

歩道上に放置・駐輪された二輪車の時空間分布推定のための 画像解析機械学習モデルに関する研究

研究代表者：東京理科大学 寺部慎太郎
研究分担者：東京理科大学 松田昇磨

1. 序論

(1) 研究の背景

自転車やバイク（本研究では原動機付自転車、普通自動二輪車、大型自動二輪車を指す）といった二輪車は都市内交通の重要な交通手段であるが、駐輪場が不足あるいは適切な位置に配置されていないため、歩道上に放置されているものが多い。駅周辺や中心市街地の歩道等には依然として放置二輪車が存在しており、歩行者の通行の妨げとなっている。

特に近年では、交通手段としての自転車に期待される役割は拡大している。2021年に閣議決定された「第2次自転車活用推進計画」¹⁾では自転車が排出ガス低減による都市環境の保全、利用者の健康増進、災害時の移動手段の確保に資する交通手段であると期待されている。

一方で、放置二輪車は長期にわたって対策が求められている課題として残っている。放置二輪車は歩行者の通行を妨げるだけでなく、街の美観を損ねる要因として指摘されている。放置自転車の課題に関しては国土交通省が「自転車駐車場の整備のあり方に関するガイドライン（第2版）」²⁾において放置自転車の現状やそれに対する駐輪場整備による対策を示している。これまでの放置二輪車は鉄道利用者の放置が多かったため、駅前の駐輪場整備は積極的に行われていた。これにより鉄道利用者の放置二輪車の台数は減少した。しかし、駐輪場に余裕がある場合でも路上駐輪が発生しているケースや、通勤通学時間帯ではない日中に路上駐輪が発生するケースが確認されており、放置二輪車対策と利用者のニーズに乖離があることがうかがえる。これらの放置二輪車の利用目的は買い物や食事で、商業施設の利用者に向けた駐輪場の整備が進められていないことが原因となっている。渋谷区が2021年に策定した「渋谷区自転車等駐車場の整備と駐輪対策に関する方針」³⁾では短時間の駐輪を行う場合は放置に対する問題意識が低くなり、目的地から離れた駐輪場や短時間利用であっても料金の発生する駐輪場の利用を避ける場合があると指摘している。このように同じ放置駐輪であっても、目的や放置時間によって放置の傾向が異なり、それにより効率的な放置二輪車対策の手法は異なる。そのため、放置二輪車対策のための利用者の目的や放置時間の把握が重要となっている。

このように地域の駐輪場の配置及び容量を適切に設計するためには、二輪車の駐輪場所、駐輪開始推定時刻、駐輪終了推定時刻、駐輪推定時間、すなわち時空間分布を調査する必要があるが、調査員の目視に頼っている。

さて、国土交通省では、データとデジタル技術を活用し、業務の高度化・効率化・低コスト化などを図るために、インフラ分野のDX⁴⁾を推進している。また、道路分野においては、デジタル技術や新技術の導入等による道路管理や行政手続きの省力化・効率化を目指し、道路システムのDX⁵⁾が推進されている。道路システムのDXでは、深層学習による物体検出などのAI画像解析による、パトロールカー等に搭載するカメラ映像から塗装の損傷状況の自動検知や、CCTVカメラ映像から交通障害の自動検知や交通量調査の自動化・高度化などを試みている。そこで、放置二輪車対策でも自動化・高度化のためのDXは検討されるべきである。



図1 放置自転車の例



図2 放置バイクの例

(2) 研究の目的

本研究の目標は、都市部における放置二輪車の放置時間と放置二輪車の利用目的の関係性を明らかにし、効率的な放置二輪車対策を可能にすることである。

そのため本研究では、機械学習による画像解析技術、歩道上に放置あるいは駐輪された二輪車の検知に応用する。それにより、調査員の目視調査に頼らない、頻度の高い自動化された駐輪二輪車の調査が可能になる。このような二輪車の放置台数に加え放置箇所、放置時間が簡単に調査できるシステムを構築し、この調査結果を用いることにより、地区内の歩道上に放置・駐輪された二輪車の時空間分布を推定することを目的とする。

さらに、調査結果から放置二輪車の放置時間を把握し、利用者の目的や放置箇所周辺の状況に基づいて放置の傾向を分析する。その結果を考察することで、対象地域における放置二輪車の課題を把握し、それに適した放置二輪車対策の実施に貢献することを目指す。

2. 既往研究のレビューと本研究の位置付け

(1) 放置自転車調査に関する研究

辻野ら⁹⁾は交通に対する障害が発生する状況に対してランク付けを行い設定した区域においてランク別に放置台数の調査を行った。台数と相対危険度の間に正の相関が認められる区域では、放置自転車の撤去や駐輪場の整備による放置自転車の台数を減らす取り組みが危険度を取り除くことができるとしている。また、西田ら⁷⁾はパーソントリップ調査において「道路上・歩道上に駐輪」として駐輪場所が記録されたものを放置自転車として集計した。堺市の調査結果とパーソントリップ調査データから集計された結果を比較したところ、ゾーンが異なる点や年代が異なる点から十分な比較ができなかったものの、パーソントリップ調査データから放置時間分布やトリップチェーンの分析が可能になることを示した。

(2) 深層学習による物体検出を用いた車両の交通量調査に関する研究

今井ら⁸⁾は、汎用的な学習器や学習モデルの交通量調査への適応可能性を目的として検討を行った。車両を認識する認識モデルとして物体検出の手法である YOLOv3 の既存モデルを用い、車両の種別を分類する分類モデルとして深層学習の画像分類器の VGG19 で学習、構築し、通過台数と車両の種別（大型車・小型車）が分かる車両認識技術を実装した。岩崎ら¹⁰⁾は、車種別交通量と車両走行軌跡を自動計測できるようにするのを目的として、自動計測を行うアルゴリズムの構築と実験を行った。アルゴリズムの概要は、電力柱の上部から撮影した交差点の交通流動画に対し、ファインチューニングを行った

