

인공 신경망을 이용한 모형말뚝의 수평변위와 최대 휨모멘트 예측

Prediction of Lateral Deflection and Maximum Bending Moment of Model Piles Using Artificial Neural Network

김 병 탁*¹ Kim, Byung-Tak

김 영 수*² Kim, Young-Su

이 우 진*³ Lee, Woo-Jin

Abstract

In this paper, Artificial Neural Network(ANN) is applied to the prediction of lateral deflection and maximum bending moments of single and group piles. The results of neural network are compared with the measured data from model test.

A series of model tests are performed with single and group piles in Nak-Dong River Sand. For the verification of applicability of EBPNN(*Error Back Propagation Neural Network*), a total of 600 data of model test results for single and group piles are used. Also, in this study, the structure of neural network with one input layer - two hidden layer - one output layer 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. The number of neuron for each hidden layer is determined as 30 from the results of model test and the learning ratio is determined as 0.9 to optimize network learning. The results show that the prediction of BPNN can provide a good matching with model pile tests results by training with data more than 50% of total data. These limited results show the possibility of utilizing the neural networks for prediction of the lateral deflections and maximum bending moments of laterally loaded piles.

요 지

본 논문에서는 단일 및 군말뚝의 수평변위와 최대 휨모멘트를 예측하기 위하여 인공신경망을 도입하였다. 인공신경망에 의한 결과는 낙동강 모래지반에서 단일 및 군말뚝에 대하여 수행한 일련의 모형실험결과와 비교하였다.

인공신경망중의 하나인 오류 역전파 신경망(EBPNN)의 적용성 검증을 위하여 600개의 모형실험결과들을 이용하였다. 그리고 신경망의 구조는 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. 인공신경망 학습결과와 실험결과와의 비교에 의하면, 신경망의 최적학습을 위하여 적합한 은닉층의 뉴런 수는 각각 30개로 그리고 학습률은 0.9로 결정되었다. 전체 데이터의 50% 이상으로 학습을 수행한 신경망의 모델은 정확한 예측을 하는 것으로 나타났다. 따라서, 인공신경망 모델이 수평하중을 받는 말뚝의 수평변위와 최대 휨모멘트의 예측에 적용될 수 있는 가능성을 보여주었다.

Keywords : Single pile, Group pile, Neural network, Lateral deflection, Maximum bending moment(MBM)

*1 정회원, 경북대학교 공과대학 토목공학과 공학박사

*2 정회원, 경북대학교 공과대학 토목공학과 교수

*3 정회원, 고려대학교 공과대학 토목환경공학과 부교수

1. 서론

산업의 급속한 발달과 더불어 토목, 건축의 각종 구조물이 점차 복잡하여지고 말뚝의 사용재료, 설치 방법 및 사용 목적도 다양화되고 있다. 구조물이 복잡하여짐에 따라 말뚝에 작용하는 하중상태도 복잡하여지고 있다. 이러한 하중조건은 자연적으로 말뚝의 거동을 복잡하게 하고 있다. 다양한 사용목적에 맞게 말뚝을 안전하고 경제적으로 설계하려면 무엇보다도 이런 복잡한 하중조건하에서의 말뚝의 수평거동 및 말뚝과 지반사이의 상호작용에 관한 연구가 이루어질 필요성이 있다.

최근에는 구조물의 대형화로 인하여 수평력을 받는 말뚝에 주목하지 않을 수 없게 되어, 이에 관한 연구가 국내·외에서 최근에도 활발히 진행되고 있는 실정이다. 또한 이러한 실험결과들을 바탕으로 국외의 여러학자들은 말뚝의 수평거동을 예측할 수 있는 해석기법들을 많이 제안하고 있다.

그러나, 지반조건과 하중조건 및 말뚝 조건들의 다양화로 인하여, 이들 조건들을 동시에 고려한 설계 및 말뚝의 정확한 수평거동 예측은 매우 어려운 실정이다. 이에 외국 의 몇몇 학자들은 이러한 어려움을 극복하기 위한 방법으로 인간의 신경세포 구조를 응용한 인공 신경망 (artificial neural network)을 지반 공학적인 문제에 적용하기 시작 하였다.

이인모 등(1994)은 인공 신경망 이론의 학습방법중 하나인 오류 역전파 학습 알고리즘을 모형말뚝의 연직 극한 지지력 예측에 적용하여, 이 이론이 말뚝의 극한 지지력의 합리적인 산정방법으로 적용될 수 있는지의 가능성을 검토하였다. 그의 연구결과에 의하면, 총 28개의 모형실험결과에 오류 역전파 학습 알고리즘을 적용하여 14개 이상의 학습자료에 의하여 학습된 신경망의 예측결과가 실험결과와 잘 맞는 것으로 나타났다. 그리고 학습시의 학습계수와 모멘텀은 각각 0.2와 0.9로 결정되었으며, 신경망의 은닉층은 2개층으로 각 층의 뉴런은 30개와 10개로 구성하였다.

Kiefa (1996)는 사질토 지반에서 항타 말뚝의 지지력의 결정에 GRNN (General Regression Neural Network)을 적용하는 연구를 수행하였다. 59개의 현장 항타말뚝의 결과를 이용하여 5개의 입력층을 갖는 GRNN를 적용한 예측결과와 실험결과와의 상관계수는 0.9 이상으로 상당히 일치하는 것으로 밝히고 있다. 그리고, Nawari *et al* (1999)는 말뚝의 수직 및 수평거동을 EBPNN (Error Back Propaga-

tion Neural Network)과 GRNN의 신경망을 이용하여 예측하였으며 현장실험결과와 비교하였다.

