

연구논문

노천 채석장 대기소음 예측을 위한 머신러닝 모델 개발

정다희¹ · 최요순^{2*}¹부경대학교 환경해양대학 에너지자원공학과 석사과정, ²부경대학교 환경해양대학 에너지자원공학과 교수

Development of Machine Learning Models for Predicting Air Overpressure in an Open-pit Mine

Dahee Jung¹ and Yosoon Choi^{2*}¹M.S Course, Dept. of Energy Resources Engineering, Pukyong National University, Busan, Korea²Professor, Dept. of Energy Resources Engineering, Pukyong National University, Busan, Korea

*Corresponding Author. Yosoon Choi, energy@pknu.ac.kr, Dept. of Energy Resources Engineering, Pukyong National University, Busan, Korea

Received

19 January 2022

Final version Received

17 February 2022

Accepted

22 February 2022

Abstract

In this study, machine learning models were developed to predict air overpressure resulting from blasting in an open-pit mine. A total of 924 blasting data were collected from an open-pit mine at the Mt. Yogmang located in Changwon-si, Gyeongsangnam-do, Korea. The blasting data consisted of hole length, burden, spacing, maximum charge per delay, powder factor, number of holes, ratio of emulsion, monitoring distance and air overpressure. Four algorithms including k-nearest neighbors (kNN), random forest (RF), extreme gradient boosting (XGBoost) and deep neural network (DNN) were used to train the machine learning models. Mean absolute error (MAE), mean squared error (MSE), and root mean squared error (RMSE) were analyzed to evaluate the performance of the trained models. As a result, the RF model showed superior performance with MAE, MSE and RMSE of 4.938, 42.032 and 6.483, respectively.

Key words : Blasting, Air overpressure, Machine learning, Open-pit mine

요약

본 연구에서는 노천 채석장 발파에서 발생하는 대기소음을 예측하기 위한 머신러닝 모델을 개발하였다. 경상남도 창원시에 위치한 욱망산 노천 채석장에서 924개의 발파 데이터를 수집하였다. 각 발파 데이터는 천공장, 저항선, 공간격, 지발당 최대장약량, 비장약량, 총 공수, 에멀전폭약 비율, 이격거리, 대기소음으로 구성되었다. 머신러닝 모델 개발을 위해 kNN (k-nearest neighbors), RF (random forest), XGBoost (extreme gradient boosting), DNN (deep neural network) 알고리즘을 사용했다. 훈련된 모델의 성능을 MAE(평균 절대 오차), MSE(평균 제곱 오차) 및 RMSE(평균 제곱근 오차)로 평가한 결과, RF 모델이 MAE, MSE, RMSE가 각각 4.938, 42.032, 6.483로 가장 우수한 성능을 보였다.

주요어 : 발파, 대기소음, 머신러닝, 노천 채석장

서 론

광업 및 건설 현장에서 발파 작업으로 인해 발생하는 대기소음(air overpressure), 발파진동, 비석은 인근 지역주민과 환경에 피해를 줄 수 있다(Khandelwal and Singh, 2005; Monjezi *et al.*, 2011; Rezaei *et al.*, 2011; Roy *et al.*, 2011; Armaghani *et al.*, 2015a; Ebrahimi *et al.*, 2016). 특히, 발파 충격파에 의한 급격한 기압 변화로 발생하는 대기소음은 사람의 청각, 폐, 뇌 및 기타 장기에 손상을 유발할 수 있으며, 주변 건물의 유리창을 파손하는 등 재산피해를 줄 수 있다(Khandelwal and Kankar, 2011; Mohamad *et al.*, 2016). 따라서 발파시 발생할 수 있는 대기소음의 크기를 발파설계 단계에서 예측하여 피해방지 대책을 수립하는 것이 중요하다.

그동안 발파시 발생하는 대기소음의 크기를 예측하는 기법에 관한 연구가 다수 수행되었다(Siskind *et al.*, 1980; Hustrulid, 1999; Kuzu *et al.*, 2009; Hajihassani *et al.*, 2014). 기존의 연구들은 지발당 최대장약량과 이격거리를 고려하여 대기소음을 예측할 수 있는 경험식을 다음과 같이 제시하였다.

$$AOp = H(DW^{-b})^{-\beta} \quad (1)$$

여기서 AOp 는 대기소음(dB(A)), D 는 발파원으로부터의 이격거리(m), W 는 지발당 최대장약량(kg/delay)이다. b 는 상승근 환산거리(Square Root Scaled Distance, SRSD)를 적용시 1/2, 삼승근 환산거리(Cube Root Scaled Distance, CRSD)를 적용시에는 1/3이다. H 와 β 는 암반 및 발파 조건에 따르는 상수를 의미한다(Table 1). 그러나 많은 연구에서 경험식을 이용한 대기소음 예측은 정확도가 높지 않다고 보고하였다(Khandelwal and Singh, 2005; Khandelwal and Kankar, 2011; Armaghani *et al.*, 2015a;

Armaghani *et al.*, 2016; Hasanipanah *et al.*, 2016; Hasanipanah *et al.*, 2017; Armaghani *et al.*, 2018).

