

# 인공신경망 기법에 근거한 지반물성치의 불확실성을 최소화하기 위한 터널 역해석 사례연구

유광호<sup>1\*</sup>, 송원영<sup>2</sup>

## A case study on a tunnel back analysis to minimize the uncertainty of ground properties based on artificial neural network

Kwang-Ho You, Won-Young Song

**ABSTRACT** There is considerable uncertainty in ground properties used in tunnel designs. In this study, a back analysis was performed to find optimal ground properties based on the artificial neural network facility of MATLAB program of using tunnel monitoring data. Total 81 data were constructed by changing elastic modulus and coefficient of lateral pressure which have great influence on tunnel convergence. A sensitivity analysis was conducted to establish an optimal training model by varying the number of hidden layers, the number of nodes, learning rate, and momentum. Meanwhile, the optimal training model was selected by comparing MSE (Mean Squared Error) and coefficient of determination ( $R^2$ ) and was used to find the correct elastic moduli of layers and the coefficient of lateral pressure. In future, it is expected that the suggested method of this study can be applied to determine the optimum tunnel support pattern under given ground conditions.

**Keywords:** Back analysis, artificial neural network, elastic modulus, coefficient of lateral pressure

**요약** 터널 설계 시 사용되는 지반 물성치는 불확실성을 내포한다. 본 연구에서는 최적의 지반물성치를 찾기 위해 터널 계측자료를 활용하여 MATLAB 프로그램의 인공신경망 분석 기능을 이용한 역해석을 수행하였다. 터널 내공변위에 많은 영향을 주는 탄성계수와 측압계수를 변화시켜 총 81개의 학습자료를 구축하였다. 최적의 학습모델을 구축하기 위해 은닉층 수와 노드(node) 수 및 학습율과 관성항을 변화시켜가며 매개변수 연구를 수행하였다. 한편 최적의 학습모델은 평균제곱오차(MSE, Mean Squared Error)와 결정계수( $R^2$ )를 비교하여 선정되었고, 이를 이용하여 정확한 지층의 탄성계수와 측압계수를 찾았다. 향후 주어진 지반조건에서 최적의 터널 지보패턴을 결정하는 등의 목적으로 본 연구에서 제시된 방법이 적용될 수 있을 것으로 기대된다.

**주요어:** 역해석, 인공신경망, 탄성계수, 측압계수

---

접수일(2011.12.13), 수정일(2011.12.21), 게재확정일(2012.1.13)

<sup>1</sup>수원대학교 토목공학과 교수

<sup>2</sup>수원대학교 토목공학과 석사과정

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

## 1. 서론

최근 국내에는 국토의 효율적인 이용, 도심권 교통체증 및 인구의 도심권 과밀현상 등을 해결하기 위해 각종 고속도로, 고속철도 및 도심지 지하철도 등이 건설되거나 계획 중에 있다. 한편 우리나라는 국토면적의 70% 이상이 산지로 이루어져 있고, 환경에 대한 관심이 고조되고 있어, 터널 시공이 증가될 것으로 기대되고 있다.

터널은 지하구조물로서 지상구조물과 다르게 하중조건, 굴착 대상 암반의 역학적 거동특성 등이 명확하지 않다. 따라서 많은 변수들을 고려해야 하고 수치해석을 통한 실제 거동예측이 쉽지 않다. 또한 수치해석에 사용되는 물성치도 한정된 시추조사나 물리탐사에 의해 산정되기 때문에 많은 불확실성(uncertainty)을 포함하게 된다. 이러한 불확실성을 줄이기 위해 계측자료를 활용한 역해석 기법이 연구되고 있다.

국내에서는 김문겸과 장정범(1995)이 실제 현장계측자료를 이용하여 지반의 탄성계수와 정지토 압계수를 추정하는 역해석 프로그램을 직접법에 근거하여 개발하였다. 역해석 결과를 시추조사자료, 실내 및 현장실험 결과 등과 비교·분석한 결과 거의 일치한다고 판단하였다. 또한 전양수(2002)는 직접탐색법 알고리즘 이용하여 터널의 주요 설계정수인 탄성계수와 측압계수를 결정할 수 있는 역해석 알고리즘을 개발하였다. 해석된 각 결과 값들과 현장 계측자료의 회기분석을 통해 실제 현장과 부합한 결과가 도출되었다. 한편 한명식 등(2002)은 터널 미시추 구간에서 보다 신뢰성 높은 암반분류 예측을 위하여 인공신경망 입력자료에 대한 적정성을 사전 평가하였고, 그 이후에 물리탐사 자료를 입력변수로 활용하여 미지의 터널구간에 대한 RMR 값을 예측하였다.