본 연구에서는 지반조건과 말뚝조건을 고려한 단일말뚝과 군말뚝의 수평거동 예측은 단일 및 군말뚝에 대한 200회의 모형실험결과를 이용하여 인공 신경망 중에서 일반적으로 널리 이용되고 있는 오류 역전파 신경망 (EBPNN) 모델을 적용하였다. 그리고 오류 역전파 신경망에서 학습의 효율을 극대화하기 위한 적절한 학습률과 신경망 구조를 제안하였다. 또한 오류 역전파 신경망을 이용하여 다양한 지반 및 말뚝 변수를 갖는 단일 및 군말뚝의 수평거동을 해석할 수 있는 프로그램을 개발하였다.

2. 인공 신경망 (Artificial Neural Network)

2.1 인공 신경망의 정의

인간이 가지고 있는 신체 기능의 대부분은 신경세포 (neuron)들의 유기적 결합체인 신경망 (neural network)에 의하여 통제된다. 신경망의 증추를 이루고 있는 것이 뇌이다. 인간의 뇌는 대략 150억개의 신경세포들로 구성되며, 각 신경세포는 약 1만개 정도의 연결점 (synapse)을 통하여 인접한 다른 신경세포들과 신호를 서로 주고받는다. 이와 같은 복잡한 구조와 방대한 신호처리 체계는 인간 이외의 다른 생명체에서는 찾아 볼 수 없는 것이다. 물론 인간이 이루어 놓은 그 어떠한 기술문명의 산물도 이와는 견줄 수 없다. (김대수, 1998)

한편, 공학자들의 궁극적인 관심은 뇌의 생리학적 구조와 기능을 밝히는 데 있지 않다. 그보다는 뇌의 복잡한 구조적 특징과 이로부터 비롯되는 고도의 신호처리 체계를 연구하여 고난도의 실제 문제에 적용할 수 있는 새로운 연산 기법을 개발하는데 그 목표를 두고 있다. 이를 위해서는 보고 듣고 깨닫는 인지능력, 연상기억, 추론, 학습 등의 기능이 뇌에서 어떻게 구현되는가를 이해해야 한다. 이를 바탕으로 하여 von Neumann 방식의 컴퓨터와는 전혀 다른 새로운 개념을 갖는 신경회로 컴퓨터 (neural computer)를 개발하고자 하는 것이다. 이는 뇌의 생물학적 구조와 기능을 닮은 시스템을 의미하는 것은 아니다. 단지, 뇌의 구조와 기능을 이해함으로써 뇌가 수행하는 연산기능의 원리로부터 새로운 개념을 추출하여 이를 구현하는 것을 의미한다. 따라서 신경회로 컴퓨터는 뇌의 시스템이라고 볼 수 있다. 이와 같은 시스템을 인공 신경망 (artificial neural network)이라고 한다.

2.2 오류 역전파 신경망 알고리즘

말뚝의 수평거동 예측을 위하여 본 연구에서 사용한 오류 역전파 신경망(EBPNN)은 델타규칙과 거의 유사하고 다수의 층으로 이루어진 다층 퍼셉트론을 학습시킬 수 있는 일반화된 델타규칙을 이용하고 있다. 일반적으로, 오류 역전파 신경망은 입력값과 목표출력으로 이루어진 학습 샘플들을 사용하여 샘플입력에 대한 신경망의 출력값과 목표 출력사이의 오차가 최소로 되도록 규칙에 따라 연결 강도를 조정하는 지도학습(supervised learning)이며, 주어진 학습 샘플들을 사용하여 신경망의 성능이 원하는 수준이 될 때까지 연결강도를 조정하여 새로운 샘플이 인가 되는 경우 그 연결강도를 이용하여 예측하는 Off-line 학습을 수행하게 된다.

(1) 출력층 뉴런의 오차 계산

그림 1은 일반화된 델타 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 델타 규칙과 동일하다. 즉, 목적 패턴에서 출력 뉴런의 활성화값을 짝 값이 바로 해당 출력 뉴런의 오차가 된다. 그림 1에서 e_5, e_6, e_7 로 나타낸 것이 각 출력 뉴런들의 오차가 된다.

(2) 뉴런의 델타 계산

델타 규칙의 경우, 위에서 구한 오차를 사용하여 바로 가속 가중치를 조절하지만, 일반화된 델타 규칙에서는 이 오차를 한번 더 가공하여 각각의 출력층 뉴런에 대해 델타(δ)를 구한다. 그림 1에 $\delta_5, \delta_6, \delta_7$ 로 나타낸 것이 해당

출력층 뉴런들의 델타가 된다.

뉴런의 오차로부터 출력층 뉴런들의 델타를 구하는 식은 다음과 같다.

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

여기서, δ_j 는 출력층 뉴런 j 의 델타, $f'(net_j)$ 는 출력층 뉴런 j 의 활성화함수의 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 활성화값이다.