이러한 한계를 극복하기 위해 최근에는 머신러닝 모델을 이용한 대기소음 예측에 관한 연구가 활발히 진행되고 있다. Khandelwal and Singh(2005)는 마그네사이트 광산에서 수집된 56개의 발파 데이터를 이용하여 대기소음의 크기를 예측할 수 있는 인공신경망(artificial neural network, ANN) 모델을 개발하였다. Armaghani *et al.*(2015b)는 노천광산에서 128개의 발파 데이터를 획득하여 다섯 개의 입력변수(지발당 최대장약량, 비장약량, 저항선, 전색장, 이격거리)와 한 개의 출력변수(대기소음)로 구성된 ANFIS(adaptive neuro-fuzzy inference system)을 개발하였다. 그 밖에도 발파로 인한 대기소음을 예측하기 위한 머신러닝 모델 개발에 관한 연구가 다수 수행되었다(Armaghani *et al.*, 2016; Hasanipanah *et al.*, 2017; Nguyen and Bui, 2019; Nguyen *et al.*, 2020). Table 2는 대기소음 예측용 머신러닝 모델 개발 관련하여 기존 연구들이 수행된 지역(국가), 사용된 데이터의 수, 고려한 인자들의 종류를 보여준다. 그러나 해외 연구동향과는 달리 국내에서는 대기소음 예측을 위한 머신러닝 모델 개발에 관한 연구가 미흡한 실정이다.

본 연구에서는 국내 노천 채석장에서 2012년 9월부터 2018년 8월까지 수집된 924개의 발파 모니터링 데이터를 이용하여 발파시 발생하는 대기소음을 예측할 수 있는 머신러닝 모델을 개발하였다. 천공장, 저항선, 공간격, 지발당 최대장약량, 비장약량, 총공수, 장약된 화약 중 에멀전폭약의 비율, 이격거리를 모델의 입력인자로 사용하였고, 4종의 머신러닝 알고리즘 즉, kNN(k-nearest neighbors), RF(random forest), XGBoost(extreme gradient boosting), DNN(deep neural network)을 이용하여 모델을 훈련하였다. 훈련된 4종의 머신러닝 모델의 대기소음 예측 성능을 비교하여 연구지역에서 사용될 수 있는 최적의 머신러닝 모델을 제안하였다.

Table 1. Values of H and β used in the empirical formula for air overpressure prediction in previous studies

Reference	Rock and blasting conditions	H	β
Siskind <i>et al.</i> 1980	Quarry blasts, behind face	622	0.515
	Quarry blasts, direction of initiation	19,010	1.12
	Quarry blasts, front of face	22,182	0.966
Hustrulid, 1999	Detonations in air	185,000	1.2
Kuzu <i>et al.</i> 2009	Quarry blasts in competent rocks	261.54	0.706
	Quarry blasts in weak rocks	1833.8	0.981
	Overburden removal	21,014	1.404
Hajihassani <i>et al.</i> 2014	Quarry blasts, front of face (distance of 300 m)	10,909	1.09
	Quarry blasts, front of face (distance of 600 m)	959.48	0.45

Table 2. Study area, the number of data and features considered in previous studies for predicting air overpressure using machine learning models

Reference	Khandelwal and Singh, 2005	Armaghani <i>et al.</i> , 2015b	Armaghani <i>et al.</i> , 2016	Hasanipanah <i>et al.</i> , 2016	Hasanipanah <i>et al.</i> , 2017	Nguyen and Bui, 2019	Nguyen <i>et al.</i> , 2020
Study area (country)	Mirzapur and Pitoragarh (India)	Kulai, Senai and Kota Tinggi (Malaysia)	Rafsanjan (Iran)	Kerman Province (Iran)	Kerman Province (Iran)	Ha Long (Vietnam)	Hanoi (Vietnam)
Number of data	56	128	70	77	83	114	146
Feature	Maximum charge per delay	○	○	○	○	○	○
	Monitoring distance	○	○	○	○	○	○
	Burden		○			○	○
	Spacing					○	○
	Powder factor		○			○	○
	Bench height						○
	Stemming		○			○	○
	Number of holes						○
	Vertical distance					○	
	Air humidity						○

연구방법

연구지역 및 데이터

본 연구에서는 경상남도 창원시에 있는 옥망산의 노천 채석장(35°05'12"N, 128°47'24"E)을 연구지역으로 선정하였다(Fig. 1). 옥망산 정상의 해발고도는 약 200m이며, 지형 경사는 20~40° 정도이다. 연구지역의 산지와 능선 쪽에는 안산암과 유문암이 주로 분포하며, 해안 쪽에서는 산상으로 분포한 화강암을 볼 수 있다(Lee *et al.*, 2001). 연구지역에 관한 추가적인 설명은 Jung and Choi(2021)에 제시되어 있다. 연구지역에서는 2012년 9월부터 2018년 8월까지 총 4,612회의 발파가 시행되었고, 발파가 시행될 때 이격거리에 따른 대기소음 측정 결과를 기록하였다.

본 연구에서는 연구지역에서 시행된 과거 발파 기록을 정리하여 머신러닝 모델 개발을 위한 데이터 세트를 제작하였다. 제작된 데이터 세트는 8개의 입력변수와 1개의 출력변수로 구성된다. 8개의 입력변수는 천공장, 저항선, 공간격, 지발당 최대장약량, 비장약량, 총공수, 에멀전폭약 비율, 이격거리이다. 여기서 에멀전폭약 비율은 에멀전과 안포(ANFO)를 혼합한 화약에서 에멀전이 차지하는 비율을 의미한다. 출력변수로는 대기소음 측정값을 사용하였다.



