

# 인공 신경망 이론을 이용한 말뚝의 극한지지력 해석(Ⅰ)－이론

Analysis of Ultimate Bearing Capacity of Piles Using Artificial  
Neural Networks Theory (I)－Theory

이정학<sup>\*1</sup>

Lee, Jeong - Hark

이인모<sup>\*2</sup>

Lee, In - Mo

## Abstract

It is well known that human brain has the advantage of handling disperse and parallel distributed data efficiently. On the basis of this fact, artificial neural networks theory was developed and has been applied to various fields of science successfully. In this study, error back propagation algorithm which is one of the teaching technique of artificial neural networks is applied to predict ultimate bearing capacity of pile foundations.

For the verification of applicability of this system, a total of 28 data of model pile test results are used. The 9, 14 and 21 test data respectively out of the total 28 data are used for training the networks, and the others are used for the comparison between the predicted and the measured. The results show that the developed system can provide a good matching with model pile test results by training with data more than 14. These limited results show the possibility of utilizing the neural networks for pile capacity prediction problems.

## 요지

인간의 두뇌는 분산 병렬 처리에 효과적이라는 사실에 근거하여 인공 신경망이론이 개발되었으며, 과학의 여러 분야에서 성공적으로 적용되어지고 있다. 본 연구에서는 인공 신경망 이론의 학습방법 중 하나인 오차 역전파 학습 알고리즘을 모형 말뚝의 극한지지력 예측에 적용하여, 이 이론이 말뚝의 극한지지력의 합리적인 산정방법으로 적용될 수 있는지의 가능성을 검토하였다.

이러한 시스템의 타당성 검토를 위하여 총 28개의 모형 말뚝재하시험 결과를 이용하였으며, 그 중에서 9, 14, 21개의 자료를 네트워크 학습에 이용하여 나머지 자료의 예측 가능 정도를 분

\*1. 정회원, 고려대학교 대학원 토목환경공학과 박사과정

\*2. 정회원, 고려대학교 공과대학 토목환경공학과 부교수

석하여 보았다. 개발된 시스템은 14개 이상의 학습자료에 대하여 모형 말뚝재하시험의 결과와 잘 맞는 것으로 나타났다. 이와같은 결과들을 종합하여 보건데 신경망 이론이 말뚝의 극한지지력 예측 문제에 적용될 수 있는 가능성을 보여 주었다.

---

---

## 1. 서 론

말뚝 기초는 구조물의 하중을 지지층까지 전달하여 주는 기초형식의 하나로 공사부지 확보가 점점 어려워짐에 따라 지반조건이 열악한 지역에서의 구조물의 기초로 요즈음 많이 사용되어지고 있다.

이러한 말뚝의 극한지지력 산정 방법은 많은 학자들에 의하여 발표되어 왔으나 어느 것도 신뢰성 있는 방법으로 받아들여지지 못하고 있는 실정이다. 또한 말뚝의 하중 지지 mechanism을 선단지지력과 주면마찰력의 합으로 가정하여 해석한 정역학적 공식이나 말뚝 항타시 얻을 수 있는 간단한 측정으로부터 지지력을 구하는 동역학적 공식등은 모두 지반조건, 말뚝의 제원 등 극한지지력에 영향을 미칠 수 있는 여러 인자들과 지지력과의 상관관계를 모델링한 것으로 지반이 가지고 있는 여러 가지 불확실성 등을 고려할 때, 이러한 상관관계를 모든 경우에 적용하는 데 문제가 있을 수 있다 하겠다. 극한지지력 산정 시의 이러한 문제점들로 인하여 현재까지 가장 신뢰성 있는 방법으로 제시되는 것은 말뚝재하시험 뿐이라 하여도 과장되지 않은 말일 것이다.

이에 본 연구에서는 기존에 발표된 말뚝재하시험의 결과들로 부터 요즈음 전기나 전자분야에서 많이 활용되고 있는 인공 신경망(*artificial neural networks*)이론을 적용한 극한지지력 산정 방법에 대한 연구의 일환으로 오차역전파(error back propagation : EBP) 알고리즘을 이용한 극한지지력 해석 방법에 대하여 연구를 수행하였으며, 이 방법의 타당성 검토를 위하여 모형 말뚝재하시험에 적용하여 검증하도록 하였다.

## 2. 인공 신경망(*artificial neural networks*) 이론

최근 인간의 뇌가 대량의 복잡한 정보를 효율적으로 병렬처리 할 수 있을 뿐만 아니라 학습능력이 있다는 사실에 근거하여 문제 해결에 필요한 규칙의 개발이 필요 없는 새로운 계산방법으로 인공 신경망이 제안되었으며 여러 분야에서 성공적으로 응용되고 있다. 지금까지 알려진 바로는 인간의 두뇌는  $10^{10} \sim 10^{11}$ 개의 뉴런(neuron)으로 구성되어 있으며, 그림 1에 이러한 뉴런의 구조를 나타내었다. 그림 1에서 보듯이 하나의 뉴런은 세포체(cell body)와 축색돌기(axon), 수상돌기(dendrite)로 구성되어 있다. 축색돌기는 다른 뉴런으로 정보를 전달하는 역할을 하며, 수상돌기는 다른 뉴런으로 부터 정보를 받아 이를 세포체에 전달하는 역할을 한다. 또한 각 뉴런들은 시냅스(synapse) 연결을 통하여 정보를 교환한다.

이러한 뉴런의 구조로 부터 많은 수의 인공뉴런으로 구성된 인공 신경망은 그림 2와 같이 한쪽 방향만의 신호 채널을 통하여 서로 연결된 처리기(processing element, PE)들이 병렬, 분산, 정보처리를 할 수 있도록 모델링한 것이다.