이상과 같이 출력층 뉴런들의 델타가 구해지면, 이 델타를 아래층 뉴런들로 역전파하는 과정이 진행된다. 이러한 델타의 역전파는 마치 신경망의 정상적인 동작을 완전히 바꾸어 놓은 것과 같다. 즉, 위층 뉴런에서 발생한 델타에 그것에 연결된 연결 가중치가 곱해져 아래층 뉴런으로 전달되고 그렇게 전달된 델타들은 합해진다. 그리고 그렇게 합해진 값이 바로 은닉층 해당 뉴런의 오차가 된다. 이렇게 은닉층 뉴런들의 오차가 구해지면, 다음 식을 이용하여 은닉층 뉴런의 델타를 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 활성화함수의 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 활성화값이다.

(3) 연결 가중치의 조절

뉴런들 사이의 연결 가중치의 조절은 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 활성화값이다.

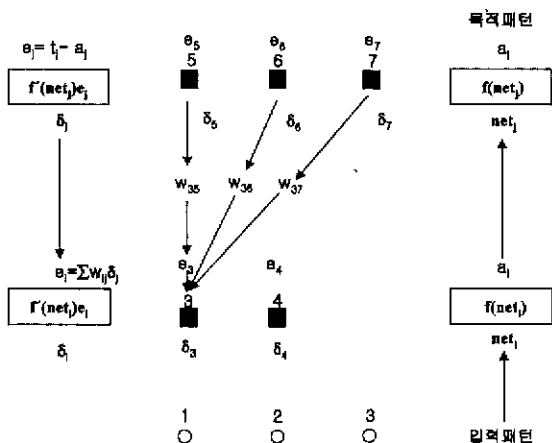


그림 1. 오류 역전파 알고리즘의 개념도

식 (3)에서 δ_j 는 연결 가중치를 수정하고자 하는 뉴런 j 의 델타 값이다. 그리고 a_i 는 뉴런 j 에 달려있는 아래층 뉴런이다. 연결 가중치는 그것에 달려 있는 뉴런의 활성화 값에 비례해서 조절된다.

(4) 활성화 함수

일반적으로, 신경망에서 적용하고 있는 활성화 함수는 선형 함수, 계단 함수, 선형포화 함수, 시그모이드 함수, 그리고 Gaussian 함수로 정리할 수 있다. 본 연구에서 신경망의 활성화 함수는 미분 가능하고 비선형적인 시그모이드 함수를 사용하였으며, 다음과 같은 식으로 표현된다.

$$f(x) = \frac{1}{1 + e^{-(ax-b)}} \quad (4)$$

여기서, a 는 시그모이드 함수의 기울기를 결정하는 x 의 계수이다.

(5) 모멘텀

모멘텀은 신경망의 연결 가중치 조절식에 관성을 줌으로써 학습 시간을 단축하고 학습 성능의 향상을 위해 고안된 것이다. 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.

$$w(new)_{ij} = w(old)_{ij} + \eta \delta_j a_i + \beta \Delta w_{ij}(old) \quad (5)$$

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

(6) 바이어스

바이어스 (bias)는 입력층 뉴런을 제외한 모든 뉴런이 가지는 특성으로서 시그모이드 함수의 b 에 해당하는 역할을 한다. 즉, 역치 함수의 역치와 유사한 기능을 수행하는 것이다. 바이어스는 그림 2에서와 같이 마치 언제나 출력이 1인 가상적인 뉴런을 달고 있는 연결 가중치처럼 취급된다. 따라서, 바이어스는 뉴런의 활성화에 참여할 뿐만 아니라 다른 연결 가중치들과 마찬가지로 학습에 의해 조절

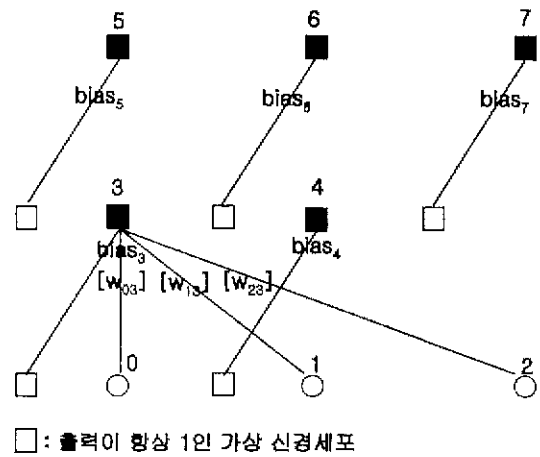


그림 2. 뉴런과 바이어스

된다. 바이어스의 학습 역시 마치 그것이 언제나 출력이 1인 가상적인 뉴런을 달고 있는 연결 가중치와 같이 이루어진다. 즉, 뉴런 j 의 바이어스는 다음 식에 의해 조절된다.

$$bias(new)_j = bias(old)_j + \eta \delta_j a_i + \beta \Delta bias_j(old) \quad (6)$$

우변의 마지막 항은 바이어스의 모멘텀 항이다.

바이어스도 그것에 달려 있는 가상적인 뉴런의 출력이 언제나 1이라는 점을 제외하고는 다른 연결 가중치와 동일하게 취급된다.

바이어스가 일반화된 델타 규칙을 사용하는 신경망의 학습에 미치는 영향은 강력하다. 특히 일반화된 델타 규칙의 경우 시그모이드 함수를 사용하기 때문에 이 바이어스의 역할은 매우 중요하다.

(7) 시스템 오차 계산

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

$$E_p = \frac{1}{2} \sum_{i=1}^n (o_{p,i} - t_{p,i})^2 \quad (7)$$

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.

본 연구에서의 일반화된 델타 규칙을 이용한 신경망 학습은 다음과 같은 단계로 이루어진다.