YOLOv2 を用いて、車種別に各車両の検出をし、車両が初めて計測領域内に入った時に走行軌跡の記録を開始し、前フレームの車両の BBox の重なりを基に同一車両か判断し、計測領域を出るまで走行軌跡を記録するといったものである。中島ら¹⁰⁾は、車種別交通量と車両走行軌跡を自動計測できるようにするのを目的として、これまでにファインチューニングした YOLOv2 を用いて自動計測を行うアルゴリズムの構築と実験を行った。この研究では、YOLOv2 の新しいバージョンである YOLOv3 を用いて交差点内の交通量と車両走行軌跡の自動計測を行う実験を行った。その結果、YOLOv3 を使い車両検出精度や車両走行軌跡の記録精度の向上が見られた。ドゥルバドラハラ¹¹⁾は、市販の安価な Web カメラを三脚に取り付け、歩道から撮影した同映像を画像解析することで交通量調査を行う手法を検討している。本研究では、移動している車両をトラッキングし、進入方向別に通過車両の計測をする手法について検討した。システム概要は、歩道から安価な Web カメラで撮影された動画に YOLOv3 で物体検出を行い車両の検出を行う。検出された車両に対して、マルチオブジェクトトラッキングを行い車両の動きを検出し、推測を行い、車両の ID 割り当てを行う。更にバウンディングボックスの中心が基準線を通じた時カウントし、トラッキングデータから得られる車両の初検出座標により進入方向を特定する。また、トラッキング精度向上のため閾値を設定し、ID の割り当てを行う際に、マッチング候補のバウンディングボックスとカルマンフィルターが予測した値が閾値を超えた場合に同一判定する。計測実験の結果、道路付帯構造物により車両が隠されトラッキング失敗していることや YOLO で認識されていない車両があることが確認された。

(3) 駐輪行動に関する研究

太田¹²⁾は自治体に対して買い物客に対する放置自転車の実態に対するアンケートを実施するとともに、各自治体の放置自転車に対する取り組みを調査した。買い物客による放置自転車に対して問題が生じていると回答したのは 3 大都市圏の自治体や地域の中核的な市を中心に 101 の自治体だった。しかし、問題が生じているとした自治体の半数以上が買い物客等による放置自転車の傾向を把握しておらず、買い物客等による放置自転車の傾向やそれを推測することが可能になるような調査を行っている自治体も 37 自治体であった。買い物客等による放置自転車に向けた対策としては駐輪場の整備がメインとなっており政令市や特別区では駐輪場整備用地の不足が対策に向けた課題となっていることがわかった。吉田ら¹³⁾は京都中心市街地について自転車放置場所の局所的特性の組合せと放置台数の関係について分析を行った。京都市の中心市街地で行われた放置自転車の位置と台数の

調査の資料をもとにカーネル密度分布図を作成し、自転車の放置がピークとなる箇所を特定した。また、決定木を用いて放置状況の局所的特性の組合せを明らかにした。これにより、カーネル密度分布図から得られた放置自転車がなくなる箇所の他に放置台数のなくなる特性をもつ地域を見つけることが可能になった。

(4) 放置自転車対策に関する研究

森重ら¹⁴⁾は撤去頻度の強化に要する限界費用を試算するために、アンケート調査を実施して保管料の支払い意思額や駐輪場所の選択要因をモデル化した。買い物目的の自転車利用者にとっては駅前の駐輪場の利便性が低く、買い物目的の駐輪者に対して利便性の高い駐輪環境を提供する必要があることが分かった。梶田ら¹⁵⁾は駐輪者や違法駐輪者に過去の違法駐輪歴をアンケートして撤去経験とその後の駐輪行動について調べた。撤去後の駐輪行動について関係式を求め、自転車非利用者、駐輪場利用者、違法駐輪者と撤去強度や保管料の関係を示した。その結果撤去された自転車の保管料を上げた場合には違法駐輪とともに自転車利用者全体が減少することがわかった。

(5) 本研究の位置づけ

既往研究では、深層学習による物体検出を車両の交通量調査や人流把握などに応用しようと検討する研究は多数存在するが、物体検出を放置二輪車の状況把握に応用しようとする研究は見当たらない。

また、放置自転車に対して放置台数の調査を行ったり、アンケート調査を行ったりすることで、放置台数を決定する要因についての分析や放置台数の予測を行うものが多く見受けられる。しかし、放置時間に対する分析は少ない。これは調査による放置時間の把握が困難であることが理由にあると考えられる。放置時間の把握には放置二輪車ごとに継続的に行う必要があるが、多くの台数を対象にすると調査コストが大きくなり、分析に適したサンプル数を確保できない。

そこで本研究では、現状の放置二輪車調査で把握できる状況より詳しい状況が簡単に調査できるシステムを確立することを目的として、歩道を撮影した動画に対し深層学習による物体検出を用いて解析を行うことで、放置二輪車の台数・箇所・放置時間が把握できるシステムの構築を試みた。

3. 放置状況の調査

(1) 調査の概要

本研究では恵比寿駅周辺地域を対象地域とした（図3）。渋谷区が指定した放置自転車禁止区域を含む概ね

半径 500m の地域である。恵比寿地区自転車まちづくり協議会にて小規模まちなか駐輪場候補地を検討していたので、それも考慮した。




図3 調査の対象地域

調査では歩道の様子を撮影することで放置二輪車の状況を記録した。撮影方法については、カメラを三脚に固定し、三脚に車輪を取り付けて、三脚を押しながら撮影することで一定の画角を保ちながら撮影した（図4）。



図4 調査の様子

また、撮影開始時には時刻を撮影開始時刻として記録した。調査中は、GPS ロガーを携帯して、撮影中の位置情報を記録した。

撮影は対象地域内の道路から図5に示す17のコースを選定し、撮影を行った。コースでは主に歩道から車道側を撮影し、放置されている二輪車を撮影した。歩道に商業施設が多く面しているコースについては歩道から建物側に向けて撮影を行い、建物側にある放置二輪車についても撮影を行った。また、調査以前から放置二輪車が確認された地点については商業施設でない場合において

