

## 인공신경회로망을 이용한 압밀응력비에 따른 정규압밀점토의 비배수전단강도 예측

### Prediction of Undrained Shear Strength of Normally Consolidated Clay with Varying Consolidation Pressure Ratios Using Artificial Neural Networks

이 윤 규<sup>\*1</sup> Lee, Yun-Gyu

윤 여 원<sup>\*2</sup> Yoon, Yeo-Won

강 병 희<sup>\*3</sup> Kang, Byung-Hee

#### Abstract

The anisotropy of soils has an important effect on stress-strain behavior. In this study, an attempt has been made to implement artificial neural network model for modeling the stress-strain relationship and predicting the undrained shear strength of normally consolidated clay with varying consolidation pressure ratios. The multi-layer neural network model, adopted in this study, utilizes the error back-propagation learning algorithm. The artificial neural networks use the results of undrained triaxial test with various consolidation pressure ratios and different effective vertical consolidation pressure for learning and testing data. After learning from a set of actual laboratory testing data, the neural network model predictions of the undrained shear strength of the normally consolidated clay are found to agree well with actual measurements. The predicted values by the artificial neural network model have a determination coefficient( $r^2$ ) above 0.973 compared with the measured data.

Therefore, this results show a positive potential for the applications of well-trained neural network model in predicting the undrained shear strength of cohesive soils.

#### 요 지

일반적으로 자연상태의 흙은 이방성을 나타내며, 이러한 흙의 이방성이 응력-변형률 거동에 미치는 영향은 매우 크다. 따라서 본 연구에서는 인공신경회로망 모델을 이용하여 압밀응력비 변화에 따른 정규압밀점토의 응력-변형률 거동을 모델링하고 비배수전단강도를 예측하여 보았다.

이때 사용된 신경회로망은 일반화된 레타규칙으로도 불리우는 오차역전파 학습 알고리즘을 이용한 다층 신경회로망이다. 신경회로망의 학습은 인공퇴적점토시료를 이용, 연적압밀응력과 압밀응력비를 다르게 정규압밀시킨 후 비배수전단시험을 실시하여 얻어진 시험결과를 이용하였고, 학습된 신경회로망을 이용하여 학습시 제외되었던 압밀응력비 상태에서의 비배수전단강도를 추론하여 본 결과 예측치와 실측치가 잘 일치하였다. 검토결과 실측치와 추론치 사이에는 결정계수( $r^2$ ) 0.973 이상의 높은 상관관계가 있음을 확인하였다.

따라서, 본 연구결과는 점토의 비배수전단강도를 예측함에 있어서 인공신경회로망 모델의 적용 가능성을 보여주었다.

**Keywords :** Artificial neural networks, Anisotropy, Consolidation pressure ratio, Undrained shear strength, Normally consolidated clay.

\*1 정회원, 안동정보대학 토목과 조교수

\*2 정회원, 인하대학교 공과대학 토목공학과 부교수

\*3 정회원, 인하대학교 공과대학 토목공학과 교수

## 1. 서 론

흙의 전단강도를 정확하게 예측하는 것은 얇은기초 및 깊은기초의 지지력 해석과 같은 기초공학적인 문제와 절토, 흙댐 및 성토후의 사면안정해석 및 옹벽에 작용하는 토압의 계산 등과 같은 토질공학과 관련된 문제를 해결하는데 아주 중요한 요소이다.

그러나 흙의 전단강도는 점토광물의 형태, 함수비, 간극비, 응력이력, 전단이 진행되는 동안의 배수상태, 하중의 재하속도, 온도 및 흙의 구조(fabric) 등과 같은 많은 요소들에 의해 복합적으로 결정되기 때문에 강도를 정확하게 예측한다는 것은 매우 어려운 일이다.

이렇듯 흙의 전단강도에 영향을 미치는 많은 요인들 중에서 특히 초기 압밀응력의 상태 및 응력경로가 흙의 응력-변형률 거동에 미치는 영향은 매우 큰 것으로 알려져 있으며, 우리가 편의상 실시하고 있는 등방압밀삼축시험에서 얻어진 강도정수는 실제 원자반 상태를 표현하는 이방압밀삼축시험에 의한 강도정수보다 과대 평가되고, 이방압밀된 시료의 응력-변형 특성을 등방압밀 시험시료로부터 직접적으로 예측할 수 없다는 문제점을 가지고 있다.

