

# 機械学習による過圧密比の深度分布推定

Depth distribution estimation of over consolidation ratio by machine learning

陳 冉<sup>1)</sup>  
Ran Chen  
竹山 智英<sup>2)</sup>  
Tomohide Takeyama  
銭谷 誠司<sup>3)</sup>  
Seiji Zenitani  
橘 伸也<sup>4)</sup>  
Shinya Tachibana  
飯塚 敦<sup>5)</sup>  
Atsushi Iizuka

概要：地盤の過圧密比は、地盤の応力履歴を示すパラメータであり、地盤の挙動を解析するうえで重要なパラメータのひとつである。本研究では、地盤の応力履歴を表すパラメータである過圧密比の深度分布推定の新たな手法、および有限要素解析結果を用いて、ニューラルネットワークを学習させる手法を提案した。提案手法により、特定の地盤の基盤入射地震波と地表面地震波を把握できれば、地盤の過圧密比の深度分布を推定することが可能である。本研究で用意した教師データによって学習させたニューラルネットワークによって、予測した過圧密比と正解値との比較で、予測の精度が高いことを示した。

キーワード：ニューラルネットワーク 動的有限要素解析 過圧密比

## 1. 研究背景および目的

地盤の過圧密比は、地盤の応力履歴を示すパラメータであり、地盤の挙動を解析するうえで重要なパラメータのひとつである。地盤の土層区分・N値などの情報はボーリング調査により得られるが、コストの問題から圧密試験が行われ、過圧密比が得られることは少ない。圧密試験が実施されていない箇所での過圧密比の深度分布が上手く推定できれば、より正確な数値解析が可能となる。これまでの研究において、地盤の材料パラメータ推定に経験式<sup>1)</sup>が使用され、過圧密比についてはN値からの推定が行われているが、N値は現在の地盤の強度や剛性とは相関性があると考えられるが、応力履歴を表す過圧密比と相関性があるとは考えにくい。また、実際の地盤においては、ボーリング調査結果にはばらつきが存在するため、パラメータを推定することが困難であることもある<sup>2)</sup>。

圧密試験が行われていない箇所における過圧密比の深度分布推定のための有望な手段として、ニューラルネットワーク(以下はNNと略称する)などの機械学習を用いることが考えられる。本研究では、力学的な手法とNNを用いて地盤の過圧密比を推定する手法を提案する。NNのトレーニングデータは、有限要素法による地震応答解析を実施することにより得る。本手法の有効性はテストデータセットとダミーデータセットでの相関性検定により評価する。

## 2. 仮想地盤の構築

本研究においては、正規圧密地盤の掘削除荷により過圧密状態となった仮想地盤を想定する。仮想地盤においては、以下の3つの仮定をする。

- ・ 均一な地盤である。
- ・ 元々、正規圧密状態の飽和地盤が侵食などの作用によって過圧密状態になる。
- ・ 地表面付近の過圧密比は2から22までの値をとる。

提案するモデルは、図1(a)に示したように、元の正規圧密地盤の地表面から深さ  $a$  (m) を掘削し、除荷により赤線のような過圧密比の深度分布曲線を描くものとする。過圧密比 OCR の深度分布を表す式は式(1)のようになる<sup>3)</sup>。

$$\text{OCR} = \frac{\gamma_t z + \gamma_t a}{\gamma_t z} = 1 + \frac{a}{z} \quad (1)$$