もコースに含めて撮影を行い、建物側の様子を撮影した。




図5 調査コース

17の撮影対象コースに対して、2024/8/21（水）10:30-26:00（18時-21時は雨で中断）、2024/9/15（日）10:30-26:00（22時-25時は雨で中断）の日時に撮影を行い、概ね90分に1回巡回して複数回同じ個所の放置状況を記録した。終電後でも放置されている二輪車を把握するため25時以降まで調査した。

(2) 調査結果の集計

調査映像から撮影された二輪車の放置時間、放置箇所の推定を行う。推定を行うために、調査映像から二輪車が写っているフレームを画像として記録した。二輪車1台あたり1枚の画像を記録し、二輪車と画像を対応させた。調査時に記録した映像の撮影を開始した時刻と、画像が該当するフレームの映像における再生時間から、二輪車の画像が撮影された時刻を特定した。放置自転車の場合と同様に放置されたバイクが撮影された場合も画像と、撮影された時刻を記録した。自転車とバイクの画像は合わせて4,335枚記録された。

(3) 放置時間の推定

記録された二輪車が同じコースの異なる時間帯に撮影された映像に記録されているか確認した。複数の時間帯で同じ二輪車が撮影されている場合には初めて撮影された時刻、最後に撮影された時刻、最後に撮影されたあとに同じコースを撮影した際の時刻を記録した。これにより、複数回撮影された放置二輪車は初めて撮影された時刻から最後に撮影された時刻の間は継続して放置されており、最後に撮影された時刻から次に同じコースを撮影した時刻の間に放置を終了したことがわかる。

また、4,335枚の画像から同一の二輪車の判別を行った結果、1,908台の自転車と99台のバイクが本研究の分

析対象として記録された。

(4) 放置箇所の推定

放置箇所推定には、調査時に携帯したGPSロガーに記録された位置情報を利用した。GPSロガーにはランダムな時間間隔で、時刻と位置情報が記録される。屋外にいる場合は位置情報の記録は行われるものの、記録を行う間隔は10秒程度から30秒以上の場合までさまざまであった（時間と移動距離に応じてGPSロガーが適切に記録する設定にしたため）。

画像が撮影された時刻の前後にGPSロガーが位置情報を記録している時刻を特定し、記録された2点の位置を参考に画像が撮影された位置を算出した。具体的には画像が撮影された時刻とその前後にGPSロガーが位置情報を記録した時刻のそれぞれの時間差から、2点の内分点を算出した。記録した画像ごとに位置情報を推定し、地図上にプロットした結果が図6である。同様にバイクを地図上にプロットした結果が図7である。



図6 自転車画像撮影位置と放置時間



図7 バイク画像撮影位置と放置時間

(5) 調査データの特徴

本調査で得られた放置状況のデータは、同一判定された放置二輪車の推測された位置が大きく異なっていた。2 回以上撮影された二輪車は 789 台あり、同じ二輪車と判定されたものの中で、推定された位置が最も離れていた距離は、平均 52.2m、最大 369.7m であった。この誤差の原因として挙げられる要因は GPS ロガーの位置情報の不正確性と、撮影開始時刻の精度がある。

GPS ロガーは 10 秒以上の間隔で位置情報が記録されるため、数メートル程度の誤差が発生しやすい。また、調査開始後など、直前に屋内にいた場合は位置情報が通常の計測間隔と異なる場合や、直前の位置情報の精度が悪い場合がある。

撮影開始時刻は分単位で記録されている。動画内の二輪車が写っているフレームの再生時間は秒単位での記録を行っているものの、撮影開始時刻の精度が悪く、推定される画像撮影時刻と GPS ロガーによって記録された位置情報の照合を行う際に 1 分に近い時間の誤差が大きな位置情報の誤差を引き起こしている場合がある。

以上のことから、分析の際には二輪車の位置情報の不正確性を考慮する必要があると言える。

4. 画像解析機械学習モデル

(1) 画像解析の概要

撮影した動画から撮影者がいる側のガードレール付近の放置二輪車の台数を機械学習により自動的に計測することを目標としている。撮影した動画にYOLO11を実行し出力された結果に対して停止条件と乗車条件を設定し、停止かつ乗車してないと判定された自転車・バイクをそれぞれ放置自転車・放置バイクとして計測した。

(2) YOLO11 の実行

YOLO とは、2016 年に提案されてから今日に至るまで改良され続け様々なバージョンモデルが出ている物体検出モデルである。2025 年 3 月現在、YOLO の最新バージョンモデルは Ultralytics 社が開発した YOLO11 である。今回は YOLO11 の学習済みモデルを使用した。

YOLO11 の特徴としては、物体検出、インスタンス・セグメンテーション（画像内の物体を個別に識別し、ピクセル単位で輪郭を特定する画像認識技術）、物体追跡を同時に行える。そのため、動画に対してYOLO11を実行した結果はフレームごとに物体のクラス（種類）、BBBox（バウンディングボックス：物体を囲んだ長方形）の座標、セグメント領域座標、IDが出力される。

停止条件として以下の二つの条件を設定した（図 8）。

1. BBox の横幅が最大のフレームで、BBox の底辺が動画の半分より下側に位置する

2. BBox 中心の x 座標が連続するフレームでカウントライン(中央に設定)を左から右に通過




図8 停止条件（上：自転車例，下：バイク例）

また、乗車条件として以下の二つの条件を設定した(図9)。

1. カウンタライン通過直後のフレームにおいて、人間と二輪車の BBox の重なり面積が人物の BBox の 30%以上
2. カウンタライン通過直後のフレームにおいて、二輪車の BBox 中心座標が人物の BBox 内




