

# 高齢者の自立行動支援のための安全運転支援型電動車いすの開発

研究代表者 松島 宏典 久留米工業高等専門学校 制御情報工学科 准教授

## 1 はじめに

現在、日本では高齢化が進んでおり、2036年には33.3%で3人に1人が高齢者となる社会に突入することが予想されている[1]。特に、地方では急激な少子高齢化が進んでおり、生活機能をどのように維持していくかが深刻な社会問題となっている。現在、生活機能維持のためには、大多数が自家用車の運転を利用しているが、今後は対応が一層困難になることが予想される。そこで、解決方法の一例として、バスを基本とした公共交通によるモビリティの確保が以前から求められている[2]。しかし、財源不足が深刻化しているため、路線バスの縮小や撤退など、公共交通のサービスレベル低下が懸念されている。また、高齢者の外出目的は、日用品の買い物や食事・社交・娯楽などの頻度が高いため[3]、買い物の際の荷物の運搬や行先の多様化等、実際の状況に即した対応が必要となる。そのため、今後も自家用車の運転による移動に頼らざるを得ないのが現状である。

高齢者の自家用車運転移動で問題となっているのは、ハンドル操作不適やブレーキとアクセルの踏み間違いなどが原因で発生する交通事故の増加である。このような高齢者による交通事故が多発しているため、東京都内で運転免許証を自主返納した人が、最近では4万人弱となり、前年同期の2倍近くになっているとの警視庁の報告が挙がっており、その他の大都市圏でも返納件数は多くなっている[4]。免許返納後、交通機関が充実している都市部ではその影響は小さいが、地方では返納後に移動手段が制限されることへの不安が背景にあるため、これらは高齢化社会の課題となっている。そこで、課題解決のため、福祉機器の利活用への期待が高まっている。

福祉機器の利活用として、各自治体で次世代電動車いすを活用した実証実験が行われている[5]。結果として、電動車いすの利活用によるメリットが得られたものの、歩道、道路の傾斜、凹凸や損傷、植栽(木)の根による盛り上がり、車道と歩道間の段差など、インフラ構造物に対して運転時に不安が生じるという課題が見つかった。

そこで、本研究では、コンピュータビジョンに基づいた安全運転支援機能を電動車いすに付加することによって、事故の発生原因を解消し、利便性の向上や地方創生に貢献することを目的とする。安全運転支援機能として、道路の路面状況の把握と自己位置推定の最適化、対象物の寸法推定予測について取り組む。

## 2 研究概要

### 2-1 関連研究

以前より、ステレオカメラを複数配置し、全方向の情報を解析することにより安全を確保することを目指したインテリジェント電動車いすや、歩行者 ITS (Intelligent Transport Systems 高度道路交通システム) を利用して自動車との衝突防止を目指した電動車いす用衝突警報装置の開発等の研究が行われている。しかし、導入するシステムが高価になる等、普及には問題点があった(佐藤・坂上, 2006; Nawai and Futami, 2006; Nawai, 2007; Sato and Sakagami, 2006; Murota et al., 2007; Satoh et al., 2007; Oda and Shimizu, 2006; Hayashi, 2002; Kurozumi and Yamamoto, 2006; Komiya et al., 2001; Mizuguchi et al., 2008)。よって、市街地を走行している電動車いすや、新たに販売される市販電動車いすに対して、簡単に、そして安価に設置できるシステムの開発が求められた。また、超音波センサを用いた電動車いす用安全走行装置の開発等の研究も行われてきたが、こちらも普及には至っていない(Masuzawa and Minami, 2009)。最近では、車いすの姿勢および乗り心地を、デプスセンサにより計測した路面の凹凸から予測する研究等が行われているが、短い区間の自動運転を想定した技術であり、安全運転支援の観点からのアプローチは行われていない(杉山・奥田他, 2018)。また、ユーザが音声命令によって電動車いすに自律走行を実現させる研究等も行われているが、高齢者は自分自身の判断基準そのものに不安があるため、システムそのものが適さない問題点がある(長谷川・古谷他, 2018)。また、空港や建物内など、整地された環境を対象にした研究がほとんどとなっている。



