

深層学習を用いた土の粒度分布推定法の基礎的研究

Basic Study on Deep Learning Method for Estimating Soil Particle Size Distributions

岩下将也* 大塚義一**

要 旨

土の粒度分布は、地盤の力学的性質や締固め特性等を決める重要な指標であるが、現場で大量に発生する土に対し、高頻度に粒度分布の測定を実施することは困難である。粒子の輪郭を画像解析によって測定する推定法も提案されているが、輪郭の明確でない小粒子を含む土には対応できない。簡便な方法で小粒子も含めた土の粒度分布を推定できれば、建設工事の生産性向上につながる。本研究では、機械学習手法の一つである畳み込みニューラルネットワークを用いて、砂質土、細粒土のそれぞれの画像から粒度分布の推定を行う基礎的実験を行った。実験の結果、二乗平均平方根誤差 10%未満で粒度分布を推定できた。本稿では、実験方法、機械学習によるモデルの作成法、推定結果とその評価について報告する。

キーワード：砂質土、細粒土、粒度分布、CNN、VGG16、転移学習

1. まえがき

土の粒度分布は、地盤の締固め特性や透水性、液状化強度などの性質を推定する上で重要な指標の一つである。粒度分布の測定には、ふるい分析や沈降分析を行う必要があるが、建設現場の工事過程で生成される大量の土に対し、これらの分析を頻繁に実施することは困難である。粒度分布をより簡便に推定できれば、建設工事の生産性向上や、建設物、造成物の品質向上につながる。

こうした背景から、土表面の画像から粒度分布を自動的に推定する研究事例は多くあり、代表的な方法として、土表面の土粒子の輪郭を画像処理によって抽出し、そこから粒径、粒度分布を推定するものがある¹⁾。しかし、この方法では画像から輪郭を補足できない小粒子の場合に適用できず、適用範囲は大粒子の粒度分布の推定に限られる。

近年、関連する研究として、画像分類の分野で高い性能を発揮することが知られている深層学習、畳み込みニューラルネットワーク (Convolutional Neural Network、以下、CNN) を用いて、現場発生土の画像から、土の性状を推定する研究事例が報告されている²⁾。

CNN の特長として、画像を判別する上で必要な種々の特徴を自動で抽出できる点がある。土表面には、粒子の集合による様々な特徴が現れており、輪郭の抽出ができない小粒子に対しても、特有の特徴を抽出し、粒度分布を推定できる可能性がある。

本研究では画像上で粒子の輪郭が判別できない小粒子を含む細粒土、砂質土の 2 種類の画像を対象に、CNN によって粒度分布を推定する実験を行った。実験の結果、適用した CNN によって、二乗平均平方根誤差 10%未満で粒度分布を推定できた。本稿では、実験方法、推定法の詳細と、推定性能の評価結果について報告する。

2. 実験の方針と実験フロー

2.1 実験の前提

実験の適用範囲として、推定する粒度分布の区分範囲、および実験で扱う土の性質について以下のように定めた。

a. 推定する粒度分布の区分範囲

粒度分布の区分範囲は、ふるい分析に準じるものとした。表-1 に、JIS A 120 4:2009 「土の粒度試験方法」に規定されているふるい分析の粒径区分範囲を示す。この

表-1 ふるい分析の粒径区分

粒径範囲		粒子名	
53 mm以上	75 mm未満	粗礫	礫
37.5 mm以上	53 mm未満		
26.5 mm以上	37.5 mm未満		
19 mm以上	26.5 mm未満	中礫	
9.5 mm以上	19 mm未満		
4.75 mm以上	9.5 mm未満	細礫	
2 mm以上	4.75 mm未満		
0.85 mm以上	2 mm未満	粗砂	砂
0.425 mm以上	0.85 mm未満		
0.25 mm以上	0.425 mm未満		
0.106 mm以上	0.25 mm未満	中砂	
0.075 mm以上	0.106 mm未満		
	0.075 mm未満	細砂	
		細粒	

