

機械学習による NATM トンネルにおける 切羽面の岩盤評価

Karnallisa Desmy HALIM^{1*}・金子 元気²・尹 禮分³・楠見 晴重³

¹関西大学大学院理工学研究科 (〒565-8680 大阪府吹田市山手町3丁目3番35号)

²(株)大林組 (〒108-8502 東京都港区港南2-15-2 品川インターシティB棟)

³関西大学 環境都市工学部 (〒565-8680 大阪府吹田市山手町3丁目3番35号)

*E-mail: k696905@kansai-u.ac.jp

山岳トンネル工法 (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を決定する際に、切羽面の岩盤評価が重要となる。現在の技術において、岩盤を評価する際に、技術者の経験に基づく差が生じ、統一かつ標準的な評価法とはいえない。本研究では、バイアスが生じない評価手法の確立を目指すために、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。機械学習としてクラス分類法のサポートベクターマシン (SVM) を使用する。これまで建設現場で記録された切羽面の評価点および支保パターンを学習させた結果、高い精度で支保パターンの判定ができることを示した。また、トンネル建設現場における支保パターン決定の流れを取り入れた解析方法では、さらなる精度向上が見られた。

Key Words : NATM tunnel, rock face classification, support vector machine, machine learning

1. はじめに

山岳トンネル建設工法である New Austrian Tunneling Method (NATM工法) のトンネル設計において、岩盤の種類や強度などの工学的諸性質によって地山が分類され (＝地山等級区分)、分類された地山に応じて崩壊などを防ぐための標準的な支保構造、要するに支保パターンを設定している。

トンネルの工事にあたっては、切羽面の観察および計測により地山等級の判定が行われたうえ、「安全性」を確保しつつ、「経済性」を考慮した合理的な施工を実現するよう、必要に応じて支保パターンの変更を実施する。また、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、適切な補助工法を選定する必要がある。

本来、トンネルにおける地山等級の判定は、切羽面における岩石の強度や亀裂などを観察し、その結果に基づく点数付けを行って評価される。しかし、その評価基準や様式などについては統一されず、各現場の担当者が岩盤を評価する際に、個人的な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、2006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¹⁾。

さらに、少子高齢化にともなう人手不足や建設現場に

おける安全性の向上のため、近年、さまざまな社会インフラの調査、設計、施工、維持管理の各段階において情報通信技術 (ICT) の利用拡大が見られている。建設現場における ICT の普及により、より高効率・高精度な施工の実現が期待されている。

トンネル地山等級判定マニュアルは、評価点の設定について十分まとめられているが、それを基に支保パターンを決定する際の基準があいまいである。

本研究では、山岳トンネルの建設において、現在、技術者によって行われる支保パターンの決定を機械学習の導入により、効率的かつ標準的に岩盤を評価する手法の確立を目指す。統計的な機械学習の一つであるクラス分類法のサポートベクターマシン (Support Vector Machine, SVM) を用いて、国土交通省により定められている岩盤評価に基づいた支保パターンの判定に適用した。また、その支保パターンの決定に際してその定量的解析を実施した。最終的に、その有用性の検証を行った。

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、切羽面の岩盤を観察および計測する際、国土交通省が決めた9つの評価項目 (表-1) をもとに、切羽面の各部分 (右肩、天端、左肩) に分け

て評価する。つまり、1つの切羽面に対して計27個の項目があり、各項目に1~4点の点数が担当技術者の判断によって付けられる。この点数のことを評価点と呼ぶ。そして、定められた計算方法によって、1つの切羽面につき1つの総合的な評価点が求められる。

支保パターンはB, CI, CII, DI, DII, DIIIの6つに区分され、その違いは支保工の設定に大きく関係する。決定された支保パターンによって、ロックボルトの本数や、吹き付けコンクリートの厚さ、鋼製支保工の種類、インバートの有無という支保の強度が決められる。支保工の強度は、Dになるほど強くなる、つまりBは岩盤の強度が高く、Dにつれて低いということである。ところで、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、評価点に基づいて設定される。よって、本研究ではDIIIのデータを用いない。

トンネル地山等級判定マニュアル（試行案）に提案される流れでは、観察結果の点数付けの次に、図-1のような箱ひげ図から支保パターンを決定するが、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に該当する。そのため、この基準はあいまいであることがわかる。

