

機械学習による月面DEMの高解像化

小野寺 康祐¹ 井上 博夏² 山本 光生² 山本 幸生²
大嶽 久志² 荒木 徹也³ 廣田 雅治⁴ 石川 博³

1. 首都大学東京システムデザイン学部
2. 宇宙航空研究開発機構
3. 首都大学東京システムデザイン研究科
4. 岡山理科大学

目次

1. 研究背景と目的
2. 手法
3. 実験
4. 今後の展望とまとめ

目次

1. 研究背景と目的
2. 手法
3. 実験
4. 今後の展望とまとめ

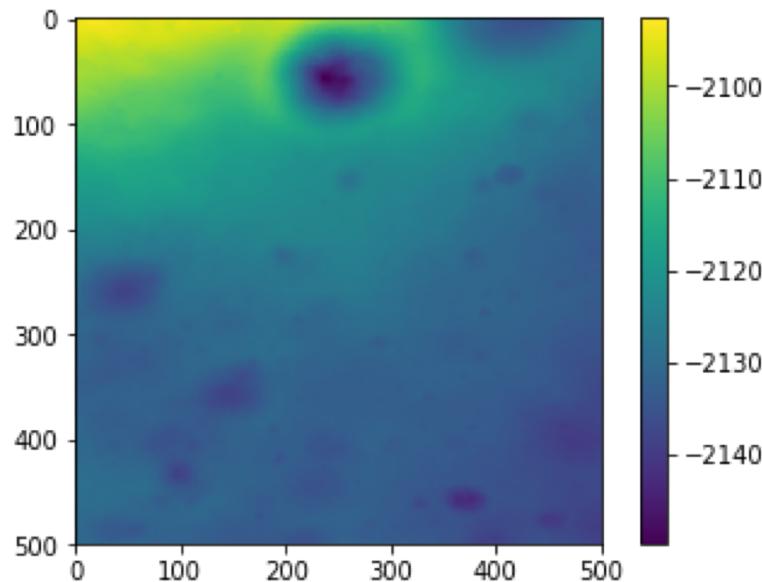
研究背景

月面探査機の**着陸地点**や**走行経路の検討**には
月面の**数値標高モデル(DEM)**が用いられる

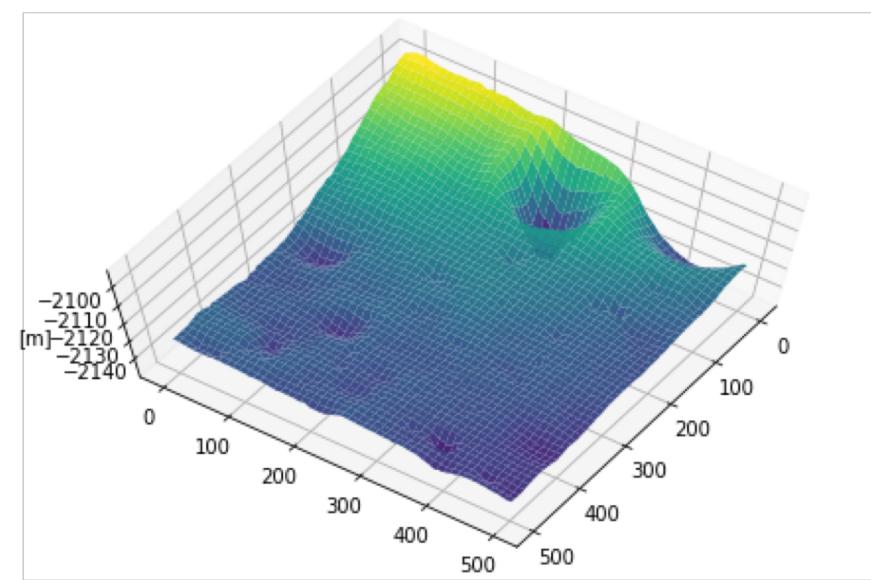
DEM(Digital Elevation Model)

→ 座標を表すピクセルごとに標高値を持つデータ

研究背景



DEMの可視化例(2D)

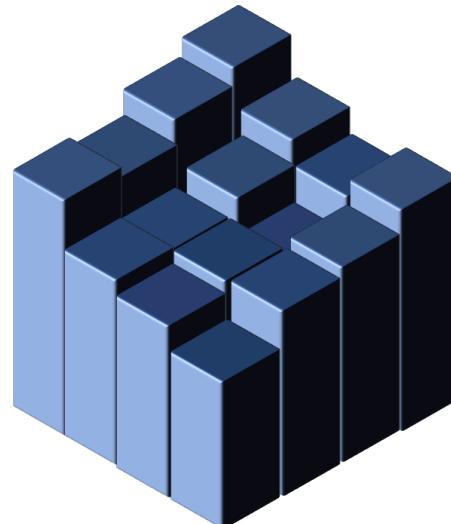


DEMの可視化例(3D)

