

# 순환인공신경망을 활용한 터널굴착면 전방 Q값 예측에 관한 연구

홍창호<sup>1</sup> · 김진<sup>2</sup> · 류희환<sup>3</sup> · 조계춘<sup>4\*</sup>

<sup>1</sup>정회원, 한국원자력연구원 방사성폐기물처분연구부 박사후연구원

<sup>2</sup>비회원, 한국과학기술원 건설및환경공학과 석사과정

<sup>3</sup>정회원, 한국전력공사 전력연구원 구조내진그룹 선임연구원

<sup>4</sup>정회원, 한국과학기술원 건설환경공학과 교수

## Study on Q-value prediction ahead of tunnel excavation face using recurrent neural network

Chang-Ho Hong<sup>1</sup> · Jin Kim<sup>2</sup> · Hee-Hwan Ryu<sup>3</sup> · Gye-Chun Cho<sup>4\*</sup>

<sup>1</sup>Postdoctoral Researcher, Div. of Radioactive Waste Disposal Research, KAERI

<sup>2</sup>Graduate Student, Dept. of Civil and Environmental Engineering, KAIST

<sup>3</sup>Senior Researcher, Structural & Seismic Tech. Group, KEPSCO Research Institute

<sup>4</sup>Professor, Dept. of Civil and Environmental Engineering, KAIST

\*Corresponding Author : Gye-Chun Cho, gyechun@kaist.ac.kr

### Abstract

Exact rock classification helps suitable support patterns to be installed. Face mapping is usually conducted to classify the rock mass using RMR (Rock Mass Rating) or Q values. There have been several attempts to predict the grade of rock mass using mechanical data of jumbo drills or probe drills and photographs of excavation surfaces by using deep learning. However, they took long time, or had a limitation that it is impossible to grasp the rock grade in ahead of the tunnel surface. In this study, a method to predict the Q value ahead of excavation surface is developed using recurrent neural network (RNN) technique and it is compared with the Q values from face mapping for verification. Among Q values from over 4,600 tunnel faces, 70% of data was used for learning, and the rests were used for verification. Repeated learnings were performed in different number of learning and number of previous excavation surfaces utilized for learning. The coincidence between the predicted and actual Q values was compared with the root mean square error (RMSE). RMSE value from 600 times repeated learning with 2 prior excavation faces gives a lowest values. The results from this study can vary with the input data sets, the results can help to understand how the past ground conditions affect the future ground conditions and to predict the Q value ahead of the tunnel excavation face.

**Keywords:** Rock mass classification, Q-value, Recurrent neural network, Tunnel ahead prediction

### OPEN ACCESS

Journal of Korean Tunnelling and  
Underground Space Association  
22(3)239-248(2020)  
<https://doi.org/10.9711/KTAJ.2020.22.3.239>

eISSN: 2287-4747  
pISSN: 2233-8292

Received April 14, 2020

Revised May 4, 2020

Accepted May 7, 2020



This is an Open Access article distributed under the terms of the Creative Commons Attribution

Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Copyright © 2020, Korean Tunnelling and Underground Space Association

## 초 록

터널 굴착 시 정확한 암반 분류는 적합한 지보패턴을 설치하는 데 도움을 준다. 암반의 분류를 위해 주로 RMR (Rock Mass Rating)과 Q값을 산정하여 수행되며, 페이스 매핑(face mapping)을 바탕으로 산정된다. 점보드릴 및 프로브드릴의 기계 데이터를 활용하거나 딥러닝을 활용한 굴착면 사진 분석 등의 방법이 암반등급 분류를 예측하기 위해 사용되고 있으나, 분석 시 오랜 시간이 소요되거나, 굴착면 전방의 암반등급을 파악할 수 없다는 점에서 한계를 갖는다. 본 연구에서는 순환인공신경망(Recurrent neural network, RNN)을 활용하여 굴착면 전방의 Q값을 예측하는 방법을 개발하였고 페이스 매핑으로부터 획득한 Q값과 비교/검증하였다. 4,600여개의 굴착면 데이터 중 70%를 학습에 활용하였고, 나머지 30%는 검증에 사용하였다. 학습의 횟수와 학습에 활용한 이전굴착면의 개수를 변경하여 학습을 수행하였다. 예측된 Q값과 실제 Q값의 유사도는 RMSE (root mean square error)를 기준으로 비교하였다. 현재 굴착면과 바로 직전의 굴착면의 Q값을 활용하여 600회 학습하여 예측한 Q값의 RMSE값이 가장 작은 것을 확인하였다. 본 연구의 결과는 학습에 사용한 데이터 값 등이 변화하는 경우 변화할 수 있으나 터널에서의 이전 지반상태가 앞으로의 지반상태에 영향을 미치는 시스템을 이해하고, 이를 통해 터널 굴착면 전방의 Q값의 예측이 가능할 것으로 판단된다.

