

# 深層学習を用いた火星や月のクレーター探知とセグメンテーション

マンドロイ ヨグラジ シン (東海大学大学院工学研究科),

稲田 喜信 (東海大学)

## Deep Learning Approach for Martian and Lunar Surface Crater Detection and Segmentation

Yograj Singh Mandloi (Graduate school of Engineering, Tokai University),

Yoshinobu Inada (Tokai University)

### Abstract

The presented study applies a deep learning technique for identification and segmentation for the crater region on Martian and Lunar surface images. We modified an existing deep convolutional neural network architecture and with transfer learning, trained the modified network on a limited image dataset. The model was able to detect and segment the craters on the Martian and the Lunar surface, which can be utilized for better understanding of planet topography, selection of landing sites for various lander missions and path planning for planetary rovers.

**Key Worlds** : Mars, Lunar, Deep Learning, Crater detection, segmentation

### 概要

本研究では、火星と月の表面画像におけるクレーター領域の探知やセグメンテーションに深層学習手法を適用した。既存の深層畳み込みニューラルネットワークアーキテクチャを変更し、転移学習を使用して、限られた画像データのセットで、変更されたネットワークを学習させた。その結果、クレーターの探知やセグメン

レーションが可能となったことから、着陸船の着陸地点の選択や探査機の経路計画に役立てることができると思われる。

## 1. はじめに

惑星や衛星の表面の調査は、宇宙科学の研究にとって非常に重要であり、特に衝突クレーターの調査は、様々な着陸ミッションの着陸地点の選択、ローバーミッションの経路計画のために重要である。コンピュータビジョンを用いた過去の研究では、クレーターの識別用に開発された明示的なアルゴリズムがあり、火星表面のデジタル地形データを利用した例や<sup>[1]</sup>、クレーターの形状に基づいた補間クレーター検出アルゴリズムを導入した例がある<sup>[2]</sup>。また、月のクレーターの検出には、地形分析や数学的形態に基づいたアルゴリズムが提案されている<sup>[3]</sup>。

近年、機械学習、特にディープラーニングの進歩によって、学習を用いた認識システムが実現可能になった。M. Ricardoらは、機械学習アプローチを使用して、画像をクレーターと非クレーターに分類するために、バイナリ分類器を使用した<sup>[4]</sup>。また、S. Ariらは、UNetベースのアーキテクチャを使用して、火星のデジタル地形モデル（DTM）のクレーターのリング形状を識別する深層学習ベースの方法を提案した<sup>[5]</sup>。本研究では、火星と月の表面の実際の画像データを用いて、転送学習の技術を使用して認識を試みた結果を紹介する。

## 2. 方法

畳み込みニューラルネットワーク（CNN）は、画像特徴認識のための優れた学習機能を持つことから、クレーターの形状の特定の特性を見つけるための明示的なアルゴリズムを定義する代わりに、CNNを使用して、3次元画像を1次元ベクトルにマッピングする学習ベースのアルゴリズムを提案した。深層CNNモデルには非常に多数の結合の重みパラメーターがあるため学習が遅くなり、精度を高めるには非常に長い時間学習する必要がある。また、データセットが小さい場合、

長時間かけても十分に学習できない。そこで、限られた学習データセットを使用して精度を高めるために、転送学習の技術を使用した。

本研究では、100個の出力ニューロンを含む MASKS RCNN<sup>[6]</sup>の最終レイヤーを変更して100個のオブジェクトを検出し、さらにその周囲にマスクを作成した。その例として、図1に示すように、画像から背景とクレーターの2つの出力を行うための最終レイヤーを作成し、これに転移学習手法を適用した。