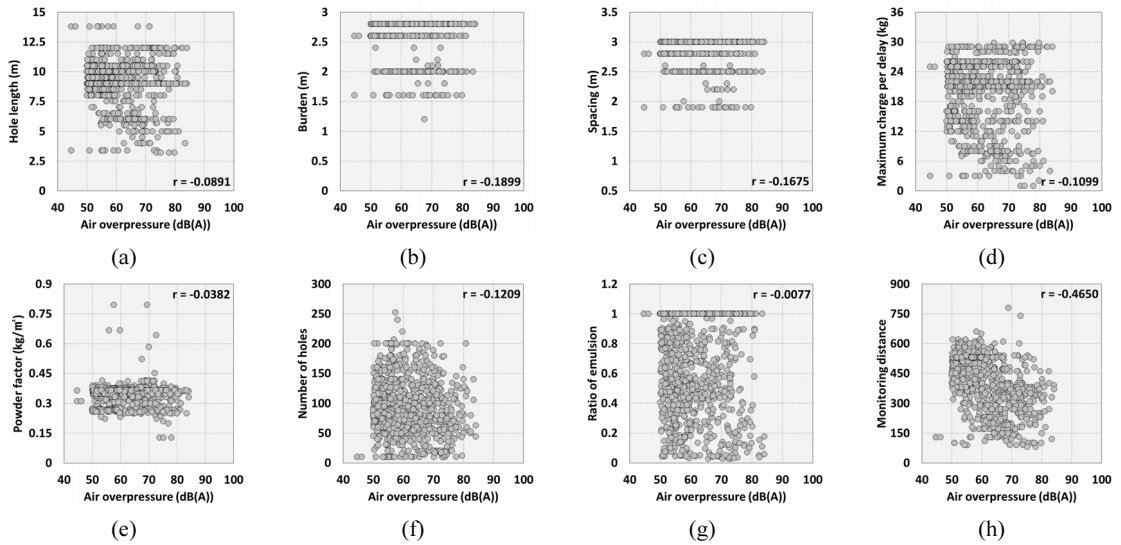
Fig. 1. Bird's-eye view of the study area.

연구지역의 발파 기록 중 값이 누락되거나 이상치를 보이는 것을 제외하면 머신러닝 모델 개발에 활용 가능한 유효 데이터 수는 총 924개였다. Table 3은 유효 데이터의 입력변수와 출력변수에 대한 통계적 특성을 보여주며, Fig. 2는 대기소음과 각 입력변수 간의 상관성과 Pearson 상관계수(r)를 보여준다. 대기소음과 각각의 입력변수는 개별적으로는 상관관계가 없거나 약한 음의 상관관계를 보였다.

본 연구에서는 유효 데이터 924개 중 80%(739개)를 학습데이터 세트로 사용하였고, 나머지 20%(185개)를 테스트 데이터 세트로 사용하였다.

Table 3. Basic statistics of data sets used for developing machine learning models

Type	Feature	Unit	Statistics						
			min	Q1	median	mean	Q3	max	STD
Input	Hole length	m	3.2	9.0	9.0	9.1	10	13.8	1.9
	Burden	m	1.2	2.6	2.8	2.6	2.8	2.8	0.3
	Spacing	m	1.9	2.8	3.0	2.9	3.0	3.0	0.2
	Maximum charge per delay	kg	1.0	15.0	22.0	19.6	25.0	29.8	6.7
	Powder factor	kg/m ²	0.128	0.333	0.357	0.342	0.364	0.795	0.051
	Number of holes		10.0	60.0	90.0	92.8	120	252.0	45.6
	Ratio of emulsion		0.028	0.388	0.684	0.650	1.000	1.000	0.324
	Monitoring distance	m	80.0	312.5	420.0	400.0	520.0	780.0	129.6
Output	Air overpressure	dB(A)	44.7	55.0	59.5	61.6	67.8	84.1	8.3

**Fig. 2.** Correlation between the input ((a) hole length, (b) burden, (c) spacing, (d) maximum charge per delay, (e) powder factor, (f) number of holes, (g) ratio of emulsion, and (h) monitoring distance) and output (air overpressure) variables.

머신러닝 알고리즘

본 연구에서는 kNN, RF, XGBoost, DNN 알고리즘을 사용하여 대기소음 예측을 위한 머신러닝 모델을 훈련하였다. kNN 모델은 머신러닝에 사용되는 간단한 지도학습 모델이다(Quiros *et al.*, 2017). 훈련 데이터에서 k개의 표본을 선택한 후 가장 가까운 이웃(neighbors)을 기준으로 예측을 수행한다. 따라서 가장 가까운 이웃을 결정하는데 사용되는 거리에 따라 예측 정확도가 달라진다(Pandya *et al.*, 2013). kNN은 훈련 데이터를 미리 학습하지 않고 그대로 가지고 있다가 작업 요청이 있을 때 학습을 수행하기 때문에 게으른 학습(lazy learning) 모델이라고도 한다(Elevaro

et al., 2018).

