

Readjusting 기법을 적용한 인공신경망의 모형말뚝 수평변위 예측

Prediction of Lateral Deflection of Model Piles Using Artificial Neural Network by the Application Readjusting Method

김 병 탁^{*1} Kim, Byung-Tak

김 영 수^{*2} Kim, Young-Su

정 성 관^{*3} Jung, Sung-Kwan

Abstract

In this paper, Artificial Neural Network(ANN), which used Readjusting Method to improve learning velocity and avoid false local minimum, is applied to the prediction of lateral deflection of single and group piles. This neural network is named M-EBPNN in this paper. The result of neural network(M-EBPNN) is compared with measured data from model test and also with the results of EBPNN to evaluate the learning velocity and false local minimum.

A series of model tests was performed with single and group piles in Nakdong River Sand. For the verification of applicability of the M-EBPNN, a total of 600 data of model test results for single and group piles are used. Also, in this study, a neural network structure with one input layer, two hidden layer, and one output layer, which is the same as the structure of the EBPNN, is used. The 25, 50 and 75%, respectively, out of total data are used for training the neural network, and the others are used for the comparison between the predicted and the measured results. Also, the number of neuron for each hidden layer and learning ratio used, is the same as the EBPNN algorithm. The results show that the learning epoch of the M-EBPNN for the same learning pattern was reduced by 88% and the convergence to global minimum is guaranteed compared with the results of EBPNN. The predicted values utilizing the M-EBPNN can provide a better matching with the results of model pile tests compared with the results of the EBPNN. These limited results show the possibility of utilizing the neural networks for the prediction of the lateral deflection of laterally loaded pile.

요 지

본 논문에서는 단일 및 군말뚝의 수평변위를 예측하기 위하여 신경망 학습속도의 향상과 지역 최소점 수렴을 방지하는 Readjusting 기법을 적용한 인공신경망을 도입하였다. 이 인공신경망을 M-EBPNN 이라고 한다. M-EBPNN에 의한 결과는 낙동강 모래지반에서 단일 및 군말뚝에 대하여 수행한 일련의 모형실험결과와 비교하였으며, 그리고 신경망의 학습속도와 지역 최소점의 수렴성을 평가하기 위하여 오류 역전파 신경망(EBPNN)의 결과와도 비교 분석하였다.

M-EBPNN의 적용성 검증을 위하여 200개의 모형실험결과들을 이용하였으며, 신경망의 구조는 EBPNN의 구조와 동일한 한개의 입력층과 두개의 은닉층 그리고 한개의 출력층으로 구성되었다. 전체 데이터의 25%, 50% 그리고 75% 결과는 각각 신경망의 학습에 이용되었으며 학습에 이용하지 않은 데이터들은 예측에 이용되었다. 그리고, 신경망의 최적학습을 위하여 적합한 은닉층의 뉴런 수와 학습률은 EBPNN에서 결정한 값들을 본 신경망에 이용하였다. 해석결과들에 의하면, 동일한 학습패턴에서의 M-EBPNN의 학습 반복횟수는 EBPNN 보다 최고 88% 감소하였으며 지역 최소점에 수렴하는 현상은

*1 정회원, 한국해양연구원 연구원

*2 정회원, 경북대학교 공과대학 토목공학과 교수

*3 정회원, 경북대학교 농과대학 조경학과 교수

거의 나타나지 않았다. 따라서, 인공신경망 모델이 수평하중을 받는 말뚝의 수평변위 예측에 적용될 수 있는 가능성을 보여주었다.

Keywords : Single pile, Group pile, Neural network, Lateral deflection, Readjusting method, False local minimum

1. 서 론

오류 역전파 알고리즘은 학습시 전역적 최소점이 아닌 지역 최소점에서 연결강도에 대한 오차함수의 미분계수가 영(zero)이 됨으로 그곳에서 탈출할 수 없게 되고 오차만남게 되는 문제점과 Off-line 학습으로 학습 완료까지 많은 횟수의 반복학습이 필요하여 학습시간이 길어지는 단점이 있다. 이러한 문제점 및 단점이 오류 역전파 알고리즘의 가장 큰 결점으로 대두되고 있으며 이들 외의 문제점으로는 추가 학습시 전체적인 재학습이 필요하다는 것과 학습의 완료시점을 예측할 수 없다는 것이다. 이들 중 신경망 학습속도를 개선하기 위한 여러 가지 방법들로는 일괄수정법, 출력값의 제한, 모멘텀 방법, 수정 모멘텀 방법, 학습률의 최적화 방법, 복잡도 방법, 선택된 재학습 방법 그리고 연결강도 갯수를 축소하는 방법이 제안되고 있으나, 아직까지도 이들 방법들이 명확한 해결방법이라고는 할 수 없다(김대수, 1998).

일반화된 엘타규칙의 신경망에서 활성함수로 사용하는 시그모이드 함수는 미분하게 되면 벨(bell) 형상으로 이루어져 뉴런간의 연결강도를 재조정하는 역전파 과정에서 활성함수의 미분값이 영(zero)과 1에 가까워짐에 따라 연결강도의 수정이 거의 이루어지지 못하게 되며, 이러한 현상을 “premature saturation”이라 한다. 따라서, 신경망의 학습속도가 상당히 늦어질 뿐만 아니라 시스템 오차가 전역 최소점 (global minimum)이 아닌 지역 최소점 (local minimum)에 수렴할 가능성 있다. 이러한 문제점들이 오류 역전파 신경망을 이용한 말뚝의 수평거동 예측시에 상당히 발생하고 있으며, 특히 수평변위 예측에서는 잣은 지역 최소점에 수렴하면서 전역 최소점에 수렴하는 것으로 나타났고 이에 따라 신경망 학습에 많은 시간이 소요되는 것을 김병탁의 2인 (2000c)에서 밝힌바 있다. 시스템 오차의 지역 최소점에 수렴하는 것을 방지하기 위한 신경망 알고리즘으로는 Annealing (Kirkpatrick 등, 1983), Mean Field Annealing (MFA; Bilbro 등, 1992), On-line weight updating (Xu 등, 1992), Starting with appropriate weights (Kolen 와 Pollack, 1991) 등이 최근 제안되고 있다.

