

1. 背景

1991年に「再生資源の利用の促進に関する法律」が制定されて以降、建設発生土リサイクルは建設業の重大テーマの一つとなっている。発生土を利用する際には、対象土の粒度特性に応じた適用用途の選定¹⁾が重要であり、施工前に実施する粒度試験（JIS A 1204）の結果に基づいて利用計画が立案される。一方で、施工中に計画と異なる発生土が出現する場面も少なくなく、発生土を無駄なく利用するためには、発生土の粒度特性の把握と施工管理への反映を迅速に行う必要がある。しかしながら、粒度試験は結果の受領までに数日を要することから時間的制約上の課題がある。

こうした状況の中、短時間で粒度分布を推定する技術として土砂の画像から粒度を判定する技術開発が積極的に進められている^{2),3),4)}が、細粒分を多く含む細粒土への適用は、礫分など大粒子に対する微細粒子の付着によって細粒分の割合を過大に推定するといった事例も報告されている³⁾。そこで、細粒土を含む多様な土砂にも適用可能な粒度判定技術の確立を目的に、画像認識性能に長けた深層学習を活用したAI粒度判定システム「ASYST」を開発した。

本稿では、開発時の取組みと実工事における現場適用性の検証内容について報告する。

2. 開発時の取組み

(1) 解泥土砂を用いた粒度推定（第一フェーズ）

文献³⁾で報告された微細粒子の影響を考慮し、撮影対象として解泥（水で解した）した土砂を採用した（**図-1**）。これは、微細粒子の付着を防ぎつつ、付着土砂と沈殿土砂といった画像的特徴が粒度推定に有利に働くことを期待したものである。そこで、開発の第一フェーズでは、解泥土砂の画像から粒度情報を読み取るトライアルとして粒度を調整した24種類の混合土（以下、人工試料）を対象に細粒分含有率 F_c の推定を試みた。人工試料の詳細を**表-1**に示す。人工試料は、礫分含有率を2種類（10%、20%）に大別した上で、砂分含有率を8パターン、細粒分含有率 F_c を4パターンに区分して作製した。礫分と砂分は最大粒径9.5mmの砂質土（ $F_c=0.6\%$ ）をふるい分けしたものを、細粒分はコンシステンシー特性の異なる3種類の粘性土（A、B、C）を用いた。

解泥土砂は、土試料の土粒子重量 $m_s=50$ gを定量として密閉容器（ガラス製；胴径63mm、高さ126mm、容量260



図-1 撮影対象とした解泥土砂

表-1 人工試料の配合条件

| 試料 No. | 含有率 (%) | | | 細粒分調整用粘性土種類 |
|--------|---------------------|----------------------|------------------|--|
| | 礫分 (2.00mm ~4.75mm) | 砂分 (0.075mm ~2.00mm) | 細粒分 (0.075mm 未満) | |
| 1 | 10 | 80 | 10 | 粘性土A ($w_L=57.4\%$ $w_P=22.0\%$ $I_P=35.4\%$) |
| 2 | 20 | 70 | 10 | |
| 3 | 10 | 60 | 30 | |
| 4 | 20 | 50 | 30 | |
| 5 | 10 | 40 | 50 | |
| 6 | 20 | 30 | 50 | |
| 7 | 10 | 20 | 70 | |
| 8 | 20 | 10 | 70 | |
| 9 | 10 | 80 | 10 | 粘性土B ($w_L=64.7\%$ $w_P=29.3\%$ $I_P=35.4\%$) |
| 10 | 20 | 70 | 10 | |
| 11 | 10 | 60 | 30 | |
| 12 | 20 | 50 | 30 | |
| 13 | 10 | 40 | 50 | |
| 14 | 20 | 30 | 50 | |
| 15 | 10 | 20 | 70 | |
| 16 | 20 | 10 | 70 | |
| 17 | 10 | 80 | 10 | 粘性土C ($w_L=147.7\%$ $w_P=35.6\%$ $I_P=112.1\%$) |
| 18 | 20 | 70 | 10 | |
| 19 | 10 | 60 | 30 | |
| 20 | 20 | 50 | 30 | |
| 21 | 10 | 40 | 50 | |
| 22 | 20 | 30 | 50 | |
| 23 | 10 | 20 | 70 | |
| 24 | 20 | 10 | 70 | |

