

모듈형 인공신경망을 이용한 연직배수공법에서의 압밀침하량 예측

Prediction of Consolidation Settlements at Vertical Drain Using Modular Artificial Neural Networks

민 덕 기*¹ Min, Tuk-Ki
황 광 모*² Hwang, Kwang-Mo
전 형 원*³ Jeon, Hyoung-Won

Abstract

In this paper, consolidation settlements with time at vertical drain sites were predicted by artificial neural networks. Laboratory test results and field measurements of two vertical drain sites were used for training and testing neural networks. Predicted consolidation settlements by trained artificial neural networks were compared with measured settlements by field instrumentation. To improve the prediction accuracy, modular artificial neural networks were studied.

From the results of applying artificial neural networks to the same situation, it was shown that modular artificial neural network model was more accurate for the prediction of the consolidation settlements than the general model.

요 지

본 논문에서는 인공신경망을 이용하여 연직배수공법에 있어서 시간에 따른 압밀 침하량을 예측하여 보았다. 연직배수공법이 시행된 두 지역 현장의 실내시험과 침하계측 자료를 이용하여 인공신경망을 학습시키고, 학습된 인공신경망을 통하여 얻어진 압밀 침하량과 실제 압밀 침하량을 비교 분석하였으며, 보다 정확한 예측을 하기 위하여 모듈형 인공신경망의 개념을 도입하였다. 여러 개의 모듈로 구성된 모듈형 인공신경망과 일반 인공신경망을 이용하여 압밀 침하량을 예측해 본 결과, 모듈형 인공신경망 모델이 일반 인공신경망 모델보다 정확한 예측을 하는 것으로 나타났다.

Keywords : Modular artificial neural networks, Consolidation settlement, Vertical drain

*1 정희원, 울산대학교 공과대학 토목환경공학과 교수

*2 정희원, 울산대학교 대학원 토목공학과 박사 과정

*3 정희원, 울산대학교 대학원 토목공학과 석사 과정

1. 서론

본 연구에서는 인공신경망을 이용하여 연직배수공법에 있어서 성토하중에 따른 경시적 압밀 침하량을 예측하고자 하였다. 연직배수공법의 설계와 압밀침하량의 예측의 경우에 다음과 같은 사항을 필수적으로 고려한다.

- 1) 연직배수공법의 대상이 되는 지반의 기본 물성과 역학적 특성.
- 2) 연직 배수재의 기본 물성과 배수재의 간격과 시공 방법.
- 3) 선행재하공법에 사용되는 성토하중의 재하시기, 지속 기간 그리고 재하하중의 크기.

연직배수공법에서 위의 사항을 대부분 고려하여 압밀 침하량을 예측하지만 압밀침하에 미치는 여러 변수들의 상호관계를 정확하게 반영하지 못하거나 또는 그 영향을 무시하기 때문에 정확한 예측이 어렵다. 이러한 문제점을 보완하기 위하여 현장에서는 계측을 통하여 시공 중에 발생하는 여러 문제점을 파악하여 현장의 여건에 맞추어 공사를 진행하고 있다. 본 논문에서는 연직배수공법의 설계에 사용되는 변수들과 압밀침하량에 영향을 줄 것으로 예상되는 변수들 그리고 현장 계측 결과들을 이용하여 성토하중에 따른 경시적 압밀 침하량을 예측할 수 있는 인공신경망을 연구하였다.

경과 시간에 따른 침하예측을 지반의 특성과 현장 여건을 고려하여 예측하기 위하여 실제로 연직배수공법이 시행된 여러 현장의 물성시험과 역학시험 그리고 현장 침하 계측 자료 등을 이용하여 인공신경망을 학습시키고, 학습된 신경망을 통하여 얻어진 침하량과 실제 침하량을 비교 분석하였다. 또한 압밀침하량을 보다 정확하게 예측하기 위하여 모듈형 인공신경망의 개념을 도입하여 인공신경




그림 1. 다층 오류 역전파 신경망

망을 구성하고 교육시켰다.

