

TECHNICAL NOTE

## 터널 심발공 비장약량 예측을 위한 머신러닝 기법의 적용성 평가

권정인<sup>1</sup>, 이호성<sup>2</sup>, 고태영<sup>3\*</sup>

<sup>1</sup>강원대학교 에너지-인프라 융합학과 석사과정, <sup>2</sup>지윤이앤씨 대표, <sup>3</sup>강원대학교 에너지자원·산업공학부 조교수

# Evaluation of Machine Learning Techniques for Predicting Specific Charge of Cut Hole Blasting in Tunnel

Jung In Kwon<sup>1</sup>, Ho Sung Lee<sup>2</sup>, and Tae Young Ko<sup>3\*</sup>

<sup>1</sup>Graduate Student, Department of Integrated Energy and Infra System, Kangwon National University

<sup>2</sup>CEO, JIYUN E&C

<sup>3</sup>Assistant Professor, Department of Energy and Resources Engineering, Kangwon National University

\*Corresponding author: [tyko@kangwon.ac.kr](mailto:tyko@kangwon.ac.kr)

Received: November 26, 2024

Revised: November 29, 2024

Accepted: December 2, 2024

### ABSTRACT

This study aims to develop an optimal machine learning model for predicting the specific charge of cut holes in tunnel blast design using data collected from 18 tunnel sites in South Korea. Input variables included round length, number of charge holes per area, excavation section coefficient, cross-sectional area, maximum and minimum spacing of cut holes, cut method type, explosive type, RMR, maximum overburden depth, and rock type. Nine different machine learning models were applied and compared: Linear Regression (LR), Lasso Regression, Ridge Regression, Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Random Forest (RF), Light Gradient Boosting Machine (LightGBM), Histogram-based Gradient Boosting (HGB), and Artificial Neural Network (ANN). The Random Forest model showed the best performance with an  $R^2$  of 0.852 and RMSE of 0.082 on test data. Variable importance analysis using SHAP (SHapley Additive exPlanations) revealed that cut method type was the most influential factor (Mean Absolute SHAP Value: 0.1627), followed by minimum spacing (0.0393) and maximum spacing (0.0170). In contrast, maximum overburden depth (0.0041), RMR (0.0045), explosive type (0.0029), and round length (0.0008) showed relatively low importance. The developed model can be utilized to predict optimal specific charge under various geological conditions in tunnel sites, significantly enhancing the efficiency and safety of tunnel construction projects.

**Keywords:** Tunnel blasting, Specific charge, Cut hole blasting, Machine learning, Variable importance analysis

### 초록

본 연구는 국내 18개 터널 현장의 데이터를 활용하여 터널 발파 설계에서 심발공의 비장약량을 예측하기 위한 최적의 머신러닝 모델을 개발하는 것을 목적으로 한다. 입력변수로는 굴진장, 단위면적당 천공수, 굴착단면계수, 전체 막장면의 단면적, 심발공의 최대 및 최소 공간격, 심발 공법 유형, 사용한 폭약의 종류, RMR, 최대 토피고, 암종이 사용되었다. 선형회귀(LR), Lasso회귀, Ridge회귀, 서포트벡터머신(SVM), K-최근접이웃(KNN), 랜덤포레스트(RF), LightGBM, 히스토그램 기반 그라디언트부스팅(HGB), 인공신경망(ANN)의 9가지 머신러닝 모델이 적용되어 비교되었다. 랜덤포레스트 모델이 테스트



트 데이터에서 R2 0.852, RMSE 0.082로 가장 우수한 성능을 보였다. SHAP (SHapley Additive exPlanations) 분석을 통한 변수 중요도 분석 결과, 심발 공법 유형이 가장 큰 영향을 미치는 것으로 나타났다(Mean Absolute SHAP Value: 0.1627), 최소 공간격(0.0393)과 최대 공간격(0.0170)이 그 뒤를 이었다. 반면, 최대 토피고(0.0041), 암반 등급(0.0045), 사용한 폭약 종류(0.0029), 굴진장(0.0008)은 상대적으로 낮은 중요도를 보였다. 본 연구에서 개발된 모델은 터널 현장의 다양한 지질 조건에서 최적의 비장약량을 예측하는데 활용될 수 있으며, 이는 터널 건설 프로젝트의 효율성과 안전성을 크게 향상시킬 수 있다.

**핵심어:** 터널발파, 비장약량, 심발공 발파, 머신러닝, 변수 중요도 분석

## 1. 서론

터널 건설에서 발파 작업의 효율성과 정확성은 프로젝트의 효율성, 안전성, 비용에 큰 영향을 미친다. 터널 발파 작업의 목표는 정확한 설계를 통해 진동과 소음을 최소화하면서 발파 효율을 극대화하는 것이다. 이를 위해 비장약량, 천공 배치 및 간격, 전폭약의 종류, 심발 공법 등 주요 설계 요소를 종합적으로 고려해야 한다. 이 중에서도 비장약량은 발파 설계의 핵심 요소로, 발파에 사용된 폭약의 총 중량을 파쇄할 암석의 총 부피로 나눈 값이다. 이는 암석의 파쇄도와 비산 거리에 직접적인 영향을 미쳐 최적의 설계 조건을 결정하고 총 발파 비용을 산출하는 데 중요한 역할을 한다. 또한, 정확한 비장약량 예측은 파괴불량으로 인한 2차 발파 비용을 줄이고, 에너지 분포를 최적화하여 파쇄 효율을 높이는 데 기여한다(Choi et al., 2009, Kahriman et al., 2001).

터널 발파는 1자유면에서 진행되며, 암석이 구속된 상태에서 2자유면이 형성되면서 암석을 파쇄하고, 자유면으로부터 암석을 멀리 비산시키는 작업이다(Min et al., 2005a). 심발 발파는 터널 발파 과정의 첫 단계로, 이후 모든 발파 공정에 영향을 미쳐 터널 굴착의 성공 여부(굴진율, 파쇄도, 진동 발생 등)를 결정하는 중요한 역할을 한다. 초기 심발 영역은 제한된 자유면만을 가지고 있어 다른 영역에 비해 더 높은 비장약량과 가장 강한 폭약이 필요하다. Hwang and Lee(2002)는 심발 영역의 천공 종류, 배열 형태, 장약량, 장약방법, 기폭시스템 등이 발파 효율과 진동에 큰 영향을 끼친다고 보고하였으며, Son et al.(2019)는 터널 발파에서 심발 공법에 따른 발파진동 저감효과를 현장 시험 발파와 수치해석(FLAC3D)을 통해 비교 분석하여, 다단 평행 심발 공법이 진동 저감에 효과적임을 정량적으로 평가하였다.

