

## 機械学習による月面 DEM の高解像化

小野寺 康祐<sup>\*1</sup>, 井上 博夏<sup>\*2</sup>, 山本 光生<sup>\*2</sup>, 山本 幸生<sup>\*2</sup>, 大嶽 久志<sup>\*2</sup>,  
荒木 徹也<sup>\*3</sup>, 廣田 雅春<sup>\*4</sup>, 石川 博<sup>\*1</sup>

### Resolution enhancement of DEM of the lunar surface using machine learning

ONODERA Kosuke<sup>\*1</sup>, INOUE Hiroka<sup>\*2</sup>, YAMAMOTO Mitsuo<sup>\*2</sup>, YAMAMOTO Yukio<sup>\*2</sup>,  
OTAKE Hisashi<sup>\*2</sup>, ARAKI Tetsuya<sup>\*3</sup>, HIROTA Masaharu<sup>\*4</sup>, ISHIKAWA Hiroshi<sup>\*1</sup>

#### ABSTRACT

Digital Elevation Model (DEM) of the lunar surface is one of the data used to discuss landing sites and travel route candidates for the lunar probe. When using DEM, if the DEM resolution is low, cannot grasp the detail for the terrain. However, the creation of a high-resolution DEM of the lunar surface is expensive because it requires manual work. In this paper, we aim to generate a high-resolution DEM without manual work by using a low-resolution DEM that exists for the entire lunar. In general, the interpolation method is used to generate a higher resolution DEM from the existing DEM. However, the interpolation method is not sufficient for use to discuss the landing site of the lunar explorer and moving path candidates. In this paper, we consider that a method using deep learning that achieves high performance in image super-resolution can be applied and verified the effectiveness of the method. In the evaluation based on the mean of mean error and the mean of maximum error, the verified method generated a DEM with higher accuracy than the general interpolation method. However, we consider that the performance is insufficient for discussing the landing site of the lunar probe and travel route candidates for the lunar probe.

**Keywords:** Digital Elevation Model, Deep Learning, Neural Network

#### 概 要

月面の数値標高モデル (Digital Elevation Model; DEM) は、月面探査機の着陸地点や移動経路候補を検討するために用いるデータの一つである。DEM を使用する際、DEM の解像度が低いと詳細な地形を把握することができない。しかし、月面の高解像度の DEM の作成は人手による作業を必要とするため、高いコストがかかる。そこで本研究では、月の全球分存在する低解像度の DEM を用いて、人手を介さずに高解像度の DEM を生成することを目標とする。一般的に既存の DEM からより解像度の高い DEM を生成するという目的には補間手法が用いられるが、月面探査機の着陸地点や移動経路候補の検討という目的に用いるには十分でない。そこで本研究では、画像の超解像において高い性能を実現している深層学習の技術を用いた手法が適用できると考え、その手法の有効性を検証した。平均平均誤差および平均最大誤差による評価では、検証した手法は一般的な補間手法よりも高精度な DEM が生成された。しかし、月面探査機の着陸地点や移動経路候補の検討のためには不十分な性能であると考えられる。

---

doi: 10.20637/JAXA-RR-19-006/0003

\* 2019年12月17日受付 (Received December 17, 2019)

\*<sup>1</sup> 首都大学東京大学院 システムデザイン研究科 (Graduate School of Systems Design, 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> 群馬大学 理工学部 (School of Science and Technology, Gunma University)

\*<sup>4</sup> 岡山理科大学 総合情報学部 (Faculty of Informatics, Okayama University of Science)

## 1 はじめに

月面探査機の着陸地点や移動経路候補を検討するために用いるデータの一つとして、月面の数値標高モデル (Digital Elevation Model; DEM) がある。DEM はピクセルごとに標高値を持つデータである。一つのピクセルが表す地域が小さく空間分解能 (以下、解像度と呼称する) が高い DEM でなければ、詳細な地形を把握することができない。月面の DEM を可視化した例を図 1、図 2 に示す。それぞれの図において、各ピクセルの色はその DEM 内における標高値の大きさを表しており、色が明るいピクセルほど標高値が大きいことを表している。

月面の DEM には SLDEM2013<sup>1)</sup> (以下、SLDEM と呼称する) などが存在する。SLDEM は JAXA の月周回衛星「かぐや (SELENE)」の地形カメラ (Terrain Camera; TC) によって収集されたデータによるステレオ視に加え、LOLA<sup>2)</sup> のデータによる全体調整や、TC の欠損部分の補完などを施して構築された DEM である。また、SLDEM と比較して高解像度な DEM として、LRO NAC DEM<sup>3)</sup> (以下、NACDEM と呼称する) が存在する。しかし、NACDEM はある程度の質と量の月面画像が揃っている領域でなければ作成することができず、月面の一部のものしか公開されていない。加えて、NACDEM の作成には人手による作業が必要となる。そのため、3km 四方の DEM の作成にも三ヶ月以上の作業を必要とし、その作業者には専門的な知識と作業に対する熟練が求められることから、高いコストがかかるという問題が存在する。SLDEM と NACDEM の諸元を表 1、表 2 に示す。

表 1 SLDEM2013 の諸元

| DATA SET ID               | データ数  | MAP SCALE [m/pixel] |
|---------------------------|-------|---------------------|
| SLN-L-TC-5-SLDEM2013-V1.0 | 64800 | 7.4031617246699464  |

表 2 LRO NAC DEM の諸元

| DATA SET ID           | データ数 | MAP SCALE [m/pixel] |
|-----------------------|------|---------------------|
| LRO-L-LROC-5-RDR-V1.0 | 464  | 2 ~                 |