2. 인공신경망

인간의 두뇌와 신경 세포에 대한 연구에서 시작된 신경망에 대한 연구는 세포의 가장 기본적인 뉴런을 수학적인 모델로 나타내고 이러한 모델로 구성된 인공신경망은 현재 여러 분야에서 많은 문제에 이용되고 있다.

1943년 McCulloch와 Pitts⁸⁾가 제안한 최초의 수학적 모델에서 시작된 인공신경망은 현재까지 여러 학자들에 의하여 많은 모델들이 제안되었지만, 1986년 Rumelhart 등이⁹⁾ 제안한 일반화된 델타 규칙(generalized delta rule)이 현재 인공신경망 모델로 가장 널리 이용되고 있다. 이 규칙은 다층 퍼셉트론(multi-layer perceptron)을 학습시키기 위한 학습규칙으로 주로 사용되며, 이렇게 다층 퍼셉트론과 일반화된 델타 규칙을 결합한 형태를 오류 역전파(error back propagation) 알고리즘이라 부른다.

오류 역전파 신경망은 그림 1과 같이 입력층과 출력층 그리고 2개 이상의 은닉층으로 구성되었다.




그림 2. 모듈형 인공신경망 구성

3. 모듈형 인공신경망

일반적으로 사용되고 있는 다층 오류 역전파 인공신경망은 하나의 입력층과 여러 개의 은닉층 그리고 출력층으로 구성되어 있다. 이러한 인공신경망을 모듈형 신경망과 구분하기 위하여 본 연구에서는 일반 인공신경망이라 부르기로 한다.

현실적인 문제에 있어서 어떠한 특정 문제를 해결하기 위해서는 그 문제에 가장 적합한 전문적인 지식이 필요한 것이지 폭 넓은 일반적인 지식이 필요하지는 않다. 이것을 인공신경망의 관점에서 보면 어떠한 문제를 해결하기 위한 인공신경망은 그 문제에 가장 적합한 학습 패턴으로 학

습한 인공신경망이 그 문제를 해결하는 능력이 가장 뛰어나다. 모듈형 인공신경망은 이러한 개념을 도입한 것이다. 모듈형 인공신경망은 그림 2와 같이 여러 개의 일반 인공신경망들을 병렬의 형태로 구성한 것이며, 각각의 모듈은 한가지의 문제를 해결하기 위한 일반 인공신경망으로 되어 있다. 각각의 모듈은 그 목적에 알맞은 학습패턴으로 학습하고, 학습되어진 모듈을 통한 결과는 최종적 결과를 출력하기 이전에 모든 결과를 조합하여 최종적인 값을 출력한다. 이와 같이 모듈형 인공신경망은 폭넓은 범위에 대한 예측보다는 복잡하고 정확한 예측에 적합한 인공신경망이라 할 수 있다.

인공신경망에 있어서 결과의 예측에 큰 영향을 미칠 수 있는 것 중의 하나가 입력 패턴이다. 인공신경망을 학습시키고 결과를 예측하는데 있어서 잘못 분류되거나 계산된 입력 값을 사용할 경우 출력 값 또한 정확하지 못할 것이다.

인공신경망에 있어서 입력 패턴에 문자형(label) 변수가 있을 경우 인공신경망은 이것을 인식할 수 없으므로 인공신경망에 문자형 변수를 사용하기 위해서는 문자형 변수를 수(number)의 변수 형태로 바꾸어야 한다. 하지만 문자형 변수를 임의의 수의 형태로 바꾸어 입력할 경우 문자형 변수가 가지고 있던 의미와는 상당한 차이를 갖게 된다. 즉 임의의 숫자를 부여함으로써 인하여 문자형 변수들 사이에 상하 관계가 형성되고 이 관계에 의하여 인공신경망을 학습할 경우 의도한 것과는 다른 형태의 인공신경망이 될 것이다. 또한 하나의 출력 값을 위한 인공신경망이라도 뚜렷하게 분류가 되는 2개 이상의 그룹으로 입력 패턴이 구분되는 경우에 있어서는 하나의 일반 인공신경망이 두 가지 이상의 패턴의 입력 값으로 학습을 하기보다는 두 개 이상의 모듈화된 인공신경망을 사용하여 각각의 입력 패턴에 맞는 인공신경망을 구성하는 것이 보다 정확한 예측을 할 수 있을 것이다.

