

인공신경망을 이용한 터널 거동 예측 시스템 개발

The Development of Tunnel Behavior Prediction System Using Artificial Neural Network

이 종 구^{*1} Lee, Jong-Ku
문 홍 득^{*2} Moon, Hong-Deug
백 영 식^{*3} Paik, Young-Shik

Abstract

Artificial neural networks are efficient computing techniques that are widely used to solve complex problems in many fields. In this study, in order to predict tunnel-induced ground movements, Tunnel Behavior Prediction System (TBPS) was developed by using these artificial neural networks model, based on a field instrumentation database (i.e. crown settlement, convergence, axial force of rock bolt, compressive and shear stress of shotcrete, stress of concrete lining etc.) obtained from 193 location data of 31 different tunnel sites where works are completed. The study and test of the network were performed by Back Propagation Algorithm which is known as a systematic technique for studying the multi-layer artificial neural network. The tunnel behaviors predicted by TBPS were compared with monitored data in the tunnel sites and numerical analysis results. This study showed that the values obtained from TBPS were within allowable limits. It is concluded that this system can effectively estimate the tunnel ground movements and can also be used for tunneling feasibility study, and basic and detailed design and construction of tunnel.

요 지

인공신경망은 복잡한 문제를 해결하는데 있어 여러 분야에서 널리 활용되고 있는 매우 효과적인 기법으로 알려져 있다. 본 연구에서는 터널거동을 효과적으로 예측하기 위해 이러한 인공신경망 기법을 이용한 터널거동 예측시스템 (TBPS)을 개발하였다. 본 시스템 개발을 위해 시공이 완료된 31개 현장 193 개소 지점으로부터 얻은 터널 계측자료 (즉, 천단침하, 내공변위, 록볼트 축력, 슛크리트 압축 및 전단응력, 내진시 라이닝의 응력 등)를 D/B화하여 이용하였다. 또한 개발된 TBPS의 학습을 위해 가장 효과적이라 알려진 역전파 알고리즘을 사용하여 이들 자료의 학습을 실시하였다. 이러한 과정을 통해 개발된 TBPS를 이용하여 예측한 터널 거동 값과 현장계측 값, 수치해석에 의한 결과 값의 상호 비교 분석을 실시하였다. 비교분석 결과, TBPS에 의한 거동예측결과 값의 변화는 실무에 적용 가능한 범주에 있는 것으로 나타났다. 따라서 본 연구에서 개발된 TBPS는 터널의 타당성검토나 기본 및 실시설계 등에 적용하여 효율적으로 필요한 정보를 신속하게 얻을 수 있는데 사용될 수 있을 것으로 판단된다.

Keywords : Back propagation algorithm, Monitored data, Neural networks, TBPS, Tunnel behavior

*1 정회원, 한국종합기술개발공사 상무이사 (Member, Managing Director, Korea Engr. Consult. Corp., jklee@kecc.co.kr)

*2 정회원, 진주산업대학교 토목공학과 교수 (Member, Prof., Dept. of Civil Engr. Jinju National Univ.)

*3 정회원, 경희대학교 토목공학과 교수 (Member, prof., Dept. of Civil Engr. Kyung Hee Univ.)

1. 서론

산악지역 터널공사시 보다 간편하고 정확한 터널거동예측을 위해 인공신경망(Artificial Neural Network, ANN)이론을 적용하여 기존 터널거동예측의 한계성을 극복하고자 하였다. 설계를 위하여 굴착시 3차원의 지반조건을 2차원으로 고려할 때 허용하는 파괴 메카니즘을 이해하여야 하고, 암반의 역학적 특성의 평가와 시공시 발생하는 경계조건들의 변화를 평가 하기 위하여 합리적인 거동예측기술이 요구되며 시공하는 동안 수행하게 되는 계측관리의 정확성이 요구되나 지반거동의 예측은 매우 어려운 실정이다. 이를 위해 인공신경망 중 다층신경망을 본 연구의 목적에 적합한 구조로 구축하였고, 역전파 알고리즘으로 학습시켜 터널 거동 예측시스템을 개발하였다. 본 역전파 신경망을 이용한 터널거동 예측시스템의 학습을 위한 자료는 터널 거동에 영향을 미치는 영향인자를 고려하여 먼저 신뢰성 분석을 실시하여

선별된 계측자료의 결과를 데이터베이스화하여 사용하였다. 또한 역전파 신경망의 학습자료가 예측결과에 미치는 영향을 분석하여 역전파 신경망의 학습자료에 대한 예측시스템의 민감성을 분석하였다. 마지막으로 학습이 완료된 터널거동 예측시스템을 이용하여 시공이 완료된 현장 터널의 천단침하, 내공변위 및 지보재의 응력 등을 예측하고 이를 실 계측치와 비교하여 개발된 터널 거동 예측시스템의 현장 적용성을 확인하였다.

2. 역전파 신경망 (Back Propagation Neural Network)

역전파는 인공신경망(ANN)의 훈련 방법 중의 하나이다. 대부분의 다층 인공신경망의 학습은 Rumelhart(1986) 등에 의한 저서에서 제시된 역전파 알고리즘을 사용하여 수행할 수 있다. 이 알고리즘은 주어진 입력에 대해 원하는 출력결과를 학습시키고자 할 때 사용하며(supervised learning), 출력 층의 각 신경에서 발생하는 출력오차를

