

# 土質定数推定システム「サウンディング AI」

秋本 哲平・熊谷 隆宏

地盤調査として一般的に実施されるボーリングを伴う調査方法は、コストや時間がかかるため、ボーリングを伴わないサウンディング調査で代用されることがある。サウンディング調査では、経験から求められた推定式を用いて土質定数を推定するが、入力パラメータの微調整や適切な推定式の選定など、手間や時間がかかり、実施する技術者の主観が入りやすいといった課題がある。このような課題を解決するために、AIを用いた土質定数推定システムを開発した。本報では、推定手法の概要と適用結果例について報告する。

キーワード：基礎地盤、地盤調査、サウンディング、人工知能、ディープラーニング

## 1. はじめに

我が国の構造物基礎の設計では、強度に関する基本的な情報としてN値を使用することが多いため、地盤調査では一般的に標準貫入試験が実施される。また、土質特性や土質定数の詳細を把握するために、現地で採取した試料を用いて土質試験が行われる。しかしながら、これらの地盤調査は、コストや時間がかかるため、スウェーデン式サウンディングやコーン貫入試験等のボーリングを伴わないサウンディング調査で代用されることがある。

サウンディング調査は、地盤特性を連続的かつ経済的に把握できるといった利点があるものの、土質定数を直接取得することができないため、調査で取得できる貫入抵抗値や間隙水圧等から土質定数を算定する必要がある。この算定では、経験によって導き出された推定式を用いることが提案されている<sup>1)</sup>ものの、土質定数の推定精度を向上させるためには、入力パラメータの微調整や適切な推定式の選定が必要になるため、実施する技術者の主観が入りやすいといった課題がある。

こうした課題を解決するために開発したのが「サウンディング AI」である。本技術は、過去の調査で蓄積したサウンディングデータと土質定数の相関を教師データとして機械学習を行い、迅速かつ高精度に土質定数を推定するAIモデルを構築している。AIを用いることで、大量のデータ分析や処理が可能となるため、従来の推定式で用いているデータよりも多種類の

データを容易に扱うことができる。また、地盤調査の実施者は、機械学習によって構築されたAIモデルに計測データを入力するだけとなるため、技術者の主観に依存しない地盤物性値を取得することが可能である。本報では、土質定数推定手法の概要と本技術を適用した際の推定精度について報告する。

## 2. 推定手法

### (1) 実施手順

本手法の実施手順を図-1に示す。これまでに蓄積した多数の既往工事のサウンディングデータを用いて機械学習を行い、土質定数を推定するAIモデルを構築する。その後、調査対象個所のサウンディングを実施し、計測されたデータをAIモデルに入力することで、土質定数を得ることができる。調査対象個所のサウンディングを行う前にAIモデルを構築しておく

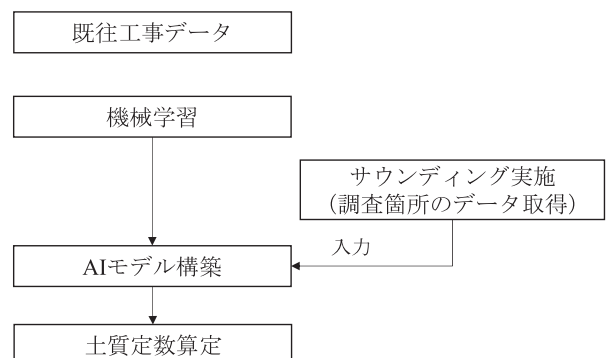


図-1 実施手順

ことで、短時間で土質定数を取得することが可能となる。

本手法で対象としているサウンディングは、施工時の削孔作業と同時に計測できるロータリー式サウンディング (RST) と電気式コーン貫入試験 (CPT) の2種類である。また、推定する土質定数は、地盤の強度情報として必要である N 値と土質分類の指標となる細粒分含有率  $F_c$  である。