본 연구의 목적은 지반공학 분야에 주로 적용되고 있는 오류 역전파 신경망(EBPNN)의 단점에 대한 검토와 FLM(False Local Minimum) 문제 및 신경망 학습 속도를 동시에 개선할 수 있는 Readjusting 알고리즘(Fukuoka 등, 1998)을 지반공학 문제 중에 말뚝의 수평거동 예측에 적용하여 타당성을 검증하고자 함에 있다.

Readjusting 알고리즘을 적용한 신경망(M-EBPNN)의 학습속도와 말뚝의 수평변위 예측결과는 EBPNN의 결과들과 비교 분석하여 M-EBPNN의 학습속도 개선효과와 수평거동 예측 가능성을 검토하였다.

2. 인공 신경망 알고리즘

2.1 오류 역전파 신경망

본 연구에서 사용한 오류 역전파 신경망(EBPNN)은 텔타규칙과 거의 유사하고 다수의 층으로 이루어진 다층 페셉트론을 학습시킬 수 있는 일반화된 텔타규칙을 이용하고 있다. 일반적으로, 오류 역전파 신경망은 입력값과 목표출력으로 이루어진 학습샘플들을 사용하여 샘플입력에 대한 신경망의 출력값과 목표 출력사이의 오차가 최소로 되도록 규칙에 따라 연결강도를 조정하는 지도학습(supervised learning)이며, 주어진 학습 샘플들을 사용하여 신경망의 성능이 원하는 수준이 될 때까지 연결강도를 조정하여 새로운 샘플이 인가되는 경우 그 연결강도를 이용하여 예측하는 Off-line 학습을 수행하게 된다(김병탁 등, 2000c).

그림 1은 일반화된 텔타 규칙에서의 오차 역전파 과정을 나타내고 있다. 먼저, 그림 1의 오른쪽에 나타낸 것과 같이 신경망이 주어진 입력 패턴에 동작하여 출력을 했을 때, 출력층 뉴런들의 오차가 구해진다. 출력층 뉴런들의 경우 오차를 구하는 방법은 텔타 규칙과 동일하다. 즉, 목적 패턴에서 출력 뉴런의 활성값을 뺀 값이 바로 해당 출력 뉴런의 오차가 된다. 그림 1에서 e_5, e_6, e_7 로 나타낸 것이 각 출력 뉴런들의 오차가 된다.

텔타 규칙의 경우, 구한 출력층 오차를 사용하여 바로

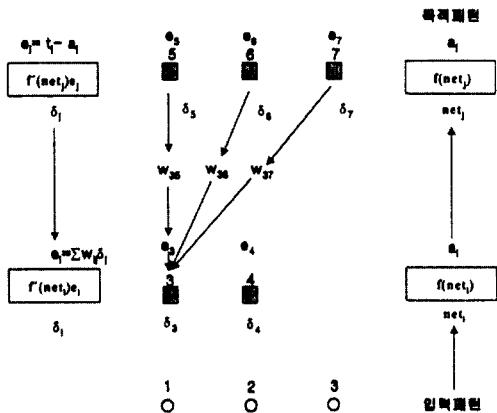


그림 1. 오류 역전파 알고리즘의 개념도

가속 가중치를 조절하지만, 일반화된 델타 규칙에서는 이 오차를 한번 더 가공하여 각각의 출력층 뉴런에 대해 델타 (δ)를 구한다. 뉴런의 오차로부터 출력층 뉴런들의 델타를 구하는 식은 다음과 같다.

$$\begin{aligned}\delta_j &= f'(net_j) \cdot e_j \\ &= \frac{\partial f(net_j)}{\partial net} \cdot e_j = a_j(1-a_j) \cdot (t_j - a_j)\end{aligned}\quad (1)$$

여기서, δ_j 는 출력층 뉴런 j 의 델타, $f(net_j)$ 는 출력층 뉴런 j 의 활성함수의 미분값, e_j 는 출력층 뉴런 j 의 에러, t_j 는 출력층 뉴런 j 에 대응하는 목적 패턴의 성분, 그리고 a_j 는 출력층 뉴런 j 의 활성값이다.

이상과 같이 출력층 뉴런들의 델타가 구해지면, 이 델타를 아래층 뉴런들로 역전파하는 과정이 진행된다. 이 때 은닉층 뉴런의 델타는 다음 식을 이용하여 구할 수 있다.

$$\begin{aligned}\delta_i &= f'(net_i) \cdot e_i \\ &= \frac{\partial f(net_i)}{\partial net_i} \cdot e_i = a_i(1-a_i) \cdot e_i\end{aligned}\quad (2)$$

여기서, e_i 는 $\omega_{ij} \delta_j$ 의 합, δ_i 는 은닉층 뉴런 i 의 델타, $f(net_i)$ 는 은닉층 뉴런 i 의 활성함수의 미분값, e_i 는 은닉층 뉴런 i 의 오차, ω_{ij} 는 뉴런 i 에서 뉴런 j 로의 연결 가중치, δ_j 는 출력층 뉴런 j 의 델타, 그리고 a_i 는 은닉층 뉴런 i 의 활성값이다.

오류 역전파 신경망은 출력값과 목표값의 오차를 줄이기 위하여 입력층에 입력되는 각 패턴에 따라 뉴런들 사이의 연결 가중치를 조절하게 되며 이는 다음 식에 의해 이루어진다.

$$w(new)_{ij} = w(old)_{ij} + \eta \delta_j a_i \quad (3)$$

여기서, $w(new)_{ij}$ 는 뉴런 i, j 사이의 조절된 후의 연결 가중치, $w(old)_{ij}$ 는 뉴런 i, j 사이의 조절되기 전의 연결 가중치, η 는 학습률, δ_j 는 뉴런 j 의 델타, 그리고 a_i 는 뉴런 i 의 활성값이다.

일반적으로, 신경망에서 적용하고 있는 활성함수는 선형함수, 계단함수, 선형포화함수, 시그모이드 함수, 그리고 Gaussian 함수로 정리할 수 있다. 본 연구에서 신경망의 활성함수는 미분 가능하고 비선형적인 시그모이드 함수를 사용하다. 신경망의 연결 가중치 조절식에 관심을 줌으로써 학습 시간을 단축하고 학습 성능의 향상을 위하여 고안된 모멘텀은 현재의 연결 가중치와 그 이전 연결 가중치의 차에 의해 계산된다. 따라서, 모멘텀을 구하기 위해서는 이전의 연결 가중치를 저장하고 있어야 한다. 모멘텀은 신경망의 연결 가중치 조절 과정에 추가되며, 이 모멘텀이 추가됨으로써 일반화된 델타 규칙에 의한 연결 가중치를 조절하는 식 (3)은 다음 식과 같이 변하게 된다.

$$w(new)_{ij} = w(old)_{ij} + \eta \delta_j a_i + \beta \Delta w_{ij}(old) \quad (4)$$

β 는 학습률 η 와 유사한 역할을 하는 것으로 모멘텀의 크기를 제어하기 위한 상수이다. β 는 0에서 1사이의 값이며, 일반적으로 0.7 ~ 0.9정도의 값이 사용된다.

