

ANN 및 SVR 알고리즘을 활용한 최적 터널지보패턴 선정에 관한 연구

이제겸¹ · 김양균² · 이승원^{3*}

¹정회원, 한양대학교 자원환경공학과 박사과정

²정회원, 한양대학교 자원환경공학과 연구교수

³정회원, 한양대학교 자원환경공학과 교수

A study on the optimization of tunnel support patterns using ANN and SVR algorithms

Je-Kyum Lee¹ · YangKyun Kim² · Sean Seungwon Lee^{3*}

¹Ph.D. Student, Dept. of Earth Resources and Environmental Engineering, Hanyang University

²Research Professor, Dept. of Earth Resources and Environmental Engineering, Hanyang University

³Professor, Dept. of Earth Resources and Environmental Engineering, Hanyang University

*Corresponding Author : Sean Seungwon Lee, seanlee@hanyang.ac.kr

Abstract

A ground support pattern should be designed by properly integrating various support materials in accordance with the rock mass grade when constructing a tunnel, and a technical decision must be made in this process by professionals with vast construction experiences. However, designing supports at the early stage of tunnel design, such as feasibility study or basic design, may be very challenging due to the short timeline, insufficient budget, and deficiency of field data. Meanwhile, the design of the support pattern can be performed more quickly and reliably by utilizing the machine learning technique and the accumulated design data with the rapid increase in tunnel construction in South Korea. Therefore, in this study, the design data and ground exploration data of 48 road tunnels in South Korea were inspected, and data about 19 items, including eight input items (rock type, resistivity, depth, tunnel length, safety index by tunnel length, safety index by rick index, tunnel type, tunnel area) and 11 output items (rock mass grade, two items for shotcrete, three items for rock bolt, three items for steel support, two items for concrete lining), were collected to automatically determine the rock mass class and the support pattern. Three machine learning models (S1, A1, A2) were developed using two machine learning algorithms (SVR, ANN) and organized data. As a result, the A2 model, which applied different loss functions according to the output data format, showed the best performance. This study confirms the potential of support pattern design using machine learning, and it is expected that it will be able to

OPEN ACCESS

Journal of Korean Tunnelling and
Underground Space Association
24(6)617-628(2022)
<https://doi.org/10.9711/KTAJ.2022.24.6.617>

eISSN: 2287-4747
pISSN: 2233-8292

Received October 13, 2022

Revised October 25, 2022

Accepted October 27, 2022



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Copyright © 2022, Korean Tunnelling and Underground Space Association

improve the design model by continuously using the model in the actual design, compensating for its shortcomings, and improving its usability.

Keywords: Rock mass class, Tunnel support, Machine learning, SVR, ANN

초 록

터널 건설 시 암반 등급에 따라 다양한 지보재를 적절히 병용하여 지보패턴을 결정하고 시공이 이루어진다. 이 과정에서 시공 경험이 풍부한 전문가의 기술적 판단이 필요한데, 터널 설계의 초기 단계인 타당성 조사 및 기본설계 단계에는 상대적으로 짧은 수행기간과 부족한 자료 및 예산으로 인해 설계에 많은 어려움이 존재한다. 터널 건설의 급증과 함께 축적된 설계 데이터와 머신러닝을 활용한다면, 지보패턴 설계를 보다 신속하고 신뢰도 있게 수행할 수 있다. 따라서 본 연구에서는 암반등급 판정 및 해당 암반등급에 적합한 지보패턴 설계를 자동화하고자 국내 48개 도로터널의 설계자료 및 지반조사 자료를 수집하였으며, 8개의 입력항목(암종, 전기비저항, 심도, 터널연장, 터널연장에 따른 방재등급, 위험도지수에 따른 방재등급, 터널 종류, 터널 단면적)과 11개의 출력항목(암반등급, 슛크리트 제원 2개 항목, 록볼트 제원 3개 항목, 강지보 제원 3개 항목, 콘크리트 라이닝 2개 항목)에 대한 데이터를 정리하였다. 이와 같이 정리된 데이터를 활용하여 2가지 머신러닝 알고리즘(SVM, ANN)을 활용하여 3가지 머신러닝 모델(S1, A1, A2)을 개발하였으며, 세 가지 모델의 성능을 비교해본 결과 출력값의 데이터 형식에 따라 서로 다른 손실함수를 적용한 ANN 기반의 A2 모델이 가장 뛰어난 성능을 보였다. 본 연구를 통해 머신러닝을 활용한 지보패턴 설계의 가능성을 확인할 수 있었으며, 향후 지속적으로 실제 설계에 사용함으로써 단점을 보완하고 적용성을 개선해 나간다면 설계에 보다 큰 도움을 줄 수 있는 지보패턴 설계 모델을 개발할 수 있을 것으로 기대된다.

주요어: 암반등급, 터널지보, 머신러닝, SVR, 인공지능경망

1. 서론

터널 건설 시 록볼트, 슛크리트, 강지보와 같은 1차 지보재와 콘크리트 라이닝으로 대표되는 2차 지보재를 사용하며, 추가적으로 필요에 따라 강관다단 그라우팅과 같은 보조공법을 사용한다. 다만, 설계 단계에서는 아직 굴착 되지 않은 터널의 암반 특성을 정확히 파악하기 힘들기 때문에 암반등급에 따라 다양한 지보재를 적절히 병용하여 지보패턴을 결정하게 된다.