表-1 切羽面評価項目一覧

評価区分	説明
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

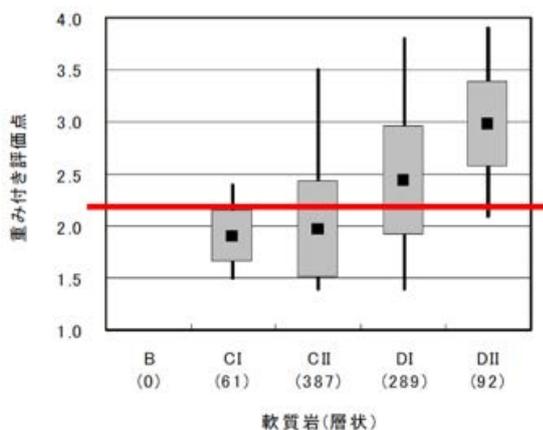


図-1 支保パターンを決定する際の箱ひげ図¹⁾

さらに、このような場合では、支保パターンの決定を行う技術者によって経験に基づくバイアスによる個人差が生まれる可能性がある。したがって、結局は熟練した技術者の判断で最終の支保パターンが決定されるので、効率化および標準化が難しい状況である。

そこで、本研究では、評価点による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つの切羽に対する27個の点数行列を説明変数とし²⁾、実際に施工において採用された支保パターンを従属変数とする。この採用された支保パターンを正解と扱い、機械学習による判断はどこまで過去の人間の判断に近似できるかの精度を確認し、有用性について検証する。

3. サポートベクターマシン (SVM)

(1) SVMの概要

サポートベクターマシンは1992年にVapnik³⁾らによって提案され、2つのパターン認識問題を解くための手法である。パターン分類の問題が線形分離不可能な場合、図-2に示されるように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。

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その真ん中を通る識別関数（図-3）を解析的に求める。この距離をマージンと呼び、マージンの最大化を求めながら、識別関数を決める。また、マージン領域の端に位置するデータをサポートベクターと呼ぶ。

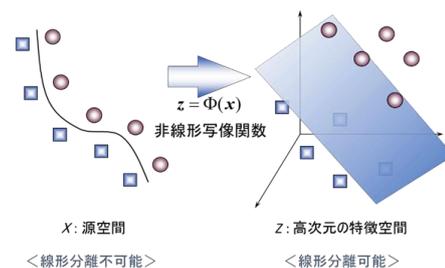


図-2 データの高次元の特徴空間への写像

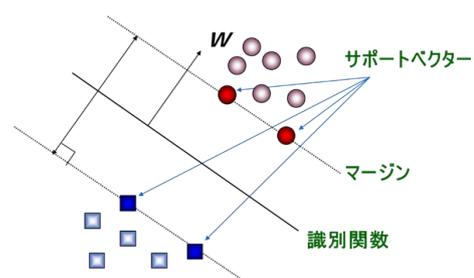


図-3 サポートベクターマシン

(2) SVMの種類

SVMは大きく2つの種類がある。一つ目は、クラスが2つであるサンプル（データ集合）の完全分離を目的とするハードマージン法である。これは、線形分離可能な場合にデータを完全に分離する直線を求める手法である。もう一つ目は、ある程度の誤判別を許容するソフトマージン法である。サンプルに異なるクラスのデータが重なっている場合、つまり、線形分離不可能な場合に分類の多少な誤りを許容しつつ、最も完全分離に近い直線を求める手法である。ハードマージン法とソフトマージン法のイメージは図-4に示されている。

本研究では、使用された評価点データは、人間の目視などで決定しているため、その判断は必ずしも正しいとは限らない。よって、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と考えられ、本研究でソフトマージン法を用いたほうが適切と判断した。

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、 $\mathbf{y} = 1$ 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 i 番目のデータ $\mathbf{z}_i = \Phi(\mathbf{x})$ にし、特徴空間における最適な分離超平面である式 (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、判別に於ける許容誤差を考慮できる。

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

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。さらに、式 (2) に対するラグランジュ双対問題である式 (3) を考える。

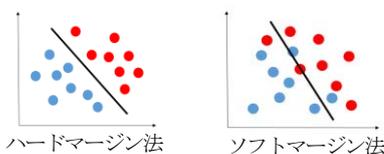


図-4 SVMの種類

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

上記の式 (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

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

を用いることで、計算の簡略化と非線形識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を用いて精度の比較検証を行う。ガウス関数は以下である。