そこで本研究では、すでに月の全球分存在する低解像度の DEM (SLDEM) を用いて、人手を介さずに高解像度の DEM を生成することを目標とする。地球の地理データにおいては、既存の DEM からより解像度の高い DEM を生成するという目的に補間手法が用いられている。補間手法では、与えられた関数によって既知部分の標高値から未知部分の標高値の推定を行う。しかし、補間手法を月面に適用する場合、未知部分に標高の変化が急な小さなクレーターなどの地形が存在すると、その地形を推定することが難しい。よって、月面探査機の着陸地点や移動経路候補の検討という目的に用いるには十分でない。そこで、本研究では、超解像において高い性能を実現している深層学習の手法を適用し、低解像度の DEM から高解像度の DEM を生成する。この結果を公開されている高解像度の DEM と比較することで、検証手法の性能を生成された DEM の精度と、着陸地点選定や移動経路設計に対する有効性の二つの観点から検証する。

本論文は、以下の構成に従う。2 章では、本研究に関連する研究について述べる。3 章では、本研究で有効性の検証を行う、具体的な手法を説明する。4 章では、3 章で示した手法に基づいた実験とその結果についての考察を行う。5 章では、本論文のまとめ及び今後の課題について述べる。

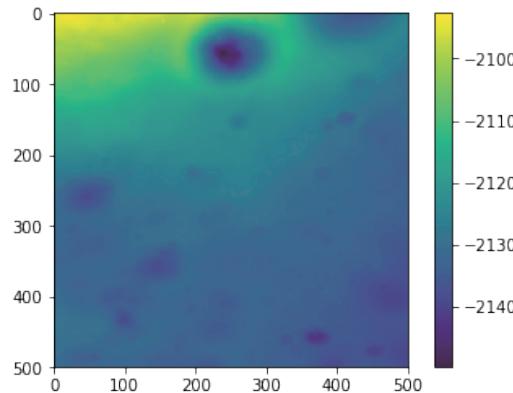


図 1 DEM の可視化例（2D）

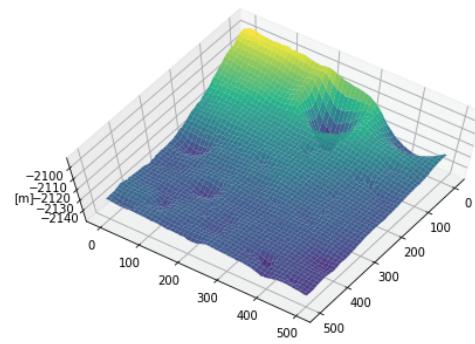


図 2 DEM の可視化例（3D）

## 2 関連研究

### 2.1 DEM の補間

地球上においては、航空機に搭載されたレーザスキャナなどによって地形の点群データを取得し、その点群データから DEM を作成することが行われておる、その際に補間手法が用いられている。点群データは、航空機の撮影位置などの影響により、場所によっては密にデータを取得できないことがある。そのような、点群データが疎な場所では DEM の標高値を精度良く内挿できていない可能性がある。そのため、点群データが疎な場所で得られた DEM の標高値から、点群データが疎な場所の DEM の標高値を補間することが行われている<sup>4)</sup>。しかし、データが疎な場所の範囲が大きいほど、補間の精度が悪くなることも報告されている。

また、本研究と類似した目的である、既存の DEM からより解像度の高い DEM を生成するという目的にも補間手法が用いられている。古館らの研究<sup>5)</sup>においては、線形補間<sup>6,7)</sup>やスプライン補間<sup>8)</sup>、Akima の補間<sup>9)</sup>などがその代表的な手法として挙げられ、性能の比較が行われている。

本研究では、深層学習の技術を用いた手法の有効性の検証を、古館らの研究で挙げられている手法と比較を行うことを行う。

### 2.2 単一画像超解像

本研究は低解像度の DEM を用いて高解像度の DEM を生成することを目的としているが、画像を取り扱った研究において、本研究と類似した目的を持つ单一画像超解像（Single image super-resolution; SISR）の研究が存在する。

SISR は 1 枚の低解像度 (LR) の画像から高解像度 (HR) の画像を生成することを目的とした研究である。高い知覚品質を持つ高解像度画像からは価値のある情報を得られるため、医療用画像処理や衛生画像処理、セキュリティ画像処理のような多くの分野において広く応用されている研究である。

初期の SISR の主な手法は Bicubic 補間<sup>10)</sup>などの補間ベースの手法、再構成ベースの手法<sup>11)</sup>、スパースコーディングを用いた学習ベースの手法<sup>12)</sup>の 3 つが存在していた。しかし、最近では深層学習ベースの手法が他の手法よりも優位性を示している<sup>13)</sup>。

深層学習ベースの手法では主に畳み込みニューラルネットワーク (Convolutional Neural Network; CNN) を用いる。CNN は主に画像認識に応用されるニューラルネットワークの一種である。隣接した層間の特定のユ

ネットのみが結合を持つ層を持っており、これは生物の脳の視覚野に関する神経科学の知見を元に考案されている。また、CNNは画像認識だけではなく、セグメンテーション、姿勢推定など様々なタスクを解くためのベースネットワークとしても広く利用されている<sup>14)</sup>。

Chao ら<sup>15), 16)</sup>は3層のCNNを用いた超解像手法(SRCNN)を提案し、高性能なSISRを実現した。また、CNNの層をより深くしたVDSR<sup>17)</sup>やRED<sup>18)</sup>、EDSR<sup>19)</sup>などが提案されている。

