

ドライブレコーダ動画を用いた路上駐停車判定手法の提案

松田 明大^{1,a)} 松井 智一¹ 松田 裕貴^{1,2} 諏訪 博彦^{1,2} 安本 慶一^{1,2}

概要: 近年, 禁止区域での路上駐停車が社会問題の一つになっている. 特に大都市圏や観光地では, 多くの路上駐停車が存在する. また, 路上駐停車は渋滞や事故を引き起こす要因ともなりうるため, リアルタイムな検出により迅速な対応が求められる. 先行研究では, 定点カメラや過去動画との比較により路上駐停車の検出が行われた. しかしながら, 定点カメラの設置地点のみでの検出や, 過去動画の限定的なエリア, 処理速度・精度などが問題としてある. 本研究では, これらの問題を解決するために, 一般に幅広く普及しているドライブレコーダ動画を用いたリアルタイムな路上駐停車の判定の実現を目指す. そのために, 車載デバイスのみを用いた路上駐停車の特徴に基づいた機械学習による判定手法を提案する. 物体検出モデルである YOLOv3 を用いて動画を解析し, 計 1765 台分の Bounding Box の座標情報とその時の自車情報をもとに, データセットを作成した. そして, ランダムフォレストとロジスティック回帰を用いてモデルを作成し, ホールドアウト法と層化 K-分割検証法により評価を行ったところ, 2つのモデルにおいて, それぞれ F 値が最大 93%, 90% となった. この結果により, Bounding Box と自車データを用いた路上駐停車判定手法の有効性が確認された.

A method for detecting street parking vehicles using drive recorder videos

AKIHIRO MATSUDA^{1,a)} TOMOKAZU MATSUI¹ YUKI MATSUDA^{1,2} HIROHIKO SUWA^{1,2}
KEIICHI YASUMOTO^{1,2}

1. はじめに

近年, 禁止区域での路上駐停車が社会問題の一つとなっている. 2019 年に警察庁交通局により行われた路上駐停車に関する調査では, 東京都特別区の禁止区域における瞬間路上駐停車台数は約 5 万 2700 台であり, 多くの違法駐停車車両が存在する [1]. 違法な路上駐停車はそれ自体が交通上の問題でありながら, 他の様々な問題を引き起こす要因にもなり得る. 路上駐停車によって引き起こされる交通上の問題には, 渋滞や路上駐停車への追突がある. また, 路上駐停車によって発生する死角からの飛び出しによる人身事故なども挙げられる.

路上駐停車やそれによって起こる問題に対応するため, 駐車規制区間の延長や時間制限区間の実施の検討が行われ

ている. しかし, これらは根本的な解決とはならず, 既存の問題が複雑化すること考えられる. さらに, 国や行政などの大規模な協力が必要であり, 莫大なコストと時間が必要である.

路上駐停車に対して, 街中に設置されている定点カメラを複数台用いて, 短期的な駐停車車両を検出するシステムが開発されている [2]. このシステムでは, 街の中に設置されている定点カメラを複数台用いて路上駐停車の検出を行なっている. しかし, 定点カメラでは画角に収まる範囲の限定的な検出であることや, 設置場所が限られているため, 特定のエリアのみの検出であることが問題として挙げられる.

本研究では, 一般車両への搭載が増加しているドライブレコーダの動画を用いて, 定点カメラよりも効率的でリアルタイムな路上駐停車判定の実現を目指す [3]. ドライブレコーダは街のあらゆる状況を録画しているため, 情報量が圧倒的に多い. また, エリアの制限を受けないため, 従来の手法よりも効率的に道路交通上の情報を収集することが

¹ 奈良先端科学技術大学院大学

Nara Institute of Science and Technology

² 理化学研究所 革新知能統合研究センター

RIKEN center for Advanced Intelligence Project(AIP)

a) matsuada.akihiro.lr2@is.naist.jp




図 1 路上駐停車判定モデルの作成フロー

路上駐停車のリアルタイム認識手法




図 2 提案モデルを用いたリアルタイム認識システム

可能である。一方で、収集した動画を全てクラウドにアップロードし解析を行うのは、通信網への負荷や通信コスト、リアルタイム性の観点から問題である。また、定点カメラの映像と異なり、ドライブレコーダ動画は、自車の動きや周辺環境の影響を受け、複雑な状況となっている。そこで、通信負荷や通信コストを削減するために、車両に搭載されたデバイスで路上駐停車の検出をリアルタイムで行い、その結果のみをクラウドにアップロードする。