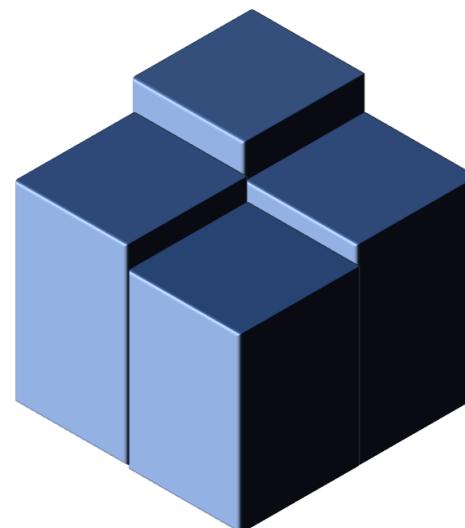
研究背景

DEMを用いる際、高解像度なDEMでなければ詳細な地形を把握することができない

高解像度 ⇒ ピクセルの大きさが小さく範囲あたりのデータ密度が高い



高解像度なDEMの
イメージ



低解像度なDEMの
イメージ

月面の高解像度DEMの問題点

- 月面の一部分しか公開されていない
- 人手を要する手法を用いて作成する必要があり、
高いコストがかかる

研究の目的

深層学習の技術を用いて人手を介さない
方法で月面の高解像度のDEMを生成する

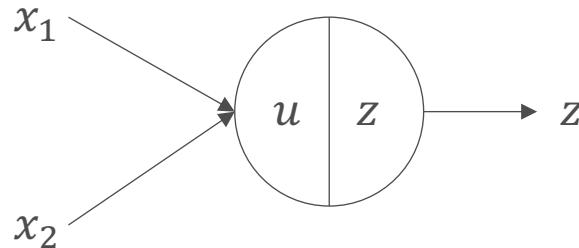
目次

1. 研究背景と目的
2. 手法
3. 実験
4. 今後の展望とまとめ

深層学習の概要

多層のニューラルネットワークを用いた 機械学習の一手法

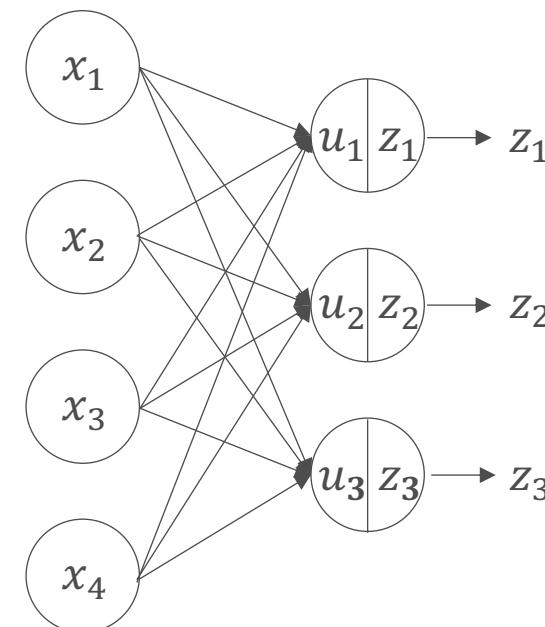
x_1, x_2 : 入力 w_1, w_2 : 重み
 b : バイアス f : 活性化関数



$$u = w_1x_1 + w_2x_2 + b$$

$$z = f(u)$$

ユニットの入出力例



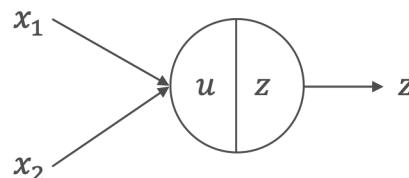
2層のニューラルネットワーク

深層学習の概要

学習方法

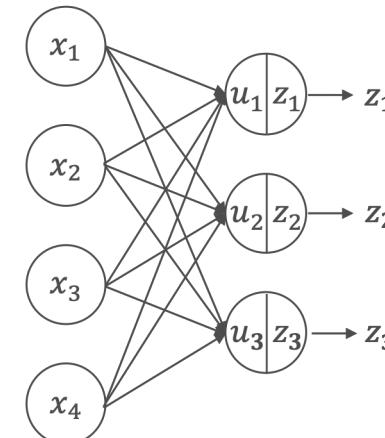
- 入力とするデータ x と、それに対する望ましい出力 d のペアを用意する
- x をネットワークに与えた際に、出力 z ができる限り d に近づくように各ユニットの重みとバイアスを調整することで学習
- z と d の近さを測る尺度を損失関数と呼ぶ

