

인공신경망을 이용한 터널 주변 폭파 시 파쇄영역의 빠른 예측에 관한 연구

유광호^{1*} · 전석원²

¹정회원, 수원대학교 토목공학과 교수

²정회원, 서울대학교 지구환경시스템공학부 교수

A study on the fast prediction of the fragmentation zone using artificial neural network when a blasting occurs around a tunnel

Kwang-Ho You^{1*}, Seok-Won Jeon²

¹University of Suwon, Dept. of Civil Engineering, Professor

²Seoul National Univ. Dept. of Urban and Geosystem Engineering, Professor

ABSTRACT: When collapse occurs due to explosion near a tunnel, fragmentation zone should be comprehended quickly to recover the function of the tunnel itself. In this study, a method to interpret explosion behavior and predict the fragmentation zone fast. For this purpose, the various 3D-meshes were generated using SolidWorks and explosion analyses were carried out using AUTODYN. The influence of explosion variables such as source location on fragmentation volume were examined by performing sensitivity analyses. Also, a training database for an artificial neural network analysis had been established and the optimal training model was selected, and the predicted results for fragmentation volume and radius were verified. The suggested method had demonstrated that it could be effective for the fast prediction of fragmentation zone.

Keywords: Blasting, Tunnel, Artificial neural network, Fragmentation zone

요 지: 터널 인근에서 폭발이 일어나 붕괴가 발생할 경우 터널의 기능을 회복시키기 위해서는 파쇄영역에 대하여 빠르게 파악하여야 한다. 본 연구에서는 폭발에 따른 거동을 파악하고 파쇄영역을 빠르게 예측할 수 있는 방법을 서술하였다. 이를 위해 SolidWorks를 이용하여 다양한 3차원 요소망을 작성하고, AUTODYN을 이용하여 폭발해석을 수행하였다. 민감도 분석을 실시하여 해석결과를 이용해 폭발위치 등과 같은 폭발변수가 파쇄부피에 미치는 영향을 살펴보았다. 또한 인공신경망 학습자료로 구축하고, 최적의 학습모델을 선정하고, 파쇄부피와 반지름의 예측결과를 검증하였다. 연구결과, 본 연구에서 서술된 방법이 파쇄영역을 빠르고 효과적으로 예측할 수 있음을 확인하였다.

주요어: 폭발, 터널, 인공신경망, 파쇄영역

1. 서 론

우리나라는 국토를 효과적으로 활용하기 위하여 지하공간을 활용하는 경우가 증가하고 있다. 이러 이 유로 교통, 저장, 군사시설 등 여러 가지 기능의 터널을

포함한 지하공간이 많이 분포하고 있는 실정이다. 또한 세계 유일의 분단국가로서 항상 전쟁의 위험을 가지고 있다. 전쟁 발생 시 유용하게 사용될 터널이 폭파무기 등에 의해 붕괴가 발생할 수 있다. 이런 경우 피해상황을 빠르게 파악하고 복구 작업을 효율적으로 실시하기 위해서는 먼저 폭발에 의해 발생된 파쇄영역을 정확하게 파악해야 하며, 이를 짧은 시간에 정확하게 예측할 수 있는 기법이 요구된다.

*Corresponding author: Kwang-Ho You
E-mail: khyou@suwon.ac.kr

Received February 14, 2013; Revised February 25, 2013;
Accepted February 28, 2013

터널과 인접한 위치에서 폭발이 일어나 터널 붕괴가 발생하는 경우, 폭발에 의한 거동을 파악하기 위해서는 실 규모의 터널폭파 실험을 수행하는 것이 가장 신뢰도 높은 방법이다. 하지만 실제 실험은 준비에서 완료까지 많은 시간과 비용이 요구되며, 장소섭외가 쉽지 않다는 문제점이 있다. 따라서 실험을 대체할 수 있는 검증된 해석기법에 대한 연구가 요구된다.

최근 들어 ANSYS Inc.에서 제공하는 동해석 프로그램인 AUTODYN을 사용하여 실제 실험을 대체하는 경우가 늘어나고 있다. Cho et al. (2008)은 TBM 디스크 커터의 암석절삭에 관하여 기존의 LCM 시험을 모사하기 위한 수치해석을 실시하였다. 수치모사를 위하여 AUTODYN 프로그램을 선정하였으며, 이를 통하여 각기 다른 4가지 이상의 커터 간격 조건에 대해 수치해석을 수행하였다. 그 결과, 수치해석과 LCM 시험에서 도출된 최적 커터 간격은 대체로 일치하여, 추후 LCM 시험결과를 보완할 수 있을 것으로 판단하였다. 또한 You and Son (2013)은 터널 주변에서의 폭발에 따라 발생된 버력을 빠르게 파악하고 처리하는 데 걸리는 시간을 예측하고자 하였다. 이를 위해 다양한 폭발변수의 모델에 대하여 AUTODYN으로 폭발해석을 실시하고 이에 따라 발생하는 버력량을 산정하는 방법을 제시하였다. 그리고 버력처리에 사용될 건설장비의 작업량을 파악하고 산정된 버력량에 적용하여 처리에 소요되는 시간을 예측하였다. 또한 예측된 처리시간을 폭발변수 별로 비교하고 분석하였다.

한편 여러 가지 현상이나 문제를 파악하기 위하여 주로 실험이나 수치해석을 이용한 방법이 사용된다. 실험은 비교적 정확하지만 시간이 오래 걸리고 비용이 많이 소요되는 단점이 있고, 수치해석은 실험보다는 시간과 비용이 적게 소요되지만, 실제 현상을 그대로 나타낼 수 없는 단점이 있다. 이를 대체하거나 보완하기 위한 방법으로 인공지능망을 이용하는 방법이 많이 사용된다. 인공지능망은 학습을 통하여 실험이나 수치해석을 수행하지 않고 빠르게 결과를 예측할 수 있으나, 학습에 사용되는 자료의 양과 질에 추론

결과가 크게 좌우된다. Shin and Kwon (2009)은 터널 설계 시 대부분을 차지하는 미 시추 구간의 지반등급 분류를 위하여 시추공에서 얻은 직접조사 결과와 시추구간의 전기 비저항 탐사결과를 이용해 인공지능망 학습을 실시하여 예측하고자 하였다. 그 결과, 예측결과가 탐사로부터 추정된 취약지반 구간의 위치와 거의 일치함을 확인하였다. 또한 You and Song (2012)은 터널설계 시 사용되는 지반 물성치의 불확실성을 최소화하기 위해 인공지능망 학습을 통하여 최적의 지반 물성치를 찾고자 하였다. 이를 위해 실제 현장을 대상으로 다양한 물성치로 수치해석된 결과를 학습자료로 구축하였다. 그리고 다양한 인공지능망 구조로 학습한 결과의 평균제곱오차, 결정계수를 비교해 최적의 학습구조를 선정하고, 학습결과를 실제 현장의 계측변위와 비교하여 최적의 지반 물성치를 산정하였다.

