



## 完全自律飛行ロボットに搭載した360 度カメラによる自己位置認識

メタデータ	言語: jpn 出版者: 交通流数理研究会 公開日: 2020-07-07 キーワード (Ja): キーワード (En): 作成者: 大谷, 元気, 本田, 泰 メールアドレス: 所属:
URL	<a href="http://hdl.handle.net/10258/00010218">http://hdl.handle.net/10258/00010218</a>

# 完全自律飛行ロボットに搭載した360度カメラによる自己位置認識

大谷元気<sup>1</sup>, 本田泰<sup>2</sup>

<sup>1</sup> 室蘭工業大学大学院 工学研究科 情報電子工学系専攻

<sup>2</sup> 室蘭工業大学大学院 しくみ解明系領域

## 概要

完全自律飛行ロボットは3次元自己駆動粒子の一種である。本研究では360度カメラを搭載した飛行ロボットの三次元座標と向きを認識を試みる。座標や向きを知る手段はGPSや方位センサー等様々なものがある。しかし、室内や磁場の安定しないような場所では正確な向きや座標を知ることができない。そこで本研究では、360度カメラを用いて飛行ロボットの向きと座標の認識を目指した。基準としたい場所にカラーオブジェクトを2つ設置し、そのカラーオブジェクトと飛行ロボットの相対座標と向きを認識した。ニューラルネットワークを用いて認識し、球面投影モデルと比較した。

## Self-location recognition by a 360-degree camera mounted on a completely autonomous flying robot

Genki Ohtani<sup>1</sup>, Yasushi Honda<sup>2</sup>

<sup>1</sup> Division of Information and Electronic Engineering, Graduate school of Engineering, Muroran Institute of Technology, Japan

<sup>2</sup> College of Information and Systems, Muroran Institute of Technology, Japan

## Abstract

Completely autonomous flying robot is one of three dimensions self-driven particle. This study was made to recognize the three-dimensional coordinates and direction of a flying robot equipped with a 360-degree camera. The purpose of this study is to derive the three-dimensional coordinate relative to color objects. We used neural networks as a means to end. And we compared neural network with the spherical projection model for purposes.

## 1 はじめに

近年、ドローンと呼ばれる無人航空機は人々の生活に馴染み深いものとなっている。一方で、その安全性が懸念されている。地上で動作するロボットとは違い、空中で動作するため落下による事故の危険性も高い。そして、操縦の難しさによるヒューマンエラーも少なくない。そのため、ドローンは環境の変化に適応する自律行動を取ることが求められている。

本研究で扱う飛行ロボットは4回転翼自律飛行ロボット [1] である。完全自律飛行ロボットは3次元自己駆動粒子の一種である。飛行ロボットは自律飛行するため、自分の位置や向きを把握する必要がある。ロボットの座標や向きを知る手段は様々なものがある。GPSや方位センサーなどの小型で安価なものが多数市販されている。また、複数のドローン間で直接通信を行い、衝突などの危険を回避し安全性を高める研究も行われている [2]。これらの研究に置いても、GPSなどの外部からドローンの位置情報を得ることを前提としている。しかし、GPSを受信できな

いような場所や磁場の安定しないような場所では座標や向きを知ることはできない場合も存在する。そこで我々は、飛行ロボット自身に搭載したカメラによる画像情報を使い、座標と向きを認識できないかと考えた。

本研究の目的は、飛行ロボットに搭載したカメラによる色検出を用いてカラーオブジェクトと飛行ロボットの3次元座標と相対的な向きを認識することである。基準としたい点の床に2つのカラーオブジェクトを配置することで、飛行ロボットの座標と向きの認識を目指した。

本研究では目的達成のために2つの手法を提案し比較を行った。1つ目は、順伝播型ニューラルネットワークの教師付き学習を用いた手法である。ニューラルネットワークを用いることで、カメラの歪によるカラーオブジェクトの歪や飛行姿勢によるノイズを補正できると考えた。2つ目は、カメラの歪を補正する式を作成し座標取得を目指す手法 (球面投影モデル) である。この2つのモデルにより飛行ロボットの3次元座標と向きを認識し精度を比較した。

## 2 4回転翼自律飛行ロボット

本実験で使用するロボットは4回転翼自律飛行ロボット [1] である。飛行ロボット下部に下向きにカメラを搭載しており、地面に設置した2つのカラーオブジェクトのピクセル情報を取得する。カメラは図2のように捉えたカラーオブジェクトを四角形の枠で囲い、その枠の左上角の座標と枠の幅と高さを取得する。本研究において提案する2つの手法はどちらもこのカメラで取得したピクセル情報を使用する。



