

# 深層学習を用いたリュウグウ表面のボルダー自動検出 およびその大きさ・形状分布の計測

関すおみ<sup>1,2</sup>, 神山徹<sup>2</sup>, Xuanchao Fu<sup>1,2</sup>, Wenhao Shen<sup>1,2</sup>, 吉川一朗<sup>1</sup>

(<sup>1</sup>東京大, <sup>2</sup>産総研)

小惑星の歴史を考察する上で、その表面上に分布するボルダーの大きさや形状は、小惑星の起源や進化の条件に制約を与える重要な指標である。Michikami et al. [1] ははやぶさ 2 の光学航法カメラが撮影したリュウグウの画像 14 枚を用いて 16,000 個のボルダーを数え上げ、ボルダーサイズ頻度分布やボルダーの三軸比を調査した。そしてボルダーは主に母天体の衝突破壊により形成されたと結論づけ、画像ごとにボルダーの流入や形成過程が異なるという示唆を得た。

ボルダーを数え上げ、大きさや形状を計測することはリュウグウの歴史を考察する上で重要だが、手作業での計測は効率が悪く、リュウグウ全域を調査し地域依存性を明らかにすることは難しい。そこで本研究では、深層学習の手法を導入し、画像中のボルダーの検出ならびに形状・大きさの計測を自動化する。とくにボルダー検出と大きさ・形状計測の両方を実現する Instance Segmentation という手法に注目した。また深層学習モデルの訓練に必要なボルダー検出に適した十分な枚数の教師データは存在しなかったため、ボルダーを個別に識別したデータを用意した。

用意した 100 枚の教師データを用いて Instance Segmentation の代表的なモデルである Mask R-CNN の訓練を行い、個々のボルダーを自動検出できること、ボルダーの大きさ・形状を取得できることを確認した。また 23 枚の画像に対して訓練したモデルを用いて推論を行ったところ、サイズ頻度分布は Michikami et al [1] 同様にべき乗分布を示し、power-index も類似した値を示すことが確認できた。

従来手作業で計測していたボルダーのサイズ頻度分布や形状を深層学習の手法を用いて自動で取得し、先行研究[1]の結果と整合的なサイズ頻度分布が得られた。しかし数十ピクセル以下の小さなボルダーをはじめ、ボルダーの検出もれも確認できた。教師データの調整や Mask R-CNN のモデル構造を改良し、実寸で 1m 以下のボルダーを検出できるモデルを実現し、ボルダーサイズ頻度分布の地域依存性とその原因を調査する。

[1] Michikami, Tatsuhiro, et al. "Three-axial shape distributions of pebbles, cobbles and boulders smaller than a few meters on asteroid Ryugu." *Icarus* 381 (2022): 115007.



# 深層学習を用いたリュウグウ表面のボルダー自動検出 およびその大きさ・形状分布の計測

関すおみ<sup>1,2</sup>, 神山徹<sup>2</sup>, Xuanchao Fu<sup>1,2</sup>, Wenhao Shen<sup>1,2</sup>, 吉川一朗<sup>1</sup> (1東京大, 2産総研)

## 研究背景・目的

小惑星の歴史を考察する上で、その表面上に分布するボルダーの大きさや形状は、小惑星の起源や進化の条件に制約を与える。例えば衝突破壊によって形成された岩石の三軸比は $2:\sqrt{2}:1$ であることが衝突破壊実験から判明している[1]。小惑星が衝突破壊から直接形成されたものか否かを判断する際、ボルダーの三軸比は判断材料の一つになる。

小惑星リュウグウは母天体の衝突破壊の後、再集積して形成されたと考えられているため、ボルダーの大きさ・形状は形成過程を明らかにする重要な指標となる。Michikami et al.[2]ははやぶさ2の光学航法カメラ(ONC-T)が撮影した画像を用いて、リュウグウ表面のボルダーについてサイズ頻度分布と三軸比を調査した。14枚の近接画像から直径5cm~7mのボルダーを約16,000個抽出し、ボルダーは主に母天体の衝突破壊により形成されたと結論づけた。また画像ごとにボルダーのサイズ頻度分布の傾きが微妙に異なることから、地域によってボルダーの流入や形成過程が異なることが示唆された。

