

法政大学学術機関リポジトリ

HOSEI UNIVERSITY REPOSITORY

# 車椅子ロボットにおける屋外ナビゲーションアルゴリズムの性能評価

著者	厚沢 圭佑
出版者	法政大学大学院理工学研究科
雑誌名	法政大学大学院紀要. 理工学・工学研究科編
巻	60
ページ	1-5
発行年	2019-03-31
URL	<a href="http://doi.org/10.15002/00021960">http://doi.org/10.15002/00021960</a>

# 車椅子ロボットにおける屋外ナビゲーションアルゴリズムの性能評価

PERFORMANCE EVALUATION OF OUTDOOR NAVIGATION ALGORITHMS  
FOR THE WHEELCHAIR ROBOT

厚沢圭佑

Keisuke Atsuzawa

指導教員 チャピ ゲンツィ 教授

法政大学大学院理工学研究科機械工学専攻修士課程

This paper proposes navigation algorithms for mobile robot through the odometry approach. The proposed algorithms include the odometry-based algorithm which uses only odometry calculated from robot motions, and the visual-assisted algorithm that applies visual data to assist in the navigation. The visual-assisted algorithm takes the convolutional neural network with regression setups in addition to the odometry. Goal of the visual-assisted algorithm help localize the robot in navigation by recognizing the scene using camera images. Navigation algorithms are tested for outdoor navigation tasks in the specified route. The experiments consist of two situations for navigation on the same route: with obstacles and without obstacles. Experimental results state that the navigation using only odometry is sufficient for navigation in the experimental environments. The visual-assisted algorithm is proved to be an interesting alternative way of improvement for odometry, in which a large number of improvements and optimizations for visual techniques of outdoor robot navigation are still available to be studied and implemented further.

**Key words** : Outdoor robot navigation, Robot odometry, Convolutional neural network, Visual data

## 1. 緒言

屋外環境におけるナビゲーションおよび自己位置推定は、多くのロボット研究者を惹きつける移動ロボット分野における問題である。屋外での自律走行を行うために様々な方法が提案され、多くの方法が確立されつつある中で、GPSもナビゲーションおよび自己位置推定のために、多くの機会を利用して利用されている。

GPSを利用した移動ロボットの例としては、環境監視用ローバー式ロボットの自律誘導[1]、屋内外環境間でのロボットビークルのナビゲーション[2]、農業支援トラクターロボットナビゲーション[3]、実生活地形におけるローバーロボットナビゲーションのための経路計画 [4]などがある。しかしながら、GPSは曇りなどの悪天候、高層建築物および高さのある木々が近くにある場所では、衛星からの信号受信を妨げられ、パフォーマンス低下を招く弱点がある。

ロボット自身の動きからロボット位置を推定する方法としてオドメトリが古くから利用されている。オドメトリは、GPSが使用不可な状況で有効な手段であるが、ロボットの動作中の内部データの急激な変化や推定誤差の蓄積により、自己位置推定における大きな誤差が発生する。

他方で近年、ディープラーニングの進歩により、GPSの軌跡をディープラーニングで使用したタクシー運転手の効率性を高めるためのシステムの開発[5]等、ディープラーニングと既存の技術を組み合わせて新しい技術を開発するといった、既存の技術を有効利用するための選択肢が増えている。有望なディープラーニングベースの選択肢の一つである畳み込みニューラルネットワーク(CNN)は、視覚情報や画像を効果的に扱う動物の視覚野を模した畳み込み層からなるニューラルネットワークである[6]。

CNNの性能は、歯科用パノラマX線画像における歯の検出[7]および顔の表情から感情認識[8]等の画像分類作業にCNNを適用した様々な用途にて実証されている。また、物体検出のためのFaster\_R-CNNアルゴリズムでは、CNNの畳み込み層を使用して画像を表す特徴マップを作成することができる[9]。CNN生成された特徴マップは、画像から立体姿勢の推定[10]で言及されているように、分類に加えて回帰タスクにも使用できることが示されている。これは、画像データを通じてロボットの位置決定にCNNを適用できる可能性があると言える。

