

機械学習による未調査区間の地盤特性予測

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

1. はじめに

建設工事における、設計・施工の地盤調査は必要不可欠である。現在、ボーリング調査と物理探査などによって地盤調査が行われているがボーリング調査がなされていない未調査区間に対しては物理探査を行い、地盤調査をする。上記に挙げたボーリング調査、物理探査には問題点がある。ボーリング調査の問題点は費用が高く、工期も長い。局所的な調査しかできないことである。物理探査の問題点は定量的なデータの取得が難しく、地盤の強弱のデータしか測定することができないため、設計にそのまま生かすことは難しい。そこで、本研究では未調査区間に対してボーリング調査と物理探査で得られたデータを用い、機械学習によって岩盤地盤情報の予測を行う。この方法が確立されれば、地盤調査の費用、時間を削減しながら広範囲の定量的なデータを得ることができる。それによって、ボーリング調査と物理探査を補完でき、地盤情報の予測を高い精度で行うことができるかを検討する。

2. 機械学習

先述したように、物理探査で求められる電気比抵抗は電気的強弱を表すもので電気比抵抗の値が高いほど、丈夫な岩盤とされている。

Q 値(rock mass quality)は Barton(1974)が提唱した岩盤分類法であり、1000(割れ目のほとんどない硬い岩盤)～0.001(きわめて軟弱な膨張性の岩盤)となっている。これを受けて Bieniawski(1978)は RMR(rock mass rating)法を提唱した。これは一軸圧縮強度、RQD、不連続面の間隔、不連続面の状態、地下水条件の5つの要素を点数化し、評点の合計で岩盤分類を行うというものである。¹⁾

Q 値では 0.001～200 までの数値がデータの中に見られた。RMR より大きい数値の差があるため、Q 値での分類は行わなかった。電気比抵抗では Re1～Re9 の平均を取って分類を試みたが、Windows-shifting を行う際に3つずつデータがずれ込み、同じ値を使うということがあったため、分類という点においては不向きであると考えた。本研究においては均等な学習データとテストデータを作成するため、RMR での分類を行った。すべてのデータが均等になるように分類を行ったところ、RMR が 0～50, 51～60, 61～65, 66～72, 73～77, 78～81, 82～87 の7分類に分けた。

より良い学習を行い、正解に近い予測を出すにはデータそのものを加工することもある。その例として正規化、標準化が挙げられる。電気比抵抗の値が 0～10476 と差が開いているので、これを解消するために正規化、標準化を行う。正規化は最

大値を 1、最小値を 0 にする変換方式であり、観測値の最大値、最小値が明確な時に有効である。ただ、大きい外れ値に敏感なため大きい外れ値が存在する場合は標準化を用いるケースが多い。標準化は平均を 0、標準偏差を 1 に収める変換方式である。正規化とは違い決まった範囲に値を収めるようなものではない。最大値や最小値が不明であるデータに有効である。

学習のためのパラメータ決定には Generalized Data Analyzer and Predictor (以下 GDAP)を使用した。これは機械学習の中の回帰を行うためのソフトである。自分が定めた学習データを入力することで機械が学習を行い、回帰によって未知の値を出力することができる。GDAP には様々なパラメータやアルゴリズムが存在し、予測に影響を与える。その中でも特に予測値に影響を与える学習率、中間層(隠れ層)の数、ノード数に着目してパラメータの決定を行った。その他のパラメータは GDAP で解析を行っていくうちに、実測値に予測値が近くなったものを適用した。平均コストの変化及び、実測データとテストデータが近づいているかをみてパラメータの決定を行った。最終的には学習率が 0.001、中間層(隠れ層)の数が 5、ノード数が 20 と決定した。

3. 学習結果

正規化させた時の電気比抵抗の値を 0～0.30 0.31～0.75 0.76～1.00 の3つに分類した。また、電気比抵抗値の青い部分を低位、緑色の部分を中位、赤色の部分を高位とした。相関関係を見やすくするために図1のように、Zone を3つに分けて分析した。距離 0～100・760～1000 を Zone 1、110～445 を Zone2、450～750 を Zone3 とする。

電気比抵抗の分布




図1 電気比抵抗の分布図およびZone分け

RMR と Q 値の相関関係を確かめるために今回、Barton and Bieniawski(2008)³⁾、Chonquet and Hadjigeorgion(1993)⁴⁾ Barton(1995)⁵⁾ が提案した関係式を用いて比較した。