図 2.1 実験車両例



図 2.2 画像データ例




図 2.3 3次元データ例

## 2-2 システム構成

本研究の実験車両例を図 2.1 に示す。本研究では、電動車いすにスズキセニアカー、WHILL Model CR 等を用いた。センサには、カメラが付属しているタブレット PC、USB カメラ等を用いた。また、周辺環境の 3 次元情報を取得するために、YVT-35LX-FK、AR-VLP-16 等を用いた。ここで、取得された画像データと点群データを図 2.2、2.3 にそれぞれ示す。

## 3 研究内容

### 3-1 路面状況把握

道路上には、クラックやポットホールなどの損傷や段差、落下物といった変状が存在する[6]。これらの道路変状は通行車両の走行安定性を低下させるため、未然に回避する必要がある。特に、電動車いすなどの小さな車両では、その影響が顕著であり、大きな事故につながる恐れがある。安全運転支援では、それらの道路変状を検出し、自動でブレーキやステアリングの制御を行う、または音声などで運転者に伝えるといった支援を行う。画像認識の分野においては、カメラ画像を用いて道路変状検出を行うことが多い[7, 8, 9]。近年では機械学習の一つである畳み込みニューラルネットワーク (CNN) を用いた道路変状検出手法が広く研究されている[10, 11, 12, 13]。CNN は精度が高く、特徴抽出器の設計が不要という利点があるものの、計算量が大きことや学習に大量の教師データを必要とするという欠点もあり、多くの時間と手間を要する。一方で、教師データなしで CNN を学習させることができる DeepCluster[14]が提案されているものの、モバイル環境上での動作が検証されていないという課題もある。本研究では、モバイル環境上で動作させることや、運用中に継続して学習を行うことで性能向上を図ること、学習コストの低減を想定しているため、計算量が小さく、教師データなしで学習が可能な手法を提案する。

#### (1) 提案手法

本研究では、CNN を用いた画像分類による道路変状検出を提案する。モバイル環境上で動作させることを考慮して、計算量の小さい CNN である MobileNet や EfficientNet を使用した。MobileNet は、モバイルデバイスの CPU 上で動作させることを目的として提案された CNN であり、これまでに v1 から v3 が提案されている。MobileNetV3 では、MobileNetV2 で導入された Inverted Residual Block に対して Squeeze-and-Excitation (SE) モジュールを追加し、自動アーキテクチャ探索 (Neural Architecture Search) や、非線形関数に h-swish 関数を用いるなどの工夫によって、パラメータ数の削減と計算速度の向上を実現している。一方、EfficientNet は、CNN のスケールアップに関する研究において提案されたモデルであり、既存手法と同等の精度でありながら、パラメータ数が大幅に削減されているという特徴を有している。一般的に、モデルのスケールアップは、ネットワークの深さや幅、解像度を変化させる。これにより、モデルの

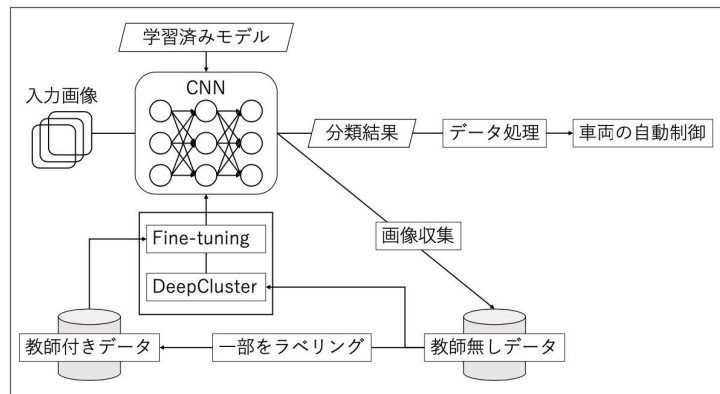


図 3.1 道路変状検出システムの概要図

性能を向上させることができるが、多くの場合、手動の調整を必要とし、依然として最適解と言えない性能を示すことがある。そのため、本手法では幅、深さ、解像度を一定の係数で一律にスケールする複合スケールリングを導入している。このスケールリング手法は、従来の個々のスケールアップよりも全体的に性能と効率を向上させることができる。

