

赤外分光計データを用いた火星におけるダストの光学的厚さの推測 Estimation of dust optical depth observed by MGS/TES from visible images observed by MGS/MOC using a convolutional neural network

宮部 花鈴[†] 小郷原一智[‡]
Karin Miyabe Kazunori Ogohara

1. はじめに

火星ではしばしばダストストーム(砂塵嵐)が発生し,探査機などに悪影響を及ぼしている.たとえば,火星探査機は太陽光発電によりバッテリーを充電しており[1],ダストストームが発生すると活動を停止してしまう.このようなダストヘイズによる悪影響を防ぐには,過去の火星データを分析し,ダストヘイズの発生要因や傾向を把握する必要がある.そのためには,数 10[km]~数 100[km]のスケールで火星地表面のダスト分布を入手しなければならない.過去の観測により火星地表面の可視画像データは利用可能であるが,ダストの光学的厚さ (Dust Optical Depth, DOD) を可視画像から導出することはできない.一方,赤外分光計で観測した赤外域における DOD は利用可能であるが,可視画像と比べて大変狭い範囲に限定される.いずれにしても,ダストの動きを把握するには不十分である.そのため本研究では Convolutional Neural Network(CNN)を用い,赤外分光計によって観測された DOD を教師データとし,周辺領域の可視画像の模様から各画素の DOD を推定する.

2. 関連研究

火星におけるダストストームを検出するため,画像セグメンテーションを用いた研究が行われている[2].しかしながらダストヘイズの動きを詳細に把握するには,ダストストーム領域の検出だけでなく DOD の数値を取得する必要があるだろう.また,[2]は教師データを著者自ら作成しており,

物理的には根拠がない.

一方地球では,ハイパースペクトル画像から光合成色素(フィコシアニン,クロロフィル)の濃度推定がされている[3].推定には CNN が用いられており,本研究でも CNN による回帰を利用することは有効であると期待できる.

3. 使用データ

本研究で使用するデータは,周回機 Mars Global Surveyor (MGS)に搭載された Mars Orbiter Camera(MOC) で撮影された可視画像データと,Thermal Emission Spectrometer(TES)で取得したダストの光学的厚さ(DOD)データで,これらは火星を南極から北極に向かってスキャンする形で取得される.TES は MOC の視野の中心付近のごく狭い領域しか観測できない.表 1 に DOD データの各範囲におけるデータ数の一覧を示す.おおよそ DOD 0.0~1.0 の範囲でデータが存在するが,0.0~0.4 のデータが約 95%を占めており,全体として非常に不均一なデータセットとなっている.

4. 研究の目的

DOD の値に大きな偏りがあったことから,DOD の大きいデータを正確に推測するのは非常に困難であった.そこで,先行研究[2]を参考に DOD が大きい小さいかを 2 分類推測したあとに,DOD の小さいデータのみに対してより精度の高い DOD 推測を行うという流れで検証する.そのため,膨大に存在する DOD の小さいデータでモデルを訓練することで,DOD の小さいデータに対して精度の高い推測を可能とする CNN モデルを構築することが本研究の目的である.

表 1 DOD と各データ数分布

DOD	データ数
~0.0	406
0.0~0.1	117842
0.1~0.2	54359
0.2~0.3	17745
0.3~0.4	6460
0.4~0.5	7869
0.5~0.6	947
0.6~0.7	662
0.7~0.8	241
0.8~0.9	101
0.9~1.0	31
合計	206663

