

コーン貫入試験と人工知能技術を活用した 土質定数推定手法に関する研究

秋本 哲平¹・江守 辰哉²・片山 遥平²・上野 一彦²・熊谷 隆宏²

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: teppei.akimoto@mail.penta-ocean.co.jp (Corresponding Author)

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)

海底地盤のN値や土質定数を取得するための調査では、自己昇降式作業台船(SEP船)等を必要とし、気象海象の影響を強く受けることから、コーン貫入試験のような簡便かつ短期間で実施可能な調査方法が求められている。コーン貫入試験は、経験的に得られた換算式による土質定数の推定が可能であるものの、土質や場所によって換算式の選定や換算式に用いるパラメータの微調整が必要となる。本研究では土質定数(N値、 F_c)の推定精度を高める手法として、人工知能技術(AI)の活用による推定手法の適用性を検討した。検討結果から、AIを用いることで推定精度の向上を見込めることが示唆されたものの、AIで推定する際は、推定する地点における数点のコーン貫入試験結果を取得し、事前に学習する必要があることがわかった。

Key Words : neural network, deep learning, soil constant, sounding, cone penetration test

1. はじめに

我が国の構造物基礎の設計は、N値を使用することが多いことから、調査項目としてN値を欠かすことはできない。そのため、海底地盤の調査も、陸上と同じようにボーリングと採取試料の土質試験によって行われることが一般的である。N値の取得方法である標準貫入試験は、海底地盤を調査対象とした場合、海上からの作業となるため、水深に応じた引き上げ作業が必要となることから、大水深であるほど効率が悪く、非常に手間のかかる作業となってしまう。また、海上で調査を実施する場合、自己昇降式作業台船(SEP船)等を必要とし、気象海象の影響を強く受けるため、コーン貫入試験¹⁾のような簡便かつ短期間で実施可能な調査方法が求められている。

コーン貫入試験は、ヨーロッパを中心に地盤調査、設計に広く用いられており、地盤特性を連続的かつ経済的にリアルタイムで把握できることから、洋上風力発電の地盤調査でも使用されている。標準貫入試験のように直接N値を計測することはできず、試料を直接観察することもできないため、コーン貫入試験で取得できる先端抵抗、周面摩擦、間隙水圧を組み合わせる土質分類を行う手法がいくつか提案されている²⁾³⁾⁴⁾。鈴木ら⁵⁾は、Robertson⁶⁾の提案する土質性状指数 I_c を用いることで、日本の土に関する土質分類が可能であることを確認し、コーン貫入試験結果を土質定数に換算する式を提案して

いる。これらの経験的に得られている換算式を用いることで、コーン貫入試験の結果から土質定数を推定することが可能であるが、土質や場所によっては換算式の選定や換算式に用いるパラメータの微調整が必要となる。

一方、熊谷・秋本⁷⁾は、ボーリング削孔時の計測データを活用し、人工知能技術であるディープニューラルネットワークに基づくマルチタスクモデルによりN値や細粒分含有率を推定する手法を提案している。本研究では、既往の地盤調査方法であるコーン貫入試験より得られた計測データや各種の管理データを多種類かつ大量のデータ分析を可能とする人工知能技術(AI)によって分析し、土質定数を推定する手法を提案する。提案する手法について、従来の換算式による推定精度と比較しながら、適用性の検討を行った。

2. 使用データ

人工知能技術(AI)を活用するため、コーン貫入試験結果(入力データ)とボーリング結果(正解データ)がセットとなったデータを使用した。使用データは、3地点(A・B・C)で取得したデータである。使用データの一例を表-1に示す。ボーリング本数は少ないものの、概ね深度1mごとにN値と細粒分含有率 F_c を取得しているため、総データ数は、N値が648、 F_c が441となっており、数多く

