

인공신경망 기법과 굴진면 관찰자료를 활용한 터널 역해석 연구

유광호^{1*}, 김경석²

A tunnel back analysis using artificial neural network technique and face mapping data

Kwang-Ho You, Kyoung-Seok Kim

ABSTRACT Considerable uncertainties are included in ground properties used for tunnel designs due to the limited investigation and tests. In this study, a back analysis was performed to find optimal ground properties based on artificial neural network using both face mapping data and convergence measurement data. First of all, the rock class of a study tunnel is determined from face mapping data. Then the possible ranges of ground properties were selected for each rock class through a literature review on the previous studies and utilized to establish more precise learning data. To find an optimal training model, a sensitivity analysis was also conducted by varying the number of hidden layers and the number of nodes more minutely than the previous study. As a result of this study, more accurate ground properties could be obtained. Therefore it was confirmed that the accuracy of the results could be increased by making use of not only convergence measurement data but also face mapping data in tunnel back analyses using artificial neural network. In future, it is expected that the methodology suggested in this study can be used to estimate ground properties more precisely.

Keywords: Back analysis, artificial neural network, ground property, rock class, face mapping data

요약 터널 설계 시 사용되는 지반물성치는 한정적인 조사 및 시험을 통해 산정되기 때문에 불확실성을 내포한다. 본 연구에서는 최적의 지반물성치를 찾기 위해 터널의 굴진면 관찰자료와 계측자료를 활용하여 인공신경망을 이용한 역해석을 수행하였다. 우선 굴진면 관찰자료를 이용하여 연구대상 터널의 암반등급이 선정되었다. 기존연구에 대한 문헌고찰을 통해서 암반등급별로 지반물성치의 가능한 범위를 지정하여 보다 정확한 학습자료 구축을 위해 활용되었다. 또한 최적의 학습모델을 찾기 위해 은닉층 수와 각 은닉층의 노드 수를 기존연구보다 세분하여 변화시켜가며 매개변수 연구를 수행하였다. 연구결과, 기존 연구와 비교했을 때, 보다 정확한 지반물성치를 얻을 수 있었다. 따라서 계측자료 뿐만 아니라 굴진면 관찰자료를 인공신경망을 이용한 역해석에 활용하면 결과의 정확성을 높일 수 있음을 확인하였다. 향후 본 연구에서 제시된 방법론을 사용하여 지반물성치를 보다 정확하게 추정할 수 있을 것으로 기대된다.

주요어: 역해석, 인공신경망, 지반물성치, 암반등급, 굴진면 관찰자료

접수일(2012.07.05), 수정일(2012.07.13), 게재확정일(2012.07.17)

¹수원대학교 토목공학과 교수

²수원대학교 토목공학과 박사과정

*교신저자: 유광호 (E-mail: khyou@suwon.ac.kr)

1. 서론

현대사회에서 터널 및 지하공간 개발은 고도의 산업발달과 도시의 인구집중으로 인해 한계에 도달한 지상공간 개발의 대안으로 제시되어 활발히 진행되고 있으며, 향후 지하공간의 활용에 대한 중요성은 더욱 커지고 있다. 특히 터널과 같은 지하구조물은 장기간의 공기와 막대한 비용이 소요되며, 많은 사람들이 이용하는 구조물로서 안정성이 확보되어야 한다. 따라서 터널을 설계하고 시공하는 데에 있어 터널 거동을 보다 합리적이고 현실적으로 해석하여 안정성을 확보하는 것이 중요하다.

이를 위해 수치해석기법이 이용되고 있지만 해석에 사용되는 지반물성치는 한정적인 조사 및 시험을 통해 산정된다. 이러한 지반물성치에는 많은 불확실성이 포함되어 터널 굴착으로 인한 터널 및 주변 지반의 안정성 및 거동특성을 정확히 평가하기에는 어려움이 많은 실정이다. 현재 불확실성을 줄이기 위해 계측자료를 활용한 역해석 기법(유광호와 송원영, 2012; 송원영, 2012 등)이 연구되고 있다.

김문겸과 장정범(1995)은 실제 현장계측자료를 이용하여 지반의 탄성계수와 정지토압계수를 추정하는 역해석 프로그램을 직접법에 근거하여 개발하였다. 개발된 역해석 프로그램은 타 역해석 프로그램 결과 및 시추조사자료, 실내 및 현장실험 결과 등과 비교·분석하였다.

신후성과 권영철(2009)은 탄성역전파(resilient back-propagation) 학습알고리즘 인공신경망 기법을 활용하여 터널 설계 시 미시추 구간의 지반 등급 분류를 산정하는 기법을 제안하였다. 실제 터널 현장 시추조사 자료를 사용하여, 전통적인 지구통계학적 크리깅(kriging)기법에 의해 얻은 결과와 비교·분석하였다.

김종규(2011)는 지층 물성치에 포함된 불확실성을 줄이기 위해 인공신경망을 이용한 역해석을 실시하였다. 인공신경망의 학습자료를 구축하기 위해 탄성계수와 측압계수를 사용하였으며, 최적의 인공신경망 모델을 이용하여 최적의 물성치인 탄성계수와 측압계수를 찾을 수 있었다.

유광호와 송원영(2012)은 최적의 지반물성치를 찾기 위해 터널 계측자료를 활용하여 MATLAB 프로그램의 인공신경망 분석 기능을 이용한 역해석을 수행하였다. 탄성계수와 측압계수를 입력변수로 사용하여 학습자료를 구축하였으며, 학습을 위해 GDM(Gradient Descent with Momentum) 알고리즘 기반의 최적인공신경망 모델을 이용하여 지층의 탄성계수와 측압계수를 추정하였다.

송원영(2012)은 실제 현장을 대상으로 내공변위에 직접적인 영향을 주는 암반의 탄성계수와 점착력, 측압계수를 LM(Levenberg-Marquardt) 알고리즘 이용한 인공신경망 기반의 역해석을 통해 산정하였다. 학습자료 구축을 위해 은닉층 수를 3개, 6가지의 노드 수를 층별로 동일하게 하여 총 18개의 매개변수 연구를 실시하고 최적의 인공신경망 구조를 찾아내었다. 최적의 구조로 학습된 결과를 FLAC에 입력하여 역해석 결과와 비교하였다.