본 논문에서 시공이 완료된 터널을 대상으로 폭파 무기 등이 터널 주변을 타격했을 경우 파쇄된 지반의 부피(파쇄부피)와 형상(파쇄반지름)을 빠르게 예측하고자 하였다. 또한 폭발변수에 따른 파쇄부피 변화에 대하여 파악하고자 하였다. 이를 위해 SolidWorks (SolidWorks Corp., 2011)로 다양한 모델을 작성하고 요소망을 구성해 총 192 가지 모델에 대하여 AUTODYN (ANSYS Inc., 2010)으로 폭발해석을 실시하였다. 또한 해석된 결과를 이용하여 민감도 분석을 실시해 변수에 따른 파쇄부피의 변화를 파악하고, 해석결과에서 파쇄반지름을 측정해 학습자료로 구성하여 MATLAB (MathWorks Inc., 2010)을 사용하여 인공지능망 학습을 실시하였다. 그리고 다양한 구조로 학습된 결과에 대하여 매개변수 연구를 실시해 최적의 학습구조를 선정하고, 이를 이용해 예측된 파쇄부피와 파쇄반지름에 대하여 학습자료와 비교하여 검증을 실시하였다.

2. 폭발해석

폭발거동을 모사하기 위한 프로그램으로는 ConWEP,

AtBlast, LS-DYNA, AUTODYN 등이 널리 사용된다. 본 연구는 동적해석 프로그램인 AUTODYN (ANSYS Inc., 2010)을 사용하였다. AUTODYN은 실험이 거의 불가능한 현상들(음속 이상의 초고속 충돌관통 현상, 폭발 등)에 대한 해석적 방법을 제공해 실제 실험을 대체할 수 있는 가상 실험효과가 있다. 실제 폭발을 프로그램으로 구현하기 위해서는 폭발압력을 산정하여 적용하는 것이 중요하다. 또한 물질의 거동을 표현하기 위해 프로그램에서 제공되는 다양한 종류의 물성 모델 중 적절한 모델을 선택하여 사용할 필요가 있다.

2.1 폭발압력 산정

폭발은 물질이 고온, 고밀도, 고압의 가스로 변환되면서 파장을 발생시키는 급격한 에너지 방출의 과정이다. 개방공간에서의 파장은 초기에 주변의 대기와 평형상태를 이루기 위해 압력을 순간적으로 상승시킨 후, 아주 짧은 시간(수천분의 1초)동안 감쇄되는 충격파 형태를 이룬다. 이를 정압 상태(positive phase)라 한다. 또한 충격파는 공기를 통해 전달된 입사압력(incident pressure)이 구조물 등과 충돌 시 반사되면서 증폭된다. 이를 반사압력(reflected pressure)이라고 하고, 해석 시 고려되는 구조물에 직접적으로 작용하는 폭발압력인데 Konya and Walter (1991)가 제안한 식 (1)을 이용하여 산정할 수 있다.

$$P = \frac{4.18 \times 10^{-7} \times SG_e \times V^2}{1 + 0.8 \times SG_e} \quad (1)$$

여기서, P : 폭발압력(kbar, 1 kbar = 100 kN/m²)
 SG_e : 비중
 V : 폭발속도(ft/s)

2.2 물성 모델

수치해석 시 구성되는 물질의 거동을 실제와 같이 나타내기 위해서는 거동에 대한 정의가 필요하다. 이

를 위해 AUTODYN 프로그램에서는 상태방정식(EOS, equation of state), 강도(strength) 모델, 파괴(failure) 모델 등 다양한 형식의 물성 모델들이 제공된다.

2.2.1 상태방정식

상태방정식이란 물질의 일정량에 대하여 압력이나, 부피, 온도 등의 상태 변수들 사이에 성립하는 관계식을 말한다. 각각의 물질을 나타내는 상태방정식은 다양한데, 이 중 JWL (Jones-Wilkins-Lee) 상태방정식은 식 (2)와 같이 폭발 물질을 나타내기 위해 사용되는 경험적 식이다. 이 식은 폭약이 기폭되어 압력이 1 kbar까지 떨어지는 동안 폭약의 거동을 나타내기 위해 사용된다(ANSYS Inc., 2010).

$$P = A \left(1 - \frac{w\eta}{R_1} \right) e^{-\frac{R_1}{\eta}} + B \left(1 - \frac{w\eta}{R_2} \right) e^{-\frac{R_2}{\eta}} + w\rho E \quad (2)$$

여기서, P : 폭발압력(MPa)

A, B : 폭발물에 대한 동적 실험으로 결정되는 계수(MPa)

R_1, R_2, w : 폭발물에 대한 동적 실험으로 결정되는 상수

ρ : 밀도(kg/cm³)

η : ρ/ρ_0 (ρ_0 : 초기 밀도)

E : 초기 단위부피 당 내부에너지(MJ/m³)

알짜이 미세 공극을 가진 재료의 거동특성은 여러 연구에 의해 파악되었는데 이런 거동을 프로그램에 구현하기 위하여 P-alpha 상태방정식을 이용한다. 식 (3)의 상태방정식은 재료에 압력을 가할 시, p_e 압력에 이르기까지 탄성적인 변형을 보이고, 그 후 p_s 압력에 이르기까지는 소성적인 변형을 보인다.

$$\alpha = 1 + (\alpha_p - 1) \left[\frac{p_s - p}{p_s - p_e} \right]^2 \quad (3)$$

여기서, α_p, p_s, p_c : 실험을 통해 결정되는 상수
 α : 공극률

$$Y_{elastic} = Y_{fail} \times F_{elastic} \times F_{ca}(p)$$

$$Y_{fric} = B \times p^M \tag{4}$$

2.2.2 강도 모델 및 파괴 모델

압반은 정적인 하중을 받을 때 보다 변형속도가 큰 동적하중을 받을 때 더 큰 강도에 도달하게 되어 큰 외력에 저항할 수 있다. 그 이유는 폭발하중과 같이 매우 짧은 시간 동안 작용하는 하중의 속도를 재료의 변형속도가 따라가지 못해 파괴가 되기 전에 항복점과 극한응력에 도달하기 때문이다. 이러한 재료의 강도와 파괴에 대한 특징을 표현하기 위해 다양한 종류의 모델 중에서 선택하여 사용해야 한다.

AUTODYN에서 제공하는 모델은 Johnson Cook, elastic, RHT 콘크리트 등이 있는데 이 중 Riedel et al. (1999)에 의해 정립된 RHT (Riedel-Hiermaier-Thoma) 콘크리트 모델이 주로 사용된다. 이 모델은 취성재료가 동적하중을 받을 때 거동을 표현하기 위해 만들어졌고 압력, 변형률, 변형률 속도 경화, 누적손상, 변형률 연화 등과 같은 여러 특징을 도입할 수 있는 장점이 있다. 또한 식 (4)에서 제시되는 탄성한계($Y_{elastic}$), 재료 파괴강도(Y_{fail}), 파손된 재료의 잔류 강도(Y_{fric})와 같은 세 강도를 도입하여 충격과 충격을 받는 콘크리트 재료의 비선형적 손상거동을 효과적으로 묘사할 수 있다(Park, 2012).

