

인공신경망을 이용한 터널시공 시 예측결과 분석에 관한 연구 A Study on Instrumentation Results Analysis Using Artificial Neural Network in Tunnel Area

이종휘¹⁾, Jong-Hwi Lee, 이동근²⁾, Dong-Geun Han, 변요셉³⁾, Yo-Seph Byun, 천병식⁴⁾, Byung-Sik Chun,

^{1),2)} 한양대학교 건설환경공학과 석사과정, Graduate Student, Dept. of Civil and Environmental Engineering, Hanyang University

³⁾ 한양대학교 건설환경공학과 박사과정, Ph. D. Candidate, Dept. of Civil and Environmental Engineering, Hanyang University

⁴⁾ 한양대학교 건설환경공학과 교수, Professor, Dept. of Civil and Environmental Engineering, Hanyang University

SYNOPSIS : Although it is important to reflect the accurate information of the ground condition in the tunnel design, the analysis and design are conducted by limited information because it is very difficult to get it practically on considering various geography and geotechnical condition. So construction management of information concept is required to manage immediately on the field condition because it is very time-consuming to establish the countermeasure of underground reinforcement and the pattern change of Bo. Therefore, when construction is on tunnel area, examination of accurate safety and prediction of behavior is performed to overcome the limit of predicting behavior by using Artificial Neural Network(ANN) in this study. Firstly, the field data was secured. Secondly, suitable structure was made on multi-layer perceptrons among the ANN. Thirdly, learning algorithm-propagated applies to ANN. The data for the learn of field application using ANN was used by considering impact factors, which influenced the behavior of tunnel, and performing credibility analysis. crown displacement, spring displacement, subsurfacement, and rock bolt axial force are predicted at the tunnel construction and on-site application was confirmed by using ANN from analyzing and comparing with measurement value of on-site.

In this study, the data from Seoul Highway OO tunnel section was applied to the ANN Theory, and the analysis on the investigate value and the reasoning for the value associated with field application was performed.

Keywords : Artificial Neural Network, Multi-layer back propagation

1. 서 론

현재 터널은 포함한 많은 지하구조물이 시공되고 있으며 계획단계에서 일정 간격으로 지반조사를 실시하고 이 결과를 바탕으로 지반 특성을 파악하여 이를 설계에 반영한다. 특히 터널과 같은 지하 공간 개발을 위해서는 지반등급 분류가 구간별 지보패턴을 결정짓는 중요한 근거자료로 활용되고 있으므로 지반 정보를 정도 높게 획득하는 것이 공사비 손실을 최소화하고 시공·공용 중 구조물 안전성을 확보하

기 위해 중요하다(신휴성 등, 2009).

터널의 설계 시 해당지반에 관한 정보를 정확히 반영하는 것은 대단히 중요하지만 다양한 지형 및 지질조건을 모두 고려한 지반조사 및 시험 등은 경제적, 기술적으로 인하여 현실적으로 실시하기 어렵기 때문에 한정된 정보에 의하여 해석 및 설계를 하고 있는 실정이다. 또한 이를 검토하는 단계에서 기존의 수치해석 방법은 해석결과가 실제 터널거동과 다른 경우가 대부분이며, 시간이 많이 소요되어 현장 상황에 빠르게 대처할 수 있는 정보화 개념의 시공관리가 요구된다(이종구, 2002).

따라서, 본 연구에서는 다층퍼셉트론(multi-layer perceptron)를 연구에 적합한 구조로 구축을 하고, 역전파 알고리즘으로 학습시켜 적용하였다. 인공신경망 학습과 검증을 위하여 서울외곽순환도로 OO터널 현장계측자료 33개의 구간(999개 데이터)중 6개의 구간을 사용하였다. 또한, 지보패턴, 토피고, 암종, 굴착공법, 굴진장 등 터널 거동에 미치는 영향인자를 입력변수로 고려하였으며, 학습이 완료된 인공신경망 모델을 이용하여 터널 구간별 굴착일에 따른 천단침하, 내공변위, 지중변위, 록볼트 축력을 출력변수로 예측하고 현장 계측치와 비교분석을 통하여 인공신경망을 이용한 터널 시공 시 현장 적용성을 평가하였다.

2. 인공신경망 이론

2.1 역사적 배경

McCulloch와 Pitts(1943)에 의해 신경생리학(neurophysiology)과 수학적 논리(mathematical logic)를 결합한 인공신경망 논리적 계산법이 확립되었으며 인공신경망(artificial neural networks, ANNs)의 기본이 되었다. Rosenblatt(1958)는 컴퓨터를 기반으로 하는 최초의 신경회로망 모델인 퍼셉트론(perceptron)에 대한 논문을 발표하였으며 오늘날 역전파 신경회로망과 Kohonen 신경회로망의 토대가 되었다. 후에 Rumelhardt와 McClelland(1986) 등은 병렬분산처리(Parallel Distributed Processing)를 통해 하나 이상의 중간층을 갖는 다층 퍼셉트론(multi-layer perceptron)을 발표하였으며, 이는 선형 분리뿐만 아니라 단층 퍼셉트론(multi-layer perceptron)이 풀지 못하던 여러 가지 문제점도 해결됨으로써 오늘날 가장 일반적으로 활용되는 모델이 되었다(Eberhart R, 1990).