지보패턴의 설계방법으로는 크게 세 가지 방식이 있는데, 첫 번째는 여러 시공 실적에 근거하여 작성된 지보패턴을 참고하는 방법이고, 두 번째는 인접한 현장의 사례 혹은 지반 조건이 유사한 경우의 설계 예를 참고하는 방법이며, 세 번째는 해석에 의해 지보패턴을 선정하는 방법이다(MOLIT, 2011). 이 중에 첫 번째와 두 번째 방법은 기존의 시공이력을 참고하는 경험적인 방법이기 때문에 많은 시공 실적이나 경험을 보유해야 하며, 이를 정밀 분석 후 적절한 지보패턴을 선정하는 과정에서 고도의 기술적 판단이 필요하다.

그러나, 터널 설계 초기단계인 타당성 조사 및 기본설계 시에는 상대적으로 짧은 수행기간과 부족한 자료 및 예산으로 인해 작업에 많은 어려움이 있다. 이와 관련해서, 미굴착 지반의 암반등급을 사전에 파악하거나(Kim et

al., 2021; Kim and Lee, 2022), 머신러닝을 활용하여 암반등급을 보다 간편하고 정확하게 판정하기 위한 연구들이 수행되고 있으나(Shin and Kwon, 2009; Rai et al., 2015; Galende-Hernandez et al., 2018; Lee et al., 2021) 동일한 암반등급이라 할지라도 지반의 특성에 따라 현장 별로 적용되는 지보량이 달라지게 되며, 현장에 적합한 세부적인 지보량을 설계하기 위해서는 여전히 많은 부담이 따르는 실정이다.

한편, 최근에는 사람이 해야만 했던 단순, 반복 업무를 자동화할 수 있는 환경적인 여건이 마련되고 있다. 머신러닝이 부상하면서 방대한 양의 데이터를 효율적으로 분석할 수 있는 수단이 보편화되고 있으며, 최근 10년간 2,067개소의 도로터널이 새로 시공되어 개통되는 등(MOLIT, 2022) 국내 터널 건설의 증가와 함께 터널 설계와 관련된 데이터 또한 급증하고 있다.

따라서 머신러닝 기법과 터널 설계 데이터를 활용한다면 기존의 터널 설계 이력에 기반한 지보패턴 설계를 신속하고 신뢰도 있게 수행할 수 있을 것으로 판단된다. 일반적인 설계 과정은 먼저 다양한 데이터를 활용하여 암반 등급을 판정하고, 판정된 암반등급을 기반으로 지보패턴을 산정하게 된다. 따라서 본 연구에서는 8개의 입력항목(암종, 전기비저항, 심도, 터널연장, 방재등급, 터널종류, 터널 단면적)으로부터 암반등급을 예측하고, 더 나아가 지보패턴까지 산출하기 위한 모델을 개발하였다. 48개 도로터널 현장의 터널설계보고서 및 지반조사보고서를 정리하여 총 1,162개의 설계 데이터셋을 수집하였으며, 두 개의 머신러닝 알고리즘(SVR, ANN)을 활용하여 세 가지 예측 모델을 개발하고 그 성능을 비교하였다.

2. 문헌연구

2.1 지보패턴 최적화 선행연구

터널 시공 시 사용하는 지보재는 록볼트, 슛크리트, 강지보와 같은 1차 지보재와 콘크리트 라이닝으로 대표되는 2차 지보재로 구분된다. 추가적으로 암반의 물성이 안 좋을 경우, 필요에 따라 강관다단 그라우팅과 같은 보조 공법을 병행하게 된다. 이와 같은 지보재의 대표적인 제원과 시공순서 등을 굴착 암반의 공학적인 특성과 터널의 토피 등을 고려하여 암반 조건별로 표준화한 것이 표준지보패턴이다. 표준지보패턴을 적용할 때는 현장조사 결과로부터 나타난 암반의 특성(절리, 강도, 방향성 등)과 기존 적용사례 등을 비교, 검토하고 이에 대한 정성적, 정량적 평가를 수행한 후, 책임기술자의 판단에 의해 지보재량을 조정하게 된다(MOLIT, 2011).

이에 따라 지보재량을 최적화하기 위한 연구가 다수 수행되었다. Kim et al. (2003)은 인공신경망(ANN)을 이용하여 흙막이 벽체를 지지하는 지보공 공법을 최적화하기 위한 연구를 수행하였다. Carbonell et al. (2011)은 세 가지 휴리스틱 방법(MGB, SA, TA)을 사용하여 콘크리트 라이닝 시공 시 비용을 절감할 수 있도록 최적화하는 방법을 제안하였다. Kim and Moon (2016)은 갱구사면의 안정성 확보를 위해 차분진화 알고리즘을 활용하여 쏘일네이팅 공법에 대한 최적화를 수행하였으며, Kang et al.(2018)은 마찬가지로 차분진화 알고리즘을 활용하여 슛크리트 두께, 록볼트의 길이 및 설치간격을 최적화하기 위한 연구를 진행하였고, Soranzo et al. (2022)은 강화 학습과 유한차분법을 활용하여 최적 터널지보패턴을 도출하는 연구를 진행하였다.

