

머신러닝을 이용한 터널발파설계 자동화를 위한 기초연구

김양균¹ · 이제겸² · 이승원^{3*}

¹정회원, 한양대학교 자원환경공학과 연구교수

²정회원, 한양대학교 자원환경공학과 박사과정

³정회원, 한양대학교 자원환경공학과 교수

A fundamental study on the automation of tunnel blasting design using a machine learning model

Yangkyun Kim¹ · Je-Kyum Lee² · Sean Seungwon Lee^{3*}

¹Research Professor, Dept. of Earth Resources and Environmental Engineering, Hanyang University

²Ph.D. Student, 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

As many tunnels generally have been constructed, various experiences and techniques have been accumulated for tunnel design as well as tunnel construction. Hence, there are not a few cases that, for some usual tunnel design works, it is sufficient to perform the design by only modifying or supplementing previous similar design cases unless a tunnel has a unique structure or in geological conditions. In particular, for a tunnel blast design, it is reasonable to refer to previous similar design cases because the blast design in the stage of design is a preliminary design, considering that it is general to perform additional blast design through test blasts prior to the start of tunnel excavation. Meanwhile, entering the industry 4.0 era, artificial intelligence (AI) of which availability is surging across whole industry sector is broadly utilized to tunnel and blasting. For a drill and blast tunnel, AI is mainly applied for the estimation of blast vibration and rock mass classification, etc. however, there are few cases where it is applied to blast pattern design. Thus, this study attempts to automate tunnel blast design by means of machine learning, a branch of artificial intelligence. For this, the data related to a blast design was collected from 25 tunnel design reports for learning as well as 2 additional reports for the test, and from which 4 design parameters, i.e., rock mass class, road type and cross sectional area of upper section as well as bench section as input data as well as 16 design elements, i.e., blast cut type, specific charge, the number of drill holes, and spacing and burden for each blast hole group, etc. as output. Based on this design data,

OPEN ACCESS

Journal of Korean Tunnelling and
Underground Space Association
24(5)431-449(2022)
<https://doi.org/10.9711/KTAJ.2022.24.5.431>

eISSN: 2287-4747
pISSN: 2233-8292

Received August 9, 2022

Revised September 13, 2022

Accepted September 13, 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

www.kci.go.kr

three machine learning models, i.e., XGBoost, ANN, SVM, were tested and XGBoost was chosen as the best model and the results show a generally similar trend to an actual design when assumed design parameters were input. It is not enough yet to perform the whole blast design using the results from this study, however, it is planned that additional studies will be carried out to make it possible to put it to practical use after collecting more sufficient blast design data and supplementing detailed machine learning processes.

Keywords: Tunnel design, Tunnel blast, Blast design, Machine learning, NATM

초 록

지금까지 국내에서는 수많은 터널들이 완공되어 오면서 시공에서뿐 아니라 설계에서도 다양한 경험과 기술이 지속적으로 축적되어 왔다. 따라서 이제는 매우 복잡한 지질조건 또는 특수한 터널구조가 아니라면 일반적인 터널설계작업은 설계 항목에 따라 기존 유사 설계사례를 수정 또는 보완하는 것만으로도 충분한 경우도 적지 않다. 특히 터널발파설계의 경우, 실제 터널시공시 현장에서 시험발파를 통해 시공을 위한 발파설계를 추가로 수행하는 것이 일반적이라는 것을 감안할 때, 설계단계에서 수행하는 발파설계는 예비설계 성격을 지니고 있어 기존의 유사 설계사례를 참고하는 것도 타당하다고 사료된다. 한편 최근 4차산업혁명시대에 들어서면서 전 산업분야에 걸쳐 그 활용도가 급증하고 있는 인공지능은 터널 및 발파분야에서도 다양하게 활용되고 있지만, 발파터널의 경우 발파진동 및 암반분류 등의 예측 분야에서 주로 활용되고 있을 뿐 터널발파패턴 설계에 활용된 사례는 많지 않다. 따라서 본 연구에서는 터널발파설계를 인공지능의 한 분야인 머신러닝 모델을 이용하여 자동화하기 위한 시도를 하였다. 이를 위하여 25개 학습용 터널설계 자료 및 2개의 시험용 설계자료에서 4가지의 입력데이터(지보패턴, 도로유형, 상반 및 하반 단면적) 및 16개의 출력데이터(심발공 종류, 비장약량, 천공수, 각 발파공 그룹별 공간격과 저항선 등)를 발췌하였다. 이를 기반으로 3가지 머신러닝 모델, 즉, XGBoost, ANN, SVM 모델을 시험한 결과 XGBoost 모델이 상대적으로 최상의 결과를 나타내었다. 또한 이를 이용하여 실제 발파 설계 상황을 가정하여 발파패턴을 제안하도록 한 결과 일부 항목에서 보완이 필요하긴 하지만 일반적 설계와 유사한 결과를 나타내었다. 본 연구가 기초연구 성격이어서 전체 발파설계를 완벽하게 수행하기는 아직 부족하지만, 향후 충분한 발파설계데이터를 확보하고 세부적인 처리과정을 보완하여 실용적인 활용이 가능하도록 추가 연구를 수행할 계획이다.

주요어: 터널설계, 터널발파, 발파설계, 머신러닝, 발파굴착터널

1. 서론

국토의 70%가 산악지대로 이루어진 국내 지형적 특성상, 도로 및 철도와 같은 사회간접시설 확충을 위해서는 터널건설이 필수적이다. 이에 따라 터널건설의 수요도 지속적으로 증가 또는 유지되고 있으며, 2020년을 기준으로 국내의 도로 및 철도 터널은 총 3,526개소, 총연장은 3,062.3 km이 건설되었으며, 최근 10년간 연평균 131개소, 159.6 km의 도로 및 철도 터널이 준공되었다(MOLIT Statistics System, 2021a; 2021b).

발파굴착(NATM)터널에 있어서 터널발파는 암반을 실제로 굴착해서 공간을 만들어 준다는 점에서, 그리고 시간적 측면에서 전체 터널 시공과정 중 상당히 중요한 비중을 차지한다. Kim and Bruland (2015)는 노르웨이와

국내 터널에서의 천공, 장약 및 발파, 환기, 버력처리, 부석정리, 슛크리트타설, 그리고 록볼트 타설로 반복되는 터널굴착 사이클(cycle)에 대한 시공시간 비교 분석을 통해, 국내 2개 터널현장에서 마킹, 천공, 장약 및 발파, 환기로 이루어지는 터널발파작업이 전체 사이클 시간(cycle time)에서 평균 42.5%를 차지했다고 보고한 바 있다.

경제적이고 안전한 터널 시공을 위해서는 설계부터 최적화되어야 한다. 지금까지 국내에서는 수 많은 NATM 터널을 설계해오면서 이에 대한 경험과 기술이 축적되고 발전되어 왔기에 이제 터널설계 중 일부 항목은 기존 유사 설계사례를 수정 또는 보완하는 것만으로도 충분한 경우도 적지 않다. 특히 발파설계의 경우, 실제 터널시공시 현장에서 사전 시험발파를 통해 발파결과에 영향을 미치는 여러가지 요소들을 상세하게 파악할 수 있기에 터널 설계단계에서 수행하는 발파설계는 예비설계 성격을 가지고 있어 기존의 양호한 유사사례를 참고하는 것도 타당하다고 사료된다.