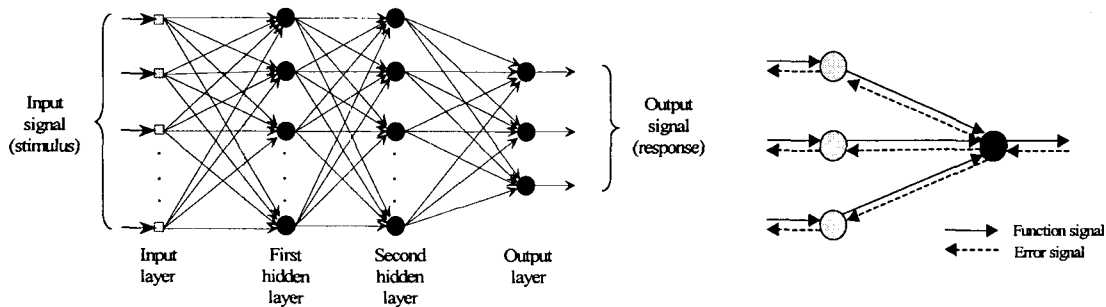


그림 1. 다층 인공신경망의 구조(왼쪽)와 역전파 알고리즘에서의 신호의 흐름도(오른쪽)

표 1. 역전파 알고리즘에서 사용되는 기호의 정의

용어	정의
i, j, k	서로 다른 신경을 나타내며, 신경 j 는 신경 i 의 바로 오른쪽 층에, 신경 k 는 신경 j 의 바로 오른쪽 층에 존재
n	n 번째 학습패턴이 MLP에 주어짐을 나타냄
$\xi(n)$	n 번째 학습패턴이 주어졌을 때 출력층에 존재하는 모든 신경의 제곱오차의 합
ξ_{av}	모든 학습패턴이 주어진 후의 $\xi(n)$ 의 평균
$e_j(n)$	n 번째 학습패턴이 주어졌을 때 출력신경 j 의 오차
$d_j(n)$	n 번째 학습패턴에 대한 출력신경 j 의 원하는 출력결과
$y_j(n)$	n 번째 학습패턴이 주어졌을 때 출력신경 j 의 출력결과
$w_{ji}(n)$	n 번째 학습패턴이 주어졌을 때 입력신경 i 와 출력신경 j 를 연결하는 링크의 가중치
$v_j(n)$	n 번째 학습패턴이 주어졌을 때 신경 j 의 내부 활성화 수준(internal activity level)
$\varphi_j(\cdot)$	신경 j 의 비선형 활성화함수
$x_i(n)$	n 번째 학습패턴의 i 번째 요소로서 입력층 신경 i 를 통해 MLP에 주어짐.
$o_k(n)$	n 번째 학습패턴이 주어졌을 때 출력층에 존재하는 신경 k 의 출력결과
$w_{kj}(n)$	n 번째 학습패턴이 주어졌을 때 은닉층의 신경 j 와 출력층의 신경 k 를 잇는 연결링크의 가중치
a	모멘텀 상수
η	역전파 알고리즘에서의 학습률

각 층으로 역으로 전파시켜 나가면서 연결링크의 가중치 수정을 통해 오차를 최소화시키는 기법이다.

2.1 사용기호의 정의

역전파 알고리즘에서 사용되는 기호를 정의하면 표 1과 같다.

2.2 이론적 배경

알고리즘의 반복단계 n에서(즉, n번째의 학습패턴을 입력신호로 사용하는 단계) 신경 j의 출력오차 $e_j(n)$ 은 식 (1)과 같이 정의된다.

$$e_j(n) = d_j(n) - o_j(n) \quad (1)$$

신경 j의 제곱오차는 $\frac{1}{2} e_j^2(n)$ 로 정의하며, 출력 층에 존재하는 신경의 총 제곱오차의 합을 $\xi(n)$ 으로 정의한다. 또한 학습시키고자 하는 패턴이 n개가 있을 경우 각 패턴에 대한 $\xi(n)$ 의 평균을 ξ_{av} 라 하면, 이를 학습성과를 나타내는 지표로 사용할 수 있다.

$$\xi(n) = \frac{1}{2} \sum_{j \in c} e_j^2(n) \quad (2)$$

$$\xi_{av} = \frac{1}{N} \sum_{n=1}^N \xi(n) \quad (3)$$

여기서 c는 출력노드의 집합이며, N은 학습패턴의 총 개수이다.

신경망의 학습은 학습 데이터를 하나씩 입력받을 때마다 가중치를 변화시켜 나가는 방식(pattern-by-pattern learning)과 모든 학습 데이터를 입력받은 후(이를 one epoch 이라 함) 가중치를 변화시켜 나가는 방식(batch

learning)의 두 가지가 있으며, 전자는 각 신경의 제곱오차의 합 $\xi(n)$ 의 방향벡터를, 후자는 제곱오차의 합을 총 학습패턴수로 나눈 평균제곱오차 ξ_{av} 의 방향벡터를 각각 사용하여 가중치를 수정해 나간다. 본 연구에서는 계산시간이 빠른 후자의 방식을 사용하여 학습을 시켰다. 신호의 흐름을 신경 j에 대해 간략화 시켜 나타내면 그림 2와 같다.

n번째 학습패턴이 주어질 때 신경 j에 입력되는 신호 $v_j(n)$ 은 식 (4)와 같다.

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (4)$$

그림 2에서, y_0 는 항상 +1의 값을 가지며, w_{j0} 는 임계값을 의미한다.