多くのCNNによる超解像手法では、低解像度の画像をBicubic補間などの補間手法で拡大した後、CNNによるモデルの入力とすることで高解像度の画像を生成する。学習段階では、元となる画像を用意し、それらを縮小した後に再びBicubic補間などの補間手法で拡大することで、低解像度の画像を生成する。そうして用意した低解像度の画像を入力データ、元の画像を正解データとして扱いモデルの学習を行う。

DEMも画像と同じくピクセルごとに値を持つデータである。そのため、DEMに対してもCNNを適用することが可能である。そこで、本研究ではSISRの研究を参考にした手法を用いて実験を行う。

### 3 検証手法

本研究では、CNNによるSISRの手法を参考にし、任意の地域の低解像度のDEMから、その地域の高解像度のDEMを得る手法を検証する。

本研究では画像ではなくDEMを用いるが、基本的にはSISRの場合と同様に低解像度のDEMを入力データ、高解像度のDEMを正解データとしてモデルを学習する。SISRの手法と異なる点としては、本研究の場合は月面の全球分存在する低解像度のDEM(SLDEM)と、月面の一部分だけ作成されている高解像度のDEM(NACDEM)が別々のデータとして公開されている。そのため、高解像度のDEMから低解像度のDEMを作成するのではなく、NACDEMと、それに対応する座標のSLDEMを補間手法によって拡大したデータを高解像度のDEMと低解像度のDEMのペアとして学習を行う。この方法は、高解像度のDEMからダウンサンプリングによって低解像度のDEMを得る場合に比べ、高解像度のDEMに対応する座標の低解像度のDEMを切り出すという処理が必要となる。

しかし、実際に高解像度のDEMを生成する際に用いるSLDEMを用いることで、より実用に適するモデルとして学習することが期待できる。

#### 3.1 モデルの概要

本研究で参考にしたCNNによるSISRの手法であるVDSRとREDについて説明する。

VDSRはJiwon ら<sup>17)</sup>によって提案されたモデルである。図3にVDSRのモデルの概要を示す。非常に深い層のネットワークを用いることで高い性能を実現している。深い層を用いるモデルの問題点として、学習が収束するまでに時間がかかってしまうことが挙げられる。しかしこのモデルでは、出力層で入力データを足し合わせることにより、中間層では目標データと入力データの差のみを学習させるようにすることで、学習の早い収束を実現している。

REDはMao ら<sup>18)</sup>によって、超解像やノイズ除去などを含む画像復元の手法として提案されたモデルである。図4にREDのモデルの概要を示す。対称的な畳み込み層と逆畳み込み層からなるモデルであり、畳み込み層では入力データを抽象化した特徴を得る。一方、逆畳み込み層では得られた特徴マップをアップサンプリングすることで画像の細部を復元する。この対となる畳み込み層と逆畳み込み層を接続することで、勾配消失の問題を防ぎ、深い層の学習を可能とする。また、この接続によって畳み込み層側から逆畳み込み層側へ特徴マップを渡すことになる。これにより、畳み込み処理によって抽象化される前の元の入力画像に近い特徴マップも保持される。そのため、綺麗な画像を復元することにも寄与する。

この二つの手法を利用した理由は、低解像度の画像を高解像度の画像と同じサイズに拡大してからネット

トワークの入力とするため、低解像度の DEM の解像度と高解像度の DEM の解像度の倍率が異なるペアを同一のネットワークで学習することが可能ということにある。高い性能を実現しているモデルの他の例として EDSR などがある。これらのモデルは Sub-pixel convolution<sup>20)</sup> という手法を用いている。Sub-pixel convolution は、入力時点では低解像度の画像を拡大せずにそのまま入力し、得られた特徴マップをネットワーク内で並び替えることで、最終的に拡大された画像を出力する手法である。この手法は Deconvolution と比較して効率的な拡大を可能とするとされているが、ネットワーク内で拡大を行うため、拡大率はあらかじめ設定した倍率で固定となる。そのため、Sub-pixel convolution を用いるモデルの場合、入力データの解像度と出力データの解像度の倍率が異なるペアを同一のネットワークで学習することができない。一方、今回用いるデータセットでは、低解像度の DEM (SLDEM) の解像度が全ての地域で一定であるのに対し、高解像度の DEM (NACDEM) は地域ごとに解像度がある程度異なっており、解像度の倍率が異なるペアを学習で使用することになる。そのため、EDSR などの Sub-pixel convolution を用いる手法は今回使用するデータセットには適さない。

また、VDSR と RED の両者を利用した理由は、VDSR が画像の超解像のみを目的とした手法であるのに対して、RED は超解像のみならず、ノイズ除去なども含む画像復元を目的とした手法であるという違いにある。この違いが高解像度の DEM の生成の影響する可能性を考え、比較のために両者を利用して実験を行なった。