2.2 인공신경망 특성 및 구조

인공신경망이란 인간의 신경조직을 모델로 하여 간단한 기능의 처리기 사이를 서로 대규모로 연결시킨 네트워크 형태의 정보처리 구조를 의미하며 다음과 같은 특성들을 지니고 있다(Rich E et al, 1991). 첫째, 인공신경망은 예제를 통한 학습으로 작업을 진행하게 되며, 입력값과 출력값이 주어지게 되면 다수의 처리기로 구성된 네트워크가 평형상태에 도달할 때까지 자체적으로 학습이 진행된다. 둘째, 인공신경망은 정보를 분산된 형태로 저장하며, 이러한 저장 형태는 오류가 일부 포함된 정보에 대해서도 제대로 작동할 수 있는 결함허용 시스템(fault-tolerant system)을 가진다. 셋째, 인공신경망은 병렬분산 처리된다. 인공신경망은 다수의 처리기에 의해 동시에 병렬처리(parallel processing)가 이루어지며 단시간 내에 오차보정 능력이 높은 정보처리가 가능하다(김대수, 1992).

그림(a)와 같이 다수의 뉴런들로 이루어진 생물학적 특성을 기반으로 그림(b)와 인공신경망을 모델을 구현할 수 있다. 이 때 가장 중요한 고려사항은 뉴런의 역할을 수행하는 처리기와 활성화함수(activation function)이며 시냅스는 강도를 조정할 수 있는 연결선으로 구성된다. 처리기들은 그림 2.2와 같이 다른 처리기 혹은 입력장치로부터 N개의 입력신호를 받아들여 모두 합하고 임계값(Θ : threshold value)을 더하거나 뺀 후에 이 값을 활성화함수를 통해 내보내는 기능을 한다.

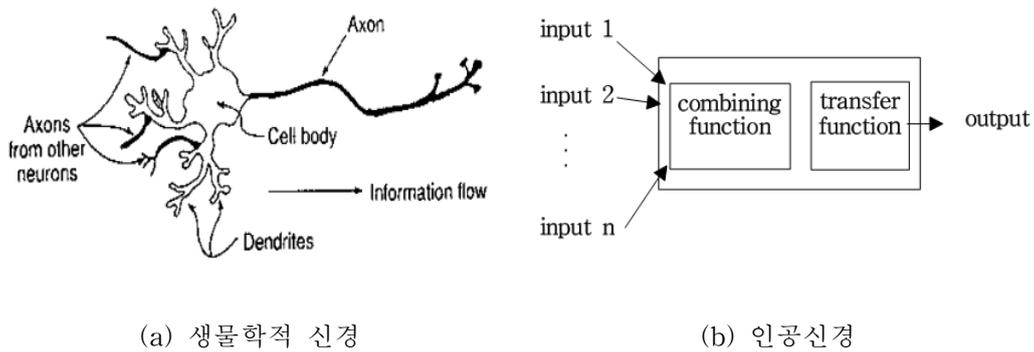


그림 1. 생물학적 신경과 인공신경(Wasserman P.D, 1989)

2.3 다층 역전파 인공신경망(multi-layer back propagation neural network)

본 연구에서 적용된 인공신경망으로 입력층과 출력층 사이에 하나 이상의 중간층이 존재하는 인공신경망으로 된 층상구조형태이다. 이 때 입력층과 출력층 사이의 중간층을 은닉층(hidden layer)이라고 하며, 이러한 은닉층과 함께 입력층, 출력층 방향으로 연결된 전방향(feedforward) 네트워크이다. 다층 퍼셉트론은 단층 퍼셉트론과 유사한 구조를 가지고 있지만 중간층과 각 처리기의 입·출력 특성을 비선형으로 함으로써 단층 퍼셉트론의 단점들을 극복하였다. 또한 대부분의 다층 퍼셉트론의 역전파 학습 알고리즘을 통해 학습시키는 것이 가능하다(Pao Y, 1989).

역전파 인공신경망은 학습단계(learning phase for training)와 산출단계(production phase for estimation)로 동작한다. 먼저 학습단계에서는 입력패턴(input pattern)과 목적패턴(target pattern)이 다수의 입·출력쌍으로 주어지고, 이 입·출력쌍의 관계를 잘 표현해주도록 연결강도의 크기를 수정한다. 이러한 작업은 각 입력패턴에 대해 출력을 먼저 계산한 후, 원하는 출력과 실제 출력과의 차이를 줄이는 방향으로 연결강도를 조정함으로써 수행된다. 하나의 입력패턴에 대한 조정과정이 끝나면 새로운 입·출력쌍이 주어지고 같은 과정으로 학습을 반복함으로써 입·출력간의 상관관계를 잘 묘사해줄 수 있는 연결강도를 구한다. 산출단계에서 필요로 하는 결과에 대한 입력만 주어지면 이러한 상관관계에 의해서 적절한 출력이 계산된다(Pao Y, 1989).

3. 연구방법

3.1 인공신경망 학습

본 연구에서는 인공신경망 학습엔진인 GDAP를 이용하였으며(Pande, Shin, 2004; Shin, et al, 1994), 인공신경망의 모델을 구축하기 위해 역전파 (Back Propagation Neural Network) 알고리즘을 적용하였다. 인공신경망의 학습자료를 이용한 반복 학습 수행동안 지속적으로 검증 자료에 대한 오차율을 모니터링하면서 검증자료에 대한 오차율이 상승하기 시작하는 시점에서 학습을 종료시켰다. 또한, 최적의 학습 일반화를 확보하기 위하여 early-stopping 기법을 적용하였다(Skouras et al., 1994; Prechelt, 1998).

