

# かぐや DEM を用いた、機械学習による中央丘クレーター識別

原 聡志<sup>\*1</sup>, 山本 幸生<sup>\*2</sup>, 荒木 徹也<sup>\*1</sup>, 廣田 雅春<sup>\*3</sup>, 石川 博<sup>\*1</sup>

## Identification of moon central peak craters by machine learning using Kaguya DEM

Satoshi Hara<sup>\*1</sup>, Yukio Yamamoto<sup>\*2</sup>, Tetsuya Araki<sup>\*1</sup>, Masaharu Hirota<sup>\*3</sup>  
Hiroshi Ishikawa<sup>\*1</sup>

### Abstract

There are many craters in the moon. Among them are craters having a special structure called “central peak” (hereinafter referred to as “the central-peak crater”). This central peak has an important characteristic that substances inside the moon crust are exposed on the moon surface. Therefore, by measuring the surface of the central peak, it is possible to estimate the material of the surrounding inner crust. By analyzing the inner crust, it is expected that estimation of the cause of craters and central peaks, the process of the environment of the moon surface, and crustal deformation of the past. However, except for some famous craters, the investigation has not progressed much. The reason for this is that the discovery of the central peak is based on visual observation of images by experts, so there are few known the central-peak craters. In order to solve this problem, it is necessary to automate the discovery method of the central-peak crater and prepare a catalog that records the position and size of central peaks, thereby greatly increasing the prospecting point candidate of the central-peak crater. Therefore, in this research, the final goal is to create a catalog of the central-peak crater, and for that purpose we propose an automatic discovery method of the central-peak crater. In this research, we use Digital Elevation Model (DEM) of the lunar surface observed by JAXA’s lunar orbit satellite “KAGUYA” to identify the central-peak crater by machine learning and verify its accuracy. Specifically, we first extract craters using a high-speed crater automatic extraction method called “Rotating Pixel Swapping Method for DEM”, label them, and then try to identify the central-peak crater by CNN. As a result, it was impossible to obtain a highly accurate discrimination model that could create the catalog of the central-peak craters, but we could confirm the possibility that CNN is an effective method in the central-peak crater identification.

**Key Words :** Moon Central Peak, Machine Learning, Neural Network

---

doi: 10.20637/JAXA-RR-18-008/0001

\* 平成 30 年 12 月 19 日受付 (Received December 19, 2018)

\*<sup>1</sup> 首都大学東京大学院 システムデザイン研究科 (Tokyo Metropolitan University)

\*<sup>2</sup> 宇宙航空研究開発機構宇宙科学研究所 (Institute of Space and Astronautical Science, Japan Aerospace Exploration Agency)

\*<sup>3</sup> 岡山理科大学 総合情報学部 (Okayama University of Science)

## 概要

月には大小多数のクレーターが存在している。その中には、「中央丘」という特殊な構造物を有するクレーター（以下「中央丘クレーター」と呼称）が存在している。この中央丘には、月面表面に表出しているながらも、月地殻内部の物質が露出しているという重要な特徴がある。すなわち、中央丘表面の探査によって、周囲の内部地殻の物質を推定することが可能となるのである。この内部地殻の分析により、クレーター及び中央丘の成因の推定や、過去の月面の表層環境や地殻変動の過程が推定できることが期待される。しかし現在、中央丘クレーターの探査が盛んに行われてはいない。その要因として、中央丘の存在確認が専門家の画像目視によるものであるが故、中央丘クレーターとして知られているクレーターが数少ないことが挙げられる。これを解決するため、中央丘クレーターの発見手法を自動化することで、中央丘クレーターの場所、大きさ等を網羅した一覧（本研究では中央丘クレーターカタログと呼称）を作成し、今後の月面探査において調査対象の候補となりうる中央丘を大幅に増加させることが求められる。よって本研究では、中央丘クレーターカタログの作成を最終目標とし、その為の中央丘クレーターの自動発見手法を提案する。本研究においては、JAXA の月周回衛星「かぐや (SELENE)」の観測にもたらされた月面の数値標高モデル (DEM) を用い、機械学習による中央丘クレーターの識別を行い、それが中央丘クレーターカタログを作成できるほどの精度を有しているか検証する。具体的には、まず回転ピクセルスワッピング法という DEM データからの高速クレーター抽出手法を用いて各クレーターの DEM データを抽出、それらにラベル付けを行った後、CNN による中央丘クレーターの識別を試す。結果として、中央丘クレーターカタログを作成できるほどの高精度な識別モデルを得ることはできなかったが、中央丘クレーター識別において CNN が有効な手法であることは確認できた。