**주요어:** 암반분류, Q값, 순환인공신경망, 터널굴착면 전방예측

## 1. 서론

일반적으로 터널 굴착 시 암반을 분류하는 것은 지보패턴 등을 결정하는 데 매우 중요한 역할을 하며 정확한 지보패턴의 결정은 안전한 터널 굴착 및 공사기간의 단축, 공비감소 등으로 이어진다. 대표적인 암반분류 방법은 RMR (rock mass rating)과 Q시스템으로부터 얻어지는 Q값이 있다. Bieniawski (1973)가 제안한 RMR은 암반의 일축압축강도(uniaxial compressive strength, UCS), RQD (rock quality designation), 절리 간격, 절리 개수, 지하수, 절리 방향 등을 고려하여 산정되며, Q값은 RQD, 절리 set의 개수, 절리 거칠기, 절리, 지하수, 응력감소계수(stress reduction factor, SRF) 등을 활용하여 획득된다. 터널 굴착면의 암반분류는 대부분 작업자가 육안을 통해 기록한 페이스 매핑(face mapping)을 바탕으로 이루어지는 것이 현실이나 점보드릴/프로브드릴의 기계 데이터, 전기비저항 탐사, 그리고 인공지능 딥러닝을 활용한 굴착면 사진 분석 등을 활용하여 얻어지기도 한다(Ryu et al., 2014; Kim et al., 2015; Kim et al., 2019a; 2019b). 하지만 점보드릴이나 프로브드릴을 활용한 천공/코어획득 시 기계 데이터를 활용한 굴착면 전방의 암반분류 방법은 데이터 획득 및 분석에 오랜 시간이 소요된다는 단점이 있다. 또한 굴착면 사진 분석의 경우 사진을 통해 간단하게 암반분류를 할 수 있다는 장점이 있지만 굴착면 전방의 암반 등급에 대해서는 전혀 파악할 수 없다.

모든 터널은 연속된 지반을 굴착해가기 때문에 이전 굴착면의 정보가 앞으로 등장할 터널 굴착면의 정보와 밀접한 연관이 되어 있다는 것은 엔지니어의 경험으로 예측 가능하다. 하지만 이를 객관적으로 활용할 만한 검증된 방법이 존재하지 않았다. 최근 TBM에서 추력 및 토크 등의 기계굴진 데이터를 바탕으로 딥러닝하여 터널 굴착면 전방을 예측하는 연구들이 수행되어오고 있지만(Jung et al., 2019) 지나간 터널굴착면 및 현재 굴착면의 암반등급

만을 활용하여 굴착면 전방의 암반등급을 예측하는 국내 사례는 거의 없다.

본 연구에서는 4,000개 이상의 터널 굴착면 페이스 매핑을 통해 획득된 Q값을 딥러닝의 한 종류인 순환인공신경망(recurrent neural network, RNN)을 학습시키고 학습된 인공지능을 활용하여 굴착면 전방의 Q값을 예측하는 방법을 개발하였다. 이를 검증하기 위해 실제 페이스 매핑으로부터 획득한 Q값과 비교 및 분석하였다.

## 2. 암반분류(Rock mass classification)

암반의 종류를 분류하는 방법 중 가장 널리 사용되는 것이 RMR (rock mass rating)과 Q분류법이다. RMR은 Bieniawski (1973)에 의해 제안된 방법으로 암반의 일축압축강도(uniaxial compressive strength, UCS), RQD (rock quality designation), 절리간격(spacing of discontinuity), 절리상태(condition of discontinuity), 지하수(groundwater), 절리방향(discontinuity orientation) 등의 항목들을 점수화하고 이들 항목의 배점을 더하고 빼 얻어진다.

$$RMR = UCS_r + RQD_r + SoD_r + CoD_r + GWC_r + DCO_r \quad (1)$$

여기서,  $UCS_r$ 은 일축압축강도를 바탕으로 한 점수(rating),  $RQD_r$ 은 RQD를 바탕으로 한 점수,  $SoD_r$ 은 절리간격을 바탕으로 한 점수,  $CoD_r$ 은 절리 조건을 바탕으로 한 점수,  $GWC_r$ 은 지하수조건을 바탕으로 한 점수,  $DCO_r$ 은 절리방향을 바탕으로 한 점수이다.

