

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

熊谷 隆宏¹・秋本 哲平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: 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)
E-mail: Teppei.Akimoto@mail.penta-ocean.co.jp

液状化対策工として薬液注入工法を実施する際、あるいは地震時における地盤の液状化の可能性を判定する際に、細粒分含有率やN値といった性状を綿密かつ正確に把握できていることが望ましい。埋立地盤のような複雑な土層構成においても、細粒分含有率やN値を精度良く推定するため、2011~2017年における東京国際空港の地盤改良工事で取得したボーリング削孔時の計測データを活用するとともに、非線形の回帰が可能なランダムフォレスト法、サポートベクターマシン、ニューラルネットワークの3タイプの機械学習モデルを構築し、それぞれの適用性を検討した。特に、ニューラルネットワークで細粒分含有率やN値を同時に学習するマルチタスクモデルにより、精度良く推定できることが分かった。

Key Words : *neural Network, deep learning, machine learning, soil property, permeable grouting method*

1. はじめに

地震時に液状化する可能性のある地盤に対しては、適切な地盤改良による対策が実施されるが、特に、近傍に既存の施設が存在する場合には、隆起や側方変位等の影響の少ない浸透型薬液注入工法が広く適用されている。

浸透型薬液注入工法は、製造時は水と同程度に粘性が低く、一定時間経過後にゲル化する特性を持つ薬液を低圧で土中に注入し、間隙水を薬液に置き換える工法であるため、周辺地盤への影響が極めて小さい長所を持つ。ただし、対象地盤の透水性が低い場合、通常の注入速度で薬液を注入すると、土粒子骨格を崩しながら薬液が圧入される「割裂注入」になりやすい¹⁾。地表面への薬液の漏出や地盤の隆起、また上部施設の損傷が生じる等の危険性があるため、細粒分含有率が20%以上の高い地盤では、注入速度を低減させる等の対応が必要である。すなわち、薬液注入工法の適用に際しては、注入位置の土質性状に応じて、注入速度や注入率等の薬液注入諸元を適切に設定する必要がある。

港湾や空港等に代表される埋立によって造成された地盤は、埋立時に投入した土の性状によって複雑な土質

構成となっているため、50m程度に1か所の事前ボーリング調査だけで対象区域全体の土質を綿密に把握することは極めて難しい。そこで、海野ら²⁾は、薬液注入管を挿入するための先行削孔工程で使用される機械にセンサーを取り付けて取得した各種データを分析することにより、「砂質土」、「粘性土」といった土質区分を推定する方法を提案している。ただし、削孔時に得られた個々のデータは土質性状と高い相関があるとは言えず、精度の良い推定結果を得ることは容易でない。

なお、土質区分と関係がある細粒分含有率と、地盤の強度に係るN値の値をともに把握することができれば、その結果に基づいて液状化判定を行い、地盤改良が必要な範囲を設定することが可能である。澤田ら³⁾は、原位置のサウンディング調査法として、動的コーン貫入試験に間隙水圧計測を組み合わせることで、N値と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、ボーリング削孔時の計測データと土質関連の試験データの相関について、大量のデータの分析に極めて高い能力を発揮するニューラルネットワーク等の人工知能技術を用いて機械学習し、N値および細粒分含有率を推定する効率的で精度の良い手法を提案する。

2. 計測データおよび土質関連試験結果

土質およびN値の推定手法を構築するにあたり、2011～2017年の間に、東京国際空港における薬液注入工法による地盤改良工事で取得したデータを利用する。対象となる誘導路地盤の改良工事(5工区)の位置を図-1に示す。

取得したデータの詳細は、薬液注入管を挿入するための先行削孔時の計測データ、および事前のボーリング調査(全20箇所)における標準貫入試験および採取した試料に対する細粒分含有率試験の結果である。

削孔時に計測したデータ(以下、削孔関連データとする)は、送水圧(WP)、回転トルク(FOT)、削孔速度(SPD)、削孔荷重(LT)の深度5mm毎の連続データである。送水圧とは、掘削グズ(スライム)を地上に排出するための水を送る圧力であり、透水性の低い粘性土の掘削時に大きい値を示す傾向がある。また、削孔速度は、地盤が軟らかい粘性土で大きくなる傾向がある。一方、回転トルクは、削孔ロッドを回転させる力、また、削孔荷重は、押し込み圧力と時間を掛け合わせた値で定義され、それぞれ砂質や礫質の硬い地盤で大きい値を示す傾向にある。