그림 2에서 보듯이 인공 신경망은 정보가 들어오는 입력층(input layer), 입력이 들어가는 뉴런에 미치는 영향의 크기를 조절해 주는 가중치(weight)와 이를 입력과 가중치로 들어온 정보를 결합하여 주는 결합 함수(combining function), 이 결합 함수로부터 나온 결과를 변환하여, 출력값을 결정하게 되는 전이함수(transfer function) 등으로 구성되어 있다. 이 전이함수는 다음 그림 3에 수록한 것과 같이 계단 함수, 임계논리 함수, 시그모이드 함수 등

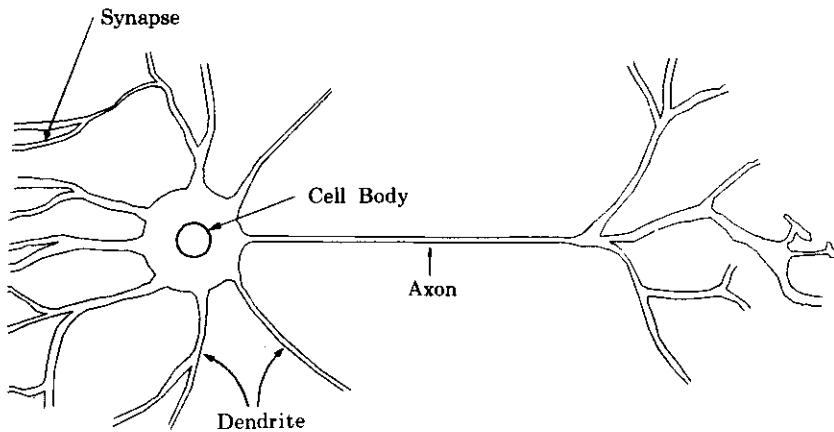


그림 1. 뉴런의 구조

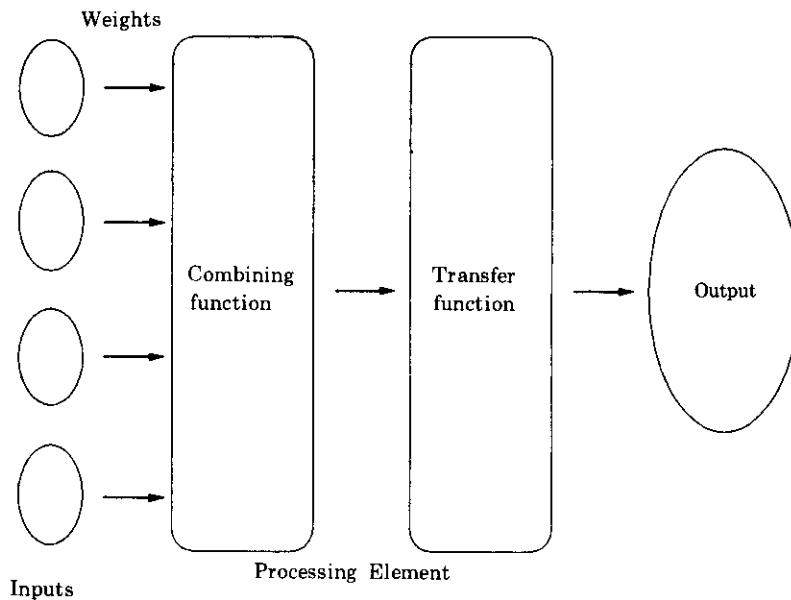


그림 2. 인공 신경망의 모델

3종류의 비선형 함수를 많이 사용하고 있다.

이러한 인공 신경망은 학습과정(learning phase)과 회상과정(recall phase)의 두가지 상태로 작동한다. 학습과정은 상호 연관된 입력과 출력 형태를 인공 신경망이 인식하도록 뉴런 사이의 연결강도를 조정하므로써 정보를 기억시키는 과정을 말하며, 회상과정은 학습과정이 끝난 상태에서 주어진 입력에 대해 계산된

값을 출력시키는 과정이다. 인공 신경망의 학습은 모든 뉴런 각각에 대해 연결된 뉴런의 상태값과 연결선의 연결도로 부터 자신에게 전달되는 자극의 합을 구한 다음 자신의 상태값을 계산함으로써 학습과정을 실시하고 회상과정에서는 단 한번의 계산으로 출력 뉴런의 값이 결정된다.

이와같이 인공 신경망은 임의의 입력 N차원

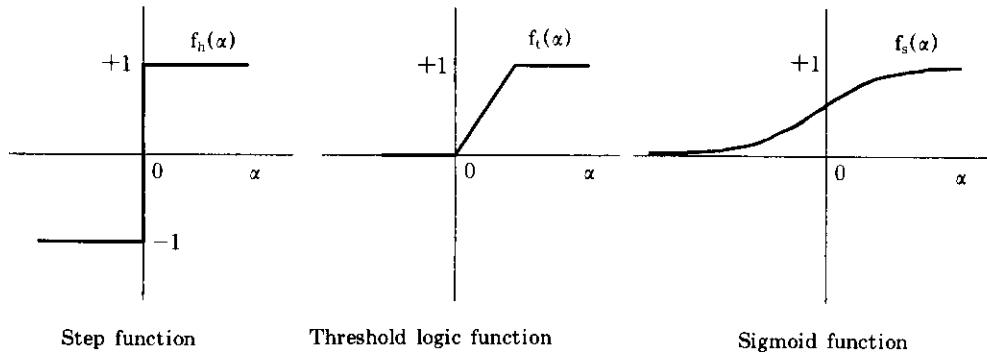


그림 3. 전이함수의 종류

공간을 출력 M차원 공간으로 mapping하는 것으로 생각할 수 있으며, 입력 및 출력 공간과 mapping 특성에 따라 연상기억, 변환, 분류, 인식, 최적화등의 기능을 수행할 수 있다. 이러한 mapping은 어떻게 뉴런들 사이의 연결강도를 조정할 것인가를 결정하는 학습규칙(learning rule)에 따라 결정된다. 학습규칙은 주어진 입력에 대하여 원하는 출력을 주입시키는 지도 학습(supervised learning)과 원하는 출력 없이 학습을 실시하는 자율학습(unsupervised learning)으로 분류될 수 있다.<sup>4)</sup>

