

未調査岩盤地盤の特性予測に対するクリギングと機械学習の比較

東北工業大学 学生会員 ○山内拓磨
 正会員 権 永哲
 学生会員 藤澤巧大
 非会員 大友駿哉

1. はじめに

土木構造物の設計・施工における地盤調査は必要不可欠である。現在、地盤調査・評価方法としてボーリング調査を行い統計学などの処理に基づいたクリギング法などを用いて未調査領域の予測を試みている。しかし、大半の工事現場ではボーリング調査を行う数が限られている。その理由として、ボーリング調査の調査範囲が狭く、時間や費用が掛かることが挙げられる¹⁾。調査範囲が狭い為、調査が行われない「未調査領域」が存在してしまう。

また、地盤の評価方法とされるクリギング法は距離による影響を強く受けるため、距離が離れてしまうと影響力を受けにくくなるといった問題もある。

そこで、本研究ではボーリング調査に加えて広範囲での調査が可能な物理探査データを使用し機械学習によって未調査領域の予測を行う。また、機械学習による予測とクリギング法による予測結果を比較する。

2. 機械学習について

機械学習 (Machine Learning) は人工知能 (Artificial Intelligence) 分野の 1 つである。機械が事例や経験から自動的にデータを学習し、パターンや法則から予測することができる。図 1 に示すように、機械学習は「教師なし学習」と「教師あり学習」の 2 種類が存在する。「教師あり学習」は学習データに正解を付けたものを学習させ、データを予測させる方法である。

本研究では、「教師あり学習」に分類される回帰を使用する。回帰は連続値を使用し、ある数値から別の数値を予測することが可能である。地盤評価を行うにあたってより細かな数値が必要になるため、統計的に根拠のある予測が可能なることから回帰を用いる。




図 1 機械学習の分類

3. クリギング法について

クリギング法は地球統計学に分類され、空間内挿推定

の一手法である。図 2 は空間内挿推定の一例であり、データ間の値を補間するという意味である。異なる位置で得られたデータをもとに、統計学の観点から観測されていない位置における値を推定することが可能である。




図 2 空間内挿推定アプローチ

空間内挿推定には、クリギング以外にも逆距離荷重法といわれる IDW (Inverse Distance Weighted) 法がある。対象地点の近くに存在する別の地点のデータ値の平均を取ることで、対象地点のデータ値を予測する。平均を取る際はデータ値を持つ地点までの距離の逆数を重みとした加重平均で求める。

$$Z(s_0)_{idw} = \frac{\sum_{i=1}^p \frac{Z(s_i)}{d_i^a}}{\sum_{i=1}^p \frac{1}{d_i^a}} \quad (1)$$

クリギングは距離に重点を置いた考え方であり、近い位置のデータほど値が近くなりやすいという統計的な傾向、すなわち空間的相関を有するといった仮定のもと行われる。周囲の計測値を加重して対象地点の予測を行う。

$$\hat{Z}(s_0) = \sum_{i=1}^n e_i Z(s_i) \quad (2)$$

加重は計測ポイントから予測地点までの距離だけでなく、計測ポイントの全体的な空間配置によっても決まる²⁾。

4. RMR・Q 値の予測および結果分析

本研究ではボーリング調査と物理探査の 2 つの結果から互いのデータが存在する地点を学習させ、未調査領域を物理探査のみで定量的なデータの推測を行いたい。そのためボーリング調査と物理探査の関連性に着目し機械学習の 1 つである「Window-shifting 学習法」を用いた。

図 3 に示すようにボーリング調査と物理探査のデータが存在する R5 を中心とした 3×3 のデータをワンセットとして学習させた。トレーニングデータはボーリング調査が行われている範囲のみで 1 つ 1 つ学習を行う。テスト

データは、物理探査のみの地点とする。

ボーリング調査と物理探査の相関関係を学習させることで、物理探査のみの地点でも地盤特性予測が可能となる。物理探査には電気探査による電気比抵抗値を用いる。




図 3 Window-shifting 学習法の概要

クリギング法及び機械学習にて RMR と Q 値の予測を行うにあたり、図4はボーリング調査と物理探査のデータを等高線図に表したものである。ボーリング調査は7箇所で行われ計 98 個のデータが存在する。ボーリング調査が行われていない2450 箇所(未調査領域)の RMR と Q 値をそれぞれ予測した。未調査領域の予測には電気探査による電気比抵抗値を用いる。




図 4 地山の地盤状態

図5と図6はクリギング法による RMR と Q 値予測の結果を等高線図に表したものである。図7と図8は機械学習による予測結果である。機械学習による RMR 予測は、クリギング法に比べより細かく定量的にデータ収集することができた。

機械学習による RMR では距離 500~750m, 標高 15~50m 時の値が電気比抵抗値と少しずれてしまった。原因として一部地盤内に高い値が集中してしまい、かつその付近にボーリング調査がされていない。そのため学習を行う中で高い値を取ることができずこのような結果に至ったと考える。実際設計・施工に使用される値としたとき評価分類としては 1 段階下がるものの大きな誤差とはならないため適切な予測ができたと考える。

Q 値は分布が RMR 同様に細かく見られるものの値は全般的に低く出てしまった。考えられる理由として、Q 値データ幅の分布が大きかったため十分に予測ができなかったと考えられる。




図 5 クリギング法による RMR 予測




図 6 クリギング法による Q 値予測




図 7 機械学習による RMR 予測




図 8 機械学習による Q 値予測

5. まとめ

機械学習を用いた未調査領域の RMR・Q 値予測では、Window-shifting 学習法を使用しボーリング調査データと物理探査データを学習させ、物理探査データのみでクリギング法よりもより細かく定量的なデータを導くことができた。機械学習はクリギング法に比べ様々なプロセスを踏み予測へと進む、そのため学習段階で信頼性の高いデータが不可欠であり、データ整理・検討が重要であると考えられる。当然ではあるが、クリギング法は距離の影響を強く受けてしまうためボーリング調査間の距離が離れてしまうと得られるデータは一定となる。ポイントごとの定量的なデータの収集は可能なものの機械学習ほどの細かなデータの分布は見ることができない。

参考文献

- 1) 地盤工学会地盤調査法改訂編集委員化(編)：地盤調査の方法と解説, pp.139-141, 2004.
- 2) 坂田義隆(著)：クリギング入門—空間データ推定の確率論的アプローチ, p.6, pp.14-17, p.65, 2021.