한편 국외에서는 Fakhimi 등(2004)은 토양의 점착력과 수평응력을 추정하기 위해 터널 계측변위와 수치모델링 결과가 일치할 때까지 역해석을 수행하였다. 그 결과, 역해석을 통하여 현장의 점착력과 수평응력을 추정할 수 있다는 결론을 도출하였다. 또한 Zhang 등(2006)은 현장에서의 수평응력과 암반의 변형계수를 결정하기 위해 반복 알고리즘인 직접적인 검색기법과 최소제곱 감소기법을 적용한 역해석 기법을 적용하였다.

또한 최근에는 본 연구에서 적용한 역해석 기법 중 인공신경망을 이용한 연구가 활발하게 이뤄지고 있다. 이종구(2002)는 인공신경망 중 다층 퍼셉트론을 이용하여 터널 예측시스템을 개발하였다. 이를 위해 터널 거동에 영향을 미치는 영양인자인 토피고와 측압계수, 단면형상 등의 설계인자와 신뢰성분석을 통해 선정된 계측자료를 적합한 다층퍼셉트론 구조에 입력하여 학습시켰다. 학습이 완료된 터널거동 예측시스템을 이용하여 기 시공 현장 터널의 천단침하, 내공변위 및 지보재의 응

력 등을 예측하고 실 계측치와 비교하여 적용성을 확인하였다. 국외현장 데이터를 이용한 인공신경망 모델을 개발한 임안식(2006)은 다양한 설계 파라미터에 의한 수치해석 결과를 데이터베이스화 하였으며 이를 인공신경망에 적용하여 지반물성치인 측압계수와 점착력을 예측하였다. 예측된 지반물성치를 이용하여 지반 및 터널 거동을 예측하는 모델을 제시하였다. 그리고 유충식 등(2008)은 터널 설계 자동화 시스템 중 지보패턴 선정 및 안정성 평가에 있어 인공신경망 개념을 접목시켜 예비 설계단계에서의 적용성에 대해 연구하였다. 이를 위해 먼저 국내 도로터널을 대상으로 설계 데이터베이스(database)를 구축하여 인공신경망 구축 시 국내 설계 여건을 반영하도록 하였다. 구축된 인공신경망 학습자료를 이용한 학습 및 최적화 연구를 통해 인공신경망 엔진을 구축하였으며, 구축된 인공신경망 엔진이 지보패턴 적정성을 검토하는데 있어 최적화되었음을 확인하였다.

김종규(2011)는 지층 물성치에 포함된 불확실성을 줄이기 위해 인공신경망을 이용한 역해석을 실시하였다. 역해석의 학습자료를 구축하기 위해 정용훈(2001)이 자체 개발한 인공신경망 프로그램을 이용하였으며, 터널 거동에 영향을 미치는 지반정수인 탄성계수와 측압계수를 사용하였다. 매개변수 연구를 위해 은닉층 수는 2개로 고정하였다. 우선 학습율과 관성항을 0.95 및 0.80으로 고정하고 4가지 경우에 대한 학습결과를 비교하여 최적의 노드수를 찾았다. 찾아진 노드수를 사용한 4가지 경우의 학습결과를 비교하여 최적의 학습율과 관성항의 조합을 찾았다. 학습한 인공신경망 모델은 평균계급근오차와 결정계수를 통하여 적정성이 판단되었고, 최적의 물성치인 탄성계수와 측압계수가 찾아질 수 있었다. 그러나 인공신경망 모델의 구조가 총 8가지 경우의 민감도 분석을 통해 얻어졌기 때문에 최적이라고 단정하는 데에는 어려움이 많다.

설계 시 예측된 내공변위와 시공 시 계측된 내공변위와의 차이는 지반물성치의 불확실성, 사용 해석프로그램, 지보패턴 등에 따라 달라질 수 있다. 본 연구에서는 지반물성치의 불확실성이 내공변위의 차이에 가장 큰 영향을 미친다고 가정하였다. 따라서 지반 물성치에 포함된 불확실성을 최대한 줄이기 위해 인공신경망을 이용한 역해석을 실시하였다. 김종규(2011)의 연구와 달리, 인공신경망 해석을 위해 MATLAB 프로그램(Math Works Inc., 2010)을 사용하였다. 또한 은닉층 수 2가지(2개, 3개), 노드 수 6가지(4, 6, 8, 10, 12, 14개), 학습율 4가지(0.01, 0.02, 0.03, 0.04), 관성항 4가지(0.40, 0.60, 0.80, 0.95)로 구분하여 총 192개의 민감도 분석을 통한 매개변수 연구를 수행하여 최적의 학습모델을 찾았으며, 이를 이용하여 최적의 지반물성치를 추정할 수 있었다. 학습자료 구축을 위해 지반범용 해석 프로그램인 FLAC 2D(Itasca Consulting Group, Inc., 2005)를 사용하였다.

