

敵対的生成ネットワークを用いた 月面の高解像度DEMの生成

小野寺 康祐¹ 山本 幸生² 荒木 徹也³ 石川 博⁴

1. 東京都立大学大学院 システムデザイン研究科
2. 宇宙航空研究学開発機構
3. 群馬大学
4. 東京都立大学

目次


1. 研究背景と目的
2. CNNを用いた超解像手法
3. GANを用いた手法
4. 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



DEMの可視化例(2D)




DEMの可視化例(3D)


研究背景

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を用いる際の問題点

- 高解像度のDEMは**月面の一部のものしか公開されていない**
- 高解像度のDEMは、専門的な知識を持った作業者が**人手で時間をかけて作成**する必要がある
- 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ない

研究の目的

低解像度のDEMは月の全球分存在



低解像度のDEMを用いて**人手を介さない**
方法で高解像度のDEMを生成

目次

1. 研究背景と目的
2. CNNを用いた超解像手法
3. GANを用いた手法
4. まとめ


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可能

画像の超解像

- 入力された低解像度の画像から高解像度の画像を生成
- 近年ではCNNによる手法によって高い性能を実現




Bicubic
(22.20 dB / 0.7979)



EDSR (Ours)
(29.05 dB / 0.9257)

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.

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



CNNを用いた画像の超解像手法を応用し、
解像度の低さが原因で失われた地形を推定可能か検証

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


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と同等の解像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



使用モデル1 - VDSR

□ Accurate Image Super-Resolution Using Very Deep Convolutional Networks

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

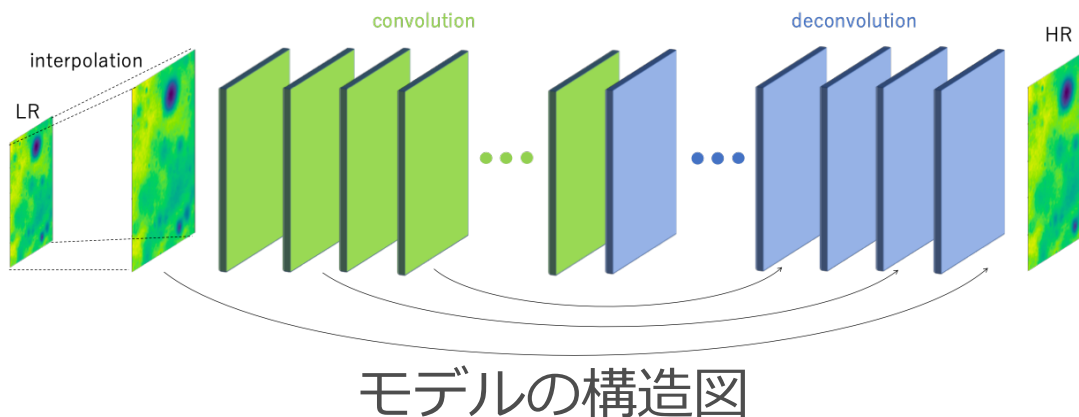


モデルの構造図

- それまで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した超解像モデル
- 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

使用モデル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

評価方法

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と比較し評価

- 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

古舘守通, 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 件
 - バリデーションデータ : 4,000 件
 - テストデータ : 4,000 件

[1]坪内彩音, 篠田玲奈, 郭哲也, 後藤祐紀, 春山純一, 三宅亙. 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.宇宙科学情報解析論文誌, Vol. 8, pp. 1-10 (2019.3), 2016.

[2] ROBINSON, M. S., et al. Lunar reconnaissance orbiter camera (LROC) instrument overview. Space science reviews, 2010, 150.1-4: 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]		平均平均誤差 [m]	平均最大誤差 [m]
スプライン補間	5.1436	17.4075	VDSR(最近傍)	5.0498	17.4673
Akima補間	5.1422	17.3667	VDSR(線形補間)	5.0392	16.9617
最近傍補間	5.1572	17.8092	RED(スプライン)	5.0431	17.0997
線形補間	5.1396	17.3109	RED(Akima)	5.0554	17.1397
VDSR(スプライン)	5.0426	17.0763	RED(最近傍)	5.0591	17.5657
VDSR(Akima)	5.0413	17.0447	RED(線形)	5.0387	16.9942

