

## 인공신경망을 이용한 압밀거동 예측

# Estimating a Consolidation Behavior of Clay Using Artificial Neural Network

박형규<sup>1)</sup>, Hyung-Gyu Park, 강명찬<sup>2)</sup>, Myung-Chan Kang, 이 송<sup>3)</sup>, Song Lee

<sup>1)</sup> 서울시립대학교 토목공학과 석사과정, Graduate Student, Dept. of Civil Engineering, University of Seoul

<sup>2)</sup> 서울시립대학교 토목공학과 박사과정, Graduate Student, Dept. of Civil Engineering, University of Seoul

<sup>3)</sup> 서울시립대학교 토목공학과 교수, Professor, Dept. of Civil Engineering, University of Seoul

**SYNOPSIS** : Artificial neural networks are efficient computing techniques that are widely used to solve complex problems in many fields. In this study, a back-propagation neural network model for estimating a consolidation behavior of clay from soil parameter, site investigation data and the first settlement curve is proposed. The training and testing of the network were based on a database of 63 settlement curve from two different sites. Five different network models were used to study the ability of the neural network to predict the desired output to increasing degree of accuracy. The study showed that the neural network model predicted a consolidation behavior of clay reasonably well.

**Key words** : Artificial neural networks, Back-propagation, Predict, Consolidation behavior

## 1. 서 론

현재 연약지반 계량시의 압밀거동은 Terzaghi 압밀이론이나 유한변형 압밀이론을 이용하여 예측하는 것이 일반적이나, 실제 예상한 침하량과 침하 시간은 현장의 계측치와 다소 차이가 발생하는 실정이다. 이에 인공신경망 이론은 복잡한 상호관계를 가지는 영향인자와 물리적 거동간의 상호관계를 파악하는데 효과적으로 사용되므로, 본 논문에서는 실제 현장기록과 실내 실험자료 그리고 지반 조사자료 등의 영향인자를 이용하여 인공신경망 학습을 수행한 후에 실내 실험 데이터와 현장 조건을 바탕으로 현장의 침하량을 예측하고자 한다. 또한 침하에 영향을 주는 주요 인자의 파악과 최적의 입력인자를 알아보고, 이를 바탕으로 최적의 인공신경망 설계방안을 제시하고자 한다. 이에 우선 기존의 표준압밀시험 데이터를 이용하여 모듈형 인공신경망 학습을 수행하였고, 실내시험의 침하량과 침하 시간의 예측을 통하여 현장에서의 침하 예측 가능성을 파악하였다. 현장 계측자료와 실내시험 데이터를 사용하고 다양한 인공신경망 설계 방안을 적용하여 학습을 수행한 인공신경망 모델을 이용하여 현장의 침하량과 침하 시간의 예측을 실시하였다.

본 논문에서는 성토단계를 분리한 모듈형 인공신경망을 사용하며, 공학적으로 많이 응용되고 있는 역전파 이론(Back Propagation)을 이용하여 학습을 수행하였다. 또한, 학습에 사용하지 않은 데이터를 사용하여 신뢰성을 검증하여 보고자 한다.

## 2. 모듈형 인공신경망

### 2.1 모듈형 인공신경망 알고리즘

실제 어떤 특정한 문제점이 발생하였을 때 우리는 어떤 특정 분야에 대한 전문가가 필요하다. 이때 특정 분야 전문가라는 것은 일반적인 지식 중에서 특정한 영역의 지식을 가진 사람으로써, 모든 일반적인 지식을 모른다고 해서 놀라운 일이 아니라고 할 수 있을 것이다. 이와 마찬가지로 일반적인 인공신경망이란 어느 특정한 분야에 대한 신경망으로써 복잡한 물리적 거동에 대해서는 하나의 인공신경망이 아닌 여러 인공신경망을 복합한 신경망이 필요하게 되었다. 즉, 일반적인 인공신경망은 신경망에서 계산된 예측치와 실제 값을 비교하여 입력층과 출력층 사이의 연결강도를 예측치가 실제 값에 수렴할 때까지 역으로 변화시켜 가는 방식을 따르나, 이러한 방식의 신경망은 각 성도 단계에서의 특수성을 고려하지 못하고 전반적인 성도에서 침하와 침하 시간과의 관계를 파악하는 것으로 전반적인 해를 구할 수 있으나 특정 성도 단계에 대한 정확한 예측이 떨어지는 편이다. 이에 본 논문에서는 각각의 성도 단계에서의 침하 시간과 침하량을 이용하여 각각의 범위에 적합한 인공신경망을 형성한 후에 하나의 범위로 통합시킨 신경망인 모듈형 인공신경망을 사용하여 학습을 수행하였다.

