

## 인공신경망을 이용한 연약지반성토의 침하예측 연구

### A Study on the Settlement Prediction of Soft Ground Embankment Using Artificial Neural Network

김 동 식<sup>1</sup> Kim, Dong-Sik

채 영 수<sup>2</sup> Chae, Young-Su

김 영 수<sup>3</sup> Kim, Young-Su

김 현 동<sup>4</sup> Kim, Hyun-Dong

#### Abstract

Various geotechnical problems due to insufficient bearing capacity or excessive settlement are likely to occur when constructing roads or large complexes on soft ground. Accurate predictions of the magnitude of settlement and the consolidation time provide numerous options of ground improvement methods and, thus, enable to save time and expense of the whole project. Asaoka's method is probably the most frequently used one for settlement prediction and the empirical formulae such as Hyperbolic method and Hoshino's method are also often used. To find an elaborate method of predicting the embankment settlement, two recurrent type neural network models, such as Jordan model and Elman-Jordan model, are adopted. The data sets of settlement measured at several domestic sites are analyzed to obtain the most suitable model structures. It was shown from the comparison between predicted and measured settlements that Jordan model provides better predictions than Elman-Jordan model does and that the predictions using CPT results are more accurate than those using SPT results. It is believed that RNN using cone penetration test results can be a highly efficient tool in predicting settlements if enough field data can be obtained.

#### 요    지

연약점토지반에 도로, 대규모 단지조성공사에 따른 지지력의 부족과 과대한 침하량으로 인하여 여러 가지 어려운 문제가 발생하며 최종 침하량 및 침하시간의 정확한 예측은 지반개량공법의 선정은 물론 사업비, 사업기간에 중대한 영향을 미치게 된다. 현재 사용되고 있는 침하량 예측기법으로는 Terzaghi의 압밀이론을 응용한 Asaoka법과 경험식인 Hyperbolic법, Hoshino법 등이 있다. 그러나 이러한 방법들에 의하여 예측된 침하량과 실제 침하량이 정확히 일치하지 않는 경향이 있다고 알려지고 있다. 게다가 이런 방법 등은 계측결과가 없는 설계단계에서는 사용할 수 없는 단점을 가지고 있다. 본 논문에서는 국내 단지조성공사에서의 데이터와 다양한 테스트 결과값을 이용하여 성토시 침하를 보다 정확하게 예측하기 위해 인공신경망 기법인 Jordan 모델과 Elman-Jordan 모델을 적용하여 가장 적합한 모델 구조를 얻고자 하였다. 개선된 인공신경망 모델에 의한 예측치를 실측치와 비교하였고, 결과값에 의하면 Jordan 모델이 Elman-Jordan 모델보다 실측치와 잘 일치하고 콘관입 저항을 이용한 예측치가 표준관입시험을 이용한 결과치보다 실제에 더 가깝다는 것을 알 수 있다. 따라서 더 많은 현장실험 데이터가 확보된다면 콘관입시험을 이용한 순환형 인공신경망 기법이 침하량 예측에 있어 가장 효과적인 방법이 될 것이라 사료된다.

**Keywords :** ANN, Elman-Jordan model, Jordan model, Settlement, Soft ground

1 정희원, (주)KCC건설, 수원대학교 토목공학과 박사과정 (Member, Graduate Student, Dept. of Civil Engrg., The Univ. of Suwon, dskim@kccworld.net, 교신저자)

2 정희원, 수원대학교 토목공학과 교수 (Member, Prof., Dept. of Civil Engrg., The Univ. of Suwon)

3 정희원, 경북대학교 토목공학과 교수 (Member, Prof., Dept. of Civil Engrg., Kyungpook National Univ.)

4 경북대학교 토목공학과 석사과정 (Graduate Student, Dept. of Civil Engrg., Kyungpook National Univ.)

\* 본 논문에 대한 토의를 원하는 회원은 2008년 1월 31일까지 그 내용을 학회로 보내주시기 바랍니다. 저자의 검토 내용과 함께 논문집에 게재하여 드립니다.

## 1. 서 론

최근 우리나라는 급격한 산업화로 인하여 사회간접시설 확충의 필요성이 그 어느 때 보다도 대두되고 있고, 공단, 공항, 주거단지와 도로 등을 조성하기 위하여 해안 및 연약지반에 대단위 매립 또는 성토사업이 활발히 추진되고 있다. 이러한 연약지반 위에 도로, 교량, 대규모 단지 등이 건설 된다면 지지력의 부족과 과대한 침하량으로 인하여 여러 가지 어려운 문제가 발생하며 최종침하량 및 최종침하시기의 정확한 예측은 지반개량공법의 선정은 물론 전체사업의 사업비, 사업기간에 중대한 영향을 미치게 된다.

현재 침하량의 예측기법으로는 설계 시에 토질시험에서 얻어진 압밀계수를 이용하여 Terzaghi 1차원 압밀이론에 근거한 시간-침하량 관계를 구하는 방법이고 또 하나는 최근에 현장에서 널리 이용되고 있는 실측치를 근거로 장래침하를 예측하는 방법이 제안되고 있으며 그 방법으로는 국내에서 널리 사용되고 있는 Terzaghi의 압밀이론을 응용한 Asaoka법, 그리고 경험식인 Hyperbolic 법과 Hoshino법 등이 있다. 또한 Asaoka법, 쌍곡선법, 그리고 Hoshino법 등은 계측결과가 없는 설계단계에서는 사용할 수 없는 단점을 가지고 있다.

본 논문에서는 이러한 단점을 보완하고자 국내 연약지반상의 단지조성공사와 도로공사현장에 대한 표준관입시험, 콘관입시험 및 각종 실내시험 결과와 침하 계측결과를 바탕으로 인공신경망이론을 이용하여 성토에 따른 침하예측에 대한 최적신경망을 구하였다.