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

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]		平均平均誤差 [m]	平均最大誤差 [m]
スプライン補間	5.1436	17.4075	VDSR(最近傍)	5.0498	17.4673
Akima補間	5.1422	17.3667	VDSR(線形補間)	5.0392	16.9617
最近傍補間	5.1572	17.8092	RED(スプライン)	5.0431	17.0997
線形補間	5.1396	17.3109	RED(Akima)	5.0554	17.1397
VDSR(スプライン)	5.0426	17.0763	RED(最近傍)	5.0591	17.5657
VDSR(Akima)	5.0413	17.0447	RED(線形)	5.0387	16.9942

小数点以下第5位で四捨五入


平均誤差，最大誤差の両方において，CNNを用いた手法の誤差が最小

一般的な補間手法より正確な標高値を推定可能

高解像度DEMと低解像度DEMの例




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


生成されたDEMの例



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を用いた手法は補間手法より正確な標高値を推定可能
- 標高の変化が急な地形の推定はできなかった

原因考察

- データセットにおいて小さな凹凸が失われているパターンのデータの不足
- 平均的に誤差が小さい結果を推定しようとするため、低解像度DEMに存在しない地形の推定が困難

GAN (Generative Adversarial Network) を取り入れた手法を用いることで解決を試みる

目次

1. 研究背景と目的
2. CNNを用いた超解像手法
3. GANを用いた手法
4. まとめ


画像の超解像におけるGAN



Ledig, Christian, et al. "Photo-realistic single image super-resolution using a generative adversarial network." Proceedings of the IEEE conference on computer vision and pattern recognition. 2017.

GANを用いた画像の超解像手法の例


従来のCNNによる超解像手法(左から2番目)とGANを取り入れた手法(左から3番目)を比較すると、GANを取り入れた手法はより細部が際立った結果となっている



DEMの生成にGANを適用した場合にも、細部(標高の変化が急な地形)が際立つような結果を推定できるかを検証

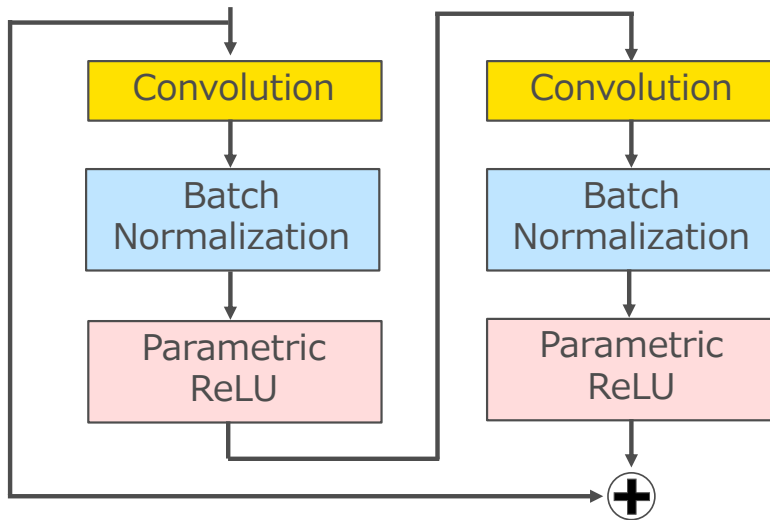
手法

- 入力された低解像度DEMから高解像度DEMを生成するGenerator(生成器)と、生成器が生成した結果と本物の高解像度DEMを分類するDiscriminator(識別器)を用意
- 以下の処理を繰り返し、生成器が本物に似た結果を生成できるよう学習
 - 生成器を用いて生成したDEMと本物の高解像度DEMを用いて識別器を学習
 - 生成結果を識別器に入力した際に、本物の高解像度DEMと分類されるように生成器を学習（この際識別器は学習させない）

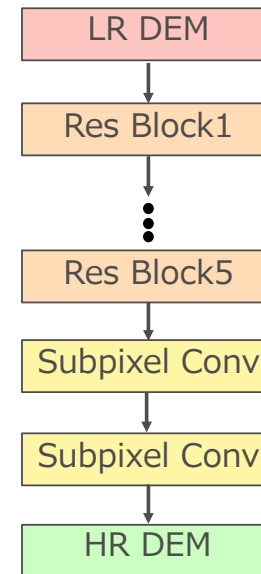


モデル - 生成器

- Residual Blockを重ねた構造
 - 畳み込み層とBlockへの入力を足し合わせる構造
 - 活性化関数としてバッチ化正規化層とParametric ReLUを使用
- Subpixel Convolutionを用いてモデル内の後半でデータを拡大
 - モデル内で大きなサイズのデータを扱わずに済み, 学習が高速化
 - 今回は2倍の拡大を2回行い, 入力サイズの4倍のサイズのDEMを生成




Residual Blockの概要図



モデル全体の概要図

Subpixel Convolution


- 特徴量を拡大する手法の一種
 - 他の類似手法の例：Upsample, Deconvolution
- 畳み込みによって得た複数チャンネルの特徴マップを並べ、単一チャンネルの特徴マップとすることで拡大
- 高速に拡大処理ができる一方で、生成結果において格子状のパターン (checkerboard artifact) が現れやすくなる




Shi, Wenzhe, et al. "Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.