따라서 본 연구에서는 최근 인공지능(AI ; artificial intelligence) 분야에서 폭넓게 연구되고 있는 인공신경회로망(ANN ; artificial neural networks) 이론을 도입하고 그 알고리즘(algorithm)을 파악하여 전단강도에 영향을 미치는 여러 요인들 중에서 압밀응력비( $K_c$  ; consolidation pressure ratio)에 따른 정규압밀점토의 응력-변형률 관계 및 간극수압의 거동 추론을 위한 모델링을 실시하고 비배수전단강도를 예측할 수 있는 인공신경회로망 모델의 적용성을 검토하였다.

## 2. 흙의 전단강도 이방성

Duncan과 Seed(1966)는 흙의 이방성(anisotropy)을 고유이방성(inherent anisotropy) 및 응력유도이방성(stress-induced anisotropy) 두 가지로 구분하였다. 고유이방성은 흙이 하중을 받아 변형하기 이전부터 가지고 있던 본래의 구조이방성이고, Hansen과 Gibson(1949)이 처음 설명한 응력유도이방성은 흙이 자중 등의 하중을 받아 변형됨으로써 발생한 후천적 구조이방성을 의미하는데 실제 현장적용에 있어서는 고유이방성과 응력유도이방성이 조합되어 있는 복합이방성(combined anisotropy)을 고려한다.

일반적으로 실험실에서는 포화 점토에 대해서 등방압밀

삼축압축시험을 주로 실시하고 있는데, 이는  $K_0$ 압밀과 같은 이방압밀이 가능한 시험장비의 확보가 어려우며 시험절차가 까다롭고 시험시간이 오래 걸리는 등의 어려움 이외에 변형을 예측하기 위한 대부분의 이론적 모델이 흙의 이방성을 무시하고 있기 때문이다. 그러나 등방압밀삼축압축시험에서 측정된 강도정수는 이방압밀삼축시험에 의한 결과보다 과대 평가되므로 원위치지반의 비배수전단강도를 정확히 측정하기 위해서는 복합이방성을 고려한  $K_0$ 압밀비배수시험이 이루어져야 한다.

Sivakugan 등(1988)은 간극수압계수  $A$ 와 압밀응력비( $K_c$ )를 이용하여 등방압밀(CIUC)과 이방압밀(CAUC)에서의 비배수전단강도증가율을 식 (1), (2)와 같이 나타내었다.

여기에서,  $S_u$ 는 비배수전단강도,  $\sigma'_{vc}$ 는 유효연직응력,  $N_\phi = (1 + \sin \phi') / (1 - \sin \phi')$ 이며,  $A_{fl,0}$ 은 등방압밀일 때의 파괴시 간극수압계수이고  $A_{fk,c}$ 는 임의의 압밀응력비로 이방압밀되었을 때의 파괴시 간극수압계수이다.

$$\left(\frac{S_u}{\sigma'_{vc}}\right)_{CIUC} = \frac{1}{2} \left[ \frac{N_\phi - 1}{1 + (A_{fl,0} N_\phi - A_{fl,0})} \right] \quad (1)$$

$$\left(\frac{S_u}{\sigma'_{vc}}\right)_{CAUC} = \frac{\sin \phi' [A_{fk,c}(1 - K_c) + K_c]}{1 + (2A_{fk,c} - 1)\sin \phi'} \quad (2)$$

## 3. 인공신경회로망 이론

현재 널리 사용되고 있는 노이만형 컴퓨터는 논리적, 수치적 연산분야에서는 대단한 장점을 갖고 있지만, 인간이 간단히 수행할 수 있는 패턴인식이나, 불완전한 정보로부터 바른 결론을 도출해 낼 수 없다는 단점을 가지고 있다. 인공신경회로망은 이들 패턴인식이나 부정확한 정보의 처리를 위해 인간의 두뇌 작용을 신경세포들간의 연결관계로 모델링하여 컴퓨터로 다루고자 하는 것이다. (Schalkoff, 1992)

신경회로망은 학습(learning)과 재생(recall)이라는 2단계로 작업을 수행하는데 학습이란 패턴의 분류에 따라 신경회로망의 연결강도(connection strength)를 적당한 값으로 지정하는 과정이고, 재생이란 학습된 강도와 입력벡터들과의 거리를 계산하여 가장 가까운 클래스(class)로 분류하는 과정이다. 인간 두뇌의 기능을 모방하고자 하는 인공신경회로망은 노드(node) 혹은 처리요소(PE ; processing element)라고 하는 많은 수의 뉴런(neuron)들이 복잡하게 연결된 망으로 구성되는데 인공신경회로망의 뉴런 구조는 그림 1과 같다.