削孔関連データは、5mm深度毎に連続的に取得されている一方、標準貫入試験により得られるN値やサンプリング試料に対する細粒分含有率の土質関連データは、離散的に得られている。削孔関連データと土質関連データの相関を分析、あるいは人工知能により機械学習するには、深度情報に基づき、削孔関連データと土質関連データを紐づけるようデータを加工する必要がある。

以下の方法により削孔関連データの加工を行った。

- ①ボーリング調査地点から半径7mの範囲内で取得された複数の削孔関連データに対し、各調査深度の上端から下端までの区間で平均処理する。
- ②ボーリング調査深度で平均値を求めた削孔関連データに対し、さらにボーリング調査地点からの距離の逆数

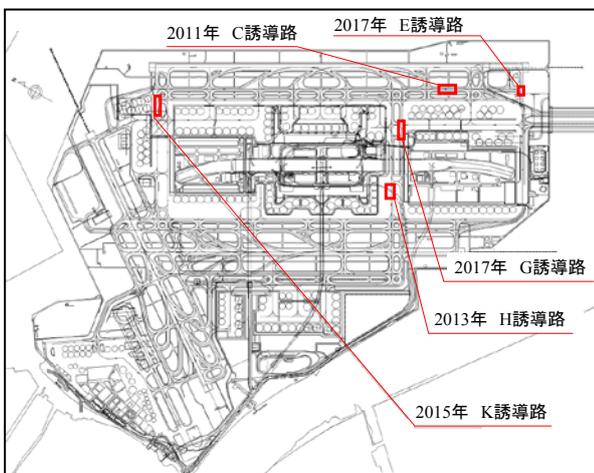
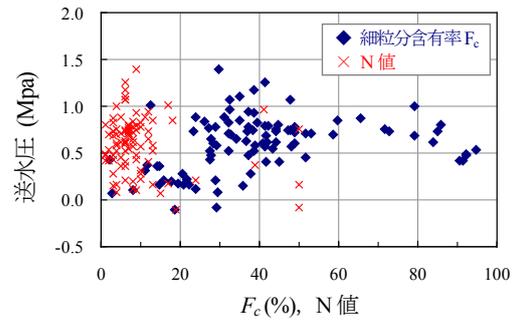


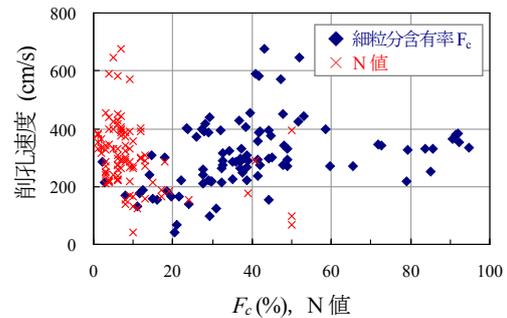
図-1 東京国際空港における薬液注入による地盤改良工事の実施位置(2011～2017年)

による重み付けを行って平均処理する。

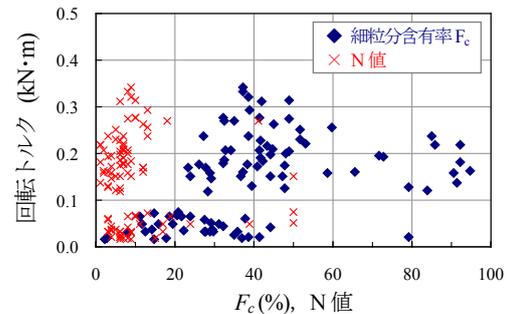
このように紐づけた削孔関連データと細粒分含有率(F_c)およびN値との関係を図-2に示す。個々の計測データと土質、またN値との相関を見出すことは容易でなく、個々の計測値が同程度であっても、特にN値は大きくばらつくことが分かる。深度情報を含む計測データを入力変数として、 F_c を推定する重回帰分析を行った結果を図-3に示す。線形解析の重回帰分析では、特に F_c が50%を超える領域で精度が低いことが分かる。