x_1, x_2 : 入力 w_1, w_2 : 重み
 b : バイアス f : 活性化関数



$$u = w_1x_1 + w_2x_2 + b$$
$$z = f(u)$$

ユニット一つの入出力



2層のニューラルネットワーク

畳み込みニューラルネットワーク

- 畳み込みニューラルネットワーク
(Convolutional Neural Network; CNN)
 - 主に画像認識などに用いられるニューラルネットワークの一種
 - 入力に対してフィルタ処理を行い特徴マップを得る
 - 一般的なフィルタ処理：平滑化，エッジ検出など
⇒ あらかじめ重みを設計したフィルタによる処理
 - CNNではフィルタの重みを訓練データから自動で学習することができる

畳み込み層と逆畳み込み層

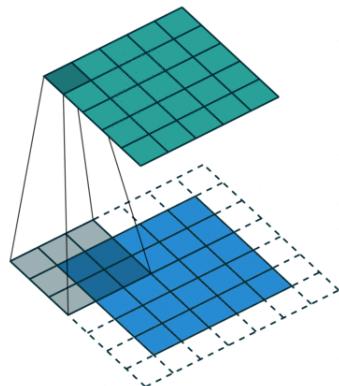
本研究で使用するCNNの処理である畳み込み層と逆畳み込み層の概要

- 畳み込み層：

入力に対してフィルタをかけ特徴マップを出力する

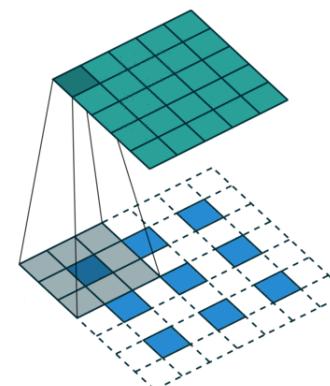
- 逆（転置）畳み込み層：

入力を拡大してから畳み込み処理を行う



畳み込み

(padding, no strides)



逆畳み込み

(padding, no strides)

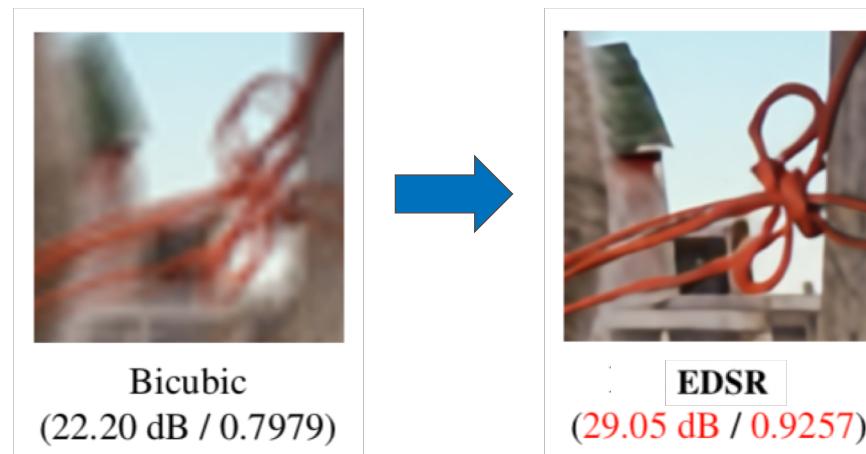
青：入力 緑：出力

関連研究

本研究と類似した目的を持つ画像の超解像という研究が存在

□ 画像の超解像

- 低解像度の画像から高解像度の画像を生成することを目的とした研究
- 近年では畳み込みニューラルネットワークによる手法によって高い性能を実現している



Lim, Bee, et al. "Enhanced deep residual networks for single image super-resolution." The IEEE conference on computer vision and pattern recognition (CVPR) workshops. Vol. 1. No. 2. 2017.