Q값은 Barton (1974)에 의해 제안되었으며 RQD, 절리군 개수 인자( $J_n$ ), 절리거칠기 인자( $J_r$ ), 절리( $J_a$ ), 지하수 인자( $J_w$ ), 그리고 SRF (stress reduction factor)의 곱과 나눔으로부터 구해진다. Q값의 범위는 0.001~1,000으로 매우 넓다.

$$Q = \frac{RQD}{J_n} \times \frac{J_r}{J_a} \times \frac{J_w}{SRF} \quad (2)$$

## 3. 순환인공신경망(Recurrent neural network, RNN)

기존의 인공신경망과 합성곱 신경망(Convolutional neural network, CNN)에서는 시간의 흐름과 같이 이전의 값들이 이후의 값들에 영향을 미치는 현상들에 대한 분석이 어려웠다. 특히 오차 역전파 알고리즘은 경사하강법이나 뉴턴법 등을 활용하여 미분값이 0이 되는 지점을 찾아가도록 설계되었으나 전체 최소값(global minimum)이 아닌 부분 최소(local minimum)값을 가지는 방향으로 흘러갈 수 있다는 한계점이 존재한다. 이를 극복하기 위해 개발된 것이 순환인공신경망(RNN)으로 주식차트의 예측, 문자 자동완성 등의 분야에서 성공적으로 사용되고 있다. 순환인공신경망의 개념은 다음 Fig. 1과 같으며 앞에서 발생한 이벤트가 다음의 것을 예측하는 데 영향을

주도록 설계되어 있다(Zhang et al., 2018). 본 연구에서 활용한 RNN 알고리즘은 LSTM (Long short term memory) 방법으로 Hochreiter and Schmidhuber (1997)에 의해 처음 제안되었으며 GRU (gated recurrent unit)와 더불어 가장 대표적인 RNN 상용 알고리즘이다. Fig. 2(a)는 LSTM의 기본구조로 입력(input), 망각(forget), 출력(output)으로 이루어져 있고 Fig. 2(b)는 GRU의 기본구조로 리셋(reset)과 업데이트(update)로 이루어진다. 프로그래밍 언어로는 파이썬(Python)을 활용하였고 LSTM을 활용하기 위해 구글에서 제공하는 텐서플로우(tensor flow)를 활용하였다.




Fig. 1. Basic concept of recurrent neural network system (Zhang et al., 2018)




Fig. 2. Basic concept of (a) LSTM and (b) GRU (Zhao et al., 2019)

## 4. 현장데이터 수집 및 순환인공지능공망을 활용한 터널굴착면 Q값 예측

### 4.1 터널 Q값 획득 및 인공지능 학습

본 연구에서 획득한 터널굴착면의 Q값은 총 4,689개로 9개의 터널에서 확보하였다. 따라서 8곳에서는 연속적이지 못한 데이터값을 가지고 있지만 총 데이터 개수에 비해 무시할 수 있는 수로 판단하였다. NATM 공법을 활용한 터널 굴착 시 1회 발파 당 굴진거리는 암반의 상태 등에 따라 변화하므로 각 터널 굴착면 사이의 거리는 서로