하지만 김종규(2011), 유광호와 송원영(2012), 송원영(2012)이 수행한 기존연구에서는 모두 공통적으로 학습자료 구축 시 탄성계수와 점착력을 실시설계 시 사용된 지반물성치를 임의의 비율로 감소시켜 적용하였다. 또한 매개변수 연구 시 각 은닉층별 노드 수를 같게 하여 충분한 매개변수 연구가 수행되지 못했으며, 추정된 지반물성치는 학습자료 구축 시 사용된 물성치의 범위를 벗어나 신뢰성이 떨어진다는 문제점이 있었다.

본 연구에서는 기존연구의 이러한 문제점을 보완하기 위해 굴진면 관찰자료를 활용하여 암반등급을 추정하고, 이를 바탕으로 인공신경망의 학습자료를 구축하였다. 또한 각층의 탄성계수, 점착력 및 측압계수를 기존연구보다 훨씬 세분화시켰고, 은닉층 수를 4개로 증가시켰으며, 각 은닉층별 노드 수를 달리하여 총 258가지의 보다 다양한 매개변수 연구를 실시하였다. 한편 Itasca Consulting Group Inc.에서 개발한 지반해석용 프로그램 FLAC-2D ver 5.0이 학습자료 구축을 위한 수치해석에 사용되었고, MATLAB 프로그램(Math Works Inc., 2010)이 인공신경망 해석을 위해 사용되었다. 이때 학습을 위해 LM 알고리즘이 사용되었으며, 최적의 지반물성치를 추정한 결과 인공신경망 입력변수 범위 내의 결과를 얻어 신뢰성이 높은 것으로 판단할 수 있었다.

2. 인공신경망을 활용한 역해석


2.1 역해석 개요

일반적으로 역해석(back analysis)은 정해석(forward analysis)의 수치해석결과가 계측결과에 근접하도록 수치해석 모형의 미지 변수를 정의하는 해석과정을 의미한다. 현재까지의 역해석 방법으로는 해석적 방법과 수치해석적 방법을 이용한 직접법(direct method)과 역산법(inverse method)이 많이 사용되고 있고, 그 외 시행착오법(trial and error method)이 사용되기도 한다.


직접법은 계측결과와 해석결과를 비교하여 그 차이가 최소화될 때까지 수치해석 과정의 반복연산을 통하여 자동으로 역해석 대상인 미지 매개변수를 수정하는 방법이다. 역산법은 일반적인 응력해석 방법의 역으로, 응력해석에서의 미지수인 변위나 응력을 입력 값으로 하여 암반의 탄성계수 및 측압계수를 구하는 방법이다. 시행착오법은 역해석 기법의 가장 기본적인 접근방법으로 정해석 결과인 변위와 응력 등을 그에 대응하는 계측결과와 상호 비교를 한다.

2.2 인공신경망 이론

인공신경망이란 인간의 신경조직을 모델로 하여 간단한 기능의 처리기 사이를 서로 대규모로 연결시킨 네트워크 형태의 정보처리 구조이다. 인공신경망의 구조는 생물학적 신경조직의 기본 단위는 뉴런(neuron)이며 인간의 뇌는 다수의 뉴런들이 서로 연결된 신경회로망으로 이루어져있다.



(a) 생물학적 신경



(b) 인공신경

그림 1. 생물학적 신경과 인공신경(after Wasserman, 1989)

각 뉴런은 그림 1(a)와 같이 세포체(cell body)로 이루어진 중심부와 축삭돌기(axon), 수상돌기(dendrite)로 이루어진 신경섬유로 구성되고, 뉴런 상호간 또는 뉴런과 다른 세포는 시냅스(synapse)로 연결되어 있다(Wasserman, 1989). 이러한 뉴런의 생물학적 특성을 기반으로 그림 1(b)와 같은 인공신경망 모델을 구현할 수 있다. 인공신경망에서 가장 중요한 고려사항은 뉴런의 역할을 수행하는 처리기와 활성화함수(activation function)이며 시냅스는 강도를 조정할 수 있는 연결선으로 구성된다.

2.3 다층 퍼셉트론

인공신경망은 신경망을 구성하는 뉴런의 종류와 연결 형태, 그리고 연결링크에 가중치를 부여하는 방식 등에 따라 여러 유형으로 나뉜다. 본 연구에서는 역전파 학습 알고리즘을 이용하는 다층 퍼셉트론을 이용하였다.




그림 2. 다층퍼셉트론의 구조

다층 퍼셉트론은 인공신경망의 일종으로서 역전파(back-propagation) 신경망이라고도 하며, 입력층(input layer)과 출력층(output layer) 사이에 하나 이상의 중간층이 존재하는 인공신경망 모델로 그림 2와 같은 층상구조를 갖는다. 이 때, 입력층과 출력층 사이의 중간층을 은닉층(hidden layer)이라 하며 네트워크는 입력층, 은닉층, 출력층 방향으로 연결된 전방향(feed forward) 네트워크이다.

다층 퍼셉트론에서 신호의 종류는 함수신호와 오차신호가 있으며, 함수신호는 입력층에서 시작되어 은닉층을 거쳐 출력층으로 전파된다. 반면, 오차신호는 출력층에서 시작되어 각 층으로 역방향 전파된다. 즉, 입력층의 뉴런이 외부의 입력신호를 받아들여 은닉층으로 보내면 은닉층과 출력층은 이 신호를 받아 입력신호 및 가중치의 비선형 활성화함수를 이용해 함수신호를 계산하여 각 뉴런의 출력신호를 생성하고, 학습 알고리즘의 역전파 단계에서 필요한 순간오차를 계산한다.

대부분의 다층 퍼셉트론의 학습은 역전파 학습 알고리즘을 사용하여 수행할 수 있다. 본 연구에서 사용한 MATLAB 프로그램(Math Works Inc., 2010)은 GD(Gradient Descent), GDM(Gradient Descent with Momentum), GDA(Gradient Descent with adaptive learning rate), LM(Levenberg-Marquardt) 등과 같은 다양한 학습 알고리즘을 주어진 문제에 따라 선택할 수 있으며, 각 알고리즘에서 요구하는 학습 파라미터를 쉽게 설정하여 학습에 반영할 수 있다. 특히 LM 알고리즘은 비선형 함수들의 제곱의 합과 최소화 함수로 만들어진 Newton 방법을 변형한 것이며, 인공신경망 학습에 매우 잘 맞는 것으로 알려져 있다(강승온, 2009). 이 알고리즘은 주어진 입력에 대해 원하는 출력결과를 학습시키고자 할 때 사용하며, 출력층의 각 뉴런에서 발생된 출력오차를 역으로 전파시켜 나가면서 연결링크의 가중치 수정을 통해 오차(error)를 최소화 시킨다. 오차는 목표값과 인공신경망 학습 결과와의 차이를 나타내며, error와 MSE는 식 (1)과 식 (2)로 정의된다.

$$error = \sum_{i=1}^N (O_i - T_i)^2 \quad (1)$$

$$MSE = \frac{\sum_{i=1}^N (O_i - T_i)^2}{N} \quad (2)$$

여기서 T_i 와 O_i 는 각각 학습에 사용된 목표 출력과 인공신경망에 의해 학습된 출력을 의미하며, N 은 입출력 자료의 수를 나타낸다.