ここに、 $a$  は掘削前の地表面高(m)、 $z$  は任意深度の深さ(m)、 $\gamma_t$  は土の単位体積重量である。

式(1)は NN の活性化関数に用いられるため、0 から 1 の値をとるように  $a$  を式(2)のように変換する。

$$a = 20a' + 1 \quad (2)$$

従って、式(1)は式(3)のように再定義される。仮想地盤の有限要素分割は図1(c)に示す。

$$\text{OCR} = 1 + \frac{20a' + 1}{z} \quad (3)$$

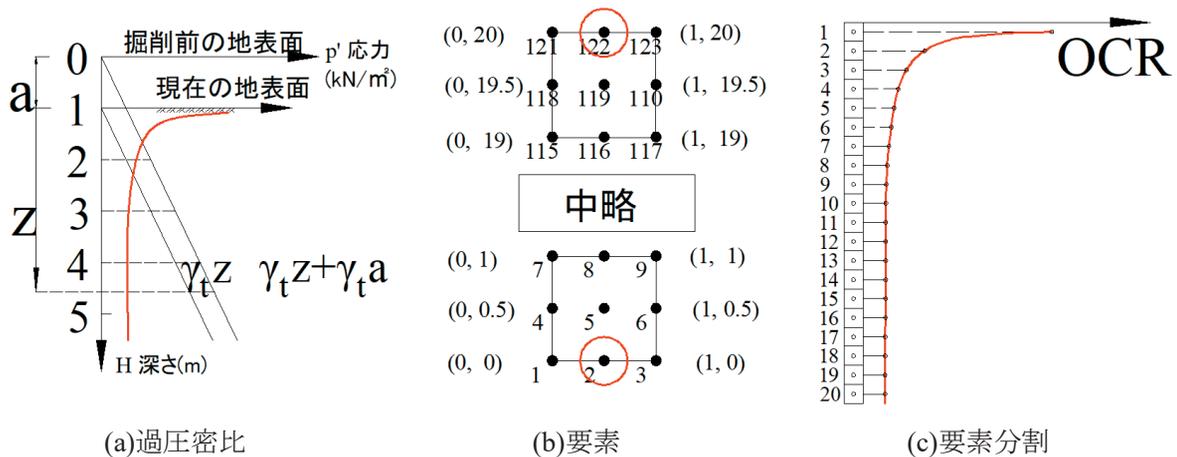


図1 仮想地盤のモデル

## 3. 有限要素法解析

### (1) 弾塑性構成モデル

本研究で用いたモデルは EC モデル及び下負荷面モデルなどの塑性硬化モデルである。間隙比-応力比関係を指数関数と捉え定式化したモデルを EC モデルという。関口・太田による一般化応力  $\eta^*$  を導入し、一般応力条件下で異方圧密された土を考慮できるよう拡張されている。EC モデルの降伏関数は式(4)となる。

$$f(\boldsymbol{\sigma}', \boldsymbol{\varepsilon}_v^p) = MD \ln \frac{p'}{p'_0} + \frac{MD}{n_E} \left( \frac{\eta}{M} \right)^{n_E} - \boldsymbol{\varepsilon}_v^p = 0 \quad (4)$$

ここで、 $M$  は限界状態定数、 $D$  はダイレイタンス係数、 $\boldsymbol{\varepsilon}_v^p$  は塑性体積ひずみ、 $n_E$  はフィッティングパラメータである。

## (2) 解析実行

本研究では、動的有限要素解析で得られた解析結果を NN のトレーニングデータとする。左右両端を周期境界とした 1 次元モデルの下端面から地震波を与えた。掘削深さ  $a$  を変化させ、過圧密比の深度分布が異なる 2000 通りの仮想地盤を対象に動的解析を実行した。表 1 に、解析に用いた物性値を示す。

図 2 にトレーニングデータ作成について示す。動的解析を行った後、入力した基盤面での地震波・計算結果として得られる地表面での地震波をそれぞれフーリエ変換し、それぞれのフーリエスペクトルを合わせて、NN のトレーニングデータとして扱う。トレーニングデータのベクトルの長さは 2048 である。

表 1 解析に用いた地盤物性値

$e_{ref}$	$D$	$\Lambda$	$M$	$\nu'$	$n_E$	$m$	$\lambda$	$\kappa$
1.41789	0.051	0.697	1.22	0.344	1.4	0.1	0.2158	0.0654

