

機械学習によるトンネル切羽の岩盤判定と支保パターン決定に関する研究

関西大学大学院 学生員 ○金子元紀
関西大学環境都市工学部 正会員 尹 禮分
関西大学環境都市工学部 フェロー 楠見晴重
(一社)近畿建設協会 西尾彰宣

1. はじめに

NATM 工法によるトンネル建設現場では、「安全性」及び「経済性」を確保した合理的な施工を行うために、切羽面の岩盤評価に基づいた適切な支保パターンの決定が重要になる。現在においては、岩盤評価は熟練した技術者によって、あらかじめ決められた評価項目にしたがって点数付けを行っている。しかし、現在はこの技術者が不足している傾向にある。そのため、技術者不足の解消と合理的トンネル建設を推進する必要がある。

このような背景の中で、熟練した技術者によって判断されているものを、ICT や AI をトンネル建設現場に取り入れることで、人間の判断ではなく標準的な評価手法として確立しようとする動きがある。

そこで本研究では、熟練した技術者によって集積された切羽面における岩盤評価のデータを基に、機械学習を適用する。そして、支保パターンを決定していく手法に関して検討を行う。機械学習の方法としては、サポートベクターマシン (Support Vector Machine; SVM) を用いる。また、集積したデータは国土交通省による岩盤評価項目である。これらの解析結果により、SVM による支保パターン決定の有用性を検証する。

2. サポートベクターマシン (SVM)

SVM¹⁾ は、1990 年代初頭パターン分類問題に対して提案された手法の一つである。学習データに対し、2 値のカテゴリ分類問題を考える。与えられた分類問題は一般には線形分類可能ではないと仮定し、そこで何らかの非線形写像を行い、線形分離可能になるとする。すると、写像先の空間における超平面によって 2 つに分類することができる。このような分離超平面は一般に複数個存在するが、その中でも分離超平面と一番近いデータとの距離ができる限り大きいものが望ましいという考え方が、SVM の特徴である。学習点と超平面の

最小距離をマージンといい、最小距離を与える点及びその原象のことをサポートベクターという。

写像は像空間において線形分離ができる限り可能になるように一般には像空間が高次元になるようにとられる。このとき、目的関数に高次元ベクトルの内積があり計算に負荷がかかる。そこで原空間の距離を像空間の内積として保存するようなカーネル関数を導入する。カーネル関数が正定であれば、このような関係を満たす写像が存在することが知られている。SVM におけるカーネルとしては種々のものが提案されているが、代表的なものとして多項式カーネルおよびガウシアンカーネルがある¹⁾。

本研究ではパターン認識に優れた SVM を用いて、トンネルの支保パターン分類に適用する。

3. 支保パターンおよび評価項目

岩盤判定において切羽を観察する際、国土交通省が設定した基準となる、評価区分判定の目安として統一された表の 9 つの項目²⁾を、それぞれ切羽を右肩、天端、左肩の 3 つに分けて評価し、1~4 点の点数がつけられる。評価項目とその内容について表 1 に示す。

表 1 岩盤評価における評価項目とその内容

評価項目	内容
切羽の状態	切羽における岩塊の状態など
素掘面の状態	素掘面の肌落ちの程度など
圧縮強度	岩石の硬さ
風化変質	風化や変質の程度
割れ目の頻度	割れ目の間隔
割れ目の状態	密着、開口の状態
割れ目の形態	割れ目の性状
湧水	湧水の位置、量
水による劣化	水による岩石の劣化の程度

キーワード 機械学習, SVM, トンネル, 岩盤判定, 支保パターン

連絡先 〒564-8680 吹田市山手町 3-3-35 第 5 実験棟 地盤環境工学研究室 TEL 06-6368-0837

評価点を設定し、切羽から地山の状態を確認した後、地山を支えるために適切な支保構造を設定する。NATM工法による支保パターンにはB、CI、CII、DI、DII、DIIIがある。パターンの違いは、ロックボルトの本数や、鋼製支保工、インバートを加えるかという、支保の強度の違いがある。強度の強さとしては、Dになるほど強い、すなわち岩盤の強度が弱いということである。DIIIは土被りの高さによって設定される。

4. SVMによる支保パターン判定

今回は、表2に示す3カ所のトンネルデータを対象としてSVMによる支保パターン判定を行う。

表2 トンネルデータの詳細

	データ数	トンネル形式	長さ
No.1 トンネル	121 個	二車線 道路 トンネル	398m
No.2 トンネル	117 個		570m
No.3 トンネル	531 個		7.8km

まず、すべての支保パターンに対するデータを用いて判定を行い、図1にSVMによる判定結果を示す。各支保パターンに対するデータのうち、SVMによって正しく判定されたデータ数およびその割合（正判別率）を表し、全体としては約80%の精度が得られた。

支保パターンごとのデータ数に偏りがあり、一番データ数の多いCIIは、91%の正判別率が得られた。しかし、次に多いDIの正判別率は57%と比較的低い。その中では、DIをCIIと誤判別しているものがほとんどである。




図1 SVMによる支保パターンに対する判定結果

次にDIIIは土被りの高さによって設定されるため、DIIIを取り除いた残りの支保パターンに対するデータ

を用いて判定を行う。全体の正判別率は82.9%であり、支保パターンごとの詳細正判別率を図2に示す。




図2 SVMによる支保パターンに対する判定結果 (DIIIを除く)

図1と図2からわかるように、特にCIに対する正判別率に大きな違いが見られる。支保パターンCIに対するデータは9個で少ないことが一つの原因として考えられる。データ数を増やし、支保パターンのデータ数の偏りを解消することで、より安定的な判別が可能になると考えられる。さらに、学習用データとテスト用データを分けて判別を行うことが課題である。

SVMの判別において注目すべき点は、実際採用されているパターンがより強度の強いDであるデータに対してCと判別しているものである。これは、人間の判断により、安全性を考慮した結果少し強い強度の支保パターンに設定しているということは考えられるが、そうでない場合に、この判断は人命にかかわる可能性がある。

5. まとめ

本研究は学習の精度を検証した結果であるが、現時点で80%以上の正判別率を得ることができた。これは、目視など点検者の技術や経験によって結果にばらつきが生じる評価点データに対して高い精度であると言える。したがって、岩盤評価において、機械学習を適用することに有用性はあると結論付ける。

参考文献

- 1) Bernhard Schoelkopf, Alexander J. Smola 他：Learning with Kernels, 2001
- 2) 近畿地方整備局道路部道路工事課：トンネル地山等級判定マニュアル（試行案），2016