## 1 はじめに

月面のクレーターの中には、内部に中央丘と呼ばれる構造物を有するものがある。この中央丘とは、クレーターの内部に形成される丘状の凸構造物で、月地層の内部物質が表層に露出している月面における貴重な観測点である。中央丘は主に生成時の衝突の規模が大きいもの、つまりは大型のクレーターに存在する傾向にあり、中央丘を有するクレーターは中央丘クレーターと呼称されている [1][2]。そして Matsunaga らの研究 [3] のように、この中央丘クレーターの分析によって、月の科学的解析における有力な情報を得ることが期待できる。しかし現在、中央丘の分析を推進する上で、中央丘クレーターのカタログが存在しないという課題がある。従来、分析対象とされてきた中央丘クレーターは、月面画像等を専門家が目視することで発見してきた。しかし、無数に存在する月面クレーターを一つ一つ専門家が確認し、それによって中央丘クレーターを網羅的に探索する事は長大な時間を要し、非効率的である。そこで本研究では、中央丘クレーターを自動で抽出する為の手法の考案を試みる。

専門家が月面クレーターから中央丘クレーターを識別する上で識別対象とするものはクレーターの画像であり、その画像情報は中央丘クレーターの形状を表している。この画像から中央丘クレーターに特有の構造を確認することで、専門家は目視での中央丘クレーター識別を行うことができる。その為、中央丘クレーターの構造的特徴を何らかの方法で解析することにより、中央丘クレーターの識別が自動化できると考えられる。そこで本研究では、JAXA の月周回衛星「かぐや (SELENE)」によって収集された月面の数値標高モデル (Digital Elevation Model, DEM)[4] を用いる。DEM は地形、本研究ではクレーターの形状を表現できる為、その解析によって中央丘クレーターの構造的特徴の解析が可能となる。本研究で用いる DEM データは全て、DARTS at ISAS/JAXA にて公開されている\*4ものを使用する。

中央丘クレーターの構造的特徴の自動的な解析を実現するために、本研究では、月面物性や地質学への専門性を必要としない、機械学習による分類問題への帰着を提案する。機械学習による分類の為、我々はまず既存手法によるクレーターのみ抽出を行なう。そして学習のためのラベルをそれらに付与し、機械学習による中央丘クレーターの識別を行い、その有効性を検討する。

本論の構成は次の通りとなる。2章では、本研究及びその中で用いられる手法に関連する研究について言及

\*4 DARTS at ISAS/JAXA  
<http://darts.jaxa.jp>




図 1: DEM データ

する。3章では、本研究における具体的な手法を提案する。4章では、3章での提案手法に基づいた実験を行い、その結果の分析、考察を行う。5章では、本論のまとめ及び今後の課題について述べる。

