

CASE STUDY

## 암반공학분야에 적용된 인공지능 알고리즘 분석

김양균\*

노르트론 대표

# An Analysis of Artificial Intelligence Algorithms Applied to Rock Engineering

Yangkyun Kim\*

Chief Engineer, NORTRON

\*Corresponding author: [ykim.nortron@gmail.com](mailto:ykim.nortron@gmail.com)

Received: February 10, 2021

Revised: February 19, 2021

Accepted: February 19, 2021

### ABSTRACT

As the era of Industry 4.0 arrives, the researches using artificial intelligence in the field of rock engineering as well have increased. For a better understanding and availability of AI, this paper analyzed the types of algorithms and how to apply them to the research papers where AI is applied among domestic and international studies related to tunnels, blasting and mines that are major objects in which rock engineering techniques are applied. The analysis results show that the main specific fields in which AI is applied are rock mass classification and prediction of TBM advance rate as well as geological condition ahead of TBM in a tunnel field, prediction of fragmentation and flyrock in a blasting field, and the evaluation of subsidence risk in abandoned mines. Of various AI algorithms, an artificial neural network is overwhelmingly applied among investigated fields. To enhance the credibility and accuracy of a study result, an accurate and thorough understanding on AI algorithms that a researcher wants to use is essential, and it is expected that to solve various problems in the rock engineering fields which have difficulty in approaching or analyzing at present, research ideas using not only machine learning but also deep learning such as CNN or RNN will increase.

**Keywords:** Rock engineering, Artificial intelligence, Machine learning, Artificial neural networks, Algorithm

### 초록

4차 산업혁명 시대의 도래에 따라 암반공학분야에서도 인공지능을 활용한 연구가 점차 증가하고 있다. 본 논문에서는 인공지능에 대한 이해와 그 활용도를 더욱 증진시키기 위하여, 암반공학기술의 주된 적용 대상인 터널, 발파, 광산과 관련된 최근의 국내외 연구 중 인공지능이 활용된 논문들에서 그 알고리즘의 종류와 적용방법을 분석하였다. 터널에서는 암반분류, TBM굴진율 및 막장전방 지질 예측, 발파에서는 암반의 파쇄도 및 비산거리, 광산에서는 폐광의 침하가능성 예측을 위해 주로 활용되고 있으며, 기계학습의 다양한 알고리즘 중 인공신경망이 압도적으로 많이 활용되고 있는 것으로 나타났다. 연구결과의 정확도와 신뢰성 제고를 위해 사용하고자 하는 인공지능 알고리즘에 대한 정확하고 상세한 이해가 필수적이며, 현재는 접근이나 분석이 난해한 암반공학 분야의 다양한 문제해결을 위해 기계학습뿐 아니라 CNN 또는 RNN과 같은 딥러닝을 활용한 연구 아이디어들이 점차 증가될 것으로 기대된다.

**핵심어:** 암반공학, 인공지능, 기계학습, 인공신경망, 터널



## 1. 서론

4차 산업혁명은 전 세계가 마주한 현실이다. 단기적으로는 ‘인공지능(Artificial intelligence, AI)’의 등장, 중장기적으로는 ‘과학기술’의 유례없이 빠른 발전 속도에 따른 사회 전반의 변혁을 의미한다. 인공지능은 초연결 사회의 방대한 데이터를 학습하는 기계가 지적 업무를 수행할 수 있게 된다는 점에서 과거와 큰 차이를 보인다(Committee on the fourth industrial revolution, 2019). 이에 따라 각국은 AI를 새로운 국가 경쟁력으로 인식하고, 글로벌 리더십 확보를 위한 다양한 AI 관련 정책 및 전략을 추진 중이다(Secretariat of committee on the fourth industrial revolution, 2020).

이와 같은 배경에서 암반공학 전공자의 상당수가 취업하는 건설업계를 대상으로 2019년 스마트 건설기술 활용현황을 조사한 결과(CERIK, 2019), Fig. 1에 나타난 바와 같이, 빅데이터 및 인공지능 분야의 경우 전체 조사대상 건설기업 201개 중 빅데이터 및 인공지능 기술을 모르거나 사용하지 않는 기업의 비율이 88.6%로 나타났다. 이것은 평균 11.4%의 기업만이 인공지능 기술을 활용할 수 있다는 것을 의미하는데, 10년내 빅데이터 및 인공지능기술을 도입할 계획이라고 밝힌 기업이 평균 28%로 나타나(Fig. 2) 현재보다는 인공지능을 접하거나 활용할 가능성이 상당히 높아질 것으로 전망된다. 그러나 조사대상 기업 중 스마트건설기술 도입에 적극적인 종합대형건설회사 16개를 제외한 나머지 종합건설회사 90개 및 전문건설회사 95개 중 평균 약 24%만이 10년 내 인공지능기술의 도입을 고려하고 있는 상황이다. 따라서 국내 지하공간 및 자원개발기술의 생산성, 안전성, 경제성을 혁신시키기 위해서, 그리고 국내기술보다 선진화된 외국기술에 적극 대응하고 글로벌 기술경쟁력을 갖추기 위해서 4차 산업혁명기술, 특히 인공지능 기술에 대한 보다 폭 넓은 이해와 적극적인 활용이 필요하다.

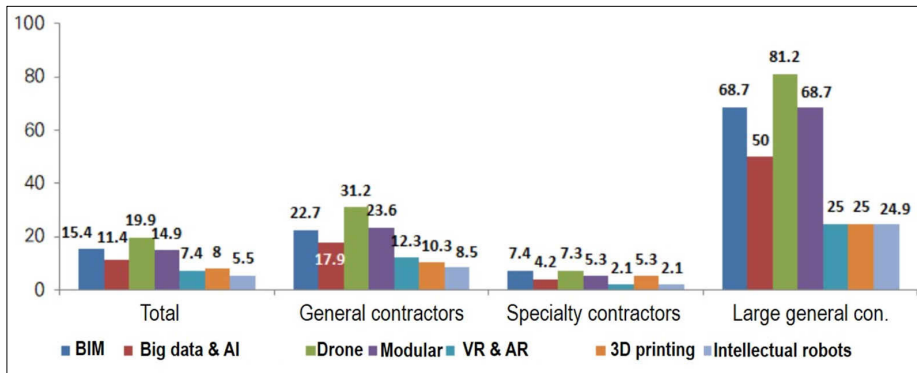


Fig. 1. Application level of smart construction technologies among local construction companies (CERIK, 2019)

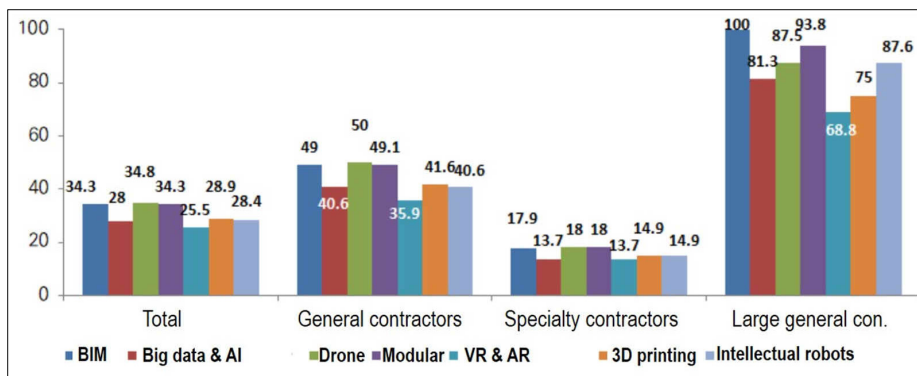


Fig. 2. Plan of local construction companies to introduce smart construction technologies in 10 years (CERIK, 2019)

본 논문에서는 전통적 암반공학기술이 적용되는 터널, 발파, 광산 등을 대상으로 인공지능 기법이 활용된 최근 5년 이내의 주요 연구 사례들을 정리해보고, 향후 연구방향에 대해서도 제안을 하고자 한다. 이를 위해 매우 다양하고 복잡한 인공지능 알고리즘에 대한 상세한 설명 대신 암반공학 주요 분야에 적용되어온 인공지능 기법 및 알고리즘의 종류 및 용도에 중점을 두고 내용을 정리하였다.

## 2. 인공지능 알고리즘 개요

1956년 미국 다트머스대학에서 John McCarthy 및 Marvin Minsky 등의 주도로 미래를 추측하는 워크숍이 개최된 이후(Moor, 2006) AI기술은 특히 최근 들어 비약적으로 발전하고 있다. AI란 지능적 기계 특히 지능적 컴퓨터 프로그램을 만드는 과학과 공학이며, 컴퓨터를 사용해서 인간의 지능을 이해하는 작업들과 관련되어있다(McCarthy, 2007).