본 논문에서 사용한 모듈형 인공신경망의 개략도는 아래 그림 1과 같으며, 각각의 모듈은 하나의 성도 단계를 의미하는 것으로써, 하나의 모듈은 하나의 일반적인 신경망과 동일하게 작용한다. 여기서 각 모듈에서의 최적의 신경망을 선택하기 위하여 은닉층의 수와 노드수는 각각 다르게 사용하였으며, 최종적으로는 각각의 모듈에서의 침하시간과 침하량이 결과 부분에서 합해지는 과정을 가지고 있다.

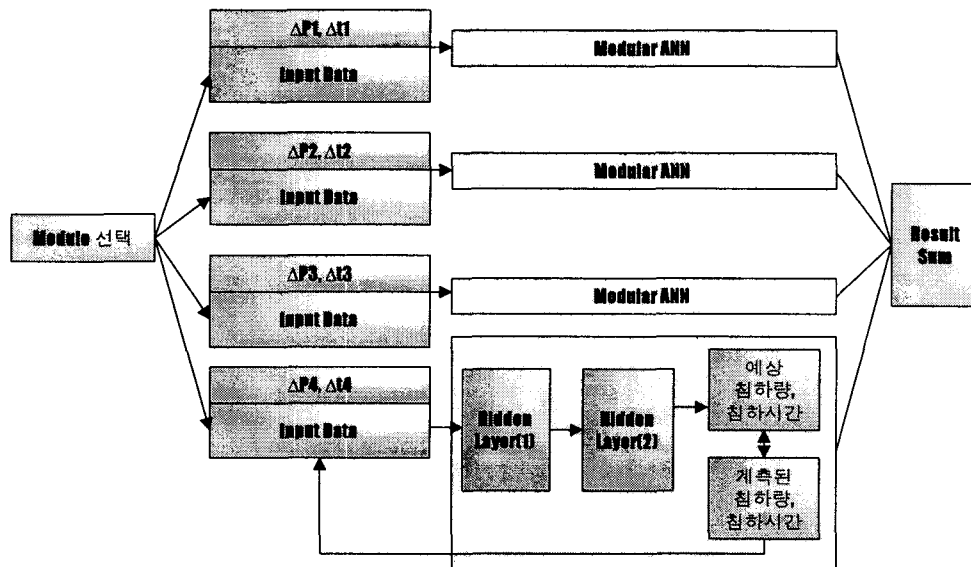


그림 1 모듈형 인공신경망 개략도

### 2.2 모듈형 인공신경망의 설계

Eberhart와 Dobbins는 신경망 이론에 역전과 이론을 적용할 때 다음과 같은 순서를 거쳐야 한다고 제안하였다.

#### 2.2.1 데이터 확보와 정규화

인공신경망의 학습을 위한 데이터를 수집하게 되는데, 비록 데이터 수가 많게 되면 학습에 걸리는 시

간이 증가되지만, 많은 수의 데이터와 많은 횟수의 학습은 비선형 함수에 대한 정확한 이해를 가능하게 하여 보다 정확한 침하량 예측이 수행될 수 있으므로 각 모듈당 충분한 수의 데이터의 확보는 신경망 학습의 정확도와 직결되게 된다. 또한 학습 후 수렴 정도를 높이기 위해서는 인공신경망에 학습을 시키기 전에 데이터를 0~1사이의 값으로 정규화 하여야 하며, 본 논문에 사용된 정규화 방법은 Master의 방법(1993)을 따르기로 한다.

학습 데이터 중 최대 값과 최소 값을  $V_{max}$ 와  $V_{min}$ 이라고 한다면 임의의 값  $V$ 는 다음의 A값으로 정규화 된다.

$$A = \frac{(V - V_{min})}{(V_{max} - V_{min})} \quad (1)$$

## 2.2.2 영향인자 파악

침하 거동에 영향을 미치는 중요 인자를 파악하고 이러한 인자를 가지고 학습을 하는 것이 인공신경망의 학습 정밀도를 좌우하는 중요한 부분으로 만약 침하거동에 영향을 미치지 않는 인자를 학습인자로 사용하고 중요인자를 학습에 사용하지 않게 된다면 영향 인자와 Output간의 상호관계의 파악이 되지 않아 그 정확도는 현저히 떨어지게 된다. 이에 중요 인자와 영향을 미치지 않는 인자를 모두 학습에 사용하게 된다면 학습에 소요되는 시간이 커지게 될 것이고, 중요인자가 아닌 인자들은 일종의 Noise 작용을 하게 되어 정확도의 감소는 물론 수렴 여부도 불확실하게 되므로 입력 Parameter와 출력 Parameter간의 상관관계를 파악하여 최소한의 중요인자를 파악하는 것이 중요하다.

