

ニューラルネットワークを用いたタンブリング衛星の姿勢推定

Motion Estimation of Tumbling Satellites by Neural Network

○西山佳克¹, 大津隼人¹, 塚本大生¹, 笠井悠吾², 佐々修一³, 安部明雄³

○Yoshikatsu Nishiyama¹, Hayato Otsu¹, Daiki Tsukamoto¹, Yugo Kasai², Shuichi Sasa³, Akio Abe³

In recent years, with space development, there are many artificial satellites that are uncontrollable due to breakdown or disposal on the orbit around the earth. These space debris have to be captured because they may cause catastrophic damage due to contact with other operational spacecraft. The debris may have a complex three-axis rotational motion called a “tumbling”, it is difficult to accurately measure the attitude angle and angular velocity of the debris. So far, several methods for estimating the tumbling motion using image information have been studied, the problems of discontinuity in image sequence exist. The characteristic points of the debris are repeatedly disappear/appear due to the tumbling motion or the influence of contrast owing to sunlight irradiation exist. In this study the neural network is applied to the estimation of a tumbling satellite, and the numerical simulation is carried out to evaluate the estimation accuracy of the proposed method.

1. 緒論

近年、宇宙開発の発展と共に、故障や廃棄によって制御不能となった人工衛星が地球軌道上に多く発生し、宇宙ゴミ(スペースデブリ)となり問題となっている。このスペースデブリは超高速で飛翔するため、わずか数 cm の大きさでも他の稼働中の宇宙機と接触することで壊滅的な被害を与える可能性がある。これを未然に防ぐためデブリを回収、除去する必要がある。その方法の1つとして、対象のデブリに回収用の衛星(Chaser 衛星)を接近させ、運動を同期、捕捉させ回収、もしくは大気圏へ落下させる方法が提案されている。しかし、デブリはタンブリング運動という複雑な3軸回転運動をしている可能性があり、デブリの相対姿勢角や相対角速度を正確に把握するのは困難である。画像情報を用いたタンブリング運動の推定方法はこれまでにいくつか検証されてきたが、デブリの特徴点がタンブリング運動により消失・出現を繰り返す非連続性や、太陽光照射によるコントラストの影響など、画像認識に関する問題が様々挙げられる^[1]。本研究では、タンブリング衛星の姿勢推定に関してニューラルネットワーク(以下NNと表記する)を適用し、数値シミュレーションにより、その有効性を検証した。

2. NN (ニューラルネットワーク)

2.1 NNの数理モデル化

NNとは、以下のFigure1に示すように人間の脳神経系を数理モデル化したものである。




Figure1. Neural Network Model^[2]

2.2 階層型ネットワーク^[2]

本研究では、以下のFigure2に示すような衛星上のマーカー座標を入力し、衛星姿勢に対応するクォータニオンを出力する階層型ネットワークを用いる。このNNは入力層、隠れ層、出力層の3つの層で構成されており、丸い部分はFigure1で説明したニューロンである。




Figure2. Layered Network^[2]

使用するアルゴリズムは、NNの学習方法として最も一般的な誤差逆伝播法を用いている。また、局所解に陥りやすくするため、確率的勾配降下法(SGD)を使用している。NNの詳細データを以下のTable1に示す。

Table1. Hyper Parameter and Structure of NN

Number of Data		20000
Hidden Layers	Number of Layers	1
	Number of Units	200
Output Layers	Activation Function	Ramp Function
	Teacher Data	$4(q_0, q_1, q_2, q_3)$
Activation Function		tanh
Mean Square Error of the Target		5.0×10^{-4}
Weight Change Method		Adam Method ^[3]

1 : 日大理工・学部・航宇 2 : 日大理工・院(前)・航宇 3 : 日大理工・教員・航宇

3. 衛星モデル

モデルは不透明な立方体を利用する。また、立方体の各頂点にマークが付いていると仮定して番号を振り、衛星姿勢(クォータニオン)とマーク座標が1対1に対応しているとする。




Figure3. Satellite Model

Figure3 の r は Chaser 衛星とデブリ衛星の距離, 点 O は Chaser 衛星のカメラを表している。今回は簡単のためマークの3次元座標を直接計測できるとしている。