のデータを使用している。

(1) データの取得

地点 A のデータは、国外の埋立工事の際に事前調査で取得したデータであり、ボーリング 1 本に対してコーン貫入試験 1 本が対応しているものの、ボーリングとコーン貫入試験の平面距離は 2~7m の範囲にあり、平均 4.6m 離れているため、多少信頼性が低いデータも含まれている。深度 25m までのデータを取得しており、N 値の範囲が 2~50、 F_c の範囲が 2~100% と多種類の土層で構成されている地盤である。

地点 B と地点 C のデータは、本研究のために茨城県内で取得したデータであり、1 本のボーリングの周辺で 9 本のコーン貫入試験を実施したものである。コーン貫入試験は、1 台の機械で実施しているため、機械によるばらつきは無い。また、ボーリングとコーン貫入試験の平面距離は、最大 4m、平均 1.6m であり、ボーリングに近い位置でコーン貫入試験を実施しているため、信頼性の高いデータである。地点 B は、深度 25m までのデータを取得しており、N 値の範囲が 1~24、 F_c の範囲が 4~68% の砂質土を主体とした地盤である。地点 C は、深度 15m までのデータを取得しており、N 値の範囲が 1~50、 F_c の範囲が 4~92% のシルトを主体とした地盤である。上記のように、国内外 3 地点のデータを使用することで、多種類の土質を推定対象としている。

(2) 取得データの整理方法

コーン貫入試験は、深度 1m ごとに実施される標準貫入試験に比べ、深度方向に連続的にデータを取得できるといった特徴を有しており、深度 1cm ごとにデータを取得している。N 値は、標準貫入試験で測定される深さ 30cm 分を測定深度ごとに設定し、 F_c は試料を採取した深度ごとに設定した。機械学習を行う上で、N 値や F_c の調査深度と一致するようにコーン貫入試験結果を抽出して紐付けした。

AI を活用した土質定数の推定手法 (AI 法) を適用する際のデータ構成を表-2 に示す。換算式を用いて土質定数を推定する方法 (従来法) と AI 法のいずれの推定方法においても推定する土質定数 (目的変数) は、液状化判定が可能となる N 値と細粒分含有率 F_c の 2 種類とした。AI 法における説明変数は、従来法で使用する先端抵抗、周面摩擦、間隙水圧のデータ (CPT データ) に加え、貫入速度、貫入深度、貫入角度といった貫入時の制御データ、コーンの外径およびボーリングからの距離を使用した。貫入時の制御データは、CPT データに影響を与えていると考えられることから、説明変数として使用することで、土質定数の推定精度向上が期待できる。コーンの直径は、国によって標準的に使用されるコーンの直径が

表-1 使用データ一覧

| 地点 | ボーリング (本) | コーン試験 (本) | N 値 | F_c |
|----|-----------|-----------|-----|-------|
| A | 10 | 10 | 123 | 78 |
| B | 1 | 9 | 396 | 234 |
| C | 1 | 9 | 129 | 129 |
| 合計 | 12 | 28 | 648 | 441 |

表-2 AI による推定時のデータ構成

| 説明変数 (入力値) | | 目的変数 (出力値) |
|------------|-------|--------------|
| CPT データ | 貫入抵抗 | N 値 F_c |
| | 周面摩擦 | |
| | 間隙水圧 | |
| 制御データ | 貫入速度 | |
| | 貫入深度 | |
| | 貫入角度 | |
| 形状データ | コーン外径 | |
| 位置データ | 距離 | |

表-3 検討ケース一覧

| 検討ケース | 学習データ | テストデータ |
|-------|-----------------------------|----------------|
| ケース1 | 地点 B・C のデータを用いた従来法の換算式による推定 | |
| ケース2 | 地点 A・B・C : 80% | 地点 A・B・C : 20% |
| ケース3 | 地点 A・B : 100% | 地点 C : 100% |
| ケース4 | 地点 A・B : 100% + 地点 C : 3本 | 地点 C : 3本 |

異なることから、説明変数として使用している。ボーリングからの距離は、ボーリング (目的変数) とコーン貫入試験 (説明変数) との平面的な距離を示しており、距離が近いほど目的変数と説明変数の相関が高くなると考えられるため、距離も説明変数として加えている。