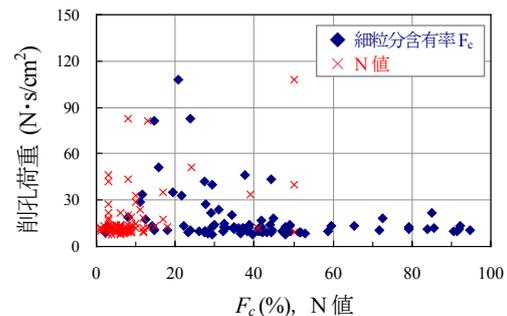
(1) 送水圧



(2) 削孔速度



(3) 回転トルク



(4) 削孔荷重

図-2 削孔関連データと土質関連データの関係

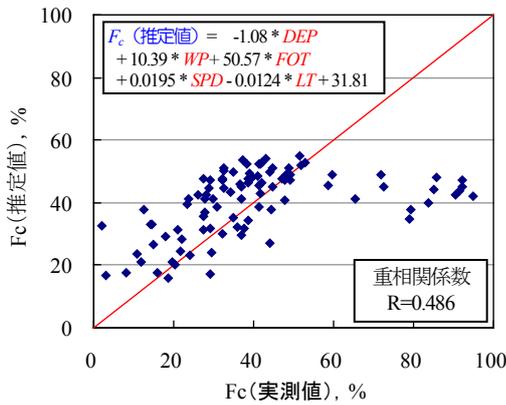


図-3 重回帰分析による細粒分含有率の推定結果と実測値の比較

表-1 機械学習における教師データの構成

説明変数	深度 (DEP)
	送水圧 (WP) の平均値と分散
	回転トルク (FOT) の平均値と分散
	削孔速度 (SPD) の平均値と分散
目的変数	削孔荷重 (LT) の平均値と分散
	細粒分含有率 (F_c) N値

3. 人工知能による機械学習手法

線形の重回帰分析では、 F_c が50%以上の粘性土に区分される領域で、精度が低いことが確認された。このため、本研究では機械学習手法のうち、非線形の回帰が可能なランダムフォレスト、サポートベクター、ニューラルネットワークの3つの手法を選定し、適用性の検討を行う。

(1) 教師データの作成

機械学習では、大量のデータを分析することが可能であるため、計測関連データについては、ボーリング調査区間内の「平均値」だけでなく、傾きやバラツキ等の特徴を考慮するため、「分散」を特徴量として追加する。表-1に示すように、深度および、送水圧、回転トルク、削孔速度、削孔荷重の各平均値と分散の9種類のデータを説明変数（入力）、また、細粒分含有率 (F_c) と N 値を目的変数（出力）とする教師データを作成した。

さらに、機械学習にあたっては、2次元の交互作用特徴量や多項式特徴量、すなわち、上述の説明変数に関して、「 $X_1 \cdot X_2$ 」や「 $X_1 \cdot X_3$ 」のように掛け合わせたものや、「 X_1^2 」や「 X_2^2 」のように二乗したものを追加する。

(2) 適用する機械学習モデル

a) ランダムフォレスト法

決定木法に基づくモデルは、例えば Hastie ら⁴⁾に示されるように、上から順に条件を分岐させた階層的な木構

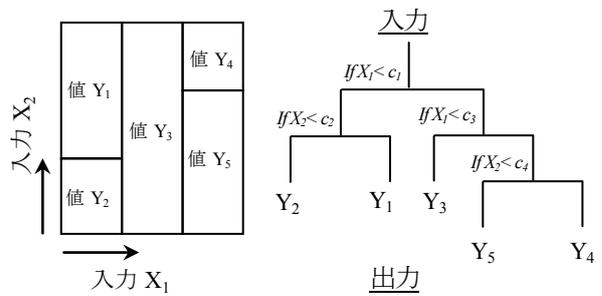


図-4 決定木法のモデル化例 (2次元データの分類)

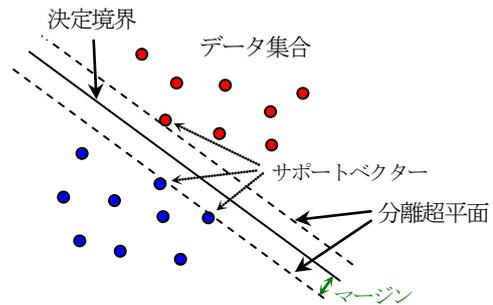


図-5 サポートベクターマシンにおけるデータの分類のイメージ

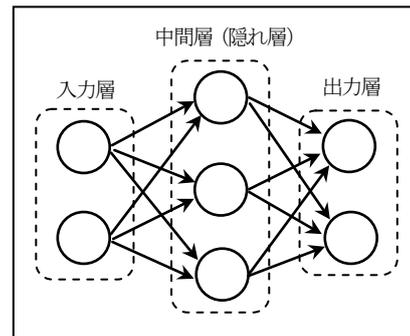


図-6 ニューラルネットワークの基本構成 (中間層の階層数やニューロン数は任意)

