

투수 및 이완하중 파악을 위한 터널 라이닝의 인공신경망 역해석

Tunnel-lining Back Analysis Based on Artificial Neural Network for Characterizing Seepage and Rock Mass Load

공 정 식¹ Kong, Jung-Sik

최 준 우² Choi, Joon-Woo

박 현 일³ Park, Hyun-Il

남 석 우⁴ Nam, Seok-Woo

이 인 모⁵ Lee, In-Mo

Abstract

Among a variety of influencing components, time-variant seepage and long-term underground motion are important to understand the abnormal behavior of tunnels. Excessiveness of these two components could be the direct cause of severe damage on tunnels, however, it is not easy to quantify the effect of these on the behavior of tunnels. These parameters can be estimated by using inverse methods once the appropriate relationship between inputs and results is clarified. Various inverse methods or parameter estimation techniques such as artificial neural network and least square method can be used depending on the characteristics of given problems. Numerical analyses, experiments, or monitoring results are frequently used to prepare a set of inputs and results to establish the back analysis models. In this study, a back analysis method has been developed to estimate geotechnically hard-to-known parameters such as permeability of tunnel filter, underground water table, long-term rock mass load, size of damaged zone associated with seepage and long-term underground motion. The artificial neural network technique is adopted and the numerical models developed in the first part are used to prepare a set of data for learning process. Tunnel behavior, especially the displacements of the lining, has been exclusively investigated for the back analysis.

요 지

터널과 관련된 여러 영향인자중 시간의 따른 투수상태와 지반의 장기거동은 터널의 이상 거동을 이해하는데 있어서 중요하다. 터널은 이러한 인자에 의해서 심각한 손상을 입을 수 있으나 시공 후 이러한 인자들에 의해 발생한 영향을 정량적으로 분석해 내는 것은 쉽지 않다. 입력과 출력간의 상관관계가 비교적 독립적이라면 터널거동에 미치는 인자들의 영향은 역해석 기법을 적용하여 예측할 수 있다. 모델을 구성하는 입출력 자료의 특성에 따라 인공신경망 기법이나 최소제곱법 등 다양한 역해석 방법이 개발 될 수 있으며 수치해석, 실험 또는 계측 결과가 역해석 모델의 구성 및 검증에 위해 쓰일 수 있다. 본 연구에서는 시공 후 터널의 내공 변위 변화로부터 투수 및 지반의 장기거동과 관련된 인자들 중 배수재의 투수계수, 지하수위, 장기 이완 하중 크기 및 암반 손상 패턴 등의 변화에 의한 영향을 정량적으로 분석할 수 있는 역해석 기법을 개발하였다. 역해석은 인공신경망 기법을 적용하였으며 학습데이터 확보를 위해 수치해석 모델이 개발 되고 다양한 하중 상태에 대한 거동 분석이 이루어졌다.

Keywords : Artificial neural network, Long-term behavior, Rock mass load, Seepage, Tunnel-lining

1 고려대학교 사회환경시스템공학과 조교수 (Prof., Dept. of Civil and Environmental Engrg., Korea Univ.)

2 고려대학교 사회환경시스템공학과 (Dept. of Civil and Environmental Engrg., Korea Univ.)

3 정희원, 삼성물산(주)건설부문 기술연구소 선임연구원 (Member, Senior Researcher, R & D Team, Samsung Corporation)

4 정희원, 삼성물산(주)건설부문 토목기술팀 (Member, Manager, Civil Works Division, Samsung Corporation)

5 정희원, 고려대학교 사회환경시스템공학과 교수 (Member, Prof., Dept. of Civil and Environmental Engrg., Korea Univ., inmollee@korea.ac.kr, 교신저자)

* 본 논문에 대한 토의를 원하는 회원은 2007년 2월 28일까지 그 내용을 학회로 보내주시기 바랍니다. 저자의 검토 내용과 함께 논문집에 게재하여 드립니다.

1. 서론

지중에 위치하고 있는 터널은 다양한 원인에 의해 터널의 안정성이 위협 받거나 사용성에 문제가 발생하기도 한다. 특히 장기 거동에 대한 터널의 안전성 확보 및 유지를 위해서 터널 주변 지반의 투수상태 및 지중응력상태를 파악하는 것이 매우 중요한 과제이다. 그러나 현재까지 라이닝 배면에 위치한 지반의 투수상태나 작용하중을 측정할 수 있는 효율적 방법이 제시되어 있지 않으며, 측정이 이루어지는 경우에도 측정 결과로부터 관련 영향인자들의 변동 상태를 분석 해내는 과정에 포함된 다양한 불확실성으로 인해 분석 결과의 신뢰도에 문제가 제기되고 있다. 지반응력을 간접적으로 측정하는 한국시설안전기술공단(2003)의 연구와 내공변위에 의한 콘크리트라이닝의 건전도를 파악하는 이준석(2002)의 연구가 진행되어 있으나, 터널의 변상 관련 주요 영향 인자인 지하수와 소성영역의 변화에 의한 영향이 고려되지 않았다.

본 연구에서는 터널 라이닝의 거동으로부터 지반의 투수상태와 하중상태를 예측하고, 이로부터 변상유발 주요 요인들의 시간에 따른 변화를 분석할 수 있는 방법을 개발하였다. 터널 라이닝의 거동 분석(최준우, 2005)을 통해 토사터널에 대해서는 부직포 투수계수 저하와 수위 변화를 주요 변상유발 인자로 보았으며, 암반터널에 대해서는 암반의 점소성 거동과 이완하중을 주요 변상유발 인자로 보았다. 이를 이용하여, 변상 발생 터널 및 시공 후 공용중인 터널 주변 지반의 투수상태와 하중상태를 예측할 수 있는 역해석 기법을 인공신경망을 토대로 개발하였다.

