

機械学習の適用による切羽前方地山の ひずみ予測

渡辺 淳¹・萩野 知²・木梨 秀雄³・鈴木 拓也⁴

¹ 正会員 株式会社大林組 土木本部トンネル技術部 (〒108-8502 東京都港区港南 2-15-2)
E-mail:watanabe.atsushi@obayashi.co.jp

² 正会員 株式会社大林組 天ヶ瀬減勢池部 JV 工事事務所 (〒611-0015 京都府宇治市志津川南詰 15)
E-mail:hagino.satoru@obayashi.co.jp

³ 正会員 株式会社大林組 土木本部トンネル技術部 (〒108-8502 東京都港区港南 2-15-2)
E-mail:kinashi.hideo@obayashi.co.jp

⁴ 正会員 株式会社大林組 土木本部トンネル技術部 (〒108-8502 東京都港区港南 2-15-2)
E-mail:suzuki.takuya@obayashi.co.jp

トンネル掘削において、地山等級、掘削時の変位などの前方地山の性状を予測することは、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、掘削時地山の安定性の指標となる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などの補助工法の要否を判断することができる。本研究では、機械学習の適用により、切羽前方探査データを活用して前方地山の掘削時の天端ひずみおよび側壁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。

Key Words : machine learning, probing ahead of face, strain, overburden

1. はじめに

近年、AI的手法の一つとして機械学習が建設分野にも活用されつつある。機械学習とは、与えられたデータから、その潜在的な特徴や関係を抽出・定量化し、新しいデータに対する予測性能を獲得する分析手法である。

画像処理の分野では、例えば、畑ら¹⁾は切羽画像から、強度、風化変質、割目間隔などの各種切羽観察項目を判定するモデルを深層学習により構築し、69%から89%の的中率を実現した。また、宇津木ら²⁾はAIの画像認識技術を活用し、画像から岩石種や風化程度などを自動で判定するシステムを構築した。

数値データの処理に関しては、杉浦ら³⁾はドリルジャンボで発破孔を穿孔する際の穿孔データと切羽評価点の機械学習を遺伝的プログラミングを用いて行った。長谷川ら⁴⁾は事前調査で得られる弾性波速度や比抵抗、地表地質踏査の結果と施工時支保パターンとの関係をニューラルネットワークを用いて評価する手法を構築した。

一方で、近年様々な手法が開発されつつある切羽前方探査技術では、削孔時のデータから独自の指標を算出し、地山等級をはじめとした切羽前方地山の性状を判断して

いる。例えば、桑原ら⁵⁾は、ドリルジャンボを用いたノンコア削孔検層で得られるフィード圧と削孔速度から「正規化削孔速度比」と呼ばれるパラメータを算出し、切羽前方地山の硬軟を判定した。

本研究では、切羽前方探査で得られる削孔データを機械学習の入力値として適用することで、切羽前方の地山性状を予測するモデルを作成し、判定精度の高度化を試みた。

2. 学習手法および予測対象

本研究では機械学習⁶⁾の中でも、教師あり学習と呼ばれる手法を用いている。これは、入力データとそれに対応する応答が既知である出力データの組み合わせ（以下、教師データ）から、それらの関係性を求めるものである。入力データを離散的なカテゴリに分類する手法を分類学習と呼び、出力値が数値データのように連続変数であるような学習手法を回帰学習と呼ぶ。これらの学習手法の概念を図-1に示す。機械学習によって構築された予測モデルを、出力値が未知である入力値に適用すること

(以下、予測)により予測値が得られる。機械学習は過去の事象を学習してモデル化し、将来を予測するという点で線状構造のトンネル工事には適すると考えられる。

3. 切羽前方探査および各種計測データ

本研究では、竣功済みの全長約2000mの道路トンネルを対象に機械学習を用いた前方予測を試みた。図-2のように地質は花崗岩、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であった。当現場では概ね全線にわたりドリルジャンボによるノンコア削孔検層を実施しており、正規化削孔速度比が得られている。また、一部区間で天端崩落対策として長尺フォアパイリング等を施工している。