*技術研究所環境研究グループ **土木本部土木部環境技術室

規定では、75mm 未満の土粒子を最大 13 種に分類可能である。

なお、0.075mm 未満の土粒子については、沈降分析によってより詳細な区分に分類が可能であるが、実業務での活用性の観点から、沈降分析レベルの粒度推定は不要と考え、推定対象外とした。

b. 対象とする土の性質

土の性質には含水比や、粒子の組成なども含まれるが、これらの性質の推定は本研究の対象外とした。実験では、自然乾燥状態の土を原料とし、同じ原料を用いて粒度分布のみ変更した土（以下、混合土）を用いて、それぞれの粒度分布を推定する。

2.2 機械学習手法と作成データ

粒度分布の推定には、機械学習手法の一つである教師あり学習を用いる。教師あり学習の考え方を図-1に示す。教師あり学習では、入力値と出力値が既知であるデータセット（訓練データ）を基に、入力値を出力値に変換する計算モデルを自動的に生成する。この過程を学習という。学習後のモデルにテスト用の入力データを入れ、推定値を出力し、テストデータの真値と比較し、モデルの推定性能を評価する。実験では、混合土の画像を入力し、粒度分布を出力するモデルを構築し、推定性能を評価する。訓練データとテストデータは、以下のように考えた。

a. 訓練データ

モデルの学習を適切に行うには、訓練データに正確な情報が含まれている必要がある。ここで図-2に、混合土と、単一の粒径区分内の粒径粒子のみで構成された土（以下、単一粒径土）の3回の攪拌後の画像を示す。混合土の場合、表面に分布する粒子の構成は、攪拌するごとに変化している。土表面の粒子は、その土の粒度分布に常に対応した構成であるとは限らず、多様な特徴を示す。一方、単一粒径土は、ある範囲の粒径粒子のみが集まっているため、攪拌を繰り返しても、特徴的な一様性が保たれていることがわかる。以上の観察から、訓練データには、画像の特徴と粒径の対応が明確である単一粒径土を用いる方針とする。

b. テストデータとその評価

混合土の粒度分布の推定においても、1枚の土の表面画像から、その土全体の粒度分布を推定することは適切ではない。そのため、攪拌した複数の表面画像をテストデータとして用意し、各テストデータの粒度分布の推定結果を算術平均によって総合し、これをもって土全体の粒度分布の推定結果とする。

なお、建設現場で扱われる土は、ベルトコンベアによる運搬時や、保管容器内への堆積の過程で、土の表面が常に変化する状況が多くあり、複数の画像を総合して粒度分布を推定する考え方は、これらの状況に適用可能と考える。




図-1 教師あり学習の考え方




図-2 攪拌による土の特徴変化
(上：混合土、下：単一粒径土)

