

機械学習の適用による切羽前方地山の 地山等級および掘削時のひずみ予測

萩野 知¹・木梨 秀雄²・岡崎 雄一³

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:hagino.satoru@obayashi.co.jp

²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

³正会員 株式会社大林組 大沼トンネルJV工事事務所 (〒041-1355 北海道亀田郡七飯町西大沼404-5)
E-mail:okazaki.yuichi@obayashi.co.jp

トンネル建設に際し、前方地山の性状(地山等級、掘削時の変位等)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、前方地山の支保パターンや掘削時のひずみ量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天端崩落対策工等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支保パターンや掘削時の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, support pattern, strain, overburden

1. はじめに

近年、AI的手法の一つとして機械学習がトンネル建設に活用されつつある。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

ンコア先進ボーリングによる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」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。また、磐田ら⁶⁾はダウンザホール式の水圧ハンマを搭載したボーリングマシンを用いて、削孔を行った際の削孔データから独自に算出した「エネルギー指標値」から地山等級の評価を行った(3章にて詳述)。

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⁷⁾ および予測対象

本研究では機械学習の中でも、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、推論）により予測値が得られる。

予測対象は地山等級および、変位量から算出した掘削による地山のひずみ量（以下、掘削時ひずみ）とした。なお、変位量をひずみに変換するのは、掘削径の影響を排除したり先行変位率を考慮した全ひずみの概念を導入したりするためである。

図-2に地山等級と掘削ひずみの予測結果の活用方法の一例を示す。切羽前方地山の地山等級を予測することができれば、事前に支保パターンの変更を判断する助けとなる。また、掘削時ひずみを予測することができれば、逆解析から切羽前方地山の物性値を予測したり、例えば限界ひずみから得られる管理基準値の超過を事前に予測

したりすることも可能となる。これにより、補助工法、特に天端ひずみ（3章で詳述）の場合は天端崩落対策工の導入を検討することもできる。

3. 切羽前方探査および各種計測データ

本研究における検討の対象としたトンネル（図-3）は、延長約4000mで、砂岩、粘板岩、チャート等の地質で構成されており、実施地山等級はC I, C II, D Iである。当現場では概ね全線に渡り、1章で述べた水圧ハンマによる切羽前方探査が実施されている。これまでの削孔データから得られた実績値を基に設定したエネルギー指標値の閾値を表-1に示す。ただし、エネルギー指標値は地山の硬軟を捉えているものの、地山等級の決定にはその他の要因も加味されるため、過去の実績では、エネル