図1: 飛行ロボットが相互作用飛行している様子

## 3 ニューラルネットワーク

本研究では順伝播型のニューラルネットワークを使用する。入力データとして2つのカラーオブジェクトのピクセル情報を用いる。図2のように1つ目のオブジェクトの左上角のx座標、y座標、幅、高さ、そして2つ目オブジェクトの左上角のx座標、y座標、幅、高さの8ユニットを入力とする。そして、飛行ロボットの3次元座標と向きの計4つのデータを出力とする。教師データはモーションキャプチャで取得した飛行ロボットの3次元座標と向きを使用する。

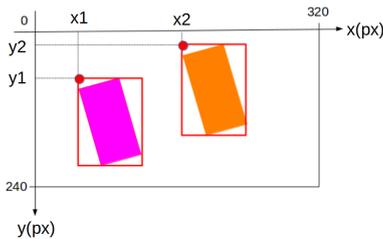


図2: カメラが取得するピクセル情報

ニューラルネットワークの構成は図3のように入力層1層8ユニット、中間層1層100ユニット、出力層1層4ユニットとする。飛行実験で取得したデータの一部をテストデータとし学習を行う。また、入力層と中間層の活性化関数は  $\tanh$  を用い、出力層のみ恒等写像を用いた。学習アルゴリズムは Adam を使用した。過学習を防ぐため、テストデータの平均自乗誤差が最小になるところで学習をとめる。学習を行う際、入力データを+1 から-1 の範囲に収まるように正規化する

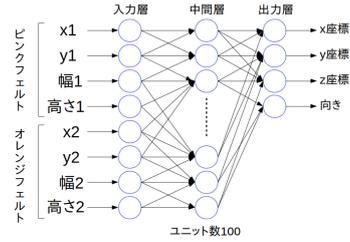


図3: 本研究におけるニューラルネットワークの構成

## 4 球面投影モデルによる2次元座標と向きの導出

先行研究 [3] において、天井に下向きに固定した360度カメラにより2次元座標の検出が可能であることが示されている。本研究ではカメラは固定されていないものの、ランドマークとなるカラーオブジェクトは固定されているため先行研究 [3] と同様に最小二乗法を用いて飛行ロボットの2次元座標の検出が行えると考えた。

### 4.1 飛行ロボットの向きの導出

図4のように2つのカラーオブジェクトの中心を結んだ直線に対し垂直な直線とx軸に垂直な直線における角度  $\theta$  を飛行ロボットとカラーオブジェクトとの相対的な向きと考える。

$$\theta = \arctan \frac{h}{w} \quad (1)$$

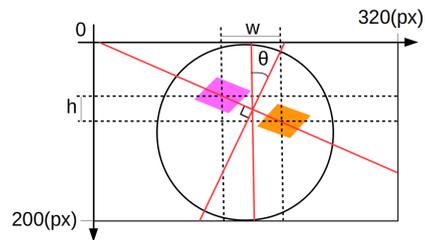


図4: 飛行ロボットとオブジェクトの相対向きの導出手法の概略図

### 4.2 2次元座標の導出

先行研究 [3] より、飛行ロボットとカラーオブジェクトを真上から見た時の飛行ロボットとカラーオブジェクトの距離を  $R_{\text{real}}(\text{mm})$ 、画像上の中心から2枚のカラーオブジェクトの中心までの距離を  $R_{\text{pic}}(\text{px})$ 、高度を  $l(\text{mm})$  とすると、

$$R_{\text{real}} = (a + b) \tan \left\{ \left( \frac{\pi}{2} \right) \left( \frac{R_{\text{pic}}}{160} \right) c \right\} \quad (2)$$

となる。  $a$ 、  $b$ 、  $c$  は固定値で  $a=1.48$ 、  $b=-323$ 、  $c=1.13$  である。

次に  $R_{\text{real}}$  を用いて実際の飛行ロボットの  $x$  座標,  $y$  座標を計算する. 本研究では, 飛行ロボットにカメラが搭載されているため飛行ロボットの向きによりカラーオブジェクトの写り方が変わる. そこで図5のように画像を飛行ロボットの向き  $\theta$  分回転させることですべての画像が飛行ロボットの向きが0度の時の画像に変換できる.