신경 j는 $v_j(n)$ 및 활성화함수를 사용하여 식 (5)와 같이 출력신호를 계산한다.

$$y_j(n) = \varphi_j(v_j(n)) \quad (5)$$

하나의 학습패턴이 주어질 때마다 연결링크의 가중치를 수정해 나가는 방식으로 학습시키는 경우, 매 단계 가중치는 제곱오차 합의 부(-)의 기울기 방향으로 수정해 나간다.

$$\Delta w_{ji}(n) = -\eta \frac{\partial \xi(n)}{\partial w_{ji}(n)} = \eta \delta_j(n) y_i(n) \quad (6)$$

여기서, η : 역전파 알고리즘에서의 학습률

$$\delta_j(n) = e_j(n) \varphi_j'(v_j(n)) \quad (7)$$

여기서, $\delta_j(n)$: 출력 신경 j에 대한 local gradient

신경 j의 활성화함수는 일반적으로 그림 3과 같이 S




그림 2. 출력신경 j에서의 신호의 흐름도




그림 3. 활성화함수

자 모양의 곡선(Sigmoid)을 나타내는 식 (8)을 사용한다.

$$\varphi_j(v_j(n)) = \frac{1}{1 + \exp(-v_j(n))} \quad (8)$$

신경 j의 활성화함수로 식 (8)을 사용할 경우 식 (7)은 식 (9)와 같이 변환될 수 있다.

$$\delta_j(n) = [d_j(n) - o_j(n)]o_j(n)[1 - o_j(n)] \quad (9)$$

식 (9)를 사용하여 학습시키는 경우, 학습률, η 의 값이 작을수록 안정적으로 최종해에 도달하지만 학습속도가 느려진다는 문제점이 있다. 반면, 학습속도를 향상시키기 위해 학습률을 너무 큰 값으로 사용할 경우에는 최종해에 도달하지 못하고 발산하는 문제점이 있다. Rumelhart(1986)는 이러한 문제점을 해결하기 위해 식 (6)에 모멘텀 상수, α 를 추가하여 식 (10)과 같이 가중치를 수정하는 방안을 제시하였다.

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) + \alpha \Delta w_{ji}(n-1) \quad (10)$$

2.3 역전파 알고리즘의 훈련

전술한 이론적 배경을 바탕으로 학습시키고자 하는 신경망이 은닉층을 1개만 가지고 있고 활성화함수로 시그모이드 함수를 사용하는 경우에, 역전파 알고리즘을 이용한 학습과정을 정리하면 아래와 같고, 흐름도는 그림 4와 같다.

단계0 : 난수발생 함수를 이용하여 초기 가중치를 생성한다. 초기 가중치의 범위는 일반적으로 -0.3 ~ 0.3의 값을 사용한다.

단계1 : 종료조건이 만족될 때까지 단계2~단계9를 반복한다.

단계2 : 각각의 학습패턴에 대해 단계3~단계8을 반복한 후 단계9로 간다.

단계3 : 입력층 신경을 통해 하나의 학습패턴을 입력받는다. 입력층의 각각의 신경은 입력받은 신호를 은닉층의 모든 신경으로 보낸다.

단계4 : 은닉층에 포함된 각각의 신경은 입력받은 신호(x_i)와 연결링크의 가중치(w_{ji})를 사용하여 출력신호(y_j)를 계산한다.

$$y_j = \frac{1}{1 + \exp(-\sum_{i=0}^p w_{ji}x_i)}, \quad j = 1, 2, \dots, p \quad (11)$$

계산된 출력신호를 출력층의 모든 신경으로 보낸다.

단계5 : 출력층에 포함된 각각의 신경은 입력받은 신호(y_j)와 연결링크의 가중치(w_{kj})를 사용하여 출력신호(o_k)를 계산한다.

$$o_k = \frac{1}{1 + \exp(-\sum_{j=0}^p w_{kj}y_j)}, \quad k = 1, 2, \dots, m \quad (12)$$

단계6 : 출력층에 포함된 각각의 신경은 주어진 학습패턴에 대해 원하는 출력결과(d_k)와 실제 출력결과(o_k)와의 차이(e_k)를 계산하고, 오차면의 기울기와 관련된 값(δ_k)을 계산하고 이를 이용하여 은닉층과 출력층 사이의 가중치의 변화량(Δw_{kj})을 계산한다. 계산된 δ_k 를 은닉층의 모든 신경으로 보낸다.

$$e_k = d_k - o_k, \quad k = 1, 2, \dots, m \quad (13)$$




그림 4. 은닉층의 신경 j와 출력층의 신경 k사이의 신호의 흐름

$$\delta_k = (d_k - o_k) o_k (1 - o_k), \quad k = 1, 2, \dots, m \quad (14)$$

$$\Delta w_{kj} = \alpha \Delta w_{kj}(old) + \eta \delta_k y_j, \quad j = 0, 1, \dots, p, \quad (15)$$

$$k = 1, 2, \dots, m$$

단계7 : 은닉층에 포함된 각각의 신경은 출력층으로부터 받은 δ_k 와 w_{kj} 를 사용하여 오차면의 기울기와 관련된 δ_j 를 계산하고, 입력층과 은닉층 사이의 가중치의 변화량(Δw_{ji})을 계산한다.

$$\delta_j = y_j(1 - y_j) \sum_{k=1}^m \delta_k w_{kj}, \quad j = 1, 2, \dots, p \quad (16)$$

$$\Delta w_{ji} = \alpha \Delta w_{ji}(old) + \eta \delta_j x_i, \quad i = 0, 1, \dots, n, \quad (17)$$

$$j = 1, 2, \dots, p$$

단계8 : 연결링크의 가중치를 수정한 후 모든 학습패턴이 주어졌을 경우에는 단계9로 가고, 그렇지 않으면 단계2로 돌아간다.

$$w_{ji}(new) = w_{ji}(old) + \Delta w_{ji} \quad (18)$$

$$w_{kj}(new) = w_{kj}(old) + \Delta w_{kj} \quad (19)$$

단계9 : 학습의 종료조건을 검사한다. 즉, 전 epoch단계와 현 epoch단계의 평균제곱오차의 변화율이 미리 설정한 값보다 작으면 학습을 종료하고, 그렇지 않으면 단계1로 돌아간다.