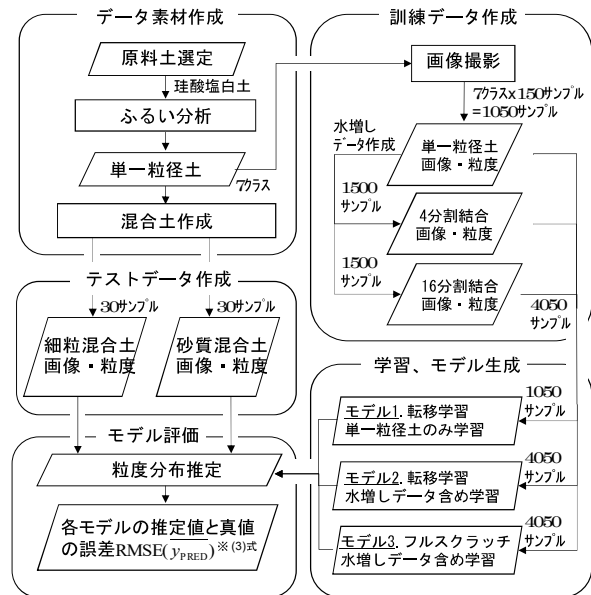


図-3 実験フロー

2.3 実験のフロー

以上を踏まえて実施した実験のフローを図-3に示す。原料土を選定し、これをふるい分析に掛け、複数種の単一粒径土を作成する。訓練データとして単一粒径土の画像と粒度のデータセットを作成した後、単一粒径土を混合し、テストデータとして、粒度分布の異なる2種類の土の画像と粒度のデータセットを作成する（3章）。続いて、訓練データを学習するモデルを設定する。その際、学習方法別に複数種を用意する（4章）。訓練データを学習した各モデルに、テスト用の混合土の画像を入力し、粒度分布の推定値とその平均値を得る。実際の粒度分布との誤差を求め各モデルの性能を総合評価する（5章）。以下、これらの実施内容について説明する。

3. データ作成

3.1 原料土の選定とふるい分析

原料土は、ソフトシリカ社の購入土「珪酸塩白土」を選定し、目開きによってふるい分析した。原料土の写真を図-4に、原料土の粒度分布を表-2に合わせて示す。原料土は4.75mm未満の土粒子で構成され、これらを全7区分に分けた。

3.2 訓練データの作成

a. 単一粒径土

ふるい分析によって得られた7区分の単一粒径土を容器に入れ、上方に固定したカメラ(CANON Power Shot S120)により屋内で画像を撮影し、画像処理によって224×224画素、50mm四方のサイズ(画素分解能0.22mm)に成形した。画像データは、各区分で150サンプル、合計1,050サンプル取得した。図-5に、各区分の単一粒径土の撮影画像を示す。区分1から区分5までは、画像の目視では粒径の輪郭が判別できない。

b. 分割・結合画像によるデータの水増し

単一粒径土の粒度分布は、該当する粒径区分の粒子が100%となるが、単一粒径土の画像とその粒度分布のみを訓練データに用いた場合、単一性そのものを特徴として学習する可能性があり、多様な粒径粒子で構成される混合土の推定に対応できない可能性がある。

限られた訓練データでモデルの性能を上げるため、訓練データに種々の変換を加え、データ量を増やす手法は「水増し」と呼ばれ広く用いられている。本実験においても、推定性能の向上を目的として水増しをした。その方法として、複数の粒径粒子を含む特徴を学習させるため、各区分の単一粒径土の画像を分割し、それらをランダムにつなぎ合わせた結合画像を作成した。作成した結合画像を図-5に示す。分割・結合数は4分割と16分割の2パターンとし、結合画像の粒度分布は、その画像に含まれる各区分の面積割合によって算出した。例えば、16枚のうち区分3の画像が4枚含まれている場合、区分3の質量率は25%となる。このようなデータセットを各分割パターンごとに1500サンプル、合計3000サンプル作成し、訓練データに加えた。

3.3 テストデータの作成

続いて単一粒径土を再構成して、混合土を作成した。混合土の粒度分布を表-2に、撮影した画像サンプルを図-4に合わせて示す。すべての粒径区分の土を最低5%含むように作成した。また、土の工学分類には、細粒分50%以上で構成される細粒土と、細粒分50%未満で構成される砂質土の、大きく2種類がありことから³⁾、本実験の混合土もこの定義を参考に、砂質土と細粒土の2種を作成した。砂質土は細粒分5%とし、細粒土は細粒分55%とした。作成した各混合土の画像は、単一粒径土と同じ要領で各種30枚、合計60枚撮影した。



原料土 混合土(砂質土) 混合土(細粒土)

図-4 原料土写真と混合土のサンプル画像

表-2 原料土と混合土の粒度分布(質量率)

