

## 터널 발파 진동 저감을 위한 대구경 무장약공 천공 장비의 최적 세팅조건 산정을 위한 딥러닝 적용에 관한 연구

김민성<sup>1)</sup> · 이제겸<sup>1)</sup> · 최요현<sup>1)</sup> · 김선홍<sup>2)</sup> · 정건웅<sup>2)</sup> · 김기림<sup>3)</sup> · 이승원<sup>1)\*</sup>

### A Study on the Optimal Setting of Large Uncharged Hole Boring Machine for Reducing Blast-induced Vibration Using Deep Learning

Min-Seong Kim, Je-Kyum Lee, Yo-Hyun Choi, Seon-Hong Kim,  
Keon-Woong Jeong, Ki-Lim Kim, Sean Seungwon Lee

**Abstract** Multi-setting smart-investigation of the ground and large uncharged hole boring (MSP) method to reduce the blast-induced vibration in a tunnel excavation is carried out over 50m of long-distance boring in a horizontal direction and thus has been accompanied by deviations in boring alignment because of the heavy and one-directional rotation of the rod. Therefore, the deviation has been adjusted through the boring machine's variable setting rely on the previous construction records and expert's experience. However, the geological characteristics, machine conditions, and inexperienced workers have caused significant deviation from the target alignment. The excessive deviation from the boring target may cause a delay in the construction schedule and economic losses. A deep learning-based prediction model has been developed to discover an ideal initial setting of the MSP machine. Dropout, early stopping, pre-training techniques have been employed to prevent overfitting in the training phase and, significantly improved the prediction results. These results showed the high possibility of developing the model to suggest the boring machine's optimum initial setting. We expect that optimized setting guidelines can be further developed through the continuous addition of the data and the additional consideration of the other factors.

**Key words** Blast vibration reduction, Center-cut method, Large-diameter horizontal boring, machine setting optimization, Deep learning

**초 록** 터널 발파 굴착 시 발생하는 진동을 저감시키기 위해 사용되는 MSP(Multi-setting smart-investigation of the ground and pre-large hole boring method) 공법은 1회 천공 시 수평방향으로 50m에 달하는 장거리를 천공하기 때문에 고 중량 해머비트와 룯드의 일방향 회전으로 룯드의 처짐과 우향 현상이 동반된다. 이는 전문가의 경험과 시공 이력을 바탕으로 가변적인 세팅을 통해 일부 보정되고 있다. 그러나 암반 특성, 장비 상태, 경험 부족 등은 목표 지점으로부터 천공 오차를 발생시키는 원인이 되며, 큰 이격 오차 발생 시 재시공으로 인한 공기 증가와 경제적 손실이 발생된다. 본 연구에서는 딥러닝을 활용하여 상황별 천공 장비의 최적 세팅조건 산정 모델을 개발하였으며, 학습 과정에서 발생 가능한 과적합 문제를 방지하기 위해 dropout, early stopping, pre-training 기법들을 사용하여 향상된 결과를 도출하였다. 본 연구를 통해 대구경 천공 장비의 상황별 초기세팅 산정 모델 개발의 높은 가능성을 확인했으며, 지속적인 데이터 수집과 다양한 인자들의 추가 학습을 통해 최적화된 세팅 가이드라인을 개발할 수 있을 것으로 기대된다.

**핵심어** 발파 진동 저감, 심발 공법, 대구경 수평 천공, 장비 세팅 최적화, 딥러닝

1) 한양대학교 자원환경공학과

2) (주)성진이엔씨

3) (주)유신

\* 교신저자 seanlee@hanyang.ac.kr

접수일 : 2020년 12월 3일

심사 완료일 : 2020년 12월 10일

게재 승인일 : 2020년 12월 14일

## 1. 서론

터널이나 지하공간 개발을 위한 암반 굴착 시 가장 경제적이고 효율이 좋은 발파 공법이 일반적으로 많이 사용되고 있다. 특히, 단일 자유면 특성을 가진 터널 구조물에서는 발파 시 발생하는 진동과 소음 등의 공해를 최소화하기 위해 심발 공법을 포함한 다양한 공법들이 적용 및 개발되어지고 있다(김동현 외, 2007; 황남순 외, 2016; 박훈 외, 2018).