3.2 학습자료 및 인공신경망 구축

인공신경망 학습 시 다음 표 1과 같이 입력변수와 출력변수를 사용하였으며, 시스템오차는 0.001, 은닉층의 층수는 김 등(1998)의 연구를 근거로 2층으로 각각 고정하였다. 은닉층 노드수의 결정은 식 (1)과 식 (2)의 값의 평균을 이용하여 결정하였다.

표 1. 인공신경망 학습에 사용된 입·출력 변수

구분	입력변수	출력변수
터널 거동 예측	지보패턴	천단변위 내공변위 지중변위 록볼트축력
	RMR	
	Q	
	암종	
	굴진장	
	굴착형태	
	굴착일수	

$$\sqrt{(i^2 + j^2)} = k \quad (1)$$

$$\sqrt{(i \times j)} = k \quad (i: \text{입력변수}, j: \text{출력변수}) \quad (2)$$

학습율과 모멘텀 상수가 학습효율 및 추론능력에 가장 큰 영향을 미치며, 학습율 0.04~0.1와 모멘텀 상수 0.1~0.9값을 인공신경망 모델의 선정의 지표로 삼았다(Russell, Roy, 1990). 표 2에서 인공신경망의 모델을 이용하여 학습을 한 결과, 학습율과 모멘텀 상수의 결과 값으로 학습율 0.07, 모멘텀 상수 0.8일 경우 평균 오차값이 가장 작아 이를 인공신경망 모델의 최적의 구조를 평가하고 모델을 선정하였다.

표 2. 인공신경망의 모델

입력층의 노드수	은닉층수	은닉층의 노드수	출력층의 노드수	학습율	모멘텀상수
7	2	7	4	0.05	0.6~0.9
				0.06	0.6~0.9
				0.07	0.6~0.9
				0.08	0.6~0.9
				0.09	0.6~0.9

굴착일수 별 천단침하, 내공변위, 지중변위, 록볼트축력을 산정하는데 인공신경망 모델의 최적의 구조는 은닉층 노드수 7개, 모멘텀 상수 0.8, 학습율 0.07, 은닉층의 수 3개, 목표시스템 오차값 0.001을 적용하였을 때 아래 그림 2와 같은 최적의 인공신경망 모델로서 결정하였다.

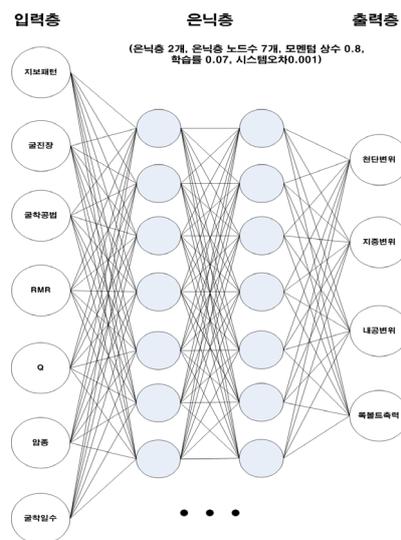


그림 2. 인공신경망 모델 구축

4. 현장개요

본 터널현장의 지반특성은 주절리가 N30~40E(0~90SE, 80~90NW)방향으로 N50E의 사면방향과 거의 일치하는 양상으로 조사되었다. 시추조사결과로 연암층에서는 RMR 19, RQD 9%이하인 상태이고 보통암~경암층에서는 RMR 28~82범위, RQD 0~100%범위인 상태였으며 Q는 0.09~113.33 정도의 범위로 분포하였다.

터널현장에 설치된 계측기기는 상행선 및 하행선방향으로 천단 침하계 총 350개, 내공 변위계 총 1568개, 록볼트 축력계 총 188개, 지중 변위계 188개이다. 본 연구에서는 터널 상부에 위치한 계측기에 대해서만 적용을 하였다.

5. 인공신경망 학습 및 검증 결과

5.1 인공신경망 학습 결과

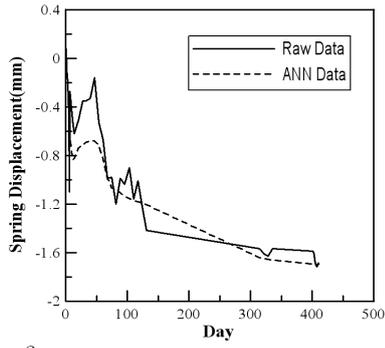
다음 표 3은 인공신경망 학습에 사용된 터널 현장의 개요를 보여주고 있다. 터널의 구간별 지보패턴, 굴진장, RMR, Q, λ 의 물성치를 나타내고 있다. λ 는 상반내공변위/천단침하를 나타내는 값을 말한다. 또한 지보패턴은 표준 TYPE에 대한 것으로, 본 논문에서는 상세 내용은 생략을 하였다.