(2) 機械学習モデル

機械学習の手法は、決定木法的一种であるランダムフォレスト法、サポートベクターマシンおよびディープニューラルネットワーク (DNN) の3種類の手法を比較し、最も推定精度が高かった DNN を採用している<sup>2)</sup>。図-2に DNN の概念を示す。入力層と出力層の間に複数の中間層を有しており、高度な情報処理が可能となることから、精度の高い推定が期待できる。中間層のニューロン数や階層数、パラメータ最適化手法、活性化関数等のハイパーパラメータは、多数の組み合わせに対して推定誤差が最小となる最適な値を設定している。

ハイパーパラメータの検証は、4分割交差検証を用いている。学習データをランダムに4分割し、1つのデータ群 (テストデータ) を検証用とし、残りの3つのデータ群 (学習用データ) 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精度を検証することができるため、一定のデータに過度に適合した過学習現象を防止でき、最適なハイパーパラメータを選定することができる。

土質定数の推定精度の検証は、二乗平均平方根誤差 (RMSE) を用いている。二乗平均平方根誤差は、推定値と実測値の平均誤差を定量的に評価しているため、数値が小さいほど推定精度が高いことを示している。




図-2 DNN の概念

3. ロータリー式サウンディングでの適用

(1) 使用データ

ロータリー式サウンディング (RST) は、薬液注入等の削孔作業を伴う工事において、削孔作業と同時にデータが取得できる調査方法であるため、事前調査にかかる時間やコストを大幅に削減することが可能である。RST の概要を図-3に示す。通常の削孔機械に変位量センサーや圧力センサーを取り付け、貫入時の圧力や送水圧を計測している。RST による計測データと対応する地盤調査結果を教師データとして AI モデルを構築している。

使用した教師データは、2011年~2017年の間に、東京国際空港で実施した5工区の地盤改良工事 (図-4) で取得したデータである。全20箇所のボーリング調査での標準貫入試験結果および採取試料での細粒分含有量試験結果と取得したデータを紐づけて教師データとしている。RST で取得できるデータは、送水圧 (WP)、回転トルク (FOT)、削孔速度 (SPD)、

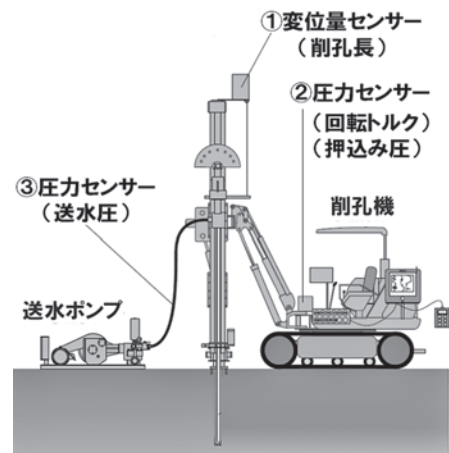


図-3 RST の概念

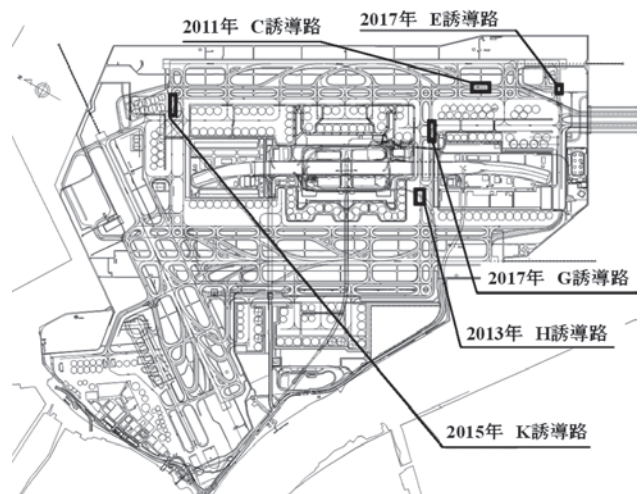
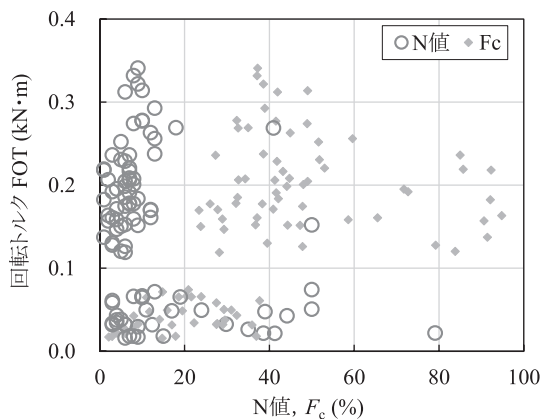