区分	1	2	3	4	5	6	7
目開き範囲 [mm]	~ 0.075	0.075 ~ 0.106	0.106 ~ 0.25	0.25 ~ 0.425	0.425 ~ 0.6	0.6 ~ 2	2 ~ 4.75
原料土	3%	2%	5%	4%	6%	38%	41%
混合土(砂質土)	5%	5%	10%	10%	20%	30%	20%
混合土(細粒土)	55%	15%	10%	5%	5%	5%	5%




図-5 訓練データのサンプル画像

4. モデルの学習と推定

モデルには、高い画像認識性能を示すCNNを使用した。CNNの基本的な考え方と、本実験で適用したCNNについて示す。

4.1 CNNの考え方

a. ニューラルネットワーク

CNNは、機械学習アルゴリズムの一つであるニューラルネットワークを発展させ、高度な画像認識を可能にした技術であり、基本構造はニューラルネットワークと同じである。ニューラルネットワークは、パーセプトロンと呼ばれる作用素をつなぎ合わせることで推論が実現される。図-6に、パーセプトロンの構成例と計算を示す。

1 次元配列の入力値 x_m^l (①特徴量) と、2 次元配列 w_{mn}^l (②重み) の内積をとり、1 次元配列 b_n^l を加算した $x_n^{l'}$ を求める (③内積とバイアスの加算)。求められた $x_n^{l'}$ を、伝達関数 f に入力し、その出力を新たな特徴量 x_n^{l+1} として、次のパーセプトロンに渡す (④伝達関数)。このパーセプトロンを並列につないだものをレイヤー、レイヤーを複数直列につないだものを、多層パーセプトロン (MultiLayer Perceptron、以下、MLP) と呼ぶ。入力値が複数のパーセプトロンを伝達していくことで、最終的にクラス C の推定値 $y_{\text{PRED},C}$ を得る。モデルの学習においては、推定値と真値の差が小さくなるよう、重みとバイアスを探索する最小化アルゴリズムが用いられる。

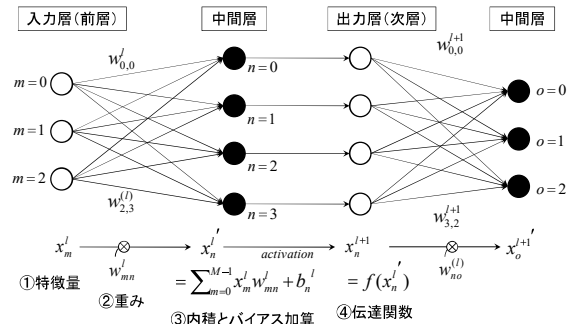


図-6 パーセプトロンの構成例と計算

b. CNN

CNN は、画像処理技術の一つである畳み込み積分の考え方をニューラルネットワークに適用したものであり、畳み込み係数を重みに用いる。CNN の構成例とその計算を図-7に示す。多くの CNN では、畳み込み層、プーリング層、全結合層の3層が備わっている。畳み込み層は、ニューラルネットワークと類似した構造を持ち、画像データ (複数の2次元配列) である3次元配列の入力特徴量 x_{ijm}^l (①特徴マップ) と、4次元配列の重み w_{stmn}^l (②カーネル) に、畳み込み積分が適用される (③畳み込み)。全チャンネルの総和で、マップを集約し、バイアスを加算した $x_{ijmn}^{l'}$ (④総和・バイアス加算) が伝達関数へ入力され (⑤伝達関数への入力)、その出力として次層の特徴マップ x_{ijm}^{l+1} が得られる (⑥次層の特徴マップ)。

