

機械学習の適用による切羽前方地山の掘削時天端ひずみ予測

(株)大林組 正会員 ○萩野 知 木梨 秀雄 岡崎 雄一 渡辺 淳

1. はじめに

山岳トンネル建設に際し、前方地山の性状（地山等級、地下水等）を予測することは、合理的な設計および施工を実現するうえで非常に重要である。特に、掘削時の天端部地山の安定性（ひずみレベル）を事前に把握することができれば、適切な支保パターンの選定や先受け工等の補助工法の要否を判断することができる。そこで、本研究では、機械学習の適用により、前方探査データを活用して掘削時の天端ひずみを予測するモデルの構築を試みるとともに、モデルの精度に与える入力値の影響を検証した。

2. 機械学習

本研究では、天端ひずみを予測するモデルの構築に際し、機械学習の「教師あり学習」を用いた。教師あり学習では、まず既存の入力値と出力値の組合せである教師データをもとに、それぞれの出力値に対応する入力値のパターンを学習させ予測モデルを構築する。その上でこれを、出力値が未知である入力値に適用し予測を行う。なお学習段階においては、手法の異なる19種類の回帰学習器（表1）を適用した。各回帰手法の詳細は参考文献¹⁾を参照されたい。

3. 手法

本研究では、すでに竣工済みの全長約2000mの道路トンネルを対象としている。地質は花崗岩、閃緑岩で構成され、坑口部以外の実施支保パターンはCⅡ、DⅠ、DⅡである。距離程（以下、TD）0から1200mを学習の対象に、1200m以降を予測の対象とした。当現場では概ねトンネル全線に渡り、ノンコア先進ボーリングが実施されており、削孔時に得られるフィード圧と削孔速度から、正規化削孔速度比²⁾と呼ばれるパラメータが得られる。また、一部区間において天端崩落対策として充填式フォアポーリングおよび注入式フォアポーリングを施工している。

機械学習における入力値として土被り厚、正規化削孔速度比、断面あたりの先受け工の打設本数、実施支保パターンを、出力値として掘削時の天端ひずみを採用した（図1）。天端ひずみについては、トンネル全線に渡り概ね10mから20mの間隔で実施されたA計測の実施断面において、天端の最終沈下量を上半の掘削半径で除することにより求めており、先行変位率は30%を見込んでいる。

表1 回帰学習器一覧

A	線形回帰
B	交互作用あり線形回帰
C	ロバスト線形回帰
D	ステップワイズ線形回帰
E	回帰木(最小リーフサイズ 4)
F	回帰木(最小リーフサイズ 12)
G	回帰木(最小リーフサイズ 36)
H	SVR 線形カーネル
I	SVR 2次カーネル
J	SVR 3次カーネル
K	SVR ガウスカーネル(スケール 0.5)
L	SVR ガウスカーネル(スケール 2)
M	SVR ガウスカーネル(スケール 8)
N	アンサンブルブースティング決定木
O	アンサンブルバギング決定木
P	ガウス過程回帰 二次指数カーネル
Q	ガウス過程回帰 Matern 5/2カーネル
R	ガウス過程回帰 指数カーネル
S	ガウス過程回帰 有理二次カーネル




図1 ひずみの計測値、正規化削孔速度比および土被り

キーワード 機械学習、ひずみ、前方探査、土被り、トンネル

連絡先 〒108-8502 東京都港区港南 2-15-2 品川インターシティ B 棟

(株)大林組 土木本部生産技術本部トンネル技術部 TEL03-5769-1319

続いて、TD1200m までの教師データを用いて構築した予測モデルから TD1200m 以降の天端ひずみの予測を行い、実際の計測値との比較を行った（図2）。

なお、実施支保パターンについてはそれ自体に大小関係を持たないカテゴリと分類されるデータとして、それ以外の入力値は数値データとして学習および予測を実施している。

4. 結果

予測モデルの精度の検証に際し、平均二重誤差平方根（以下、 $RMSE$ ）を用いた。 $RMSE$ は、標本数 n 、天端ひずみの予測値 x_i 、天端ひずみの実際の計測値 c_i から、下記の式(*)より求められ、これは予測値と計測値のひずみ誤差を意味する。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - c_i)^2} \quad (*)$$

学習器の選定に際し $RMSE$ の値が最も小さくなったのは、回帰学習器 C、H、M（表1網掛け）であった。これらについて入力値、特に入力土被り厚が予測精度に与える影響について検討を行った。

学習および推論段階に入力値として用いる土被り厚のデータに、上限値として「入力最大土被り厚」を設定した。例えば、入力最大土被り厚を 50m と設定した場合、50m 以上の土被り厚は、入力値をすべて 50 とする。 $RMSE$ と入力最大土被り厚の関係は図3の通りで、入力最大土被り厚 75m で $RMSE$ が小さくなる傾向にある。これは、土被り厚が天端沈下を与える影響が、ある土被り厚を上限に著しく小さくなったためだと考えられる。

$RMSE$ が最も小さくなったのは、学習器 C を用い、入力最大土被り厚を 75m とした場合で、予測値と計測値は図4の通りである。この図から、本手法では現場の管理ひずみレベル 1%以上の領域を概ね予測でき、補助工法の要否を評価できる可能性が示唆される。なお、 $RMSE$ は 0.22%であり、当該区間の限界ひずみ 1%に比して十分に小さかった。

5. まとめ

機械学習の適用により、土被り、前方探査、実施支保パターン、補助工法のデータから、天端ひずみを予測するモデルを構築し、その精度を検証した。今後は、本手法を地質や土被りの異なる様々なトンネルに適用し、予測精度の向上につなげていきたい。

謝辞

本研究においては、MathWorks Japan の井原瑞希氏にご協力いただいた。ここに感謝の意を表す。

参考文献

- 1) C.M.ビショップ:パターン認識と機械学習 上 ベイズ理論による統計的予測、丸善出版、2016
- 2) 桑原 徹、畑 浩二、稲川雄宣、平川泰之:変換解析システムによるノンコア削孔トンネル切羽前方予測技術、トンネル工学論文集第 18 巻、pp.1-10、2008




図2 学習から予測に至るプロセス




図3 予測誤差と入力最大土被り厚




図4 天端ひずみの予測値と計測値