エッジデバイスによるリアルタイム路上駐停車判定・可視化システム

松田 明大 *1　松井 智一 *1　松田 裕貴 *1*2　諏訪 博彦 *1*2　安本 慶一 *1*2
奈良先端科学技術大学院大学 *1
理化学研究所 革新知能統合研究センター *2

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にもなり得るため，リアルタイムな検出による迅速な対応が求められる．関連研究では，主に定点カメラが用いられていたが，検出エリアが限定されていることが大きな問題としてある．そこで本研究では，幅広く普及しているドライブレコーダ動画を用いた，リアルタイムに路上駐停車の認識及び可視化を行うシステムを提案する．路上駐停車を検出する学習モデルを作成し，エッジデバイスを用いて認識を行う．認識した車両の位置情報を取得しマップに表示することで，路上駐停車位置の可視化を行う．

The system of real-time street parking detection and visualization using an edge device

Akihiro Matsuda*1　Tomokazu Matsui*1　Yuki Matsuda*1*2　Hirohiko Suwa*1*2　Keiichi Yasumoto*1*2
Nara Institute of Science and Technology*1
RIKEN Center for Advanced Intelligence Project*2

Abstract In recent years, street parking in prohibited areas has become a social problem. Especially in metropolitan areas and tourist areas, there are many street parked cars. In addition, because street parking can cause traffic congestion and accidents, real-time detection is required. In related studies, fixed-point cameras have been mainly used, whereas a major problem is the limited detection area. In this paper, we propose a system that detects and visualizes street parking in real-time using dashboard camera videos, which are widely used. We create a learned model for detecting street parking and recognize cars using an edge device. Displaying the location information of cars on a map, we can visualize the position of street parked cars.

Keyword: *ITS, Street parking, Object detection, Real-time sensing, Dashboard camera, Edge Device*

1.　はじめに

近年，特に大都市圏や観光地では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，渋滞や人身事故といった他の様々な問題を引き起こす要因にもなり得る．

これまで，路上駐停車に対応するため，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きた．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も考えられる．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．関連研究としては路上駐停車に対し，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，問題として定点カメラでは画角に収ま

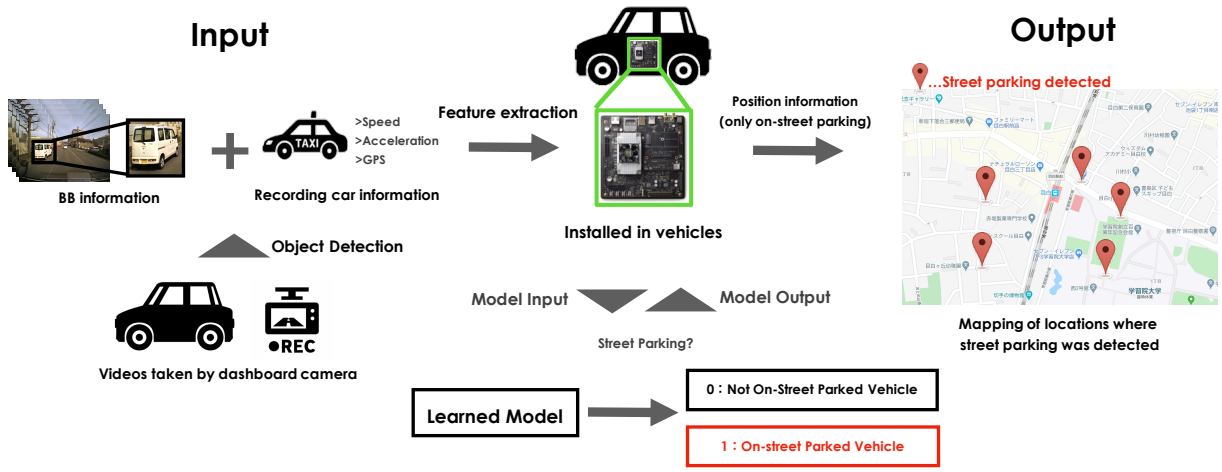

Fig.1 提案システムの全体構成

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挙げられる．

そこで本研究では，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かつ広範囲で，リアルタイムに路上駐停車を検出するシステムの実現を目指す[3]．ドライブレコーダは街のあらゆる状況を録画しており，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情報を収集することが可能である．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．そこで，通信負荷や通信コストを削減するために，車両に搭載されたエッジデバイスで路上駐停車の判定をリアルタイムで行い，結果のみをクラウドにアップロードすることを目的とする．本論文では，ドライブレコーダの動画を学習したモデルを用いて，車両に搭載したエッジデバイスによって認識・処理を行い，路上駐停車位置をリアルタイムに可視化するシステムを提案する．