ICNR


- 格子状のパターンの発生を抑えるためにICNRを使用
- 未学習のSubpixel Convolutionにデータを入力すると、格子状のパターンが発生
 - 最終的な生成結果においても格子状のパターンが発生しやすくなる
- ICNRを用いて層の初期化をすることで、初期の発生をある程度抑えることが可能



low resolution dem



sub-pixel convolution

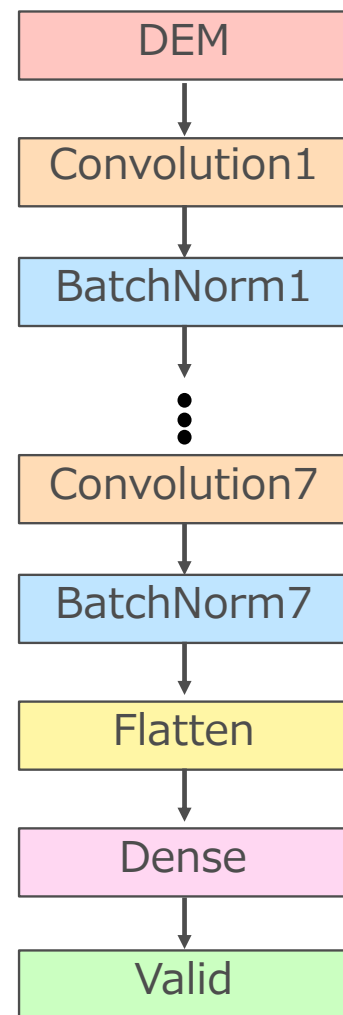


ICNR

Aitken, Andrew, et al. "Checkerboard artifact free sub-pixel convolution: A note on sub-pixel convolution, resize convolution and convolution resize." arXiv preprint arXiv:1707.02937 (2017).

モデル - 識別器

- 畳み込み層とバッチ正規化層を交互に重ねた構造
- 活性化関数をsigmoidとした最終層で，入力されたDEMが訓練データに含まれている確率を得る



モデル全体の概要図

実験条件

□ データセット

- 高解像度DEM : 256×256 pix
- 低解像度DEM : 64×64 pix

□ データ数

- トレーニングデータ : 32,000 件
- バリデーションデータ : 1,000 件
- テストデータ : 8,000 件

□ バッチサイズ : 16

□ イテレーション : 130,000

- イテレーション毎に, トレーニングデータからバッチサイズ分のデータを取り出して学習
- データに対して左右反転と回転を適用することでデータを水増し

□ 識別器の学習一回につき生成器を三回学習

- 識別器の性能が生成器の性能に対して高くなりすぎることを防ぐため

実験結果

手法	平均平均誤差 [m]	平均最大誤差 [m]	平均ZNCC
線形補間	4.341	12.872	0.864
モデル	4.646	14.581	0.880

小数点以下第3位で四捨五入

- 前回の実験において用いた補間手法のうち、最も性能が良かった線形補間と比較して評価
- 評価指標に正規化相互相関（ZNCC）を追加
 - 主に画像の類似度評価に用いられる手法
 - 1に近いほど正解データに類似している
 - 生成結果の可視化と併せて、探査機の着陸地点の選定などに重要な地形の再現度の評価に使用