## 2 提案手法



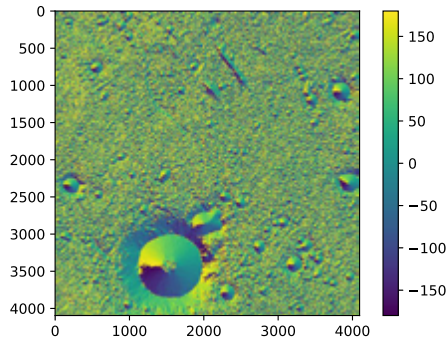

### 2.1 クレーターの抽出

本研究での前処理として、月面の DEM データからクレーターの領域のみを抽出する。図 1 に、DEM データの一例を示す。縦軸は南北 (単位はピクセル)、横軸は東西 (同左)、色は標高 (単位は m (メートル) をピクセルの値に変換) を表している。そこで本研究においては、山本らの開発した RPSD(RPSW for DTM) 法 [5] を用いてクレーターの自動抽出を行う。

RPSD 法の基本方針として、任意のある領域の DEM を解析対象とし、その各地 (ピクセル) の高度及び勾配、そしてクレーター内部の勾配の回転対称性に着目する。これらより解析対象の中からクレーターの中心となる地点を推定し、そこから周囲の標高を分析することで、具体的なクレーター範囲を決定していく。

具体的な処理として、まず解析対象となる一定範囲の DEM データを取得する。次に、取得した DEM データから、各地点の勾配の大きさを表す斜面勾配マップ  $S(x, y)$  と各地点の勾配の向きを表す斜面方位マップ  $F(x, y)$  を計算する。次に、 $S(x, y)$  と  $F(x, y)$  について、それらを角度  $\phi$  だけ回転させたマップ  $S_\phi(x, y)$  と  $F_\phi(x, y)$  を作成する。本研究においては、 $\phi = 90^\circ, 180^\circ, 270^\circ$  のものを作成した。図 2~図 5 に、斜面勾配マップ及び斜面包圍マップの一例を示す。解析範囲は図 1 と同じ範囲であり、斜面勾配マップの色は勾配の大きさを、斜面包圍マップの色は勾配の向き ( $0^\circ$  で東、 $180^\circ$  もしくは  $-180^\circ$  で西、 $-90^\circ$  で南、 $90^\circ$  で北向きに上がっていく) を表す。

以上を作成した後、ある一点のピクセル  $(x_0, y_0)$  における回転対称性を計算していく。まずは、中心点  $(x_0, y_0)$  から縦軸、横軸とも  $\pm l_{max}$  (抽出対象最大サイズ指定のためのパラメータ) の範囲を  $S(x, y), F(x, y)$  から切り出し、 $S_{x_0, y_0}(x, y)$  及び  $F_{x_0, y_0}(x, y)$  を作成する。同様の範囲での切り出しを  $S_\phi(x, y), F_\phi(x, y)$  でも行い、 $S_{x_0, y_0, \phi}(x, y)$  及び  $F_{x_0, y_0, \phi}(x, y)$  を作成する。次に、作成した  $S_{x_0, y_0}(x, y)$  及び  $S_{x_0, y_0, \phi}(x, y)$  より、斜面勾配が  $\theta_L \sim \theta_U$  の範囲にあるピクセルだけを抽出した斜面勾配抽出マップ  $U_{x_0, y_0, \phi}(x, y)$  を作成する。また、 $F_{x_0, y_0}(x, y)$  及び  $F_{x_0, y_0, \phi}(x, y)$  より、斜面方位について回転角  $\phi$  に対して回転対称となっているピクセル (閾値  $\omega$

図 2: 斜面勾配マップ  $S(x, y)$ 図 3: 90° 回転後の斜面勾配マップ  $S_{90}(x, y)$ 図 4: 斜面方位マップ  $F(x, y)$ 図 5: 90° 回転後の斜面方位マップ  $F_{90}(x, y)$ 

を設定し、回転時の斜面方位の差が $\omega$ 以下となるようなピクセル)だけを抽出した回転対称点抽出マップ  $V_{x_0, y_0, \phi}(x, y)$  を作成する。 $U_{x_0, y_0, \phi}(x, y), V_{x_0, y_0, \phi}(x, y)$  の両マップにおいては、抽出されたピクセルの値を 1、抽出されなかったピクセルの値を 0 とおく。

