

移動ロボットのための全方位画像を使った Deep Learning 環境認識法

竹林, 洋亮 / TAKEBAYASHI, Yosuke

(出版者 / Publisher)

法政大学大学院理工学・工学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 理工学・工学研究科編 / 法政大学大学院紀要. 理工学・工学研究科編

(巻 / Volume)

58

(開始ページ / Start Page)

1

(終了ページ / End Page)

4

(発行年 / Year)

2017-03-31

(URL)

<https://doi.org/10.15002/00014346>

移動ロボットのための全方位画像を使った Deep Learning 環境認識法

A study of Deep Learning based environment recognition by applying Omni-directional images for a Mobile Robot

竹林洋亮

Yosuke Takebayashi

指導教員 小林一行教授

法政大学大学院理工学研究科システム理工学専攻修士課程

This paper describes a study of Deep Learning based environment recognition by applying Omni-directional images. In order to apply Omni-directional images to deep neural network, we decompose image which may be suitable for detecting moving direction. The validity of proposed approach is confirmed by applying actual outdoor omnidirectional images.

Key Words : Machine Learning, Deep Learning, Mobile Robot.

1. はじめに

近年、自動運搬ロボットや自動運転車など、自律移動機能の開発が活発である。このような場面において、自己位置の推定、経路の決定が重要となる。一般に、自律移動ロボットはホイールオドメトリ、GPS、障害物等の情報から経路を決定する。ホイールオドメトリは車輪の回転数を加算していく手法のため、蓄積誤差が生じる。これをGPSや障害物情報で補正する手法を用いることが多い。しかし、屋内のGPSを使用できない場所や、障害物を誤検出する場合は自己位置の補正が破綻してしまう。本研究では蓄積誤差の生じない手法として、コースの画像を学習させることで、画像から進行方向を判別し、経路決定のための情報の1つとすることを考えた。

画像の学習には様々な手法があるが、本研究ではDeep Learningで画像を学習させた。Deep Learningとは、多層のニューラルネットワークを用いた機械学習である。一般的には画像認識に適用され、特徴を抽出し、複数のカテゴリに分類することが可能である。従来、機械学習を行なう場合は特徴抽出、ベクトル表現、学習器など多くの処理を必要としていた。これをDeep Learningで行った場合、ネットワーク構築一つで済む。

2. 移動ロボット

移動ロボットはFig.1の対向二輪駆動ロボットを使用する。上方に搭載された全方位カメラは、全方位の画像を取得することができる。他に障害物センサー、ジャイロセンサー、GPSなどを搭載し、これらの情報を基に自律走行が可能である。




Fig.1 Mobile robot

3. 経路決定

移動ロボットの経路決定にはホイールオドメトリ、GPS、障害物等の情報を用いる。これらの情報をもとにポテンシャル法、A*法で経路を決定する。屋内など、GPSを使用できない場所や、障害物を誤検出する場合は自己位置の推定が破綻し、経路決定ができない。本研究では、コースの環境を学習させることで画像から進行方向を判別し、経路決定のための情報の1つとすることを考えた。

4. 全方位カメラ

コースの環境を学習させるため、全方位カメラで画像を取得した。全方位カメラを使用することで、移動ロボットの前方だけでなく、側面や後方の画像も一度に取得することができる。通常のカメラを複数搭載するよりも単純でずれの無い画像処理が可能である。学習後、進行方向の判別をする際にも、一度に全方位の判別を可能とする利点もある。

本研究では全方位カメラに THETA S を使用した。THETA S は広角レンズのカメラを2つ搭載し、全天球の画像を取得することができる。



Fig.2 THETA S

5. 画像の取得

学習用の画像を取得する際は、移動ロボットから全方位カメラを外し、カメラを手で持ち取得した。THETA S は全天球の画像を取得できるが、進行方向の学習には地面側の画像で十分であると考え、一方のレンズが地面を向くようにTHETA Sを持ち、画像を取得した。

Fig.3の全方位画像を天球の中心から切り開き161x360pixelのr-theta画像に変換した。この画像から130x130pixelで8方向に切り出し、学習データとした。学習データの解像度は学習に大きな影響を及ぼし、可能な限り小さい方が好ましい。本研究では、人間が目視で画像に教師データを付与するため、人間が見て間違えることのない大きさとしてこの解像度に決定した。