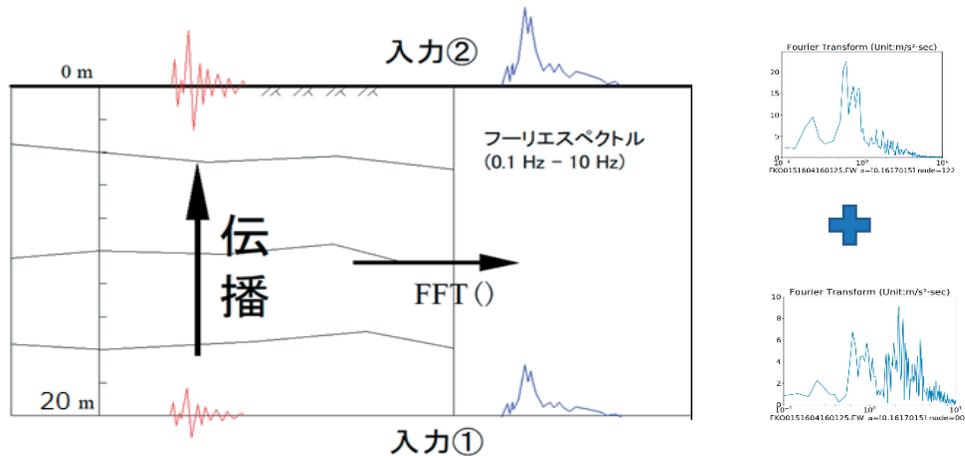


図 2 トレーニングデータの作成

## 4. NN の学習と結果の検証

### (1) 活性化関数

本研究で用いた NN の活性化関数は sigmoid 関数及び Mish 関数である<sup>4)</sup>。式(5)から式(8)にその導関数も合わせて示す。

Sigmoid 関数の曲線図は図 3 のように示されている。関数の式は式(5)、式(6)のように示されている。

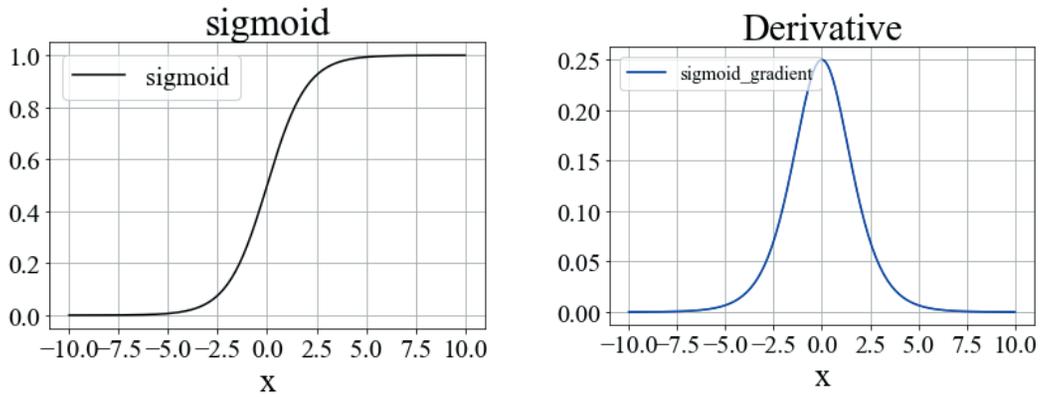


図3 sigmoid関数とその導関数の曲線図

Sigmoid 関数 
$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

Sigmoid 関数の導関数 
$$\sigma'(x) = \sigma(x) \cdot (1 - \sigma(x)) \quad (6)$$

Mish 関数の曲線図は図 4 のように示されている。関数の式は式(7)、式(8)のように示されている。

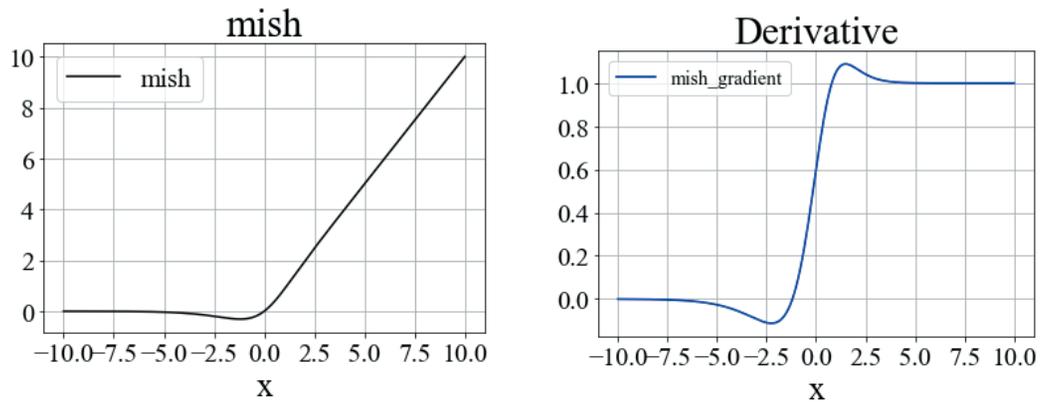


図4 Mish関数とそれらの導関数の曲線図

Mish 関数 
$$f(x) = x \cdot \tanh[\ln(1 + e^x)] \quad (7)$$

Mish 関数の導関数 
$$f'(x) = e^x \cdot \frac{4(x+1) + 4e^{2x} + e^{3x} + (4x+6)e^x}{(2e^x + e^x + 2)^2} \quad (8)$$