[1단계] 학습자료의 수를 결정한다. 여기에 사용되는 학습 데이터는 0.1과 0.9사이의 정규화된 값이다.

[2단계] 신경망의 상태를 결정하는 연결 가중치와 바이어스를 각각 -1.0~1.0사이의 임의의 값으로 초기화한다.

[3단계] 정규화시킨 학습패턴을 신경망에 제시한다.

[4단계] 학습 패턴의 값을 입력층 뉴런에 제시하여 출력되는 값 o_{pj} , 입력층과 은닉층 사이의 연결 가중치 w_{vj} 와 은닉층 뉴런 j 의 바이어스 θ_j 를 이용하여 은닉층 뉴런 j 의 입력 net_{pj} 를 구한다. 다음으로 net_{pj} 와 시그모이드 함수를 이용하여 은닉층 뉴런 j 의 출력 o_{pj} 를 구한다.

[5단계] 은닉층 뉴런의 출력 o_{pj} , 은닉층과 출력층 사이의 연결 가중치 w_{jk} 와 출력층 뉴런 k 의 바이어스 θ_k 를 이용하여 출력층 뉴런 k 의 입력 net_{pk} 를 구한다. 다음 net_{pk} 와 시그모이드 함수를 이용하여 출력층 뉴런 k 의 출력 o_{pk} 를 구한다.

[6단계] 학습패턴의 목표출력 t_{pk} 와 실제 출력 o_{pk} 와의 차로부터 출력층 뉴런 k 에 연결된 연결 가중치와 출력층 뉴런 k 의 바이어스에 대한 델타 δ_{pk} 를 구한다.

[7단계] 델타 δ_{pk} 와 은닉층과 출력층간의 연결 가중치 w_{jk} 와 은닉층의 출력 net_{pj} 로부터 은닉층 뉴런 j 에 연결된 결합 가중치와 은닉층 뉴런의 바이어스에 대한 델타 δ_{pj} 를 구한다.

[8단계] 6단계에서 계산한 출력층 뉴런 k 에서의 델타 δ_{pk} , 은닉층 뉴런 j 의 출력 o_{pj} , 상수 α 와의 곱을 더하여 은닉층 뉴런 j 와 출력층 뉴런 k 에 연결된 연결 가중치 w_{jk} 를 수정한다. 또 델타 δ_{pk} 와 상수 β 와의 곱을 더하여 출력층 뉴런 k 의 바이어스 θ_k 를 수정한다.

[9단계] 은닉층 뉴런 j 의 델타 δ_{pj} , 입력층 뉴런 i 의 출력 o_{pi} , 상수 α 와의 곱을 더하여 입력층 뉴런과 은닉층 뉴런 j 에 연결된 연결 가중치 w_{vj} 를 수정한다. 또 델타 δ_{pj} 와 상수 β 와의 곱을 더하여 은닉층 뉴런 j 의 바이어스 θ_j 를 수정한다.

[10단계] 모든 학습패턴에 대하여 전부 학습할 때까지 3단계로 되돌아간다.

[11단계] 학습의 반복 횟수가 제한 횟수보다 적으면 3단계로 되돌아간다.

[12단계] 학습을 종료한다.

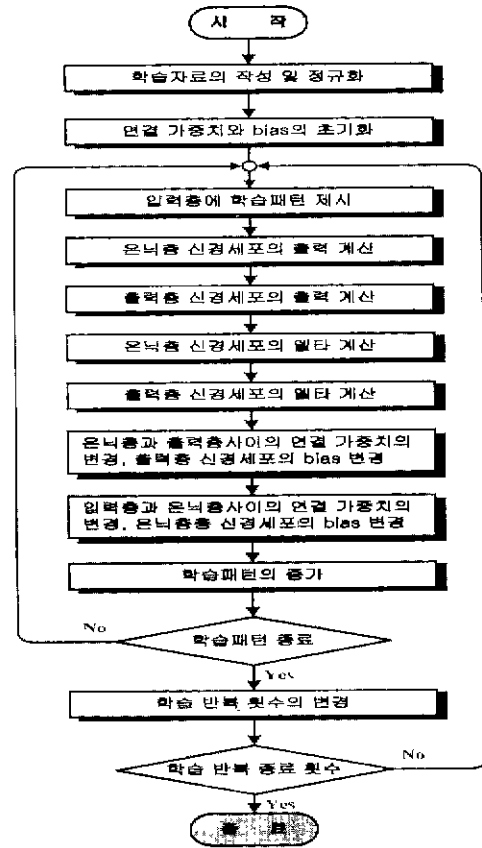


그림 3 오류 역전파 신경망의 흐름도

1 단계부터 12 단계까지의 처리를 흐름도로 나타내면 그림 3과 같다. 여기서 4 단계부터 5 단계까지는 입력층으로부터 출력층에의 전방향(forward)처리이고, 6단계와 7 단계는 델타를 구하는 과정이며, 8 단계부터 9 단계까지는 출력층으로부터 은닉층과 입력층에의 역방향(backward) 처리이다.

3. 인공 신경망을 통한 결과 분석

3.1 인공 신경망 구조

본 연구에서는 말뚝의 수평변위와 최대 휨모멘트(MBM)를 각각 다른 신경망 구조에서 학습과 예측하였다. 이는 균말뚝의 모형실험에서 실험상의 어려움으로 최대 휨모멘트를 측정하지 못하였기 때문이다. 즉, 수평변위를 예측하는 경우에는 단일 및 균말뚝에 대하여 신경망 해석을 수행하였고, 최대 휨모멘트를 예측하는 경우에는 단일 말뚝에 대하여만 신경망 해석을 수행하였다.