인공지능을 구현하는 방법 및 종류는 기술의 발전에 따라 매우 다양하게 개발되어 왔다. 기관 또는 연구자에 따라 세부분야 역시 약간씩 다르게 분류하고 있지만, 인공지능 구현방법에 따라 그 분야를 대체로 Table 1과 같이 구분할 수 있다. 표에서 나타난 다양한 분야 중 최근 전 산업분야에서 그 활용도가 증가하고 있는 자연어처리(NLP)는 컴퓨터가 인간의 언어를 이해하고 해석하며 조작하도록 돕는 분야이며, 음성인식(speech recognition)은 사람의 말소리를 입력 받아 텍스트로 변환해 주는 기술이고, 컴퓨터 비전(computer vision)은 영상데이터로부터 유용한 정보를 자동으로 추출하기 위한 기술(Spencer et al., 2019)이라고 정의할 수 있다.

**Table 1.** Subsets of AI

Subsets	Definition	Algorithms/Categories
AI Planning	The task of finding a procedural course of action for a declaratively described system to reach its goals while optimizing overall performance measures ( <a href="https://researcher.watson.ibm.com/researcher/view_group.php?id=8432">https://researcher.watson.ibm.com/researcher/view_group.php?id=8432</a> )	-
Expert systems	A computer system emulating the decision-making ability of a human expert ( <a href="https://en.wikipedia.org/wiki/Expert_system">https://en.wikipedia.org/wiki/Expert_system</a> )	-
Robotics	A multidisciplinary area that combines electrical engineering, mechanical engineering and computer science ( <a href="https://eecs.oregonstate.edu/robotics">https://eecs.oregonstate.edu/robotics</a> )	-
NLP (Natural Language Processing)	The automatic manipulation of natural language, like speech and text, by software ( <a href="https://machinelearningmastery.com/natural-language-processing/">https://machinelearningmastery.com/natural-language-processing/</a> )	<ul style="list-style-type: none"> <li>• Text generation</li> <li>• Question answering</li> <li>• Context extraction</li> <li>• Classification</li> <li>• Machine translation</li> </ul>
Speech recognition	The task of recognising speech within audio and converting it into text ( <a href="https://paperswithcode.com/task/speech-recognition">https://paperswithcode.com/task/speech-recognition</a> )	<ul style="list-style-type: none"> <li>• Speech to text</li> <li>• Text to speech</li> </ul>
Computer vision	A field of study that seeks to develop techniques to help computers “see” and understand the content of digital images ( <a href="https://machinelearningmastery.com/what-is-computer-vision/">https://machinelearningmastery.com/what-is-computer-vision/</a> )	<ul style="list-style-type: none"> <li>• Machine vision</li> <li>• Image recognition</li> </ul>
Machine learning	A branch of artificial intelligence that aims to program machines to perform their jobs more skillfully. This is done by using intelligent software that takes inputs to train a model to produce the desired result (Morgenroth et al., 2019)	<ul style="list-style-type: none"> <li>• Supervised learning</li> <li>• Unsupervised learning</li> <li>• Reinforced learning</li> <li>• Deep learning</li> <li>• Ensemble</li> </ul>

기계학습(machine learning)은 학자들 또는 전문가들마다 약간씩 다르게 정의하고 있지만 기계학습 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, 이것을 머신러닝이라 정의하였다. 암반공학 분야에서는 현장 측정, 시험 또는 여타 분석 데이터를 토대로 주어진 기술적 상황의 결과를 추정하거나 예측할 때, 또는 데이터들 사이의 상관관계를 보다 효과적으로 분석할 때 주로 활용되고 있다.

기계학습 알고리즘은 학습종류, 과정 및 방법에 따라 Fig. 3에 나타난 바와 같이 크게 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.

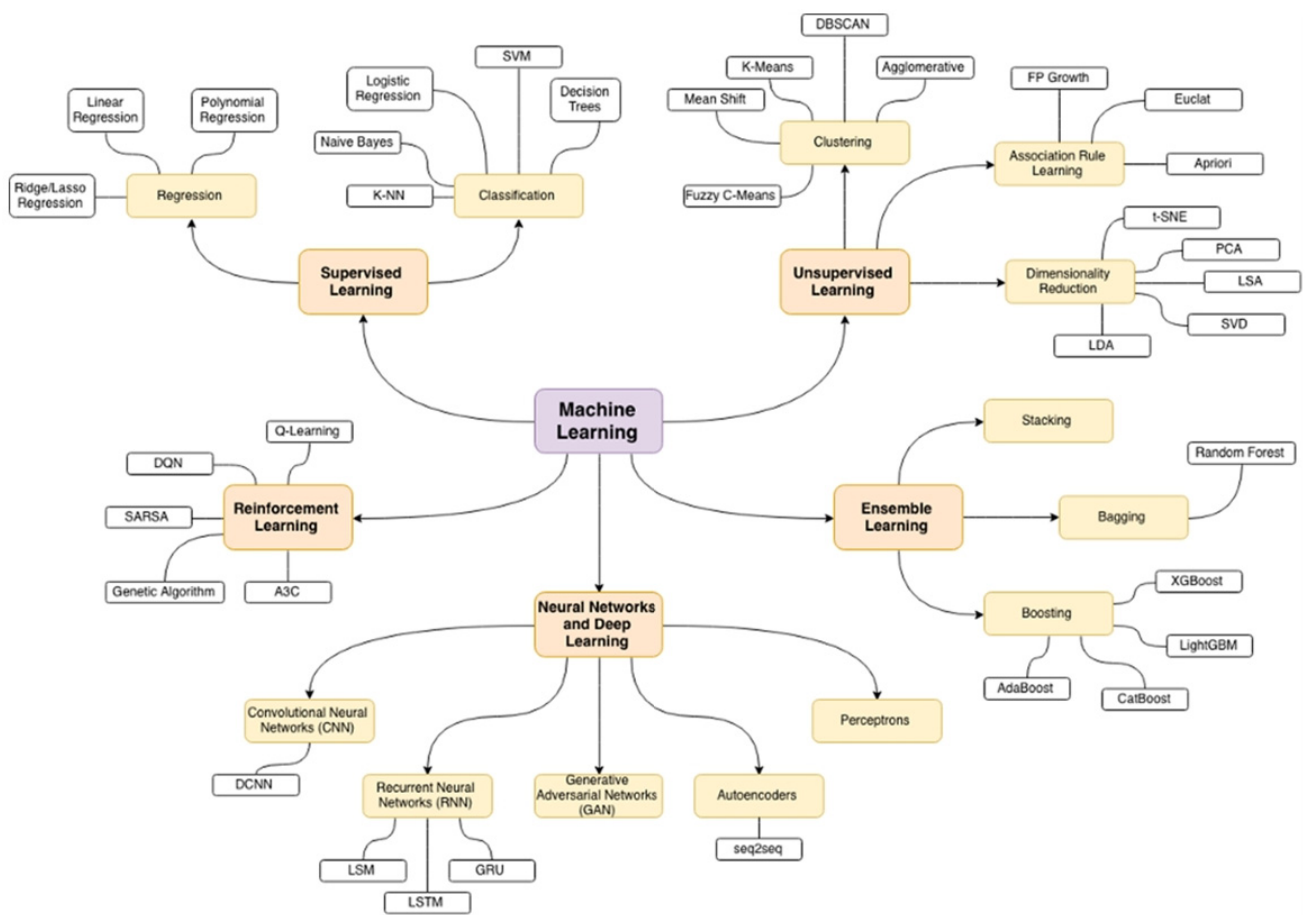


Fig. 3. Mind map of machine learning algorithms (Downloaded from <https://medium.com/datadriveninvestor/>)

지도학습은 입력값 및 이에 대한 결과값이 주어지며, 입력값을 이용하여 결과값이 산출되도록 학습하는 방법으로 분류(classification)와 회귀(regression)알고리즘으로 구분된다. 비지도학습은 입력값에 대응하는 출력값의 제공없이 컴퓨터 스스로 분류하도록 하는 방법으로 군집(clustering), 연관규칙학습(association rule learning), 차원축소(dimension reduction) 알고리즘으로 분류할 수 있다. 강화학습은 어떤 환경 안에서 정의된 주체(agent)가 현재의 상태(state)를 관찰하여 선택할 수 있는 행동(action)들 중에서 가장 최대의 보상(reward)을 가져다주는 행동이 무엇인지를 학습하는 방식이다. 앙상블 학습은 여러 개의 알고리즘을 사용하

여 그 결과를 결합함으로써 보다 정확한 예측을 도출하는 기법이며 다른 기법들보다 대체적으로 양호한 성능을 나타내기에 최근 그 활용이 증가하고 있다.