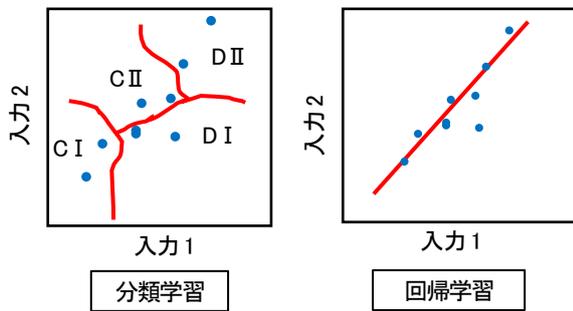


図-1 分類学習と回帰学習

表-1 地山等級とエネルギー指標値（実績値）

エネルギー指標値	地山等級
4.5以上	B
4.2~4.5	C I
2.5~4.2	C II
1.25~2.5	D I
1.25以下	D II

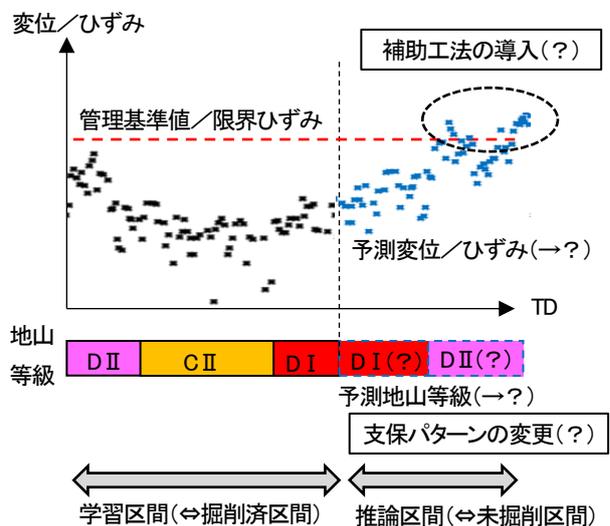


図-2 推論結果の活用方法の一例

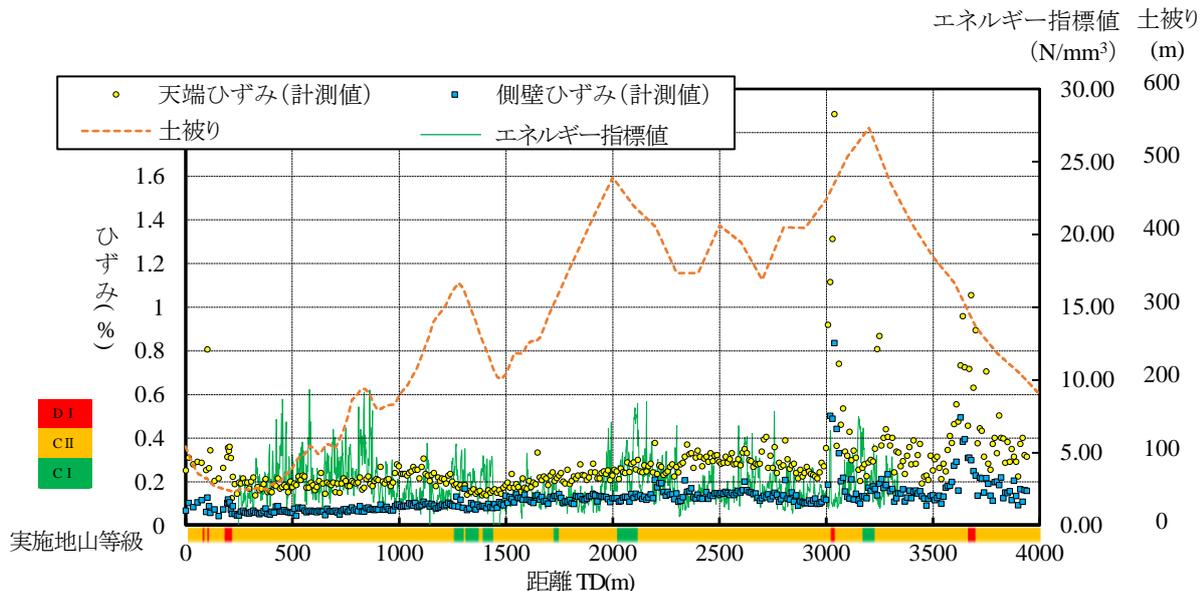


図-3 トンネルの各種計測データ、土被りおよび実施地山等級

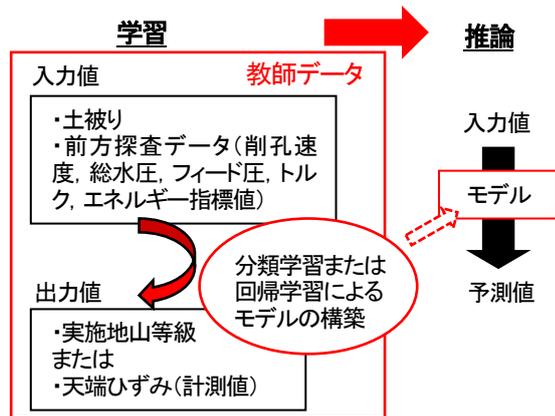


図-4 学習から推論に至る過程

ギー指標値のみによる適合率は5割程度である。

対象となるトンネルの掘削時ひずみ，エネルギー指標値，土被りおよび実施地山等級は図-3の通りである。

側壁ひずみ，天端ひずみについては，掘削が完了している区間で概ね10m間隔で実施されたA計測の実施断面において，それぞれ内空変位を掘削直径で除したものを，天端の最終沈下量を上半の掘削半径で除したものを，先行変位率30%を見込んで算出している。