표 1. 각 경우에 대한 입력변수의 범위

입력자료	표준관입		콘관입	
	연직배수재 사용	연직배수재 미사용	연직배수재 사용	연직배수재 미사용
$c_c$	0.1555~0.764	0.3525~0.7935	0.2290~0.7940	0.229~0.7935
$c_v(\text{cm}^2/\text{s})$	0.00049~0.01006	0.00096~0.00897	0.0045~0.0079	0.0017~0.0091
$e_0$	0.8393~1.6755	1.222~1.763	0.898~1.6805	1.112~1.763
PBD	0~1	-	0	-
Pack Drain	0~1	-	1	-
Sand Drain	0~1	-	0	-
연직배수재 간격(m)	1.4~2.3	-	1.5~2	-
연직배수재(cm)	2.55~70	-	5~6.2	-
연약층 두께(m)	1.5~29	5~30.5	2.1~35	2.1~28
N치	1~9.428571	1~3.4	-	-
콘관입저항력( $\text{kg}/\text{cm}^2$ )	-	-	2.5~15.7	1.3~18.4
성토고(m)	0~10.66	0~9.9	0~14.8	0~5.7
함수비(%)	26.24~59.05	40.5~64.9	30.2~59.9	33.8~64.75
경과일수(day)	0~1879	0~1667	0~1744	0~1539

## 2. 인공신경망의 적용 및 분석

### 2.1 입력데이터

본 연구에 사용된 입력 데이터는 전국의 7개 지역에서 60개소의 자료를 사용하였으며, 학습에 56개소의 자료를, 예측에 4개소의 자료를 사용하였다. 표준관입 및 콘관입시험 결과를 사용한 경우, 또 연직배수재를 사용한 경우와 사용하지 않은 경우로 총 네가지로 나누어 학습, 예측하였다. 실내 시험 데이터로서  $c_c$ ,  $c_v$ ,  $e_0$ , 함수비 등과 연약층(점토)두께, 표준관입시험 성과에 의한 N치, 콘관입시험 성과에 의한 콘관입저항력을 사용하였다. 이때 평균 N치와 콘관입저항력은 연약 점성토지반 두께에 대한 가중법으로 산정하였다. 그 외에 연직배수재 간격, 연직배수재 직경, 성토고와 경과일수 등을 사용하였다. 각 경우에 대한 입력변수의 범위는 표 1과 같다. 그리고 표 2에서 입력예를 나타내었다.

### 2.2 학습 및 최적신경망

#### (1) 학습

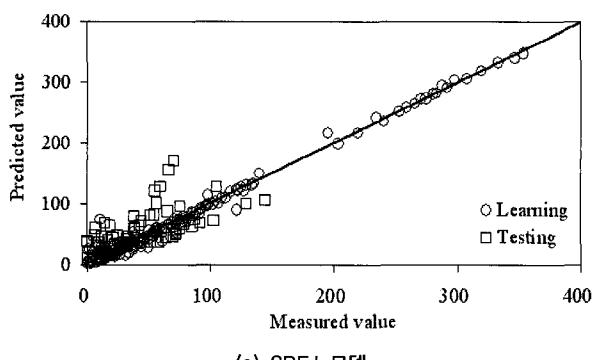
인공신경망을 이용한 침하량 예측을 위해 Giles 등 (1994), Jian-hua 등(1998), Parlos 등(1994)의 연구를 바탕으로, 네가지 경우 각각에 대해서 순환형 신경망(Recurrent Neural Network)인 Jordan 모델과 Elman-Jordan 모델을 사용하였다. 이때 동적신경망에서 은닉층은 3층이상인 경우 수렴성이 보장되어 있으나, 진동

이나 발산할 가능성이 있으므로 안전하게 하기위해 은 낙층이 하나인 모델로 구성하였고, 은낙층 노드수는 입력변수 개수의 1배, 1.5배, 2배로 임의로 정하였다. Mohamed 등(1994)의 경우 학습율은 0.005, 0.02, 0.1, 0.2, 0.4, 모멘텀은 0.01, 0.05, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.8 사용하였고, 김병탁 등(2000)은 학습율은 0.1, 0.3, 0.5, 0.7, 0.9, 모멘텀은 0.9를 사용하였다. 본 연구에서는

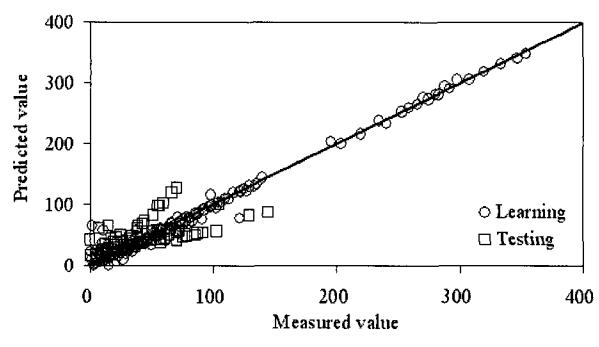
이를 고려하여 학습율은 0.01, 0.1, 0.3, 0.5, 모멘텀은 0.1, 0.3, 0.5, 0.7을 사용하여 학습하였다. 그리고 김영수 등(2005)의 연구에서 수렴오차는  $5 \times 10^{-4} \sim 5 \times 10^{-5}$ , 최대 반복횟수(Epoch)는 100만회로 하였는데 본 연구에서는 이를 바탕으로 수렴오차는 (입력자료의 개수) $\times 10^{-4}$ , 최대 반복횟수는 40만회로 정하였다. 그리고 은낙층, 출력층의 활성함수는 대표적인 시그모이드 함수를 사용하

표 2. 00지구 00측점의 입력예

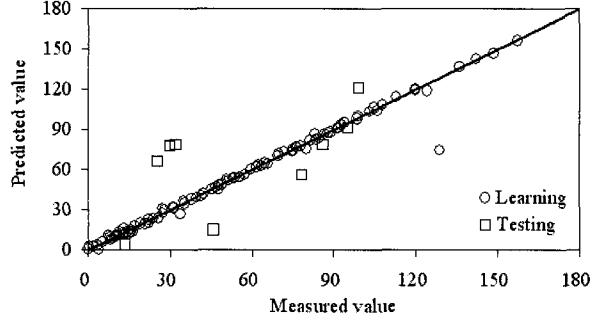
$c_c$	$c_v$ ( $\text{cm}^2/\text{sec}$ )	$e_0$	P.B.D	Pack Drain	Sand Drain	보강재 간격(m)	보강재 직경(cm)	연약층 두께(m)	N치	성토고 (m)	함수비 (%)	경과일수 (day)	침하량 (cm)
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	0	42.5	0	0
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	0.4	42.5	4	1.4
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	0.6	42.5	7	2.6
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	0.6	42.5	14	3.1
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	0.6	42.5	17	3.3
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	1.0	42.5	21	4.8
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	1.0	42.5	25	6.1
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	1.0	42.5	28	6.5
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	1.4	42.5	32	6.6
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	1.8	42.5	35	6.7
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	1.8	42.5	38	6.8
0.384	0.0009	0.8839	0	0	1	1.5	70	10.4	4	1.8	42.5	45	7.3
•	•	•	•	•	•	•	•	•	•	•	•	•	•
•	•	•	•	•	•	•	•	•	•	•	•	•	•
•	•	•	•	•	•	•	•	•	•	•	•	•	•