これらの関係式を予測値とともに重ねて示したのが、図2～

図5である。この論文では紙面の関係上 Zone 1 のデータのみを提示するが、全体的な傾向は一致していることを述べておきたい。まず、図2に zone1 の全位データを示す。

ており、曲線状に RMR・Q 値の関係予測が出ている。

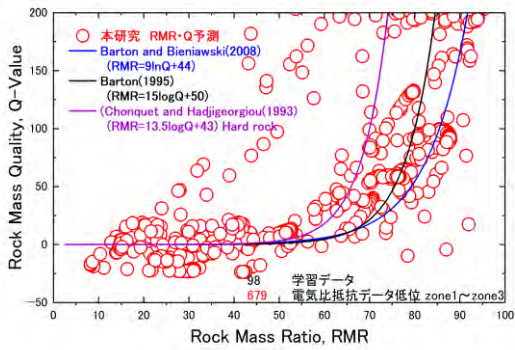


図2 zone1 の電気比抵抗の全体のデータ

Zone 1 の電気比抵抗の低位のデータにおいては、学習データ 98 個、未調査区間の電気比抵抗 272 個を使用した。全体的に分布が散らばっているがその多くは既往研究の関係式の線に近づいた分布となった。

また、今回は電気比抵抗値が低い値を中心にグラフに表したため、RMR・Q 値が低い地点に点が集まり、RMR・Q 値が高い地点の点は関係式から離れる結果となった。




図5 電気比抵抗の高位箇所 (Zone 1)

今回、機械学習を用いて岩盤地盤情報である RMR と Q 値を予測し相関関係を究明した結果として、電気比抵抗値が低位は多少のデータのばらつきはあったが機械学習を用いても相関関係は見られた。また、電気比抵抗値が中位と高位は全体的にデータがまとまり、曲線的にデータが取れ、相関関係も見られた。全体的に相関関係が見られた要因として、データ整理の段階で学習させるデータに着目してパラメータを決定できたからであると考えられる。

4. まとめ

機械学習を用いた岩盤地盤情報は、目標である物理探査とボーリング調査のデータを使用し、未調査区間の RMR・Q 値を用いて相関関係から精度の高い予測を出すことができた。機械学習を用いて予測をする際に、使用するデータに誤りがあると精度の高い予測が得られない、高い精度で予測を行うためには予測を行う前の段階でデータ整理を慎重に行う必要がある。

参考文献

- 1) 土木学会(編)：岩盤力学, pp. 20-25, 1985.
- 2) Abbas, S.M., and Prof. Dr. Konietzky, H. H.: Rock Mass Classification Systems, p.19, p.32, 2017.
- 3) Fresno, D.C., Garcia, J.A., Munoz, F.B. and Carrera, R.D. : Correlation between Bieniawski's RMR and Barton's Q Index in Low-Quality Soils, p.3, 2010.
- 4) Milne, D., Hadjigeorgiou, J. and Pakalnis, R.: Rock Mass Characterization for Underground Hard Rock Mines, Tunnelling and Underground Space Technology, Vol.13, Issue4, pp. 383-391, 1998.
- 5) Barton, N.: The influence of joint properties in modelling jointed rock masses.: A review, 8th Int Rock Mech. Congress, Tokyo, pp.1023-1032, 1994.

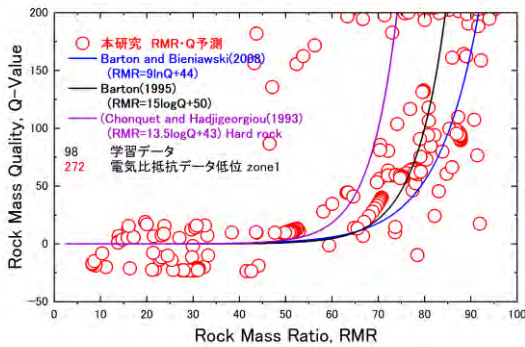


図3 電気比抵抗の低位箇所 (Zone 1)

Zone 1 の電気比抵抗の中位のデータにおいては、学習データ 98 個、未調査区間の電気比抵抗 159 個を使用した。相関グラフは全体的に散らばりがなく関係式の範囲に分布した。また、多くの点を取ることができた場合、曲線状に点が続いていくことが予想される。




図4 電気比抵抗の中位箇所 (Zone 1)

Zone 1 の電気比抵抗の高位のデータにおいては、学習データ 98 個、未調査区間の電気比抵抗 79 個を使用した。電気比抵抗が高位のデータについても全体的にデータが中央に集まっ