마지막으로 인공지능망과 심층학습은 인간 두뇌의 신경세포를 수학적으로 모델링한 것이다. 현재 일반적으로 활용되는 인공지능망은 Fig. 4에서처럼 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성되어 있고 각각의 층은 다수의 노드로 구성된다. 입력층 각각의 노드를 통해 입력된 학습데이터(feature)는 입력층 노드와 은닉층 각각의 노드 사이에 임의로 설정된 가중치(weight)와 곱해지고 편차(bias)와 더해져서 은닉층 각각의 노드로 입력이 된 후, 다양한 종류의 활성화 함수(activation function)를 통과해서 그 출력값이 변환된다. 이렇게 해서 산출된 각 노드의 결과값들은 그 다음 은닉층으로 입력되어 이전과 동일한 과정을 거쳐 마지막 출력층(output layer)으로 전달된 후 임시 결과값이 산출되는데 이 임시 결과값과 실제 값(label)과의 차이가 손실함수(loss function)에 의해 결정된다. 이런 식으로 순방향전파(feedforward propagation)과정이 완료된 후 손실함수에 의해 결정된 오차를 감소시키기 위한 역전파(back propagation)과정이 진행된다. 역전파는 순방향전파와 역방향으로 진행되면서 최적화 알고리즘(optimizer)에 의해 노드 간 가중치와 편차를 순차적으로 편미분하며 그 값들을 갱신시킨다. 인공지능망 학습은 이러한 순방향과 역방향 전파가 설정된 횟수만큼 또는 규칙대로 수행한 후 최종 예측값을 도출하게 된다.

인공지능망은 그 구조의 발전단계별로 단층 퍼셉트론(single layer perceptron, SLP), 다층 퍼셉트론(multi layer perceptron, MLP) 및 은닉층이 보통 2개 이상인 심층신경망(deep neural network, DNN)으로 구분될 수 있으며, DNN을 응용한 알고리즘에는 합성곱신경망(convolutional neural network, CNN), 순환신경망(recurrent neural network, RNN) 등이 있다. 딥러닝(deep learning)이란 데이터의 특징추출(feature extraction)과정 등이 입력에 의해 이루어지는 기계학습과는 달리 DNN내에서 자동으로 수행되는 학습과정이다.

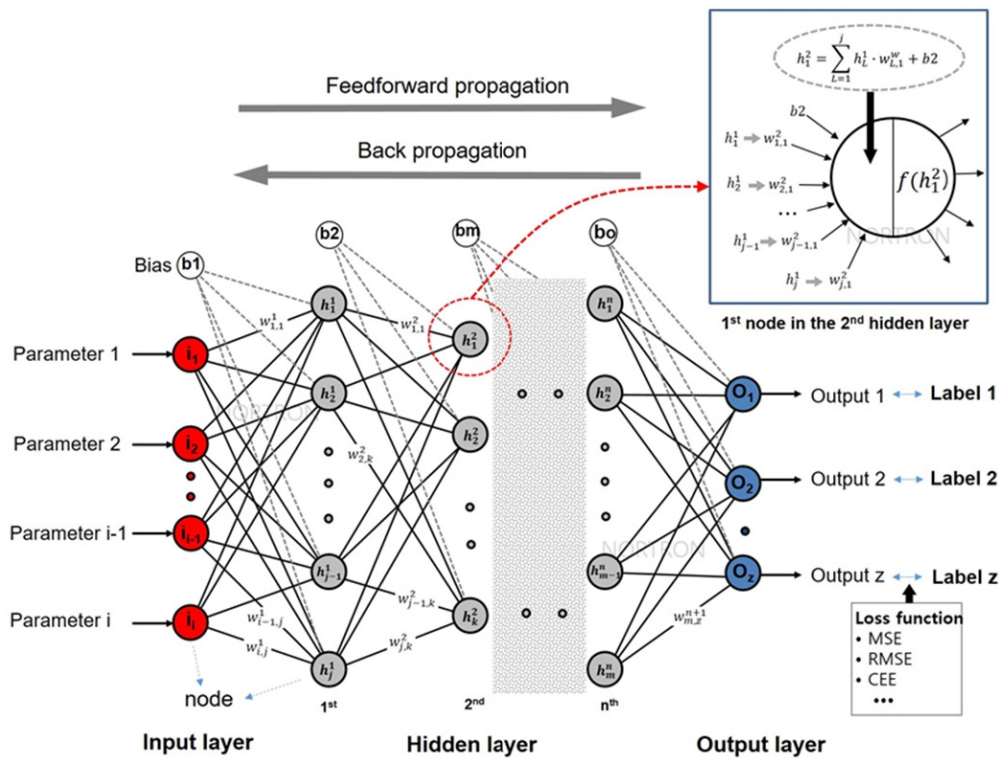


Fig. 4. Typical architecture of ANN

### 3. 암반공학 대상에 적용된 인공지능 알고리즘 사례 분석

#### 3.1 터널

##### 3.1.1 Face mapping 및 암반분류

1990년대 초반까지는 보다 객관적이고 효율적인 암반분류와 지보설계를 위한 연구에 인공지능의 한 분야인 전문가시스템이 주로 적용되어 왔다(Butler and Franklin, 1990). 그 이후 기계학습 알고리즘인 인공신경망(ANN)이 국내외적으로 암반분류에 적용되기 시작했는데, Sklavounos and Sakellariou(1995)는 5개 RMR 평가항목으로 구성된 총 20개의 데이터를 인공신경망 학습에 사용하였고, 국내에서는 Lee and Moon(1994)이 RMR과 Q값 사이의 상관관계를 결정할 수 있는 인공신경망 모델을 적용하였다. 또한, Yang and Kim(1999)은 암반의 성질을 평가하는 특성치의 선택을 위해 국내의 데이터베이스를 기반으로 인공신경망을 이용한 새로운 암반분류 시스템을 제안하였다.

최근의 인공신경망을 이용한 암반분류 연구는 예측정확도를 제고하기 위해 많은 학습데이터를 기반으로 보다 정교해진 알고리즘, 인공신경망과 다른 분석방법들을 병용하거나, 다른 기계학습 방법만을 사용하는 사례도 증가하고 있다. Öge(2018)은 RMR, Q, GSI 사이의 상관관계 분석을 위해 총 250개의 데이터를 사용하여 인공신경망 분석을 하였는데 단순회귀분석의 결과보다 더 양호한 결과를 얻었고, Jang et al.(2019)은 총 3,125개의 RMR 데이터를 이용하여 강건설계(robust design)에 의한 학습과 인공신경망을 적용하여 예측정확도를 극대화하였다. Xue et al.(2019)은 일축압축강도, 암반무결계수, 연화계수, 절리면계수, 지하수상태 등 5개 항목을 주성분분석(PCA)과 이상점 이론을 통해 암반분류를 시도하였다. 주성분분석이란 분산-공분산 관계를 이용하여 주어진 데이터들의 집합에서 데이터를 구분하는 가장 중요한 요소들을 찾아 고차원의 데이터를 저차원의 데이터로 변환시키는 차원 축소의 한 방법이다. Hasegawa et al.(2019)은 인공신경망을 활용하여 탄성파속도, 전기비저항, 터널심도에 따라 터널막장 주변 암질상태를 4단계로 예측하였는데, 인공신경망의 구조가 복잡하다고 예측정확도가 반드시 향상되지는 않는다는 결론을 얻었다.

