

マシンラーニング手法による広域地盤設計定数の予測

東北工業大学 学生会員 ○高橋 那知

東北工業大学 非会員 吉原 太智

東北工業大学 正会員 権 永哲

1. はじめに

本研究は土木構造物の施工・設計の際、ボーリング調査が行われない「未調査区間」の地盤に対して、合理的な方法で地盤の定数評価が行えないかという疑問に端を発した。ここでは、ボーリング調査（直接法）と物理探査（間接法）の2種類の地盤調査法を用いて研究を行った。ボーリング調査は穴を掘り直接地盤の状態・特性を調査することができる。しかし、費用や時間がかかり、広範囲での調査を行うことができない。そのため工事現場の大半は「未調査区間」である。また一部のボーリング調査の結果は工事現場全域のデータとして使われている。一方、物理探査は広範囲での調査が可能であるが定量的なデータを収集できないため施工・設計に適用することは難しい。この2つの地盤調査法の相関関係を導くために機械学習を用いた。

本研究では定量的なデータの収集が可能な直接法と広範囲での調査が可能な間接法の相関関係を機械学習手法を用いて学習させる。最終的に間接法のみで学習させた相関関係から「未調査区間」の定量的なデータの予測、つまり広域地盤設計の予測を目的としている。

2. RMR の予測

本研究ではボーリング調査と物理探査の結果が互いの存在する地点を学習させ、物理探査のみで定量的なデータをする推測するため「Window-shifting 学習法」が用いられる。ボーリング調査と物理探査の関連性に着目した。図1にあるように、ボーリング調査と物理探査の結果がともに存在する R_5 の地点を中心とした 3×3 の物理探査結果をワンセットとして学習させた。トレーニングデータとしてボーリング調査部分を上下に移動して深さ分のデータの学習を行う。テストデータは、物理探査結果のみの地点を上下左右に移動させ予測を行った。ボーリング調査結果とその周りの物理

探査結果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設計定数の予測が可能となる。物理探査の結果には電気探査による電気比抵抗値、ボーリング調査の結果には RMR が用いられた。




図1 Window-shifting 学習

RMR とは岩盤分類法の一手法である。岩盤分類パラメータと5つの要素（一軸圧縮強度、RQD、不連続面の間隙、不連続面の状態、地下水の状態）に与えられる評点の合計で求められる²⁾。良好な場合は100点に近くなり不良の場合は点数が小さくなっていく。この岩盤の評点を多項分類に用いることで①…0~10, ②…20~40, ③…40~60, ④…60~80, ⑤…80~100 に分類した。多項分類は機械学習の学習アルゴリズムの1つで、3種類以上のグループに分類することが可能である。そのため本研究では3種類以上分類するため多項分類を使用した³⁾。

本研究では2か所のトンネル工事の現場を往復して得られた4つの岩盤データを使用した。Window-shifting 学習法は岩盤から粘土までの地盤に適用可能である。今回は、土の地盤に比べて異方性が低く予測がしやすい岩盤での予測を行った。また、予測結果の評価方法は正解値と予測値の面積の比率から求めた。理由として、本研究はただ当たっているかを見るのではなく予測の精度を高めるためである。よって、我々は正解率と区別するために正確さという呼び方にした。

3. 結果分析

本研究は進めていくうえで機械学習による RMR の正確さを高めていくために行ったことは表 1 の示したように大きく分けて 5 項目存在する。

表 1 正確さを高めるうえで行ったことと予測結果

正確さを高めるうえで行ったこと	正確さ
① トレーニングデータ数を揃える	0.44
② 極端なデータの削除	0.48
③ トレーニングデータ数を揃える データ数を全体的に増やす 分類①を水増し	0.80
④ 分類に応じたデータの指定 テストデータ数の変更	0.86
⑤ 各分類の数値確認 分類①, ②の水増し	0.84

①はトレーニングデータを揃えることから取り組んだ。所持しているデータは各分類に分けるとデータ数が均等ではなかった。そのためトレーニングデータを揃えるために、アンダーサンプリングを行った。5つの分類の中で最もデータ数の少ない分類①に合わせることで均等にした。正確さは 0.44 と 5 割を下回った。②では①の正確さが低い原因となった分類①と④のデータを見直すことにした。分類①と④の数値で極端に似ているデータを削除することで明確に区別することを目的としている。正確さは 0.48 と少し上がったものの 5 割を下回った。そのことから③ではトレーニングデータ数を増やして学習させた。データ数を 2 倍程度にすることで学習量も増やせるのではないかと考えた。データの水増し方法は 2 つの同じ分類のデータからそれぞれの地点の地盤調査結果の平均と求めることで新しいデータを作り出した。その結果、正確さは 0.80 と精度の高い予測を行うことができた。次の④では初めからデータの整理を行った。各分類の値に応じない極端なデータを削除した。また分類③のトレーニングデータでアンダーサンプリングにより削除していたデータをテストデータに加えて予測を行った。機械学習の予測においてテストデータ数の増減が正確さへ影響を及ぼすのかを判断するためである。結果正確さは 0.86 と少し上がった。このことからテストデータの増減により正確さへ大きな影響を及ぼすことは少ない

のではないかと考えた。最後の⑤は④で行われてきた方法に加え、分類①, ②のデータ数が少ないことから水増しした。正確さは 0.84 となった。最終的に、表 1 にも書いてあるように 8 割程度の正確さで安定して予測することが可能になった。各分類にそぐわないデータを削除することと全体的にデータ数を増やしたことで精度の高い予測ができたのではないかと考えた。

今回は異方性の低い岩盤で予測を行った。そのため精度の高い結果を得ることができた。今後は異方性の高い土の地盤での予測を行った際、同じように精度の高い結果を得られるかが問題になってくるであろう。また、今回行った水増しの方法は 2 つのデータの平均値から新たにデータを増やしたものである。そのため今後、オーバーサンプリングをする際はプログラミングを使用して信頼度の高い方法を検討してほしい。

4. まとめ

機械学習を用いた広域地盤設計定数の予測はボーリング調査と物理探査の相関関係を学習させ、物理探査のみで未調査区間の定量的なデータを導くことに対して精度の高い結果を得ることができた。また高い精度を得るためには信頼性の高いデータが不可欠であると考え。データ数や分類の分け方などデータ収集の段階が一番重要である。データ整理の段階で極端なデータを取り除き、各分類のデータの範囲を決めることやデータの水増しが精度に影響を及ぼすことが確認できた。これらの要素を踏まえて機械学習を行った本研究ではボーリング調査と物理探査の相関関係から定量的なデータが推測できたと考えられるであろう。

参考文献

- 1) 社団法人地盤工学会：地盤調査の方法と解説，pp.79-170，2004.
- 2) 岩盤分類の歴史と現況－土木学会
<https://www.jsce.or.jp/committee/tun/chapter2.pdf>
2021 年 12 月 20 日アクセス
- 3) ニューラルネットワークの基礎
https://tutorials.chainer.org/ja/13_Basics_of_Neural_Networks.html 2021 年 12 月 21 日アクセス