本研究への適用

DEMは画像と同様にピクセルごとに値を持つデータ
であるのでCNNを適用可能



画像の超解像と同様に、解像度の低さが原因で失われた地形の情報を推定できるのではないか

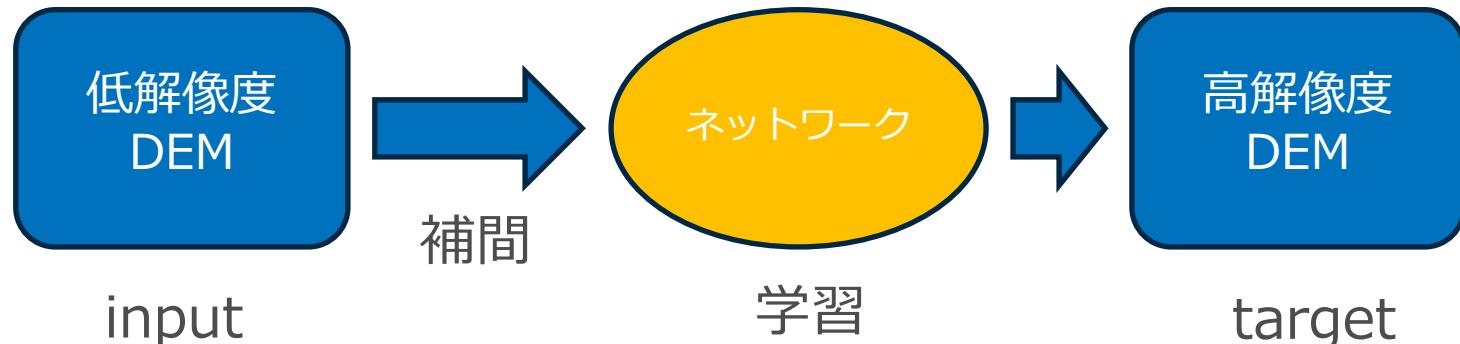


実験により検証

手法

新たに入力された低解像度DEMの解像度を向上させるようなネットワークを作成する

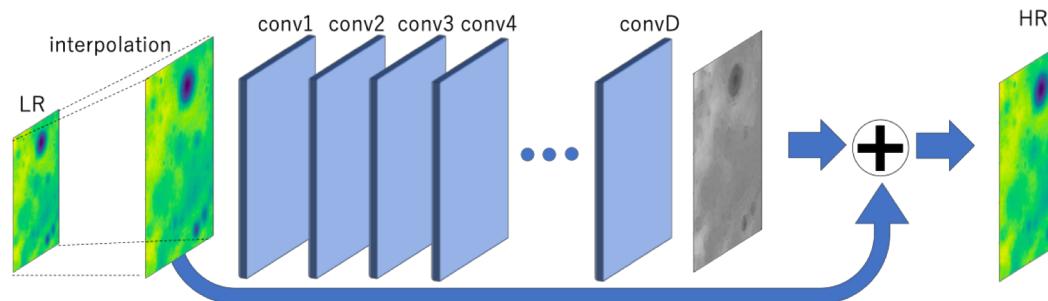
1. 同じ座標の低解像度DEMと高解像度DEMを用意
2. 低解像度DEMを高解像度DEMと同等の密度になるように補間
3. 補間したDEMを入力データ，高解像度DEMを目標データとしてCNNによるモデルを学習



参考モデル1 - VDSR

- Accurate Image Super-Resolution Using Very Deep Convolutional Networks

- Kim, Jiwon, Jung Kwon Lee, and Kyoung Mu Lee
- CVPR 2016

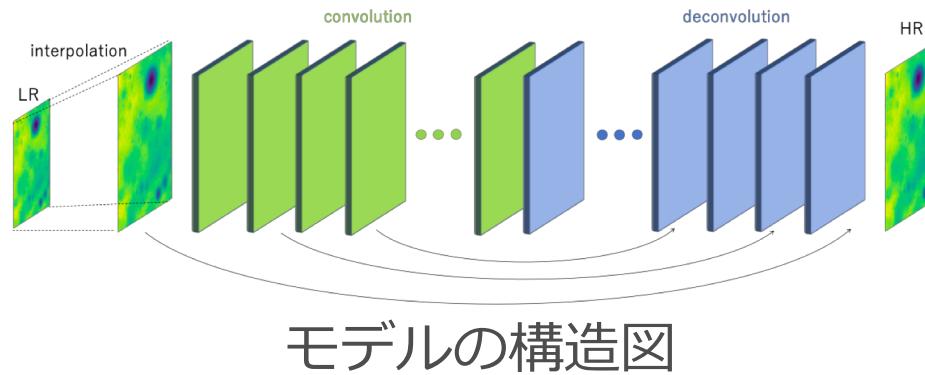


モデルの構造図

- 既存のモデルと比較して、深い層のネットワークを用いることで高い性能を実現
- 最終層で入力を足し合わせる
 - 入力に対しての差のみを学習させることにより早い収束を実現

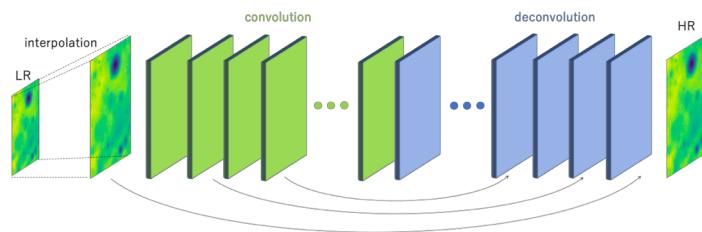
参考モデル2 - RED

- Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections
 - Mao, Xiaojiao, Chunhua Shen, and Yu-Bin Yang
 - NIPS'16