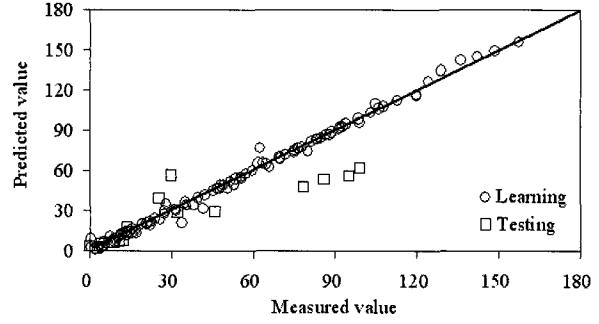
(a) SDEJ 모델



(b) SDJ 모델



(c) SEJ 모델



(d) SJ 모델

그림 1. 표준관입 저항치를 이용한 경우

였다. 시그모이드 함수는 식 (1)과 같다.

$$sig(x) = \frac{1}{1+e^{-x}} \quad (1)$$

일반적으로 인공신경망의 학습에서 모든 입력변수들은 식 (2)에 의해 0~1의 범위로 정규화시켜 입력된다 (Ellis 등(1992)).

$$x_{normal} = \frac{x + (x_{max} - 9 \times x_{min})/8}{(x_{max} - x_{min})/0.8} \quad (2)$$

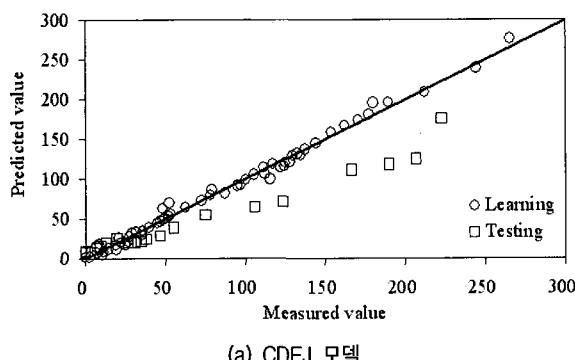
그리고 최적의 신경망 모델을 선정하는 기준은 MAE (Mean Absolute Error), MAPE(Mean Absolute Percent Error) 등이 있는데, 본 연구에서는 그 중에서 널리 쓰이는 RMSE(root mean square error)를 사용하였다.

$$RMSE = \sqrt{\frac{e_1^2 + e_2^2 + e_3^2 + \dots + e_n^2}{n-1}} \quad (3)$$

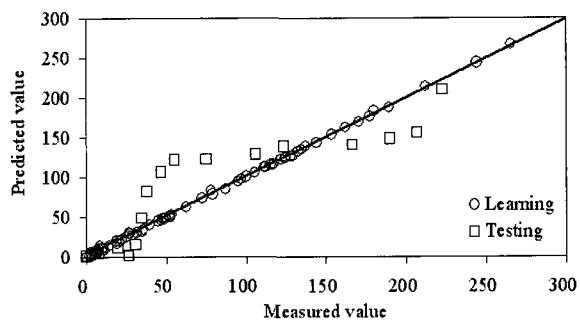
학습결과는 그림 1~2와 같다.

## (2) 최적신경망 모델

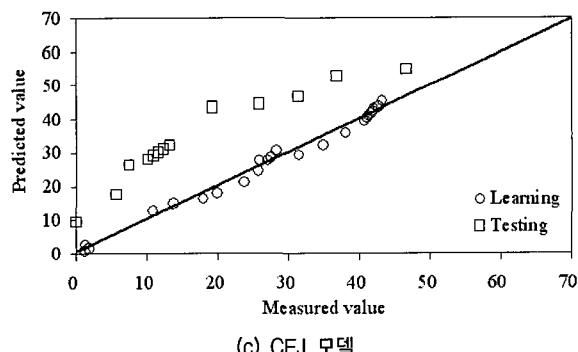
최적모델과 구조는 표 3과 그림 3~4에 나타내었다. 표준관입은 연직배수재를 사용한 경우 E-J 모델(SDEJ)은 13-20-1의 구조로 학습율은 0.5, 모멘텀은 0.5이고, Jordan 모델(SDJ)은 13-26-1의 구조로 학습율은 0.5, 모멘텀은 0.1이다. 연직배수재를 사용하지 않은 경우 E-J 모델(SEJ)은 8-16-1의 구조로 학습율은 0.3, 모멘텀은 0.1이고, Jordan 모델(SJ)은 8-8-1의 구조로 학습율은 0.5, 모멘텀은 0.7이다. 콘관입은 연직배수재를 사용한



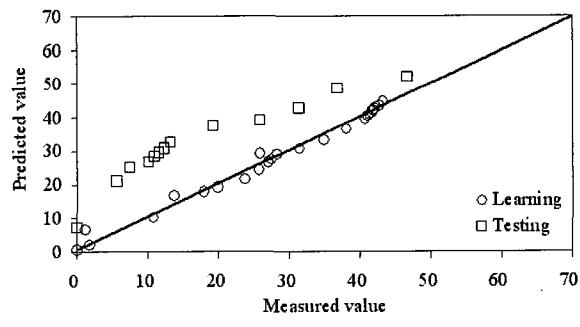
(a) CDEJ 모델



(b) CDJ 모델



(c) CEJ 모델



(d) CJ 모델

그림 2. 콘관입 저항력을 이용한 경우

표 3. 최적신경망 모델

	SDEJ 모델	SDJ 모델	SEJ 모델	SJ 모델	CDEJ 모델	CDJ 모델	CEJ 모델	CJ 모델
입력층의 뉴런수	13	13	8	8	13	13	8	8
은닉층의 뉴런수	20	26	16	8	13	13	8	12
출력층의 뉴런수	1	1	1	1	1	1	1	1
학습율	0.5	0.5	0.3	0.5	0.3	0.3	0.5	0.01
모멘텀	0.5	0.1	0.1	0.7	0.7	0.7	0.7	0.1
상관계수	0.6819	0.6519	0.8079	0.7039	0.9658	0.9640	0.9124	0.9737
RMSE	29.0474	26.5283	24.5742	24.4548	26.0622	21.8031	17.1847	15.1837

