

一次元圧密を対象とした PINN による沈下予測とパラメータ推定

香川大学 正会員 ○久保 栞, 筑波大学 正会員 西尾 真由子, 東京大学 正会員 井上 純哉
山梨大学 正会員 宮本 崇, 東京大学 正会員 全 邦釘

1. 緒言

軟弱地盤上における構造物の建設時には、圧密にもなう地盤の沈下問題が発生する。そのような場合、対象となる地盤における土の種類や圧密特性など、様々な土質パラメータを力学試験や地盤調査によって推定し、それらをもとにした数値解析を行うことが一般的である。近年では、これら順・逆問題の両者に対して機械学習を用いた研究が進められており^[1,2]、当該分野においても機械学習の有用性は高いと考えられる。しかし、入手できる学習データが限られる点や、順・逆問題に対してそれぞれモデルを構築し、予測・推定を行う際のコストを鑑み、本研究では、物理法則を考慮した機械学習モデルである Physics-Informed Neural Networks (PINN)を用いて、圧密による沈下量・ひずみ分布の予測と、圧密係数の推定を同時に行うこととする。

2. 問題設定とモデルの構築

図-1 に示す粘土層からなる一次元の単純な地盤に対し、一定荷重を加えることで生じる圧密沈下量を予測し、対象地盤における圧密係数の推定を行う。本研究で対象とする一次圧密現象は、三笠の圧密方程式（式 1）によって記述されるものとする。

$$\frac{\partial \varepsilon(z,t)}{\partial t} = C_v \frac{\partial^2 \varepsilon(z,t)}{\partial z^2} \quad (1)$$

このとき、 ε はひずみ、 z は深さ、 t は時間、 C_v は、本研究において推定対象としている圧密係数をそれぞれ示す。加えて、粘土層の上面は排水、下面は非排水条件と




図-1 想定地盤

する. 本研究において設けた初期・境界条件は以下の通りである.

初期条件：

$$\varepsilon|_{z=0,t=0} = m_v q \quad \text{and} \quad \varepsilon|_{z \neq 0,t=0} = 0 \quad (2)$$

境界条件：

$$\left. \frac{\partial \varepsilon}{\partial t} \right|_{z=0} = 0 \quad \text{and} \quad \left. \frac{\partial \varepsilon}{\partial z} \right|_{z=H} = 0 \quad (3)$$

このとき、 m_v は体積圧縮係数、 q は載荷荷重、 H は層厚である。本解析では、 C_v 、 m_v をそれぞれ $C_v = 5.20 \times 10^{-7}$ (m²/s)、 $m_v = 1.20 \times 10^{-6}$ (m²/N)、 q 、 H をそれぞれ 100.00 N/m²、5.00 m とする。

PINN は Raissi らが 2019 年に発表した深層学習手法^[3]であり、工学分野においても徐々に活用が検討されているものの、現在はまだ基礎的な問題にのみ適用されている段階である。PINN の概要は図-2 に示す通りであり、Neural Networks (NN)によって予測された沈下量 $\hat{u}$ を自動微分することで得られた値をもとに、図-2 内青枠で示した二乗誤差(MSE)をそれぞれ算出する。PINN では図-2 内 MSE_{NN}に加え、PDE や IC/BC など、複数の物理法則に関する項を損失関数として与えている。本研究で構築したモデルの詳細、Collocation point ならびに観測データ等について表 1 にそれぞれ示す。なお、表に記載のない項目については、文献^[3]と同様としている。なお、PINN に予測・推定を行うにあたっては、載荷重量と、圧密係数が未知であると仮定し、圧密係数に関しては、初期値を 1.0×10^{-7} (m²/s)とする。圧密係数は推




図-2 PINN 概略図

キーワード 機械学習, Physics-Informed Neural Networks, 圧密

連絡先 761-0301 香川県高松市林町 2217-20

香川大学四国危機管理教育・研究・地域連携推進機構 TEL087-864-2544

表 1 モデル概要と学習データ

Hidden layer	9 layers with 20 neurons
activation function	Tanh
Optimization function	adam
Training times	400 epoch (1000 iterations/epoch)
Number of collocation points for each term	
for PDE	10000
for IC	1000
for BC	5000
Number of observation data	
of settlement (u)	241 (1 times/day)
of strain (e)	241 (1 times/day)

定時に負の領域に発散することを防ぐため、指数関数として定義し、また、各パラメータのスケールが大きくなるため、これらの正則化を行う。

3. PINN による予測・推定結果

本稿では、観測データにノイズを含まないケース (Case 1) と、10%のノイズを含むケース (Case 2) に対し、载荷開始から 100 日後のひずみ分布ならびに沈下量の予測と圧密係数の推定を行い、それらの結果を図-3,4、表-2 にそれぞれ示す。このとき学習に使用した観測データは、それぞれ载荷開始から 10 日分である。

図-3 より、ノイズの有無によらず、解析解と同様のひずみ分布が得られている。本研究では、学習に使用した観測データが、沈下量と地表面におけるひずみのみであることから、このようなひずみ分布は損失関数に PDE 項があるために予測できたものであると考えられる。圧密係数については、学習経過にともなって解析解に収束していることから(図-4)、PINN を用いることで、沈下量、圧密係数のいずれも数値解析と同程度の精度で予測・推定が可能であることが示唆される (表-2)。

4. 結言

物理法則を考慮した深層学習手法である PINN を用いて、圧密によって生じるひずみ分布と沈下量の予測、そして圧密係数の推定を行った。PINN では、観測回数や観測期間に依存せず、自由に学習データを作成することができるため、観測データが限られる場合であっても、予測・推定が可能となる。加えて、観測データにノイズが含まれる場合であっても、含まない場合と同等の精度を保つことが可能であることから、実際の現場においても有用であると考えられる。以上より、PINN によって、順・逆問題を精度よく同時に解くことが可能であることが示唆されたため、圧密問題への PINN の適用性は高く、今後の活用が期待される。




図-3 ひずみ分布の予測結果




図-4 圧密係数の推定結果

表 2 PINN による予測・推定結果

	Predicted settlement [m] (true: 0.282257)	Estimated Cv [m²/sec] (true: 5.20×10 ⁻⁷)
Case 1 (Noise-free)	0.282349	5.20×10 ⁻⁷
Case 2 (with 10% noise)	0.281285	5.15×10 ⁻⁷

参考文献

[1] X. Xion and L. Zhou: “Study on Prediction of Settlement of Foundation Based on Artificial Neural Network”, Architectural Engineering, Vol. 2, Issue 4, pp.78-85 (2014)

[2] M. Kanayama, . Rohe, and L. . Paassen: “Using and improving neural network models for Ground Settlement Prediction”, Geotechnical and Geological Engineering, no. 32, pp. 687-697 (2014)

[3] M. Raissi, P. Perdikaris, and G.E. Karniadakis: “Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations”, Journal of Computational Physics, 378, pp.686-707 (2019)

謝辞

本研究は、JST【ムーンショット型研究開発事業】
グラント番号【JPMJMS2032】の支援を受けたものです。