다르다. 1회 발파로 인한 굴진거리가 일정한 간격은 아니지만 연속적인 터널굴착면 데이터이므로 본 연구에서는 터널굴착면의 개수를 활용하여 인공지능을 학습하였다. 일반적인 인공지능 및 머신러닝의 경우 총 데이터의 약 70%를 학습에 사용하고 나머지 30%를 검증에 사용한다. 본 연구에서도 약 70%에 해당하는 3,282개의 Q값과 이를 계산하는 데 필요한 6가지의 항목들(RQD,  $J_n$ ,  $J_r$ ,  $J_a$ ,  $J_w$ , SFR)을 포함해 총 7개의 입력변수를 학습시키고 1,407개의 Q값을 RNN으로 예측된 Q값을 검증하는 데 활용하였다. 이때, 예측한 Q값은 현재 굴착면 바로 앞의 굴착면의 Q값을 의미하며 Q값의 예측에는 전방의 굴착면의 정보는 포함되지 않는다. 입력 데이터의 신뢰성 확보를 위해 각 항목의 최대값( $X_{max}$ )과 최소값( $X_{min}$ )을 활용한 정규화(min-max scaler =  $(X_{input} - X_{min}) / (X_{max} - X_{min})$ )를 통해 데이터를 전처리한 후 인공지능을 학습하였고 예측된 Q값은 정규화 과정을 역산하여 도출하였다. LSTM 셀의 층은 1개층으로 하였고 히든 레이어는 10개로 설정하였으며 학습 비율(learning rate)은 0.01로 하였다. 터널 굴착면에서 획득한 Q값의 인자와 Q값을 활용하여 통해 인공지능을 학습시켰으며 본 연구에서 활용된 인공지능의 학습 과정을 도식화하면 Fig. 3과 같다. 인공지능의 경우 학습에 사용하는 데이터를 다수 학습시키게 되면 학습되지 않은 데이터를 예측하는 데 오류가 발생하기도 한다. 터널굴착면 전방의 Q값을 예측하도록 순환인공신경망을 학습시키는 데 있어 몇 개의 학습의 횟수(N)와 이전 터널굴착면의 개수(m)를 활용하여 예측할 것인지는 매우 중요하다. 따라서 학습에 사용한 터널굴착면의 개수를 2~10개로 바꾸며 600회, 800회, 1,000회, 1,200회 학습을 수행하였다.

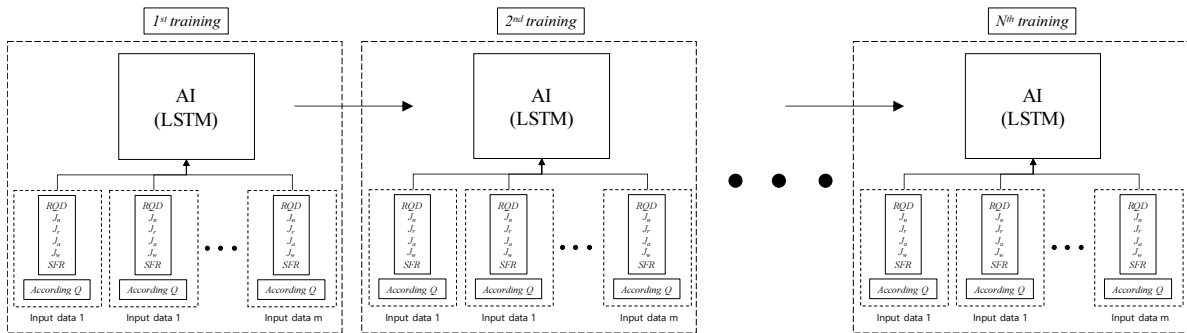


Fig. 3. Input data set for training and training process

#### 4.2 RNN을 활용한 Q값 예측 및 실제 Q값과의 비교

Fig. 4는 각각 2개, 3개, 5개, 10개의 터널굴착면을 활용하여 RNN을 1,200회 학습 시 도출된 실제 Q값과을 활용해 예측된 Q값이다. 2개, 3개, 5개의 터널굴착면을 활용하여 예측한 Q값들의 경우 초반 50개의 Q값에 대해서는 정확한 예측을 하지 못하고 있다. Figs. 5~7은 각각 2개, 3개, 5개, 10개의 터널굴착면을 활용하여 RNN을 1,000회, 800회 및 600회 학습 시 도출된 전방의 Q값과 실제 굴착 시 도출된 Q값을 비교한 것이다. Figs. 4~7의 그래프만을 활용해서 인공지능을 활용해 예측한 Q값과 실제 Q값의 일치도를 판별하기는 쉽지 않다.