MSP(Multi-setting smart-investigation of the ground and pre-large hole boring method) 공법은 터널 막장면에 382mm의 흡을 천공해 대구경의 자유면을 추가로 확보하여 발파 진동을 저감시키는 심발 공법 중 하나이다. 350mm 이상의 대구경 무장약공과 다른 제어발파 공법을 조합한 경우 기존 전통적인 심발 공법에 비해 최대 70%의 진동 저감 효과가 있는 것으로 보고되고 있다(백종현 외, 2012; 조래훈 외, 2013; 최형빈 외, 2016). MSP 공법은 천공을 위한 전체 공정과 터널의 굴착 사이클 등을 고려하여 통상적으로 1회 천공 시 수평방향으로 약 50m에 달하는 장거리를 천공한다. 50m 길이를 천공하기 위해서는 5m 길이의 룯드가 추가 연결되게 되는데, 천공 깊이가 증가할수록 중력과 회전의 영향을 받아 룯드의 처짐과 우향 현상에 따른 경로 이탈이 동반되며, 천공 전 장비의 변칙적인 세팅을 통해 이를 일부 보완하고 있다. 이때, 전체 천공 구간은 심발공으로 활용 가능한 범위 내에 위치해야하기 때문에 각 현장들의 특성을 고려한 천공 장비의 합리적인 초기 세팅조건을 산정하는 것이 매우 중요하다.

그러나 예측 불가능한 막장 전방 50m 구간의 지질 변화와 같은 환경적 요인은 예상 천공 경로를 이탈시키는 큰 요인이 되며, 특히 암반 내에 존재하는 단층, 절리, 파쇄대 등으로 인해 예상치 못한 큰 오차가 발생될 수 있다. 또한, 천공장비의 상태, 장비 운전원의 숙련도 등에 의해 최종 천공 목표 지점으로부터 이격 오차가 발생될 수 있으며, 천공 오차가 심한 경우 재시공이 요구되어 공기 증가와 경제적 손실을 야기할 수 있다. 현재는 다양한 시행착오와 시공경험을 가진 전문가의 판단에 의존하여 각 상황별로 천공장비의 변칙적인 초기세팅이 이루어지고 있는 실정이며, 전문가의 판단을 뒷받침할 수 있는 근거와 전문가의 부

재 시 이를 대체할 수 있는 합리적인 가이드라인이 필요하다.

따라서 본 논문에서는 다양한 조건에서의 시공이력, 전문가의 경험과 노하우를 데이터베이스화하고, 이를 딥러닝 기법에 적용하여 천공장비의 상황별 최적 초기세팅을 제안하는 딥러닝 모델을 개발하였다. 학습 시 과적합을 방지하고 최적의 모델을 학습시키기 위해 dropout, early stopping, pre-training 등의 기법을 사용하였고, 각 기법의 효과를 비교 분석하였다.

## 2. MSP 공법 소개

### 2.1 공법 소개

MSP 공법은 382mm의 대구경 헤머비트를 사용하는 고성능 대구경 천공장비를 이용해 터널 굴진 방향으로 약 50m의 무장약공을 천공하여 암반 구속도를 완화시키고, 이를 자유면으로 활용해 발파진동을 저감시키는 공법이다. 본 공법은 기존의 전통적인 심발 공법에 비해 진동 저감 효율이 매우 좋은 것으로 보고되고 있으나, 기존 천공장비의 경우 천공을 위한 준비/철수, 룯드 추가연결, 장시간의 천공 시간 등으로 인해 현장 공기를 지연시켜 많이 활용되지 못하였다. 최근 고성능 대구경 천공장비를 개발하여 천공 준비 및 철수 시간을 대폭 절감시켰으며, 천공 시간 또한 소폭 절감시켜 현장 적용사례가 증가하고 있는 추세이다. 그림 1에 나타난 고성능 대구경 천공장비는 실시간 천공 데이터 모니터링 시스템을 탑재하고 있어 천공 시 발생하는 타격압, 회전압, 추진압, 천공 속도, 타격진동 등을 모니터링 할 수 있으며, 이를 통해 천공 시 발생하는 일련의 과정들을 실시간으로 모니터링하여 예측이 어려운 막장 전방의 지질변화에 즉각 대응할 수 있고 장비의 망실을 사전에 방지할 수 있다. 또한, 천공 완료 직후 천공 경로 및 지반 탐사 복합시스템을 활용해 천공 경로를 추적하여 천공 품질을 확인하고, 그에 따른 재시공 여부를 즉시 파악할 수 있다. 이와 동시에 약 50m에 달하는 전체 천공 구간의 영상정보를 획득해 막장 전방의 지질 정보를 파악하여 터널 시공에 중요한 정보를 제공할 수 있다.