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，リアルタイムに路上駐停車を検出・可視化するためのシステムの概要について述べる．第 4 章では，提案するエッジデバイスによる路上駐停車判定手法について述べる．第 5 章では，路上駐停車の判定精度とエッジデバイス上における認識・処理速度について述べる．第 6 章では，路上駐停車として検出した車両の位置情報を取得する手法について述べる．最後に第 7 章では，本論文の結論及び今後の展望について述べる．

2. 関連研究

本章では，路上駐停車における関連研究と既存手法について述べる．路上駐停車に関する研究は多くなされているが，路上駐停車を判定する研究は少ない[4)5)6)7)]．本論文では，路上駐停車の判定に関する関連研究について述べる．

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提案している[8)]．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．

Wen らは，Mobile Laser Scanning(MLS) の点群から車両認識や位置検出，分類を行うシステムを提案している[9)]．レーザスキャニングの点群から，車両の認識や位置検出，分類を行う．点群によって認識対象をセグメント化し，各対象に車両認識モデルを適合させる．取得した位置や向きなどの情報を，異なる時刻に取得されたデータと照らし合わせ，特徴の一致度を持続時間とともに推定する．車両の認識と分類，変化の検出において高い精度であるが，MLS の届く範囲での認識であるため路上駐停車の側道を通り，スキャニングを行う必要がある．また，異なる時刻のデータが必要であるため，リアルタイムな認識が難しい．

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の検出システムを提案している[10)]．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 (Region 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．

本研究の位置付けとして，本節で述べた既存研究の問題点を解決するため，路上駐停車をエッジデバイスを用いてリアルタイムに効率的かつ高精度で判定し，そ

の位置情報を可視化するシステムの構築を目指す．

3. システム概要

本章では，提案するシステムについて述べる．初めにシステムの概要を図 1 に示す．入力は，ドライブレコーダ動画とその動画を撮影する車両（自車）データである．また，実際に車両に搭載する際には，エッジデバイスに接続したカメラとセンサの値を入力とする．そして，出力はマップへの可視化である．以上の一連の処理を，エッジデバイス上で全て行う．

3.1 システム要件

エッジデバイスによるリアルタイム路上駐停車判定システムの実現のための必要要件について述べる．提案システムに求められる主な要件 3 つを以下に示す．

要件 1 車両に搭載可能な簡易的なエッジデバイスであること

要件 2 認識から駐車位置取得までのリアルタイム性を担保できること

要件 3 路上駐停車を広範囲かつ高精度で認識可能であること

要件 1 について，車両に搭載しオンデバイスによる処理を行うため，一般車両に搭載可能な簡易的なデバイスであることが求められる．既存の研究では，大掛かりな装置を車両に搭載することが必要であるなどの問題があった．本論文では要件 1 を満たすため，一般に販売され車両に搭載可能な NVIDIA 社製のデバイスである Jetson を用いる．そして，カメラやセンサモジュールを接続することで，撮影や加速度，GPS 情報を取得可能なドライブレコーダを模倣した簡易的なデバイスによってセンシングを行う．

要件 2 について，路上駐停車に起因する問題を未然に防ぐためにリアルタイム認識し，迅速に駐車位置を把握することが求められる．既存の研究では，あらかじめ撮影しておいた画像との比較など，リアルタイム性に問題があった．本論文では要件 2 を満たすため，オンデバイス認識・処理を行う．ドライブレコーダを模したデバイスを用いて撮影を行いながら軽量な認識モデルと学習済み判定モデルによって，路上駐停車位置の結果のみを取得する．また，GPU を搭載したデバイスにより処理速度を向上させ，画像データをテキストデータに変換し，判定モデルに入力することで処理負荷を軽減する．さらに，路上駐停車と判定された車両のみの位置情報をリアルタイムデータベースにアップロードすることにより，通信負荷の軽減を行う．各処理の通信負荷を軽減することで，車両の認識から可視化までのリアルタイム性を追求する．