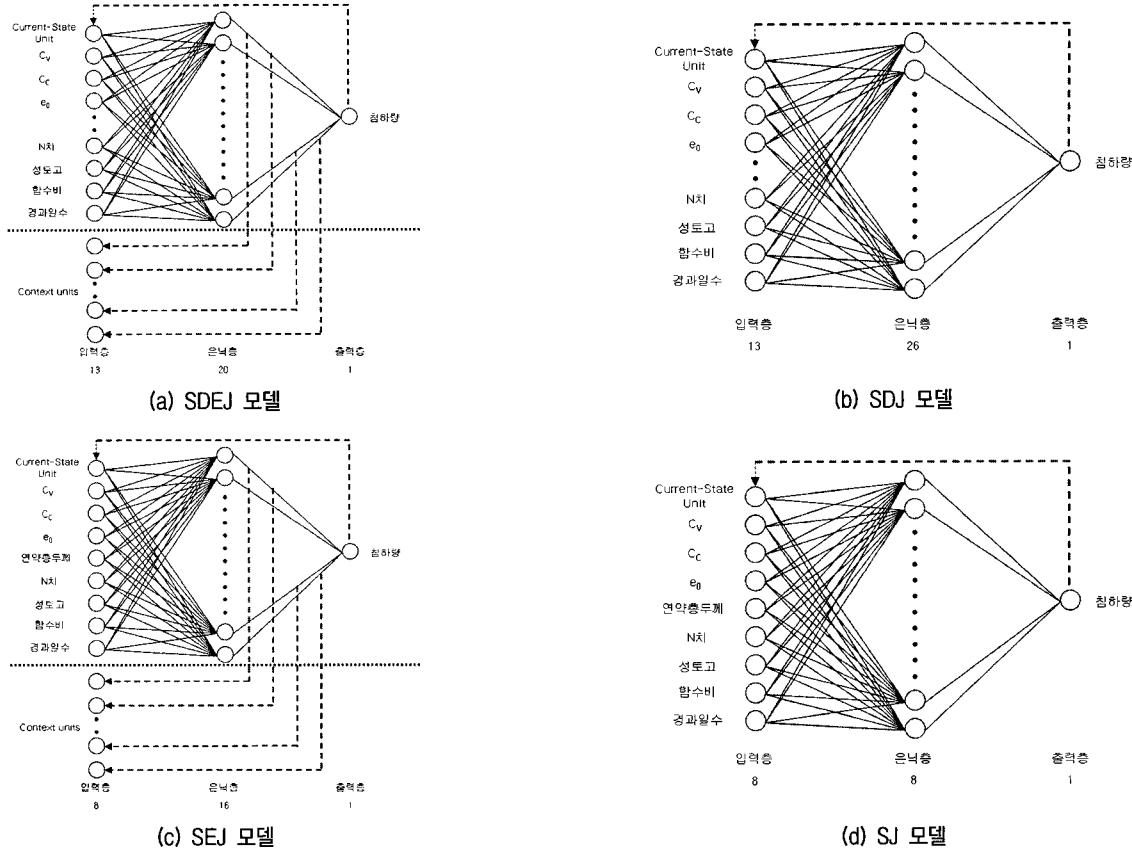


그림 3. 표준관입 저항치를 이용한 경우

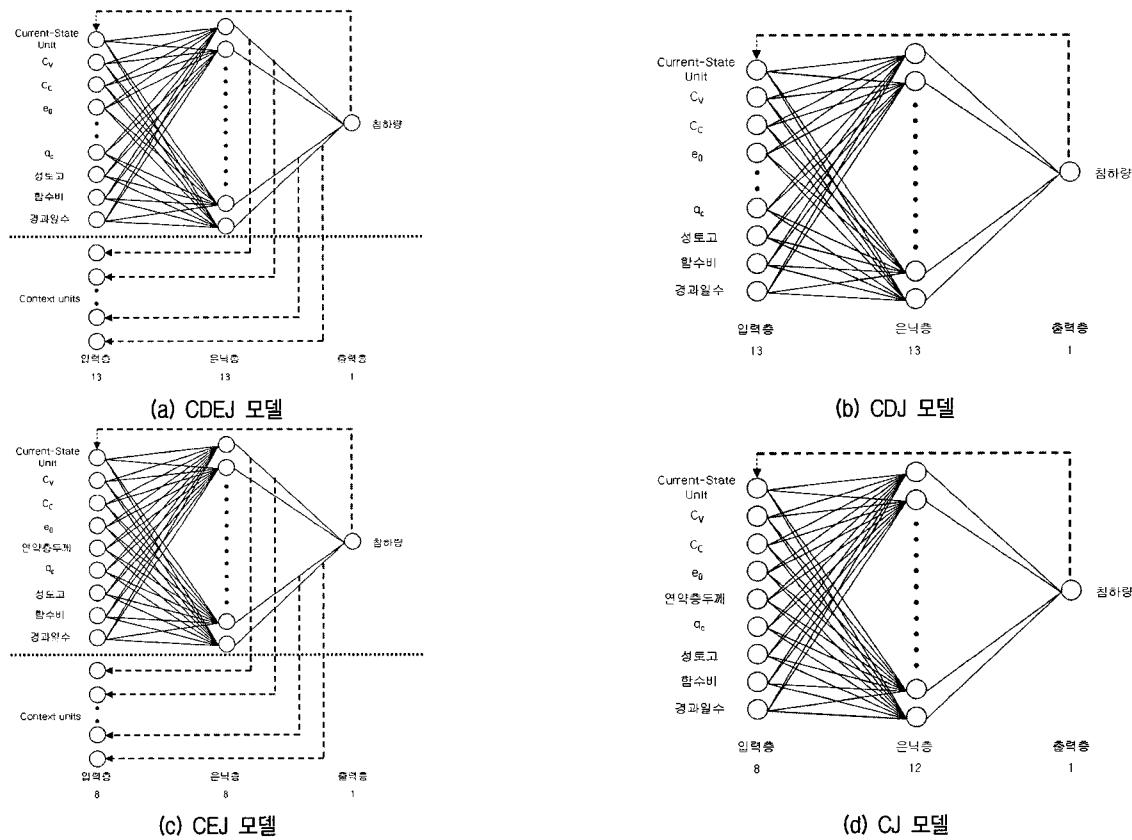


그림 4. 콘관입 저항력을 이용한 경우

경우 E-J 모델(CDEJ)은 13-13-1의 구조로 학습율은 0.3, 모멘텀은 0.7이고, Jordan 모델(CDJ)은 13-13-1의 구조로 학습율은 0.3, 모멘텀은 0.7이다. 연직배수재를 사용하지 않은 경우 E-J 모델(CEJ)은 8-8-1의 구조로 학습율은 0.5, 모멘텀은 0.7이고, Jordan 모델(CJ)은 8-12-1의 구조로 학습율은 0.01, 모멘텀은 0.1이다. 그 결과 표준관입은 상관계수가 0.6~0.8 사이로 대체적으로 작게 나타났고, RMSE는 24~29사이로 크게 나타났다. 콘관입은 상관계수가 대체적으로 0.9이상으로 높게 나타났고, RMSE는 CDEJ모델에서 26이 넘었을 뿐 나머지 경우들은 대체로 낮게 나타났다. 전체적으로 콘관입의 결과가 표준관입의 결과보다 좋음을 알 수 있다. 그리고 Jordan 모델이 E-J 모델보다 더 좋은 결과를 나타냈다. 특히 CJ모델이 상관계수가 0.9737, RMSE는 15.18로 가장 좋은 결과를 나타냈다.

### 2.3 최적신경망에 의한 침하량 예측

그림 5~8은 위에서 구한 네 가지 경우의 최적 신경망 모델을 사용하여 예측한 결과를 나타낸 것이다. SDEJ모델과 SDJ모델의 경우 예측침하량은 실제침하량과 경향이 비슷하게 나타났다. 하지만 오차가 20~30cm 정도 크게 나타났다. SJ모델의 예측침하량은 마지막 성토단계를 제외하고는 실제침하량과 값이 거의 일치하