また、運用中に継続して学習を行うことで性能向上を図る上で、学習コストを低減させるために、CNN の教師なし学習手法である DeepCluster を導入する。この手法は、ニューラルネットワークのパラメータと、その結果として得られた特徴量のクラスタ割り当てを組み合わせることで学習するクラスタリング手法である。DeepCluster は標準的なクラスタリング手法である k-means を使用して特徴量を反復的にグルーピングし、そのクラスタ割り当てを次の学習の教師として使用することで、ネットワークの重みを更新する。これにより、教師ラベルを必要とせず、CNN の学習が可能となる。

図 3.1 に本システムの概要を示す。CNN の学習は以下の 3 ステップで構成されている。

ステップ① 教師ありデータを用いて、教師あり学習を行う。

ステップ② 教師なしデータを用いて、DeepCluster による教師なし学習を行い、最終層以外の学習を行う。

ステップ③ ①で用いた教師ありデータを用いて、CNN が分類可能な状態にするために fine-tuning を行う。

DeepCluster を使用する理由としては、教師ラベルや CNN の分類結果を使用せずに、大量の学習データを用いた教師あり学習を行った場合と同等の汎化性能を得ることが期待できるためである。実際の運用では、以下のような流れとなる。

#### 1. 事前の準備

ステップ①を実行し、学習済みモデルを得る。入力画像の道路領域を手動で分割しておく。

#### 2. 運用

学習済みモデルを用いて、分割された各領域の画像を分類する。同時に、画像を教師なしデータとして収集する。

#### 3. 運用時間外

収集した教師なしデータを用いて、ステップ②の教師なし学習を実行する。そして、既存もしくは新たにラベリングした教師ありデータを用いて、ステップ③を実行し、モデルを更新する。

### 3-2 自己位置推定最適化

移動車両が現在どこに位置しているかを算出する自己位置推定技術は、自律動作する上で必要不可欠である。自己位置推定を行うためにはマップ情報が必要であり、マップが作成されていない領域において自己位置推定を行うことはできない。Simultaneous Localization and Mapping (SLAM) は、自己位置推定と新たなマップの作成の両方を行う技術であり、事前に地図情報が無い場合でも自己位置推定、それに伴う地図作成を行うことを可能とする。SLAM を行うためには現在の周囲の状況を把握するためのセンサが必要となるが、カメラセンサを用いる SLAM は特に Visual SLAM と呼ばれる。

本研究では、Visual SLAM システムの一つである ORB-SLAM3 [15] において用いられている PnP 問題を解くアルゴリズムを改良し、ORB-SLAM3 の性能の向上を試みる。また、真値が存在するデータセットを用いた評価実験を行い、比較手法と提案手法の違いについて検証する。

#### (1) 提案手法

特徴点ベースの Visual SLAM では、カメラセンサから得られた画像から抽出された点群とそれまでに得られた点群との対応関係を明らかにし、現在のカメラ姿勢（並進+回転）を推定する処理を行う必要がある。このような処理は Perspective-n-Point (PnP) と呼ばれており、この処理を行うアルゴリズムは様々なものが存在する。PnP アルゴリズムにおいて重要な要素は外れ値除去性能である。図 3.2 に示されるように、特徴点の誤対応（外れ値）が存在する可能性がある。この外れ値を適切に取り除いたうえでカメラ姿勢を求めることで、より正確な結果を得ることが可能となる。そこで、本研究では、REPPnP と LM 法を組み合わせる手法を提案する [16]。REPPnP は PnP 処理を高速に行う