そして、全ての  $U_{\phi}(x, y)$  及び  $V_{\phi}(x, y)$  において値が 1 となっているようなピクセルのみを抽出した回転対称性評価マップ  $H_{x_0, y_0}(x, y)$  を作成する。このマップはすなわち、斜面勾配が  $\theta_L \sim \theta_U$  の範囲にあり、かつ斜面方位が  $360/\phi$  個の回転角に対して回転対称条件を満たすピクセルだけを抽出したマップである。図 6～図 11 に、回転対称性を持つ点と持たない点それぞれの斜面勾配抽出マップ、回転対称点抽出マップ、回転対称性評価マップを示す。黄色いピクセルが抽出された点、紫のピクセルが抽出されなかった点を示す。

この  $H_{x_0, y_0}(x, y)$  の全ピクセルの値を合計し、同様の計算を解析対象 DEM データの全ピクセルで行う (実際には計算コスト低減のため、数ピクセルおきに計算を行う) ことにより、解析対象 DEM データに対する回転対称性関数  $R(x, y)$  を求める。そして、 $R(x, y)$  の高いものから閾値分率  $f$  を使ってクレーター中心候補点をリストアップする。

次に、リストアップされた候補点に対し、クレーター径の測定を行う。まず、中心候補点から横軸、縦軸それぞれの正負方向への高度プロファイル  $P(n)$  を作成する。そして  $P(n)$  よりさらに斜面勾配プロファイル  $Q(n)$  を作成する。これらより、 $n = l_{min}$  (抽出対象最小サイズ指定のためのパラメータ) から  $n$  を順次増加させていき、中心候補点からの高度が  $P_{min}$  (最小深さ閾値) より高く、かつクレーター壁面の最大勾配から  $\sigma$  だけ勾配が緩くなった (もしくは勾配の値が負になった) 最初の地点での  $n$  を求める。この際、 $n$  が  $l_{max}$  に達

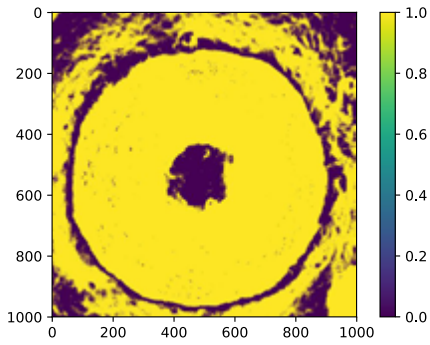


図 6: 回転中心性のある観測点における  
斜面勾配抽出マップ  $U_{x_0, y_0, \phi}(x, y)$  ( $\phi = 270^\circ$ )




図 7: 回転中心性のある観測点における  
回転対称点抽出マップ  $V_{x_0, y_0, \phi}(x, y)$  ( $\phi = 270^\circ$ )




図 8: 回転中心性のある観測点における  
回転対称性評価マップ  $H_{x_0, y_0}(x, y)$




図 9: 回転中心性のない観測点における  
斜面勾配抽出マップ  $U_{x_0, y_0, \phi}(x, y)$  ( $\phi = 270^\circ$ )




図 10: 回転中心性のない観測点における  
回転対称点抽出マップ  $V_{x_0, y_0, \phi}(x, y)$  ( $\phi = 270^\circ$ )