하나의 뉴런은  $X_0, X_1, \dots, X_n$ 의  $n$ 개의 입력을 위한 연결선

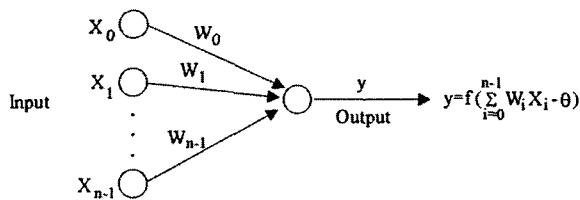


그림 1. 인공신경회로망의 뉴런 구조

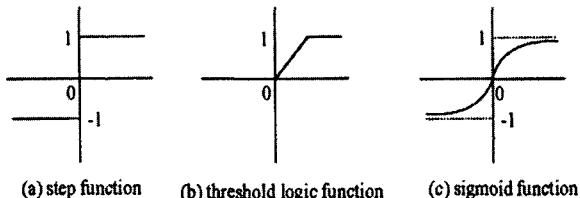


그림 2. 뉴런에서 사용되는 비선형 함수

을 가지며, 각 입력 성분은 각각의 연결선에 가해지는 연결 강도  $W_i$ 와 곱해진 후, 이들의 연결강도합이 어느 임계치(threshold),  $\theta$  이상이면 뉴런은 활성화되어 출력이 된다. 이 때 그림 2와 같은 비선형 함수  $f$ 를 수행한 활성화값이 뉴런의 최종적인 출력값이 된다.

신경회로 망은 학습방식에 따라 지도학습(supervised learning)과 비지도학습(unsupervised learning)으로 분류된다. 지도학습이란 실험 데이터의 입력벡터와 그에 대응하는 출력값을 함께 신경회로망에 입력시킨 후 학습시키는 방법으로, 대표적인 알고리즘으로는 Hopfield 학습규칙, 델타규칙(delta rule)과 오류역전파(EBP; error back-propagation) 학습규칙 등이 있으며, 비지도학습은 목표값 없이 학습 데이터만을 단순히 신경회로망의 입력으로 사용하면 스스로 연결 강도를 학습시키는 방식으로 경쟁학습(competitive learning) 알고리즘과 ART (adaptive resonance theory) 모델이 있다. (Lippman, 1987)

다층퍼셉트론(multi-layer perceptron)은 입력층과 출력층 사이에 하나 이상의 은닉층(hidden layer)을 가지는 전방향(feed-forward) 신경회로망이며, 이때 은닉층은 비선형분리 가능한 문제의 해결을 위해서 사용된다. 다층퍼셉트론을 학습시키는 알고리즘은 일반화된 델타규칙(generalized delta rule)으로도 불리우는 오류역전파 학습규칙이다. 이 알고리즘은 원하는 목표값과( $T$ ) 실제 출력값( $O$ ) 사이의 오차 제곱합(sum of squared errors)으로 정의된 비용함수(cost function)  $E$ 의 값을 경사하강추적법(gradiant descent method)에 의해 최소화하는 방향으로 학습한다.

$$E = \sum_p E_p, (E_p = \frac{1}{2} \sum_j (T_{pj} - O_{pj})^2) \quad (3)$$

여기에서,  $p$ :  $p$ 번째 학습패턴

$E_p$ :  $p$ 번째 패턴에 대한 오차

$T_{pj}$ :  $p$ 번째 패턴에 대한 목표출력의  $j$ 번째 요소

$O_{pj}$ :  $p$ 번째 패턴에 대한 목표출력의  $j$ 번째 요소

오류역전파 학습규칙은 전방향 퍼셉트론의 실제 출력과 목표 출력간의 평균제곱오차(MSE; mean square error)를 최소화시키기 위해서, 연결강도에 대한 오차의 미분계수가 감소하는 방향으로 연결강도를 계속 변경시키는 반복적인 경사하강 알고리즘(iterative descent algorithm)이다. 따라서 오류역전파의 활성화 함수는 연속이면서 미분가능해야 한다. 따라서 각 출력뉴런 및 은닉뉴런들은 일반적으로 비선형 S자형의 시그모이드(sigmoid) 함수를 활성화 함수로 사용한다.