キーワード 粒径加積曲線, 深層学習, 画像解析

連絡先 〒230-0035 横浜市鶴見区安善町1丁目3 東亜建設工業 技術研究開発センター TEL045-503-3741

ml) に投入し、含水比を $w=150\%$ に調整したのち、上下に振り混ぜて作製した。ここで、含水比 $w=150\%$ は事前実験をつうじて設定した数値であり、一般的な自然土の液性限界 w_L の上限値以上⁵⁾ かつ付着土砂の特徴を容易に視認できる値として採用した。その後、回転台の中心に解泥土砂をセットし、回転台が 60 秒間で 1 回転する様子を側方から固定カメラにより撮影速度約 6.7 枚/秒で撮影した。これを 1 試料当り 20 回繰り返し、約 8040 枚 (=60 秒×約 6.7 枚/秒×20 回) の画像を取得した。

上記の手順は各試料 2 セットずつ実施し、取得した画像をそれぞれ教師データとテストデータに用いた。なお、AI の学習手法は、CNN (Convolutional Neural Network) [ResNet18]⁶⁾ を採用している。

実験結果を表-2 に示す。表中の「正解率」は、問題と解答 (推定結果) が一致した割合を意味している。正解率は各 F_c によってばらつきが見られるものの、平均正解率は 82.8 % と高い結果が得られた。この取組みから、画像を用いた粒度推定として解泥土砂でのアプローチが有用と判断し、その後の粒径加積曲線の推定に着手することとした。

表-2 細粒分含有率 F_c の推定結果

| 細粒分含有率 | 正解数 | 不正解数 | 合計 | 正解率 |
|--------|-------|-------|-------|-------|
| 10% | 45037 | 3202 | 48239 | 93.4% |
| 30% | 37127 | 11112 | 48239 | 77.0% |
| 50% | 35532 | 12708 | 48240 | 73.7% |
| 70% | 42142 | 6098 | 48240 | 87.4% |

平均正解率 82.8%



図-2 専用撮影装置

(2) 粒径加積曲線の推定 (第二フェーズ)

前述のトライアルの結果を受け、開発の第二フェーズでは土砂画像から粒径加積曲線を推定する AI モデルの構築に取り組んだ。AI モデルの教師データには、人工試料 24 種の粒度試験結果 (粒径加積曲線) から抜粋した 10 点の粒度データを使用し、75 μm より大きい粗粒分の範囲は規定のふるい目径を (7 点)、75 μm 以下の細粒分の範囲は曲線からの読取値をそれぞれ用いた (0.03 mm, 0.01 mm, 0.003 mm の 3 点)。また、画像内の粒度推定に不要な要素 (背景の映り込み、照度や画角等の違い) は推定精度を低下させるため、これらを排除する目的で専用撮影装置 (図-2) を別途開発し、画像の取得は本装置で行った。

粒径加積曲線の推定結果として、各試料の二乗平均平方根誤差 $RMSE$ (Root Mean Squared Error) を図-3 に示す。なお、 $RMSE$ は教師データに採用した 10 点の粒度データにおける正解値 (粒度試験結果) と推定値との誤差を平均化したものであり、値が小さいほど推定精度が高いことを意味する。各試料の $RMSE$ は、全試料平均で 2.35 %、最大値は No.4 の 6.15 % となっている。ここで、No.4 の推定結果を図-4 に示すが、正解値と推定値の差を表す絶対誤差は最大 7.9 % であり、全試料の中で $RMSE$ が最も大きい結果となった No.4 であっても実用上十分な推定精度を有していると判断できる。