図 11: 回転中心性のない観測点における  
回転対称性評価マップ  $H_{x_0, y_0}(x, y)$

図 12: 横軸正方向への高度プロファイル  $P(n)$ 図 13: 横軸正方向への斜面勾配プロファイル  $Q(n)$ 

しても条件を満たさなかった場合、計算結果は導出しない。 $P_{min}$  及び  $\sigma$  については、山本らの研究に準じ、 $P_{min} = l_{max} * 0.05$ 、 $\sigma = 15$  とした。以上の計算作業を中心候補点の上下左右四方向に行い、導出された数値の平均を中心候補点に対するクレーターのリム径 (クレーター径) とした。この際、任意の整数パラメータ  $s_{min}$  ( $0 < s_{min} < 5$ ) を設定し、計算結果が  $s_{min}$  個以上導出されなかった候補点については、クレーター中心ではなかったとみなす。図 12 及び図 13 に、横軸正方向 (東向き) の高度プロファイル及び斜面勾配プロファイルを示す。対象点は図 6 と同じ点で、横軸がピクセル数、縦軸が標高 (単位は m をピクセルに変換) もしくは勾配 (単位は rad) を表す。

以上の計算により、一つの対象 DEM データ内に存在する半径  $l_{min} \sim l_{max}$  のクレーター群が抽出される。これらを DEM データそれぞれに実行することにより、クレーター群のデータセットを得る。

## 2.2 機械学習による識別

次に、抽出したクレーター群を機械学習によって分類し、中央丘クレーターを識別する。抽出されたクレーターの DEM は 1 チャンネルの、即ち各ピクセル毎に一つだけ値を有する画像データと類似したデータ形式である為、画像処理分野において用いられる機械学習手法が有効であると考えられる。よって、画像分類の代表的な手法の一つである CNN(Convolution Neural Network)[6] による分類を行う。CNN とは教師あり学習、つまり教師データを必要とする学習であり、機械学習アルゴリズムの一つである Neural Network に畳み込みフィルタの層を導入したもので、画像識別において高い性能を発揮することが示されている。

CNN の動作の概要は以下の通りである。CNN に入力された画像はまず、畳み込み層、プーリング層の二種を任意に積層させたネットワークを通る。畳み込み層とは、入力画像に対しフィルタによる畳み込みを行う層である。簡単のために入力、出力ともチャンネル数 1、即ち各ピクセル毎に一つしか画素値を持たない二次元画像で考えると、入力画像を  $I_{(x,y)}$ 、フィルタのカーネル (フィルタを表す行列、ここでは大きさを  $3 \times 3$  とする) を  $K_{(x,y)}$ 、出力画像を  $O_{(x,y)}$  とした時の畳み込みの計算は以下ようになる。

$$O_{(x,y)} = \sum_{j=1}^3 \sum_{k=1}^3 I_{(x-2+j,y-2+k)} \times K_{(j,k)}$$

この演算によって、畳み込み層では入力画像からエッジ等の特徴を抽出できる (y 軸方向のエッジを抽出するフィルタのカーネルの一例:  $[[1, 2, 1], [0, 0, 0], [-1, -2, -1]]$ )。カーネルにチャンネル数の次元を付加して三次元行列とすれば、チャンネル毎に別々の特徴が抽出され、出力は各ピクセル毎に複数の値を有する三次元画像となる。プーリング層とは、入力画像の圧縮を行う層である。畳み込み層、プーリング層によって特徴量の抽

出と次元削減を行った後は、Neural Network と同様の全結合層、即ち (多層) パーセプトロンによって分類を行う。以上のネットワークにおいて、畳み込み層のカーネルおよび全結合層の重み・バイアスを変数として教師データによって学習させることで、目的の識別モデルを得ることができる。

CNN による分類の為、識別モデル作成の前に人手によるクレーター群へのラベル付けを行う。ラベル付けの際は、抽出したクレーターの DEM を二次元画像として表示し、それを実験者が目視確認することによって、どのラベルを付与すべきかの判断を行った。付与するラベルは、「クレーターでない」「非中央丘クレーターである」「中央丘クレーターである」の三種とした。「クレーターでない」というラベルを設けた理由は、より網羅的な中央丘クレーター探索を行う為、RPSD 法において後述のようにパラメータを調整し、高再現率低適合率なデータセットを作成したためである。加えて、中央丘の有無に関係しない、CNN でのクレーターの識別可能性についても検証するためでもある。