2. 매개변수 분석

2.1 개요

인공신경망 기법을 이용한 역해석 기법의 효율성을 높이기 위해서는 학습에 사용되는 입력 인자의 변동에 따른 결과의 변동 패턴이 서로 유사성이 적고 상호 독립적이어야 한다. 이러한 기본 개념을 토대로 검증 가능한 다양한 내공 변위 중 입력 인자의 변화에 따른 독립적 패턴을 확보할 수 있는 내공 변위의 설정이 중요하다.

역해석을 통한 터널 상태 진단 시 고려해야할 효율적 영향 인자의 파악을 위해, 콘크리트 라이닝의 거동에 영향을 미칠 수 있는 영향인자들에 대한 매개변수 분석을 실시하였다. 이를 위해 'PENTAGON-2D' 해석 프로그램이 사용되었다.

상기 해석 프로그램은 지반 및 구조물의 상호거동을 2차원 연속체 모델과 유한요소법을 이용하여 해석하는 프로그램이며, 지하수 해석과 역학적 해석의 독립적 수행 가능하며 두 하중이 동시에 작용하는 경우에 대해서도 하중 단계별 중첩법에 의한 분석 결과의 통합으로 연계해석을 수행할 수 있다. 토사터널을 대상으로 투수해석 인자들을 고려하여 매개변수 분석을 실시하였고, 암반터널을 대상으로 지반의 장기거동 인자들에 대해 매개변수 분석을 실시하였다.

2.2 투수해석 인자들에 대한 매개변수 분석

투수해석 인자들에 대한 매개변수 분석을 위한 토사터널의 해석 단면과 물성치는 그림 1에 나타내었으며, 지하철 5호선구간의 터널 단면을 기준으로 한 것이다. 입력치 변화에 따른 내공 변위의 패턴 변화를 분석하기 위하여 지반 물성치를 바꾸어가면서 매개변수 분석을 실시하였다. 투수계수의 변화에 따른 내공변위의 변화 분석을 위해 시공 후 터널에 대해 부직포의 투수계수를 1cm/sec에서 0.25cm/sec로 변화시키며 결과를 해석하였다.

그림 2는 터널 주변의 수위가 각각 터널 직경의 2.5배, 3배, 4배인 상황에서, 시공 후 부직포 투수계수가 저




그림 1. 투수해석 매개변수분석을 위한 해석단면




그림 2. 수위에 대한 매개변수 분석결과

하될 경우 발생하는 콘크리트 라이닝의 변위를 나타낸 것이다. 터널이 지하 수위면에서 더 깊은 곳에 위치하면, 콘크리트 라이닝의 천단변위 발생량이 더 큰 것을 알 수 있다.

그림 3은 지반의 투수계수에 다른 상황에서 시공후 부직포 투수계수가 감소할 경우 발생하는 내공변위를 나타낸 것이다. 지반의 투수계수가 클수록, 즉 지반 투수계수와 설치전 부직포 투수계의 비율(K_f^{ini}/K_{gnd})이 작을수록, 콘크리트라이닝의 내공변위가 크게 나타남을 확인하였다. 이 때, 설치전 부직포의 투수계수는 1cm/sec로 가정하였고, 그라우팅의 투수계수는 지반의 투수계수의 1/20로 가정하였다(Barton, 2002). 그라우팅의 물성치도 콘크리트 라이닝의 내공변위에 영향을 미칠 수 있으나, 그라우팅 부분의 물성치는 지반의 물성치에 영향을 많이 받아 독립적이지 않다. 그라우팅의 물성치 역시 실측이 쉽지 않기 때문에 인공신경망을 이용한 역해석에서 그라우팅 부분의 투수계수는 공칭투수계수를 이용하였다.

이외에도 다양한 인자들에 대한 터널 라이닝의 내공 변위 변화를 살펴보았으며, 매개변수 분석을 실시한 인자들과 적용 범위와 결과를 표 1에 에 나열하였다. 수위와 지반투수계수이외의 물성치가 다를 경우에도 상이




그림 3. 지반투수계수에 대한 매개변수 분석결과

표 1. 매개변수 분석을 위한 투수해석 인자들

매개변수	적용범위	천단변위(mm)		발생변위차(mm)
		최소변위	최대변위	
지하수위 (H_{in})	2.5D~4D	5.83	12.28	6.45
설치전 부직포-지반 투수계수비율 (K_f^{ini} / K_{gnd})	$1 \times 10^2 \sim 1 \times 10^5$	0	17.93	17.93
지반의 탄성계수 (E_{gnd})	30MPa~70MPa	5.70	5.85	0.15
지반의 포아송비 (ν_{gnd})	0.3~0.45	5.71	5.90	0.19
지반의 점착력 (C_{gnd})	0.5kPa~2kPa	5.82	5.83	0.01
지반의 내부마찰각 (ϕ_{gnd})	20°~40°	5.82	5.85	0.03
지반의 측압계수 (K_{0gnd})	0.3~0.7	5.76	5.93	0.17

한 변위가 발생하는 것을 볼 수 있으나, 그 차이가 지반 투수계수나 수위에 의한 차이보다 상대적으로 작았다. 따라서, 인공신경망을 통한 투수계수 및 수위 상승량 예측에는 콘크리트라이닝의 천단과 측벽 변위와 함께 지하수위 및 라이닝 설치 직전의 부직포-지반 투수계수 간의 비율을 사용하였다.

2.3 지반의 장기 거동에 대한 매개변수 분석

지반의 장기거동인자들에 대한 매개변수 분석을 위한 암반터널의 해석 단면과 물성치는 그림 4와 표 2에




그림 4. 장기거동 매개변수분석을 위한 해석단면

표 2. 장기거동 매개변수분석을 위한 물성치

구분	풍화도	풍화암(D=0)	풍화암(D=0.6)
단위중량 (γ_t , kN/m ³)	20	23	23
점착력 (c, kPa)	30	250	160
내부마찰각 (ϕ , °)	30	35	24
탄성계수 (E, MPa)	20	500	350
포아송비 (ν)	0.35	0.3	0.3
측압계수 (K_0)	0.5	0.5	0.5

나타내었으며, 도로터널 표준단면(한국도로공사, 2003)을 대상으로 한 것이다. 손상범위에 대한 매개변수 분석을 제외한 나머지 해석에서는 과발파 손상범위를 3m로 가정하였으며, 발파손상정도를 $D=0.6$ 으로 가정하였다. 시공후 발생하는 이완하중은 콘크리트 라이닝에 재하되는 것으로 가정하였다.