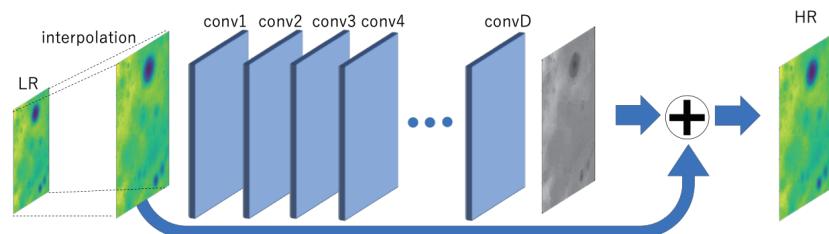


図 3 VDSR の概要図

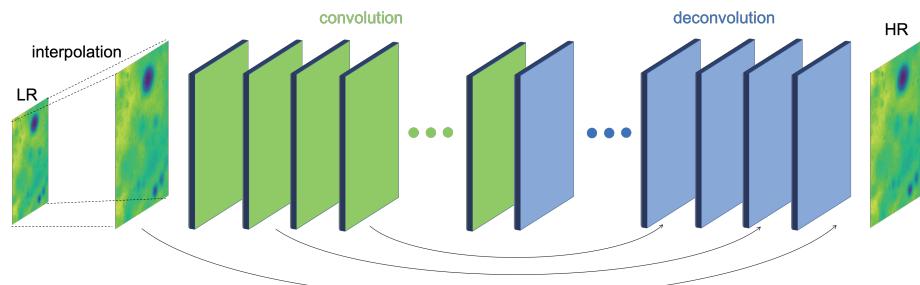


図 4 RED の概要図

### 3.2 モデルの構造

今回使用したモデルの構造を表3, 表4に示す。それぞれの表において、Numberはモデルの各層に割り当てた番号、Typeは層の種類を表している。層の種類としては、Convolutionが畳み込み層、Deconvolutionが逆畳み込み層、Addが入力を足し合わせて出力する層を表している。また、Kernelは畳み込み層におけるフィルタのサイズ、Strideは畳み込み層においてフィルタを入力に対して適用していく間隔、Filtersは畳み込み層におけるフィルタの数を表している。Activationは活性化関数を表しており、本研究のモデルでは正規化線形関数(Rectified Linear Unit; ReLU)を用いている。

表3 本研究で使用した VDSR の構造

| Number | Type          | Kernel       | Stride | Filters | Activtion |
|--------|---------------|--------------|--------|---------|-----------|
| Input  |               |              |        |         |           |
| 1      | Convolution   | $3 \times 3$ | 1      | 128     |           |
| 2      | Convolution   | $3 \times 3$ | 1      | 96      | ReLU      |
| 3 - 20 | Convolution   | $3 \times 3$ | 1      | 64      | ReLU      |
| 21     | Convolution   | $3 \times 3$ | 1      | 1       |           |
| 22     | Add(input,21) |              |        |         |           |

表4 本研究で使用した RED の構造

| Number | Type          | Kernel       | Stride | Filters | Activtion |
|--------|---------------|--------------|--------|---------|-----------|
| Input  |               |              |        |         |           |
| 1 - 12 | Convolution   | $3 \times 3$ | 3      | 64      |           |
| 13,14  | Deconvolution | $3 \times 3$ | 3      | 64      |           |
| 15     | Add(14,11)    |              |        |         | ReLU      |
| 16,17  | Deconvolution | $3 \times 3$ | 3      | 64      |           |
| 18     | Add(17,9)     |              |        |         | ReLU      |
| 19,20  | Deconvolution | $3 \times 3$ | 3      | 64      |           |
| 21     | Add(20,7)     |              |        |         | ReLU      |
| 22,23  | Deconvolution | $3 \times 3$ | 3      | 64      |           |
| 24     | Add(23,5)     |              |        |         | ReLU      |
| 25,26  | Deconvolution | $3 \times 3$ | 3      | 64      |           |
| 27     | Add(26,3)     |              |        |         | ReLU      |
| 28,29  | Deconvolution | $3 \times 3$ | 3      | 64      |           |
| 30     | Add(29,Input) |              |        |         | ReLU      |

### 3.3 学習

ネットワークのパラメータを最適化するために最小化する対象となる関数について説明する。

補間手法によって拡大した低解像度のDEMを $\mathbf{x}$ 、高解像度のDEMを $\mathbf{y}$ 、各DEMのピクセル数を $n$ とする。学習するためのデータセットとして座標が対応した $\mathbf{x}$ と $\mathbf{y}$ が与えられた場合に、目標となるのは値 $\hat{\mathbf{y}} = f(\mathbf{x})$ を予測する、関数 $f$ を最適化することである。ここで $\hat{\mathbf{y}}$ は目標となる $\mathbf{y}$ に対する推定値であり、関

数  $f$  はネットワークそのものを示している。

学習のために用いる損失関数として平均二乗誤差 (Mean Squared Error; MSE)  $\frac{1}{n}(\mathbf{y} - f(\mathbf{x}))^2$  を用いる。ここで、MSE は目標データである  $\mathbf{y}$  と低解像度 DEM をネットワークに入力した結果得られる出力  $f(\mathbf{x})$  の誤差を評価する関数として用いており、MSE が小さいほど目標データに近い出力が得られていることを意味する。この損失関数を最小化するようにネットワークのパラメータを最適化する。

## 4 評価実験

### 4.1 データセット

実験に使うデータセットとして、低解像度の DEM には DARTS at ISAS/JAXA (<https://www.darts.isas.jaxa.jp>) で公開されている SLDEM を使用した。また、高解像度の DEM としては NACDEM<sup>3)</sup> を使用した。SLDEM の解像度は約 7.4m/pixel であり、NACDEM においては公開されているもののうち、解像度が約 2m/pixel のものを使用した。

NACDEM は欠損値も含んでいるため、欠損値を除く部分から  $500 \times 500$  ピクセルごとにデータを切り出した。その後、切り出した NACDEM の座標に対応する地域の SLDEM を切り出し、高解像度の DEM と低解像度の DEM のペアのデータセットを作成した。

