

機械学習を用いた山留め壁の予測解析に関する検討

Study on Predictive Analysis of Retaining Walls Using Machine Learning

梶 伸之*¹ 角田晋相*²

概 要

本研究は、山留め壁の予測解析に用いる土質パラメータの推定において、機械学習技術の適用可能性を検討したものである。従来の順解析プログラムによる予測解析は、非線形性のある土質に適用可能であるが、実測変位に基づき繰り返し計算を行う必要があるため、解析には時間を要するという課題がある。そこで本研究では、実測変位から土質パラメータを効率的に推定するため、全結合ニューラルネットワーク (FCNN) と畳み込みニューラルネットワーク (CNN) の2種類のモデルを構築し、多数の弾塑性解析データを用いて学習を実施した。推定した土質パラメータを用いた計算変位と実測変位を比較した結果、FCNN モデルは CNN モデルよりも高精度な推定が可能であることを確認した。検討結果から、機械学習による土質パラメータの推定は、山留め壁の予測解析において実現場への適用可能性があることが確認された。

key words : 機械学習、ニューラルネットワーク、山留め壁、弾塑性解析、予測解析

1. はじめに

近年の人工知能 (AI) 技術の発展により、建築分野でもデータ駆動型の解析手法が導入されている。特に、画像による構造物の劣化診断、地震応答解析などの分野において、機械学習が適用される事例が増加している¹⁾。これらの手法は、従来の数値解析と比較して、計算時間を短縮しながら高精度な予測の実現が期待されている。

山留め壁の予測解析では、実測変位をもとに未知の土質パラメータを仮定し、順解析プログラムで得られた計算変位と実測変位の誤差が最小となるように土質パラメータを決定して解析を行う (図-1)。この方法は、非線形性のある土質に適用可能であるが、繰り返し計算により最適なパラメータを求めるため結果を出すには時間を要する。一

方、変位を実測してから次工程の対応を決定する際、予測解析にはリアルタイム性が求められる。

そこで、本報では、実現場の山留め壁の設計データおよび実測変位を用いて、山留め壁の予測解析に用いる土質パラメータの推定に機械学習を用いた手法を検討した結果^{2),3)}について報告する (図-2)。

2. 検討概要

2.1 山留め壁の概要

検討で用いた山留め壁の概要を図-3に示す。敷地の地層構成は表層から順に埋土、細砂、礫混り細砂、シルトである。山留め壁はソイルセメント柱列壁(H=488×300×11×18@900, L=18.5m)で、支保工は3段切梁である。また、4次掘削で最終根切り深さに到達する。

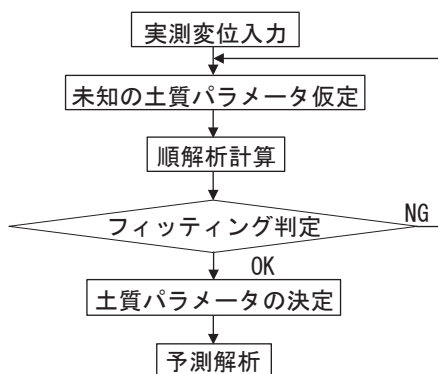


図-1 現状の予測解析手法

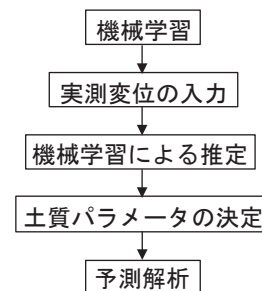


図-2 機械学習を用いた予測解析手法

*1 Nobuyuki TOMO

技術本部技術研究所 研究員

*2 Shinsuke TSUNODA

技術本部技術研究所 主席研究員

2.2 機械学習を用いた土質パラメータの推定

機械学習を用いた土質パラメータ推定の概念図を図-4に示す。機械学習の際に、通常山留め壁の弾塑性解析の入力と出力を逆にすることで、実測変位から土質パラメータを推定することができる。機械学習の入出力層データ(学習データ)は山留め壁弾塑性解析プログラム(コード:KASETSU-5X)による弾塑性解析での入出力データを用いた。

2.3 学習データ

学習データの範囲を表-1に示す。機械学習においては学習範囲内における欠損値(内挿)は学習範囲外における予測値(外挿)よりも高い精度で推定できるとされている⁴⁾。本検討では、層番号2~5のうち砂質土層に対しては内部摩擦角(ϕ)を、 25° 、 ϕ_d (設計値)、 50° の3通り、粘性土層に対しては粘着力Cを設計値(C_d)の0.75倍、1.0倍および2.0倍の3通りとした。また、水平地盤反力係数 k_h は層番号3~6について、設計値(k_{hd})の0.75倍、1.0倍および2.0倍の3通りとした。その他の値はすべて設計値として、合計 $3^4 \times 3^4 = 6561$ 通りの弾塑性解析の入力値および解析結果を学習データとして用いた。

