

機械学習を利用した地盤の圧密沈下予測手法の検討

Examination of consolidation settlement prediction method for ground using machine learning

佐藤快成 ○金山素平

Sato K. 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問題であり、数多くの研究者によって幅広く研究されてきた。軟弱地盤は、その高い圧縮性と低い透水性のため、長期間にわたって沈下が継続する。そのため、沈下管理を行うことは、施設の機能維持や、人々の安全確保において極めて重要なことである。近年、動態観測結果に基づいた手法としてニューラルネットワークを利用した圧密沈下予測手法に関する研究が行われている。現在は、この手法を利用して双曲線法等の既存の手法より精度の高い予測を行えること、初期の沈下データに対して比較的精度の高い予測を行えることが分かっている。本研究では、汎用性の高い圧密沈下予測手法の構築を目的とし、ニューラルネットワークモデルを使用した予測手法の予測精度を検討した。

2. 試験方法

本研究では、オランダ国内の 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、沈下板 1, 4, 5, 8, 9 にて測定されたデータ (それぞれ TAM-1, TAM-4, TAM-5, TAM-8, TAM-9) を利用した。Fig.1 はそれぞれの沈下挙動を示した図である。本研究では、Fig.2 に示す通り、ある地点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予測を行う際に適用したときの予測精度について検討した。なお BLO, TAM-5, TAM-8 を学習に使用するデータ、TAM-1, TAM-4, TAM-9 を予測に使用するデータとした。これは、異なる沈下挙動に対するネットワークモデルの適用性を知るためである。予測を行う際は、予測に用いるデータの範囲が予測結果に及ぼす影響を検討するために、実測沈下量の最終値 S_f に対する各実測値 S_i の比を沈下量比 $R (=S_i/S_f \times 100)$ と定義し、 $R=35, 50, 60\%$ のときの各教師データを用いてそれぞれ沈下予測を行った。またニューラルネットワークの入出力関係に関して、経過時間 t_j (入力値, t_1, t_2, \dots, t_j) とその沈下量 S_j (入力値 S_1, S_2, \dots, S_j) から沈下速度 $v_{j+1} (= (S_{j+1}-S_j)/(t_{j+1}-t_j))$, 出力値, v_2, v_3, \dots, v_{j+1}) を学習する Rate pattern を採用した。

3. 結果と考察

Fig.3 は、BLO, TAM-5, TAM-8 を学習したネットワークモデルを使用し、TAM-4 を予測した結果であり、Table 1 はそれぞれの予測精度を示したものである。学習済みモデルを使用したとき、すべての場合において平均予測率 APR の変動係数 CV は 0.09~0.22 % と低い値を示した。BLO データ学習済みモデルの予測結果である Fig.3 (1)~(3) において、APR は 0.93~0.96 であり、沈下量比 R に関係なく、