そこで本研究では、オドメトリとGPSデータを埋め込んだカメラ画像を学習したCNNを組み合わせて、ロボットの自己位置推定法を考案、検証する。

本稿の以下の構成は、次のようになっている。2章では、車椅子ロボットやCNN等の実装部分についての説明を記述した。3章ではナビゲーションタスクで使用したナビゲーションアルゴリズムについての説明を記述した。4章では提案したナビゲーションによる実験と実験結果について記述した。最後に、5章では本稿の結論を記述し、今後の展望について論述した。

## 2. 実装部分

### (1) 自己位置推定のための

#### 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク(CNN)は大抵画像として扱われる二次元行列を用いて使われているニューラルネットワークである。CNNは活性化関数およびダウンサンプリングとともに、一つまたは複数の二次元フィルタの層によって形成される[11]。典型的には、CNNは所

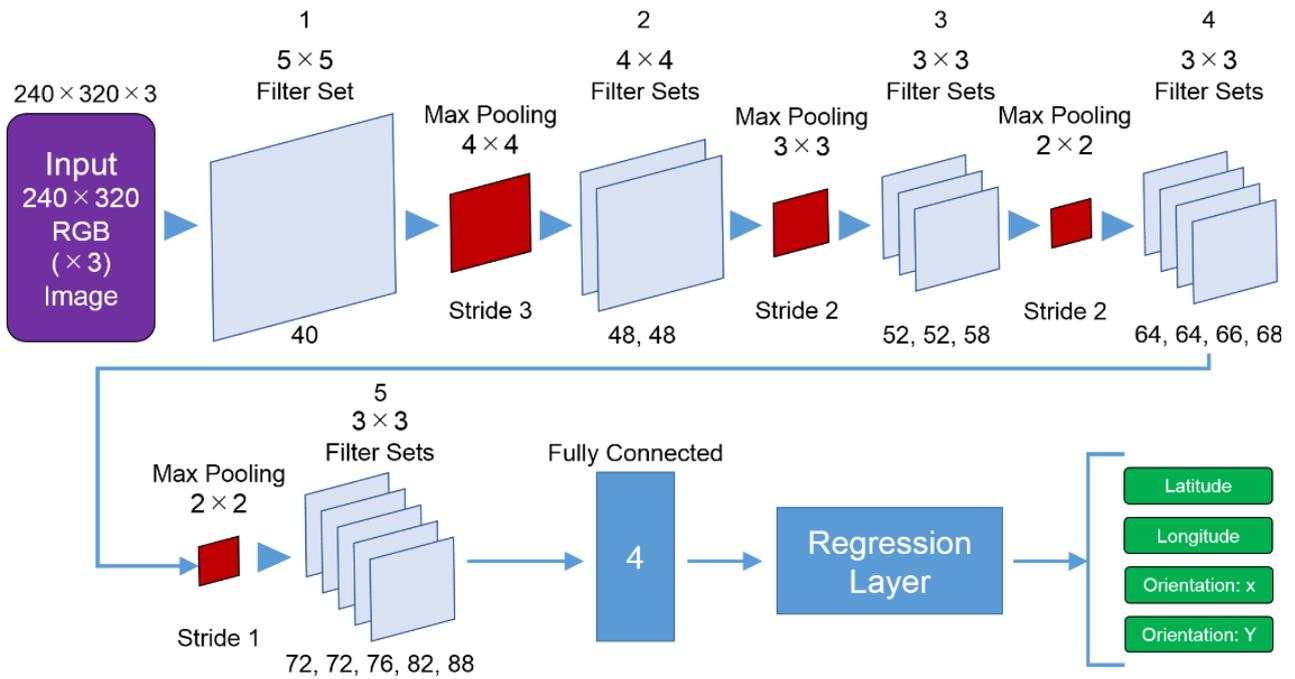


Fig.1 Design of the implemented CNN for localization.