実験結果

手法	平均平均誤差 [m]	平均最大誤差 [m]	平均ZNCC
線形補間	4.341	12.872	0.864
モデル	4.646	14.581	0.880


小数点以下第3位で四捨五入

□ ZNCCは線形補間より良い性能

- より正解データに近い地形を生成できている

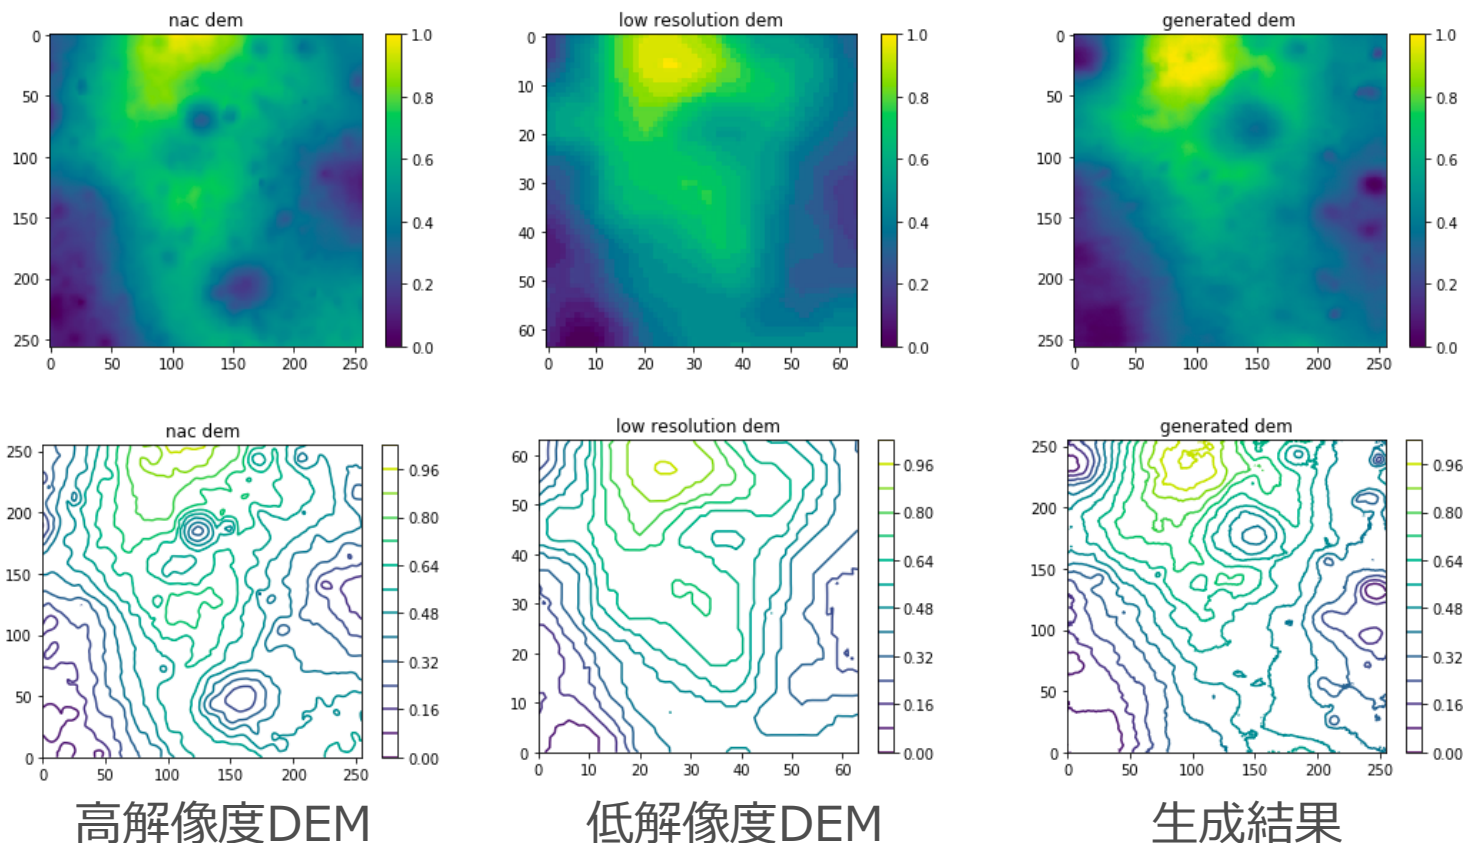
□ 誤差の性能は低下

- 超解像においては知覚品質と歪みのトレードオフが示されている