使用したデータの内訳は、トレーニングデータが 16,000 ペア、バリデーションデータが 4,000 ペア、テストデータが 4,000 ペアとなっている。トレーニングデータは学習に用いるデータであり、バリデーションデータは学習中にモデルの評価を行うために用いるデータである。また、テストデータはそれぞれの手法の評価を行うために用いるデータである。

また、実験環境には NVIDIA GeForce 1080Ti を使用し、GPU 環境において実験を行った。

### 4.2 比較手法

実験では、古館らの研究<sup>5)</sup>で挙げられている、既存の DEM からより解像度の高い DEM を生成する際に用いられている、以下に示す補間手法と比較を行い、有効性の検証を行う。

- スプライン補間
- Akima 補間
- 線形補間
- 最近傍補間

スプライン補間は、データ点（ピクセル）で区分される小区間ごとに、多項式を定めて補間を行う手法である。ここで、多項式の係数は 2 階までの導関数が連続となるように決定する。本研究では 3 次以下の多項式を定めて補間を行う 3 次スプライン補間を用いる。Akima の補間はスプライン補間と同様に小区間ごとに 3 次以下の多項式を定めて補間を行う手法だが、1 階までの導関数が連続であれば良いという点が異なっている。そのため、スプライン補間に比べて振動しにくいとされている。また、線形補間は小区間ごとに 1 次の多項式を定めて補間を行う手法であり、最近傍補間は最も近くに存在するピクセルの値をそのまま用いる手法である。

評価指標として、生成された DEM の精度の評価のためには、古館らの研究<sup>5)</sup>をはじめとした DEM の生成に関する多くの研究で使用されている平均誤差と最大誤差を使用する。生成されたデータと公開されている高解像度の DEM である NACDEM を比較して誤差が小さければ、精度が高い DEM を生成することができていると言える。また、探査機の着陸地点の選定や移動経路の設計においては、標高の変化が急な小さなクレー

ターなどの地形の再現度合いおよび平坦度が重要となるが、これらの評価には、生成された DEM の可視化結果および高解像度の DEM との誤差をフーリエ変換し可視化した結果によってそれぞれ評価を行う。

## 4.3 結果

実験結果を表 5 に示す。表において、下四つが CNN を用いた手法の結果である。それら四つの手法の括弧内に記載されている補間手法は、低解像度の DEM の拡大に用いた補間手法を示している。また、評価指標の平均平均誤差は、出力されたデータと正解データである高解像度の DEM とのピクセルごとの誤差の平均値を、テストデータである 4,000 ペアで平均した値であり、平均最大誤差はピクセルごとの誤差の最大値を、テストデータである 4,000 ペアで平均した値である。

### 4.3.1 誤差

平均平均誤差においては、線形補間を用いた RED が、平均最大誤差においては線形補間を用いた VDSR が最も性能が良く、どちらの指標においても CNN を用いた手法の性能が良い結果となった。これらの結果から、性能の観点において一般的な補間手法と比較した場合、CNN を用いた手法は高解像度の DEM の生成において有効性があるといえる。

一般的な補間手法の中では、平均平均誤差、平均最大誤差の両方において線形補間が最も良い性能を示しており、最近傍補間は両方において最も誤差が大きい結果となった。

CNN を用いた手法の結果を比較してみると、RED、VDSR のどちらにおいても補間手法に線形補間を用いた場合の方が、最近傍補間を用いた場合よりも良い性能を示している。このことから、CNN による手法の性能には、低解像度の DEM の拡大に用いる補間手法の性能が影響することが推察される。

表 5 実験結果

|              | 平均平均誤差 [m] | 平均最大誤差 [m] |
|--------------|------------|------------|
| スプライン補間      | 5.1436     | 17.4075    |
| Akima 補間     | 5.1422     | 17.3667    |
| 最近傍補間        | 5.1572     | 17.8092    |
| 線形補間         | 5.1396     | 17.4673    |
| VDSR (最近傍補間) | 5.0498     | 17.4673    |
| VDSR (線形補間)  | 5.0392     | 16.9617    |
| RED (最近傍補間)  | 5.0591     | 17.5657    |
| RED (線形補間)   | 5.0387     | 16.9942    |

(小数点以下第 5 位で四捨五入している)

### 4.3.2 可視化

それぞれの手法を適応した結果と、正解データである高解像度の DEM の誤差を可視化した例を図 5 に示す。また、正解データである高解像度の DEM とそれに対応した座標の低解像度の DEM を可視化した例と、低解像度の DEM に対して各手法を適用した結果を可視化した例を図 6 に、それぞれの手法を適応した結果と、正解データである高解像度の DEM の誤差をフーリエ変換したものを、テストデータである 4,000 ペアで平均して可視化した結果を図 7 に示す。

図 5 における、上一列の補間手法によって生成された DEM の誤差と、下一列の CNN を用いた手法によって生成された DEM の誤差を比較すると、相対的な誤差の大きさを表す色の明るさが全体的に暗くなっている

ことから、全体的に誤差が小さくなっていることがわかる。この結果と、誤差の結果から、CNNによる手法は、一般的な補間手法よりも正確な標高値を推定できていると言える。

図6における①の高解像度のDEMと②の低解像度のDEMを比較すると、①の高解像度のDEMにおいて見られる小さな凹凸が②の低解像度のDEMにおけるでは存在していないことがわかる。このような情報が低解像度のDEMでは失われている。③から⑥はそれぞれの補間手法によって生成されたDEMを可視化した例だが、この小さな凹凸を推定できていないことがわかる。