여기서, $F_{elastic}$: 파괴 강도에 대한 탄성한계 비
 B : 잔류 파괴 상수
 p : 정규화된 압력
 $F_{ca}(p)$: 정수압력 상태의 탄성 편차 응력을 제한하는 함수
 M : 잔류 파괴 지수.

3. 인공신경망 학습

인공신경망이란 인간의 신경조직을 모방하여 간단한 기능의 처리기 사이를 서로 대규모로 연결시킨 네트워크 형태의 정보처리 구조이다. 또한 복잡하고 비선형적인 특성을 가지는 값을 이용하여 특정값을 예측하고자 할 때 유용하여 최근에 다양한 분야에 적용되고 있다. 생물학적 신경조직은 Fig. 1(a)와 같은 뉴런(neuron)을 기본 단위로 다수의 뉴런들이 서로 연결된 신경회로망이다. 각 뉴런은 세포체(cell body)로 이루어진 중심부 축삭돌기(axon), 수상돌기(dendrite)로 이루어진 신경섬유로 구성되어 있다(Wasserman, 1989). 이러한 생물학적 특성을 기반으로 하여 Fig. 1(b)와 같은 인공적인 신경모델을 구현할 수 있다. 인공신경망의 종류는 다양하지만 입력층과 출력층

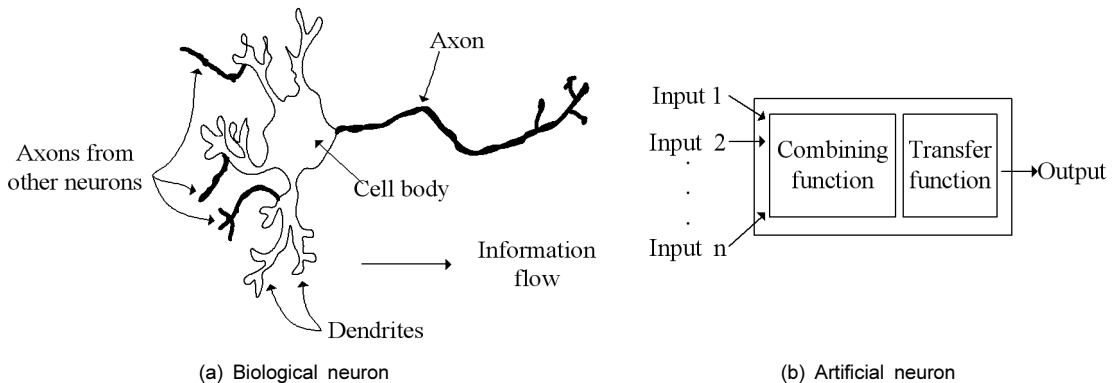


Fig. 1. Biological neuron and artificial neuron (after Wasserman, 1989)

사이에 여러 층이 존재하여 연결강도를 다양하게 조절할 수 있는 다층 퍼셉트론(multi-layer perceptron)이 자주 사용된다. 그리고 인공신경망에 사용되는 다양한 알고리즘 중에서 학습 대상의 특징에 따라 적절한 방법을 선택하는 것이 중요하다.

3.1 다층 퍼셉트론

인공신경망에 사용되는 퍼셉트론 모델은 단층과 다층 퍼셉트론으로 나눌 수 있다. 단층 퍼셉트론은 입력층과 출력층으로만 구성되며, 학습은 주어진 입력에 대하여 원하는 출력이 나오도록 연결선의 강도를 조정함으로써 이루어진다. 이 경우 학습결과는 가능한 두 가지 중의 하나로 나타나기 때문에 실제로 적용하기에는 많은 무리가 있다. 단층 퍼셉트론의 단점을 극복하기 위해 다층 퍼셉트론(MLP)을 이용하는데, 이는 입력층과 출력층 사이에 하나 이상의 중간층이 존재하는 인공신경망 모델로 Fig. 2와 같은 층상구조를 갖는다.

입력층과 출력층 사이의 중간층을 은닉층(hidden layer)이라 하며, 입력, 은닉, 출력 방향으로 연결된 전방향(feed forward) 네트워크이다. 다층 퍼셉트론은 단층 퍼셉트론과 유사한 구조를 가지고 있지만 중간층과 각 처리기의 입출력 특성을 비선형으로 함으로써 단층 퍼셉트론의 단점들을 극복하여 복잡한 문제를 학습하는 데 자주 쓰인다(Pao, 1989).

3.2 학습 알고리즘

인공신경망 학습에 사용되는 학습 알고리즘은 주어진 문제에 따라 선택할 수 있으며, 각 알고리즘에서 요구하는 학습변수를 손쉽게 설정하여 학습에 반영할 수 있다. 현재 일반적으로 사용되는 알고리즘은 LM, GD, GDM, GDA, SCG 등이 있다.

본 연구에서 사용되는 LM (Levenberg-Marquardt) 알고리즘은 비선형 함수들의 제곱의 합과 최소화 함수로 만들어진 Newton's method를 변형한 방법이며, 인공신경망 학습에 매우 잘 맞는 것으로 알려져 있다. 또한 GD (gradient descent) 알고리즘은 기울기 하강법으로 기울기에 비례한 현재 위치에서 단계적으로 함수의 최소 또는 최대에 점진적으로 접근하는 방법이다. GDM (gradient descent with momentum) 알고리즘은 국부적인 최소값을 얻기 위해 관성항에 따라 경사를 감소시키는 방법이다. GDM은 역전파 알고리즘의 가중치를 개선하는 학습율과 관성항을 포함하고 있다. GDA (gradient descent with adaptive learning rate) 알고리즘은 학습율과 사용하는 관성항의 기울기 변화에 따라 가중치를 향상시키는 방법이다. SCG (scaled conjugate gradient) 알고리즘은 최적화 관점에서 전체적인 오류 함수를 최소화 시키는 인공신경망 네트워크 학습이다. 그리고 다변량 함수는 네트워크 가중치에 의존한다.

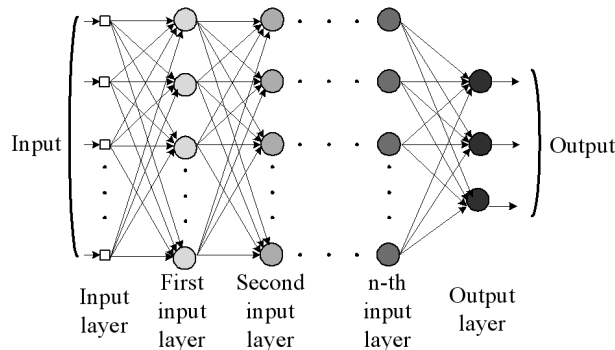


Fig. 2. Structure of multi-layer perceptron (after You and Song, 2012)

4. 폭발해석 모델링 및 분석

4.1 해석모델 개요

폭발해석에 사용되는 영역은 SolidWorks를 이용하여 Fig. 3과 같이 작성되었다. 터널 주변에서의 폭발을 연구대상으로 하기 때문에 터널이 포함된 보통암 내지 극경암의 암반사면으로 구성하였다. 해석영역은 충분히 넓게, 즉 높이 50 m, 길이 160 m, 폭 80 m이고 사면높이 40 m, 경사 20°의 암반으로 구성하여 해석결과가 영역의 크기에 영향을 받지 않도록 하였다. 터널은 x축 방향으로 60 m까지 굴착되고, 터널 단면은 반원형으로 폭 5 m, 높이 4 m인 것(터널반지름 2.5 m)과 폭 14 m, 높이 8 m인 것(터널반지름 7 m) 2가지가 고려되었다.