그림 1. 고성능 대구경 천공 장비


## 2.2 공법 특징

본 공법은 1회 천공 시 약 50m를 천공하기 때문에 그림 2의 (a)와 같이 일반적인 세팅을 통해 직선 형태로 천공할 경우 천공 깊이가 증가함에 따라 고 중량의 해머비트(0.9ton)와 5m 룯드(0.8ton/개)가 중력의 영향을 받아 바닥부로 처지는 문제가 발생한다. 따라서 그림 2의 (b)와 같이 천공장비 초기 세팅 시 변칙


적인 세팅을 통해 전체 천공구간이 심발공으로 활용할 수 있도록 상향 세팅하여 천공을 수행한다.

또한, 해머비트의 피스톤 왕복운동에 의한 압반 타격이 주 파괴 메커니즘인 MSP 공법은 최선단에 위치한 해머비트가 동일 지점을 타격하지 않도록 하고, 파쇄된 슬러지를 원활히 외부로 배출시키기 위해 해머비트와 룯드가 일정속도를 유지하며 시계방향으로 회전한다. 그림 3의 (a)와 같이 일반적인 세팅을 할 경우 룯드의 일방향 회전으로 인해 천공 진행방향을 목표 방향으로부터 점차 우향시키는 문제가 발생한다. 따라서 그림 3의 (b)와 같이 천공장비의 초기 세팅 시 장비의 후미를 우측으로 이동시키는 변칙적인 세팅을 통해 전체 천공구간이 심발공으로 활용될 수 있도록 한다.

대구경 무장약공은 효율적인 심발 발파를 위해 터널 중앙에서 하단부에 위치시키는 것이 일반적이며(백중현 외 2012), 각 구간별로 막장면에 천공된 위치를 기준삼아 발파패턴 설계가 이루어진다. 전체 천공



(a) 일반적인 초기 세팅



(b) 변칙적인 초기 세팅

그림 2. 장비 초기 세팅각도의 중요성

구간에 대한 대구경 무장약공의 심발 허용 범위는 터널 형태와 크기에 따라 조정될 수 있는데, 본 연구에서는 최대 심발 허용 범위를 좌, 우, 상향에 대해서는 1.5m로 설정하였고, 특히 터널 바닥면에 근접하거나 더 하부에 있는 경우 심발공으로 활용이 불가능하기 때문에 하향 오차에 대해서는 1m를 최대 오차범위로 설정하였다.

이러한 룯드의 처짐과 휘어짐은 다양한 조건에서의 시공 경험과 노하우를 가진 전문가의 주관적 판단에 의존하여 보정되고 있다. 또한, 천공 오차를 최소화하기 위해 해머비트의 마모 상태, 튜빙 유격 등의 상시적인 전문가의 점검을 통해 최적의 장비 상태를 유지시키고 있으며, 천공 중 특이사항이 없는 경우 최초 막장면에서 해머비트의 자리 잡기를 제외한 전 구간에 대





그림 3. 장비 후미 이동 거리의 중요성



(a) 중방향 처짐



(b) 타공방향 이탈

그림 4. 천공 이격오차 발생 사례



해서 추진압, 회전압, 타격압을 동일 수준으로 유지하여 오차를 유발할 수 있는 변수를 최소화하고 있다.

그러나 막장 전방의 지질 변화, 장비 운전원의 숙련도, 전문가의 부재(부정확한 계산) 등이 복합적으로 작용하여 목표 천공 지점으로부터 예상치 못한 이격 오차를 발생시켜 심발 허용 범위를 벗어날 수 있다. 그림 4의 (a)는 중단부의 목표 천공위치로부터 1.7m의 하향 오차가 발생한 사례이며, 그림 4의 (b)는 2.3m의 우상향 오차가 발생한 사례를 보여주고 있다. 이러한 천공 오차는 전체 천공 구간에 대한 막장면의 단면적이 동일함에도 발생될 수 있고, 여러 요인들이 복합적으로 작용하여 정확한 원인을 규명하기 어려우며, 심발 허용 범위로부터 이격 오차가 심한 경우 재시공에 따라 현장의 공기 증가와 경제적 손실이 발생할 수 있다.

