

人工知能技術による土質推定に基づく 埋立管理システムの開発

熊谷 隆宏¹・白 可²・佐々木 優³・田代 司³・琴浦 毅²・鶴見 文孝⁴

¹ 正会員 五洋建設(株) 技術研究所 (〒329-2746 栃木県那須塩原市四区町 1534-1)
E-mail: Takahiro.Kumagai@mail.penta-ocean.co.jp

² 正会員 五洋建設(株) 技術研究所 (〒329-2746 栃木県那須塩原市四区町 1534-1)

³ 五洋建設(株) 国際土木本部 (〒112-8576 東京都文京区後楽 2-2-8)

⁴ 正会員 五洋建設(株) 国際土木本部 (〒112-8576 東京都文京区後楽 2-2-8)

埋立による港湾建設や土地造成を行う場合、材料として一般的に砂質土が用いられているが、社会の持続的発展の観点からは、浚渫粘土や建設発生土を有効利用することが望ましい。ただし、粘性土を使用する場合、すべりに対する安定性や将来沈下量の検討が必要であり、使用する粘性土の土質特性を事前に把握することが重要である。本研究では、土源情報、湿潤密度、撮影画像等の情報に基づき、圧密特性を含む土質特性を迅速に推定する人工知能技術を導入する。畳み込みニューラルネットワーク(CNN)を用いて構築した機械学習モデルは、圧密定数や液性限界等を精度良く推定できることを確認した。土質推定AIモデルと、土運船から投入した粘性土の堆積形状解析技術および圧密沈下解析技術を統合し、将来沈下の予測が可能な埋立管理システムを提案する。

Key Words : neural network, CNN, machine learning, soil property, reclamation

1. はじめに

海域の埋立によって土地を造成する場合、一般に材料として砂質土が用いられている一方、航路や泊地の浚渫等で発生する粘性土の多くは土砂処分場に処分されている。社会の持続的発展の観点からは、砂資源の利用を抑制し、粘性土を有効利用することが望ましく、今後埋立材料に粘性土を用いることが重要になると考えられる。

一方、軟弱な粘性土で埋め立てられた場合、すべりに対する安定性や将来の圧密沈下量が懸念される。これらの検討にあたっては、使用した粘性土の圧密および強度特性を把握する必要があるが、形成された層に対する詳細な原位置調査や、投入前の土に対する各種土質試験を実施してこれらの特性を把握することは現実的でない。

近年、判断や評価の高度化や迅速化、また省力化を目的として、様々な分野で人工知能(Artificial Intelligence: AI)技術の活用が図られている。建設分野においては、例えば、宇津木ら¹⁾は、画像や音声認識において広く利用されている畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)²⁾の手法を用いて、切羽観察結果と弾性波速度計測結果に基づき、トンネル切羽の自動評価を行うシステムを構築している。また、熊谷・秋本³⁾は、ニューラルネットワークのマルチタス

ク学習手法を用いて、ボーリング削孔時の計測結果に基づき、N値および細粒分含有率を推定する解析モデルを提案している。

本研究では、画像認識分野で広く適用されているCNNの手法を用いて、土源情報、湿潤密度、撮影画像等の情報より、土運船上の粘性土の土質特性を迅速に推定するAIモデルを構築した。さらに、AIによる土質推定解析と、土運船から投入した粘性土の堆積形状解析および圧密沈下解析を統合した新しい埋立管理システムを提案する。

2. 埋立管理システムの概要

本研究で提案する埋立管理システムは、埋立に使用する粘性土の土質特性および形成される埋立層の土層構成を含む堆積形状を把握した上で、将来沈下量の予測機能を持つことを特徴とする。図-1に、埋立管理システムにおける一連の解析のフローを示す。まず初めに、投入する粘性土に対し、AIモデルを用いて土質特性を推定する。次に、推定された土質特性のうち、非排水せん断強さの値を考慮して、投入された粘土の堆積形状の解析を行い、最終的に、推定された圧密定数と埋立層の堆積形状に基づき、沈下解析を行う手順となる。