한편 암반분류를 위한 막장관찰 시 가장 문제가 되는 사항중 하나는 세부 평가항목에 대해 평가자마다 평가점수에 많은 차이가 있을 수 있다는 점이다. 최근에는 딥러닝 중 영상데이터 분석에 적합한 CNN(convolutional neural networks)을 이용하여 이러한 문제를 해결하기 위한 시도도 이루어지고 있다. CNN은 1990년대 뉴욕대학의 Yann LeCun 교수의 필기체 숫자인식에서 처음 등장하였는데, 기존의 신경망에서는 픽셀 주위의 지역적인 정보를 표현하지 못했으나 합성곱 연산을 도입함으로써 이를 극복하였다. 그 후 CNN의 인식률을 향상시키기 위해 네트워크를 더 깊게 구성하는 방식으로 연구가 진행되었으며, ZFNet, VGG, ResNet,



Fig. 5. Classification process of tunnel faces using Inception-ResNet-v2 model (Chen et al., 2021)

GoogLeNet(Inception-v1), DenseNet 등이 등장하였다(Lee et al., 2018). Kim et al.(2019)은 막장면 암반상태 분류를 신속하게 결정하기 위하여, CNN기법중 옥스퍼드 대학에서 개발되고 이미지가 사전 학습된 VGG16모델을 적용하여 막장사진만으로 매우 높은 암반등급 예측정확도를 도출하였다. Chen et al.(2021)은 150개 터널현장에서 수집된 35,000장의 막장면 사진을 기존의 Inception v3 모델에 ResNet 장점을 흡수시킨 모델인 Inception-ResNet-v2모델로 학습한 후 5가지로 분류된 막장면 암반상태를 매우 정확하게 분류하였다(Fig. 5).

### 3.1.2 암석파열(Rock burst)

지하 공동을 굴착할 때 심부의 높은 현장 응력으로 인해 암석의 종류, 암반 내 불연속면의 특성에 따라 나타나는 취성거동인 암석 파열(rock burst)을 예측하기 위해 기계학습 알고리즘이 사용되었다. Dong et al.(2013)은 암반파열현상의 가능성과 강도를 예측하기 위해 기계학습 알고리즘인 Random forest(RF)를 적용하였는데, RF는 Decision Tree의 분류보다 정확도를 개선시키기 위해 여러 개의 나무(tree)를 생성하여 각각 나무의 예측을 종합하여 결론을 내리는 구조이다. 분석을 위해 접선방향응력, 일축압축강도, 인장강도, 탄성에너지지수 등 4가지를 입력인자로, 4단계로 구분된 암석파열의 강도를 출력인자로 하여 총 36개의 학습데이터를 사용하였다. SVM 및 인공신경망 모델과 예측결과를 비교한 결과 RF가 가장 우수한 예측성능을 나타냈다. Li et al.(2017) 역시 135개의 암석파열사례로부터 암석파열 현상을 예측하기 위해 터널심도, 최대 접선응력, 일축압축강도, 인장강도, 탄성에너지지수 등 5가지의 입력인자와 파열발생유무로 구분된 결과값을 적용하였다. 이 연구에서는 데이터의 특성들이 서로 완전히 독립되어 있다는 Bayes의 정리에 기반하여, 과거의 데이터를 활용하여 미래의 사건확률을 추정하는 기계학습의 한 종류인 Naïve Bayes 알고리즘이 적용되었다.

Feng et al.(2019)는 수력발전소의 심부터널내 암석파열현상을 예측하기 위해 실시간 미세지진(microseismic)계측을 통해 수집된 93개의 암석파열데이터를 확률신경망(probabilistic neural network, PNN)으로 분석하였다(Fig. 6). 확률신경망은 신경망구조로 구성된 베이지안 분류기로서 새로운 입력개체에 대해 특정 클래스에 속할 확률을 계산하여 구분한다(Specht, 1990).




Fig. 6. Probabilistic neural network block diagram (Feng et al., 2019)

한편 기계학습 알고리즘뿐 아니라 딥러닝 기법인 CNN 알고리즘도 암석파열을 예측하기 위해 적용되었는데, Zhao and Chen(2020)은 암석파열의 강도를 예측하기 위해 상기 여러 논문들에서 적용된 입력인자와 결과를 동일하게 하고 이를 CNN과 ANN을 이용하여 예측하고 그 결과를 비교하였다. 결과적으로 CNN의 결과가 더 양호하게 도출되었지만, CNN에 적용된 데이터

의 형식 및 적용과정이 정확히 서술되어 있지 않은 한계가 있다.

### 3.1.3 TBM 굴진율

인공지능을 사용한 TBM터널 연구의 대부분은 TBM 굴진데이터에 기반한 굴진율 예측, 운전조건, 그리고 막장전방 지질상태 예측에 대한 연구로 구분되며, 굴진율 예측과 관련된 최근의 연구는 인공신경망을 기본으로 다양한 알고리즘 또는 분석기법을 부가하여 예측결과의 정확도를 향상시키고자 하는 연구가 지속적으로 시도되고 있다(Pham et al., 2011, Salimi et al., 2015, Armaghani et al., 2019). Pham et al.(2011)은 복합지반에서 TBM굴진율을 보다 정확히 예측하기 위해 인공신경망에 퍼지추론 평가모델(fuzzy reasoning evaluation model)을 접목하였는데, 이 연구에서는 암석의 성질, TBM제원 및 운전조건으로 구성된 총 10가지의 입력데이터를 학습하여 굴진율을 예측하였다. Armaghani et al.(2019)도 풍화된 정도가 다른 화강암지대에 위치한 12,649m길이의 도수르터널에서 일축압축강도, RMR 등과 같은 암반특성, 추력, 커터헤드 RPM 등과 같은 TBM운전조건을 입력데이터로 하여 TBM의 굴진속도를 예측하였다. 이 연구에서는 인공신경망 분석시 편차(bias)와 가중치(weight)의 성능을 향상시키기 위해 인공신경망에 제국주의 경쟁알고리즘(imperialist competitive algorithm, ICA) 또는 입자무리 최적화(particle swarm optimization, PSO)가 결합된 복합최적화기법이 개발되었으며, 분석결과 PSO-ANN 복합기법이 최상의 예측결과를 나타냈다.

Zhou et al.(2019)은 TBM 굴진율 예측을 위해 인공신경망과 유전자 프로그래밍(genetic programming)기법을 적용하였다. 이 연구에서는 추력, RPM과 같은 TBM 운전조건과 RQD, RMR과 같은 암반특성으로 구성된 총 6개의 입력데이터와 TBM 굴진율을 출력데이터로 하는 총 1,286개의 데이터를 이용하였다. 또한, Xu et al.(2019)은 TBM 굴진율예측을 위해 인공신경망모델외에 KNN(K-nearest neighbor, 최근접 이웃 알고리즘), SVM(support vector machine), CART(classification and regression tree, 분류 및 회귀 나무기법) 등 5개 알고리즘을 적용하여 그 결과를 비교하였는데, KNN에서 가장 양호한 예측결과를 얻을 수 있었다. 여기서 KNN은 label(실제 결과값)이 주어지지 않은 데이터를, 가장 가까운 유사속성을 가진 label이 주어진 데이터에 따라 분류하는 지도학습 알고리즘이며, SVM은 주어진 데이터 그룹을 바탕으로 새로운 데이터가 어떤 데이터그룹에 속할지를 판단하는 이진 선형 또는 비선형 분류모델이다. CART는 주어진 데이터 세트를 기반으로 설명변수들을 계층적으로 분할하고 각 분할에 대해 종속변수의 값을 예측하는 기법으로, 종속변수가 이산적인 경우에는 분류나무를, 연속적인 경우에는 회귀나무를 사용하는 것이 일반적인 Decision tree(의사결정나무)의 한 알고리즘이다.

TBM운전상태와 제원에 대한 데이터를 이용하여 TBM 막장 전방의 지질상태를 인공신경망을 이용하여 실시간으로 예측하는 연구 또한 진행되고 있는데 (Zhao et al., 2019, Jung et al. 2019), Zhao et al.(2019)은 심도별로 5개의 지층 각각을 변형계수 등 7가지의 물리적, 역학적 특성에 따라 2-7개, 총 20가지의 세부 지질상태로 구분하고, TBM굴진과 관련된 총 72종류의 운전조건데이터 수백만 개를 학습하였다. 굴진 및 지질데이터의 부족한 정보를 보완하기 위해 특징증대(feature augmentation)기법도 적용하여 예측한 결과, 인공신경망이 Random forest, SVR, KNN 등과 같은 기계학습의 주요 알고리즘결과보다 더 나은 예측 결과를 얻을 수 있었다. Jung et al. (2019)은 암반지반, 연약지반, 그리고 혼합지반 등 3가지로 터널지반을 구분하고, 굴진속도, 추력, 커터 토크로 구성된 핵심 TBM 운전데이터 5,057개를 2개의 은닉층으로 된 인공신경망으로 학습시켜 90%이상의 예측정확도로 지반을 구분할 수 있었다. Liu et al. (2020)도 RPM, 토크, 추력, 굴진속도 등 4개 항목으로 구성된 320개의 TBM 운전조건을 입력데이터로 하여, 담금질(simulated annealing)기법이 접목된 역전파신경망(back propagation neural network)을 이용하여 일축압축강도, 연약면 사이의 거리, 취성도, 불연속면의 경사각 등 4개의 지질특성을 예측하였다. 이와 유사하게 지하철 터널 굴진시 수집된 다양한 굴진 및 지반특성데이터를 인공신경망으로 분석하여 지표면에서의 침하량을 분석한 연구도 수행되었다 (Koukoutas and



Sofianos, 2015).