바이어스 (bias)는 입력층 뉴런을 제외한 모든 뉴런이 가지는 특성으로서 시그모이드 함수의 b 에 해당하는 역할을 한다. 그리고, 바이어스는 마치 언제나 출력이 1인 가상적인 뉴런을 달고 있는 연결 가중치처럼 취급된다. 따라서, 바이어스는 뉴런의 활성에 참여할 뿐만 아니라 다른 연결 가중치들과 마찬가지로 학습에 의해 조절된다. 바이어스의 학습 역시 마치 그것이 언제나 출력이 1인 가상적인 뉴런을 달고 있는 연결 가중치와 같이 이루어진다.

일반화된 델타규칙에서 학습 완료 정도를 나타내는 시스템 오차 (system error)는 다음 식에서와 같이 출력 패턴과 목적 패턴과의 차이에 의해 계산할 수 있다.

$$E_p = \frac{1}{2} \sum_{i=1}^b (o_{p,i} - t_{p,i})^2 \quad (5)$$

여기서, $o_{p,i}$ 는 입력 패턴 p 에 대한 출력층 i 번째 뉴런의 실제 출력값, $t_{p,i}$ 는 목적 패턴 p 의 i 번째 성분, 그리고 E_p 는 모든 패턴에 대한 신경망의 총 오차이다.

2.2 Readjusting 기법

Readjusting 기법은 뉴런의 포화영역에서 활성함수의

미분값이 Zero가 됨으로 연결강도가 변하지 않은 점을 각 패턴 오차가 최소화될 때까지 활성함수 미분값을 상대적으로 크게 유지하는 개념을 적용하는 기법이다.

이를 위하여 Fukuoka 등(1998)은 신경망 포화도(degree of saturation)라는 계수를 이용하였으며 다음의 식과 같다.

$$D_i^l \equiv |y_i^l - 0.5| \quad (6)$$

여기서, D_i^l 는 신경망 임의 l 층에서의 i 번째 뉴런의 신경망 포화도이고 y_i^l 는 임의 l 층에서의 i 번째 뉴런의 활성값이다.

그림 2는 EBPNN 과 Readjusting 기법에서의 신경망 포화도의 변화를 학습반복횟수에 대하여 나타낸 것으로 EBPNN 에서는 신경망의 학습속도가 감소하지 않고 있으나 Readjusting 기법에서는 활성함수의 미분값을 증가시켜 주는 방향으로 신경망 포화도 값이 감소하고 있음을 보여주고 있다.

지역 최소점과 포화영역에 빠지는 것을 방지하기 위하여, 신경망 포화도는 다음의 식으로 표현되는 최대 신경망 오차(e_{\max})가 클 때 작게 유지되어야 활성함수의 미분값이 증가하여 학습의 속도가 개선될 수 있다.

$$e_{\max} = \max |y_{j,c}^3 - d_{j,c}| \quad (7)$$

여기서, $y_{j,c}^3$ 는 출력층 j 번째 출력값이고, $d_{j,c}$ 는 출력층 j 번째 목표값이다.

각 뉴런의 활성값은 뉴런의 입력값($\sum \omega y$)에 의하여 결정된다. 만약, 각 연결강도에 0에서 1 사이의 값을 갖는 임의 계수(β)를 적용한다면, 뉴런에 입력된 절대값은 감소한다. 따라서, 활성값은 시그모이드 함수의 중심에 근접하게 된다. 이러한 기법을 Readjusting 이라고 하며, 이 기법은 신경망의 포화도를 감소시키고 활성함수의 미분값을 증가시켜준다.

신경망 학습에서 만족할만한 결과를 얻기 위하여는 β 와 학습률(η)의 관계를 정립할 필요가 있으며 이를 관계를 나타내면 다음의 식과 같다.

1) 은닉층 - 출력층간 연결강도의 경우

$$\beta_j^l = 1 - \eta e_{\max} \gamma \quad (8)$$

2) 입력층 - 은닉층과 은닉층들간의 연결강도

$$\beta_j^l = 1 - \frac{1}{2} \eta e_{\max} \gamma \quad (9)$$

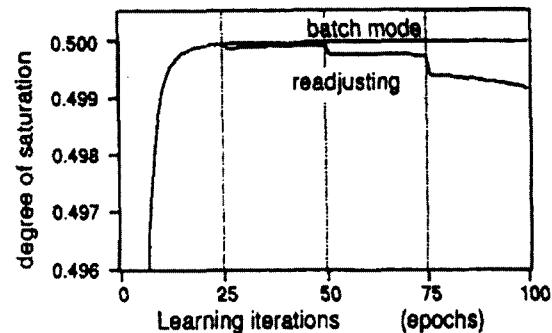


그림 2. 학습반복횟수와 신경망 포화도의 관계
(Fukuoka, 1998)

표 1. 신경망 포화도에 따른 γ 값

D_j^l	e_{\max}		
	0.0~2 E_p^*	2 E_p ~3.4 E_p	$\geq 3.4 E_p$
0.5~0.43		0.5	1.0
0.43~0.1	0.0	0.1	0.5
0.1~0.0		0.02	0.1

* E_p 는 학습의 종료시점을 결정하는 시스템 오차이다.

여기서, γ 는 다음의 표 1과 같이 정리할 수 있다.

이 기법은 시그모이드 함수의 기울기를 효과적으로 조절하고 있기 때문에 지역 최소점을 개선하는 MFA (Mean Field Annealing)과 신경망 학습속도를 개선하는 STELA (Standstill Evading Learning Algorithm)과 유사하다. 본 Readjusting 기법은 EBPNN 의 기능을 향상시키기 위하여 EBPNN 에 적용되는 것으로서 신경망 학습동안에 임의의 학습 반복횟수(T_r)마다 식(8)과(9)에서 얻어지는 β 값을 각 연결강도에 고려하여 신경망 학습을 수행하게 된다.