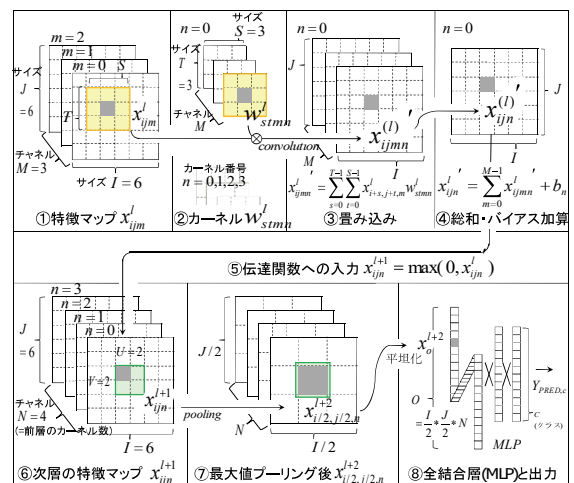


図-7 CNN の構成例と計算

カーネルの作用により、層が深まるにつれ特徴マップのチャンネルが増える。プーリング層では重要な特徴のみを抽出し、マップサイズを縮減する (⑦最大値プーリング後 $x_{i/2, j/2, n}^{l+2}$)。畳み込み層によるチャンネルの増加とプーリング層によるマップの縮小により画像全体から多種多様な特徴が抽出される。カーネルは特徴量のフィルタの役割を果たし、畳み込み演算により、画像内を網羅的に平行移動することで、少数の重みで画像全体の局所的な特徴が効率的に抽出される。最終的に出力された特徴マップは1次元配列に変換 (平坦化) され、全結合層と呼ばれる MLP を経て、出力 $y_{\text{PRED},C}$ が得られる (⑧全結合層(MLP)と出力)。

c. CNN のモデル例

CNN のネットワーク構造は様々なものが提案されている。代表的な CNN の一つである VGG16⁴⁾ の構造を図-8に示す。224×224画素、3チャンネルの画像に対し、3×3の微小な画素のカーネルを複数含む2~3層の畳み込み層と1層のプーリング層からなる5つのブロックを経て、7×7画素、512チャンネルの特徴マップが生成される。これを平坦化した25,088の特徴量を3層の全結合層に接続することで、1,000クラスの出力をする設計となっている。2015年に公表されて以降、画像分類の性能の

■VGG16畳み込み層、プーリング層

	特徴マップ X			カーネル W・プーリング		
	サイズ	チャネル	サイズ	チャネル	個数	
畳み込みレイヤ-1	224	224	3	3	3	64
畳み込みレイヤ-2	224	224	64	3	3	64
最大値プーリング1	224	224	64	最大値抽出, サイズ縮小(1/2)		
畳み込みレイヤ-3	112	112	64	3	3	64
畳み込みレイヤ-4	112	112	128	3	3	128
最大値プーリング2	112	112	128	最大値抽出, サイズ縮小(1/2)		
畳み込みレイヤ-5	56	56	128	3	3	128
畳み込みレイヤ-6	56	56	256	3	3	256
畳み込みレイヤ-7	56	56	256	3	3	256
最大値プーリング3	56	56	256	最大値抽出, サイズ縮小(1/2)		
畳み込みレイヤ-8	28	28	256	3	3	256
畳み込みレイヤ-9	28	28	512	3	3	512
畳み込みレイヤ-10	28	28	512	3	3	512
最大値プーリング4	28	28	512	最大値抽出, サイズ縮小(1/2)		
畳み込みレイヤ-11	14	14	512	3	3	512
畳み込みレイヤ-12	14	14	512	3	3	512
畳み込みレイヤ-13	14	14	512	3	3	512
最大値プーリング5	14	14	512	最大値抽出, サイズ縮小(1/2)		
抽出特徴量	7	7	512			