Fig.3 Omni-directional image




Fig.4 Division of image

6. Deep Learning

環境の学習には、Deep Learning の1つである Convolution Neural Network を用いた。これは、画像に様々なフィルタをかけ、最終的に多層パーセプトロンで画像を分類する学習方法である。この手法で学習用画像を直進、右旋回、左旋回、転回の4つに分類した。

本研究では、Convolution Neural Network を Google が公開する機械学習用ライブラリの TensorFlow で構築した。学習には NVIDIA のビデオカード、GeForce GTX 1060(6GB GDDR5)を使用した。以下に学習に用いたネットワークを示す。

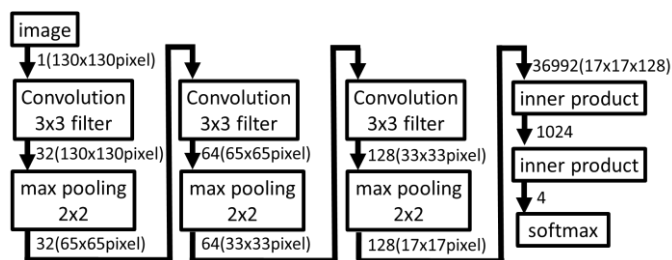


Fig.5 Convolution Neural Network

7. 実験環境

本研究では環境認識の検証として、学内の庭をコースとして使用した。スタート地点を直進し、庭の周りを回る約150mのコースを学習させた。




Fig.5 Experiment course

8. 学習データ

定められたコースを走行させ、画像を取得し、画像それぞれに対応した教師データを手動で設定する。教師データは、画像が移動ロボットの前方に見えた場合の進行方向とした。取得した8方向の画像の内3枚は撮影者、移動ロボット自身が映りこんでいるため、使用しないこととした。また、障害物が画像の大半を占めているもの、画像が非常に不鮮明なものなど、学習に適さないものは除いた。




Fig.6 Training data

9. 判別結果の統合

全方位カメラを搭載したことにより、進行方向を判別する際にも3方向、または5方向の画像の判別結果を得ることができる。判別結果の統合は、結果の整合が取れているかどうかで判断する。例えば、左旋回と判別された画像より右にある画像が右旋回と判別された場合は整合が取れていないことになる。まず、前方、左方、右方の画像で整合性を確認し、合わなければ、更に左前方、右前方の判別結果を追加し、進行方向の判別結果を統合する。具体的な統合過程を以下に示す。

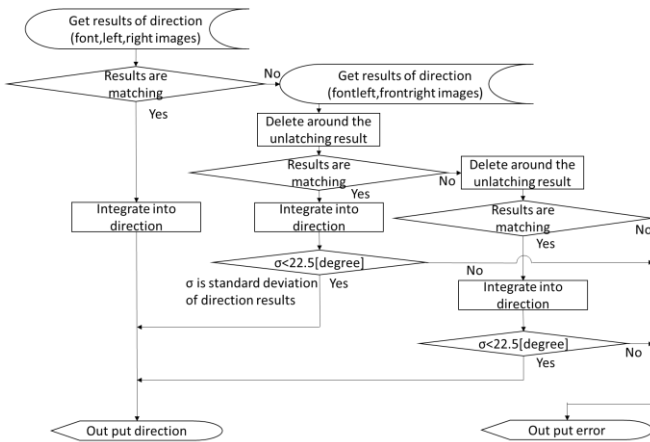


Fig.7 Results integration

10. 学習結果

コース1周分、約500枚の画像を学習させた。学習結果を以下に示す。




Fig.8 Result of learning lap1

学習終了後、新たにコース1周分の画像を取得し、未知の画像として進行方向を判別することで効果を検証し

た。正しい進行方向を90%以上示す場合を正解とした結果、約500枚中52枚の誤りを確認した。

学習用データを更に9セット用意し、同様に学習と結果の確認を行った。計10セット分の学習結果を以下に示す。




Fig.9 Transition of learning result

Table.1 Transition of learning result

Single result	Lap1	Lap1-2	Lap1-3	Lap1-4	Lap1-5
Miss[sheet]	52	43	39	37	28
Accuracy[%](/500)	89.6	91.4	92.2	92.6	94.4
Omni-directional result	Lap1	Lap1-2	Lap1-3	Lap1-4	Lap1-5
Miss[sheet]	4	4	4	3	3
Accuracy[%](/100)	96	96	96	97	97