이들 2가지 신경망 구조에서 공통된 점은 각 신경망에

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 (w_U , %)	0.0	34.06	완전 포화인 경우 : 34.06%
하부층 지반 함수비 (w_D , %)	0.0	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	고정조건인 경우 : -1.0 자유조건인 경우 : 1.0
말뚝선단 구속조건	-1.0	1.0	
하중직각방향의 말뚝간격비 (S_1/D)	0.0	12.0	단일말뚝의 경우 : 0.0
하중제하방향의 말뚝간격비 (S_2/D)	0.0	12.0	
말뚝 수 (n)	1.0	9.0	단일말뚝의 경우 : 1.0
수평하중 (Q , kg)	0.0	10.0	-
항타높이 (DH, cm)	0.0	15.0	단일말뚝의 경우 : 0.0
하중제하방식	-1.0	1.0	중심제하의 경우 : -1.0 편심제하의 경우 : 1.0
말뚝배열방식	0.0	6.0	단일말뚝의 경우 : 0.0

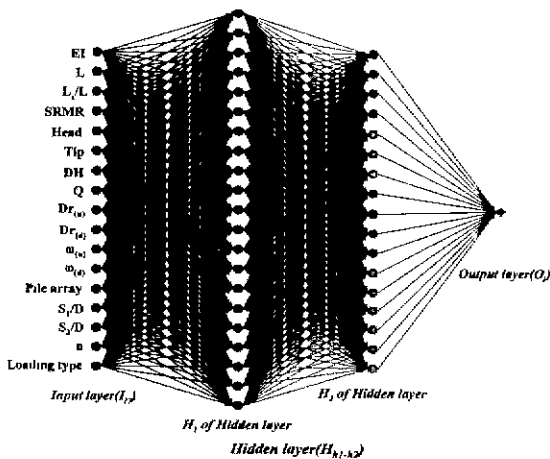


그림 4. 신경망 구조 ($I_{17}H_{30-30}O_1$)

서의 은닉층(hidden layer)은 모두 2계층으로 이루어져 있다. 신경망 구조는 그림 4와 같다. 그림 4는 17개의 입력 변수를 갖는 구조($I_{17}H_{30-30}O_1$)로서 수평변위를 예측하는 경우에 사용하였으며, 최대 휨모멘트를 예측하는 경우에는 그림 4의 입력변수들 중에서 균말뚝의 하중제하방식 (loading type), 말뚝 수(n), 말뚝배열방식(pile array), 하중제하방향 말뚝간격(S_2), 하중직각방향 말뚝간격(S_1)이 포

합되지 않는 신경망 구조($I_{12}H_{30-30}O_1$)를 사용하였다.

단일말뚝과 균말뚝의 모형실험에 사용한 입력변수들은 그림 5의 각 모형실험 개요도에 표시하였다. 그리고, 본 연구에서 사용한 모형말뚝의 재료는 직경 1.2cm, 두께 0.25mm, 길이 21~51cm, 탄성계수 2.1×10^6 kg/cm², 항복 휨모멘트 70 kg×cm, 휨강성 3.41×10^4 kg×cm 로서 스테인레스스틸재료의 강관말뚝을 사용하였다. 또한, 실측한 수평변위는 그림 5에서, 단일말뚝의 경우, LVDT-2의 측정값을 그리고, 균말뚝의 경우, 2개의 LVDT 측정값의 평균값을 사용하였다.

신경망 입력층의 입력 변수 값들에 대한 정규화를 위하여 본 연구에서는 다음의 식을 적용하였다. 그리고, 각 신경망에 적용한 입력 값의 범위는 표 1과 같다.