## 2.1 다층 퍼셉트론(multi-layer perceptron)

최초의 신경망 모델은 1957년에 Rosenblatt이 발표한 퍼셉트론(perceptron)이랄 수 있으며, 여러 학자들에게 많은 관심을 집중시켰으나 이 모델이 XOR 함수와 같이 단순한 비선형 분리 문제도 풀 수 없는 것으로 밝혀진 후 약 20년간 학자들의 관심에서 멀어지게 되었다. 그 후 1970년대 말과 1980년대 초반에 들어 일련의 학자들에 의해 이러한 문제의 해결을 위하여 퍼셉트론에 은닉층(중간층)을 쓰는 그

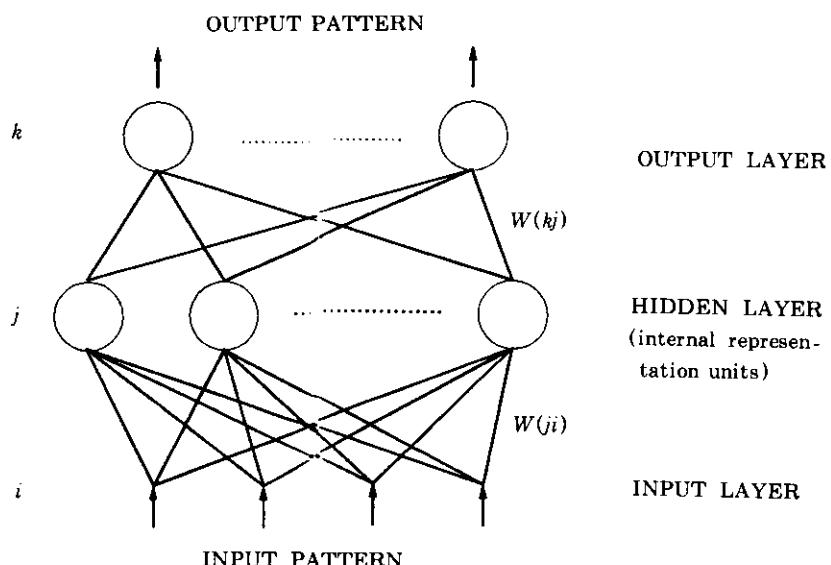


그림 4. 하나의 은닉층을 갖는 다층 퍼셉트론

그림 4와 같은 다층 퍼셉트론 모델이 개발되었다.

그림 4에서와 같이 입력층과 출력층 사이에 은닉층이 존재한다면, 원래의 입력층은 확대되어지며, 은닉층에서 입력패턴의 재코드화가 이루어져 입력으로부터 요구되어지는 출력의 대응을 드롭게 된다. 즉 입력층으로부터 더 많은 처리기(processing element)를 갖는 은닉층으로의 적절한 연결이 있으면 항상 이 은닉층을 통해 입력에서 출력으로의 어떤 대응을 수행하는 표현(representation)을 찾을 수 있게 되는 것이다.<sup>6)</sup>

이러한 다층 퍼셉트론의 학습은 지도학습의 하나인 오차역전파(error back propagation; EBP) 알고리즘에 의해 수행되어지는데, 이 알고리즘은 신경망에서 구해진 실제 출력값(actual output)과 구하고자 하는 목표 출력값(desired output)간의 오차에 대한 평균제곱의 총합을 최소로 하도록 연결강도를 조정하는 델타규칙(delta rule)에 따른 것이다.<sup>4, 7)</sup>

## 2.2 오차역전파(error back propagation) 학습 알고리즘

EBP 알고리즘의 델타규칙의 적용을 위해서는 연결강도공간(weight space)에서 오차를 점진적으로 탐색해 나가는 점진적 기울기 감소(gradient descending search) 방법을 사용한다. 즉 델타규칙에 의해 연결강도의 변화는 연결강도 공간상에 주어지는 오차의 제곱의 높이로 하는 곡면에 대하여 기울기가 감소하게 되며, 이 오차의 제곱이 가장 많이 감소하는 방향으로 변화하게 되는 것이다. 이는 전향적(forward) 방향(입력층에서 출력층)으로 진행하여 주어진 입력 데이터에 대한 실제 출력값을 계산하고, 이에 대응하는 목표 출력값과의 오차를 하위층에 후향적(backward)으로 전달하면서 일률적으로 연결강도를 조정해 나가는 과정을 반복적으로 적용함으로서 신경망 전체를 학습시키는 알고리즘이다.<sup>5)</sup>