3. EBPNN 과 M-EBPNN에 의한 학습 및 예측결과 비교분석

3.1 신경망 구조와 학습방법

본 연구에서는 단일 및 군말뚝의 수평변위를 신경망 구조에서 학습과 예측을 수행하기 위하여 200회의 단일 및 군말뚝의 모형실험 결과들을 이용하였다.

본 연구에서 사용한 신경망 구조는 은닉층(hidden layer)이 모두 2개 층으로 이루어져 있다. 신경망 구조는 그림 3과 같이 17개의 입력 변수를 갖는 구조($I_{17}H_{30-30}O_1$)로 형성하였다.

단일밀뚝과 군말뚝의 모형실험에 사용한 입력변수들

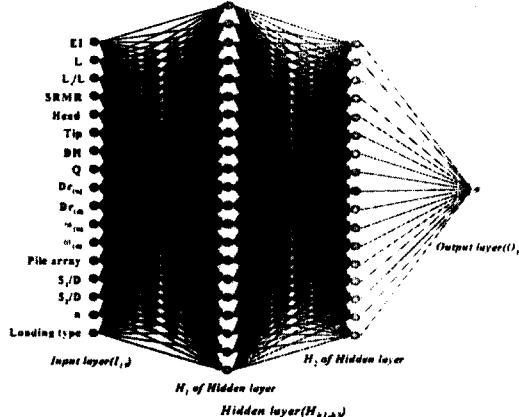


그림 3. 신경망 구조 ($I_{i,j}H_{k1,2,j}O_j$)

은 그림 4의 각 모형실험 개요도에 표시하였다. 신경망 입력층의 입력 변수 값들에 대한 정규화를 위하여 본 연구에서는 다음의 식을 적용하였다. 그리고, 각 신경망에 적용한 입력 값의 범위는 표 1과 같다.

$$x_{norm} = \frac{x + (x_{max} - 9x_{min})/8}{(x_{max} - 9x_{min})/0.8} \quad (10)$$

여기서, x_{norm} 는 정규화한 값이고 x_{max} 와 x_{min} 는 각 입력 변수 중 최대값과 최소값이며, x 는 각 입력층 뉴런에서의 입력 값이다.

신경망 학습시 입력되는 입력 패턴의 수는 모형실험 결과들 (김영수 등, 1998, 1999, 2000a; 김병탁, 2000b) 각각에서 수평하중 1, 2, 3, 4kg에 해당하는 전체 데이터(600개) 중에서 25%, 50%, 75%의 3가지 종류로 임의 선택하여 학

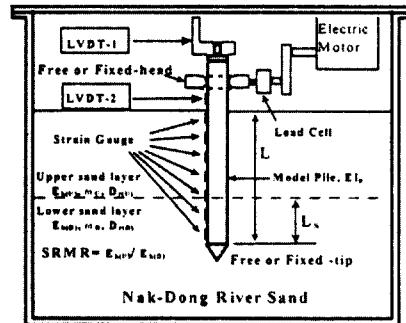


그림 4-(a). 단일말뚝의 모형실험 개요도(김병탁, 2000b)

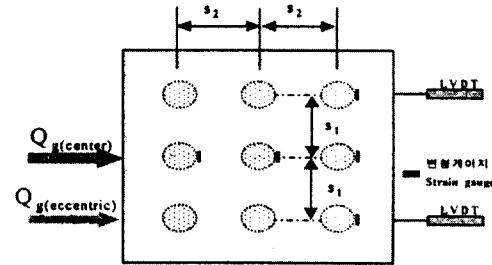
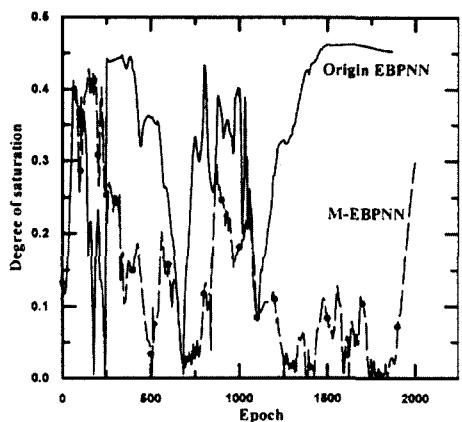


그림 4-(b). 군말뚝의 모형실험 개요도(김병탁, 2000b)

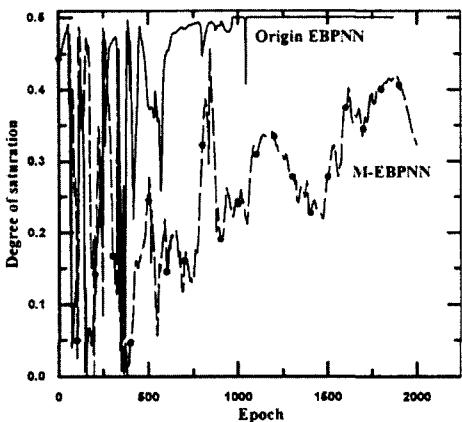
습을 하였다. 이는 신경망의 학습 반복횟수 (epoch)가 입력 패턴의 수와 관련하여 결정되기 때문에 이에 대한 검토를 위하여 달리 학습을 수행하였다. 그리고, 본 연구에서 사용한 모형말뚝의 제원은 직경 1.2cm, 두께 0.25mm, 길이 21~51cm, 탄성계수 $2.1 \times 10^6 \text{ kg/cm}^2$, 항복 휨모멘트 $70 \text{ kg} \times \text{cm}$, 휨강성 $3.41 \times 10^4 \text{ kg} \times \text{cm}^2$ 로서 스테인레스 스틸재질의 강관말뚝을 사용하였다. 또한, 실측한 수평변