그러나 터널 현장 조건은 매우 복잡하여 동일한 발파 설계를 적용하기 어려운 경우가 많으며, 각 현장 조건을 고려한 발파 설계가 필요하다. 이러한 복잡한 문제를 해결하기 위해 최근에는 복잡한 데이터에서 패턴을 훈련하여 예측을 수행하는 인공지능(Artificial Intelligence, AI)의 한 종류인 다양한 머신러닝(Machine Learning) 모델을 활용하여 터널 발파 설계를 위한 비장약량 예측 연구가 활발히 진행되고 있다. Jong and Lee(2001)은 현장의 지질 조건과 발파 조건을 종합적으로 고려한 비장약량 산정을 위해 신경망 이론의 적용을 제안하였다. Alipour et al.(2012)은 대만 철도 터널 발파에서 인공신경망(Artificial Neural Network, ANN)과 다변량 선형 회귀 분석(Multiple Variable Linear Regression Analysis, MVLRA)을 결합한 모델을 개발하여 비장약량을 예측하였으며, Alipour et al.(2021)은 서포트 벡터 머신(Support Vector Machine, SVM) 알고리즘을 사용하여 비장약량을 예측하였으며, Adesida(2022)은 암반 공학 시스템(Rock Engineering System, RES)을 기반으로 다변량 선형 회귀 분석을 활용한 비장약량 예측 모델을 제시하였다. Kim et al.(2022)은 극단 그래디언트 부스팅(eXtreme Gradient Boosting, XGBoost) 모델을 활용하여 터널 발파 설계 자동화를 위해 비장약량 예측하는 연구를 수행하였고, Taiwo et al.(2024)은 결정 트리(Decision Tree) 모델을 활용하여 발파 작업의 비장약량을 예측하는 연구를 진행하였다(Table 1).

**Table 1.** Review of machine learning applications for specific charge prediction

Model developed by	Parameters considered in models	Applied machine learning model
Jong and Lee(2004)	Tunnel orientation Major discontinuity Secondary discontinuity Rock Strength RQD RMR	ANN
Alipour et al.(2012)	P-wave velocity RQD Tunnel area Coupling ratio Blast hole depth	ANN MVLRA
Alipour et al.(2021)	Max. Depth Tunnel area UCS RQD Coupling ratio	SVM
Adesida(2022)	RMR Blastability index Porosity Specific gravity UCS Drilled-hole diameter	MVLRA
Kim et al.(2022)	Rock mass class Road type Excavation area	XGBoost
Taiwo et al.(2024)	RMR Bulk density Rebound hardness value P-wave velocity RQD Burden-to-Spacing ratio	DT ANN

하지만 기존 연구는 주로 해외 사례를 바탕으로 진행되었거나, 터널 발파의 전체적인 비장약량을 예측하는 데 초점을 맞추고 있어, 국내 터널 발파 작업의 심발 영역에 바로 적용하기에는 한계가 있다. 또한, Jong and Lee(2004)에 따르면, 국내 터널 건설 현장에서는 발파 작업이 주로 발파 엔지니어들의 경험에 의존해 이루어졌으며, 비장약량에 영향을 미치는 지질 조건에 따라 서로 다른 설계를 적용해왔다고 보고하였다.

따라서 본 연구의 주요 목적은 국내 터널 현장 조건을 고려해서 정량적으로 심발 영역의 비장약량을 예측하는 머신러닝 모델을 개발하는 것이다. 이를 위해 18개 발파 터널 현장의 자료를 바탕으로 비장약량에 영향을 미치는 주요 인자들을 선정하고, 다양한 머신러닝 알고리즘을 적용하여 최적의 예측 모델을 도출하였다.

## 2. 데이터 수집 및 분석

### 2.1 데이터 수집 과정

본 연구를 위해 국토교통부 건설CALS시스템(Construction CALS, 2024) 및 설계사 등을 통해 국내 고속도로 및 국도 건설사업의 18개 도로 터널 프로젝트의 데이터를 수집하였다. 이들 터널은 모두 차량 통행을 위한 도로 터널로, 2차로 이상의 단면을 가진 NATM 터널이다. 수집된 항목은 터널 설계도면, 발파 패턴도, 지질 및 지보 패턴 개요도, 평면 및 종단면도이다. 터널 설계 도면과 발파 패턴도를 통해 터널의 형태와 심발 영역의 단면적 및 공간격, 굴진장, 천공장, 심발 공법의 유형, 전체 막장면의 단면적 및 천공 수, 사용한 폭약의 종류와 같은 실제 현장에서 적용된 발파 설계와 관련된 자료를 수집하였다. 지질 및 지보 패턴 개요도에서는 암종, 터널 통과 구간의 RMR을 수집하였으며, 평면 및 종단면도를 통해 터널의 위치, 연장, 토피고와 같은 자료를 수집하였다.

특히, 심발 영역의 비장약량을 예측하기 위해 심발 영역이 포함된 전단면과 상하반 분할발파 시의 상반 영역에 대한 데이터를 수집하고, 총 208개의 데이터 세트를 구성하였다. 이를 바탕으로 데이터베이스를 구축하여 모델 학습에 활용하였다.

### 2.2 입력변수 선정

본 연구에서는 터널 발파 설계 데이터를 바탕으로 11개의 입력변수를 선정하였다. 선정된 입력변수는 굴진장, 단위 면적당 천공 수, 굴착단면계수, 전체 막장면의 단면적, 심발 영역의 최대 및 최소 공간격, 심발 공법 유형, 사용한 폭약의 종류, RMR, 최대 토피고, 암종이다.

굴진장(Round length)은 한 번의 발파 작업으로 실제 전진한 길이를 나타내며, 터널 발파 설계의 가장 핵심 지표이다. 단위 면적당 천공 수(No. of charge holes per area)는 식 (1)과 같이 전체 터널 단면적에 대한 천공 수의 비율로 계산되며, 이는 설계에 직접적인 영향을 미친다(Kim et al., 2022).

$$\text{단위 면적 당 천공 수 (holes/m}^2\text{)} = \frac{\text{발파 공수 (holes)}}{\text{전체 터널 단면적 (m}^2\text{)}} \quad (1)$$

Jung et al.(2001)은 굴착단면계수(Excavation section coefficient)가 비장약량에 직접적으로 영향을 미치는 요인 중 하나라고 보고하였다. 굴착단면계수는 굴진장과 터널 단면적을 이용하여, 식 (2)와 같이 계산한다.

$$\text{굴착 단면 계수} = \left(1 + \frac{\text{굴진장 (m)}}{\sqrt{\text{터널 단면적 (m}^2\text{)}}}\right)^2 \quad (2)$$

최대 토피고(Max. Overburden depth)는 터널 상부의 지반 하중을 반영하는 요소로, 해당 굴착 구간의 지반고와 계획고의 차이로 산출된다. 전체 막장면의 단면적(Cross-sectional area)은 심발공이 위치한 전단면과 상하반 분할발파 시의 상반 영역 단면적을 의미하며, 이는 파쇄할 암석의 총 부피와 직접적으로 관련되어 비장약량 산정에 영향을 미친다. 심발 부분의 최대 공간격(Max. Spacing)과 최소 공간격(Min. Spacing)은 발파 효율을 극대화하기 위한 심발공 배치의 기준이 된다. RMR (Rock Mass Rating)은 Bieniawski(1973)가 제안한 정량적 암반 분류 방법으로, 임반 강도, RQD, 불연속면 간격과 상태, 지하수 상태 등을 종합적으로 평