3. 土質定数の推定方法

検討ケースを表-3 に示す。ケース 1 は、従来法の換算式による推定であり地点 B と地点 C のデータを用いた。ケース 2,3,4 は学習データとテストデータの条件を変更した AI 法による推定であり、地点 A・B・C のデータを用いて汎化性能を検証している。

(1) 従来法での推定方法

従来法では、いくつか提案されている換算式から、最も精度が高かった式(1)と式(2)を使用した⁹⁾。なお、単位体積重量は、繰り返し計算によって決定している。

$$N = 0.341I_c^{1.94}(q_t - 0.2)^{(1.34 - 0.0927I_c)} \quad (q_t > 0.2\text{MPa})$$

$$= 0 \quad (q_t \leq 0.2\text{MPa}) \quad (1)$$

$$F_c = I_c^{4.2} \quad (2)$$

$$I_c = [(3.47 - \log Q_t)^2 + (\log F_r + 1.22)^2]^{0.5} \quad (3)$$

ここで、 I_c は土質性状指数、 q_t は補正先端抵抗 γ 、 Q_t は基準化先端抵抗 γ 、 F_r は基準化周面摩擦比 γ である。

(2) 人工知能技術を活用した推定方法

図-1にAI法による推定手順を示す。各地点で取得したデータを整理した後、学習データを用いて機械学習を実施する。機械学習の手法としては、ボーリング時の計測データをAIで分析して土質定数を推定した熊谷・秋本⁹⁾の研究と同様に、ディープニューラルネットワーク(DNN)⁸⁾を使用した。使用したDNNのモデルを図-2に示す。ニューラルネットワークは、入力層と出力層の間に中間層(隠れ層)と呼ばれる層を持ち、階層的に信号が処理されることにより、高度な情報処理が可能となる手法である。この中間層を多層とすることで、情報伝達と処理を増やし、予測精度を向上させたモデルがディープニューラルネットワーク(DNN)である。中間層のニューロン数や階層数、パラメータ最適化手法等のハイパーパラメータ⁸⁾と呼ばれる学習を制御するパラメータは、多数の組み合わせに対して推定誤差を評価し、推定誤差が最小となる最適な値を設定した。推定誤差の評価は、式(4)で定義される推定値と実測値の差の平均二乗誤差MSEを用いた。

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

ここで、 n はサンプル数、 y_i は実測値、 \hat{y}_i は推定値を示している。

ハイパーパラメータの検証は、バリデーションと呼ばれる分割交差検証を用いており、本研究では4分割交差検証を採用した。学習データをランダムに4分割し、1つのデータ群(検証データ)を検証用とし、残りの3つのデータ群(訓練データ)で学習する手法である。この手法によって、学習していないデータでハイパーパラメータの精度を検証することができるため、最適なハイパーパラメータが決定され、土質定数を推定するAIモデルが完成となる。このモデルに学習データとは異なるテストデータを入力して土質定数を推定し、AIモデルの推定精度および汎化性能を確認している。