폭발변수로는 터널반지름(tunnel radius)이 2.5, 7

m, 암반강도(rock mass strength)가 100, 200 MPa, TNT (trinitrotoluene) 장약량(charge)은 25, 60, 260 kg을 사용하였다. 또한 폭발위치는 Fig. 4(a)와 같이 터널 중심선(C.L., center line)으로부터 0°, 30°, 60° 회전된 선상에 위치하며 ‘×’로 표시하였다. 단, 본 논문에서는 이를 편의상 ‘회전각도(rotation angle)’라고 표기하고, Fig. 4(b)와 같이 터널갱구로부터 굴진방향으로 36.3, 42.3, 48.3 54.3 m 떨어진 위치를 각각 ①, ②, ③, ④와 굴진면으로부터 방사방향으로 떨어진 거리가 1, 2, 3 m 되는 위치를 각각 ㉠, ㉡, ㉢로 표시한다. 참고로 회전각도가 0°, 30°인 경우는 7개의 폭발위치를 선정하고, 60°인 경우는 ③번 위치 선상의 2 지점만 폭발위치로 선정하였다. 따라서 터널반지름, 암반강도, 장약량, 폭발위치(x, y, z축)를 변수로 하여 총 192 [$2 \times 2 \times 3 \times (7 + 7 + 2)$]가지 경우에 대하여 AUTODYN을 이용해 폭발해석을 실시하였다.




Fig. 3. Analysis zone and size (tunnel radius 7 m)




Fig. 4. Blasting locations (tunnel radius 7 m)




Fig. 5. Analysis model mesh

Fig. 5(a)는 Solidworks 프로그램으로 발파해석을 위하여 구성된 요소망(mesh)이다. 폭발이 발생하는 지점으로부터 파쇄대로 예상되는 영역까지는 조밀한 요소로 구성하였다. 반면 폭발의 영향이 적은 외부영역은 느슨하게 구성하여 해석시간을 효율적으로 운영하고자 하였다. 또한 폭발을 표현하기 위하여 폭발물 질을 Fig. 5(b)와 같이 구(sphere) 형태의 TNT로 설정하였다. 25 kg의 장약량을 구현하기 위하여 장약량을 밀도로 나누어 구의 부피(0.015 m³)를 구하였다. 단, 밀도는 AUTODYN에서 제공하는 ‘TNT’ 밀도인 1,630 kg/m³을 이용하였다. 60 kg 장약량인 경우는 0.037 m³, 260 kg 장약량인 경우는 0.160 m³의 부피로 설정하고 일정한 간격의 요소망으로 구성하였다.

폭발에 의해 발생하는 압력은 이론적으로 식 (1)과 같은 상태방정식에 의하면 15.29 GPa이지만 폭풍파와 폭발음 생성 및 절리를 통해 빠져나가는 누수압 등으로 인해 실제 압력은 TNT 요소 절점 당 10.72

GPa이 작용되는 것으로 가정하였다. 폭발압력은 프로그램에서 자동으로 계산되어 장약량에 관계없이 각 요소의 절점으로부터 동일한 압력이 인접한 주변 압반요소로 전파된다. 또한 장약량이 커질수록 요소의 개수가 많아져 작용되는 압력의 양도 증가하게 되는 것이다.

4.2 해석을 위한 물성치 및 경계조건

해석모델의 재료는 암반, TNT로 이루어져 있다. AUTODYN 프로그램으로 폭발해석 시 각 재료의 거동을 수치적으로 평가하기 위하여 2.2절에 서술된 바와 같이 각 재료의 상태방정식, 강도(strength) 모델, 파괴(failure) 모델에 대한 설정이 필요하다. 또한 파쇄된 암반의 탈락 판정의 기준이 되는 마멸모델이 요구된다. 본 연구에서 Table 1과 같이 암반과 TNT의 해석 모델과 물성치는 You and Kim (2012)이 사용한

Table 1. Applied models and input properties (You and Kim, 2012)

	EOS	Strength model		Failure model		Erosion model	
Rock	P-alpha	RHT concrete		RHT concrete		geometric strain	
		shear modulus	22.06 GPa	failure principal stress	10 MPa	erosion strain	2%
		compressive strength	100, 200 MPa				
		tensile strength	0.1 MPa				
shear strength	0.3 MPa						
TNT	JWL	-		-		geometric strain	
						erosion strain	2%




Fig. 6. Boundary conditions

물성치와 동일하게 사용하였다.

TNT의 경우 AUTODYN에서 제공하는 ‘TNT’ 물성치를 사용하였고, 폭발적이고 높은 팽창성을 가진 거동해석에 사용되는 JWL 상태방정식을 사용하였다. 암반에 적용된 P-alpha 상태방정식은 에너지에 의한 공극을 가진 재료의 거동을 나타낼 때 사용된다. 또한 강도 모델과 파괴 모델로는 압력 강화, 변형 강화, 변형률 강화, 변형률 연화, 균열 완화 등의 특징을 가진 RHT 콘크리트 모델을 적용하였다. TNT의 경우 강도, 파괴 모델은 고려하지 않고, 마멸 모델은 암반과 함께 적용해 요소의 기하학적 변형율(geometric strain)이 2% 이상일 경우 즉시 탈락하여 파쇄부피에 포함되도록, 즉 마멸 변형율(erosion strain) 한계를 2%로 적용하였다. 또한 길이 단위는 m, 무게 단위는 kg, 시간 단위는 sec를 사용하였다.

한편 실제와 같은 폭발해석을 위해 경계조건의 설정이 필요하다. Fig. 6과 같이 자유면을 제외한 면은 충격파(shock wave)와 변위(displacement)가 저항 없이 통과하는 무한한 영역을 가정하기 위해 ‘velocity’와 ‘transmit’ 경계조건을 적용하였다. 그리고 중력가속도는 y축 아래 방향으로 9.81 m/s^2 을 적용하였다.