그림 5는 지반의 탄성계수에 따른 매개변수 분석의 결과이다. 같은 크기의 이완하중이 발생할 경우 지반 탄성계수가 작을수록 콘크리트 라이닝의 변위가 크게 발생하고 있다. 그림 6은 터널 심도에 따른 매개변수 분석결과로서, 터널 심도가 달라도 이완하중이 같다면, 콘크리트 라이닝의 변위는 크게 다르지 않음을 보여주고 있다. 하지만, 이는 연속체(solid)요소로 지반을 묘사한 수치해석 모델의 한계로 실제 거동과 차이가 있다. 실제 상태에서의 이완하중은 손상된 암반이 연속체가 아닌 불연속체로 거동하면서 발생하는 것이기 때문에, 보다 정확한 분석을 위해서 이완영역 확장에 따른 이완하중을 단계별로 계산한 후 라이닝에 직접 재하하여 해석하였다. 일반적으로 실제 암반에서 암반의 이완하중이 발생하게 되면, 얕은 터널에서는 지표면 근처까지 이완하중으로 작용할 가능성이 높으며, 깊은 터널에서는 이완하중이 터널 주변 손상영역까지만 분포하고 더 이상 전이되지 않을 가

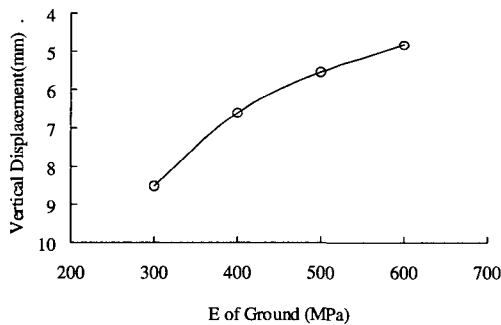


그림 5. 지반탄성계수에 대한 매개변수 분석결과

능성이 높다. 즉, 실제 거동 시 터널 심도에 의한 이완하중의 발생경향이 다르므로, 이완하중의 발생에 대한 터널 심도의 영향을 고려하는 것이 타당하다. 그러나, 본 연구에 사용된 프로그램이 기능의 한계를 가지고 있는 연속체해석 전용 프로그램이기 때문에, 심도에 따른 이완하중 발생경향을 파악하는 데에는 한계가 있어, 심도에 따른 이완하중 발생경향은 고려하지 않았다.

지반의 탄성계수 이외의 지반 물성치에 대한 매개변수 분석결과는 표 3에 나타내었다. 지반 탄성계수 이외의 물성치가 다를 경우에도 상이한 변위가 발생하는 것을 확인할 수 있으나 그 차이가 탄성계수에 의한 차이보다 상대적으로 작아 인공신경망을 위한 변수로 활용하기 어렵다고 판단하였다.

따라서, 인공신경망을 통한 이완하중 및 소성 발생범위 예측에는 콘크리트라이닝의 천단 및 측벽 변위와 함께 지반의 탄성계수를 사용하였다.

3. 인공신경망 이론

3.1 개요

인공신경망은 뉴런(neuron)으로 불리는 입출력과

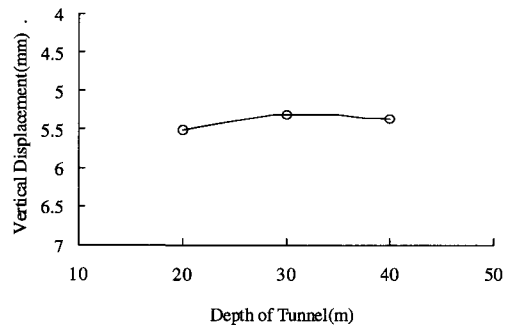


그림 6. 터널의 심도에 대한 매개변수 분석 결과

표 3. 매개변수 분석을 위한 지반의 장기거동관련 인자들

매개변수	적용범위	천단변위 (mm)		발생변위차 (mm)
		최소변위	최대변위	
터널의 심도(C)	20m~40m	5.30	5.52	0.22
지반의 탄성계수(E_{gnd})	300MPa~600MPa	4.81	8.5	3.69
지반의 포아송비(ν_{gnd})	0.25~0.35	5.21	5.83	0.62
지반의 점착력(C_{gnd})	160kPa~400kPa	5.49	5.61	0.12
지반의 내부마찰각(ϕ_{gnd})	25°~40°	5.51	5.60	0.09
지반의 축입계수($K_{0(gnd)}$)	0.4~0.7	5.32	6.01	0.69
손상된 지반의 탄성계수(E_D)	250MPa~450MPa	5.47	5.74	0.27
손상된 지반의 내부마찰각(ϕ_D)	20°~30°	5.51	5.91	0.40




그림 7. 인공신경망의 Layer 구성

관련된 단위처리개체(simple processing unit)로 이루어진 데이터 처리 방법이다(Kohonen, 1988; Khanna, 1989; Aleksander and Morton, 1990; Hertz *et al.*, 1991; Dowla and Rogers, 1995; Hagan *et al.*, 1996). 인공신경망에서 뉴런으로의 입력은 weight(w)와 bias(b)에 의해 가중 입력값이 되며, 이 값은 전달함수(transfer function)를 통해 출력된다. 즉, 실제 출력은 선택된 전달함수에 의존하게 된다. 일반적으로 전달함수는 사용자에게 의해 선택되며, 여기서 weight(w)와 bias(b)는 뉴런의 입력과 출력관계가 일정한 목표를 만족하도록 하는 학습(learning rule)에 의해 조정 가능한 스칼라 값이다(이성진 등, 2002).