이와 같이 모듈형 인공신경망은 입력 패턴에 문자형 변수를 포함하고 있거나 뚜렷하게 구분되는 경우의 학습과 예측에 적용 가능하다.

모듈형 인공신경망은 일반 신경망과 달리 여러 개의 목적 패턴을 가지는 경우에도 보다 정확한 예측을 할 수 있다. 일반 신경망에 있어서 예측하고자 하는 목적 값이 두 개 이상일 경우 신경망은 실측값과 예측값의 오차를 최소화하기 위하여 가중치를 조정할 것이다. 하지만 학습이 완료된 일반 인공신경망은 두 개 이상의 목적값 모두 만족할 수 있는 결과를 출력하지만, 하나의 목적값을 가진 일반 인공신경망에 비하여 결과의 정확도는 떨어질 것이다. 그러므로




그림 3. 모듈형 인공신경망에서의 모듈과 다수의 목적 값

일반 인공신경망에서는 하나의 예측 값을 가진 신경망이 정확하다고 볼 수 있다.

여러 개의 목적 값을 갖은 일반 인공신경망에 모듈형 인공신경망의 개념을 사용하면 그림 3과 같다. 하나의 모듈은 하나의 목적 값에 대해서만 예측을 함으로써 하나의 예측 값을 가진 일반 인공신경망이 병렬의 형태로 구성된 것과 같으며, 결과의 예측에 있어서도 여러 개의 목적 값을 예측하는 일반 인공신경망보다 정확한 결과를 예측 할 수 있을 것으로 기대된다.

4. 연직배수공법 시공 현장

연직배수공법에 있어서 압밀침하량을 예측하는 인공신경망을 만들기 위해서는 인공신경망을 학습시키기 위한 학습자료가 필요하다. 본 연구에서는 경남 Y지역과 전남 K지역에서 실제 시공된 연직배수공법 관련 자료들을 분석하여 인공신경망을 위한 학습자료를 만들었다.

두 지역의 표고는 해수면을 기준으로 한 것이며, 모두 해안과 가까운 곳에 위치해 있다. 두 지역 모두 연약 지반 층이 약 10~20m 깊이로 넓게 분포되어 있고, N치가 0~5 이하인 연약한 점토층으로 이루어져 있다. 각 현장의 지층 단면도는 그림 4.a, 4.b와 같다.

표 1. 시공현장 지반의 기본물성

기본 물성	범위
함수비(%)	40.0 ~ 88.0
간극비	1.15 ~ 2.6
포화도(%)	71.0 ~ 100
비중	2.50 ~ 2.75
습윤단위중량(t/m ³)	1.15 ~ 1.88
액성한계(%)	35.0 ~ 100.0
소성한계(%)	19.5 ~ 28.9
소성지수(%)	14.2 ~ 77.0
No. 200 통과량(%)	66.0 ~ 96.5
0.005mm입경이하(%)	12.4 ~ 52.8

■ 점성토 ■ 실트질 모래 ■ 자갈섞인 모래 ■ 연암층




그림 4.a 경남 Y지역 지층 단면도




그림 4.b 전남 K지역 지층 단면도

표 2. 시공현장 지반의 역학적 특성

역학 특성	범 위
일축강도(kg/cm ²)	0.1 ~ 1.2
점착력(kg/cm ²)	0.0 ~ 0.3
압축지수	0.38 ~ 1.05
선형압밀하중(kg/cm ²)	0.19 ~ 2.4
압밀계수(cm ² /sec)	0.36 ~ 8.3×10 ⁻³
체적변화계수(cm ² /kg)	0.03 ~ 0.29
투수계수(cm/sec)	0.79 ~ 6.3×10 ⁻⁶
재압밀지수(Cr)	0.032 ~ 0.31