本論文では、計算能力が低い車両搭載デバイスかつ複雑な環境の中でも、リアルタイムな路上駐停車の検出を実現する手法を提案する。具体的には、ドライブレコーダにより録画された動画に対して、既存の物体検出モデルを用いて車両の検出を行う。その際に付与される Bounding Box(以下, BB)の座標情報をテキストデータとして、検出

した車両のフレームインからフレームアウトまでをデータに格納する。また、車両を検出した際の、自車のスピードや加速度といった自車情報も同時に格納する。そして、作成したデータと BB を付与した動画をもとに、車両が路上駐停車かそれ以外(一般車)かのラベリングを行う。ラベリングを行なったデータに対して、機械学習手法を用いたアプローチにより、路上駐停車の判定を行う。

提案手法の有効性を検証するために、評価実験として、車両 1765 台のテキストデータセットを構築した。このデータセットをもとに不均衡データ、サンプリングデータ、そして追加検証データを構築した。それぞれ構築したデータセットを用いて、機械学習アルゴリズムであるランダムフォレストとロジスティック回帰により学習を行った。学習したモデルを検証し、認識精度 F 値の最大値を確認し

た。不均衡データセットに対しては、ロジスティック回帰のホールドアウト検証で 62%、均衡データセットに対しては、ランダムフォレストのホールドアウト検証で 93%、追加検証データセットでは、ロジスティック回帰のホールドアウト検証で 83% の認識精度を確認した。

本論文の構成は以下の通りである。第 2 章では、既存の路上駐停車の検出に関する研究を取り上げ、既存手法における課題を整理する。第 3 章では、路上駐停車の判定手法のフローについて述べる。第 4 章では、機械学習手法を用いた路上駐停車判定の評価実験について述べる。第 5 章では、評価実験の判定結果について述べる。第 6 章では、得られた結果に対する考察を述べる。最後に第 7 章では、本論文の結論と今後の展望について述べる。

2. 関連研究

久徳らは、過去の車載カメラ映像との差分による前方車両の検出を行なっている [4]。片側 1 車線の道路を対象に、過去と現在の時間方向に対応づけられたフレーム同士の相関の高い領域を検出対象としている。その中でもあらかじめ、センターラインより右側は対象外とするなど限定的な検出領域とし、窓単位での比較を行なった。対応窓間の差分の指標として、車両の水平方向のエッジ情報が用いられた。提案手法では、曇天時に適合率と再現率がそれぞれ最大 82%、71% であり、晴天時に適合率と再現率がそれぞれ最大 53%、63% であった。しかし、これらは最大値であり、適合率と再現率ともに平均すると 50% 前後と低い。そして、天候に大きく影響を受けており、晴天時に認識精度が大きく低下している。さらに、ある一定の走行領域かつ限定された領域の対象物のみ検出する、といった多くの制限がある。

また、久徳らは、過去の車載カメラ映像との時空間差分による不特定障害物の検出手法についても提案している [5]。現在と過去の対応づけられたフレームの中で、撮影視点の違いによるずれを考慮し、検出領域を平面であると仮定した道路面に限定している。差分の指標として、特徴量は輝度変化に頑健な RGB ベクトル間の角度が用いられることにより、検出精度を向上させた。しかし、道路面の位置合わせにおける手間や精度の問題、限定的な検出領域や走行車線などの問題がある。また、過去の車載カメラ映像との差分を検証する際に、過去映像に路上駐停車をはじめとする障害物が存在する場合には、差分を検証することが難しい。

Xuemei らは、SSD (Single Shot MultiBox Detector) アルゴリズムをベースとした違法駐車を検出システムを提案している [6]。ある一定の角度から撮影された固定カメラの映像に対して、SSD を用いて車両の検出を行い、ROI (Resion Of Interest) 内の車両をトラッキングし、停車した対象のカウントを行なっている。しかし、固定カメラの映像を対象とした手法あり、エリアが限定されている。また、

