

NATM における機械学習による 支保パターン決定に関する研究

金子 元紀^{1*}・榎並 大希²・尹 禮分³・楠見 晴重³・西尾 彰宣⁴

¹ 関西大学大学院理工学研究科 (〒564-8680 大阪府吹田市山手町 3 丁目 3 番 35 号)

² 関西大学環境都市工学部都市システム工学科 (〒564-8680 大阪府吹田市山手町 3 丁目 3 番 35 号)

³ 関西大学環境都市工学部 (〒564-8680 大阪府吹田市山手町 3 丁目 3 番 35 号)

⁴ 一般社団法人近畿建設協会 (〒540-6591 大阪府大阪市中央区大手前 1 丁目 7-31)

*E-mail: k391330@kansai-u.ac.jp

山岳工法 (NATM) によるトンネル建設現場では、トンネルの支保パターン (CI-DIII) を決定するに際して、切羽面の岩盤評価が重要となる。現在その評価は、熟練した技術者があらかじめ決められた評価点項目にしたがって点数付けを行っており、統一かつ標準的な評価法としては確立されていない。そこで、本論文では、岩盤評価に機械学習を導入することの適用性について検証した。いくつかのトンネルデータを使用し、CI-DII の 4 パターンの判別を行い、精度を検証する。この検証において、まずは約 2000 個のデータを学習させ、学習の精度を検証したところ、86%の精度を得ることができた。

Key Words : Support pattern, Machine learning, Expert systems, NATM

1. はじめに

山岳工法 (NATM) におけるトンネルの設計は、岩盤の種類や強度によって地山を分類し (=地山等級区分)、分類した地山に応じて崩壊などを防ぐための支保構造、つまり支保パターンを設定する。トンネル工事の施工にあたっては、切羽の観察および計測により地山等級を判定したうえで、「安全性」を確保しながら「経済性」を考慮した合理的な施工ができるよう、必要に応じて支保パターンの変更を実施し、標準支保パターンによる支保工のみで対処できない場合は適切な補助工法を選定する必要がある¹⁾。

トンネル地山等級の判定は、切羽における岩の硬さや亀裂等を観察し、その結果を点数化して地山を評価するが、その評価基準や様式等について統一されたものではなく、各現場における担当者の経験などに依存して行われてきた。そこで、近畿地方整備局ではトンネル地山等級の判定を客観的かつ統一的に運用するため、平成 18 年にトンネル地山等級判定マニュアル (試行案) をとりまとめ、この案に基づいて現状運用している²⁾。さらに、近年建設現場にも情報化施工が取り入れられ、情報通信技術 (ICT) の利用拡大によって、高効率・高精度な施

工の実現が期待されている³⁾。

しかし、トンネル地山等級判定マニュアルを用いても、評価点を設定した後に支保パターンを決定する際の基準があいまいであり、施工者の技術や経験に頼る面が大きく、その判定にも時間がかかる。

そこで、本研究では山岳トンネルの建設において、熟練した技術者によって行われる支保パターン決定を、機械学習を導入することによって、効率的かつ標準的に評価する評価法の確立を目指す。統計的機械学習の一種であるサポートベクターマシン⁴⁾ (Support Vector Machine, 以下 SVM と略す) を用いて、国土交通省による岩盤評価データに対して支保パターンの分類を行い、その有用性について検証する。

2. 支保パターンおよび切羽面の岩盤評価

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、評価区分判定の目安として統一された 9 つの項目を、それぞれ切羽を右肩、天端、左肩の 3 つに分けて評価し、1 つの切羽に対して計 27 個の項目に 1~4 点の

点数が施工者の判断によって付けられる。その後、定められた計算方法によって、1つの切羽につき1つの点数が求められる。この点数を評価点とする。評価項目と評価内容について表-1に示し、切羽の天端、左肩、右肩の分け方について図-1に示す。

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²⁾。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ため、DIIIを除いた残りの支保パターンは、切羽から地山の状態を確認した後、評価点に基づいて設定される¹⁾。

表-1 評価項目一覧

評価項目	内容
切羽の状態	切羽における岩塊の状態
素掘面の状態	素掘面の肌落ちの程度
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




図-1 天端、左肩、右肩の分け方




図-2 評価点と支保パターンの対応図²⁾

しかし、この支保パターンを決定する際、図-2のような箱ひし図から支保パターンが決定されるが、図からわかるように、例えば評価点が2.2であった場合CI~DIIのすべてに当てはまることとなり、この基準ではあいまいであることが分かる。さらにこの場合、経験のある技術者の判断によって最終の支保パターンが決定されるため、ばらつきがあり時間がかかる。すなわち、結局は技術者の判断で支保パターンが決定されるので、効率化、標準化が難しい状況である。