### 3. 딥러닝 모델 개발

#### 3.1 딥러닝 알고리즘

MSP 공법의 완성도 높은 천공을 위해 가장 중요한 요소는 각 현장 상황에 적합한 장비의 초기 세팅 각도와 후미이동거리를 결정하는 것이다. 따라서 다양한 시공이력과 전문가의 노하우를 학습하여 현장 상황별 최적의 초기 세팅 조건을 제안하는 딥러닝 모델을 개발하였다. 본 논문에서 사용된 딥러닝 알고리즘은 생물의 신경세포 구조를 모방한 인공신경망을 기반으로 하는 머신러닝 기법의 일종이다. 딥러닝 모델은 Input 레이어, Output 레이어 그리고 두 레이어 사이에 존재하는 다수의 Hidden 레이어로 구성되며, 인접한 두 레이어 간에 존재하는 노드들의 연결 강도를 가중치라는 값을 이용하여 나타낸다. Input 레이어와 Hidden 레이어에서의 계산을 거쳐 최종적으로

Output 레이어에서 추론값을 도출해내게 되는데, 추론값과 실제값의 차이인 오차를 계산하고 오차를 최소화하는 방향으로 가중치를 수정하게 된다. 이 과정을 모든 데이터셋에 대해 반복적으로 수행하고, 오차가 일정값 이하로 수렴할 경우 학습을 완료하게 된다.

#### 3.2 학습 인자

딥러닝 모델의 학습인자를 선정하기 위해 이론적으로 시공 오류를 초래할 수 있는 변수들과 실제 고려되는 변수들을 모두 검토하였으며, 초기모델 개발을 위해 데이터의 중요도, 정확성, 획득 용이성 등을 고려하여 표 1과 같이 4개의 입력변수와 2개의 출력변수를 선정하였다. 암반특성은 천공 대상 암반의 물리적 특성을 내포하고 있는 인자로, 암반의 강도에 따라 처짐과 휘어짐의 정도가 상이하기 때문에 암반 특성을 이해하기 위한 기초자료로 사용되는 RMR (Rock mass rating)을 기반으로 천공 대상 암반을 극경암, 경암, 보통암, 연암, 풍화암으로 분류하여 학습하였다. 천공장은 1회 천공 시 요구되는 총 천공 길이로, 통상적으로 50m를 천공하나 현장 상황에 따라 10-60m를 천공한 사례가 있으며, 총 천공장이 길어질수록 중단부의 목표 천공 위치에 도달시키기 위한 상향각도가 커지기 때문에 룯드의 처짐을 보정하는 인자로 학습하였다. 중단구배는 노선 진행방향에서 상향 및 하향으로 기울어진 정도를 나타내는데, 이는 도로의 구분, 주변 지형 여건 등에 따라 달라지며, 하향구배일수록 중력의 영향을 많이 받기 때문에 룯드의 처짐을 보정하는 인자로 학습하였다. 이격거리는 중단부의 목표 천공 위치와 실제 천공 위치간의 이격 오차를 나타낸다. 전문가의 판단에 따른 상황별 초기 세팅조건과 그에 따른 천공결과를 내포하고 있다. 출력변수는 대규모 천공장비의 최적 초기세팅조건을 산

표 1. 머신러닝 최종 인자 선정

항목	구분	세부 내용
암반특성	Input 인자	천공 대상 암반 분류
천공장		현장 상황별 설계 천공장
중단구배		노선의 진행방향에서 상/하 방향으로 기울어진 정도
이격거리		중단부에서의 목표천공 위치 대비 실제 천공 결과의 이격거리
초기세팅각도	Output 인자	룰드의 처짐 현상을 보정하는 천공장비의 초기 상향세팅 각도
장비후미이동		룰드의 우향 현상을 보정하는 천공장비의 초기 후미이동 거리

출하기 위해 초기세팅 시 사용되는 인자로, 룯드의 처짐을 보정하는 장비의 초기세팅각도와 룯드의 우향 현상을 보정하는 후미이동거리로 선정하였다. 국내에 위치한 3개의 지하철 터널 및 배수로 터널 공사현장 중 곡선반경이 없는 직선 노선을 대상으로 데이터들을 수집하여 학습을 진행하였다.

