

切羽定量評価結果に基づく機械学習による支保パターン選定に関する検討

鹿島建設(株) 正会員 ○戸邊勇人 宮嶋保幸 山下 慧
(株)システム計画研究所 西岡 拳 鶴 英雄

1. はじめに

トンネルの建設で支保パターン選定のために実施される岩判定の省略または省力化を目的として、切羽定量評価結果をリアルタイムに関係者間で共有するシステムを構築し、建設中のトンネル現場で試行した¹⁾。本稿では、切羽定量評価技術による強度、風化度、割れ目間隔の結果を利用し、機械学習によって支保パターンを選定した結果について報告する。なお本稿は、国土交通省公募の「2020 年度建設現場の生産性を飛躍的に向上するための革新的技術の導入・活用に関するプロジェクト」の成果である。

2. 機械学習のモデルの入出力パラメータ

機械学習に利用した入力パラメータを表-1に示す。入力パラメータのうち、破壊エネルギー係数はコンピュータジャンボの穿孔データから取得し、風化と割れ目に関しては切羽写真の画像解析結果²⁾から取得した。機械学習モデルは、これらの入力パラメータの値を解析し、現場で施工管理として行っている切羽観察による切羽評価点を正解として、予測値を出力するモデルを構築した。

3. 適用した機械学習手法

今回の試行では 3 種類の機械学習の手法を利用した。各手法の特徴について以下に示す。

① ニューラルネットワーク (NN)

ニューラルネットワークは教師データ量が豊富な場合、高い精度が期待できる。一方、教師データが少ないと過学習や学習が収束しないといった問題が発生する可能性がある。

② サポートベクターマシン (SVM)

ニューラルネットワークなどと比較して学習時に調整が必要なパラメータの数が少なく、データ量が比較的少量でも学習可能な手法。データ量が少ないうちは、ニューラルネットワークよりも高い精度が期待できる。

③ ツリー系アルゴリズム (GBDT)

ツリー系アルゴリズムの一つである Gradient Boosting Decision Tree (GBDT) を使用した。入力データの前処理 (正規化等) が少なく済み、手軽に評価できるため数値データを入力する判別問題で一般的に良く使用されている。

4. 教師データ

教師データには、切羽観察による切羽評価点を使用した。切羽観察では切羽を天端・左肩・右肩の 3 つの部位に分けて切羽評価点をつけているため 1 切羽あたり 3 データを取得した (41 切羽で 123 データ)。データの分布を図-1 に示す。切羽評価点 1.8 にデータが偏っているため、切羽評価点 1.9 以上は複製してデータを増やした。例えば 1.9 の場合、10 個のデータを 6 つ複製し 70 データとし、1.8 のデータ数 73 と同等にした。

5. 機械学習による切羽評価点の算出結果

機械学習による予測結果を考察するため、41 切羽を対象とした機械学習モデルを使って天端・左肩・右肩

キーワード トンネル, 岩判定, 切羽評価, 機械学習
連絡先 〒182-0036 東京都調布市飛田給 2-19-1 鹿島建設(株)技術研究所 TEL042-489-8109

表-1 入力パラメータ

入力パラメータ	
破壊エネルギー係数	
風化変質度	
割れ目交差密度	
割れ目間隔	平均-中央値
	平均-平均
	平均-標準偏差
	最小-中央値
	最小-平均
	最小-標準偏差
最大-中央値	最大-平均
	最大-標準偏差




図-1 切羽評価点のデータ数

の部位ごとに算出した切羽評価点を切羽ごとに加重平均して、実際の切羽観察の結果と比較して支保パターン選定精度について検討した。具体的には切羽評価点 2.0 以上が D I, 2.0 より小さい場合 C II となり、支保パターンが一致した場合を正解とした。機械学習モデルによる切羽評価点の予測値と切羽観察による切羽評価点の比較例として、図-2 に SVM の場合のトンネル距離程 (TD.) ごとの切羽評価点の推移を示す。D I と C II の境界となる切羽評価点 2.0 に赤線を示した。TD.200m 付近の切羽評価点が低下する傾向や TD.250~300m 付近の切羽評価点が低い分布が概ね整合していることが確認できる。次に機械学習の手法ごとの傾向を比較するため、図-3 に予測と切羽観察の切羽評価点の関係を示した。ここで、2.0 を境界として正答領域 (OK) と誤答領域 (NG) を示した。ここで評価精度を算出すると NN が 61%, SVM が 71%, GBDT が 15% となった。今回検討した範囲では、地質状況のコントラストが小さいため表-1 に示した入力パラメータの評価精度が十分に得られなかったことや、図-1 に示したようにデータに偏りがあったため十分な精度を得ることができなかったが、今回の試行の中で、機械学習の手法ごとに以下の特徴を確認できた。

- ・ 今回の試行では、SVM が最も評価精度が高い結果となった。これは、NN に比べて SVM が少量のデータであっても高い精度が得られるという手法の特徴を示していると考えられる。
- ・ 今回の試行では、GBDT では入力パラメータ（地質定量評価結果）に限らず、出力される予測値がほぼ一定の値を示した（図-3）。これは、データ数の少なさと地質的なコントラストが小さいことが原因であることが考えられる。

6. おわりに

機械学習を利用した切羽評価点の算出について検討し、機械学習の手法によって特徴があることが確認できた。今後、継続したデータ蓄積と切羽定量評価技術と機械学習モデルの精度改善を図り、実用化に向けて取り組む所存である。実用化に向けては、データ数や地質的なコントラストを考慮して適切な機械学習手法の選定を図りたい。




図-2 切羽評価点の算出結果 (SVM の例)




図-3 切羽評価点の正解値（切羽観察）と機械学習モデルによる予測値

参考文献

- 1) 宮嶋ほか：切羽のデジタルデータを活用した切羽評価帳票の自動作成システムの開発，土木学会第 76 回年次学術講演会，VI部門，2021。（投稿中）
- 2) 工藤ほか：画像解析によるトンネル切羽の割れ目間隔の自動解析手法と現場への適用，土木学会第 76 回年次学術講演会，III部門，2021。（投稿中）