図9 乗車条件

(3) 放置箇所把握方法

放置箇所は「放置二輪車と判定された物体が検出された時の撮影者の位置」とした。そのため、調査時に GPS ロガーを持っているので調査の緯度経度を取得した。放置二輪車の検出時刻の緯度経度をそれぞれの放置二輪車に付与することで各放置箇所を把握した。

(4) 放置時間把握方法

放置時間は以下の方法で把握する。

1. 各動画から、放置二輪車のセグメンテーション画像を切り取る。
2. 切り取られた各セグメンテーション画像を VGG16 という画像分類モデルに入力して最終層の一つ前の層の値を取り出すことで各画像の特徴量を算出する。
3. 最初の時間帯の動画から切り取られた画像に対するそれに続く時間帯の動画から切り取られた画像のコサイン類似度を計算する。（自転車同士・バイク同士で計算）
4. 類似度が 0.70 以上だった場合同一の物体とする。
（同一だった場合、ある時刻に撮影された動画と別の時刻に撮影された動画の時刻差の間中放置されていたことになる）
5. 3、4 を最初に撮影した動画から最後に撮影した動画まで繰り返す。

5. 画像解析の結果とその考察

(1) 放置台数把握結果

2024 年 8 月 21 日に撮影した動画を用いて、ルートごとの放置台数を把握した。正解データ（実測データ）は第 3 章で示した、調査データを目視で確認したものである。その例を表 1、表 2 に示す。ルート 5、ルート 16 はデータに不備があったので算出できなかった。なお、調査ルート番号の 1-1 は 1 ルートの 1 回目に撮影した動画を表している。カウント率は推論値/実測値×100 で計算している。カウント率は実際の台数が 0 の時は「-」、実際の台数=0 かつ推論台数=0 の時は「100%」とした。ルート別のカウント率の分布を図 10、図 11 に示す。

表 1 自転車の放置台数把握結果（ルート 1 の例）

調査ルート番号	実測(台)	推論(台)	カウント率(%)
1-1	9	8	88.9
1-2	10	9	90.0
1-3	9	7	77.8
1-4	13	10	76.9
1-5	16	14	87.5
1-6	16	13	81.3
1-7	15	13	86.7
1-8	7	6	85.7

表 2 バイクの放置台数把握結果（ルート 1 の例）

調査ルート番号	実測(台)	推論(台)	カウント率(%)
1-1	0	2	-
1-2	0	1	-
1-3	0	1	-
1-4	0	1	-
1-5	1	2	200.0
1-6	0	1	-
1-7	0	2	-
1-8	0	0	100.0

(2) 放置箇所把握結果

動画を用いて放置自転車箇所を地図上に示した結果の例を図 12 に示す。




図 10 自転車の放置台数把握結果の分布




図 11 バイクの放置台数把握結果の分布



図 12 放置自転車箇所結果（ルート 1 の例）

(3) 放置時間把握結果

放置台数結果の精度が良かったルート1とルート13で放置時間判定をした。ルート1の結果の一部を表3に示す。なお、表の「正解」列の1というのは1回目の撮影時の時だけに映った放置自転車、1~5は1回目から5回目の撮影時まで放置されていたということである。それぞれの正答率は1ルート：34.2%、13ルート：13.3%であった。

表3 ルート1の放置時間判定結果（一部）

	正解	推論	正誤
no1	1~5	検出失敗（バイクと検出）	×
no2	1	1~2	×
no3	1	1	○
no4	1~8	1,2~3,3~5,6,7,8	×
no5	1~7	1~2,3,4~5,6	×
no6	1~8	1~6,7	×
no7	1~2	1	×
no8	1	1~3	×
no9	1~6	1~3,4~6	×
no10	2~6	6,7	×
no11	4	検出失敗	×
no12	4~5	4~5	○

(4) 放置台数把握結果の考察

昼間の放置自転車の台数把握精度は8割程度となり高い精度が出ているといえる。しかし、道路に対して縦に放置されている自転車が多いルートでは、自転車の一部しか映ってない自転車が多くありそれが原因で精度が低くなったと考えられる。また、ガードレールの後側(道路側)に放置されている自転車が多かったルート3では誤認識が多く精度が低かった。

夜間の放置自転車の台数把握精度は昼間よりも精度は低く、安定していない。理由は、動画内では暗くて自転車がはっきりと見えないためである。

バイクの放置台数把握精度は、昼間・夜間関係なく低い。理由は、チャイルドシート付き自転車やファットバイクなどがバイクとして認識されてしまうので過剰にバイクと検出されてしまうからである。

(5) 放置箇所把握結果の考察

推論による放置箇所をマッピングした結果を見ると、特徴は把握できていることが見てとれた。しかし、放置自転車が車道にあると判定され少しずれている。これは、GPS ロガーの緯度経度データの取得ずれや、カメラとGPS ロガーの時刻ずれ、GPS ロガーの緯度経度取得間隔が約1分と長いのが影響していると考えられる。

(6) 放置時間把握結果の考察

放置時間把握結果の精度はとても低い。原因は撮影回数が8回と多く、放置箇所推定のちょっとしたずれによって別の自転車と認識されてしまい、放置時間が正しく推定できないことが主な原因だと考えられる。

(7) 画像解析の結果とその考察のまとめ

昼間の調査で数回の撮影なら精度良く台数・箇所・放置時間を把握することができるが、今回の調査のように長時間かつ夜間調査があると現状では精度良く把握することが難しいため、改善をする必要がある。また、バイクの精度は放置台数ですら良くないので改善をする必要がある（図13、図14）。



図13 バイクの検知画像の例（バイクと正しく認識した例）



図14 バイクの検知画像の例（ファットバイクをバイクと誤って認識した例）

6. 生存時間解析の方法

本章と次章では、生存時間解析を用いて調査データの分析を行う。生存時間解析とは、特定のイベントが発生するまでの時間を統計的に分析する手法である。これは、患者の疾患の発症などをイベントとして主に医療分野での予測に用いられる。生存時間解析の特徴として、イベントが発生する前に観察期間が終了した場合など、正確なイベント発生までの期間が不明な場合でも打ち切りデータとして分析に利用することができる点が挙げられる。

