

인공신경망 이론 및 지반공학 적용사례



박현일

삼성물산 건설부문 기술연구소
(hyunil77.park@samsung.com)

1 서론

지반재료의 거동특성은 퇴적, 풍화 등과 같은 물리적인 조성이력 등에 따라 매우 복잡하다(Jaksa, 1995). 특히 균질성(homogeneity) 및 등방성(isotropy)을 갖고 있는 강재, 콘크리트 및 목재 등과 같은 토목재료들에 비해 지반재료는 비균질성(heterogeneity) 및 비등방성(anisotropy)을 포함한 매우 복잡한 거동특성을 갖고 있다. 이와 같은 지반의 복잡한 거동 특성의 원인으로서 하중이력, 시간, 공사조건, 시추 및 샘플링 시의 시료 교란 등을 들 수 있다. 이러한 지반거동을 모사하기 위해서는 매우 정교한 해석적 방법들이 필요하며, 많은 수의 설계변수들을 신뢰성 있게 추정해야 한다. 따라서, 기술자의 입장에서는 소요시간과 비용적인 측면을 고려하여 보다 단순한 해석방법이나 경험적 모델을 선호하게 된다.

현업에서 널리 사용되는 회귀분석(regression analysis) 방법의 경우, 단수(single) 모델에서 단지 한 개의 출력값을 구할 수 있다. 이에 반해 인공신경망(Artificial Neural Network, ANN) 기법은 단수(single) 모델에서도 다수

(multi)의 출력 값을 구할 수 있다. 또한 비선형 거동에 대한 선형 가정화 없이 입력과 출력의 관계를 도출할 수 있다. 또한 오류가 포함된 자료의 모델링하거나, 불명확한 변수들 간의 관계를 모델링 하는 경우에 적합하며, 자료 모델링에 대해 일반화(generalization) 성능이 매우 우수한 것으로 알려져 있다(Coit 등, 1998; Twomey와 Smith, 1998).

ANN 기법은 1990년대 초부터 다양한 지반공학 분야에 적용되기 시작하였다: (1) 구성관계 모델링 (Agrawal 등, 1994; Gribb와 Gribb, 1994; Penumadu 등, 1994; Ellis 등, 1995; Millar와 Calderbank, 1995; Ghaboussi와 Sidarta 1998; Zhu 등, 1998; Sidarta와 Ghaboussi, 1998; Najjar와 Ali, 1999; Penumadu와 Zhao, 1999); 지반재료 물성치 (Goh, 1995; Najjar 등, 1996; Najjar와 Basheer, 1996; Romero와 Pamukcu, 1996; Ozer 등, 2008; Park 등, 2009; Park과 Kim, 2010; Park과 Lee, 2010); 말뚝 지지력 (Chan 등, 1995; Goh, 1996; Bea 등, 1999; Goh 등, 2005; Teh 등, 1997; Lee와 Lee, 1996; Abu-Kiefa, 1998; Nawari 등, 1999; Das와 Basudhar,

2006, Park과 Cho, 2010); 사면 안정 (Ni 등, 1995; Neupane와 Achet, 2004; Ferentinou와 Sakellariou, 2007; Zhao, 2007; Cho, 2009); 액상화 (Agrawal 등, 1997; Ali와 Najjar, 1998; Najjar와 Ali, 1998; Ural과 Saka, 1998; Juang과 Chen, 1999; Goh, 2002; Javadi 등, 2006; Kim과 Kim, 2006); 얇은 기초 (Sivakugan 등, 1998; Provenzano 등, 2004; Shahin 등, 2005); 터널 및 지하굴착 (Lee와 Sterling, 1992; Moon 등, 1995; Shi, 2000; Yoo 와 Kim, 2007). 예를 들면 말뚝기초는 지반과 말뚝 사이의 복잡한 상관관계로 인해 현재까지도 거동 메카니즘이 명확이 규명되지 않고 있다 (Kraft, 1991; Brucy 등, 1991; Baik, 2002). 많은 연구자들이 말뚝 기초의 수평 및 수직하중 지지력을 예측하기 위하여 ANN 기법을 적용하고 있다. 또한 구조물이 설치된 지반의 거동을 모사하기 위해서 지반의 구성관계 모델링이 매우 중요하며, 이를 위해 수십 년 동안 다양한 구성모델들이 연구 개발되었다. 그러나, 구성모델이 정교해 질수록 모델 변수들의 추정이 어려우며, 지반거동에 대한 이상화 (idealization) 등으로 인해 지반의 복잡한 거동을 적합하게 모사하는데 한계를 갖고 있다. 이와 관련하여 연구자들이 지반의 구성관계를 모델링할 수 있는 현실적인 대안으로서 ANN 기법에 근거한 구성모델을 제안하고 있다.