しかし、⑦から⑩のCNNを用いた手法による結果を見ると、こちらも同様に、高解像度のDEMに見られた小さな凹凸が推定できていないことがわかる。これより、これらの手法は、月面探査機の着陸地点や移動経路候補を検討するという目的に用いるためには性能が十分ではないと言える。

小さな凹凸を推定できない理由としては、データセットにおいてこのような小さな凹凸が失われているパターンの地域が、情報が失われていない地域に対して少ないことが考えられる。解決方法としては、あらかじめ小さな凹凸が失われているパターンのデータを抽出し、そのデータ数とその他パターンのデータ数が不均衡にならないようにデータセットを作成することがある。

また、その他の解決方法として、月面の画像から地形の標高値を推定するという方法も挙げられる。この方法には、単眼深度推定(Monocular Depth Estimation)の研究が応用できると考える。単眼深度推定は、1枚の画像からピクセルごとにそのシーンの奥行きを推定することを目的とした研究である<sup>21)</sup>。高解像度の月面画像は高解像度のDEMと比較して非常に多く存在しているため、今回の目的に有用な方法であると考える。

次に、図7を見ると、どの手法の誤差も比較的中心に近い低周波成分を多く含んでおり、四隅の高周波成分が少ないとすることがわかる。高周波成分が少ないとすることは、誤差が大きく変化する領域が少ないとということである。つまり、データ全体としては探査機の着陸地点の選定や移動経路の設計の際に重要な平坦度や斜度に影響するような誤差は比較的少なく、また、手法間で明確な差は見られなかった。