3. 연구 대상터널의 수치해석 및 계측변위

3.1 대상터널 개요

본 연구의 대상 터널은 호남고속철도 제 〇〇공구 현장 내에 시공 중인 충남 공주시에 위치하고 있는 9.16 km의 장대터널로서 계룡산을 관통하는 산악터널이다. 역해석 대상 지점인 STA. 36K+990 이 포함되는 사업지구 전구간의 평면도는 그림 3에 나타내었으며 대상 터널은 굴착 시점부인 갱구부에 해당된다(대우건설, 2009).

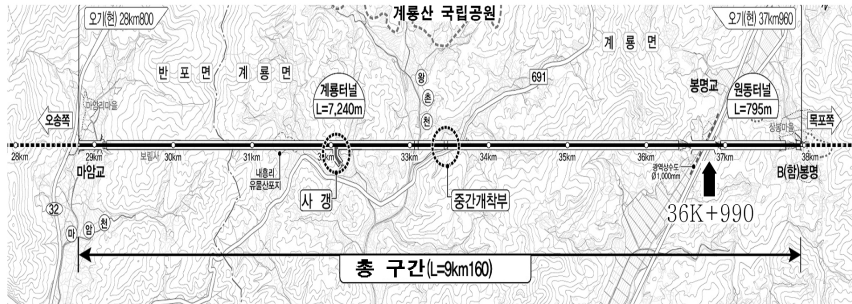


그림 3. 노선의 평면도

3.2 설계를 위한 수치해석 모델링

연구대상 터널지점(STA. 36K+990)의 지층은 그림 4와 같이 좌·우 비대칭 형상이며 3개의 지층(상층, 중층, 하층)으로 형성되어있다. 설계 시 정확한 해석을 위해 터널 넓이의 좌·우측, 하부 경계를 4.0D 이상으로 하였고, 해석영역은 터널의 중심부를 기준으로 좌·우 각각 약 65 m로 하였다. 좌·우 측면경계는 수평방향 변위를 구속하고 하부경계는 수직방향을 구속하도록 경계조건을 설정하였다. 해석터널은 상층과 중층 암반에 걸쳐 있으며, 강관다단 그라우팅은 하층 암반에 위치한다. 또한 지반조사 및 실내시험에 의해 상층은 3등급, 중층은 2등급, 하층은 1등급으로 가정하였으며, 숏크리트는 무지보-연성 숏크리트-경성 숏크리트 타설 단계별로 하중분담율을 40% - 40% - 20%로 적용하여 해석하였다.




그림 4. 대상단면 및 해석영역




그림 5. 해석 요소망 및 경계 조건

그림 5는 단면의 해석 요소 및 경계 조건을 나타낸 것이다. 해석 요소망에서 터널을 중심으로 가까운 쪽은 요소망을 촘촘하게 하였다. 그리고 효율적인 해석시간을 위하여 터널의 가까운 부분에서 바깥쪽으로 갈수록 요소망을 느슨하게 적용하였다.

해석에 사용된 지반의 물성치를 표 1에 나타냈으며, 실시설계에서는 측압계수가 1.0, 1.5, 2.0, 2.5로 구분하여 적용되었다. 한편 송기일과 조계춘(2006)이 제시한 보강영역의 등가 물성치 결정방법에 따라 강관다단 그라우팅 보강영역의 탄성계수는 원암반인 상층 암반(3등급)의 3배인 27 GPa로 적용하였다.

표 1. 해석에 사용한 지반물성치(대우건설, 2009)

구 분	단위중량 (KN/m ³)	점착력 (KPa)	내부마찰각 (°)	탄성계수 (GPa)	포아송비
3등급(상층)	25.0	1,600	42.0	9	0.25
2등급(중층)	26.0	2,600	44.0	20	0.22
1등급(하층)	27.0	3,500	48.0	28	0.20
강관다단 그라우팅	25.0	1,600	42.0	27	0.25

터널 굴착 시 거동을 알아보기 위하여 해석에 사용된 실제 지반물성치인 표 1을 사용하였다. 수치해석을 수행하기 위하여 지반해석용 프로그램 FLAC-2D ver 5.0을 이용하였으며, 표 2는 측압계수 1.0, 1.5, 2.0, 2.5에 따라 나타나는 상·하반 천단 변위 및 내공변위를 나타낸 것이다. 변위를 비교해 보면 측압계수가 2.5일 때 하반 내공변위가 1.10 mm로 나타난 것을 제외하고는 변위 모두 1.0 mm 이내로 나타나 터널 굴착 시 변위가 거의 발생하지 않는 것으로 나타났다.

표 2. 측압계수에 따른 변위비교(대우건설, 2009)

(단위: mm)

측압계수	상반 천단침하	상반 내공변위	하반 천단침하	하반 내공변위
1.0	0.22	0.05	0.18	0.33
1.5	0.17	0.08	0.10	0.58
2.0	0.12	0.13	0.03	0.84
2.5	0.07	0.21	0.05	1.10

3.3 설계 시 예측변위와 계측변위의 비교

터널에서 굴진에 의해 발생하는 변위는 터널의 주변 지반 상태, 굴착 방법, 보강방법 등 다양한 변수의 영향을 받기 때문에 예측하기 매우 어렵다. 터널에서 일반적으로 사용되는 계측기기는 1차 슛크리트가 타설된 후 굴진면에 근접하여 설치된다. 터널의 총변위는 굴진면 굴착 이전의 변위인 초기변위, 굴착 후 계측기 설치 전까지 발생하는 변위 및 계측기 설치 후 측정되는 계측변위를 합한 변위이다. 일반적으로 선행변위는 총변위의 30~40%에 해당되는 것으로 알려져 있다(김주화 등, 2008). 한편 총변위에 대한 선행변위의 비율은 지반조건이나 터널조건 등에 따라 매우 크게 달라질 수 있으므로, 본 논문에서는 단순히 계측변위의 30%를 선행변위로 가정하였다.