本研究の生存時間解析ではイベントを放置の終了とし

て、調査による二輪車放置の確認から放置終了までの期間について分析を行う。また、放置時間データを区間打ち切りデータとして扱う。区間打ち切りとはイベントの正確な発生時刻は不明なものの、特定の区間にイベントが発生したことがわかる場合を指す。第3章で解説した放置時間データは、最後に撮影された時刻から、その次の撮影時までの間に放置が終了したことが分かることから区間打ち切りとして扱うことができる。

分析は統計解析ソフトのRに含まれる、区間打ち切り向けの回帰モデルを提供する **icenReg** パッケージを利用した。

(1) ノンパラメトリック最尤推定法

ノンパラメトリック最尤推定法ではデータの分布について仮定をせずに、生存関数の推定を行う。生存関数を生存曲線として図示することで、全体的な放置時間の分布を可視化する。区間打ち切りが含まれるデータにおいては **EMICM** アルゴリズムによって生存関数が推定される。

ノンパラメトリック最尤推定法では推定を行う対象をカテゴリ別に分けることで、それらの違いを可視化できる。対象地域内すべての二輪車について生存関数を推定する一方で、コースごとに生存曲線を描き、小さな範囲での比較を行う。

(2) cox 比例ハザードモデル

cox 比例ハザードモデルはイベント発生までの時間に共変量が与える影響を評価する。生存時間解析における多変量解析手法の一つであり、これにより放置二輪車の周辺の状況から放置時間を予測するモデルを構築する。

各説明変数のイベント発生に対する影響はハザード比で表される。ハザード比はある説明変数が1単位増加した際のイベント発生率の比を表す。ハザード比が1より大きいとき、変数が増加するごとにイベント発生率が大きくなることを示す。ハザード比により変数同士の放置時間への影響の大きさを比較するために説明変数は標準化を行う。

説明変数は、道路幅員（図15）、駐輪場までの距離、放置禁止区域の対象かどうか、鉄道駅までの距離、銀行までの距離、小売店（コンビニ、スーパー、デパート・百貨店、衣料品、医療・美容品、家庭用品、娯楽品、車両関連店舗、食品、美容院）までの距離、公園までの距離である。




図15 対象地域内の道路幅員

(3) 放置時間の予測方法

cox 比例ハザードモデルの結果から、対象地域内の放置箇所を場所ごとに予測する。変数選択、モデル比較を行って選択された cox 比例ハザードモデルのパラメータを利用して相対的なイベント発生リスクをリスクスコアとして算出する。リスクスコアが大きいほど放置終了が発生しやすく、放置時間が短い傾向にあるといえる。

予測のために地図上で対象地域内に 5m 間隔のポイントデータを作成する。このポイントデータについてそれぞれモデルの説明変数として必要な施設との位置関係や周辺の状況を記録し、それらを説明変数としてポイントごとにリスクスコアを算出する。

7. 生存時間解析の結果

(1) 平均的な放置時間の結果

調査対象の放置自転車すべての生存曲線を図16に示す。これを見ると、観測開始から1時間以内に生存確率が50%を下回っている。これは半数以上の自転車が一回目の撮影から次の撮影までの間隔である約1時間30分以内に放置を終了していることを示している。一方で、2割程度の自転車が5時間以上放置されていることもわかる。




図16 放置自転車全体の生存曲線

(2) cox 比例ハザードモデルによる結果

比例ハザードモデルの結果を表 4 に示す。

ハザード比が 1 より大きい車両関連店舗、コンビニエンスストアでは、店舗から遠い（距離が長い）ほどイベント発生率が高い（放置終了が起きやすい＝放置時間が短い）ことを示している。すなわち、これらの店舗の近くでは放置時間が長くなりがちである。

ハザード比が 1 より小さいその他小売店、美容院では、店舗から遠い（距離が長い）ほどイベント発生率が小さい（放置終了が起きにくい＝放置時間が長い）ことを示している。すなわち、これらの店舗の近くでは放置時間が短くなりがちである。

また、道路幅員はハザード比が 1 より小さいので、幅員が広いほど放置時間が長く、放置禁止区域内はハザード比が 1 より大きいので、区域内にある（変数＝1）ほどイベント発生率が高い（放置終了が起きやすい＝放置時間が短い）ことを示している。

選択された変数のうち、コンビニエンスストアを除く変数はすべて p 値が 0.05 を下回っており統計的に有意であった。

表 4 cox 比例ハザードモデルの結果（その 1）

説明変数	パラメータ	ハザード比	p 値
車両関連店舗	0.944	2.570	<0.001
その他小売店	-0.509	0.601	0.003
コンビニエンスストア	0.279	1.322	0.123
美容院	-1.244	0.288	<0.001
道路幅員	-0.159	0.853	0.010
放置禁止区域	0.341	1.406	<0.001
AIC	4695.397		

上記のモデルでは、コンビニエンスストアの近くでは放置時間が長い傾向にあること、美容院の近くでは放置時間が短い傾向があることが、直感と反する結果になった。このモデルではあらゆる種類の店舗までの距離を説明変数としているため、必ずしも最寄りの店舗種類の情報を反映していない可能性がある。

そこで、放置された自転車ごとに放置箇所からもっとも近い施設を調べ、その施設以外の値を 0 とし、近い施設

表 5 cox 比例ハザードモデルの結果（その 2）

説明変数	パラメータ	ハザード比	p 値
駐輪場	-1.118	0.327	<0.001
衣料品店	-0.185	0.831	0.101
スーパー	-0.460	0.631	0.012
コンビニエンスストア	-0.590	0.554	0.006
食品店	0.289	1.336	0.025
銀行	-0.736	0.479	0.043
公園	-0.487	0.615	0.038
道路幅員	-0.119	0.888	0.086
放置禁止区域	0.245	1.278	0.014
AIC	4714.306		