## 2.2.3 인공신경망 학습

학습은 출력 층에서의 오차의 제곱의 합이 더 이상 최소화되지 않을 때까지 수행하는 것을 기본으로 하되, 기본적으로 10000 Cycle 이상의 학습을 수행하며 오차 제곱의 합이 더 이상 최소화하지 않을 경우나 기준 오차 이내에 도달할 때까지 학습을 수행하였다. 10000 Cycle의 학습을 수행하는데 약 30초의 시간이 소요되었다. 또한 은닉층의 수와 은닉 층에서의 Node의 수를 변화시켜가며 오차 제곱의 합이 최소가 되는 신경망을 최적의 신경망으로 규정하여 학습을 수행하였다.

## 2.2.4 신뢰성 검증

학습이 종료된 후에 학습에 사용되지 않은 데이터를 가지고 신경망의 신뢰성을 검증하여야 하며, 이때 검증에 사용되는 데이터의 정규화 된 입력 변수 값은 0에서 1사이의 값을 가져야 한다. 만약 이 범위에 포함되지 않는다면 학습에 의한 Mapping된 범위를 벗어나게 됨으로써 신뢰성 검증에 합당한 결과를 산출하지 못하게 되는 우를 범하게 된다.

## 2.2.5 상대적인 중요도 파악

신경망 학습 후 학습인자의 상대적인 중요도를 파악함으로써 중요도가 낮은 입력 Parameter를 다음 학습에서 제외시키고 새로운 Parameter를 학습에 사용함으로써 최적의 인자를 사용하여 신경망 학습이 가능하게 된다. 여기서 신경망 학습인자의 상대적인 중요도를 파악함은 1991년 Garson이 제안한 방법을 사용하였다.

### 3. 모듈형 인공지능망 설계 방안

본 논문에서는 기존의 실내 압밀시험 데이터를 이용하여 모듈형 인공지능망을 학습시킨 후 침하량과 침하시간을 예측하여 현장 침하거동 예측 가능성을 파악하였다. 또한 현장 계측자료와 실내시험 데이터를 사용하고 다양한 인공지능망 설계 방안을 적용하여 학습을 수행한 인공지능망 모델을 이용하여 현장의 침하량과 침하 시간의 예측을 수행하였으며, 설계방안 중 최적의 설계방안과 침하량-침하시간에 영향을 미치는 주요인자에 대하여 살펴보았다.

#### 3.1 실내 압밀시험 데이터를 이용한 학습(설계방안 I)

그림 2와 같이 표준압밀시험을 현장의 지반에 재하 하는 성토 과정으로 모델링하여 침하량과 침하시간을 예측하여 보았다. 이에 우선 기존의 표준압밀시험 데이터를 이용하여 모듈형 인공지능망 학습을 수행하였고, 실내시험의 침하량과 침하 시간의 예측을 통하여 현장에서의 침하 예측 가능성을 파악하였다.

실내 압밀시험 데이터를 이용한 학습의 설계방안은 물성시험과 역학시험자료 등을 이용하는 가장 일반적인 설계방안으로써, 입력 변수로는 LL, PI,  $P_c$ ,  $P_0$ ,  $P_1$ ,  $C_c$ ,  $C_v$ ,  $e_0$  를 사용하였다. 또한 각 하중단계에서의 시간에 따른 침하량은 전체 하중 재하 시간을  $T_T$ 라 할 때  $0.1T_T$ ,  $0.5T_T$ ,  $0.75T_T$ ,  $1.0T_T$ 에 해당하는 시간의 침하량을 예측하도록 설계하였다.