역전파 알고리즘의 수렴성은 일반적으로 증명하기는 불가능하며, 단지 실용적인 측면에서 가중치의 수정을 종료하는데 사용되는 몇 가지 조건을 고려해 볼 수 있다. Kramer와 Sangiovanni-Vincentelli(1989)는 종료 조건을 오차면(error surface)의 기울기, 평균제곱오차(ξ_{av})의 변화율, 오차면(error surface)의 기울기와 평균제곱오차(ξ_{av})의 변화율과 같이 2가지를 모두 고려한 경우의 3가지로 분류하여 제시하였고, 본 연구에서는 3번째




그림 5. 신뢰도 95%의 데이터 검증

의 방법을 적용하여 오차면의 기울기의 크기가 충분히 작은 값에 도달하였거나, 평균제곱오차의 값이 충분히 작은 값에 도달하였을 때를 종료조건으로 다층 퍼셉트론을 학습시켰다.

3. 터널거동 예측시스템(TBPS) 개발

3.1 터널계측자료의 D/B화

먼저 터널의 거동특성과 관련 있는 영향인자를 분석하고, 또한 신뢰성분석을 통하여 선정된 계측자료를 2가지로 구분하였는데, 터널 굴착 중 거동예측을 위한 자료와 터널 준공 후 내진시 거동예측을 위한 자료로 구분하여 D/B화 하였으며, 이들 D/B화된 자료를 인공신경망의 학습에 이용하였다. 즉 그림 5~6의 결과와 같이 신뢰도 95%의 구간에 만족하는 터널계측 데이터 169개를 추출하였다. 이들 계측자료의 선정시 내진시의 터널 거동 데이터에 대해서는 국내 계측자료의 미 확보로 수치해석을 통한 동적 해석방법의 결과를 인공신경망 학습자료로 이용하였다. 이들 내진시 자료를 포함한 총 169개의 데이터에 대하여 각 현장별로 다양한 지반조건을 만족시키기 위하여 최대 5개 지층으로 구분 할 수 있도록 하였으며, 또한 터널의 다양한 조건을 모델링 할 수 있도록 인접터널간 이격거리, 굴진방법, 락볼트의 길이(횡간격, 종간격), 슛크리트의 두께, 굴진장 등에 대한 데이터를 정리하였다.

3.2 인공신경망 매개변수를 이용한 TBPS 모델결정

다층 인공 신경망은 입·출력층 및 은닉층의 구조와 학습에 필요한 학습률 및 모멘텀 상수 등의 학습상수와 학습횟수가 인공신경망의 학습효율 및 추론능력에 영향을 미친다. 따라서 이미 구축된 데이터베이스를 대상으로 터널굴착시, 터널의 천단침하·내공변위 및 지보재의 응




그림 6. Log Scale에서의 UUL, LLL

력 등 터널 거동의 예측과 터널시공 후의 내진시, 라이닝의 변위 및 응력의 예측에 가장 적합한 인공신경망 모델을 각각 결정하기 위하여 다층 인공신경망 실험모델을 선정하고 역전파 알고리즘을 이용하여 학습을 수행하였다.

3.2.1 인공신경망 입력매개변수 모델화

신뢰성 분석을 실시하여 D/B화 된 계측자료로 인공신경망 학습을 실시하기 위하여, 최대 5개층의 입력변수를

선정하여 지반의 구성에 따라 상단 1st layer에서부터 순서대로 입력 가능하도록 하였으며, 보다 다양한 지반조건을 반영시키기 위하여 터널거동에 영향을 주는 44개의 매개변수를 선정하여 표 2와 같이 모델화 하였다.

3.2.2 다층 역전파 인공신경망 모델의 매개변수연구

(1) 매개변수에 따른 인공신경망 모델들의 결정본 연구에서 입력층의 노드수는 이미 구축된 데이터베

표 2. 입력매개변수 모델화

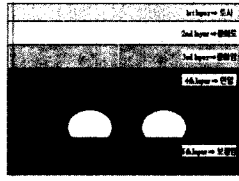
조 건	항 목		번 호	
기하학적 조건	토피고(m)		[1]	
	터널의 높이(m)		[2]	
	터널의 굴착폭(m) -스프링 라인의 폭-		[3]	
지반조건	지층을 5개로 구분 	1st layer ~ 5th layer	측압계수	[4]
			두께(m)	[5] ~ [9]
			탄성계수(tf/m ²)	[10] ~ [14]
			포아송비	[15] ~ [19]
			단위중량(t/m ³)	[20] ~ [24]
			점착력(t/m ²)	[25] ~ [29]
			내부마찰각(°)	[30] ~ [34]
	지하수위(m)		[35]	
인접터널과의 이격거리(m) - 복선터널의 경우 -		[36]		
시공 및 보강조건	굴진방법	전단면 굴착	[37]	
		반단면 굴착		
		다단벤치굴착		
	Rock-bolt의 평균길이(m)		[38]	
	Rock-bolt의 평균수평간격(m)		[39]	
	Rock-bolt의 평균수직간격(m)		[40]	
	숫크리트의 두께(cm)		[41]	
1회 굴진길이(m)		[42]		
내진설계조건	설계지반 가속도(g)		[43]	
	지진파 종류	장주기	[44]	
		단주기		
장단주기				

표 3. 인공신경망 모델

모 델 명	입력층	은닉층	출력층	학습률(η)	모멘텀 상수(α)	시스템오차
A 모델	44	45	9	0.04	0.02	0.0001
				0.07	0.04	
				0.10	0.06	
				0.12	0.075	
				0.15	0.09	
B 모델	44	20	9	0.04	0.02	0.0001
				0.07	0.04	
				0.10	0.06	
				0.12	0.075	
				0.15	0.09	

이스를 근거로 표 3과 같이 모델을 은닉층의 변화에 따라 A모델 25개, B모델 25개, 총50개의 모델로 선정하였고, 출력층의 노드수는 터널굴착시의 거동을 나타내는 천단침하, 내공변위, 슛크리트의 최대 휨응력 그리고 최대 전단응력, 락볼트의 축력 등, 5개 항목과 터널완공시의 내진 특성을 나타내는 콘크리트 라이닝의 천단변위, 내공변위, 최대 휨응력, 최대 전단응력 등, 4개 항목으로 총 9개 항목을 선정하였으며, 은닉층의 층수는 김홍택 등(1998)의 연구를 근거로 단층으로 각각 고정시켰다.