### 3.3 과적합 방지 기법

과적합은 학습 데이터를 과하게 학습하여 학습 데이터에 대해서는 높은 정확도를 나타내지만, 실제 데이터 적용 시에는 성능이 떨어지는 현상이다. 과적합의 원인은 여러 가지가 있으나, 대표적으로 학습에 사용된 데이터의 양이 적을 경우 과적합이 발생하기 쉽다. 최근 개발된 고성능 대구경 천공장비는 기존의 대구경 천공장비에 비해 성능이 월등히 개선되어 기존 장비와의 초기 세팅 조건이 변동되어 기존 천공장비의 데이터들을 사용할 수 없으며, 공법 특성상 초기세팅 조건에 대한 데이터는 현장 당 하나씩밖에 획득할 수 없기 때문에 데이터가 비교적 부족하다고 판단되어 과적합을 방지하고 모델의 성능을 향상시킬 수 있는 Dropout, Early stopping, Pre-training 기법들을 사용하였다.

Dropout 기법은 학습이 진행되는 동안 무작위로 일정 비율만큼 일부 노드를 계산과정에서 생략하는

방법으로, 한 모델을 학습하는 만큼의 시간만 소요되면서도 생략되는 노드의 조합만큼 다양한 모델을 결합하는 효과를 얻을 수 있다(Srivastava et al., 2014). Early stopping 기법은 학습과 함께 검증오차를 지속적으로 확인하여 검증오차가 현 단계까지의 최소값보다 높아질 경우 학습을 중단하고 최소값의 검증오차를 산출한 경우의 모델을 최종 모델로 사용하는 기법으로, Dropout과 같은 복잡한 계산 없이 매우 간단한 방법만으로도 과적합을 효과적으로 방지할 수 있는 방법이다. Pre-training 기법은 딥러닝 학습 이전 초기 가중치를 산정할 때 랜덤 값을 부여하지 않고 사전에 학습된 다른 모델의 가중치를 가져와 사용하는 방법이다. 이 방법은 주로 학습이 완료된 모델을 원하는 데이터에 맞도록 정교화하기 위해 사용된다(Goodfellow et al., 2016). 본 논문에서는 데이터의 부족에 따른 과적합 문제를 극복하기 위해 실제 데이터를 기반으로 더미 데이터를 생성하여 딥러닝 모델을 사전 학습시키고, 실제 데이터에 최적화된 모델을 확보하기 위해 사전 학습된 모델을 실제 데이터로 재학습하는 과정을 거쳤다.