4.3 해석결과 분석

본 연구에서는 터널 주변에서의 폭발에 따른 파쇄부피를 파악하고자 하였다. 이를 위해 다양한 변수로 작성된 요소망에 대하여 AUTODYN 폭발해석을 실시하였다. 그리고 해석결과로 제공되는 파쇄부피에 대하여 민감도분석을 실시하였다. 또한 결과의 비교를 위하여 편의상 Fig. 4(b)와 같이 터널갱구에서 가장

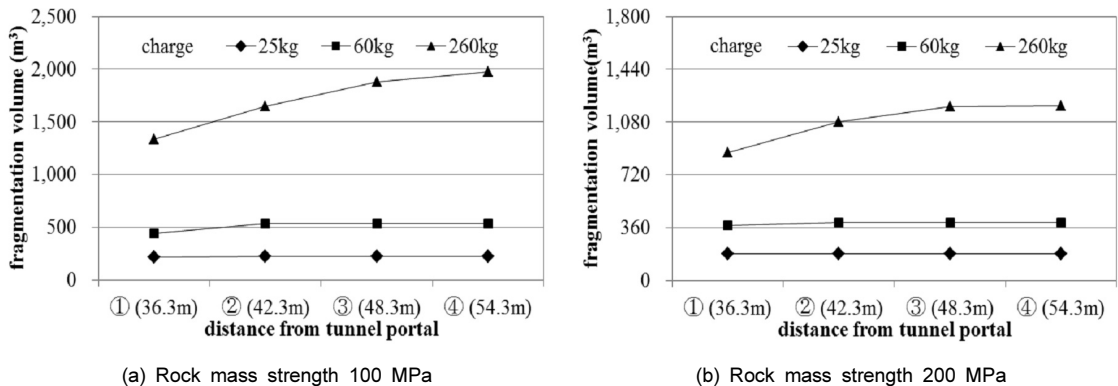


Fig. 7. Fragmentation volume vs. distance from tunnel portal as a function of charge (tunnel radius 7 m, distance form tunnel exca. surface ①(2 m), rotation angle from the tunnel C.L. 0°)




Fig. 8. An illustration of a blasting analysis result (side view)

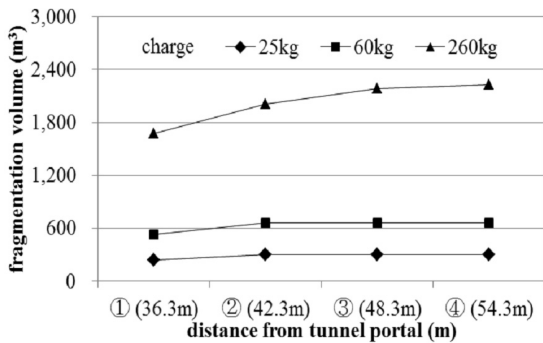
가까운 폭발위치를 ①, 굴진면에 일정한 간격으로 가까워지는 위치를 ②, ③, ④로 나타내었다. 그리고 굴착면과 가장 가까운 위치는 ㉠, 일정한 간격으로 멀어지는 위치는 ㉡, ㉢로 나타내었다.

Fig. 7(a)는 터널반지름이 7 m이고 암반강도가 100 MPa, 폭발위치가 굴착면으로부터 ㉡, 회전각도가 0°인 경우 터널갱구로부터의 거리에 따른 장약량별 파쇄부피이다. 폭발위치가 터널 갱구에서 멀어짐에 따라 파쇄부피가 증가하다가 수렴하였다. 25 kg의 경우 그림에는 나타나지 않지만 폭발위치가 ①에서 ②일 때까지 파쇄부피가 미소하게 증가하였다. 또한 장약량이 커질수록 파쇄부피의 변화폭이 커지고 수렴 위치가 터널 갱구에서 멀어지는 것으로 나타났다. 이는 Fig. 8과 같이 폭발위치가 터널 갱구에서 가까운 경우 파쇄영역(원으로 표시)의 일부 영역이 사면경계를 벗


어나게 되어 파쇄부피에 포함되지 않기 때문으로 판단된다. 그리고 폭발위치가 막장면에 가까워질수록 사면경계를 벗어나는 영역이 줄어들어 파쇄부피는 증가하다가 벗어나는 영역이 없게 되면 수렴하게 된다. 또한 장약량이 증가하게 되면 파쇄영역 또한 증가하게 되므로 파쇄량이 커지고 수렴되는 위치가 터널 갱구에서 멀어지게 된다.

Fig. 7(b)는 암반강도가 200 MPa인 경우 갱구로부터의 거리에 따른 장약량별 파쇄부피이다. 이 경우도 암반강도가 100 MPa인 경우와 비슷한 경향을 보인다. 하지만 암반강도가 높아짐에 따라 파쇄부피는 전체적으로 줄어든 것을 알 수 있다. 또한 파쇄부피의 수렴 위치가 터널 갱구에 가까운 위치로 나타났다. 이는 장약량은 같아도 암반강도가 높으면 파쇄영역이 작게만 들어져서 파쇄부피가 줄어들고 사면경계를 벗어나는 영역 또한 줄어들기 때문이다.

한편 Fig. 9(a)는 터널반지름이 2.5 m이고 암반강도가 100 MPa, 폭발위치가 굴착면으로부터 ㉡, 회전각도가 0°인 경우 터널갱구로부터의 거리에 따른 장약량별 파쇄부피이다. 터널갱구로부터의 거리에 따른 장약량별 파쇄부피가 터널반지름이 7 m인 경우와 동일한 경향을 보이지만 전체적으로 일정량의 파쇄부피가 증가한 것으로 나타났다. 이는 터널과 파쇄영역이 겹쳐지는 부분은 파쇄되는 암반이 존재하지 않기 때문에 파쇄부피로 포함되지 않는데, 터널의 크기가 작아



(a) Rock mass strength 100 MPa



(b) Rock mass strength 200 MPa


Fig. 9. Fragmentation volume vs. distance from tunnel portal as a function of charge (tunnel radius 2.5 m, distance from tunnel exca. surface ㉡(2 m), rotation angle from the tunnel C.L. 0°)

지게 되면 파쇄영역과 겹쳐지는 부분의 크기가 축소되어 파쇄부피로 포함되지 않는 부분이 감소함에 따라 전체적으로 증가한 것으로 판단된다. Fig. 9(b)는 암반강도가 200 MPa인 경우 갱구로부터의 거리에 따른 장약량별 파쇄부피이다. 이 경우 암반강도가 100 MPa인 경우와 비슷한 경향을 보인다.

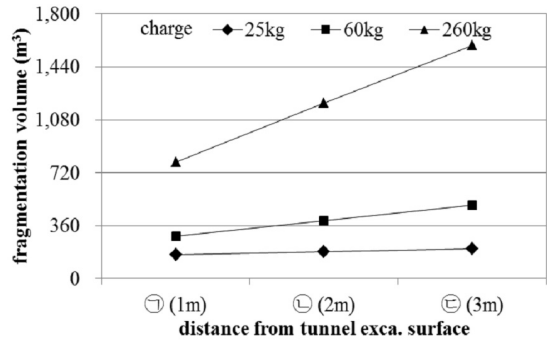
Fig. 10(a)는 터널반지름이 7 m이고 암반강도가 100 MPa, 폭발위치가 터널 갱구로부터 ④, 회전각도 0°인 경우 터널 굴착면으로부터의 거리에 따른 장약량별 파쇄부피이다. 폭발위치가 굴착면에서 멀어질수록 파쇄부피가 증가하는 것을 알 수 있다. 그리고 장약량이 증가할수록 파쇄부피의 변화폭 또한 증가하는 것으로 나타났다. 터널과 파쇄영역이 겹쳐지는 부분은

파쇄되는 암반이 존재하지 않기 때문에 파쇄부피로 포함되지 않는다. 이에 따라 폭발위치가 굴착면에서 멀어지게 되면 터널과 파쇄영역이 겹치는 부분이 줄어들어 파쇄부피는 증가한다. 또한 폭발위치가 본 연구에서 해석한 범위를 벗어난 위치까지 멀어져 겹치는 영역이 없어진다면 파쇄부피는 수렴될 것으로 판단된다. Fig. 10(b)는 암반강도가 200 MPa인 경우 터널 굴착면으로부터의 거리에 따른 장약량별 파쇄부피이다. 이 경우도 암반강도가 100 MPa인 경우와 비슷한 경향을 보인다. 하지만 암반강도가 높아짐에 따라 파쇄부피는 전체적으로 줄어든 것을 알 수 있다.