要件 3 について，搭載車両が移動する広範囲で複雑な状況下においても，高精度で車両を判定することが求められる．既存の研究では，限定的な範囲での認識であることや認識可能な車両が限定されているなどの問題があった．本論文では要件 3 を満たすため，タクシー会社から提供される多くのドライブレコーダ動画を解析し，様々な状況における車両データを学習した判定モデルを用いることで，汎用的かつ高精度な判定を行う．また，今後は物体認識モデルを転移学習し，認識精度を向上させる．

Table 1 デバイスのスペック表

item	Jetson TX2
Size	87×50mm, 170×170mm(board)
Weight	85grams(core)
OS	Ubuntu
CPU	Dual-Core NVIDIA Denver 2 Quad-Core ARM Cortex-A57
GPU	256-core NVIDIA Pascal™ GPU with 256 NVIDIA CUDA cores
Memory	8GB 128-bit LPDDR4 Memory3
Connector	USB，HDMI, SD，Ethernet
Bluetooth	Bluetooth
Wireless LAN	IEEE802.11ac
Power	5.5-19.6V
Consumption	7.5W|15W

3.2 システム構成

デバイスにカメラやセンサモジュールを取り付け，撮影や様々な情報の取得を行う．そして，物体認識モデルを用いてリアルタイムに車両の認識を行う．認識の際に車両に付与される Bounding Box(以下，BB) の座標情報を，各車両ごとにテキストデータとして時系列的に取得する．また，撮影側であるデバイスの速度や加速度を BB 情報と時系列的に結合する．その情報を入力として，路上駐停車判定の学習済みモデルにより判定を行う．学習済みモデルにより，車両が路上駐停車であると判定された場合，その位置情報を取得し，マッピングのために情報を保持する．以上の認識から処理までのフローを全てエッジデバイス上で行う．

3.3 使用するデバイス

デバイスには，NVIDIA 社製の組み込みシングルボードコンピュータである Jetson TX2[1]を用いる．Jetson TX2 のスペックを表 1 に示す．Jetson AGX Xavier は AI コンピューティングデバイスとして，GPU を搭載したエッジ IoT デバイスでありながら，持ち運び可能なサイズと重さであることから車両に搭載するデバイスとして選定した．また，Jetson TX2 専用の Development Tool Kit を使用することで，様々なコネクタに対応可能であるため，センサモジュールを取り付けることを想定した車載デバイスにおいて，拡張性の面でも選定理由として挙げられる．