가한다. RMR은 비장약량 예측의 주요 변수 중 하나이다. 암종(Rock type)은 퇴적암, 화성암, 변성암으로 구분하였다. 각 암종은 일축압축강도, 인장강도, 밀도, 탄성계수와 같은 암석 고유의 물리적 특성을 반영하며, Jung et al.(2001)은 이러한 특성이 폭약량 결정에 가장 큰 영향을 미친다고 보고하였다. 국내 터널 현장에서 일반적으로 적용되는 심발 공법 유형(Blast cut type)은 경사공 심발 공법(V-cut), 평행공 심발 공법(Cylinder cut), 그리고 이들의 변형인 이중경사공 심발 공법(Double V-cut)으로 구분된다(Min et al., 2005a). 심발공법의 유형은 자유면 형성과 파쇄 메커니즘에 직접적인 영향을 미치므로 비장약량 결정에 핵심적인 요소이다. 경사공 심발 공법(V-cut)은 천공 작업이 용이하고 경험자가 비교적 많다. 중심부에서 만나는 경사공들이 켜기 형태의 자유면을 형성하여 발파효율이 높은 특징이 있다. 특히 굴진장 2.0 m 이내의 단공 발파에서 유리하며, 암질이 불량한 구간에서도 안정적인 적용이 가능하다. 평행공 심발 공법(Cylinder cut)은 제한된 자유면 조건에서 무장약공을 중심으로 평행하게 배치된 장약공들을 동시에 기폭하여 중앙부를 파쇄하는 메커니즘을 사용한다. 장공 발파 및 소단면 터널 발파에 유리하지만 정밀한 천공 기술이 요구되며, 특히 천공 오차가 발파 효과에 큰 영향을 미친다. 이중경사공 심발 공법(Double V-cut)은 V-cut의 응용 형태로, V-cut에서 보조적인 경사공을 추가하여 굴진 효율을 높인 공법이다. 주로 굴진장이 깊은 경우에 적용되며, 보조 cut을 추가함으로써 심발 성능을 향상시킬 수 있다. 이 공법은 기본적으로 V-cut의 장점을 활용하면서 심발부의 파쇄 효율을 높이기 위해 개발되었다.

정밀한 천공기술이 요구되는 평행공 심발공법(Cylinder cut)이 가장 많은 비장약량을 필요로 한다. 이는 제한된 자유면 조건에서 무장약공 주변의 발파를 통해 초기 자유면을 형성해야 하기 때문이다. 반면 경사공 심발공법(V-cut)은 켜기형태의 자유면 형성이 용이하여 상대적으로 적은 비장약량이 요구된다. 이중경사공 심발공법(Double V-cut)의 경우, V-cut을 기본으로 하되 보조 cut이 추가되므로 V-cut과 유사한 수준의 비장약량이 필요하다. 또한, 사용한 폭약의 종류(Type of Explosives)에 따라 폭발력과 파쇄 능력에 차이를 주어 발파 설계가 달라지며, Min et al.(2005b)은 이를 적절히 고려하지 않을 경우 여굴이나 진동 증가 등의 문제가 발생할 수 있다고 보고하였다. 사용한 폭약의 종류는 일반 에멀전, 고성능 에멀전, 다이너마이트로 구분된다. 일반 에멀전 폭약은 1.1-1.2 g/cm<sup>3</sup>의 밀도와 5,700 m/s의 폭발속을 가지며, 내수성과 취급 안정성이 우수하여 연암에서 보통암 구간의 일반적인 발파에 널리 사용된다. 고성능 에멀전 폭약은 1.2-1.3 g/cm<sup>3</sup>의 밀도와 6,000 m/s의 폭발속을 가지는데, 이는 일반 에멀전 대비 더 높은 폭발력을 제공하여 경암 구간이나 높은 파쇄도가 요구되는 구간에 적합하다. 다이너마이트는 1.3-1.5 g/cm<sup>3</sup>의 밀도와 6,100 m/s의 가장 높은 폭발속을 가지므로 극경암 구간에서 주로 사용된다(Hanwha Corporation, 2017). 폭약의 밀도와 폭발속 차이는 발파 설계에 직접적인 영향을 미친다. 일반적으로 밀도가 높을수록 장약 밀도가 증가하여 동일 체적당 더 많은 폭발에너지를 발생시키며, 폭발속이 높을수록 더 큰 폭발압과 충격파를 생성하므로 동일한 천공패턴에서도 암반 파쇄도가 달라질 수 있다. 따라서 폭약 선정 시에는 대상 암반의 강도와 요구되는 파쇄도를 고려하여 적절한 물성의 폭약을 선택해야 하며, 필요한 경우 천공패턴과 비장약량을 조정할 필요가 있다.

### 2.3 데이터 분포

심발 영역의 비장약량 예측을 위한 입력변수들의 분포 특성을 Fig. 1에 나타내었다. 입력변수들은 수치형 변수와 범주형 변수로 구분되며, 수치형 변수에는 비장약량, 굴착단면계수, 단위면적당 천공수, 전체 막장면의 단면적, 최대 토피고, 최대 공간격, 최소 공간격, RMR이 포함된다. 범주형 변수로는 암종(화성암, 변성암, 퇴적암), 심발 공법 유형(V-cut, Cylinder cut, Double V-cut), 사용 폭약의 종류(에멀전, 고성능 에멀전, 다이너마이트)가 있다. Fig. 1의 분포도를 살펴보면, 비장약량은 1.0-2.0 kg/m<sup>3</sup> 구간에서 높은 빈도를 보이며, 굴착단면계수는 14.5-15.5 구간에서 가장 높은 빈도가 나타난다. 최대 토피고(Max. Overburden depth)는 100 m 이하 구간에서 대부분의 데이터가 집중되어 있으며, 왼쪽으로 치우친 분포 특성을 보이는데 이는 대부분의 터널이 비교적 낮은 심



도에서 시공되었음을 의미한다. 범주형 데이터에서는 암종의 경우 화성암이, 심발 공법에서는 V-cut이, 폭약 종류에서는 Emulsion 이 가장 높은 빈도를 나타내고 있다. 이러한 데이터 분포 특성은 심발 영역의 비장약량 예측 모델 개발에 있어 중요한 기초자료로 활용된다.




Fig. 1. Distribution of numerical and categorical input variables

Table 2는 수치형 변수들의 기술통계량을 보여준다. 변수들의 변동 정도를 변동계수(표준편차/평균)로 비교해보면, 굴착단면계수(0.16), 단위 면적당 천공 수(0.16), 전체 막장면의 단면적(0.19)은 낮은 변동성을 보였다. 굴진장(0.45), 최대 공간격(0.25), 최소


공간격(0.36)은 중간 정도의 변동성을 나타냈다. 반면, 최대 토피고(0.93)와 비장약량(0.52)은 높은 변동성을 보였으며, 특히 최대 토피고는 변동계수가 0.93으로 가장 큰 변동성을 나타냈다.

**Table 2.** Statistical summary of numerical variables for specific charge prediction model


Type	Variables	Unit	Mean	Std	Max	Min
Input	Round length	m	1.98	0.90	3.50	1.0
	Excavation section coefficient		1.54	0.24	2.04	1.23
	No. of charge holes per area	holes/m <sup>2</sup>	1.79	0.28	2.99	1.41
	Cross sectional area	m <sup>2</sup>	67.8	12.6	88.6	46.2
	Max. Overburden depth	m	78.7	73.4	471.9	13.3
	Max. Spacing	mm	1622.7	400.3	2500.0	735.0
	Min. Spacing	mm	503.2	181.4	950.0	201.0
Output	Specific charge	kg/m <sup>3</sup>	1.65	0.85	4.18	0.53

## 2.4 데이터 분석


수집된 데이터를 바탕으로, 암반등급(Rock grade)을 RMR의 범위를 기준으로 I, II, III, IV, V로 나누어 암반등급에 따른 주요 발파 변수들의 데이터 분포를 Fig. 2에서 분석하였다. Fig. 2(a)에서는 암반등급이 낮아질수록 심발 영역의 비장약량이 감소하는 경향을 보였다. 암반등급 I의 경우 평균 비장약량이 약 2.1 kg/m<sup>3</sup>이며 1.2-2.8 kg/m<sup>3</sup> 범위의 분포를 보였고, 암반등급 V에서는 평균 1.1 kg/m<sup>3</sup>로 감소하며 1.0-1.3 kg/m<sup>3</sup>의 좁은 분포를 나타냈다. 이는 암반등급이 높을수록 암반의 강도가 크고 더 치밀한 구조를 가지고 있어 단위 부피 당 암석을 발파하는데 소요되는 장약량이 증가하는 것을 보여준다.