이와는 달리 Cachim and Bezuijen(2019) 및 Li et al.(2021)은 다양한 TBM 굴진데이터에 기반하여 다른 TBM 운전조건을 예측하고자 하였다. Cachim and Bezuijen(2019)는 순방향 인공신경망(feedforward artificial neural network)을 이용하여 굴진속도, 추력, 스크류 컨베이어의 토크, 폼 주입비(Form Injection ratio, FIR)중 커터헤드 토크와 가장 상관성이 높은 FIR을 시계열(time series)로 분석하여 EPB TBM의 커터헤드 토크를 예측하고자 하였다.

또한 LSTM(long short-term memory)기법을 이용하여 TBM의 운전조건을 분석하는 연구도 진행되었는데 (Chen et al., 2019; Li et al., 2021), RNN 고유의 장기의존성 문제를 해결한 LSTM은 Hochreiter and Schmidhuber (1997)에 의해 소개된 개념이며 전체적으로 은닉층의 메모리 셀에 입력게이트(input gate), 망각 게이트(forget gate), 출력 게이트(output gate)를 추가한 구조이다 (Fig. 7). RNN과 비교하여 긴 시퀀스의 입력을 처리하는데 탁월한 성능을 발휘하며, 언어, 음성인식 등 다양한 분야에서 사용되고 있다.

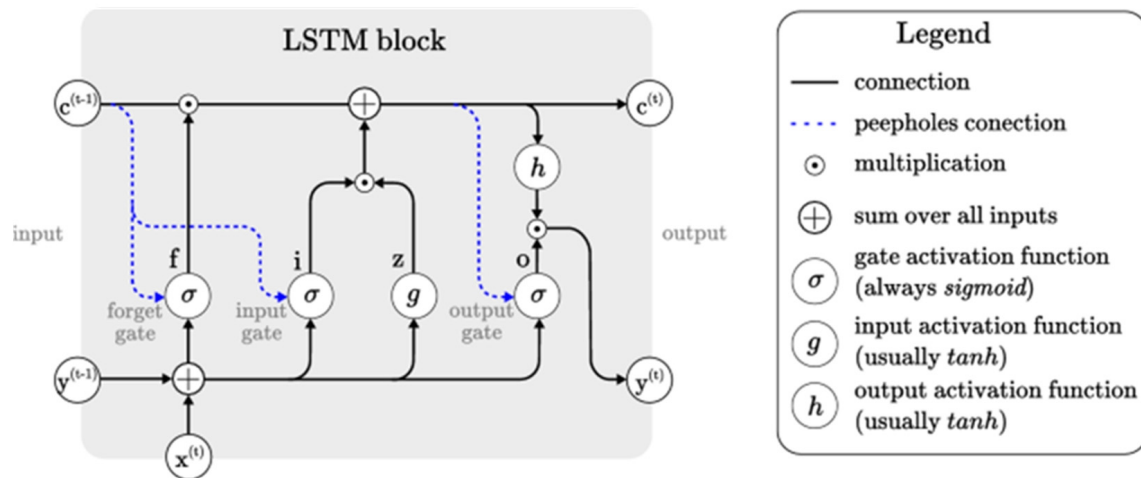


Fig. 7. Typical architecture of LSTM (Houdt et al, 2020)

Li et al.(2021) 또한 터널 72.1 km에서 수집된 TBM 굴진데이터를 기반으로 LSTM모델을 이용하여, TBM 운전시 실시간으로 총추력(total thrust) 및 토크(torque)를 분석하는 연구를 수행하였는데 기존 CSM TBM 굴진을 예측모델의 이론식에서 산출된 결과보다 더 양호한 결과를 얻을 수 있었다.

### 3.2 발파

발파작업에서 고려해야 하는 3가지 사항, 즉, 안전성, 경제성, 시공성 중 가장 중요한 안전성은 발파 시 발생하는 비석의 거리와 진동의 크기에 의해 좌우된다. 따라서 발파작업을 보다 안전하고 효율적으로 수행하기 위한 다양한 기술적 노력들이 국내외적으로 진행되고 있으며 이에 따라 인공신경망의 활용도 증가하고 있다.

Parida and Mishra(2015)는 철광산에서 수집된 발파진동데이터 9개를 입력데이터로 하는 인공신경망 분석을 실시하였고 그 예측결과와 USBM, Langefors-Kihlstrom 등의 경험식에서 산출된 결과들과 실제 측정된 발파진동과의 차이를 비교하였는데, 발파 지점까지의 거리와 지발당 장약량 2개를 입력인자로 하고 총 9개 데이터 중 5개만 학습에 사용하였음에도 다른 방법보다 더 양호한

결과를 도출한 것으로 결론지었다. 이와 유사하게 Das et al.(2019)도 노천탄광에서 수집된 암반밀도, 천공수, P파속도, 폭약밀도 등 15개의 입력인자(Fig. 8)로 구성된 248개의 데이터를 인공신경망으로 분석하고 그 결과를 USBM 발파진동 추정식 등과 같은 기존의 다양한 경험식과 비교하였는데, 실제 진동과의 평균오차가 11.8%로 기타 경험식에 의한 결과보다 월등하게 양호한 결과를 얻을 수 있었다.




Fig. 8. ANN architecture used in the study of Das et al. (2019)

Monjezi et al.(2011)은 철광의 채광발파시 수집된 지발당장약량, 최소저항선, SMR 등 10가지 입력인자로 구성된 총 220개의 데이터를 인공신경망으로 학습하여 발파후 파쇄도를 예측하고자 하였다. 최종 분석시 인공신경망은 뉴런(노드)수 9개 및 7개로 구성된 2개의 은닉층이 적용되었고, 동일한 입력인자를 사용한 다중회귀분석과 비교한 결과 인공신경망에 의한 예측결과가 훨씬 더 양호하게 나타났다. Rosales-Huamani et al.(2020) 또한 인공신경망을 이용하여 최소저항선, 벤치높이, 천공경, 장약량, 폭약밀도 등 8가지 인자로 구성된 입력데이터 47개 중 37개를 학습에 이용하여 파쇄입도를 예측하고자 하였다. 이를 위해 최종적으로 13개의 뉴런으로 구성된 1개의 은닉층을 사용하였으며, 다양한 최적화 알고리즘(optimizer)을 시험한 결과 Momentum이 최상의 결과를 나타냈다. 최적화 알고리즘이란 인공신경망에서 학습속도를 빠르게 하기 위해 손실함수를 최소화하기 위한 가중치 (weight)를 업데이트 하는 방법이다.

발파시 비석거리도 인공지능을 이용하여 예측하는 연구들도 진행되었는데(Ghasemi et al., 2014, Lu et al., 2020), Ghasemi et al.(2014)은 인공신경망과 퍼지모델을 이용하여 비석의 거리를 예측하는 연구를 수행하여, 퍼지모델이 보다 더 양호한 결과를 도출했다고 결론지었다. 이 연구에서는 동광산에서 수집된 총 230의 발파데이터를 사용하였고 입력인자는 천공장, 최소저항선, 공간격,

전색길이, 비장약량, 지발당장약량 등 6가지였으며 인공신경망모델에서는 9개의 뉴런으로 이루어진 1개의 은닉층만을 구성하였다.

한편 You and Jeon(2013)은 터널 주변에서 폭발이 일어나 붕괴가 발생할 경우, 폭발에 따른 거동을 파악하고 파쇄영역을 빠르게 예측하기 위해 인공신경망을 활용하였다. 즉, 3차원 수치해석 결과를 바탕으로 학습데이터를 구축하고 인공신경망을 이용하여 파쇄부피와 파쇄반지름 각각을 예측하였는데, 학습에 사용된 입력인자는 터널반지름, 암반강도, 장약량, X, Y, Z축으로 설정된 발파위치 등 6개를 선정하였고, 은닉층을 2개 또는 3개로 구성하였다.