그림 4에서 주어진 바와 같이 신경망의 맨

아래층을 입력층, 맨 위층을 출력층 그리고 중간에 있는 층을 은닉층이라 하고 각 층들은 PE들로 구성되어 있다고 할 때, 입력층의 한 PE는 입력벡터의 각 원소와 대응하고 출력층으로부터의 출력값은 판별함수(discreminant function)의 출력과 같다. 즉, EBP 알고리즘에서의 각 PE는 자신의 바로 위층의 모든 PE와 연결되어 있고, 각 연결은 그것과 관계된 무한의 양 또는 음의 연결강도를 갖고 있으므로 신경망의 출력값은 입력과 연결강도의 함수라 할 수 있다.<sup>5)</sup> PE  $j$ 층의 출력은 그 PE로 들어오는 총 입력값에 대한 활성함수 값이 되며, 다음 식(1)과 같다.

$$o_j = f(\text{net}_j + \theta_j) \quad (1)$$

$o_j$  : PE  $j$ 층의 출력값

$f$  : 활성함수

$\theta_j$  : PE의 고유 바이어스(bias) 값

여기에서 PE에 들어오는 입력값  $\text{net}_i$ 는 그 이전층의 모든 PE들의 가중합으로 다음 식(2)와 같다.

$$\text{net}_i = \sum_j w_{ji} o_j \quad (2)$$

$w_{ji}$  : 하위 PE  $i$ 에서 바로 위층 PE  $j$ 로의 연결강도

$o_j$  : PE  $j$ 의 출력값

각 PE에서 사용하는 활성함수  $f$ 는 비선형적이고 미분 가능한 시그모이드 함수를 사용하면 식(1)은 다음 식(3)과 같이 나타낼 수 있으며, 시그모이드 함수는 그림 5와 같은 형태를 갖는다.

$$\begin{aligned} o_j &= f(\text{net}_j + \theta_j) \\ &= \frac{1}{(1 + e^{-(\text{net}_j + \theta_j)})} \end{aligned} \quad (3)$$

이와같이 각 층의 PE에 대하여 전향적(forward) 방향으로 계산된 값들과 원하는 출력값

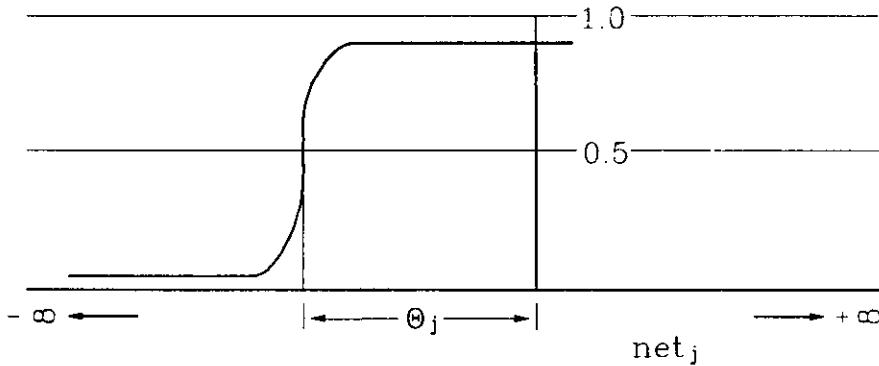


그림 5. 바이어스 항을 갖는 sigmoid 활성함수

과의 차이를 줄이는 방향으로 상위층에서 하위 층으로 연결강도를 조정해 나가는 계산을 수행 한다. 이때 각 입력 패턴에 대한 오차 자승 (square of error)  $E_p$ 는 다음과 같이 나타내어 진다.

$$E_p = \frac{1}{2} \sum_k (t_{pk} - o_{pk})^2 \quad (4)$$

$t_{pk}$  : 입력 패턴  $p$ 에 대한 출력층에서의 원 하는 출력값

$o_{pk}$  : 입력 패턴  $p$ 에 출력층에서의 실제 출력값

연결강도의 변화량을  $\Delta\omega_{kj}$ 라고 하면, 연결강도의 변화는 다음 식(5)와 같이 연결강도에 대한 오차의 변화율에 비례하는 증가 변위를 취함으로 얻을 수 있다.

$$\Delta\omega_{kj} \propto -\frac{\partial E}{\partial \omega_{kj}} \quad (5)$$

식(5)를 사용하여 연결강도를 조정하는 방법은 출력층에 직접 영향을 미치는 경우와 미치지 않는 경우에 대하여 각각 다음과 같이 구한다.

### 2.2.1 출력층에 직접 영향을 미치는 경우의 연결강도 조정

앞의 식(5)와 지수(index)  $k$ 가 출력층을 나타내며,  $j$ 는 은닉층을 나타낸다면, 식(5)의 우변 항은 chain rule을 이용하여 다음과 같이 나타낼 수 있다.

$$-\frac{\partial E}{\partial \omega_{kj}} = -\frac{\partial E}{\partial \text{net}_k} \frac{\partial \text{net}_k}{\partial \omega_{kj}} \quad (6)$$

여기에서,  $-\partial E / \partial \text{net}_k$ 를 error signal  $\delta_k$ 로 정의하면 식(6)의 우변 항들은 각각 다음 식(7)과 식(8)로 나타내어진다.

$$\begin{aligned} \delta_k &= -\frac{\partial E}{\partial \text{net}_k} = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial \text{net}_k} \\ &= -\frac{\partial}{\partial o_k} \left[ \frac{1}{2} \sum_k (t_k - o_k)^2 \right] \frac{\partial o_k}{\partial \text{net}_k} \\ &= (t_k - o_k) \frac{\partial o_k}{\partial \text{net}_k} \\ &= (t_k - o_k) f'(net_k) \end{aligned} \quad (7)$$

$$\frac{\partial \text{net}_k}{\partial \omega_{kj}} = \frac{\partial}{\partial \omega_{kj}} (\sum_i \omega_{kj} o_i) = o_j \quad (8)$$