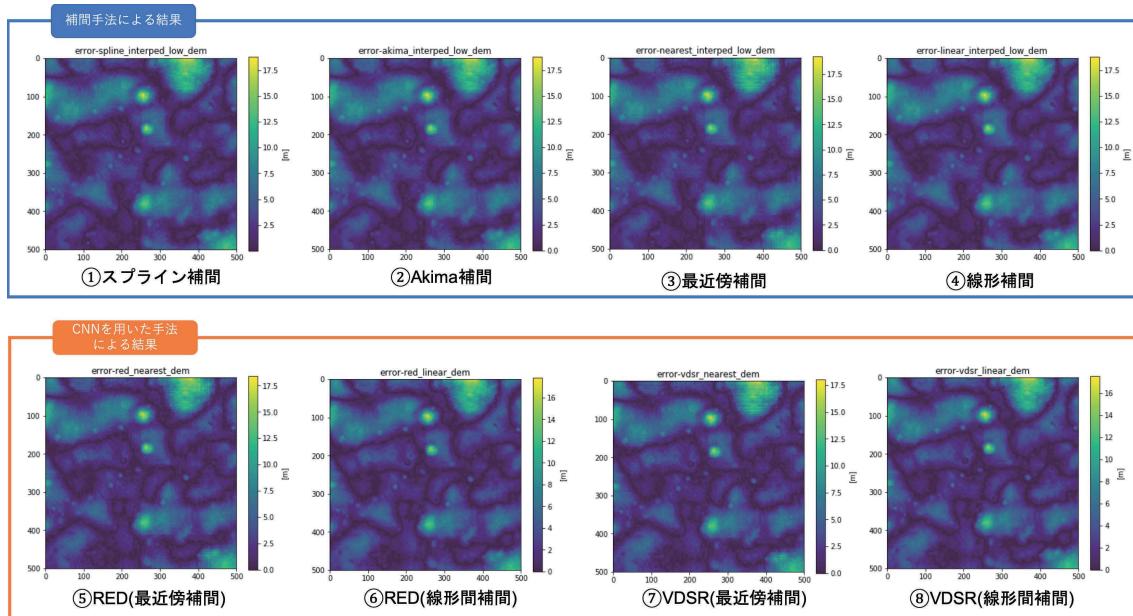


図5 実験結果例（誤差の可視化）

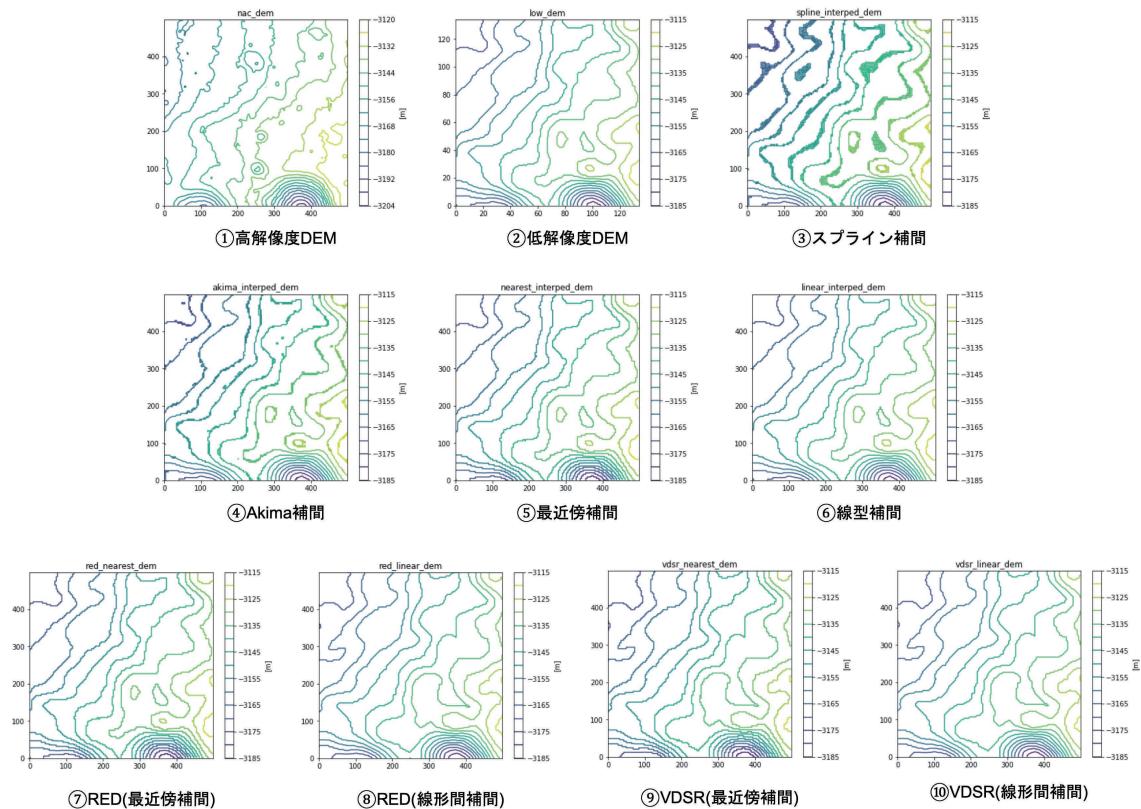


図 6 実験結果例 (DEM の可視化)

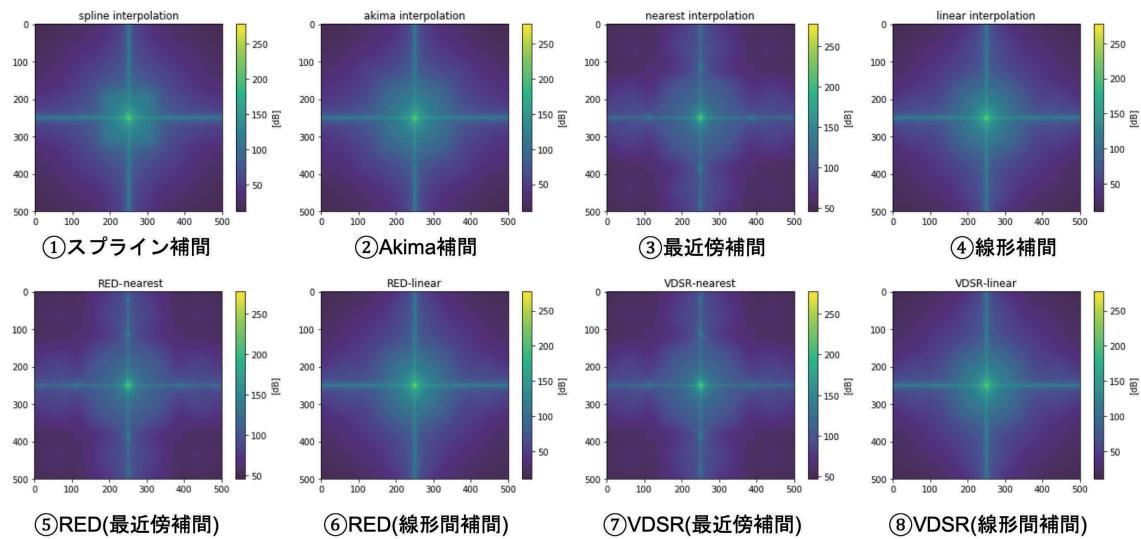


図 7 実験結果例 (誤差を周波数成分ごとに可視化)

## 5 まとめと今後の展望

本研究では、深層学習の技術を用いて人手を介さずに月面の低解像度の DEM から高解像度の DEM を生成する手法について検証した。検証した手法は、類似した目的を持つ解像度が低い画像から解像度が高い画像を生成する画像の超解像の研究を参考にした。

スプライン補間などの地球の DEM に一般的に適用される補間手法と比較して、今回検証した手法は精度が高い DEM を生成したが、一般的な補間手法と同様に、標高の変化が急な地形の推定をすることはできず、平坦度や斜度への影響についても一般的な補間手法と比較して有意な差はなかった。そのため、月面探査機の着陸地点や移動経路候補を検討するという目的のために用いるには性能が十分ではないと言える。一般的な補間手法よりも精度が高い DEM を生成できることから、何らかの制約条件により事前に急激な変化がないことを確認した地域であれば、今回検証した手法は有効であると考える。しかし、標高の変化が急な地形を含む地域である場合は、地形の推定が困難であり、低解像度から補間を用いて高解像化された DEM を検討に用いるのは注意を要する。この場合、部分的に解像度の高い地形データを用いる等の対策が必須である。

今後の課題としては、高解像化対象の地域に、地形の推定が困難となる標高の変化が含まれるか否かを判別することがある。含まれる場合には、その誤差の上限を定量的に示し、作成された DEM が探査目的に利用可能かを利用者が識別できるようにすることが重要であろう。

加えて、標高の変化が急な地形の推定を可能とすることも今後の課題として挙げられる。方法としては、データセットにおける、標高の変化が急激な小さな凹凸が失われているパターンが存在するデータの数と他のパターンのデータ数の不均衡の解消や、1枚の画像からピクセルごとに奥行きを推定すること目的とした研究である単眼深度推定の手法を参考にすることで、月面の画像から地形の標高値を推定するという方法が考えられる。