## 2.3 適合率と再現率

本研究において精度評価の指標として用いる、適合率および再現率について説明する。任意のラベル  $A$  に関する適合率、再現率はそれぞれ以下の式で計算される。

$$\text{適合率} = \frac{\text{機械学習によって } A \text{ と識別され、正解のラベルが } A \text{ であるデータの数}}{\text{機械学習によって } A \text{ と識別されたデータの総数}}$$

$$\text{再現率} = \frac{\text{機械学習によって } A \text{ と識別され、正解のラベルが } A \text{ であるデータの数}}{\text{正解のラベルが } A \text{ であるデータの総数}}$$

適合率は、実験結果がどれ程誤りのない結果を示しているかを測る指標である。一方再現率は、実験結果が本来現れるべき結果をどれ程漏らさずに示しているかを測る指標である。一般にこの二指標はトレードオフの関係にある。つまり適合率を上げようとするほど再現率は低下し、逆に再現率を上げようとするほど適合率は低下する。本研究では、中央丘クレーターに対する識別精度の高い識別モデルを構築することで、それによる中央丘クレーターの自動抽出を行うことを目的としている。よって、中央丘クレーター以外の物を中央丘クレーターとして誤識別される事や、中央丘クレーターでありながらそうと識別されない事より少ない、つまり中央丘クレーターに関する適合率・再現率の高い識別モデルを構築することが本研究の主目標である。

# 3 実験結果

## 3.1 データセット

本実験においては、ISAS/JAXA により公開されている月面の DEM データを用いる。本データは月面球表面を、「正距円筒図法 (Simple Cylindrical Projection)」と呼ばれる同径の円筒上に射影する投影法によって長方形に変形させた上で、横軸に経度方向すなわち東西、縦軸に緯度方向すなわち南北をとったものである。全球面は  $1^\circ \times 1^\circ$  の小正方形に分割されており、小正方形一枚につき  $4,096 \times 4,096$  ピクセル、その各ピクセルごとに高度データが格納されたバイナリデータとなっている。小正方形は全部で  $360 \times 360 = 129,600$  枚存在するが、南北の極点に近づくほど DEM の経度方向への歪みが大きくなっていきクレーター抽出が困難になっていく為、本研究においては極付近は実験対象とせず、北緯  $60^\circ \sim$  南緯  $60^\circ$ 、東経  $180^\circ \sim$  西経  $180^\circ$  を実験対象とした。

RPSD 法によって抽出されたクレーターへのラベル付けを施した結果、非クレーター及び非中央丘クレーターに対し中央丘クレーターの数が非常に不足していた。CNN での学習において教師データ内であるラベルのデータ数が相対的に極端に少ない場合、学習後の識別モデルがそのラベルの識別に関して極端に低精度になる危険がある。よって学習データセット内でのラベル毎のデータ数を均一にするため、中央丘クレーターにの

み反転, 回転等の処理を施し, データセットのオーバーサンプリングを行った.

前処理を施したデータセットは学習用データとテストデータに分割し, 学習用データで識別モデルの学習を行い, テストデータで識別精度の検証を行った.