(a) Distribution of specific charge according to rock grade



(b) Distribution of round length according to rock grade



(c) Distribution of charge holes per area according to rock grade

**Fig. 2.** Relationship between rock grade and main design parameters for tunnel blasting


Fig. 2(b)에서는 암반등급이 낮아질수록 굴진장이 뚜렷하게 감소하는 것으로 나타났다. 암반등급 I의 경우 평균 굴진장이 약 2.9 m였으며 2.0-3.5 m 범위의 분포를 보였고, 암반등급 V에서는 평균 1.1 m로 감소하며 1.0-1.2 m의 매우 좁은 분포를 나타냈다. Min et al.(2005a)에 따르면, 굴진장은 발파 능력보다는 암반 자체의 지보능력에 의해 결정되기 때문에, 암반의 품질이 좋을수록 터널 굴착 시 더 긴 구간을 안전하게 발파할 수 있어 굴진장이 증가한다.

Fig. 2(c)에서는 암반등급이 낮아질수록 단위 면적 당 천공 수는 증가하는 경향을 보였다. 암반등급 I에서는 평균 약 1.7공/m<sup>2</sup>이며 1.5-1.9공/m<sup>2</sup>의 좁은 분포를 보였으나, 암반등급 V에서는 평균 2.2공/m<sup>2</sup>로 증가하며 2.0-2.4공/m<sup>2</sup>의 분포를 나타냈다.

박스플롯에서 보이는 바와 같이 암반등급이 낮아질수록 데이터의 분산도 점차 증가하는 특징을 보였다. 이는 암질이 불량해질수록 천공장과 공당 장약량은 감소시키고 천공 수는 증가시키는 설계 및 시공 패턴을 반영한 결과를 나타낸 것이다(Kim et al., 2022).

터널 발파에 사용된 심발 공법과 폭약 종류의 암반등급별 분포를 Fig. 3에 나타내었다. Fig. 3(a)에서 Cylinder-cut은 암반등급 I, II, III 등급에서 주로 사용되었으며, 특히 I등급에서 63.2%로 가장 높은 사용 비율을 보였고, II등급에서 44.6%, III등급에서는 32.7%로 암반등급이 낮아질수록 사용 비율이 감소하였다. IV, V등급의 암반에서는 주로 V-cut과 Double V-cut이 사용되었으며, V-cut의 경우 IV등급에서 62.5%, V등급에서 50.0%의 높은 사용 비율을 보였다.

Fig. 3(b)에서는 에멀전 폭약의 사용 비율이 암반등급 I에서 23.7%, II에서 42.9%, IV에서 72.7%, V등급에서는 100%로 암반등급이 낮아질수록 뚜렷하게 증가하는 경향을 보였다. 반면, 고성능 에멀전 폭약은 암반등급 I에서 60.5%, II에서 42.9%, IV에서 12.7%로 암반등급이 낮아질수록 사용 비율이 감소하였다. 다이내마이트의 경우는 암반등급 I에서 15.8%, II에서 14.3%, III에서 14.5%, IV에서 8.5%로 사용되었으며, V등급에서는 사용되지 않았다. 이는 암반의 강도가 높은 등급에서는 고성능 에멀전 폭약이나 다이내마이트와 같이 폭발력이 더 큰 폭약을 사용하고, 암반 강도가 낮은 등급에서는 일반 에멀전 폭약을 주로 사용하는 발파 설계 경향을 보여준다.



(a) Percentage distribution of blast cut types for different rock grades (b) Percentage distribution of explosive types for different rock grades

Fig. 3. Distribution of blast cut type and explosive type according to rock grade

### 3. 연구 방법론

#### 3.1 데이터 전처리

본 연구에서는 터널 설계, 시공 및 발파 현장 사례 자료를 수집하였다. 데이터 구축 과정에서 수작업 입력으로 인한 오류, 입력 누



락 등 다양한 원인으로 발생한 결손 데이터를 삭제하였다. 데이터 전처리는 두 단계로 진행하였다. 첫 번째로 One-Hot Encoding 기법을 사용하여 고유한 이진 값의 벡터로 변환하였다. 이는 특정 범주의 존재 여부를 나타내는 기법으로, Table 3과 같이 4가지 특성에 대해 적용하였다. 두 번째로, 수치형 데이터에 Min-Max scaling을 적용하였다. 이는 각 수치형 변수를 [0, 1] 범위로 변환하는 기법으로, 변수의 최솟값은 0, 최댓값은 1로 조정된다. 이를 통해 수치형 데이터와 범주형 데이터를 동일한 범위에서 분석할 수 있도록 하였다.

**Table 3.** Feature values for One-Hot encoding

Features	Categorical values
RMR	I (100-81)
	II (80-61)
	III (60-41)
	IV (40-21)
	V (20-0)
Blast cut type	Cylinder-Cut
	V-Cut
	Double V-Cut
Rock type	Igneous rock
	Metamorphic rock
	Sedimentary rock
Type of explosives	High performance emulsion
	Emulsion Dynamite

### 3.2 머신러닝 모델 성능 평가 방법론

본 연구는 터널 발파 설계의 심발부 비장약량 예측을 위해 다양한 머신러닝 모델을 적용하고, 각 모델의 예측 성능을 평가 및 비교하였다. 먼저, 선형 회귀 기반 모델인 Linear Regression (LR), Lasso Regression (Lasso), Ridge Regression (Ridge)을 사용하여 변수 간의 선형 관계를 분석하였으며, 규제 기법을 통해 과적합을 방지하였다. 과적합 현상은 알고리즘이 학습데이터 내에서는 정확하나 학습에 사용되지 않은 외부 데이터에서는 정확도가 떨어지는 현상이다. 다음으로, Support Vector Machine (SVM)과 K-Nearest Neighbors (KNN)를 적용하여, 데이터의 비선형성을 고려한 예측을 수행하였다. SVM은 커널 함수를 통해 데이터를 고차원 공간으로 매핑하여 비선형 관계를 분석하며, KNN은 가까운 이웃 데이터의 특성을 이용하여 간단하고, 구현이 용이하여 효율적인 데이터 분석이 가능하다(Kwon et al., 2022). 또한, 앙상블 모델들을 활용하였는데, 배깅(Bagging) 기법을 사용하는 Random Forest (RF)와 부스팅(Boosting) 기법을 사용하는 Light Gradient Boosting Machine (LightGBM), HistGradientBoosting (HGB)을 적용하였다. 이들 모델은 여러 모델의 결과를 결합해 단일 모델보다 더 우수한 예측 성능을 보인다. RF는 데이터의 복잡한 구조와 변수 간의 비선형적인 상호 작용을 고려해 직관적이며 모델 해석 가능성을 높여주며(Hong et al., 2024), LightGBM,

HGB와 같은 부스팅 기반 모델들은 순차적인 학습을 통해 약한 학습기들을 결합하여 오류를 점진적으로 줄여 다음 모델이 더 잘 학습하도록 유도한다(Freund and Schapire, 1996). 마지막으로, 인공신경망 기반의 Artificial Neural Network (ANN) 모델을 활용하였다. ANN은 다수의 노드를 포함한 여러 층을 순차적으로 쌓아 올린 구조를 이용하여 복잡한 비선형 관계를 학습하고 예측 정확도를 높인다(Lee et al., 2022).