현장에서 측정기(total station)를 이용한 계측결과를 표 3에 나타내었다. 표 3에서 보이는 바와 같이 계측된 상반 천단변위는 4.0 mm이며, 선행변위는 계측변위의 30%로 가정한 1.2 mm이다. 나머지 계측변위 역시 이와 같은 방법으로 구하면 상반 총 천단변위는 5.2 mm, 상반 총 내공변위는 1.3 mm, 하반 총 천단변위는 13 mm, 하반 총 내공변위는 6.5 mm로 나타난다.

총 변위는 계측변위로부터 선행변위를 예측하고 계산하여 구한 값이다. 굴착 이전에 발생하는 선행변위와 굴착 후에 발생하는 계측변위를 합한 총 변위로 구성되며, 일반적으로 계측을 통해 측정된 변위는 총 변위보다 작게 나타난다. 선행변위를 포함한 총 변위와 실시설계 시 계산변위인 표 2와 비교해본 결과 최소 5.0 mm에서 10 mm 이상까지 변위 차이가 나타나므로 실시설계 시 예측된 변위가 계측변위와 많은 차이가 있음을 알 수 있다.

이와 같은 변위 차이는 추정된 암반등급은 물론 수치해석에 사용되는 지반물성치가 한정된 시추조사나 물리탐사 등에 의해 산정되므로 많은 불확실성(uncertainty)을 포함하기 때문이다. 따라서 해석결과의 신뢰도가 떨어지고, 궁극적으로 지보패턴도 과소 또는 과다 보강 설계될 수 있다. 지반물성치의 불확실성을 줄이기 위해 내공변위 계측자료를 활용한 역해석 기법 등을 사용하는 것이 필요하다.

표 3. 선행변위를 고려한 천단·내공변위 (단위: mm)

구 분		천단변위/선행변위	내공변위/선행변위
상반 굴착 후	계측변위	4.0 / 1.2	1.0 / 0.3
	총 변위	5.2	1.3
하반 굴착 후	계측변위	10 / 3.0	5.0 / 1.5
	총 변위	13	6.5

4. 지반물성치 산정을 위한 역해석

4.1 암반등급을 고려한 학습자료 구축

인공신경망을 이용한 역해석을 수행하기 위해서는 학습자료 구축이 필요하다. 본 연구에서는 학습자료 구축을 위하여 Itasca Consulting Group Inc.에서 개발한 지반해석용 프로그램 FLAC-2D ver 5.0을 사용하여 수치해석을 수행하였다. 해석단면 및 영역은 실시설계 시 사용되었던 것을 동일하게 사용하였다. 한편 굴진면 관찰자료를 이용하여 암반등급을 산정하였다. 이를 근거로 지반물성치의 가능한 범위를 결정하고, 가능한 경우의 수를 조합하였다. 조합된 모든 경우에 대하여 학습자료 구축을 위한 수치해석을 실시하였다. 이 때 인공신경망에 선택된 입력변수로는 터널 거동에 영향을 미치는 지반정수인 각 층(상층, 중층, 하층)의 탄성계수와 점착력, 측압계수를 사용하였다. 출력변수는 터널 상·하반 분할 굴착 시, 상반굴착으로 인해 발생하는 천단변위 및 내공변위와 하반굴착 후 발생하는 천단변위 및 내공변위를 사용하였다.

4.1.1 암반등급 선정

터널굴착 시 매 굴진면에서 발파 및 버력처리 후 굴진면 관찰 기술자가 그림 6과 같이 수작업에 의하여 대표적인 암반분류법인 RMR 분류법을 통해 암반등급을 평가한다. 본 연구에서는 기존연구와 달리 암반등급을 고려한 인공신경망 학습자료를 구축하기 위하여 굴진면 관찰자료를 이용하였다.

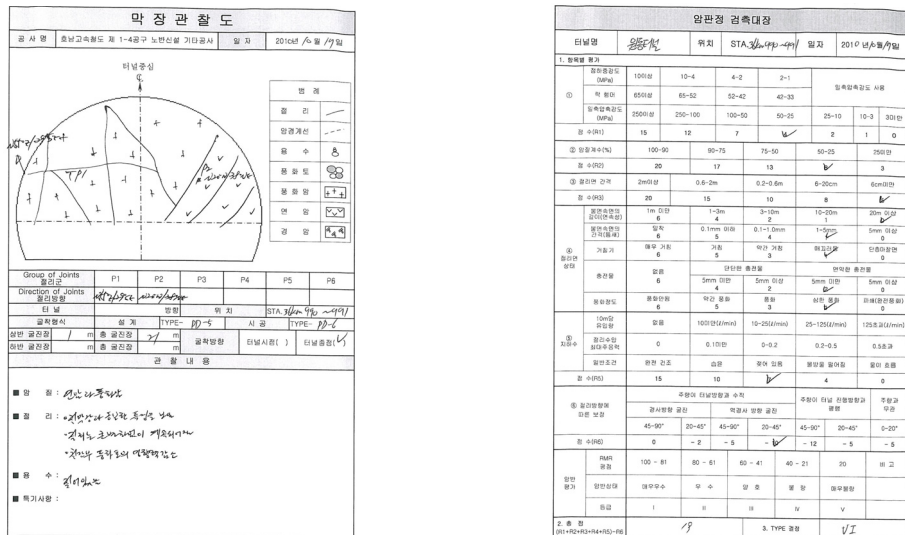


그림 6. 대상지점의 굴진면 관찰자료

역해석 대상 지점인 STA. 36K+990의 굴진면 관찰자료는 그림 6과 같으며, RMR 분류값이 19점으로 이 지점의 암반상태는 5등급에 해당된다. 다만 이 지점에서 터널이 중층과 상층 경계부에 위치하므로 중층과 상층의 암반등급은 5등급으로 가정하였다. 한편 터널 하부에 위치한 하층은 시추자료가 없기 때문에 암반등급을 평가하는 것은 불가능하다. 일반적으로 심도가 깊어질수록 암반등급이 좋아지기 때문에 5등급인 굴진면의 암반등급 보다 1등급 좋을 것으로 판단하여 4등급으로 가정하였다.