이들 식(6), (7), (8)로 부터 연결강도의 변화량  $\Delta\omega_{kj}$ 는 다음과 같이 나타낼 수 있다.

$$\begin{aligned}\Delta\omega_{kj} &= \eta\delta_k o_j \\ &= \eta \cdot (t_k - o_k) \cdot f'(net_k) \cdot o_j\end{aligned}\quad (9)$$

$\eta$  : 학습률(learning rate, gain term)

### 2.2.2 출력층에 직접 영향을 미치지 않는 경우의 연결강도 조정

$j$ 는 은닉층의 지수,  $i$ 는 하위 은닉층 또는 입력층의 지수라 하면, 식(6)은 다음과 같이 표현된다.

$$-\frac{\partial E}{\partial \omega_{ji}} = -\frac{\partial E}{\partial net_i} \frac{\partial net_i}{\partial \omega_{ji}} \quad (10)$$

여기에서,  $-\partial E / \partial net_i$ 를 error signal  $\delta_i$ 로 정의하면 식(10)의 우변 항들은 각각 다음 식(11)과 식(12)로 나타내어진다.

$$\begin{aligned}\delta_i &= -\frac{\partial E}{\partial net_i} = -\frac{\partial E}{\partial o_i} \frac{\partial o_i}{\partial net_i} \\ &= -\frac{\partial E}{\partial o_i} f'(net_i)\end{aligned}\quad (11)$$

$$\frac{\partial net_i}{\partial \omega_{ji}} = \frac{\partial}{\partial \omega_{ji}} (\sum_k \omega_{kj} o_k) = o_j \quad (12)$$

식(11)에서 오차  $E$ 는 식(7)에서 나타낸 바와 같이  $E = 1/2 \sum (t_k - o_k)^2$ 로 주어져  $-\partial E / \partial o_i$ 를 쉽게 구할 수 있으므로 다음과 같이 나타낸다.

$$\begin{aligned}-\frac{\partial E}{\partial o_i} &= -\sum_k \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial o_i} \\ &= -\sum_k \frac{\partial E}{\partial net_k} \frac{\partial (\sum_l \omega_{lk} o_l)}{\partial o_i} \\ &= -\sum_k \frac{\partial E}{\partial net_k} \cdot \omega_{ki} \\ &= \sum_k \delta_k \omega_{ki}\end{aligned}\quad (13)$$

식(13)으로부터 식(11)은 다음과 같이 나타낼 수 있다.

$$\delta_i = \sum_k \delta_k \omega_{ki} \cdot f'(net_i) \quad (14)$$

이 식들로 부터 연결강도의 변화량  $\Delta\omega_{ji}$ 는 다음과 같이 나타낼 수 있다.

$$\begin{aligned}\Delta\omega_{ji} &= \eta\delta_j o_i \\ &= \eta \cdot [f'(net_i) \sum_k \delta_k \omega_{ki}] \cdot o_i\end{aligned}\quad (15)$$

$\eta$  : 학습률(learning rate, gain term)

이와 같이 식(9)와 식(15)를 이용하여 반복 수행을 함으로서 연결강도를 다음 식(16)과 같이 조정한다.

$$\omega_{ji}(t+1) = \omega_{ji}(t) + \Delta\omega_{ji}(t+1) \quad (16)$$

$t$  : 반복회수(iteration number)

또한 연결강도 공간에서 현재의 탐색방향에 대한 이전 연결강도 변화값의 변화율로서 모멘텀 항(momentum term)  $\alpha$ 를 도입하는 데 이는 네트워크 전체의 안정을 유지하게 하는 역할을 하며, 연결강도의 변화량을 다음과 같이 나타낼 수 있다.

$$\Delta\omega_{ji}(t+1) = \eta\delta_j o_i + \alpha\Delta\omega_{ji}(t) \quad (17)$$

이상에서 살펴본 EBP 알고리즘은 몇 가지 단점을 가지고 있는데, 첫번째 문제점으로는 학습이 전역적 최소치(global minimum)가 아닌 국부 최소치(local minimum)에 빠질 가능성이 있다는 점이다. 즉 오차함수는 연결강도가 만든 다차원 공간상에서 매우 복잡한 형태를 갖게 되며, 경우에 따라 오차가 0이 되는 한 개의 골짜기 이외에 그림 6.에 보인바와 같이 몇개의 골짜기가 있을 가능성이 있다. 또한 기울기 감소 방법은 반드시 가장 낮은 골짜기를 목표로 하는 것이 아니라 지금 있는 점에서 보아 가장 급경사면을 따라 내려가는 것으로 오차가 0이 아닌 지역최소점에 머무를 가능성 이 높다.<sup>4)</sup>

두번째 문제점은 EBP 알고리즘이 포화 영

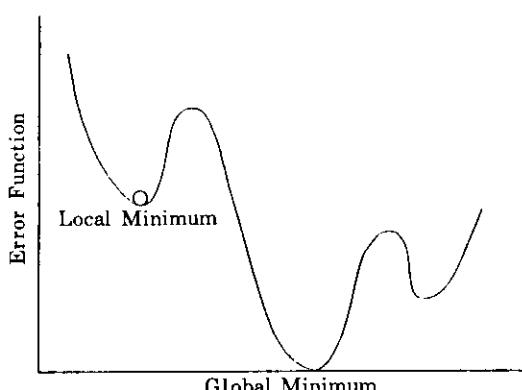


그림 6. 연결강도와 오차함수

역에서는 잘 동작되지 않는다는 점이다. 즉 뉴런의 포화 영역에서는 식(7)과 식(14)에서의  $f'$ 이 0이 되므로 연결강도는 변화하지 않는다. 이러한 상황에서 네트워크 환경이 변화한다면 네트워크는 이전의 것과는 다른 출력을 요청받게 되나  $f'$ 이 거의 0이므로 연결강도는 거의 변할 수 없는 것이다. 이밖에 EBP 학습 알고리즘의 문제점들에는 다음과 같은 것등이 있다.