본 논문에서는 이렇게 단순 작업화되고 있는 터널발파설계, 특히 발파패턴 설계를 인력이 아닌 인공지능의 한 분야인 머신러닝기법을 이용하여 자동화할 수 있는 기초연구를 수행한 결과를 정리하였다. 이를 위해 25개 도로 터널 설계보고서에서 125개의 발파설계데이터를 수집하였고, 머신러닝에서 가장 일반적으로 활용된다고 판단되는 3가지 알고리즘으로 분석하였다.

2. 문헌고찰

2.1 터널발파설계

건설산업은 타 산업 대비 낮은 생산성, 다양한 분야 전문가의 경험과 지식 요구, 프로젝트 수행단계에 내재된 많은 불확실성 등의 특성으로 4차 산업혁명을 통한 생산 프로세스의 혁신 및 가치 창출 가능성이 매우 높은 분야라고 할 수 있다(Ahn and Kim, 2017). 이에 따라 건설산업에서도 4차 산업혁명 관련 기술 접목을 통한 건설기술 및 프로세스 혁신이 중요한 현안으로 대두되고 있으며, 정부도 건설의 생산성, 안전성, 경제성을 혁신시키기 위해 다양한 스마트 건설기술의 개발 및 활용을 독려하고 있는 상황이다.

4차산업혁명시대에 들어서면서 전 산업분야에 걸쳐 그 활용도가 급증하고 있는 인공지능은 터널 및 발파분야, 특히 암반분류와 암석파열 예측을 위해 다양하게 활용되고 있다(Kim, 2021). 그러나 Langefors and Kihlström (1967) 및 Olofsson (1990) 등이 제안한 설계방식이 국내 실정에 맞게 지속적으로 수정 적용되어 온 터널발파패턴 설계와 관련하여 적용된 사례는 많지 않다. Choi (2005)는 터널발파설계를 자동화하기 위하여 발파패턴에 대한 설계식을 제안한 바 있으며, Choi et al. (2009)은 사전에 결정된 비장약량이 있는 경우 그 비장약량에 맞추어서 터널발파를 설계할 수 있는 경험적 설계방법인 비장약량 맞춤형 터널설계방법을 제안하였다. Jang and Topal (2013) 터널발파로 인해 발생하는 여굴을 예측하기 위해 비선형 다중회귀분석과 인공신경망을 적용하였으며, Lee (2016)는 터널발파진동의 크기를 예측하기 위하여 인공신경망(ANN)을, 굴진장과 장약계수를 최적화하기 위하여 유전자 알고리즘(Genetic algorithm) 이용하는 연구를 수행하였다.

한편 Hafner et al. (2019)은 도심지 터널중단선형을 설계하기 위해 인공지능(artificial intelligence, AI)과 BIM (Building Information Modeling)기술을 적용하였으며, Trivedi et al. (2014)은 발파진동, 폭풍압, 비석, 발파암의 파쇄 등의 예측에 적용된 인공신경망(Artificial Neural Network, ANN) 사례 및 향후 전망을 평가한 바 있다. 또한 Wu et al. (2020)은 광산터널발파설계를 위한 데이터베이스 기반 지능형 설계시스템을 개발하여 심발공 및 발파패턴 등을 설계하도록 하였는데, 이 데이터베이스 내부의 데이터 검색규칙을 결정하기 위해 T-S fuzzy 신경망을 사용하였다. Alipour et al. (2021)은 터널발파시 필요한 비장약량을 예측하기 위하여 SVM (Support Vector Machine)알고리즘을 적용하였는데, 암질지수(RQD), 일축압축강도, 터널굴착단면적, 천공장, 커플링비(coupling ratio)를 입력데이터로 하였다. 최근 Soranzo et al. (2022)은 강화학습(reinforced learning)과 유한차분법(finite difference method)을 이용하여 최적의 터널 지보패턴을 선정하는 연구를 수행하였다.

2.2 터널발파설계 규정 및 주요 설계인자

국가건설기준인 국토교통부 터널굴착(MOLIT, 2016)편에서는 발파설계시, ① 굴착 단면의 크기 및 형상 ② 굴진장 ③ 심발형식 ④ 심발공, 발파공 및 주변공의 직경, 배치, 각도 및 천공 깊이 ⑤ 화약의 종류와 장약량 ⑥ 뇌관의 형식 ⑦ 점화 및 기폭 순서 ⑧ 현장 시험발파 계획을 포함하도록 규정하고 있다. 이와 관련하여 본 연구에서는 상기의 항목 중 발파패턴 설계와 직접적인 관련이 있는 굴진장, 심발형식, 심발공 및 발파공의 배치, 천공깊이, 장약량에 분석대상으로 하였다. 참고로 굴착단면의 크기 및 형상은 발파설계 이전 굴착단면설계단계에서 이루어지므로 본 연구에서는 제외하였고, 터널발파시 발파공의 직경은 45 mm, 화약의 종류는 에멀전폭약, 뇌관은 비전기식 뇌관이 국내에서는 일반적으로 사용되고 있다.

2.3 머신러닝 알고리즘

본 연구 수행의 핵심 수단인 머신러닝(machine learning)은 학자들 또는 전문가들마다 약간씩 다르게 정의하고 있지만, 머신러닝 발전에 큰 기여를 해온 Mitchell (1997)은 컴퓨터 프로그램이 성능지표에 의해 측정되는 어떠한 작업을 수행할 때 경험이 축적되면서 성능이 향상된다면, 컴퓨터프로그램은 그 작업 및 성능지표와 관련된 경험으로부터 학습된다고 할 수 있는데, 이 과정을 머신러닝이라 정의하였다. 머신러닝은 학습종류, 과정 및 방법에 따라 지도학습(supervised learning), 비지도학습(unsupervised learning), 강화학습(reinforcement learning), 앙상블학습(ensemble learning), 인공신경망 및 심화학습(neural networks and deep learning)으로 구분할 수 있지만, 응용방법에 따라 상호 간에 연관되어 있다. 또한 각각의 학습방법은 그 원리 및 구조 등에 따라 다양한 세부 알고리즘으로 구분할 수 있는데, 대다수의 암반 및 터널분야 연구에서는 Random forest, 주성분분석(PCA), Ensemble 등과 같은 머신러닝 기법도 많이 활용되고 있지만, 가장 많이 적용되고 있는 알고리즘은 인공신경망(ANN)인 것으로 나타났다(Kim, 2021). 본 연구에 활용된 3가지 알고리즘에 대한 개요는 다음과 같다.

2.3.1 SVM (Support Vector Machine)

SVM은 기본적으로 데이터를 두 개의 그룹으로 분리하는 기법으로 이를 위해 먼저 데이터들과 거리가 가장 먼 초평면(hyperplane)을 설정한다. 이후 분류되지 않은 새로운 점이 나타나면 초평면의 어느 쪽에 속하는지 판별해서 분류하게 된다(Fig. 1). 일반적으로 서포트 벡터(support vector)를 이용하여 서로 다른 변수들을 구분하기 위한 목적으로 사용되지만, 반대로 서포트 벡터의 간격 안에 최대한 많은 데이터들이 들어가도록 학습할 경우 회귀 목적으로 사용될 수 있다.