4.1.2 학습자료 구축

실시설계 시 사용된 지반물성치를 임의로 감소시켜 학습자료를 구축했던 기존연구와 달리 굴진면 관찰자료를 이용하여 암반등급을 산정하였다. 이를 근거로 지반물성치의 가능한 범위를 먼저 선정하고, 그 범위 내에서 조합 가능한 경우의 수를 고려하여 학습자료를 구축하였다. 우선, 문헌고찰을 통해 기존에 사용된 암반등급별 탄성계수와 점착력 값을 표 4와 같이 조사하였다. 표 4에서 보는 바와 같이 기존연구에서는 5등급의 탄성계수는 0.30~5.85 GPa, 점착력은 0.03~0.14 MPa 범위의 값이 사용되었다. 또한 4등급의 탄성계수는 1.00~13.01 GPa, 점착력 0.10~1.12 MPa 사이의 값이 사용되었다.

표 4의 탄성계수와 점착력 값을 이용하여 암반등급별 가능한 범위를 구했다. 이 때 너무 크거나 작은 값은 제외시켰다. 또한 각 등급별로 지반물성치의 범위가 중복되는 경우 등급의 경계값은 비례적인 조정을 통해 표 5와 같이 선정하였다. 수정된 각 물성치들의 가능한 범위는 4등급 및 5등급의 경우는 표 5의 음영된 부분과 같이, 각각 탄성계수는 1.90~5.50 GPa과 0.30~1.90 GPa이며, 점착력은 0.12~0.37 MPa과 0.05~0.12 MPa이다.

표 4. 기존연구에 사용되었던 등급별 탄성계수와 점착력

사 례	탄성계수 (GPa)					점착력 (MPa)				
	5등급	4등급	3등급	2등급	1등급	5등급	4등급	3등급	2등급	1등급
허재록(2001)	1.0	3.16	10.00	40.00	80.00	0.041	1.12	3.05	8.30	22.5
한국도로공사 도로교통기술원 (2002)	5.85	13.01	19.13	29.24	34.12	0.05	0.1	0.25	0.50	1.00
	2.80	6.04	13.01	28.02	34.12	0.05	0.1	0.25	0.50	1.00
박종원(2003)	1.59	3.42	7.37	15.87	34.20	0.05	0.1	0.25	0.50	1.00
서영욱(2003)	1.59	3.42	7.37	15.87	34.20	0.05	0.1	0.25	0.50	1.00
박연준 등(2004)	2.80	6.04	13.01	28.02	34.12	0.05	0.1	0.25	0.50	1.00
강창민(2009)	0.30	1.00	5.00	10.00	20.00	0.03	0.03	0.3	0.90	1.50
권순섭(2009)	0.33	1.40	5.40	9.70	19.50	0.14	0.5	1.7	3.8	6.70
박춘식(2010)	0.30	1.0	8.00	12.00	20.00	0.03	0.03	0.15	0.80	2.00
유일형(2011)	1.40	3.00	6.50	14.00	17.00	0.05	0.2	0.6	2.00	3.00

표 5. 암반등급별 지반물성치 범위

암반등급	탄성계수(GPa)	점착력(MPa)
1등급	23.00~34.00	2.40~6.70
2등급	11.00~23.00	1.10~2.40
3등급	5.50~11.00	0.37~1.10
4등급	1.90~5.50	0.12~0.37
5등급	0.30~1.90	0.05~0.12

본 연구와 동일하게 지층별 탄성계수 및 점착력과 측압계수가 학습자료의 변수로 사용되었던 유일한 기존연구인 송원영(2012)과의 비교가 표 6에 정리되었다. 표 6에서 보는 바와 같이 송원영(2012)은 실시 설계 시 사용된 각 지층의 탄성계수와 점착력을 지층에 상관없이 2가지의 같은 비율로만 감소시켜 총 192개(=2⁶ × 3)의 학습자료를 구축하였다. 반면 본 연구에서는 암반등급에 따라 지반물성치의 가능한 범위 내에서 각 층별로 탄성계수와 점착력, 측압계수를 각각 3가지의 다른 비율로 감소시켜 총 2,187개(=3⁷)의 학습자료를 구축하였다. 표 6에서 괄호안의 숫자는 실시 설계 시 사용된 값에 대한 비율을 의미한다.

표 6. 학습자료 구축을 위한 층별 지반물성치 비교

지층	추정 암반 등급	본 연구			기존연구(송원영, 2012)		
		탄성계수 (GPa)	점착력 (MPa)	측압계수	탄성계수 (GPa)	점착력 (MPa)	측압계수
상층	5등급	1.800(1/5)	0.107(1/15)	0.5	0.900(1/10)	0.800(1/5)	0.5
		0.900(1/10)	0.080(1/20)		0.225(1/40)	0.160(1/10)	
		0.300(1/30)	0.053(1/30)				
중층	5등급	2.000(1/10)	0.130(1/20)	0.75	2.000(1/10)	0.520(1/5)	0.75
		1.000(1/20)	0.087(1/30)		0.500(1/40)	0.260(1/10)	
		0.290(1/70)	0.052(1/50)				
하층	4등급	5.600(1/5)	0.350(1/10)	1.0	2.800(1/10)	0.700(1/5)	1.0
		2.800(1/10)	0.233(1/15)		0.700(1/40)	0.350(1/10)	
		1.870(1/15)	0.117(1/30)				

4.2 최적의 학습모델 선정을 위한 매개변수 연구

본 연구에서는 인공신경망 학습모델의 구축을 위하여 MATLAB 프로그램(Math Works Inc., 2010)의 역전파 알고리즘 중 인공신경망 학습에 매우 잘 맞는 것으로 알려져 있는 LM (Levenberg-Marquardt) 알고리즘을 사용하였다(강승은, 2009). LM 알고리즘은 은닉층(hidden layer) 수와 노드(node) 수에 따라서 학습능률 및 예측 능력이 큰 차이를 나타낸다. 그러므로 터널 굴착 중 물성치

표 7. 매개변수 연구 개요

모 델	은닉층 수	각 은닉층의 노드 수				경우의 수
		1번째 은닉층	2번째 은닉층	3번째 은닉층	4번째 은닉층	
H-1 ~ H-6	2	4 6 8 10 12 14				$6 \times 1 = 6$
H-7 ~ H-42	3	4 6 8 10 12 14	4 6 8 10 12 14			$6 \times 6 = 36$
H-43 ~ H-258	4	4 6 8 10 12 14	4 6 8 10 12 14	4 6 8 10 12 14		$6 \times 6 \times 6 = 216$

표 8. 학습모델 구성

모 델	ANN layers
H-1	7-4-4-4
⋮	⋮
H-6	7-14-14-4
H-7	7-4-4-4-4
⋮	⋮
H-42	7-14-14-14-4
H-43	7-4-4-4-4-4
⋮	⋮
H-221	7-12-14-12-12-4
⋮	⋮
H-258	7-14-14-14-14-4