표 3. 학습을 위한 터널현장의 구간별 개요

	구 간	지보패턴	굴진장	RMR	Q	λ
1	4K+735	IV	0.5	22	0.06	2.01
2	4K+745	IV	1	27	0.11	2.04
3	4K+755	IV	1	30	0.08	2.00
4	4K+765	IV	1	32	0.11	2.03
5	4K+790	IV	2.5	48	0.848	2.02
6	4K+810	V	2	53	0.571	2.15
7	4K+970	III	2	69	3.45	2.11
8	5K+390	V	3	66	13.67	2.04
9	5K+470	V	2	36	0.441	1.95

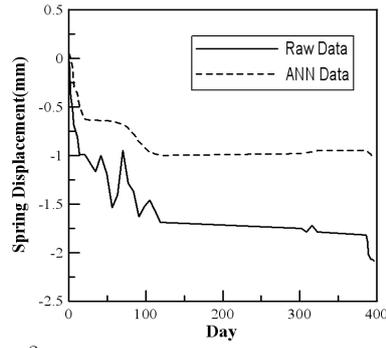
5.1.1 내공변위(상부)

내공변위의 경우 총 6개의 구간에서 상관관계 R^2 값이 0.7022~0.9087 사이의 값으로 나타나 비교적 구간별 편차가 큰 것으로 나타났다. 또한, 다음 그림 3과 같이 굴착일수 별 내공변위의 현장 계측치와 학습된 인공신경망 모델의 예측치 값을 상호 비교한 결과, 구간 4k+745, 4k+765, 4k+810의 경우 상관관계는 비교적 높으며 추세는 비슷하였으나 값에서 차이를 보였다. 구간 4k+735의 경우 현장 계측치와 예측값은 거의 일치하는 것으로 나타났고 구간 4k+755, 4k+790의 경우 상관관계는 비교적 떨어지지만 추세는 비슷한 것으로 나타났다.



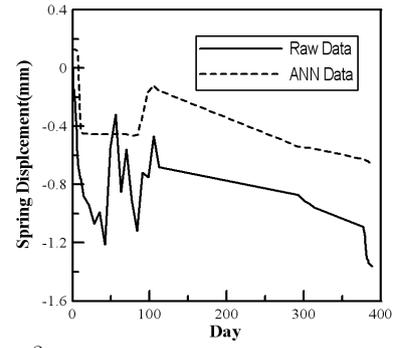
$R^2=0.8882$

(a) 4k+735



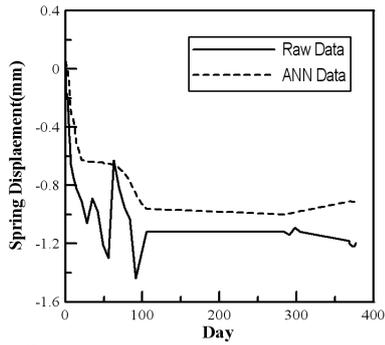
$R^2=0.9087$

(b) 4k+745



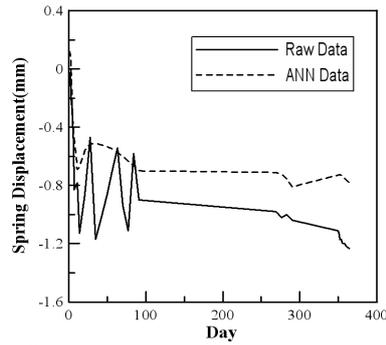
$R^2=0.7022$

(c) 4k+755



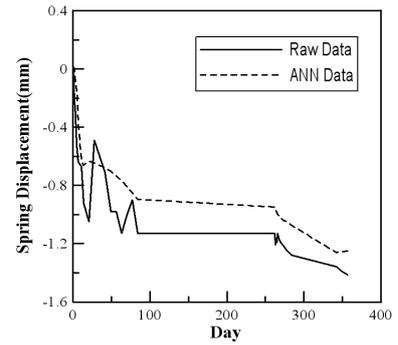
$R^2=0.848$

(d) 4k+765



$R^2=0.7962$

(e) 4k+790



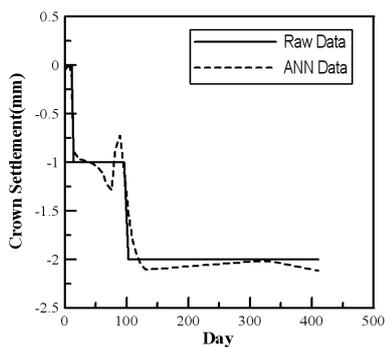
$R^2=0.8954$

(f) 4k+810

그림 3. 내공변위 학습결과

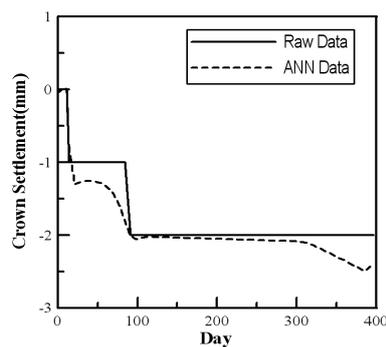
5.1.2 천단침하량

천단침하의 경우 해당 구간에서 상관관계 R^2 이 0.9326~0.9795 사이의 값으로 나타났다. 현장 계측치와 인공신경망 예측치를 상호 비교 결과, 다음 그림 4와 같이 총 6개 구간에서 굴착일수 별 추세가 거의 일치하는 것으로 나타났다.