학습률과 모멘텀 상수는 입력변수들의 상관관계 분석을 통하여, Russell and Roy(1990)등이 제시한 학습률 0.04~0.15의 범위 값을 채택하였으며, 모멘텀 상수는 0.02~0.09값을 적용하였다.

(2) 시스템오차 결정

반복횟수와 시스템오차와의 상관관계 및 추론오차와 추론오차율 평가를 통하여 적절한 시스템오차를 선정하고자 시스템오차를 0.001, 0.0001, 0.00001에 대하여 반복횟수 1,000,000회에 대한 오차수렴경향 분석을 실시하였다. 그림 7 (c)는 시스템오차가 0.00001인 경우에 반복횟수의 제한으로 0.000035에서 오차수렴을 마친 결과이다. 또한 추론오차 및 추론오차율 평가 결과를 통하여 시스템오차가 0.00001의 경우 전체 평균오차 및 전

체 평균오차율은 각각 0.52와 14.97%이며, 0.0001의 경우 각각 0.51과 14.54%로 0.00001의 경우보다는 오차 및 오차율이 0.01, 0.43% 정도 작은 것을 알 수 있다.

이 결과에서 시스템오차가 0.00001의 경우에서와 같이 낮은 오차 값에서 학습을 마쳤다고 하더라도 요구하는 오차정도를 만족하지 못하는 경우에는 오히려 오차 및 오차율이 클 수 있다는 것을 확인할 수 있었다. 따라서 시스템오차가 0.001의 경우보다는 반복횟수의 증가로 인하여 연산시간이 비교적 크나 0.00001의 경우보다는 작고, 오차 및 오차율이 가장 작게 평가된 0.0001의 경우를 시스템오차로 선정하였다.

3.3 신경망의 학습

높은 값의 학습률은 많은 양의 연결가중치의 변화를 주기 때문에 학습속도가 빨라지지만 발산의 위험성이 큰 것으로 알려져 있다. 본 연구결과에서도 0.2이상의 값에서는 발산하는 것을 확인할 수 있었다. 따라서 표 3과 같이 모델 A-1~25, B-1~25에 대해 학습률 0.04~0.15, 모멘텀 상수 0.02~0.09로 변화시키면서 역전파 인공신경망 모델을 이용하여 학습자료 169개(D/B자료), 시스템오차 0.0001로 학습을 실시하였고, 최대 학습반복회수는 1,000,000회이다. 학습상수의 변화에 따라 학




그림 7. 반복횟수와 시스템 오차와의 상관관계




그림 8. 추론오차 및 추론오차율


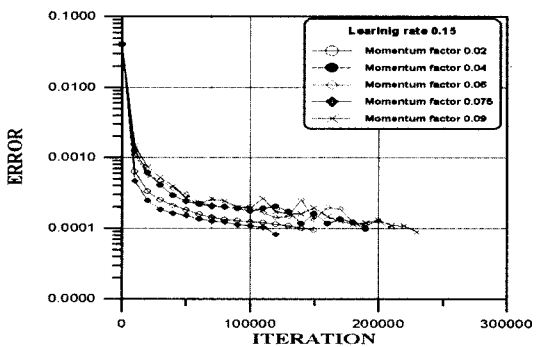



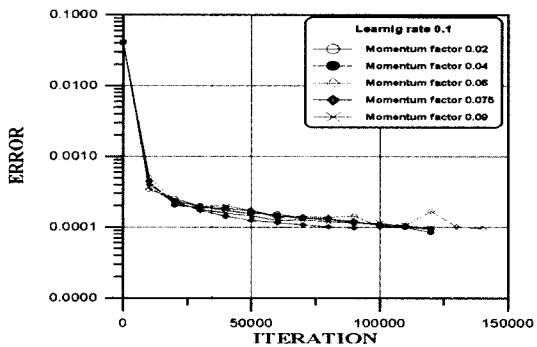

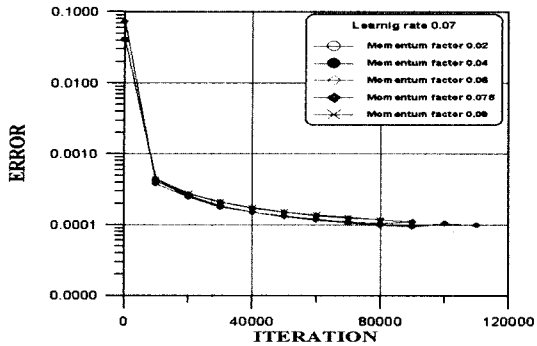




그림 9. 모델 A의 오차수렴경향

그림 10. 모델 B의 오차수렴경향

습오차가 시스템오차 이하인 역전과 인공신경망 모델의 오차수렴경향은 그림 9 및 그림 10과 같다.

그림 9는 은닉층 45일 때 학습률에 따른 모멘텀 상수의 변화에 대하여 정리한 것으로 모델 A-1~25의 오차수렴경향을 나타낸 것이다. 모델 A-1~10은 모멘텀 상수의 변화에 민감한 반응 없이 일정한 오차수렴 경향을 가지는 반면, 모델 A-11~25은 모멘텀상수의 변화에 따라 민감한 반응을 보이며, 학습률이 높아질수록 불규칙적인 오차수렴 경향을 보인다.