図 3.2 特徴点マッチング例

アルゴリズムであり、 $i$  番目のマッチングが外れ値かどうかを表した行列に対して特異値分解を施すことにより外れ値の除去を行い、カメラ姿勢を推定する。また、最適化の際に Quicksort をベースとしたアルゴリズムである Qiuickselect を用いることで高速に最適化を行うことを可能としている。

従来手法は、線形式の L2 ノルムに対して、Levenberg-Marquardt 法を複数回適用し、外れ値を除去することで最適化を行うが、提案手法では、まず REPPnP を用いた PnP 処理を行う。次に、REPPnP のみの適用では十分な精度が期待できないため、これに加えて LM 法を用いた最適化を複数回行う。ここで、処理時間の増大を防ぐために、REPPnP 適用後の LM 法の最適化は、従来手法のそれよりも抑えられる。

### 3-3 対象物の寸法推定予測

対象物の寸法推定予測技術は、交通死傷者の削減、高齢者の移動支援、運転時の負荷軽減など、社会福祉に大きな貢献をもたらす。安全運転支援技術において、衝突予測および回避システムの実現は特に重要な課題である。そこで、本研究では畳み込みニューラルネットワーク (CNN) による 3D ボックス推定を用いた周辺対象物の行動予測システムについて提案する。3D ボックス推定では、CNN モデルを用いて画像内の対象物体の大きさや方向を回帰し 2 次元情報から 3 次元情報を取得する。得られた 3D ボックスを俯瞰図として表し、ボックスの中心及び 4 つの頂点を入力として関連ベクトルマシン (RVM) で軌道を予測し、その有用性について検証する。

#### (1) 提案手法

道路環境における自車周辺の移動対象物の危険行動を予測するシステムを図 3.3 に示す。始めに、多物体認識によって対象物体の種類を識別する。次に、識別した対象物体の 3D ボックスを推定する。推定された 3D ボックスは、俯瞰図へと投影される。これらの俯瞰図は、デジタル地図と合成されることにより、より正確な情報へと変換される。最後に、取得した位置情報に基づき、移動対象物の行動を予測する。

本研究では、カメラ情報に基づいた行動予測システムを提案する。現在主流となっている LiDAR は、カメラと比較してコスト高であり、消費電力も大きいなどのデメリットがある。一方、カメラは LiDAR に比べて汎用的で扱いやすいが、精度が劣る問題点がある。そこで、今回、行動予測システムに CNN を導入し、その有用性について検証する。本論文では、移動対象物を自動車として評価を行う。

本研究ではマルチビン損失を適用した CNN と画像幾何学的制約に基づいた 3D ボックス推定を行う [17]。3D ボックス推定は物体認識によって得られた 2D ボックスを基に行われる。ゆえに、推定される 3D ボックスの頂点は 2D ボックスの辺と重なるものと仮定する。3D ボックスの 8 つの頂点と 2D ボックスの辺の対応の組み合わせは  $8^4 = 4096$  通りある。ただし、道路上での車両状態が直立で回転もないと仮定すると、頂点と辺の組み合わせは  $4^4 = 256$  へと削減することができる。3D ボックスは中心  $\mathbf{T} = [t_x, t_y, t_z]^T$ 、寸法  $\mathbf{D} = [d_x, d_y, d_z]$ 、および回転  $\mathbf{R}(\theta, \phi, \alpha)$  で表される。