3. 機械学習モデルの構築

機械学習のモデルは全結合ニューラルネットワーク(Fully Connected Neural Network: FCNN)および畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)を使用した。各ニューラルネットワークの概念を図-5に示す。本検討では文献5)を参考に機械学習モデルを作成した。

3.1 全結合ニューラルネットワーク(FCNN)の概要

FCNNは、入力層から出力層までのすべてのノードが完全に接続された構造を持つニューラルネットワークで、入力値と出力値の関係について、様々な事例を学習させることで、複雑な非線形処理が可能である。

3.2 畳み込みニューラルネットワーク(CNN)の概要



CNNは、時系列データや画像データに対して、畳み込み操作を行うことで、局所的な特徴を抽出するモデルで、入力データの時間的または形状的な特徴を考慮することができる。

3.3 ハイパーパラメータの設定

ハイパーパラメータとは、モデルの学習過程において事前に設定する必要があるパラメータであり、モデルの計算精度に大きな影響を与える。最適化を行うハイパーパラメータとその探索範囲を表-2に示す。FCNNおよびCNNのハイパーパラメータチューニングに、Preferred Networks社が開発したハイパーパラメータの自動最適化フレームワークであるOptunaを使用した⁶⁾。

3.4 学習方法と過学習対策

ニューラルネットワークを用いた機械学習では、最適な



(2) 地層構成および断面図

図-3 山留め壁の概要

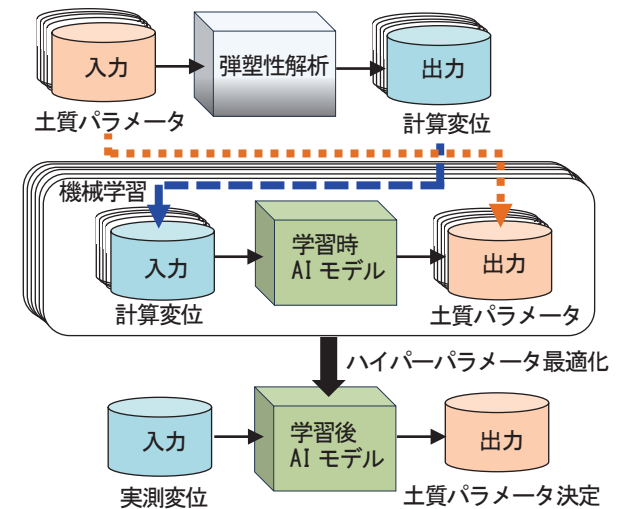


図-4 機械学習を用いた土質パラメータ推定の概念図

表-1 学習データの範囲

層番号	層名称	土質	γ	ϕ_d	C_d	k_{hd}
			kN/m ³	度	kN/m ²	kN/m ³
1	埋土	粘性	16.0	5.0	15.0	1500
2	細砂	砂質	18.0	30.0	0.0	4000
3	礫混り細砂	砂質	18.0	25.0	0.0	5000
4	シルト	粘性	16.0	0.0	50.0	10000
5	礫混り細砂	砂質	18.0	35.0	0.0	21000
6	シルト	粘性	15.1	2.0	90.0	18000

【学習範囲】 ϕ : 25/ ϕ_d /50、 C : 0.75 C_d / C_d /2.0 C_d
 k_h : 0.75 k_{hd} / k_{hd} /2.0 k_{hd}

※数値は設計値を示す。添え字(d)は設計値を示す。
 ハッチングは変更したパラメータを示す。
 γ :単位体積重量、 ϕ :内部摩擦角、 C :粘着力
 k_h :水平地盤反力係数

パラメータを探索する際に、予測値と正解値の差で計算される損失関数の値が小さくなるよう計算を行う。本検討では、損失関数に MSE（二乗和誤差）式(1)を用いた⁷⁾。

機械学習では、学習データをすべて学習するのではなく、訓練データと検証データの2つに分けることが一般的である。本検討では、学習データの70%を訓練データ、30%を検証データとした。また、学習時には損失関数を用いて、訓練データによる訓練損失 (train_loss) と検証データによる評価損失 (value_loss) の両方を計算した。本検討では、学習時の計算変位とは異なる実測変位から土質を推定することを目的としていることから、予測計算には value_loss が最も小さい最適モデルを採用した。