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

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

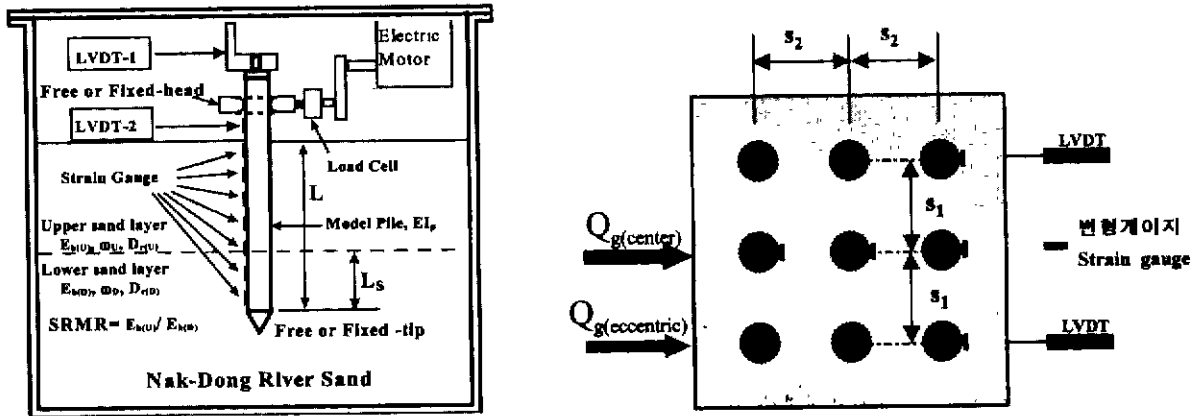


그림 5. (a) 단일말뚝의 모형실험 개요도
(b) 군말뚝의 모형실험 개요도

3.2 인공 신경망 학습결과 검증

신경망 학습시 입력되는 입력 패턴의 수는 모형실험결과들(김영수 등, 1998, 1999, 2000a; 김병탁, 2000b) 각각에서 수평하중 1, 2, 3, 4kg에 해당하는 전체 데이터 중에서 25%, 50%, 75%의 3가지 종류로 임의 선택하여 학습을 하였다. 이는 신경망의 학습 반복회수(epoch)가 입력 패턴의 수와 관련하여 결정되기 때문에 이에 대한 검토를 위하여 달리 학습을 수행하였다.

신경망의 학습은 최대 휨모멘트와 수평변위에 대한 학습으로 나누어서 수행하였으며, 각 학습에 필요한 학습률(η)은 0.1, 0.3, 0.5, 0.7, 0.9의 5가지로 달리하며 학습에 필요한 학습 반복회수를 검토하였다. 그리고, 50% 학습에 대한 시스템 오차를 각 학습률에 따라 분석한 결과는 그림 6과 같다. 학습시의 모멘텀(β)은 일반적으로 국내외에서 인공 신경망을 적용할 경우 0.9 를 사용하고 있으며 본 연




그림 6. 학습률에 따른 시스템 오차의 수렴성

구에서도 이를 이용하였다.

또한 초기상태에서 연결강도와 바이어스를 모두 같은 값으로 설정하면 학습이 불가능해지는 균형문제(symmetry problem)가 발생하는데 이러한 균형문제를 해결하기 위하여, 본 연구에서는 초기의 연결 강도와 바이어스는 -1.0 ~ 1.0 사이의 난수를 발생시켜 초기화하였다.

은닉층의 수는 2개이며 각 은닉층의 뉴런 수는 각각 30 개인 신경망 구조에서 각 학습 패턴 수에 대한 실험결과와 학습결과와의 상관계수는 0.932 이상으로 상당히 높은 일치성을 보였다. 그리고, 동일한 학습률에서 학습 패턴 수가 증가할수록 시스템 오차(E_p)에 수렴하는 학습 반복회수가 크게 증가하고 있으며, 동일한 학습 패턴 수에서의 학습률에 따른 학습 반복회수의 변화는 규칙성을 찾아볼 수 없었다. 그러나, 동일한 시스템 오차와 학습 패턴 수에서 학습 반복회수가 가장 적은 학습률은 $I_{12}H_{30-30}O_1$ 과 $I_{17}H_{30-30}O_1$ 에 무관하게 0.9로 나타났다(그림 6 참조).

동일한 은닉층의 뉴런 수(H_{30-30})에 대한 고찰 결과, 학습률 0.9의 경우에서 시스템 오차의 노이즈와 학습 반복회수가 가장 적게 발생하여 이를 이용한 은닉층의 뉴런 수에 따른 학습 반복회수의 변화를 수평변위와 최대 휨모멘트에 대하여 고찰한 결과는 표 2와 3과 같다. 은닉층의 뉴런 수는 은닉층 H_1 과 H_2 에 대하여 각각 10, 20, 30, 40으로 4가지 경우에 대하여 학습 반복회수를 결정하였다. 이때의 학습 패턴 수는 전체 데이터의 75%로서 최대 휨모멘트를 학습하는 경우 333개 그리고 수평변위를 학습하는 경우 450개를 사용하였다. 그리고, 학습 종료시점의 시스템 오차는 0.1로 하였다.

일반적으로 은닉층 뉴런의 구조는 대칭적으로 구성되

표 2. 최대 휨모멘트 학습시 은닉층 뉴런 수에 따른 Epoch의 변화 ($E_p=0.1, \eta=0.9, \beta=0.9$)

Epoch		Number of H_1			
		10	20	30	40
Number of H_2	10	1,303	1,033	4,219	200,000 (0.659*)
	20	6,819	462	2,168	1,323
	30	1,834	15,986	355	4,095
	40	509	52,872	7,389	3,510

* Epoch=200,000 이내에서 0.1의 시스템 오차 범위 내에 수렴하지 않은 상태에서의 시스템 오차

표 4. 오류 역전파 신경망에 사용한 변수들의 요약

학습항목	학습 패턴 수	입력 뉴런 수	은닉층 뉴런 수		시스템 오차, E_p
			H_1	H_2	
최대 휨모멘트	111	12	30	30	0.0111
	222				0.0222
	333				0.0333
수평변위	150	17	30	30	0.0150
	300				0.0300
	450				0.0450

는 것이 바람직하나, 이들은 학습률과 모멘텀에 영향을 받음으로서 획일적이지 못하며 다양하게 구성된다. 본 연구에서의 학습률과 모멘텀에 적합한 은닉층 뉴런의 수는 최대 휨모멘트에 대한 학습에서는 H_{20-20} 과 H_{30-30} 의 구조가 적합하며, 수평변위에 대한 학습에서는 H_{20-10} , H_{30-10} , H_{30-30} , H_{40-40} 의 구조가 적합하게 나타났다.