RF 알고리즘은 무작위로 생성된 수많은 결정 트리(decision tree)들을 숲과 같은 하나의 형태로 만들어 학습을 수행한다. 하나의 트리의 학습 결과가 좋다면 많은 수의 트리는 더 좋을 것이며, 다양함을 표현하기에 적합할 것이라고 가정한다. RF는 결정 트리에서의 수직 경계들을 합하여 더 유연한 경계를 생성할 수 있다는 장점이 있다(Yoon *et al.*, 2018). 마찬가지로 XGBoost도 수 많은 결정 트리들을 병렬처리하여 학습을 수행하는 알고리즘이다. 병렬처리를 통해 신속하게 머신러닝 모델을 훈련할 수 있으며 앞선 결정 트리의 오류를 고려하여 가중치를 계산함으로써 연속적

인 학습이 가능하다는 장점이 있다(Zhou *et al.*, 2016).

DNN은 인간의 신경망 구조에서 영감을 받아 인간 두뇌와 유사한 형태로 정보를 처리하는 인공신경망에 바탕을 둔 알고리즘이다. 입력된 데이터는 입력층, 출력층, 다수의 은닉층의 계층 구조를 가지는 많은 수의 신경층을 통해 특징 추출 과정을 거쳐 학습을 수행한다. 은닉층과 노드의 수를 다양하게 조절함으로써 최적의 딥러닝 모델을 찾을 수 있다(Yoon *et al.*, 2018).

교차검증 및 매개변수 최적화

본 연구에서는 머신러닝 모델의 훈련 과정에서 학습데이터 세트를 이용한 5겹 교차검증(5-fold cross validation)을 수행하였다. 학습데이터 세트를 다섯 세트로 나누어 이 중 네 개로는 머신러닝 모델을 훈련하고, 나머지 한 개를 검증 데이터 세트로 사용하여 훈련과 검증을 반복적으로 수행하였다(Fig. 3). 이러한 5겹 교차검증을 통해 학습데이터 세트의 데이터를 모두 검증 데이터 세트로 사용할 수 있었다.

머신러닝 모델을 개발하기 위해서는 머신러닝 알고리즘에 포함된 다양한 매개변수들의 설정을 최적화할 필요가 있다(Park *et al.*, 2021). 본 연구에서는 Table 4와 같이 알고리즘별로 매개변수의 값을 변화시키면서 반복적으로 머신

러닝 모델 훈련을 수행한 후 최적의 매개변수 값을 선정하였다.

성능평가

본 연구에서는 회귀 문제에서 성능평가 지표로 일반적으로 사용되는 MAE(mean absolute error), MSE(mean squared error), RMSE(root mean squared error)를 이용하여 머신러닝 모델을 평가하였다. 식(2)~식(4)는 각각 MAE, MSE, RMSE의 계산식이다. 여기서 n은 전체 샘플의 수, $h(x^{(i)})$ 는 i 번째 샘플의 예측값, $y^{(i)}$ 는 i 번째 샘플의 실측값을 의미한다.

$$MAE(X, h) = \frac{1}{n} \sum_{i=1}^n |h(x^{(i)}) - y^{(i)}| \tag{2}$$

$$MSE(X, h) = \frac{1}{n} \sum_{i=1}^n (h(x^{(i)}) - y^{(i)})^2 \tag{3}$$

$$RMSE(X, h) = \sqrt{\frac{1}{n} \sum_{i=1}^n (h(x^{(i)}) - y^{(i)})^2} \tag{4}$$

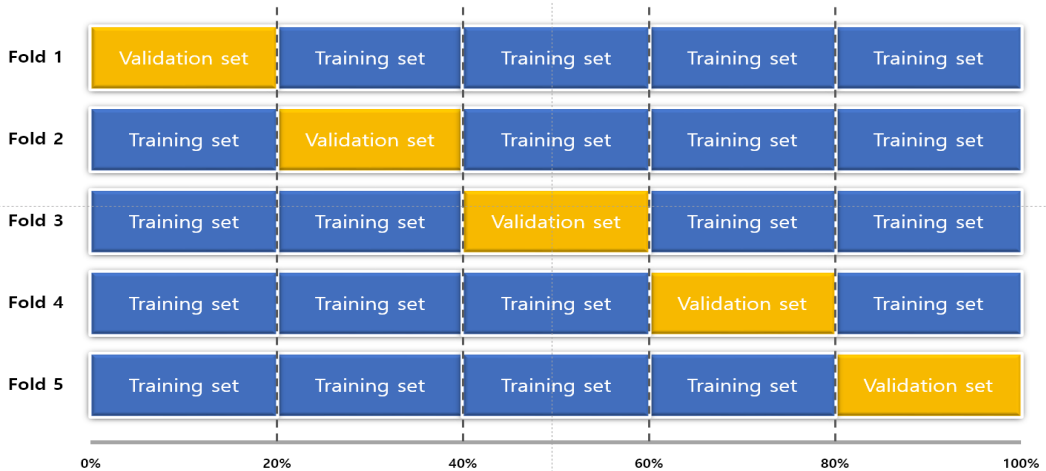


Fig. 3. Typical diagram of 5-fold cross validation.