停車した車両全てに対してカウントが開始されるため、検出車両が信号待ちなのか判定することが難しい。

上記に取り上げた研究のように、路上駐停車の検出を目的とした先行研究はいくつか存在する。問題として、検出領域が限定的であることや、検出条件が限りなく限定的であるといったことが挙げられる。しかしながら、実際の路上駐停車は街全体に広がっており、かつその状況も様々である。本論文の提案手法では、実際の状況を想定し、一般車両への取り付けが増加する移動型カメラのドライブレコーダを用いて、車線や過去情報にとらわれない検出を行う。

3. 路上駐停車の判定手法

本章では、提案手法であるテキストデータによる路上駐停車の判定手法について述べる。

3.1 提案概要

本論文では、街の中を走行・停車する車両を認識対象とし、路上駐停車判定モデルを作成する。提案手法では、対象とする路上駐停車が、街中の路上駐停車ではない他の一般車両と異なる特徴を持つことに着目し、取得した車両情報と自車情報のデータセットに対して、機械学習を用いることで、路上駐停車の判定を行う。

ドライブレコーダ動画を解析し、路上駐停車判定モデル作成までのフローを図 1 に示す。Input は、ドライブレコーダにより撮影された動画とそれに対応する自車データである。Output は、検出された車両に対する判定結果である。本論文では、動画から車両の BB 情報を時系列的に取得し、動画ごとにテキストデータを作成する。また、その際の自車情報を時系列をもとに、BB 情報と結合させる。結合し作成したデータセットに対して、機械学習ベースのアプローチによって路上駐停車の判定を行う。

また、作成したモデルを用いたリアルタイムな路上駐停車認識システムを図 2 に示す。本論文における手法の有効性が確認された場合、リアルタイムな認識に向けて、Raspberry PI や Jetson といった軽量で車両に搭載可能なデバイスを用いたシステムを検討する。

3.2 対象データ

対象データとして、ドライブレコーダ動画と自車データを用いる。ドライブレコーダ動画は、京都府のタクシー会社に提供していただいている。動画サイズは 1280×720[px] であり、フレームレートは 14fps である。撮影車両はタクシー 7 台であり、取り付けられたドライブレコーダの撮影画角は、一定である。録画は、タクシーのエンジン ON から OFF までされており、約 2 分前後で動画 1 本分として分割して保存される。撮影エリアは、京都府の市街地を中心としたエリアであり、観光名所や大通りなどあらゆる街の状況が確認できる。時期は 2019 年 3 月 15 日から 27 日




図 3 BB が付与された車両




図 4 BB によって取得する座標情報

に撮影された動画を対象とし、天候条件は晴れ、または曇りとする。時間帯は、明るい時間帯のみとする。また、走行条件は設定せず、片側 1～3 車線の全ての動画データを用いる。

本論文では、タクシー 3 台によって撮影された動画のうち、合計 12 本（約 24 分）を対象に解析する。また解析の際には、処理負荷を軽減するために、動画サイズを元の $1280 \times 720[\text{px}]$ の 16:9 のアスペクト比を保ったまま $512 \times 288[\text{px}]$ にリサイズする。

自車データとして、録画している際の自車の速度や加速度が dat. ファイルとして保存されたものを用いる。加速度は、車両に取り付けられたドライブレコーダに対して、横方向が X（右が+）、前後方向が Y（前が+）、そして縦方向が Z（上が+）である。自車データは、動画に対して自車情報を取得するサンプリングレートが高いため、動画に対応するようにリサンプリングを行う。

3.3 特徴量抽出

本節では、対象データから抽出する特徴量について述べる。

3.3.1 BB(Bounding Box) の情報

動画に物体認識モデルを用いることで、BB を付与し、その際の座標情報を取得する。BB 情報を付与した画像を図

3 に示す。また、取得する座標情報を図 4 に示す。検出される車両は、検出順に 1 台ずつ番号が付与される。そして、一定の範囲までをトラッキングする。図 3 の緑色の BB で囲まれた車両は 112 番目であり、この番号ごとにフレームに対応する複数の座標情報を保持する。座標情報は、1 台の車両に対してトラッキングを行い、動画のフレームインからフレームアウトまでを取得する。扱う座標情報は、動画を正面から見た際の BB の左上及び右下の x 座標と y 座標である。扱う特徴量として、この 4 つの座標情報に加え、1 台の車両から検出されるフレーム数（どれだけ動画に映り込むか）も選定した。