Single result	Lap1-6	Lap1-7	Lap1-8	Lap1-9	Lap1-10
Miss[sheet]	14	14	18	13	10
Accuracy[%](/500)	97.2	97.2	96.4	97.4	98.0
Omni-directional result	Lap1-6	Lap1-7	Lap1-8	Lap1-9	Lap1-10
Miss[sheet]	1	0	1	1	0
Accuracy[%](/100)	99	100	99	99	100

Fig.10に正規のコースから4m右にずらしたコースを示す。このコースの画像を取得し、判別を行った。結果を以下に示す。



Fig.10 Offset course

Table.2 Result of offset curse

	Offset course	Expected course
Accuracy[%]	93	100

未知の障害物があるコースの画像取得し、判別を行った。結果を以下に示す。



Fig.11 Unlearnt obstacle

Table.3 Result of course with unlearnt obstacle

Distance[m]	10	9	8	7	6	5
Experiment 1	turnright	turnright	gostraight	turnright	turnright	turnright
Experiment 2	turnright	turnright	turnright	turnright	turnright	turnright
Expected result	gostraight	gostraight	gostraight	gostraight	gostraight	gostraight
Distance	4	3	2	1	0	
Experiment 1	turnright	turnright	turnright	turnright	turnright	
Experiment 2	turnright	turnright	turnright	turnright	turnright	
Expected result	gostraight	gostraight	gostraight	gostraight	gostraight	

1.1. 結果

今回は Deep Learning による環境認識の検証として、コースの進行方向を学習させることを考えた。その結果、コース内で正しい進行方向を判定することができた。全方位カメラを用いたことにより、道の障害物が存在した場合も、その他の方向から得られる進行方向の判定を統合することで解決できた。

1.2. 今後の課題

実際に Deep Learning による環境認識で自律走行を行う場合は、道の環境が必ず存在するため、より多くの学習をする必要がある。また、判別結果は必ず信用できるものではないため、他の環境認識アルゴリズムも併用し、補う必要がある。

本研究で用いたコースは短かったため、進行方向を判別することができた。しかし、さらに長距離の環境を学習させる場合、Convolution Neural Network を大きくする必要がある。学習ネットワークが大きくなる場合、高価なビデオカードを要求し、追加学習も困難になる。他の手段としては、コースを分割し、学習データを分割することができる。これにより、長いコースにおいても今回の結果と同様の精度を出すことができると考えられる。

参考文献

- 1) A.Giusti et al. : A Machine Learning Approach to the Visual Perception of Forest Trails for Mobile Robots, IEEE Robotics and Automation Letters, Vol.1-2, pp.661-667, 2016
- 2) Ching Wei Tseng, Hong-Ren Su, Shang-Hong Lai, and JenChi Liu: Depth image super-resolution via multi-frame registration and deep learning, 2016 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference, pp.1-8, 2016
- 3) Chris McCool, Tristan Perez, and Ben Upcroft: Mixtures of Lightweight Deep Convolutional Neural Networks: applied to agricultural robotics, IEEE Robotics and Automation Letters, 2017
- 4) Lei Tai, Shaohua Li, and Ming Liu: A Deep-Network Solution Towards Model-less Obstacle Avoidance, 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.2759-2764, 2016

- 5) Raia Hadsell, Ayse Erkan, Pierre Sermanet, Marco Scoffier, Urs Muller, and Yann LeCun: Deep Belief Net Learning in a Long-Range Vision System for Autonomous Off-Road Driving, 2008 IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.628-633, 2008
- 6) Sen Jia, Thomas Lansdall-Welfare and Nello Cristianini: Gender Classification by Deep Learning on Millions of Weakly Labelled Images, 2016 IEEE 16th International Conference on Data Mining Workshops, pp.462-467, 2016
- 7) Sohini Roychowdhury, and Johnny Ren: Non-deep CNN for Multi-Modal Image Classification and Feature Learning: An Azure-based Model, 2016 IEEE International Conference on Big Data, pp.2803-2812, 2016
- 8) Yuan Rao, and Jiangqun Ni: A Deep Learning Approach to Detection of Splicing and Copy-Move Forgeries in Images, 2016 IEEE International Workshop on Information Forensics and Security , pp.1-6, 2016