표 2. 인공 신경망 학습을 위한 입력변수 및 입력값의 범위

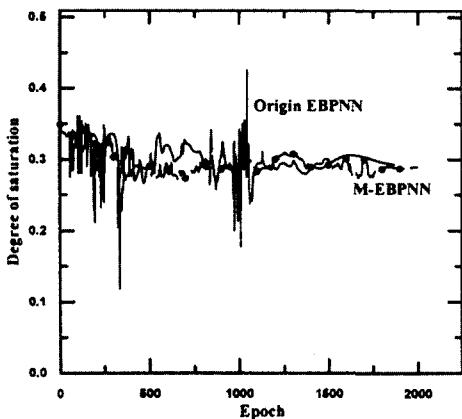
입력 변수	최소값	최대값	비 고
비균질지반 층 두께비 (L _S /L)	0.25	1.0	-
지반반력 계수비 (SRMR)	0.18	5.56	
상부층 상대밀도 (D _{r,U} , %)	26.5	72.7	
하부층 상대밀도 (D _{r,D} , %)	26.5	72.7	
상부층 지반 함수비 (ω _u , %)	0.0	34.06	
하부층 지반 함수비 (ω _d , %)	0.0	34.06	원전 포화인 경우 : 34.06%
말뚝 휨강성 (EI _p , kg×cm)	34,090	101,787	-
말뚝 근입길이 (L, cm)	21.0	51.0	
말뚝두부 구속조건	-1.0	1.0	
말뚝선단 구속조건	-1.0	1.0	고정조건인 경우 : -1.0 자유조건인 경우 : 1.0
하중직각방향의 말뚝간격비 (S ₁ /D)	0.0	12.0	단일말뚝의 경우 : 0.0
하중재하방향의 말뚝간격비 (S ₂ /D)	0.0	12.0	단일말뚝의 경우 : 1.0
말뚝 수 (n)	1.0	9.0	
수평하중 (Q, kg)	0.0	10.0	
향타높이 (DH, cm)	0.0	15.0	매입말뚝의 경우 : 0.0
하중재하방식	-1.0	1.0	중심재하의 경우 : -1.0 편심재하의 경우 : 1.0
말뚝배열방식	0.0	6.0	단일말뚝의 경우 : 0.0



(a) H_1 은닉층의 경우 (첫번째 뉴런)



(b) H_2 은닉층의 경우 (첫번째 뉴런)

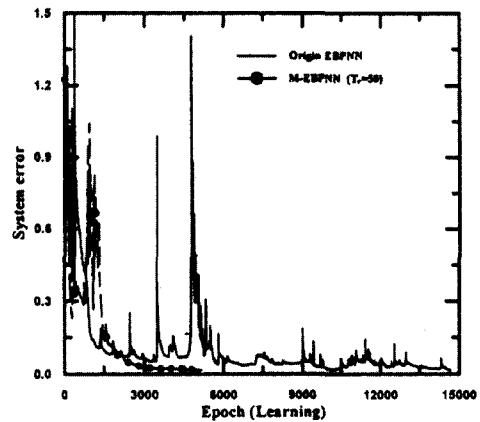


(c) 출력층 뉴런의 경우

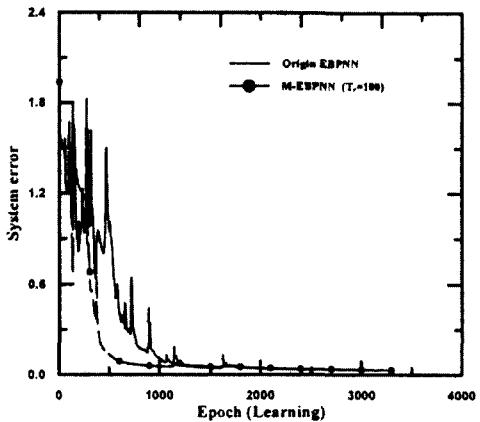
그림 5. EBPNN과 M-EBPNN의 각 뉴런의 신경망 포화도 변화
($E_0 = 0.1$ 또는 Epoch ≤ 2000 기준)

위는 그림 4에서, 단일말뚝의 경우, LVDT-2의 측정값을 그리고, 군말뚝의 경우, 2개의 LVDT 측정값의 평균값을 사용하였다.

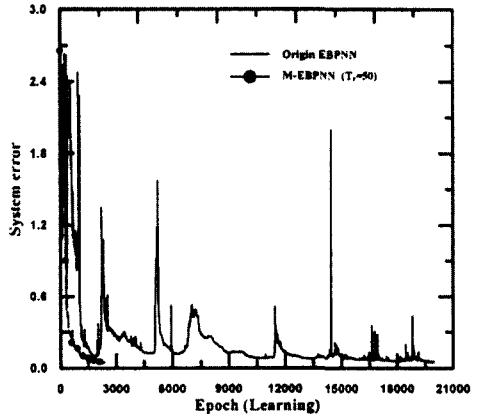
신경망의 학습에 있어 필요한 최적의 학습률은



(a) 150개의 학습 패턴수



(b) 300개의 학습 패턴수



(c) 450개의 학습 패턴수

그림 6. EBPNN과 M-EBPNN에 대한 시스템오차의 변화 비교

EBPNN과 동일하게 학습 반복횟수가 가장 적은 학습률은 0.9 그리고 모멘텀(β)은 일반적으로 국내외에서 인공 신경망에 적용할 경우 0.9를 사용하고 있으며 본 연구에서도 이를 이용하였다(김병탁 등, 2000c). 또한, EBPNN과 M-EBPNN에 있어서 초기상태에서 연결강도와 바이어스

표 3. EBPNN 과 M-EBPNN에 사용한 신경망 변수들의 요약

학습항목	학습 패턴 수	입력 뉴런 수	은닉층 뉴런 수		시스템 오차, E_p
			H_1	H_2	
수평변위	150	17	30	30	0.0150
	300				0.0300
	450				0.0450

를 모두 같은 값으로 설정하면 학습이 불가능해지는 균형 문제 (symmetry problem)가 발생하는데 이러한 균형문제를 해결하기 위하여, 본 연구에서는 초기의 연결강도와 바이어스는 -1.0~1.0 사이의 난수를 발생시켜 초기화하였다.

일반적으로 은닉층 뉴런의 구조는 대칭적으로 구성되는 것이 바람직하나, 이들은 학습률과 모멘텀에 영향을 받음으로서 획일적이지 못하며 다양하게 구성된다. 본 연구에서 M-EBPNN의 학습 및 예측시 사용할 각 은닉층의 뉴런수는 EBPNN에서 검토하여 결정된 각각 30개의 뉴런을 갖는 은닉층을 동일하게 사용하였다(김병탁 등, 2000b).

학습에 사용한 각종 변수들을 요약하면 표 3과 같으며, 표에서 학습종료 시점의 시스템 오차는 각 학습 패턴에서의 시스템 오차 0.0001에 학습 패턴 수만큼의 누적 값이다.