図-4 RST のデータ取得箇所


削孔荷重 (LT) の深度 5 mm ごとの連続データである。送水圧は、掘削クズ (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くなる傾向にある。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、削孔荷重は、押し込み圧力と時間を掛け合わせた値であり、砂質や礫質の硬い地盤で大きくなる傾向にある。取得したデータの例として、図一5に回転トルク FOT と N 値および  $F_c$  との関係を示す。N 値および  $F_c$  が大きくなるほど回転トルクが大きくなる傾向を示しているものの、回転トルクと N 値および  $F_c$  との相関は低くなっている。その他のデータも同様の傾向を示しており個々のデータのみでは土質定数の推定は困難である。

(2) 従来法での推定

従来法として重回帰分析を用いて土質定数の推定を行った。 $F_c$  の推定値と実測値を比較した結果を図一6に示す。 $F_c = 50\%$  程度までは概ね良好な傾向を示しているものの、50%以上においては、推定値が一定になっている。この傾向は個々のデータと同様であり、線形の重回帰分析では、推定精度が低いことがわかった。



図一5 回転トルクと土質定数の関係



図一6 重回帰分析による推定結果

したがって、非線形を考慮できる機械学習を用いて推定モデルを構築している。


(3) 本手法の適用例

教師データは、RSTで取得できるデータを説明変数 (入力値) とし、推定する土質定数を目的変数 (出力値) とするデータセットである。説明変数は、送水圧、回転トルク、削孔速度、削孔荷重の平均値に加え、分散も使用した (表一1)。分散を使用することで、取得データのバラツキの特徴を考慮できると考えられる。また、ボーリングと RST の実施箇所が離れていると、データの信頼度が低くなるため、ボーリングから平面距離で 7 m 以内のデータのみを使用した。教師データを 4 分割したうちの 3 つのデータ群である学習用データと 1 つのデータ群であるテストデータの推定結果と実測値との関係を図一7に示す。N 値の RMSE は 5.1,  $F_c$  の RMSE は 5.4% であり、どちらのデータも推定精度が高くなっている。また、テストデータの精度も高くなっていることから、学習用データの精度だけが高くなる過学習になっていないことがわかる。

構築した AI モデルが高精度であることが確認できたため、実施工を想定して、教師データ取得地点とは

表一1 RST の説明変数

説明変数 (入力値)	深度 (DEP)	中央値
	送水圧 (WP)	平均値・分散
	回転トルク (FOT)	平均値・分散
	削孔速度 (SPD)	平均値・分散
	削孔荷重 (LT)	平均値・分散
目的変数 (出力値)	N 値 細粒分含有率: $F_c$	



図一7 本手法による推定結果 (RST)

全く異なる新規の場所での精度確認を行った。新規地点の土質は、N 値の最大が 22、 $F_c$  の最大が 36% であり、東京国際空港のデータに比べて強度や土質の分布範囲が狭くなっており、緩く堆積した砂質土主体の地盤である。新規地点では、既存ボーリング箇所近傍で 2 本の RST を実施した。

東京国際空港のデータで構築した AI モデルを用いて、新規地点の 2 本の RST データの推定を実施したところ、 $F_c$  の RMSE は 9.8% であり、ある程度の精度が確保されたものの、N 値の RMSE は 50 以上となり、非常に精度が低いことがわかった。これは、場所によって説明変数と目的変数とを結びつける特徴が異なっているためと考えられる。そこで、新規地点で取得した 1 本のデータを加えた教師データを用いて推定モデルを構築し、残りの 1 本のデータで精度を検証した。図 8 に推定結果を示す。N 値の RMSE は 6.2、 $F_c$  の RMSE は 7.2% となり、精度が改善されたことがわかる。実測値と推定値の深度分布を図 9 に示す。下端部の N 値の推定では誤差があるものの、概ね実測値に近い値となっており、 $F_c$  の推定は深度ごとの傾向をよく捉えていることがわかる。新規地点のデータ