두 현장은 모두 연직배수공법과 선형재하공법을 병용하여 시공되었으며, 배수에 의한 압밀침하량과 현장의 안정성을 평가하기 위하여 지표면과 각층의 침하 계측을 공사가 완료될 때까지 계속하였다. 두 현장은 Pack Drain으로 설계가 되어 있으며, Pack Drain 타입 후 약 60~70cm의 Sand Mat를 포설하였다. Pack Drain의 간격과 타입길이는 현장의 조건에 따라 차이가 있으며, 정방형의 배열로 시공되었다.

두 지역의 지반은 대체적으로 ML, CL, 및 CH로 분류되

표 3. 인공신경망 학습을 위한 입력 변수

지반조사	점토층 깊이	배수재의 물성	영향원 지름(de)
	N 치		Drain의 투수계수
침하계측결과	경과시간	역학적 특성	배치방법
	성토 하중		n (= de/dw)
기본 물성	함수비	설치 간격의 영향	
	간극비	일축강도	
	포화도	점착력	
	비중	압축지수	
	습윤단위중량	선형압밀하중	
	액성한계	압밀계수	
	소성한계	체적변화계수	
	소성지수	투수계수	
	No. 200 통과량	재압밀지수(Cr)	
	0.005mm입경이하		

었으며, 현장에서 채취된 교란 시료와 불교란 시료를 통한 기본 물성과 역학적인 특성은 다음의 표 1과 2와 같다.

5. 인공신경망의 학습

5.1 인공신경망 학습을 위한 입력 패턴과 목적 패턴

인공신경망 학습자료는 두 현장에서 행한 실내시험결과와 연직배수재의 물성 그리고 현장 계측을 통하여 얻은 자료를 사용하였으며, 계측 자료는 경남 Y지역에서 29개, 전남 K지역에서 31개의 자료를 사용하였다. 이중 인공신경망을 학습시키기 위하여 40개의 자료를 사용하였다.

연직배수공법에서 압밀 침하량에 영향을 미칠 수 있는 변수들을 연직배수공법의 설계 방식과 여러 경험적인 공식들을 조사 분석하여 다음 표 3과 같은 변수들로 정하였다. 입력 패턴에 사용되는 변수는 크게 지반조사를 통하여 구해지는 변수와 배수재의 물성 그리고 실내시험을 통하여 구한 기본 물성과 역학적인 물성을 포함하였으며, 연직배수공법에서의 재하하중과 경과시간 등으로 구성하였다.

5.2 각 인공신경망의 구성과 학습

인공신경망에 있어서 은닉층과 각 층의 노드의 수가 증가함에 따라 학습오차가 항상 감소하는 것은 아니다. 그러므로 본 연구에서는 은닉층의 수와 노드의 수를 변화시키며 인공신경망을 구성하였다. 그중 학습 최대 오차가 가장 작은 형태인 입력층과 출력층의 노드가 각각 29개와 1개이며, 은닉층은 모두 4층으로 구성되어있고, 각 은닉층의

노드의 수가 20개, 20개, 10개, 5개인 일반 인공신경망을 사용하였다. 그리고 이때의 실측값과 예측된 값사이의 최대 오차는 0.028이었다.

일반 인공신경망은 성토하중을 재하하는 순간부터 압밀 침하가 완료된 시간까지의 실측자료를 이용하여 학습을 위한 입력 패턴과 목적 패턴을 만들었으며, 이를 이용하여 일반 인공신경망을 학습시켰다. 일반 인공신경망의 학습에 있어서 학습 최대 오차가 1×10^{-3} 이하로 내려가지 않으면 학습을 종료하였다.