造で構成される。各ノードにおいて、閾値 c に対する特徴量 X の大小の判定を行って下方に分岐し、最終的に細分化した条件に合致する解を得ることができる。図-4に、決定木法モデルの例を示す。決定木法は、判断基準が木構造で可視化されるため、人間が理解しやすい長所がある一方、学習データにない範囲外の予測を行うことができない (外挿できない) 短所を持つ。

本研究では、決定木法の一つであるランダムフォレスト法を適用する。ランダムフォレスト法は、特徴量の少しずつ異なる複数の決定木をランダムに構築して、アンサンブル学習 (複数の学習モデルを構築し、それぞれに並列に予測させて平均値等を求めることにより最終予測を行う学習) を行う手法を用い、一般に単一モデルによる予測よりも精度が高いことが知られている。

b) サポートベクターマシン

サポートベクターマシンは、例えば Hastie ら⁴⁾や元田ら⁵⁾に示されるように、あるデータ集合に対してクラス

を分離する境界線（または平面）とデータ間の最短距離（マージン）を最大化するように決定境界を定めるモデルである（図-5）。近年、多項式や Gauss カーネル等を用いたカーネル法を組み合わせ、データを高次元空間上に写像することにより、非線形的なクラス分離やパターンの認識ができるように拡張されている。

c) ニューラルネットワーク

ニューラルネットワークは、例えば、斎藤⁶⁾や巢籠⁷⁾に示されるように、人間の脳を構成する神経細胞（ニューロン）の情報伝達や処理の特性を模擬するモデルである。図-6のように、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になる。この中間層が複数の場合は特に、ディープニューラルネットワークまたはディープラーニングと呼ばれる。

(3) 解析モデルの構築フロー

解析モデルを構築するフローを図-7に示す。削孔関連データと土質関連データを加工し、説明変数と目的変数と対応させた教師データを作成した後、機械学習モデルのタイプを選定する。それぞれのモデルには、ハイパーパラメータと呼ばれる学習や処理の挙動を制御するパラメータがあり、事前に設定する。

決定木法では、木の深さの最大値や葉の数の最大値等、サポートベクターマシンでは、カーネル関数等、また、ニューラルネットワークでは、中間層の階層数やニューロン数、パラメータ最適化手法（解法）、活性化関数等がハイパーパラメータに相当する。これらを事前に設定した上で、推定誤差を最小化するよう重みやバイアス等のパラメータの最適値を探索し、モデルを構築していく。

本研究では、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る。学習にあたり、学習データに過度に適合させた過学習現象が生じないように注意が必要である。学習に使用しない検証用データを用いて精度を評価しながら、適切なハイパーパラメータを決定する。

なお、サポートベクターマシンやニューラルネットワークは、入力する説明変数のスケールにモデルが敏感に反応しやすく、変数間でスケールの差異が大きい場合は精度が向上しない。このため、説明変数はスケールを合わせる必要がある。スケール変換手法として、最小値0, 最大値1として変換する「正規化」や、平均値0, 分散1の正規分布を与える「標準化」が一般的である。

4. 解析結果

(1) ランダムフォレスト法

決定木法の一つであるランダムフォレスト法では、ハ

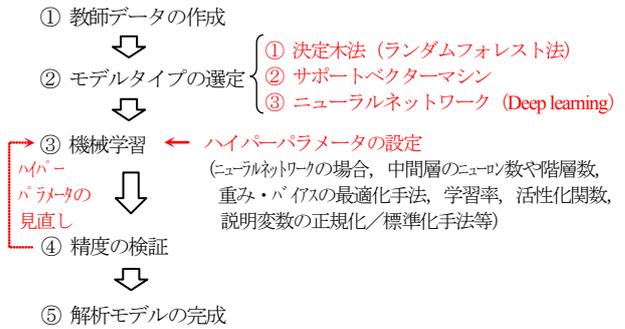


図-7 解析モデル構築のフロー

イパーパラメータとして、木の深さの最大値や、1本の木を生成する際に使用する特徴量の最大数が精度に及ぼす影響が大きい。本研究では、木の深さの最大値を5~15、また、1本の木で使用する特徴量の最大数を全特徴量数の10~50%の間でモデルの応答特性を確認した。