## (2) 順層伝播

NN の概念図を図 5 に示す。出力層の活性化関数は sigmoid 関数、他の全ての層の活性化関数は Mish 関数とした。添え字は節点番号を示し、上付き文字は層数を表す。y は教師データのことを表し、w は重み関数のことを表す<sup>5)</sup>。

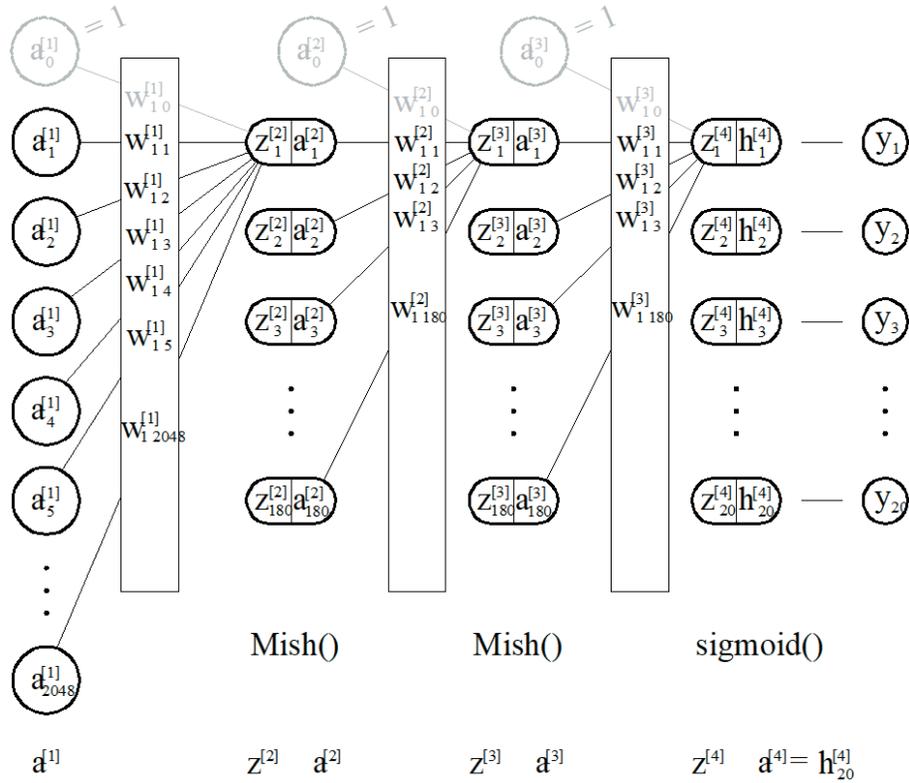


図5 NNの仕組み

$\mathbf{a}^{[1]}$ は入力層、 $\mathbf{z}^{[2]}$ は隠れ層の第一層未活性化ニューロンの値、 $\mathbf{a}^{[2]}$ は隠れ層の第一層活性化したニューロンの値、 $\mathbf{z}^{[3]}$ は隠れ層の第二層未活性化ニューロンの値、 $\mathbf{a}^{[3]}$ は隠れ層の第二層活性化したニューロンの値、 $\mathbf{z}^{[4]}$ は出力層未活性化ニューロンの値、 $\mathbf{a}^{[4]}$ は出力層活性化したニューロンの値を表す。

### (3) 誤差逆伝播

コスト関数は式(9)のように定義し、学習は式(10)で表される勾配降下法を用いて誤差逆伝播によって、重み値を調整した。

$$J = -\frac{1}{m} \sum_{j=0}^{m-1} [y_j \ln a_j^L + (1 - y_j) \ln (1 - a_j^L)] \quad (9)$$

$$\mathbf{w} = \mathbf{w} - \alpha \frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} \quad (10)$$