(1) 土質推定 AI

CNNの手法を用いる本研究の機械学習のモデル構造を図-2に示す。土源情報、湿潤密度、撮影画像および触感による硬・軟情報を入力データとし、圧縮指数、膨潤指数、圧密係数、液性限界等の土質定数を出力データとして、相関を機械学習させるモデルである。土源情報としては、採取場所（浚渫場所や陸上掘削土の採取場所等）を入力し、湿潤密度については、土運船の船首部、中央部、船尾部の3箇所まで採取した粘性土に対し、重量と体積を計測して求めた密度の平均値を入力する。

機械学習の前半部の処理において、画像から特徴量を抽出し、抽出した特徴量とその他のスカラー情報を結合し、後半部ではニューラルネットワークのディープラーニングにより目的変数の推定を行う流れとなる。

前半部の画像データの処理に関しては、画像から有効な特徴量を抽出する処理が重要であり、本研究では、巨大なデータセットを用いて学習済みの既存モデルを導入する転移学習²⁾の手法を用いた。一般に公開されている学習済モデルとしては、VGG⁴⁾、GoogLeNet⁵⁾、ResNet⁶⁾等が知られており、本研究では、畳み込み層とプーリング層の繰り返し配置で構成され、モデル構造が単純なVGGに分類されるVGG16モデルを導入した。

また、説明変数のうち、「土源情報」や「硬軟情報」等の文字列データについては、数値データへの変換が必要であり、本研究では、One-Hot Encording⁷⁾の手法を用い

た。文字列データを分類する複数のカテゴリを設けた後、各カテゴリに対して0または1の数値を立て、データの特徴を数値的に表現する手法である。

教師データを用いて、推定誤差を最小化するようにディープラーニング部分の各パラメータの最適化を行って構築したモデルに対し、新たなデータを入力すると、対応する土質定数の値が目的変数として出力される。

(2) 堆積形状解析

土運船から投入した粘性土の堆積形状解析について、投入した土が正規確率分布に従って拡散することを仮定する松見・岸口⁸⁾が提案する手法を導入する。この手法では、土運船の船倉を小区画に分割した後、式(1)に示される確率密度関数 $f(x,y)$ を用いて、各区画から投入された土の移動量（堆積形状）を評価する。そして、土運船から投入された土の全体堆積形状は、各区画から投入された土の堆積形状の総和で表現される。

$$f(x,y) = \frac{1}{2\pi\sigma^2} \exp\left\{-\frac{x^2+y^2}{2\sigma^2}\right\} \quad (1)$$

ここに、 σ は標準偏差（拡散係数）である。

この簡便な手法は、砂質土の堆積形状だけでなく、例えば、熊谷ら⁹⁾のように、ブロックの投入による人工マウンド礁の造形成状の解析にも適用されている。砂やブロック、また石材に適用されていた手法に対し、本研究では、広がり程度の指標となる標準偏差が粘土の非排水せん断強さに依存する考え方を導入し、粘土に対しても適用できるよう拡張させる。すなわち、AIにより推定された液性限界や非排水せん断強さから、入力パラメータの標準偏差（拡散係数）を求め、解析する手法を用いる。