한편 터널반지름이 2.5 m인 경우 터널갱구로부터의 거리에 따른 장약량별 파쇄부피가 터널반지름이

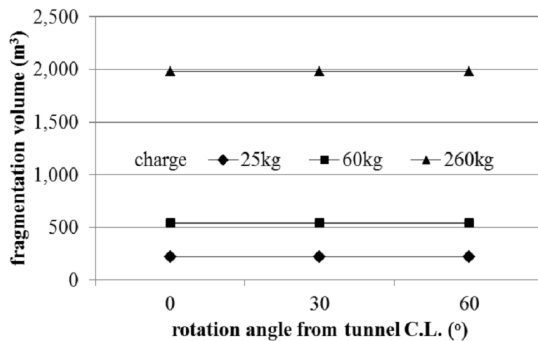


(a) Rock mass strength 100 MPa

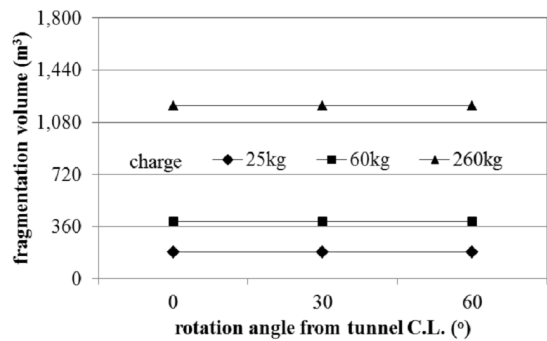


(b) Rock mass strength 200 MPa

Fig. 10. Fragmentation volume vs. distance from tunnel exca. surface as a function of charge (tunnel radius 7 m, distance from tunnel portal ④(54.3 m), rotation angle from the tunnel C.L. 0°)



(a) Rock mass strength 100 MPa



(b) Rock mass strength 200 MPa

Fig. 11. Fragmentation volume vs. rotation angle from the tunnel C.L. as a function of charge (tunnel radius 7 m, distance form portal ④(54.3 m), distance from exca. surface ㉠(2 m))

7 m인 경우와 동일한 경향을 보인다. 또한 전체적으로 일정량의 파쇄부피가 증가한 것을 확인하였다.

Fig. 11(a)는 터널반지름이 7 m이고 암반강도가 100 MPa, 폭발위치가 터널 갱구로부터 ④, 굴착면으로부터 ㉠에 위치한 경우 회전각도에 따른 장약량별 파쇄부피이다. 회전각도가 0°(천장부)에서 60°로 증가하면서 폭발위치가 이동하여도 파쇄부피는 일정하게 유지되어 변화가 없었다. 또한 장약량이 증가하면서 파쇄부피도 증가하는데 25 kg에서 60 kg으로 증가된 폭보다 60 kg에서 260 kg으로 증가된 폭이 크게 나타났다. Fig. 11(b)는 암반강도가 200 MPa인 경우 회전각도에 따른 장약량별 처리시간 파쇄부피이다. 암반강도가 100 MPa인 경우와 장약량별 경향이 동일하게 나타났다. 또한 암반강도가 증가됨에 따라 전체적인 파쇄부피는 감소하였음을 알 수 있다.

한편 터널반지름이 2.5 m인 경우 터널갱구로부터의 거리에 따른 장약량별 파쇄부피가 터널반지름이 7 m인 경우와 동일한 경향을 보인다. 또한 전체적으로 일정량의 파쇄부피가 증가한 것을 확인하였다.

5. 파쇄영역 예측을 위한 인공신경망 학습

본 논문에서 터널 주변에서 폭발이 일어날 경우 파쇄부피와 파쇄반지름을 빠르게 예측하고자 하였다. 이를 위해 AUTODYN 해석자료를 바탕으로 학습자료를 구축하여 인공신경망 학습을 실시하였다. 단, 학습 구조에 따라 학습결과가 상이하기 때문에 다양한 학습구조로 매개변수 연구를 실시하여 최적의 학습구조를 선정하였다. 그리고 최적의 학습구조로 예측된 파쇄부피와 파쇄반지름에 대하여 AUTODYN 해석결과와 비교해 검증하였다.

5.1 학습자료 구축

학습에 사용될 입력변수로는 터널반지름, 암반강도, 장약량, 폭발위치(x축, y축, z축) 등 6가지 변수를

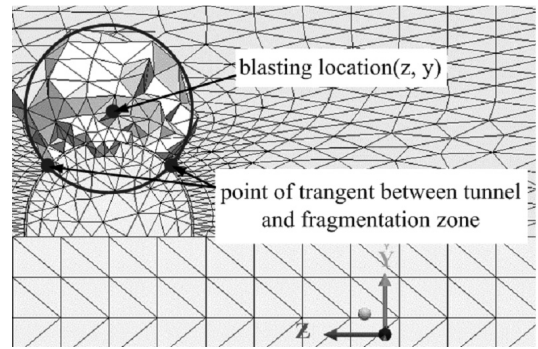


Fig. 12. An example for the estimation of a fragmentation zone radius

사용하였다. 그리고 출력변수는 해석결과에서 파쇄부피와 파쇄반지름을 사용하고자 하였다. 파쇄반지름은 AUTODYN에서 제공하지 않기 때문에 Fig. 12와 같이 결과로 출력된 화면에서 파쇄영역과 터널이 맞닿는 2개점의 위치와 폭발위치와의 거리를 각각 계산하여 평균값을 사용한다. 단, 파쇄영역은 구 형태라고 가정한다.