CNN は、方向と寸法の 2 つの推定処理を行っているが、方向推定を行う場合、回転  $\mathbf{R}$  について考慮する必要がある。図 3.4 は車両とカメラの角度関係を表している。図より自車両カメラと対象となる車両の角度関係を考慮すると、対象車両の方向  $\theta$  は一定であるが方向  $\theta_i$  は連続的に変化していくことが分かる。したがって、この  $\theta_i$  を CNN を用いて回帰する。本手法では、マルチビン損失を用いて方向推定を行う。最初に画像面を重複する  $n$  個のビンに分割する。各ビンについて、ビンの中心角度からの差分と信頼確率を、CNN を用いて計算する。マルチビン損失は式 (3.1) (3.2) によって表される。

$$L_{loc} = -\frac{1}{n_{\theta^*}} \sum \cos(\theta^* - c_i - \Delta\theta_i), \quad (3.1)$$

$$L_{\theta} = L_{conf} + w \times L_{loc}, \quad (3.2)$$

ここで、 $n_{\theta^*}$  は真値角  $\theta^*$  をカバーするビンの数であり、 $c_i$  はビン  $i$  の中心角度である。 $\Delta\theta_i$  はビンの中心角度からの角度差分、 $L_{conf}$  は信頼確率の損失関数で二値交差エントロピーが用いられる。ここで、 $\theta_{ray}$  は画素値から簡単に求めることができるの




図 3.3 予測システム外観図




図 3.4 カメラとの位置関係

で、 $\theta_{ray}$ と $\theta_l$ より最終的な $\theta$ が算出される。寸法推定では、値の誤差が少ないため L2 損失が使用される。これらのモデルは確率的勾配降下法(SGD)を用いて最適化される。ここで、従来手法では、CNN を適用する際、3D ボックスの寸法推定では平均二乗誤差を、方位推定では前述のとおり二値交差エントロピーを用いて学習が行われていた。しかし、自車両に対して対象物が近接、遠隔に存在する場合において、推定値の誤差が大きくなる課題があった。そこで、本研究では、損失関数として Huber 関数に基づいて外れ値の修正を行うことで精度改善を図る。Huber 損失関数は次式で記述される。

$$L_{conf} = \begin{cases} \frac{1}{2}(t-x)^2 & , (|t-x| < \delta) \\ \delta\left(|t-x| - \frac{1}{2}\delta\right) & , (otherwise) \end{cases} \quad (3.3)$$

ここで、 $t$ は真値、 $x$ は推定値、 $\delta$ は調整パラメータである。

また、3D ボックス推定によって得られた座標値をもとに行動予測を行う。車線変更の軌道を予測するために、関連ベクトルマシン(RVM) [18]を使用する。RVM はベイズ学習法の一つで、回帰問題や分類問題を解くために使用される。これはベイジアン線形回帰モデルと同じであるが、よりまばらな解が得られるよう事前分布に修正を加える。そして、各重みパラメータに対して異なるハイパーパラメータが採用される。これらのハイパーパラメータを最大化することにより、重みの大部分は無限大になる。また、対応する重みパラメータの事後分布はゼロとなる。したがって、これらのパラメータに対応する基底関数を除去することができ、スパースモデルを得ることができる。RVM には、3D ボックスの中心座標、および、4つの頂点座標が入力され、隣接車線から走行車線へ軌道変更する直後の軌道が予測される。ここで、変更を行う車両は、自車両の走行車線前方に出現すると仮定するため、自車両から十分に離れた前方の座標も入力点とする。

## 4 結果

### 4-1 路面状況把握結果

ここでは、3種類の実験を行い、提案手法の有効性を検証する。

実験1では、3つのCNNを用いて、提案手法の精度面での有効性を検証する。データセットには、物体検出用の道路画像のデータセットである Road Damage Dataset (RDD) [19]を基に作成した画像分類用のものを使用した。表 4.1 に RDD のデータの内容を示す。また、表 4.2 と図 4.1 に今回作成したデータセットの概要とデータの一例をそれぞれ示す。使用する CNN は MobileNetV3 small, MobileNetV3 large, EfficientNet-b0 の3種類を利用した。実験内容としては、まず学習用データのうち、教師ありデータ 5000 枚を2セット用意する。そして、1セット目の教師ありデータを用いて、提案手法によるCNNの学習を行う。これを1周目とし、次に、2セット目の教師ありデータを用いて、2周目の学習を行う。その際、教師なしデータには、学習用データ全体を使用する。1, 2周目のそれぞれの3-1で記載したステップ①, ③実行後のテストデータに対する精度の4種類を比較した結果を表 4.3 に示す。