設には放置箇所からの距離を入れる手法で説明変数を設定しなおした。その結果を表 5 に示す。

ハザード比が 1 より大きい食品店では、店舗から遠い（距離が長い）ほどイベント発生率が高い（放置終了が起きやすい＝放置時間が短い）ことを示している。すなわち、この店舗の近くでは放置時間が長くなりがちである。

ハザード比が 1 より小さいそれ以外の種類の店舗では、店舗から遠い（距離が長い）ほどイベント発生率が小さい（放置終了が起きにくい＝放置時間が長い）ことを示している。すなわち、これらの店舗の近くでは放置時間が短くなりがちである。

美容院は変数選択の結果、最終モデルには残らなかった。施設の変数以外の駐輪場、道路幅員、放置禁止区域は他のモデルと同様の結果を示していた。

このモデル（その 2）は直感に近い結果を示したが、AIC は元の距離を変数とするモデル（その 1）よりも大きくなり、放置時間を予測するモデルとしては精度が高くならなかった。

(3) 放置時間の予測

精度の高い、距離の連続値を説明変数としたモデル（その 1）のパラメータからリスクスコアを算出する。

Risk Score

$$\begin{aligned}
 &= (\text{車両関連店舗までの距離}) \times 0.0002064 \\
 &- (\text{その他小売店までの距離}) \times 0.002392 \\
 &+ (\text{コンビニエンスストアまでの距離}) \times 0.001981 \\
 &- (\text{美容院までの距離}) \times 0.007523 \\
 &- (\text{道路幅員}) \times 0.00006164 \\
 &+ (\text{放置禁止区域}) \times 0.3439
 \end{aligned}$$

この式を用いて対象地域内を示したものが図 17 である。駅周辺や恵比寿ガーデンプレイス周辺はリスクスコアが 0.6 以上の地域がある。放置禁止区域の内外でリスクスコアは大きく異なっていることがわかる。




図 17 対象地域内の放置自転車のリスクスコア

(4) 放置バイクに関する分析

放置自転車の分析と同様にバイクについてノンパラメトリック最尤推定法とcox 比例ハザードモデルによる分析を行う。Cox 比例ハザードモデルでは(2)で AIC が最も小さかった放置箇所と施設の距離を変数とする手法で変数を設定する。

ノンパラメトリック最尤推定法によって推定されたバイク全体の生存曲線を図 18 に示す。バイクと自転車の生存曲線を比較すると 3 時間から 8 時間の生存確率が高く、バイクのほうが放置が長い傾向があると言える。




図 18 放置バイク全体の生存曲線

放置バイクを対象とした比例ハザードモデルの結果を表 6 に示す。P 値が 0.05 を下回る変数は 1 つしかなく、選択された変数も 3 つと自転車を対象にしたモデルよりも少なかった。

ハザード比が 1 より大きいその他小売店では、店舗から遠い（距離が長い）ほどイベント発生率が高い（放置終了が起きやすい＝放置時間が短い）ことを示している。すなわち、この店舗の近くでは放置時間が長くなりがちである。

ハザード比が 1 より小さいスーパーや駅では、店舗・施設から遠い（距離が長い）ほどイベント発生率が小さい（放置終了が起きにくい＝放置時間が長い）ことを示している。すなわち、スーパーや駅の近くでは放置時間が短くなりがちである。

その他小売店のハザード比が 1 より大きく、放置自転車の分析とは逆の結果になっている。

表 6 放置バイクを対象とした比例ハザードモデルの結果

説明変数	パラメータ	ハザード比	p 値
スーパー	-1.604	0.201	0.028
その他小売店	1.308	3.700	0.053
駅	-1.272	0.280	0.124
AIC	249.080		

表 6 の結果を用いて(3)と同様に対象地域内のリスクスコアを算出したものが図 19 である。放置自転車のリスクスコアと比べて放置時間が短い傾向を示している範囲が狭く、特に駅西側を除く商業施設が多い地域が自転車

の場合と比べてリスクスコアが小さくなっている。




図 19 対象地域内の放置バイクのリスクスコア

(5) 生存時間解析結果の考察

モデルを 2 種類推定したが、モデル（その 2）の結果が解釈しやすい。しかし結果の解釈が容易なモデルが、必ずしも精度が高くない結果になった。

食品店は比較的施設数が多く、放置箇所との距離が短くなりやすい。このような施設では閾値が小さく設定された場合に二値変数の 0 と 1 の値をとる個体の数が均衡し、予測力が向上したと考えられる。その一方で閾値が大きくなると多くの放置箇所が食品店の近くにあると判定され、食品店の予測力が低下したと考えられる。これは、施設数が恵比寿駅の一つしかない駅の変数が閾値を大きく設定されたときのみ変数が選択されたことに関しても同様の理由が考えられる。

コンビニエンスストアは利用時間が短い施設であるが、コンビニエンスストアの近くでは放置時間が長くなるという傾向が見られた。これは自転車の駐輪時間は利用目的によって応じて決まるという内容に沿う結果とはなっていない。この結果は今回の分析が施設の利用者の放置時間の傾向を正確に予測するものではないことを示している。一つの放置自転車に対して自転車利用者が利用する施設の情報ではなく、利用者が利用しない施設を含む複数の施設との位置関係が説明変数に含まれている。これにより施設利用者の放置時間の長さを予測するのではなく、場所ごとの施設構成と放置時間の関係を分析し、予測するものとなっている。コンビニエンスストアはそのほか小売店と異なり、商業施設が集中するエリア以外にも多く立地しているが、コンビニエンスストアの近くでは放置時間が長いという傾向は商業施設が集中するエリアではないエリアの放置傾向を反映した結果なのではないかと考えられる。そのため、モデル（その 2）では、最寄りの店舗種類を反映した結果になった。