3.2 신경망들의 학습시 신경망 포화도 변화

일반적으로 지반공학분야에 적용되고 있는 EBPNN의 학습속도 향상을 위하여 활성함수의 미분값을 증가시켜 주는 Readjusting 기법을 적용한 M-EBPNN와 EBPNN의 신경망 포화도를 비교 분석하였다.

각 신경망 알고리즘에 대한 뉴런의 신경망 포화도는 본 연구에서 사용한 총 78개의 뉴런 중 은닉층 (H_1, H_2)에서 각각 첫 번째 뉴런 1개와 출력층 뉴런 한 개에 대하여 비교하였으며, 학습반복횟수에 따른 신경망 포화도의 변화는 그림 5에서와 같이 나타났다.

그림에서와 같이, 신경망 포화도가 0.5에 가까운 경우는 활성함수의 미분값이 거의 zero에 가까워 연결강도의 조정에 영향을 거의 미치는 학습의 경우이며, 신경망 포화도가 zero에 가까운 경우는 학습동안 연결강도를 활발히 조정함으로서 신경망의 효율을 증가시켜주는 학습이라고 할 수 있다. 따라서, H_1 과 H_2 의 은닉층의 경우에서는 초기의 학습동안 EBPNN과 M-EBPNN의 신경망 포화도 변화가 큰 차이를 보이지 않으나, 학습반복횟수가 점차 증가함에 따라 EBPNN은 신경망 포화도가 0.5에 가까워지며 M-EBPNN은 신경망 포화도가 0.3이하 정도 값으로 나타나고 있다. 그러나 출력층 뉴런의 신경망 포화도는 EBPNN과 M-EBPNN의 신경망 포화도 변화가 거의 유사하게 나타나고 있는데, 이는 은닉층에서 뉴런들의 흥분을 충분히 고려하여 출력층에서 뉴런 값을 나타내고 있기 때문으로 사료된다.

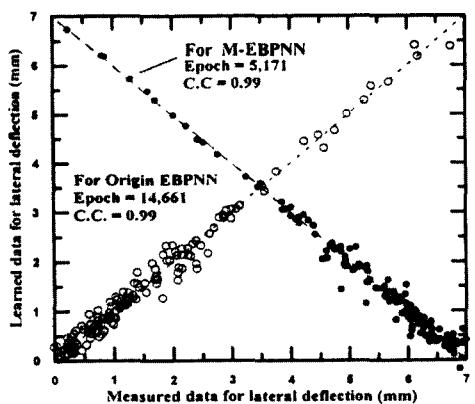
3.3 신경망들의 학습결과 비교

신경망내 연결강도의 값을 감소시켜 활성함수의 포화 영역에 접근하는 것을 방지하여 줌으로 학습의 속도를 증가시키고 지역 최소점으로의 수렴을 방지할 수 있는 Readjusting 기법에서 변수인 T_r 의 값에 따른 신경망 학습 속도를 검토하면 표 4와 같이 나타난다. 이때 학습에 사용한 신경망 구조는 그림 3과 동일한 구조를 이용하였다. 각

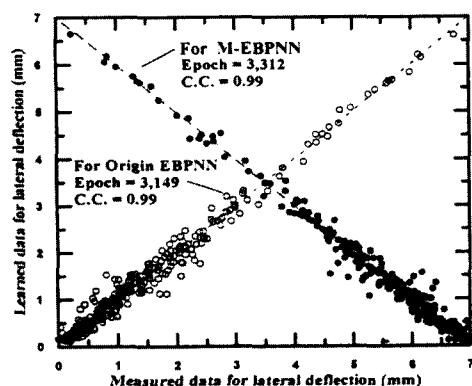
표 4. T_r 에 의한 학습 반복횟수(Epoch) 및 상관계수(C.C.)의 변화

T_r	150개 패턴 ($E_p = 0.015$)		300개 패턴 ($E_p = 0.030$)		450개 패턴 ($E_p = 0.045$)	
	Epoch	C.C.	Epoch	C.C.	Epoch	C.C.
Origin EBPNN	14,661	0.998	3,149	0.994	19,962	0.997
25	8,494	0.918	17,795	0.909	6,393	0.975
50	5,171	0.998	200,000 (0.199*)	0.761	2,361	0.998
100	6,039	0.907	3,312	0.994	3,984	0.971
200	6,850	0.858	4,257	0.959	3,994	0.970
500	200,000 (0.309*)	0.624	71,77	0.944	200,000 (0.195*)	0.887

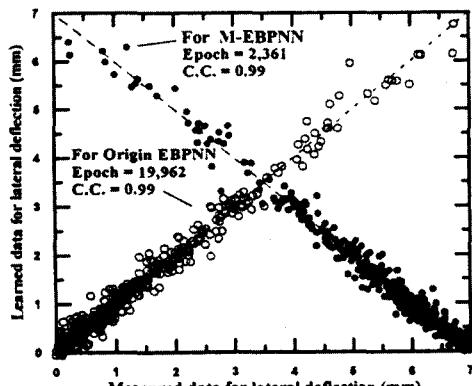
* Epoch=200,000 이내에서 각 시스템 오차 범위 내에 수렴하지 않은 상태에서의 시스템 오차



(a) 150개의 학습 패턴수



(b) 300개의 학습 패턴수



(c) 450개의 학습 패턴수

그림 7. 신경망 학습 후 실험결과와 EBPNN 및 M-EBPNN의 학습결과의 비교

학습 패턴에서 학습 반복횟수에 대한 T_r 의 영향은 크지 않으나, 전반적으로 T_r 이 증가함에 따라 학습 반복횟수는 증가하여 나타났으며 150개와 450개의 학습패턴에서는 $T_r=50$ 에서 그리고 300개의 학습패턴에서는 $T_r=100$ 에서 최소의 학습 반복횟수가 결정되었다.

오류 역전파 학습 알고리즘에 의한 학습속도와 Read-

justing 기법에 의한 학습속도를 비교한다면, 동일 학습패턴에서 반복횟수는 최고 88%의 감소를 나타내어 학습속도 측면에서는 탁월한 것으로 평가할 수 있다.