Table 4. Values used for parameter tuning in machine learning algorithms

	kNN	RF	XGBoost	DNN
Parameter	neighbors	depth & estimators	depth & estimators	hidden layer / nodes
Min	1	100	100	1 / 20
Max	300	500	500	5 / 60
Step	(+) 1	(+) 50	(+) 50	(+) 1 / 10

연구결과

본 연구에서는 4종류의 머신러닝 알고리즘에 의한 예측 결과를 비교하여, 연구지역에서 발파 작업시 대기소음을 예측하는데 사용할 머신러닝 모델을 선정하였다. 5겹 교차검증을 통해 머신러닝 알고리즘별로 매개변수를 최적화하였다(Fig. 4). kNN 모델의 경우 neighbors가 1부터 87까지 증가할 때 MAE가 감소하다가 87 이후부터는 MAE가 다시 증가하는 것을 볼 수 있다. 따라서 kNN 모델은 neighbors를 87로 설정할 때 MAE가 5.398로 최적의 성능을 보임을 알

수 있다. RF 모델의 경우 매개변수들의 조합에 따라 예측 성능이 크게 달라졌다. 매개변수 조합 중 depth가 250, estimators가 450일 때, MAE가 5.206로 가장 좋은 훈련 결과를 보였다. XGBoost 모델은 모든 매개변수 조합에서 MAE가 5.732로 동일한 예측 성능을 보였다. DNN 모델의 경우 hidden layer의 수가 1, nodes의 수가 40일 때 MAE가 5.366으로 가장 우수한 예측 성능을 보였다.

5겹 교차검증을 통해 선정된 최적의 매개변수들을 머신러닝 알고리즘에 적용하여 모델을 훈련한 후 테스트 데이터 세트(전체 데이터의 20%, 185개)에 대한 모델의 예측 성

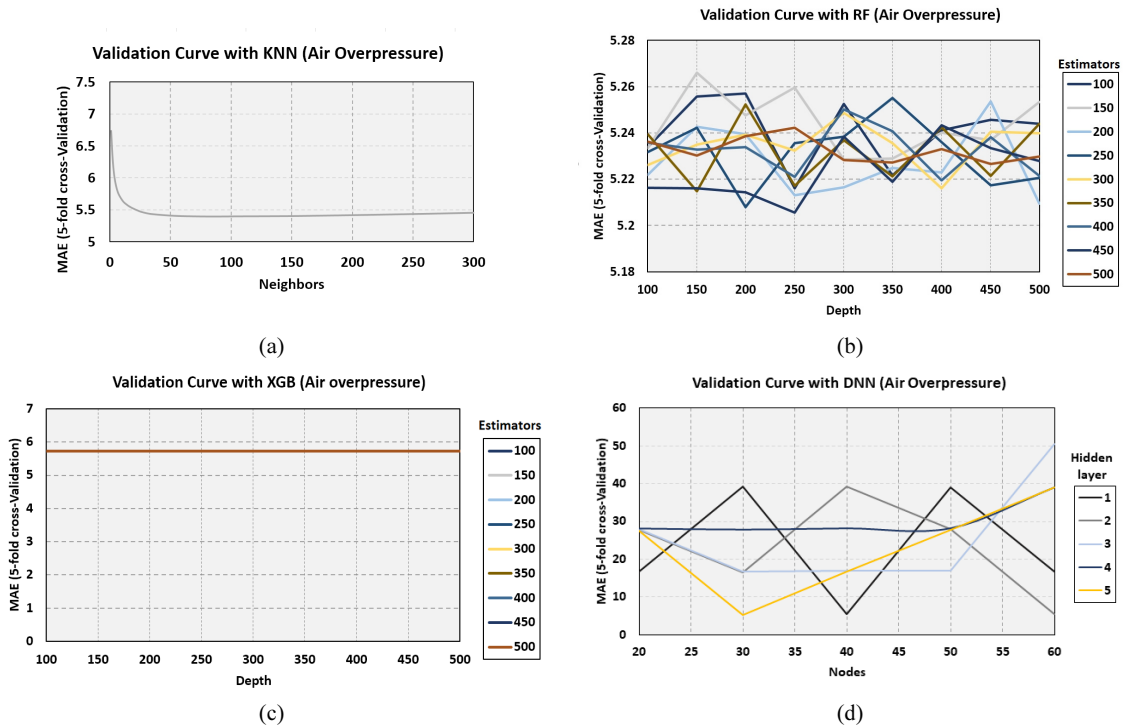


Fig. 4. Variations of training accuracy with parameter changes. (a) kNN. (b) RF. (c) XGBoost. (d) DNN.

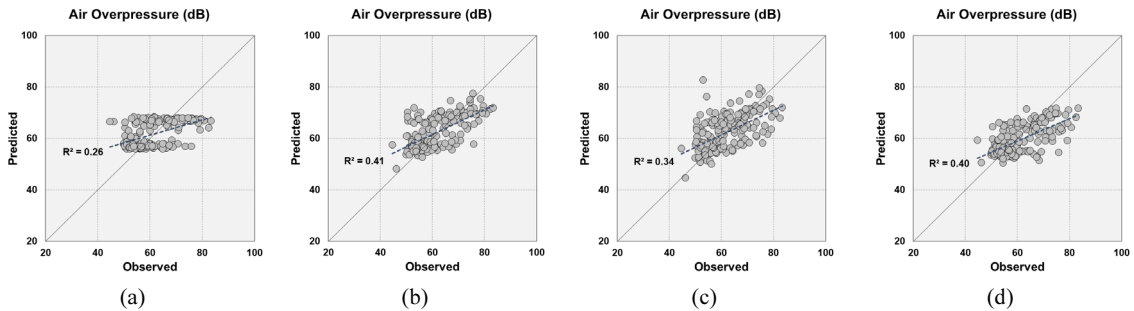


Fig. 5. Correlation between the predicted and observed values of air overpressure. (a) kNN. (b) RF. (c) XGBoost. (d) DNN.