機械学習の入力値にはTD0~1200m区間の土かぶり、正規化削孔速度比とし、出力値に掘削時の地山の接線方向ひずみ γ (以下、ひずみ)を採用した。ひずみについてはトンネル全線に渡り、おおむね10mから20mの間隔で実施したA計測の実測断面にて、天端の最終沈下量および内空変位量を掘削半径で除することにより求めている⁸⁾。なお、先行変位率は30%を見込んでいる。図-3のように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以降のひずみの予測を行い、実測値と比較した。

対象となるトンネルのひずみ、土被りおよび正規化削

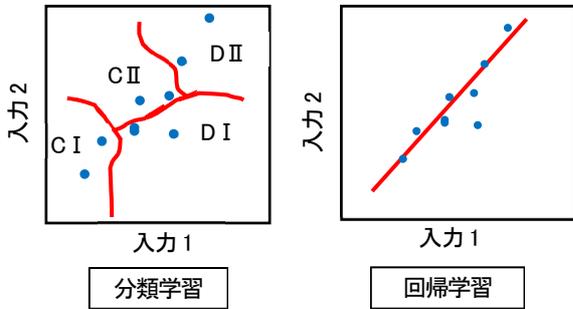


図-1 分類学習と回帰学習

孔速度比は図-3の通りである。

4. 土かぶりと正規化削孔速度比からの予測

(1) 入力データ

学習および予測には前処理として1m毎の平均化した入力値を用いている。入力値としては、予備検討より、土かぶりおよび削孔検層で得られる正規化削孔速度比を選定した。

(2) 掘削時のひずみの予測

ひずみの予測については、TD 0mから1200mを学習区間に、TD 1200mから2000mを予測の対象とする。

出力値であるひずみは数値データとして扱い、学習区間での回帰学習により予測モデルを作成した。回帰学習は、サポートベクター回帰(以下、SVR)、アンサンブル回帰、ガウス過程回帰を試行した。これらは、一般的に教師データのサンプル数が少ない場合においても安定した予測精度が得られると言われている。回帰学習で得られた予測モデルから、予測値であるひずみを得る。