- GANを用いた手法により知覚品質が高い結果を得られた一方で、歪みが大きくなったことが原因



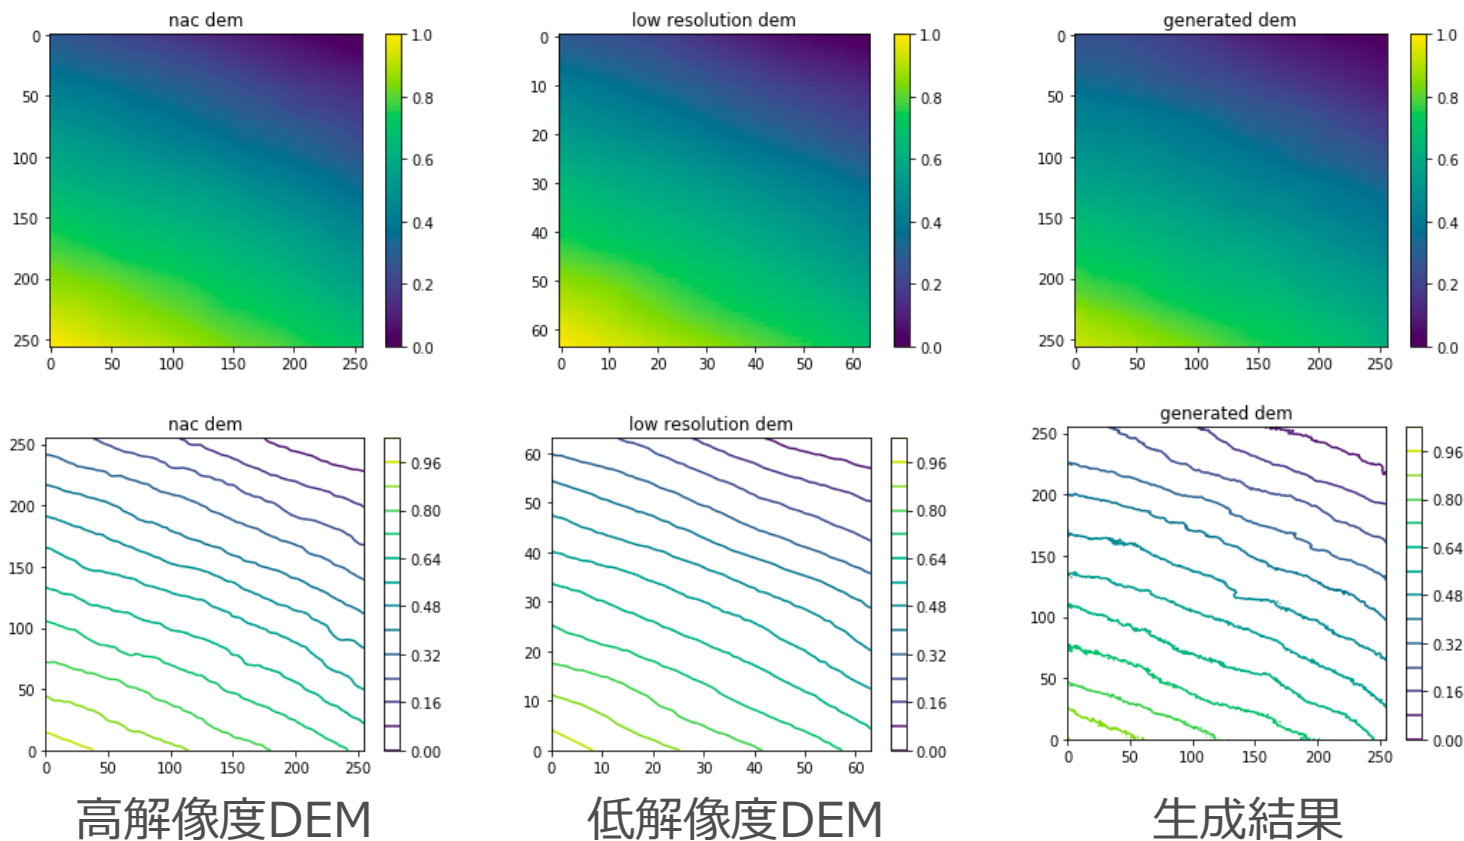
Blau, Yochai, and Tomer Michaeli. "The perception-distortion tradeoff." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018.