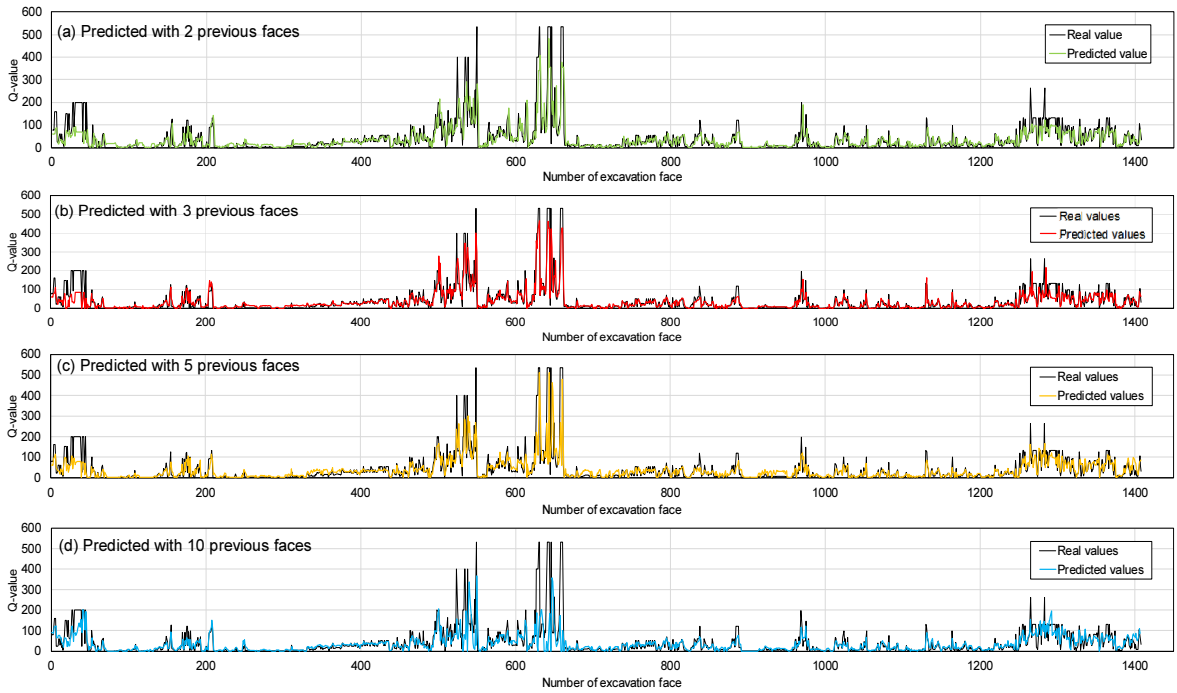


Fig. 4. Q-value from tunnel (black line) and RNN (colored lines) (training: 1,200 times)

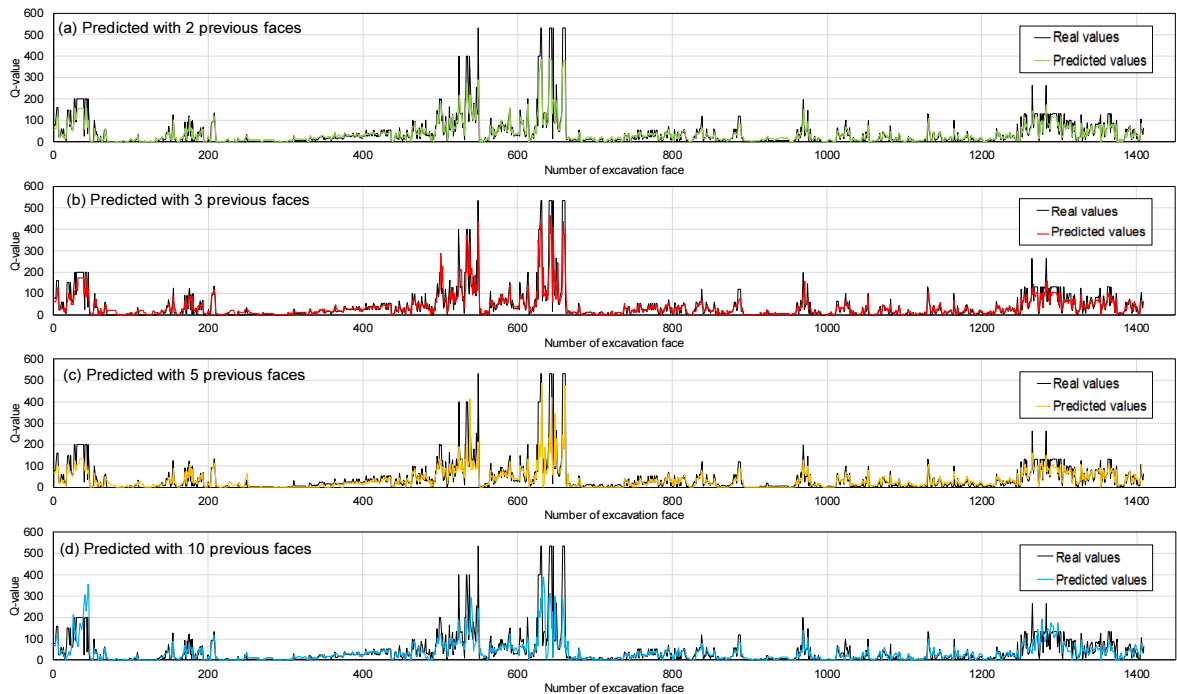


Fig. 5. Q-value from tunnel (black line) and RNN (colored lines) (training: 1,000 times)