이와 같이 ANN 기법이 공학적인 문제에 대하여 효율적인 접근방법임에도 불구하고, 신경망의 구조와 설계변수 값을 결정할 수 있는 기법에 대한 연구는 제한적으로 수행되었다 (Hecht-Nelson, 1987; Bounds 등, 1988; Lawrence와 Fredrickson, 1988; Cybenko, 1989; Marchandani와 Cao, 1989; Fahlman과 Lebiere, 1990; Lawrence, 1994; Swingler, 1996; (Öztürk, 2003)). 신경망 구조의 설계 변수들을 선정함에 있어서 다음과 같은 구체적인 문제점들이 내재되어 있다. 첫째, 어떤 공학문제의 경우 입력변수들과 출력값 간의 공학적인 연관성이 명확하지 않을 수 있다. 이 경우 신경망 구조의 복잡함을 피하며 동시에 입력정보에 대한 중요한 정보의 손실을 피할 수 있는 입력변수들의 적합한 조합을 찾기 어렵다. 둘째, 은닉층의 노드 수를 너무 많이 설정하게 되면 불필요한 연산의 실행과 과다하게 세분화된 구분으로

인하여 과적합(overfitting)이 일어나 일반성이 감소하게 된다. 따라서, 주어진 문제에 적합한 최적의 은닉층의 노드 수가 신경망의 성능에 매우 큰 영향을 미칠 수 있다. 현재까지 신경망 구조설계는 어떤 공식화된 설계원칙이 존재하지 않는 분야로서 신경망 개발 전문가의 주관적인 경험적 지식(heuristic)과 많은 수의 신경망 구조를 반복적으로 적용하는 시행착오(trial-error)에 의존하고 있다.

본 기술기사에서는 ANN 기법의 이해를 돋기 위하여 다음과 같이 내용을 구성하였다. (1) ANN 기법의 개요, (2) ANN 구조설계의 가이드라인, (3) 지반공학 분야에 대한 적용사례 (4) ANN 모델을 사용한 계산 예, (5) 결론으로 정리되었다.

2. ANN에 대한 개론

2.1 인공 뉴런(neuron)의 개념

인간의 대뇌피질(cerebral cortex)은 대략 $10^{10} \sim 10^{11}$ 개의 뉴런으로 이루어져 있으며, 각각의 뉴런은 약 1000개의 수상돌기(dendrite)를 가지고 있다. 각 뉴런은 본체인 세포체(cell body), 수상돌기(dendrite), 축색돌기(axon) 등으로 구성되어 있으며 축색돌기의 연결부분을 시냅스(synapse)라고 한다(그림 1 참고). 수상돌기는 세포체 주위의 섬유데미 모양을 연결되어 있으며, 인접한 뉴런으로부터 신호가 세포체로 들어오는 통로 역할을 한다. 축색돌기는 하나의 기늘고 긴 섬유로 되어 있으며 인접한 뉴런으로부터 정보를 전달하는 통로 역할을 한다.

인간의 뇌는 신경세포가 복잡하게 서로 연결된 네트워크로서 외부 혹은 다른 신경세포로부터 시냅스를 통하여 입력신호를 받아 세포체에서 적절한 처리를 수행하여 그 결과를 축색돌기를 통해 다른 신경세포에 전달하는 계산 기능을 수행한다. 다른 신경세포의 수상돌기가 만나는 지점인 시냅스에서 두 세포간의 연결강도가 변화된다. 연결강도의 변화가정이 신경세포 간의 영향력의 크기를 조절하는 뇌에서의 학습과정이며, 입력에 대한 신경회로망의 반응을 결정하는 역할을 수행한다. 입력부위는 뉴런의 수