모델 학습과 평가를 위해 전체 데이터를 훈련 데이터(70%)와 시험 데이터(30%)로 나누어 분석했으며, 그리드 서치(Grid Search) 기법을 활용하여 Table 4와 같이 모델들의 하이퍼파라미터를 조정하여 성능을 최적화하였다. Grid Search는 모델별로 설정된 하이퍼파라미터 공간의 특정 부분 집합에 대해 가능한 모든 조합을 탐색하여 최적의 조합을 찾고, 탐색 공간의 모든 후보를 체계적으로 평가하는 기법이다(Liashchynskyi et al., 2019). 각 모델별 주요 하이퍼파라미터는 다음과 같다. Lasso와 Ridge에서는 규제 강도를 조정하는 alpha를 조정하였고, SVM에서는 경계선의 간격을 결정하는 c와 데이터 분리를 위한 kernel을 설정하였다. KNN에서는 데이터 분류의 기준이 되는 최근접 이웃 수(n\_neighbors)를 조정하였다. RF에서는 모델의 개수(n\_estimators)와 깊이(max\_depth)를, LightGBM에서는 학습 속도(learning\_rate)와 모델의 개수(n\_estimators), HGB에서는 반복 횟수(max\_iter)와 학습 속도(learning\_rate)를 조정하였다. ANN에서는 은닉층의 크기(hidden\_layer\_sizes), 활성화 함수(activation function), 은닉층의 개수(layer number)를 조정하였다.

**Table 4.** Optimal hyperparameters of machine learning models

Model	Optimal hyperparameters
Lasso	alpha: 0.001
Ridge	alpha: 0.1
SVM	C: 1, Kernel: linear
KNN	n_neighbors: 3
RF	max_depth: 10, n_estimators: 100
LightGBM	learning_rate: 0.1, n_estimators: 200
HGB	learning_rate: 0.1, max_iter: 200
ANN	hidden_layer_sizes: (50, 50), activation function: Relu, n_layers: 3

또한, 전체 데이터 세트가 적은 경우 발생할 수 있는 성능 평가의 신뢰성 저하를 보완하기 위해 5겹 교차 검증(5-fold cross Validation)을 수행하였다. 이는 데이터를 5개의 폴드(fold)로 나눈 후, 각 폴드를 한 번씩 검증 데이터로 사용하고 나머지 4개의 폴드는 훈련에 사용하는 방법이다.

모델의 성능 평가는 결정계수(Coefficient of determination,  $R^2$ )와 평균 제곱근 오차(Root Mean Squared Error, RMSE)를 활용하였다. 결정계수는 모델이 예측한 값이 실제 데이터의 분산을 설명하는 정도를 나타내며, 1에 가까울수록 예측 성능이 우수함을 의미한다. 평균 제곱근 오차는 예측값과 실제값 사이의 오차를 나타내며, 값이 작을수록 모델의 예측 정확도가 높음을 의미한다. Fig. 4는 원시 데이터의 전처리부터 머신러닝 알고리즘 적용 및 성능 평가에 이르는 전체 분석 프레임워크를 보여준다.

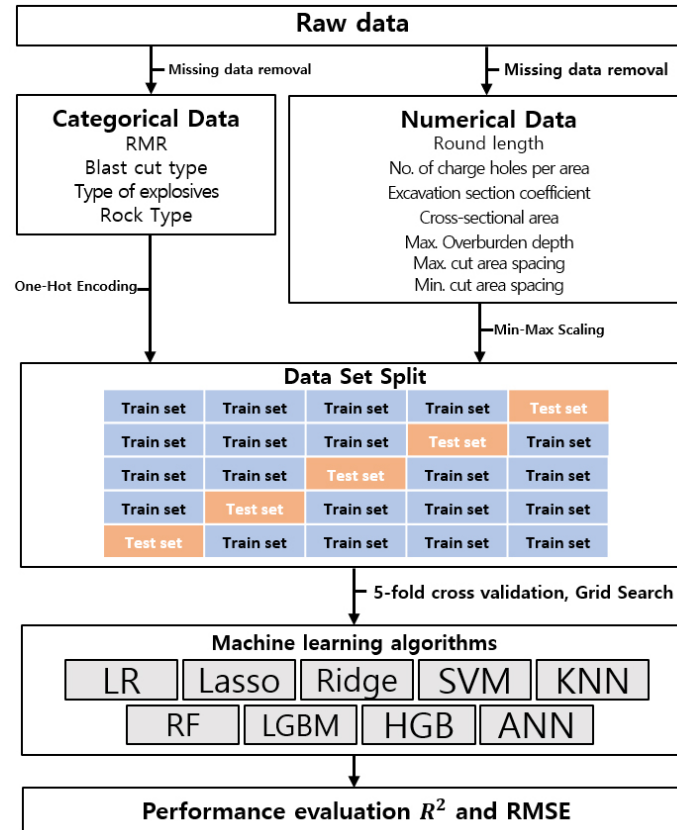


Fig. 4. Framework of machine learning analysis for specific charge prediction

## 4. 결과 및 토의

### 4.1 비장약량 예측 성능

Table 5는 비장약량 예측을 위한 머신러닝 모델들의 5겹 교차 검증 결과를 보여준다. 각 모델의 성능은 결정계수( $R^2$ )와 평균 제곱근 오차(RMSE)로 평가되었으며, 각 지표의 평균값과 표준편차를 통해 모델의 예측 성능과 안정성을 분석하였다.

모델의 최적성은 다음 세 가지 기준으로 평가하였다. 첫째, 테스트 데이터에서의 예측 정확도로, 이는 높은  $R^2$ 와 낮은 RMSE 값으로 평가된다. 둘째, 모델의 안정성으로, 이는  $R^2$ 와 RMSE의 표준편차를 통해 평가된다. 셋째, 훈련 데이터와 테스트 데이터 간의 성능 차이로, 이는 모델의 일반화 능력을 나타낸다.

양상블 기반 모델(RF, LightGBM, HGB)은 다른 모델들에 비해 전반적으로 우수한 예측 성능을 보였다. 특히 RF는 테스트 데이터에서 가장 높은  $R^2$ (0.852)와 가장 낮은 RMSE(0.082)를 기록했을 뿐만 아니라, 낮은 표준편차( $R^2$ 의 경우 0.076, RMSE의 경우 0.020)를 보여 예측의 안정성도 확보하였다. 또한 RF의 훈련 데이터( $R^2$  0.985)와 테스트 데이터( $R^2$  0.852) 간의 성능 차이가 다른 양상블 모델들과 비교하여 적절한 수준을 유지하여, 과적합 없이 좋은 일반화 성능을 보여주었다. HGB는 테스트 데이터에서의  $R^2$ 가 0.846, RMSE가 0.085로 두 번째로 우수한 성능을 보였으며, LightGBM은  $R^2$  0.840, RMSE 0.086으로 세 번째로 우수한 성능을 나타냈다.