特徴量として、座標情報を選定したのは、いくつか理由がある。最も大きな理由は、路上駐停車が他の走行する車両とは異なる特徴をもつためである。BB の座標情報に着目すると、路上駐停車の BB は動画のフレームインから、撮影車が近づくにつれ、だんだんと大きくなる。そして、フレームアウトの前フレーム時点で、BB の大きさが最大になり、次フレームにはフレームアウトする。対して他の走行している車両では、BB の大きさはその状況により様々に変化する。この座標情報の変化に着目し、特徴量とした。路上駐停車の特徴については、先行研究 [14] にて詳しく定義している。

3.3.2 自車の情報

自車データの中から日付や変動のない数値を除去し、分類した。扱う特徴量として、速度、加速度 (X,Y,Z 方向) を選定した。これらの特徴量の選定理由として、BB の座標情報に着目していることが挙げられる。座標情報の増加量や大きさは、自車の速度や加速度に起因すると考えられるからである。また、座標情報と自車データを時系列に対応させるために、BB の座標情報を取得した際のフレーム番号と、その際の自車データのフレーム番号を用いた。

3.3.3 特徴量の作成

取得した 4 つの座標情報に対して、BB の幅や高さ、面積についても算出し特徴量として加えた。そして、BB に関する特徴量 8 個と自車データに関する特徴量 4 個に対して、それぞれ最大、最小、平均、分散を算出し、検出されたフレーム数を加えて特徴量を 49 個とした。この特徴量は、車両ごとに保持している。

3.4 物体認識モデル

動画を物体認識モデルに入力し、その際の BB 情報を取得する。本論文では、物体認識モデルに YOLOv3 (You Only Look Once) を選定した [8][9]。YOLO は、認識精度が高く、計算量の少ない低負荷なアルゴリズムとして、物体認識の分野で幅広く用いられている。特徴として YOLO は、画像全体をグリッド分割し、分割した領域毎に物体のクラスと BB を求める。そのため、画像の領域候補を探し出さずに画像全体を一度だけ認識し、CNN により物体の




図 5 不均衡データセットに対する認識結果の混同行列




図 6 均衡データセットに対する認識結果の混同行列

表 1 動画解析環境

名称	詳細
Device	Macbook Pro 2018
OS	macOS Mojave version10.14.6
CPU	Intel Corei5 2.3GHz
GPU	Intel Iris Plus Graphics 655 1536 MB
Memory	8GB 2133 MHz LPDDR3
OS(Colab)	Ubuntu 18.04.3 LTS
CPU(Colab)	Intel(R) Xeon(R) CPU 2.3GHz
GPU(Colab)	NVIDIA-SMI 440.82
Memory(Colab)	11~13GB RAM

検出からクラス分類まで行うため、計算量が減りリアルタイムでの検出が可能となる。ここでは、学習済みデータとして COCO データセットを用いた [10]。

また、認識した物体のトラッキングには、カルマンフィルタを用いた。YOLO により検出した車両の BB と、カルマンフィルタにより算出した次フレームにおける同一車両の BB との IoU (Intersection over Union) をそれぞれ算出し、自車の移動と検出車両が移動することに対応するために、一定の閾値を設定した。

3.5 動画解析の環境

動画の解析環境について、表 1 に示す。動画解析には、Google Colaboratory の GPU 環境を使用した。動画解析の処理時間を短縮することは、今後リアルタイムでの路上駐停車判定を行う際に必要である。その有効性を確認する

表 2 不均衡データセットに関する認識結果

手法	正解率	適合率	再現率	F 値
RF-HoldOut	0.98	0.80	0.31	0.44
RF-5fold	0.98	0.68	0.29	0.41
LR-HoldOut	0.98	0.62	0.62	0.62
LR-5fold	0.99	0.69	0.53	0.60

表 3 均衡データセットに対する認識結果

手法	正解率	適合率	再現率	F 値
RF-HoldOut	0.94	1.00	0.88	0.93
RF-5fold	0.92	0.92	0.92	0.92
LR-HoldOut	0.90	1.00	0.81	0.90
LR-5fold	0.88	0.93	0.82	0.87

ために、表 1 の Colab を用いないデバイス環境のみで、動画を解析したところ処理時間は、1.5fps 程度であった。同様の動画に対して、Google Colaboratory の GPU 環境で解析を行った際には 15fps であった。この速度は、今後のリアルタイム解析において指標となる。