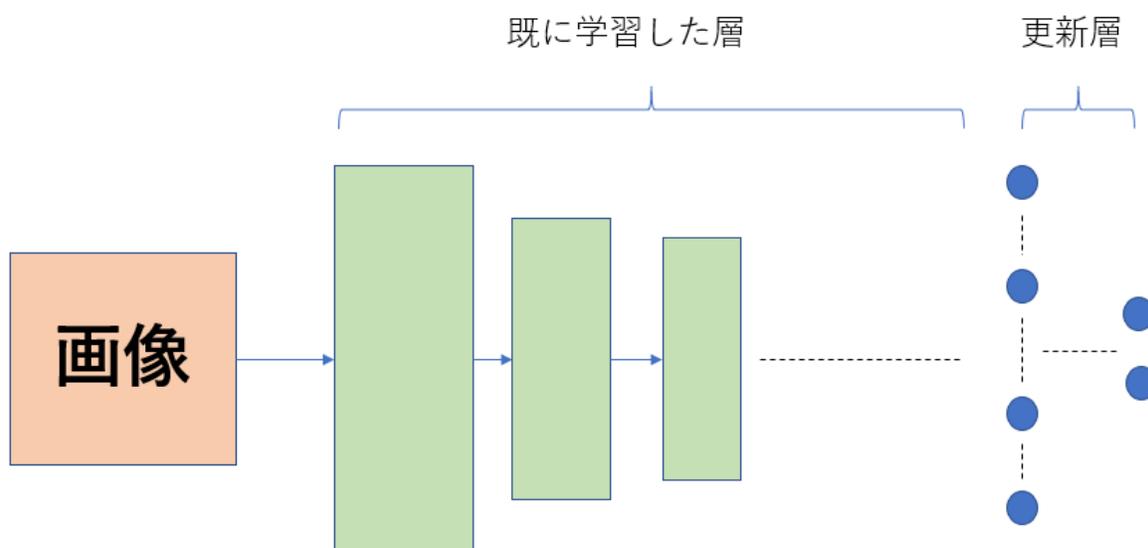


図1 転移学習

モデルがすでに大量のデータセットで学習されている時、学習した知識を使用して学習することで、学習を高速化することが可能である。図1の例では、既に学習した層のネットワークの結合の重みは更新せず、最終層の重みのみを更新する。学習の最適化は、最後の層のみで実行されるため高速な学習が可能になる。このようにして、様々な形状のクレーターの共通の特性を保持しながら、より具体的な形状の特性を学習することが可能になる。

### 3. 結果

本研究では、COCO データセット<sup>[7]</sup>の事前学習モデルを用いて学習を開始した。こうすることで、画像データの基本的な特徴を維持しつつ、検出とセグメンテーションのためのクレーター特有の特徴を追加することができた。学習に必要なデータセットとして、火星探査衛星から得られた火星の表面画像を使用した結果、学習済みモデルは、図2に示すようにクレーターの周囲に信頼スコアが 0~1 の境界ボックスを生成し、クレーターとして分類された領域を抽出した。