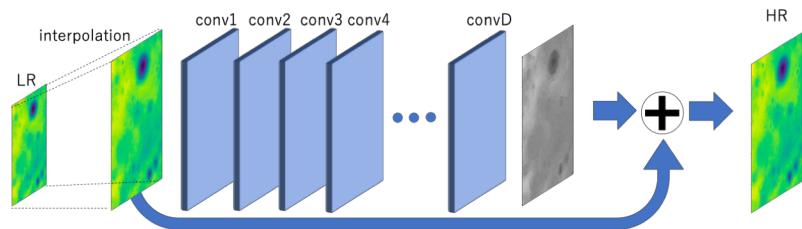


- 対称的な畳み込み層部と逆畳み込み層部からなる超解像やノイズ除去を含む画像復元を実現するモデル
- 2層ごとに畳み込み層と逆畳み込み層を接続（加算）
 - 畳み込みによって失われる元データに近い情報を保持
- 畳み込み層側では抽象的な特徴の抽出を、逆畳み込み層側では得られた特徴からの画像の復元を学習

実験に使用したモデル



REDの構造図



VDSRの構造図

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

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

- Type : 層の種類
 - Convolution, Deconvolution, Add
- Activation : 活性化関数
 - ReLU(正規化線形関数)
- 損失関数 : MSE(平均二乗誤差)
- Optimizer : Adam

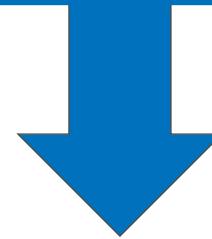
目次

1. 研究背景と目的
2. 手法
3. 実験
4. 今後の展望とまとめ

実験内容

同じ座標の低解像度DEMと高解像度DEMを用意

低解像度のDEMに各手法を適用



適用した結果と高解像度のDEMの誤差を評価

評価

比較対象

地球のDEMに対して一般的に適用される補間手法などと比較

- スプライン補間
- Akima補間
- 最近傍補間
- 線形補間

評価指標

既存の研究でDEMの補間の性能評価に用いられている平均誤差と最大誤差を評価指標として使用

参考文献

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.

データセット

- 低解像度DEM：SLDEM2013¹
 - 解像度：約 7.4 m/pix
- 高解像度DEM：LRO NAC DEM²
 - 解像度：約 2 m/pix
- サイズ：500×500 pix
- データ数
 - トレーニングデータ : 16,000ペア
 - バリデーションデータ : 4,000ペア
 - テストデータ : 4,000ペア

[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] Robinson, M. S. M. S., Brylow, S. M. S. M., Tschimmel, M., Humm, D., Lawrence, S. J. S. J., Thomas, P. C. P. C., … Hiesinger, H. (2010). Lunar Reconnaissance Orbiter Camera (LROC) Instrument Overview. Space Science Reviews, 150(1), 81–124.

実験結果

青：一般的な補間手法 赤：CNNを用いた手法

	平均平均誤差 [m]	平均最大誤差 [m]	平均処理時間[ms]		平均平均誤差 [m]	平均最大誤差 [m]	平均処理時間[ms]
スプライン補間	5.1436	17.4075	174.8834	VDSR(最近傍補間)	5.0498	17.4673	308.0614
Akima補間	5.1422	17.3667	149.1344	VDSR(線形補間)	5.0392	16.9617	186.0215
最近傍補間	5.1572	17.8092	237.6935	RED(スプライン補間)	5.0431	17.0997	199.5647
線形補間	5.1396	17.3109	102.9666	RED(Akima補間)	5.0554	17.1397	207.3846
VDSR(スプライン補間)	5.0426	17.0763	250.3660	RED(最近傍補間)	5.0591	17.5657	260.9077
VDSR(Akima補間)	5.0413	17.0447	225.4870	RED(線形補間)	5.0387	16.9942	130.3407

小数点以下第5位で四捨五入

- CNNを用いた手法の括弧による表記は低解像度DEMの補間に用いた補間手法
- 平均平均誤差：
各DEMのペアにおけるピクセルごとの誤差の平均値をデータセット全体で平均
- 平均最大誤差：
各DEMのペアにおけるピクセルごとの誤差の最大値をデータセット全体で平均
- 平均処理時間：
DEM一つあたりの平均処理時間

実験結果 – 一般的な補間手法

	平均平均誤差 [m]	平均最大誤差 [m]	平均処理時間[ms]
スプライン補間	5.1436	17.4075	174.8834
Akima補間	5.1422	17.3667	149.1344
最近傍補間	5.1572	17.8092	237.6935
線形補間	5.1396	17.3109	102.9666