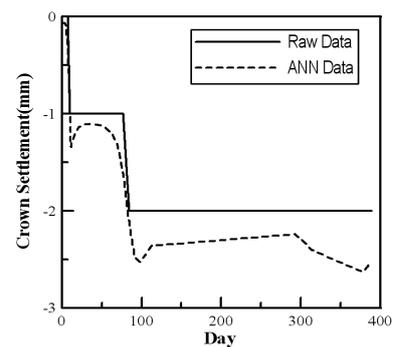
$R^2=0.974$

(a) 4k+735



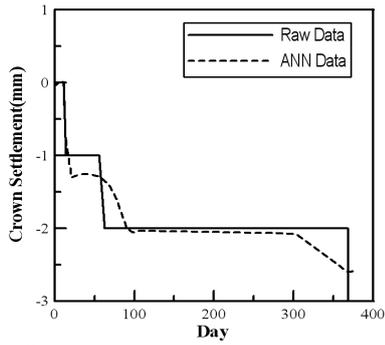
$R^2=0.9493$

(b) 4k+745



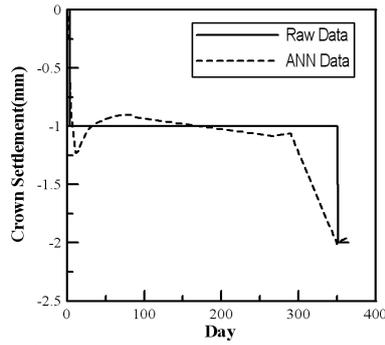
$R^2=0.9727$

(c) 4k+755



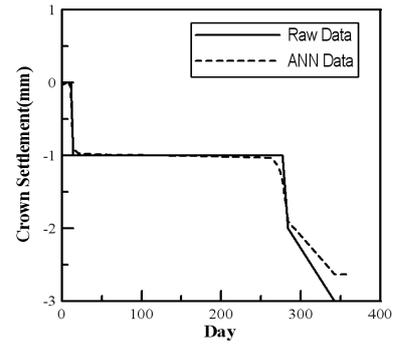
$R^2=0.9326$

(d) 4k+765



$R^2=0.9652$

(e) 4k+790



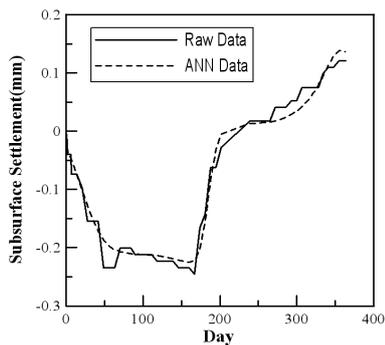
$R^2=0.9795$

(f) 4k+810

그림 4. 천단침하량 학습결과

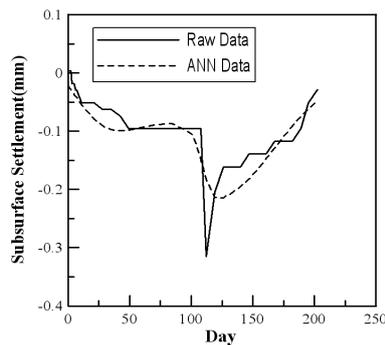
5.1.3 지중변위(상부) 및 록볼트 축력(상부)

그림 5에서 보는 바와 같이 지중변위의 경우 총 3개의 구간에서 상관관계 R^2 이 0.7634, 0.7707, 0.8674의 값으로 나타나 비교적 낮은 상관계수를 나타냈으나 현장 계측치와 예측치의 굴착일수 별 추세를 거의 일치하는 경향을 나타냈다. 또한 그림 6에서 보는 바와 같이 록볼트 축력의 경우 상관관계 R^2 이 0.9794, 0.9493, 0.9727의 값으로 나타나 높은 신뢰성을 나타냈다.



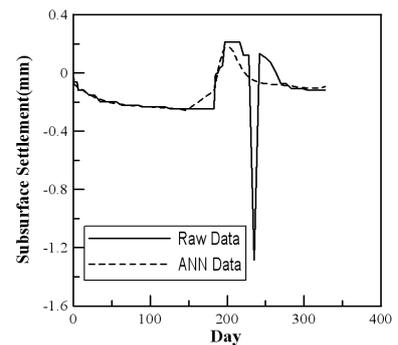
$R^2=0.8674$

(a) 4k+970



$R^2=0.7707$

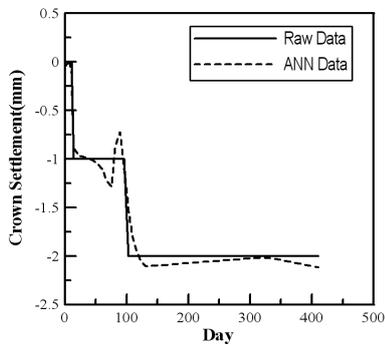
(b) 5k+470



$R^2=0.7634$

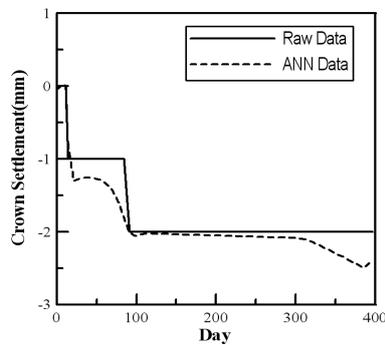
(c) 4k+755

그림 5. 지중변위 학습결과



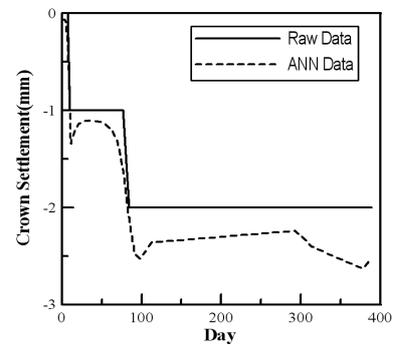
$R^2=0.974$

(a) 4k+970



$R^2=0.9493$

(b) 5k+390



$R^2=0.9727$

(c) 5k+470

그림 6. 록볼트 축력 학습결과

5.2 인공신경망 검증 결과

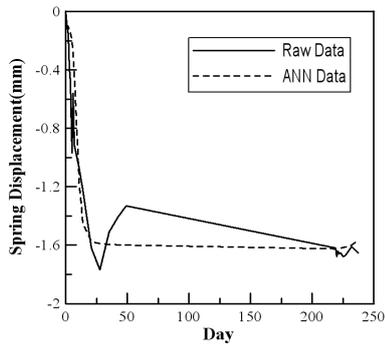
다음 표 4는 인공신경망 검증에 사용된 터널 현장의 개요이다. 이를 이용하여 굴착일수 별 내공변위, 천단침하, 록볼트 축력, 지중변위 순으로 인공신경망 학습에 대한 검증을 실시하여 현장적용성에 관하여 분석을 실시하였다.

