

## 山岳トンネルにおける AI を用いたトンネル変位量予測の検討

大成建設株式会社 正会員 ○中田 祐輔, 市田 雄行, 大塚 勇

### 1. 背景

山岳トンネル工事における坑内変位量の予測には、従来はおもに二次元、三次元の FEM 解析が用いられているが、解析に要する時間・手間や、地山性状の不確実性による予測精度のばらつき等に課題がある。一方、山岳トンネル工事で記録される切羽観察簿には、切羽の安定性や地山の風化程度などの評価が記録されている。切羽観察簿の評価結果に加えて、土被りや支保パターン等の施工実績とともに坑内変位計測結果を AI に学習させ、切羽観察断面における変位量を予測させることができれば、地山の状態をリアルタイムに反映した変位量予測を行い、それに基づく施工管理を行うことができる可能性がある。そこで本検討では、AI を活用した変位量予測の可能性を検討する。

### 2. 検討概要

本検討では、AISing 社の開発した AI モデル「MST」を用いる。MST は木構造をベースとした AI アルゴリズムであり、軽量・高精度で追加学習を行うことが可能である。

AI モデルに与える説明変数および目的変数を表 1 に示す。AI モデルの学習用データとしては説明変数および目的変数のセットを用い、検証用データについては AI モデルに説明変数を与えて目的変数である変位量を予測させ、予測値と実測値の間の RMSE (平均二乗偏差) をとることで精度検証を行う。なお、観察簿の評価には「切羽の安定性」、「圧縮強度」、「割れ目の状態」などの 10 項目があり、それぞれ 1 を最小値、4~6 を最大値とした評価区分が記録されている。

本検討には、近傍の 3 つの現場 (①~③) における計測・観察データを用いる。それぞれの現場で用いたデータの数を表 2 に示し、全現場の計測変位量の頻度分布を図 1 に示す。

AI の学習方法としては、

- I: 予測地点以外のすべてのデータを学習し交差検証
- II: 予測現場以外の 2 現場のデータのみ学習し交差検証
- III: II に加え、予測現場のデータを順次追加学習

の 3 通りで検討を行う。

表 1 説明変数および目的変数

説明変数	目的変数
<ul style="list-style-type: none"> <li>・観察簿の評価 (A~J)</li> <li>・支保剛性</li> <li>・土被り</li> <li>・掘削径</li> </ul>	<ul style="list-style-type: none"> <li>・最終変位量</li> </ul>

※支保剛性は支保パターンに基づいて算出

表 2 データ数

現場	①	②	③
計測断面数	124	43	44




図 1 計測変位量分布

学習方法 I	学習方法 II	学習方法 III
各地点について、その地点以外全てを学習させ交差検証	各地点について、他現場の点のみを学習させ交差検証	各地点について他現場の点のみを学習させた状態から、順次追加学習
現場 1: 学習 (予測・検証)	現場 1: 学習 (予測・検証)	現場 1: 追加学習 (予測・検証)
現場 2: 学習	現場 2: 学習	現場 2: 初期学習
現場 3: 学習	現場 3: 学習	現場 3: 初期学習

図 2 学習方法ケース

キーワード 山岳トンネル 坑内変位 AI 切羽観察簿

連絡先 〒163-0606 東京都新宿区西新宿 大成建設株式会社 土木設計部 TEL 03-5381-5296

また、データの特徴を分析するため、全現場のデータを学習させた AI モデルにて、説明変数ごとの重要度解析を行った。

### 3. 検討結果

3 現場すべてのデータについて、学習方法 I～III を用いて検証を行った結果を図 3～5 に示す。縦軸が AI による予測値、横軸が実測値を表し、45 度の線上の点は 100% の予測精度であることを示す。学習方法 I を用いた場合 RMSE は 9.75mm であり、グラフから、全体として予測値が実測値の傾向を捉えられていることが分かる。一方で、個々のデータによっては予測値が実測値の 0.5 倍や 3 倍程度となっている点もあることが確認できる。

学習方法 II を用いた場合 RMSE は 17.25mm となり、グラフから、特に計測変位量の大きい範囲で予測値が実測値の傾向を捉えられていないことが分かる。この原因として、図 1 に示したように学習データの中に変位量の大きいデータが少ないため、該当範囲のデータの学習が AI モデルに有効に反映されていないことが考えられる。

学習方法 II で生成されたモデルに基づく形で、予測現場におけるデータを順次追加学習させて検証を行った学習方法 III では、RMSE は 11.01mm となっており、学習方法 I には及ばないものの精度が大幅に向上していることが分かる。他現場のデータを初期学習させたうえで施工実績を追加学習していくという、実際の現場でも適用可能な方法で、変位量の傾向を捉えられることを示すことができた。

重要度解析の結果を図 6 に示す。今回検討に用いたデータでは、「圧縮強度 (観察簿 C)」「土被り」「割れ目の状態 (観察簿 G)」「掘削径」「支保剛性」の順に変位量予測における重要度が高いことが分かった。

### 4. 考察

AI モデルの精度検証から、学習方法を適切に選択すれば実測値の傾向を捉えた予測を行えることが確認された。また、重要度解析の結果から、観察簿データの一部は変位量を予測する上で重要な要因となり得ることが分かった。

他現場の初期学習を行って当該現場で追加学習する学習方法の予測精度は、初期学習時のデータ数や現場数を増やすことで向上する可能性があり、今後さらなる検討が必要である。

また今回検討した以外の説明変数として、初期変位速度や先進ボーリングの結果などを追加することで予測精度を向上できる可能性があり、引き続き効果的な説明変数の検討が必要である。

今後の実用上の課題として、変位量予測をどのように施工管理に用いるかという目的の明確化がある。図 3 に示したように予測値と実測値には倍スケールの誤差が生じ得るため、正確な値として変位量を予測するのは困難である可能性がある。これに対し、「ある一定以上の変位が生じるかどうか」という分類問題とすることで精度を向上させることも考えられる。予測精度を実用上の目的に応じて設定する方法も、今後検討する必要がある。




図 3 予測結果 (学習方法 I)

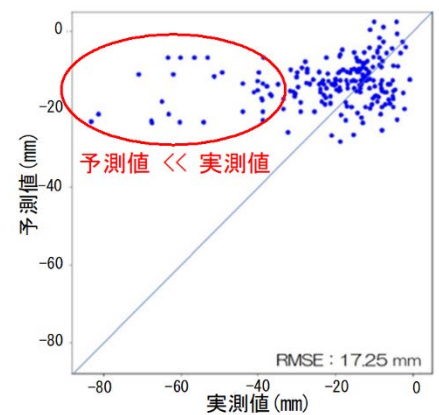


図 4 予測結果 (学習方法 II)




図 5 予測結果 (学習方法 III)




図 6 重要度解析結果