なお，表-1に示すエネルギー指標値と地山等級の実績値のみをもとに前方探査実施区間の地山等級を評価したところ，適合率は約30%であった。

4. 手法

(1) 入力データ

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，土被りおよび前方探査時に得られる，削孔速度，総水圧，フィード圧，トルク，エネルギー指標値を用いている。エネルギー指標値については20mごとに移動平均した値を用いている。

(2) 地山等級の予測

出力値である地山等級は数値情報を持たないカテゴリデータとして扱い，分類学習により予測モデルを作成した。仮に，前方探査を実施している区間のうち，はじめの約3分の2である距離（以下，TD）200mから2600mを学習区間，それ以降のTD 2601mから3400mを推論区間として設定した。これにより，前方探査を実施した範囲内で学習区間と推論区間を設定することにより，学習区間における分類学習で構築された予測モデルの精度の検証が可能となる。

学習段階で用いた分類学習手法は，決定木，判別分類，ロジスティック回帰分類，サポートベクターマシン（以下，SVM），最近傍分類（以下，KNN），アンサ

ンプル分類である。なお，分類学習による適合率は5分割の交差検定により算出している。ここで，5分割の交差検定とは，教師データを5つの集合に分割し，そのうちの4つで分類学習を行う。そこで得られたモデルを残りの1つの集合に適用し，適合率を検証する手法である。これを5分割の場合には分類学習を行う4つの集合の選択を5種類変えて試行し，それぞれの適合率を平均化する。

分類学習により構築されたモデルを推論区間の入力値に適用することで，地山等級の予測値が得られる。なお，推論についても既掘削区間で試行されているため，同区間の実際の地山等級との適合率が得られる。

(3) 掘削時の天端ひずみの予測

ひずみの予測については，学習区間と推論区間の組み合わせを2通り設定した。前方探査実施区間のうち，1つ目が，地山等級と同様に，TD 200mから2600mを学習区間に，TD 2601mから3400mを推論の対象とするものであり，2つ目はTD 1400mから3400mを学習区間，TD 200mから1399mを推論区間とするものである。以下では，前者を「パターンA」，後者を「パターンB」と呼ぶ。

出力値である天端ひずみは連続変数である数値データとして扱い，学習区間の教師データを用いて回帰学習により予測モデルを作成した。回帰学習においては，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一般的に言われている，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。回帰学習で得られた予測モデルを推論区間の入力値に適用し，予測値を得る。

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，推論区間における標本数 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（1）より求められる。

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

RMSEは予測値と実際の計測値とのひずみ誤差を意味し，次元は天端ひずみと同じである。

以上述べた，入力データの選択から教師データの学習，推論に至る一連の過程を図-4に示す。

4. 結果および考察

(1) 地山等級の予測

地山等級の予測に際し，分類手法ごとの学習段階および推論段階における適合率は図-5の通りとなった。

学習段階での適合率は85%から99%の範囲にあるのに対し，推論段階での適合率は60%から90%程度であり，

推論段階のほうが、適合率が低くなっている。これは、機械学習により、学習区間における入力値と出力値との間に良好な相関関係を見出すことができた場合でも、これを推論区間に適用すると、出力値が正解から大きく外れることを示唆している。これは過学習と呼ばれる現象で、機械学習によるモデル化の課題の1つである。

図-5には、推論区間における実際の地山等級のうちC IおよびC IIそれぞれの実際の地山等級別の適合率（以下、等級別適合率）の平均値も併せて示してある。なお、D Iパターンについては、図-3の通り学習区間であるTD 200mからTD 2600mのうち、D Iパターンの実施区間が前方探査区間外で、分類学習における出力値として用いられていないため、入力値とD Iパターンとの相関関係を学習することはできない。そのため、推論段階で出力される可能性が無く、等級別適合率の平均値を算出するには除外している。