그림 7은 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성된 본 논문에서 사용한 인공신경망의 예이다. 여기서, 입력층의 뉴런들은 해석에서 고려되어야 하는 입력 설계변수이고, 반면에 출력층의 뉴런은 목표 출력값을 의미한다. 각 뉴런은 다음 층의 모든 뉴런들과 연결고리를 갖고 있으나 동일 층에서 각 뉴런간의 연결고리는 주어지지 않는다. 각 뉴런은 sigmoid 함수로 명명되는 활성화함수를 포함하고 있으며, 가중치는 모든 신경망의 연결고리에 할당되게 된다.

3.2 역전파(Backpropagation) 알고리즘

퍼셉트론 학습규칙(perceptron learning rule)과 LMS(least mean square) 알고리즘은 단일층의 퍼셉트론 네트워크를 훈련시키기 위해 개발 되었는데, 이는 단지 선형분리구분문제(linearly separable classification problems)만을 풀 수 있다는 단점이 있었다. 따라서, 이러한 단점을 극복하기 위해 다층 네트워크(multilayer network)이 개발되었으나 이러한 네트워크를 학습시킬 수 있는 알고리즘을 개발 할 수는 없었다. 이후, 1980년대에 들어서 역전파 알고리즘(backpropagation algorithm)이 개발됨으로써 현재까지는 역전파 알고리즘으로 훈련 되어지는 다층퍼셉트론(multilayer perceptron)이 가장 널리 사용되는 인

공신경망 모델이다(Hagan et al. 1996).

역전파 알고리즘은 근사적 경사하강추적 알고리즘(approximate steepest descent algorithm)이며, 수행지수(performance index)로는 식 (4)와 같은 평균 제곱오차(mean square error)를 식 (5)과 같이 산정하여 근사적으로 이용한다.

$$F(x) = E[e^T e] = E[(t - a)^T (t - a)] \quad (4)$$

$$\hat{F}(x) = [t(k) - a(k)]^T [(t(k) - a(k))] = e^T(k)e(k) \quad (5)$$

여기서, $F(x)$ = 평균제곱오차, $\hat{F}(x)$ = 근사적 평균제곱오차, e = 오차행렬, t = 목표값, a = 출력값, k = iteration 횟수 이다.

3.3 일반화 기법 및 정규화를 이용한 학습

인공신경망 모델의 적용 시에 발생하는 문제중 하나가 과적합(overfitting)문제이다. 훈련에 사용된 자료에 대한 오차는 매우 작은 값을 얻도록 해주지만, 그 신경망에 제공된 새로운 자료에서는 오차가 더 커질 수 있다는 것이다. 신경망 내의 미지수의 개수가 훈련 자료의 총 개수보다 훨씬 작다면 과적합의 문제는 발생할 가능성이 매우 작다. 따라서 많은 자료를 확보하는 것이 필요하지만, 충분히 많은 자료가 확보되지 않은 상황에서는 일반화 기법을 이용하여 신경망의 학습결과에 대한 신뢰도를 확보할 수 있다. 이러한 일반화 기법은 Bayesian방법과 오차가 목표치에 도달하기 전에 학습을 중단시키는 Early stopping방법이 주로 이용되는데, 본 연구에서는 보다 좋은 일반화 결과를 제공하는 것으로 알려져 있는 Bayesian방법을 이용하였다. 평균 제곱오차로 이루어진 전형적인 수행함수(performance function)에 신경망의 weight와 bias의 평균제곱합에 대한 항을 추가하여 보다 일반적인 학습이 가능하도록 하였다(이성진, 2002; Foresee and Hagan, 1997).

더불어 보다 효과적인 신경망의 학습을 위해 각각의 입력자료들을 최대값과 최소값을 기준으로 $\{-1, 1\}$ 사이에서 정규화하는 작업을 수행할 수 있도록 하였다. 훈련에 적용되는 자료의 선처리 과정으로서 입력자료(p_n) 및 목표출력값(t_n)이 식 (6)과 같이 정규화 되었다(Kurup and Dudani, 2002).

$$p_n = 2(p - p_{\min}) / (p_{\max} - p_{\min}) - 1$$

$$t_n = 2(t - t_{\min}) / (t_{\max} - t_{\min}) - 1 \quad (6)$$

여기서, \mathbf{p} = 입력행렬, \mathbf{t} = 목표출력값, \mathbf{p}_n = 정규화된 입력행렬, \mathbf{t}_n = 정규화된 목표출력값, \mathbf{p}_{max} = 입력물성치에서 최대값으로 구성된 입력행렬, \mathbf{p}_{min} = 입력물성치에서 최대값으로 구성된 입력행렬, \mathbf{t}_{max} = 목표출력값들 중에서 최대값, \mathbf{t}_{min} = 목표출력값들 중에서 최소값이다.