- ① 학습이 완료되기까지 많은 회수의 반복학습이 필요하다.
- ② 응용분야에 따라 학습파라미터의 조절이 필요하다.
- ③ 추가 학습시 전체적인 재학습이 필요하다.
- ④ 학습의 완료시점을 예측할 수 없다.

이러한 단점을 보완하기 위하여 입력자료의 학습시 자료 전체에 대하여 일괄 수정을 하며, 은닉층의 PE 개수를 증가시키거나, 학습률을 작게하며, 연결강도의 초기치를 여러가지로 랜덤(random)하게 주어 학습회수를 늘리는 등의 방법을 사용한다.<sup>5, 6)</sup>

### 3. 예제해석 및 결과

본 연구에서 개발된 신경망 모델은 입력층, 2개의 은닉층과 출력층을 갖는 4개의 층으로

이루어져 있으며, 각 층의 PE의 개수는 자유롭게 결정할 수 있도록 하였다. 또한 입력 자료의 적절한 학습효과를 결정할 수 있도록 각 층의 학습률  $\eta$ 와 모멘텀 항  $\alpha$ 를 입력할 수 있도록 모델링 하였다.

개발된 신경망 모델의 타당성 확인을 위하여 대표적인 비선형 함수인 sine 함수에 대하여 학습을 시켜 본 결과 그림 7.에서 보는 바와 같이 20000번 이상의 반복계산 후에는 잘 일치하는 경향을 보임을 알 수 있었다.

말뚝의 극한 지지력 예측을 위한 개발된 신경망 모델에 대하여 다음과 같은 모형 말뚝재하시험 결과를 이용하여 예제해석을 실시하였다.

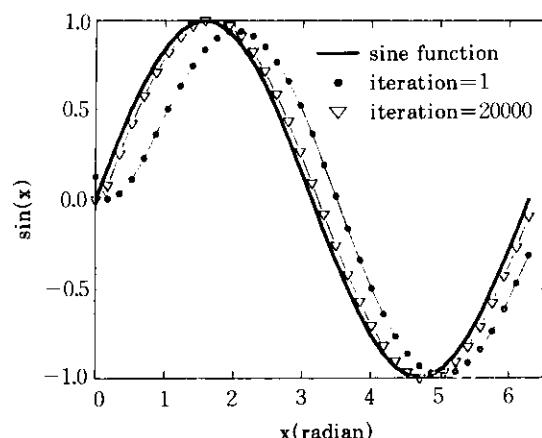


그림 7. sine 함수의 mapping

### 3.1 모형 말뚝재하시험

말뚝의 극한지지력 예측을 위한 EBP 알고리즘의 적용성을 검토하기 위하여 모형 말뚝재하시험 결과를 이용하였다. 이 시험에 사용된 말뚝은 외경 4cm, 길이 50cm, 말뚝의 선단부는 60° 각도를 갖는 폐단 강관 말뚝으로 4.3kg의 추를 말뚝 두부에서 30cm 높이에서 낙하시켜 모형 지반에 관입 시켰다. 또한 실제 지반조건을 재현하기 위하여 연직방향 압력과 측압을 달리할 수 있는 calibration chamber에 모래를 일정 높이에서 낙하시켜 상대밀도 90% 이상의

균질한 지반을 형성한 후 24시간 이상 가압함으로서 모형지반을 제작하였으며, 이에 대한 상세한 사항은 이<sup>1, 2, 3)</sup>등이 발표한 참고문헌에 수록되어 있다.

이러한 모래지반에 말뚝 두부를 항타함으로서 말뚝을 관입 시켜, 말뚝의 근입깊이, 지반에 가한 압력, 말뚝의 항타회수에 따른 극한 지지

력을 산정한 바 다음 표 1과 같다. 표 1에서 보는 바와 같이 균질한 모래 지반에 항타된 말뚝의 경우 지지력에 영향을 미치는 인자인 calibration chamber의 압력(평균 주응력), 말뚝의 근입 깊이, 항타회수를 극한지지력 산정을 위한 학습자료로 하여 예제해석을 수행하였다.

표 1. 모형 말뚝재하시험 결과

자료 번호	근입 깊이 (cm)	chamber 압력(kg/cm <sup>2</sup> )		평균 주응력 (σ <sub>m</sub> )*	항타회수	극한지지력 (kg)
		연직방향(σ <sub>1</sub> )	측 방향(σ <sub>3</sub> )			
1	15	0.75	0.30	0.45	64	279
2	20	0.75	0.30	0.45	96	368
3	25	0.75	0.30	0.45	147	440
4	30	0.75	0.30	0.45	195	497
5	35	0.75	0.30	0.45	248	387
6	40	0.75	0.30	0.45	297	535
7	45	0.75	0.30	0.45	349	499
8	15	1.00	0.40	0.60	71	205
9	20	1.00	0.40	0.60	105	340
10	25	1.00	0.40	0.60	161	375
11	30	1.00	0.40	0.60	213	403
12	35	1.00	0.40	0.60	266	419
13	40	1.00	0.40	0.60	321	502
14	45	1.00	0.40	0.60	377	615
15	15	1.50	0.60	0.90	100	341
16	20	1.50	0.60	0.90	144	436
17	25	1.50	0.60	0.90	202	589
18	30	1.50	0.60	0.90	254	540
19	35	1.50	0.60	0.90	308	600
20	40	1.50	0.60	0.90	358	595
21	45	1.50	0.60	0.90	414	819
22	15	2.00	0.80	1.20	101	450
23	20	2.00	0.80	1.20	156	530
24	25	2.00	0.80	1.20	211	642
25	30	2.00	0.80	1.20	258	765
26	35	2.00	0.80	1.20	310	670
27	40	2.00	0.80	1.20	358	724
28	45	2.00	0.80	1.20	404	774

$$* \text{mean normal stress, } \sigma_m = \frac{(\sigma_1 + 2 \cdot \sigma_3)}{3}$$