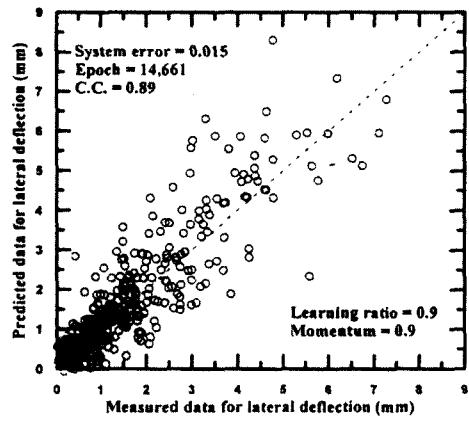
변위에 대한 학습을 수행하고 각 학습패턴에서 학습동안의 시스템 오차의 변화를 EBPNN과 M-EBPNN에 대하여 나타내면 그림 6과 같다.

그림 6에서 고찰한 바와 같이, EBPNN의 경우, 수평변위의 학습동안에는 목표값과 출력값의 오차를 역전파하여 각 신경망 층간의 연결강도를 조정하는 과정에서 일부 뉴런이 흥분하는 현상으로 인하여 노이즈가 상당히 발생하고 있으며 오류 역전파 알고리즘의 문제점 중의 하나인 지역 최소점에 자주 수렴한 후 다시 신경망이 흥분하는 결과를 보여주고 있다. 이는 수평변위의 학습시의 입력 변수들은 단일 및 균일 뿐만 아니라 모든 실험변수들을 적용하여 상호 조합하는 과정이 상당히 복잡하게 이루어지기 때문에 사료된다. 그러나, 오류 역전파에 의한 학습동안의 시스템 오차가 자주 지역 최소점에 빠지는 학습 패턴에서는 Readjusting 기법을 적용할 경우 급경사의 기울기를 따라 신경망이 학습되어 전역 최소점에 수렴하는 결과를 보여주고 있다. 상대적으로 적은 시스템 오차의 노이즈를 발생하는 300개의 학습패턴의 경우에는 학습 초기에 급경사의 기울기를 따라 시스템 오차가 급격히 떨어지거나 전역 최소점에 수렴하기까지는 EBPNN의 결과와 거의 비슷하게 나타났다.

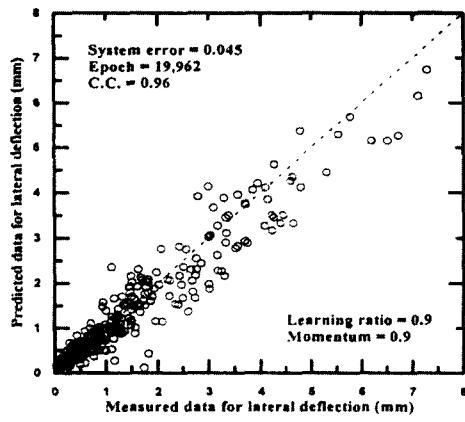
이와 같이, Readjusting 기법에 의한 학습효과는 이 기법을 적용하기 전 학습동안의 시스템 오차의 노이즈가 상당히 많거나 지역 최소점에 자주 빠지는 경우의 신경망에서 훨씬 증가되는 것을 알 수 있다.

신경망 학습 후에 실험결과와 학습결과의 비교를 각 학습패턴에서 EBPNN과 M-EBPNN에 대하여 나타내면 그림 7과 같다. 각 학습이 이루어진 후 학습종료 시스템 오차에 수렴한 학습결과와 실험결과의 상관계수는 EBPNN과 M-EBPNN에 관계없이 0.99 이상으로 학습이 잘 이루어졌다. 그림에서와 같이, 동일한 시스템 오차에서 Readjusting 기법을 적용한 신경망에서는 학습 반복횟수가 급격히 감소됨에 따른 신경망 학습의 결과는 EBPNN의 학습결과와 거의 차이가 없음을 학습결과들의 비교를 통하여 알 수 있었다. 따라서, Readjusting 기법을 적용한 신경망에 의한 학습의 정도가 높음을 알 수 있으며, 학습에 필요한 시간은 20 ~ 30분 정도였다.

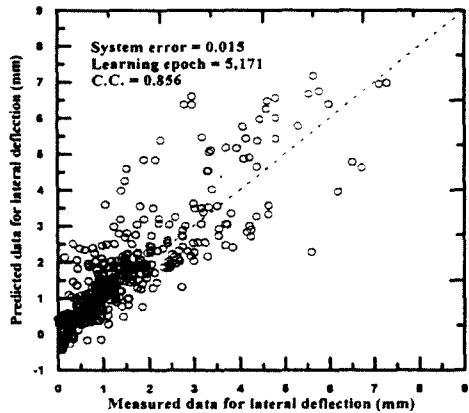
이와 같이, 신경망 학습의 측면에서 Off-line 학습인 EBPNN에 Readjusting 기법을 적용하는 신경망 알고리즘



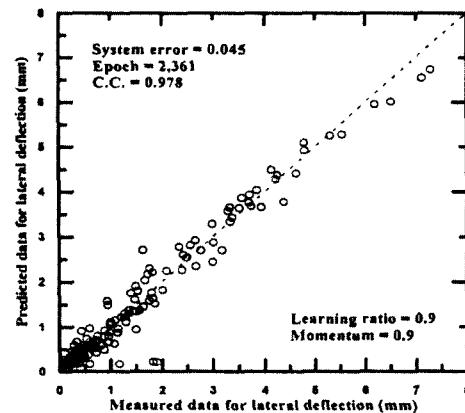
(a) Origin EBPNN (150개의 학습패턴)



(b) Origin EBPNN (450개의 학습패턴)



(c) Readjusting 기법 적용 (150개의 학습패턴)



(d) Readjusting 기법 적용 (450개의 학습 패턴)

그림 8. 학습한 신경망에 의한 예측결과와 모형실험결과의 비교(150과 450개의 학습 패턴수)

의 학습결과는 상당히 만족스럽지만, 신경망 학습속도를 증가시키기 위한 연결강도 감소계수(β)의 고려시 필요한 T_r 의 적절한 결정이 중요하다고 할 수 있다.

3.4 수평거동 예측

EBPNN 알고리즘은 학습을 위하여 주어진 학습 패턴 수 모두에 대한 정보를 종합적으로 저장하고 모든 학습 패턴에 적합한 목표값을 출력하기 위하여 신경망내의 연결 강도와 바이어스를 재조정하게 된다. Readjusting 기법을 적용한 M-EBPNN 알고리즘은 대부분 EBPNN 알고리즘과 동일하나, 연결강도의 재조정시 β 를 이용하여 EBPNN의 단점을 보완하고 있다. EBPNN과 M-EBPNN 알고리즘은 공통적으로 일반화된 델타규칙을 이용한 학습을 통하여 조정된 연결강도와 바이어스를 새로운 입력 패턴들에 적용하여 신경망에 의한 수평거동 예측을 수행하였다.