### 3.4 모델 학습

모델 생성 및 학습은 파이썬 환경에서 Tensorflow 및 Keras를 사용하여 수행하였으며, 딥러닝 모델 구

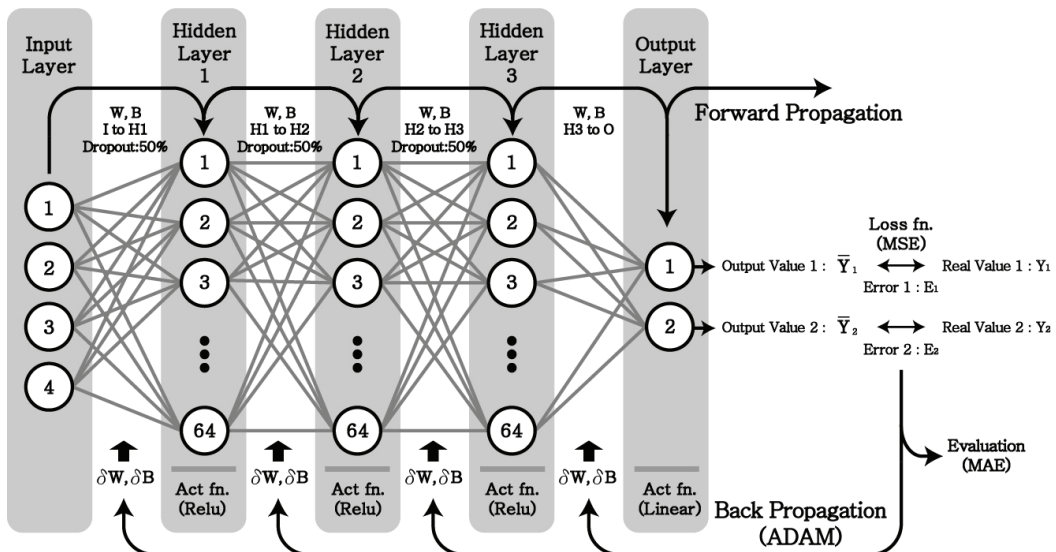


그림 5. 딥러닝 구조

조는 그림 5에 나타내었다. Hidden 레이어 개수는 3개, 각 레이어의 노드 수는 64개를 설정하여 모델을 구성하였다. Hidden 레이어의 활성화 함수는 Relu 함수를 사용하였고, Output 레이어의 활성화 함수는 Linear 함수를 사용하였다. 손실함수는 MSE(Mean Square Error)를 사용하였고, 역전파 알고리즘은 ADAM을 사용하였다. Dropout은 Output 레이어를 제외한 모든 Hidden 레이어 사이에 적용하였고, Dropout되는 비율은 0.5(50%)로 설정하였다. Early stopping 시 최저 오차를 판단하기 위한 유예 범위인 Patience 값을 200 Epoch로 설정하여 학습을 진행하였으며, 사전학습 시에도 동일하게 적용하였다.

#### 4. 결과 및 고찰

각 기법들에 따른 효율을 비교분석하기 위해 아무

기법도 사용하지 않고 학습이 진행된 경우를 포함하여 총 5개의 case study를 수행하여 검증오차를 비교 분석하였다. 각 기법에 대한 일반적인 결과를 확인하기 위해 각 case별로 20회씩 학습을 수행하였다. 학습 결과를 확인하기 위해 절대오차의 평균값을 사용하는 MAE(Mean absolute error)를 사용하였으며, 식 (1)로 계산된다.

$$MAE = \sum_{n=1}^{N_{output}} \frac{|y - \bar{y}|}{N_{output}} \quad (1)$$

여기서,  $\bar{y}$ 는 모델에서 나온 추론값,  $y$ 는 실제값이며,  $|y - \bar{y}|$ 는 두 값의 차이의 절대 오차이다. MAE를 통해 각 경우에 대한 학습 결과를 표 2에 나타내었다. 각 기법들을 단독으로 사용한 경우 아무 기법도 사용하지 않은 Case 1보다 전반적으로 더 나은 결

표 2. Case 별 검증 오차 (MAE)

	Case 1	Case 2	Case 3	Case 4	Case 5
사용 기법	None	Dropout	Early stopping	Pre-training	Dropout Early stopping Pre-training
Trial 1	3.4442	2.7841	2.8631	2.1498	0.9445
Trial 2	2.5854	2.8072	2.7189	2.2257	1.6982
Trial 3	2.6836	2.2488	2.3051	1.2891	0.9803
Trial 4	2.3159	2.4716	2.2403	0.9123	0.9235
Trial 5	4.0135	3.9837	3.9503	1.9900	2.2026
Trial 6	2.8928	3.1055	2.9674	0.9540	1.1029
Trial 7	2.3117	2.5661	2.0693	2.2277	1.6152
Trial 8	2.6955	2.2772	2.3342	0.9410	1.1892
Trial 9	4.3988	4.8600	4.6363	2.5076	1.8862
Trial 10	3.1205	3.1618	2.6848	1.8328	1.0705
Trial 11	3.2882	3.3289	3.2228	1.9370	1.4391
Trial 12	3.8281	3.4044	3.3881	1.4869	1.4867
Trial 13	3.7198	3.4876	3.8669	1.4803	2.1597
Trial 14	3.4412	3.8155	3.1682	1.2171	1.4272
Trial 15	3.6359	3.7889	3.5359	2.3672	1.7781
Trial 16	3.0114	3.2926	3.0916	1.4035	1.1308
Trial 17	2.6657	2.2217	2.2007	1.8964	1.6567
Trial 18	3.1768	3.2518	3.2467	1.8501	1.4855
Trial 19	3.4463	3.6094	3.3811	2.2203	1.0360
Trial 20	2.7352	2.7171	2.3504	1.2781	0.8907
Mean	3.1705	3.1592	3.0111	1.7083	1.4052

과를 보였으며, Pre-training 만을 사용한 Case 4가 약 1.71로 가장 나은 결과를 보였다. Dropout 및 Early Stopping 기법만을 사용한 Case 2, 3은 경우에 따라서 Case 1과 비슷하거나 더 큰 오차가 발생하였다. Case 1은 오차값이 약 3.17로 가장 높게 나왔으며, 본 모델의 경우 각 기법들을 개별적으로 사용할 때보다 여러 기법을 조합해서 사용한 Case 5가 약 1.41로 가장 작은 오차를 보였다.