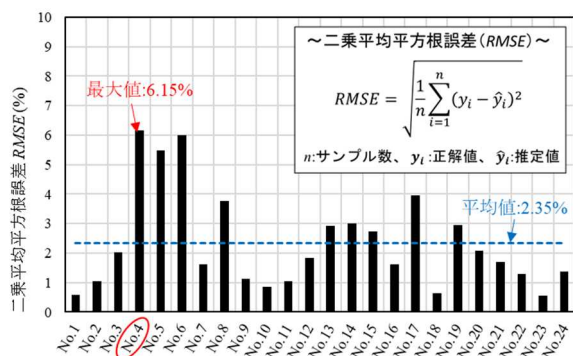


図-3 各試料における二乗平均平方根誤差




図-4 正解値と推定値の比較 (No.4)

(3) 自然土砂への適用性と追加学習の効果（最終フェーズ）

第一，第二フェーズの取組みをつうじ，解泥土砂の画像から粒径加積曲線を推定する AI モデルの妥当性を確認した．一方，これまでの検証は人工試料のみを対象としていたため，現場実装を考慮して自然土砂への適用性を確認する必要があると考えた．また，実装後は教師データの拡充（追加学習）を繰り返しつつ運用することを想定し，開発の最終フェーズとして自然土砂への適用性に加え，追加学習の効果も検証することとした．

本取組みにおける追加学習効果の検証イメージを図-5 に示す．第二フェーズで構築した AI モデルをベースに自然土砂の学習前後で推定精度の比較を行っている．なお，今回の検証では『港湾基準の液状化判定に用いる粒度範囲 ($U_c \geq 3.5$ ，特に液状化の可能性あり)』を学習範囲に設定し，収集した自然土砂の中から該当する土砂（53 種類）を選定して教師データに追加した．

追加学習による推定精度の比較結果を図-6~8 に示す．ここでは，粒度特性の異なる 3 種類（試料 A，試料 B，試料 C）の結果を挙げている．いずれも追加学習によって推定精度は大幅に向上し，試料 C では RMSE が 1 割程度まで低下している．この結果から，自然土砂への適用性と追加学習の効果があると判断した．