(3) 将来沈下解析

土田・小野¹⁰⁾は、軟弱地盤上に広域の埋立を行う場合を対象に、面的な沈下のばらつき（不同沈下）を評価す

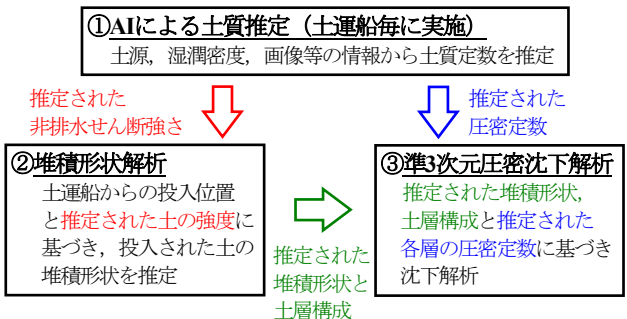


図-1 埋立管理システムにおける解析のフロー

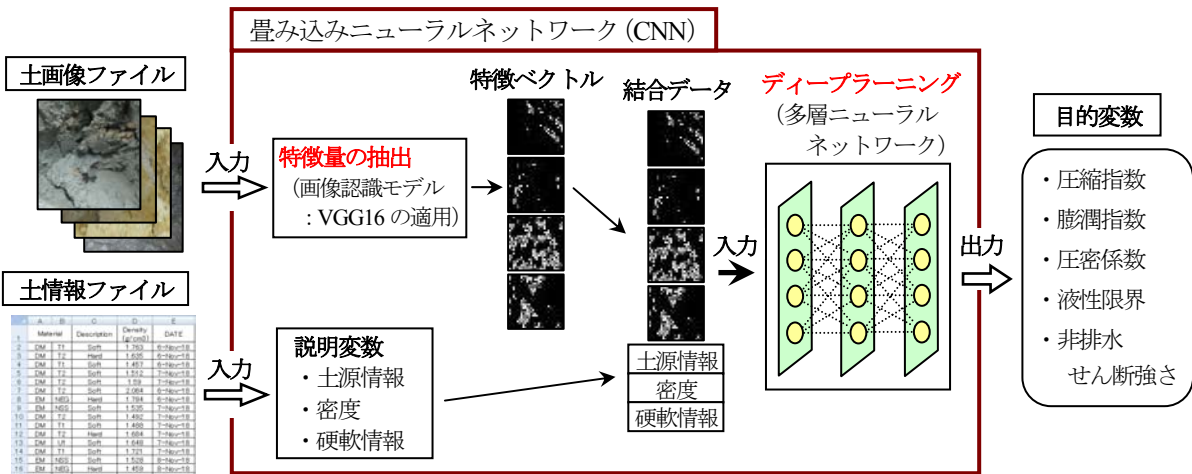


図-2 土質特性に関する機械学習のモデル構造




図-3 沈下解析における地盤の三次元要素分割イメージ

る手法を提案している。この手法は、地盤を三次元要素に分割した後、各要素に作用する応力をBoussinesqの弾性理論式を用いて求め、一次元圧密方程式をモンテカルロシミュレーションにより解析する手法である。本研究は、土田・小野¹⁰⁾の手法を援用し、 c_c 法等の設計で用いられる圧密計算手法に基づく簡便な準三次元解析手法を用いる。沈下量は以下のような方法によって計算する。

- ① 図-3のように地盤を三次元要素に分割し、要素ごとに独立に沈下量を計算する。地表面の総沈下量は、各要素の沈下量の総和によって求められる。
- ② 各要素に作用する地中応力は、地盤を弾性体と仮定したBoussinesqの式を用いて計算する。
- ③ 各要素の最終沈下量は、 c_c 法を用いて計算する。
- ④ 多層地盤における圧密速度は、ドレーンが打設されない場合は換算層厚法、打設される場合はBarronの近似式を用いて計算する。


土運船の各投入に対する堆積形状解析により土層構成を含む堆積形状を推定した後、地盤を三次元要素に分割し、AIにより推定されている各要素の圧密定数を入力することにより、将来沈下解析を実施する流れとなる。

3. 土質試験および模型実験


前章に示した土質推定 AI モデルおよび堆積形状解析モデルの構築に際しては、各種パラメータの最適化を図るための実測データが必要である。本研究では、土質推定 AI モデルの構築のために、液性限界・塑性限界試験および標準圧密試験を実施し、また、堆積形状解析モデルの構築のために、土運船から投入した粘性土の海底面での堆積形状を調べる遠心模型実験を実施した。