## 2. 인공신경망을 활용한 역해석

### 2.1 역해석 개요

일반적으로 역해석(back analysis)은 정해석(forward analysis)의 수치해석결과가 계측결과와 일치하도록 수치해석 모형의 미지 변수를 정의하는 해석과정을 의미한다. 역해석은 현재 지하공동의 안정성 문제를 포함한 지반공학의 여러 문제에까지 연구되고 있다. 현재까지의 역해석 방법으로는 해석적 방법과 수치해석적 방법을 이용한 직접법(direct method)과 역산법(inverse method)이 많이 연구되고 있고, 그 외 시행착오법(trial & error method)이 연구되기도 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. 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.




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

### 2.3 다층 퍼셉트론

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

#### (1) 다층 퍼셉트론의 구조

다층 퍼셉트론은 인공신경망의 일종으로서 역전파 신경망 또는 다층 전방향 신경망이라고도 하며, 인공신경망에 사용되는 퍼셉트론 모델은 단층 퍼셉트론(single layer perceptron)과 다층 퍼셉트론(multi-layer perceptron)으로 나뉠 수 있다. 단층 퍼셉트론은 입력층과 출력층으로만 구분되며, 신경망의 학습은 주어진 입력에 대하여 원하는 출력이 나오도록 연결선의 가중치(weight)를 조정함으로써 이루어진다. 그러나 단층 퍼셉트론이 가지는 문제점은 분리가 불가능한 입력 패턴의 집합이 들어오면 결정 경계선이 진동하고 패턴들의 분포가 중복되어진다. 또한 단위 함수를 사용하기 때문에 가중치의 변화에 매우 민감하며 비선형적인 문제를 해결하기 힘들기 때문에 실제 활용에 적용하기에는 많은 무리가 있다.

다층 퍼셉트론은 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 퍼셉트론은 단층 퍼셉트론과 유사한 구조를 가지고 있지만 중간층과 각 처리기의 입·출력 특성을 비선형으로 함으로써 단층 퍼셉트론의 단점들을 극복하였다.

다층 퍼셉트론에서 신호의 종류는 함수신호(function signal)와 오차신호(error signal)가 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




그림 2. 다층 퍼셉트론의 구조

---

함수신호를 계산하여 각 뉴런의 출력신호를 생성하고, 학습 알고리즘의 역전파 단계에서 필요한 순간오차를 계산한다.

## (2) 역전파 학습 알고리즘

대부분의 다층 퍼셉트론의 학습은 역전파 학습 알고리즘을 사용하여 수행할 수 있다. 이 알고리즘은 주어진 입력에 대해 원하는 출력결과를 학습시키고자 할 때 사용하며, 출력층의 각 뉴런에서 발생된 출력오차를 역으로 전파시켜 나가면서 연결링크의 가중치 수정을 통해 오차를 최소화시킨다.

본 연구에서는 Math Works Inc.(2010)에서 개발한 MATLAB 프로그램을 사용하였다. MATLAB 프로그램은 다양한 학습 알고리즘을 주어진 문제에 따라 선택할 수 있으며, 각 알고리즘에서 요구하는 학습 파라미터를 쉽게 설정하여 학습에 반영할 수 있다. 또한, 네트워크 작업 시 GD, GDM, GDA, LM, SCG 등과 같은 훈련 알고리즘을 선택하여 입력한다. 알고리즘 GD(Gradient Descent back-propagation)는 기울기 하강법으로 기울기에 비례한 현재 위치에서 단계적으로 함수의 최소 또는 최대에 점근적으로 접근하는 방법이다. GDM(Gradient Descent with Momentum back-propagation) 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 back-propagation) 알고리즘은 학습율과 사용하는 관성항의 기울기 변화에 따라 가중치를 향상시키는 방법이다.

LM(Levenberg-Marquardt back-propagation) 알고리즘은 비선형 함수들의 제곱의 합으로 된 최소화 함수로 만들어진 Newton's method를 변형한 방법이며, 인공신경망 학습에 매우 잘 맞는 것으로 알려져 있다. SCG(Scaled Conjugate Gradient back-propagation) 알고리즘은 최적화 관점에서 전체적인 오류 함수를 최소화시키는 인공신경망 네트워크 학습이다. 그리고 다변량 함수는 네트워크 가중치에 의존한다. 본 연구에서 사용된 가중치 수정방법으로는 GDM 알고리즘을 선택하였으며, 다음과 같은 과정을 통해 진행된다.

우선 가중치 개선에 앞서  $n$ 번째 학습패턴이 주어졌을 때 출력뉴런  $k$ 에 대해 원하는 목표값  $T_{nk}$ 과 실제 인공신경망의 계산에 의한 출력값  $O_{nk}$ 사이의 오차값( $E$ )을 평균제곱오차(MSE, Mean Squared Error)를 적용하여 식 (1)과 같이 구한다.

$$E = \frac{1}{2} \sum_{n=1}^N (T_{nk} - O_{nk})^2 \quad (1)$$

여기서,  $N$ 은 학습패턴의 총 개수이다.