- 全ての評価指標について線形補間が最も良い性能
- 全体的には
線形補間>Akima補間>スプライン補間>最近傍補間

実験結果 – CNNによる手法

	平均平均誤差 [m]	平均最大誤差 [m]	平均処理時間[ms]
VDSR(スプライン補間)	5.0426	17.0763	250.3660
VDSR(Akima補間)	5.0413	17.0447	225.4870
VDSR(最近傍補間)	5.0498	17.4673	308.0614
VDSR(線形補間)	5.0392	16.9617	186.0215
RED(スプライン補間)	5.0431	17.0997	199.5647
RED(Akima補間)	5.0554	17.1397	207.3846
RED(最近傍補間)	5.0591	17.5657	260.9077
RED(線形補間)	5.0387	16.9942	130.3407

- 平均平均誤差 : 線形補間を用いたRED
- 平均最大誤差 : 線形補間を用いたVDSR
- RED, VDSRのどちらにおいても線形補間が最も良い性能
⇒ 低解像度DEMの拡大に用いる手法も性能に影響

実験結果

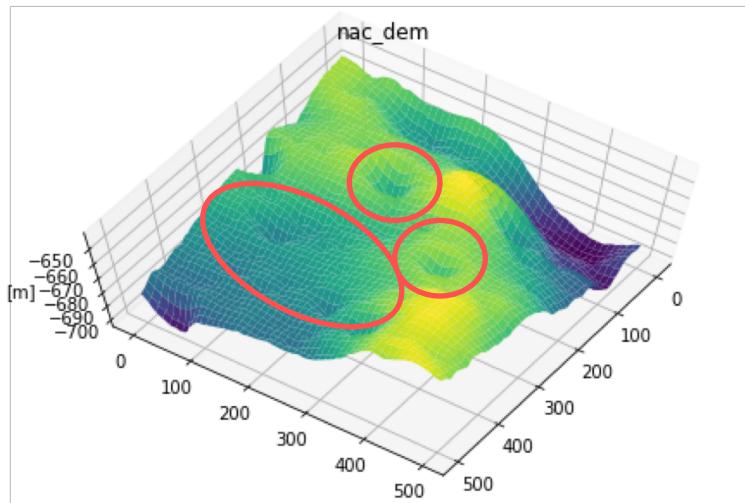
青：一般的な補間手法 赤：CNNを用いた手法

	平均平均誤差 [m]	平均最大誤差 [m]	平均処理時間[ms]		平均平均誤差 [m]	平均最大誤差 [m]	平均処理時間[ms]
スプライン補間	5.1436	17.4075	174.8834	VDSR(最近傍補間)	5.0498	17.4673	308.0614
Akima補間	5.1422	17.3667	149.1344	VDSR(線形補間)	5.0392	16.9617	186.0215
最近傍補間	5.1572	17.8092	237.6935	RED(スプライン補間)	5.0431	17.0997	199.5647
線形補間	5.1396	17.3109	102.9666	RED(Akima補間)	5.0554	17.1397	207.3846
VDSR(スプライン補間)	5.0426	17.0763	250.3660	RED(最近傍補間)	5.0591	17.5657	260.9077
VDSR(Akima補間)	5.0413	17.0447	225.4870	RED(線形補間)	5.0387	16.9942	130.3407

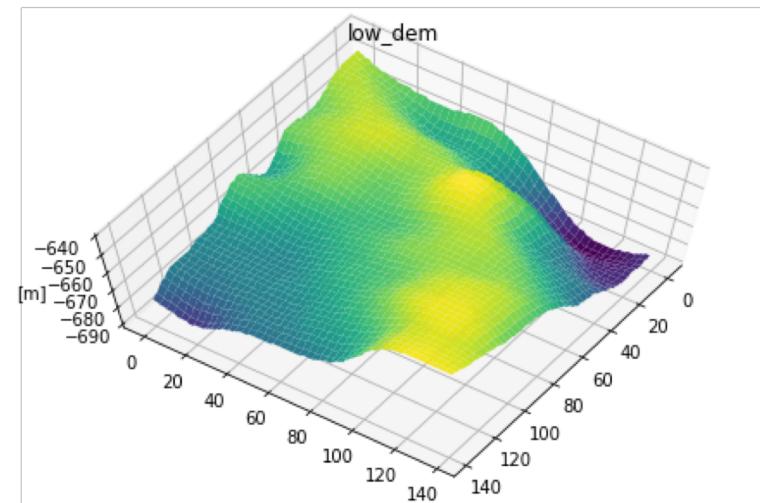
小数点以下第5位で四捨五入

- 各評価指標において最も性能が良かった手法
 - 平均平均誤差：線形補間を用いたRED
 - 平均最大誤差：線形補間を用いたVDSR
 - 平均処理時間：線形補間
- 平均平均誤差、平均最大誤差の両方において、CNNを用いた手法が最も誤差が小さかった
- CNNによる手法は処理に補間手法も用いているため、その分処理にかかる時間が長くなっている