2.2 머신러닝 기법

머신러닝(Machine learning)은 사람이 직접 처리하기 힘든 방대한 양의 데이터를 사람 대신 기계가 분석할 수 있도록 만드는 방법이다. 머신러닝을 구현하기 위한 알고리즘은 여러 가지가 있으며, 터널 및 지하공간 분야에서 주로 사용되는 알고리즘으로는 Support vector machine (SVM), Artificial neural network (ANN), XGBoost 등이 있다(Kim, 2021), 본 연구에서는 그 중 두 가지 알고리즘(SVR 및 ANN)을 활용하였다.

SVR (Support Vector regression)은 SVM (Support vector machine) 알고리즘을 기반으로 데이터의 경향을 가장 잘 나타내는 회귀모델을 찾는 머신러닝 기법이다(Fig. 1(a)). 선형회귀 뿐만 아니라 Kernel 함수를 활용한 비선형 회귀 또한 가능하며, Gamma 및 C와 같은 초매개변수(Hyper parameter)를 조절하여 모델을 최적화하게 된다. ANN (Artificial neural network)은 다수의 노드가 포함된 여러 개의 층을 순차적으로 배치한 구조를 활용하여 예측모델을 만드는 머신러닝 기법으로(Fig. 1(b)), 다량의 데이터에 대한 결과값과 실제값 간의 오차를 계산하고, 그 오차를 줄이는 방향으로 모델을 반복적으로 수정하는 방식으로 학습이 이루어지며, 노드의 개수, 층의 개수, 활성화함수, 오차의 계산방식(손실함수) 등의 초매개변수를 설정하여 모델을 생성하게 된다.

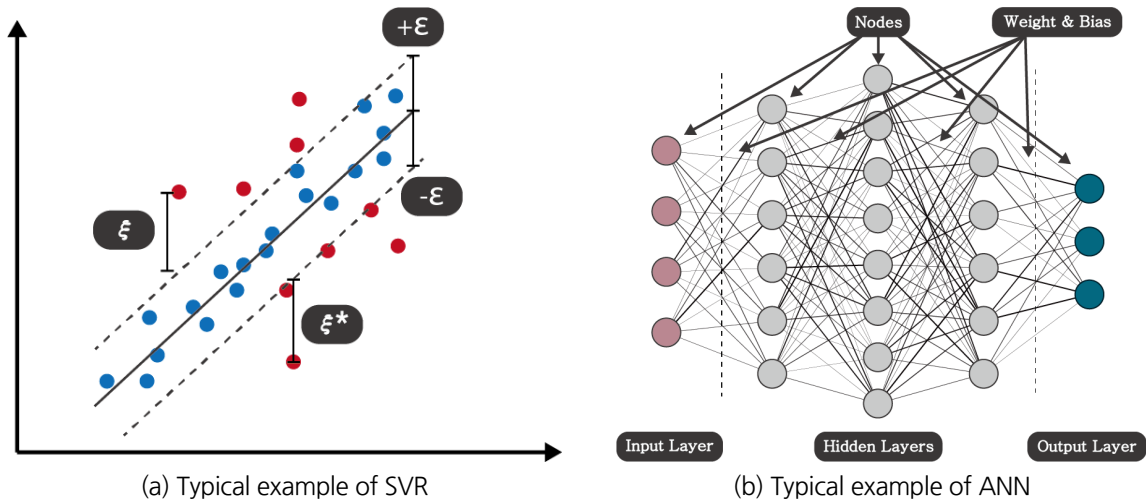


Fig. 1. Typical example of machine learning algorithm (modified from Lee et al., 2021)

3. 데이터 수집

본 연구를 수행하기 위해 총 48개의 국내 2, 3차로 도로터널을 대상으로 터널설계보고서, 지반조사보고서, 설계도면을 참고하였다. 수집한 데이터의 종류는 Table 1과 같다. 암반등급을 예측하기 위해 암종, 전기비저항, 지반고에 대한 데이터를 수집했으며, 지보패턴 예측을 위해 터널연장에 따른 방재등급, 위험도지수에 따른 방재등급, 터널종류: 국도(National) 및 고속국도(Highway), 터널단면적에 대한 데이터 및 지보패턴(숏크리트, 록볼트,

강지보, 콘크리트라이닝) 제원에 대한 데이터를 수집하였다. Table 2는 입력값으로 사용된 4개 항목에 대한 평균, 표준편차 및 최대/최소값을 나타낸 것이다. 전기비저항, 터널연장 및 터널 심도의 경우 표준편차가 각각 2,665 Ω, 1,642 m, 110 m로 현장에 따른 값의 편차가 상당히 크게 발생했으며, 이와는 반대로 터널 직경의 경우 16.7 m²로 상대적으로 작은 편차를 보였다.