#### 4. 해석 및 결과분석

##### 4.1 시료 및 시험결과

점토시료는 인천광역시에서 채취한 점성토 95%와 벤토나이트 5%를 중량비율로 혼합한 시료로서 0.1N의 염화칼슘( $CaCl_2 \cdot 2H_2O$ ) 용액 중에서 현탁액을 만들어 퇴적조에 넣어 단계적으로 수압에 의한 압력을 증가시켜 약 110kPa의 압력하에서 약 2개월 이상 방치하여 암밀시켜 시료를 준비하였다. 점토시료의 물리적 성질과 표준암밀시험 결과는 표 1과 같고,  $K_0$ 암밀시험에서 연직유효암밀응력( $\sigma'_{vc}$ )에 따른 정지토압계수( $K_0$ )는 그림 3과 같다. 정규암밀점토에서 연직유효암밀응력이 증가함에 따라  $K_0$ 는 변화하지만 선행암밀응력을 전후로 어떠한 값에 수렴하게 되는데 이 값이 정지토압계수이다. 그림 3과 같이 응력이 200~350kPa 범위

표 1. 시료의 물리적 성질과 표준암밀시험 결과

Liquid limit (%)	52
Plastic limit (%)	21
Water content (%)	43±1
Degree of saturation (%)	98~100
Compression index	0.46
Swelling index	0.07
Preconsolidation pressure (kPa)	100
Specific gravity	2.71
Ave. particle size, D50 (mm)	0.0042
Clay content (<2μm) (%)	36
USCS	CH

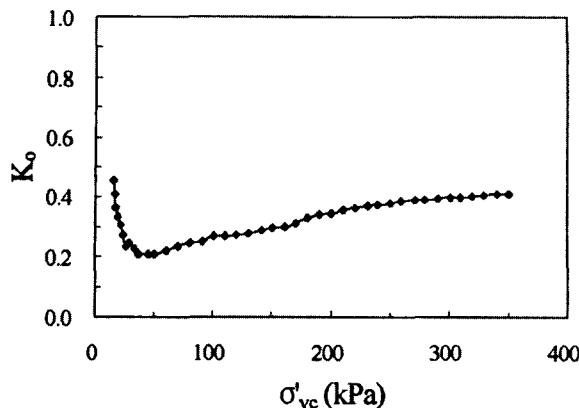


그림 3. 연직유효압밀응력에 따른 정지토압계수

일 때  $K_0$ 값은 0.4에 수렴하므로  $K_0=0.4$  이다.

시험은 압밀응력비( $K_c = \sigma_h'/\sigma_v'$ )를 1.0, 0.7, 0.5, 0.4로 달리한 시료에 대하여 3가지의 연직유효압밀응력(200, 250, 350kPa)으로 정규압밀시킨후 동일한 전단속도로 비배수전단시험을 실시하였으며, 시험결과는 표 2와 같다. 이때, 표 2에서 시험번호 0.7-200-NC의 의미는 점토에 대하여 압밀응력비는 0.7로 연직유효압밀응력은 200kPa로 정규압밀시킨후 비배수전단시험을 실시하였다는 것이다.

#### 4.2 신경회로망 모델

압밀응력비에 따른 정규압밀점토의 비배수전단강도를 예측하기 위한 신경회로망 모델은 입력층, 은닉층 2개, 출력층으로 구성된 다층 신경회로망으로 변형률, 응력, 변형률 증가량, 압밀응력비, 연직유효압밀응력 및 간극수압을 입력층으로 다음 단계의 응력과 간극수압을 출력층으로 하는  $6 \times 24 \times 24 \times 2$  구조로 되어 있으며, 신경회로망 모델의 구조는 그림 4와 같다.