3.6 路上駐停車判定モデルの作成

本論文における機械学習アルゴリズムには、比較検討のために、ランダムフォレスト (RandomForest, RF) とロジスティック回帰 (LogisticRegression, LR) の 2 つを選定した。ランダムフォレストを選定した理由は、高精度かつ表現力や汎化性能も高く、幅広い分野において採用されているからである [11]。また、ロジスティック回帰を選定した




図 7 追加検証データセットに対する認識結果の混合行列

表 4 追加検証データセットに対する認識結果

手法	正解率	適合率	再現率	F 値
RF-HoldOut	0.95	0.50	1.00	0.67
RF-5fold	0.98	1.00	0.60	0.75
LR-HoldOut	0.98	0.71	1.00	0.83
LR-5fold	0.98	1.00	0.60	0.75

理由は、主に二値分類問題に幅広く採用されているからである [12]. 学習モデルの構築には、Python の機械学習ライブラリである scikit-learn を用いており、2 つのモデルのパラメータは scikit-learn のデフォルト設定値である [13].

4. 評価実験

本章では、ラベリングを行なった結合データに対して、機械学習を適用した結果について述べる. 各動画を解析したデータを一つにまとめたデータセットに対して、機械学習手法を適用する.

4.1 データセット

動画 12 本分 (約 24 分) の中で全 1765 台分の車両が確認された. 内訳は、一般車 1709 台に対して路上駐停車 56 台であり、検出した車両の 30 台に 1 台の割合で路上駐停車が存在していることになる. これは、解析するデータやそれぞれのタクシーの撮影エリア、時期や時間帯によって変動するものである.

一般的に、不均衡なデータに対してモデルを作成した場合、サンプル数の多いクラスのみに適した判別器となることが考えられる. そこで本実験では、不均衡データ (収集したデータ) と、不均衡データの中から一般車に対してランダムサンプリング (アンダーサンプリング) を用いることで、一般車 51 台、路上駐停車 51 台の均衡なサンプリングデータを用いて評価を行う.

また、モデル性能を実際の利用場面を想定して検証するために、データセットと同条件の環境で、追加の動画を解析する. 追加検証のデータセットには、一般車 95 台及び路上駐停車 5 台の計 100 台を用意する.



図 8 一般車として誤認識された路上駐停車 (1)



図 9 一般車として誤認識された路上駐停車 (2)

4.2 評価検証手法

データセットの分割と検証方法には、ホールドアウト法 (Hold-out 法) と層化 K-分割検証法 (Stratified K-fold Cross-Validation 法) を用いる. ホールドアウト法は、データセットに対して、学習用データとテストデータを一定 (6:4 など) に分割し、検証する手法である. 本論文ではその割合を、7:3 に設定した. 層化 K-分割検証法は、一般的な K-分割交差検証法がデータセットを単純に K 個のサブセットに分割するのにに対して、層化 K-分割検証法では、サブセット内のクラス比率が、全体の比率と同じになるように分割する. これにより汎化性能を向上させている. そして、1 つのサブセットに対して残りの K-1 個のサブセットを用いて認識を行う. これを K 回繰り返して、評価する手法である. 本論文では、K の値を 5 と設定した.



図 10 路上駐停車として誤認識された一般車 (1)




図 11 路上駐停車として誤認識された一般車 (2)



図 12 路上駐停車として誤認識された一般車 (3)




図 13 路上駐停車として誤認識された一般車 (4)

5. 路上駐停車の判定結果

5.1 不均衡データに対する結果

不均衡データに対するホールドアウト法を用いた認識結果の混同行列と、層化 5-分割検証法を用いた認識結果の混同行列を図 5 に示す。また、このとき路上駐停車のクラスが 1、他の一般車のクラスが 0 である。そして、路上駐停車の判定が目的であるため、正解率と路上駐停車の適合率 (Precision)、再現率 (Recall)、F 値 (F-measure) を算出し、その結果を表 2 に示す。不均衡データにおいて、LR-HoldOut で最大 F 値 62%を確認した。不均衡データであるため、再現率が低くなることが確認された。