Table 1. Descriptions of data

Category	Type of data		Remarks	Variable type	Purpose
Input data	Rock type		Gneiss, Granite, Andesite, Shale, Sandstone, Extra-type	Categorical	-
	Resistivity		Ω	Numerical	-
	Depth		m	Numerical	-
	Tunnel length		m	Numerical	-
	Safety index by tunnel length		1, 2, 3, 4	Numerical	-
	Safety index by risk index		1, 2, 3, 4	Numerical	-
	Tunnel type		National/Highway	Categorical	-
	Tunnel area		m ²	Numerical	-
Output data	Rock mass grade by RMR		1, 2, 3, 4, 5	Numerical	Regression
	Shotcrete	Thickness	mm	Numerical	Regression
		Steeffiber	Used/Not used	Categorical	Classification
	Rockbolt	Length	m	Numerical	Regression
		Longitudinal spacing	m	Numerical	Regression
		Lateral spacing	m	Numerical	Regression
	Steel support	Type	H girder (HG)/Lattice girder (LG)	Categorical	Classification
		Specific size	LT1/LT2/LT3/HT1/HT2	Categorical	Classification
		Spacing	m	Numerical	Regression
	Concrete lining	Thickness	mm	Numerical	Regression
Steel reinforcement		Used/Not used	Categorical	Classification	

a) LT: Size type of lattice girder, HT: Size type of H girder

b) LT1: (if necessary) 50×20×30, LT2: 50×20×30, LT3: 70×20×30, HT1: 100×100×6×8, HT2: 150×150×7×10

Table 2. Representative values of input data

Category	Type of data	Mean	Standard deviation	Min value	Max value
Input data	Resistivity (Ω)	2,512.3	2,665.2	45	19,140
	Depth (m)	143.6	110.2	0	743
	Tunnel length (m)	1,874.2	1,642.2	115	7,081
	Tunnel area (m ²)	94.8	16.7	67.1	138.0

데이터 비율은 경상남도, 충청도, 경상북도 순으로 높았으며(Table 3), 데이터의 암종별 분포는 현장별로 2개 이상의 암종이 관찰된 경우를 고려하여 편마암이 32%로 가장 많았고 그 뒤로 화강암, 안산암, 사암, 셰일 순으로 많은 비율을 차지하였다. Fig. 2는 암반등급 별 데이터 비율을 나타낸 것으로, 2등급(31.7%)과 3등급(32.6%) 데이터가 가장 많이 수집되었으며, 1등급(9%)과 5등급(5.2%) 암반에 대해서는 상대적으로 적은 양의 데이터가 수집되었다.

Table 3. Geological and locational information of the collected data

Province	Number of data	Rock type	Number of data
Gyeongsangnam-do	660 (57%)	Gneiss	403 (32%)
Gyeongsangbuk-do	141 (12%)	Granite	281 (22%)
Chungcheongnam-do	121 (10%)	Andesite	218 (17%)
Gyeonggi-do	105 (9%)	Sandstone	130 (10%)
Chungcheongbuk-do	91 (8%)	Shale	96 (7%)
Gangwon-do	35 (3%)	Other rock types	151 (12%)
Jeollabuk-do	9 (1%)	Total	1,279
Total	1,162	-	-




Fig. 2. Data ratio by rock grades

Fig. 3은 암반등급의 변화에 따라 적용된 지보패턴의 제원을 도시한 것으로, 이를 통해 국내 터널 설계 시 지보재 적용 양상을 확인할 수 있다.

1등급이나 2등급과 같이 암반이 확실하게 양호하거나, 4등급이나 5등급과 같이 암반이 확실하게 불량한 경우 서로 다른 현장이라도 동일한 지보패턴을 적용한 사례가 많았으나, 3등급 암반의 경우에는 현장별로 적용된 지보패턴의 차이가 많이 발생하였다. 또한 지보패턴 항목 중 ‘숏크리트 두께’, ‘록볼트 종간격’, ‘강지보 규격’, ‘강지보

설치간격'의 경우 암반등급의 변화에 따라 적용된 제원의 차이가 크게 발생하였다.

1등급 암반에서 5등급 암반으로 암질이 불량해질수록 '샷크리트의 두께' (Fig. 3(a))는 증가하였고, '록볼트 종간격' (Fig. 3(c)), '록볼트 횡간격' (Fig. 3(d)) 및 '강지보 설치간격' (Fig. 3(g)) 등은 점차 줄어들면서 설치되는 지보재의 양이 증가하였으며, 3등급부터는 강지보 및 철근콘크리트 라이닝이 적용되기 시작하였다(Fig. 3(e), Fig. 3(h)). 강지보의 경우 대부분 Lattice girder가 사용되었으며, 가장 많이 활용된 규격은 LT3 (50×20×30 mm)이다 (Fig. 3(f)).