최종 도출된 오차는 장비의 초기세팅조건과 후미 이동거리의 평균 오차를 의미한다. MSP 장비 세팅 시 장비의 후미이동은 1cm 단위로, 세팅각도는 0.1° 단위로 조정하는데, 오차가 각 항목에서 동일하게 발생했다고 가정할 경우, Case 5의 평균 오차인 1.4는 후미이동에 있어서는 비교적 양호하다고 판단될 수 있으나, 세밀하게 조정되는 세팅각도에 있어서는 비교적 큰 오차라고 판단된다.


50m 길이의 장거리를 천공하는 MSP 공법은 전체 천공구간에 대한 지질 특성을 전부 고려할 수 없는 한계가 있어 막장면의 암 판정에 따른 암질(강도) 정보만을 반영하여 천공되고 있다. 이는 천공 대상 암반의 전체 구간을 대표하는데 무리가 있으며, 막장 전방의 암반 특성에 따라 예상치 못한 이격오차를 발생시킨다. 그림 6의 (a)는 천공된 2공 중 1공이 목표 천공지점으로부터 종방향 이탈이 발생하여 상향 천공된 사례이며, (b)는 총 3공 중 1공이 횡방향으로 이탈한 사례를 보여주고 있다. 이와 같이 동일한 현장조건과 초기세팅으로 천공되었음에도 불구하고 막장 전방에 존재하는 절리, 파쇄대 등의 영향으로 예상 천

공 경로를 이탈시켜 각기 다른 천공 결과가 발생할 수 있다. 이러한 이유들로 학습에 사용된 현장별 데이터들은 다양한 오차를 내포하고 있어 비교적 큰 오차를 발생시킨 것으로 판단된다. 또한, 학습 시 전체 데이터의 일부를 무작위로 추출하여 검증 데이터로 사용하게 되는데, 일반적인 경향을 대표할 수 있는 데이터들로 구성된 경우 좋은 결과를 도출할 확률이 높으나, 반대로 큰 이격 오차가 발생된 이상 데이터들이 포함된 경우에는 오차를 증가시킬 수 있다. 본 연구에서는 딥러닝을 위한 학습 데이터의 수가 충분하지 않았으며, 중단부 이격 오차가 발생된 데이터들이 일부 포함되어 있어 비교적 큰 오차를 발생시킨 것으로 판단된다.

위 사례와 같이 막장 전방의 지질 변화에 기인하여 발생하는 이격 오차를 최소화하기 위해서는 전체 천공 구간에 걸친 암반 특성의 연속적인 변화를 파악하여 천공 시 반영하는 것이 중요하다. 본 연구팀에서는 천공 시 발생하는 추진압, 회전압, 타격압, 타격 진동, 천공 속도 등을 실시간으로 계측할 수 있는 천공 데이터 모니터링 시스템을 개발 및 시험 운용 중에 있으며, 막장 전방의 암반 특성과 관련하여 천공 오차를 초래하는 변수들 간 상관관계 분석을 고도화하기 위한 노력이 지속적으로 이루어지고 있다. 향후 현장 상황별 지속적인 데이터 수집과 모니터링 데이터들의 학습을 통해 지속적으로 딥러닝 모델을 고도화하여 지질 변화에 따른 천공 경로 이탈에 대한 문제를 상당히 해결할 수 있을 것으로 판단된다.



(a) 종방향 이탈



(b) 횡방향 이탈

그림 6. 중단부 천공 이격오차 발생 사례



## 5. 결론

본 연구에서는 터널 발파진동 저감을 위한 심발 공법 중 하나인 MSP 공법의 현장 적용을 위한 대구경 무장약공 천공 시 발생하는 천공 오차를 최소화하기 위해 딥러닝을 활용하여 시공 이력과 전문가의 노하우를 학습하여 현장 상황별 최적 초기세팅 조건 산정 모델을 개발하였다.