그림 10은 은닉층이 20일 때 학습률에 따른 모멘텀 상수의 변화에 대한 모델 B-1~25의 오차수렴 경향을 나타낸 것이다

앞의 그림에서 모델 B도 모델 A의 경향과 비슷한 양상을 보이고 학습률이 높아질수록 모멘텀 상수의 변화에 민감한 반응을 보이며 불규칙적인 오차 수렴경향을 보인다.

따라서 A, B 모델 모두 비슷한 오차수렴 경향을 가지며 설정된 50개의 전 모델이 시스템오차인 0.0001에 만족하는 것을 알 수 있었다.

3.4 TBPS의 모델결정

선정된 모델에 대해 각각 학습을 수행하고 각 모델에 대한 학습횟수, 학습오차, 수렴 경향도를 바탕으로 터널

굴착시 거동과 완공 후의 거동을 실측값과 예측값으로 재 추론하여 보았다. 재 추론된 터널변위와 지보재의 응력은 식 (20)과 같은 추론오차율 산정식을 이용하여 각 인공신경망 모델에 대한 학습자료의 평균 재 추론 오차율(Average Inference Error Rate, AIER)을 산정하였다.

$$AIER(\%) = \frac{1}{n} \sum \frac{|K_m - K_p|}{K_m} \times 100 \quad (20)$$

여기서, n은 추론자료 수이며 K_m 는 실 계측자료의 값, K_p 는 예측된 값이다.

재 추론에 의한 오차의 설정은 학습에 사용된 169개 데이터의 실측값과, 같은 조건에서 각 모델별 추론된 예측치와의 오차비율에 의해 결정하였다. 그 오차의 결과 값은 모델 A, B 중에서 모델 B-8(은닉층 : 20, 학습률 : 0.07, 모멘텀상수 : 0.06)이 평균오차율 10.36%로 제일 작게 되는 것을 알 수 있다.(그림 11 참조)

따라서 본 연구의 목적에 가장 적합한 인공신경망 모델을 B-8 (은닉층 : 20, 학습률 : 0.07, 모멘텀상수 : 0.06)로 결정하였다. 그림 12는 결정된 역전과 인공신경망의 구조로서 입력층과 단층의 은닉층, 그리고 출력층으로 이루어진 역전과 인공신경망이며, 은닉층의 노드수 : 20, 학습률 : 0.07, 모멘텀상수 : 0.06의 값을 가진다.




그림 11. 인공신경망 B모델의 재추론 결과

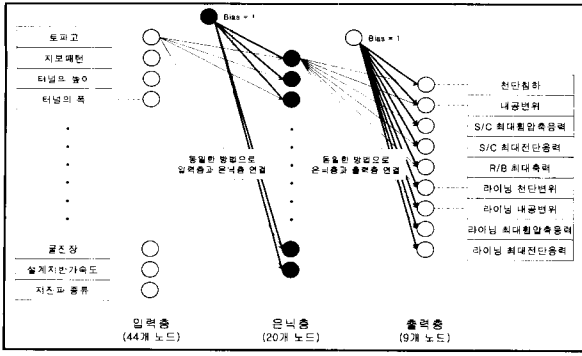


그림 12. TBPS에 사용된 인공신경망의 구조

4. TBPS의 신뢰성 분석

4.1 TBPS의 민감도 분석

본 연구에서 개발된 TBPS를 이용하여 토피고, 측압 계수, 이격거리의 변화에 따른 터널거동의 분석 결과 값을 그림 13~15와 같이 각각 그래프에 나타내었다. 그림 13과 같이 토피고의 변화에 따른 터널의 변위를 검토해 보면 천단침하와 내공변위가 암종에 따라 차이는 있지만 각각 일정하게 감소 또는 증가하는 경향을 나타내고

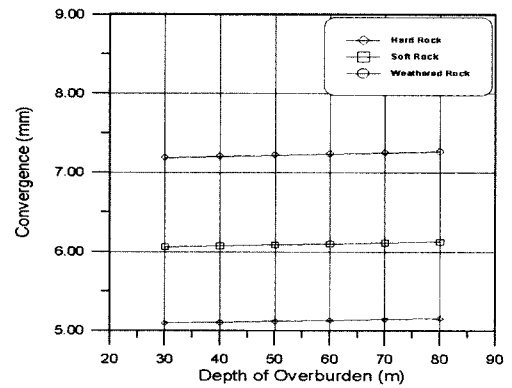
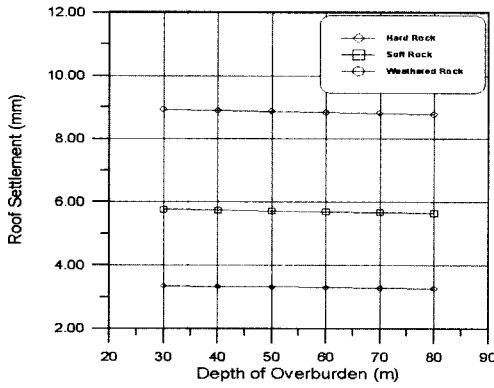


그림 13. 토피고에 따른 민감도분석

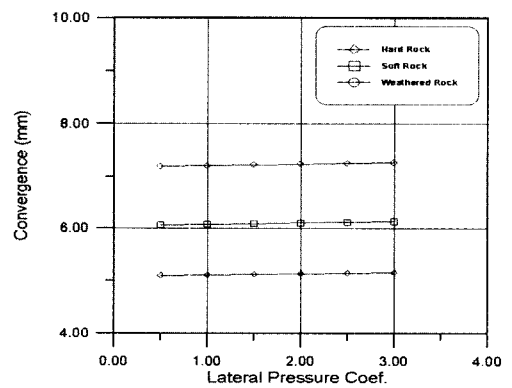
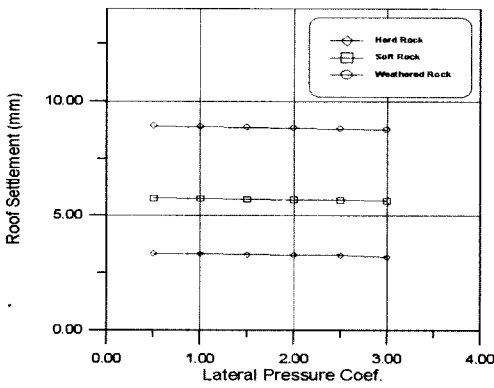