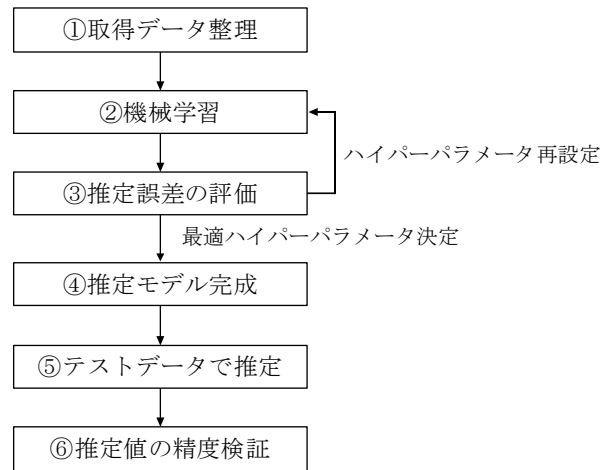


図-1 AI法による推定手順

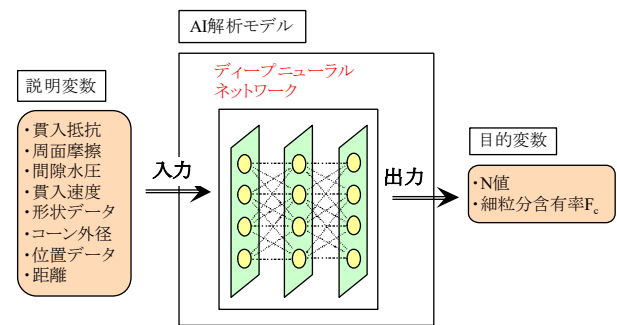


図-2 ディープニューラルネットワークの概念

4. 土質定数の推定結果

テストデータでの推定精度は、平均二乗誤差(式(4))の平方根となる式(5)の二乗平均平方根誤差RMSE⁹⁾と式(6)の決定係数 R^2 を用いて検証した。RMSEは、個々の実測値と推定値との誤差のサンプル全体の平均を意味しており、誤差の絶対量であるため、小さい値ほど実測値に近い推定値となっている。 R^2 は、推定値の精度を示す値であり、1に近いほど実測値と等しいことを表している。式(6)に示す通り、推定値があまりにも実測値と離れている場合には負の値を示すこともある。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6)$$

ここで、 \bar{y} は実測値の平均値を示している。

(1) 従来法での推定結果

データの信頼度が高い地点B・Cのコーン貫入試験結

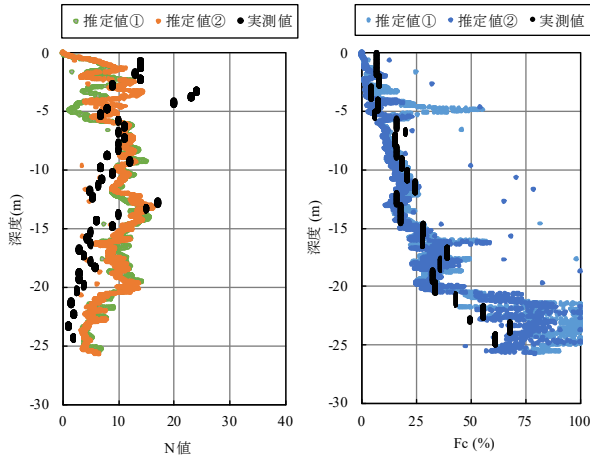


図-3 従来法での推定 N 値と推定 F_c の深度分布 (地点 B)

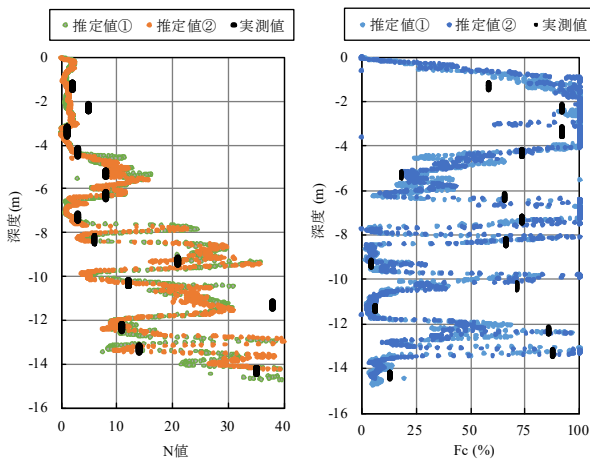


図-4 従来法での推定 N 値と推定 F_c の深度分布 (地点 C)