### 3.3 광산침하

폐광지역의 지반침하는 인근 주민들의 생활안전에 큰 위협이 될 뿐 아니라 국토개발의 장애물이 되고 있기에, 그동안 국내외에서는 폐광지역 지반침하 가능성을 평가하기 위해 이론적 방법, 수치해석기법, 통계기법, 회귀분석, 모형분석 등을 활용한 다양한 연구가 수행되어 왔다. 그러나 이러한 모든 방법들이 광범위하고 복잡한 채굴적 및 지질상태를 조사하거나 반영하기에는 한계가 있을 수밖에 없으므로 폐광 다수 지점에 대한 침하가능성을 신뢰성 있게 분석하기는 어렵다. 따라서 조사가능한 한정된 폐광정보와 이에 따른 실제 침하발생 여부에 대한 다수의 데이터를 수집할 수 있다면 인공신경망기법은 새로운 평가지점에 대한 침하가능성을 판단하는데 다른 방법보다 더 적합한 방법이라고 할 수 있다.

Hejmanowski et al.(2016)는 지하광산 주변지역에 광범위하게 설치된 피에조미터에서 측정된 지하수 압력데이터와 대수층의 특성데이터를 이용해서 지하수위 저하로 인해 야기된 지표 침하를 예측하기 위해 인공신경망인 MLP, SVM 및 기타 분석기법들이 이용하여 결과를 분석하였는데, 그 결과 MLP에서 가장 양호한 결과를 얻을 수 있었다.

Oh et al.(2019)은 국내 폐탄광에서 발생하는 지표침하 민감도 지도를 보다 정확하게 만들기 위해, 태백지역을 3,863개의 세부 구역으로 구분하고 지질, 구역 용도, RMR, 지하수위 등 8개의 영향인자를 조사하였다. Bayes Net, Naïve Bayesian, Logistic Regression, MLP 및 Ensemble기법의 일종인 Logit Boost 등의 알고리즘으로 각 구역별 침하민감도 지수(land subsidence

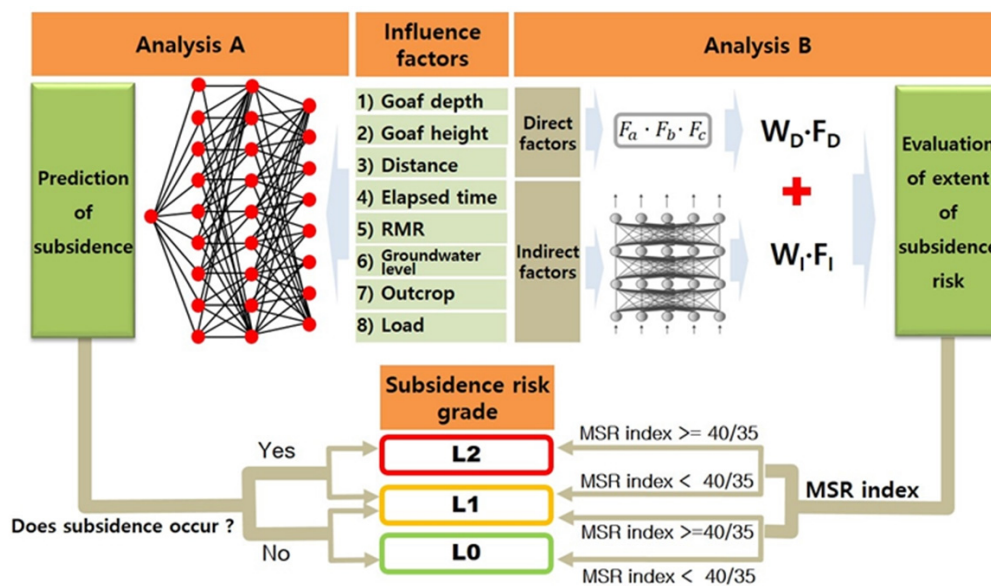


Fig. 9. Process to produce MSR index(Kim and Lee, 2020)

susceptibility index, LSSI)를 분석한 결과 Logit Boost가 91%의 정확도로 가장 양호한 결과를 나타냈다.

또한, Kim and Lee(2020)도 폐광침하 가능성을 예측하기 위해 폐광침하위험도 지수(mine subsidence risk Index)를 제안하면서(Fig. 9), 국내 폐광 37개소에서 발생한 227개소의 침하 및 비침하지에 대해 채굴적 또는 갱도로부터 평가지점까지의 수직 및 수평거리, RMR, 폐광후 경과시간 등 8가지를 입력인자로 하는 인공신경망분석(Fig. 9)을 실시하는 한편, 위험도평가의 정확도를 높이기 위해 Hudson(1992)이 제안한 상관도행렬(interaction matrix)개념도 도입했다. 결과적으로 새로 조사된 위험도 평가지점에 대해 83-86%의 정확도를 나타냈다.

### 3.4 암반공학에 적용된 알고리즘 분석결과

상기와 같이 인공지능이 암반공학 분야에 적용된 최근 5년 이내 주요 논문들을 검토해 본 결과, Table 2에 제시된 바와 같이, 인공지능이 비교적 많이 적용되는 세부분야는 발파터널의 경우 암반분류와 암석파열, TBM의 터널에서는 굴진을 예측 및 막장전방 예측, 발파에서는 파쇄도 및 비석거리 예측이었고, 광산에서는 폐광침하예측을 위해 활용되었다. 이외에도 암종구별(Fan et al., 2020, Ran et al., 2019, Pham and Shin, 2020)에도 많이 활용되고 있으며, 암석물성 예측(Sudakov et al., 2019, Ren, et al. 2018)에도 적용되고 있다.

세부분야를 막론하고 대다수의 연구에서 가장 많이 적용되고 있는 알고리즘은 인공신경망(ANN)으로 나타났다. 이것은 연구에서 수집되는 데이터의 대부분이 수치형(numerical)과 범주형(categorical) 같은 정형데이터로 구성되어 있고, 최근에는 학습데이터 수의 증가 및 다양한 사전처리(preprocessing)방법 적용, Dropout 적용, 은닉층의 수 및 학습률(learning rate)와 같은 초매개변수(hyperparameter) 최적화 등의 기법이 활용되면서 그 예측결과의 정확도도 향상되고 있기 때문으로 분석된다.

**Table 2.** Algorithms applied to rock engineering

Field	Use	Algorithms
Drill & blast	• Rock mass classification	• ANN • PCA
	• Face mapping	• CNN
Tunnel	• Rock burst	• ANN, PNN, CNN • Naïve Bayes, Random forest
	• Advance rate	• ANN • KNN, SVR, CART • Fuzzy model, Genetic algorithm
TBM	• Geological condition	• ANN • Random forest, SVR, KNN
	• Operating condition	• ANN • RNN (LSTM)
Blasting	• Fragmentation	
	• Flyrock	• ANN
	• Blast vibration	• Fuzzy model
	• Overbreak	
Mine	• Subsidence risk	• ANN • SVM, Naïve Bayesian, Logistic regression • Ensemble
	• Rock type classification	• CNN
Rock	• Rock properties	• ANN, CNN • SVM

인공신경망 외에 Random forest, 주성분분석(PCA), Ensemble 등과 같은 기계학습 기법도 적용되고 있는데, 이것은 인공신경망의 결과와 비교목적으로 활용하기 위한 용도가 일반적이었으며, 딥러닝기법인 CNN을 활용한 연구는 그 특성상 사진이 주된 데이터인 막장관찰 및 암종구별을 위해 수행되었고, 시계열분석에 적합한 RNN은 TBM과 같이 운전조건을 예측하는데 활용되고 있었다.

한편 앞에서 검토해본 바와 같이 인공신경망이 암반공학 분야에 적용되는 주된 인공지능 알고리즘이기는 하지만, 데이터의 종류와 형식, 초매개변수의 설정방법 등에 따라 인공신경망이 아닌 다른 기계학습 알고리즘에서 상대적으로 더 양호한 예측결과를 나타내는 경우도 적지 않고, 동일한 인공신경망을 적용하더라도 데이터의 수 및 처리방법 등에 따라 예측 정확도는 많은 차이를 나타내고 있었다. 그러나 인공신경망 또는 딥러닝의 특성이 해당 결과가 도출된 근거를 세부적으로 추적하기가 어려운 일종의 블랙박스여서 우연 또는 의도적인 결과 오류가 있다 해도 이를 심층적으로 규명하는 데에는 한계가 있다.

결과적으로 보다 심도 있고 다양한 암반공학기술 개발을 위해서 그리고 연구결과의 신뢰성 제고를 위해서 무엇보다 중요한 것이 사용자의 해당 알고리즘의 활용능력과 데이터의 수 및 품질이라고 사료된다.