표 3. 수평변위 학습시 은닉층 뉴런 수에 따른 Epoch의 변화 ($E_p=0.1, \eta=0.9, \beta=0.9$)


Epoch		Number of H_1			
		10	20	30	40
Number of H_2	10	16,334	1,406	1,230	5,510
	20	200,000 (0.679*)	3,172	69,116	200,000 (0.239*)
	30	200,000 (0.159*)	3,589	1,868	2,135
	40	200,000 (0.142*)	72,186	1,217	1,503

* Epoch=200,000 이내에서 0.1의 시스템 오차 범위 내에 수렴하지 않은 상태에서의 시스템 오차


따라서, 오류 역전파 알고리즘에 의한 최대 휨모멘트와 수평변위의 예측을 위한 신경망 학습에 사용한 각종 변수들을 요약하면 표 4와 같다.

표 4에서 학습종료 시점의 시스템 오차는 각 학습 패턴에서의 시스템 오차 0.0001에 학습 패턴 수만큼의 누적 값이다. 표 4에서 정리한 알고리즘의 변수들을 이용하여 최대 휨모멘트와 수평변위에 대한 학습을 수행하고 학습동안의 시스템 오차의 변화를 나타내면 그림 7과 같다. 그리고 각 학습이 이루어진 후 학습종료 시스템 오차에 수렴한 학습결과와 실험결과와의 상관계수는 0.98 이상으로 학습이 잘 이루어졌다.

그림 7에서 고찰한 바와 같이, 최대 휨모멘트의 학습동안에는 최급하강법의 일반화된 델타규칙과 같이 시스템 오차가 급격히 감소하여 완만하게 학습종료 시스템 오차




(a) 수평변위 학습

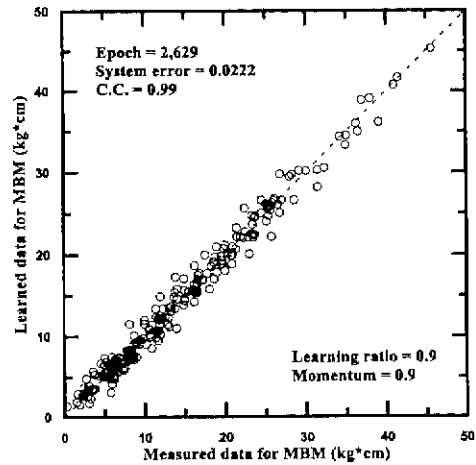


(b) 최대 휨모멘트 학습

그림 7. 학습동안의 학습패턴에 따른 시스템오차의 변화

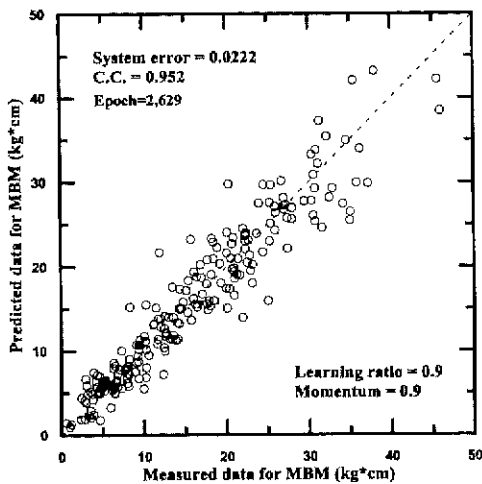


(a) 수평변위 학습 (300 patterns)

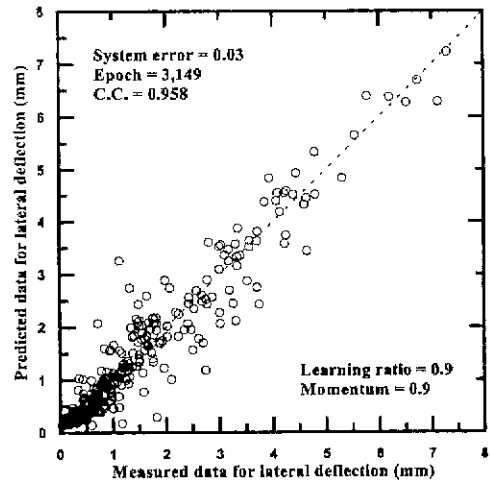


(b) 최대 휨모멘트 학습 (222 patterns)

그림 8. 신경망 학습 후 실험결과와 학습결과의 비교



(a) 최대 휨모멘트 (222 patterns)



(b) 수평변위 (300 patterns)

그림 9. 학습한 신경망에 의한 예측결과와 모형실험결과의 비교

에 수렴하고 있다. 그러나, 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 군말뚝의 모든 실험변수들을 적용하여 상호 조합하는 과정이 상당히 복잡하게 이루어지기 때문으로 사료된다. 최대 휨모멘트와 수평변위의 예측을 위한 신경망 학습 후의 실험결과와 학습결과의 비교를 전체 데이터의 50%를 학습한 경우에 대하여 나타내면 그림 8과 같다. 그림에서와 같이, 역전파 알고리즘에 의한 학습의 정도는 높음을 알 수 있으며, 학습에 필요한 시간은 최대 휨모멘트의 경우 10 ~ 30분 정도

그리고 수평변위의 경우 30 ~ 60분 정도였다. Off-line 학습인 역전파 학습 알고리즘에서 학습에 소요되는 시간은 상당히 길어지나, 학습 후 구성된 신경망내의 연결강도와 바이어스에 의하여 새로운 입력 패턴의 결과를 예측하는데 소요되는 시간은 수 초에 불과하다.