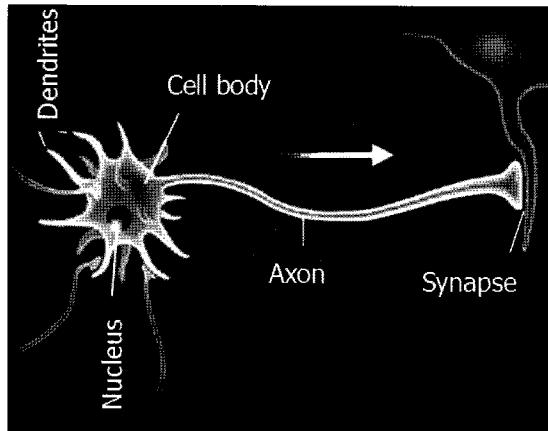


그림 1. 생물학적 뉴런(neuron)

상돌기에 해당하며, 다른 뉴런의 신호를 시냅스로부터 받는 기능을 갖고 있다. 결합기능 부위는 뉴런의 세포체와 같이 활성적(active) 정보를 가진 입력신호와 억제성(inhibitory) 정보를 갖는 입력신호를 가한다. 출력 부위는 뉴런의 축색돌기에 해당하며, 세포체의 점화에 의해 발생되는 전기적 에너지를 통해 다른 뉴런으로 전달된다. ANN은 수상돌기와 축색돌기를 전선으로 모방하고, 시냅스를 연결강도로 모방한다. 인공신경망은 수학적 연산 능력을 가진 노드(node)들이 상호 연결된 것으로서 적절한 학습규칙에 의해 동작한다. 이를 생물학적 신경망과 구별하여 인공신경망이라 부른다.

2.2 인공 뉴런(neuron)의 수학적 모델링

뉴런 혹은 노드(node)는 신경망을 구성하는 자료처리

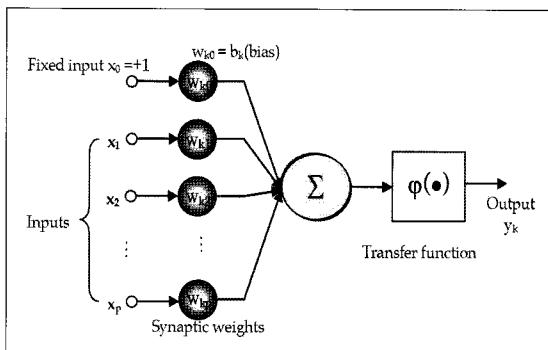


그림 2. 인공 뉴런의 개념도

단위 개체이다. 그림 2에 나타난 바와 같이 뉴런 모델은 세 가지 기본요소로 구성되어 있다. 입력값은 연결강도(weight, w)와 임계값(bias, b)에 의해 가중입력 값이 되며 전달함수(transfer function)를 통해서 출력된다. 식 (1)에 나타난 바와 같이 k 번째 뉴런에 연결된 j번째 시냅스에 들어오는 입력 x_j 는 연결강도(weight), w_{kj} 와 곱해져서 합쳐진다. 이러한 과정을 생물학적 관점에서 살펴보면 연결강도는 시냅스의 강도에 해당하고, 세포체는 가중 입력과 전달함수로 표현되며, 출력은 축색돌기에서의 신호를 의미한다.

$$v_k = [w_{k0} \quad w_{k1} \quad \dots \quad w_{kp}] \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_p \end{bmatrix} = w_k^T x \quad (1)$$

2.3 전이함수(Transfer function)

전이함수는 출력 값에 대하여 수학적인 처리를 수행하며, 공학분야에서 사용되는 대표적인 세 종류의 전이함수들을 본 장에 정리하였다. 첫째로, 그림 3(a)에 나타나 있는 선형(linear) 함수는 중첩(superposition) 개념에 근거하여 제안되었으며, 식 (2)와 같이 표현될 수 있다.

$$y = f(u) = \alpha u \quad (2)$$

여기서, α 는 선형함수의 기울기를 의미한다.

시그모이드(sigmoid) 함수는 그림 3(b)에 나타난 바와 같이 단극성 혹은 양극성 비선형 연속함수이며, 신경망 모델의 전이 함수로서 가장 널리 사용되고 있다. 시그모이드 함수는 S자 모양이므로 S형 곡선으로 불리기도 하며, 연속적이며 미분 가능하다. 수학적으로 표현하면 다음 식(3)과 같다.