実験2では、一般画像のデータセットを使用して、提案手法における教師なし学習の効果を検証する。MNIST, CIFAR10, STL10 の3種類のデータセットを使用し、CNN には MobileNetV2 を用いた。実験の手順は、まずデータセットの一

表 4.1 Road Damage Dataset

Damage Type	Detail	Class Name	
Crack	Longitudinal	Wheel mark part	D00
		Construction joint part	D01
	Lateral	Equal interval	D10
		Construction joint part	D11
Alligator Crack	Partial pavement, overall pavement	D20	
Other Corruption	Rutting, bump, pothole, separation	D40	
	Cross walk blur	D43	
	White line blur	D44	

表 4.2 データセット概要

項目	内容
クラス数	7
ラベルの種類	3種類のクラック, ポットホール, 白線, マンホール蓋, 舗装面
画像サイズ	64×64
学習用データ数	36000
テスト用データ数	5000

部のデータを用いて教師あり学習を実行(ステップ①)し、その後全データを使用してDeepClusterを実行(ステップ②)、最後にステップ①で使用したデータを用いて fine-tuning (ステップ③)を行った。なお、CIFAR10, STL10 での実験では、CNN の初期値として ImageNet



(a) クラック (b) ポットホール (c) 舗装面

学習済みの重みを使用した。表 4.4 に使用したデータ数、ステップ①, ステップ③ 実行後のテストデータに対する精度を示す。

実験 3 では、実験 1 で使用した CNN を使用して、推論時間の比較を行った。1 フレーム

あたり 16 枚程度の画像を処理すると仮定し、バッチサイズを 20 とした。実験用 PC の CPU, GPU, モバイル PC の CPU を使用して、テストデータに対する推論時間(msec)の平均を求めた。表 4.5 に結果を示す。

#### 4-2 自己位置推定最適化結果

提案手法の性能を評価するため、単眼カメラのデータセットである KITTI データセットを利用した。今回の実験では、3 シーンのデータセットを用いて実験を行う。評価対象の手法は、LM 法, EPnP[19], 提案手法の 3 手法とした。また、ORB-SLAM3 から出力される軌跡データは、スケールにズレが生じてしまう可能性があるため、それらを修正するために変換処理を施して誤差算出を行い評価した。以下に変換式を示す。

$$\min_k \sum_i \|t_i - kt_i^*\|^2 \quad (4.1)$$

ここで、 $t_i, t_i^* \in R^3$  はそれぞれ  $i$  番目のフレームの結果を表す。実験結果を表 4.6 に示す。太字で示されている数値が最も良い結果を表す。

次に、実験において作成された地図データの一例を図 4.2 に示す。図左が従来手法で作成された地図の一部であり、右が提案手法で




図 4.2 地図データ作成例

図 4.1 データセット例

表 4.3 道路画像データセット結果

CNN	Accuracy[%]			
	1-1	1-3	2-1	2-3
MobileNetV3 small	74.5	75.3	76.9	76.1
MobileNetV3 large	75.5	76.7	77.6	77.5
EfficientNet b0	74.9	76.6	77.5	77.9

表 4.4 一般画像データセット結果

Dataset	Number of data		Accuracy[%]	
	Labeled	Unlabeled	step1	step3
MNIST	3000	60000	93.8	96.5
CIFAR10	5000	50000	87.8	90.6
STL10	5000	50000	95.6	95.6

表 4.5 推論時間

CNN	Experimental PC		Mobile PC
	CPU	GPU	CPU
MobileNetV3 small	21.0	7.3	80.1
MobileNetV3 large	54.0	9.0	186.7
EfficientNet b0	116.0	12.5	457.2