そこで本研究では、評価点から支保パターンを決定する流れの中に機械学習を取り入れることで、効率化と標準化を目指す。1つの切羽に対して評価点を設定するための27個の点数行列を説明変数とし、実際に施工された支保パターンを従属変数とする。

実施された支保パターンを正解とし、機械学習がどこまで過去の人間の判断に近づくことができるのか精度を確認し、有用性について検証する。

3. サポートベクターマシン (SVM)

サポートベクターマシンは1992年にVapnikらによって提案された手法で、2つのパターン認識問題を解くための手法である。パターン分類問題が線形分離不可能な場合、ある非線形写像によって線形分離可能な高次元空間にマッピングを行うことで、線形分離可能な状態となり、最適な分離超平面を求めることができる(図-3)。

図-4は、SVMにおける各要素の概要を示している。サポートベクターマシンでは、正例と負例からの距離を最大にして真ん中を通る識別関数を解析的に求める。この距離をマージンと呼び、マージン最大化を行いながら識別関数を決める。このとき、マージン領域の端に相当する場所に位置するデータをサポートベクターという。




図-3 データの高次元の特徴空間への写像




図-4 サポートベクターとマージン

SVM には、クラス（パターン）が 2 つであるデータ集合の完全分離を目的とするハードマージン法と、ある程度の誤判別（ノイズ）を許容するソフトマージン法が存在する。本研究では、使用データである評価点のデータは、人間の目視などで決定しているため、必ずしもその判断が正しいとは限らず、そのデータを使用している以上、ある程度の誤差は許容する必要があるため、ソフトマージン法を用いる。

データ集合 A と B を分離する分離超平面 H_0 は、分離超平面の法線ベクトル $\mathbf{w}$ とバイアス項 b を用いて式 (1) のように表すことができる：

$$H_0 : \mathbf{w}^T \mathbf{x} + b = 0 \quad (1)$$

ここで、 $\mathbf{x} \in A \cup B$ は入力データであり、 $y = 1$ or -1 は教師値の出力データである。

SVM ではデータの写像、すなわち $\mathbf{z} = \Phi(\mathbf{x})$ を行い、特徴空間における最適な分離超平面（式 (1)）を求める。ソフトマージン SVM では 2 つのデータ集合 A と B を完全に分離するハードマージン SVM に対し、スラック変数 ξ を導入することにより制約を緩め、判別における許容誤差を考慮することができる：

$$\begin{aligned} & \underset{\mathbf{w}, b, \xi}{\text{minimize}} \quad \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^{\ell} \xi_i \\ & \text{subject to} \quad y_i (\mathbf{w}^T \mathbf{z}_i + b) \geq 1 - \xi_i, i = 1, \dots, \ell \quad (2) \\ & \quad \quad \quad \xi_i \geq 0, i = 1, \dots, \ell \end{aligned}$$

ただし、 C はマージン（目的関数の第 1 項）と許容誤差（目的関数の第 2 項）とのトレードオフ（trade-off）パラメータであり、その値を大きく取れば誤判別の度合いを少なくし、完全分離に近い判別結果となる。本研究では、パラメータ C の値は交差検定（cross-validation）を用いて決定する。

さらに、ソフトマージン SVM（式 (2)）に対するラグランジュ双対問題（式 (3)）を考える⁴⁾：

$$\begin{aligned} & \underset{\alpha}{\text{maximize}} \quad \sum_{i=1}^{\ell} \alpha_i - \frac{1}{2} \sum_{i,j=1}^{\ell} \alpha_i \alpha_j y_i y_j \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j) \\ & \text{subject to} \quad \sum_{i=1}^{\ell} \alpha_i y_i = 0, \\ & \quad \quad \quad 0 \leq \alpha_i \leq C, i = 1, \dots, \ell. \end{aligned} \quad (3)$$

上記定式化（式 (3)）における目的関数の第 2 項で、内積を保存するようなカーネルトリック⁴⁾

$$K(\mathbf{x}_i, \mathbf{x}_j) \equiv \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j) \quad (4)$$

を用いることで、計算の簡略化と非線形識別（判別）関数へ拡張することができる。これが SVM の大きな特徴の一つであり、本研究では代表的なガウスカーネル関数と多項式カーネル関数を用いて精度の比較検証を行う。ガウス関数および p 次多項式関数は以下のとおりである：

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp \left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2} \right) \quad (5)$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i^T \mathbf{x}_j)^p \quad (6)$$