연직배수공법에서 성토하중과 성토시기 그리고 지속 시간 등을 모두 고려한 인공신경망 모델을 만들기는 상당히 어렵다. 현장의 여건에 따라서 성토하중의 크기와 시간이 불규칙하며 성토의 지속시간 또한 일정하지 않다. 그러므로 일반 인공신경망으로는 한계가 있다. 그래서 본 연구에서는 모듈형 인공신경망의 개념을 도입한 것이다

모듈형 인공신경망은 성토하중의 단계에 따라 모두 6개의 모듈로 구성하였다. 모듈에 사용하는 인공신경망은 압밀 침하량을 예측하기 위한 일반 인공신경망과 동일한 형태로 구성하였다. 하나의 모듈은 하나의 성토 단계에 대한 압밀 침하량을 예측하는 것으로 첫 번째 모듈은 하중 재하를 위한 성토고가 0에서 1m사이인 경우에 대한 압밀 침하량을 산정하며, 두 번째 모듈은 1에서 2m사이의 성토고이며, 마지막 여섯 번째 모듈은 성토고가 5~6m일 경우 침하량을 예측한다. 각 모듈에 의하여 예측된 압밀 침하량 모두는 결과 출력 전에 조합해서 전체 연직배수에 의한 압밀 침하량 결과를 출력하게 된다

모듈형 인공신경망의 각 모듈에 대한 최종 학습 오차 값은 아래의 표 4와 같았다.

표 4. 각 모듈의 학습 오차

Module	학습 최대 오차
Module 1 (성토 1단계)	0.0159
Module 2 (성토 2단계)	0.0272
Module 3 (성토 3단계)	0.0299
Module 4 (성토 4단계)	0.0290
Module 5 (성토 5단계)	0.0134
Module 6 (성토 6단계)	0.0276

인공신경망의 학습에 있어서 국부 최소치(local minimum)에 빠지는 것을 막기 위하여 본 연구에서는 주어진 입력에 대한 신경세포의 민감도를 조절하기하기 위한 바이어스(bias)와 함께 연결 가중치 조절 식에 관성을 줌으로써 학습

시간을 단축하고 학습성능을 향상하기 위한 모멘텀(momentum) 그리고 학습시 연결 가중치의 변화율을 결정하는 학습률을 변화시키며 학습시켰다. 모멘텀과 학습률을 변화시켜며 학습을 한 결과, 모멘텀과 학습률이 각각 0.5와 0.4일 때 가장 작은 오차의 학습결과를 보였다.

6. 인공신경망을 통한 결과 분석

6.1 인공신경망의 학습결과 검증

학습된 두 인공신경망에 대한 검증을 위하여 본 연구에서는 연직배수공법에서의 압밀 침하량을 재추론하였고, 재추론 능력의 지표로는 다음 식 1에서와 같은 평균추론 오차율(AIER, Average Inference Error Rate) 산정식을 사용하였다.

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

여기서, n은 추론자료이며 K_m 은 실측치, K_p 는 예측치를 의미한다.

아래 그림 5는 일반 인공신경망에서 학습에 사용된 실측값과 예측된 값 사이의 재추론 결과를 보여주고 있으며 재추론 오차율은 5.99%로 비교적 낮게 나타났다. 일반 인




그림 5. 일반 인공신경망의 재추론 결과

표 5. 각 모듈에 대한 재추론 오차율

Module	재추론 오차율
Module 1 (성토 1단계)	2.89 %
Module 2 (성토 2단계)	0.69 %
Module 3 (성토 3단계)	0.48 %
Module 4 (성토 4단계)	0.46 %
Module 5 (성토 5단계)	0.19 %
Module 6 (성토 6단계)	0.25 %

공신경망의 재추론 결과 실제의 압밀 침하량 예측에 적용 가능하다는 것을 알 수 있다.

모듈형 인공신경망의 학습에 대해서도 일반 인공신경망과 같이 평균추론 오차 식을 사용하여 재추론 오차를 구하였으며, 각 모듈에 대한 재추론 결과는 표 6과 같다.