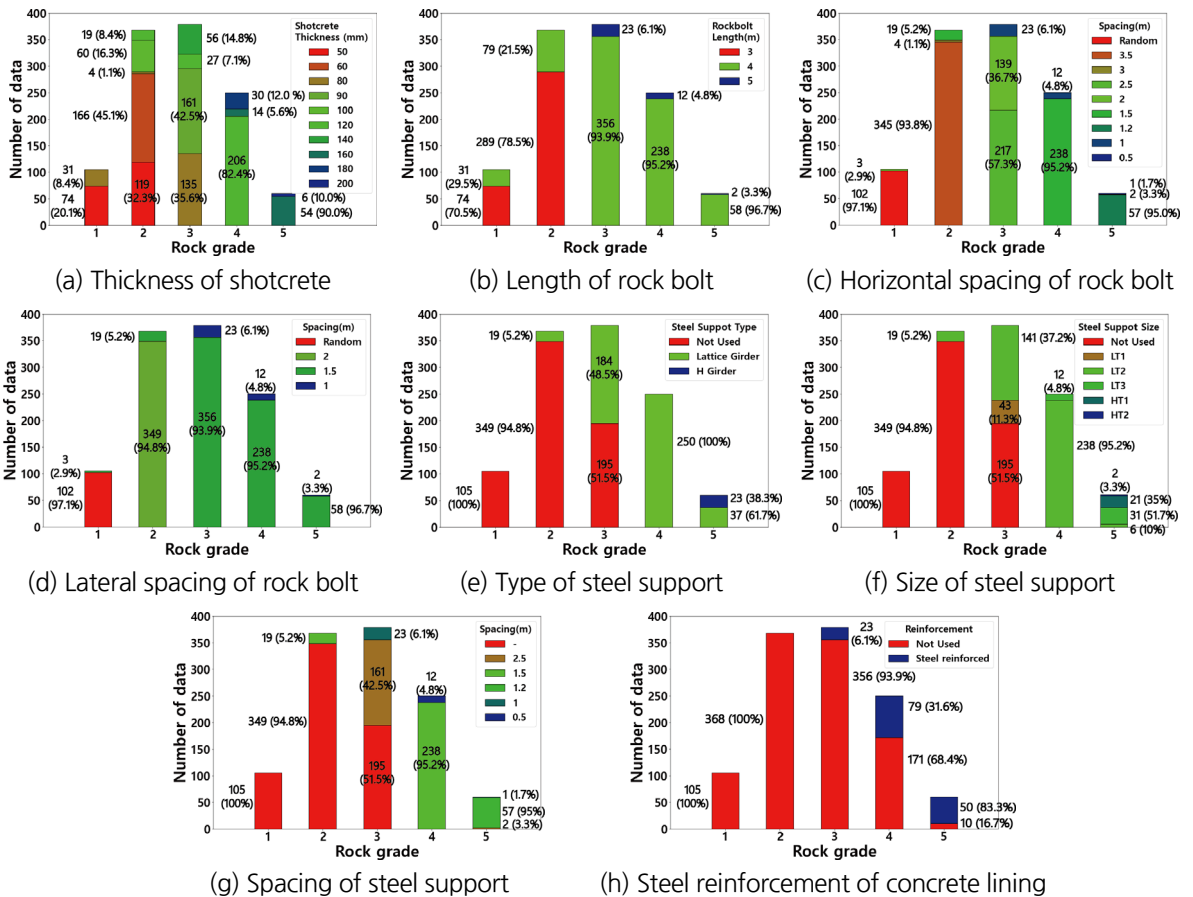


Fig. 3. Design history of the tunnel support according to the rock grade

총 1,162개의 데이터 중 987개(85%)의 데이터를 학습데이터(Training data)로 사용했으며 나머지 175 (15%) 개의 데이터를 시험데이터(testing data)로 사용하였다. 데이터의 형식이 범주형(Categorical)인 경우에는 단위벡터를 이용하여 숫자형 데이터로 변환하였으며, 데이터 형식이 숫자형(Numeric)인 경우에는 Standard scaling을 통해 데이터 항목 간 존재하는 단위 및 자릿수의 차이에 의한 영향을 최소화하였다.

4. 학습 및 학습 결과

본 연구에서는 암반분류 및 지보패턴 예측 모델을 개발하기 위해 두 가지 머신러닝 기법(SVR, ANN)을 활용하여 세 가지 모델을 개발하였으며 SVR 및 ANN 모델의 학습 성능을 최적화하고자 아래와 같이 초매개변수를 설정하였다. SVR 알고리즘을 이용한 학습 시 세 가지 초매개변수(C, Gamma, Kernel)의 후보군을 Table 4와 같이 정하였으며, 초매개변수의 변화에 따른 각각의 학습 결과를 비교하여 최소 오차를 보이는 모델(S1)을 선정하였다. C값은 10, Gamma는 10, Kernel은 RBF kernel을 사용한 경우 가장 양호한 성능을 확인할 수 있었다. ANN 알고리즘을 이용한 학습의 경우에는 모델 구조 및 출력값의 형태(Numerical, Categorical)에 따른 성능 차이를 비교해 보기 위해 두 가지 경우의 모델 구조를 설정하고 그 결과를 비교하였다(Fig. 4). 첫 번째 모델(A1)은 입력층과 출력층 사이에 3개의 은닉층(FCL, Fully connected layer)을 배치하고, 각 은닉층 사이에 0.1의 비율로 Dropout을 적용하였다. 두 번째 모델(A2)에서는 출력별 예측 목표(Classification, Regression)에 따라 최적화된 초매개변수(활성함수 및 손실함수)를 적용하기 위해 출력층을 다섯 가지로 나누었다. 분류(Classification)가 목적인 경우에