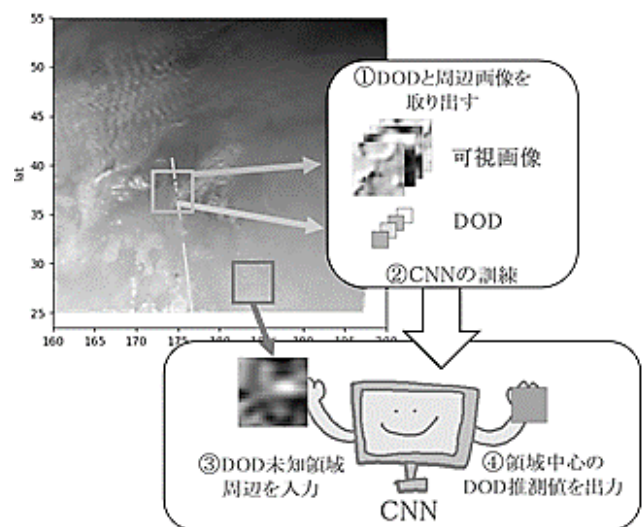


図 1 CNN を用いた訓練と推測

[†] 滋賀県立大学 The University of Shiga Prefecture
[‡] 京都産業大学 Kyoto Sangyo University

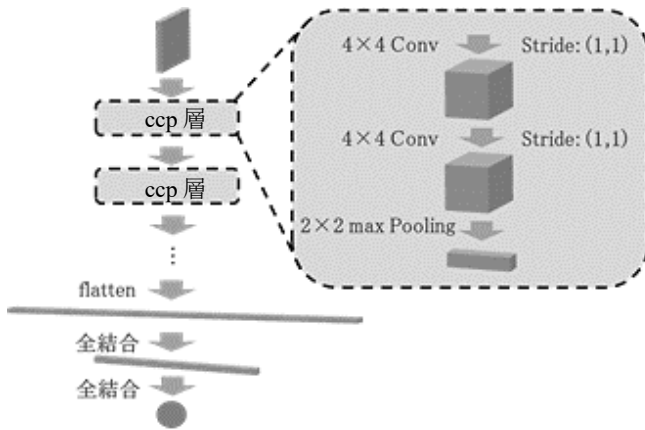


図2 CNNモデルの構造概要

5. 研究方法

本研究は、可視画像の周辺領域の模様から DOD を予測するため、CNN モデルを用いる。TES が観測できない領域の DOD を予測するため、CNN の訓練方法を検討した。図 1 に CNN モデルの訓練と推測の手順を示す。まず、①TES データと、各 TES データ周辺 80×80 [pixel] サイズ (以降パッチサイズとする) の MOC データの組を用意し、②MOC データを入力、TES データを教師データとし CNN モデルを訓練する。DOD の推測の際には、③DOD 未知領域の周辺可視画像パッチを訓練済の CNN に入力し、④領域中心の DOD を推測するという流れとなっている。ここで、今回用いた CNN モデルの概要を図 2 に示す。convolution・convolution・max pooling (以降 ccp 層とする) を 1set として数回繰り返す、全結合を 2 回行う構造となっている。誤差関数は Mean Squared Error (MSE) を用いる。

6. 結果

6.1 簡単なモデルを用いた DOD の推測

DOD の小さいデータに対して予測精度を高めるため、DOD 0.0 ~ 0.4 のデータのみを用いて CNN モデルを訓練する。図 2 に示すモデルにおいて、ccp 層を 1set とした CNN モデルを訓練した結果、validation loss (MSE) は 3.51×10^{-3} となった。このとき Root Mean Squared Error (RMSE) は 5.92×10^{-2} であり、相対誤差は約 14.8% である。

6.2 モデルの複雑化と学習率の調整

図 2 に示すモデルにおいて、ccp 層を 4set 繰り返した CNN モデルを訓練した結果、validation loss は 3.10×10^{-3} となり、簡単なモデルより精度は上昇した。

学習率はもともと 5×10^{-6} としていたが、モデルの複雑化に伴い訓練に時間を要するようになったこともあり、学習率を変化させ、学習過程・結果を比較した。 1×10^{-6} 、 5×10^{-6} 、 1×10^{-5} 、 5×10^{-5} 、 1×10^{-4} 、 5×10^{-4} の 6 通りの学習率で 200epoch 訓練したところ、最も validation loss が小さかったのは学習率 5×10^{-5} のときであり、 1×10^{-4} 以上では訓練が進まなかった。これにより、validation loss (MSE) は 7.34×10^{-4} となり、学習率を調整する前よりも精度の高いモデルを得ることができた。

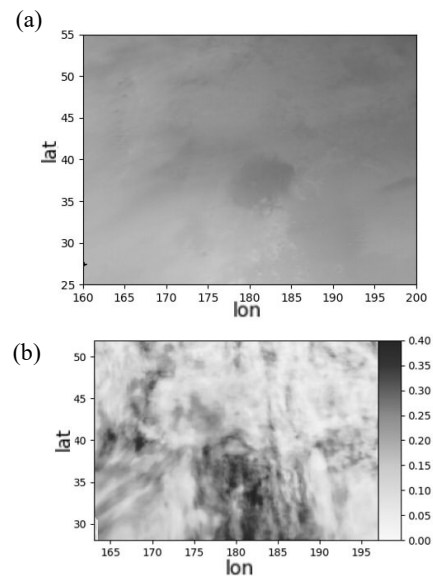


図3 DODの推測画像。(a)元画像。(b)CNNモデルで推測したDODマップ

6.3 パッチサイズとモデル構造の調整

パッチサイズを $80 (= 2^4 \times 5)$ から $64 (= 2^6)$ 、 $128 (= 2^7)$ に変更し、かつ ccp 層を増やす (モデルを複雑化させる) ことによりモデルの精度がどのように変化するか検証した。

基本的にパッチサイズは大きい、つまり周辺の情報が多いほど精度が良くなった。これを踏まえ、学習過程の様子を見ながら最適なモデルを検証した所、パッチサイズを 128×128 [pixel]、ccp 層を 6 set とした組み合わせの validation loss が最も小さかった。このとき validation loss (MSE) は 5.43×10^{-4} であり、RMSE は 2.33×10^{-2} と相対誤差は約 5.8% であった。DOD の推測結果の一例として、図 3(a) に元画像を、図 3(b) に CNN モデルで推測し作成した DOD マップを示す。

7. 結論

CNN モデルを用いて、火星の可視画像から DOD を回帰で推測することを試みた。モデルの構造やパラメータを調整した結果、validation loss (MSE) は 5.43×10^{-4} であり、RMSE は 2.33×10^{-2} と相対誤差は約 5.8% であった。

謝辞

本研究を進めるにあたり、日頃より丁寧かつ適切なお指導を賜りました小郷原一智准教授、砂山渡教授及び畑中裕司准教授に心より御礼申し上げます。また、多大な助言を賜りました滋賀県立大学工学部電子システム工学科知能情報工学分野の皆様へ感謝いたします。

参考文献

- [1] NASA Jet Propulsion Laboratory "Mars 2018 Global Dust Storm". <https://svs.gsfc.nasa.gov/30983>, Aug 20, 2018
- [2] Gichu, R., Ogohara, K. Segmentation of dust storm areas on Mars images using principal component analysis and neural network. Prog Earth Planet Sci 6, 19 (2019). <https://doi.org/10.1186/s40645-019-0266-1>
- [3] JongCheol Pyoa et al. (2019) "A convolutional neural network regression for quantifying cyanobacteria using hyperspectral imagery." Remote Sensing of Environment, vo. 233, 111350