機械学習においては、一般的に、学習時に用いる訓練データへの適応が過剰に進んでしまい、未知のデータに対して推定する精度が下がってしまう「過学習」が問題になることがある⁷⁾。そこで、ドロップアウトと呼ばれる手法⁸⁾を用いて過学習による精度の低下抑制を目指した。ドロップアウトは学習時に中間層のユニットをランダムに選び出し、その選び出したユニットを消去することで、消去されたユニットは信号の伝達を行わなくなる(図-6)。これにより、特定のノードに依存しすぎることを防ぎ、汎化性能を向上させることができる。本検討では、中間層のドロップアウト率を 0.0~0.5 に設定した。

4. 検討結果

4.1 学習結果

機械学習モデル FCNN および CNN に対してハイパーパラメータのチューニングを行い、value_loss が最小となった最適モデルをそれぞれ FCv および CNv、同様に train_loss が最小となった最適モデルを FCt および CNT とする。それぞれの損失値を表-3 に示す。

表-3 に示した各最適モデルの学習時の train_loss を縦軸に、学習回数 (エポック数) を横軸にプロットしたグラフを図-7 に示す。ここで、学習の効率化を目的に value_loss が改善されない場合は、学習を途中で止める設定としたため、各最適モデルのエポック数が異なっている。いずれのモデルもエポック数が 10 回程度で train_loss はほぼ最小値を取ることを確認した。今回の検証範囲であれば、エポック数を少なく設定することで効率的なハイパーパラメータの探索ができると考えられる。

4.2 推定結果

推定値の検証は、図-3 の施工事例に基づいて実施した。施工時の山留め壁の実測変位をもとに、value_loss が最小となった最適モデル FCv および CNv から得られた土質パラメータの推定結果を表-4 に示す。FCv および CNv から推定された土質パラメータは概ね学習範囲内に収まっていたが、()内の値については学習範囲外となっている。

表-4 で得られた土質パラメータを弾塑性解析プログ

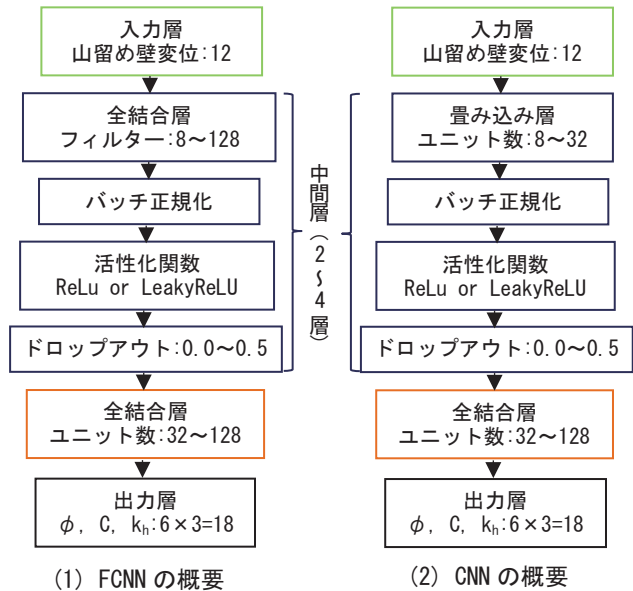


図-5 ニューラルネットワークの概要

表-2 ハイパーパラメータの探索範囲

モデル	FCNN	CNN
トライアル数	100	
中間層の数	2~4	
ユニット数	8~128	-
フィルター数	-	8~32
カーネルサイズ	-	2~4
活性化関数	ReLU, LeakyReLU	
ドロップアウト率	0.0~0.5	
最適化関数	Adam, SGD	

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2 \quad (1)$$

n: データ数、y_i: 予測値、t_i: 正解値




図-6 ドロップアウトの概念図

表-3 評価損失と訓練損失

モデル	最適モデル名	value_loss	train_loss
FCNN	FCv	0.70	0.42
	FCt	1.00	0.28
CNN	CNv	0.82	0.49
	CNt	1.24	0.25