**Table 5.** Cross-validation results of machine learning models for specific charge prediction

Model	Fold	Train R <sup>2</sup>	Train RMSE	TEST R <sup>2</sup>	TEST RMSE
LR	1	0.756	0.109	0.743	0.127
	2	0.745	0.114	0.755	0.114
	3	0.800	0.107	0.346	0.141
	4	0.770	0.109	0.651	0.133
	5	0.742	0.114	0.785	0.111
	Avg ± Std	0.763 ± 0.023	0.111 ± 0.003	0.656 ± 0.180	0.125 ± 0.013
Lasso	1	0.744	0.112	0.728	0.130
	2	0.733	0.117	0.764	0.112
	3	0.789	0.109	0.361	0.141
	4	0.758	0.112	0.687	0.126
	5	0.727	0.117	0.799	0.107
	Avg ± Std	0.751 ± 0.025	0.113 ± 0.003	0.668 ± 0.177	0.123 ± 0.014
Ridge	1	0.755	0.109	0.740	0.128
	2	0.744	0.114	0.755	0.114
	3	0.797	0.108	0.383	0.138
	4	0.770	0.109	0.655	0.132
	5	0.737	0.115	0.810	0.104
	Avg ± Std	0.761 ± 0.024	0.111 ± 0.003	0.668 ± 0.169	0.123 ± 0.014
SVM	1	0.734	0.114	0.739	0.128
	2	0.722	0.119	0.713	0.123
	3	0.775	0.113	0.347	0.142
	4	0.746	0.115	0.675	0.128
	5	0.707	0.122	0.798	0.108
	Avg ± Std	0.737 ± 0.026	0.117 ± 0.004	0.654 ± 0.178	0.126 ± 0.012
KNN	1	0.879	0.077	0.763	0.122
	2	0.874	0.080	0.725	0.121
	3	0.893	0.078	0.367	0.140
	4	0.875	0.081	0.780	0.105
	5	0.855	0.086	0.716	0.127
	Avg ± Std	0.875 ± 0.013	0.080 ± 0.003	0.670 ± 0.172	0.123 ± 0.013
RF	1	0.997	0.034	0.933	0.065
	2	0.983	0.030	0.835	0.093
	3	0.978	0.036	0.809	0.077
	4	0.988	0.026	0.758	0.110
	5	0.980	0.032	0.926	0.065
	Avg ± Std	0.985 ± 0.008	0.031 ± 0.004	0.852 ± 0.076	0.082 ± 0.020
Light GBM	1	0.959	0.045	0.903	0.078
	2	0.970	0.039	0.853	0.088
	3	0.966	0.044	0.806	0.078
	4	0.977	0.034	0.726	0.118
	5	0.967	0.042	0.914	0.070
	Avg ± Std	0.968 ± 0.007	0.041 ± 0.004	0.840 ± 0.077	0.086 ± 0.019
HGB	1	0.963	0.042	0.906	0.077
	2	0.973	0.037	0.836	0.093
	3	0.971	0.041	0.830	0.073
	4	0.980	0.033	0.745	0.113
	5	0.970	0.039	0.913	0.071
	Avg ± Std	0.971 ± 0.006	0.038 ± 0.004	0.846 ± 0.068	0.085 ± 0.018
ANN	1	0.774	0.105	0.715	0.113
	2	0.753	0.112	0.624	0.141
	3	0.804	0.106	0.359	0.141
	4	0.768	0.110	0.685	0.126
	5	0.763	0.110	0.754	0.119
	Avg ± Std	0.772 ± 0.019	0.108 ± 0.003	0.627 ± 0.157	0.128 ± 0.013

전통적인 선형 회귀 모델들(LR, Ridge, Lasso)과 SVM, KNN, ANN은 앙상블 기반 모델들에 비해 상대적으로 낮은 성능을 보였다. 이는 비장약량 예측 문제에 내재된 비선형성을 앙상블 모델들이 더 잘 포착했기 때문으로 판단된다.

Fig. 5는 모델 성능 평가 결과 최적 모델로 선정된 Random Forest 모델의 비장약량 예측 성능을 시각화한 산점도이다. 이 그래프는 Table 4에서 제시된 최적 하이퍼파라미터(max\_depth: 10, n\_estimators: 100)를 적용하여 전체 데이터셋(훈련 데이터와 테스트 데이터를 통합)에 대해 재학습한 모델의 예측 결과를 보여준다. 모델의 전체 성능은  $R^2$ 가 0.936, RMSE가 0.062로 나타났다.

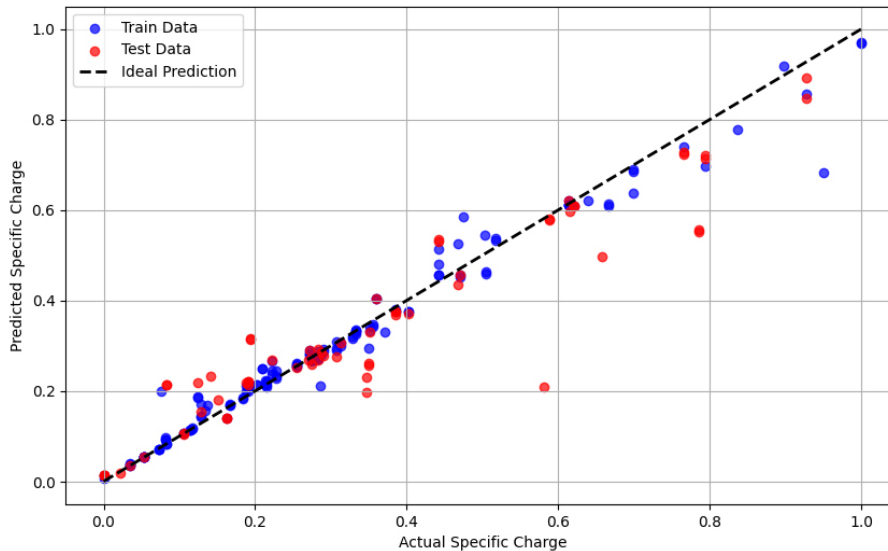


Fig. 5. Comparison of actual and predicted specific charge using random forest model

그래프에서 x축은 실제 비장약량, y축은 모델이 예측한 비장약량을 나타내며, 검은색 점선은 이상적인 예측선( $y=x$ )을 의미한다. 데이터 포인트가 이 선에 가까울수록 모델의 예측이 실제값과 잘 일치함을 의미한다. 파란색과 빨간색 점은 각각 훈련 데이터와 테스트 데이터의 예측 결과를 나타낸다.

## 4.2 변수 중요도

SHAP(SHapley Additive exPlanations)는 게임 이론의 Shapley value 개념을 기반으로 한 모델 해석 방법으로, 각 특성이 예측에 미치는 영향을 개별적으로 정량화할 수 있게 해준다. SHAP는 모든 가능한 특성 조합을 고려하여 각 특성의 한계 기여도를 계산하며, 이를 통해 복잡한 머신러닝 모델의 예측 결과를 해석하는데 유용한 도구로 활용된다.

본 연구에서는 Random Forest 알고리즘을 활용하여 비장약량의 예측 모델을 개발하고, 모델의 훈련 및 학습 과정에서 SHAP 분석을 통해 변수 중요도를 평가하였다. SHAP 분석 결과, 각 변수의 Mean Absolute SHAP Value를 산출하였으며, 이는 모델에서 해당 변수가 비장약량 예측에 기여하는 상대적인 중요도를 나타낸다. Mean Absolute SHAP Value가 높을수록 해당 변수가 모델에서 더 중요한 역할을 한다는 것을 의미한다. 특히, SHAP분석 과정에서 심발 공법 유형, 암종, 사용한 폭약 종류와 같은 범주형 변수들은 One-Hot 인코딩을 통해 확장된 개별 변수로 표현되었다. Jullum et al.(2021)에 따르면 이러한 개별 변수들을 그룹화하여 원래 변수 단위의 중요도를 평가하는 접근법은 개별 변수 수준에서 분할된 중요도를 다시 그룹 단위로 통합하여 변수의 실제 중요성을 명확히 파악할 수 있도록 한다.