$$f(x) = \frac{1}{1+e^{-\alpha x}}, 0 \leq f(x) \leq 1 \quad (3)$$

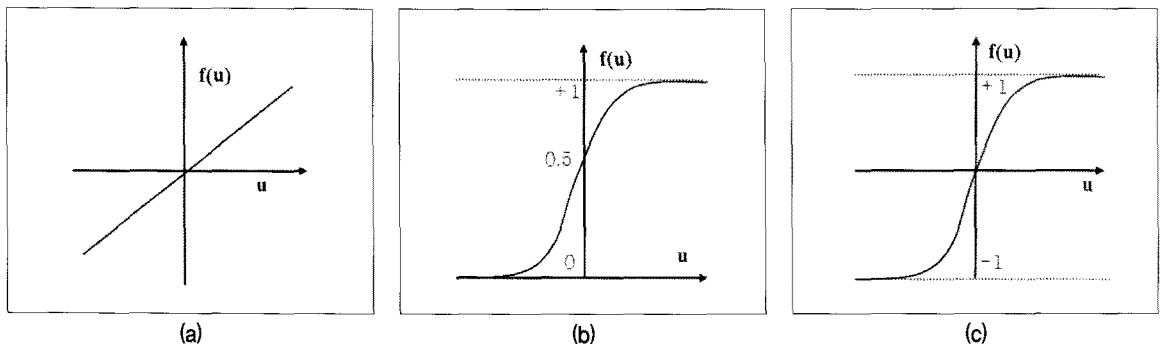


그림 3. 전이함수

여기서, α 값은 시그모이드 함수의 형상 계수로서, α 값을 변화시킴으로써 함수의 형상을 다양하게 변화시킬 수 있다. 일반적으로 α 값은 1이 사용되고 있다. 탄젠트 시그모이드(Tangent sigmoidal) 함수는 다음 식 (4)와 같이 표현될 수 있다.

$$f(x) = \frac{2}{1+e^{-\alpha x}} - 1, -1 \leq f(x) \leq +1 \quad (4)$$

2.4 다층(multi-layered) 신경망

다층 신경망은 입력층, 은닉층 및 출력층으로 구성되어 있으며, 각 층은 다수의 노드로 이루어져 있다. 특정 층을 이루고 있는 각각의 노드들은 바로 앞 층의 모든 노드들과 연결되어 있으며, 노드들 사이의 연결은 각각의 가중치를 갖는다. 다층 신경망의 일반적인 구조는 그림 4와 같다.

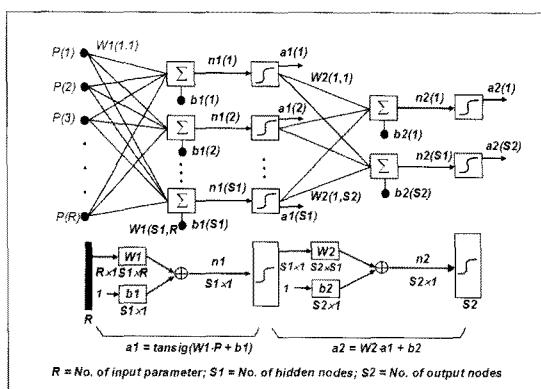


그림 4. 다층신경망에 대한 예

다. 일반적으로 신경망의 각 층은 앞 층의 출력신호를 입력신호로 받게 된다. 입력층 노드들의 활성도는 신경망에 제공되는 자료를 대변하며, 각 은닉층의 활성도는 입력신호의 활성도와 입력층과 은닉층 사이의 연결강도에 의해서 결정된다. 또한 출력층 노드들의 거동은 은닉층 노드들의 활성도와 은닉층-출력층 사이의 연결강도에 의존한다.

2.5 역전파(Back-propagation) 알고리즘

역전파 알고리즘(Backpropagation algorithm, BP)은 신경망 학습에 널리 사용되는 탐색기법 가운데 하나로서, 네트워크 에러함수를 최소화하는 경사하강법(gradient-decentant)과 일반화된 델타(delta) 법칙에 의해 지배되는 학습법이다. BP는 Rumelhart(1986)에 의해 실제적으로 ANN에 적용되도록 정립되어 음성인식, 시각적 패턴 인식문제 및 다양한 공학문제 해결에 적용되고 있으며 대부분의 다층신경망은 BP를 이용하여 학습되고 있다. BP의 연산은 전방향(forward direction) 및 역방향(backward direction)의 행렬 백터 곱과 그 사이에 수행되는 미분 가능한 비선형 연속함수 계산의 반복으로 이루어진다. 그 첫 단계인 전방향 단계에서는 신경망에 입력패턴을 제시하고 각 노드에 대한 입력값과 연결 가중치, 비선형 함수를 이용하여 은닉층들과 출력층의 활성값을 구한다. 두 번째 단계인 역방향 단계에서는 입력받은 모든 패턴들에 대해서 각각에 대한 기대치와 실제로 신경