5.2 サンプルングデータ

サンプルングデータに対するホールドアウト法を用いた認識結果の混同行列と、層化 5-分割検証法を用いた認識結果の混同行列を図 6 に示す。同様に、正解率と路上駐停車の適合率 (Precision)、再現率 (Recall)、F 値 (F-measure) を算出し、その結果を表 3 に示す。サンプルングデータにおいて、RF-HoldOut で最大 F 値 93%を確認した。不均衡データと比べ、ほとんどの指標で高い認識精度が確認された。しかし、誤認識の起きたサンプルも確認された。

5.3 追加検証データ

追加で解析した計 100 台に対し、サンプルングデータを学習したモデルで検証を行った。作成した追加検証データに対するホールドアウト法を用いた認識結果の混同行列と、

層化 5-分割検証法を用いた認識結果の混同行列を図 7 に示す。同様に、正解率と路上駐停車の適合率 (Precision)、再現率 (Recall)、F 値 (F-measure) を算出し、その結果を表 4 に示す。追加検証データにおいて、LR-HoldOut で最大 F 値 83%を確認した。しかしながら、適合率は低くなることが確認された。

6. 考察

6.1 認識モデルの有効性

不均衡なデータに対しては、正解率は軒並み高くなっている。これは、先述した通り、サンプル数の多い一般車クラスに適合したモデルであると考えられる。適合率、再現率、F 値の最大値はそれぞれ 80%、62%、62%となった。これには、路上駐停車クラスのサンプル数の増加や学習手法の工夫によって改善できると考えられる。

サンプルングデータに対しては、適合率、再現率、そして F 値の全ての値が不均衡データと比べて改善されている。特に RF においては、適合率 100%、再現率 88%、F 値 93%となった。これは、図 2 におけるリアルタイム認識手法のモデルにも活用できると考える。精度に対する改善としては、さらに動画を解析し、様々な状況における路上駐停車クラスのサンプル数を増加させることや、より有効な手法の検討を行うことが考えられる。

追加検証データに対しては、データ数が少ないものの高精度で 2 値クラスの分類を行うことができ、モデルの有効性が確認された。実際の環境で使用するために、あらゆる状況における路上駐停車クラスのサンプルを用いた学習と

検証を行うことで、汎化性能の高いモデルを構築できると期待される。

6.2 誤認識が起きたサンプル

前節で述べた通り認識精度は高いと考えるが、誤認識の起きたケースがいくつかある。均衡データセットに対する認識結果の混同行列である図6において、F値の高いRFの認識結果(RF-HoldOut および RF-5foldの結果)で誤認識されたケースについて考察する。

図6のRF-HoldOutにおいて、路上駐停車クラスである車両が、一般車クラスとして誤認識されたサンプルが2つ存在する。それぞれ図8と図9に示す。図8では、車両番号238を付与された車両が路上駐停車であるにも関わらず、一般車として誤認識された。これは、動画に対して238の車両の手前に位置するシルバーの軽自動車と並走しているため、238の車両の検出が遅れたことが原因として考えられる。そのため、路上駐停車の特徴であるBBが徐々に広がっていく様子を取得することが、困難であったと考えられる。また、検出するフレーム数も少なくなり、十分な情報が得られなかったことも問題であったと考えられる。

図9では、車両番号46を付与された路上駐停車が、一般車として誤認識された。この場合も図8と同様、手前に並走する車両が原因で誤認識されたと考えられる。これには、路上駐停車の検出に用いるフレーム数が少ないことが考えられる。そのため、様々な状況における路上駐停車のサンプル数を増加させることで、誤認識を減らすことができると考えられる。また、ラベリングの精度を向上させるために、条件を数字で明確化させることも必要であると考えられる。

図6のRF-5foldにおいて、一般車クラスである車両が、路上駐停車クラスとして誤認識されたサンプルが4つ存在する。それぞれ図10～図13に示す。それぞれに共通する特徴として、自転車に対して反対車線の車両を路上駐停車であると認識している。図11は、反対車線に位置する路上駐停車であり、ラベリングの条件を変更する必要がある。しかしながら、図10、図12、図13は路上駐停車クラスであると誤認識された。これは、先述した路上駐停車の特徴であるBBが徐々に広がっていく変化率が、反対車線の車両と類似するからである。これに対しては、学習に用いる特徴量の寄与率の重みを変化させることで、検出モデルを改善することが考えられる。また、BBの位置にフィルタリングをかけることや物体検出モデルをファインチューニングすることで、誤認識を減らすことができると考えられる。