표 9. 학습결과의 검증지표

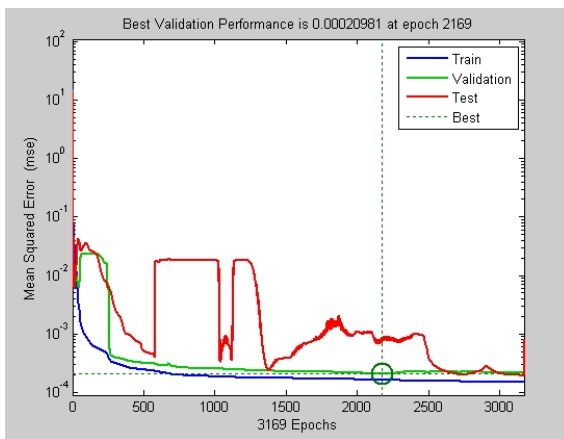
모 델	평균제곱오차	결정계수(R^2)
H-1	0.0829	0.9949
⋮	⋮	⋮
H-6	0.0117	0.9955
H-7	0.0705	0.9965
⋮	⋮	⋮
H-42	0.0311	0.9996
H-43	0.0224	0.9979
⋮	⋮	⋮
H-221	0.0002	0.9998
⋮	⋮	⋮
H-258	7.6472	0.5821

예측을 위한 최적의 학습자료를 선정하기 위해서 은닉층 수 3가지 (2, 3, 4개), 노드 수 6가지(4, 6, 8, 10, 12, 14개)로 구분하여 표 7과 같이 총 258개의 매개변수 연구를 수행하였다. 단, 마지막 은닉층과 바로 전의 은닉층의 노드 수는 같다고 가정하였다.

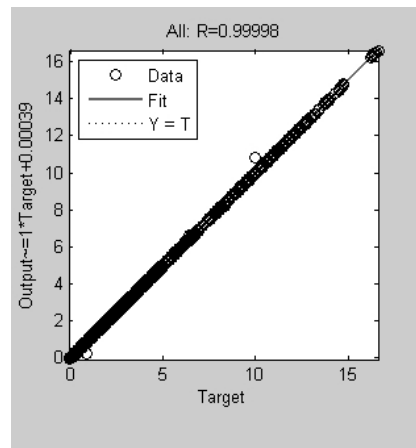
최적 인공신경망의 구조를 결정하기 위하여 표 8과 같이 H-1에서 H-258까지 총 258가지 학습모델이 매개변수 연구에 사용되었다. 이 때 최대 학습횟수는 10,000번으로 제한되었으며, 입력층의 노드 수는 7개, 출력층의 노드 수는 4개로 고정하였고, 은닉층의 수는 2, 3, 4개로 구분하였다. 각 은닉층의 노드 수를 동일하게 변화시킨 기존연구와 달리 각 은닉층의 노드 수는 은닉층 별로 4, 6, 8, 10, 및 14개의 조합으로 변화시켜가며 학습시켰다.

표 9는 258개 학습모델의 학습결과를 검증지표인 평균제곱오차(MSE, Mean Squared Error)와 결정계수 R^2 (Coefficient of Determination)로 정리한 것이다. 평균제곱오차는 인공신경망에 의한 학습 성능을 비교하는 수단으로 사용되며, 평균제곱오차가 작은 값을 가지는 모델일수록 더 신뢰도가 높음을 의미한다. 한편 결정계수는 $R^2=1$ 일 경우, 모든 표본 관측치가 추정된 회귀선 상에만 있다는 것이며, 1에 가까울수록 적합성이 높음을 의미한다.

학습결과 은닉층수 4개, 1번째 은닉층 수 12개, 2번째 은닉층 수 14개, 3번째 은닉층 수 12개, 4번째 은닉층 수 12개인 H-221 모델의 평균제곱오차와 결정계수는 그림 7과 같이 각각 0.0002와 0.9998로 나타나 최적 학습모델로 선정되었다. 한편 본 연구에서 선정된 최적 학습모델은 결정계수 0.9999와 평균제곱오차 0.0064를 갖는 송원영(2012)의 최적 학습모델과 비교할 때, 결정계수는 거의 비슷하지만, 평균제곱오차가 약 30배 정도 작아 더 신뢰할 수 있는 학습모델이라 판단된다. 한편, 그림 7(a)에서 평균제곱오차의 그래프가 3개 인데, 이는 학습결과를 정밀하게 검증하기 위해 MATLAB에서는 총 학습자료의 60%, 20%, 20%를 무작위로 분할하여 각각 학습(train), 검증(validation) 및 시험(test)에 사용하고 최적의 평균제곱오차(best)를 도출한다.



(a) 평균제곱오차



(b) 결정계수

그림 7. H-221 모델(7-12-14-12-12-4)의 학습결과

최적의 학습모델 H-221에 대한 인공신경망 구조가 그림 8에 도시되었다. 입력변수는 상, 중, 하층의 탄성계수($E_{상}$, $E_{중}$, $E_{하}$) 및 점착력($C_{상}$, $C_{중}$, $C_{하}$), 측압계수(K_0)이며 은닉층 수는 4개에서 각각 노드 수 12개, 14개, 12개, 12개를 갖추고 있다. 또한 출력변수는 상반 천단 변위, 하반 천단 변위, 상반 내공 변위, 하반 내공 변위 구성되어 있다.