分析からは、放置時間に直接影響するような施設を特定することはできなかったと考えられる。しかし、リスクスコアの予測結果のように周辺施設の構成によって放置時間の傾向が異なることが考えられる。そのため、この予測モデルは単一の施設の発生による放置傾向の変化は予測することが難しいものの、施設立地のパターンから放置傾向を予測することは可能になったと言える。

放置禁止区域内では放置時間が短くなる傾向があることに関して、これは放置禁止区域内において長時間放置を避ける規範意識が現れていることが考えられる。この結果から、長時間駐輪が問題となるエリアを放置禁止区域に設定することが対策として有効であるといえる。

道路幅員が広いほど放置時間が長くなる傾向があることも、放置されている自転車が歩行者の通行の妨げになりにくい箇所での規範意識が低いことを反映していると考えられる。放置禁止区域に関する結果も加味すると、放置時間は自転車利用者の目的地の要素だけによって決定されるのではないといえる。放置しにくいと感じる箇所でも長時間駐輪する必要がある場合は自転車を放置するのではなく、駐輪場を利用することを選択する自転車利用者が多いことが考えられる。

バイクを対象とした分析については、分析対象となったバイクの台数が 99 台と少なかったことから、予測性能が低く、自転車の分析と比べて少ない変数のモデルの方が AIC は小さくなりやすかったことが考えられる。リスクスコアによる放置時間の予測も自転車の場合の予測と比べて極端に小さな値になる範囲が広がった。

8. 結論

(1) 研究の成果

本研究では、恵比寿駅周辺地域を対象に、機械学習による画像解析技術を、歩道上に放置あるいは駐輪された二輪車の検知に応用した。それにより、調査員の目視調査に頼らない、頻度の高い自動化された駐輪二輪車の調査が可能にすることを目指した。このような二輪車の放置台数に加え放置箇所、放置時間が簡単に調査できるシステムを構築し、この調査結果を用いることにより、地区内の歩道上に放置・駐輪された二輪車の時空間分布を推定することを可能にした。

恵比寿駅周辺の 17 のコースを選定し、歩道上に放置された放置二輪車の様子を撮影した。複数回撮影を行い、映像から同一の二輪車を見分けることで撮影された放置二輪車の放置箇所と放置時間を推定した。

画像解析の結果からは、昼間の調査で数回の撮影なら精度良く台数・箇所・放置時間を把握することができるが、長時間かつ夜間調査があると精度良く把握することが難しいことがわかった。また、バイクの精度は高くな

いことがわかった。

放置の終了を対象のイベントとして、観察開始から放置終了までの時間について生存時間解析によって分析を行った。放置時間の分布を確認したところ、1 時間 30 分以内の放置が多いことがわかった。次に、放置箇所の周辺の施設や状況を説明変数として放置終了リスクを予測するモデルを構築した。予測モデルでは放置箇所周辺の小売店などの施設の利用時間と、放置時間の直接的な関係から放置時間を予測することはできなかったものの、商業施設が密集する地域は放置時間が短いなど、施設の立地状況と、放置時間との関係から予測することができた。放置禁止区域外の商業施設が少ないエリアは放置時間が長く、新たに放置禁止区域に指定することで放置の長い二輪車の数を減らせる可能性を示した。

これらの成果は、都市部における放置二輪車の放置時間と放置二輪車の利用目的の関係性を明らかにし、効率的な放置二輪車対策立案に資するものである。

(2) 今後の展望

調査について、より誤差の少ない手法を取り入れることで予測モデルの性能向上が見込める。放置箇所から二輪車利用者の目的地を推測が可能になると、予測性能が高く、解釈のしやすいモデルになると考えられる。そのためには、時間についてより細かく計測を行う調査と、より細かく位置情報を把握する GPS ロガーを用意して調査をやり直す必要がある。

また、夜間における放置自転車情報の把握を可能にすることや、放置時間が精度良く把握できるようにシステムの改良をする必要がある。

本研究では、調査をおよそ 1 時間 30 分ごとに行ったため、放置時間について 1 時間 30 分間隔で把握していたが、実際にはより短い放置時間についても把握することで駐輪場の料金施策などに活かしやすくなることが考えられる。調査間隔を短くするためには、調査コストや、調査範囲の観点から難しくなるため、調査対象の二輪車の台数や地域の範囲を絞って行う必要がある。

予測モデルについて、施設の立地状況と放置時間との関係を予測することが可能になったが、施設と放置時間との直接的な関係について分析することができなかったために対象地域以外の予測が可能になっていない可能性がある。具体的には、商業施設が多い地域は放置が短く、商業施設多いエリアを代表する施設として美容院やその他小売店があると考えたが、これは恵比寿駅周辺に限定した立地特性である可能性がある。そのため、対象地域を変えて同様の調査を行うことで様々な地域に対応した予測モデルの構築が可能になる可能性がある。

