

## 沈下観測データを学習した深層学習モデルの予測精度の検討

Settlement prediction accuracy of deep learning model trained on observation data

○栗崎祥\* 金山素平\*\*  
Kurisaki A.\* and Kanayama M.\*\*

### 1. はじめに

軟弱地盤上に築造される盛土構造物の沈下は古くから地盤工学上の重要な問題であり、これまで国内外問わず数多くの研究者によって研究されてきた。盛土構造物の機能を適切に維持していくためには、地盤の沈下現象に対し高い精度を有する予測手法の構築が必要である。本研究では、ニューラルネットワークを多層化させた深層学習ネットワークモデルを従来の沈下予測手法に代わる手段として確立することを目的とする。さらに、汎用性の高い圧密沈下予測手法の構築を目指し、深層学習ネットワークモデルの予測精度を検討した。

### 2. ニューラルネットワークモデルと沈下予測への適用

本研究ではオランダ、アムステルダム近郊のBloemendalerpolder にて測定された沈下データ (BLO) と熊本県玉名市横島町の事前載荷盛土において測定された沈下データ (TAM1～TAM9) を利用した。本研究では、Fig. 2 に示す通り、ある観測データで事前に学習して構築されたネットワークモデルを他地点の沈下予測に用いた。予測をする際は、予測に用いるデータ範囲が予測結果に及ぼす影響を検討するため、実測沈下量の最終値  $S_f$  に対する各実測値の比を沈下量比  $R (= S_t / S_f \times 100)$  と定義し、 $R=35, 50, 60, 100\%$  の各教師データを用いてそれぞれ沈下予測を行った。なお、実測沈下量の最終値  $S_f$  まですべて学習して構築した学習ネットワークモデル（学習済みモデル）を構築した。その学習済みモデルの再現性を比較検討した。また、深層ニューラルネットワークモデルの入出力関係に関して、経過時間とその沈下量から沈下速度を学習する Rate pattern を採用した。検討条件 A として、深層学習ネットワークモデルに単一データを学習した場合の再現性、検討条件 B として、複数の沈下観測データを学習したモデルの予測の再現性を検討した。最後に、検討条件 C として、学習済みモデルに用いた沈下観測データとは異なる観測データを沈下予測に用いた場合の沈下予測精度について検討した。本研究の流れ



Fig. 1 Settlement phenomenon of tetrapod on soft clay ground

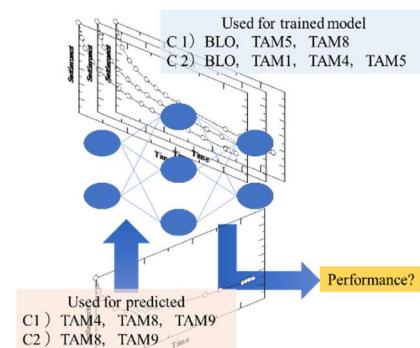


Fig. 2 Outline of this research

Table 1 Contest of examination

検討条件	学習に使うデータ（全データ）	予測に使うデータ（各R=35,50,60 %）
A 1) 2)	なし	BLO
	BLO	BLO
B 1) 2)	BLO, TAM5, TAM8	BLO, TAM5, TAM8
	BLO, TAM1, TAM4, TAM5	BLO, TAM1, TAM4, TAM5
C 1) 2) 3)	BLO	TAM1, TAM4, TAM5, TAM8, TAM9
	BLO, TAM5, TAM8	TAM1, TAM4, TAM9
	BLO, TAM1, TAM4, TAM5	TAM8, TAM9

ータとは異なる観測データを沈下予測に用いた場合の沈下予測精度について検討した。本研究の流れ

\*九州大学大学院生物資源環境科学府, \*\*九州大学大学院農学研究院

\*Graduate school of Bioresource and Bioenvironmental Sciences, Kyushu University, \*\*Faculty of Agriculture, Kyushu University

キーワード：圧密沈下、沈下速度、予測、深層学習

を Table 1 に、検討条件 C2) の詳細を Fig. 3 に示す。検討条件 C2) では、沈下パターンが類似していない BLO, TAM5, TAM8 の 3 地点の沈下観測データを学習データとして採用し、TAM1, TAM4, TAM9 の 3 地点のデータを予測データとして採用した。