果を用いて従来法による土質定数の推定を行い、推定精度を確認した(ケース1)。従来法での推定結果の例として、地点Bにおける推定N値と推定 F_c の深度分布を図-3に、地点Cにおける深度分布を図-4に示す。ボーリングとコーン貫入試験の平面距離が1mと非常に近く、信頼度の高い2か所(調査位置①および②)のコーンデータをそれぞれ示している。地点Bは砂質土主体であるが、下部にシルト層が存在するため、下部のN値が低い地盤となっている。N値の推定値は、10前後の値が多く、実測値との誤差が大きくなっている深度が見られる。 F_c の推定値は、深度が深くなるほど F_c が高くなる実測値の傾向と同様の傾向を示しているが、 F_c が高くなるほど誤差が大きくなっている。地点Cは、浅い深度ではシルト主体の土質であるが、深度10m以深からはシルト層と細砂層の互層地盤となっており、推定が難しい地盤といえる。そんな地盤であっても従来法による推定値は、N値と F_c のいずれの定数も深度ごとの差が大きくなっており、実測値と同様の傾向を示している。既往の文献¹⁰⁾¹¹⁾に見られるように、深度分布で見ると概ね地盤の特徴をとらえていることが確認できる。

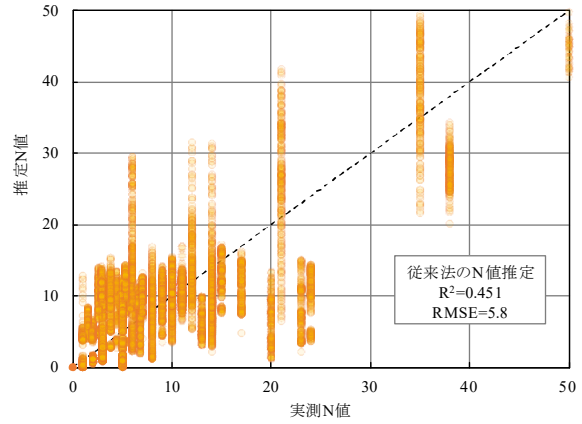


図-5 従来法によるN値の推定結果(ケース1)




図-6 従来法による F_c の推定結果(ケース1)

地点B・Cの全データでの推定N値と実測N値の関係を図-5に、推定 F_c と実測 F_c の関係を図-6に示す。なお、色が濃くなっている箇所ほど点数が多いことを示している。本対象地点では、N値10前後の推定値が多く、 F_c は50%以上の範囲で実測値より高く推定していることがわかる。本ケースの決定係数 R^2 は、N値が0.451、 F_c が0.548となっており、いずれも0.5程度の値であることから相関関係が確認された。しかしながら、N値のRMSEは5.8、 F_c のRMSEは16.2%となっていることから、推定値にはある程度の誤差が含まれていることがわかった。

(2) 人工知能技術(AI)による推定結果

検討ケース2では、地点A・B・Cの全データをランダムに学習データ8割とテストデータ2割に分割し、学習していないテストデータにて精度を検証している。図-7、図-8に推定値と実測値の関係を、表-4に各ケースの推定精度の一覧を示す。本ケースの決定係数 R^2 は、N値が0.992、 F_c が0.997であり、RMSEはN値が0.94、 F_c が1.5%となった。非常に高い推定精度が得られていることから、テストデータと同地点におけるデータで学習する




図-7 AI法によるN値の推定結果(ケース2)




図-8 AI法によるFcの推定結果(ケース2)

表-4 推定精度一覧

| 検討ケース | 決定係数 R^2 | | 二乗平均平方根誤差 RMSE | |
|-------|------------|--------|----------------|------|
| | N値 | Fc | N値 | Fc |
| ケース1 | 0.451 | 0.548 | 5.8 | 16.2 |
| ケース2 | 0.992 | 0.997 | 0.94 | 1.5 |
| ケース3 | -0.173 | -2.391 | 12.7 | 57.8 |
| ケース4 | 0.882 | 0.518 | 3.7 | 21.4 |

ことにより飛躍的に精度が向上することがわかった。そこで、ケース3では、地点Aと地点Bのデータで学習し、全く学習していない地点Cのデータでの推定を行った。表-4に示す通り、 R^2 はN値、 F_c ともに負の値となり、RMSEも非常に大きな値となっていることから、推定値の精度は非常に低いことがわかる。ケース2とケース3の検討結果から、目的変数である土質定数と説明変数であるコーン貫入試験関連データとの相関関係は、地点によって異なっているものと想定される。そのため、AI法にて土質定数を推定する際は、推定地点におけるデータが必要であると考えられる。