本研究では、数値行列から支保パターンを分類するため、数値パラメータからのパターン認識に優れた SVM を用いることとする。

4. 解析

(1) 解析方法および解析データ

検証に使用するデータとして、NATM における評価点データを使用する。ここで、DIII のパターンはトンネル掘削時の土被りの高さによって設定されるため、評価点との関連性は低いと判断した。そこで本研究では DIII を省いた 9 項目×3（右肩、天端、左肩）の評価点の行列データ 1948 個を使用し、CI、CII、DI、DII の 4 つの支保パターンの分類を目指し、精度を解析する。

まず、評価点のデータに対する SVM の学習の精度を解析する。次に、8 : 2 の割合で学習用とテスト用のデータに分け、テストの精度を確認する。データ数は、学習用データが 1558 個、テスト用データが 390 個である。

精度は、実際に現場で採用された支保パターンを正解とする。すなわち、人間の判断に対する SVM の予測精度である。

(2) 学習の精度解析の結果

学習の精度とは、テスト用データを用いず、学習データだけで予測した精度である。図 - 5 に正解した個数および支保パターン各々の的中率を示す。学習の全体の精

度は85.6%であり、高い精度を得ることができた。図-5より、CIの精度が悪いといえる。これはデータ数が少ないという点が原因であるといえる。また、SVMがCIをCIIと判別していることが多くあり、これは人間によるデータを使用しているため、実際の支保パターン判定の際、より強度の強い支保パターンを選定しているデータが多いということが考えられる。

この結果より、SVMは評価点データを十分に学習することができることが分かったので、次に学習用データとテスト用データを分け、テスト用のデータの精度を検証する。




図-5 支保パターン各々の的中率

(3) テスト精度の解析結果

データを学習用とテスト用に分け、精度を検証したところ、85.9%の精度を得ることができた。表-2にSVMによる予測結果を示す。表中の数字はデータ数であり、括弧内はそれぞれの支保パターンの精度を示している。縦軸が実際に採用されたパターンであり、横軸はSVMが予測した結果となる。全体の精度は高いが、各々の精度を見るとやはりCIの精度は低い。この理由は前述したようにデータ数と、データの質が原因であると考えられる。しかし、データ数の多いCIIやDIを見ると精度は高いといえるため、各々のパターンのデータを増やすことができれば、精度は上がることが予想できる。

また、85.9%の精度は、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まれてしまう評価点データに対して高いといえるので、この結果からは、機械学習をトンネルの岩盤判定に適用することに有用性はあるといえる。

表-2 SVMによる予測結果(括弧内は各々の精度)

		SVMで予測されたパターン			
		CI	CII	DI	DII
採用されたパターン	CI	3 (37.5%)	5 (62.5%)		
	CII	2 (0.7%)	260 (92.9%)	18 (6.4%)	
	DI		29 (31.2%)	64 (68.8%)	
	DII			1 (11.1%)	8 (88.9%)

5. おわりに

本研究における解析から得られた結果を以下に示す：

- 機械学習を使用し、評価点のデータから支保パターンを予測することができた。
- 2つの解析ともに約86%の精度を得ることができた。この精度は、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まれてしまう評価点データに対して高いといえる。
- それぞれの支保パターンの精度を見たとき、データ数が多いほど精度が高い。
- 精度が低いものに関して、支保パターンを決める際に用いられる別のデータが反映されていないことも原因として挙げられる。
- 正しく予測されていないデータは、人間があえて強い強度の支保パターンに決定したデータである可能性がある。

以上を踏まえて、機械学習をトンネルの岩盤判定に適用することに有用性はあると結論付ける。

参考文献

- 1) 桜井春輔・足立紀尚：都市トンネルにおけるNATM，鹿島出版会，pp.86-92，1988
- 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
- 3) 江本美奈子・五味篤暁：建設会社における情報化施工の最前線，J-STAGE，50巻，9号，pp.820-823，2012
- 4) B. Schoelkopf, A.J. Smola : *Learning with Kernels -Support Vector Machines, Regularization, Optimization, and Beyond (Adaptive Computation and Machine Learning series)-*, The MIT Press, 2002

DESIGN FOR SUPPORT PATTERNS OF NATM TUNNEL USING MACHINE LEARNING

Genki KANEKO, Taiki ENAMI, Yeboon YUN,
Harushige KUSUMI, Akinobu NISHIO

At the tunnel construction site using the NATM , it is important to evaluate the cutting face of the rock when engineers determine the support pattern (CI ~ DIII) of the tunnel. At present, the evaluation is performed by skilled engineers according to the predetermined evaluation items, and it has not been established as a standard evaluation method. Therefore, in this paper, we verified the applicability of introducing machine learning for rock mass evaluation. Using some tunnel data, 4 patterns of CI ~ DII are distinguished and the accuracy is verified. In this verification, about 2000 data were first learned and the accuracy of the learning was verified. As a result, about 86% accuracy was obtained.