목표 상황에 적합한 기법 선정과 과적합 방지를 위해 Dropout, Early stopping, Pre-training 기법들을 조합하여 총 5개의 모델을 구성하여 각 모델별 오차를 비교하였다. 그 결과 각각의 기법들은 아무 기법도 적용하지 않은 기본모델보다 대부분의 경우에 있어서 향상된 결과를 도출했으며, 세 가지 기법을 조합하여 모델을 구성하였을 때 기본 모델 대비 오차를 절반 이하로 수렴시키는 최적의 결과를 보였다.

본 연구를 통해 고성능 대구경 천공장비의 상황별 초기세팅 조건 산정 모델 개발의 가능성을 파악하였으며, 향후 실시간 천공 데이터 모니터링 시스템을 통해 막장 전방의 전체 천공 구간에 대한 암반특성과 천공 오차 간의 상관관계 분석을 고도화하고, 해머비트의 마모 상태, 튜빙 유격 등과 같이 전문가의 주관적 판단을 통해 고려되는 천공장비 특성 인자들을 추가 학습한다면 보다 완성도 높은 모델로 개발이 가능할 것으로 기대된다. 또한, 다양한 현장에서 지속적인 데이터 수집을 통해 모델을 최적화시킨다면 전문가의 판단 근거를 뒷받침하고, 경험이 부족한 비전문가도 객관적 판단을 가능하게 하는 완성도 높은 가이드라인을 완성할 수 있을 것으로 기대된다.

## 감사의 글

본 연구는 국토교통부 국토교통기술사업화지원사업의 연구비지원(20TBIP-C144416-03)에 의해 수행되었습니다.

## 참고문헌

1. 김동현, 이상필, 이훈연, 이태노, 전석원, 2007, 터널 심발발파공법 SAV-Cut(Stage Advance V-Cut)의 특징 및 현장적용 사례연구, 화약·발파(대한화약발파공학회지), Vol.25, No. 1, pp. 31-43.
2. 박훈, 석철기, 노유송, 2018, 인공절리를 이용한 심발 발파에서의 지반진동 비교, 화약·발파(대한화약발파공학회지), Vol. 36, No. 4, pp. 16-25.
3. 백종현, 백상현, 한동훈, 원아람, 김창섭, 2012, 선대구경 수평보링 발파공법(PLHBM)의 설계 연구, 화약·발파(대한화약발파공학회지), Vol. 30, No. 2, pp. 66-76
4. 조래훈, 김도경, 노병돈, 2013, 전자뇌관과 선대구경수평보링공의 발파진동 저감효과, 대한지질공학회 학술발표회 논문집, 제주, pp. 57-60.
5. 최형빈, 한동훈, 기경철, 2016, 편마암지역에서 선대구경 수평보링 공수적용에 따른 지반진동 감쇠효과 연구, 화약·발파(대한화약발파공학회지), Vol. 34, No. 2, pp. 1-9.
6. 황남순, 이동훈, 이승재, 2016, 전자뇌관을 활용한 발파 시공 사례, 화약·발파 (대한화약발파공학회지), Vol. 34, No. 4, pp. 40-45.
7. Goodfellow, I., Bengio, Y., Courville, A., 2016, Deep Learning, MIT Press, Cambridge, 246-325.
8. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R., 2014, Dropout: A Simple Way to Prevent Neural Networks from Overfitting, J. Mach. Learn. Res., Vol. 15, No. 56, pp. 1929-1958.



**김민성**

한양대학교 자원환경공학과  
박사과정

Tel: 02-2220-4018  
E-mail: mskim9264@gmail.com



**이제겸**

한양대학교 자원환경공학과  
석사과정

Tel: 02-2220-4018  
E-mail: leejk1991@hanyang.ac.kr



**최요현**

한양대학교 자원환경공학과  
박사과정

Tel: 02-2220-4018  
E-mail: netisen@hanyang.ac.kr



**김선홍**

(주)성진이엔씨 대표이사

Tel: 031-942-1983  
E-mail: shkim85@empas.com



**정건웅**

(주)성진이엔씨 전무

Tel: 031-942-1983  
E-mail: candid68@naver.com



**김기림**

(주)유신 이사

Tel: 02-6202-0826  
E-mail: duftkk11@daum.net



**이승원**

한양대학교 자원환경공학과  
교수

Tel: 02-2220-2243  
E-mail: sesanlee@hanyang.ac.kr