망의 출력층에서 산출된 출력값과의 차이를 계산하여 오차 제곱합(sum of squared error)을 구하고 이를 역방향 즉 출력층에서 입력층으로 순서대로 층과 층 사이의 연결 가중치 값들을 변화시키는 단계이다. 이는 신경망에 대해서 주어진 데이터를 가장 잘 반영하는 연결강도인 가중치를 찾아내는 것인데, 이는 오차함수를 최소화하는 최적화 문제가 된다.

3. ANN 구조 설계

인공신경망의 구조를 설계하기 위해서는 층(layer)의 수, 각 층의 노드(node) 수, 층 사이의 전이함수 및 학습 알고리즘이 결정되어야 한다. 또한 입력 층에 포함될 변수들을 선정하는 것은 매우 어려운 과정이라 할 수 있다: (1) 입력 변수들 사이에 상호 의존적(interdependency)이거나 중복성(redundancy)이 존재하기 때문에, 입력층에서 특정 변수들을 제외시킬 필요성이 있다. (2) 인공신경망은 대체로 입력변수들과 출력값 사이의 관계가 명확치 않는 문제들에 적용되기 때문에 입력변수 조합을 선정하는 것이 쉽지 않다. 현재까지는 최적의 신경망 구조를 도출할 수 있는 명확한 방법이 존재하지는 않다(Chung과 Kusiak, 1994; Kusiak과 Lee, 1996; Öztürk, 2003). 따라서, 인공신경망 구조는 다양한 신경망 구조에 대한 시행착오(trial and error)방법을 통하여 설계된다. 그럼에도 불구하고, 은닉층의 노드 수, 각 층의 수, 학습 알고리즘 등을 포함한 신경망 구조 관련 연구들이 제한적으로 수행된 연구결과들이 다음과 같이 정리되어 있다.

3.1 은닉층 수

은닉층 수와 각 은닉층의 노드 수를 결정하는 것은 상당한 노력을 요하는 작업이다. 은닉층 수는 입력변수들과 출력값의 관계의 복잡도에 의해서 결정되며, 신경망의 성능을 결정하는 매우 중요한 단계이다. 일반적으로 입력변수들과 출력값 사이에 선형적인 관계가 존재한다면 단일 은닉층(OHL, One Hidden layer)으로 충분하고, 더블 은닉층(THL, Two Hidden layer)보다 많은 수의 은닉 층이 요구되는 문제는 거의 드물다고 할 수 있다(Cybenko, 1989; Bounds 등 1988). THL이 OHL보다 우수하며, cascade correlation과 같은 구조에 보다 효율적인 것으로 보고되기도 하였다(Chester, 1990; Fahlman과 Lebiere, 1990; 등). 신경망구조가 커짐에 따라 신경망 학습이 개선되는 이유는 추가적인 자유도 증가로 인해 수렴성이 개선될 수 있다. 즉 추가적인 변수 추가로 인해 지역 해(local optimum) 혹은 플레토(plateaus)에 대한 수렴 가능성성이 감소하게 된다. 은닉층 설계 시에 우선적으로 OHL을 먼저 검토하는 것이 적합하다 (Lawrence, 1994). OHL의 학습결과가 좋지 않는 경우에 은닉층 노드 수를 증가시켜야 하며, 은닉층 수의 증가는 최종적으로 검토하는 것이 적합하다.

3.2 은닉층 노드 수

은닉층 노드 수는 대상문제에 따라 결정된다. 표 1에 정리된 바와 같이 은닉층 노드 수는 입력층과 출력층의 노드 수의 조합으로 선정한다. 이후에 학습 시의 오차가 수렴 기준과 수렴 속도를 비교하여 노드 수를 증가 혹은 감

표 1. 은닉층 노드 수를 결정하는 방법

식	참고문헌
$h = 2i + 1$	Hecht-Nelson (1987)
$h = (Ho)/2, \frac{N}{10} - i - o \leq h \leq \frac{N}{2} - i - o$	Lawrence와 Fredrickson (1988)
$h = ilog_2 p$	Marchandani와 Cao (1989)

*. h = 은닉층 노드 수, i = 입력층 노드 수, o = 출력층 노드 수

소시키면서 최종적인 은닉층 노드 수를 결정하는 것이 효과적이다.