역전파 모델은 오차값  $E$ 를 최소화하기 위하여 중간층의 가중치에 대한 수치를 변경시키면서 학습을 행한다. 가중치 변경문제는 입력과 목표패턴의 집합을 기준으로 하여 오차값  $E$ 의 크기에 따라 가중치를 변경한다. 학습과정에 있어 각층의 노드에서는 오차가 발생하며,  $p$ 번째 학습패턴에 대한 뉴런  $j$ 에서 발생한 오차  $\delta_{pj}$ 는 식 (2)와 같이 기술할 수 있다(정용훈, 2001).

$$\delta_{pj} = O_{pj}(1 - O_{pj}) \sum_k \delta_{pk} W_{pk} \quad (2)$$

단,  $p$ 번째 학습패턴에 대한 출력 뉴런  $k$ 의 오차  $\delta_{pk}$ 는 식 (3)과 같다.

$$\delta_{pk} = (T_{pk} - O_{pk}) O_{pk} (1 - O_{pk}) \quad (3)$$

$W_{kj}(t)$ 는 학습횟수가  $t$ 일 때 은닉 뉴런  $j$ 로부터 출력 뉴런  $k$ 로의 가중치이며, 식 (4)와 같이 갱신된다.

$$W_{kj}(t+1) = W_{kj}(t) + \eta \delta_{pk} O_{pj} + \alpha (W_{kj}(t) - W_{kj}(t-1)) \quad (4)$$

여기서,  $t$ 는 학습횟수,  $\eta$ 는 학습율,  $\alpha$ 는 관성항으로서 1회의 학습에 따른 변화량을 계산하기 위하여 이용된다. 학습율은 신경망 모델에 따라 다른 값으로 연결가중치의 변화율을 뜻하며, 관성항은 오차값이 이전에 변하던 방향으로 조정되도록 해줌으로써 올바른 최소점에 도달하지 못하고 진동하는 현상을 방지하여 학습을 빨리 진행시켜주는 역할을 한다. 각 층에 대한 오차는 역방향으로 전달된다.

### 3. 연구 대상터널 및 수치해석 개요

#### 3.1 대상터널 개요

본 연구의 대상 터널은 호남고속철도 제 ○○공구 현장 내에 시공 중인 충남 공주시에 위치하고 있는 9.16 km의 장대터널로서 계룡산을 관통하는 산악터널이다. 대상 터널은 상·하반으로 분할 굴착하여 시공하였으며, 측정기(total station)를 이용한 측정은 시점에 따른 굴진면의 변화를 분석하여 측변위의 수렴여부를 확인하였다. 역해석 대상 지점인 Sta. 36K+990 지점이 포함되는 사업지구 전구간의 평면도는 그림 3에 나타내었으며 대상 터널은 굴착 시점부인 갱구부에 해당된다(대우건설, 2009).

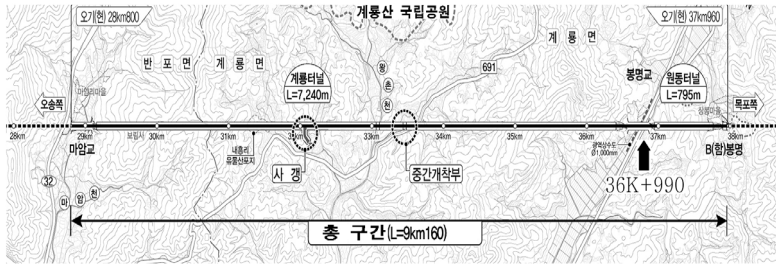


그림 3. 노선의 평면도

### 3.2 실시설계를 위한 수치해석

실제 설계에서 고려된 터널 단면 주변 지층 및 해석 개요도를 그림 4에 나타내었다. 지층은 좌·우 비대칭 형상이며, 원활한 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 중간층 암반에 걸쳐있으며, 강관다단 그라우팅은 상층 암반에서 수행되는 것으로 가정하였다. 슛크




그림 4. 대상단면 및 해석영역




그림 5. 해석 요소망 및 경계 조건



리트는 무지보 - 연성 슛크리트 - 경성 슛크리트 타설 단계별로 하중분담율을 40% - 40% - 20%로 적용하여 해석하였다.

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, 그림 4에서 보는 바와 같이 상층은 3 등급, 중간층은 2 등급, 하층은 1 등급에 해당되는 것으로 판단하였다. 또한 실시설계에서는 축압계수가 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 3 등급 암반의 3배인 27 GPa로 적용하였다.