Fig. 6은 SHAP 분석을 통해 비장약량 예측에 대한 각 입력변수들의 기여도를 시각화한 결과를 나타낸다. 분석 결과, 심발 공법 유형은 비장약량 예측에 가장 영향력 있는 변수로 나타났다. Mean Absolute SHAP 값이 약 0.1627로, 다른 변수들에 비해 월등히 높은 기여도를 보였으며, 이는 비장약량 예측 모델에서 심발 공법 유형이 가장 큰 영향을 미치는 변수임을 보여주었다. 이는 심발 공법의 특성상 발파 초기 자유면 형성에 결정적인 영향을 미치며, 이에 따라 전체 발파 효율과 필요 장약량이 크게 달라지기 때문으로 해석된다. 두 번째와 세 번째로 중요한 변수는 최소 공간격과 최대 공간격으로, 각각 약 0.0393과 0.0170의 값을 나타냈다. 이러한 결과는 예측 과정에서 공간격 조건이 중요한 입력변수로 작용함을 나타내며, 발파 설계 시 공간격의 결정이 비장약량에 상당한 영향을 미친다는 것을 의미한다. 특히, 최소 공간격이 최대 공간격보다 더 높은 값을 보이는 것은 발파 효율성 측면에서 최소 공간격의 설정이 더욱 중요함을 시사한다.

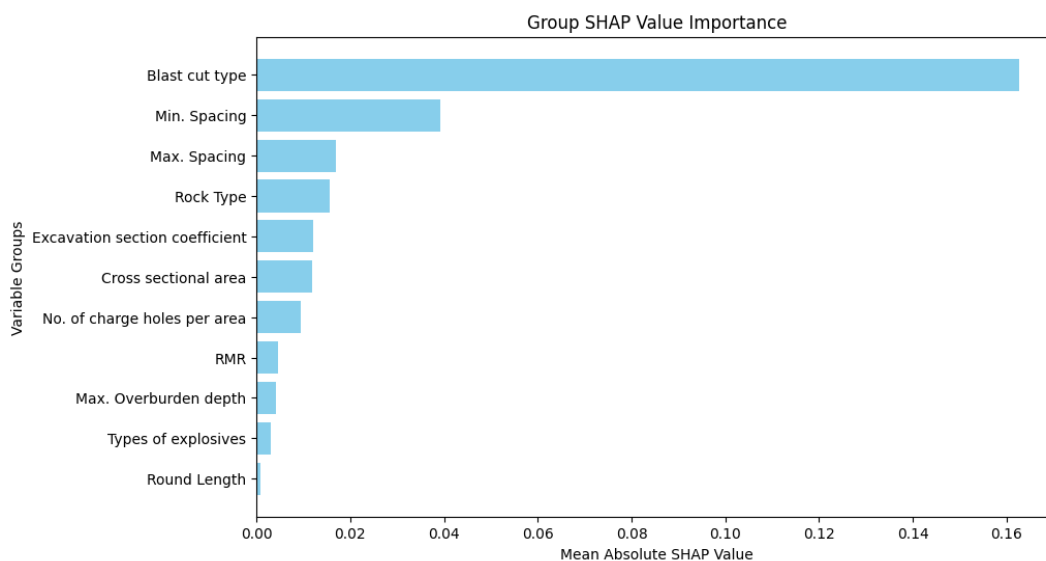


Fig. 6. Variable importance based on SHAP values for specific charge prediction

이는 최소 공간격이 발파 시 인접 공들 간의 상호작용과 응력파의 전달에 직접적인 영향을 미치기 때문이다. 그리고 암종이 약 0.0157의 값을 나타냈다. 이는 암종의 고유한 물리적 특성이 폭약량 결정에 영향을 끼친다는 점을 확인할 수 있다.

또한, 굴착 단면 계수, 전체 막장면의 단면적과 단위 면적당 천공 수는 각각 약 0.0119, 0.0117, 0.0094의 값을 나타내며, 단면적과 연관된 터널의 설계 요소들이 비장약량 예측에 영향을 끼친다는 점을 확인할 수 있다. 이러한 결과는 터널의 기하학적 특성이 비장약량 결정에 있어 중간 정도의 영향력을 가진다는 것을 보여준다. 특히, 이러한 변수들은 서로 연관성을 가지면서도 각각 독립적인 영향을 미치는 것으로 나타났다.

반면, RMR(약 0.0045), 최대 토피고(약 0.0041), 사용한 폭약 종류(약 0.0029), 굴진장(약 0.0008)의 변수들은 상대적으로 낮은 값을 보였다. 이는 이러한 변수들이 비장약량 결정에 있어 보조적인 역할을 하며, 주요 설계 변수들에 비해 상대적으로 적은 영향을 미친다는 것을 의미한다.

이러한 변수 중요도 분석 결과는 발파 설계 과정에서 각 변수들의 우선순위를 결정하는데 중요한 지표로 활용될 수 있다. 특히, 심발 공법 유형의 선택과 공간격의 설정이 비장약량 결정에 가장 큰 영향을 미치는 것으로 나타났으므로, 이러한 요소들에 대한 신중한 고려가 필요하다.

결론적으로, SHAP를 통한 변수 중요도 분석은 심발 공법 유형과 공간격 조건이 예측 과정에서 핵심 변수임을 명확히 보여주었다. 이러한 결과는 발파 설계자들이 비장약량을 결정할 때 우선적으로 고려해야 할 요소들을 제시하며, 더 효율적이고 경제적인 발파 설계를 위한 근거를 제공한다.

### 4.3 실무 적용성 검토

현재 터널 발파 실무에서 심발공의 비장약량 설계는 주로 발파 전문가의 경험과 유사 현장의 설계사례를 참고하여 이루어지고 있다. 실무자들은 암반강도와 RMR 등 지반조건, 터널 단면적과 굴진장, 심발공법의 유형, 사용하는 폭약의 특성 등을 주요 설계변수로 고려하며, 시험발파를 통한 결과를 바탕으로 설계를 수정/보완하는 방식을 사용하고 있다.

본 연구의 SHAP 분석 결과는 이러한 실무 접근방식에 대해 중요한 시사점을 제공한다. 분석 결과에 따르면 심발공법 유형과 최소 공간격이 가장 큰 영향을 미치는 것으로 나타났다. 반면 실무에서 중요하게 고려되어 온 RMR은 상대적으로 낮은 영향도를 보였다. 이는 실무자들이 심발공 설계 시 공법 선정과 공간격 설정에 더 많은 주의를 기울일 필요가 있음을 의미한다.

본 연구에서 개발된 Random Forest 모델은 높은 예측 정확도를 보여주었으며, 이는 기존의 경험적 접근법을 보완하는 정량적 의사결정 도구로서 활용될 수 있음을 시사한다. 특히 설계변수들의 상대적 중요도를 객관적 수치로 제시함으로써, 실무자들이 보다 체계적이고 효율적인 설계를 수행하는데 도움을 줄 수 있을 것으로 기대된다.

## 5. 결론

본 연구에서는 터널 내 발파공법 설계 시 심발 영역의 비장약량을 예측하기 위해 다양한 머신러닝 기법의 적용성을 평가하였다. 주요 연구 결과는 다음과 같다.