### 3.2 パラメータ

実験に際し, USGS(アメリカ地質調査所)/NASA より公開されている<sup>\*5</sup>クレーターカタログ [7] を元に, RPSD 法におけるパラメータの一部を調整した. 調整対象となるパラメータは, クレーター抽出精度に対し影響の大きい  $f$  および  $s_{min}$  とした. 両パラメータ共に, 値を大きくする程抽出対象クレーターの形状に対して厳密性を要求するようになるが, 本研究では抽出されたクレーターの識別を CNN によって抽出後に行える為, この厳密性を緩める方向での調整を行った. これらは,  $f$  を小さくすることによって回転中心性の低さによって間引かれるクレーター中心候補点の数を減らし, より回転中心性の低い中心点を有するクレーター, つまり真円に対して歪みの大きいクレーターを許容し,  $s_{min}$  の値を減らす事でクレーター中心から東西南北いずれかの位置に別のクレーターによる「えぐれ」が存在した場合を許容する事で, 抽出されるクレーターの絶対数を増やす事を意図したものである. 両パラメータの検証, 調整はグリッドサーチによって行い, 結果として本研究において用いる値は  $f = 0.003$ ,  $s_{min} = 3$  とした. このパラメータによる抽出では, 抽出対象サイズのクレーターに対し約 80% の再現率を記録した. また, クレーター中心候補点の導出精度及び計算コスト削減のため,  $l_{min}$ ,  $l_{max}$  は山本らの論文内で用いられていた値と比較して小さな値とした. より大型のクレーターを探索する場合も, この値を増大させるのではなく, 解析対象 DEM データをつなぎ合わせ, それを  $4,096 \times 4,096$  に縮小することで抽出可能範囲に落とし込んだ. 以上のようにして, 本実験においては一回の RPSD 法計算における解析対象範囲を  $32^\circ$  四方,  $64^\circ$  四方,  $128^\circ$  四方の三通り,  $(l_{min}, l_{max})$  をそれぞれ  $(8, 32)$ ,  $(8, 32)$ ,  $(16, 64)$  とすることで, 抽出対象クレーターの直径を合わせて約 4km~128km とした. これ以上の大きさのクレーターに関しては, USGS のクレーターリストに記載の数値を利用し, RPSD 法を用いずに自動抽出した. 抽出されたクレーターの中で, 小型のクレーターは数が膨大であるのに対し中央丘クレーターの数が少ないため, 本実験では直径が約 8km 以上のクレーターのみを学習に利用した.

### 3.3 学習モデル

本実験で構築する CNN 学習モデルは以下の通りである.

入力に抽出された  $500 \times 500$  のクレーターの DEM データ

⇒ フィルタ数 16 の畳み込み層及びプーリング層

⇒ フィルタ数 32 の畳み込み層及びプーリング層

⇒ フィルタ数 64 の畳み込み層及びプーリング層

⇒ フィルタ数 128 の畳み込み層及びプーリング層

⇒ ノード数 4,096, 活性化関数 Leaky Relu の全結合層  $\times 2$

⇒ ソフトマックス関数による三値分類

学習における最適化アルゴリズムには Adam[8] を用いた. 実装には深層学習用フレームワーク Tensorflow[9] を, 実験環境には NVIDIA GeForce 1080Ti を使用し, GPU 環境による学習を行った. 一世代あたり 50 枚の入力で学習を行い, 学習に一世代あたり約 1.32 秒を要した.

<sup>\*5</sup> USGS (アメリカ地質調査所) /NASA  
<https://planetarynames.wr.usgs.gov/Page/MOON/target>



表 1: 識別結果

		正解ラベル				
		非クレーター	非中央丘	中央丘	再現率	適合率
テストデータ数		966	439	272		
識別結果	識別数 (非クレーター)	859	111	13	88.9%	87.4%
	識別数 (非中央丘)	32	133	32	30.3%	67.5%
	識別数 (中央丘)	75	195	227	83.5%	45.7%




図 14: 中央丘クレーターの識別成功例




図 15: 中央丘クレーターの識別失敗例

### 3.4 識別精度

提案手法により, 3.3 節のモデルを用い, ミニバッチ数 50 の確率的勾配降下法 [10] によって 20,000 世代の学習を行った. 過学習防止のため, early stopping によって最適な学習モデルの保持を図った.