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 축압계수 1.0, 1.5, 2.0, 2.5에 따라 나타나는 상·하반 천단 변위 및 내공변위를 나타낸 것이다. 변위를 비교해 보면 축압계수 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 1. 해석에 사용한 지반물성치(대우건설, 2009)

구 분	단위중량 (KN/m <sup>3</sup> )	점착력 (KPa)	내부마찰각 (°)	탄성계수 (GPa)	포아송비
5 등급	22.0	200	33.0	0.56	0.30
4 등급	23.0	500	35.0	2	0.27
3 등급	25.0	1,600	42.0	9	0.25
2 등급	26.0	2,600	44.0	20	0.22
1 등급	27.0	3,500	48.0	28	0.20
강관다단 그라우팅	25.0	1,600	42.0	27	0.25

표 2. 축압계수에 따른 변위비교(대우건설, 2009)

(단위: mm)

축압계수	상 반		하 반	
	천단침하	내공변위	천단침하	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

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

### 3.3 선행변위를 포함한 총 변위의 예측

터널에서 굴진에 의해 발생하는 변위는 터널의 주변 지반 상태, 굴착 방법, 보강방법 등 다양한 변수에 의해 발생되어 예측하기 매우 어렵다. 터널에서 일반적으로 사용되는 계측기기는 1차 슛크리트가 타설된 후 굴진면에 근접하여 설치된다. 일반적으로 30~40%의 선행변위가 발생된 후 계측기로부터 침하량을 측정할 수 있게 된다(김주화 등, 2008).

현장에서 측정기(total station)를 이용한 계측결과를 표 3에 나타내었다. 선행변위를 포함한 총 변위를 예측하기 위하여 선행변위를 30% 가정하였다. 표 3에서 보이는 바와 같이 계측된 상반 천단 변위는 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 기법이 사용된다.

## 4. 지반물성치 산정을 위한 역해석

### 4.1 학습자료 구축

인공신경망을 이용한 역해석을 수행하기 위해서는 학습자료 구축이 필요하다. 본 연구에서는 학

습자로 구축을 위하여 Itasca Consulting Group Inc.(2005)에서 개발한 지반해석용 프로그램 FLAC-2D ver 5.0을 사용하여 수치해석을 수행하였다. 터널 내공변위는 지반의 강도정수(탄성계수, 점착력 등)에 따라 달라지는데, 본 연구에서 가장 큰 영향을 미치는 것으로 알려진 지반정수인 탄성계수와 측압계수를 매개변수로 사용하였다(김문겸과 장정범, 1995; 전양수, 2002). 입력변수로 선택된 상층, 중간층, 하층 암반의 탄성계수 3가지와 측압계수를 각각 3가지 값으로 변화시켜 총 81개의 자료구축을 하였다. 출력변수는 터널 상·하반 분할 굴착 시, 상반굴착으로 인해 발생하는 천단변위 및 내공변위와 하반굴착 후 발생하는 천단변위 및 내공변위를 사용하였다. 탄성계수 물성치는 실시설계에서 사용된 값을 1/10, 1/40, 1/70로 감소시킨 값이고, 측압계수는 0.5, 0.75, 1.0으로 구분하였다. 한편 각 암반등급의 점착력은 실시설계에서 사용된 값을 1/10로 모두 감소시켰을 때 계측변위와 근접한 변위가 나타났다. 따라서 학습에 사용된 점착력은 실시설계에서 사용된 값을 1/10로 감소시킨 값으로 상층(3 등급) 암반의 경우는 0.16 MPa, 중간층(2 등급) 암반의 경우는 0.26 MPa, 하층(1 등급) 암반의 경우는 0.35 MPa로 사용하였다.

#### 4.2 학습 및 최적 데이터베이스를 위한 매개변수 연구

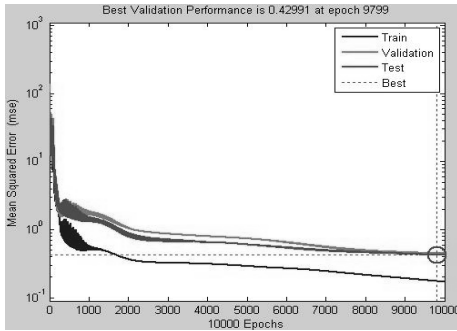
본 연구에서는 인공신경망 학습 데이터베이스 구축을 위하여 MATLAB 프로그램(Math Works Inc., 2010)에서 네트워크 작업 시 역전파 훈련 알고리즘 중 GDM(GDM, Gradient Descent with Momentum) 방법을 사용하였다. GDM은 은닉층(hidden layer) 수와 노드(node) 수 및 학습율(learning rate)과 관성항(momentum)에 따라서 학습 능력 및 예측 능력이 큰 차이를 나타낸다. 그러므로 터널 굴착 중 물성치 예측을 위한 최적의 학습 데이터베이스를 선정하기 위해서 은닉층 수 2가지(2개, 3개), 노드 수 6가지(4, 6, 8, 10, 12, 14개), 학습율 4가지(0.01, 0.02, 0.03, 0.04), 관성항 4가지(0.40, 0.60, 0.80, 0.95)로 구분하여 총 192개의 민감도 분석을 수행하였다. 단, MATLAB 프로그램에서는 은닉층 개수 입력 후 노드 수 입력에서 첫 번째 은닉층 노드 수는 입력이 가능하지만, 마지막 노드 수는 그 전 은닉층의 노드 수와 같게 들어가도록 제한되어 있다. 반복 학습 수행하는 동안 지속적으로 검증 자료에 대한 오차율을 모니터링하면서 학습하였다.