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

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クラス認識に優れたSVMを用いることとする。

4. 解析結果および考察

本研究で行われた解析では、NATM工法における評価点のデータを使用する。ここで、支保パターンDIII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、DIIIを除いた残りの支保パターンの決定に際する点数付けによる評価点と関連が低いと判断した。そのため、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4983個を用いてCI, CII, DI, DIIの4つの支保パターンの分類を実施し、SVMによる分類結果の精度を解析する。なお、実際の施工中のトンネルにおいて支保パターンBに決定される切羽が非常に少なく、本研究の現段階では支保パターンBのデータを入手できていないため除く。

本研究で行った解析の手順として、データを学習用データとテスト用データに分け、MATLABによるSVMを用いて学習用データを学習させてから、テスト用データのクラス分類を実施する。また、実際のトンネル現場における安全性を向上させるための一つ前の切羽を考慮した時の支保工判定を行う。最後に、一つ前の切羽の支保工判定を考慮しないとき、およびそれを考慮したときのそれぞれの結果の解析や比較を行う。

支保パターンのデータを8：2の割合で学習用データとテスト用データに分けて、テストの精度を解析する。各支保パターンの学習用データおよびテスト用データのデータ数は、表-2のようである。

精度の解析に関しては、実際のトンネル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の予測精度を解析する。

(1) SVMのマルチクラス分類による支保工判定

以下、解析の結果を述べる。10回の解析を行う結果の精度の平均を表-3に表す。表-3により、CIの精度が低いことが見られる。SVMによる分類がCIIであると判断したが、実際に採用された支保パターンはCIである理由として、予測対象データにおいて、人間側が経済面を考慮して支保パターンをCIに決定した可能性、また、安全面を考慮してCIIに決定した可能性の2つが挙げられる。

さらに、対角成分より左側に予測されているものは、実際の施工現場で導入することを考慮したときに危険性があると考えられる。実際に採用された支保パターンを正解と扱うとき、SVMの予測では支保パターンのランクが良好岩盤側と評価され、安全面を考慮したときに結果として危険側となる可能性があるためである。

これは、本研究で人間による評価点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、脆弱岩盤側に支保パターンを設定しているデータが多いと考えられる。

以上の結果は、実際の施工を考慮したとき危険な予測であることは変わりがないため、次はより現場に近い方法で支保パターン判定を行えるように解析を行う。

表-2 トンネル現場における支保パターンのデータ数

支保パターン	全データ	学習用データ	テスト用データ
CI	168	134	34
CII	2957	2366	591
DI	1778	1422	356
DII	80	64	16
計	4983	3986	997

表-3 SVMのマルチクラス分類による支保パターンの的中数

全体の精度 82.89%		SVMによる予測の支保パターン			
		CI	CII	DI	DII
パターン 支保 真の	CI	9	24	1	-
	CII	3	532	57	-
	DI	-	74	308	4
	DII	-	-	8	8

単位：個

(2) 1つ前の切羽における評価点を考慮した支保工判定

今回の解析は、実際の支保パターン決定の流れに着目した。トンネル施工における支保パターン決定には、現切羽の支保パターンにおいて、一つ前の切羽の評価によって決定された支保パターンと同じになることが多いと考えられる。そのため、一つ前の切羽の支保パターンと評価行列を考慮した判定方法を提案する。

このような支保パターン判別の流れは図-5のように示す。まず、SVMによる予測パターンに対して、その一つ前の支保パターンが脆弱岩盤側か良好岩盤側で分行い、その後の予測対象の評価点行列と一つ前の評価点行列の要素が $\alpha\%$ ($\beta\%$) 以上一致しているときに一つ前のパターンに変更するという作業を加え、変更後の支保パターンを予測パターンとして精度を確認する。

ここで、

α : SVMの予測パターンより一つ前の支保パターンのランクが脆弱岩盤側の場合、一つ前の切羽の評価点行列と、予測したデータの評価点行列の要素の一致率 (%)

β : SVMの予測パターンより一つ前の支保パターンのランクが良好岩盤側の場合、一つ前の切羽の評価点行列と、予測したデータの評価点行列の要素の一致率 (%)

と定義する。なお、SVMの予測パターンと一つ前のパターンが同じ場合と、一つ前のデータが無いもしくはDIIIである場合はSVMの予測結果通りとする。

a) 一致率 $\alpha\%$ 、 $\beta\%$ を変化させたときの的中確率

分岐の境界として設定する α と β は割合で変更させるため、0%~100%を10%間隔で変化させる。つまり、11×11×10の計1210回の解析を行った。 α と β の値に対応する評価点の一致数を表-4に示し、その精度を図-6で示す。この解析において、最も精度が高い α と β の組み合わせ