표 4. 검증을 위한 터널현장의 구간별 개요

	구 간	지보패턴	굴진장	RMR	Q	λ
1	5k+140	III	3	62	6.074	2.16
2	5k+170	II	3	68	13.67	1.22
3	5k+200	II	3	70	18.22	2.14
4	5k+500	IV	3	48	1.72	2.08
5	5k+530	IV	3	52	2.945	2.14
6	5k+560	IV	3	50	2.592	2.16
7	5k+770	III	3	60	6.01	2.19
8	6k+090	IV	2	61	11.04	2.07

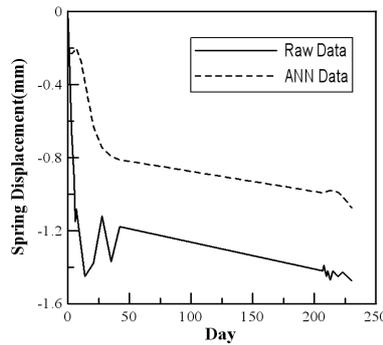
5.2.1 내공변위(상부)

내공변위의 경우 총 6개의 구간에서 상관관계 R^2 값이 0.8642~0.9728 사이의 값으로 나타나 비교적 높은 상관관계가 있는 것으로 나타났다. 하지만 그림 7에서 보는 바와 같이 추세가 불일치하는 경향을 나타냈다.



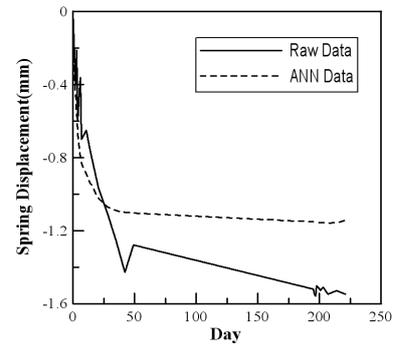
$$R^2=0.8912$$

(a) 5k+140



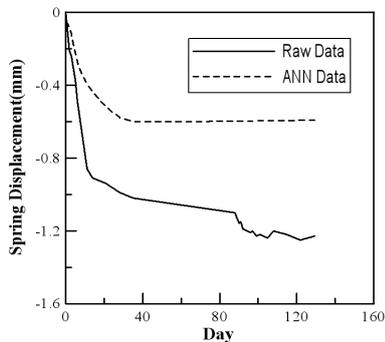
$$R^2=0.8642$$

(b) 5k+170



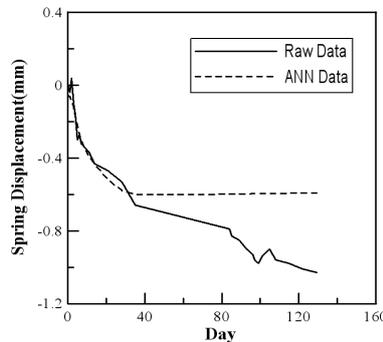
$$R^2=0.881$$

(c) 5k+200



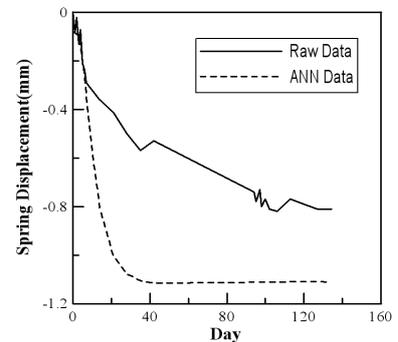
$$R^2=0.9728$$

(d) 5k+500



$$R^2=0.8785$$

(e) 5k+530



$$R^2=0.8785$$

(b) 5k+560

그림 7. 내공변위 검증 결과

5.2.2 천단침하량

천단침하의 경우 총 6개의 구간에서 상관관계 R^2 값이 0.8087~0.9593 사이의 값으로 나타나 비교적 높은 상관관계가 있는 것으로 나타났다. 하지만 그림 8에서 보는 바와 같이 구간 5k+140, 5k+170, 5k+200의 경우에는 추세가 일치하는 경향을 나타냈지만, 구간 5k+500, 5k+530, 5k+560은 추세가 불일치하는 경향을 나타냈다. 전체적으로는 일부 구간에서는 적용성이 있는 것으로 나타나지만 더 많은 구간의 데이터에 대해 검증이 필요할 것으로 판단된다.