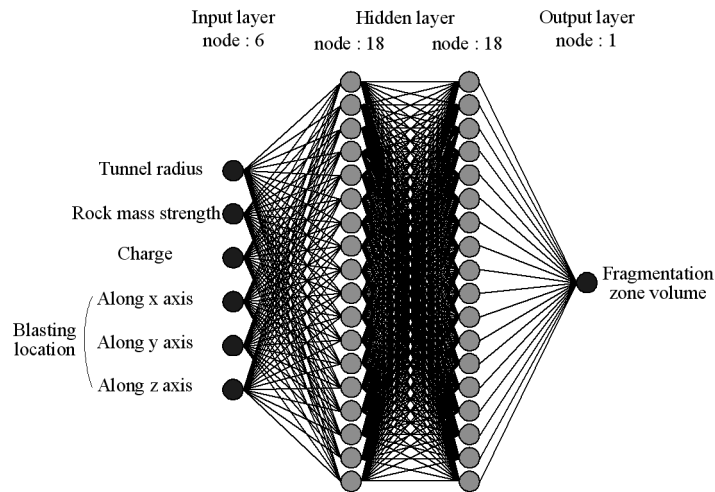
5.2 매개변수 연구를 통한 최적의 학습구조 선정

폭발변수와 해석결과로 구축한 학습자료를 이용해 인공신경망 학습이 가능한 MATLAB으로 학습을 실시하였다. 파쇄부피와 파쇄반지름을 동시에 출력자료로 구성하여 예비학습을 실시한 결과, 터널 갱구부 근처에서는 두 변수 사이의 상관성이 아주 낮게 나타나 학습성능이 크게 저하되는 것을 확인하였다. 따라서 파쇄부피와 파쇄반지름을 동시에 출력자료로 사용하기 보다는 각각 별도의 출력자료로 사용하여 학습을 실시하였다. 단, 인공신경망의 최대 학습횟수는 10,000번으로 제한하였고, 학습결과의 평균제곱오차(MSE, mean squared error), 결정계수(R^2)를 비교하여 적정성을 평가하였다.

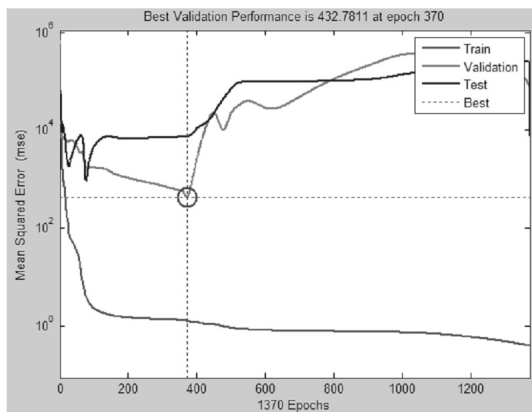
학습자료의 입력층은 6개의 노드, 출력층은 1개의 노드로 구성된다. 학습에는 LM (Levenberg-Marquardt) 알고리즘을 사용하였는데, 이 알고리즘은 은닉층과 노드 수에 따라 학습 능률 및 예측능력에 큰 차이를

Table 2. A result of parametric study


Model	Number of hidden layer	Node number of hidden layer			Number of cases	Fragmentation volume		Fragmentation zone radius	
		First	Second	Third		MSE	R^2	MSE	R^2
A-01 ~ A-08	2	6, 8, 10, 12, 14, 16, 18, 20		X	8 × 1 = 8	1925.90010 365808.08500 3003.96470 · · ·	0.99678 0.73074 0.96363 · · ·	0.02221 5.60880 0.00675 · · ·	0.99285 0.62005 0.99563 · · ·
A-09 ~ A-72	3	6, 8, 10, 12, 14, 16, 18, 20	6, 8, 10, 12, 14, 16, 18, 20		8 × 8 = 64	2354.83020 1041153.26500 527302.48050 · · ·	0.98172 0.13582 0.80733 · · ·	0.01366 0.01312 0.02985 · · ·	0.97173 0.99674 0.98625 · · ·



(a) Structure of model



(b) Mean squared error



(c) R^2

Fig. 13. A result and structure of A-09 model(6-18-18-1) which studied fragmentation volume

보인다. 따라서 최적의 학습모델을 선정하기 위하여 Table 2와 같이 은닉층 수 2가지(2, 3개), 노드 수 8가지(6, 8, 10, 12, 14, 16, 18, 20개)로 총 72(8 + 8 × 8)가지 경우에 대하여 매개변수 연구를 실시하였다. 단, 각 은닉층의 노드 수 입력 시 마지막 은닉층은 바로 전 은닉층 노드 수와 동일하게 적용된다. 예를 들어 은닉층 수가 2개인 A-05 모델의 각 층 노드 수는 입력층 6개, 1번째와 마지막 은닉층 각각 14개, 출력층 1개이다. 또한 은닉층 수 3개인 A-35 모델은 입력층 6개, 1번째 은닉층 12개, 2번째와 마지막 은닉층 각각 10개, 출력층 1개이다. 즉, A-05 모델은

‘6-14-14-1’, A-35 모델은 ‘6-12-10-10-1’의 구조를 가진다.

Table 2는 72가지 학습 구조에 대한 인공신경망 학습 결과의 평균제곱오차와 결정계수이다. 여기서 평균제곱오차는 학습 성능을 비교하는 수단으로 사용되는데, 평균제곱오차가 작은 값을 가지는 모델일수록 신뢰도가 높음을 의미하고, 결정계수는 1에 가까울수록 높은 적합성을 의미한다.

파쇄부피에 대한 매개변수연구 결과 A-07 모델이 최적의 학습모델로 선정되었다. 평균제곱오차와 결정계수는 Fig. 13과 같이 432.78110, 0.99783으로 나타


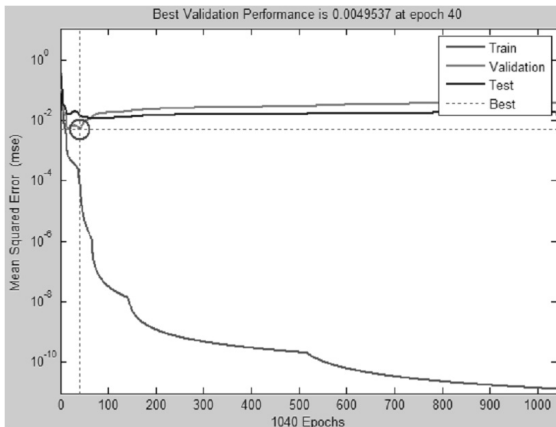



Fig. 14. A result and structure of A-41 model(6-14-6-6-1) which studied fragmentation zone radius

났다. 또한 2개의 은닉층으로 이루어져있고 1번째 은닉층 노드 수 18개, 마지막 은닉층 노드 수 18개이다.

파쇄반지름에 대한 매개변수연구 결과 A-41 모델이 최적의 학습모델로 선정되었다. 평균제곱오차와 결정계수는 Fig. 14와 같이 0.00495, 0.99792로 나타났다. 또한 3개의 은닉층으로 이루어져있고 1번째 은닉층 노드 수 14개, 2번째와 마지막 은닉층 노드 수 6개이다.

5.3 예측결과 검증

학습자료로 사용되었던 폭발변수를 입력변수로 하여 최적의 인공신경망 구조로 예측을 실시하고 기존의 해석결과와 비교하였다. 비교 결과 파쇄부피의 경우 평균 상대오차는 3.90%, 평균 절대오차는 21.56 m³으로 나타났고, 최대 상대오차는 24.35%, 최대 절대오차는 180.80 m³으로 나타났다. 최대 오차는 터널 반지름 7 m, 암반강도 200 MPa, 장약량 260 kg, 회전각도 60°, 폭발위치가 터널 갱구로부터 54.3 m, 굴착면으로부터 2 m 위치에서 발생되었다. 또한 파쇄반지름의 경우 평균 상대오차는 0.55%, 평균 절대오차는 0.03 m로 나타났고, 최대 상대오차는 11.24%, 최대 절대오차는 0.51 m로 나타났다. 최대 오차는 터널반지름 7 m, 암반강도 100 MPa, 장약량 60 kg, 회전각도 60°, 폭발위치가 터널 갱구로부터 54.3 m, 굴착면으로부터 2 m에 위치에서 발생되었다.