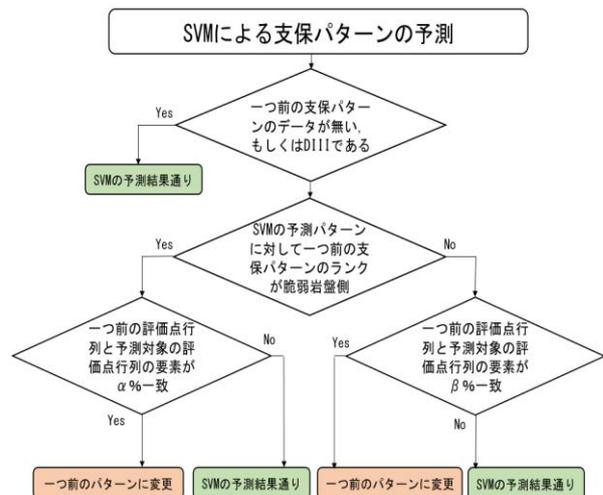


図-5 SVM予測結果の変更フロー

わせは、 $(\alpha, \beta) = (50\%, 40\%)$ である。図-6により理解したことが2つある。その一つ目は、精度は β に依存していないこと、すなわちSVMによって予測された支保パターンに対して一つ前の切羽は良好岩盤側の場合が少なく、そのときのSVM予測の精度が高いことである。二つ目は、 α が60%を超える場合、精度が低くなること、すなわちSVMによって予測された支保パターンに対して一つ前の切羽は脆弱岩盤側の場合、一つ前の支保パターンに依存されやすいことである。

この結果より、SVMによる予測の支保パターンより一つ前の支保パターンが脆弱岩盤側の場合、一つ前の切羽の評価点と対象の評価点が半分違っていても、一つ前の支保パターンに変更すべき、もしくはそのように施工されてきたといえる。

b) 一つ前の切羽を考慮した支保パターンの的中率

次に、(a)において最も精度が高い一致率 $(\alpha, \beta) = (50\%, 40\%)$ のSVMによる予測の結果を確認する。(1)と同じく10回の解析を行い、得られた結果の平均を表-5に示す。全体の精度が約90%に上がり、(1)の結果に比較する

表-4 α, β と一致数の対応表

α, β (%)	0	10	20	30	40	50	60	70	80	90	100
一致数 (個)	0	3	6	8	11	14	17	20	22	25	28

と、支保パターンDの判別精度が全体的に向上している。また、(1)の的中数を表した表で問題視した対角成分より左側を見ると、誤判別は減少したことが見られる。この結果から、実際の施工では一つ前の切羽の評価点が5割ほど異なっても、一つ前の切羽の支保パターンに影響されているといえる。さらに、精度は一致率 α に依存していることから、SVMの予測パターンに対して一つ前の切羽が脆弱岩盤側の場合、安全面を考慮した施工にこの方法は有用であると考えられる。

以上の解析により、評価点行列を用いて機械学習で解析を行ったが、80%~90%以上の精度を得ることができたことから、評価点と施工時に採用された支保パターンはある程度相関していることがわかる。そのため、評価点のデータ集をSVMで学習し、支保パターンCI~DIIの判別を出力することが可能であると認められた。

表-5 一つ前の切羽を考慮したSVMのマルチクラス分類による支保パターンの的中数

単位：個

全体の精度 90.15%		SVMによる予測の支保パターン			
		CI	CII	DI	DII
真の 支保 パターン	CI	8	24	2	-
	CII	0	530	61	-
	DI	-	7	346	3
	DII	-	-	3	13