予測モデルの精度の評価には、平均二重誤差平方根

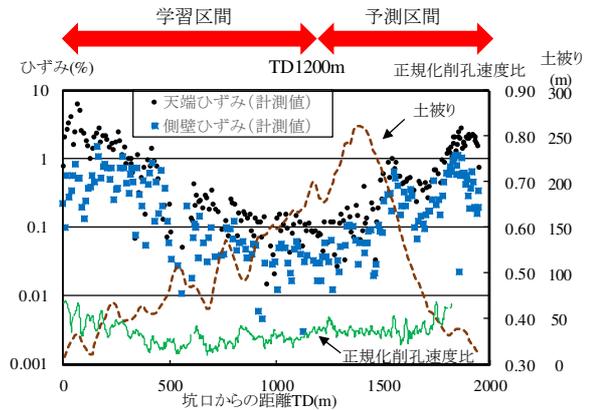


図-3 トンネルの各種計測データ、土被り

(以下、RMSE)を用いた。RMSEは、標本数 n 、天端ひ

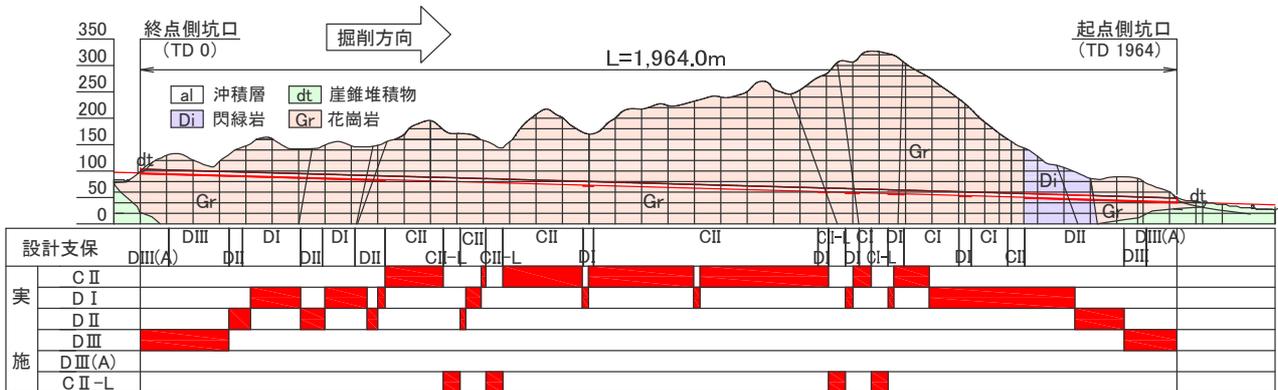


図-2 地質縦断面図

ずみの予測値 x , 天端ひずみの実際の計測値 c から, 下記の式(1)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.

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

(3) 予測値

土かぶりと正規化削孔速度比からのひずみの予測値と実測値の比較を, 天端ひずみは図-5に, 側壁ひずみは図-6に示す. ひずみの予測に際し, 3つの学習手法の中で, 推論段階でのRMSEが最も小さくなったのはSVR⁹であった.

図-5より,天端ひずみは, 学習区間および予測区間において, おおむね実測値に近い予測が得られたが, 区間A, B, Cでは大きな差が生じている.

図-6より,側壁ひずみは, 天端ひずみと同様で, 学習区間および推論区間において, おおむね実測値に近い予測が得られたが, 区間A, Bではやや差が生じている.

(4) 不一致区間の考察

- ・区間A: TD0~150mは側壁ひずみが一致しているものの, 天端ひずみは実測値に比べて予測値が過小評価となっている. この区間は, 坑口部であり, トンネルアーチ仮インバートによる閉合を行っても地盤の支持力不足による沈下があった. この支持力不足の条件が, 予測モデルに反映していないためと考えられる. 一方, TD150~400m区間は, 天端ひずみ, 側壁ひずみともに実測値に比べて過小評価となっている. この区間は図-3により正規化削孔速度比が坑口部よりも小さく, 比較的硬質であることが分かる. しかし, 正規化削孔速度比のデータは大小の変動幅が大きく, き裂の多い区間であることを示しており, 掘削時の変位が大きくなる傾向にあった. このため, き裂の情報を入力値として与えていない本モデルでは, 予測値と実測値に差が生じたものと考えられる.

- ・区間B: 天端ひずみ, 側壁ひずみともに予測値が実測値を下回り, 過小評価となっている. この区間も, TD150~400mと同様に, 速度データは大小の変動が大きく, 多き裂であることから変位が大きくなる傾向であった. き裂の情報を入力値として与えていない本モデルでは, 予測値と実測値に差が生じたものと考えられる.

- ・区間C: 天端ひずみは予測値が実測値を上回る過大評価, 側壁ひずみは予測値と実測値がおおむね一致している. この区間は, 当初からDIIと安全側のパターンであった. さらに露頭部や前方探査より区間Aと同様な地質であったことから, 天端ひずみが大きくなることが予測できた. このため, 天端崩落対策の長尺フォアパイリング, 切羽安定対策の長尺鏡ボルトの他に早期閉合で施工