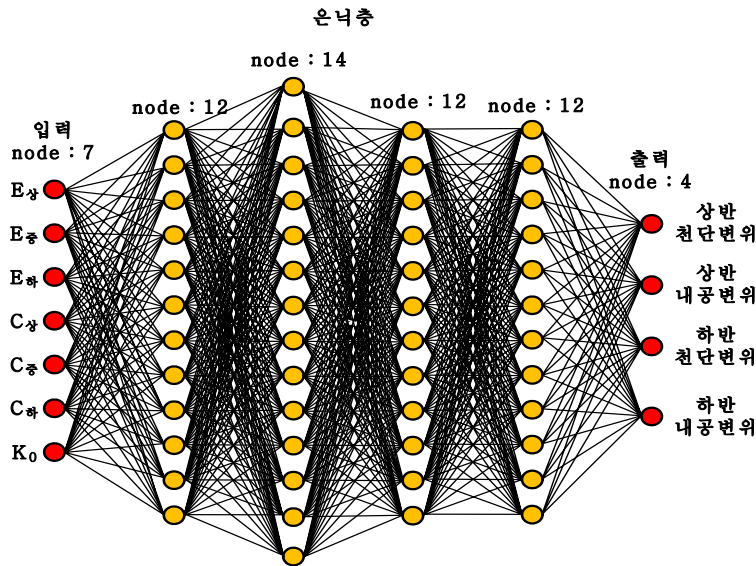


그림 8. H-221 모델(7-12-14-12-12-4)의 구조

4.3 최적 지반물성치 산정

최적의 지반물성치는 그림 9와 같은 순서에 따라 산정되었다. 각 층의 탄성계수($E_{상}$, $E_{중}$, $E_{하}$) 및 점착력($C_{상}$, $C_{중}$, $C_{하}$), 측압계수(K_0)를 학습된 인공신경망 모델에 입력하여 예측된 변위와 계측변위의 차이가 ± 2.00 mm 안에 들어 올 때까지 시행착오법에 의해 반복 수행하여 7개의 입력변수인 지반물성치의 최적의 값이 산정되었다. 단, ± 2.00 mm는 터널 높이의 약 $1/5,000(=2 \text{ mm}/10 \text{ m})$ 에 해당하는 충분히 작은 값으로 판단되어 허용기준으로 사용하였다.

최적의 학습모델을 이용한 역해석 과정을 통해 최적 지반물성치를 추정하여 표 10과 같이 지층별로 정리하고, 기존연구 결과와 비교하였다. 표 10에서 보는 바와 같이 송원영(2012)이 추정된 지반물성치 중 상층, 중층 및 하층의 점착력이 각각 0.117, 0.217 및 0.317 MPa로 나타나 표 6에 명시된 학습자료 구축 시 사용되었던 점착력의 범위를 벗어남을 알 수 있었다. 반면에 본 연구에서 추정된 지반물성치는 학습자료 구축 시 사용된 물성치 범위내의 결과가 나와 신뢰성이 높은 것으로 판단된다.

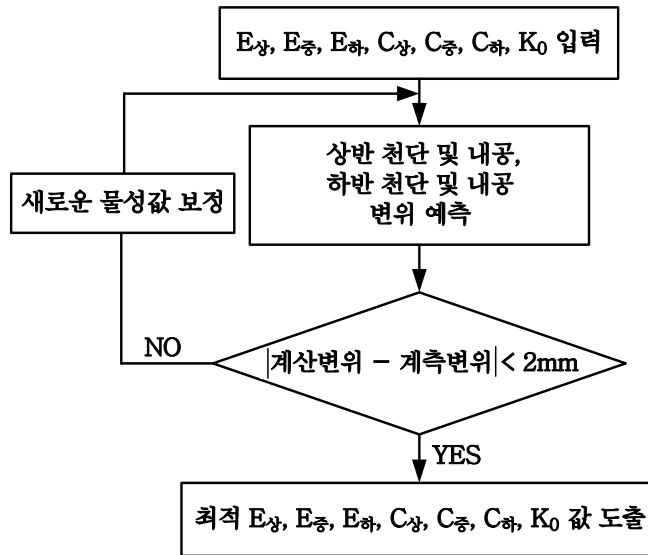


그림 9. 최적 지반물성치 산정을 위한 순서도

표 10. 산정된 최적 지반물성치 비교

구 분	본 연구			기존연구(송원영, 2012)		
	탄성계수 (GPa)	점착력 (MPa)	측압계수	탄성계수 (GPa)	점착력 (MPa)	측압계수
상층	0.394	0.062	0.731	0.431	0.117	0.817
중층	0.445	0.086		0.531	0.217	
하층	2.175	0.231		2.261	0.317	

또한 기존연구와 본 연구의 인공신경망 분석을 통해 추정된 물성치를 이용하여 지층구조를 추정해 보았다. 송원영(2012)의 결과는 탄성계수의 경우 상층과 중층은 비슷하지만 하층은 차이를 보여, 상층과 중층이 동일한 층으로 간주되어 2개 지층으로 구성된 것으로 판단할 수 있으나, 점착력의 경우는 각 지층간의 차이가 0.100 MPa로 일정하여 상층과 중층을 동일한 층으로 판단하는 데에 무리가 있었다. 그러나 본 연구에서 추정된 탄성계수와 점착력 모두 상층과 중층은 비슷한 값을 가지는 반면 하층과 확연한 차이를 보여 상층과 중층을 동일한 층으로 간주하여 2개의 지층을 갖는 구조라고 판단할 수 있었다. 또한 표 6의 문헌고찰을 통해 산정된 등급별 지반물성치 범위를 감안하더라도 그림 10과 같이 상층과 중층은 동일한 층으로 5등급, 하층은 4등급에 해당하는 2개의 지층구조로 보는 것이 보다 합당할 것으로 판단된다.




그림 10. 인공신경망 결과를 고려한 지층도

최적의 인공신경망 학습모델을 통해 지반물성치의 불확실성을 최대한으로 줄였을 때 얻은 내공변위를 표 11에 나타내었다. 본 연구의 최대 오차는 표 11에서와 같이 1.3 mm로 나타났다. 이 값은 최대 오차가 2.5 mm였던 송원영(2012)의 연구결과와 비교할 때, 더 적은 값으로 보다 정확하게 추정되었다. 이 결과는 계측자료 뿐만 아니라 굴진면 관찰자료도 활용하여 역해석을 수행했기 때문으로 판단된다. 따라서 굴진면 관찰자료를 활용한 인공신경망 분석을 통해 역해석을 수행함으로써 계측자료만을 활용한 기존의 인공신경망 연구보다 더 정확한 지반물성치를 추정할 수 있을 것으로 기대된다.

표 11. 계측변위와 인공신경망 예측변위 비교

(단위: mm)

구 분	상반굴착 시		하반굴착 시	
	천단침하	내공변위	천단침하	내공변위
계측변위	5.20	1.30	13.0	6.50
인공신경망 예측변위	6.17	1.07	11.70	6.97
오 차	0.97	0.23	1.30	0.47

5. 결 론

본 연구에서는 호남고속철도 제 ○○공구의 산악터널을 대상으로 굴진면 관찰자료를 활용하여 암반등급을 추정하고, 지반물성치의 가능한 범위를 선정하였다. 이를 바탕으로 인공신경망의 학습자료를 구축하였다. 매개변수 연구를 통해 최적의 학습모델을 찾고, 이를 이용하여 최적의 지반물성치를 추정하였다. 연구결과 다음과 같은 결론을 도출할 수 있었다.