- 1) 총 18개 터널 발파 프로젝트에서 208개의 데이터 세트를 수집하여 분석에 활용하였다. 이 데이터들은 굴진장, 단위 면적당 천공수, 굴착단면계수, 전체 막장면의 단면적, 심발 영역의 최대/최소 공간격, 심발 공법 유형, 폭약 종류, RMR, 최대 토피고, 암종을 포함하고 있다. 데이터 전처리 과정에서는 범주형 변수에 One-Hot Encoding을, 수치형 변수에는 Min-Max scaling을 적용하였다.
- 2) 9가지 머신러닝 모델(LR, Lasso, Ridge, SVM, KNN, RF, LightGBM, HGB, ANN)을 비교 평가한 결과, Random Forest 모델이 가장 우수한 성능을 보였다. 이 모델은 테스트 데이터에서 평균  $R^2$  값 0.852, 평균 RMSE 값 0.082를 기록하였으며, 낮은 표준편차( $R^2$ : 0.076, RMSE: 0.020)를 보여 예측의 안정성도 확보하였다.
- 3) SHAP (SHapley Additive exPlanations) 분석을 통한 변수 중요도 분석 결과, 심발 공법 유형(Mean Absolute SHAP Value: 0.1627)이 비장약량 예측에 가장 큰 영향을 미치는 것으로 나타났으며, 최소 공간격(0.0393)과 최대 공간격(0.0170)이 그 뒤를 이었다. 이는 발파 설계 시 심발부 형성과 공간격 설정이 비장약량 결정에 핵심적인 역할을 한다는 것을 의미한다. 반면, 최대 토피고(0.0041), 암반 등급(0.0045), 사용한 폭약 종류(0.0029), 굴진장(0.0008)은 상대적으로 낮은 중요도를 보여, 이러한 요소들이 비장약량 결정에 있어 보조적인 역할을 함을 확인하였다.
- 4) 본 연구에서 개발된 모델은 터널 현장의 다양한 지질 조건에 맞춤형 발파 설계를 가능하게 하여, 터널 건설 프로젝트의 효율성과 안전성을 향상시킬 수 있음을 보여준다. 향후 연구에서는 확대공, 외곽공, 바닥공 등 터널 전체 영역으로 모델을 확장하고, 실시간 데이터 업데이트를 통한 모델의 지속적인 개선이 필요할 것으로 판단된다.

## 감사의 글

본 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 수행되었음(과제명 : 초장대 K-지하고속도로 인프라 안전 및 효율 향상 기술 개발, 과제번호 RS-2024-00416524)

## REFERENCES

- Adesida, P.A., 2022, Powder factor prediction in blasting operation using rock geo-mechanical properties and geometric parameters, *International Journal of Mining and Geo-Engineering*, 56(1), 25-32.
- Alipour, A., Jafari, A., and Hossaini, S.M.F., 2012, Application of ANNs and MVLRA for estimation of specific charge in small tunnel, *International Journal of Geomechanics*, 12(2), 189-192.
- Alipour, A., Mokhtarian-Asl, M., and Asadzadeh, M., 2021, Support vector machines for the estimation of specific charge in tunnel blasting, *Periodica Polytechnica Civil Engineering*, 65(3), 967-976.
- Bieniawski, Z.T., 1973, Engineering classification of jointed rock masses, *Civil Engineering= Siviele Ingenieurswese*, 1973(12), 335-343.
- Choi, B.H., Ryu, C.H., and Jung, J.H., 2009, Tunnel Blasting Design Suited to Given Specific Charge, *Explosives and Blasting*, 27(2), pp. 33-41.
- Construction CALS, 2024, Home page, <https://www.calspia.go.kr/io/index.do>(Jun 24, 2024).
- Freund, Y. and Schapire, R.E., 1996, Experiments with a new boosting algorithm, In: *icml*, 96, 148-156.
- Hanwha Corporation, 2017, Technical Manual of Commercial Explosives Products, Hanwha Corporation, Seoul, Korea.
- Hong, J.P., Kang, Y.S., and Ko, T.Y., 2024, Estimation of Cerchar abrasivity index based on rock strength and petrological characteristics using linear regression and machine learning, *Journal of Korean Tunnelling and Underground Space Association*, 26(1), 39-58.
- Hwang, H. and Lee, T.N., 2002, A Study on pilot Test of the Composition Presplitting Angle Cut method in tunnel blasting, *Journal of Korean Tunnelling and Underground Space Association*, 4(4), 287-300.
- Jong, Y.H. and Lee, C.I., 2004, Influence of geological conditions on the powder factor for tunnel blasting, *International Journal of Rock Mechanics and Mining Sciences*, 41(3), 533-538.
- Jong, Y.H. and Lee, J.I., 2001, Application of Neural Network Theory for Predicting Specific Charge and Vibration Velocity in Tunnel Blasting, *Proceedings of the Korean Society for Rock Mechanics Conference and Seminar*, pp. 75-84.
- Jullum, M., Redelmeier, A., and Aas, K., 2021, groupShapley: Efficient prediction explanation with Shapley values for feature groups, arXiv preprint arXiv, 2106.12228.
- Jung, D.H., Kim, S.H., Bae, H.J., Seok, J.H., and Chu, Y.B., 2001, A Study on the Determination of Suitable Specific Charge in Tunnel Blasting Design, *Journal of Korean Tunnelling and Underground Space Association*, 3(1), 21-26.
- Kahrman, A., Özkan, Ş.G., Sül, Ö.L., and Demirci, A., 2001, Estimation of the powder factor in bench blasting from the Bond work index, *Mining Technology*, 110(2), 114-118.
- Kim, Y.K., Lee, J.K., and Lee, S.W., 2022, A fundamental study on the automation of tunnel blasting design using a machine learning model, *Journal of Korean Tunnelling and Underground Space Association*, 24(5), 431-449.
- Kwon, K.B., Choi, H.S., Oh, J.Y., and Kim, D.K., 2022, A study on EPB shield TBM face pressure prediction using machine

- learning algorithms, *Journal of Korean Tunnelling and Underground Space Association*, 24(2), 217-230.
- Lee, J.K., Kim, Y.K., and Lee, S.S., 2022, A study on the optimization of tunnel support patterns using ANN and SVR algorithms, *Journal of Korean Tunnelling and Underground Space Association*, 24(6), 617-628.
- Liashchynskiy, P. and Liashchynskiy, P., 2019, Grid search, random search, genetic algorithm: a big comparison for NAS, arXiv preprint arXiv:1912.06059.
- Min, H.D., Jeong, M.S., Song, Y.S., and Park, Y.S., 2005a, Blast Design Methods Considering Site Specific Characteristics(II), *Journal of Korean Tunnelling and Underground Space Association*, 7(4), 63-80.
- Min, H.D., Lee, Y.J., Park, Y.S., and Choi, K.Y., 2005b A Case of Application in Hard Rock Tunnel and Development of High Performance Emulsion Explosives(MegaMEX), *Explosives and Blasting*, 23(1), 55-64.
- Son, J.H., Kim, B.R., Lee, S.J., Kim, N.S., Lee, H., and Choi, S.O., 2019, A Numerical Study on the Reduction Effect of Blasting Vibration with Cut Method, *Explosives and Blasting*, 37(1), 1-13.
- Taiwo, B.O., Gebretsadik, A., Abbas, H.H., Khishe, M., Fissaha, Y., Kahraman, E., Rabbani, A., and Akinlabi, A.A., 2024, Explosive Utilization Efficiency Enhancement: An Application of Machine Learning for Powder Factor Prediction using Critical Rock characteristics, *Heliyon*, 10(12), e33099.