그림 2 표준압밀시험의 재하와 침하곡선

물성시험 자료	역학시험 자료	현장 재하 자료	하중-시간-침하곡선
LL, PI	$P_c$ , $C_c$ , $C_v$ , $e_0$	$P_0$ , $P_1$	

표 1 설계방안 I에서의 입출력 Parameter

#### 3.2 물성시험 자료와 압밀 계수값 등을 이용한 학습(설계방안 II)

일반적으로 압밀 설계자료로 사용하는 LL, PI,  $P_c$ ,  $C_c$ ,  $C_v$ 와 같은 물성시험과 역학시험자료 그리고 연약층의 심도와 두께 그리고 각 성토 단계에서 성토시간과 성토하중을 입력 변수로 사용하여 학습을 수행하였고, 인공지능망 학습인자를 변화시켜가면서 수렴시간보다는 수렴정도가 높은 인공지능망을 최적의 설계 상태로 설정하여 학습을 수행하였다. 또한 각 성토단계에서의 시간에 따른 침하량은 전체 시간을  $T_T$ 로 할 때  $0.1T_T$ ,  $0.25T_T$ ,  $0.5T_T$ ,  $0.75T_T$ ,  $1.0T_T$ 에 해당하는 시간의 침하량을 예측하도록 설계하였다.

물성시험 자료	역학시험 자료	지반조사자료	하중-시간-침하곡선
LL, PI $D_{10}$ , $D_{50}$	$P_c$ , $C_c$ , $C_v$ , $r_d$	연약층의 두께 연약층의 깊이 	

표 2 설계방안 II에서의 입출력 Parameter

### 3.3 물성시험 자료와 실제 역학시험 데이터 등을 이용한 학습(설계방안 III)

설계방안 II에서의 역학시험 자료에 사용된  $P_c$ 값이나  $C_c$ 값 등은  $e - \log P$  곡선을 모두 표현하지 못하므로  $e - \log P$  곡선을 입력변수로 직접 사용함으로써 보다 정확한 압밀거동에 대한 고려가 이루어질 수 있다. 그와고공소괄세미양인 0.14, 0.25, 0.54, 0.75, 1.0의 모든 입력 Parameter들은 동일하되 역학시험 자료만을  $e - \log P$ 로 대체하여 학습을 수행하였다.




표 3 설계방안 III에서의 입력력 Parameter

### 3.4 설계방안 II + 초기 성토-침하기록을 이용한 학습(설계방안 IV)

설계방안 II나 III는 물성시험과 역학시험 자료 그리고 지반조사 자료를 이용하여 인공 신경망을 학습시킨 것으로써, 위의 입력자료들이 현장의 모든 여건과 지반조건을 반영하기에는 무리가 따른다고 할 수 있다. 그러므로 현장의 여건을 내포하고 있는 초기 현장 하중-시간-침하 곡선을 입력변수로 사용함으로써 보다 합리적인 침하 예측이 이루어질 수 있다. 따라서 설계 방안 IV에서는 설계방안 II에서 사용된 입력 Parameter에 초기 성토-침하기록을 추가하여 학습을 수행하였다.




그림 3 설계방안 IV에서의 입력 Parameter

### 3.5 물성시험과 초기 성토-침하기록 등을 이용한 학습(설계방안 V)

갑작스러운 시공 등으로 인한 역학시험 자료가 없는 경우에 대하여 침하량 예측을 수행하였으며, 역학시험에서의  $C_c$ 값과  $C_v$ 값을 대체하기 위하여 LL값이나 입도 분포 데이터 그리고 1단 성토시의 성토-침하기록을 사용하였다. 학습에 사용된 입력 데이터는 그림과 같다.




그림 4 설계방안 V에서의 입력 Parameter

### 3.6 초기 성토-침하기록을 이용한 학습(설계방안 VI)

비록 실내시험과 지반조사 자료를 가지고 압밀이론에 따른 침하예측을 하지만 실제 예상한 침하량과 침하시간에는 다소 차이가 발생하는 실정이다. 이에 현장에서는 시공 중에 지표 침하나 간극수압 계측 등을 실시하고 쌍곡선법이나 Hoshino법 등의 방법에 초기 현장 자료를 사용하여 침하량 예측을 보완하고 있다.

이와 마찬가지로 초기현장 자료만을 가지고 침하량을 예측함으로써 지반조사와 실내시험을 수행하기 전이나 수행하기 힘든 경우에 초기 성토-침하기록과 신경망을 이용한 침하 예측이 가능한가를 파악해 보았다.