望の入力画像のサイズを持つ入力層から始まる。例として、 $320 \times 240$  ピクセルのカラー画像を CNN に使用する場合、 $320 \times 240 \times 3$  のサイズの入力層を用いる。入力層の後は、二次元フィルタまたは畳み込み層、活性化関数およびダウンサンプリング層で構成される。通常、一つの畳み込み層の後は活性化関数の層が続く。これには多くの研究において活性化関数として整流線形単位 (ReLU) が使用されている。ダウンサンプリングについて、畳み込み層から生成された特徴マップのダウンサンプリングのために様々なタイプのプーリング層が適用される。ダウンサンプリングは、計算量を削減し、CNN の性能を向上させることを目的としている。しかしながら、ダウンサンプリングは情報量を少なくしすぎてしまう問題が発生する場合がある[12]。CNN は特に分類作業に適用され、完全に接続された層および分類のための層、例えば Softmax 分類器は、フィルタ、活性化関数、およびダウンサンプリング層の後の構成に続いて接続される[7][8]。しかしながら、いくつかの研究は、分類層を完全に接続された層と回帰のための層とに代えている。その結果、これらの手法の CNN は、[10]で述べられているデモンストラーションのような回帰タスクを処理するために画像を使うことができる。

本研究で実装した CNN の設計を Fig.1 に示す。CNN は全部で 52 の層からなる。CNN の入力層は、 $240 \times 320 \times 3$  (240 行, 320 列, および 3 色チャンネル) のサイズを有する。CNN には、15 セットの畳み込み層、トレーニングパフォーマンスを向上させるためのバッチ正規化、および ReLU も含まれている。各セットに対して、畳み込み層、バッチ正規化、および ReLU を一つのフィルタセットとしてまとめて表している。畳み込み層は、各部分に異なるサイズの二次元フィルタと異なる数のフィルタを使用した。大きいフィルタサイズは畳み込みの初期の層に適用され、小さいフィルタサイズはそれより後の層に適用され、最小のフィルタサイズは  $3 \times 3$  である。一方、最初の畳み込みの 40 個のフィルタから始めて、より少ない数のフィルタがより早い畳み込みの層に適用される。ネットワークが後の層で進むにつれて、フィルタの数は増える。この設計では、 $4 \times 4$ ,  $3 \times 3$ ,

$2 \times 2$ , および  $2 \times 2$  のサイズの四つの最大プーリング層を採用した。プーリング層のストライド設定は、それぞれ 3, 2, 2, および 1 であり、最大プーリング層の位置も示している。実装された CNN の後半には、一つの完全接続層と回帰用の層がある。設計された CNN には、最後に完全に接続された層のニューロン数が 4 であるため、四つの出力がある。これらの四つの出力は、X 軸と Y 軸システムの緯度、経度、およびコンパス方位の場所で構成されるネットワークの結果ターゲットのプレースホルダーになっている。

実施した CNN トレーニングは、GPS 座標およびコンパス方位からなる対応するメタデータとともに、 $320 \times 240$  ピクセルのサイズの 4000 セットの画像を採用した。これらの画像のセットは、各画像が GPS 受信機からの GPS 座標とコンパスセンサからの方位でタグ付けされた法政大学、小金井キャンパスの中庭で撮影を行った。CNN トレーニングでは入力データとして画像を使用し、埋め込み GPS 座標とコンパス方位をターゲットデータとして使用した。2000 セットの画像と対応するメタデータをトレーニングのためにランダムに選択し、残りの 2000 セットのデータを検証として使用した。CNN トレーニングの設定には、52 トレーニングエポック、64 のバッチサイズ、および  $1 \times 10^{-6}$  の初期学習レートが含まれている。ここで、学習レートは 20 エポックごとに 0.02 のレートで減少させた。検証済み CNN は、検証データセット内の入力画像から GPS 座標およびコンパス方位を生成することによって初期テストを行った。CNN と検証出力データセットの結果を比較すると、CNN は約 1% の誤差を達成している。