しており, 予測値に対して実際の天端ひずみを抑制されたと考えられる. 本モデルでは, 入力値に補助工法や早期閉合条件を与えていないために, 予測値との差が生じ

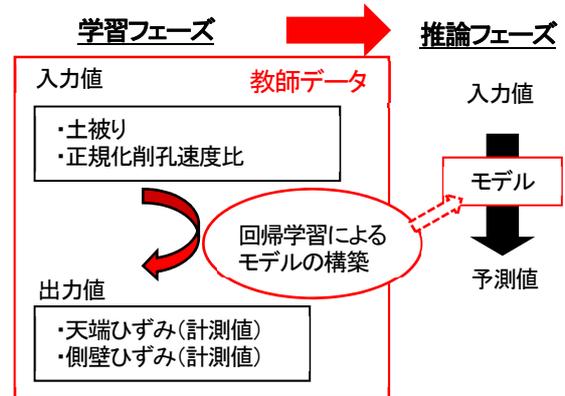


図4 学習から予測に至るプロセス

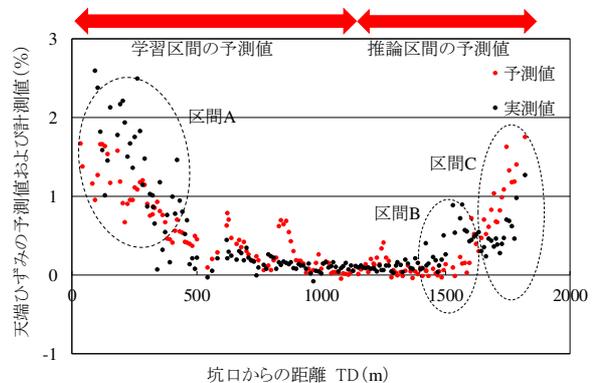


図5 天端ひずみの予測値

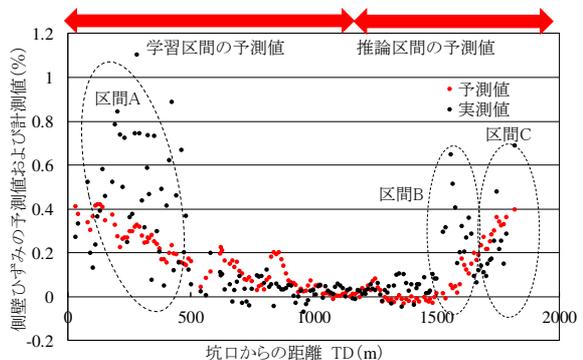


図6 側壁ひずみの予測値

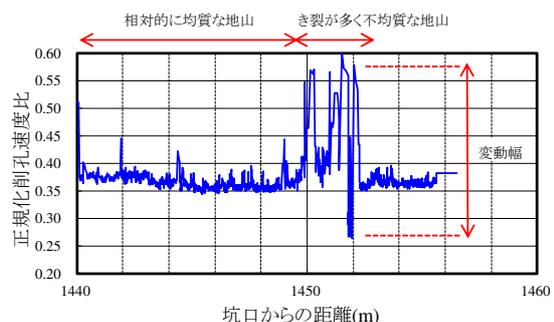


図7 多き裂区間の正規化削孔速度比変動状況

たものと考えられる。

5. 正規化削孔速度比の変動幅

入力値を土かぶり、正規化削孔速度比としたモデルから得られたひずみの予測値と実測値は、おおむね一致したものの、他き裂区間や補助工法使用区間において、予測値と実測値に差が生じた。桑原ら¹⁰⁾は、正規化削孔速度比のばらつきが大きいケースの場合、地山の不均質、力学的異方性と判断している。このため、入力値に多き裂区間の目安となる正規化削孔速度比の変動幅を追加して再検討を行った。

(1) 入力データ

前モデルと同様に、学習および推論には前処理として1m毎の平均化した入力値を用いている。入力値としては、土かぶりおよび前方探査時に得られる正規化削孔速度比の他に、正規化削孔速度比の変動幅を追加している。

(2) 掘削時のひずみの予測

ひずみの予測についても、前モデルと同様にTD 0mから1200mを学習区間に、TD 1200mから2000mを推論の対象とする。

出力値であるひずみは数値データとして扱い、学習区間での回帰学習により予測モデルを作成した。回帰学習においても同様に、SVR、アンサンブル回帰、ガウス過程回帰を試行した。回帰学習で得られた予測モデルから、予測値であるひずみを得る。