[1]Jetson：https://www.nvidia.com/ja-jp/autonomous-machines/embedded-systems/

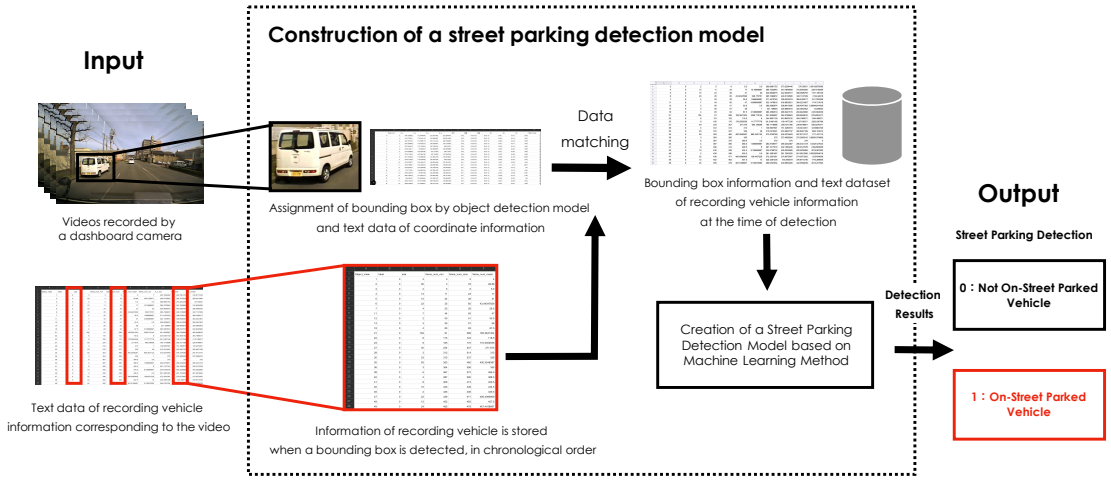

Fig.2 路上駐停車判定モデルの構築

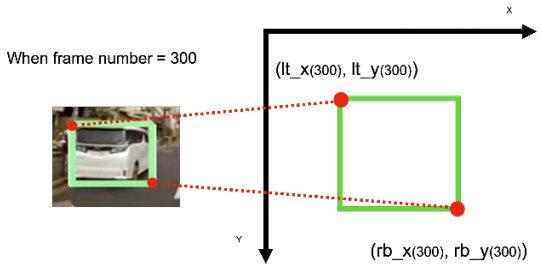

Fig.3 取得する座標値

4. 路上駐停車判定モデル

本章では，路上駐停車判定モデルの構築について述べる．モデル構築のフローについて，図 2 に示す．路上駐停車の判定には，物体認識モデルを用いて BB の座標値とその際の撮影車側 (デバイス) の加速度等の情報を取得する．そして，特徴量生成を行い学習モデルを作成し，判定を行う [11]．

4.1 対象データ

学習済みモデルには，ドライブレコーダ動画を 12 本（約 24 分）を解析し，計 1765 台分の車両の結果を用いた．動画の元サイズは 1280×720[px] であり，解析負荷の軽減のため，16:9 のアスペクト比を保ったまま 512×288[px] にリサイズする．動画の撮影エリアは主に京都府内の観光地であり，天候条件は晴れまたは曇りのデータを対象とした．内訳は路上駐停車以外の車両 (以下，一般車)1709 台に対して，路上駐停車 56 台である．ただし，この比率は時期や時間帯によって変動するものである．

4.2 特徴量

本論文で用いた特徴量を表 2 に示す．特徴量には，認識された車両に付与される BB の座標情報と撮影車側 (デバイス) の速度や加速度などの自車データを用いる．扱う BB の座標値を図 3 に示す．画像に対して BB の

Table 2 使用する特徴量一覧

Domain	Features name
Frame	Number
Bounding Box	Top left x-coordinate
	Top left y-coordinate
	Bottom right x-coordinate
	Bottom right y-coordinate
	Width
	Height
	Area
Recording car	Speed
	Acceleration(x,y,z direction)

左上及び右下の x 座標と y 座標の 4 つの座標値を取得し，それぞれの幅や高さ，面積などを特徴量として作成する．そして，座標情報と撮影車情報に対して最大最小，平均，分散を求め 45 個の特徴量を作成する．これらの車両ごとに保持した特徴量を用いて，学習モデルを作成する．

4.3 物体認識モデル

ドライブレコーダ動画解析のため，物体認識モデルには YOLOv3(You Only Look Once) を選定した [12]．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．学習済みデータセットとして COCO データセットを用いた [13]．また，認識した物体のトラッキングには DeepSORT を用いた [14]．

4.4 学習モデルの作成

解析したデータに対して，均衡化を行うため一般車に対してランダムサンプリングを行った．一般車と路上駐停車の比率を均衡化し，ランダムフォレスト (Ran-

Table 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

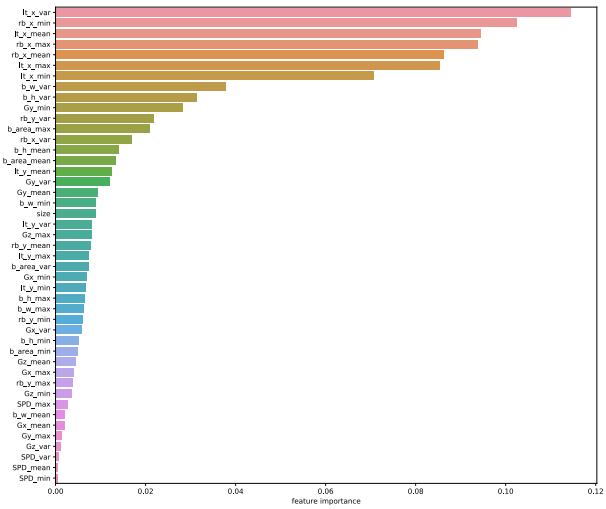

Fig.4 特徴量の重要度

dom Forest;RF) とロジスティック回帰 (Logistic Regression;LR) により学習を行った．また，モデル構築の際は Python の機械学習ライブラリである scikit-learn を用いており，モデルのパラメータは scikit-learn のデフォルト設定値である [15]．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）を用いた．本論文では，ホールドアウト法の割合を 7:3 に，K-分割検証法の K の値を 5 と設定した．