表 4.6 比較結果

Sequence 00			
	並進誤差 [m]	回転誤差 [deg]	処理時間 [s]
LM	<b>7.62635</b>	1.09641	0.966221
EPnP	8.82579	1.16355	7.879890
REPPnP	8.85150	<b>1.03262</b>	<b>0.832672</b>

Sequence 02			
	並進誤差 [m]	回転誤差 [deg]	処理時間 [s]
LM	83.0479	1.75197	0.580282
EPnP	<b>66.5682</b>	<b>1.34618</b>	5.45177
REPPnP	71.4043	1.94068	<b>0.540082</b>

Sequence 03			
	並進誤差 [m]	回転誤差 [deg]	処理時間 [s]
LM	<b>3.56149</b>	0.876663	0.785805
EPnP	3.59483	0.870312	5.96253
REPPnP	3.86282	<b>0.869941</b>	<b>0.639303</b>



図 4.3 3D ボックス推定結果例




図 4.4 3D ボックス推定結果比較例（上：従来，下：提案）




図 4.5 軌道予測結果例  
（上：中心座標，下：4 頂点座標）

作成されたものである。この図は、一度通過した場所を再度通過するという状況であるため、本来はこの地点での地図データは連結されるように生成されるべきである。従来手法では、ズレが発生しているのが確認できるが、提案手法では正確に地図データの生成が行われていることが確認できる。

### 4-3 対象物寸法推定予測結果

本実験では KITTI データセットを使用する。推定した 3D ボックスを基に行動予測手法に従って車線変更の軌道を予測する。予測には、3D ボックスの中心座標、4 つの頂点座標の 2 種類を用いて、それぞれの結果を比較する。3D ボックス推定結果の例を図 4.3 に示す。3D ボックス推定では、モデルの学習回数を適切に設定することによって精度を向上させることができた。また、従来手法における自車両に対して対象物が近接、遠隔に存在する場合において、推定値の誤差が大きくなる課題に対して、損失関数を更新することにより対応可能となった。結果を図 4.4 に示す。

行動予測実験の結果を図 4.5 に示す。車線変更の軌道予測では、(a) の 3D ボックスの中心を入力とした場合と比べて (b) の 3D ボックスの頂点を入力とした場合のほうが真値に近い軌道を得られた。これは入力をボックスの頂点とすることによって方向の要素が加わり、その結果 (a) に比べて軌道予測の精度が向上したからだと考えられる。

## 5 まとめ

本研究は、コンピュータビジョンに基づいた安全運転支援機能を電動車いすに付加することによって、事故の発生原因を解消し、利便性の向上や地方創生に貢献することを目的とした。安全運転支援機能として、道路の路面状況の把握、自己位置推定の最適化、対象物の寸法推定予測について取り組んだ。道路の路面状況の把握では、モバイル環境上で動作させること、運用中に継続して学習を行うことで性能向上を図ること、学習コストの低減を想定してことを考慮し、計算量が小さく、教師データなしで学習が可能な手法を提案した。自己位置推定の最適化では、回転動作時の精度を向上させること、計算コストを削減することを考慮し、REPPnP と LM 法を組み合わせることにより最適化する手法を提案した。対象物の寸法推定予測では、識別した対象物体の 3D ボックスを損失関数を最適化することで推定し、取得した位置情報に基づき、移動対象物の行動を予測する手法を提案した。これらの成果は、電動車いすの安全運転支援技術の確立に寄与するものだと考えられる。