3.3 학습 자료 수

신경망의 성공적인 학습을 위해서는 학습에 사용되는 자료 수를 매우 신중하게 결정해야 한다. 학습(training) 자료의 수에 비해 신경망 구조가 큰 경우에 과적합(over-fitted)되기 쉽다. 즉, 학습 자료에 대하여 상관(correlation) 관계가 우수한 반면에 검증(testing) 자료에 대해 상관성이 크게 저하되는 것을 의미한다. 반면에 학습 자료 수에 비해 신경망 구조가 작은 경우에는 검증 자료에 대하여 학습 자료에 대한 상관성이 크게 저하되며 이를 부적합(under-fitted) 되었다고 한다. 그러나, 신경망의 과적합과 부적합을 피할 수 있는 학습 자료 수를 결정할 수 있는 정확한 가이드라인은 현재까지 제안되지 않았다. Lawrence와 Fredrickson (1988)은 학습 자료 수를 결정할 수 있도록 다음 식 (6)을 제안한 바 있다.

$$2(i + h + o) \leq N \leq 10(i + h + o) \quad (6)$$

여기서, h 은 은닉층 노드 수이고, i 는 입력층 노드 수이며, o 는 출력층 노드 수를 의미한다.

4. ANN 기법의 지반공학 적용사례

4.1 구성관계 모델링

과거 수십 년 동안 많은 연구자들이 지반재료에 대한 파괴규준(failure criteria), 비선형성(nonlinearity), 소성(plasticity), 응력의존성(stress dependency) 등에 관한 이론들을 제안하여 지반재료의 응력-변형률 관계를 정확하게 모사하고자 하였다. 그러나 지반의 복잡한 거동메카니즘을 명확하게 규명하기 불가능하며, 동시에 이를 구성 모델에 구현하는 것이 현실적으로 매우 어렵다. 또한 구성 모델의 성능이 개선될 수록 수치해석 프로그램과 연

동하여 사용하는데 제한을 받게 된다(Shin과 Pande, 2000). 따라서, 실제적인 사용 측면에서의 활용성을 높이기 위하여 구성모델을 간단화 시키기도 하지만, 이로 인해 구성모델의 성능은 저하될 수 있다.

Ghaboussi와 공동 연구자들은 지반재료에 대한 거동 특성에 대한 지식이나 가정사항 없이 응력 의존성, 배수 조건 등의 지반재료 거동을 모사할 수 있는 신경망에 기반된 체계를 제안하였다(Ghaboussi와 Sidarta, 1998; Sidarta와 Ghaboussi, 1998). Ghaboussi 등(1998)은 유한요소법과 자동학습 알고리즘을 연계하여 일반적인 소성이론으로 모사가 곤란했던 비균질 삼축실험 자료를 신경망으로 학습하였다. 기존 구성모델로 실험결과의 거동 모사가 곤란한 경우에 새로운 구성 모델 혹은 구성관계식의 제안이 요구된다. 그러나 기존 실험자료에 대하여 학습된 ANN 모델의 경우, 추가적인 학습을 통하여 새로운 자료의 거동 모사에 필요한 추가적인 정보를 쉽게 확보할 수 있다(Zhu 등, 1998). 또한 인공신경망에 근거한 구성 모델이 접선강도행렬(tangent stiffness matrix)을 계산하는 유한요소프로그램에 성공적으로 탑재된다고 보고되었다(Shin과 Pande, 2000; Hashash 등, 2004). Hashash 등 (2004)은 신경망 변수들을 사용한 외연적(explicit) 전개를 통하여 신경망 모델로부터 접선강도행렬이 도출 가능하다고 보고한 바 있다. 이와 같이 ANN 모델은 암반, 점토, 모래, 자갈 등의 다양한 지반재료의 구성관계 모델링에 적용되고 있다(Zhu 등, 1998; Millar와 Calderbank, 1995; Penumadu 등, 1994; Ellis 등, 1995; Penumadu와 Zhao, 1999; Najjar와 Ali, 1999). 그러나, 신경망에 기반한 구성모델은 학습에 사용된 특정 재료 모사에만 적합하다. 또한, 전통적인 구성모델이 경화법칙, 흐름법칙 등과 같은 소성개념을 모사하는 변수들에 의해 직접적으로 거동 모사에 대한 조정이 가능 한데 반해 신경망 기반 구성모델은 거동모사에 대한 조정이 매우 어렵다는 단점이 있다.