4. 姿勢推定 NN の構築

3節のモデルをクォータニオンで回転させ, NN を用いてその姿勢を推定する。モデルが不透明であることによって生じるカメラから見えない特徴点(以下隠れ点と表記する)は, 特徴点の座標を用いて特定し, 消去する。

まず, クォータニオンを次式のように定義する。

$$q = [q_0 \ q_1 \ q_2 \ q_3]^T \quad (1)$$

次に立体のマーク座標 $(x_{o1}, y_{o1}, z_{o1}), (x_{o2}, y_{o2}, z_{o2}), \dots, (x_{o8}, y_{o8}, z_{o8})$ を決め, これを初期位置とする。この頂点座標をランダムで生成したクォータニオンを使って次式により回転させ, その座標を求める。

$$(x, y, z)^T = C_q (x_0, y_0, z_0)^T \quad (2)$$

C_q は座標変換行列である。座標変換した立体の頂点座標を入力データ, その際のクォータニオンを教師データとして学習を行う。

精度検証では, まず学習時と同様に, ランダムで作成したクォータニオンを使ってモデルを回転させ, 特徴点座標を求める。次に求められた座標データを学習済みの NN へ入力し, 得られた出力と真値との絶対誤差を比較することで, 学習精度を検証する。絶対誤差 ε_A は次のように定義している。

$$\varepsilon_A = |q_i - \hat{q}_i| \quad (3)$$

式中の q_i は真値のクォータニオン, \hat{q}_i は NN で推定されたクォータニオンを表している。

NN では入力データ数を固定しなければならないが, 本研究では見えるマーク数が衛星の回転によって変化してしまう。そのため, 見えるマークの個数で場合分けを行ない, 見えているマークが4個, 6個, 7個の場合の3組の NN (NN4, NN6, NN7) を用意している。

学習・検証の流れを以下の Figure4 に示す。




Figure4. Learning Flow

5. 検証結果

クォータニオンの各成分の平均誤差に対応する推定画像を真の画像と重ねたものを Figure5, クォータニオン各成分の絶対誤差の分布図を Figure6 に示す。

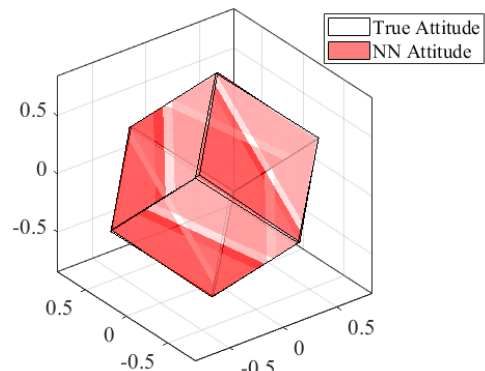


Figure5. True Attitude and Estimated Attitude by NN

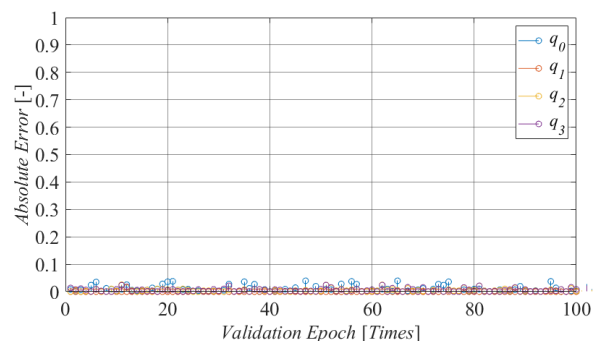


Figure6. Distribution Chart of Quaternion Absolute Error

これよりランダムに作成したクォータニオンデータを用いて NN の精度検証を行なった結果, 高い精度での推定が可能であることが確認できた。

今後はタンブリング運動をシミュレーションし, その場合のマーク座標での検証や, カメラを使用した実験検証を行なう予定である。

6. 参考文献

[1]小岩希: 画像情報を用いたタンブリング衛星の運動推定, 第59回宇宙科学技術連合講演集, 2015, p1.
 [2]坂和正敏・田中雅博: ニューロコンピューティング入門, 森北出版社, 1996, pp.2-5.
 [3]Xavier Glorot, Antonie Bordes, Yoshu Bengio: Deep Sparse Rectifier Neural Networks, Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics