 兵庫国道事務所 管理第二課 (〒650-0042 神戸市中央区波止場町3-11)

²近畿地方整備局 福知山河川国道事務所 (〒620-0875 京都府福知山市字堀小字今岡2459-14) .

本論文は、DX技術の進展を背景に、AI画像解析技術と自転車プローブデータを活用して、自転車の動向を調査する方法について紹介するものである。効率的かつ正確に自転車の動向を把握することで、今後の安全で快適な自転車通行空間の整備等に生かすことが期待される。

キーワード 自転車, DX, AI 画像解析, 人流データ

1. はじめに

数ある交通モードの中で、自転車は最もその利用実態や特性が把握しにくいもののひとつである。日々の通勤や通学のほか、レジャーやスポーツ、買い物など、様々な目的で自転車を使用する。また、自転車の移動経路は多様であり、道路や歩道、公園、さらには私有地など、指定されたルート以外の場所を含むことがある。他の交通モードと比べて非常に個別的かつ非計画的に利用される傾向から、自転車の動向を正確に追跡し、分析することが難しくなっている。挙動や軌跡も複雑で、交通状況把握の最も基礎的なデータである道路交通センサス調査においても自転車は計測対象外となっている。

一方、令和3年5月に第2次自転車活用推進計画が閣議決定されるなど、低炭素で健康的な移動手段として今後も自転車の活用が求められており、安全で快適な走行空間を確保するための実態把握が不可欠である。

本稿は、上記の背景を踏まえ、捉えにくい自転車の利用動向を、DX技術を活用してマクロな視点・ミクロな視点の両面から把握しようと試みた結果を報告するものである。

2. 自転車の利活用実態把握における課題

(1) 自転車の挙動把握における課題

従来、自転車の調査方法としては、調査箇所にビデオを設置、記録を行い、目視にて通行台数の計測及び衝突その他の利用上の問題を観測して実施していた。従来の

調査手法には非効率な面があり、より効率的に事象を計測できる手法が求められている。

(2) 自転車の交通量や経路・OD把握における課題

自転車の交通量は前項に挙げたビデオ調査や人手による観測により計測することができるが、あくまでも調査日一日の量しか把握できない。また、移動経路や発終点を把握する方法としては、アンケート調査が挙げられるが、アンケートに回答した限られた対象の傾向となってしまう。これをより網羅的に把握するための手法が求められている。

3. 調査対象箇所及び目的

国道171号甲武橋は、近傍に複数の中学校や高校が立地しており、周辺地域の学生が通学ルートとして使用している。しかし、自転車歩行者道幅員が上下線とも1.5m程度と狭く、図-1に示すように、朝夕の通勤通学時間帯は集中し危険な状態である（南側：1,468台/12h、R3.12.16交通量調査結果）。

国道2号武庫大橋は、付加車線が設置された区間において、歩道の有効幅員が1.8m（縁石を加え2.0m）と狭く、朝ピーク時自転車と歩行者、自転車同士の離合が難しいケースが生じている。

本稿では、両橋梁における課題を定量的に把握するため、AI画像解析技術を活用して、すれ違い・離隔の自動計測を実施した。また、当該区間課題の影響を受けている利用者の特性を把握するため、人流データを活用して利用経路や目的地等を分析した。



図-1 甲武橋における自転車同士のすれ違い状況




図-2 アノテーションボックスによる走行軌跡の判定

4. 自転車同士のすれ違い離隔計測（ミクロ視点）

(1) 解析モデルの選定

AI推測モデルは、汎用性の高いUltralytics社のYOLO11（2024/10リリース）を用いた。ライセンスはAGPL-3.0（<https://www.gnu.org/licenses/agpl-3.0.html>）が適用される（複製・改変・再配布・商用利用可）。

(2) 学習データの取得

AI識別に使う画像・映像は固定カメラから撮影されており、撮影位置や画角によって正面、側面、俯瞰など複数パターンの自転車画像の解析が必要となる可能性がある。このため、なるべく多くの学習データから汎用性の高い自転車識別モデルを作成することが重要と考えた。

ベースとした教師モデルは、Roboflow cyclistを活用した。これは、テーマに応じてユーザーが収集した数百～数千枚の画像をダウンロードして利用できる。

多くは識別のための枠の位置情報（アノテーション）が付随しており、学習データ作成時に大部分を占める作業を簡略化できる。アノテーションは、自転車+運転者を囲むボックスであり、下段中央が概ね自転車のタイヤが接地する位置となるため、ボックス下辺中央点の位置の自転車の走行軌跡点を示すことになる。厳密には、奥方向に向かう自転車は後輪の接地部分、手前方向に向かう自転車は前輪の接地部分を示している。（図-2）

しかし、Roboflowからダウンロードしたデータのみを用いて自転車（cyclist）認識モデルを作成し、実際の映像でテストした結果、2台がまとめられて1台となる検知をしたり、検知に著しい遅れが見られたりなど認識精度の低い箇所が一部に見られた。（図-3）