Table 4. Hyper-parameter for the training with SVR algorithm

Model name	Hyper-parameter	Description	Candidates	Optimal values
S1 (SVR)	C	Tolerance of data misclassification	0.1, 1, 10, 100	10
	Gamma	Determine the distance of the data sample to influence	0.0001, 0.001, 0.01, 0.1, 1, 10, 100	10
	Kernel	Select a method of mapping data in an input space into a high-dimensional space which is capable of linear classification	RBF, Linear	RBF

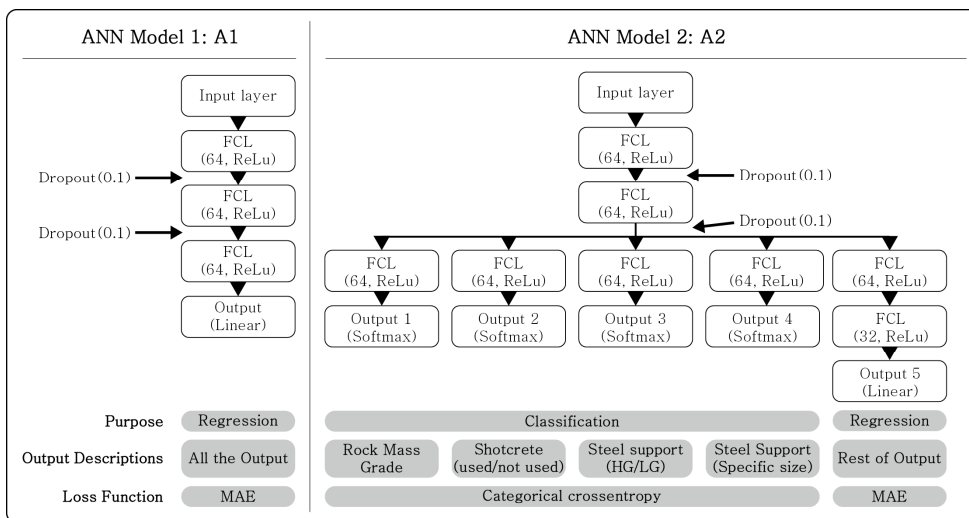


Fig. 4. Hyper-parameter of ANN models

는 활성화함수로 SoftMax를 사용하고, 손실함수로는 Categorical cross-entropy를 적용했으며, 회귀(Regression)가 목적인 경우에는 활성화함수로 Linear function을 사용하고, 손실함수로는 평균절대오차(MAE)를 적용했다.

Table 5는 사용한 예측모델에 따른 성능을 평가하여 나타낸 것이다. 출력값의 데이터 형식이 범주형인 경우에는 성능평가를 위해 정확도(Accuracy)를 사용하였고, 출력값의 데이터 형식이 수치형인 경우에는 평균절대오차(MAE)를 사용하였다. 학습결과는 출력값에 따라 다르지만, 평균적으로 0.499의 MAE값과 98.1%의 정확도로 양호한 결과를 보였다. 가장 우수한 성능을 보이는 모델은 A2 모델로, 시험 오차(Test error)를 기준으로 11개의 출력값 중 8개 항목에서 다른 알고리즘을 사용한 모델보다 뛰어난 성능을 보였으며, 나머지 3개의 항목에서도 약간 저조하지만 다른 알고리즘과 비슷한 성능을 보였다. 이와 같은 결과를 바탕으로 ANN 알고리즘을 활용하는 경우 출력값의 데이터 형태에 따라 적절한 손실함수와 활성화함수를 혼용하는 것이 모델의 예측성능을 향상시키는데 영향을 미친다는 것을 확인할 수 있다.

Table 5. Performance of each machine learning models

Type of data		Training error			Testing error			Remark	Units
		S1	A1	A2	S1	A1	A2		
Rock grade by RMR		0.108	0.086	0.055	0.181	0.153	0.097	MAE	Grade (1~5)
Shotcrete	Thickness	3.689	2.975	1.685	6.443	4.946	3.059	MAE	mm
	Steel fiber	99.5	97.6	99.2	99.4	95.3	98.8	ACC (%)	Used/Not used
Rockbolt	Length	0.048	0.012	0.017	0.072	0.009	0.024	MAE	M
	Longitudinal spacing	0.133	0.149	0.073	0.177	0.263	0.128	MAE	M
	Lateral spacing	0.064	0.074	0.031	0.083	0.127	0.063	MAE	M
Steel support	Type	99.3	95.8	98.9	97.1	97.7	99.4	ACC (%)	H/Lattice girder
	Specific size	98.9	91.3	98.6	94.2	88.4	97.1	ACC (%)	LT1/LT2/LT3/HT2/HT3
	Spacing	0.104	0.055	0.040	0.132	0.068	0.074	MAE	m
Concrete lining	Thickness	2.037	0.221	0.031	2.293	0.193	0.051	MAE	mm
	Steel reinforcement	99.2	98.3	98.3	97.1	94.2	97.1	ACC (%)	Used/Not used
Average MAE		0.883	0.510	0.276	1.340	0.823	0.499	MAE	-
Average accuracy		99.2	95.8	98.8	97.0	94.0	98.1	ACC (%)	-