※ハッチングは着目した最小値

※添え字「v」は value_loss が最小の最適モデル

※添え字「t」は train_loss が最小の最適モデル




図-7 訓練損失と学習階数

表-4 土質パラメータの推定結果

層 番号	FCv			CNv		
	施工ステップ 6			施工ステップ 6		
	ϕ 度	C kN/m ²	k_h kN/m ³	ϕ 度	C kN/m ²	k_h kN/m ³
1	4.96	13.81	1484	3.96	14.44	2060
2	33.90	0	3397	(64.78)	0	3236
3	29.10	0	5407	35.55	0	4349
4	0.49	64.36	10392	0.53	45.70	7769
5	36.60	0	22811	32.59	0	14453
6	2.27	86.29	(37657)	3.77	74.24	14247

※ハッチング：学習範囲内
 ※（ ）内：学習範囲外

ラムに入力し、各施工ステップの計算変位を出力し、実測変位と比較を行った。FCv および CNv について、施工ステップ-6 (3 次掘削後 3 段切梁設置時) の計算変位と実測変位との比較結果を図-8 に示す。今回の検証範囲では、value_loss の値がより小さい最適モデル FCv の方が実測変位に近い推定結果を示すことが確認された。表層部に関しては、機械学習時間を短縮するために設計値を採用したため、推定値は設計値付近に留まり、実測変位との整合性は十分に得られていない。一方、安全上重要となる最大変位付近においては、実測変位に近似した推定結果が得られた。

5. まとめ

本検討では、山留め壁の弾塑性解析のデータを用いて機械学習モデルを構築し、実測変位をもとに土質パラメータを推定した。その結果、本手法による土質パラメータの推定が、実現場への適用可能性があることが確認された。

現状では、学習データの作成およびモデルの学習には時間を要する一方で、実測変位から土質パラメータの推定は短時間で可能である。今後は、学習時の時間削減方法の検討を進めるとともに、現場条件にそぐわない土質パラメータが得られた場合の取り扱いについても検討する。また、他物件の実測データへの適用についても確認を進める予定である。

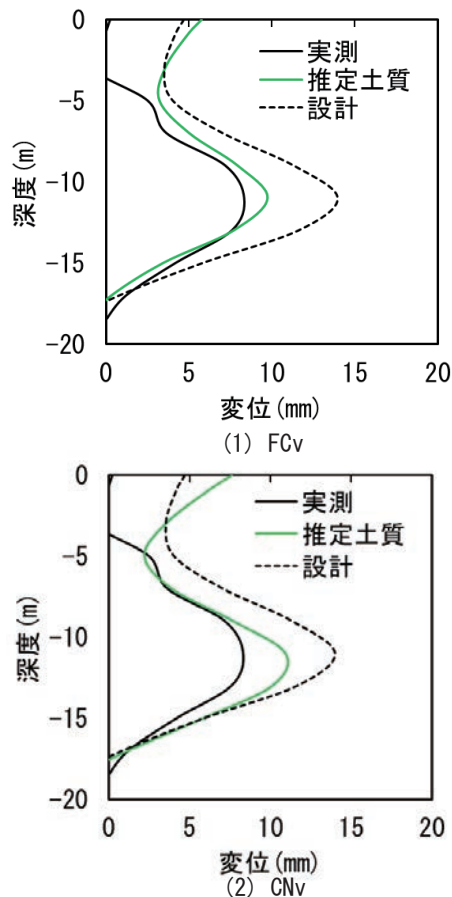


図-8 施工ステップ 6 計算変位および実測変位の比較

【参考文献】

- 1) 荻野律：機械学習を用いた地震発生時の建物使用可能性の評価に向けた基礎的検討、土木学会全国大会第 78 回年次学術講演会、CS10-51、2023.9
- 2) 相羽他：機械学習を用いた山留壁の予測解析に関する検討 (その 1 検討概要)、2025 年度日本建築学会大会 (九州) 学術講演会、2025.9
- 3) 柄他：機械学習を用いた山留壁の予測解析に関する検討 (その 2 予測解析結果)、2025 年度日本建築学会大会 (九州) 学術講演会、2025.9
- 4) 山本ほか：機械学習による指差しの指示位置推定検証と内挿表現評価、第 33 回ファジィシステムシンポジウム講演論文集
- 5) 斎藤康毅：ゼロから作る Deep Learning—Python で学ぶディープラーニングの理論と実装、2016.9
- 6) J Snoek 他：Practical Bayesian Optimization of Machine Learning Algorithms、2012
- 7) 樋口善彦：機械工学と人工知能 (2)、産業技術大学誌第 56 巻、pp.105-111、2023
- 8) N Srtivastava 他：Dropout: A Simple Way to Prevent Neural Networks from Overfitting、Journal of Machine Learning Research15、2014.6