そこで、解析対象とは別日、別アングルで撮影した過年度撮影データを学習に用いて追加学習を行うことにより、精度向上を図った。（表-1、図-4）



図-3 認識精度が低いケースの例

表-1 学習データの画像数

種別	画像数	備考
標準モデル Roboflow cyclist	4,000	ダウンロードデータ
追加学習用画像	330	2022/12撮影データより抽出
合計	4,330	




図-4 認識精度の改善例

(3) 自転車識別AIモデル評価

実際の映像の目視確認数との比較により追加学習後のモデルの適合率、再現率を算出した。検証データは、2024/10/1 7～19時のうち交通量の多い8時～8時30分の30分間データとし、歩道上り・下り自転車に対し、正しくIDが振られているかを確認した。表-2に検証結果を示す。適合率（AIの自転車検知数（正解）/AIの自転車検知数（正解+不正解））は、上下計で99%でありAIでの自転車検知の正確性は高いことが分かった。また、再現率（AIの自転車検知数（正解）/実際の自転車台数）は、上下計で97%であり、ほぼ漏れなく検知できていることが分かった。

(4) 平面投影手法の検討

解析に用いる映像は、歩道上を斜めから撮影した映像であり、すれ違い離隔を計測するためには平面投影が不可欠であった。映像画像上の画素単位での自転車位置情報を実際の位置や距離単位に換算するため、歩道を中心とした平面に投影を行うこととした。投影には実寸を計測したものや図面上の寸法値を基準とした。(図-5)

(5) すれ違い離隔の計測

認識された点の内、歩道内を通る自転車の軌跡点を平面上にプロットした。また点の移動方向分析から上下方向に分類し、方向別に着色を行った。(図-6)

ID別の最接近点をすれ違い離隔として以下のルールで算定を行った。なお、アノテーションボックスの中心間距離に加え、より利用者の実感に沿うように最少離隔測定位置での計測も行った。(図-7)

- ①同時に存在する他IDに対し全時間で離隔距離を算定
- ②①で得られた距離のうち各IDで最小のものを抽出

計測結果を図-8、9、10に示す。中心間は60~100cm、最少離隔は5~40cmの間に分布している。

表-2 モデル検証

計測方法		全体	上り	下り
実際の自転車数		179	65	114
AI検知	AIの自転車検知数(正解のみ)	173	63	110
	AIの自転車検知数(不正解のみ)	2	0	2
	AIの自転車検知数(正解+不正解)	175	63	112




図-5 平面投影イメージ




図-6 軌跡の取得状況




図-7 離隔計測イメージ




図-8 離隔計測結果(cm)

中心間: 67.0cm・最小離隔: 5.66cm 中心間: 71.1cm最小離隔: 10.6cm




図-9 最小離隔の橋梁による差(cm)



図-10 離隔が小さいすれ違いの例

5. 人流データによる移動実態分析（マクロ視点）

(1) 活用するデータの選定

人流データは様々なデータベンダーが提供（販売）しているため、各ベンダーが提供するデータの仕様等を調査し、サンプル数が多く、交通モードで自転車を判別可能なデータであるブログウォッチャー株式会社の「ポイントデータ（行動ログ）」を採用した。当該データは、アンドロイドOSのスマートフォンで特定のアプリをインストールされ、かつデータ取得を許諾されたユーザーのみのデータとなっている。分析期間は令和6年5月7日～6月6日の1ヵ月とし、分析範囲は兵庫県に1度でも履歴が残った自転車ユーザーの期間中全データとした。本分析における仕様は表-3の通りである。

(2) 分析手法の検討

購入したデータは自転車以外を含む膨大な移動データであり、その中から甲武橋及び武庫大橋を通過する自転車移動のみを抽出する必要があった。分析手法が確立されていないことから、以下に示す独自の分析手順を検討した。（図-11）

(3) ステップ1：自転車ログの抽出

兵庫県内全データから、移動手段フラグが自転車となっているログのみを抽出（11,868,307ログ）した。また、作業性を考慮し、武庫川周辺エリアに絞り込み（2次メッシュ4つ分、約25km四方）を行った。その結果、2,348,807ログが残存した。（除去率；80%）

(4) ステップ2：武庫川渡河ログペア抽出

ステップ1で抽出したログについて、同一IDで武庫川を跨ぐログ2点を抽出（74,246ログペア）した。日を跨いだ2点は純粋な移動ではない可能性が高いため、異なる日付である場合を除去し52,783ログペアを抽出した。（除去率；29%）




図-11 分析手順

(5) ステップ3：対象橋梁渡河ログペア抽出

ステップ2まででは、渡河した橋梁が不明瞭であるため、自転車が最短経路を選択する傾向にあることに着目し、DRMルート解析によって渡河橋梁を特定し、甲武橋または武庫大橋を渡河したと考えられるログペアを抽出した。最短経路探索には、ArcGISのネットワークアナリストを使用（図-12）し、道路データはDRMを使用した。なお、自転車の通行ができない高速道路等の自専道は除外し解析した。その結果、11,959ログペアが抽出された。（除去率；77%）