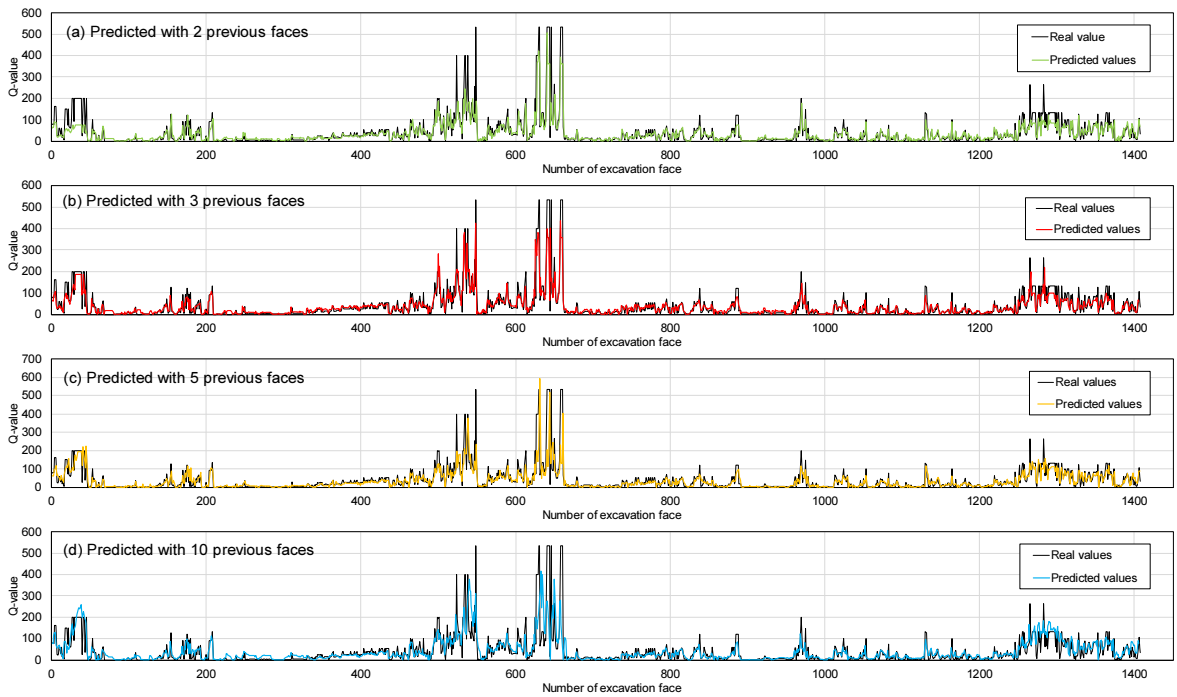


Fig. 6. Q-value from tunnel (black line) and RNN (colored lines) (training: 800 times)