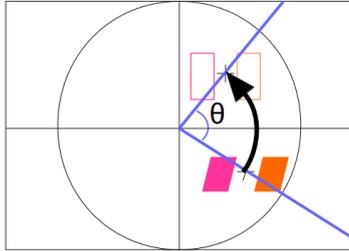


図5: 画像回転のイメージ

カメラの画像を回転させることで図6のような関係が成り立つ. したがって  $x$  座標  $X_{\text{real}}, y$  座標  $Y_{\text{real}}$  は以下の式となる.

$$X_{\text{real}} = R_{\text{real}} \cos \theta_1 \quad (3)$$

$$Y_{\text{real}} = R_{\text{real}} \sin \theta_1 \quad (4)$$

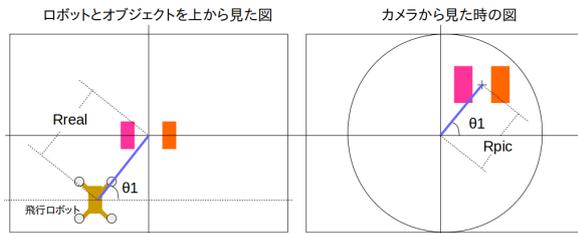


図6: 2次元座標導出のイメージ図

## 5 飛行実験

ニューラルネットワークによる学習に必要なデータの取得を行うために飛行実験を行った. また, 球面投影モデルとニューラルネットワークの精度を比較するための飛行データも取得した.

### 5.1 実験手法

モーションキャプチャにより原点とする位置を決める. そして図7のように地面にカラーフェルトを貼り付ける. モーションキャプチャのレートとカメラのレートを50に指定し飛行ロボットを飛行させる. 飛行する際, ピンクのオブジェクトを用い相互作用飛行 [1] させる. 飛行中の飛行ロボットの3次元座標をモーションキャプチャで取得し, 同時にカメラによりカラーフェルトの2次元座標を取得する.

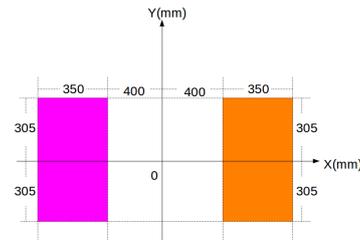


図7: カラーオブジェクトの位置関係図

## 5.2 実験結果

モーションキャプチャの範囲に制限があるため, モーションキャプチャのデータ取得の範囲外に出てしまうことがしばしば見られた. そして, 同様にカメラの画角にも制限があるため, カラーオブジェクトがカメラの範囲外に出てしまうことも起きた. このように取得できなかったデータを除き, 約100回の飛行データから訓練データ18000データ, テストデータ6000データを作成した.

## 6 球面投影モデルとニューラルネットワークの比較

約1分間の飛行データを使用し, 球面投影モデルとニューラルネットワークにより計算した飛行ロボットの3次元座標と向きを比較した. 比較には平方平均自乗誤差 (RMSE) を使用し, モーションキャプチャで取得した飛行ロボットの実際の3次元座標と向きとの誤差を数値化した. ニューラルネットワークと球面投影モデルで取得した飛行ロボットの  $x, y, z$  座標と向きとモーションキャプチャで取得した実際の飛行ロボットの  $x, y, z$  座標と向きを比較した図を図8, 9, 10, 11に示す. 本実験では, 球面投影モデルに使用する高度のデータはモーションキャプチャにより取得したデータを使用している. そのため,  $z$  座標はモーションキャプチャとニューラルネットワークの2つの結果を示す.

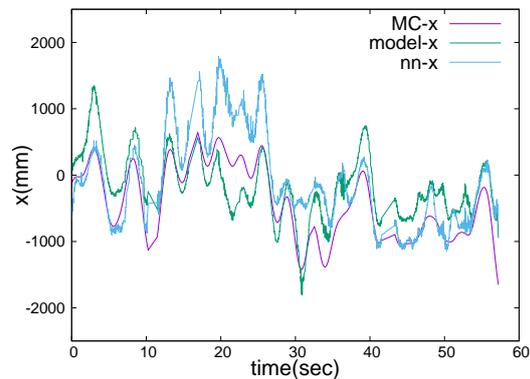


図8:  $x$  座標の比較 (紫:モーションキャプチャ, 緑:球面投影モデル, 青:ニューラルネットワーク)