■実験用全結合層

	特徴量 X
全結合層3	1000
全結合層4	1000
全結合層5	256
全結合層6	256
出力層	7

■VGG16全結合層

	特徴量 X
平坦化(7×7×512)	25,088
全結合層1	4,096
全結合層2	4,096
出力層	1,000

接続

図-8 VGG16 の構造と本実験の転移学習構成

高さ、ネットワークの簡潔さ、ライセンス制約の少なさ等から、広く使用されている CNN モデルの一つである。

4.2 実験に適用した CNN

a. ネットワーク構成

本実験で適用した CNN は VGG16 をベースとし、全7区分を出力できるよう、新たに全結合層を作成し、既存の全結合層2に接続した(図-8、実験用全結合層)。

b. 出力層の伝達関数

出力層の伝達関数には(1)式で示すソフトマックス関数を用いた。

$$y_{\text{PRED},c} = \frac{e^{x_c}}{\sum_{n=1}^N e^{x_n}} = \frac{1}{1 + \exp(-x_c + \log D)} \quad (1)$$

(ただし $D = \sum_{n=1}^N e^{x_n} - e^{x_c}$)

x_n : 区分 n の出力層の入力値

n : 区分番号

c : 推定粒径区分

N : 区分総数(= 7)

ソフトマックス関数は、入力 x_c を変数とする標準シグモイド関数を、変数軸の方向に $\log D$ 平行移動したものである。定義域 $(-\infty, \infty)$ において値域 $(0, 1)$ で分布する増加関数の特徴と、全クラスの出力の総和が 1 となる特徴の 2 つを備えており、任意の実数を入力として、各クラスの確率分布を出力する伝達関数として使用されることが多い。本実験のモデルの推定値は粒度分布、つまり 0~100% の間で分布する各粒径区分ごとの粒子の質量率であり、それらの総和は 100% となることから、ソフトマックス関数が適用できる。

c. 転移学習の適用と訓練データの変更

VGG16 は、汎用的な対象物の分類を目的として作成された大量の画像データセットの学習によって、高い性能があることが検証されており、検証の際に使用された学習済みのネットワークが商用利用可能なライセンスで公開されている。学習済みのネットワークを部分的に用い、残りのネットワークに新たな学習をすることで、少量の訓練データであっても、比較的高性能なモデルが生成できる。この手法は転移学習と呼ばれ、大量の訓練データの用意と膨大な学習時間が課題となる AI 開発の現場においても広く用いられている。

本実験では、すべての層を実験用の訓練データのみで学習する場合(フルスクラッチ)と、畳込み層に学習済みの VGG16 ネットワークを用い(図-8、網かけ部)、全結合層のみを実験用訓練データで学習する場合(転移学習)について推定性能を出し、その違いを確認する。また、これと合わせ、3.2 節で述べた分割結合画像によるデータの水増しの有効性も確認するため、水増しデータの学習の有無で、推定性能の違いを確認する。

本実験のモデルの学習パターンを表-3に示す。モデル1とモデル2を比較し、水増しの有効性を、モデル2とモデル3を比較し、転移学習の有効性を確認する。

表-3 モデルの学習パターン

	転移学習	結合画像の水増し
モデル1	使用	不使用
モデル2	使用	使用
モデル3	不使用	使用

5. モデルの推定結果と性能評価

5.1 推定方法

砂質土、細粒土の各区分の推定は 2.2 節で述べた通り、全画像の推定値の算術平均値を採用し、(2)式によって算出する。

$$\overline{y_{\text{PRED},c}} = \frac{1}{K} \sum_{k=1}^K y_{\text{PRED},c,k} \quad (2)$$

k : 推定用画像サンプル番号

K : 推定用画像サンプル総数(= 30)

5.2 モデルの評価方法

各モデルの推定性能は、砂質土、細粒土それぞれの粒度分布の真値 y_{TRUE} に対する、推定結果 $\overline{y_{\text{PRED},c}}$ の二乗平均平方根誤差 (Root Mean Square Error、以下、RMSE) を用いて評価し、(3)式で算出する。

$$\text{RMSE}(\overline{y_{\text{PRED}}}) = \sqrt{\frac{1}{N} \sum_{c=1}^N (y_{\text{TRUE},c} - \overline{y_{\text{PRED},c}})^2} \quad (3)$$