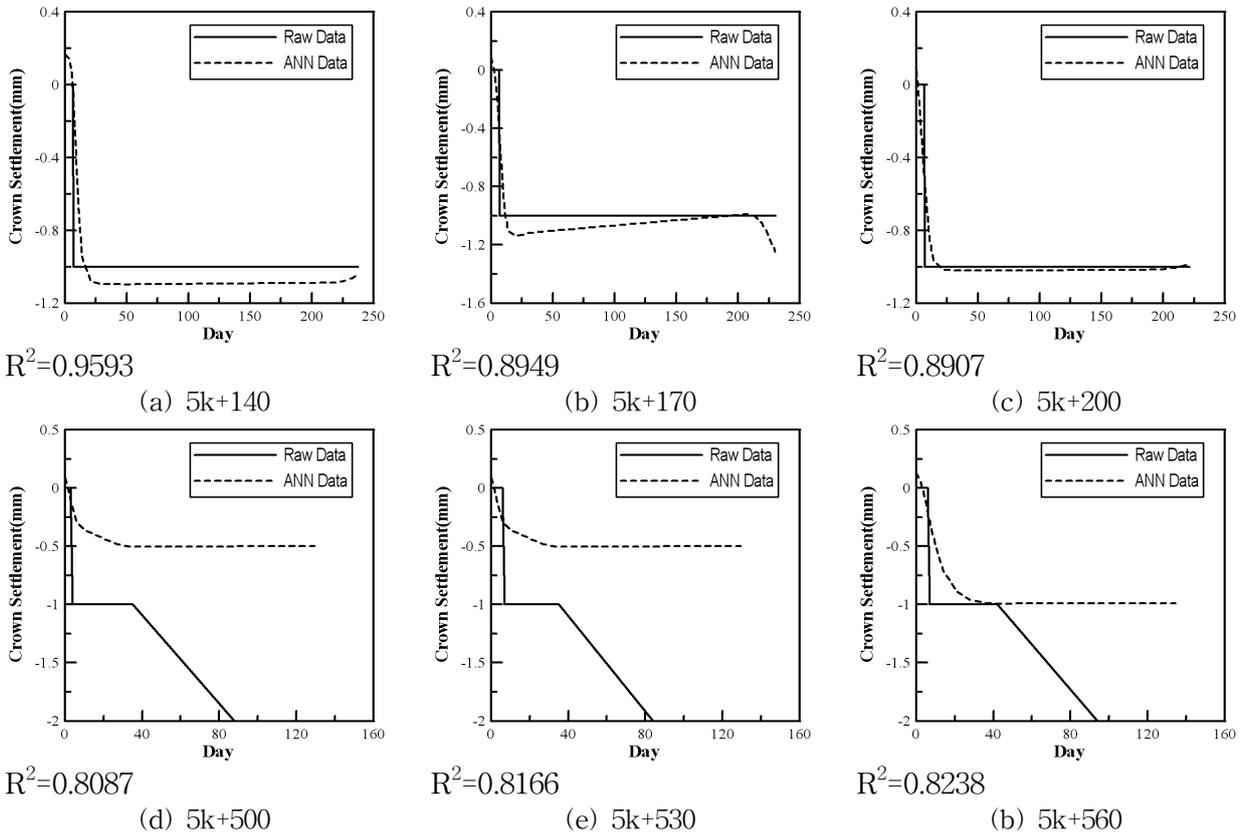
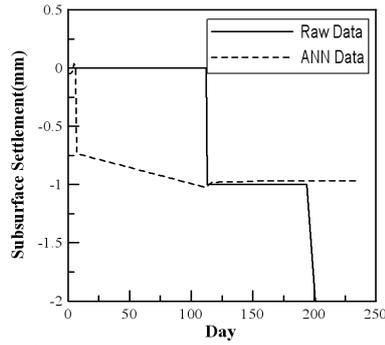


그림 8. 천단침하 검증 결과

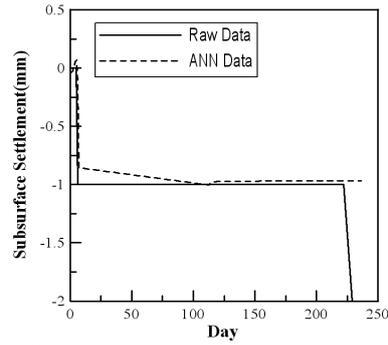
5.2.3 지중변위(상부) 및 록볼트 축력(상부)

지중변위와 록볼트 축력의 의 경우 2개의 구간에서 검증을 하였다. 지중변위의 경우 상관관계 R^2 값은 구간 5k+770, 6k+090에서 각각 0.7528, 0.752의 값을 나타냈으며, 록볼트 축력의 경우 해당 구간에서 각각 0.9527, 0.9573의 값을 나타냈다. 그림 9, 10에서 보는 바와 같이 지중변위의 경우 적용성이 떨어지는 것으로 나타났으나 록볼트 축력의 경우는 높은 상관관계와 추세가 일치하는 경향으로 보아 적용성이 높을 것으로 판단된다.



$$R^2=0.7528$$

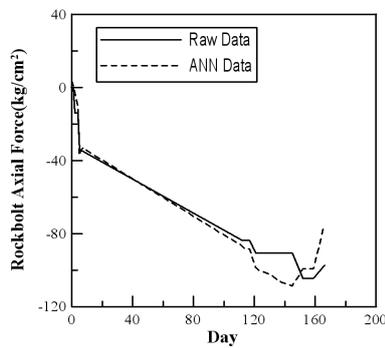
(a) 5k+770



$$R^2=0.752$$

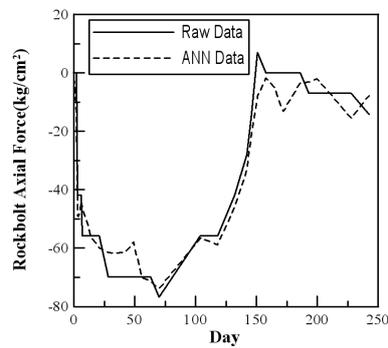
(b) 6k+090

그림 9. 지중변위 검증 결과



$$R^2=0.9527$$

(a) 5k+770



$$R^2=0.9573$$

(b) 6k+090

그림 10. 록볼트 축력 검증 결과

6. 결론

서울외곽순환고속도로 00터널구간의 현장계측자료를 바탕으로 학습이 완료된 인공신경망 모델을 이용하여 시공현장의 터널 구간별 굴착일수 별 천단침하, 내공변위, 지중변위, 록볼트의 응력을 예측하고 현장 계측치와 비교분석을 통하여 현장적용성과 타당성을 평가한 결과는 다음과 같다.