표 3. 비배수전단시험 결과 (유강현, 1998)

$K_c$	Test no.	Consolidation pressure (kPa)		$\varepsilon_f$ (%)	$(\sigma_v - \sigma_h)$ <sub>max</sub> (kPa)	$S_u$ (kPa)	$\phi'$ (°)	$A_f$
		$\sigma'_{vc}$	$\sigma'_{hc}$					
1.0	1.0-200-NC	200	200	15.93	207.1	103.5	36.5	0.615
1.0	1.0-250-NC	250	250	15.86	268.0	134.0		0.601
1.0	1.0-350-NC	350	350	16.99	333.0	166.5		0.679
0.7	0.7-200-NC	200	140	6.01	189.6	98.4	35.2	0.578
0.7	0.7-250-NC	250	175	6.97	231.0	115.5		0.586
0.5	0.5-200-NC	200	100	2.14	171.9	86.0	35.6	0.566
0.5	0.5-250-NC	250	125	3.23	217.0	108.5		0.586
0.4	0.4-200-NC	200	80	1.88	162.6	81.3	35.2	0.475
0.4	0.4-250-NC	250	100	2.54	206.6	103.3		0.451
0.4	0.4-350-NC	350	140	2.87	274.5	137.3		0.456

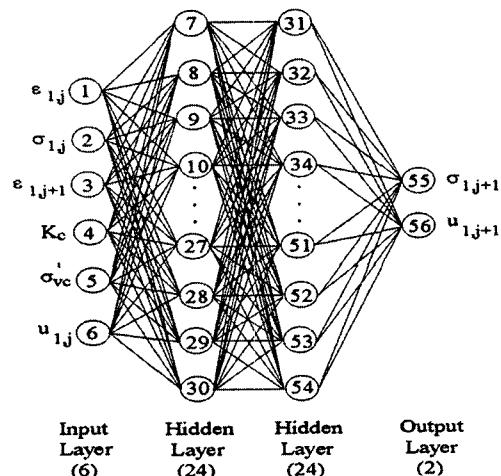


그림 4. 해석을 위한 다층 신경회로망의 구조

배규진 등(1988)에 의하면 일반적으로 은닉층이 3개 이상인 경우에는 이론상 어떠한 패턴인식 영역도 형성할 수 있으나 학습시간과 학습횟수가 기하급수적으로 증가하여 불량한 신경회로망의 추론효과를 초래할 수도 있으므로 본 연구에서는 은닉층의 층수를 2개로 하였다. 이렇듯 다층 역전파 인공신경회로망의 학습효율 및 추론능력은 신경회로망의 구조(frame)는 물론 학습에 필요한 학습률(learning rate) 및 관성률(momentum) 같은 학습상수등에 따라 크게 변화한다. 따라서 본 연구에서는 인공신경회로망의 구조 및 학습상수가 학습효율 및 추론능력에 미치는 영향을 검토하고 최적의 인공신경회로망 모델을 결정하기 위하여 은닉층의 노드 수를 6~48개, 학습률은 0.1~0.5, 관성률은 0.5~0.9 사이에 변화를 주어 총 108개의 모델을 구성하고 이를 검토하여 보았으며, 검토결과 은닉층 노드수는 24개, 학습률과 관성률은 각각 0.5와 0.9인 신경회로망 모델이 최적모델인 것으로 나타났다.

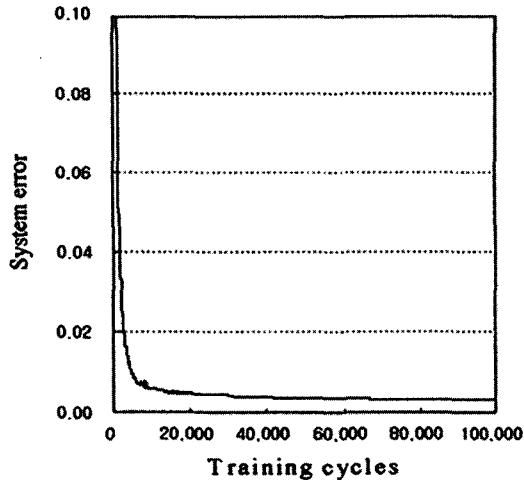


그림 5. 학습진행에 따른 시스템 오차 변화

또한 초기상태로서 연결강도와 고정입력치들을 모두 같은 값으로 설정하면 학습이 불가능해지는 균형문제(symmetry problem)가 발생하는데 이러한 균형문제를 해결하기 위하여 초기 연결강도는 -0.1~0.1사이의 난수를 발생시켜 초기화하였으며, 학습종료시점은 시스템오차 0.001, 반복횟수 100,000회로 하였다. 학습을 위한 입력자료로는 압밀응력비가 1.0, 0.7, 0.4일 때 각각 연직유효압밀응력을 200, 250, 350kPa로 변화시켜 얻어진 응력-변형률 관계와 간극수압의 거동을 이용하였고 학습시 제외된 압밀응력비 0.5일 때의 거동을 모델링 하였으며, 압밀응력비에 따른 비배수전단강도를 추론하여 실측치와 비교하여 보았다.