ここで、 $J$ は重み $\mathbf{w}$ に関する関数である。  
各層の勾配は式(11)から式(16)によって表すことができる。

$$\text{出力層の勾配} \quad \frac{\partial J(\mathbf{w})}{\partial \mathbf{z}^{[4]}} = \mathbf{h}^{[4]} - \mathbf{y}^{[4]} \quad (11)$$

$$\mathbf{a}^{[3]} \text{の勾配} \quad \frac{\partial J(\mathbf{w})}{\partial \mathbf{a}^{[3]}} = (\mathbf{h}^{[4]} - \mathbf{y}^{[4]}) \cdot \sigma'(\mathbf{z}^{[4]}) \cdot \mathbf{w}^{[3]} \quad (12)$$

$$\mathbf{a}^{[2]} \text{の勾配} \quad \frac{\partial J(\mathbf{w})}{\partial \mathbf{a}^{[2]}} = \frac{\partial J(\mathbf{w})}{\partial \mathbf{a}^{[3]}} \cdot f'(\mathbf{z}^{[3]}) \cdot \mathbf{w}^{[2]} \quad (13)$$

$$\mathbf{w}^{[3]} \text{の勾配} \quad \frac{\partial J(\mathbf{w})}{\partial \mathbf{w}^{[3]}} = \frac{\partial J(\mathbf{w})}{\partial \mathbf{z}^{[4]}} \cdot \mathbf{a}^{[3]} \quad (14)$$

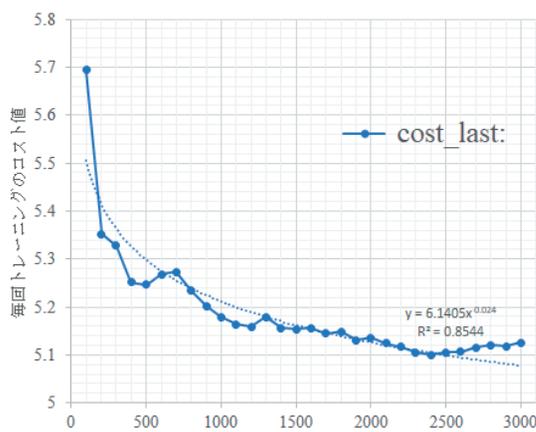
$$\mathbf{w}^{[2]} \text{の勾配} \quad \frac{\partial J(\mathbf{w})}{\partial \mathbf{w}^{[2]}} = \frac{\partial J(\mathbf{w})}{\partial \mathbf{a}^{[3]}} \cdot \sigma'(\mathbf{z}^{[3]}) \cdot \mathbf{a}^{[2]} \quad (15)$$

$$\mathbf{w}^{[1]} \text{の勾配} \quad \frac{\partial J(\mathbf{w})}{\partial \mathbf{w}^{[1]}} = \frac{\partial J(\mathbf{w})}{\partial \mathbf{a}^{[2]}} \cdot f'(\mathbf{z}^{[2]}) \cdot \mathbf{a}^{[1]} \quad (16)$$

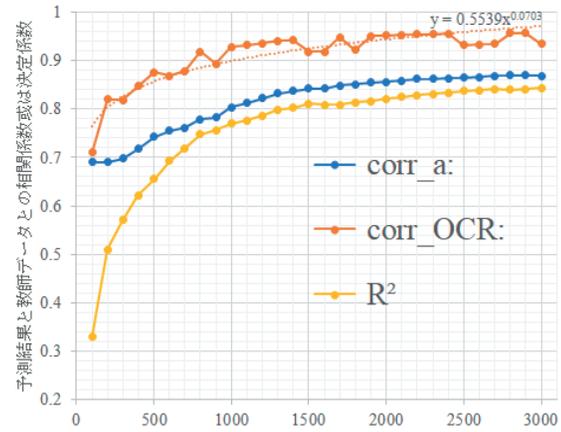
式(9)を用いてコスト関数の値がイタレーションで収束する場合、ニューラルネットワークの学習が完了したとみなす。

#### (4) 学習イタレーション回数の検討

トレーニングデータ回数を 100 から 3000 まで 100 間隔で増加させて検討した結果、最適なデータ数は約 2000 と思われる (図 6 参照)。



(a)最終コスト値の変化



(b)相関係数或は決定係数の変化

図 6 イタレーション回数増えると共に学習の結果の変化

ここで用いる NN の仕組みは図 4.6 に示す。

405,020 個の重みにおいて勾配降下法でトレーニングをする、学習回数は 3000 回である。

ニューラルネットワーク詳細				
	層			教師データ
	入力層	隠れ層	出力層	OCR
層数	1	2	1	1
ニューロン数	2048+1	180+1	20	20
重み数	180 × (2048+1) + 180 × (180+1) + 20 × (180+1) = <b>405,020</b>			
活性化関数	Mish()、sigmoid()			
学習率	α = 0.3			
正則化係数	λ = 0.1			