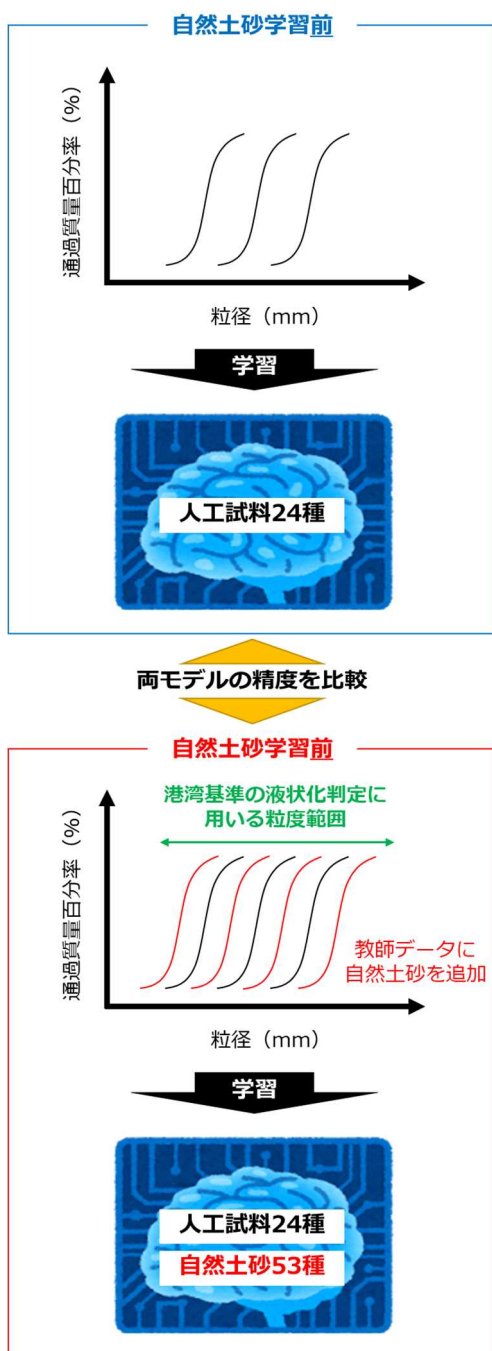


図-5 追加学習効果の検証イメージ

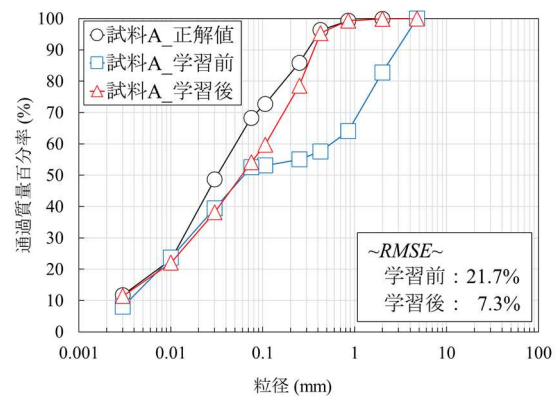


図-6 追加学習の効果（試料 A）




図-7 追加学習の効果（試料 B）




図-8 追加学習の効果（試料 C）

3. ASYST の現場適用性

前章で説明した取組みを踏まえ、AI 粒度判定システムとして構築した技術が「**ASYST**」である（**図-9**）。現場で取得した解泥土砂の画像をオンラインサーバ上の AI モデルにアップデートし、解析を実行することで粒径加積曲線をダウンロードできる仕組みである。これにより、複数現場での同時使用を可能とし、粒度データの一元管理化によって追加学習を効率的に実施することができる。

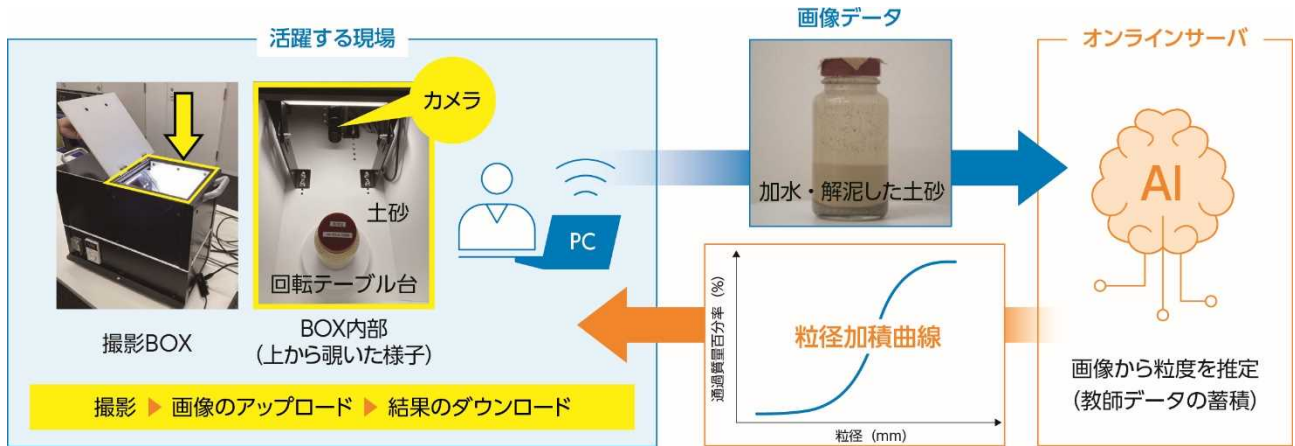


図-9 ASYST の全体概要

実工事で検証した ASYST の現場適用性について報告する。対象とした工事の概要を**表-3**に示す。

本工事は、千葉県富津沖に存在する自然由来の窪地を埋め戻すものである。海中の酸素欠乏や泥の堆積による海水の濁り防止といった海域環境の改善を目的とした工事であるが、他事業から受け入れた建設発生土を粒度調整して埋戻材料に再利用する特性から建設発生土リサイクルの側面も併せ持つ。