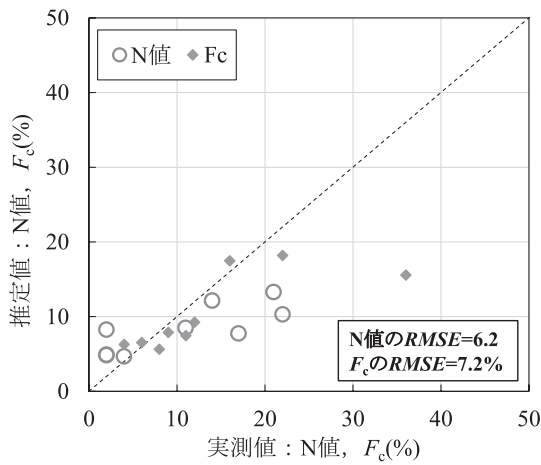


図 8 新規地点での推定結果 (RST)




図 9 新規地点での推定深度分布 (RST)

を教師データに加えることで、地域特性を学ぶことができるため、精度が向上したものと考えられる。

新規地点での調査を実施する場合は、新規地点における初期データを学習データに加えることで、十分な精度を確保することが可能である。

#### 4. 電気式コーン貫入試験での適用

##### (1) 使用データ

電気式コーン貫入試験 (CPT) は、ロッド先端のコーン貫入試験器を地盤内に押し込むことで、貫入抵抗、周面摩擦、間隙水圧の 3 成分が取得できるサウンディング調査である。図 10 にコーン貫入時に使用する貫入機の例を示す。幅 2.5 m、高さ 2 m、奥行き 1.4 m 程度の自走式の小型機械で実施できるため、狭小箇所でも簡易に実施することが可能である。また、一定の貫入速度 20 mm/s で貫入するため、短時間で地盤調査が可能である。

本検討に使用したデータは、3 地点で計測したデータである。ボーリング 12 本、CPT 28 本の結果であり、N 値は 648 データ、 $F_c$  は 441 データである。地点 A は海外の港湾工事における事前調査のデータであり、地点 B と地点 C は本検討のために茨城県内で取得し




図 10 コーン貫入機の例

表 2 CPT の説明変数

説明変数 (入力値)	CPT データ	貫入抵抗
		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	平面距離	

た。AI 構築に使用した説明変数（入力データ）を表一2に示す。電気式コーンで取得できる3成分のデータ（CPTデータ）に加え、CPTデータに影響を及ぼしていると考えられる、貫入速度、貫入深度、貫入角度といった調査時に貫入機械を制御しているパラメータも使用した。また、国内外で大きさが異なるコーン外径とデータの精度に影響を及ぼすボーリングからの平面距離も説明変数としている。


(2) 適用例

全データのうち、75%を学習用データとし、25%をテストデータとして、AI推定モデルの推定精度を検証した。図一11に地点Bのテストデータで推定した深度分布を示す。地点Bは砂質土主体で、下部にシルト層が存在しているため、N値が低く、 $F_c$ が高くなっている。N値や $F_c$ の変化点において、一部で実測値と異なる点があるものの、かなり正確に推定できており、下部にいくほどシルトが多くなる傾向をよく示している。図一12に地点Bのテストデータで推定した結果と実測値の比較を示す。N値、 $F_c$ ともにRMSE

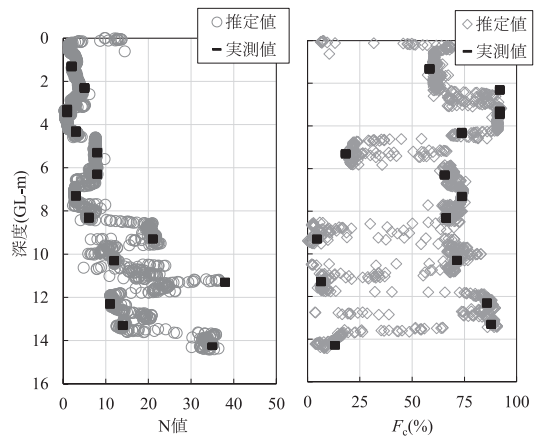
は非常に小さく、実測値と大きく異なる値が数点あるものの、推定精度が非常に高いモデルあることがわかる。