정규화된 자료들이 가중치 값들을 구하기 위해 인공신경망 모델의 학습과정에 사용된다. 따라서, 최종적으로 구해진 정규화된 출력값은 식 (7)을 통하여 실제적인 출력값으로 환산될 수 있다.

$$\mathbf{t} = 0.5(\mathbf{t}_n + 1) \cdot (\mathbf{t}_{max} - \mathbf{t}_{min}) + \mathbf{t}_{min} \quad (7)$$

정규화된 출력값 \mathbf{t}_n 은 식 (8)과 같이 내부입력벡터의 전파에 의하여 구할 수 있다. 정규화된 입력물성치와 최종적인 출력 값의 관계식은 식 (6)과 식 (8)로부터 식 (9)와 같이 정리될 수 있다. *logsig*는 *logsigmoid*함수로서 식 (10)과 같이 나타낼 수 있다.

$$\mathbf{t}_n = \mathbf{w}_2 \times \text{logsig}(\mathbf{w}_1 \times \mathbf{p}_n + \mathbf{b}_1) + \mathbf{b} \quad (8)$$

$$\mathbf{t} = 0.5 \times (\mathbf{w}_2 \times \text{logsig}(\mathbf{w}_1 \times \mathbf{p}_n + \mathbf{b}_1) + \mathbf{b}_2 + 1) \times (\mathbf{t}_{max} - \mathbf{t}_{min}) + \mathbf{t}_{min} \quad (9)$$

$$\text{logsig}(X) = \frac{1}{1 + \exp(-X)} \quad (10)$$

여기서, \mathbf{w}_1 = 입력층 뉴런들과 은닉층 뉴런들과의 연결가중치 행렬, \mathbf{b}_1 = 은닉층 뉴런들에 대한 bias 행렬, \mathbf{w}_2 = 은닉층 뉴런들과 출력층 뉴런들과의 연결가중치 행렬, \mathbf{b}_2 = 출력층의 bias 행렬이다.

4. 인공신경망을 이용한 역해석

4.1 개요

인공신경망(Artificial Neural Networks)이론을 활용하여, 시공 후 터널에 발생하는 변위를 계측하여 토사터널에서는 부직포 투수계수저하와 수위상승량, 암반 터널에서는 이완하중 및 점소성 거동의 진행정도가 각각 어느 정도인지 예측하였다. 토사터널에서의 이완하중과 암반 터널에서의 투수계수저하는 투수 및 암반거동에 의한 터널 라이닝의 거동 분석(최준우, 2005)의 터널 변상 발생과정 분석에 따르면 발생 가능성이 낮으므로 해석에 포함하지 않았다. 인공신경망의 학습 자료는 유한요소 해석 프로그램인 'PENTAGON-2D'의 해석 결과를 사용하

였으며, 인공신경망의 학습 및 검증에는 'MATLAB' 프로그램을 활용하였다.

4.2 수리조건예측을 위한 인공신경망의 적용

인공신경망을 이용하여 시공후 터널의 부직포 투수계수와 수위상승량을 예측하기 위한 학습 및 검증 데이터를 확보하기 위해 그림 8과 같은 단면에 대하여 수치해석을 실시하였다.

터널 굴착 중에는 부직포 투수계수를 1cm/sec로 가정하였고, 시공이 완료된 후 부직포 투수계수를 저하시키고, 지하수위를 상승시켜 해석을 수행하였으며, 시공 후 추가로 발생한 변위를 역해석에 활용하였다. 수치해석을 통해 초기수위, 증가수위, 지반의 투수계수, 부직포의 투수계수를 달리한 85가지 상황에서의 천단 및 측벽 변위를 구하였고, 이 85개의 데이터에 Bayesian기법을 적용하여 수치해석 결과에 대한 학습을 수행하였으며, 인공신경망 모델 두가지(A-I, A-II)를 구성하였다.

부직포와 지반의 투수계수는 절대값이 아닌 부직포-지반 투수계수의 비율(K_f / K_{gnd})을 입출력 변수로 활용하였다. 모델 A-I은 그림 9(a)에 나타난 바와 같이 입력유니트 3개, 은닉 유니트 6개 그리고 출력 유니트 2개의 노드를 갖는 인공신경망구조(3×6×2)로 구성되어 있다. 입력변수는 초기수위(H_{ini}), 천단과 측벽의 내공변위(D_y, D_x)이며, 출력변수는 시공 후 콘크리트 라이닝에 추가적인 변위가 발생하였을 때의 부직포-투수계수 비율(K_f / K_{gnd})과 수위상승량(ΔH)이다. 모델 A-II는 그림 9(b)와 같이 A-I의 인공신경망 모델의 입력변수에 부직포 설치전의 부직포-지반의 투수계수비율(K_f^{ini} / K_{gnd})를 추가하여 입력 유니트 4개, 은닉 유니트 6개 그리고 출력 유니트 2개의 노드를 갖는 인공신경망구조(4×6×2)로






그림 8. 수리조건예측 해석을 위한 해석 단면

구성되어 있다.

부직포-지반투수계수 비율의 학습 및 검증 결과는 그림 10과 같으며, 수위상승량에 대한 학습 및 검증결과는 그림 11과 같다. 인공신경망의 검증에는 표 4의 데이터 15개를 사용하였다. 그림 10의 부직포-지반투수계수비율에 대한 모델 A-I을 이용한 학습 및 검증의 상관계수는 각각 0.946, 0.952이고, 모델 A-II를 이용한 학습 및 검증의 상관계수는 0.924, 0.956으로 모델 A-I을 이용한 결과와 유사하게 나타났다.




(a) 인공신경망 모델 A-I




(b) 인공신경망 모델 A-II

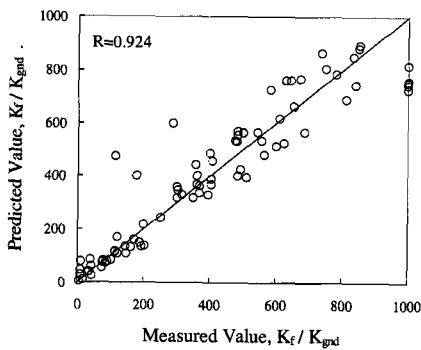
그림 9. 수리조건예측을 위한 인공신경망의 구성




(a) 인공신경망 모델 A-I 학습결과



(b) 인공신경망 모델 A-I 검증결과



(c) 인공신경망 모델 A-II 학습결과




(d) 인공신경망 모델 A-II 검증결과


그림 10. 부직포-지반 투수계수비율에 대한 학습 및 검증결과

그림 11의 수위상승에 대한 모델 A-I을 이용한 학습 및 검증의 상관 계수는 0.931, 0.965로 나타났으며, 모델 A-II을 이용한 학습 및 검증의 상관 계수는 0.923, 0.834로 나타나 모델 A-II보다 모델 A-I가 수위 상승량 예측에 보다 적합한 것으로 나타났다.