### 3.2 예제해석 결과

주어진 입력자료들에 대한 EBP 학습 알고리즘의 적용을 위해서는 먼저 은닉층 PE의 수, 연결강도의 초기치, 학습률, 모멘텀 항등을 결정하여야 하며, 이를 중 학습률과 모멘텀 항은

대개의 경우 사용하는 적정치가 있으나, 그외의 것들은 시행착오적 방법으로 구하여야 한다. 본 예제해석에서 여러번의 반복을 통하여 구해진 위의 값들은 다음과 같다.

- 첫번째 은닉층 PE의 수 : 30개
- 두번째 은닉층 PE의 수 : 10개

· 연결강도의 초기치 : -1.0~1.0사이의 난수(random value)

· 학습률 : 0.2

· 모멘텀 항 : 0.9

이와같은 변수들을 사용하여 표 1.에서 구한 말뚝의 근입깊이, 평균 주응력, 항타회수의 3개를 입력층, 극한지지력을 출력층으로 하는 3-30-10-1의 신경회로망을 구성하였다.

이 신경망으로 부터 학습에 필요한 입력자료의 개수를 자료번호가 3의 배수인 경우(9개), 홀수인 경우(14개), 짝수인 경우(14개), 4의 배수를 뺀 나머지의 경우(21개)들에 대하여 예제 해석을 실시한 결과 신경망 시스템의 평균 오차는 그림 8과 같이 나타났다. 이 그림에서 보듯이 학습자료의 갯수가 증가함에 따라 학습시키는 데 필요로 하는 반복 계산이 기하 급수적으로 증가함을 알 수 있다.

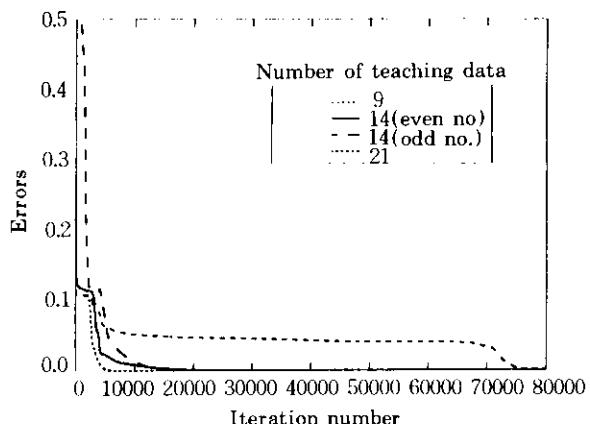


그림 8. 학습자료의 갯수에 따른 오차의 변화

이와같이 학습된 자료로부터 학습시키지 않은 자료의 극한지지력을 구하여 보면 각각 다음과 같이 그림 9~그림 12에 보인 바와 같다. 이 그림들에서 보듯이 학습자료가 14개 이상인 경우의 극한지지력 예측값들은 실측값과의 최대오차가 20%를 넘지않음을 알 수 있다. 또한 학습자료의 개수를 9개 이하로 줄여서 학습시킨 후의 지지력 예측결과는 그 오차의 범위가 넓게 분포함을 볼때, 적절한 결과를 얻기위해서는 많은 수의 학습자료를 필요로 함을 알 수 있다.

#### 4. 결론 및 향후의 연구과제

본 연구에서는 요즈음 인공지능의 한 분야로 많은 연구가 진행되고 있는 신경망 이론의 오차역전파(EBP) 학습 알고리즘을 적용한 말뚝 기초의 극한지지력을 예측 모델을 개발한 바 다음과 같은 결론을 얻을 수 있었다.