1) 8개 구간에 학습된 인공신경망 모델의 최적의 구조는 은닉층 노드수 6개, 모멘텀 상수 0.8, 학습률 0.07, 은닉층의 수 3개로 적용하였을 때 학습결과 내공변위 상관관계 R^2 은 0.7022~0.9087, 천단침하 상관관계 R^2 은 0.9326~0.9795, 지중변위 상관관계 R^2 은 0.7634~0.8647, 록볼트 축력 상관관계 R^2 은 0.9493~0.9794 이고 검증결과 내공변위 상관관계 R^2 은 0.8642~0.9728, 천단침하 상관관계 R^2 은 0.8087~0.9593, 지중변위 상관관계 R^2 은 0.75 전후의 값, 록볼트 축력 상관관계 R^2 은 0.95 전후의 값을 나타냈다.

2) 굴착일수 별로 터널의 거동을 인공신경망 모델을 학습하였고 현장 계측치와 인공신경망 예측치를 비교하였을 때, 학습 시 상관계수 R^2 은 평균 0.85 이상, 현장 적용성 판단을 위한 검증 데이터에 대한 상관계수 R^2 은 0.81 이상으로 나타나서 학습된 인공신경망 모델은 기타 유사한 지반상태에서 시공이 되는 터널현장에서 적용이 가능할 것으로 사료된다. 단, 지중변위의 경우는 검증 시 낮은 상관관계와 추세가 불일치하는 것으로 나타나서 적용성이 떨어지는 것으로 판단된다. 추후 인공신경망 모델을 이용한 터널 계측의 신뢰성 향상을 위해서는 보다 더 많은 구간에 대해서 검증이 필요할 것으로 사료된다.

3) 한편, 다양한 지형 및 지질조건 하에서의 터널거동 예측을 위해서는 더 많은 케이스의 결과가 필요하며 다양한 조건의 터널현장 측정자료가 필요할 것으로 판단된다. 이를 확보하기 위해서 시공된 터널현장 측정자료의 축적과 다양한 인공신경망 모델 구축이 필요할 것으로 판단된다.

참고문헌

1. 김대수(1992), “신경망 이론과 응용(I)”, 하이테크정보, pp. 364.
2. 김홍택, 강인규, 박성원(1998), “인공신경망을 이용한 쏘일네일링 굴착벽체의 변형 예측기법에 관한 기초연구”, 대한토목학회 학술발표회 논문집, pp.401-404.
3. 신휴성, 권영철(2009), “미시추 구간의 정량적 지반 등급 분류를 위한 윈도우-쉬프팅 인공 신경망 학습 기법의 개발”, **한국터널공학회논문집** 11권 2호, pp. 151~162.
4. 이종구(2002), “인공신경망을 이용한 터널 거동예측시스템 개발”, 경희대학교 일반대학원 박사학위논문, pp 1~5.
5. Eberhart R. and Dobbins R. (1990), “Neural Network PC Tools; A Practical Guide”, *Academic Press*, pp. 414.
6. McCulloch W. S. and Pitts W. H. (1943), "A logical calculus of the ideas immanent in nervous activity", *Bulletin of Mathematical Biophysics*, Volume 5, pp. 115~133.
7. Pande, G. N. and Shin, H. S. (2004), "Artificial Intelligence v. Equations", *Proceedings of Institute of Civil Engineers in Civil Engineering*, Vol. 157, No. 1, pp. 39~42.
8. Prechelt L. (1998), “Automatic early stopping using cross validation: quantifying the criteria”, *Neural Networks*, Vol. 11, pp. 761~767.
9. Pao Y. (1989), “Adaptive pattern Recognition and Neural Networks”, *Addison-Wesley*, pp. 309.
10. Rich E. and Knight K. (1990), “Artificial Intelligence”, *McGraw-Hill Inc.*, pp. 612.
11. Rosenblatt, F. (1958), "The Perceptron: A Probabalistic Model for Information Storage and Organization in the Brain", *Psychological Review*, Volume 65, pp. 386~408.
12. Rumelhart, D. E. and McClelland, J. L. (1986), “Parallel Distributed Processing”, Volume I, II, *MIT Press*, Cambridge.
13. Shin, H. S. (2002), “Neural network based constitutive models for finite element analysis”, PhD thesis, *Department of Civil Engineering*, University of Wales Swansea..
14. Skouras K., Groutis C., and Bramson M.J. (1994), “Estimation in linear-models using gradient descent with early stopping”, *Statistics and Computing*, Vol. 4, No. 4, pp. 271~278.
15. Wasserman P.D. (1989), “Neural Computing: Theory and Practice”, *ANZA Reasearch Inc.*, pp. 230.