부직포 설치전의 부직포-지반 투수계수 비율을 고려하지 않은 A-I모델과 이를 고려한 A-II모델의 시공 후 부직포-투수계수 비율의 학습결과와 검증결과 및 수위상승에 대한 학습결과는 같은 수준의 정확도를 갖는다.




(a) 인공신경망 모델 A-I 학습결과



(b) 인공신경망 모델 A-I 검증결과



(c) 인공신경망 모델 A-II 학습결과



(d) 인공신경망 모델 A-II 검증결과

그림 11. 수위상승에 대한 학습 및 검증결과

표 4. 수리조건 예측을 위한 인공신경망 검증 데이터

초기수위 (H_{ini} , DT)	증가수위 (ΔH , m)	지 반 투수계수 (K_{gnd} , cm/sec)	시공후 부직포 투수계수 (K_f , cm/sec)	부직포-지반 투수계수 비율 (K_f / K_{gnd})		천단변위 (D_y , mm)	측벽변위 (D_x , mm)
				설치전	시공후		
18	13.0	0.00120	0.250	833.333	208.333	3.923	-0.165
4	4.0	0.00150	0.060	666.667	40.000	15.238	-5.005
4	3.0	0.00234	0.710	427.698	303.770	3.889	-1.022
4	4.0	0.00114	0.400	877.193	350.877	4.407	-1.092
15	8.9	0.00080	0.080	1250.00	100.000	7.364	-1.744
15	12.2	0.00218	0.728	459.764	334.928	2.784	0.149
6	5.0	0.00182	0.700	549.348	384.544	2.576	0.303
7	5.9	0.00120	0.100	833.333	83.333	11.736	-3.488
10	1.2	0.00154	0.713	649.985	463.572	1.213	-0.231
9	4.9	0.00079	0.530	1272.37	674.693	-0.455	0.571
12	5.4	0.00102	0.820	978.555	802.097	-1.415	1.243
5	2.2	0.00124	0.985	806.622	794.233	0.003	0.293
11	2.3	0.00128	0.700	779.994	545.996	0.335	0.081
7	1.1	0.00040	0.270	2500.00	675.000	-0.617	0.296
5	5.0	0.00060	0.395	1666.66	658.333	0.293	0.306

그러나 수위 상승에 대한 검증결과를 보면 A-I모델의 경우에 더 정확한 예측이 가능함을 확인하였다. 따라서, 부직포 투수계수 저하와 수위상승량 예측을 위한 인공 신경망의 구성에는 설치 전 부직포-지반 투수계수의 비

율이 입력변수로서 고려되지 않은 A-I모델이 적합하다.

85가지 데이터를 모델 A-I을 통해 학습시켜 산정한 연결 가중치(w_1 , b_1 , w_2 , b_2)는 표 5에 나타내었으며, 그림 9(a)의 식에 적용 되는 값들이다.

4.3 이완하중 및 손상범위예측을 위한 인공신경망의 적용

인공신경망을 이용하여 터널의 이완하중 및 손상범위를 예측하기 위한 학습 및 검증 데이터를 확보하기 위해 그림 12와 같은 단면에 대하여 수치해석을 실시하였다. 굴착중 발파에 의해 터널 주변 암반이 손상을 받은 뒤, 시공 후에 점소성 거동에 의해 손상 암반이 이완되어 콘크리트 라이닝에 하중으로 작용하도록 수행하였으며, 발파로 인해 손상된 지반의 물성치는 Hoek-Brown(2002)

표 5. 모델 A-I의 연결가중치 행렬

w ₁					b ₁	
-1.511	3.165	6.139			-0.595	
-0.502	1.613	-2.118			0.183	
-1.099	1.617	4.371			-2.735	
0.090	5.024	3.072			2.167	
1.421	1.895	0.062			0.005	
-1.216	-1.972	1.396			2.704	
w ₂					b ₂	
1.483	0.509	-1.304	-4.294	0.941	0.219	1.747
4.488	-1.414	-4.035	0.503	3.024	-3.236	-0.280

주) 은닉층 $H = w_1 \times \begin{pmatrix} H_{y1} \\ D_Y \\ D_X \end{pmatrix} + b_1$,

출력층 $t = \left(\frac{K_f / K_{ygd}}{\Delta H} \right) = w_2 \times \log sig(H) + b_2$





그림 12. 이완하중과 손상범위 예측을 위한 단면



(a) 인공신경망 모델 B-I


파괴기준의 적용을 통해 산정하였다. 표 6은 수치해석을 실시한 단면에 사용된 물성치를 나타내고 있다.

85개의 데이터에 Bayesian기법을 이용한 인공신경망 학습을 수행하였으며, 인공신경망 모델은 그림 13에 나타난 바와 같이 모델 B-I, 모델 B-II의 두가지로 구성하였다. 모델 B-I은 입력 유닛 2개, 은닉 유닛 4개 그리고 출력유닛 2개의 노드를 갖는 인공신경망구조(2×4×2)로 구성되어 있다. 입력변수는 천단과 측벽의 내공변위(D_Y, D_X)이며, 출력변수는 이완하중의 크기(L_{rock})와 손상범위(A)이다. 모델 B-II는 모델 B-I의 입력 변수에 지반의 탄성계수를 추가하여 입력 유닛 3개, 은닉 유닛 4개 그리고 출력 유닛 2개의 노드를 갖는 인공신경망구조(3×4×2)로 구성되어 있다.

인공신경망 학습 및 검증 결과는 그림 14, 그림 15와 같다. 인공신경망의 검증에는 표 7의 15개 데이터를 사용하였다. 그림 14를 보면 이완하중 예측을 위해 모델 B-I을 이용한 학습 및 검증의 상관계수는 0.985, 0.969로 나타났으며, 모델 B-II를 이용한 상관계수는 0.997, 0.994로 모델 B-I과 B-II의 결과가 유사하게 나타났다.