신경망에 의한 예측은 학습에 입력한 각 패턴들을 제외

한 나머지 패턴 수에 대하여 수행하였다. M-EBPNN에 적용한 신경망의 구조는 EBPNN에 의한 예측과 동일한 것을 이용하였다. 모형실험 결과들 중 전체 데이터의 25%와 75%를 학습한 경우에서 EBPNN과 M-EBPNN 알고리즘에 의한 예측결과와 실험결과를 수평변위에 대하여 비교하면 그림 8과 같다.

M-EBPNN에 의한 수평변위의 예측정도는 EBP NN에서와 같이 신경망 학습에 입력한 패턴 수에 따라 변화하였으며, 예측결과와 실험결과의 상관계수는 0.856~0.978의 범위로 나타나 M-EBPNN에 의한 예측결과는 모형실험의 결과와 아주 높은 일치성을 보여주고 있다. 그러나, 학습 패턴 수가 150개로 적은 경우에는 오류 역전파의 결과보다 작은 상관계수를 나타냈다.

이와 같이, 신경망 학습에서 학습속도의 증가효과가 탁월할 뿐만 아니라 수평거동의 예측에서도 아주 높은 일치성을 보이고 있어, 다양한 입력 변수를 고려할 경우 시스템 오차의 노이즈가 상당히 발생할 것으로 추정되는 신경망

예측에 M-EBPNN의 알고리즘을 적용한다면 학습속도 증가와 만족스러운 예측을 기대할 수 있을 것으로 사료된다.

4. 결 론

말뚝의 수평변위 예측에 EBPNN과 M-EBPNN의 인공신경망을 적용한 결과는 다음과 같다.

- (1) EBPNN에 의한 학습속도와 M-EBPNN에 의한 학습속도를 비교한 결과, 동일 학습패턴에서 반복횟수는 최고 88%의 감소하여 학습속도 측면에서는 탁월한 것으로 나타났다. 또한, 학습시 발생하는 지역 최소점(false local minimum)의 문제는 M-EBPNN의 경우 EBPNN에 비하여 상당히 적게 발생하여 충분히 전역 최소점(global minimum) 수렴을 보장할 수가 있는 것으로 나타났다.
- (2) EBPNN 알고리즘에 의한 은닉층 뉴런의 신경망 포화도 변화는 연결강도의 재조정을 어렵게 하는 양상을 나타내어 신경망 학습의 성능을 저하시키고 있었으나, M-EBPNN은 이러한 EBPNN의 단점을 충분히 보완할 수 있는 결과를 보여주고 있다.
- (3) M-EBPNN 알고리즘을 이용한 신경망의 예측결과와 실험결과의 상관계수는 0.86 이상으로 나타나 정확한 예측이 가능하였다.

이러한 M-EBPNN 알고리즘과 매우 다양한 조건에 대한 많은 현장실험결과들을 바탕으로 체계적인 데이터베이스를 활용한다면 신뢰성과 경제성을 갖춘 말뚝의 수평거동 예측결과가 얻어질 수 있을 것으로 사료된다.

참 고 문 헌

1. 김대수 (1998), “신경망 이론과 운용 (I)”, 하이테크 정보.
2. 김영수, 김병탁(1998), “균질지반과 비균질지반에서 강관 모형말뚝의 수평거동 특성에 관한 모형실험”, 한국지반공학회지, 제14권, 제6호, pp. 153-166.
3. 김영수, 김병탁(1999a), “비균질지반에서 항타 관입한 단일 강성말뚝의 수평거동 연구”, 한국지반공학회지, 제15권, 제6호, pp.167-185.
4. 김영수, 정성관, 김병탁(1999b), “비균질 사질토 지반에서 단일 휨성 말뚝의 수평거동에 대한 말뚝두부 구속효과 연구”, 한국지반공학회지, 제15권, 제5호, pp.65-80.
5. 김영수, 김병탁(2000a), “사질토 지반에서 군말뚝의 수평거동에 관한 연구”, 한국지반공학회지, 제16권, 제1호, pp.117-130.
6. 김병탁 (2000b), “비균질 사질토 지반에서 말뚝의 수평거동 연구”, 박사학위논문, 경북대학교.
7. 김병탁, 김영수, 이우진(2000c), “인공신경망을 이용한 말뚝의 수평변위와 최대 휨모멘트의 예측”, 한국지반공학회지, 제16권, 제5호, pp.169-178
8. 이인모, 이정학 (1994), “인공 신경망 이론을 이용한 말뚝의 극한지력 해석(I).이론”, 한국지반공학회지, 제10권, 제4호, pp.17-27
9. Bilbro, G.L., Snyder, W.E., Gramier, S.J., and Gault, J.W. (1992), “Mean field annealing: A formalism for constructing GNC-like algorithms”, IEEE Transactions on Neural Networks, Vol.3, pp.131-138.
10. Fukuoka, Y., Matsuki, H., Minamitani, H., and Ishida, A.. (1998), “A modified back-propagation method to avoid false local minima”, Neural Networks, Vol.11, pp.1059-1072.
11. Kiefa, M.A.A. (1996), “General regression neural networks for driven piles in cohesionless soils”, ASCE, Vol.124, No.12, pp.1177-1185.
12. Kirkpatrick, S., Gelatt, C.D. Jr., and Vecchi, M.P. (1983), “Optimization by simulated annealing”, Science, Vol.220, pp.671-680.
13. Kolen, J.F. and Pollack, J.B. (1991), Back propagation is sensitive to initial conditions, Advances in Neural Information Processing Systems 3, San Mateo.
14. Nawari, N.O., and Nusairat, J. (1999), “Artificial intelligence techniques for the design and analysis of deep foundations”, Electronic Journal of Geotech. Eng., EJGE, Vol.4.
15. Xu, L., Klasa, S., and Yuille, A.(1992), “Recent advances on techniques of static feedforward networks with supervised learning”, Int. J. of Neural Systems, Vol.3, pp.253-290.

(접수일자 2000. 9. 15)