## 4. 결론

현재까지 오랜 동안 암반공학기술 적용대상물의 계획, 설계 및 시공시 필요한 공학적타당성 검토는 이론적, 경험적, 수치해석적 방법들에 의해 주로 수행되어 왔으며, 각각의 방법들은 장단점이 있다. 이론적 방법은 결과값이 정확하긴 하지만 매우 특정한 상황에서 한정적으로만 적용이 가능하고, 경험적 방법은 수집된 데이터를 통계적으로 분석하여 설정된 일정한 수식에 의해 또는 영역별로 결과값을 추정하며, 수치해석적 방법은 주어진 실제 상황을 그와 유사하게 모사해서 결과를 추정한다. 이와는 달리, 대규모의 데이터로부터 데이터 내부의 세부적인 특징 및 경향을 자체적으로 파악하여 그와 관련된 새로운 상황이 주어졌을 때 신뢰성 있게 그 결과를 예측할 수 있다는 점에서 다른 산업분야에서와 마찬가지로 암반공학 분야에서도 향후 인공지능 특히 기계학습의 필요성과 활용도는 지속적으로 증가할 것으로 예상된다.

- 1) 상기와 같이 인공지능이 암반공학 분야에 적용된 최근 5년 이내 논문들을 검토해 본 결과, 인공지능이 비교적 많이 적용되는 세부분야는 발파터널의 경우 암반분류와 암석파열, TBM을 활용한 터널 굴착 분야에서는 굴진을 예측 및 막장전방 예측, 발파에서는 파쇄도 및 비석거리 예측이었고, 광산에서는 폐광침하예측을 위해 활용되었다. 이외에도 암종구별에도 많이 활용되고 있으며, 암석물성 예측에도 적용되고 있다.
- 2) 예측결과의 비교를 위해 그리고 예측 정확도 제고를 위해 Random forest, 주성분분석(PCA), Ensemble 등과 같은 기계학습 기법도 적용되고 있지만, 세부분야를 막론하고 대다수의 연구에서 가장 많이 적용되고 있는 알고리즘은 인공신경망(ANN)으로 나타났다. 이것은 연구에서 수집되는 데이터의 대부분이 수치형(numerical)과 범주형(categorical) 같은 정형데이터로 구성되어 있고, 최근에는 학습데이터 수의 증가 및 다양한 사전처리(preprocessing)방법 적용, Dropout 적용, 은닉층의 수 및 학습률(learning rate)와 같은 초매개변수(hyperparameter) 최적화 등의 기법이 활용되면서 그 예측결과의 정확도도 향상되고 있기 때문에 분석된다.
- 3) 데이터의 종류와 형식, 초매개변수의 설정방법 등에 따라 인공신경망이 아닌 다른 기계학습 알고리즘에서 상대적으로 더 양

호한 예측결과를 나타내는 경우도 적지 않고, 동일한 인공지능망을 적용하더라도 데이터의 수 및 처리방법 또는 연구자의 알고리즘 활용능력에 따라 그 예측결과에서 많은 차이가 나타났다. 그러나 인공지능망 또는 딥러닝의 특성이 해당 결과가 도출된 근거를 세부적으로 추적하기가 어려운 일종의 블랙박스여서 우연 또는 의도적인 결과오류가 있다 해도 이를 심층적으로 규명하는 데에는 한계가 있다. 따라서 보다 심도 있고 다양한 암반공학기술 개발을 위해서 그리고 연구결과의 신뢰성 제고를 위해 사용하고자 하는 인공지능 알고리즘에 대한 정확하고 상세한 이해가 필수적이라고 사료된다.

이상과 같이 현재 국내외적으로 진행되고 있는 인공지능을 활용한 연구 동향을 종합했을 때, 현재는 접근이나 분석이 난해한 암반공학 분야의 다양한 문제해결을 위해 또는, 다른 공학적 접근방법보다 월등히 우수한 결과도출을 위해 기계학습 외에 딥러닝 알고리즘인 CNN 및 RNN 등과 같은 보다 고차원적인 기법들을 활용한 연구 아이디어들이 점차 증가될 것으로 기대된다.

## REFERENCES

- Armaghani, D.J., M. Koopialipoor, A. Marto and S. Yagiz, 2019, Application of several optimization techniques for estimating TBM advance rate in granitic rocks, *Journal of Rock Mechanics and Geotechnical Engineering* 11(4), 779-789. <https://doi.org/10.1016/j.jrmge.2019.01.002>.
- Butler A.G. and J.A. Franklin, 1990, An expert system for rock mass classification, *Static and Dynamic considerations in Rock Engineering*, Balkema, Rotterdam, 73-80.
- Cachim, P. and A. Bezuijen, 2019, Modelling the Torque with Artificial Neural Networks on a Tunnel Boring Machine. *KSCE J Civ Eng* 23, 4529-4537. <https://doi.org/10.1007/s12205-019-0302-0>.
- CERIK (Construction & Economy Research Institute of Korea), 2019, Survey on Smart Technology Applications of Korean Construction Companies and Strategies for Activation, Report.
- Chen, H., C. Xiao, Z. Yao, H. Jiang, T. Zhang and Y. Guan, 2019, Prediction of TBM Tunneling Parameters through an LSTM Neural Network," 2019 IEEE International Conference on Robotics and Biomimetics (ROBIO), Dali, China, 702-707. doi: 10.1109/ROBIO49542.2019.8961809.
- Chen, J., T. Yang, D. Zhang, H. Huang and Y. Tian, 2021, Deep learning based classification of rock structure of tunnel face, *Geoscience Frontiers* 12, 395-404.
- Committee on the fourth industrial revolution, 2019, Recommendations to the government for the fourth industrial revolution.
- Das, A., S. Sinha and S. Ganguly, 2019, Development of a blast-induced vibration prediction model using an artificial neural network. *Journal of the Southern African Institute of Mining and Metallurgy*, 119(2), 187-200. <https://dx.doi.org/10.17159/2411-9717/2019/v119n2a11>.
- Dong L.J., X.B. Li and K. Peng, 2013, Prediction of rockburst classification using Random Forest, *Transactions of Nonferrous Metals Society of China* 23(2), 472-477, [https://doi.org/10.1016/S1003-6326\(13\)62487-5](https://doi.org/10.1016/S1003-6326(13)62487-5).
- Fan, G., F. Chen, D. Chen, Y. Li and Y. Dong, 2020, A Deep Learning Model for Quick and Accurate Rock Recognition with Smartphones, *Mobile Information Systems*, Article ID 7462524, 14. 2020. <https://doi.org/10.1155/2020/7462524>.
- Feng, G., G. Xia, B. Chen, Y. Xiao and R. Zhou, 2019, A Method for Rockburst Prediction in the Deep Tunnels of Hydropower Stations Based on the Monitored Microseismicity and an Optimized Probabilistic Neural Network Model. *Sustainability* 11, 3212. <https://doi.org/10.3390/su11113212>.
- Ghasemi, E., H. Amini, M. Ataei and R. Khalokakaei, 2014, Application of artificial intelligence techniques for predicting the flyrock distance caused by blasting operation. *Arab J Geosci* 7, 193-202. <https://doi.org/10.1007/s12517-012-0703-6>.