木の深さを深くし、特徴量を増やすとともに学習用データに対する精度は上がるものの、検証用データに対する精度は変わらず、過学習の傾向が現れた。木の最大深さを8、使用する特徴量の最大数を全特徴量数の10%に制限することで、学習用と検証用それぞれのデータに対する精度が同程度になり、最適なハイパーパラメータと判断した。図-8にランダムフォレスト法による F_c の回帰結果を示す。推定誤差の評価は式(1)で定義される目的変数の推定値と真値の差の平均二乗誤差 \bar{E}^2 を用いた。

$$\bar{E}^2 = \frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2 \quad (1)$$

ここで N はサンプル数、 y_i は推定値、 t_i は真値を示す。重回帰分析では推定が困難であった F_c が50%以上の領域を含めて、ランダムフォレスト法により、十分な精度で推定できることがわかった。

(2) サポートベクターマシン

カーネル法によりデータを多次元空間に写像し、その

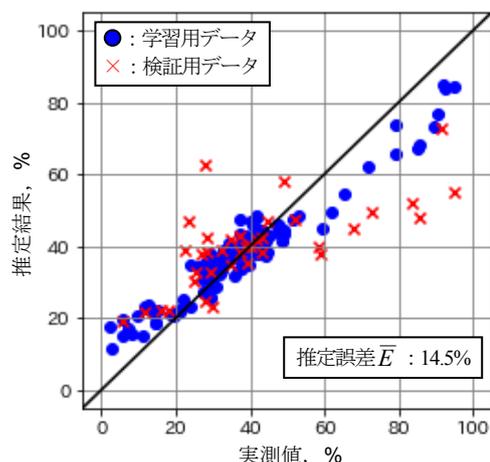


図-8 ランダムフォレスト法による F_c の回帰結果

空間で線形の識別を行うことにより、非線形の問題に対応できる。本研究では、各種のカーネル関数のうち、広く適用されている式(2)の Gauss カーネルを用いた。

$$K(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right) \quad (2)$$

ここで、 K はカーネル関数、 x は特徴量、 γ は1つのサンプルの影響範囲を示すパラメータである。

本研究では、 γ の値として $2^3, 2^4, 2^5$ の3ケースを選定するとともに、回帰分析に必要な ε -不感損失関数の許容誤差 ε の値として2, 4, 8の3ケースを抽出し、最適なハイパーパラメータの検討を行った。さらに、説明変数のスケール変換手法として、「正規化」と「標準化」の検討を併せて行った。 $\gamma=2^4$ 、および $\varepsilon=8$ を与えた条件で説明変数の「正規化」を行ったケースが、検証用データに対する推定精度が最も高く、最適な設定値と判断した。

上記のハイパーパラメータを用いて F_c の回帰を行った結果を図-9 に示す。ランダムフォレスト法と同様に、重回帰分析では推定が困難であった F_c が 50%以上の領域を含めて、十分な精度で推定できることがわかった。

(3) ニューラルネットワーク

ニューラルネットワークでは、ニューロン間をつなぐ重みやバイアスに代表されるパラメータの最適値を求める手法が極めて重要である。最適化問題の解法としては、目的関数の勾配を用いて、勾配方向にパラメータを逐次的に更新しながら、最適解を探索する手法である勾配降下法(最急降下法)が良く知られている。一方、例えば、矢部⁸⁾に示されるように、勾配降下法は1次の勾配のみを考慮するのに対し、Newton法や準Newton法は2次の勾配まで考慮するため、効率よく最適解に到達することができる。矢部⁸⁾やFletcher⁹⁾に示されるように、BFGS法は準Newton法の一つであり、Nocedal¹⁰⁾が提案するlimited memory BFGS method (L-BFGS法)は、計算機に