1. 인공신경망 분석 결과 최적의 학습모델은 은닉층 수가 4개이고 노드 수가 각각 12, 14, 12, 12개 일 경우로 나타났으며, 기존연구에서 사용된 학습모델보다 평균제곱오차가 작아 더 신뢰도가 높을 것이라고 판단된다.

2. 산정된 최적의 지반물성치를 문헌고찰을 통해 얻은 등급별 지반물성치의 범위를 참고로 분석한 결과, 하층은 실제 4등급 지층에 해당되고, 상층과 중층은 동일한 층으로 5등급 지층에 해당되는 것으로 추정되었다. 한편 이때 얻어진 변위들은 모두 계측변위와 최대오차 1.30 mm 이내로 기존연구보다 더 정확한 결과가 나왔다.
3. 인공신경망을 이용한 터널 역해석을 통해 지반물성치를 추정할 경우, 굴진면 관찰자료가 효과적으로 활용될 수 있음을 확인하였다. 또한 기존에 계측자료만 이용한 인공신경망 결과보다 굴진면 관찰자료를 추가로 활용함으로써 더 정확한 결과를 얻을 수 있었다.

한 터널 현장의 특정 지점에서 계측된 자료를 토대로 수행된 본 연구는 천단변위와 내공변위만이 계측자료로 사용되었으며, 지표침하, 지중변위 및 지보재 응력 등은 제외되었다. 또한 실제 터널 거동은 3차원 수치해석을 통해 보다 정확하게 규명될 수 있으나, 본 연구에서는 2차원 수치해석에 기초하여 결과를 도출하였음에 유념해야 한다. 향후 유사 터널 현장에서 설계 시 터널 변위 계측자료와 굴진면 관찰자료를 인공신경망 학습데이터로 활용하여 지반물성치의 적정여부를 체계적으로 판단하는 데에 본 연구에서 제안한 방법이 유용하게 사용될 수 있을 것으로 사료된다. 하지만 본 연구의 대상터널은 평행한 3개의 지층구조를 갖는 토피가 낮은 천층터널로서 지층의 수가 다르고 복잡한 경우나 심도가 깊은 터널의 경우에는 연구결과를 그대로 적용하는 데에는 무리가 있음에 주의해야한다.

참 고 문 헌

1. 강승온, 전상욱, 박경현, 전용희, 이동호 (2009), “신경망 학습알고리즘의 비교와 2차원 익형의 비정상 공력하중 예측기법에 관한 연구”, 한국항공우주학회지, 제37권, 제5호, pp. 425-432.
2. 강창민 (2009), 대단면 근접 병설터널 필라구간 안정성 평가 및 보강방안, 경북대학교 대학원 석사학위 논문, 101p.
3. 김문겸, 장정범 (1995), “유한요소-경계요소 조합에 의한 터널 계측결과의 역해석”, 한국암반공학회 논문집, 제5권, 제3호, pp. 205-213.
4. 김종규 (2011), 인공신경망 기법에 근거한 역해석을 이용한 터널 지보패턴의 적정성 평가 사례 연구, 수원대학교 대학원 박사학위 논문, 94p.
5. 김주화, 채영수, 박연준 (2008), “수평경사계를 이용한 토사터널의 선행변위 예측”, 한국암반공학회 논문집, 제18권, 제5호, pp. 355-365.
6. 권순섭 (2009), “수치해석에 의한 암반특성의 변화가 터널에 미치는 영향”, 한국철도학회 논문집, 제12권, 제1호, pp. 31-38.

-
7. 대우건설 (2009), 호남고속철도 제 ○○공구 노반신설 기타공사 터널해석보고서, 1,074p.
 8. 박연준, 유광호, 송한찬, 김기선, 이대혁(2004), “3차원 수치해석을 이용한 터널 막장 전방 지반상태의 예측”, 한국암반공학회지, 제14권, 제6호, pp. 440-449.
 9. 박종원 (2003), 터널의 안전을 평가기법에 관한 연구, 수원대학교 대학원 석사학위 논문, 65p.
 10. 박춘식 (2010), “시공과정 및 현장계측을 고려한 NATM 터널의 수치해석적 연구”, 한국암반공학회지, 제20권, 제1호, pp. 28-38.
 11. 서영욱 (2003), 터널의 2차원 해석을 위한 하중분배율에 관한 연구, 수원대학교 대학원 석사학위 논문, 58p.
 12. 송기일, 조계춘 (2006), “터널 사전보강 영역의 효과적 수치해석을 위한 등가 물성치 결정 기법”, 한국터널 공학회 논문집, 제8권, 제2호, pp. 151-163.
 13. 송원영 (2012), Levenberg-Marquardt 알고리즘을 이용한 터널 거동의 역해석 사례 연구, 수원대학교 대학원 석사학위 논문, 57p.
 14. 신휴성, 권영철 (2009), “미시추 구간의 정량적 지반 등급 분류를 위한 원도우-쉬프팅 인공 신경망 학습기법의 개발”, 한국터널지하공간학회 논문집, 제11권, 제2호, pp. 151-162.
 15. 유광호, 송원영 (2012), “인공신경망 기법에 근거한 지반물성치의 불확실성을 최소화하기 위한 터널 역해석 사례연구”, 한국터널지하공간학회 논문집, 제14권, 제1호, pp. 37-53.
 16. 유일형 (2011), 굴착방법과 초기지압 조건을 고려한 하중분배율의 산정 연구, 수원대학교 대학원 박사학위 논문, 108p.
 17. 한국도로공사 도로교통기술원 (2002), “암반등급에 따른 도로터널 지보체계 개선 연구”, 268p.
 18. 한명식, 양인재, 김광명 (2002), “인공신경망을 이용한 터널구간의 암반분류 예측”, 한국터널공학회 논문집, 제4권, 제4호, pp. 277-286.
 19. 허재록 (2001), 터널 발파시 암반의 RMR값이 상부구조물에 끼치는 영향, 단국대학교 대학원 석사학위 논문, 66p.
 20. Itasca Consulting Group, Inc. (2005), Fast Lagrangian Analysis of Continua, Ver. 5.0, Itasca Consulting Group, Minnesota, USA.
 21. Math Works Inc. (2010), MATLAB : Neural Network Toolbox™ User’s Guide, Ver. R2011b, Math Works Inc., 404p.
 22. Wasserman, P.D. (1989), Neural computing : Theory and practice, Anza Research Inc., 230p.