また、海上投入時の濁り防止と漁業への影響低減の観点から、施工中の管理項目に受入発生土と埋戻材料の粒度管理が規定されており、施工管理の効率化の面で ASYST の適用効果が期待できる工事（用途）の一つとなっている。

検証では、受入発生土と埋戻材料を対象にそれぞれ粒度試験と ASYST による粒度推定を実施し、結果の比較を行った。検証結果を**図-10**、**図-11**に示す。絶対誤差の最大値としては、受入土砂で 12.4%程度、埋戻材料で 9.5%程度となり、粒度試験結果と概ね一致する結果となった。

ここで、全国の試験機関を対象に実施した室内試験結果の比較報告⁷⁾によれば、例えば細粒分含有率 F_c の測定結果は試験機関によって約 6~30%の範囲でばらつきが生じている。この点を考慮すれば、今回の結果は妥当なものであり、実用上十分な精度で ASYST を現場に適用できるものと判断している。

表-3 工事概要

| | |
|------|--|
| 工事名 | 令和5年度 東京湾浅場造成工事 |
| 発注者 | 国土交通省 関東地方整備局 港湾空港部 |
| 施工者 | 東亜・みらい特定建設工事共同企業体 |
| 工期 | 令和5年4月25日～令和6年12月2日 |
| 工事数量 | 土砂混合工(84,469 m ³), 土砂投入工(74,527 m ³) |




図-10 検証結果（受入発生土）

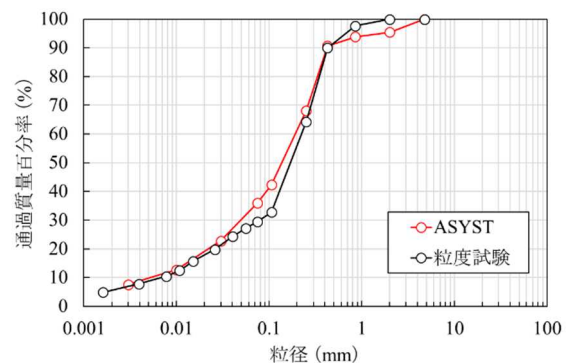


図-11 検証結果（埋戻材料）

4. 今後の展望

近年では建設就業者の少子高齢化や働き方改革の推進を背景に、建設生産プロセス全体の生産性向上および省人化を目的としたデジタル技術の導入が重要視されている。

今回開発した AI 粒度判定システム「ASYST^{アシスト}」は、デジタル技術の代表格である AI を活用した新技術であり、土の粒度情報を迅速かつ簡易に把握可能な点から、施工管理の生産性向上・省人化に貢献できる技術として期待している。今後は、教師データの拡充による推定精度の向上と適用範囲の拡大を目指し、多くの現場へ積極的に活用していく予定である。

参考文献

- 1) 国土交通省 HP : 国土交通省「技術調査関係」, 発生土利用基準 (H18.8.10)
<https://www.mlit.go.jp/tec/kankyou/hasseido.html>.
- 2) 川野健一, 藤崎勝利, 黒沼出, 岡本道孝, 小林弘明 : デジタルカメラ画像を用いたロック材の粒度解析システム, 土木学会第 67 回年次学術講演会, pp363-364, VI-182, 2012.
- 3) 岩下将也, 大塚義一 : 深層学習を用いた土の粒度分布推定法の基礎的研究, 奥村組技術研究年報 No.45, pp109-114, 2019.
- 4) 阿部友貴, 小林泰三 : 深層学習による地盤材料の工学的分類の実現に向けた基礎的検討, 第 56 回地盤工学研究発表会, 13-2-3-04, 2021.
- 5) 地盤工学会 : 地盤材料試験の方法と解析 [第一回改訂版] -二分冊の 1-, p168, 2020.
- 6) Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun : Deep Residual Learning for Image Recognition, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770-778, 2016.
- 7) 地盤工学会 HP : 技能試験実施委員会, 地盤材料試験の技能試験報告書 (2013~2021 年度)
https://www.jiban.or.jp/?page_id=550.