参考文献

- 1) 国土交通省. “自転車活用推進計画”.
<https://www.mlit.go.jp/road/bicycleuse/pdf/2plan.pdf>,
(参照 2025-1-18).
- 2) 国土交通省. “自転車駐車場の整備のあり方に関するガイドライン (第2版)”.
<https://www.mlit.go.jp/toshi/content/001611856.pdf>,
(参照 2025-1-18)
- 3) 渋谷区. “渋谷区自転車等駐車場の整備と駐輪対策に関する方針”.
https://files.city.shibuya.tokyo.jp/assets/12995aba8b194961be709ba879857f70/f3b4c48c539f4869b0419de67e8781ab/assets_kusei_000056630.pdf,
(参照 2025-1-19)
- 4) 国土交通省. 技術調査：インフラ分野の dx.
<https://www.mlit.go.jp/tec/tec tk 000073.html>. (参照 2024-1-30).
- 5) 日本道路協会. 道路システムの dx の推進.
<https://www.road.or.jp/event/pdf/20220825-1.pdf>. (参照 2024-1-30).
- 6) 辻野正訓, 白岩正三, 橋本敬: 駐輪状況の危険点数を考慮した放置自転車の調査手法の提案, 運輸政策研究, Vol.16, No.2, p.14-21, 2013.
- 7) 西田純二, 土井勉, 松本直也: パーソントリップ調査データを用いた自転車交通の実態把握に関する研究, 日本都市計画学会関西支部研究発表会講演概要集, Vol.8, p.21-24, 2010.
- 8) 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 (土木情報学), Vol. 75, No. 2, pp.I 150-I 159, 2019.
- 9) 岩崎洋一郎, 竹原洋志, 宮田俊彦, 倉本俊昌, 北島俊孝, 瀬戸口恵. 物体検出アルゴリズム YOLO を用いた交通量と車両走行軌跡の自動計測. 電気関係学会九州支部連合大会講演論文集, Vol. 2018, pp. 307-308, 2018.
- 10) 中島浩平, 岩崎洋一郎, 竹原洋志, 宮田俊彦, 倉本俊昌, 北島俊孝, 瀬戸口恵. 物体検出アルゴリズム YOLOv3 を用いた交通量と車両走行軌跡の自動計測. 電気関係学会九州支部連合大会講演論文集, Vol. 2019, pp. 61-62, 2019.
- 11) Temuulen Dulbadrakh, 鈴木雅人, 北越大輔, 西村亮. YOLO 及び MOT を用いた車種別交通量調査の自動化のための研究. 第 83 回全国大会講演論文集, 第 2021 巻, pp. 437-438, mar 2021.
- 12) 太田秀也: 買物客等による放置自転車の実態及び対策に関する研究, Vol.41, No.2, p55-63, 2018.
- 13) 吉田哲, 大庭哲治: 京都中心市街地における自転車放置場所の局所的特性の組合せと放置台数の関係, 都市計画論文集, Vol.44.2, p49-57, 2009.
- 14) 森重翔太, 佐野可寸志, 西内裕晶: 自転車利用者の駐輪行動特性と住民の効用を考慮した路上駐輪撤去活動の評価, 土木学会論文集 D3, Vol.70, No.5, I_849-I_858, 2014
- 15) 梶田佳孝, 外井哲志, 佐々木友子: 違法駐輪の撤去が駐輪行動の変化に及ぼす影響, 土木学会論文集 D, Vol.66, No.2, p.137-146, 2010.

-
- ¹国土交通省. “自転車活用推進計画”. <https://www.mlit.go.jp/road/bicycleuse/pdf/2plan.pdf>, (参照 2025-1-18).
- ²国土交通省. “自転車駐車場の整備のあり方に関するガイドライン (第2版)”. <https://www.mlit.go.jp/toshi/content/001611856.pdf>, (参照 2025-1-18)
- ³渋谷区. “渋谷区自転車等駐車場の整備と駐輪対策に関する方針”. https://files.city.shibuya.tokyo.jp/assets/12995aba8b194961be709ba879857f70/f3b4c48c539f4869b0419de67e8781ab/assets_kusei_000056630.pdf, (参照 2025-1-19)
- ⁴国土交通省. 技術調査：インフラ分野の dx. https://www.mlit.go.jp/tec/tec_tk_000073.html. (参照 2024-1-30).
- ⁵日本道路協会. 道路システムの dx の推進. <https://www.road.or.jp/event/pdf/20220825-1.pdf>. (参照 2024-1-30).
- ⁶辻野正訓, 白岩正三, 橋本敬：駐輪状況の危険点数を考慮した放置自転車の調査手法の提案, 運輸政策研究, Vol.16, No.2, p.14-21, 2013.
- ⁷西田純二, 土井勉, 松本直也：パーソントリップ調査データを用いた自転車交通の実態把握に関する研究, 日本都市計画学会関西支部研究発表会講演概要集, Vol.8, p.21-24, 2010.
- ⁸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 (土木情報学), Vol. 75, No. 2, pp.1150-1159, 2019.
- ⁹岩崎洋一郎, 竹原洋志, 宮田俊彦, 倉本俊昌, 北島俊孝, 瀬戸口恵. 物体検出アルゴリズム YOLO を用いた交通量と車両走行軌跡の自動計測. 電気関係学会九州支部連合大会講演論文集, Vol. 2018, pp. 307-308, 2018.
- ¹⁰中島浩平, 岩崎洋一郎, 竹原洋志, 宮田俊彦, 倉本俊昌, 北島俊孝, 瀬戸口恵. 物体検出アルゴリズム YOLOv3 を用いた交通量と車両走行軌跡の自動計測. 電気関係学会九州支部連合大会講演論文集, Vol. 2019, pp. 61-62, 2019.
- ¹¹ Temuulen Dulbadrakh, 鈴木雅人, 北越大輔, 西村亮. YOLO 及び MOT を用いた車種別交通量調査の自動化のための研究. 第 83 回全国大会講演論文集, 第 2021 巻, pp. 437-438, mar 2021.
- ¹² 太田秀也：買物客等による放置自転車の実態及び対策に関する研究, Vol.41, No.2, p55-63, 2018.
- ¹³ 吉田哲, 大庭哲治：京都中心市街地における自転車放置場所の局所的特性の組合せと放置台数の関係, 都市計画論文集, Vol.44.2, p49-57, 2009.
- ¹⁴ 森重翔太, 佐野可寸志, 西内裕晶：自転車利用者の駐輪行動特性と住民の効用を考慮した路上駐輪撤去活動の評価, 土木学会論文集 D3, Vol.70, No.5, I_849-I_858, 2014
- ¹⁵ 梶田佳孝, 外井哲志, 佐々木友子：違法駐輪の撤去が駐輪行動の変化に及ぼす影響, 土木学会論文集 D, Vol.66, No.2, p.137-146, 2010.