(1) 土質試験結果

土質推定に関する機械学習用の教師データを取得するために、粘性土の土源情報を把握した上で、60 ケースの液性限界・塑性限界試験と 40 ケースの標準圧密試験を実施した。代表的な試験結果として、圧縮指数 c_c および液性限界 w_L の値と湿潤密度 ρ の関係を図-4 に示す。粘性土の土源としては、浚渫粘土と陸上の掘削粘土に大きく分類されるため、図中、分けて表示している。粘性土の物性値として直ちに把握できる湿潤密度と各種土質定



(a) 圧縮指数



(b) 液性限界

図-4 各種土質定数と湿潤密度の関係




図-5 正規化含水比と非排水せん断強さの関係

数について、明確な相関は見られず、土質定数の値を簡便に推定することが容易でないことが分かる。

また、図-5に、含水比 w を液性限界 w_L で除した正規化含水比 w/w_L とベーンせん断試験により調べた非排水せん断強さ c_u の関係を示す。両者の相関は高く、この結果は、粘性土の液性限界の値が分かれば、湿潤密度から含水比を計算し、正規化含水比を用いて非排水せん断強さを推定することが可能であることを示唆している。


(2) 遠心模型実験結果

堆積形状解析モデルの構築のために、土運船から投入した粘性土の海底面での堆積形状を調べる遠心模型実験を実施した。遠心模型実験の実施状況を図-6 に示す。

積載量 $1,500 \text{ m}^3$ を想定した土運船の 1/90 模型を使用し、90 G の遠心加速度を与えて、土運船から投入した粘土の海底面での堆積形状を調べる遠心載荷実験を行った。

実験では、土運船が底開できる装置を用いることにより、実際の粘性土の投入を模擬できるようにした。4 種類の粘性土を使用し、3 条件の含水比および 2 条件の与投入高さを与えて実験を行った。

実験後、レーザー変位計を使用して土運船の横断方向及び縦断方向の堆積高さを計測することにより、粘性土



(a) 使用した土運船模型



(b) 粘土投入後の状況

図-6 遠心模型実験実施状況

の堆積形状を評価した。堆積形状は、含水比（粘土の非排水せん断強さ）に大きく依存するが、投入高さにはほとんど依存しないことが分かった。すなわち、粘性土を投入した場合、堆積形状は、作用する土圧（自重）と粘性土の強度によって概ね定まることを明らかにした。

堆積形状解析モデルにおいては、堆積の広がり程度を支配する標準偏差（拡散係数）が未知パラメータであるため、実験で得られた堆積形状を解析で再現できる適切な標準偏差の値を試行錯誤的に検討した。標準偏差の値を適切に設定することにより、図-7のように、実験で得られた堆積形状を解析で再現できることが分かった。また、標準偏差の値は、図-8のように非排水せん断強さをを用いて推定することができることが分かった。

図-5の結果とあわせ、含水比と液性限界の比である正規化含水比の値が分かれば、非排水せん断強さを推定することができるとともに、標準偏差の値を推定し、堆積形状解析を実施することができる。

4. 解析モデルの検証および解析結果例

(1) 土質推定 AI

機械学習において、土源情報、湿潤密度、撮影画像および触感による硬・軟情報を入力データに設定し、圧縮指数、膨潤指数、圧密係数、液性限界を出力データである目的変数に設定した。非排水せん断強さについては、推定された液性限界の値と事前に把握している湿潤密度より正規化含水比を求め、図-5に示される関係式を用いて推定することができる。

前章で述べた 60 ケースの液性限界・塑性限界試験と 40 ケースの標準圧密試験の結果（結果例は図-4）を機械学習用の教師データに利用した。なお、試験は、浚渫粘土と陸上の掘削粘土が同数程度になるように実施している。また、試験試料に対して、1,000 万画素数程度の一般