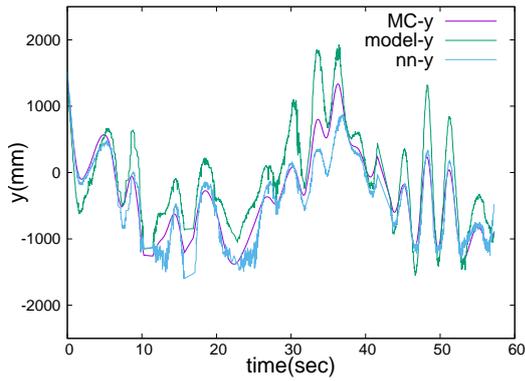


図 9: y 座標の比較 (紫:モーションキャプチャ, 緑:球面投影モデル, 青:ニューラルネットワーク)

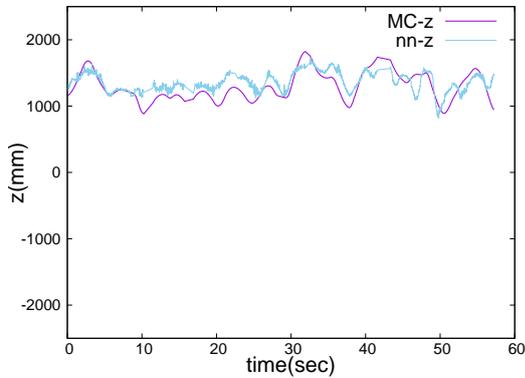


図 10: z 座標の比較 (紫:モーションキャプチャ, 青:ニューラルネットワーク)

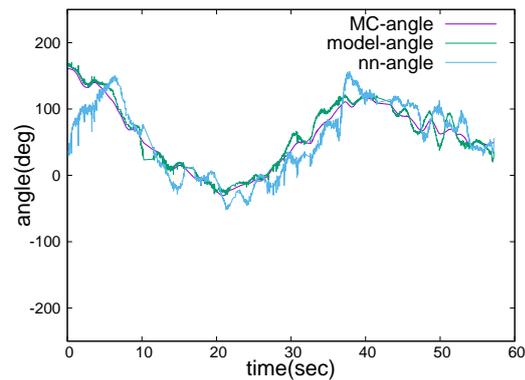


図 11: 向きの比較 (紫:モーションキャプチャ, 緑:球面投影モデル, 青:ニューラルネットワーク)

球面投影モデル, ニューラルネットワークのどちらの手法でも実際の飛行データに近い値を出力する結果となった.  $x$ ,  $y$  座標においてはニューラルネットワークが精度が高く, 向きにおいては球面投影モデルが精度が高くなった. 図 8, 9, 10, 11 を見ると, 飛行ロボットが傾いた際の座標はどちらも大きく誤差が出ている結果となった. このテストデータでの RMSE を表 1 に示す.

	球面投影モデル	ニューラルネット
$x$ (mm)	434	356
$y$ (mm)	421	245
$z$ (mm)	-	129
向き (deg)	9.0	31.0

表 1: モーションキャプチャとの RMSE

## 7 まとめ

飛行ロボットに搭載したカメラで 2 色のカラーオブジェクトを撮影し, その映像から飛行ロボットとカラーオブジェクトの相対位置認識を行うことができた.  $x$ ,  $y$  座標においてはニューラルネットワークの方が精度が高く, 向きにおいては球面投影モデルの方が精度が高くなった.

球面投影モデル, ニューラルネットワークのどちらの手法でも飛行ロボットが傾いている状態の座標に大きく誤差が出ている. 原因として球面投影モデルでは飛行ロボットの傾きの影響を考慮して計算をしていないことが挙げられる. ニューラルネットワークでも飛行ロボットが傾いている状態のときは誤差が生じているが, 学習に使用したデータには傾いている状態の座標も含まれているため球面投影モデルに比べて座標の誤差が小さくなった. 飛行ロボットの傾きを考慮することで位置認識の精度を高めることが可能であると考えられる.

本研究によって, 完全自律飛行ロボットが外部の複数オブジェクトの情報から, 自己位置及び向きを認識可能であることがわかった. すなわち, 3次元自己駆動粒子として, 環境と相互作用する完全自律飛行の可能性が示された. 今後, 複数自己駆動粒子の相互作用運動のために, リアルタイム性の検証と学習データの少ない条件に対する汎化能力の獲得が興味深い問題として残されている.

## 参考文献

- [1] 本田泰, 第 22 回交通流と自己駆動粒子系シンポジウム論文集, p17-p20, 2016
- [2] ドローン同士の直接通信でニアミスを自動的に回避する実験に成功, <https://www.nict.go.jp/press/2019/01/24-1.html> (参照日:2019/10/18)
- [3] 若月ある, 川野多佳也, 宮島高志, 本田泰, 第 24 回交通流のシュミレーションシンポジウム論文集, p33-36, 2018