3.3 수평거동 예측

오류 역전파 알고리즘은 학습을 위하여 주어진 학습 패턴 수모두에 대한 정보를 종합적으로 저장하고 모든 학습 패턴에 적합한 목표값을 출력하기 위하여 신경망내의 연결강도와 바이어스를 재조정하게 된다. 일반화된 델타규칙을 이용한 학습을 통하여 조정된 연결강도와 바이어스를 새로운 입력 패턴들에 적용하여 신경망에 의한 수평거

동 예측을 수행하였다.

신경망에 의한 예측은 최대 휨모멘트와 수평변위의 경우 각각에서 학습에 입력한 각 패턴들을 제외한 나머지에 대하여 수행하였다. 신경망에 의한 수평거동 예측결과와 모형실험결과들을 전체 데이터의 50%를 학습한 경우에 대하여 비교하면 그림 9와 같다.

신경망에 의한 최대 휨모멘트와 수평변위의 예측정도는 신경망 학습에 입력한 패턴 수에 따라 변화하였으며, 학습 패턴 수가 클수록 예측정도는 크게 나타났다. 즉, 신경망에 의한 예측결과와 실험결과 상관계수가 최대 휨모멘트의 예측에서는 0.93 ~ 0.98의 범위로 그리고 수평변위의 예측에서는 0.89 ~ 0.96의 범위로 나타나 신경망에 의한 수평거동의 예측결과는 모형실험결과와 아주 높은 일치성을 보여주고 있다.

최대 휨모멘트 예측에서 111개의 학습패턴인 경우와 수평변위의 150개의 학습패턴인 경우의 예측결과는 비교적 많은 학습 패턴 수에 비하여 상대적으로 다른 학습 패턴 수에 의한 예측결과보다 낮은 상관계수가 얻어졌다. 이는 본 연구에서 사용한 신경망이 총 뉴런 수가 73개와 78개이고 총 연결강도의 수가 1290개와 1440개로서 복잡한 구조로 이루어져 있어 200개 이하의 학습 패턴 수에 의한 수평거동 예측은 상대적으로 만족스럽지 못한 결과를 보여주는 것으로 사료된다.

이와 같이, 오류 역전파 알고리즘에 의한 말뚝의 수평거동 중에서 최대 휨모멘트와 수평변위의 예측은 신경망의 예측결과와 실험결과 상관계수가 0.89 이상으로 나타나 정확한 예측이 이루어지는 것을 보여주고 있다. 그리고 본 연구에서 상관계수 0.95 이상의 매우 정확한 예측을 위해서는 200개 이상의 학습 패턴 수에 의한 신경망의 학습을 수행할 필요성이 있었다. 따라서, 신경망에 의한 예측을 위하여는 매우 다양한 조건에 대한 많은 현장실험결과들을 바탕으로 체계적인 데이터베이스 구축이 이루어진다면 신뢰성과 경제성을 갖춘 예측결과가 얻어질 수 있을 것으로 사료된다.

4. 결론

단일 및 군말뚝의 수평거동 예측에 인공신경망을 적용한 결과는 다음과 같다.

(1) 인공신경망의 하나인 오류 역전파 알고리즘을 이용하여 말뚝의 수평거동을 예측할 수 있는 해석 프로그램

을 개발하였다. 실험결과를 이용하여 신경망을 학습하였으며, 신경망의 학습속도 측면에서 검토한 결과는 총 뉴런의 수가 30개인 17-30-30-1와 12-30-30-1의 신경망 구조가 적합한 것으로 나타났다. 그리고, 신경망의 학습률은 0.9가 가장 적합한 것으로 나타났다.

(2) 말뚝의 수평거동에 영향을 미치는 지반조건, 말뚝조건, 하중조건, 말뚝시공방법, 군말뚝 배열방식, 말뚝 수, 지반 함수비 그리고 말뚝 경계조건을 고려하여 신경망을 학습한 결과, 최대 휨모멘트와 수평변위에 대한 학습결과는 실험결과와 상관계수 0.976 이상으로 얻어져 매우 정확한 학습이 이루어졌다.

(3) 신경망에 의한 최대 휨모멘트와 수평변위의 예측결과는 실험결과와 상관계수가 0.89 이상으로 나타나 정확한 예측이 가능하였다. 그리고, 본 연구결과 상관계수 0.95 이상의 매우 정확한 예측을 위하여는 200개 이상의 학습패턴 수로 신경망을 학습할 필요가 있었다.

현장에 대한 신경망의 적용을 위하여 매우 다양한 조건에 대한 많은 현장실험결과들을 바탕으로 체계적인 데이터베이스 구축이 이루어진다면 신뢰성과 경제성을 갖춘 말뚝의 수평거동 예측결과가 얻어질 수 있을 것으로 사료되며, 현장말뚝에 대한 연구와 EBPNN의 단점을 보완할 수 있는 알고리즘의 연구개발이 요구된다.

참 고 문 헌

1. 김대수 (1998), "신경망 이론과 응용 (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. 이인모, 이정학 (1994), "인공 신경망 이론을 이용한 말뚝의 극한지력 해석 (I)-이론", 한국지반공학회지, 제10권, 제4호, pp.17-27
8. Kiefa, M.A.A. (1996), "General regression neural networks for driven piles in cohesionless soils". ASCE, Vol.124, No.12, pp.1177-1185.
9. 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.

(접수일자 2000. 7. 20)