図-7 実験で得られた堆積形状に対する再現解析結果






図-8 非排水せん断強さと標準偏差の関係



(a) 浚渫粘土



(b) 陸上の掘削粘土

図-9 機械学習に利用した粘土の画像例

的なデジタルカメラを用いて50 cm程度の距離から撮影した画像を機械学習における画像データとして利用した。利用した画像の例を図-9に示す。

ただし、機械学習を行うにあたり、教師データの数が十分でない判断し、データ数の拡張を図った。特に、画像に関しては、トリミング箇所の複数化、回転、上下・左右反転、彩度・明度調整、コントラスト調整、ぼかし、シャープ化等の処理を行って画像数を増加させた。さらに、上記の処理により画像数を増加させた際に、紐付けられる入出力の数値データに対してノイズを加えることにより、データ種類の効果的な増加を図った。数値データに対するノイズの加え方としては、試験等で得られた真値を平均値に設定し、変動係数を0.1に設定した正規分布に従うように、ばらつきを与える手法を用いた。

上記のデータ数の加工処理により、データ数を400倍の16,000に増加させて機械学習を行った。

本研究のCNNにおいて、画像認識モデルとして、一般

表-1 ニューラルネットワークにおけるハイパーパラメータ

パラメータ名	設定値
データのスケール変換手法 ²⁾	最大値・最小値による正規化
中間層の階層数	4
中間層のニューロン数	200
活性化関数 ²⁾	ReLU 関数
最適化問題の解法 ²⁾	Adam
Dropout 率 ²⁾	0.1

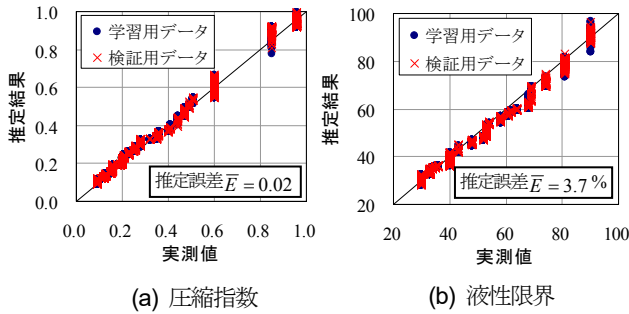


図-10 土質推定 AI による推定結果と真値の比較例

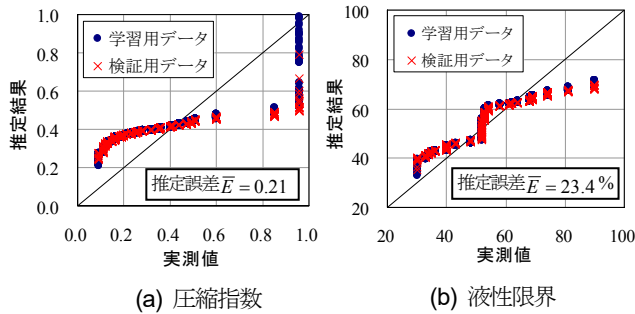


図-11 画像を使用しないモデルの推定結果と真値の比較

に公開されているVGG16を使用し、出力される特徴ベクトルと説明変数の結合データの解析には多層のニューラルネットワーク（ディープラーニング）を使用する。使用したニューラルネットワークのハイパーパラメータの一覧を表-1に示す。機械学習にあたっては、教師データのうちのランダムに抽出した80%をパラメータ最適化のための学習用、残りの20%をモデルの検証用に用いた。

代表的な土質定数として圧縮指数と液性限界に着目したAIの推定結果と真値の比較を図-10に示す。検証用データに対する推定値と真値の差の平均誤差 \bar{E} は、圧縮指数と液性限界でそれぞれ0.02, 3.7%と評価され、高い精度で推定できることが分かる。また、入力データとして、画像を使用せず、土源情報や湿潤密度等の変数のみにより学習したモデルの推定結果例を図-11に示す。画像を使用しないAIモデルでは、圧縮指数と液性限界の平均誤差はそれぞれ0.21, 23.4%で推定精度は低く、推定精度の向上には画像情報が必要であることが分かる。