파쇄부피와 파쇄반지름에 대한 예측 결과에서 회전각도가 60°인 경우 최대 오차가 발생되었다. 그 이유로는 학습자료가 상대적으로 부족하여 회전각도가 60°인 경우에 학습 성능이 떨어진 것으로 판단된다. 회전각도가 0°, 30°인 경우는 각각 7가지 변수를 이용하여 학습을 실시하였지만 60°인 경우는 2가지 변수를 이용하여 학습을 실시하였다. 이에 따라 학습자료를 더 많이 갖추어야 인공신경망 학습 성능이 향상될 것으로 판단된다.

또한 파쇄반지름 예측결과 1 m 이내의 오차가 나타

났다. 이는 해석모델의 요소망 작성 시 터널 주변의 요소 간격을 약 1 m로 구성하였는데 폭발해석 후 반지름을 측정할 때 요소 간격에 따른 오차가 포함되어 학습결과에서도 포함된 것으로 판단된다. 이에 따라 오차를 줄이기 위해 해석모델의 요소망 작성 시 터널 주변의 요소 간격을 더욱 작게 구성하여 반지름 측정 시 포함되는 오차를 최대한 줄여야 할 것으로 판단된다. 하지만 요소의 간격을 작게 할 경우 폭발해석 결과는 더 정확해지지만 해석시간은 더 소요될 것으로 판단된다.

6. 결론

본 연구에서는 단일층으로 구성된 20° 경사를 이루는 암반사면 내에 반원형 터널을 대상으로 폭발해석을 실시하고 결과를 비교·분석하였다. 폭발변수와 해석결과를 학습자료로 구축하고 인공신경망 최적 학습 구조를 선정한 뒤, 예측된 결과에 대해 검증을 실시해 다음과 같은 결론을 도출하였다.

1. 터널 주변에서의 폭발에 따른 파쇄영역은 수치해석 민감도 분석 자료를 바탕으로 구성된 인공신경망 학습데이터베이스를 활용하여 빠르고 효과적으로 산정할 수 있음을 확인하였다.
2. 폭발위치가 터널 갱구와 굴착면에 가까울수록 파쇄부피가 감소하였다. 이는 파쇄영역에서 사면의 부로 벗어나거나 터널과 겹치는 영역은 파쇄되는 암반이 존재하지 않아 실제 파쇄부피에 포함되지 않기 때문인 것으로 판단된다. 또한 터널크기가 작아질 경우 터널과 겹치는 영역의 크기가 감소하여 파쇄부피는 증가하는 것으로 판단된다. 그리고 암반강도가 감소하고 장약량이 증가할수록 파쇄부피가 증가하는 것을 확인하였다.
3. 파쇄부피에 대한 매개변수연구 결과 6-18-18-1 구조의 모델이 최적의 학습모델로 선정되었고, 파쇄반지름의 경우 6-14-6-1 구조의 모델이 선정되었

다. 또한 검증을 실시한 결과, 파쇄부피와 파쇄반지름 모두 장약량은 다르지만 회전각도가 60°인 경우 최대 오차가 나타났다. 원인으로는 다른 회전각도에 비하여 학습자료가 상대적으로 부족하여 성능이 떨어진 것으로 판단된다.

본 연구의 학습자료의 부족으로 인하여 발생한 오차에 대하여 자료의 양을 늘려 인공신경망 학습성을 높여야 할 것으로 판단된다. 또한 파쇄반지름 예측 결과에 대하여 검증하였을 때 1 m 이내의 오차가 나타났는데, 이는 해석모델의 터널 주변 요소 간격이 약 1 m로 구성되어 있어 파쇄반지름 측정 시 포함된 오차가 예측결과에도 포함된 것으로 판단된다. 이에 따라 요소 크기에 의한 오차가 발생됨에 따라 모델의 요소 크기를 축소시켜 해석시간은 더 소요되지만 결과에 포함되는 오차를 최대한 줄일 수 있을 것으로 기대된다.

감사의 글

본 연구는 국방과학연구소의 지원(UD100060AD)을 일부 받아 이루어진 결과로 관계자 분들에게 감사드립니다.

참고문헌

- Ahn, M.S., Ryu C.H., Park, J.N., Kwun J.A. (2001), "A study on the safe blast design to increase slope stability", The Journal of Korea Society for Explosives and Blasting Engineering, Vol. 19, No. 1, pp. 85-92.
- ANSYS, Inc. (2010), *ANSYS AUTODYN*, Ver. 13, ANSYS Inc., USA.
- Cho, J.W., Yu, S.H., Jeon, S.W., Chang, S.H. (2008), "Numerical study on rock fragmentation by TBM disc cutter", Journal of Korea Tunnelling Association, Vol. 10, No. 2, pp. 139-152.
- Konya, C.J., Walter, E.J. (1991), *Rock blasting and overbreak control*, National Highway Institute, p. 430.
- Math Works Inc. (2010), *MATLAB : Neural Network Toolbox™ User's Guide*, Ver. R2011b, Math Works Inc., p. 404.
- Pao, Y. (1989), *Adaptive pattern recognition and neural networks*, Addison - Wesley, p. 309.
- Park, J.W. (2012), *Analysis of structure subjected to blast load using parallel and domain*, Master Thesis, Hanyang University, p. 50
- Riedel, W., Thoma, K., Hiermaier, S., Schmolinske, E. (1999), "Penetration of reinforced concrete by BETAB-500 numerical analysis using a new macroscopic concrete model for hydrocodes" The 9th Int. Sym. Interaction of the Effects of Munitions with Structures, Berlin, Germany, pp. 315-322.
- Shin, H.S., Kwon, Y.C. (2009), "Development of a window-shifting ANN training method for a quantitative rock classification in unsampled rock zone", Journal of Korea Tunnelling Association, Vol. 11, No. 2, pp. 151-162.
- SolidWorks Corp. (2011), *SolidWorks 3D*, Ver. 2011, SolidWorks Corp, Massachusetts, USA.
- Wasserman, P.D. (1989), *Neural computing : Theory and practice*, Van Nostrand Reinhold Co., New York, USA, p. 230.
- You, K.H., Kim, D.H. (2012), "A study on the influence of blasting location on tunnel fragmentation zone", 2012 Korean Geotechnical Society, Geo Expo, pp. 1611-1615.
- You, K.H., Son, M.K. (2013), "Hauling time prediction of the muck generated by a blasting around a tunnel", Journal of Korean Tunnelling and Underground Space Association, Vol. 15, No. 1, pp. 33-47.
- You, K.H., Song, W.Y. (2012), "A case study on a tunnel back analysis to minimize the uncertainty of ground properties based on artificial neural network", Journal of Korean Tunnelling and Underground Space Association, Vol. 14, No. 1, pp. 37-53.