可視化例 – 高解像度DEMと低解像度DEM



高解像度DEM

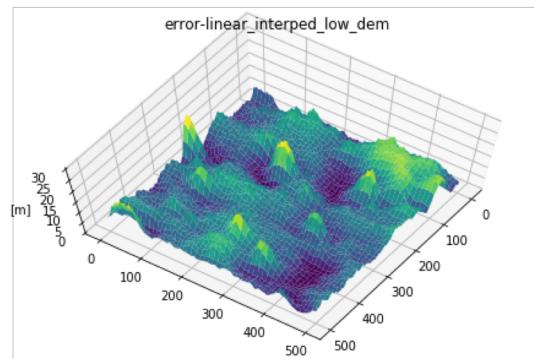


低解像度DEM

高解像度DEMに対して低解像度DEMでは
標高の変化が急な地形の情報が失われている

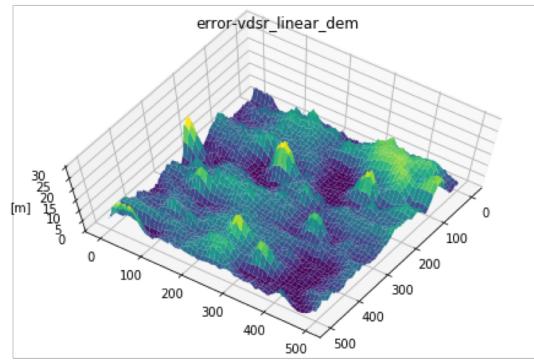
可視化例 – 誤差の可視化

誤差(大)

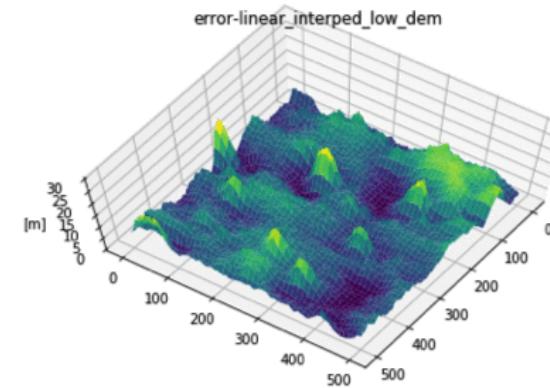


線形補間

誤差(小)



VDSR(線形間補間)

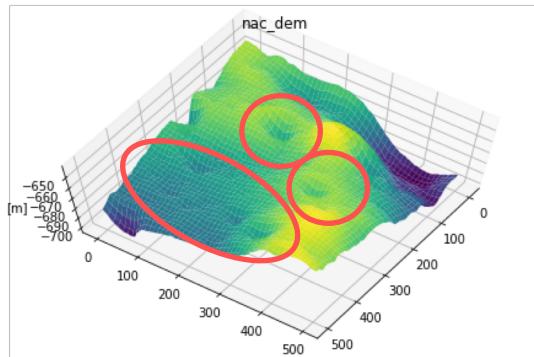


線形補間

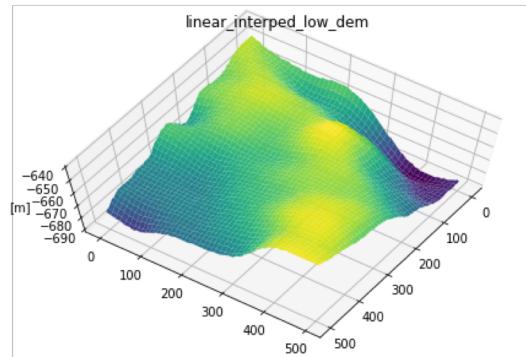
アニメーションによる比較

CNNによる手法の方が
全体的に誤差が
小さくなっている

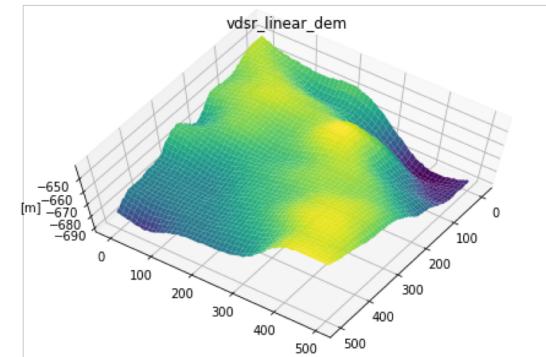
可視化例 – 生成されたデータの可視化



高解像度DEM



線形補間



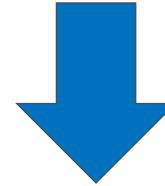
VDSR(線形間補間)