는 것을 볼 수 있다. 하지만 SEJ모델의 경우는 실제침하량과 큰 차이가 나타났다. CDJ모델이 CDEJ모델보다 실제 침하량과 더 비슷한 결과를 나타냈다. CJ모델과 CEJ 모델의 경우는 두 가지 모델이 비슷하지만 위의 경우와 마찬가지로 CJ모델의 결과가 더 좋은 결과를 나타냈다. 이런 결과를 토대로 콘관입저항력을 이용한 침하량 예측이 표준관입보다, Jordan 모델이 Elman-Jordan 모델보다 더 좋은 결과를 나타냈다는 것을 알 수 있다.

### 2.4 입력변수의 중요도 분석

각 모델들의 상대적 중요도를 평가하기 위해 Garson (1991)이 제시한 인공신경망의 sensitivity 해석기법을 적용하였다. 이는 입력총 노드 i, 은닉총 노드 j 그리고 출력총 노드 k의 연결강도를 이용하여 각각의 입력변수 가 신경망의 예측과정에서 어느 정도의 상대적 중요성을 지니고 있는가를 판단하는 것으로서 그림 9와 같은 과정으로 구성된다.

위의 과정을 이용한 두 경우 입력변수들의 상대적 중요도는 그림 10~11에 나타났다. SDEJ모델은  $c_c$ ,  $c_v$  가 2~3%로 낮게 나타났다. 다른 입력변수들은 7~10%로 대체로 비슷하게 나타났다. SDJ모델은 성토고, 함수비, 경과일수가 3%,  $c_c$ ,  $c_v$  가 4~6%로 낮게 나타났고, 다른 입력변수들은 8%이상으로 높게 나타났다. SEJ모델은

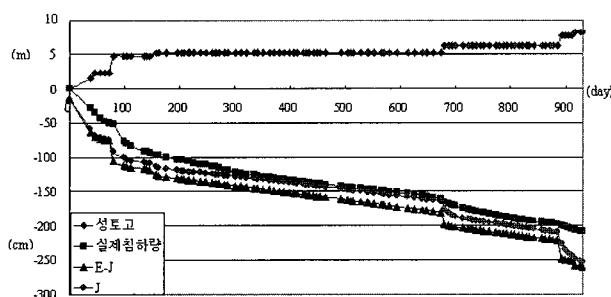


그림 5. 표준관입 저항치를 이용한 경우 (SDEJ, SDJ)

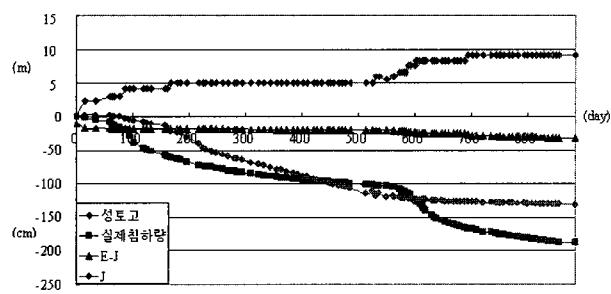


그림 7. 콘관입 저항력을 이용한 경우(CDEJ, CDJ)

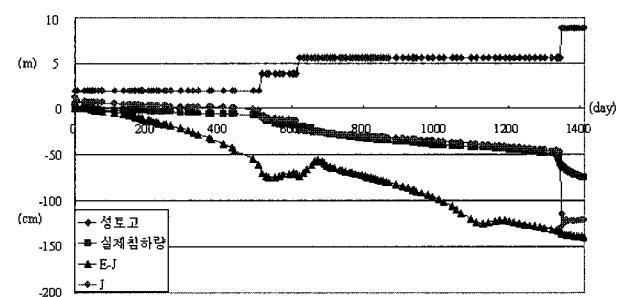


그림 6. 표준관입 저항치를 이용한 경우 (SEJ, SJ)