평균추론 오차 식으로 구한 각 모듈의 재추론 오차는 Module 1의 2.89%을 제외하고는 모두 0.69%로 이하인 것으로 나타났다. 이것은 모듈형 인공신경망의 각 모듈의 학습이 잘 이루어졌다는 것을 의미한다. 또한 일반 인공신경망의 재추론 오차가 5.99%인 것에 비하여 모듈형 인공신경망의 재추론 오차가 1%이하로 나타난 것은 모듈형 인공신경망이 일반 인공신경망보다 학습이 더 잘 이루어졌으며, 보다 정확한 예측이 가능하다는 것을 의미한다.

6.2 모듈형 인공신경망과 일반 인공신경망에 의한 압밀 침하량 비교

모듈형 인공신경망이 일반 인공신경망에 비하여 어느 정도의 정확도를 갖고 있는지를 비교하기 위하여 같은 조건에서 두 신경망을 학습시켰으며, 학습결과를 검증하기 위하여 전남 K지역의 계측 자료를 이용하였다. 예측에 사용된 계측 자료는 4단계로 나누어 성토되었으며, 611일 동안 약 2.7m의 압밀 침하가 발생하였다.

두 신경망에 의한 결과는 각각 그림 6(a)와 6(b)에 나타나 있다. 그림에 나타나 있는 것처럼 두 인공신경망 모두 실제 계측된 압밀 침하량과 유사한 결과를 보여 주고 있다. 하지만 일반 인공신경망의 경우는 경과시간 초기에는 침하량이 다소 작게 예측되었으며, 경과 시간이 점차 증가할수록 압밀 침하량이 과대하게 예측되는 것을 볼 수 있다. 이와는 다르게 모듈형 인공신경망의 경우는 초기에는 과소한 침하량의 예측을 보였지만 성토하중과 경과 시간이 증가할수록 실측값과 같은 압밀 침하량을 예측하고 있는 것을 볼 수 있다. 각 성토 단계에 대한 평균오차율이 일반 인공신경망에 있어서 성토 1단계인 경우 50.3%로써 평균오차율이 성토 1단계(0~1m)에서 33.5%인 모듈형 인공신경망보다 상당히 크게 나타났다. 일반 신경망의 경우 성토 3단계(2~3m)와 4단계(3~4m) 그리고 5단계(4~5m) 모두의 평균 오차율이 11.0%에서 약 20.0% 발생한다 비하여 모듈형 인공신경망의 경우는 세 단계 모두 10%이내의 작은 평균오차를 보였다. 그러므로 연직배수공법에서 압밀 침하량 예측은 일반 인공신경망보다 모듈화된 인공신경망이 보다 정확한 예측을




그림 6(a) 일반 인공신경망에 의한 침하량 예측 결과




그림 6(b) 모듈형 인공신경망에 의한 침하량 예측 결과

할 수 있다는 것을 알 수 있다. 하지만 모듈형 인공신경망만을 살펴보면, 성토 1단계에 해당하는 Module 1의 평균 오차율이 Module 4와 5에 비하여 상당히 큰 것을 볼 수 있다. Module 1의 평균 오차는 33.5%로써 Module 2에 비하여 약 4배 정도의 차이를 보이며, Module 4와 5와는 약 30배와 15배의 큰 값을 보이고 있다. 모듈형 인공신경망의 검증을 위하여 행한 재추론 결과에서도 성토 1단계에 해당하는 Module 1은 2.89% 평균추론 오차율로써 다른 성토단계에 비하여 상당히 큰 결과를 보였다. 이와 같은 결과는 모듈형 인공신경망의 성토 1단계에 해당하는 Module 1의 학습이 다른 모듈들과 비교하여 학습이 잘 이루어지지 않았기 때문이라 판단된다.

7. 결론

연약지반 개량공법인 연직배수공법의 압밀 침하량 예측에 모듈형 인공신경망을 적용한 결과 다음과 같은 결과를 얻을 수 있었다.