### 3. 沈下予測結果と考察

Fig. 4 に検討条件 A1), A2) の予測結果、Fig. 5 に検討条件 C2) の予測結果、Table 2 にその予測精度を示す。Fig. 3 の結果から、本研究で使用している深学習モデルに単一のデータを全て学習させた際の再現性は極めて高いことが分かる。Fig. 4 の結果から、沈下量比  $R$  が 35% から 60% に増大するにつれて、TAM1 における APR の数値は 0.85, 0.83, 0.88 とほぼ一定値を示し、過小評価する傾向にあることが分かった。RMSE の数値は 0.52, 0.81, 0.87 を示した。TAM4 における APR の数値は 0.86, 0.89, 0.93 と 1.0 に近づく傾向にあることが分かった。RMSE の数値は 0.44, 0.31, 0.38 を示した。TAM9 における APR の数値は 0.75, 0.77, 0.83 と 1.0 に近づく傾向にあることが分かった。RMSE の数値は 0.79, 1.08, 1.26 を示した。TAM9において、APR は小さい値を示し、RMSE が大きな値を示したことから、他の予測データと比較して精度の良い予測を行うことができなかつたことがわかる。TAM9 は他地点とは全く異なる沈下挙動を示すデータであるが、機械学習による先行研究結果 (APR 1.34, APR の変動係数 1.12 %) と比較すると、予測精度が改善されることが分かった。このことから、複数の観測データを学習させた際、予測する観測データが学習観測データの沈下挙動に類似する場合、高精度の沈下予測が可能になると考えられる。

### 4. まとめ

本研究では、ニューラルネットワークを多層化させた深層学習ネットワークモデルの地盤沈下の予測精度を検討した。学習済みモデルに单一あるいは複数の観測データを用いた場合、沈下の予測精度が高くなること、再現性が良いことが分かった。今後、国内外の地盤の沈下観測データを収集することによって、本深層学習モデルの沈下予測精度が高まることが期待できる。

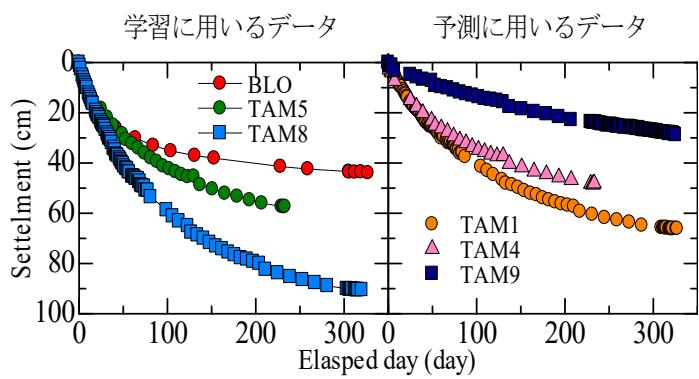


Fig. 3 Case C2) Data set for learning and prediction

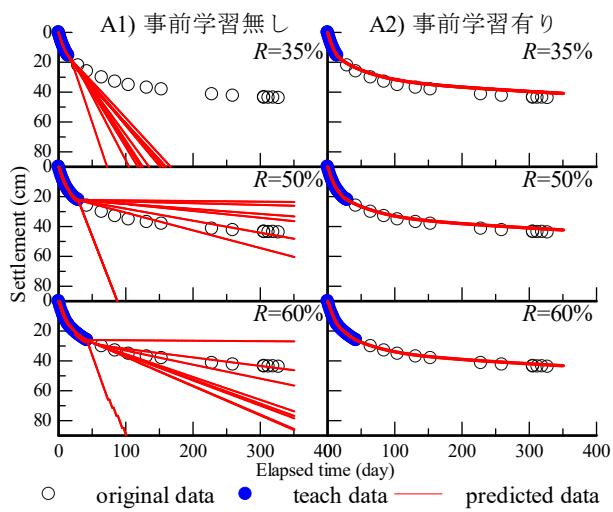


Fig. 4 Prediction results of Cases A1) and A2)

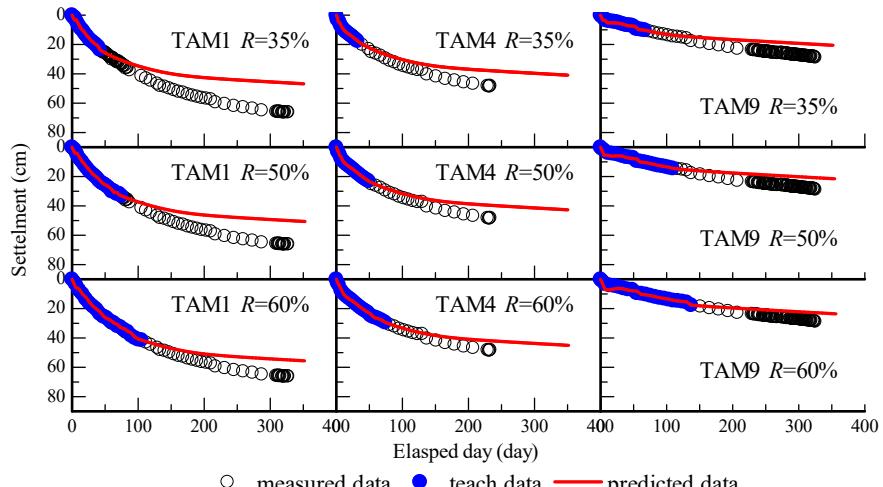


Fig. 5 Prediction results of Cases C2)