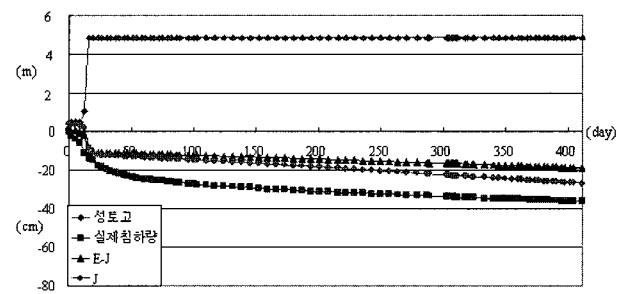


그림 8. 콘관입 저항력을 이용한 경우(CEJ, CJ)

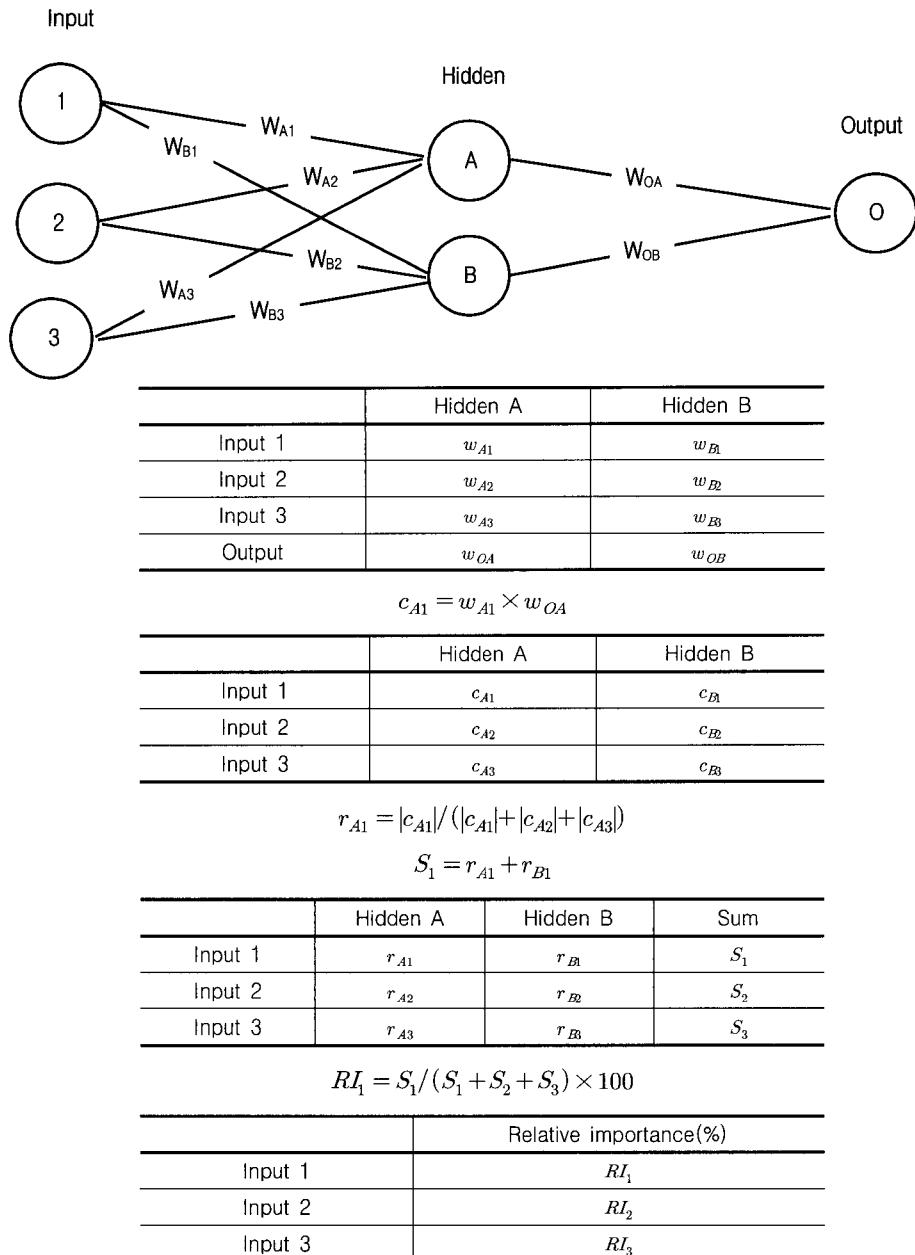


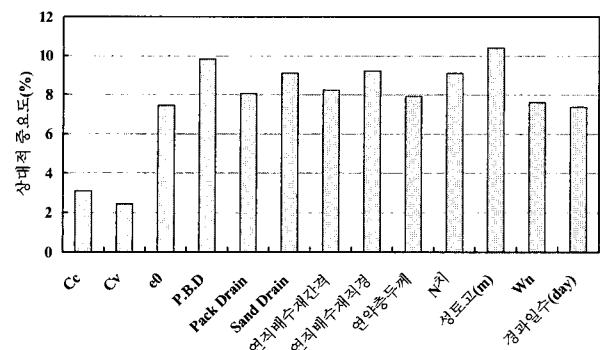
그림 9. 인공신경망의 Sensitivity 해석 기법

경과일수가 20%를 넘어서 가장 높게 나타났고, 다른 입력변수들은 7~14%로 비슷하게 나타났다. SJ모델은 성토고와 경과일수가 18%, 22%를 넘어서 높게 나타났고, N치가 5%로 가장 낮게 나타났다. CDEJ모델은 함수비는 11%, 연약충두께는 10%, 경과일수는 9%로 높게 나타났고,  $c_c$ 와 연직배수재 간격은 4%로 아주 낮게 나타났다. 다른 입력변수들은 6~8%로 대체로 비슷한 값을 나타냈다. CDJ모델은 콘관입저항력과 경과일수가 각각 11%, 13%으로 높게 나타났고, 초기간극비와 성토고는 각각 4%, 5%로 낮게 나타났다. CEJ모델은 경과일수

