

超高解像度カメラ画像を用いた機械学習による粒度分布推定に関する基礎的研究

五洋建設株式会社 正会員 ○江守 辰哉

五洋建設株式会社 正会員 熊谷 隆宏

五洋建設株式会社 正会員 木井 敦夫

株式会社システム計画研究所 非会員 西岡 拳

株式会社システム計画研究所 正会員 平河 怜

1. はじめに

土の粒度分布は、地盤の締固め特性や透水性などを推定するための重要な指標の一つである。しかしながら、土の粒度試験（JIS A 1204）は、試験室で実施する必要があることから、盛土材や埋戻し材としての品質管理を高い頻度で実施することができず、搬入土の物性のばらつきによる締固め不足やオーバークompaction等の施工不良問題を生じることがある。そこで、生産性向上や造成する土構造物の品質向上のため、現地で簡便に搬入土の粒度分布を推定する方法として、超高解像度カメラ画像を用いた機械学習モデルによる粒度分析に関する試みを実施した。本稿では、機械学習モデルによる粒径分析手法と適用結果について報告する。

2. 粒径加積曲線の解析フロー

2.1 機械学習に基づく個別粒子の領域抽出（ステージ1）

本ステージでは、撮影画像から個別粒子を認識する機械学習モデルの構築（学習ステップ）と構築した機械学習モデルによる未学習の撮影画像に対する領域抽出（推定ステップ）を行った。

学習ステップでは、個々の撮影画像にアノテーション処理を実施することで教師データを作成し、教師データに基づく領域抽出の学習・検証を繰り返すことでパラメータの最適化を図った。

推定ステップでは、学習ステージで構築した機械学習モデルを用いて、未学習画像の個別粒子領域の抽出を実施し、その検出精度を定量的に評価した。

なお、本検討における機械学習モデルとして「Mask R-CNN」¹⁾の手法を採用した。これは、個々の物体の領域を1ピクセルごとに推定するインスタンスセグメンテーションに特化した学習モデルである。インスタンスセグメンテーションでは、個別のインスタンス領域マスクを区別してマスク推定を行うので、物体間の境界を判別するのに適している。図-2に学習モデル構造の概念図を示す。

2.2 画像処理による粒径分析（ステージ2）

本ステージでは、機械学習モデルによって抽出された個別粒子の凸領域の算出と楕円フィッティングにより、個別粒子の長径と短径を求め、次式を用いて個別粒子ごとに体積を算出した。また、横軸に代表粒径、縦軸に体積の累積比率をとって粒径加積曲線を推定し、粒度試験で得られている正解値と比較検討を行った。

$$V = \frac{4}{3} \cdot \pi \cdot a^2 \cdot b \quad (\text{式-1})$$

V ：粒子の体積， $2a$ ：粒子の短径， $2b$ ：粒子の長径

キーワード 機械学習，画像解析，粒度分布，生産性向上，高解像度画像

連絡先 〒329-2746 栃木県那須塩原市四区町 1534-1 五洋建設株式会社技術研究所 TEL:0287-39-2116

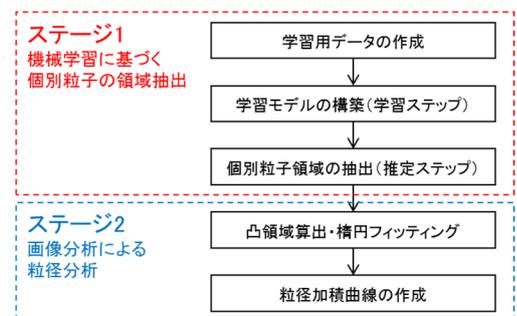


図-1 検討フロー

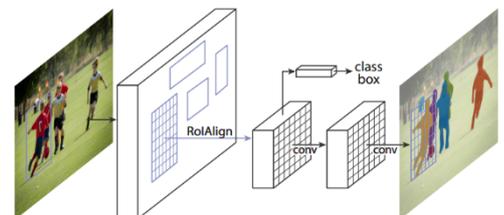


図-2 Mask R-CNNのモデル構造概念図¹⁾

表-1 粒径とピクセル数の関係

粒径(mm)	画素数(pixel)	分類
0.075	2	細砂
0.25	7	
0.425	12	中砂
0.85	24	
2	56	粗砂
4.75	133	細礫
19	532	中礫
26.5	742	粗礫
37.5	1050	

※XF IQ4 (1億5000万画素, 80mmレンズ) を使用

3. 使用材料および使用資機材

個別粒子領域の認識可能性を確認するため、クラッシャーラン（0~40mm）を撮影する地盤材料として選定した。また、撮影機材として、XF IQ4（PhaseOne 社製）を選定した。今回使用したカメラは1億5100万画素の解像度を有し、75 μ mの粒子を2ピクセルで表現することができ、理論上は砂分の検出まで可能であるとされている。表-1に粒径とピクセル数の関係を示す。