検討ケース4の土質定数推定値の深度分布を図-9に示す。なお、ボーリングからの距離が1mと最も近く、信

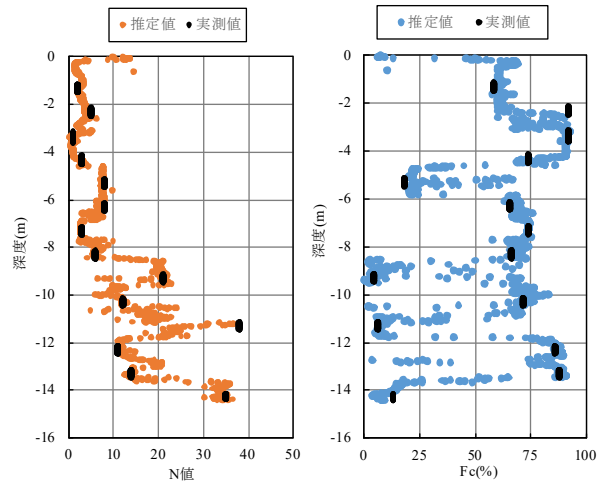


図-9 AI法での推定N値と推定Fcの深度分布(ケース4)

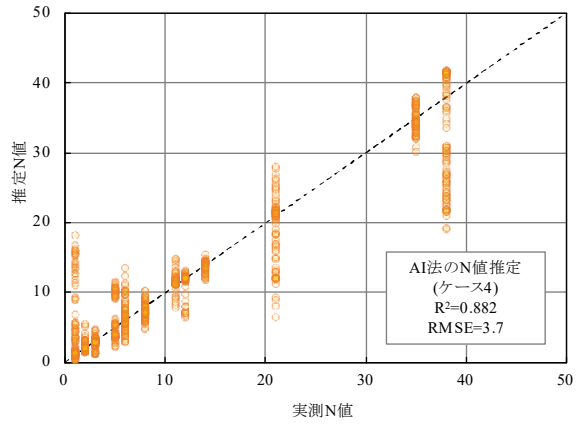


図-10 AI法によるN値の推定結果(ケース4)

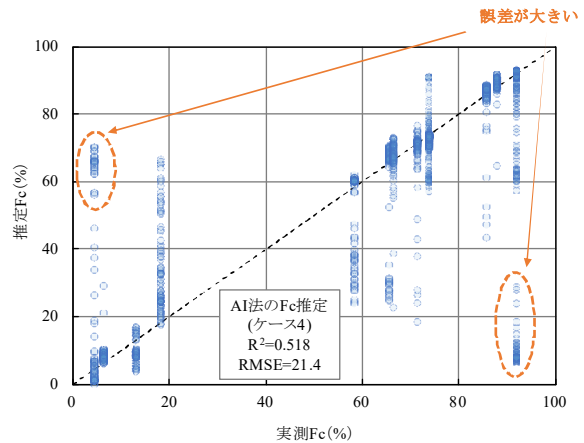


図-11 AI法によるFcの推定結果(ケース4)

頼度の高い1箇所を示している。ケース4は、実施工でのAI法の適用を想定した検討であり、施工箇所を地点Cと仮定し、施工前に地点Cにて3本の学習データを取得できた場合を仮定している。推定精度を正確に確認するため、地点Cのデータは、信頼度の高い、

ボーリングから 1.5m 以内のデータを使用した。地点 C は、下部になるほど砂層とシルト層が互層になっており、推定が難しい地盤であるものの、推定値は、実測値の傾向を示すことができている。図-10, 図-11 に推定値と実測値の関係を示す。N 値は、 R^2 が 0.882, $RMSE$ が 3.7 となっており、高い精度で推定ができていることがわかる。 F_c は、 R^2 が 0.518, $RMSE$ が 21.4% となっており、従来法と概ね同様の推定精度であった。しかしながら、 F_c の実測値の深度分布は、深度 1m の間で 80% 程度異なっている箇所もあり、その境界部分の推定も含まれることから、高 F_c と低 F_c 箇所において誤差が大きくなっているものと考えられる。