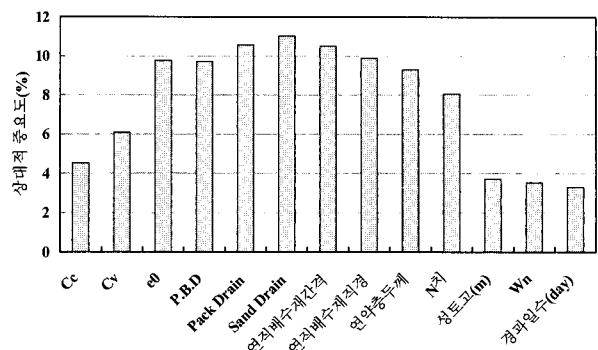
23%, 함수비 22%로 높게 나타났고,  $c_v$ 와 성토고는 15%로 나타났다. 다른 입력변수들은 5~7%로 낮게 나타났다. CJ모델은 성토고, 함수비, 경과일수가 19%이상으로 높게 나타났고, 다른 입력변수들은 4~10%로 낮게 나타났다.

### 3. 결 론

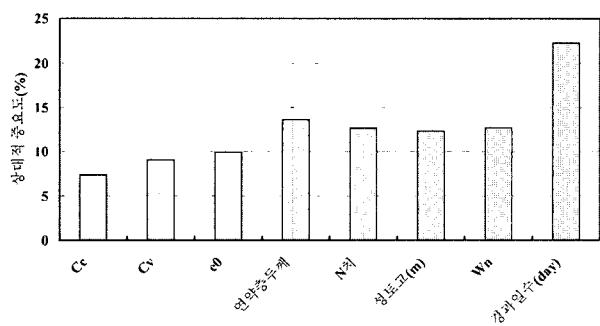
전국 7개 지역 60개소의 연약지반상의 단지조성공사와 도로공사현장에 대한 표준관입시험, 콘관입시험 그



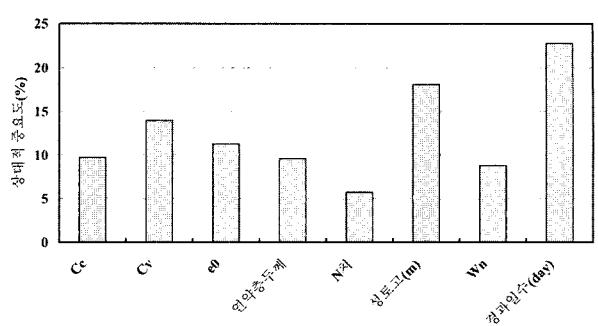
(a) SDEJ 모델



(b) SDJ 모델

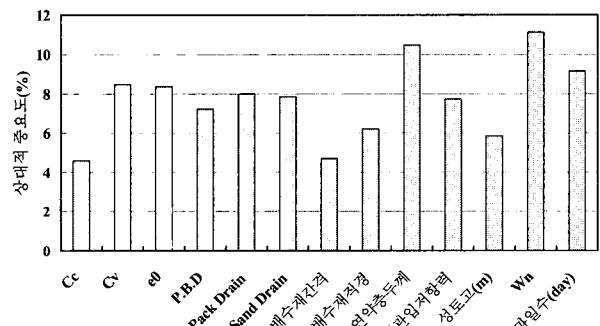


(c) SEJ 모델

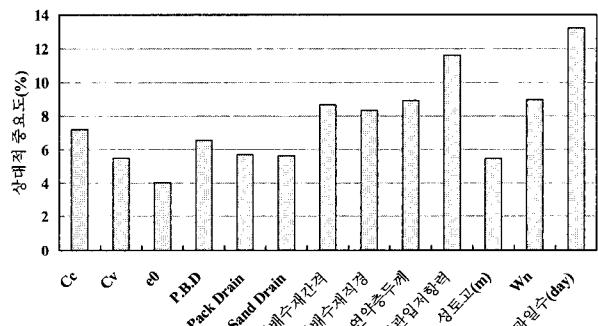


(d) SJ 모델

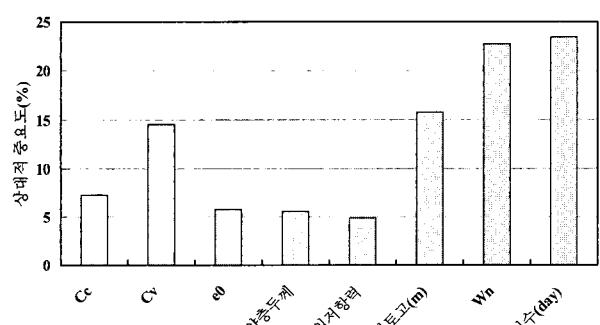
그림 10. 표준관입 저항치를 이용한 경우



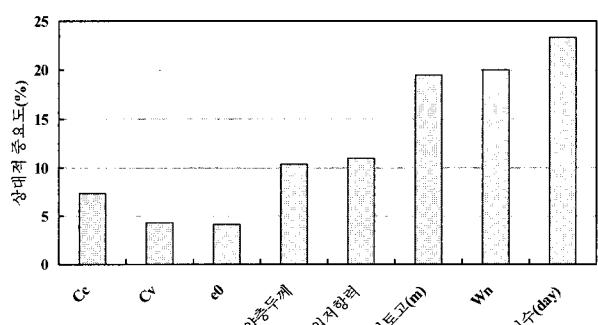
(a) CDEJ 모델



(b) CDJ 모델



(c) CEJ 모델



(d) CJ 모델

그림 11. 콘관입 저항력을 이용한 경우

리고 각종 실내시험 결과와 성토에 따른 침하량 계측자료를 사용하여 인공신경망기법으로 장래 침하량예측을 위한 모델을 개발하였으며, 그 모델을 사용하여 장래침하량을 예측하여 다음과 같은 결론을 얻었다.