(3) 予測値

土かぶりと正規化削孔速度比からのひずみの予測値と実測値の比較を、天端ひずみは図-9に、側壁ひずみは図-10に示す。ひずみの予測に際し、3つの学習手法の中で、推論段階でのRMSEが最も小さくなったのはアンサンブル回帰であった。

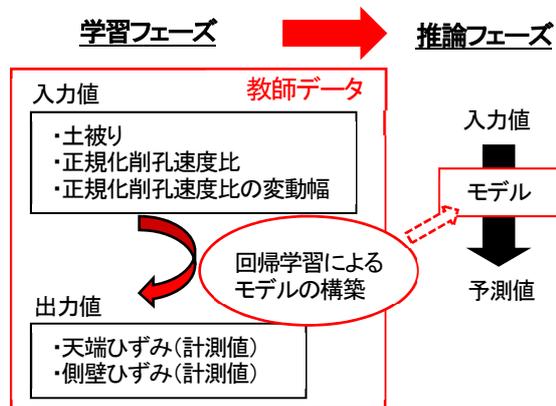


図-8 学習から予測に至るプロセス

図-9より、天端ひずみの予測値は、学習区間および予測区間において、おおむね実測値に近い予測が得られ、正規化削孔速度比の変動幅を追加したことにより精度は向上している。ただし区間Cでは、前モデル同様に大きな差が生じている。

図-10より、側壁ひずみの予測値は、天端ひずみと同様で、学習区間および推論区間において、おおむね実測値に近い予測が得られ、正規化削孔速度比の変動幅を追加したことにより精度は向上している。ただし区間Bでは、前モデル同様に大きな差が出ている。

(4) 考察

- ・区間A：正規化削孔速度比の変動幅を入力値として与えることで、TD150～400m区間は、天端ひずみ、側壁ひずみともに実測値とおおむね一致した。
- ・区間B：天端ひずみは、正規化削孔速度比の変動幅を追加したことにより、前モデルとより精度は向上している。一方、側壁ひずみは、正規化削孔速度比の差を追加しただけでは、予測値に変化が見られなかった。この区間は、き裂が多く、き裂に粘土を挟んでいた。また、湧水も600L/minと多く、湧水による地山の劣化が生じていたことから、き裂の情報を追加した本モデルでも、予測値と実測値に差が生じたものと考えられる。
- ・区間C：正規化削孔速度比の差を追加した本モデルで