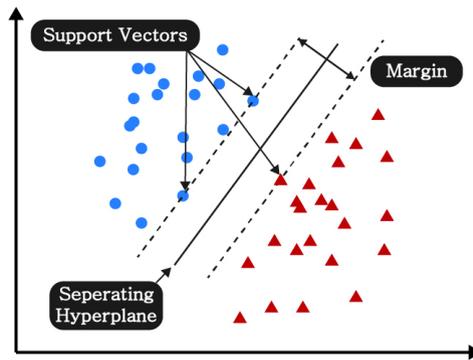


Fig. 1. Typical example of SVM (Lee et al., 2021)

2.3.2 ANN (Artificial Neural Network)

ANN은 두뇌의 정보 처리 과정을 모방해서 만든 알고리즘이다. 입력층과 출력층 사이에 다수의 은닉층을 나열하고, 각각의 은닉층에 다수의 노드를 배치하여 구성하게 된다(Fig. 2). 모델 구조, 학습하는 방법 및 조건에 따라서 학습효과의 차이가 발생한다.

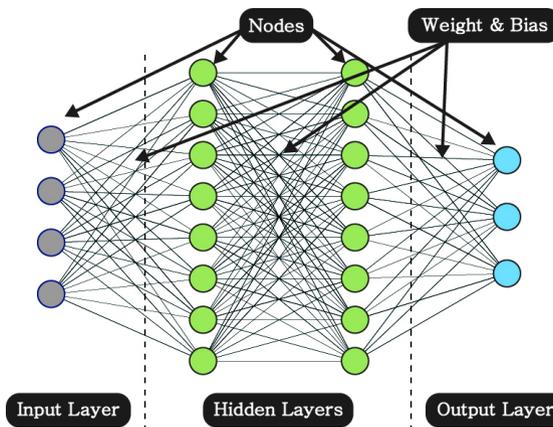


Fig. 2. Typical example of ANN (Lee et al., 2021)

2.3.3 XGboost

여러 개의 분류기(모델)를 생성해 예측 결과들을 결합함으로써 한 개의 모델을 사용할때보다 더 정확한 예측 값을 도출하는 방법을 앙상블(ensemble) 기법이라 한다. XGBoost (Fig. 3)와 Random forest이 대표적인 알고리즘이며, XGBoost는 여러 개의 분류기가 순차적으로 학습을 수행하며 다음 분류기에 가중치를 부여하면서 학습과 예측을 수행한다.

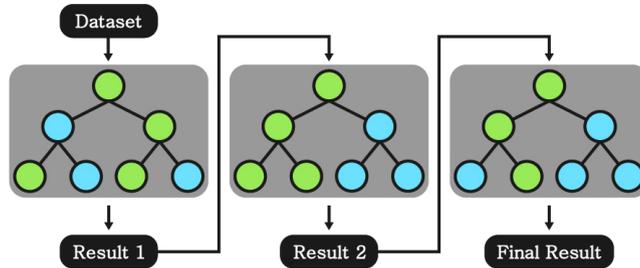


Fig. 3. Typical example of XGBoost (Lee et al., 2021)

3. 연구 방법

본 연구는 머신러닝 모델을 이용하여 기존에 인력으로 수행하던 터널발파설계를 자동화하기 위한 기초작업을 수행하는 것이다. 이를 위해 먼저 터널설계보고서 등 관련자료를 수집하여 머신러닝에 필요한 데이터를 선별하고

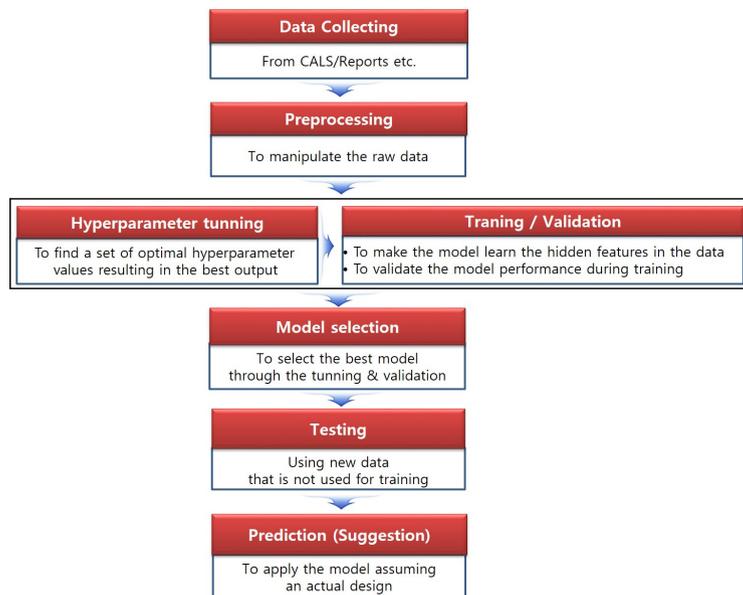


Fig. 4. Process to perform to the study

정리하였다. 또한 다양한 머신러닝 알고리즘 중에서 터널과 발파분야에서 일반적으로 활용되는 알고리즘 3가지 중에서, 정리된 데이터를 기반으로 최상의 결과를 도출하기 위한 각 알고리즘 내부의 다양한 파라미터를 설정하는 초매개변수 조정(hyperparameter tuning)과 학습(training)과 검증(validation)과정을 거쳐 본 연구목적에 적합한 최종 머신러닝 모델을 선정하였다. 이렇게 선정된 최종 모델을 이용하여 학습 및 검증에서 사용되지 않은 새로운 데이터를 이용해서 시험(test)과정을 거쳐 실제 설계보고서에서 추출한 설계데이터를 이용하여 다양한 발파 설계패턴을 예측하는 과정을 거쳤다(Fig. 4).

3.1 데이터 수집 및 정리

본 연구를 위해 국토교통부 건설CAL시스템(Construction CALS, 2022) 및 설계사 등을 통해 국내 도로 터널 25개소에 대한 터널설계자료를 수집하였다(Table 1). 수집된 자료는 터널설계보고서, 지반(토질)조사보고서, 터널설계도면, 그리고 수량산출서 4종류이며, 이 자료들에서 설계연도, 터널명, 도로유형, 위치, 터널연장, 암종, 지보패턴별 발파공수 및 발파패턴 등 총 39가지 세부항목에 대한 데이터를 조사하여 1차 정리하였다.

Table 1. Summary of the design projects to be analyzed for the study

No.	Tunnel name	Road type	Tunnel length (m)	Tunnel cross section area (m ²)	Bed rock	Blast cut type
1	Maryongjae	Local	1,300	82.205	Andesite	Cylinder-cut/V-cut
2	Hoenamjae	Local	1,710	79.088	Gneiss	Cylinder-cut/V-cut
3	Kunnae	Local	2,715	82.064	Gneiss	Cylinder-cut/V-cut
4	Hanti	National	470	67.963	Breccia	Cylinder-cut/V-cut
5	Jukjang 1	National	762	87.379	Breccia	Cylinder-cut/V-cut
6	Jukjang 2	National	974	87.919	Breccia	Cylinder-cut/V-cut
7	Masa	National	853	68.261	Shale	Cylinder-cut/V-cut
8	Kigok	National	571	89.653	Gneiss	Cylinder-cut/V-cut
9	Sindo	National	1,120	75.714	Andesite	Cylinder-cut/V-cut
10	Samun	Local	292	70.267	Limestone	Cylinder-cut/V-cut
11	Yeoncho 1	Local	767	67.072	Andesite	Cylinder-cut/V-cut
12	Yeoncho 2	Local	1,250	74.108	Andesite	Cylinder-cut/V-cut
13	Daegokchi B	Local	985	71.158	Diorite	Cylinder-cut/V-cut
14	Hahul	Local	540	76.541	Andesite	Cylinder-cut/V-cut
15	Jangyeon	National	325	76.683	Porphyry	Cylinder-cut/V-cut
16	Whadong	National	500	78.683	Granite	Cylinder-cut/V-cut
17	Myeongjin	Local	1,585	82.002	Andesite	Cylinder-cut/V-cut
18	Unmun	Local	1,870	76.032	Andesite	Cylinder-cut/V-cut
19	Ungdong	National	2,117	79.205	Andesite	Supex cut