表-3 データ仕様

項目名称	概要
固定ID	ベンダーが付与するID（継続保持）
性別	男、女
年代	20代、30代、40代、50代、60代
取得時間	位置情報の取得時間を日本標準時で表示
緯度	汎化加工済み緯度
経度	汎化加工済み経度
推定居住エリア	緯度経度の8分の1地域メッシュ
推定勤務エリア	（一辺125m）
移動手段	徒歩/自転車/車/電車
移動目的	通勤、退勤、業務、観光、短距離観光、その他
速度	計測時点の瞬間的な移動速度を表す。



図-12 最短経路探索による解析

(6) ステップ4：IDに基づく全移動データの取得

データクレンジングとして、渡河データが非連続なもの、速度が異常なものを除去（図-13）し、残存した5,238ログペアのIDに紐づく全移動を抽出した。

(7) ステップ5：起終点及び経路の分析

自転車だけの移動を抽出し、ログ間隔が15分以上のものはトリップを切断した上で、自転車移動では考えられない挙動を示しているデータを除外した。最終的に、4,649トリップを抽出（表-4）し、起終点・経路を図化した。（図-14）

(8) 分析結果

検討した手順により、甲武橋2,089トリップ、武庫大橋2,560トリップを抽出した。両橋梁とも、平日朝7時～9時、夕方17時～18時にトリップ数が増加する傾向にあった。例として甲武橋の自転車の平日朝7時～9時の通学時間帯における起終点、主な経路を図-15に示す。自転車トリップの終点は、学校や鉄道駅周辺に集中していることから、学生や鉄道通勤者等が多いことが推測される。



図-14 抽出した自転車トリップの例




図-13 速度帯ヒストグラム

表-4 トリップ抽出結果

STEP	クレンジング内容	除去数	残存数	除去率
1	移動手段が自転車のみログ数		11,868,307	
	武庫川周辺に絞り込みログ数	9,519,500	2,348,807	80%
2	武庫川を跨ぐログペア数		74,246	
	一日以内で渡河するログペア数	21,463	52,783	29%
3	武庫大橋または甲武橋を渡河したログペア数	40,824	11,959	77%
4	渡河ログペアの間に他の移動手段が含まれない連続ペア数	4,055	7,904	34%
	渡河時のルート解析速度が5～30km/hのログペア数	2,666	5,238	34%
5	自転車のみの移動の15分区切りのトリップ数	486	4,752	9%
	自転車移動では考えられない挙動を省いたトリップ数	103	4,649	2%




図-15 甲武橋を利用する自転車の経路やOD

6. 今後の課題

(1) 自転車同士のすれ違い離隔計測

図-16に示すように、日没後は著しく精度が落ちる。これは学習モデルが基本的に昼間を対象としているためと考えられ、夜間の画像を学習させることで精度向上が期待できる。平面投影手法は、カメラのパン・チルトやズームに非対応のため、カメラの視点移動があった場合に実距離変換の誤差が生じる。調査は、画角等が変化しないように慎重に実施する必要がある。




図-16 日没前後の平均検知秒数

(2) 姿勢推定poseモデルによる計測

poseモデルは、姿勢による左右（目、耳、肩、肘、手、腰、膝、足）を識別し、それらの座標が得られるため、より厳密なすれ違い離隔を計測することができる可能性がある。例えば、右肘と左肘の間隔を計測することで、より精度の高いすれ違い離隔が得られる可能性がある。

今回試行的に実施したところ、目・鼻がある場合は前向き、それ以外は後ろ向き判定を行っているため、右肘と左肘の関係が入れ替わるタイミング等が見られ、離隔計測が上手くいかないケースが多かった。（図-17）

計測精度を高めるうえで、poseモデルの適用可能性をさらに検証することが望ましい。




図-17 poseモデルによる計測結果

(3) 人流データによる移動実態分析

本分析を通じて得られた留意点を以下に整理する。

- 移動手段の区分がなされているが、速度に着目しクレンジングが必要
- 属性（性別、年齢層）の付与割合が低いため、詳細な属性別分析には適さない
- トリップに分割されていないため、OD分析時は、時系列で並べ替えてトリップ分割の上、起終点フラグを付与する必要がある
- 道路データにマッチングしていないため、経路分析を実施するためにはDRM等にマップマッチングが必要
- 起終点が同じ側になる移動のケースが含まれる購入データは、道路データに紐づけされていないことや起終点フラグがないことなどに留意と工夫が必要である。

謝辞：本論文の作成にあたり、ご助言、ご協力いただいた、（株）建設技術研究所、兵庫国道事務所の皆様に深くお礼申し上げます。