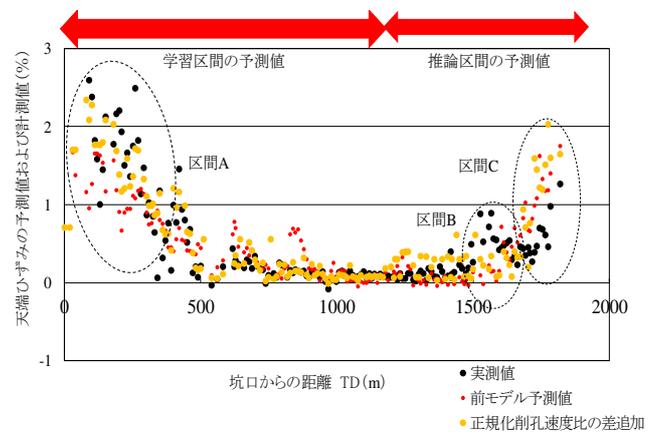


図-9 天端ひずみの予測値

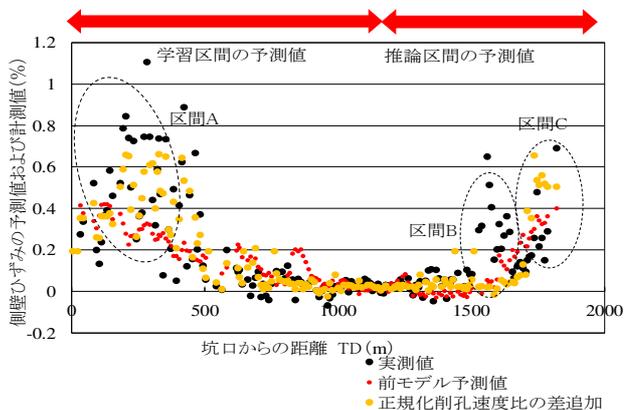


図-10 側壁ひずみの予測値

も、前モデルと同様である。実測値は、補助工法や早期閉合により抑制されたひずみであるため、予測値との差が生じたものと考えられる。一方で、この予測値は補助工法や早期閉合を行わない場合のひずみを示しているものと考えられる。

6. まとめ

今回、機械学習を利用して切羽前方探査で得られる削孔データを用いて天端ひずみおよび側壁ひずみの予測モデルを作成し、その予測精度を検証した。予測モデル作成において、き裂の影響の指標となる正規化削孔速度比の変動幅を教師データに追加することで、おおむねひずみを予測することができた。同時に、予測値と実測値の差が大きい区間も分かった。この区間は、多き裂区間、粘土および多量湧水による地山の劣化から生じたものであることが分かった。

今後は、湧水による地山の劣化などの施工条件や地質条件の異なる他現場のデータも蓄積して、機械学習に用いるデータ数を十分に確保し、機械学習による予測モデルの精度向上を目指したい。

参考文献

- 1) 畑浩二, 中岡健一: 山岳トンネル切羽評価への人工知能適用に関する研究, トンネル工学報告集, 第 27 巻, I-24, 2017.
- 2) 宇津木慎司, 中谷匡志, 鶴田亮介, 野村貴律: AI を活用したトンネル切羽地質状況自動評価システムの構築および施工現場への適用, トンネル工学報告集, 第 27 巻, I-25, 2017.
- 3) 辰巳順一, 河邊信之, 土井美里, 佐々木亨, 森本真吾, 進士正人; 遺伝的プログラミングを用いた穿孔データに基づく地山評価手法の開発, トンネル工学報告集, 第 26 巻, I-35, 2016.
- 4) 長谷川真吾, 大津宏康, 北岡貴文: ニューラルネットワークを用いた山岳トンネル建設プロジェクト事前調査段階における地山評価手法に関する研究, 第 44 回岩盤力学に関するシンポジウム講演集, 公益社団法人土木学会, 講演番号 36, 2016.
- 5) 桑原 徹, 畑 浩二, 稲川雄宜, 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.
- 6) 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.
- 7) H・カスナー: トンネルの力学, 森北出版, 1974.
- 8) 桜井春輔: NATM における現場計測と管理基準値, 土と基礎 34(2), pp.5-10, 1986.2
- 9) 萩野知, 木梨秀雄, 岡崎雄一, 渡辺淳: 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, 土木学会年次学術講演会, 第 73 回, III-509, 2018.
- 10) 桑原 徹, 畑 浩二, 赤澤正彦: ノンコア削孔調査による山岳トンネル切羽前方探査精度の検討, トンネル工学報告集第 23 巻, pp.1-9, 2013.

(2019. 8. 9 受付)

PREDICTION OF STRAIN DURING EXCAVATION AHEAD OF FACE BY APPLICATION OF MACHINE LEARNING

Atsushi WATANABE, Satoru HAGINO, Hideo KINASHI and Takuya SUZUKI

When constructing a tunnel, it is important to predict the properties of the ground ahead of face in order to realize rational design and construction. Especially, if we can grasp the amount of strain at the time of excavation ahead of face, we can judge the necessity of selecting an appropriate support pattern and the necessity of an auxiliary method such as a presupport. In this research, machine learning was applied to construct a model that predicts the support pattern ahead of face and the strain at the time of excavation by using the forward exploration data. The influence of the input value on the accuracy of the model was verified by comparing the predicted data and the actual.