## (2) 車椅子ロボット

提案手法を実装したロボットシステムは、Fig.2 に示すような車椅子ロボットである。ロボットシステムは、ノート PC、USB カメラ、コンパスセンサ、GPS、レーザ距離計、そして左右の後輪にある 2 つのヤマハ AC モータで構成されている。ノート PC は、ロボットの背面にあるプレースホルダーに置かれている。USB カメラ、GPS、およびコンパスセンサは、ロボット上部の亚克力板の上に配置されている。レーザ距離計は、車椅子ロボットの正面の左下部分に配置されており、レーザ距離計は底面前方を水平

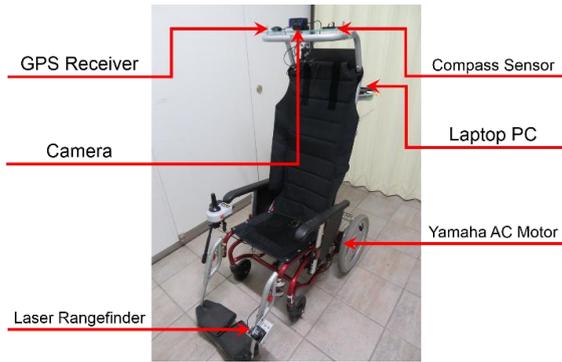


Fig. 2 Wheelchair robot and components.

から 15 度下方向に傾けて設置した。USB カメラ、コンパスセンサ、およびモータコントローラからのデータは、提案ナビゲーションアルゴリズムで利用される。GPS は、実装されたデータセット内の画像にタグを付けるために使用した。

### 3. ナビゲーションアルゴリズム

屋外ロボットのナビゲーションタスクに実装されている二つのナビゲーションアルゴリズム (オドメトリベースのナビゲーションと視覚情報から補正を行うナビゲーション) を検証に使用し、両者のパフォーマンスを比較する。本章ではそれぞれの概要について述べる。

#### (1) オドメトリベースのナビゲーション

オドメトリベースのナビゲーションでは、ロボットの位置は、ロボット内のモータの動きを使用して計算した。ロボットの動きによる位置計算のために次式の方程式を利用する。

$$Lat_{i+1} = Lat_i + \Delta y \times A \quad (1)$$

$$Lon_{i+1} = Lon_i + \Delta x \times B \quad (2)$$

ここで、 $Lat$  は緯度、 $Lon$  は経度、 $\Delta y$  はメートル単位の垂直位置差、 $\Delta x$  はメートル単位の水平位置差、 $A$  は垂直差を緯度に変換する係数、 $B$  は水平差を経度に変換する係数である。水平方向と垂直方向の位置合わせにおける位置の違いは、次式で計算される。

$$\Delta y = \Delta L \sin(\theta + \Delta\theta/2) \quad (3)$$

$$\Delta x = \Delta L \cos(\theta + \Delta\theta/2) \quad (4)$$

ここで、 $\Delta y$  はメートル単位の垂直位置差、 $\Delta x$  はメートル単位の水平位置差、 $\Delta L$  はロボットの車輪の動きと時間から計算された前の位置からのロボットの距離、 $\theta$  はロボットの向きである。 $\Delta\theta$  はロボットの左右の車輪の動きから計算された、ロボットが水平面に垂直な軸方向に回転する角度である。2.2 節で説明したように、ロボットの方向は、ロボットに取り付けられた外部コンパスセンサからも収集される。

オドメトリベースのナビゲーションフローを Fig.3 に示す。ロボットは最初に初期位置と目標位置を決定する必要がある。その後、ロボットは指定された経路に沿って目標位置に移動する。動作中に、ロボットは、モータに内蔵されたエンコーダから得られるモータ回転数を通じて現在

