

沈下観測データを学習した機械学習モデルの沈下予測精度

Settlement prediction accuracy of machine learning model trained on observation data

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。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、事前載荷盛土の沈下データを機械学習したモデル内の重みを使用し、沈下予測精度の向上を検討した。

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測定されたデータ (TAM-1, TAM-4, TAM-5, TAM-8, TAM-9) を利用した。

本研究では、Fig.1 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_t の比を沈下量比 $R (=S_t/S_f \times 100)$ 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。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 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. 予測結果と考察

Figs.2(a)-(c)は、BLO, TAM5, TAM8 の全範囲の観測データを学習させたモデルに、それぞれ TAM1, TAM4, TAM9 の $R=35, 50, 60\%$ の観測データを与えた場合の予測結果である。Table 1 に予測精度の指標となる平均予測率 APR と二乗平均平方根誤差 RMSE を示す。Fig.2, 3 から、学習と予測に使用した観測データの差異が小さい場合予測精




Fig.1 Outline of this research

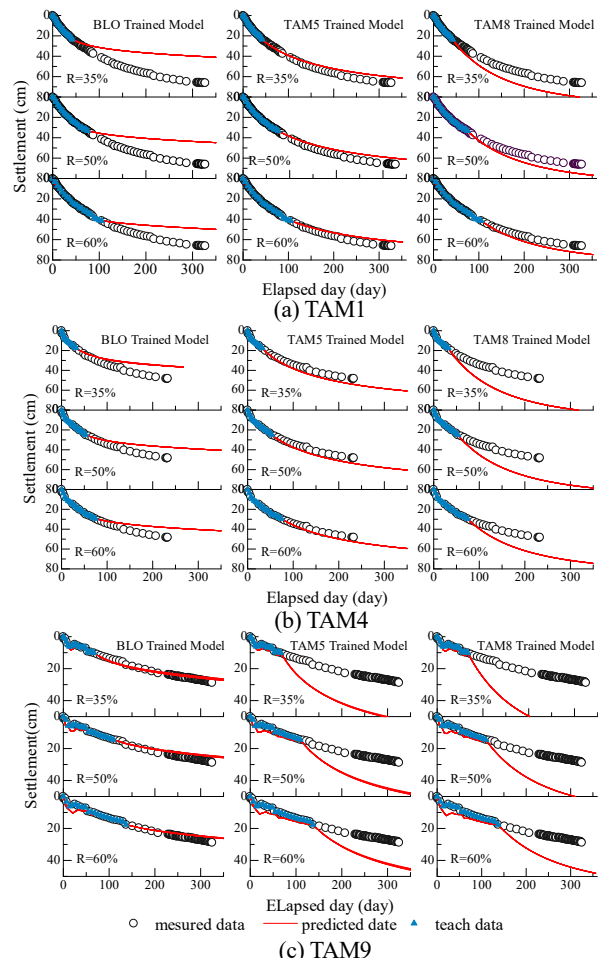


Fig.2 Prediction results by trained models

*NTC コンサルタンツ(株), **九州大学大学院農学研究院
*NTC consultants Inc., Faculty of Agriculture, Kyushu University
キーワード: 圧密沈下, 沈下速度, 予測, 機械学習

Table 1 Prediction accuracy by trained models

TAM1				TAM4				TAM9			
Trained Model	R(%)	RMSE	APR	Trained Model	R(%)	RMSE	APR	Trained Model	R(%)	RMSE	APR
BLO	35	0.10	0.78	BLO	35	0.09	0.82	BLO	35	0.29	0.98
	50	0.18	0.76		50	0.06	0.86		50	0.39	0.90
	60	0.22	0.80		60	0.09	0.87		60	0.43	0.93
TAM5	35	0.10	0.97	TAM5	35	0.11	1.14	TAM5	35	0.40	1.85
	50	0.15	0.93		50	0.09	1.10		50	0.56	1.63
	60	0.14	0.94		60	0.12	1.07		60	0.66	1.52
TAM8	35	0.14	1.18	TAM8	35	0.14	1.42	TAM8	35	0.45	2.19
	50	0.23	1.10		50	0.18	1.35		50	0.64	1.77
	60	0.25	1.08		60	0.24	1.26		60	0.74	1.59