(2) 堆積形状解析

400m×600mの範囲において実際に粘性土の埋立を

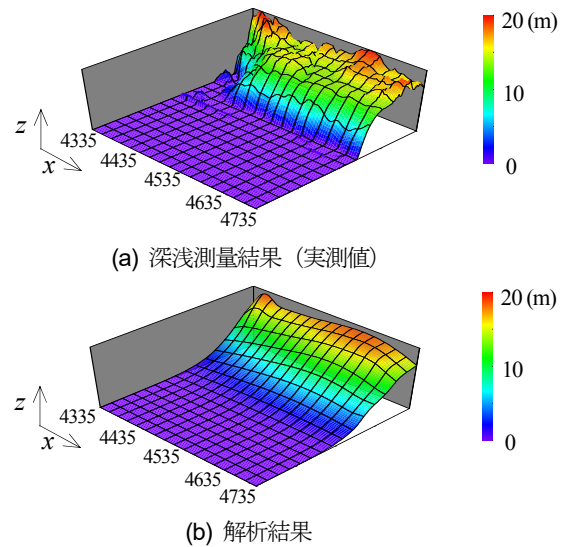


図-12 堆積形状に関する解析結果と実測値の比較




図-13 堆積高さに関する解析結果と実測値の比較

行った施工実績があり、その際の投入管理データに基づいて再現解析を実施した。積載容量が1,000 m³と1,500 m³の土運船を使用し、1,000回程度の投入により125万 m³（浚渫粘土：50万 m³，陸上発生土：75万 m³）の埋立を行ったものである。投入管理データとしては、土運船の投入座標と船首方向、粘性土の土源情報、撮影画像、計測した湿潤密度、硬・軟の触感情報が記録されている。

土運船による各投入土に対し、土質推定解析により液性限界や非排水せん断強さを推定した上で、入力する標準偏差を定め、投入座標や土運船の方向を反映した堆積形状解析を行った。実測の深浅測量結果と解析結果の比較を図-12と図-13に示すように、高い精度で堆積形状を推定できることが分かった。

(3) 将来沈下解析

堆積形状解析は、土運船の各投入に対して実施されるため、各投入土にラベル（ID番号）が付けられ、AIによって推定された土質特性の情報が紐付けられた土層構成を同時に出力することができる。各投入土に対し、土質推定解析と堆積形状解析を実施した後、図-3のように地盤を三次元要素に分割し、AIモデルにより推定されている各要素の圧密定数を入力することにより、想定荷重に対する将来沈下解析を実施することができる。

なお、沈下解析で入力する圧密降伏応力の値については、推定されている非排水せん断強さの大きさを強度増

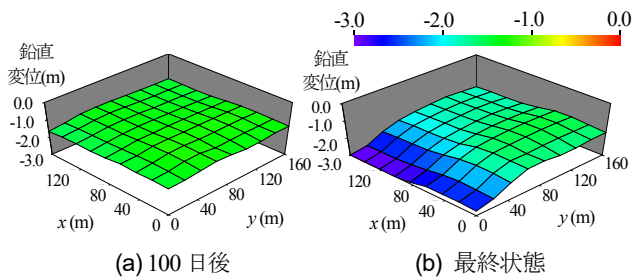


図-14 圧密沈下解析結果例 (ドレーン間隔: 1.5m)

加率 (=0.25 を仮定) で除して求めた。

実際の埋立土層に対して行った沈下解析結果例を図-14に示す。160 m 四方の範囲に 500 回程度の粘性土を投入し、層厚 25 m の埋立層が形成されている。解析では、ドレーン間隔を 1.5 m、上載荷重を 230 kN/m^2 に設定した。