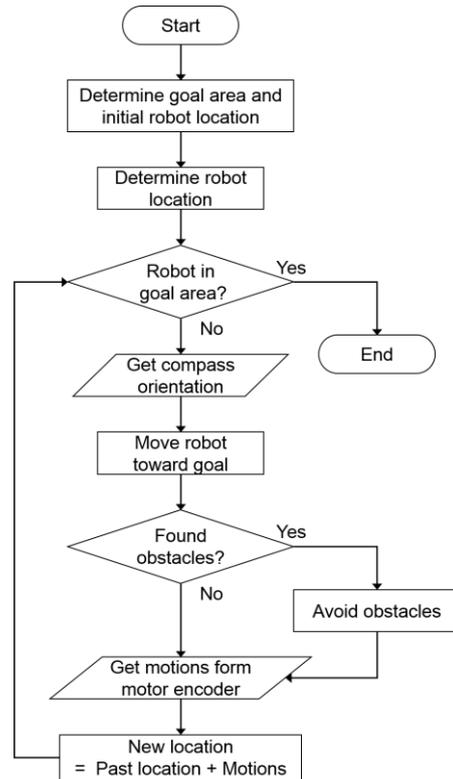


Fig. 3 Odometry-based navigation flowchart.

の位置および向きを決定し、コンパスセンサからも現在の向きを取得する。位置計算はごく短時間で終わるため、ロボットの位置はリアルタイムで求められる。ロボットは、ロボットの動きやコンパスの方向からの位置によって経路に沿って移動しながら移動し、モータの制御量はこれらの値によって制御される。ロボットが経路内で障害物に遭遇した場合、ロボットは装備したレーザ距離計からの距離データに従って検出された障害物を回避する。ロボットが目標位置に到達すると、ロボットは停止する。

#### (2) 提案手法 視覚情報から補正ナビゲーション

オドメトリベースのナビゲーションと同様に、視覚情報から補正を行うナビゲーションもオドメトリを使用している。なお、位置および向きは、ロボットに取り付けられたカメラからの画像を用いて定期的に更新される。視覚データを介して更新するこのプロセスは、CNN にカメラ画像を使用することによって完了し、ロボットの現在位置およびコンパス方位を更新する。

視覚情報から補正を行うナビゲーションの流れは、Fig.4 のフローチャートに従う。オドメトリベースのナビゲーションと同様に、視覚情報から補正を行うナビゲーションは、目標およびロボットの初期位置を取得することによって開始し、その後、ロボットはその経路に沿ってナビゲーションされる。オドメトリとコンパスセンサは同様にナビゲーションとロボット制御で使用する。レーザ距離計を用いた障害物の検出と回避は、視覚情報から調整を行うナビゲーションにも適用される。但し、ロボットの位置とコンパスの向きは、オドメトリによる自己位置推定において 5 メートルごとに画像と CNN を使用して更新される。更新された位置および方向がロボットが経路上にいないことを示す場合、ロボットは正しい経路に戻る必要がある。この CNN 使用の定期的なタイミングの背後にある理由は、CNN は処理に時間がかかり、一定のリアルタイム計算に

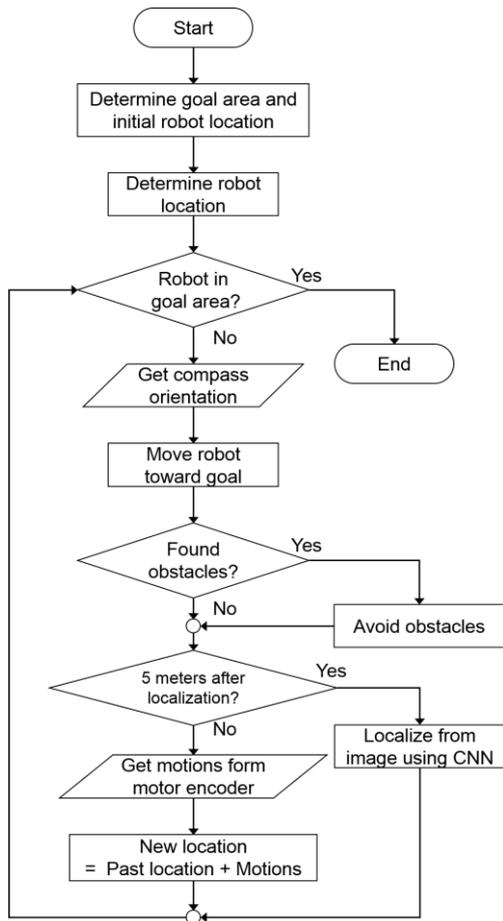


Fig4 Visual-assisted navigation flowchart.