능을 평가하였다. Fig. 5에서 kNN 모델의 예측값과 실측값의 데이터 분포를 보면 예측값이 약 55dB(A)과 68dB(A)에 몰려있는 것을 확인할 수 있다. 대조적으로 kNN 모델을 제외한 나머지 세 가지 모델은 예측값이 일부 값으로 집중되지 않고 편향되지 않은 것을 확인할 수 있다. 그러나 RF, XGBoost, DNN 모델도 예측값과 실측값의 상관계수(R^2)가 각각 0.41, 0.34, 0.40로 분석되어 약한 상관관계를 가지는 것으로 나타났다. 즉, 실측값과 예측값을 도시한 점들의 전체적인 분포를 볼 때는 4종류의 모델 모두 예측값과 실측값 간의 높은 상관관계를 보이지는 않았다.

Fig. 6은 테스트 데이터 세트를 이용해 4종의 알고리즘으로 훈련한 머신러닝 모델들의 성능지표를 계산한 후 비교한 결과이다. RF 모델은 MAE가 4.938dB(A), MSE가 42.032dB(A), RMSE가 6.483dB(A)로 분석되었다. Fig. 5와 Fig. 6을 살펴보았을 때, RF 모델은 실측값과 예측값이 약한 상관관계를 보였으나, 예측값의 분포가 편향되지 않고 성능평가의 지표로 사용한 MAE, MSE, RMSE가 다른 세 종류의 모델에 비해 상대적으로 우수한 것으로 나타났다. 따라서 본 연구에서는 RF 모델을 연구지역의 대기소음 예측 모델로 선정하였다.

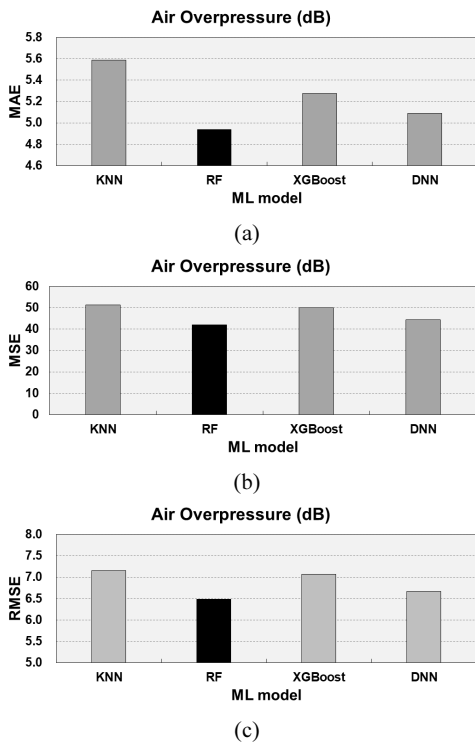


Fig. 6. Performance of the four machine learning models. (a) MAE. (b) MSE. (c) RMSE.

토 의

테스트 데이터 세트를 이용해 RF 모델과 Siskind *et al.*(1980)가 제시한 경험식의 대기소음 예측 성능을 비교해 보았다. Fig. 7은 Siskind *et al.*(1980)가 제시한 경험식을 적용하여 테스트 데이터 세트에 대한 대기소음을 예측한 결과이다. 경험식을 적용한 예측값과 실측값의 결정계수(R^2)는 0.16으로 분석되었다. Fig. 5(b)에 제시된 RF 모델을 이용한 대기소음 예측 결과와 비교할 때 경험식을 적용한 결과는 예측값과 실측값을 도시한 점들의 분포가 $y=x$ 함수의 중심선에서 상대적으로 더 크게 이격되는 것을 확인할 수 있었으며, 결정계수(R^2)도 RF 모델의 결과보다 상대적으로 작았다. 경험식을 이용한 대기소음 예측 결과의 성능지표를 분석한 결과 MAE는 13.506dB(A), MSE는 240.666dB(A), RMSE는 15.513dB(A)로 나타났다(Fig. 8). 따라서 본 연구에서 개발된 RF 모델의 대기소음 예측 성능이 기존의 경험식에 비해 우수한 것으로 판단된다.

한편 연구지역에서는 2022년부터 2033년까지 12년간 석산 개발을 통해 토사(200만 m^3)와 석재(4000만 m^3)를 생산하여 부산 신항 공사를 위한 골재로 공급할 예정이다. 본 연구에서 개발된 RF 모델은 연구지역에서 향후 석산 개발을 진행하는 동안 발파에 따른 대기소음을 예측하는데 사용될 수 있을 것이다. 예를 들어, Table 5와 같은 발파설계 인자들을 개발된 RF 모델에 입력하면 발파지점으로부터 이격거리에 따른 대기소음을 예측할 수 있다. 이격거리에 따른 대기소음 예측 결과를 거듭제곱 모델(power trendline)을 이용해 추세선으로 나타내면 Fig. 9와 같다. 발파지점으로부터 거리가 멀어질수록 대기소음의 크기가 줄어드는 것으로 예측되었다. 이 결과를 활용하면 발파지점으로부터 일정 거리 내에 사람이나 건물이 존재할 때 대기소음 크기를 사전에 예측하여 피해를 예방할 수 있을 것이다.