그림 5는 인공신경회로망 모델의 학습진행에 따른 시스템오차를 나타낸 것이다.

#### 4.3 해석 결과

인공신경회로망 모델 적용시 압밀응력비 1.0, 0.7, 0.4 일 때 정규압밀점토의 응력-변형률 거동을 학습자료로 압밀응력비 0.5일 때를 추론자료로 사용하였다. 이때 학습된 결과 중 압밀응력비 1.0일 때의 응력-변형률 거동과, 학습에서 제외한 압밀응력비 0.5일 때의 거동을 추론한 결과는 각각 그림 6, 7과 같다. 그림에서와 같이 압밀응력비에 따른 정규 압밀점토의 응력-변형률 거동에 대한 학습은 정확하게 이루어졌음을 알 수 있으며, 학습된 신경회로망을 이용한 추론값도 실험값과 잘 일치하는 것을 알 수 있다.

그림 8, 9는 연직압밀응력이 각각 200, 250kPa일 때 압밀응력비에 따른 간극수압의 변화를 나타낸 것으로 응력-변형률거동과 마찬가지로 학습과 추론이 잘 이루어진 것을 알 수 있다.

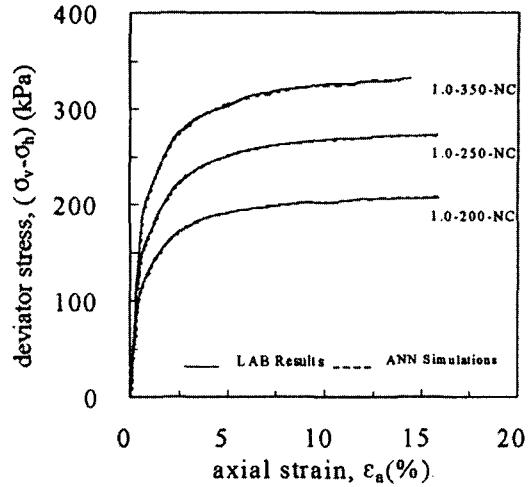


그림 6. 응력-변형률 거동 학습결과( $K_c=1.0$ )

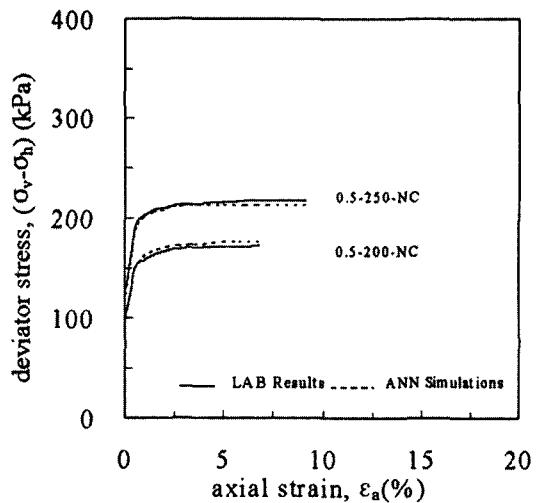


그림 7. 응력-변형률 거동 추론결과 ( $K_c=0.5$ )

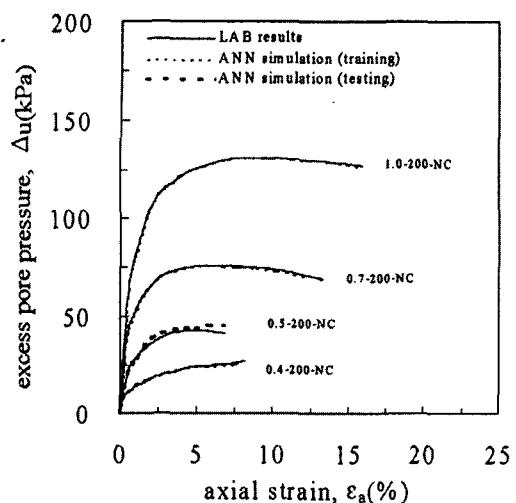


그림 8. 간극수압변화의 학습 및 추론 결과

(연직압밀응력,  $\sigma'_v = 200\text{kPa}$ )