ここで表-2に、SVMを用いた場合の予測結果を、表-3に、アンサンブル分類を用いた予測結果を示す。SVMを用いた場合では、推論段階での適合率が90.0%と、分類学習手法別で最も高い。ただし、推論段階では、すべての入力値に対してC IIを出力値としており、推論において入力値からC Iパターンを予測することはできなかった。一方、アンサンブル分類を用いた場合では、適合率は63.2%とSVMを用いた場合よりも低いものの、等級別適合率（C I：85.5%、C II：67.6%）の平均値は76.5%と、相対的に高い結果となった。

これは、推論段階における全体の適合率が高い場合でも、実際の地山等級別の適合率が低く、標本数の少ない出力値（この場合ではC I）を適切に予測できていない場合があることを意味する。検討対象のトンネルでは、

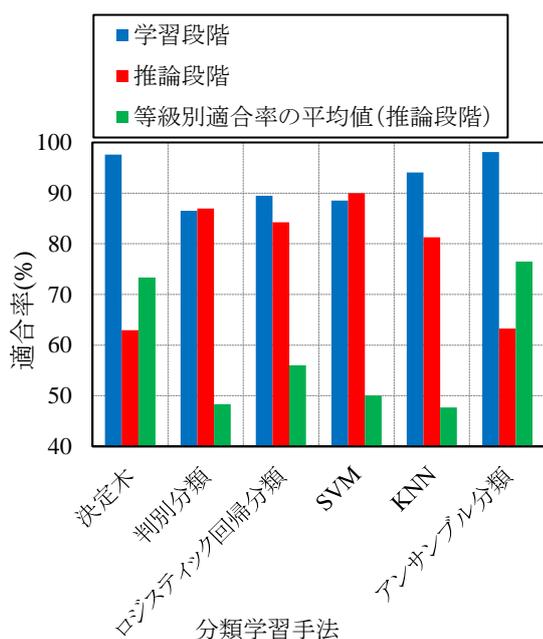


図-5 地山等級予測の適合率

学習区間、推論区間とも約9割がC IIパターンにより掘削が行われており、入力値に対してC IIを出力しやすいモデルが構築されてしまった可能性がある。このように予測モデルの精度を評価する際には、全体の適合率だけでなく、特に地山等級の分布に偏りがある場合には、等級別の適合率も併せて評価の対象とする必要があると考えられる。

(2) 天端ひずみの予測

天端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SVRであった。この学習手法を適用した際の予測値と実際の計測値を図-6と図-7に示す。図-6に示したのは、TD 200mから1400mを学習区間に用いたパターンAにおける、天端ひずみの予測値と計測値である。パターンAにおいては、当現場の管理レベルIIIに該当する限界ひずみ0.5%以上の天端ひずみを適切に予測できていないことがわかる。これは、図-3のとおり学習区間であるTD 200mから1400mの間にひずみレベルで0.5%を超える天端ひずみが計測値として存在せず、これよりも大きな天端ひずみと入力値との相関関係を見つけることはできなかったためだと考えられる。

一方、図-7に示す、TD 1400mから3400mを学習区間としたパターンBにおける予測値と計測値の関係に着目すると、推論区間に局所的にひずみレベルの高い計測値は存在しないものの、パターンAでのRMSE 0.29%に対し、パターンBではRMSE 0.039%と、後者のほうが予測誤差が小さく、より正確にひずみを予測できていることがわかる。

これは、パターンAでは、学習区間の天端ひずみレベルが推論区間に比べ小さい一方、パターンBについては、

表-2 地山等級の予測結果（適合率最大、SVMを使用）

		予測された地山等級			等級別適合率 (%)
		C I	C II	D I	
実際の地山等級	C I	0	55	0	0
	C II	0	663	0	100
	D I	0	19	0	
平均値					50.0