度 (APR=0.93-1.14) は高いことが分かる. また, 学習観測データより小さい場合, 沈下を過小評価 (APR=0.76-0.87) し, 学習観測データが予測観測データより, 大きい場合, R の増大とともに予測精度が改善される (APR=1.18-1.08) ことが分かる. 一方, Fig.4 の結果によると, すべての予測で良い結果が得られなかった. 原因は, RMSE が 0.29-0.74 と高い値を示したことから比較的規則性の高い観測データを再現できなかったことが挙げられる. これは, 学習データとは異なる傾向にある観測データを使用する場合, 本モデルの使用には注意が必要であることが分かる.

4. モデル内で構築された重みによる予測精度の改善方法

Table 2 は, 学習モデル内に構築された重みを示しており, 入力層から中間層における経過時間 t_j の重み W_t , 沈下量 S_j の重み W_s , 中間層から出力層の重みは W_v である. W_t は 0 に近い値, W_v は概ね同じ値を示したことから, 予測値へ与える影響は少ないと判断できる. W_s のみは他と比較して大きな値をとっていることにより観測データの類似性を表現することが可能となる. そこで判定値 $J_v = |W_sL - W_sP| / W_sL$ を定義し, 学習モデルに対して適切となる予測観測データを判別する. ここで, 学習モデルに含まれる重みを W_sL , 予測に用いるデータに含まれる重みを W_sP とした.

Table 2 Weights in trained models

Weight	TAM1 60%		TAM4 60%		TAM9 60%	
	Average	SD	Average	SD	Average	SD
W_t	-0.0001	0.02	-0.03	0.25	1.09	0.27
W_s	1.18	0.04	2.31	0.23	4.25	0.20
W_v	-0.98	0.00003	-0.85	0.002	-1.10	0.002
Weight	BLO all		TAM5 all		TAM8 all	
	Average	SD	Average	SD	Average	SD
W_t	1.51	0.07	0.44	0.03	0.84	0.01
W_s	2.20	0.12	2.00	0.08	0.83	0.02
W_v	-1.16	0.001	-1.10	0.001	-1.15	0.0001

Table 3 は, 判定値 J_v を基準とした予測精度の比較結果である. 各事例によって J_v 値に多少のばらつきはあるが, J_v 値が低い値を示すと, APR は 1 に近づく傾向にあることが分かる. この指標を用いることによって, 予測すべき観測データに最適な学習済みモデルを選定可能となることが判明した. 地盤の沈下観測データをより多く収集することによって, 種々の現場状況に応じた地盤の沈下予測を精度よく実施することが期待できる.

Table 3 Relationship between J_v and APR

Case	Trained Model	Judgement Value J_v	APR
TAM1	BLOall	0.46	0.80
	TAM5 all	0.41	0.94
	TAM8all	0.43	1.08
TAM4	BLOall	0.05	0.87
	TAM5 all	0.16	1.07
	TAM8all	1.79	1.26
TAM9	BLOall	0.93	0.93
	TAM5 all	1.12	1.52
	TAM8all	4.13	1.59

5. まとめ

本研究は, 汎用性の高い圧密沈下予測手法の構築を目的とし, 事前載荷盛土の沈下観測データを機械学習したモデル内の重みを利用し, 沈下予測精度の向上を検討した. 学習と予測に使用した観測データの差異が小さい場合予測精度は高いこと, 学習観測データが予測観測データより小さい場合沈下は過小評価すること, 学習観測データが予測観測データより大きい場合沈下量の増大とともに予測精度が改善されることが分かった. また, モデル内で構築された重みを考慮することによって, 予測すべき観測データに最適な学習済みモデルを選定可能となることが判明した.