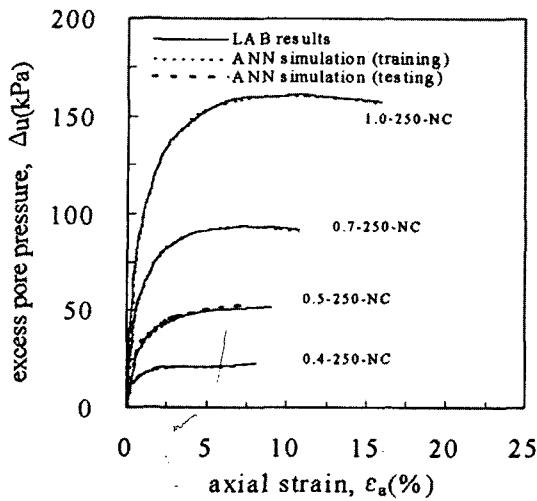


그림 9. 간극수압변화의 학습 및 추론결과  
(연직압밀응력,  $\sigma'_{vc} = 250\text{kPa}$ )

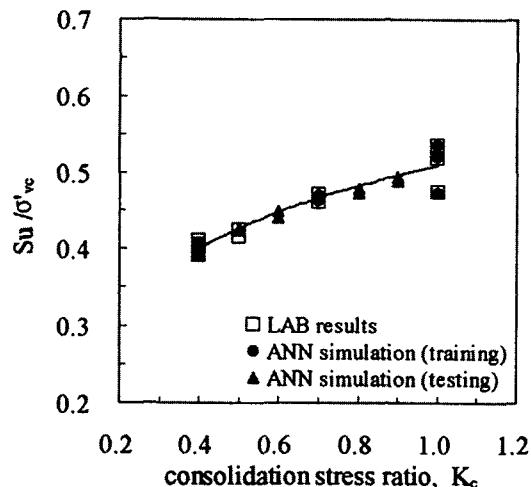


그림 10. 압밀응력비에 따른  $S_u / \sigma'_{vc}$  추론

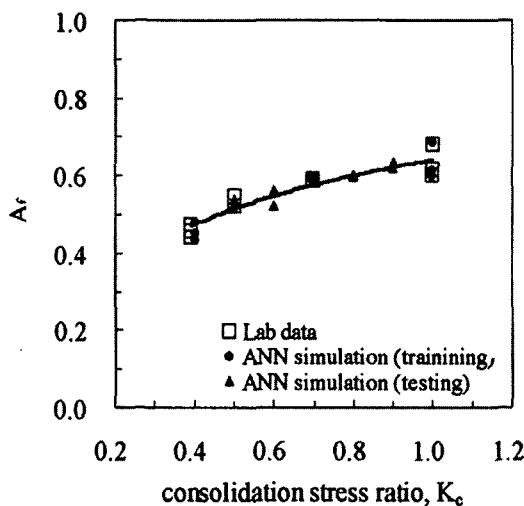


그림 11. 압밀응력비에 따른 간극수압계수 추론

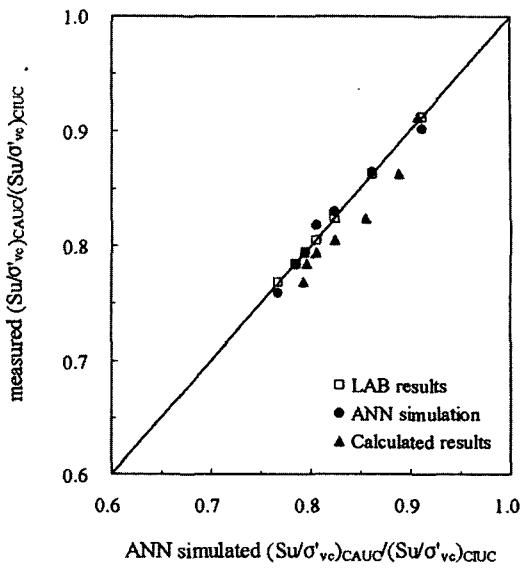


그림 12. 비배수전단강도비의 추론값과 실측값의 비교

그림 10은 압밀응력비에 따른 연직압밀응력으로 정규화한 정규압밀점토의 비배수전단강도( $S_u / \sigma'_{vc}$ )를 추론한 것이고, 그림 11은 파괴시 간극수압계수( $A_f$ )의 변화를 나타낸 것이다. 그림에서와 같이 압밀응력비가 증가할수록 비배수전단강도 및 파괴시 간극수압계수는 증가하는데, 신경회로망을 이용하여 추론한 결과는 이러한 경향을 잘 재현하는 것을 알 수 있다.