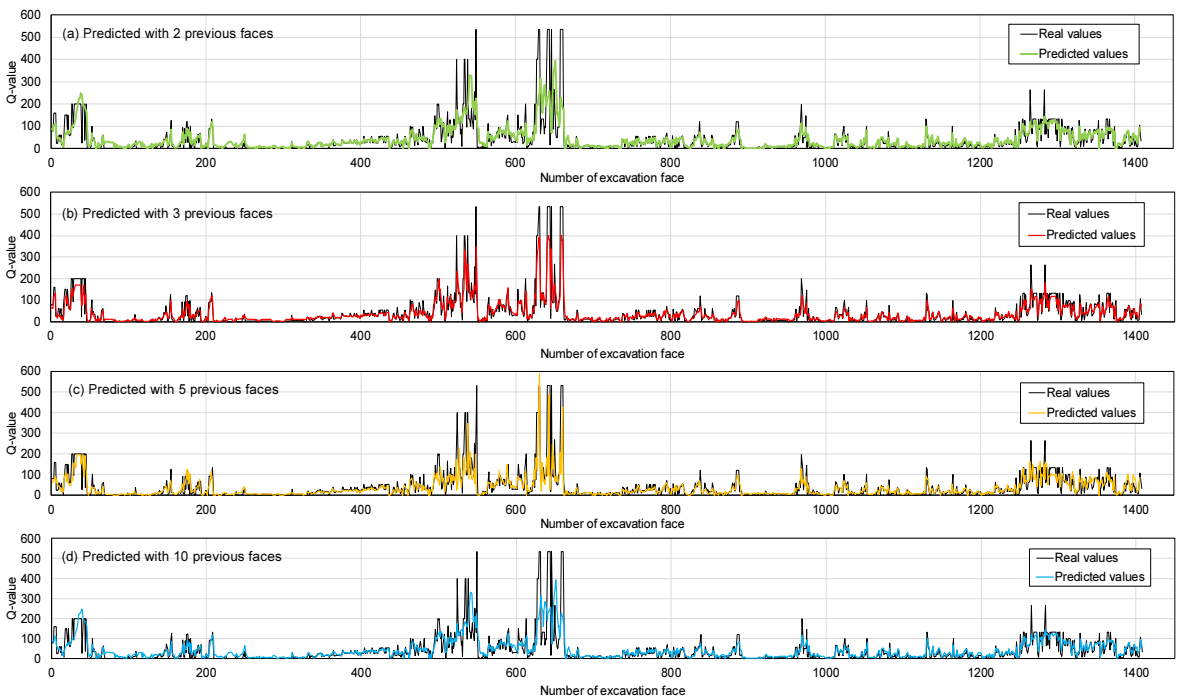


Fig. 7. Q-value from tunnel (black line) and RNN (colored lines) (training: 600 times)

예측된 값이 실제 값과 유사한 지 확인하는 방법으로 root mean square error (RMSE)를 활용하는 방법이 있다. RMSE는  $m$ 개의 값에 대하여 실제값( $a_n$ )과 예측값( $b_n$ )으로 표현되며 값이 작을수록 실제 값과 유사하다.

$$RMSE = \sqrt{\sum_{n=1}^m \frac{(a_n - b_n)^2}{m}} \quad (3)$$

Fig. 8은 학습에 활용된 터널굴착면의 수와 학습횟수에 따른 RMSE값의 범위를 나타낸다. RMSE값은 2개의 터널굴착면을 활용하여 Q값을 예측한 경우가 학습에 사용된 터널굴착면의 수와 관계없이 가장 작은 값을 보이는 것을 확인하였다. 이는 RNN을 활용한 터널 굴착면 전방의 Q값 예측에는 현재 굴착면과 바로 직전의 굴착면을 확인하여 600회 학습을 통해 굴착면 전방의 Q값을 예측하는 것이 본 연구에서는 가장 신뢰성 있음을 나타낸다.

RMSE의 값이 낮은 ‘2개의 굴착면을 활용해 1,200회 학습하여 Q값을 예측한 것’보다 RMSE의 값이 높은 ‘5개의 굴착면을 활용해 800회 학습하여 Q값을 예측한 것’이 더 상관성이 높아 보이지만 Q값의 특성상 0.001에서 1,000의 넓은 범위를 가지고 있어 Q값을 구성하는 하나의 항목의 사소한 변화도 Q값의 변화에 큰 영향을 미치게 되므로 RMSE값은 작은 Q값에서의 차이보다 큰 Q값에서의 차이의 영향이 더 크게 된다. RMSE값은 두 값의 상대적인 비교는 적합하지만 특정 값 이상일 때 정확함을 표현하기에는 부적합한 부분이 존재한다.




Fig. 8. Root mean square error in different number of prior excavation faces for learning and number of learning

## 5. 결론

본 연구에서는 순환인공신경망(RNN)의 한 종류인 LSTM을 활용하여 터널굴착면 전방의 Q값을 예측하는 시스템을 개발하였다. 본 연구에 의해 얻어진 결론은 다음과 같다.