このような解析は、適切な埋立高さ (嵩上げ高) の検討やドレーン間隔の設計に活用される。詳細な地盤調査を行うことなく、粘性土の埋立高さを効率的に決定し、埋立地の造成に必要な砂の使用量を最小化できる。

なお、本研究では、土田・小野¹⁰⁾の手法を援用し、 c_c 法等の設計で用いられる圧密計算手法に基づく簡便な準三次元解析手法を用いているが、精度については、今後、沈下量の計測結果を用いて検証する必要がある。

5. おわりに

本研究では、粘性土を用いて埋立を行うことを想定し、土運船上の粘性土に対し、土源情報、湿潤密度、写真等の情報より土質定数を推定する人工知能技術を導入するとともに、投入された粘性土の堆積形状解析と圧密沈下解析を統合した新しい埋立管理システムを構築した。

人工知能による土質推定技術および堆積形状解析技術については、土質試験結果や実際の埋立の施工データを用いて適用性を検証した。最終的に出力される沈下解

析結果については、今後、沈下に関する実測データを用いて精度の検証を行っていく必要がある。

参考文献

- 1) 宇津木慎司ら：AI を利活用したトンネル切羽地質状況自動評価システムの構築，トンネル工学報告集，第 27 巻，1-25，pp.1-7, 2017.
- 2) 斎藤康毅：ゼロから作るディープラーニング—Python で学ぶディープラーニングの理論と実装—，pp.165-273，オライリー・ジャパン，2016.
- 3) 熊谷隆宏，秋本哲平：人工知能技術とボーリング削孔時の計測データを活用した土質および強度推定手法に関する研究，土木学会論文集 B3 (海洋開発)，Vol.75, No.2, pp.L163-L168, 2019.
- 4) Simonyan, K. and Zisserman, A. : Very Deep Convolutional Networks for Large-Scale Image Recognition, In 3rd International Conference on Learning Representations (ICLR 2015), pp.1-14, 2015.
- 5) Szegedy, C., et al.: Going deeper with convolutions, Data Mining, Inference, and Prediction, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.1-12, 2015.
- 6) He, K., et al.: Deep Residual Learning for Image Recognition, Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 770-778, 2016.
- 7) 巢籠悠輔：詳解 ディープラーニング，pp.251-293，マイナビ出版，2017.
- 8) 松見吉晴，岸口孝文：捨石マウンド築造時のバージ船の配線位置について，海岸工学論文集，37 巻，pp.769-773, 1990.
- 9) 熊谷隆宏ら：ブロック直投方式を用いた人工海底山脈築造に関するブロックの落下挙動および拡散特性に関する研究，海岸工学論文集，51 巻，pp.801-805, 2004.
- 10) 土田孝，小野憲治：数値シミュレーションによる不同沈下の予測とその空港舗装設計への適用，港湾空港技術研究所報告，第 27 巻，4 号，pp.123-200, 1987.

(Received February 6, 2020)

(Accepted May 1, 2020)

RECLAMATION MANAGEMENT SYSTEM BY USE OF ARTIFICIAL INTELLIGENCE FOR ESTIMATING SOIL PROPERTIES

Takahiro KUMAGAI, Ke BAI, Yu SASAKI, Tsukasa TASHIRO, Tsuyoshi KOTOURA and Fumitaka TSURUMI

It is desirable to effectively use clayey soil for reclamation from the viewpoint of sustainable development of society. In use of clayey soil, the stability against slip and future settlement should be examined, and it is important to understand the soil properties in advance. In this study, we introduce artificial intelligence technology to estimate soil properties such as consolidation constants based on information such as soil source, wet density, and picture. It is confirmed that the machine learning model developed by using the Convolutional Neural Network (CNN) can accurately estimate the consolidation constants, the liquid limit, etc. This paper proposes a landfill management system that integrates the AI model to estimate soil properties with the sedimentary shape analysis model and settlement analysis model.