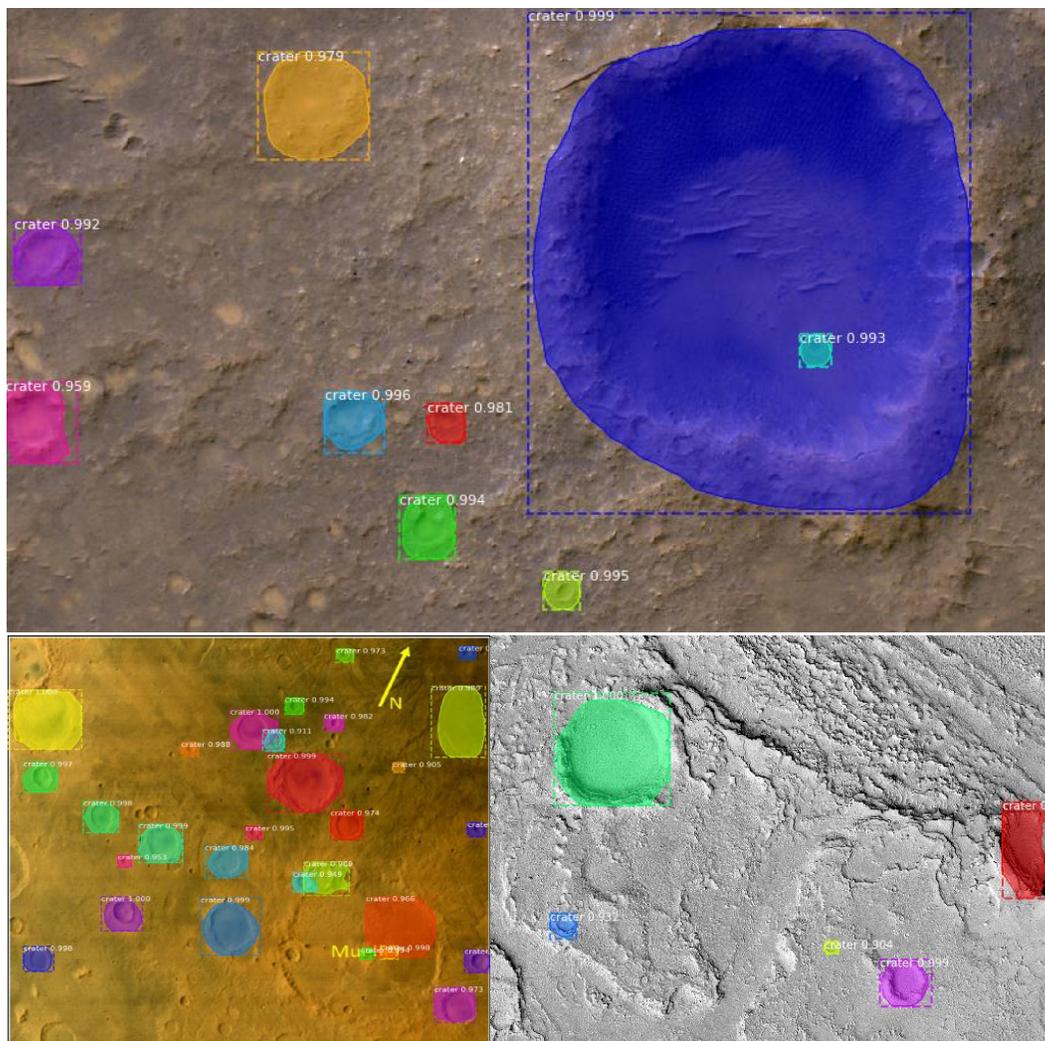


図2 火星表面でのクレーターの検出とセグメンテーション

続いて、学習済みモデルを用いて月面探査衛星が撮影した月面の画像を認識させた結果、色やカメラの角度が異なるデータであっても、学習済みモデルは図3に示すように、クレーターの一部を検出することができた。学習の段階でこのようなデータを学習データセットに含めることができれば、精度がさらに向上すると思われる。