また、今回の実験で使用した DEM は等経緯度グリッドのものを使用している。等経緯度グリッドの DEM を使用する場合の問題点として、その DEM が表す地域が高緯度であるほどクレータなどの地物が歪んでしまうことがある。今回の実験では使用する DEM の緯度帯を指定していないため、歪んだ地形の入力に対しては歪んだ地形を、歪んでいない地形の入力には歪んでいない地形を出力するようモデルは学習することになる。そのため、モデルの学習や使用には問題がないと考える。しかし、高緯度域と低緯度域の DEM のデータ数のバランスが極端に悪い場合などは、モデルの性能に悪影響を及ぼす可能性があるため対策が必要になると考える。また、特定の緯度帯ごとにモデルを学習させることにより、その緯度帯に対するより高性能なモデルとして学習させることができると考えられる。

## 参考文献

- 1) 坪内彩音, 篠田玲奈, 郭哲也, 後藤祐紀, 春山純一, 三宅瓦. *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*. Technical report, 2016.
- 2) David E Smith, Maria T Zuber, Gregory A Neumann, Erwan Mazarico, Frank G Lemoine, James W Head III, Paul G Lucey, Oded Aharonson, Mark S Robinson, Xiaoli Sun, et al. Summary of the results from the lunar orbiter laser altimeter after seven years in lunar orbit. *Icarus*, Vol. 283, pp. 70–91, 2017.
- 3) MS Robinson, SM Brylow, M Tschimmel, D Humm, SJ Lawrence, PC Thomas, BW Denevi, E Bowman-Cisneros, J Zerr, MA Ravine, et al. Lunar reconnaissance orbiter camera (lroc) instrument overview. *Space science reviews*, Vol. 150, No. 1-4, pp. 81–124, 2010.

- 4) 平岡透, 野中尋史, 龜野辰三. 結合特異値分解による dem の補間法. 写真測量とリモートセンシング, Vol. 52, No. 2, pp. 69–74, 2013.
- 5) 古館守通, 渡辺孝志, 阿部英志, 横山隆三. 数値標高モデルの生成に用いる補間手法の性能評価. GIS-理論と応用, Vol. 8, No. 1, pp. 29–38, 2000.
- 6) Gregory Cole, Scott MacInnes, and James Miller. Conversion of contoured topography to digital-terrain data. *Computers & Geosciences*, Vol. 16, No. 1, pp. 101–109, 1990.
- 7) Ben Gorte. Interpolation between isolines based on the borgefors distance transform. *ITC Journal*, Vol. 1990, No. 3, pp. 245–247, 1990.
- 8) 市田浩三. スプライン関数とその応用. シリーズ新しい応用の数字 20, 1994.
- 9) Hiroshi Akima. A new method of interpolation and smooth curve fitting based on local procedures. *J. ACM*, Vol. 17, No. 4, pp. 589–602, October 1970.
- 10) Robert Keys. Cubic convolution interpolation for digital image processing. *IEEE transactions on acoustics, speech, and signal processing*, Vol. 29, No. 6, pp. 1153–1160, 1981.
- 11) Kui Jia, Xiaogang Wang, and Xiaoou Tang. Image transformation based on learning dictionaries across image spaces. *IEEE transactions on pattern analysis and machine intelligence*, Vol. 35, No. 2, pp. 367–380, 2013.
- 12) Jianchao Yang, John Wright, Thomas S Huang, and Yi Ma. Image super-resolution via sparse representation. *IEEE transactions on image processing*, Vol. 19, No. 11, pp. 2861–2873, 2010.
- 13) Wenming Yang, Xuechen Zhang, Yapeng Tian, Wei Wang, and Jing-Hao Xue. Deep learning for single image super-resolution: A brief review. *arXiv preprint arXiv:1808.03344*, 2018.
- 14) 内田祐介, 山下隆義. 疊み込みニューラルネットワークの研究動向(パターン認識・メディア理解). 電子情報通信学会技術研究報告=IEICE technical report: 信学技報, Vol. 117, No. 362, pp. 25–38, 2017.
- 15) Chao Dong, Chen Change Loy, Kaiming He, and Xiaoou Tang. Learning a deep convolutional network for image super-resolution. In *European conference on computer vision*, pp. 184–199. Springer, 2014.
- 16) Chao Dong, Chen Change Loy, Kaiming He, and Xiaoou Tang. Image super-resolution using deep convolutional networks. *IEEE transactions on pattern analysis and machine intelligence*, Vol. 38, No. 2, pp. 295–307, 2016.
- 17) Jiwon Kim, Jung Kwon Lee, and Kyoung Mu Lee. Accurate image super-resolution using very deep convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1646–1654, 2016.
- 18) Xiao-Jiao Mao, Chunhua Shen, and Yu-Bin Yang. Image restoration using convolutional auto-encoders with symmetric skip connections. *arXiv preprint arXiv:1606.08921*, 2016.
- 19) Bee Lim, Sanghyun Son, Heewon Kim, Seungjun Nah, and Kyoung Mu Lee. Enhanced deep residual networks for single image super-resolution. In *The IEEE conference on computer vision and pattern recognition (CVPR) workshops*, Vol. 1, p. 4, 2017.
- 20) Wenzhe Shi, Jose Caballero, Ferenc Huszár, Johannes Totz, Andrew P Aitken, Rob Bishop, Daniel Rueckert, and Zehan Wang. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1874–1883, 2016.
- 21) Amlaan Bhoi. Monocular depth estimation: A survey. *arXiv preprint arXiv:1901.09402*, 2019.