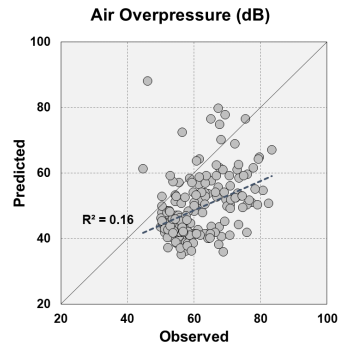


Fig. 7. Correlation between the predicted values using Equation 1 and the observed values air overpressure.

Table 5. Example of blasting design values input to the developed RF model

Hole length (m)	Burden (m)	Spacing (m)	Maximum charge per delay (kg)	Powder factor (kg/m ³)	Number of holes	Ratio of emulsion
6.4	2	2.3	8	0.29	20	1

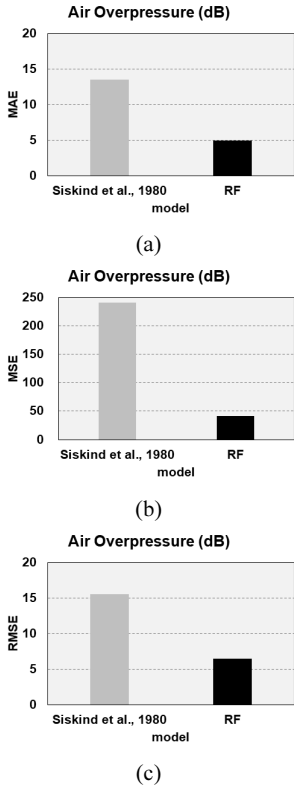


Fig. 8. Comparison of prediction performance between the empirical equation and RF machine learning model. (a) MAE. (b) MSE. (c) RMSE.

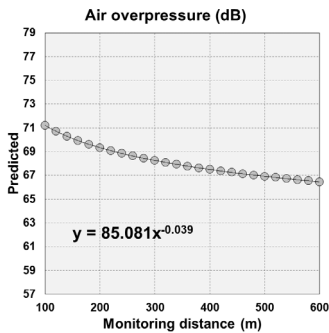


Fig. 9. Predicted air overpressure according to monitoring distance when the blast design values in Table 5 are input to the RF model.

결론

본 연구에서는 경상남도 창원시에 있는 노천 채석장에서 수집된 924개의 발파 모니터링 데이터를 이용하여, 천공장, 저항선, 공간격, 지발당 최대장약량, 비장약량, 총 공수, 에멀전폭약 비율, 이격거리 조건에 따라 발파시 발생하는 대기소음을 예측할 수 있는 머신러닝 모델을 개발하였다. 4종의 머신러닝 알고리즘(kNN, RF, XGBoost, DNN)을 이용하여 모델을 학습시킨 후 예측 성능을 비교한 결과 RF 모델이 MAE가 4.938dB(A), MSE가 42.032dB(A), RMSE가 6.483dB(A)로 평가되어 상대적으로 좋은 성능을 보였다. 그러나 개발된 대기소음 예측 모델은 연구지역의 데이터만을 이용하여 개발하였기 때문에 다른 지역에서는 사용이 어렵다. 연구지역이 아닌 다른 지역에서도 이용 가능한 범용적인 대기소음 예측 머신러닝 모델을 개발하기 위해서는 다른 지역의 데이터를 확보하고 예측 모델의 성능을 개선하기 위한 지속적인 연구가 필요할 것이다.

사사

본 연구는 2022년도 정부(산업통상자원부)의 재원으로 해외자원개발협회의 지원을 받아 수행되었다(과제명: 자원개발 산학협력 컨소시엄-스마트 마이닝 전문 인력 양성).

References

Armaghani, D.J., Hajihassani, M., Monjezi, M., Mohamad, E.T., Marto, A., and Moghaddam, M.R., 2015a. Application of two intelligent systems in predicting environmental impacts of quarry blasting, *Arabian Journal of Geosciences*, 8(11), p.9647-9665.

Armaghani, D.J., Hajihassani, M., Sohaei, H., Mohamad, E.T., Marto, A., Motaghedi, H., and Moghaddam, M.R., 2015b. Neuro-fuzzy technique to predict air-overpressure induced by blasting, *Arabian Journal of Geosciences*, 8(12), p.10937-10950.

Armaghani, D.J., Hasanipanah, M., and Mohamad, E.T., 2016. A combination of the ICA-ANN model to predict air-overpressure resulting from blasting, *Engineering with Computers*, 32(1), p.155-171.