Table 1. Summary of the design projects to be analyzed for the study (continued)

No.	Tunnel name	Road type	Tunnel length (m)	Tunnel cross section area (m ²)	Bed rock	Blast cut type
20	Keungok	National	705	75.626	Andesite	Supex cut
21	Songkwangsa2	National	2,010	80.602	Gneiss	Cylinder-cut/V-cut
22	Choenhosan	National	1,250	69.938	Diorite	Cylinder-cut/V-cut
23	Maan	Highway	3,871	91.025	Gneiss	Cylinder-cut/V-cut
24	Yangseo	Highway	3,384	89.543	Gneiss	Cylinder-cut/V-cut
25	Maebong	Highway	383	83.463	Gneiss	Cylinder-cut/V-cut

일반적으로 터널발파설계는 터널의 단면적, 지보패턴(또는 암반등급), 국도 및 고속국도 등과 같은 도로유형, 그리고 주변 보안물건 상황에 따라 발파패턴이 변화를 하게 되는데, 본 연구는 기초단계여서 보안물건까지 고려할 수 없기에 이를 제외한 나머지 4가지 항목(터널상반(또는 전단면) 단면적, 하반 단면적, 지보패턴, 도로유형)를 입력데이터로 선정하였고, 발파설계의 대상이 되는 심발공법 종류, 발파공수, 장약량, 공간격 및 저항선과 같은 총 16개 데이터를 출력데이터로 선별하였다(Fig. 5, Table 2). 단위 면적당 천공수(Number of charge holes per cross sectional area)는 1발파당 발파공수(심발공 제외)를 터널 단면적으로 나누어 계산할 수 있고, 비장약량(specific charge)은 1발파당 총장약량을 터널단면적 및 굴진장으로 나누어 계산할 수 있다.

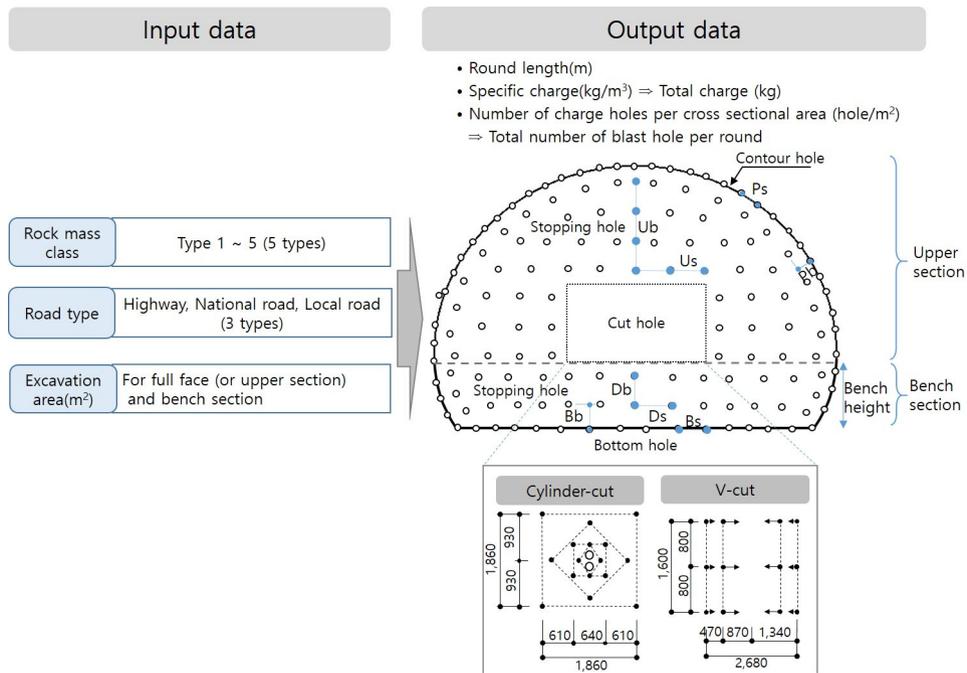


Fig. 5. Input and output data

Table 2. Details of output data

Section	Round length (m)	Bench height (m)	Cut type	Number of charge holes per area (h/m^2)	Specific charge (kg/m^3)	Spacing (cm)		Burden (cm)	
						Stopping (Us)	Contour (Ps)	Stopping (Db)	Bottom (Bb)
Full or upper	①	-	④	⑤	⑦	⑨	⑪	⑬	⑮
Bench	②	③	-	⑥	⑧	⑩	⑫	⑭	⑯

최종 선별된 출력데이터 중 주요 설계패턴 항목에 대한 데이터 분포는 Figs. 6~9과 같다. 전체 터널단면에 대한 발파공수를 계산하기 위한 단위면적당 발파공수는 Fig. 6과 같으며, 지보패턴 Type 1 및 Type 2에서는 1.2~1.4공/ m^2 이 64%를 차지하고 있으나 Type 3 및 Type 4에서는 1.4~1.6공/ m^2 의 비율이 각각 68% 및 48%, Type 5에서는 1.6~1.8공/ m^2 이 32%로 가장 높은 비중을 차지하고 있는 것으로 나타났다. 이를 지보패턴(암반등급)별로 정리하면 Fig. 6(e)에 나타난 대로 Type 1에서 Type 5로 갈수록 단위면적당 평균 발파공수는 1.39공/ m^2 에서 1.82공/ m^2 으로 점차 증가하고 있는데, 이것은 암질이 불량해질수록 천공장과 공당장약량은 감소시키고 천공수는 증가시키는 일반적인 설계 및 시공패턴이 그대로 적용되었다고 할 수 있다.