は適していないことである。なお、オドメトリベースのナビゲーションと同様に、ロボットは目標地点に到達すると停止する。

#### 4. 実験と実験結果

##### (1) 実験方法

車椅子ロボットのナビゲーションアルゴリズムの実験は、法政大学小金井キャンパス内で行った。実験の経路地図を Fig.5, また障害物配置時の様子を Fig.6 に示す。車椅子ロボットの実験は、2つの提案ナビゲーションアルゴリズムの使用による初期位置から目標位置までの経路に沿った車椅子ロボットのナビゲーションとした。ナビゲーション実験の参照経路は、地図内の開始点と目標を含む円マーカーの付いた線として示される。実験はまた、ナビゲーション経路における障害物を含む。約 1m<sup>3</sup> の大きさで5つの段ボール箱を障害物とした。障害物とその位置は、Fig.7 中の丸い四角で示されている。ロボットに取り付けられたレーザ距離計からの距離データを使用して、障害物を回避するようにした。なお、動作中のロボットの様子を Fig.8 に示す。

##### (2) ナビゲーション結果

実装ナビゲーションアルゴリズムの結果を、Fig.7 の地図上に軌跡として示す。Fig.7 (a)および(b)の三角形のマーカー付きの黒い線は、オドメトリのみを使用するロボットのナビゲーション時の軌跡を示す。菱形マーカーの線は、オドメトリと視覚データを使用した提案手法ナビゲーション時の軌跡を示す。地図上の点線はノート PC に記録されているロボットの軌跡を示し、実線は実際の環境におけるロボットの軌跡を示す。

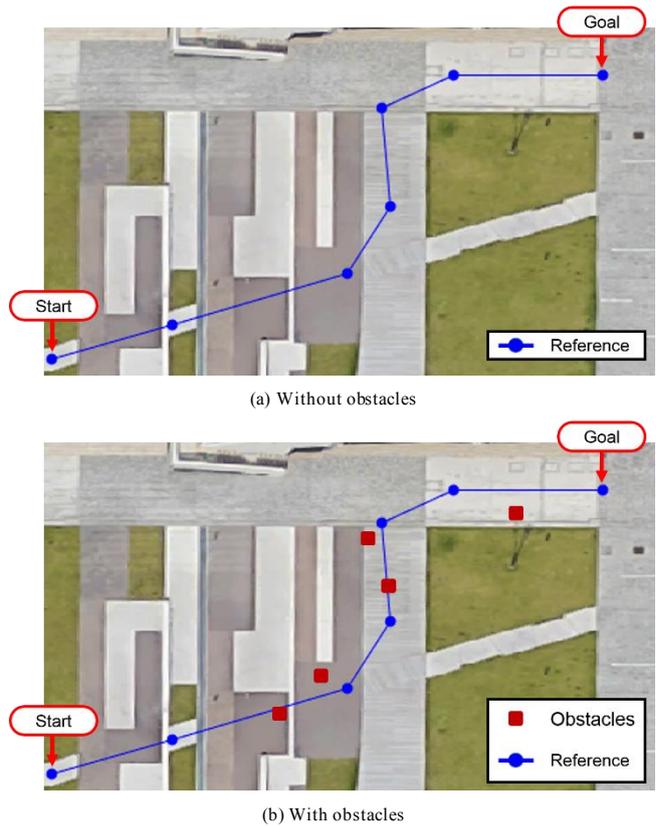


Fig.5 Maps of experimental area and designated path.