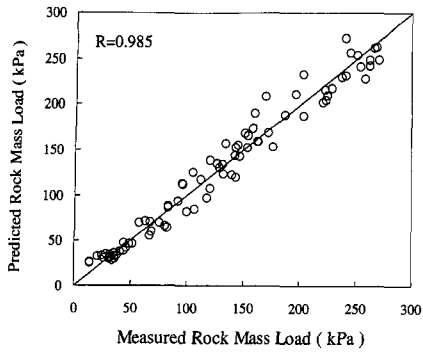
표 6. 이완하중과 손상범위 예측을 위한 물성치

구분	풍화도	풍화암(D=0)	풍화암(D=0.6)
단위중량 ($\gamma_t, \text{kN/m}^3$)	20	23	23
점착력 (c, kPa)	30	250	160
내부마찰각 ($\phi, ^\circ$)	30	35	24
탄성계수 (E, MPa)	20	입력변수	변수
포아송비 (ν)	0.35	0.3	0.3
축압계수 (K_o)	0.5	0.5	0.5

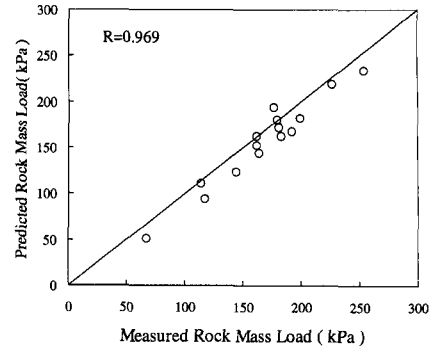


(b) 인공신경망 모델 B-II

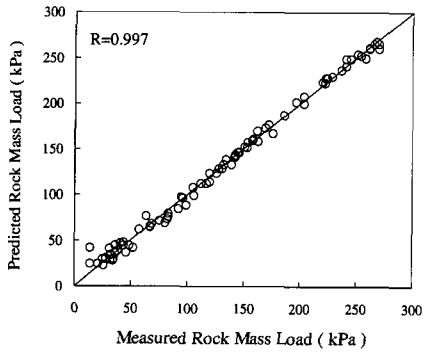
그림 13. 이완하중 및 손상범위예측을 위한 인공 신경망의 구성




(a) 인공신경망 모델 B-I 학습결과



(b) 인공신경망 모델 B-I 검증결과




(c) 인공신경망 모델 B-II 학습결과

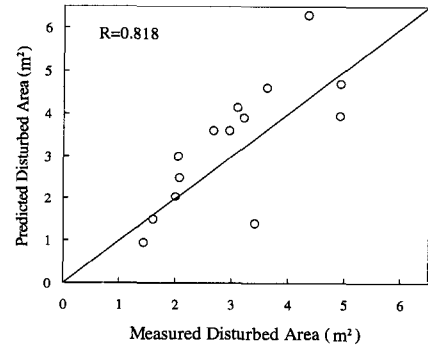


(d) 인공신경망 모델 B-II 검증결과


그림 14. 이완하중에 대한 학습결과



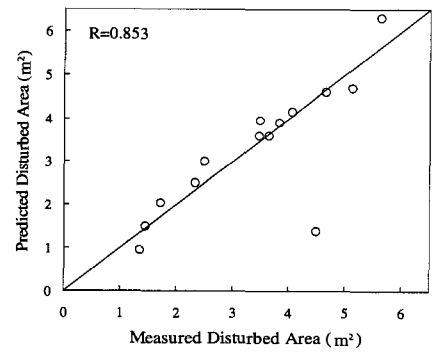
(a) 인공신경망 모델 B-I 학습결과



(b) 인공신경망 모델 B-I 검증결과



(c) 인공신경망 모델 B-II 학습결과



(d) 인공신경망 모델 B-II 검증결과

그림 15. 손상범위에 대한 학습결과

표 7. 이완하중 및 손상범위예측을 위한 인공신경망 검증 데이터

지반탄성계수 (E_{gnd} , MPa)	손상된 지반 탄성계수(E_D , MPa)	손상범위 (A , m)	이완하중 (L_{rock} , kPa)	천단변위 (D_Y , mm)	측벽변위 (D_X , mm)
560	336	3.90	254	29.278	-14.133
530	318	3.60	164	16.830	-8.376
450	270	4.70	226	29.370	-15.677
540	324	3.60	199	21.401	-10.483
600	360	6.30	192	20.561	-10.980
370	222	3.95	176	24.658	-13.271
500	300	2.50	162	17.460	-8.314
420	252	2.05	67	5.899	-2.761
550	330	4.15	183	19.173	-9.621
480	288	0.00	179	19.585	-7.690
570	342	1.40	181	20.388	-10.333
490	294	0.95	162	18.322	-8.303
520	312	4.60	144	15.030	-8.124
500	300	3.00	117	11.103	-5.470
450	270	1.50	114	12.689	-5.962

표 8. 모델 B-II의 연결가중치 행렬

w_1				b_1
-3.353	-2.220	0.166		-1.079
0.233	2.402	0.951		-1.672
-1.636	-3.886	1.430		0.275
-2.340	-1.772	-0.435		-0.269
w_2				b_2
-1.032	-0.922	0.684	-1.674	1.052
4.652	-2.264	3.334	2.840	-3.589

주) 은닉층 $H = w_1 \times \begin{pmatrix} E_{gnd} \\ D_Y \\ D_X \end{pmatrix} + b_1$,

출력층 $t = \begin{pmatrix} L_{rock} \\ A \end{pmatrix} = w_2 \times \text{logsig}(H) + b_2$

그러나, 그림 15의 손상범위예측을 위해 모델 B-I을 이용한 학습 및 검증의 상관계수는 0.783, 0.818로 모델 B-II을 이용한 학습 및 검증의 상관계수 0.868, 0.853보다 작게 나타났다. 즉, 지반의 탄성계수를 입력변수로 고려할 경우에 손상범위에 대한 인공신경망의 학습률과 예측도가 높아지는 것을 확인하였다. 따라서, 시공 후 이완하중과 손상범위 예측을 위한 인공신경망 구성에는 터널 라이닝의 천단 및 측벽 변위와 지반의 탄성계수를 고려한 모델 B-II가 모델 B-I에 보다 더 적합하다.