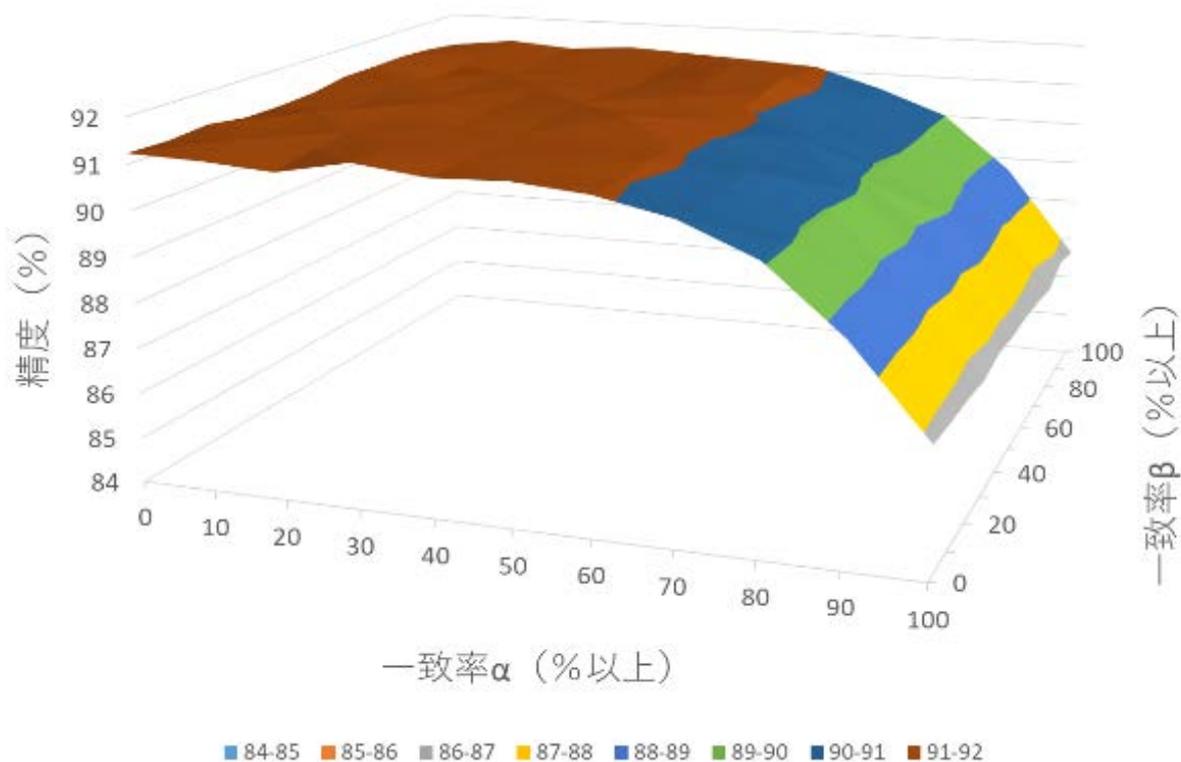


図-6 α と β の変化による精度の分布

5. おわりに

トンネルの建設現場における支保工判定の統一性が見られない課題および少子高齢化にともなう技術者の人手不足や建設現場での安全面の不安を解決するため、本研究では機械学習による岩盤評価の手法を提案した。機械学習としてサポートベクターマシン (SVM) を用いて実際のトンネル建設現場から得られた4000個以上のデータをもとに、支保パターンの決定を行った。本研究で得られた成果を以下にまとめる。

- 機械学習による支保パターン判定では、80%~90%以上の精度が得られた。これは人間が付けた評価点の行列からある程度の岩盤の特徴が現れ、その特徴をSVMにより十分に学習できたといえる。よって、SVMは評価点データを学習し、支保パターンを出力することが可能であることが認められた。
- 実際の施工時に、一つ前の支保パターンが現支保パターンに影響を与えている。これは、弱い支保パターンで施工が可能な場合でも、安全性を考慮した施工がされていると考えられることである。
- 一つ前の支保パターンと評価点行列を考慮し、必要に応じてSVMの予測結果を変更していく手法では、危険側の判定が減少した。そのため、これは安全面を考慮した際の有用な方法であるといえる。

本研究によって得られた以上の成果より、本研究では支保パターンの決定過程に機械学習の適用を試み、その有用性を示すことができた。今後はさらに研究が進み、実施工において本手法が適用されることを期待する。

参考文献

- 1) 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
- 2) 金子元紀，楠見晴重，尹禮分，西尾彰宣：「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」 Kansai Geo-Symposium2019, 6-3, 2019
- 3) 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

EVALUATION OF NATM TUNNEL FACE USING MACHINE LEARNING

Karnallisa Desmy HALIM, Genki KANEKO, Yeboon YUN and Harushige KUSUMI

The determination of support patterns by field experts in NATM plays an important role in the construction of mountain tunnels. Discrepancy in judgement based on experience and bias may lead to an inconsistent evaluation method. Therefore, this research aims to realize an unbiased and standardized evaluation method by verifying the applicability of machine learning to rock evaluation. Support vector machine (SVM) is implemented to classify support patterns based on data collected from construction sites. The proposed SVM-based model shows high accuracy. Furthermore, by taking into account the current method of rock evaluation during tunnel construction, the classification accuracy further improved.