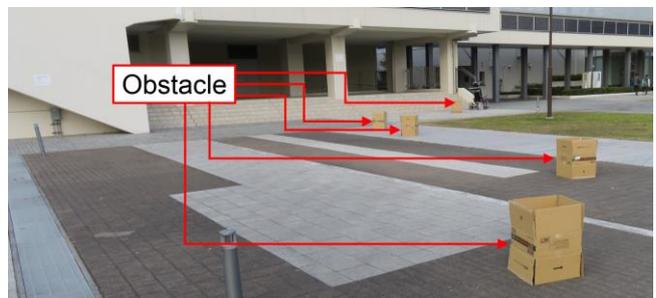
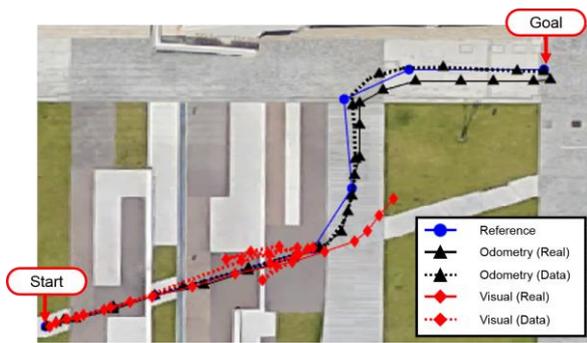


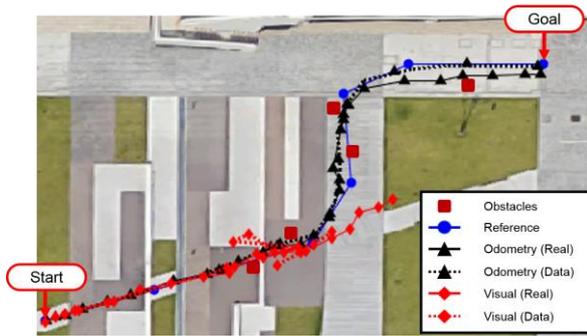
Fig.6 Obstacles in experimental environment.

Tab.1 に、ナビゲーションアルゴリズムからの経路の平均誤差を示す。ナビゲーションアルゴリズムからの誤差は、ロボットの軌跡上の位置と参照経路上の位置を同時に比較することによって求めた。誤差計算に使用した線は、オドメトリおよび提案手法ナビゲーションからのロボットの軌跡である。

Fig.7 (a)から、経路上に障害物がなく、オドメトリベースのナビゲーションは有意な誤差なく指定された経路に沿って移動したことが分かる。Fig.7 (b)の経路上に障害物が存在する場合、障害物がない場合と比較して、軌跡が参照経路からごくわずかな距離だけ回避移動する様子を見ることができ、オドメトリを用いたナビゲーションの誤差はわずかに増加した。オドメトリのみを使用したナビゲーションの誤差は、約 1m となり、障害物有無による誤差の著しい増加はなかった。提案手法ナビゲーションは、障害物のある実験的状況の有無にかかわらず、走行距離のみを使用するアルゴリズムよりも悪い軌跡を示した。ロボット



(a) Without obstacles



(b) With obstacles

Fig.7 Navigation results on the map for both experimental situations.

はすべての実験で目標位置に到達することはなかった。Tab.1に示されるような定量的結果もまた、平均誤差が約10mとなっている。

提案手法ナビゲーションエラーの原因については、まず、CNN トレーニングに約 2000 データセット用意したが、今回の実験には不十分であったこと、また実験を行ったキャンパス内の風景は単調であり、視覚情報として有用な特徴量が乏しいという点が挙げられる。また、用意したデータセットは、そのデータの構造が適切ではなく、データが回帰に対して十分に一貫していない可能性も考えられる。さらに、CNN の設計と CNN のトレーニングオプションがまだデータセットからのローカライズに十分に最適化されていない可能性がある。なお、これらの問題については現在対処されており、将来の作業に向けて改善される予定である。より多くのデータセットをシステムに実装予定であるが、新しいデータセットでは構造とデータの一貫性も考慮する予定である。