1) 신경망 이론의 큰 장점 중의 하나는 입력값과 원하는 출력값들 사이에 일정한 규

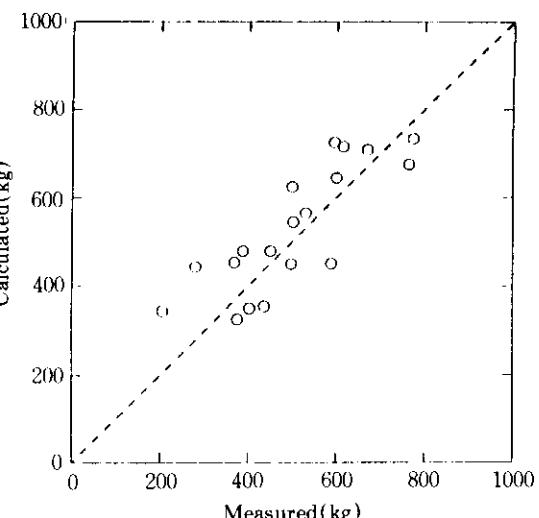


그림 9. 9개의 학습자료에 따른 극한지지력 예측

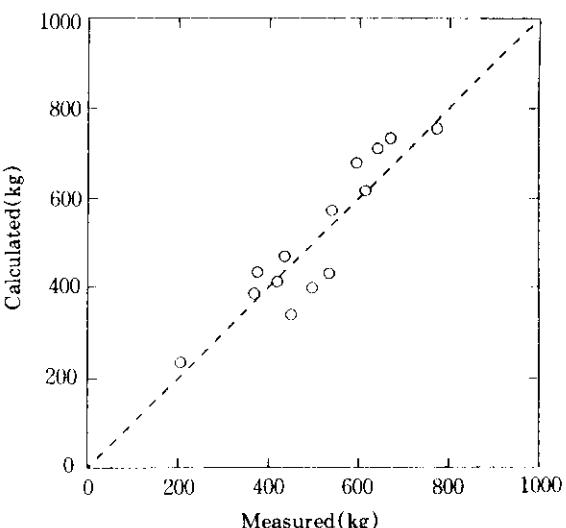


그림 10. 14개(홀수번호)의 학습자료에 따른 극한지지력 예측

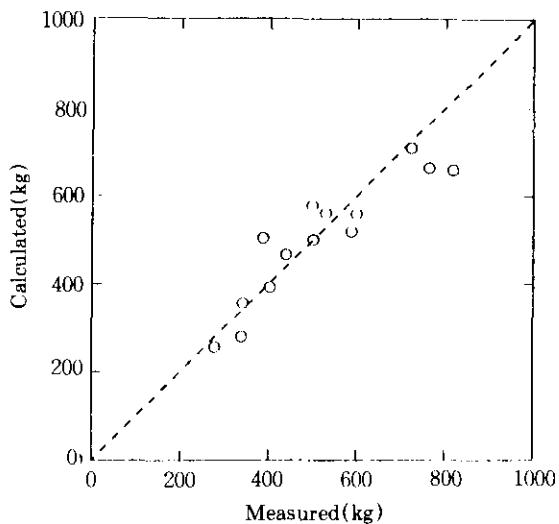


그림 11. 14개(짝수번호)의 학습자료에 따른 극한지지력 예측

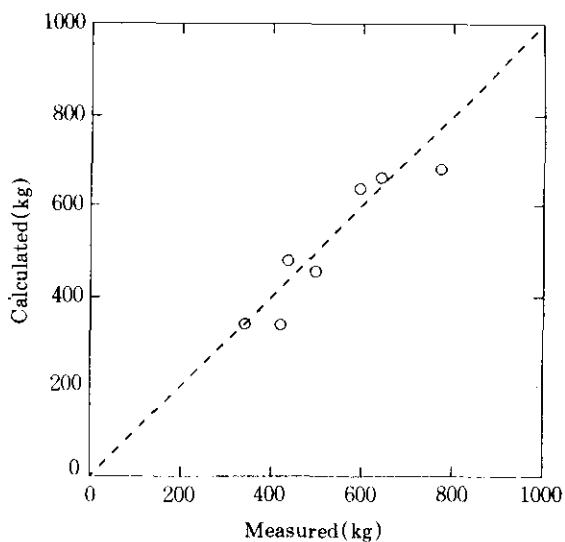


그림 12. 21개의 학습자료에 따른 극한지지력 예측

적이 필요치 않다는 것으로 본 연구에서 개발된 극한지지력 예측 모델의 경우도 말뚝의 근입깊이, 모형지반의 평균주응력, 향타회수등과 극한지지력 사이에 예측을 위한 규칙을 필요로 하지는 않으나 적절한 지지력 예측을 위하여서는 일정한 수 이상의 학습자료가 필요함을 알 수 있다. 본 연구의 경우 예측하고자 하는 자

료의 개수와 같거나 그 이상의 학습자료가 있는 경우에 적절한 지지력 예측이 이루어졌음을 볼 수 있었다.

- 2) 본 연구에서 개발된 신경망 시스템은 sine함수와 같은 비 선형 함수의 mapping<sup>ii</sup> 가능함을 알 수 있었다.
- 3) 학습자료가 많아질수록 시스템을 안정시키기 위한 반복 수행 시간이 기하급수적으로 증가함을 알 수 있었다.

본 연구는 지반공학 분야에 신경 회로망 이론의 적용 가능성을 살펴 본 1차 시도로 말뚝의 극한지지력 예측에 적용해 본 결과 그 적용 가능성이 입증되었다. 다만, 더 많은 실측자료를 이용한 실무적용에 직접 적용할 수 있는 모델 개발을 차후 연구 과제로 계속 진행중임을 밝혀 둔다.

#### 참 고 문 헌

1. 이인모, 이명환, 백세환, 김동현, 이정학(1992). “하중방향(압축-인발)과 말뚝직경이 말뚝지지력에 미치는 영향에 관한 연구”, 한국지반공학회지, 제8권, 제3호, pp.13~21
2. 이인모, 이명환, 백세환, 이정학, 김동현, 임병석(1992). “모형토조실험을 통한 말뚝지지력의 평가”, 한국지반공학회, '92 봄학술발표회 논문집, pp.13~40
3. 이인모, 이정학, 임병석, 이명환(1993). “모형실험을 통한 말뚝지지력의 평가 및 치수효과의 비교 분석”, 한국지반공학회지, 제9권, 제4호, pp. 37~44
4. Lippmann, R. P(1987). “An Introduction to Computing with Neural Nets,” IEEE ASSP Magazine, 4(2)
5. Pao, Y. H.(1988). Adaptive Pattern Recognition and Neural Networks, Adisson-Wesley
6. Rumelhart, D. E., McClelland, J. L. & the PDP Research Group(1986). “Parallel Distributed Processing”, Exploration in the Microstructure of Cognition, Vol.1, Foundations, MIT Press
7. Wasserman, P. D.(1989). Neural Computing : Theory and Practice, Van Nostrand Reinhold, New York.

(접수일자 1994. 4. 15)