- (1) 인공신경망을 이용한 침하량 예측에서 은닉층이 하나인 순환형 신경망(Recurrent Neural Network)인 Jordan 모델과 Elman-Jordan 모델을 사용하였다. 이 때 최적 인공신경망을 얻기위하여 은닉층 노드수는 입력변수 개수의 1배, 1.5배, 2배, 학습율은 0.01, 0.1, 0.3, 0.5, 모멘텀은 0.1, 0.3, 0.5, 0.7을 사용하였다. 전국 7개 지역 60개소의 한정된 자료를 가지고 얻은 결과, 연약지반성토에 따른 침하예측에서 인공신경망이론 적용의 타당성이 입증되었다.
- (2) SDEJ모델의 최적신경망은 13-20-1의 구조로 학습율은 0.5, 모멘텀은 0.5이고, SDJ모델은 13-26-1의 구조로 학습율은 0.5, 모멘텀은 0.1이다. SEJ모델은 8-16-1의 구조로 학습율은 0.3, 모멘텀은 0.1이고, SJ모델은 8-8-1의 구조로 학습율은 0.5, 모멘텀은 0.7이다. 최적모델에 대한 결과는 상관계수가 0.6~0.8 사이로 대체적으로 작게 나타났고, RMSE는 24~29 사이로 크게 나타났다.
- (3) 국내 4개 현장의 한정된 계측자료를 사용하여 장래 침하량을 예측한 결과, SDEJ모델과 SDJ모델의 경우, 예측침하량이 실제침하량과 경향이 비슷하게 나타났다. 하지만 오차가 20~30cm 정도 크게 나타났다. SJ모델의 예측침하량이 마지막 성토단계를 제외하고는 실제침하량과 거의 일치하는 것을 볼 수 있다. 하지만 SEJ모델의 경우는 실제침하량과 큰 차이가 나타났다. 그래서 연직배수재를 사용한 경우, 사용하지 않은 경우 모두 Jordan 모델이 실제 침하량과 더 잘 일치했다.
- (4) 입력변수들의 상대적 중요도를 분석한 결과, SDJ모델은 성토고, 함수비, 경과일수,  $c_c$ ,  $c_v$  낮게 나타났고, 다른 입력변수들은 대체로 높게 나타났다. SJ모델은 성토고와 경과일수가 높게 나타났고, N치가 가장 낮게 나타났다.
- (5) 최적신경망은 CDEJ모델은 13-13-1의 구조로 학습율은 0.3, 모멘텀은 0.7이고, CDJ모델은 13-13-1의 구조로 학습율은 0.3, 모멘텀은 0.7이다. CEJ모델은 8-8-1의 구조로 학습율은 0.5, 모멘텀은 0.7이고, CJ모델은 8-12-1의 구조로 학습율은 0.01, 모멘텀은 0.1이다. 콘 관입은 상관계수가 대체적으로 0.9이상으로 높게 나타났고, RMSE는 CDEJ 모델에서 26이

넘었을 뿐 나머지 경우들은 대체로 낮게 나타났다. 특히 CJ모델이 상관계수가 0.9737, RMSE는 15.18로 가장 좋은 결과를 나타냈다.

- (6) 국내 3개 현장의 한정된 계측자료를 사용하여 장래침하량을 예측한 결과, CDJ모델이 CDEJ모델보다 실제 침하량과 더 비슷한 결과를 나타냈다. CEJ모델과 CJ모델은 비슷하지만 CJ모델의 결과가 더 좋은 결과를 나타냈다. 그래서 연직배수재를 사용한 경우와 사용하지 않은 경우 모두 Jordan 모델이 실제 침하량과 잘 일치했다.
- (7) 입력변수들의 상대적 중요도를 분석한 결과, CDJ모델은 콘관입저항력과 경과일수가 높게 나타났고, 초기간극비와 성토고는 낮게 나타났다. CJ모델은 성토고, 함수비, 경과일수가 높게 나타났고, 다른 입력변수들은 낮게 나타났다.
- (8) 성토에 따른 침하량 예측에서 콘관입 저항력을 사용한 경우가 표준관입 저항치를 사용한 경우보다 계측치에 더 잘 일치가 되었다. 그 이유는 표준관입 저항치를 사용한 경우는 깊이 1.5m마다 측정한 값을 깊이에 따른 가중치로 산술평균하여 적용하였고, 콘관입 저항치를 사용한 경우는 깊이에 따라 연속적으로 측정한 값을 깊이에 따른 가중치로 산술평균하여 적용하였기 때문인 것으로 판단된다.

## 참 고 문 헌

1. 김병탁, 김영수, 이우진 (2000), “인공신경망을 이용한 모형말뚝의 수평변위와 최대 휨 모멘트 예측”, *한국지반공학회지*, 한국지반공학회, 제16권, 제5호, pp.169-178.
2. 김영수, 정성관, 손창우, 권성복 (2005), “인공신경망을 이용한 낙동강 중류지역 실트의 전단거동 예측”, *한국토목학회지*, 제25권, 제4C호, pp.285-292.
3. Ellis, G. W., Yao, C., and Zhao, R. (1992), “Neural network modeling of the mechanical behavior of sand”, *Proc., 9th Conf. ASCE Engrg. Mech.*, ASCE, New York, pp.421-424.
4. Garson, G. D. (1991), “Interpreting neural-network connection weight”, *AI Expert*, 6(7), 47-51.
5. Giles, C. L., Kuhn, G. M., and Williams, R. J. (1994), “Dynamic recurrent neural networks : theory and application”, *IEEE Trans. Neural Network*, 5(2), pp.153-160.
6. Jian-hua, Z., Musharraf M., and Scott A. (1998), “Modeling of shearing behaviour of a residual soil with recurrent neural network”, *Int. J. Numer. Anal. Meth. Geomech.*, 22, pp.671-687.
7. Mohamed, A. S., Holger, R. M., and Mark, B. J. (2002), “Predicting settlement of shallow foundations using neural network”, *Journal of Geotechnical Engineering*, ASCE, Vol.9, pp.785-793.
8. Parlos, A.G., Chong, K.T, and Atiya, A.F. (1994), “Application of the recurrent multilayer perceptron in modeling complex process dynamics”, *IEEE Trans. Neural Networks*, 5(2), pp.255-285.

(접수일자 2007. 4. 16, 심사완료일 2007. 7. 6)