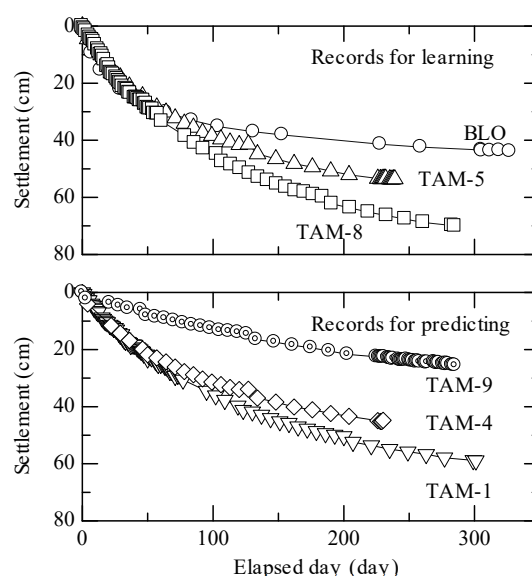


Fig.1 Settlement behavior recorded at each site

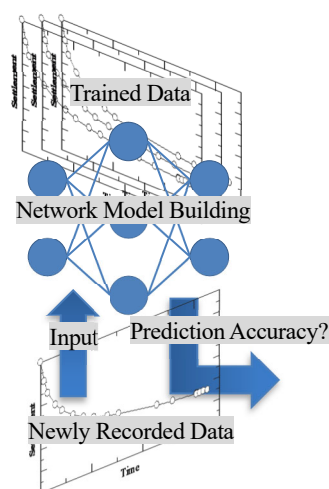


Fig.2 Outline of this research

岩手大学農学部

Faculty of agriculture, Iwate University

キーワード: 圧密沈下, 沈下速度, 予測, 機械学習

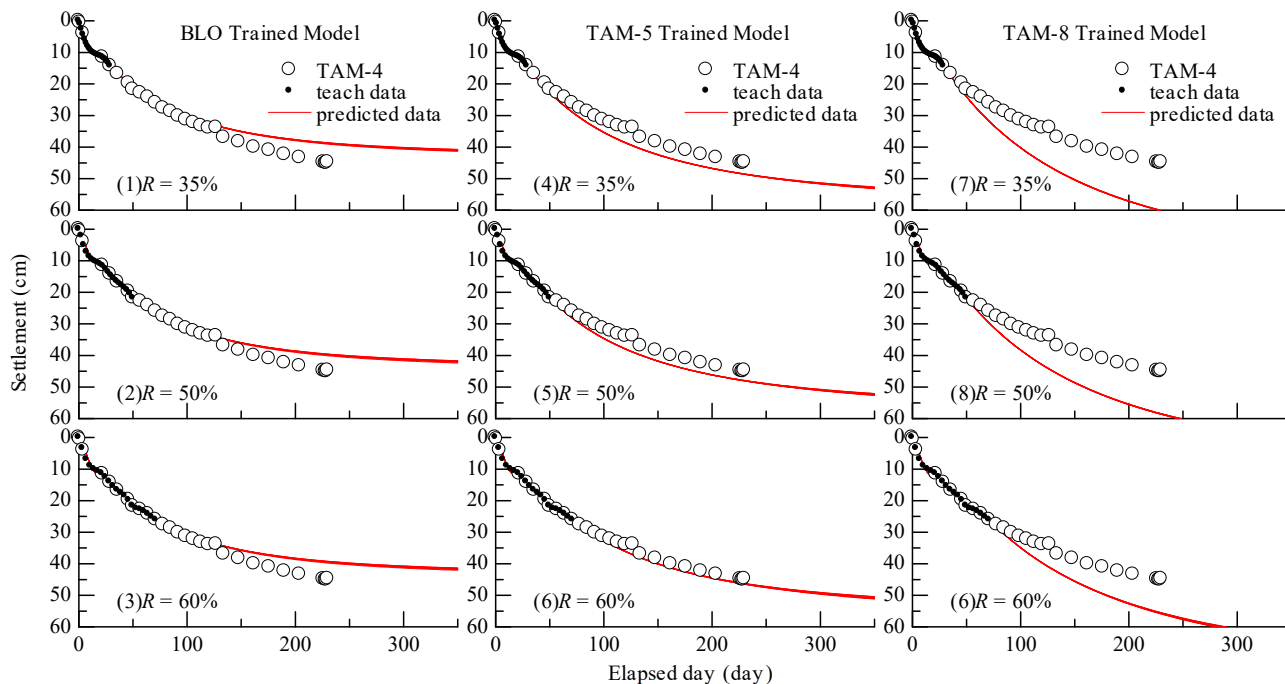


Fig.3 Prediction results of another recorded data by using the trained models

Table 1 Prediction accuracy of the trained models

BLO Trained Model				TAM-5 Trained Model				TAM-8 Trained Model			
Data	R (%)	APR	CV (%)	Data	R (%)	APR	CV (%)	Data	R (%)	APR	CV (%)
TAM-4	35	0.93	0.18	TAM-4	35	1.10	0.10	TAM-4	35	1.27	0.09
	50	0.96	0.21		50	1.08	0.10		50	1.23	0.09
	60	0.93	0.22		60	1.04	0.11		60	1.17	0.15
TAM-1	35	0.87	0.20	TAM-1	35	0.97	0.09	TAM-1	35	1.07	0.08
	50	0.82	0.26		50	0.92	0.11		50	1.04	0.14
	60	0.86	0.22		60	0.93	0.10		60	1.04	0.14
TAM-9	35	1.19	0.85	TAM-9	35	1.56	1.05	TAM-9	35	1.98	0.99
	50	0.99	0.89		50	1.26	1.30		50	1.60	1.38
	60	0.92	0.79		60	1.13	1.30		60	1.41	1.50

若干の過小評価を示した。TAM-5 データ学習済みモデルの予測結果である Fig.3 (4)~(6)では、沈下量比 R の増加に伴い、APR は 1.10 から 1.04 へ減少し、高い予測精度を示した。特に、 $R=60\%$ において、実測値とほぼ同じ値を示していることが分かる。TAM-8 データ学習済みモデルの予測結果である Fig.3 (7)~(9)では、沈下量比 R の増加に伴い、APR は 1.27 から 1.17 へ減少し、予測精度は向上したが、過大評価する傾向にあった。このことから、TAM-5 を学習したネットワークモデルを使用した予測結果は一番精度が高く、次いで BLO, TAM-8 の順となった。この原因として、事前に学習した観測値の沈下挙動が関係していると考えられる。BLO, TAM-5, TAM-8 の最終実測値は、それぞれ 43.9 cm (327 日)、53.6 cm (239 日)、70.1 cm (285 日)であった。一方、TAM-4 の最終実測値は 44.8 cm (230 日)であったことから最終沈下量の差が小さいとき、学習済みモデルの適用は可能であることが分かる。特に、学習に利用したデータの最終沈下量が、予測に利用したデータの最終沈下量より大きいとき、沈下量比 R の増加に伴い、予測精度は高い値を示した。なお TAM-1, TAM-9 の予測を行った際も、同様の傾向を示した。

4. まとめ

本研究では、機械学習を利用した圧密沈下予測手法の構築を目的とし、学習済みモデルに対し新たな観測データを適用した際の予測精度について検討した。学習時と異なるデータを使用するとき、その最終沈下量の差が小さい場合、学習済みモデルは高い予測精度を有することが分かった。特に、学習した最終沈下量が新たに学習する最終沈下量より大きい場合、学習に使用するデータ数の増加にともなって予測精度が向上することが分かった。