지보패턴 설계에 대한 예측모델의 성능을 보다 직관적으로 비교하기 위해 시험데이터에서 암반등급별로 데이터를 한 개씩 선정하여 실제값과 예측값을 비교하였으며, 세 가지 알고리즘 중 가장 우수한 성능을 보이는 A2 모델을 사용하였다. Table 6은 예측모델에 입력한 입력값이며, Table 7은 입력값에 대한 출력값을 정리한 것이다. 암반등급이 증가함에 따라 슛크리트, 록볼트, 라이닝 등의 지보량이 점차 증가하는 경향을 보이며, 슛크리트 두께

를 제외한 나머지 예측값에서 최대 0.18의 오차(MAE)가 발생하는 등 일반적인 설계와 유사한 값이 산출되었다. 반면에, 슛크리트 두께에 대한 예측값은 암반등급이 5일 때 실제값 대비 약 20 mm 정도 작게 예측되었는데, 이는 암반등급 5등급에 해당하는 데이터의 비율이 전체 데이터 대비 5.2% (60개)로 부족하여 해당 암반등급에 대해서는 충분한 학습이 진행되지 않은 것으로 판단된다.

Table 7은 예측값의 정밀도를 확인하기 위해 소수점 첫째자리 혹은 지보항목에 따라 소수점 둘째 자리까지 나타냈는데, 현장에서의 편의성을 고려하여 표현 단위를 조정하는 후처리 과정을 추가한다면 오차가 더욱 감소하게 될 것으로 판단된다.

Table 6. Input values chosen from test data to validate the A2 model

Input number	Rock type	Resistivity (Ω)	Depth (m)	Tunnel length (m)	Safety index		Tunnel type	Tunnel area (m ²)
					By tunnel length	By risk index		
1	Gneiss	3,570	161.12	2,563	2	1	Highway	110.58
2	Gneiss	9,590	159.15	2,714	2	1	Highway	111.23
3	Gneiss	2,840	502.40	1,710	2	2	National	79.09
4	Gneiss	1,501	123.58	861	3	2	Highway	110.58
5	Andesite	228	60.70	1,120	2	2	National	75.71

Table 7. Prediction results of A2 model

Type of data		Actual value					Predicted value					MAE (accuracy)				
Input number		1	2	3	4	5	1	2	3	4	5	-				
Rock grade by RMR		1	2	3	4	5	1.01	2.00	3.04	3.94	4.60	0.01	0	0.04	0.06	0.4
Shotcrete	Thickness	50	60	120	120	160	50.2	60.2	121.1	118.2	139.2	0.2	0.2	1.1	1.8	20.8
	Steel fiber	NU	U	U	U	U	NU	U	U	U	U	(1)	(1)	(1)	(1)	(1)
Rockbolt	Length	3	3	4	4	4	3.00	3.00	4.00	4.00	4.00	0	0	0	0	0
	Longitudinal spacing	0	3.5	2	1.5	1.2	0.03	3.5	2.12	1.53	1.24	0.03	0	0.12	0.03	0.04
	Lateral spacing	0	2	1.5	1.5	1.5	0.00	2.00	1.50	1.50	1.50	0	0	0	0	0
Steel support	Type	NU	NU	NU	LG	LG	NU	NU	NU	LG	LG	(1)	(1)	(1)	(1)	(1)
	Specific size	NU	NU	NU	LT2	LT3	NU	NU	NU	LT2	LT3	(1)	(1)	(1)	(1)	(1)
	Spacing	0	0	0	1.5	1.2	0.01	0.00	0.02	1.56	1.26	0.01	0	0.02	0.06	0.06
Concrete lining	Thickness	300	300	300	300	300	300.0	300.0	300.0	300.0	300.0	0	0	0	0	0
	Steel reinforcement	NU	NU	NU	U	U	NU	NU	NU	U	U	(1)	(1)	(1)	(1)	(1)

a) Not used: NU, Used: U, LG: Lattice Girder, LT2: Size type of lattice girder-50×20×30, LT3: Size type of lattice girder-70×20×30

5. 결론

본 연구에서는 물리탐사 자료 및 터널 제원 등을 종합적으로 고려하여 암반등급 및 지보재 제원을 예측할 수 있는 머신러닝 모델을 개발하였다. SVR 및 ANN 알고리즘을 기반으로 세 가지 예측모델을 학습시켜서 그 성능을 비교하였으며, 이와 같은 과정을 통해 도출된 결론은 아래와 같다.