提案手法による中央丘クレーター識別結果は, テストデータにおいて表 1 のようになった. 表 1 において, 横軸のラベルはテストデータ群に付与した正解のラベル, 縦軸はテストデータ群を識別した時の識別結果である. これより, 中央丘クレーターの識別精度は再現率が 83.5%, 適合率が 45.7% であった. 特に適合率が低く, モデルとしての識別精度は中央丘クレーターカタログの作成に用いることができる精度に達していないと考える. 低適合率の要因について, 図 15 のようにクレーター内部に起伏があるようなクレーターを中央丘クレーターと誤識別する事例が多く見受けられた. これは, 教師データを人力で作成した際, 中央丘クレーター数の少なさを補うため, クレーター内に何らかの凸構造物が存在するようなクレーターを全て中央丘クレーターとしてラベル付けしていたことが一因と考えられる. 図 14 及び図 15 に, 分類モデルに中央丘クレーターとして分類されたクレーターの識別成功例及び誤識別例を示す. 一方, 中央丘の有無を考慮しないクレーターか否かの識別精度は, 再現率が 82.6%, 適合率が 83.3% であった. これより, クレーターか否かの識別に関しては CNN が示唆されている. 非クレーターでありながら中央丘クレーターとして誤識別される事例が特に多かったため, 出力をクレーターか否かの 2 ラベルのみとするような識別モデルを別に作成すれば, より高精度な識別モデルの実現が可能であると考えられる.

## 4 まとめ

本研究では、DEMデータの画像処理的特性に着目し、CNNによる中央丘クレーターの自動識別手法を検証した。実験の結果、現在の識別モデルによって未知の中央丘クレーターを高精度に網羅するにはまだ精度が不十分であったが、CNNが中央丘クレーターの特徴を抽出できている可能性は示唆された。

今後の課題として、RPSD法のグローバル対応による教師データの増加と月面に存在する全クレーターの網羅、及び教師データの再検討によるモデルの再学習、高精度化が挙げられる。また、提案手法をより拡張し、中央丘以外の月面構造物の分類、識別をDEM及びCNNを用いて行うことが、本研究のより発展的な課題である。

## 参考文献

- [1] Carlton C Allen. Central peaks in lunar craters. *Earth, Moon, and Planets*, Vol. 12, No. 4, pp. 463–474, 1975.
- [2] W Hale and JW Head. Central peaks in lunar craters-morphology and morphometry. *Lunar and planetary science conference Proceedings*, Vol. 10, pp. 2623–2633, 1979.
- [3] Tsuneo Matsunaga, Makiko Ohtake, Junichi Haruyama, Yoshiko Ogawa, Ryosuke Nakamura, Yasuhiro Yokota, Tomokatsu Morota, Chikatoshi Honda, Masaya Torii, Masanao Abe, et al. Discoveries on the lithology of lunar crater central peaks by selene spectral profiler. *Geophysical Research Letters*, Vol. 35, No. 23, 2008.
- [4] 坪内彩音, 篠田玲奈, 郭哲也, 後藤祐紀, 春山純一, 三宅互. Selene (かぐや) 搭載地形カメラステレオペアデータから得られた数値地形モデル (dtm) ならびに数値標高モデル (dem) プロダクトの標高値の検証報告. 宇宙航空研究開発機構研究開発資料, pp. 1–36, 2016.
- [5] 山本聡, 松永恒雄, 中村良介, 関根康人, 平田成, 山口靖. 回転ピクセルスワッピング法を使ったクレーター年代学. 日本惑星科学会誌遊星人, Vol. 24, No. 1, pp. 20–32, 2015.
- [6] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, editors, *Advances in Neural Information Processing Systems 25*, pp. 1097–1105. Curran Associates, Inc., 2012.
- [7] LA Andersson and Ewen Adair Whitaker. Nasa catalogue of lunar nomenclature. 1982.
- [8] Diederik Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- [9] Martín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S Corrado, Andy Davis, Jeffrey Dean, Matthieu Devin, et al. Tensorflow: Large-scale machine learning on heterogeneous distributed systems. *arXiv preprint arXiv:1603.04467*, 2016.
- [10] Léon Bottou. Large-scale machine learning with stochastic gradient descent. *Proceedings of COMPSTAT'2010*, pp. 177–186, 2010.