5. 認識精度と解析・処理速度

本章では，学習モデルにおける路上駐停車の認識精度について述べる．また，学習モデルの作成における動画解析速度と，学習モデルを用いて路上駐停車判定を行った際の処理速度についても述べる．

5.1 認識精度

前章で作成した学習モデルの路上駐停車判定に対する認識精度を表 3 に示す．RF のホールドアウト法で最大 F 値 93%を確認した．全体として，4 つの結果全てで 90%前後の F 値を確認したことから，路上駐停車の認識は可能であると考える．また，F 値の最も高かった RF-holdout における特徴量の重要度を図 4 に示す．路上駐停車の判定に寄与する特徴量として，特に BB の x 座標に関する特徴量が高くなった．これは，駐停車車両の位置に関する特徴であり，撮影車に対してどこに位置するかが，判定に大きく寄与したと考えられる．

Table 4 認識・処理速度結果

Model \ Device	PC	Jetson TX2
YOLOv3	1.73[fps]*	1.54[fps]*
	1.79[fps]**	1.67[fps]**
	1.89[fps]***	1.90[fps]***
YOLOv3-tiny	8.14[fps]*	3.84[fps]*
	9.10[fps]**	4.89[fps]**
	10.89[fps]***	6.99[fps]***
YOLOv4	0.63[fps]*	0.81[fps]*
	0.63[fps]**	0.81[fps]**
	0.66[fps]***	0.90[fps]***

* 1280×720[px]
** 1024×576[px]
*** 512×288[px]

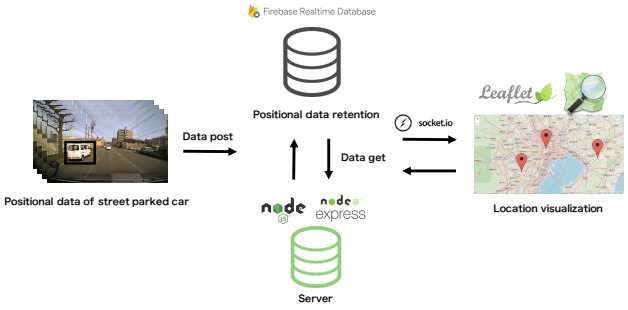

Fig.5 路上駐停車位置の可視化

5.2 解析速度

ドライブレコーダ動画の解析には，Google Colaboratory(以下，Colab) の GPU 環境を使用した．Colab を用いた環境では，動画 12 本を解析したところ，平均解析速度は 15[fps] であった．Colab を用いない PC 環境のみで動画を解析したところ，処理時間は 1.5[fps] 程度であった．PC には Macbook Pro2018 のメモリ 8GB モデルを用いた．

5.3 処理速度

学習モデルを用いた認識・処理に PC 環境と Jetson TX2 環境において，YOLOv3，YOLOv3-tiny，YOLOv4 の 3 つの物体認識モデルを用いて FPS(Frames Per Second) を確認した [16]．PC 環境は前節と同じである．それぞれの結果を表 4 に示す．対象動画は大通りを走行し，複数台の車両が確認できるものとした．また，動画は元サイズである 1280×720[px]* とそれぞれリサイズした 1024×576[px]**，512×288[px]*** である．FPS は動画に対して，10，20，30 フレーム目の平均を算出した．結果に着目すると，PC，Jetson TX2 ともにもっとも軽量な YOLOv3-tiny がリアルタ

イムに近い認識速度であると確認された．他 2 つのモデルにおいては，環境によらず速度に大きな差は確認されなかった．また，動画の解像度を下げることで，特に YOLOv3-tiny においては一定の速度向上が確認できた．動画上では Jetson TX2 にて確認した約 7[fps] の速度で路上駐停車の判定がされたことから，十分にリアルタイムな認識・処理が可能であると考える．これにより，速度の面ではエッジデバイス上で認識・処理を行うために YOLOv3-tiny を選定し，取得する動画の解像度を下げることにより，リアルタイムな認識を行う．

6. 位置情報の可視化

本章では，路上駐停車の可視化について述べる．路上駐停車であると認識された車両の位置情報を取得し，視覚的に位置の把握を行うために，マップ上に可視化する．可視化することで，第三者が容易に路上駐車位置を把握し，効率的に対策可能となる．位置情報の取得から可視化までのフローを図 5 に示す．