85가지 데이터를 모델 B-II를 통해 인공 신경망 학습을 통해 구해진 모델 B-I과 모델 B-II의 연결가중치(w_1 , b_1 , w_2 , b_2)는 각각 표 8에 나타내었으며, 그림 13(b)의 식에 적용 되는 값들이다.

참고문헌(최준우, 2005)의 해석 결과에 따르면 손상범위증가에 의해 발생하는 터널 내공변위의 크기는 이완하중 증가에 의해 발생하는 내공변위에 비해 작다. 따라서 손상범위증가에 의해 발생하는 변위는 계측시에 노이즈로 인식될 수도 있기 때문에, 본 연구에서 구성한 인공신경망 모델을 적절히 활용하기 위해서는 내공변위계측에 주의할 필요가 있다.

5. 결론

본 연구에서는 터널변상의 주요 요인인 시공 후 부직포의 투수계수 저하, 수위 증가 및 지반의 점소성 거동, 이완하중에 의한 터널 라이닝의 거동경향으로부터 시공 후 부직포의 투수계수의 저하 및 지반의 이완하중 발생크기를 예측할 수 있는 역해석 방법을 제시하였다.

터널 주변의 시공 후 부직포 투수계수 저하와 수위 상승 및 터널에 작용하는 이완하중의 크기 및 손상범위를 예측하기 위해 수치해석을 통하여 해석결과를 확보하였으며, 인공신경망 모델을 통해 부직포 투수계수와 수위 상승 및 이완하중의 크기와 손상범위를 예측해 보았다. 각 경우에 85가지 해석결과를 학습에 활용한 뒤, 학습결과를 이용하여 15가지 상황에 대하여 검증을 수행하여 각 상황에 적합한 인공신경망 모델을 선정하였다. 본 연구에서 선정된 인공신경망 모델은 주어진 해석 결과에 대하여 높은 학습률을 보였으며, 검증에서도 목표값(수치해석 적용값)과 유사한 출력값(인공신경망 예

측값)을 산출하였다. 본 연구에서 개발된 방법에서는, 시공 후 콘크리트라이닝에 발생하는 추가적인 내공변위의 계측을 통하여, 부직포 투수계수 변화, 수위증감량 및 이완하중의 크기와 손상범위의 변화를 역으로 추정해 낼 수 있는 효율적인 방법을 제시하였다.

감사의 글

본 연구는 건설교통부가 출연하고 한국건설교통기술평가원에서 위탁시행 하는 2004년도 건설핵심기술연구개발사업, "04핵심기술 C01"과 한국과학재단의 스마트사회기반시설 연구센터(SISTeC)에 의하여 연구비가 지원된 연구로서 이에 감사를 드립니다.

참고 문헌

1. 이성진, 이승래, 장범수 (2002), "인공신경망 모델을 이용한 불포화토 결보기 점착력 추정에 관한 연구", *대한토목학회논문집*, Vol.22, No.3, pp.331-344.
2. 이준석, 최일윤 (2002), "정적 내공변위를 이용한 터널 라이닝 손상 검출기법에 관한 연구", *한국지반공학학회논문집*, Vol.18, No.6, pp.153-160.
3. 최준우 (2005), *투수 및 이완하중 파악을 위한 터널 라이닝의 해석 및 역해석*, 석사학위논문, 고려대학교.
4. 한국시설안전기술공단 (2003), *공용중인 터널(산악터널)에 작용하는 지반응력 측정에 관한 연구*, 한국시설안전기술공단.
5. 한국도로공사 (2003), *도로설계요령 제4권 터널*, pp.16-28.
6. Aleksander, I. and Morton, H. (1990), *An Introduction to Neural Computing*, Chapman and Hall.
7. Barton, N. (2002), "Some New Q-value Correlations to Assist in Site Characterisation and Tunnel Design", *Journal of Rock Mechanics and Mining Science & Geomechanics*, Vol.39, No.2, pp.185-216.
8. Dowla, F.U. and Rogers, L.L. (1995), *Solving Problems in Environmental Engineering and Geoscience with Artificial Neural Networks*, MIT.
9. Forsee, F.D. and Hagan, M.T. (1997), "Gauss-Newton Approximation to Bayesian Learning", *Proceedings of the 1997 International Joint Conference on Neural Networks*, pp.1930-1935.
10. Hagan, M.T., Demuth, H.B. and Beale, M.H. (1996), *Neural Network Design*, PWS Pub.
11. Hertz, J., Krogh, A. and Palmer, R. (1991), *Introduction to the Theory of Neural Computation*, Addison-Wesley.
12. Hoek, E., Carranza-Torres, C. and Corkum, B. (2002). "Hoek-Brown Failure Criterion - 2002 Edition", *North American rock mechanics symposium*, pp.267-274.
13. Khanna, T. (1989), *Foundations of Neural Networks*, Addison-Wesley.
14. Kohonen, T. (1988), "An Introduction to Neural Computing", *Neural Networks*, Vol.1, No.1, pp.3-16.
15. Kurup, P.U. and Dudani, N.K. (2002), "Neural Networks for Profiling Stress History of Clays from PCPT Data.", *Journal of Geotechnical and Geoenvironmental Engineering*, Vol.128, No.7, pp.569-578.

(접수일자 2006. 5. 2, 심사완료일 2006. 7. 18)