1. 터널의 경우 이전의 지반 상태가 앞으로의 지반 상태에 영향을 미치는 것은 자명하나 이를 공학적인 방법으로 검증할 수 있는 방법이 존재하지 않았다. 하지만 순환신경망을 활용하면 이와 같이 이전의 값들이 앞으로의 값들에 영향을 미치는 시스템을 이해하는 데 도움이 된다. 4,000개 이상의 터널 Q값 중 약 70%는 순환신경망의 학습에 사용하고 나머지 30% Q값은 순환신경망 학습의 결과로 도출된 알고리즘의 검증에 활용하였다.
2. 2개, 3개, 5개, 10개의 이전 터널굴착면 Q값을 활용하여 600회, 800회, 1,000회, 1,200회 인공지능을 학습시켰고 이를 바탕으로 RMSE값을 이용해 예측 Q값과 실제 Q값을 비교하였다. 2개의 터널 굴착면을 800회 학습하여 터널굴착면 전방의 Q값을 예측하는 것이 가장 신뢰성 있는 것으로 나타났다. 하지만 Q값 및 RMSE의 정의 등을 고려할 때 예측값과 실제값을 비교하는 방법의 한계가 존재한다. 예측 Q값은 확보할 수 있는 Q값의 수, 학습에 사용하는 RNN 알고리즘의 종류 등에 따라 달라질 수 있다. 따라서 추후 연구에서는 실제 Q값과 예측 Q값을 정확히 비교할 수 있는 방법을 제안하고, RNN의 다른 방법 중 하나인 GRU 알고리즘을 활용하여 예측한 Q값과 본 연구에서 사용한 LSTM 알고리즘을 통해 얻은 Q값을 비교하고자 한다.

## 감사의 글

이 논문은 2020년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2017R1A5A1014883, 2020M2C9A1062949).

## 저자 기여도

홍창호는 연구 개념 및 원고작성을 하였고, 김진은 해석알고리즘을 개발하였고, 류희환은 데이터 수집 및 데이터 분석을 하였고, 조계춘은 데이터 해석 및 원고검토를 하였다.

## References

1. Barton, N., Lien, R., Lunde, J. (1974), "Engineering classification of rock masses for the design of tunnel support", Rock Mechanics, Vol. 6, No. 4, pp. 189-236.
2. Bieniawski, Z.T. (1973), "Engineering classification of jointed rock masses", The Civil Engineer in South Africa, Vol. 15, No. 12, pp. 335-343.
3. Hochreiter, S., Schmidhuber, J. (1997), "Long short-term memory", Neural Computation, Vol. 9, No. 8, pp. 1735-1780.
4. Jung, J.H., Kim, B.K., Chung, H.Y., Kim, H.M., Lee, I.M. (2019), "A ground condition prediction ahead of tunnel face utilizing time series analysis of shield TBM data in soil tunnel", Journal of Korean Tunnelling and Underground Space Association, Vol. 21, No. 2, pp. 227-242.
5. Kim, H.M., Lee, I.M., Hong, C.H. (2019a), "Effect of RMR and rock type on tunnel drilling speed", Journal of Korean Tunnelling and Underground Space Association, Vol. 21, No. 4, pp. 561-571.

6. Kim, H.Y., Cho, L.H., Kim, K.S. (2019b), “Rock classification prediction in tunnel excavation using CNN”, *Journal of the Korean Geotechnical Society*, Vol. 35, No. 9, pp. 37-45.
7. Kim, K.S., Kim, J.H., Jeong, L.C., Lee, I.M., Cho, G.C. (2015), “Development for prediction system of TBM tunnel face ahead using probe drilling equipment and drilled hole imaging equipment”, *Journal of Korean Tunnelling and Underground Space Association*, Vol. 17, No. 3, pp. 393-401.
8. Ryu, H.H., Oh, T.M., Cho, G.C., Kim, K.Y., Lee, K.R., Lee, D.S. (2014), “Probabilistic relationship between Q-value and electrical Resistivity”, *KSCE Journal of Civil Engineering*, Vol. 18, No. 3, pp. 780-786.
9. Zhang, S., Bamakan, S.M.H., Qu, Q., Li, S. (2018), “Learning for personalized medicine: A comprehensive review from a deep learning perspective”, *IEEE Reviews in Biomedical Engineering*, Vol. 12, pp. 194-208.
10. Zhao, H., Chen, Z., Jiang, H., Jing, W., Sun, L., Feng, M. (2019), “Evaluation of three deep learning models for early crop classification using sentinel-1A imagery time series—A case study in Zhanjiang, China”, *Remote Sensing*, Vol. 11, No. 22, pp. 2673.