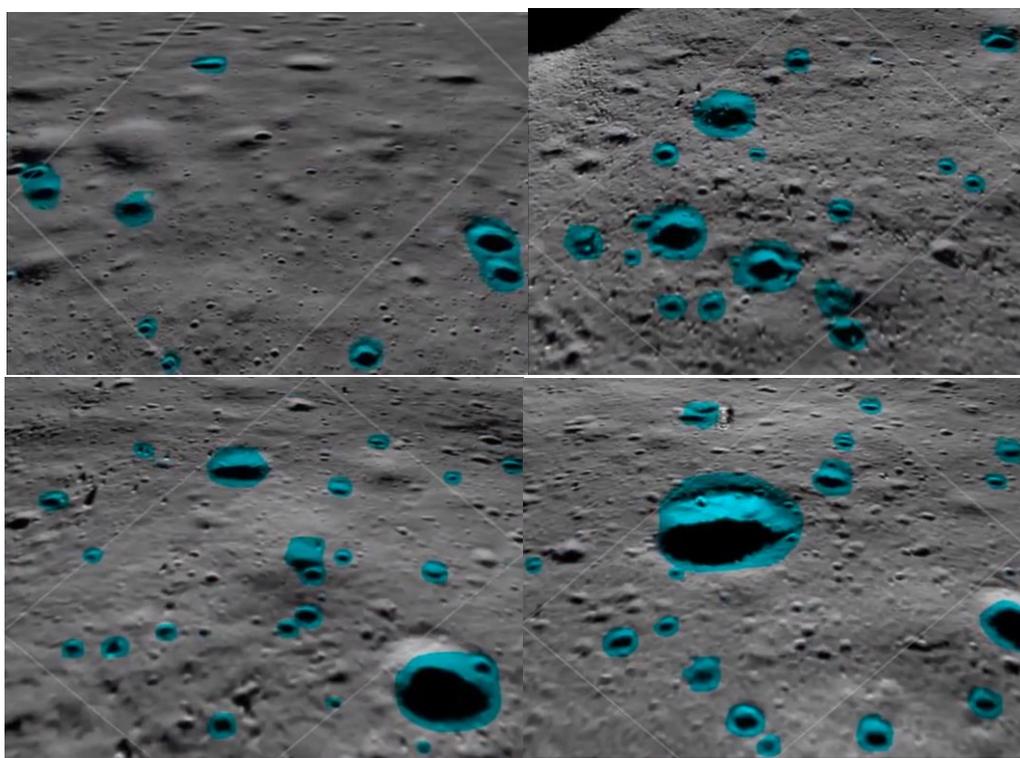


図3 月面でのクレーターの検出とセグメンテーション

深層学習ベースのクレーター検出は高速な学習が可能であるが、システムの計算能力が貧弱だと学習に時間がかかる。提案された方法は、オフラインでの検出に深層学習を使用できることを示しているが、計算リソースが制限されている状況で実時間で検出を行うには、より軽量な方法を実現する必要があると思われる。

## 参考文献

- [1] S. Goran, L. Sven, “Method for Crater Detection From Martian Digital Topography Data Using Gradient Value/Orientation, Morphometry, Vote Analysis, Slip Tuning, and Calibration,” IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING, VOL. 48, NO. 5, MAY 2010
- [2] S. Goran, L. Sven, M. Erwan, “LU60645GT and MA132843GT catalogues of Lunar and Martian impact craters developed using a Crater Shape-based interpolation crater detection algorithm for topography data,” doi:10.1016/j.pss.2011.09.003
- [3] C. Min, L. Danyang, Q. Kejian, L. Jun, and Z. Yi, “Lunar Crater Detection Based on Terrain Analysis and Mathematical Morphology Methods Using Digital Elevation Models,” IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING, VOL. 56, NO. 7, JULY 2018
- [4] M. Ricardo, P. Pedro, M. S. Jorge, and S Margarida, “Crater Detection by a Boosting Approach,” IEEE GEOSCIENCE AND REMOTE SENSING LETTERS, VOL. 6, NO. 1, JANUARY 2009
- [5] S. Ari, A. Mohamad, Z. Chenchong, J. Alan, V. Diana, K. Yevgeni, T. Daniel, M. Kristen, “Lunar Crater Identification via Deep Learning,” arXiv:1803.02192v3 [astro-ph.EP] 12 Nov 2018
- [6] K. He, G. Gkioxari, P. Dollar, R. Girshick, “Mask R-CNN,” arXiv:1604.07316v1, 24 Jan 2018
- [7] L. Tsung, M. Michael, B. Serge, B. Lubomir, G. Ross, H. James, P. Pietro, R. Deva, Z. C. Lawrence, and D. Piotr, “Microsoft COCO: Common Objects in Context,” arXiv:1405.0312v3 [cs.CV] 21 Feb 2015