1. 건설사업정보시스템(CALS) 및 설계사로부터 수집된 48개의 국내 도로 터널에 대한 터널설계보고서 및 지반 조사보고서를 기반으로 데이터를 수집하였으며, 암종, 전기비저항, 터널길이, 터널 단면적, 터널심도, 방재등급, 암반등급 및 각종 지보재의 제원을 포함한 총 19개의 데이터 항목을 정리하여 총 1,162개의 데이터셋을 구성하였다. 수집된 데이터셋을 활용하여 머신러닝 모델을 학습시킨 결과, 출력값의 데이터 형식에 따라 서로 다른 손실함수를 적용한 A2 모델에서 평균 0.50의 MAE 및 98%의 정확도로 가장 양호한 성능을 확인할 수 있었다.
2. 예측값의 정밀도를 확인하기 위해 최적의 성능을 보인 A2 모델에 5개의 시험데이터를 입력하여 그 출력값을 비교하였다. 그 결과 암반등급이 불량할수록 오차가 증가했는데, 이는 전체 데이터 대비 5등급 암반 조건의 데이터가 부족하기 때문인 것으로 판단된다. 이와 같은 데이터의 불균형은 암반등급 뿐만 아니라, 암종이나 데이터 수집지역 등의 측면에서도 존재하는데, 향후 5등급 암반의 설계 사례나 사암 및 셰일 지반에서의 설계 사례에 집중하여 데이터를 수집한다면 이러한 불균형을 완화시킬 수 있으며 지보설계에 대한 예측오차가 더욱 감소할 것으로 기대된다.
3. 지보패턴은 지반 상태에 따라 정형화 되어있으나, 암종, 심도, 방재등급 및 터널종류 등 다양한 요소에 따라 세부 제원에 약간의 차이가 발생한다. 본 연구에서 학습된 최종 모델을 활용한다면, 8개의 기초 데이터만으로도 48개의 설계사례에 기반한 암반등급 및 지보패턴을 신속하게 예측할 수 있다. 실제 지보패턴 설계를 완벽하게 수행하기에는 아직 부족함이 있으나, 기초설계 혹은 설계 이전에 개략적인 지보량을 초기 산정하는 경우 도움이 될 것으로 기대되며, 향후 실제 설계 시 다양한 활용을 통해 개선점을 도출하고 보완할 계획이다.

감사의 글

본 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 수행되었습니다(과제번호: RS-2021-KA163775, 빅데이터와 인공지능 기반의 발파굴착터널 자동설계기술 개발을 위한 기초연구). 이에 감사드립니다.

저자 기여도

이제점은 데이터 정리, 머신러닝 코드 개발, 결과분석 및 원고작성을 하였으며, 김양균은 연구개념 설계, 데이터 수집 및 정리를 하였고, 이승원은 총괄 검토를 하였다.

References

1. Carbonell, A., González-Vidoso, F., Víctor, Y. (2011), “Design of reinforced concrete road vaults by heuristic optimization”, *Advances in Engineering Software*, Vol. 42, No. 4, pp. 151-159.
2. Galende-Hernandez, M., Menendez, M., Fuente, M.J., Sainz-Palmero, G.I. (2018), “Monitor-while-drilling-based estimation of rock mass rating with computational intelligence: the case of tunnel excavation front”, *Automation in Construction*, Vol. 93, pp. 325-338.
3. Kang, K.N., An, J.S., Kim, B.C., Song, K.I. (2018), “Optimization of tunnel support patterns using DEA”, *Journal of Korean Tunnelling and Underground Space Association*, Vol. 20, No. 1, pp. 211-224.
4. Kim, B.C., Moon, H.K. (2016), “A study on the optimization technique for the plan of slope reinforcement arrangement of soil-nailing in tunnel portal area”, *Journal of Korean Tunnelling and Underground Space Association*, Vol. 18, No. 6, pp. 569-579.
5. Kim, J.Y., Seo, J.W., Kang, K.I. (2003). “A study on the selection model of retaining wall bearing methods using neural network”, *Journal of the Architectural of Korea Structure & Construction*, Vol. 19, No. 5, pp. 121-128.
6. Kim, M., Jung, J., Lee, J., Park, M., Bak, J., Lee, S.S. (2021), “Development and application of large-diameter cut-hole exploration system for assessment of the geological condition beyond NATM tunnel face”, *Tunnel and Underground Space*, Vol. 31, No. 1, pp. 1-9.
7. Kim, M.S., Lee, S.S. (2022), “Investigation of geological conditions beyond the excavation face using a MSP boring data monitoring system”, *International Journal of Rock Mechanics and Mining Sciences*, Vol. 157, 105161.
8. Kim, Y. (2021), “An analysis of artificial intelligence algorithms applied to rock engineering”, *Tunnel and Underground Space*, Vol. 31, No. 1, pp. 25-40.
9. Lee, J.K., Choi, W.H., Kim, Y., Lee, S.S. (2021), “A study on the rock mass classification in boreholes for a tunnel design using machine learning algorithms”, *Journal of Korean Tunnelling and Underground Space Association*, Vol. 23, No. 6, pp. 469-484.
10. MOLIT (2011), *Road design guideline (the chapter of tunnel)*, Ministry of Land, Infrastructure and Transport, Korea, pp. 606-3 - 606-4.
11. MOLIT (2022), *Yearbook of road bridge and tunnel statistics*, Ministry of Land, Infrastructure and Transport, Korea, pp. 13.
12. Rai, P., Schunesson, H., Lindqvist, P.A., Kumar, U. (2015), “An overview on measurement-while-drilling technique and its scope in excavation industry”, *Journal of The Institution of Engineers (India)*, Vol. 96, No. 1, pp. 57-66.
13. Shin, H.S., Kwon, Y.C. (2009), “Development of a window-shifting ANN training method for a quantitative rock classification in unsampled rock zone”, *Journal of Korean Tunnelling and Underground Space Association*, Vol. 11, No. 2, pp. 151-162.
14. Soranzo, E., Guardiani, C., Wu, W. (2022), “The application of reinforcement learning to NATM tunnel design”, *Underground Space (In Press)*, Vol. 7, No. 6, pp. 990-1002.