4. 検討結果および評価

4.1 機械学習に基づく個別粒子の領域抽出

アノテーション作業により設定した個別粒子領域（正解値）を図-3に、機械学習によって推定された個別粒子領域を図-4に示す。図中のハッチング部分が個別粒子領域として判定した箇所である。また、本検討での推定精度は、下式で表現される再現率（Recall）にて評価を行った。

$$Recall = \frac{TP}{TP + FN} \quad (\text{式-2})$$

TP（正解）：正解値と推定結果が一致

FP（誤検知）：正解値では検出されず、推定結果では検出

FN（見逃し）：正解値では検出され、推定結果では非検出

上式により求めた再現率は約75%となった。再現率が低下した要因としては、図-5に示すような泥土の付着や団粒化、粒子境界の曖昧性等によるアノテーション作業の難化や学習データのバリエーション不足が考えられる。また、誤検知と判定された粒子領域においても明らかに粒子であるものも確認できており、アノテーションデータの量産や品質向上の必要性が考えられる。

4.2 画像処理による粒径分析

機械学習によって推定された個別粒子領域に対して、凸領域の算出と楕円フィッティングにより作成した粒径加積曲線を図-6に示す。本検討では、中礫以上の粒径を持つものを検出対象としたので、粒度試験で得られた粒径加積曲線も中礫以上の通過質量百分率として補正を行った。比較的粒径の小さい区間での誤差要因としては、中礫分が粗礫や石分の空隙に入り込み個別粒子の検出が難しいことが考えられる。一方で比較的粒径の大きい区間での誤差要因としては、画像の端部に存在する粒子が実際の粒径よりも小さく認識されたことが考えられる。

5. まとめ

本検討では、画像から粒度分布を推定する機械学習モデルとして個別粒子検出によるアプローチを試みた。撮影方法や画像処理の方法などに課題はあるが、個別粒子の検出は比較的高い精度で実施できており、今後の撮影時や画像処理時の工夫、学習データの充実によって更なる推定精度の向上が示唆された。

参考文献

1) He, K., et al. : Mask R-CNN, Proc. of the IEEE Int. Conf. on Computer Vision 2017, Venice, Italy, pp. 2961-2969, 2017.

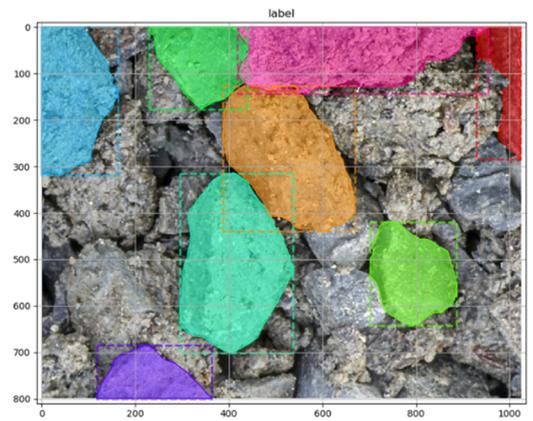


図-3 アノテーションで設定した粒子領域

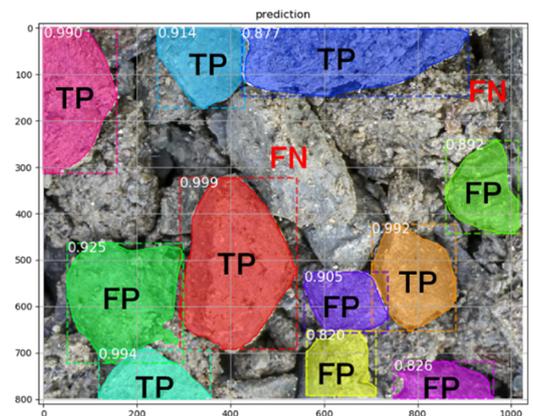


図-4 機械学習モデルで判別した粒子領域

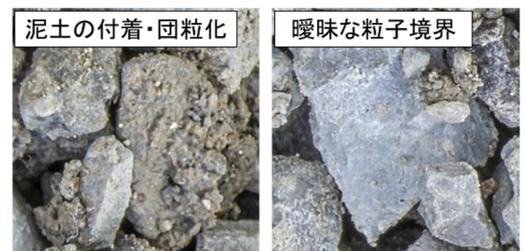


図-5 推定精度低下の要因となる画像例

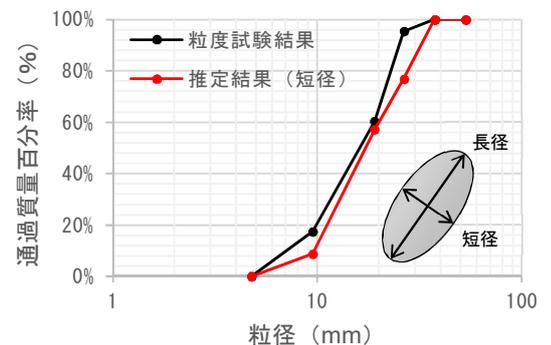


図-6 機械学習モデルによる推定結果