実施工を想定し、地点Aと地点Bのデータを学習用データとし、地点Cのデータをテストデータとして、推定精度を確認したが、RSTと同様に、新規地点に対する推定精度は非常に低くなることが確認された。そこで、地点Cの50%分のデータを学習データに加えてAIモデルを構築して、残りの50%のデータをテストデータとして精度検証を行った。図一13にN値と $F_c$ の深度分布を示す。地点Cの上層地盤は、シルト主体の土質であり、N値と $F_c$ の変動が少ないものの、10m以深からの下層地盤は、シルト層と細砂層の互層となっているため、深度ごとの変動が大きく、推定が難しい地盤である。しかしながら、AIによる推定値は、下層地盤の大きな変動傾向を正しく示している。


図一14に推定値と実測値の比較を示す。N値のRMSEは3.7であり、非常に精度が高いことがわかる。



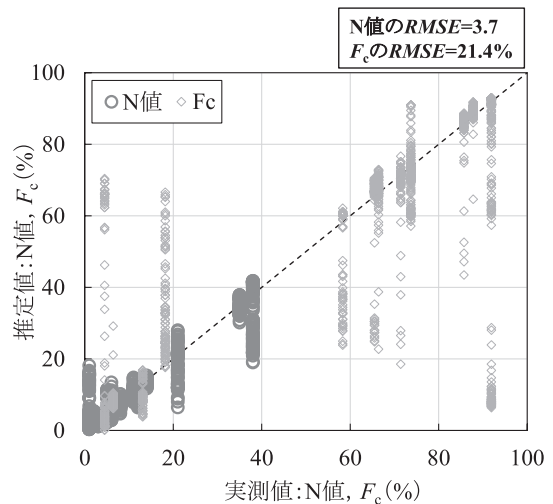
図一11 地点Bでの本手法の推定深度分布 (CPT)



図一13 地点Cでの本手法の推定深度分布 (CPT)



図一12 地点Bでの本手法の推定結果 (CPT)



図一14 地点Cでの本手法の推定結果 (CPT)

$F_c$  の RMSE は 21.4% であり、多少精度が低くなっているが、深度分布で示されている通り、下部地盤の変動が大きい箇所では実測値と大きく異なる推定値となっているためと考えられる。本手法と比較するため、従来から用いられている提案式<sup>1)</sup>を用いて推定すると、 $N$  値の RMSE は 5.8,  $F_c$  の RMSE は 16.2% であり<sup>3)</sup>、本手法は、従来法と概ね同様の精度であることがわかった。

CPT においても、RST と同様に、新規地点での推定が困難な場合は、新規地点における初期の計測データを学習データに加えて AI モデルを構築することで、十分な精度で推定することが可能である。

## 5. おわりに

簡便で高精度かつ技術者の主観に依存しない土質定数の推定手法として、サウンディング結果から AI を用いて  $N$  値と  $F_c$  を推定する手法を開発した。AI を活用することにより、従来から使われているサウンディングデータ以外の様々なデータを用いることができるため、推定精度の向上を見込めることが示唆された。一方で、新規地点においては、その地点で初期に計測したデータを学習データに加えることにより、一定の推定精度を確保する必要がある。

今後、広範囲における多数の教師データを蓄積することで、推定精度の向上が見込めるとともに、新規地点の初期データでの学習を削減できるものと考えられる。


J C M A

### 《参考文献》

- 1) 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.
- 2) 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.
- 3) 秋本哲平, 江守辰哉, 片山遥平, 上野一彦, 熊谷隆宏: 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, 土木学会論文集 B3 (海洋開発), Vol.77, No.2, pp. I\_721- I\_726, 2021.

### 【筆者紹介】

秋本 哲平 (あきもと てっぺい)  
五洋建設株式会社  
技術研究所 土木技術開発部 地盤・耐震構造グループ  
担当部長



熊谷 隆宏 (くまがい たかひろ)  
五洋建設株式会社  
技術研究所 土木技術開発部  
土木技術開発部長