路上駐停車の位置情報を取得し，リアルタイムデータベースに保存する．保存形式として，位置情報をテキストデータとしてアップロードすることで，データベースとの通信の負荷を減らす．また，新たに検出された車両データのみの通信を行うことで，通信頻度を減らす．そして，保存した位置情報を Web サーバに送信し，socket.io を用いてリアルタイムに通信を行うことで，マップ上に可視化する．

7. おわりに

本論文では，ドライブレコーダの動画を学習したモデルを用いて，車両に搭載したエッジデバイスによって認識・処理を行い，路上駐停車位置をリアルタイムに可視化するシステムを提案した．その中でも主に以下のことについて述べた．(1) ドライブレコーダ動画を学習したモデルの作成，(2) エッジデバイス上における学習モデルによる処理，(3) 路上駐停車位置の可視化．

今後の展望として，判定モデルにより汎用性を持たせるために，学習サンプルを増やすことが必要である．また，よりリアルタイムな認識と判定につなげるために，処理フローの改善も必要である．そして，実際に車両に搭載し，認識から可視化までの一連のフローを実現する．

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. https://www.npa.go.jp/bureau/traffic/seibi2/kisei/tyuusya/parking.pdf.
2) Edgar A Bernal, Zhigang Fan, Yao Rong Wang, Robert P Loce, Norman W Zeck, and Graham S Pennington. Video-based detector and notifier for short-term parking violation enforcement. October 10 2013. US Patent App. 13/441,294.
3) 電子情報技術産業協会. ドライブレコーダー統計出荷実績, 2018. https://www.jeita.or.jp/japanese/stat/drive/.
4) 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車車両の自動検出. 電子情報通信学会論文誌 A, Vol. 88, No. 2, pp. 247–256, 2005.
5) Bo Li, Tianfu Wu, and Song-Chun Zhu. Integrating context and occlusion for car detection by hierarchical and-or model. In *European Conference on Computer Vision*, pp. 652–667. Springer, 2014.
6) Xavier Sevillano, Elena Màrmol, and Virginia Fernandez-Arguedas. Towards smart traffic management systems: Vacant on-street parking spot detection based on video analytics. In *17th International Conference on Information Fusion (FUSION)*, pp. 1–8. IEEE, 2014.
7) Krzysztof Małecki. A computer simulation of traffic flow with on-street parking and drivers ’ behaviour based on cellular automata and a multi-agent system. *Journal of computational science*, Vol. 28, pp. 32–42, 2018.
8) 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. 2012.
9) Wen Xiao, Bruno Vallet, Konrad Schindler, and Nicolas Paparoditis. Street-side vehicle detection, classification and change detection using mobile laser scanning data. *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 114, pp. 166–178, 2016.
10) Xuemei Xie, Chenye Wang, Shu Chen, Guangming Shi, and Zhifu Zhao. Real-time illegal parking detection system based on deep learning. In *Proceedings of the 2017 International Conference on Deep Learning Technologies*, pp. 23–27, 2017.
11) 松田明大, 松井智一, 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判定手法の提案. 情報処理学会 マルチメディア、分散、強調とモバイル (DICOMO2020) シンポジウム, pp. 1102–1110, 2020.
12) Joseph Redmon and Ali Farhadi. Yolov3: An incremental improvement, 2018. https://arxiv.org/abs/1804.02767.
13) Tsung-Yi Lin, Michael Maire, Serge Belongie, James Hays, Pietro Perona, Deva Ramanan, Piotr Dollár, and C Lawrence Zitnick. Microsoft coco: Common objects in context. In *European conference on computer vision*, pp. 740–755. Springer, 2014.
14) Alex Bewley, Zongyuan Ge, Lionel Ott, Fabio Ramos, and Ben Upcroft. Simple online and realtime tracking. In *2016 IEEE International Conference on Image Processing (ICIP)*, pp. 3464–3468. IEEE, 2016.
15) Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, Peter Prettenhofer, Ron Weiss, Vincent Dubourg, et al. Scikit-learn: Machine learning in python. *the Journal of machine Learning research*, Vol. 12, pp. 2825–2830, 2011.
16) Alexey Bochkovskiy, Chien-Yao Wang, and Hong-Yuan Mark Liao. Yolov4: Optimal speed and accuracy of object detection, 2020. https://arxiv.org/abs/2004.10934.