## 【参考文献】

- [1] “令和2年版高齢社会白書(全体版),” 内閣府, 2020.
- [2] “日本の地域別将来人口推計,” 国立社会保障・人口問題研究所, 2013.
- [3] “全国都市交通特性調査,” 国土交通省, 2015.
- [4] “自主返納件数の都道府県別・月別の推移(令和2年),” 警察庁, 2021.
- [5] “パーソナルモビリティ(次世代電動車いす「WHILL」)を活用した商店街買い廻り実証実験,” 基山町, 2015.
- [6] W. Wang, M. Wang, et al., " Pavement Crack Image Acquisition Methods and Crack Extraction Algorithms: A review," *Journal of Traffic and Transportation Engineering*, 6, 6, pp.535-556, Aug., 2019.
- [7] S. Ogawa, K. Matsushima, and O. Takahashi, " Efficient Pavement Crack Area Classification using Gaussian Mixture Model based Features," *Proceedings of International Conference on Mechatronics, Robotics and Systems Engineering*, Dec., 2019.
- [8] S. Ogawa, K. Matsushima, and O. Takahashi, " Crack Detection based on Gaussian Mixture Model using Image Filtering," *International Symposium on Electrical and Electronics Engineering*, Oct., 2019.
- [9] D. Shiotsuka, K. Matsushima, and O. Takahashi, " Crack Detection using Improved Spectral Clustering Considering Effective Crack Features," *International Conference on Robotics and Computer Vision*, Nov., 2018.
- [10] Z. Tong, J. Gao, and H. Zhang, " Recognition, Location, Measurement, and 3D Reconstruction of Concealed Cracks using Convolutional Neural Networks," *Construction and Building Materials*, 146, 15, pp.775-787, Aug., 2017.
- [11] N. Hoang, Q. Nguyen, and V. Tran, " Automatic Recognition of Asphalt Pavement Cracks using Metaheuristic Optimized Edge Detection Algorithms and Convolution Neural Network," *Automation in Construction*, 94, pp.203-213, Oct., 2018.
- [12] C. Dung and L. Anh, " Autonomous Concrete Crack Detection using Deep Fully Convolutional Neural Network," *Automation in Construction*, 99, pp.52-58, Mar., 2019.
- [13] N. Hoang, " Automatic Detection of Asphalt Pavement Raveling using Image Texture based Feature Extraction and Stochastic Gradient Descent Logistic Regression," *Automation in Construction*, 105, 102843, Sep., 2019.
- [14] M. Caron, P. Bojanowski, et al., " Deep Clustering for Unsupervised Learning of Visual Features," *Proceedings of European Conference on Computer Vision*, pp.132-149, Sep., 2018.
- [15] C. Campos, R. Elvira, et al., " ORB-SLAM3: An Accurate Open-Source Library for Visual, Visual-Inertial, and Multimap SLAM," *IEEE Transactions on Robotics*, pp.1-17, May, 2021.
- [16] K. Aizono and K. Matsushima, "Efficient Outlier Removal Combining REPPnP and the Levenberg-Marquardt Method," *IEEE International Conference on Computer and Communications*, pp. 2181-2185, Dec., 2020.
- [17] A. Mousavian, D. Anguelov, et al., "3D Bounding Box Estimation Using Deep Learning and Geometry," *IEEE Conference on Computer Vision and Pattern Recognition*, Jul., 2017.
- [18] M. E. Tipping, "Sparse Bayesian Learning and the Relevance Vector Machine," *Journal of Machine Learning Research* 1, pp.211-244, Jun. 2001.
- [19] H. Maeda, Y. Sekimoto, et al., " Road Damage Detection and Classification Using Deep Neural Networks with Smartphone Images, " *Computer-Aided Civil and Infrastructure Engineering*, 33, 12, pp.1127-1141, Jun., 2018.
- [20] V. Lepetit, F. M. Noguier, et al., " EPnP: An Accurate O(n) Solution to the PnP Problem, " *International Journal of Computer Vision*, 81, 2, pp.155-166, Feb., 2009.



〈発表資料〉

題名	掲載誌・学会名等	発表年月
Efficient Outlier Removal Combining REPPnP and the Levenberg-Marquardt Method	IEEE International Conference on Computer and Communications	2020年12月