그림 5 설계방안 VI

#### 4. 인공신경망 해석 시스템의 적용 및 검증

방안 II에서 방안 VI까지 학습에 사용된 지반의 지층 분포는 퇴적층, 잔류토층, 풍화암으로 구분되며 퇴적층은 상부충적층, 상부해성층, 하부해성층으로 구분되어 있다. 연약층을 구성하는 토성은 CL 또는 ML로 하부로 갈수록 세립의 모래 및 실트질 모래가 분포하며, 압밀특성은 다소 과압밀된 상태로 압축성이 낮은 상태이다.




그림 6 퇴적 지층분포

	자연함수비 W <sub>n</sub> (%)	액성한계 W <sub>L</sub> (%)	초기 간극비 e <sub>0</sub>	압축지수 C <sub>c</sub>
상부 해성층	26-48	25-38	0.74-1.3	0.11-0.41
하부 해성층	24-36	27-44	0.67-1.0	0.11-0.33

표 4 현장의 지반 물성치

#### 4.1 실내 압밀시험 데이터를 이용한 학습결과(설계방안 I)

표준압밀 시험에서의 침하량과 침하시간을 예측하기 위하여 학습인자를 학습시킨 결과 첫 번째 은닉층과 두 번째 은닉층의 수가 4개 그리고 학습률 0.1, 모멘텀 상수가 0.1인 상태에서 가장 학습오차가 작게 나타났다. 그림 7과 같이 10000 번의 학습이 수행된 후에 학습오차가 10<sup>-7</sup> 정도의 정밀도가 나와 충분한 정밀도를 가지고 학습이 수행됨이 나타났다. 또한 그림 8에서 표준압밀에서 P<sub>1</sub>, P<sub>0</sub>, C<sub>c</sub>, LL등의 입력변수가 침하 거동에 가장 영향을 많이 미치는 중요인자로 나타났다.




그림 7 학습횟수에 따른 학습오차




그림 8 설계방안 I에서의 상대적인 중요도

위에서 제안된 설계방안에 의하여 학습된 신경망의 신뢰성을 검증하기 위하여, 학습에 사용되지 않은 실제 표준압밀 실험 데이터를 가지고 침하량과 침하시간을 예측하였다. 그 결과 그림 9와 같이 성토 초기의 0.1T<sub>r</sub>를 제외하고 95% 이상의 정확도로 침하량을 예측함으로써 모듈형 인공신경망에 의한 현장의 침하량과 침하시간의 예측 가능성을 제시하였다.





그림 9 표준압밀 데이터에 의한 침하량과 침하시간예측


## 4.2 실내 시험자료와 초기 성토-침하기록 등을 이용한 현장의 침하량 산정 (설계방안 II ~ VI)

그림 10은 설계방안에 따른 대표적인 시간-침하곡선으로, 설계방안에 따른 특징은 다음과 같다. 설계방안 II, III에서의 중요인자는  $P_0$ ,  $P_1$ ,  $T_L$ ,  $T_T$ 와 상부해성층의 두께와 깊이로 나타났으며, 설계방안 IV ~ VI에서의 중요인자는  $P_0$ ,  $P_1$ ,  $T_L$ ,  $T_T$ 와 초기침하곡선으로 나타났다. 설계방안 II는 초기침하량 예측 정밀도가 높은 반면 설계방안 III의 경우  $0.5T_T$ 이후의 정밀도가 높은 것으로 나타났다. 설계방안 IV는 비교적 많은 영향인자를 고려함에도 불구하고 설계방안 II, III 정밀도를 가진 침하량 예측을 하였다. 이는 중요인자가 아닌 학습인자를 너무 많이 적용함으로 인하여 일종의 Noise 작용을 한 것으로 보이며, 데이터 수에 비하여 너무 많은 영향인자를 사용하여 정확한 수렴이 어려웠던 것으로 사료된다.


이에 반하여 설계방안 V는 물성 자료와 지반조사자료를 이용하여 설계방안 II, III 보다 높은 정밀도로 침하량을 예측함으로써 최적의 설계방안으로 제시되었다. 또한 설계방안 VI는 초기 침하예측이 너무 과소 평가되기 때문에 따라서 전체적인 침하거동 예측보다는 최종침하량 예측에 사용함이 합당한 것으로 보인다.