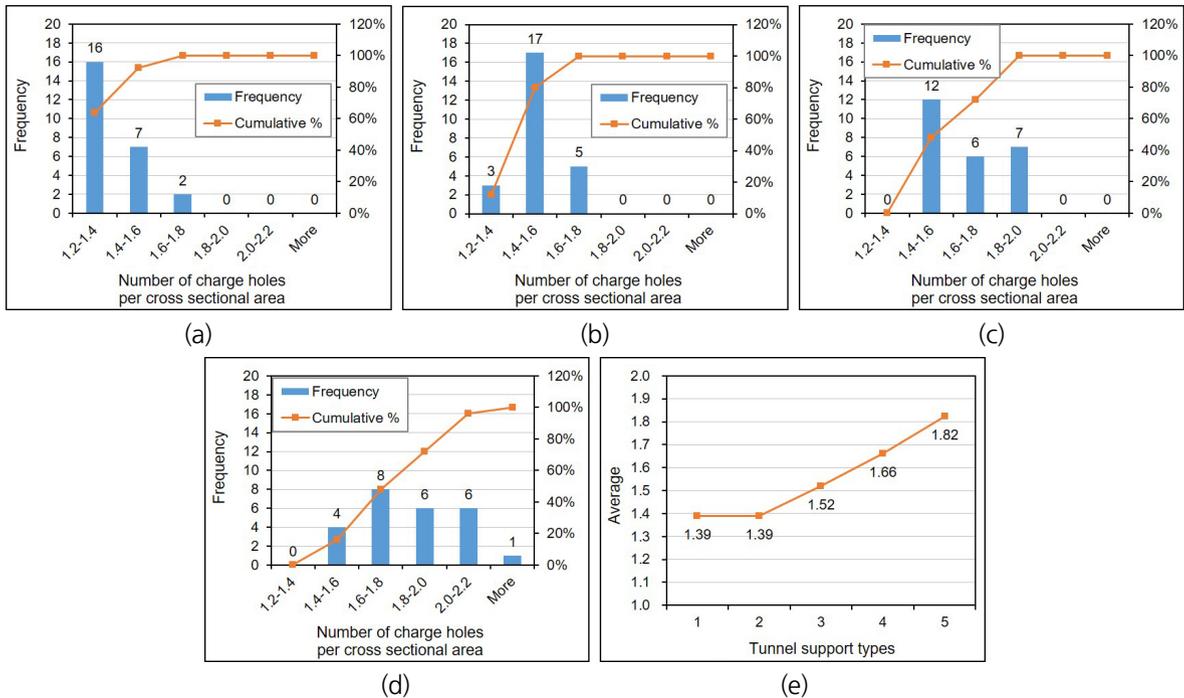


Fig. 6. Number of charge holes per cross sectional area: (a) Type 1 and 2, (b) Type 3, (c) Type 4, (d) Type 5, (e) Average with tunnel support types

적정 장약량 산정의 기준이 되는 비장약량은 Type 1 및 Type 2에서는 1.0~1.1 kg/m³ 구간이 56%, Type 3에서는 0.9~1.0 kg/m³ 구간이 56%로 가장 높은 비율을 차지하는 것으로 나타났다(Fig. 7). 또한 지보타입별 평균 비장약량은 1.07 kg/m³인 Type 1 및 Type 2의 경우에 비해 Type 5에서는 0.87 kg/m³로 18.7% 감소하는 것으로 나타났는데, 이것은 암질이 불량할수록 장약량을 감소시키는 일반적인 발파원리가 적용된 것이라고 할 수 있다.

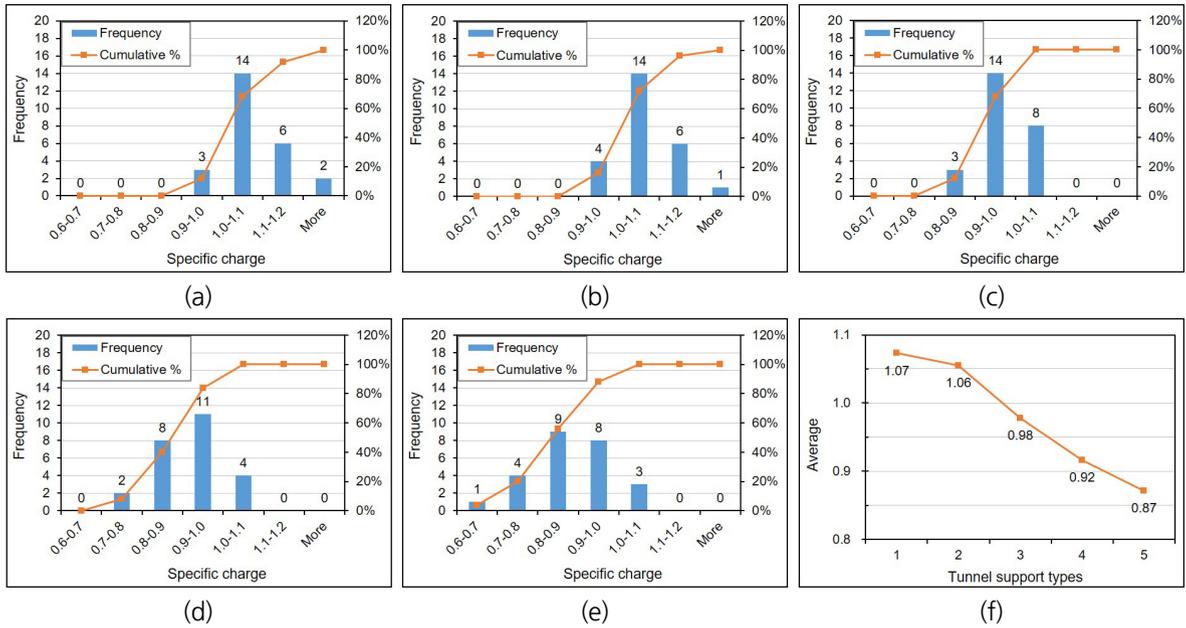


Fig. 7. Specific charge: (a) Type 1, (b) Type 2, (c) Type 3, (d) Type 4, (e) Type 5, (f) Average with tunnel support types

터널발파의 성패를 좌우하는 심발공의 경우, Fig. 8에 나타난 바와 같이 2 m 이상의 비교적 장공을 전단면으로 발파하는 Type 1~3에서는 Cylinder-cut이, 상하반 분할굴착으로 상반이 대체로 2 m 이하의 굴진이 이루어지는 Type 4 및 Type 5에서는 V-cut이 일반적으로 적용되고 있다.

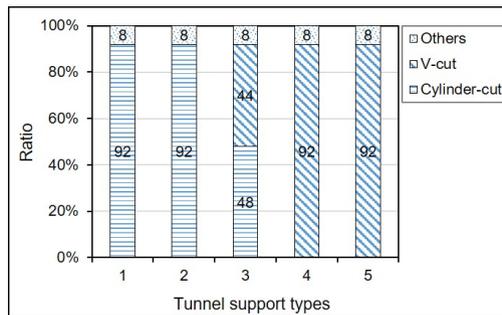


Fig. 8. Ratios of blast cut types with tunnel support types

한편 발파공 배치 간격의 기준이 되는 공간격과 저항선은, 상반 중간공 공간격의 경우 Type 1 및 Type 2에서는 1,000~1,100 mm가 일반적(25%-75%)이었으며, Type 5에서는 850~1,000 mm까지로 다른 지보타입에 비해 상대적으로 적용 범위가 넓었다(Fig. 9(a)). 상반 중간공 저항선의 경우는 Type 1에서는 일반적인 수준이 870~1,000 mm이지만 암질이 불량해 질수록 감소하여 Type 4에서는 730~800 mm로 나타났다.

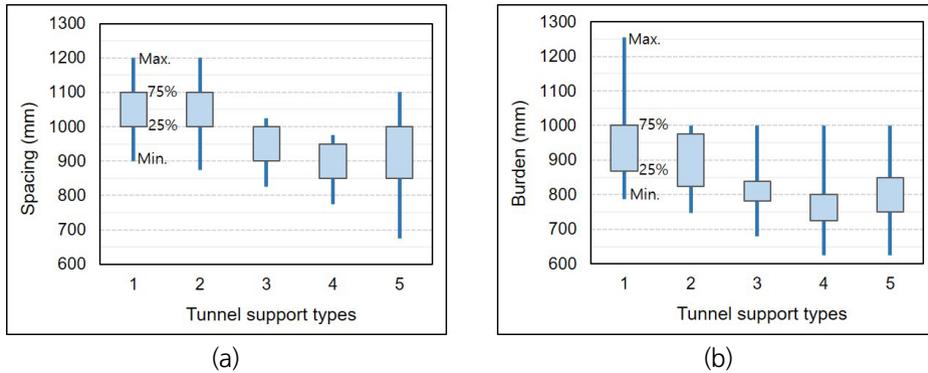


Fig. 9. Ranges of spacing and burden for stopping holes with tunnel support types

3.2 초매개변수 조정

머신러닝이란 주어진 데이터를 학습한 후 새로운 데이터가 입력시 가능하면 정확하게 어떠한 결과를 예측하거나 분류하는 과정이다. 이를 위해서는 사용하고자 하는 알고리즘이 최상의 예측성능을 도출하기 위한 상태로 설정되어 있어야 하며 이 과정을 초매개변수 조정(hyperparameter tuning)이라고 한다.