一般的な補間手法, CNNによる手法のどちらにおいても
標高の変化が急な地形の推定はできていなかった

実験結果のまとめ

- CNNによる手法の方が全体的に誤差が小さくなった
 - 低解像度DEMと高解像度DEM間の大域的な差のパターンを学習することができていると考えられる

- 標高の変化が急な地形の推定はできなかった
 - 低解像度DEMと高解像度DEM間の局所的な差のパターンを学習することができていないと考えられる



原因考察

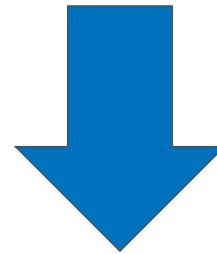
低解像度DEMと高解像度DEMの地形の差から学習するだけでは、標高の変化が急な地形を推定するためには情報が不足していることが原因と考えられる

目次

1. 研究背景と目的
2. 手法
3. 実験
4. 今後の展望とまとめ

今後の展望

現状では推定が難しい
標高の変化が急な地形の推定を可能にする

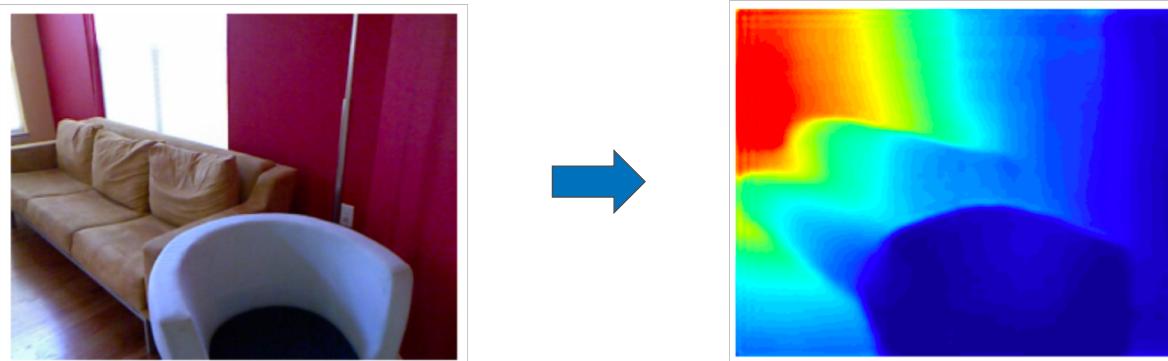


月面画像を用いることで
月面の地形の情報を得る など

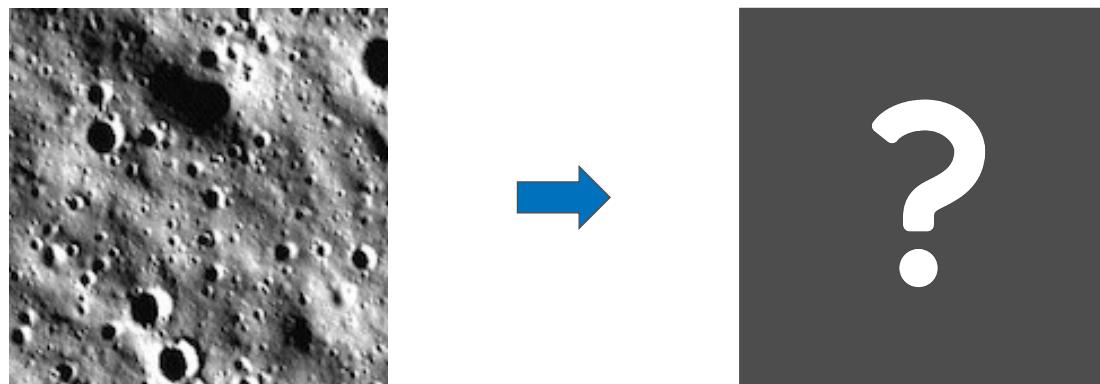
参考にできそうな研究例

□ 深度推定

- 1枚の画像から奥行きを推定することを目的とした研究



LAINA, Iro, et al. Deeper depth prediction with fully convolutional residual networks. In: *3D Vision (3DV), 2016 Fourth International Conference on*. IEEE, 2016. p. 239-248.



月面画像にも
適用可能？

まとめ

- 深層学習による月面の高解像度DEMの生成を検証
- CNNによる手法は一般的な補間手法よりも良い性能を示した
- 今回用いた手法においては標高の変化が急な地形の推定はできなかった
- 今後の課題として、現状では推定が難しい標高の変化が急な地形の推定を可能とすることが挙げられる