또한 그림 12는 신경회로망 모델의 예측에 의한 비배수전단강도비와 Sivakugan이 제안한 식에 의해 계산된 값과 실험값과 비교한 것이다.

예측결과가 실측자료와 어떻게 비교되고 얼마나 적합한 것인가 하는 문제는 점토의 비배수전단강도 예측에 있어서 인공신경회로망 모델의 신뢰성과 관계가 있다. 따라서 본 연구에서는 예측문제에 적용되고 있는 통계적 검정방법으로 계산된 오차와 비교, 검토하여 인공신경망회로망 모델의 적합도와 정확도를 검토하였다. 신경회로망 모델을 이용한 비배수전단강도비의 추론값과 실험값의 상관관계를 분석하여 본 결과 상관계수( $r$ : correlation coefficient)는 0.986, 결정계수( $r^2$ : determination coefficient)는 0.973으로 높은 상관관계가 있음을 확인 하였으며, 특히 Sivakugan이 제안한 식에 의한 결과의 상관계수 0.972, 결정계수 0.945보다 높은 상관관계가 나타나 신뢰성 있는 모델임을 확인하였다.

## 5. 결론

본 연구에서는 오차역전파학습 알고리즘을 적용한 다층

신경회로망을 이용하여 압밀응력비에 따른 정규압밀점토의 응력 - 변형률 거동 및 간극수압의 변화를 모델링하고 비배수전단강도 변화를 예측하여 보았으며 그 결과는 다음과 같다.

인공신경회로망 모델은 입력층, 은닉층 2개, 출력층으로 구성된 다층 신경회로망으로 변형률, 응력, 변형률 증가량, 압밀응력비, 연직유효압밀응력 및 간극수압을 입력층으로 응력과 간극수압 증가량을 출력층으로 하는  $6 \times 24 \times 24 \times 2$  구조로 이루어졌으며, 학습이 이루어진 신경회로망을 이용하여 응력 - 변형률 관계와 간극수압의 변화를 모델링한 결과 결정계수 0.999 이상의 매우 정확한 예측이 이루어지는 것을 확인할 수 있었다. 또한 학습이 이루어지지 않은 압밀응력비에서의 비배수전단강도를 추론하여 실험결과와 비교하여 본 결과 결정계수는 0.973 이상으로 높은 상관관계를 나타냈으며, Sivakugan이 제안한 식보다 높은 상관관계를 보임으로써 신뢰성 있는 모델임을 확인하였다.

따라서, 본 연구를 통하여 신경회로망을 이용한 점토의 비배수전단강도 예측시스템의 적용 가능성을 확인하였으며 추후 다양한 조건에서의 자료를 이용하여 많은 학습이 이

루어진다면 보다 합리적이고 실용적인 예측시스템이 될 것으로 기대된다.

## 참고문헌

1. 배규진, 김창용, 신휴성, 문현구(1998), “터널굴착 현장에 인접한 지상 구조물의 안전성 평가용 전문가 시스템의 개발( I ),” 한국지반공학회지, 제14권 제2호, pp. 107~123.
2. 유강현(1998), “이방압밀이 정규압밀점토의 압축 및 신장 비배수전단 강도에 미치는 영향,” 석사학위논문, 인하대학교, pp. 4~24.
3. Duncan, A. M. and Seed, H. B.(1966), "Anisotropy and Stress Reorientation in Clay," Journal of Soil Mechanics and Foundation Engineering Division, ASCE, Vol. 92, No. SM5, pp. 21~50.
4. Hansen, J. B. and Gibson, R. E.(1949), "Undrained Shear Strengths of Anisotropically Consolidated Clays," Geotechnique, Vol. 1, No. 3, pp. 18 9~204.
5. Lippmann, R. P.(1987), "An Introduction to Computing with Neural Nets," IEEE Acoustics Speech and Signal Processing, Vol. 4, No. 2, pp. 4-22.
6. Schalkoff, R.(1992), Pattern Recognition : Statistical, Structural and Neural Approaches, John Wiley & Sons, New York.
7. Sivakugan, N., Holtz, R. D. and Chameau, J. L.(1988), "CKOUC Shear Strength of Normally Consolidated Clays from CIUC tests," Journal of Geotechnical Engineering Division, ASCE, Vol. 114, No. 3, pp. 284~295.

(접수일자 1999. 9. 1)