5.3 推定結果および評価

モデル1、モデル2、モデル3の砂質土、細粒土の7区分の推定結果を曲線に示したものを次ページの図-9、図-10、図-11に示す。各図の上のグラフは、粒径区分内の粒子の割合を区分の上限値の位置にプロットしたもの、下のグラフはその累積である粒径加積曲線(プロット粒径未満の粒子が含まれる割合)を示している。考察の参考として、各30サンプルそれぞれの推定結果も合わせて載せている。

a. 各30サンプルの推定結果

モデル1では、各サンプルの推定値の分布範囲が大きく、質量率が際立って高い曲線が多数ある。混合土の画像の多くには、様々な粒径粒子が混在しているため、この結果は訓練データの単一粒径土特有の分布が学習された結果と考えられる。また、砂質土と細粒土で、類似の推定曲線があり、各サンプルの推定曲線のみでは、砂質土と細粒土の特徴を分類できていない。モデル2の推定曲線は、モデル1と比較して分布範囲が狭くなっている。また、細粒土と砂質土の推定曲線が重複することはなく、各サンプルの推定曲線だけを見ても、2種の土の特徴を区別することが可能である。なお、この特徴はモデル3でも共通している。

b. 全サンプル平均による推定結果

いずれのモデルも 30 サンプルの全平均を取ると、真値の粒度分布に近いトレンドが得られている。ただし、細粒土に関しては、全モデルに共通して細粒分の割合が過大に推定されている。この原因として、細粒粒子の付着が考えられる。一般に、粒子が小さくなると、付着力（分子間力）が重力を上回り、粒子が周辺物体に付着しやすくなる。図-12 に示すように、細粒分の割合が多い細粒土では、礫分などの大粒子に細粒粒子が付着することで、大粒子の画像上の特徴がほとんど失われていると考えられる。複数の粒径粒子の混合した土では、単純な画像結合では補えない変化が起こり得るため、細粒粒子の付着性などを考慮した訓練データの作成も検討が必要と考える。

c. 各モデルの誤差評価

各モデルの誤差の比較結果を図-13 に示す。モデル1と比較し、モデル2の誤差が小さくなっていることから画像結合による訓練データの水増しは、モデルの推定性能を向上させる上で、有効な手法と考えられる。一方、モデル2とモデル3の誤差の違いはわずかである。

付着粒子に関する考察で述べた通り、推定誤差を少なくするためには、より多様な訓練データが必要と考えられる。データの質、量が十分にあれば転移学習の有効性が低下する可能性もあり、訓練データの質、量を高めた上で再度、比較検討が必要と考えている。

6. まとめ

輪郭を判別できない土粒子が含まれる砂質土、細粒土を対象に、CNN を用いて単一粒径土とその結合画像を訓練データとした推定モデルを生成した。画像の分割結合による水増しと、転移学習を用いることで、RMSE 10%未満で粒度分布を推定した。1 種類の原料土から作成した 2 種類の土のみの実験結果であるため、今後は実用に向けて土の種類を増やした研究を進めたい。

【参考文献】

- 1) 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、pp.363-364、VI-182、2012
- 2) 本間伸一、森田順也、吉迫和生、本田和之、「ディープラーニングを用いた画像解析による土砂性状判別」、2018 年度人工知能学会全国大会（第 32 回）、4M1-02
- 3) 国土技術研究センター、「河川土工マニュアル平成 21 年 4 月 改訂版」、p.573、2010
- 4) K. Simonyan, et.al 「VERY DEEP CONVOLUTIONAL NETWORKS FOR LARGE-SCALE IMAGE RECOGNITION」、arXiv:1409.1556v6 [cs.CV]、2015 年 4 月




図-9 モデル1 推定結果(左:砂質土,右:細粒土)




図-10 モデル2 推定結果(左:砂質土,右:細粒土)




図-11 モデル3 推定結果(左:砂質土,右:細粒土)




図-12 細粒粒子の付着による大粒子の特徴変化




図-13 各モデルの誤差比較