- Armaghani, D.J., Hasanipanah, M., Mahdiyar, A., Abd Majid, M.Z., Amnieh, H.B., and Tahir, M.M., 2018. Airblast prediction through a hybrid genetic algorithm-ANN model, *Neural Computing and Applications*, 29(9), p.619-629.
- Ebrahimi, E., Monjezi, M., Khalesi, M.R., and Armaghani, D.J., 2016. Prediction and optimization of back-break and rock fragmentation using an artificial neural network and a bee colony algorithm, *Bulletin of Engineering Geology and the Environment*, 75(1), p.27-36.
- Elevado, K.J.T., Galupino, J.G., and Gallardo, R.S., 2018. Compressive strength modelling of concrete mixed with fly ash and waste ceramics using K-nearest neighbor algorithm, *GEOMATE Journal*, 15(48), p.169-174.
- Hajihassani, M., Armaghani, D.J., Sohaei, H., Mohamad, E.T., and Marto, A., 2014. Prediction of airblast-overpressure induced by blasting using a hybrid artificial neural network and particle swarm optimization, *Applied Acoustics*, 80, p.57-67.
- Hasanipanah, M., Armaghani, D.J., Khamesi, H., Amnieh, H.B., and Ghoraba, S., 2016. Several non-linear models in estimating air-overpressure resulting from mine blasting, *Engineering with Computers*, 32(3), p.441-445.
- Hasanipanah, M., Shahnazar, A., Amnieh, H.B., and Armaghani, D.J., 2017. Prediction of air-overpressure caused by mine blasting using a new hybrid PSO-SVR model, *Engineering with Computers*, 33(1), p.23-31.
- Hustrulid, W.A., 1999. *Blasting principles for open pit mining: General design concepts*, Rotterdam: Balkema.
- Jung, D. and Choi, Y., 2021. Prediction of blast vibration in quarry using machine learning models, *Tunnel & Underground Space*, 31(6), p.508-519.
- Khandelwal, M. and Kankar, P.K., 2011. Prediction of blast-induced air overpressure using support vector machine, *Arabian Journal of Geosciences*, 4(3-4), p.427-433.
- Khandelwal, M. and Singh, T., 2005. Prediction of blast induced air overpressure in opencast mine, *Noise & Vibration Worldwide*, 36(2), p.7-16.
- Kuzu, C., Fisne, A., and Ercelebi, S. G., 2009. Operational and geological parameters in the assessing blast induced airblast-overpressure in quarries, *Applied Acoustics*, 70(3), p.404-411.
- Lee, C.S., Hong, K.S., and Cho, T.C., 2001. Estimation of usable cut-out volume considering the structural and engineering properties of rock mass, *The Journal of Engineering Geology*, 11, p.101-113.
- Mohamad, E.T., Armaghani, D.J., Hasanipanah, M., Murlidhar, B.R., and Alel, M.N.A., 2016. Estimation of air-overpressure produced by blasting operation through a neuro-genetic technique, *Environmental Earth Sciences*, 75(2), 174p.
- Monjezi, M., Ghafurikalajahi, M., and Bahrami, A., 2011. Prediction of blast-induced ground vibration using artificial neural networks, *Tunnelling and Underground Space Technology*, 26(1), p.46-50.
- Nguyen, H. and Bui, X.N., 2019. Predicting blast-induced air overpressure: a robust artificial intelligence system based on artificial neural networks and random forest, *Natural Resources Research*, 28(3), p.893-907.
- Nguyen, H., Bui, X.N., Bui, H.B., and Mai, N.L., 2020. A comparative study of artificial neural networks in predicting blast-induced air-blast overpressure at Deo Nai open-pit coal mine, Vietnam, *Neural Computing and Applications*, 32(8), p.3939-3955.
- Pandya, D.H., Upadhyay, S.H., and Harsha, S.P., 2013. Fault diagnosis of rolling element bearing with intrinsic mode function of acoustic emission data using APF-KNN, *Expert Systems with Applications*, 40(10), p.4137-4145.
- Park, S., Jung, D., Nguyen, H., and Choi, Y., 2021. Diagnosis of problems in truck ore transport operations in underground mines using various machine learning models and data collected by internet of things systems, *Minerals*, 11(10), 1128p.
- Quiros, A.R.F., Bedruz, R.A., Uy, A.C., Abad, A., Bandala, A., Dadios, E.P., and Fernando, A., 2017. *A kNN-based approach for the machine vision of character recognition of license plate numbers*, In TENCON 2017-2017 IEEE Region 10 Conference, p.1081-1086.
- Rezaei, M., Monjezi, M., and Varjani, A.Y., 2011. Development of a fuzzy model to predict flyrock in surface mining, *Safety Science*, 49(2), p.298-305.
- Roy, S., Adhikari, G., Renaldy, T., and Jha, A., 2011. Development of multiple regression and neural network models for assessment of blasting dust at a large surface coal mine, *Journal of Environmental science and Technology*, 4(3), p.284-301.
- Siskind, D.E., Stachura, V.J., Stagg, M.S., and Koop, J.W., 1980. In: *Siskind DE (ed) Structure response and damage produced by airblast from surface mining*, US Department of the Interior, Bureau of Mines.
- Yoon, D., Kim, J., Park, J., Park, H., Byeon, J., Seo, J., Lee, J., Jang, I., Jo, S., and Choi, Y., 2018. *Introduction to resource development machine learning*, CIR, South Korea.
- Zhou, J., Li, X., and Mitri, H.S., 2016. Classification of rockburst in underground projects: comparison of ten supervised learning methods, *Journal of Computing in Civil Engineering*, 30(5), p.04016003-1-19.

**정 다 희**

2020년 부경대학교 환경해양대학 에너지
자원공학과, 공학사

현재 부경대학교 환경해양대학 에너지자원공학과 석사과정
(E-mail: jungdahee98@gmail.com)

최 요 순

현재 부경대학교 환경해양대학 에너지자원공학과 교수
(本學會誌 第58券 第6号 参照)