인공신경망 학습의 최적의 모델을 선정하기 위하여 은닉층 2개와 3개일 때, 적정성이 높은 모델을 비교해 보았다. 표 4는 은닉층 수가 3개이고, 학습율이 0.02, 관성항이 0.80이며, 은닉층 노드 수가 같은 경우의 학습모델 구조 및 적합성 검증결과를 나타낸 것이다. 즉 입력 및 출력변수는 각각 4개였으며, 4개의 노드를 갖는 H-1 모델부터 14개의 노드를 갖는 H-6 모델을 포함하여 총 96 가지의 경우에 대해 변화시켜가며 학습횟수를 10,000번으로 제한하고 학습시켰다. 적합성 검증을 위해 평균제곱오차(MSE, Mean Squared Error)과 결정계수(coefficient of determination)가 사용되었으


며, 그 결과는 표 4에 나타내었다. 표 4에서 보면 평균제곱오차는 은닉층 노드 수가 6개인 H-2 모델에서 0.43으로 가장 작으며, 은닉층 노드 수가 12개인 H-5 모델에서 83.2로 가장 큼을 확인할 수 있다. 여기서 평균제곱오차는 신경망에 의한 학습 성능을 비교하는 수단으로 사용되며, 작은 값을 가지는 모델일수록 더 성능이 좋음을 의미한다. 결정계수는  $R^2=1$ 일 경우 모든 표본 관측치가 추정된 회귀선 상에만 있다는 것이며, 1에 가까울수록 적합성이 높음을 의미한다.

표 4. 은닉층 3개에서 학습모델 구조 및 적합성 검증 (학습율: 0.02, 관성항: 0.80)

모 델	ANN layers	평균제곱오차	결정계수( $R^2$ )
H-1	4-4-4-4-4	3.54	0.98655
H-2	4-6-6-6-4	0.43	0.99811
H-3	4-8-8-8-4	1.63	0.99401
H-4	4-10-10-10-4	1.75	0.99178
H-5	4-12-12-12-4	83.2	0.47313
H-6	4-14-14-14-4	1.24	0.99299

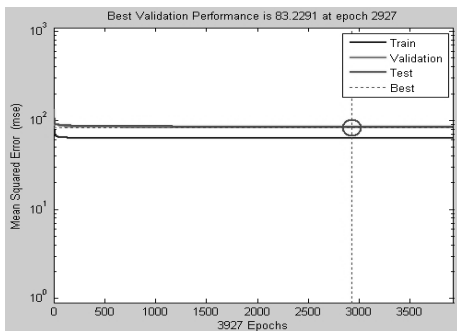


(a) 평균제곱오차




(b) 결정계수

그림 6. H-2 모델(은닉층 3개, 노드 수 6개)의 학습결과 검증



(a) 평균제곱오차



(b) 결정계수

그림 7. H-5 모델(은닉층 3개, 노드 수 12개)의 학습결과 검증

그림 6과 그림 7은 표 4에서 평균제곱오차가 가장 작게 나타난 H-2 모델과 평균제곱오차 가장 크게 나타난 H-5 모델에 있어 은닉층 수가 3개 일 때 은닉층의 노드 수에 따른 평균제곱오차와 결정계수를 통하여 학습결과를 검증한 것이다. 그림 6에서 알 수 있듯이 H-2 모델의 평균제곱오차는 0.43으로 나타났으며 결정계수는 0.99811으로 나타났다. 마찬가지로 그림 7로 부터 H-5 모델의 평균제곱오차는 83.2, 결정계수는 0.47313임을 알 수 있다. 그림 6과 그림 7을 비교해 볼 때 평균제곱오차가 작게 나타나고 결정계수가 1에 가까운 H-2 모델의 적정성이 더 높음을 알 수 있다. 한편, 그림 6(a)와 7(a)에서 볼 때 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 도출하기 때문이다.

은닉층 수가 2개 일 경우에도 은닉층 수가 3개일 경우와 동일하게 총 96경우에 대해 학습시키고 학습모델 구조에 따른 적합성 검증을 실시하였다. 그 결과 은닉층의 노드 수가 각각 12 개일 경우가 평균제곱오차는 0.47, 결정계수는 0.99796로 나타나 최적임을 알 수 있었다.