実験結果 – 可視化 1



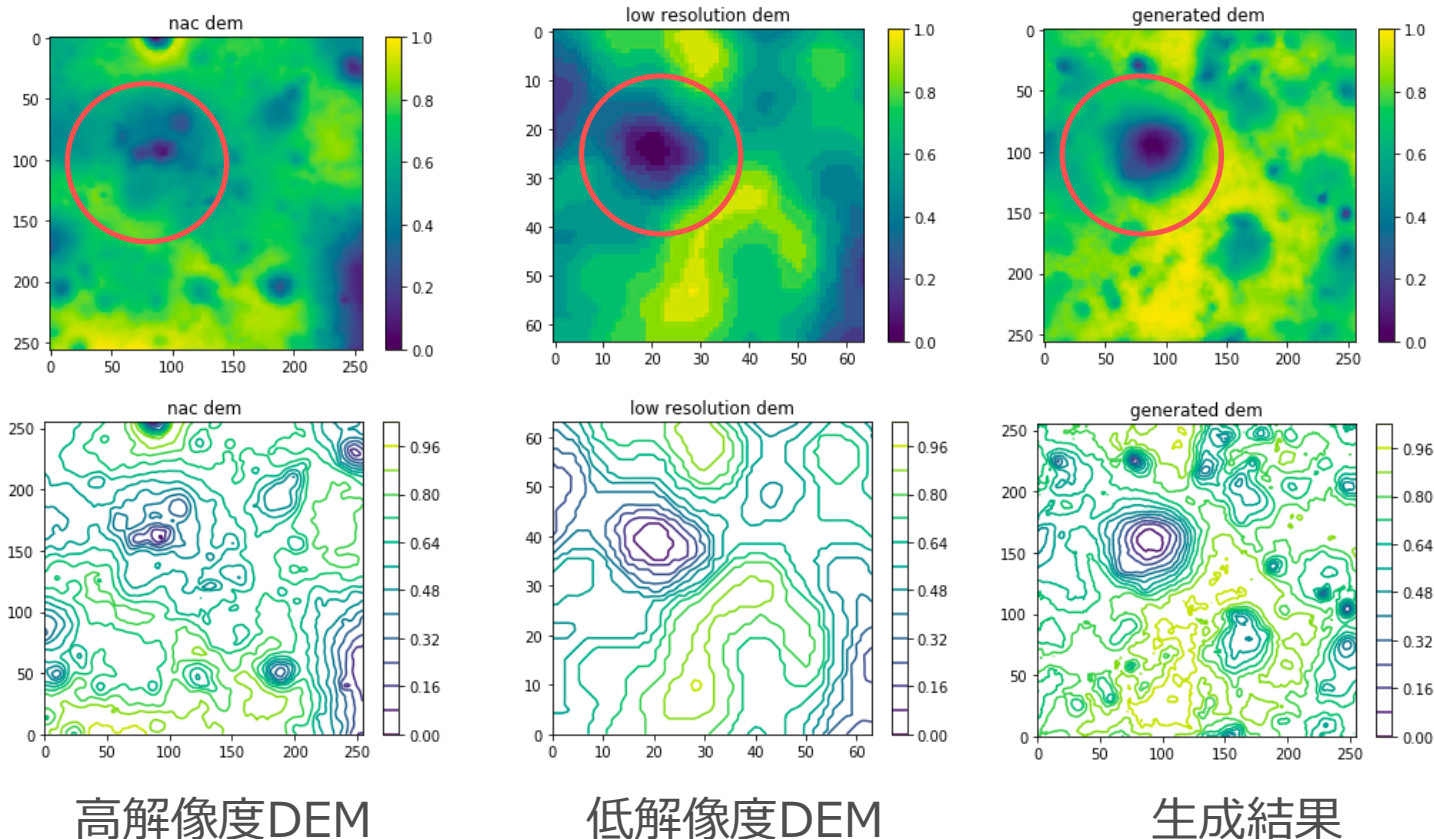
- CNNを用いた手法では困難であった，低解像度DEMには存在しない地形の推定が実現
- 高解像度DEMに類似した傾向の地形を生成できている

実験結果 – 可視化2



- 低解像度DEM, 高解像度DEMの両者共に滑らかな地形の例
- 一つ目の例のように小さなクレーター等を推定することなく, 適切に地形を生成できている

実験結果 – 可視化3



- 低解像度DEMと高解像度DEMで大きく乖離している地形が存在する例
- 小さなクレーターなどは高解像度DEMと似た傾向で生成できているが、乖離している地形については適切に生成することが難しい

目次

1. 研究背景と目的
2. CNNを用いた超解像手法
3. GANを用いた手法
4. まとめ

まとめ

- 月面の低解像度のDEMから高解像度のDEMを生成する手法を提案

- GANを用いた手法においては、より高解像度DEMに類似した結果を生成可能なことを示した
 - 低解像度のDEMにおいては存在しない地形の推定を可能とした

- 今後の展望
 - 誤差の性能とZNCCの性能の両立
 - 低解像度DEMと高解像度DEMの地形が大きく乖離している場合における地形生成の改善
 - クレーターなどの地形生成の定量的な評価