ONC-T v-bandの近接画像の総数は約300枚で、リュウグウ表面の広い範囲をカバーしている。様々な地域の表面画像から地域差を調べることは、形成過程を明らかにするために有効だが、Michikami et al.[2]では、ボルダーを手作業で抽出し計測・計数する手間が大きく、解析した画像は14枚にとどまっている。そこで本研究では、画像中のボルダー検出と大きさ・形状の計測を自動化する深層学習モデルを開発する。また開発したモデルを用いてリュウグウの複数の地域におけるボルダーのサイズ頻度分布と三軸比を比較し、リュウグウのボルダー分布に地域差が生じた原因を考察する。

## 手法

本研究ではボルダー検出と大きさ・形状計測の両方を実現するInstance Segmentationという深層学習の手法に注目した。本手法は物体検出後に領域分割を行うため、ボルダーを1つずつ検出し、同時にその大きさ・形状を捉えるのに適している。本研究ではInstance Segmentationの代表的なモデルであるMask R-CNN [4](図1)をボルダー検出に適用した。

深層学習モデルの訓練には十分な枚数の教師データが必要だが、ボルダー検出に適した大規模な教師データは存在せず、ボルダーを個別に識別したラベルデータを用意する必要があった。そこでONC-Tが高度5km以下から撮影した275枚の近接画像を使用し、30ピクセル以上のボルダーのラベル付けを行った(図2)。ラベルの総数は約15,000個であった。

また本研究ではボルダー検出に適した画像とラベルの教師データを公開することで、より精度の良いボルダー検出モデルの開発や、他の天体表面画像での追加解析を可能とする。



図1 Mask R-CNNの例




図2 教師データの例 (左)リュウグウの表面画像 (右)付与したラベル

## 実験結果

ラベル付けした100枚の教師データを用いてMask R-CNNの訓練を行い、個々のボルダーを自動検出できること、検出したボルダーを楕円で近似しボルダーの二軸比を計測できることを確認した(図3)。また23枚のONC-T画像に対して、訓練したモデルを用いて推論を行ったところ、サイズ分布はMichikami et al.[2]と同様にべき乗分布を示し(図4)power-indexも類似した値を示した(表1)。




図3 (左)入力画像 (中央)正解ラベル (右)学習モデルによる推論結果




図4 Mask R-CNNで検出したボルダーのサイズ頻度分布

表1 ボルダーのサイズ頻度分布 power-indexの比較

Michikami et al.	-2.22, -2.53, -2.18, -1.80, -2.38, -2.73, -3.13, -1.81
Our Results	-2.74, -2.75, -2.22, -1.87, -2.05, -1.86, -2.52, -2.08, -2.05, -1.20, -2.34, -1.27, -2.00, -2.15, -3.30, -3.09, -2.27, -2.40, -2.54, -2.58, -5.41, -3.57, -3.44

## 結論・今後の展望

従来手作業で計測していたボルダーのサイズ頻度分布や二軸比を、深層学習の手法を用いて自動で取得し、先行研究[2]の結果と統合的なサイズ頻度分布が得られた。しかし数十ピクセル以下の小さなボルダーをはじめ、ボルダーの検出もれも確認できた。教師データの調整やMask R-CNNのモデル構造を改良し、実寸で1m以下のボルダーを検出できるモデルを実現し、ボルダー分布の地域依存性とその原因を調査する。

またMichikami et al.[2]ではボルダーの影の長さを利用して高さを算出し、三軸比の評価に利用していた。高さの取得も自動化するため画像中の影の検出とその長さを評価する深層学習の手法も合わせて用いる。そしてONC-Tが撮影した全ての画像について、ボルダーのサイズ頻度分布と三軸比の取得を自動化する。