본 연구에서는 2.3장에서 기술한 3개의 머신러닝 알고리즘 중에서 최상의 결과를 도출하는 모델을 선정하여 적용하게 되는데, 이를 위해 동일한 데이터에 대하여 각 알고리즘의 초매개변수 조정을 실시하였다.

Table 3에 제시된 바와 같이, SVM의 초매개변수는 생성되는 경계선의 간격(C) 및 데이터 구분을 위한 커널(kernel) 등이며, ANN의 경우는 은닉층의 개수(layer number), 각 은닉층별 노드의 개수(node number)와 같은 모델구조와 활성화함수의 종류(activation function), 손실함수의 종류(loss function) 등이다. XGboost는 사용하는 모델의 개수(n estimators), 개별 모델 학습 시 사용하는 데이터의 수(subsample) 등이다.

Table 3. Hyperparameters for each algorithm

Algorithm	Hyperparameter	Description	Selected value
SVM	C	Tolerance of data misclassification	10
	Gamma	To determine the distance of the data sample to influence	0.01
	Kernel	To select a method of mapping data in an input space into a high-dimensional space which is capable of linear classification	Rbf

Table 3. Hyperparameters for each algorithm (continued)

Algorithm	Hyperparameter	Description	Selected value
ANN	Number of hidden layer	Number of layers placed between input layer and output layer	3
	Number of node	Number of nodes to place in the hidden layer	16, 32,32
	Activation function	To select the way to activate nodes	Relu
	Loss function	To select the way to calculate the difference between model output and actual value	MSE
	Optimizer	To select the way to update the weight and bias	Adam
	Dropout rate	To set the ratio of nodes to be dropped out	0.2
	Learning rate	To control the degree of learning	0.001
XGBoost	N estimators	Number of DT model to create	250
	Max depth	Maximum number of branching for each DT model	1
	Subsample	Ratio of data to use for training each model	0.2
	Learning rate	To control the degree of learning	0.1

3.3 알고리즘 학습 및 검증

3.1장과 같이 정리된 데이터는 알고리즘의 학습(train) 및 검증(validation)을 위해 일정한 비율로 분할 하는데, 경우에 따라서는 선정된 검증 데이터의 편향때문에 평가결과의 신뢰성이 저하될 수 있다. 이러한 단점을 보완하고자 수행하는 것이 k-fold 교차 검증(cross validation)이며 본 연구에서는 전체 데이터를 3개의 소 데이터셋으로 분할하고, 각각의 소 데이터셋들을 최소 한 번씩 돌아가면서 검증(validation) 데이터로 사용하도록 하였다. 이렇게 수행된 과정을 거쳐서 도출된 각 출력인자(설계패턴)별 모델의 성능은, 범주형 데이터인 심발공법의 경우 정확도(accuracy)로, 나머지 숫자형 데이터인 발파패턴의 경우는 평균절대백분율오차(mean absolute percentage error, MAPE)로 나타냈다(Table 4).

Table 4. Accuracy or mean absolute percentage error for validation data

Algorithm		XGBoost (%)	ANN (%)	SVM (%)	Type of performance measure	
Full section or Upper section	Blast cut type	87.8	78	87.8	Accuracy	
	Round length (m)	4.4	2.9	5	MAPE	
	No. of charge holes per area (h/m ²)	5.2	5.1	6.3	MAPE	
	Specific charge (kg/m ³)	6.5	5.2	6.9	MAPE	
	Stopping hole	Spacing (mm)	4	4.5	5.3	MAPE
		Burden (mm)	6.7	6.3	6.5	MAPE
	Contour hole	Spacing (mm)	2.3	2.5	2.3	MAPE
		Burden (mm)	4.5	3.4	3.1	MAPE

Table 4. Accuracy or mean absolute percentage error for validation data (continued)

Algorithm		XGBoost (%)	ANN (%)	SVM (%)	Type of performance measure	
Bench section	Bench height (m)	12.8	5.7	11.4	MAPE	
	Round length (m)	0.1	2.3	7	MAPE	
	No. of charge holes per area (h/m ²)	15.4	13.8	12.8	MAPE	
	Specific charge (kg/m ³)	13.4	13.2	9.7	MAPE	
	Stopping hole	Spacing (mm)	8.9	10	9.4	MAPE
		Burden (mm)	18.5	15.9	10.3	MAPE
	Bottom hole	Spacing (mm)	8.4	6.8	9.7	MAPE
		Burden (mm)	11.8	11.6	8.2	MAPE
Average MAPE (except blast cut type)		8.2	7.3	7.6	MAPE	

검증결과, 심발공 종류의 경우 정확도 단위로 나타난 XGBoost과 SVM모델이 87.8%, ANN이 78%로 나타났고, 나머지 15개 설계항목의 경우 3가지 모델에서 대체로 양호한 수준인 7.3%-8.2%사이로 그 차이가 크지 않았다.

4. 결과 및 분석

4.1 시험데이터를 이용한 모델 오차율 평가

3.3장에서와 같이 학습된 3가지 모델에 학습에 사용되지 않은 새로운 터널발파설계 데이터를 입력하여 모델에서 제안된 패턴과 실제 설계된 패턴과의 오차를 비교하였다. 이때 입력된 데이터는 국도 2개소의 터널설계도서에서 수집된 발파패턴관련 다양한 설계요소(Table 5)이며, 터널 A는 대면터널, B는 병설터널이다.

대면터널인 터널 A의 터널 단면적은 전단면인 경우 102 m², 터널 B는 82.9 m²이며, 설계굴진장은 터널 A는 지보패턴 Type 1인 경우 3.5 m, 터널 B는 4.0 m로 설계되어 있다.

Table 5. Details of two tunnels used for test data

Tunnel	Name	A					B				
	Length (m)	364					2,730				
	Location	Jeollanamdo, Yeosu					Jeollanamdo, Haenam				
Road type		National road					National road				
Rock support type		Type 1	Type 2	Type 3	Type 4	Type 5	Type 1	Type 2	Type 3	Type 4	Type 5
Cross sectional area (m ²)	Full section/Upper section	102.3	102.3	103.1	69.6	70.5	82.9	82.9	83.8	64.9	65.7
	Bench section	-	-	-	34.6	34.8	-	-	-	19.6	19.7

Table 5. Details of two tunnels used for test data (continued)

	Blast cut type		Cylinder-cut			V-cut		Cylinder-cut			V-cut	
	Full section or Upper section	Round length (m)		3.5	3.5	2.0	1.5	1.2	4.0	3.5	2.5	1.5
No. of charge holes per area (h/m ²)		1.36	1.36	1.52	1.84	1.96	1.30	1.22	1.50	1.77	1.96	
Specific charge (kg/m ³)		1.04	1.02	0.92	0.95	0.87	1.16	1.06	0.96	0.92	0.88	
Stopping hole		Spacing (mm)	1,050	1,050	1,000	900	900	1,100	1,100	950	850	800
		Burden (mm)	975	975	900	875	800	1,050	950	950	850	775
Contour hole		Spacing (mm)	700	700	650	600	600	650	650	600	600	550
		Burden (mm)	875	875	800	750	750	800	800	750	750	700
Bench section		Bench height (m)		-	-	-	2.21	2.21	-	-	-	1.38
	Round length (m)		-	-	-	3.0	1.2	-	-	-	3.0	2.4
	No. of charge holes per area (h/m ²)		-	-	-	1.42	1.58	-	-	-	1.58	1.83
	Specific charge (kg/m ³)		-	-	-	0.72	0.70	-	-	-	0.96	0.84
	Stopping hole	Spacing (mm)	-	-	-	1,200	950	-	-	-	1,314	992
		Burden (mm)	-	-	-	850	800	-	-	-	640	640
	Bottom hole	Spacing (mm)	-	-	-	900	800	-	-	-	900	800
		Burden (mm)	-	-	-	550	550	-	-	-	650	640