그림 14. 측압계수에 따른 민감도분석





그림 15. 이격거리에 따른 민감도분석

있으며, 그림 14의 경우 축압계수가 증가할수록 천단침하는 그 값은 미소하나 상대적으로 감소하는 경향을 나타내고 내공변위는 증가하는 경향을 보인다. 그림 15는 이격거리 변화에 대한 터널의 변위를 도시한 것으로 이격거리가 커질수록 변위가 감소하는 결과를 가져왔다.

이 결과들을 통하여 알 수 있는 사실은 터널의 거동에 미치는 영향인자를 대상으로 선정된 인공신경망 시스템 모델(은닉층 : 20, 학습률 : 0.07, 모멘텀상수 : 0.06)을 적용하여 터널거동의 민감도를 해석한 결과, 그 값의 경향이 수치해석과 여러 문헌들(김동갑 등, 2001)에 의해 이미 검증된 터널 거동과 같은 유사한 패턴의 경향을 가진다는 점이다. 이는 역전파 인공신경망의 시스템이 만족할 만한 학습과정을 수행하였음을 확인할 수가 있었으며 프로그램의 신뢰성과 적용성이 있음을 알 수가 있다.

4.2 TBPS의 추가학습에 대한 검증

개발된 TBPS의 예측결과를 보다 신뢰성을 갖도록 하기 위하여 기 구축된 현장 계측자료 외에 지속적인 자료의 축적이 필요하므로, 학습패턴의 추가시 TBPS의 학습방법 결정과 학습자료의 추가에 따른 예측시스템의 영향 분석이 요구된다. 따라서 기 개발된 TBPS를 가지고 학습에 이용하지 않은 9개 현장 24개소(현장명: A A~AI)의 선정된 계측자료를 이용하여 추가학습을 실시하고 그 결과를 통하여 추가적인 데이터에 대하여도 선정된 모델의 학습효과가 있는지 알아보았다.

학습은 선정된 모델 B-8에서 학습된 연결가중치를 사용하여 추가로 24개의 데이터를 가지고 시스템오차 0.0001, 최대학습반복회수는 1×10^6 으로 실시하였으며, 그 결과는 그림 16과 같이 시스템오차 1.0×10^{-4} 에서 빠른 경향으로 수렴하였으며, 그림 17과 같이 추론 평균 오차율이 8.45%로 줄어드는 결과를 나타내었다.




그림 16. 모델의 추가학습 오차수렴경향

따라서 선정된 B-8모델에 대하여 데이터의 추가시에도 TBPS의 신뢰성 및 적용성을 확인할 수가 있었으며, 차후 지속적으로 정확하고 광범위한 자료의 축적을 통해 추가학습이 수행되면 예측오차는 본 연구에서 얻어진 오차보다 줄어든 것으로 판단된다.

4.3 TBPS에 의한 예측치, 계측자료 및 수치해석 결과 비교 분석

8개 현장(T-C, T-D, T-E, T-F, T-G, T-H, T-I, T-J)을 대상으로 터널 굴착시 현장의 계측자료를 선정하고, 같은 단면을 수치해석을 하여 얻은 결과 값과 개발된 TBPS에 의한 예측치와의 비교를 통해 TBPS의 신뢰성을 검증하였다. 적용된 현장의 개요는 표 4와 같다.

그림 18은 각각의 데이터 비교에 의한 현장별 터널변위 및 지보재 전체의 평균오차율을 나타낸 그림이다. 그림에서와 같이 TBPS-현장계측치 비교의 경우, 최소 4.5%에서 최대 12.2%의 범위를 보이고, TBPS-수치해석치 비교의 경우, 최소 2.9%에서 최대 14.7%의 결과가 나타났으며, 현장계측과 수치해석 값의 비교결과 오차율은 7.4%~14.6%로 나타났다.

이는 터널 타당성 검토나 설계시 불확실한 요소 등이 내재된 거동예측, 그리고 현장계측과 수치해석 값을 비교한 오차율의 범위를 감안하면 TBPS의 예측치를 신뢰할 수가 있다고 판단된다.

5. 결론

본 연구에서는 인공신경망 이론을 이용하여 터널거동 예측시스템(TBPS : Tunnel Behavior Prediction System)을 개발하였고, 그 성능을 평가하여 터널의 설계 및 시공시의 적용 가능성을 검토하였으며 본 연구결과로 얻




그림 17. 추가학습을 통한 B-8모델의 추론오차분석

어진 결과를 요약하면 다음과 같다.