5. おわりに

本研究では、コーン貫入試験結果から土質定数を推定する際の精度向上を目的として、AI を活用した推定手法の適用性について検討した。AI を活用することにより、従来から使用されている CPT データに加え、コーン貫入時の制御データや平面距離データといった多種類かつ大量のデータ分析が可能となるため、推定精度の向上を見込めることが示唆された。一方で、全くの未学習地点においては、推定精度が極端に低下することも確認された。実用化においては、推定地点で学習用の計測データを取得することにより、一定の推定精度を確保することが可能であると考えられる。

海底地盤の調査においては、簡便かつ精度のよい試験方法が求められている。コーン貫入試験は、AI 技術の活用により、海底地盤の調査方法として更に有効な手段になり得るものと考えられる。そのため、現時点において不足していると考えられるボーリング調査数を増加し、

教師データを蓄積することにより、更なる推定精度向上に向けて検討を進めていく所存である。

参考文献

- 1) 地盤工学会：地盤調査の方法と解説—二分冊の1—, p.366, 2013.
- 2) Robertson, P.K. : Soil classification using the cone penetration test, *Canadian Geotechnical Journal*, Vol.27, No.1, pp.151-158, 1990.
- 3) Jefferies, M.G. and Davies, M.P. : Soil classification by the cone penetration test, Discussion, *Canadian Geotechnical Journal*, Vol.28, No.1, pp.173-176, 1991.
- 4) Robertson, P.K. and Fear, C.E. : Liquefaction of sands and its evaluation, *Proceedings of the First International Conference on Earthquake Geotechnical Engineering*, IS TO-KYO '95, Vol.3, pp.1253-1289, 1995.
- 5) 鈴木康嗣, 時松孝次, 實松俊明：コーン貫入試験結果と標準貫入試験から得られた地盤特性との関係, 日本建築学会構造系論文集, 第 566 号, pp.73-80, 2003.
- 6) 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.I_163-I_168, 2019.
- 7) 地盤工学会：地盤調査の方法と解説—二分冊の1—, pp.391-392, 2013.
- 8) 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.190-203, オライリー・ジャパン, 2016.
- 9) 小田和広, 横田健一, ト令東：ニューラルネットワークによる神戸沖沖積粘土の土性分布の予測, 第 59 回地盤工学シンポジウム, pp.707-714, 2014.
- 10) 末政直晃, 片桐雅明, 飯沢誠：コーン貫入一斉試験 2007, 地盤工学会誌, Vol.57, No.8, No.619, pp.16-19, 2009.
- 11) 吉村貢, 斎藤邦夫, 利藤房雄：CPT 結果のばらつき要因分析, 地盤工学会誌, Vol.57, No.8, No.619, pp.20-23, 2009.

(Received February 4, 2021)

(Accepted April 23, 2021)

PREDICTION METHOD OF SOIL CONSTANT BY USING CONE PENETRATION TEST AND ARTIFICIAL INTELLIGENCE TECHNOLOGY

Tepei AKIMOTO, Tatsuya EMORI, Youhei KATAYAMA,
Kazuhiko UENO and Takahiro KUMAGAI

Soil investigation to obtain the N value and soil constants of the seafloor ground require a workbench, such as the Self-Elevating Platform (SEP) ship, as well are strongly affected by meteorological and oceanographic conditions. Therefore, a simple investigation method such as a cone penetration test is required. In the cone penetration test, it is possible to predict the soil constants using empirical conversion formulas. However, the conversion formulas need minor adjustments for different soil properties and investigation locations. In this study, we will improve the prediction accuracy of the soil constants (N value, F_c) by utilizing the artificial intelligence technology (AI). The results of the study suggested that the use of AI could improve the estimation accuracy. When applying the AI technology, a number of existing data is required for pretraining the prediction method.