図 7 NN の詳細

(5) 過圧密比の深度分布推定の結果

用意したトレーニングデータによって学習を行い、トレーニングデータおよびテストデータから無作為に4ケースずつ抽出して過圧密比の深度分布の推定結果と設定値との比較した結果を図8と図9に示す。また、トレーニングと検証の結果を表2に示す。

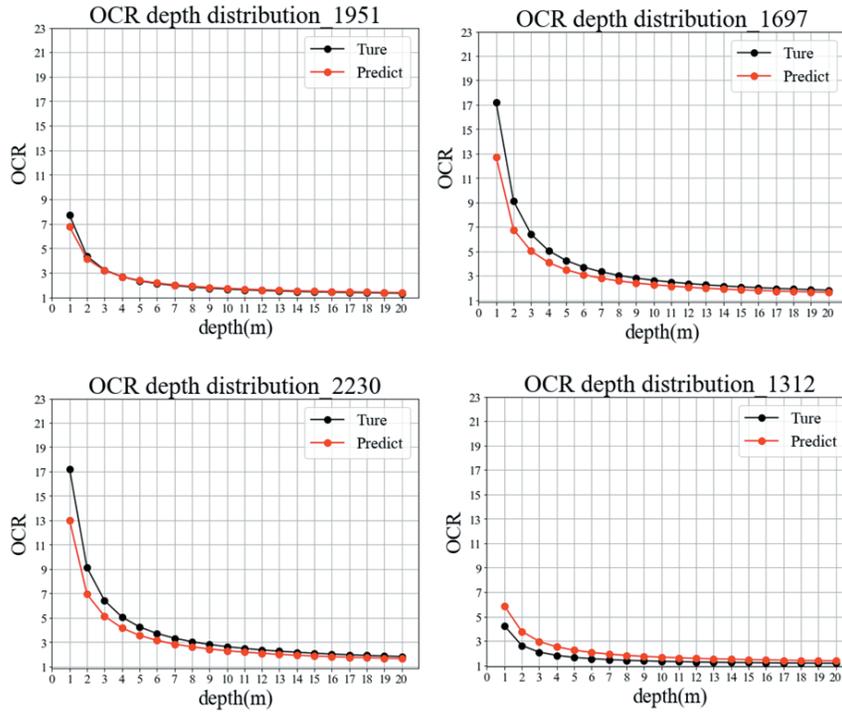


図8 トレーニングデータと予測結果の比較

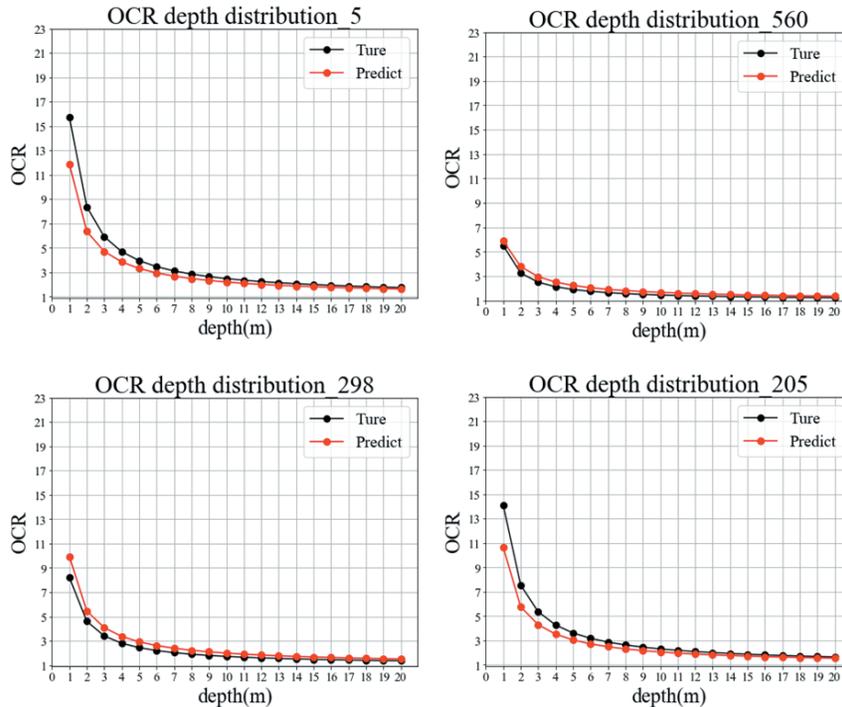


図9 テスティングデータと予測結果の比較

表2 トレーニングと検証の結果

Training set の最終結果	
学習回数	3000
平均相関係数 corr	0.987965
平均決定係数 R <sup>2</sup>	0.962264
データ数	2000
Testing set の最終結果	
平均相関係数 corr	0.987408
平均決定係数 R <sup>2</sup>	0.963576
データ数	400