192개의 학습결과를 토대로 종합적으로 판단할 때, 은닉층 수가 3개이고, 노드수가 각각 6개씩이며, 학습율이 0.02, 관성항이 0.80일 경우 평균제곱오차가 가장 낮고 결정계수가 가장 높은 것으로 나타나 최적의 인공신경망 학습모델 구조임을 알 수 있었다. 최적의 모델 H-2에 대한 인공신경망 학습모델 구조를 그림으로 나타내면 그림 8과 같다.

### 4.3 학습 데이터베이스를 이용한 최적 지반물성치 산정

최적의 인공신경망에 학습 시 평가항목별 4개의 입력변수와 4개의 출력변수의 범위는 표 5와




그림 8. 최적 인공신경망 학습모델 구조

표 5. 입·출력 변수 범위

입력변수	최소값	최대값	출력변수	최대값	최소값
상층 암반 탄성계수(GPa)	0.05	1.50	상반 천단(mm)	0.00	30.0
중간층 암반 탄성계수(GPa)	0.10	2.50	상반 내공(mm)	-2.00	20.0
하층 암반 탄성계수(GPa)	0.10	3.00	하반 천단(mm)	0.00	40.0
측압계수(Ko)	0.30	1.30	하반 내공(mm)	-2.00	25.0

같이 사용하였다. 계측변위와 근접한 변위를 빠른 시간 안에 찾기 위해 최대 및 최소값을 정하여 입력하였다.

그림 9는 최적의 지반물성치를 산정하기 위한 순서도를 나타낸 것이다. 학습이 수행된 인공신경망 변위 값과 계측변위의 차이가  $\pm 2.00$  mm 안에 들어 올 때까지 반복수행 하였으며 결과 값에 만족하는 경우, 최적의 지반물성치로 산정하였다. 단,  $\pm 2.00$  mm는 터널 높이의 약  $1/5,000(=2 \text{ mm}/10 \text{ m})$ 에 해당하는 충분히 작은 값으로 판단되어 사용하였다. 최적의 모델로 학습된 인공신경망에 적용하였을 때 지층의 측압계수는 0.536으로 나타났다. 또한 탄성계수는 실시설계 물성치와는 차이를 보이며 상층의 경우 0.271 GPa로 나타났으며, 중간층과 하층의 경우 각각 0.274 GPa과 2.911 GPa로 나타났다. 최적의 학습 데이터베이스를 사용하여 구한 최적의 지반 물성치인 값을 설계 시에 사용한 물성치인 표 1에 근거하여 지층을 추정하였다. 그 결과 상층과 중간층은 5 등급 지층에 해당되고, 하층은 실제 4 등급 지층에 해당되는 것으로 나타났다. 따라서 설계 시에 사용된 3개의 지층은 실제 2개로 나타났다.

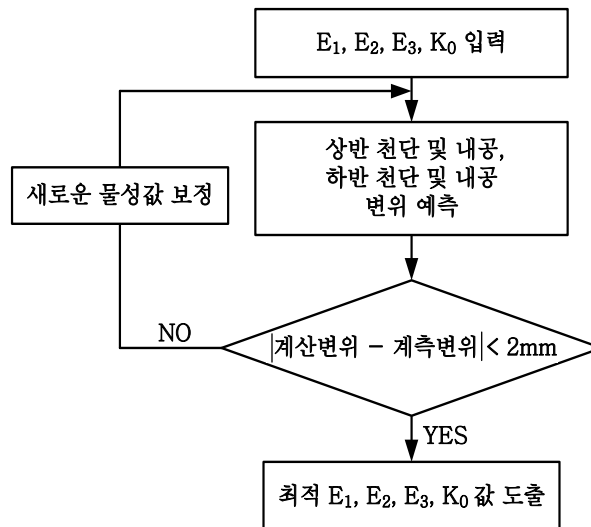


그림 9. 최적 지반물성치 산정을 위한 순서도

표 6. 계측변위와 인공신경망 예측변위 비교

(단위: mm)

변 위	상반굴착 시		하반굴착 시	
	천단침하	내공변위	천단침하	내공변위
계측 시	5.20	1.30	13.0	6.50
인공신경망 예측 시	6.92	0.97	11.26	5.39
오 차	1.72	0.33	1.74	1.11

최적의 인공신경망 학습모델을 통해 지반물성치의 불확실성을 최대로 줄였을 때 얻은 출력결과를 표 6에 나타내었다. 이 때 예측된 변위값들과 계측된 변위값들과의 오차가 모두  $\pm 2.00$  mm 이내로 비교적 잘 일치함을 알 수 있었다. 따라서 터널 굴착 시 얻어지는 내공변위 계측자료를 활용하여 인공신경망에 의한 역해석을 실시함으로써 설계 시 사용된 지반물성치들의 불확실성을 줄일 수 있을 것으로 판단된다.