설계방안 II (a)




설계방안 III (b)



설계방안 IV (c)



설계방안 V (d)



설계방안 VI (e)

그림 10 설계방안에 따른 시간-침하곡선(a~e)

설계방안	정밀도(%)
설계방안 II	91.0~92.8
설계방안 III	65.0~99.2 0.5 $T_T$ 이후 95%이상
설계방안 IV	82.0~100.0
설계방안 V	93.0%이상
설계방안 VI	50.0~99.0 최종침하량 95%이상

표 5 설계방안별 정밀도




그림 11 실측값과 예측값

그림 11은 현장계측에 의한 최종침하량과 모듈형 인공신경망 및 Terzaghi 압밀이론에 의해 각각 예측된 최종침하량과의 상관관계를 나타내고 있다. 모듈형 인공 신경망에 의해 예측된 침하량은 실측치에 비하여 약간 과소 평가하는 경향을 보이나, 이에 반해 Terzaghi 압밀 이론에 의한 침하량 산정치는 다소 과대 평가하는 경향을 보인다. 이는 본 지역의 경우, 상부층은 압축성이 큰 연약지층이고 하부로 갈수록 세립의 모래나 실트질 모래 등의 압축성이 다소 낮은 지층을 형성하고 있지만 Terzaghi 압밀 이론에 의한 최종 침하량 예측 시 상부 연약층의 물성치 사용에 기인한다고 판단된다.

모듈형 인공신경망에 의해 추정된 침하량과 실측 침하량과의 상관도  $R^2$ 은 0.98이며, Terzaghi 압밀 이론에 의한 침하량과 실측 침하량과의  $R^2$ 은 0.59정도로 모듈형 인공신경망에 의한 침하량 예측이 Terzaghi 압밀 이론에 의한 침하량 산정보다 정확한 침하량 예측이 가능한 것으로 나타났다.

## 5. 결론

본 연구에서는 모듈형 인공신경망을 이용하여 연약지반 개량시 성토하중에 의한 침하 및 침하시간의 예측을 위한 연구를 수행하였다.

이를 위해 표준압밀시험을 현장 지반의 성토과정으로 모델링한 학습을 통하여 현장의 침하 예측가능성을 확인하였고, 다양한 설계방안을 적용하여 최적의 설계방안과 압밀거동에 영향을 미치는 중요인자를 파악함으로써 다음과 같은 결론을 도출하였다.

- 1) 모듈형 인공신경망에 의하여 비교적 높은 정밀도를 가지는 시간-침하곡선을 얻을 수 있었다.
- 2) 설계방안 V가 가장 높은 93% 이상의 정밀도를 가지고 시간에 따른 침하량을 예측할 수 있었다. 비록 설계방안 IV가 비교적 많은 영향인자를 고려함에도 불구하고 설계방안 V보나 낮은 정확도를 갖은 이유는 데이터 수에 비해 너무 많은 영향인자를 사용하여 정확한 수렴이 어려웠던 것으로 사료된다.
- 3) 설계방안 VI의 경우 전체적인 침하거동 예측보다 최종침하량 예측에 사용함이 합당한 것으로 보인다.
- 4) 5가지 설계방안에서  $P_0$ ,  $P_1$ ,  $T_L$ ,  $T_T$  등이 시간에 따른 침하에 영향을 미치는 가장 중요한 인자로 나타났다.
- 5) Terzaghi 압밀이론에 의해 추정된 최종 침하량보다 모듈형 인공신경망에 의해 예측된 침하량이 비교적 정확한 것으로 나타났다.
- 6) 보다 많고 다양한 현장의 침하기록과 현장의 여건을 보다 정확히 반영할 수 있는 입력변수의 도입이 보다 정확한 침하거동 예측에 필수 조건이라고 생각되며, 연결강도의 수렴 시간 단축보다는 수렴정도의 개선을 위한 방안이 필요하다고 본다.

## 참고문헌

1. 김대수(1993), "신경망 이론과 응용", 하이테크 정보, 97~117
2. Asaoka, A.(1978). "Observational procedure of settlement prediction", Soil and Foundation, Vol.18, No.4, pp.87~101
3. Garson, G. D. (1991). "Interpreting neural-network connection weights." AI Expert, 6(7), 47~51
4. Goh, A. T. C. (1994). "Seismic liquefaction potential assessed by neural networks." J. Geotech. Engrg., ASCE, 120(9), 1467~1480
5. Jingsheng Shi, J. A. R. Ortigao, and Junli Bai(1998), "Modular Neural Networks for Predicting Settlement during Tunneling", J. Geotech. Engrg. ASCE, Vol. 124, No. 5, pp. 389~395
6. Schmertmann, J. M.(1953). "Estimating the true consolidation behavior of clay from Laboratory test results", Transaction of ASCE, Vol, pp. 311-1~311-25