7. おわりに

本論文では、図2の路上駐停車のリアルタイム認識に向けて、機械学習アプローチによる路上駐停車判定手法を提

案した。ドライブレコーダ動画を物体検出モデルにより解析を行い、BB情報とその際の自転車情報とともに、データセットを作成した。作成したデータセットを用いて、機械学習手法による路上駐停車判定モデルを構築した。その認識結果からF値を算出すると、不均衡データに対しては最大62%、均衡データに対しては最大93%、追加検証データに対しては最大83%が確認された。そして、さらに認識精度を向上させるために、誤認識された状況と車両を確認し、問題を明確化した。

今後の展望としては、動画の解析本数を増加させ、さまざまな状況における路上駐停車クラスのサンプルもとに、判定モデルの作成を行う。また、誤認識をさらに抑えるためには、ラベリングの条件を変更することや、ファインチューニングが必要であると考えられる。そして、路上駐停車のリアルタイム認識に向けた、車両に取り付けたオンデバイスでの認識の検討を行っていく。

謝辞 本研究を実施するにあたり、株式会社デンソーテン様よりドライブレコーダ動画の提供をいただいた。ここに記し感謝申し上げる。

参考文献

- [1] 全日本駐車協会 東京駐車協会:駐車対策の現状,2019, 入手先 (<https://www.npa.go.jp/bureau/traffic/seibi2/kisei/tyuusya/parking.pdf>)
- [2] Bernal, Edgar A and Fan, Zhigang and Wang, Yao Rong and Loce, Robert P and Zeck, Norman W and Pennington, Graham S:Video-based detector and notifier for short-term parking violation enforcement,October 10,2013,US Patent App. 13/441,294
- [3] 一般社団法人 電子情報技術産業協会:2019 年度ドライブレコーダー国内出荷台数実績,2019, 入手先 (<https://www.jeita.or.jp/japanese/stat/drive/2019/>)
- [4] 久徳遙矢, 高橋友和, 井手一郎, 目加田慶人, 村瀬洋:過去の車載カメラ映像との差分による前方車両の検出, FIT2008 講演論文集, H-038, 2008
- [5] 久徳遙矢, 出口大輔, 高橋友和, 目加田慶人, 井手一郎, 村瀬洋:過去の車載カメラ映像との時空間差分による不特定障害物検出, 画像の理解・認識シンポジウム (MIRU2012), 2012
- [6] Xie Xuemei, Wang Chenye, Chen Shu, Shi Guangming, Zhao Zhifu: Real-time illegal parking detection system based on deep learning, Proceedings of the 2017 International Conference on Deep Learning Technologies, pp.23-27, 2017
- [7] 小野晋太郎, 平原清隆, 影沢政隆, 池内克史:車載レンジセンサを利用した路上駐停車の自動検出, 電子情報通信学会論文誌 A, Vol.88, No.2, pp.247-256, 2005
- [8] Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi: You only look once: Unified, real-time object detection, Proceedings of the IEEE conference on computer vision and pattern recognition, pp.779-788, 2016
- [9] Joseph Redmon, Ali Farhadi: Yolov3: An incremental improvement, arXiv preprint arXiv:1804.02767, 2018
- [10] Tsung-Yi Lin, Michael Maire, Serge Belongi, James Hay, Pietro Peron, Deva Ramanan, Piotr Dollar, C Lawrence Zitnick: Microsoft coco: Common objects in context, European conference on computer vision, pp.740-755, 2014

- [11] 波部 齊：ランダムフォレスト，研究報告コンピュータビジョンとイメージメディア (CVIM)，Vol.2012，No.31，pp.1-8、2012
- [12] 中澤 秀夫：ロジスティック回帰，日本医科大学医学会雑誌、Vol.10，Np.4，pp.186-191，2014
- [13] Pedregosa,F., Varoquaux,G., Gramfort,A., Michel,V., Thirion,B., Grisel,O., Blondel,M., Prettenhofer,P., Weiss,R., Dubourg,V. : Scikit-learn: Machine learning in Python, the Journal of machine Learning research, Vol.12, pp.2825-2830, 2011
- [14] 松田明大, 松田裕貴, 諏訪博彦, 安本慶一：ドライブレコーダ動画を用いた路上駐停車の判定，情報処理学会関西支部 支部大会 講演論文集，Vol.2019，2019