## 5. 결 론

본 연구에서는 호남고속철도 제 ○○공구의 산악터널을 대상으로 내공변위에 직접적인 영향을 주는 암반의 탄성계수와 측압계수를 역해석을 통해 산정하였다. 연구결과 다음과 같은 결론을 도출할 수 있었다.

1. 학습자료 총 81개를 이용하여 은닉층 수와 은닉층의 노드 수 및 학습율과 관성항을 변화시키며 인공신경망에 학습시켰다. 그 결과, 최적의 인공신경망 모델은 은닉층 수 3 개에서 각각 6개의 노드를 갖추고 있으며 학습율은 0.02, 관성항은 0.80일 때임을 알 수 있었다.
2. 최적의 모델로 학습된 인공신경망을 적용하여 설계 시에 사용되었던 물성치와 비교한 결과 상층과 중간층은 5 등급 지층에 해당되고, 하층은 실제 4 등급 지층에 해당되는 것으로 추정되었다. 따라서 설계 시에 사용된 3개의 지층은 실제 2개로 나타났다. 한편 이때 얻어진 변위들은 모두 계측변위와  $\pm 2.00$  mm 오차 이내로 산정 물성치의 신뢰도가 높은 것으로 검증되었다.

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 유념해야한다.

---

향후 유사 터널현장에서 설계 시 터널 변위 계측자료를 인공지능망 학습데이터로 활용하여 지반 물성값의 적정여부를 체계적으로 판단하는데 본 연구에서 제안한 방법이 유용하게 사용될 수 있을 것으로 판단된다. 나아가서 터널의 안정적인 설계 및 시공이 가능해지길 기대해 본다.

## 참고문헌

1. 김대수(1992), “신경망 이론과 응용 1 = Neural networks : theory and applications”, 하이테크정보, 364p.
2. 김문겸, 장정범(1995), “유한요소-경계요소 조합에 의한 터널 계측결과의 역해석”, 한국암반공학회 논문집, 제5권, 제3호, pp. 205-213.
3. 김종규(2011), “인공지능망 기법에 근거한 역해석을 이용한 터널 지보패턴의 적정성 평가 사례 연구”, 수원대학교 대학원 박사학위 논문, 94p.
4. 김주화, 채영수, 박연준(2008), “수평경사계를 이용한 토사터널의 선형변위 예측”, 한국암반공학회 논문집, 제18권, 제5호, pp. 355-365.
5. 대우건설(2009), “호남고속철도 제 ○○공구 노반신설 기타공사 터널해석보고서”, 1074p.
6. 송기일, 조계춘(2006), “터널 사전보강 영역의 효과적 수치해석을 위한 등가 물성치 결정 기법”, 한국터널공학회 논문집, 제8권, 제2호, pp. 151-163.
7. 유충식, 김선빈, 유광호(2008), “IT 기반의 터널 최적 설계를 위한 시스템 개발”, 한국터널공학회 논문집, 제10권, 제2호, pp. 153-166.
8. 이종구(2002), “인공지능망을 이용한 터널 거동예측 시스템 개발”, 경희대학교 대학원, 박사학위 논문, 122p.
9. 임안식(2006), “인공지능망을 이용한 터널 굴착에 따른 지표면침하 및 터널거동 예측”, 경북대학교 대학원, 박사학위 논문, 224p.
10. 전양수(2002), “역해석을 이용한 터널의 설계정수산정에 관한 연구”, 전남대학교 대학원 박사학위 논문, 123p.
11. 정용훈(2001), “터널 발파에서 비장약량 및 진동속도 예측을 위한 신경망 이론의 적용”, 서울대학교 대학원 석사학위 논문, 107p.
12. 한명식, 양인재, 김광명(2002), “인공지능망을 이용한 터널구간의 암반분류 예측”, 한국터널공학회 논문집, 제4권, 제4호, pp. 277-286.
13. Fakhimi, A., Salehic, D., Mojtabei, N. (2004), “Numerical back analysis for estimation of soil parameters in the Resalat tunnel project”, Tunnelling and Underground Space Technology, Vol. 19, pp. 56-67.



14. Itasca Consulting Group, Inc. (2005), "Fast Lagrangian Analysis of Continua", Ver. 5.0, Itasca Consulting Group, Minnesota, USA.
15. Math Works Inc. (2010), "MATLAB : Neural Network Toolbox™ User's Guide", Ver. R2011b, Math Works Inc., 404p.
16. Wasserman, P.D. (1989), "Neural computing : Theory and practice", Anza Research Inc, 230p.
17. Zhang, L.Q., Yue, Z.Q., Yang, Z.F., Qi, J.X., Liu, F.C. (2006), "A displacement - based back-analysis method for rock mass modulus and horizontal in situ stress in tunneling - illustrated with a case study", Tunnelling and Underground Space Technology, Vol. 21, pp. 636-649.