Table 5에 나타난 도로유형, 지보패턴, 상반(전단면) 및 하반 단면적 등 4가지 설계항목을 모델에 입력하였을 경우, 나타난 발파패턴 세부 항목별 예측 오차율을 Table 6에 나타내었다. 전체 16가지 설계항목 중, 범주형 데이터여서 정확도로 그 성능을 나타내는 심발공 종류를 제외한 나머지 15가지 항목에 대한 각 오차율을 평균한 결과, XGBoost, ANN, SVM 모델 각각 10.8%, 11.2%, 13.9%로 나타나 XGBoost 모델이 학습 및 검증데이터가 사용되지 않은 실제 상황에서 새로운 데이터가 입력시 오차가 가장 적을 것으로 판단되었다. 또한 MAPE가 10.8%

Table 6. Accuracy or MAPE for test data

Algorithm		XGBoost (%)	ANN (%)	SVM (%)	Type of performance measure	
Full section or Upper section	Blast cut type	60	50	60	Accuracy	
	Round length (m)	5.9	5.9	7.0	MAPE	
	No. of charge holes per area (h/m ²)	7.4	10.7	8.5	MAPE	
	Specific charge (kg/m ³)	5.2	6.7	4.6	MAPE	
	Stopping hole	Spacing (mm)	6.1	6.3	5.4	MAPE
		Burden (mm)	4.3	3.2	4.3	MAPE
	Contour hole	Spacing (mm)	6.8	5.5	6.0	MAPE
		Burden (mm)	3.2	2.8	3.0	MAPE

Table 6. Accuracy or MAPE for test data (continued)

Algorithm		XGBoost (%)	ANN (%)	SVM (%)	Type of performance measure	
Bench section	Bench height (m)	24.6	24.9	21.3	MAPE	
	Round length (m)	0.1	2.7	6.9	MAPE	
	No. of charge holes per area (h/m ²)	8.1	13.0	18.3	MAPE	
	Specific charge (kg/m ³)	11.4	11.4	11.3	MAPE	
	Stopping hole	Spacing (mm)	8.1	12.1	9.8	MAPE
		Burden (mm)	36.0	29.3	54.3	MAPE
	Bottom hole	Spacing (mm)	7.3	8.6	11.4	MAPE
		Burden (mm)	27.6	24.4	36.8	MAPE
Average MAPE (except blast cut type)		10.8	11.2	13.9	MAPE	

라는 것은, 예를 들어 실제 공간격이 1,000 mm일 때 분석에 의해 제안된 공간격이 약 900~1,100 mm라는 의미이므로 실제 설계에서 수용할만한 수준이라고 판단되지만 향후 학습데이터 수가 증가하면 그 수준도 감소할 것으로 사료된다. 그러나 심발공 종류는 XGBoost와 SVM이 60%, ANN이 50%로 나타났는데 이것은 10개의 발파설계 중에 5~6개만 실제와 동일하게 예측했다는 의미가 되므로 아직 개선해야 될 사항이 많은 것으로 판단되었다.

결과적으로 성능이 상대적으로 가장 좋은 XGBoost모형을 본 연구에서 사용할 최종 모델로 선정하였다.

4.2 설계 상황을 가정한 발파패턴 설계

최종적으로 선정된 XGBoost모델에 학습 및 시험데이터에서 사용한 데이터가 아닌 발파설계 상황을 가정한 새로운 데이터를 입력하였을 때, 제안되는 발파설계패턴을 분석하였다. 입력데이터 내용은 Table 7에 나타난 바와 같이, 도로유형은 국도, 지보타입은 Type 1~5까지, 단면적은 전단면 Type 1인 경우 82.9 m²이다.

Table 7. Input data assuming actual blast design

Road type		National road				
Rock support type		Type 1	Type 2	Type 3	Type 4	Type 5
Cross sectional area (m ²)	Full section/Upper section	82.9	82.9	83.8	64.9	65.7
	Bench section	-	-	-	19.6	19.7

Table 8은 XGBoost모델에서 제안되는 발파패턴 각 항목에 대한 수치를 그대로 나타낸 표이다. 심발공의 경우 Type 3에서 V-cut을 제안하고 있는데, Type 1~3까지의 전단면에서는 일반적으로 Cylinder-cut을 사용한다는 것을 감안하면 상기 시험데이터에서 나타났던 예측 정확도 60%가 그대로 반영되고 있다고 볼 수 있다. 굴진장의

경우, Type 1~5까지 각각 3.6 m, 3.3 m, 2.1 m, 1.4 m, 1.2 m로 나타나고 있어서 일반적인 설계에서와 유사하게 나타나고 있지만 Type 2에서의 굴진장이 Type 1보다 약간 작게 제안되고 있어서, 두가지 Type에서 동일한 굴진장이 적용되는 일반적 설계와는 차이가 있었다. 단위면적당 천공수는 전단면(또는 상반)의 경우도 Type 1에서 1.33공/m²이고 Type 5로 갈수록 점점 증가하고 있어 실제 설계와 유사한 경향을 나타내고 있으며, 이를 전단면(또는 상반) 1막장당 실제 천공수로 계산하면, 각 Type별로 110공(=1.33공/m² × 82.9 m²), 109공, 119공, 97공, 108공이 된다. 또한 비장약량은 Type 1에서 1.07, Type 5에서 0.90을 나타내며 실제 설계에서와 유사하게 점차 감소하고 있다. 이를 실제 1발파당 총장약량으로 환산하면 Type 1에서는 319 kg (=1.07 kg/m³ × 82.9 m² × 3.6 m), Type 5에서는 71 kg정도가 된다.

한편 상하반 분할굴착이 이루어지는 Type 4와 5에서 벤치의 높이는 일반적인 설계에서는 동일한 높이가 적용되지만, 제안된 패턴에서는 각각 1.9 m 및 1.8 m로 약간의 오차가 나타나고 있다.

또한 발파공에 대한 공간격과 저항선이 1 mm단위로 변화가 되고 있는데, 실제 발파패턴에서는 일반적으로 50 mm단위로 변화한다는 것을 고려할 때, 향후 연구에서 보완해야 될 것으로 사료된다.