## 5. 結論

本研究では、地盤の応力履歴を表す物性値である過圧密比の深度分布推定の新たな手法として有限要素解析結果を用いてニューラルネットワークを学習させる手法を提案した。提案手法により、特定の地盤の基盤における地震波と地表面における地震波が把握できれば、地盤の過圧密比の深度分布を推定することが可能である。本研究で用意したトレーニングデータによって学習させた NN によって予測した過圧密深度分布と正解値との比較では、1 に非常に近い平均決定係数となり、予測の精度が高いことを示した。予測精度の改善や不均質地盤など今回想定した仮想地盤と異なる場合の予測については今後の課題としてあげられる。

**謝辞:** 本研究は、科学研究費補助金基盤研究(C)JP20K04682 の助成を受けたものである。ここに謝意を表す。

## 参考文献

- 1) A. Iizuka and H. Ohta, A determination procedure of input parameters in elasto-viscoplastic finite element analysis, *Soils and Foundations*, 27, 71-87, 1987.
- 2) 鹿瀬一希, 飯塚敦, 竹山智英, 地盤動的解析のための試験結果のばらつきを考慮したパラメータ範囲の検討, 都市安全研究センター研究報告, 神戸大学, 27-35, 2017.
- 3) 常田賢一, 澁谷啓, 片岡沙都紀, 河井克之, 鳥居宣之, 新納格, 秦吉弥, 基礎からの土質力学, 理工図書株式会社, 2017.
- 4) D. Misra, Mish A Self Regularized Non-Monotonic Activation Function, (1908.08681), 2019.
- 5) 米玉利悠也, 重井徳貴, 杉本知史, 高江洲竜馬, 石塚洋一, 宮島廣美, ニューラルネットワークを用いた地盤強度の推定法の精度改善, ファジィシステムシンポジウム 講演論文集 第35回, 70-73, 2020.
- 6) T. Takeyama, S. Tachibana, A. Furukawa, A finite element method to describe the cyclic behavior of saturated soil, *International Journal of Material Science & Engineering- IJMSE* 2, 1, 20-25, 2015.
- 7) 柴田徹, 粘土のダイレイタンシーについて, 京都大学防災研究所年報 第六報, 128-134, 1963.
- 8) 大野進太郎, 飯塚敦, 太田秀樹, 非線形コントラクタンシー表現式を用いた土の弾塑性構成モデル, 応用力学論文集, 9, 407-414, 2006.
- 9) 橋口公一, 弾塑性論の新体系-下負荷面の概念, 土木学会論文集 3, 2007.

**筆者:** 1) 陳冉, 神戸大学工学研究科市民工学専攻, 学生 ; 2) 竹山智英, 神戸大学大学院工学研究科, 准教授 ; 3) 銭谷誠司, 神戸大学都市安全研究センター, 特命准教授 ; 4) 橘伸也, 神戸大学都市安全研究センター, 准教授 ; 5) 飯塚敦, 神戸大学都市安全研究センター, 教授

# Depth distribution estimation of over consolidation ratio by machine learning

Ran Chen  
Tomohide Takeyama  
Seiji Zenitani  
Shinya Tachibana  
Atsushi Iizuka

## Abstract

The overconsolidation ratio of the ground is a parameter that indicates the consolidation history of the ground and is one of the important parameters for analyzing the behavior of the ground. In this study, we proposed a new method for estimating the depth distribution of the overconsolidation ratio, which is a parameter representing the stress history of the ground, and a method for training neural networks using the results of finite element analysis. If the basement incident seismic wave and the ground surface seismic wave of a specific ground can be grasped by the proposed method, it is possible to estimate the depth distribution of the overconsolidation ratio of the ground. By comparing the predicted overconsolidation ratio with the correct answer value by the neural network trained by the teacher data prepared in this study, it was shown that the prediction accuracy is high.

©2021 Research Center for Urban Safety and Security, Kobe University, All rights reserved.