- 1) 연직배수공법에 있어서 정확한 압밀 침하량을 예측하기 위하여 연직배수공법의 실측자료를 이용하여 인공신경망을 학습시켰으며, 학습 오차를 비교, 분석하여 입력층과 출력층의 노드가 각각 29개 1개이며, 은닉층의 수와 노드가 20-20-10-5인 일반 인공신경망 모델을 선정하였고, 각 모듈이 하나의 일반 인공신경망으로

구성된 모듈형 인공신경망은 모두 6개의 모듈로 구성하였다.

- 2) 연직배수공법의 설계변수인 지반의 기본물성과 역학적인 특성, 연직배수재의 물성과 시공방법, 선행재하하중의 크기와 재하시기 그리고 지속시간을 고려하여 인공신경망을 학습시킨 결과, 일반 인공신경망과 모듈형 인공신경망 모두 연직배수공법에 있어서 성토하중과 경과시간 증가에 따른 압밀침하량을 비교적 정확하게 예측할 수 있었다.
- 3) 실 계측 자료를 사용하여 학습되어진 인공신경망을 압밀 침하량 예측에 적용해본 결과, 넓은 범위의 입력패턴으로 학습되어진 일반 인공신경망보다 각 성토 단계와 같이 특정한 범위의 입력 패턴으로 학습되어진 모듈형 인공신경망이 압밀 침하량 예측에 있어서 보다 정확한 결과를 보이는 것으로 나타났다.

본 연구에서 제시한 모듈형 인공신경망의 정확도를 보다 향상시키기 위해서는 보다 다양한 지반에 대한 실측 자료에 의한 추가적인 학습이 필요하며, 나아가 연직배수공법 시공 시 성토하중 제거에 의한 압밀침하량 예측과 성토에 따른 지반의 안정성 평가에 대한 연구가 요구된다.

참고 문헌

1. 김병일, 김명모(1994), " 선행재하 공법 설계를 위한 전문가 시스템 ", 한국지반공학회지, 제10권, 제1호, pp. 83 ~ 101
2. 김홍택, 황정순, 박성원, 유한규(1999), " 유전자 알고리즘 및 인공신경망이론을 이용한 쓰일네일링 굴착벽체 시스템의 최적설계 ", 한국지반공학회지, 제15권, 제4호, pp. 113 ~ 132
3. 문상호, 문현구(1999), " 합리적인 축압계수 결정을 위한 인공신경 전문가 시스템의 개발 ", 한국지반공학회지, 제 15권, 제 1호, pp. 99 ~ 112
4. 이정학, 이인모, 조계춘(1997), " 인공신경망 이론을 이용한 암반의 투수계수 예측 ", 한국지반공학회지, 제 13권, 제 2호, pp. 77 ~ 89
5. Ellis, G. W., Yao, C., Zhao R., and D. Penumadu(1995), " Stress-Strain Modeling of Sands Using Artificial Neural Networks ", J. Geo. Eng., ASCE., Vol. 121, No. 5, pp. 429 ~ 435
6. Goh, Anthony T. C.(1996), " Neural Network Modeling of CPT Seismic Liquefaction Data ", J. Geo. Eng., ASCE., Vol. 122, No. 1, pp. 70 ~ 73
7. Jingsheng Shi, J. A. R. Ortigao, and Junli Bai(1998), " Modular Neural Networks for Predicting Settlements during Tunneling ", J. Geo. Eng., ASCE., Vol. 124, No. 5, pp. 389 ~ 395
8. McCulloch, W. S. and Pitts, W.(1943), " A Logical Calculus of Ideas Immanent in Nervous Activity ", Bullet. Math. Biophysics 5, pp. 115 ~ 133
9. Rumelhart, D. E., Hinton, G. E. and Williams, R. J.(1986), " Learning Representations by Back Propagating Errors ", Nature 323-9, pp 533 ~ 536

(접수일자 1999. 11. 29)