- (1) 터널거동 예측시스템에 가장 알맞는 인공지능망 구조는 다층 역전파 인공지능망 구조인 모델 B-8(은닉층 20, 학습률 0.07, 모멘텀상수 0.06)인 것을 알 수 있었으며, 이 경우 추론 오차가 가장 적은 것으로 밝혀졌다.
- (2) TBPS-현장계측치 비교의 경우, 최소 4.5%에서 최대 12.2%의 범위를 보이고, TBPS-수치해석치 비교의 경우, 최소 2.9%에서 최대 14.7%의 결과가 나타났으며 현장계측과 수치해석 값의 비교결과 오차율은 7.4%~14.6%로 나타났다. 이는 터널의 타당성 검토나 설계시 불확실한 요소 등이 내재된 거동예측, 그리고 현장계측과 수치해석 값을 비교한 오차율의 범위를 감안하면 TBPS의 예측치를 신뢰할 수 있다고 판단된다.
- (3) TBPS를 이용할 경우 터널의 정적, 동적거동 예측시 해석시간이 많이 소요되지 않으며, 프로그램 사용자의 숙련도에 민감하지 않아 신속한 결과를 얻을 수 있다. 특히 터널 공사 중 막장 지반조건의 변화에 따른 다음 굴착단계의 터널거동을 신속히 예측할 수 있고 이에 대한 대책 마련이 가능하게 된다.
- (4) TBPS를 사용할 때 터널 갱구부나 지질조건이 불리하여 지반보강이 필요한 경우, 또는 암반의 절리가 현저히 발달하고 파쇄대 지반 등 특수한 경우 등의 지반거동 예측시에는 엔지니어의 신중한 기술적 판단이 요구된다.
- (5) 또한, 보다 다양한 지형 및 지질조건 하에서의 터널 거동 예측을 위하여 향후 특수한 조건에 대한 터널 계측자료의 확보가 요구되며, 국내 시공된 현장계측 자료의 지속적인 축적이 필요하다.

참 고 문 헌

1. 김동갑, 박종관, 김수정(2001), "한반도 3차원 지중응력과 이를 고려한 터널해석에 대한 연구", 2001 봄 학술발표회 논문집, 한국지반공학회, pp.97-104.
2. 김홍택, 강인규, 박성원(1998), "인공지능망을 이용한 쏘일네일링 굴착벽체의 변형 예측기법에 관한 기초연구", 대한토목학회 학술발표회 논문집, pp.401-404.
3. 박광준(2001), "터널계측", 한국지반공학회지 강좌/터널(V) Vol. 17, No.11, 한국지반공학회, pp.50-61.
4. 유충식(2000), "터널해석 및 안정성 평가", 한국지반공학회지 강좌/터널(III), Vol.16, No.11, pp.50-61.
5. 이대형, 정영수, 전환석(1998), "역사지진 및 인공지진의 물리적

- 특성에 관한 연구", 한국지진공학회 논문집, 제2권 제2호, pp.35-44.
6. 이정학, 이인모(1994), "인공 신경망 이론을 이용한 말뚝의 극한 지지력 해석(1)-이론", 한국지반공학회지, 제10권 제4호, pp.17-27.
7. 이철욱, 문현구(1994), "암반터널 예비설계를 위한 인공신경회로망 전문가 시스템의 개발", 한국지반공학회지, 제10권, 제3호, pp. 79-96.
8. 한국건설기술연구원(1999), Neural Network를 이용한 터널 설계 적정성 평가용 Expert System 개발(II), 삼성물산(주) 건설부문 수탁연구보고서, pp.291.
9. 홍성영 역(1994), 실무자를 위한 터널의 설계이론, 탐구문화사, pp.2-40.
10. 황성춘, 오병현, 박성진(2001), "지반-구조물의 동적 상호작용 해석법", 한국지반공학회지 강좌/지반진동과 내진설계(V-1) Vol.17, No.2, pp.44-55.
11. Dan Hammerstrom(1993), "Working with Neural Networks", *IEEE Spectrum*, July, pp.46-53.
12. Emerald Soft, PENTAGON-3D Manual.
13. Flood Ian, Kartam Nabil(1994), "Neural Networks in Civil Engineering. II: System and Application", *Journal of Computing in Civil Engineering*, ASCE, Vol.8, No.2, pp.149-162.
14. Ghaboussi. J., Garrett Jr. J. H., Wu. X.,(1991), "Knowledge-Based Modeling of Material Behavior with Neural Networks", *Journal of Engineering Mechanics*, ASCE, Vol.117, No.1, pp.132-153.
15. Ghaboussi. J., Sidarta D. E.,(1994), "Neural network based modelling in geomechanics", *Computer Methods and Advances in Geomechanics*, Rotterdam, Balkema, pp.153-164.
16. Haykin Simon(1998), Neural Networks, Prentice-Hall, Inc., New Jersey.
17. Kiefa. M. A. Abu,(1998), "General Regression Neural Networks for Driven Piles in Cohesionless Soils", *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, Vol.124, No.12, pp. 1177-1185.
18. Kim C. Y., Bae G. J., Hong S. W., Park C. H., Moon H. K. and Shin H. S.,(2000), Neural Network Based Prediction of Ground Surface Settlement due to Tunneling, *Computers and Geotechnics*, pp.517-547.
19. Kim Hak Joon(1997), "Estimation for Tunnel Lining Loads", Ph D Dissertation, University of Alberta.
20. Rumelhart, David, McClelland, James and the PDP Research Group (1986), Parallel Distributed Processing. MIT Press, Cambridge, MA.
21. Russell C. Eberhart, Roy W. Dobbins(1990), *Neural Network PC Tools*, Academic Press Inc.
22. Shi Jingsheng, J. A. R. Ortigao, and Bai Junli(1998), "Modular Neural Networks for Predicting Settlements During Tunneling", *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, Vol.124, No.5, pp.389-395.
23. Szechy Karoly(1973), *The Art of Tunneling*, Akademiai kiado · Budapest, pp.209-265.
24. Timothy Masters,(1993), *Practical Neural Network Recipes in C++*, Academic Press, San Diego, Calif.
25. Tsuchiya, T.,(1984), A design program for a tunnelling method using bolts and shotcrete, ISRM Symposium-Cambridge, U.K. 3-6 September, Editor Brown, E. T. and Hudson, J. A.(1984), *British Geotechnical Society*, London, pp.123-130.
26. Wasserman, P. D.,(1989), *Neural Computing : Theory and Practice*, Van Nostrand Reinhold, New York.

(접수일자 2003. 3. 18, 심사완료일 2003. 4. 15)