おけるメモリの使用量を削減し、高速に動作する長所を持つ手法である。

勾配降下法とL-BFGS法の両手法を検討した結果、精度が良く、かつ高速で最適解が得られるL-BFGS法を採用することにした。また、ニューロンへの入力信号の総和を出力信号に変換する活性化関数として、多層の中間層を持つディープラーニングの解析に対応が可能なReLU(reflected linear unit)関数を適用した。

中間層の階層数として2, 3, 5の3ケース、各中間層のニューロン数として30, 50, 100の3ケースを抽出し、適切なハイパーパラメータの検討を行った結果、中間層の階層数を5、各中間層のニューロン数を50に設定するとともに、「標準化」による説明変数のスケール変換を行うことにより、検証用データに対して高い推定精度が得られることを確認した。図-10に、 F_c の回帰を行った結果を示す。 F_c の推定誤差は11.3%と評価され、14~15%程度の推定誤差を有する他の学習モデルと比較して、若干高い精度が得られることがわかった。

しかしながら、複数の階層を持つニューラルネットワークモデルを用いても、N値については、図-11に示すように十分な推定精度を得ることができない。また、他の2つのモデルでも同様に、N値の推定精度は低い。

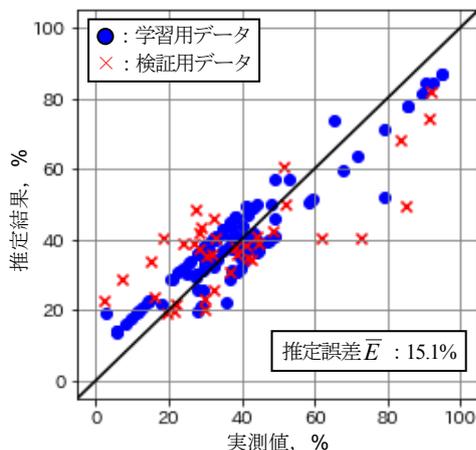


図-9 サポートベクターマシンによる F_c の回帰結果

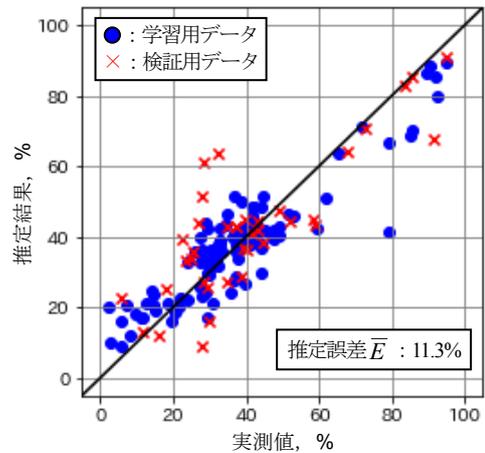


図-10 ニューラルネットワークによる F_c の回帰結果

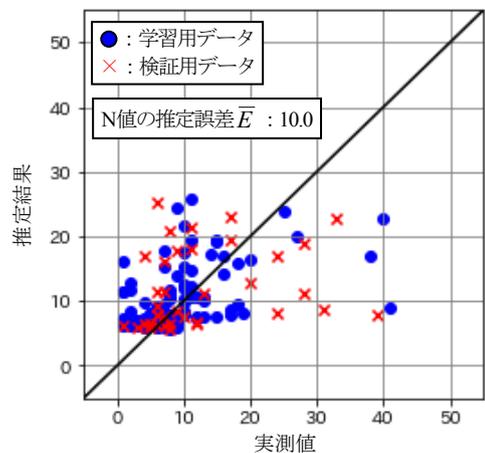


図-11 ニューラルネットワークによる N 値の回帰結果

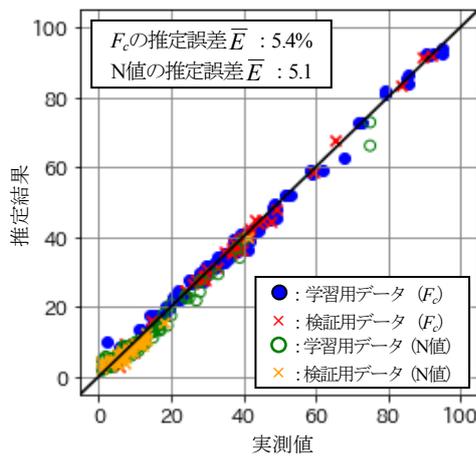


図-12 ニューラルネットワークのマルチタスク学習による F_c と N 値の回帰結果

亀井ら¹¹⁾は沖積砂質土の砂やシルトに関して、また、佐々木ら¹²⁾は東京湾岸地区の浚渫土埋立層、沖積砂層・粘土層に関して、 N 値や換算 N 値と、 F_c の間に負の相関があることを明らかにしている。これらの成果に基づき、本研究では、 F_c と N 値を別々に学習するのではなく、相関性を考慮しながら同時に学習するマルチタスク学習の手法を適用した。ハイパーパラメータとして中間層の階層数を 5、各中間層のニューロン数を 150 に設定するとともに、過学習を防止するために Dropout の手法^{6),7)} (Dropout 率を 0.3 に設定) を導入して解析した結果を図-12 に示す。 F_c と N 値の相関性を考慮して学習するモデルにより、高い精度で推定できることがわかった。

5. おわりに

埋立地盤のような複雑な土層構成においても土質や強度の分布を精度良く推定するため、非線形の回帰が可能な機械学習モデルを構築し、適用性を検討した。特に、ニューラルネットワークのマルチタスク学習モデルは、 F_c だけでなく N 値も同時に精度良く推定できることが分かった。技術の適用対象として埋立地盤に限らず、今後、教師データを新たに獲得して追加の学習や検証を行い、

モデルの精度をさらに向上させながら、地盤改良の必要な範囲の評価や、対策工としての薬液注入工法の品質の向上のために本技術が適用されることが期待される。

参考文献

- 1) (社)日本グラウト協会：新訂 正しい薬液注入工法－この一冊ですべてがわかる－, pp.231-233, 日刊建設工業新聞社, 2007.
- 2) 海野寿康, 東山文雄, 久保知久, 車田佳範：薬液注入工法における先行掘削時の諸データを用いた地盤構成の推定, 第 7 回地盤工学会関東支部発表会, pp.308-310, 2010.