## 5. 結論

本稿は走行距離法による移動ロボットのためのナビゲーションアルゴリズムを提案した。提案されたアルゴリズムには、ロボットの動きから計算されたオドメトリのみを使用するオドメトリベースのアルゴリズム、および視覚データを使用した視覚情報による補正アルゴリズムが含まれる。提案手法のアルゴリズムは、カメラ画像を使用してシーンを認識することによってナビゲーション中のロボット位置推定するために回帰設定を有する畳み込みニューラルネットワークを用いた。指定されたナビゲーションルートの屋外ナビゲーション実験を行い、パフォーマンスの検証を行った。その結果、提案手法アルゴリズムは、予想された結果が得られず、誤差はオドメトリベースのナビゲーションよりも大きいものとなった。しかしながら、屋外ロボットナビゲーションに対する視覚情報の利用方法に関して、CNN を導入するための一定の知見を得られた。



Fig.8 Wheelchair robot avoids obstacles while being navigated along the specified path.

Tab.1. Average errors of the navigation in meters.

	No Obstacles	With Obstacles
Odometry (Real)	0.97 m.	1.02 m.
Odometry (Data)	0.51 m.	0.56 m.
Visual (Real)	2.51 m.	2.05 m.
Visual (Data)	12.21 m.	8.23 m.

## 参考文献

- (1) M. Carpentiero, L. Gugliemetti, M. Sabatini, and G. B. Palmerini : "A swarm of wheeled and aerial robots for environmental monitoring", IEEE 14th International Conference on Networking, Sensing and Control (ICNSC), Calabria, pp.90-95 (2017)
- (2) Urcola P., Lorente M.-T., Villarroel J.L., and Montano L : "Robust Navigation and Seamless Localization for Carlike Robots in Indoor-outdoor Environments", Journal of Field Robotics, Vol.34, No.4, pp.704-735 (2017)
- (3) H. Wang and N. Noguchi : "Autonomous maneuvers of a robotic tractor for farming", IEEE/SICE International Symposium on System Integration (SII), Sapporo, pp.592-597 (2016)
- (4) A. Al Arabi, H. Ul Sakib, P. Sarkar, T. P. Proma, J. Anowar, and M. A. Amin : "Autonomous Rover Navigation Using GPS Based Path Planning", Asia Modelling Symposium (AMS), Kota Kinabalu, pp.89-94 (2017)
- (5) Huang Z., Zhao Z., E S., Yu C., Shan G., Li T., Cheng J., Sun J., and Xiang Y. : "PRACE: A taxi recommender for finding passengers with deep learning approaches", Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 10363 LNAI, pp.759-770 (2017)
- (6) S. R. Kheradpisheh, M. Ghodrati, M. Ganjtabesh, T. Masquelier : "Deep Networks Can Resemble Human Feed-forward Vision in Invariant Object Recognition", Scientific Reports, Vol.6, pp.1-24 (2016)
- (7) A. Betul Oktay : "Tooth detection with Convolutional Neural Networks", Medical Technologies National Congress (TIP TEKNO), Trabzon, pp.1-4 (2017)
- (8) A. Ruiz-Garcia, M. Elshaw, A. Altafhan and V. Palade : "Stacked deep convolutional auto-encoders for emotion recognition from facial expressions", International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, pp.1586-1593 (2017)
- (9) S. Ren, K. He, R. Girshick, J. Sun : "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.39 (6), pp.1137-1149 (2017)
- (10) S. Mahendran, H. Ali and R. Vidal, "3D Pose Regression Using Convolutional Neural Networks", IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Honolulu, HI, pp.494-495 (2017)
- (11) M. Browne, S. S. Ghidary, and N. M. Mayer : "Convolutional Neural Networks for Image Processing with Applications in Mobile Robotics", Speech, Audio, Image and Biomedical Signal Processing using Neural Networks. Studies in Computational Intelligence, Vol.83, pp.327-349 (2008)
- (12) G. Zhao, J. Wang, Z. Zhang : "Random Shifting for CNN: a Solution to Reduce Information Loss in Down-Sampling Layers", Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence, pp.3476-3482 (2017)