Table 8. Blast pattern proposed from the actual blast input data

Rock mass class		1	2	3	4	5	
Full section or Upper section	Blast cut type	Cylinder-cut		V-cut			
	Round length (m)	3.6	3.3	2.1	1.4	1.2	
	No. of charge holes per area (h/m ²)	1.33	1.31	1.43	1.50	1.64	
	Specific charge (kg/m ³)	1.07	1.06	0.98	0.96	0.90	
	Stopping hole	Spacing (mm)	1,115	1,112	1,000	1,011	971
		Burden (mm)	988	988	891	819	851
	Contour hole	Spacing (mm)	620	622	609	615	590
		Burden (mm)	790	787	768	776	731
Bench section	Bench height (m)	-	-	-	1.9	1.8	
	Round length (m)	-	-	-	3.0	1.2	
	No. of charge holes per area (h/m ²)	-	-	-	1.41	1.51	
	Specific charge (kg/m ³)	-	-	-	0.81	0.75	
	Stopping hole	Spacing (mm)	-	-	-	1,083	976
		Burden (mm)	-	-	-	998	976
	Bottom hole	Spacing (mm)	-	-	-	943	879
		Burden (mm)	-	-	-	770	749

5. 결론

본 연구에서는 터널설계의 다양한 설계 항목 중 발파설계를 자동화하기 위해 머신러닝 모델 초기버전을 개발하였다. 이를 위하여 25개 터널설계 자료에서 추출된 발파설계관련 데이터를 기반으로 XGBoost, ANN, SVM 등 3가지 머신러닝 모델을 시험한 후 최종 모델을 선정하였다. 이를 통해 지보패턴, 도로유형, 상반 및 하반 단면적이 주어졌을 때 심발공 종류, 비장약량, 천공수, 각 발파공 그룹별 공간격과 저항선 등의 발파패턴을 제안하도록 하였다. 본 연구에서 도출된 주요 결론은 다음과 같이 요약할 수 있다.

1. 국토교통부 건설CALS시스템 및 설계사 등을 통해 국내 도로 터널 25개소에 대한 터널설계자료를 수집하였다. 수집된 자료는 터널설계보고서, 지반(토질)조사보고서, 터널설계도면, 그리고 수량산출서 4종류이며, 이 자료들에서 설계연도, 터널명, 도로유형, 위치, 터널연장, 암종, 지보패턴별 발파공수 및 발파패턴 등 총 39가지 세부항목에 대한 데이터를 발췌하였고 이중 20가지의 설계항목을 입력 및 출력데이터로 선정하였다.
2. 상기 데이터로 학습된 모델의 검증결과, 심발공 종류의 경우 정확도 단위로 나타난 XGBoost와 SVM모델이 87.8%, ANN이 78%로 나타났고, 나머지 15개 설계항목의 경우 실제 설계패턴대비 모델에서 제안된 발파패턴의 평균절대백분율오차가 3가지 모델에서 대체로 양호한 수준인 7.3%-8.2%사이로 그 차이가 크지 않았다.
3. 학습이 완료된 3가지 머신러닝 모델에 학습과 검증에서 사용되지 않은 새로운 2개 터널설계에서 수집된 데이터를 입력하여 제안된 발파패턴과 실제 설계패턴과의 오차율을 비교한 결과, 심발공 종류는 XGBoost와 SVM이 60%, ANN이 50%로 나타났고, 나머지 15가지 설계항목에 대한 오차율이, XGBoost, ANN, SVM 모델 각각이 10.8%, 11.2%, 13.9%로 나타나 XGBosst모델이 실제 상황에서 오차가 가장 적을 것으로 분석되어 최종 모델로 선택되었다. 향후 상기 3가지 모델외에 더 좋은 성능을 나타내는 모델들에 대한 추가적인 연구가 필요하다.
4. 실제 설계상황을 가정하여 상기 4가지의 발파설계를 위한 데이터를 XGBosst모델에 입력한 결과, 대체로 지보패턴 변화에 따른 일반적인 발파설계의 경향과 유사하게 나타나고 있으나, 심발공종류에서 일부 Type에서의 오류, 그리고 일반적인 설계에서 동일하게 설계되는 Type 1과 Type 2의 굴진장이 약간의 오차를 두고 서로 다르게 제안되고 있어서 향후 연구에서 보완이 필요하다.
5. 본 연구가 기초연구 성격이어서 전체 발파설계를 완벽하고 신뢰성있게 수행하기는 아직 부족하지만, 향후 충분한 발파설계데이터를 확보하고 세부적인 처리과정을 보완하여 실용적인 활용이 가능하도록 추가 연구를 수행할 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

김양균은 데이터 수집 및 정리, 결과 분석 및 원고 작성을 하였고, 이재겸은 머신러닝 코드 개발 및 분석을 하였으며, 이승원은 총괄 검토를 하였다.

References

1. Ahn, Y.H., Kim, S.Y. (2017), "Construction industry transition with the 4th industrial revolution technology", *Journal of the Korea Institute of Building Construction*, Vol. 17, No. 2 (special issue), pp. 19-23.
2. Alipour, A., Mokhtarian-Asl, M., Asadzadeh, M. (2021), "Support vector machines for the estimation of specific charge in tunnel blasting", *Periodica Polytechnica Civil Engineering*, Vol. 65, No. 3, pp. 967-976.
3. Choi, B.H., Ryu, C.H., Jeong, J.H. (2009), "Tunnel blasting design suited to given specific charge", *Explosives and Blasting*, Vol. 27, No. 2, pp. 33-41.
4. Choi, Y.K. (2005), "Development of automated pattern generation method for tunnel blasting", *Explosives and Blasting*, Vol. 23, No. 4, pp. 19-29.
5. Construction CALS Home page, <https://www.calspia.go.kr/io/index.do> (July 2, 2022).
6. Hafner, M., Rajšter, D., Žibert, M., Tušar, T., Ženko, B., Žnidaršič, M., Fuat, F., Vladušič, D. (2019), "Artificial intelligence support for tunnel design in urban areas", *Tunnels and Underground Cities: Engineering and Innovation meet Archaeology, Architecture and Art*, Taylor & Francis, London, pp. 2196-2205.
7. Jang, H., Topal, E. (2013), "Optimizing overbreak prediction based on geological parameters comparing multiple regression analysis and artificial neural network", *Tunnelling and Underground Space Technology*, Vol. 38, pp. 161-169.
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. Kim, Y., Bruland, A. (2015), "Comparison of tunnel excavation cycle time for Norwegian and Korean tunnels", *Proceedings of the 41th ITA World Tunnel Congress*, Dubrovnik, Croatia.
10. Langefors, U., Kihlström, B. (1967), *The Modern Technique of Rock Blasting*, Wiley or Almquist & Wiksell, New York, pp. 180-229.
11. 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.
12. Lee, T.H. (2016), *Development of an artificial neural network for optimization of tunnel blasting design*, Doctoral Thesis, City University of Hong Kong, pp. 143-194.
13. Mitchell, T.M. (1997), *Machine Learning*, McGraw Hill, pp. 1.
14. MOLIT (2016), *Korean design standard, KDS 27 20 00*, Ministry of Land, Infrastructure and Transport, pp. 3-4.
15. MOLIT Statistics System Home page, http://stat.molit.go.kr/portal/cate/statView.do?hRsId=302&hFormId=4746&hDivEng=&month_yn= (September 24, 2021b).

16. MOLIT Statistics System Home page, http://stat.molit.go.kr/portal/cate/statView.do?hRsId=65&hFormId=1040&hDivEng=&month_yn= (September 24, 2021a).
17. Olofsson, S. (1990), *Applied Explosives Technology for Construction and Mining*, Applex, Ärla, pp. 131-173.
18. Soranzo, E., Guardiani, C., Wu, W. (2022), “The application of reinforcement learning to NATM tunnel design”, *Underground Space*, In Press, pp. 1-13.
19. Trivedi, R., Singh, T.N., Mudgal, K., Gupta, N. (2014), “Application of artificial neural network for blast performance evaluation”, *International Journal of Research in Engineering and Technology*, Vol. 03, No. 5, pp. 564-574.
20. Wu, Z., Luo, D., Chen, G. (2020), “Design and realization of the intelligent design system for tunnel blasting in mine based on database”, *Geofluids*, Vol. 2020, Article ID 8878783, pp. 1-11.