表-3 地山等級の予測結果（等級別適合率の平均値最大、アンサンブル分類を使用）

		予測された地山等級			等級別適合率 (%)
		C I	C II	D I	
実際の地山等級	C I	47	8	0	85.5
	C II	215	448	0	67.6
	D I	13	6	0	
平均値					76.5

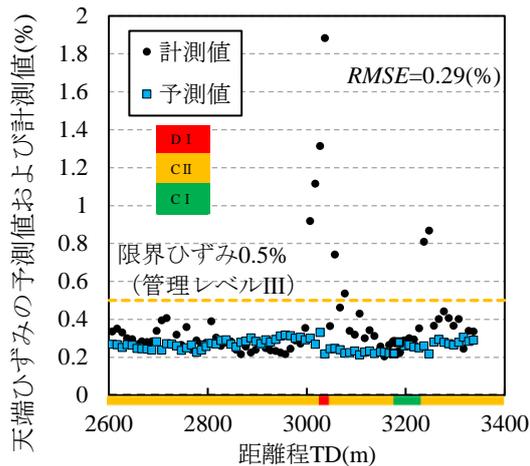


図-6 天端ひずみの予測結果 (パターン A, SVR を使用)

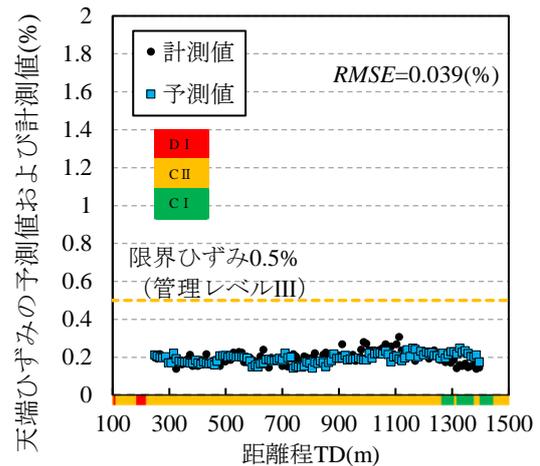


図-7 天端ひずみの予測結果 (パターン B, SVR を使用)

学習区間であるTD 1400mから3400mにおけるひずみレベルが0.10%から1.9%程度の範囲にあり、推論区間であるTD 200mから1399mにおける計測値のひずみレベルの範囲を包含しているためだと考えられる。

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地山等級および天端ひずみの予測モデルを作成し、その予測精度を検証した。

地山等級については、適切な分類学習手法を用いれば、7割以上の確率で予測することができ、前方探査における削孔データから算出されるエネルギー指標値のみによる予測精度よりは改善できたと考えられる。ただ、今回の検討対象区間においては、出力データの9割以上がC IIパターンであり、今後は出力データに偏りのない教師データを用いた機械学習を行う必要がある。

天端ひずみについては、学習区間の出力値のひずみレベルの範囲が、推論区間の計測値に対して小さい場合、適切に予測できない場合があることがわかった。また、本研究においては、ひずみの算出に用いるA計測の変位データが、概ね10mもしくは20m程度に1箇所しか存在せず、機械学習に用いた教師データのサンプル数も240程度であり、今後はデータ数を増やす必要がある。

以上のように、機械学習により教師データから予測モデルを構築する際には分類学習、回帰学習によらず出力値に偏りがなく、かつ出力値に十分な幅を持ったデータを収集して学習する必要がある。今後は、施工条件や地質条件の異なる他現場のデータを蓄積して、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.
- 6) 磐田吾郎, 天野悟, 桑原徹, 木梨秀雄: 高速ノンコア削孔システムによる切羽前方探査技術の開発, 土木学会, トンネル工学報告集第24巻, 2014.
- 7) 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.

(2018. 8. 10 受付)

PREDICTION OF SUPPORT PATTERNS AND STRAIN DURING EXCAVATION AHEAD OF FACE BY APPLICATION OF MACHINE LEARNING

Satoru HAGINO, Hideo KINASHI and Yuichi OKAZAKI

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 support pattern or 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.