- Hasegawa, N., S. Hasegawa, T. Kitaoka and H. Ohtsu, 2019, Applicability of Neural Network in Rock Classification of Mountain Tunnel, *Materials Transactions*, 60(5), 758-764.
- Hejmanowski, R., A.A. Malinowska and W.T. Witkowski, 2016, Use of the Artificial Neural Networks for Modelling of Surface Subsidence Caused by Dehydration of Rock Mass. 16th international congress for mine surveying, Brisbane, Australia, 12-16.
- Hochreiter, S. and J. Schmidhuber, 1997, Long Short-term Memory, *Neural Computation* 9(8), 1735-1780.
- Houdt, G.V., C. Mosquera and G. Nápoles, 2020, A review on the long short-term memory model. *Artificial Intelligence Review* 53, 5929-5955. <https://doi.org/10.1007/s10462-020-09838-1>.
- Hudson, J.A., 1992, *Rock Engineering Systems: Theory and Practice*; Ellise Horwood: Chichester, UK.
- Jang, M.H., T. Ha and K.H. Choi, 2019, A Study on Mechanical RMR Classification Using Artificial Neural Networks and Robust Design, *J. Korean Soc. Miner. Energy Resour. Eng.* 56(6), 654-664. <https://doi.org/10.32390/ksmer.2019.56.6.654>.
- Jung, J.H., H. Chung, Y.S. Kwon and I.M. Lee, 2019, An ANN to Predict Ground Condition ahead of Tunnel Face using TBM Operational Data. *KSCE J Civ Eng* 23, 3200-3206. <https://doi.org/10.1007/s12205-019-1460-9>.
- Kim, H., L. Cho and K.S. Kim, 2019, Rock Classification Prediction in Tunnel Excavation Using CNN. *Journal of the Korean geotechnical society* 35(9), 37-45. <https://doi.org/10.7843/KGS.2019.35.9.37>.
- Kim, Y. and S.S. Lee, 2020, Application of Artificial Neural Networks in Assessing Mining Subsidence Risk. *Applied Sciences* 10(4), 1302. <https://doi.org/10.3390/app10041302>.
- Koukoutas, S.P. and A.I. Sofianos, 2015, Settlements Due to Single and Twin Tube Urban EPB Shield Tunnelling. *Geotech Geol Eng* 33, 487-510. <https://doi.org/10.1007/s10706-014-9835-7>.
- Lee, C.W. and H.K. Moon, 1994, Development of an Artificial Neural Network - Expert System for Preliminary Design of Tunnel in Rock Masses, *Geotechnical Engineering* 10(3), 79-96.
- Lee, J.S., S.K. Lee, D.W. Kim, S.J. Hong and S.I. Yang, 2018, Trends on Object Detection Techniques Based on Deep Learning, *ETRI, Electronics and Telecommunications Trends* 33(4), 23-32.
- Li, J., P. Li, D. Guo, X. Li and Z. Chen, 2021, Advanced prediction of tunnel boring machine performance based on big data, *Geoscience Frontiers* 12, 331-338.
- Li, N., R. Jimenez and X. Feng, 2017, The Influence of Bayesian Networks Structure on Rock Burst Hazard Prediction with Incomplete Data, *Procedia Engineering* 191, 206-214. <https://doi.org/10.1016/j.proeng.2017.05.173>.
- Liu, B., R. Wang, G. Zhao, X. Guo, Y. Wang, J. Li and S. Wang, 2020, Prediction of rock mass parameters in the TBM tunnel based on BP neural network integrated simulated annealing algorithm, *Tunnelling and Underground Space Technology* 95, 103103. <https://doi.org/10.1016/j.tust.2019.103103>.
- Lu, X., M. Hasanipناه, K. Brindhadevi, H.B. Amnieh and S. Khalafi, 2020, ORELM: A Novel Machine Learning Approach for Prediction of Flyrock in Mine Blasting. *Nat Resour Res* 29, 641-654. <https://doi.org/10.1007/s11053-019-09532-2>.
- McCarthy, J., 2007, What is Artificial intelligence, Stanford University. Computer Science Department (Download from <http://jmc.stanford.edu/articles/whatisai/whatisai.pdf>).
- Mitchell, T.M., 1997, *Machine Learning*, McGraw Hill.
- Monjezi, M., H. Amiri, A. Farrokhi and K. Goshtasbi, 2010, Prediction of Rock Fragmentation Due to Blasting in Sarcheshmeh Copper Mine Using Artificial Neural Networks. *Geotech Geol Eng* 28, 423-430. <https://doi.org/10.1007/s10706-010-9302-z>.
- Moor, J., 2006, The Dartmouth college artificial intelligence conference: The next fifty years, *American Association for Artificial Intelligence, AI Magazine* 27(4), 87-91.
- Morgenroth, J., U.T. Khan and M.A. Perras, 2019, An Overview of Opportunities for Machine Learning Methods in Underground Rock Engineering Design, *Geosciences* 9(12), 504.
- Öge, I.F., 2018, Regression Analysis and Neural Network Fitting of Rock Mass Classification Systems, *Journal of Science and Engineering* 20(59), 354-368.

- Oh, H.J., M. Syifa, C.W. Lee and S. Lee, 2019, Land Subsidence Susceptibility Mapping Using Bayesian, Functional, and Meta-Ensemble Machine Learning Models. *Applied Sciences* 9(6), 1248. <https://doi.org/10.3390/app9061248>.
- Parida, A. and M.K. Mishra, 2015, Blast Vibration Analysis by Different Predictor Approaches-A Comparison, *Procedia Earth and Planetary Science* 11, 337-345. <https://doi.org/10.1016/j.proeps.2015.06.070>.
- Pham, C. and H.S. Shin, 2020, A Feasibility Study on Application of a Deep Convolutional Neural Network for Automatic Rock Type Classification. *Tunnel and Underground space* 30(5), 462-472.
- Pham, H.V., F. Yuji and K. Kamei, 2011, Hybrid Artificial Neural Networks for TBM performance prediction in complex underground conditions, *IEEE/SICE International Symposium on System Integration (SII)*, Kyoto, 1149-1154. doi: 10.1109/SII.2011.6147611.
- Ran, X., L. Xue, Y. Zhang, Z. Liu, X. Sang and J. He, 2019, Rock Classification from Field Image Patches Analyzed Using a Deep Convolutional Neural Network. *Mathematics* 7, 755. <https://doi.org/10.3390/math7080755>.
- Ren, Q., G. Wang and M. Li, 2019, Prediction of Rock Compressive Strength Using Machine Learning Algorithms Based on Spectrum Analysis of Geological Hammer. *Geotech Geol Eng* 37, 475 – 489. <https://doi.org/10.1007/s10706-018-0624-6>
- Rosales-Huamani, J.A., R.S. Perez-Alvarado, U., Rojas-Villanueva and J. L. Castillo-Sequera, 2020, Design of a Predictive Model of Rock Breakage by Blasting Using Artificial Neural Networks, *Symmetry* 12(9), 1405.
- Salimi, A., C. Moormann, T.N. Singh and P. Jain, 2015, TBM Performance Prediction in Rock Tunneling Using Various Artificial Intelligence Algorithms, 11th Iranian and 2nd Regional Tunneling Conference, Tehran, Iran.
- Secretariat of committee on the fourth industrial revolution, 2020, Trend of policy on global AI.
- Sklavounos, P. and M. Sakellariou, 1995, Intelligent classification of rock masses, *Transactions on Information and Communications Technologies* 8.
- Specht, D.F., 1990, Probabilistic Neural Networks, *Neural Networks* 3, 109-118.
- Spencer B.F., V. Hoskerea and Y. Narazaki, 2019, Advances in Computer Vision-Based Civil Infrastructure Inspection and Monitoring, *Engineering* 5(2), 199-222.
- Sudakov, O., E. Burnaev and D. Koroteev, 2019, Driving digital rock towards machine learning: Predicting permeability with gradient boosting and deep neural networks, *Computers & Geosciences* 127, 91-98. <https://doi.org/10.1016/j.cageo.2019.02.002>.
- Xu, H., J. Zhou, P.G. Asteris, D.J. Armaghani and M.M. Tahir, 2019, Supervised Machine Learning Techniques to the Prediction of Tunnel Boring Machine Penetration Rate. *Appl. Sci.* 3715. <https://doi.org/10.3390/app9183715>.
- Xue, Y., Z. Li, D. Qiu, L. Zhang, Y. Zhao, X. Zhang and B. Zhou, 2019, Classification model for surrounding rock based on the PCA-ideal point method: an engineering application, *Bulletin of Engineering Geology and the Environment* 78, 3627 – 3635.
- Yang, H.S. and J.C. Kim, 1999, Rock Mass Rating for Korean Tunnels Using Artificial Neural Network, *J. of Korean Society for Rock Mechanics, Tunnel & Underground* 9(3), 214-220.
- You, K.H. and S.W. Jeon, 2013, A study on the fast prediction of the fragmentation zone using artificial neural, network when a blasting occurs around a tunnel. *J. of Korean Tunn undergr Sp Assoc.*, 15(2), 81-95. <https://doi.org/10.9711/KTAJ.2013.15.2.081>.
- Zhao, H. and B. Chen, 2020, Data-Driven Model for Rockburst Prediction", *Mathematical Problems in Engineering*, Article ID 5735496, 14. <https://doi.org/10.1155/2020/5735496>.
- Zhao, J., M. Shi, G. Hu, X. Song, C. Zhang, D. Tao and W. Wu, 2019, A Data-Driven Framework for Tunnel Geological-Type Prediction Based on TBM Operating Data, *IEEE Access* 7, 66703-66713. doi: 10.1109/ACCESS.2019.2917756.
- Zhou, J., B.Y. Bejarbaneh, D.J. Armaghani and M.M. Tahir, 2020, Forecasting of TBM advance rate in hard rock condition based on artificial neural network and genetic programming techniques. *Bull Eng Geol Environ* 79, 2069-2084. <https://doi.org/10.1007/s10064-019-01626-8>.