- 3) 澤田俊一, 塚本良道, 石原研而：間隙水圧測定を伴う動的貫入試験法－その 4 土質分類－, 第 40 回地盤工学研究発表会, pp.1120-1121, 2005.
- 4) Hastie, T., Tibshirani, R., Friedman, J. : The Elements of Statistical Learning: Data Mining, Inference, and Prediction, pp.305-604, Springer, 2008.
- 5) 元田浩, 津本周作, 山口高平, 沼尾正行：データマイニングの基礎, pp.96-109, オーム社, 2005.
- 6) 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.39-164, オライリー・ジャパン, 2016.
- 7) 巢籠悠輔：詳解 ディープラーニング, pp.69-207, マイナビ出版, 2017.
- 8) 矢部博：工業基礎－最適化とその応用－, pp.121-176, 数理工学社, 2006.
- 9) Fletcher, R. : Practical Methods of Optimization (2nd ed.), pp.44-79, John Wiley & Sons, 1987.
- 10) Nocedal, J.: Updating Quasi-Newton Matrices with Limited Storage, *Mathematics of Computation*, 35 (151), pp. 773-782, 1980.
- 11) 亀井祐聡, 森本巖, 安田進, 清水善久, 小金井健一, 石田栄介：東京低地における沖積砂質土の粒度特性と細粒分が液状化強度に及ぼす影響, 地盤工学会論文報告集, Vol.42, No.4, pp.101-110, 2002.
- 12) 佐々木哲也, 石原雅規, 谷本俊輔, 林宏親, 江川拓也, 鷺見浩司, 川口剛：細粒分を含む砂の液状化強度の評価法に関する再検討, 土木研究所資料, 第 4352 号, 159p, 2016.

(2019.2.7 受付)
(2019.4.24 受理)

PREDICTION METHOD OF SOIL CONDITIONS BY USE OF ARTIFICIAL INTELLIGENCE TO ANALYZE BORING-OPERATION DATA

Takahiro KUMAGAI and Teppei AKIMOTO

It is required to have information on the soil conditions of fine fraction content and SPT-N value for estimating the liquefaction potential of ground, or for conducting soil improvement such as the chemical grouting method.

In this study, machine learning techniques as the random forest method, the support vector machine and the neural network are applied analyzing boring-operation data obtained in the past soil improvement works at Tokyo International Airport. It is found out that the soil conditions of fine fraction content and SPT-N value can be accurately predicted by the multi-task learning model based on the neural network.