4.2 지반재료의 물성치

지반공학에서 지반재료의 공학 물성치를 추정하기 위

해 경험적 관계식들이 많이 사용되고 있으며, 실내실험 혹은 현장시험 자료들에 통계기법을 적용하여 관계식들을 도출한다. Goh (1995c)는 지반 물성값 들간의 상관관계를 도출하기 위하여 새로운 기법을 적용하였다. Goh는 정규암밀 및 과압밀된 지반에 대하여 콘관입시험(cone penetration test, CPT)로부터 얻어진 콘저항 값과 상대 밀도 간의 상관관계를 얻기 위하여 ANN 모델을 사용하였다. Ozer 등(2008)과 Park과 Lee(2010)들은 ANN 모델을 압축지수 값과 지반물성치 간의 관계를 구하는 데에 적용하였다. Ellis 등 (1995)은 모래의 응력이력과 입경크기분포에 대한 ANN 모델을 제안하였다. Najjar 등 (1996)은 ANN 모델이 흙의 팽창(swelling)을 정확히 평가할 수 있으며, 다른 통계적 모델들에 비해 상당히 개선

된 예측결과를 제공한다고 보고하였다. Agrawal 등 (1994), Gribb와 Gribb (1994), Najjar 와 Basheer (1996b)는 ANN 모델을 점토 라이너(liner)의 투수계수 값을 평가하는데 적용하였다. Park 등 (2009)은 노상토 (subgrade soils)와 보조기층 재료(subbase materials)의 동탄성 계수(resilient modulus)를 산정할 수 있는 ANN 모델식을 제안한 바 있다. 이와 같이 ANN 모델은 학습 및 검증 단계에서 경험식들 보다 개선된 상관관계를 보여주었다.

ANN 모델의 실제 적용 Park과 Kim(2010)은 보강 경량토(reinforced lightweight soil, RLS)의 일축압축강도 값을 예측할 수 있는 ANN 모델을 제안하였다. 그림 5에 나타난 바와 같이 RLS는 준설토, 시멘트, 흙, 에어폼(air-

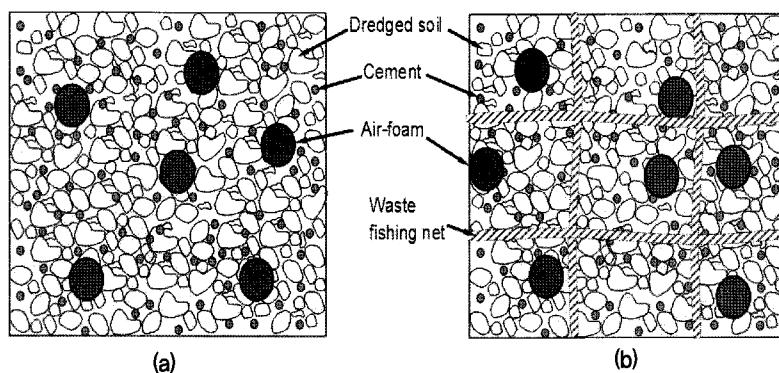


그림 5. 비보강(unreinforced) 및 보강(reinforced) 경량토 (Park과 Kim, 2010a)

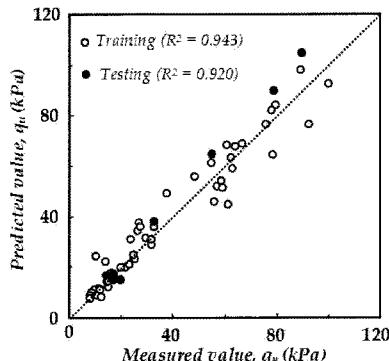
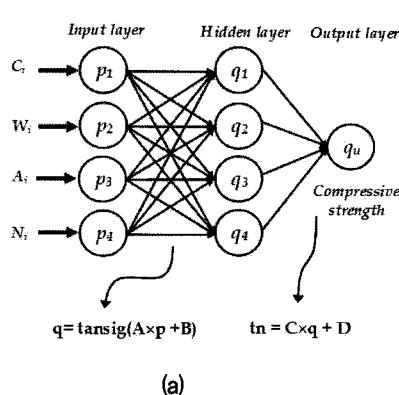


그림 6. 제안된 인공신경망 모델 및 예측결과 (Park과 Kim, 2010)

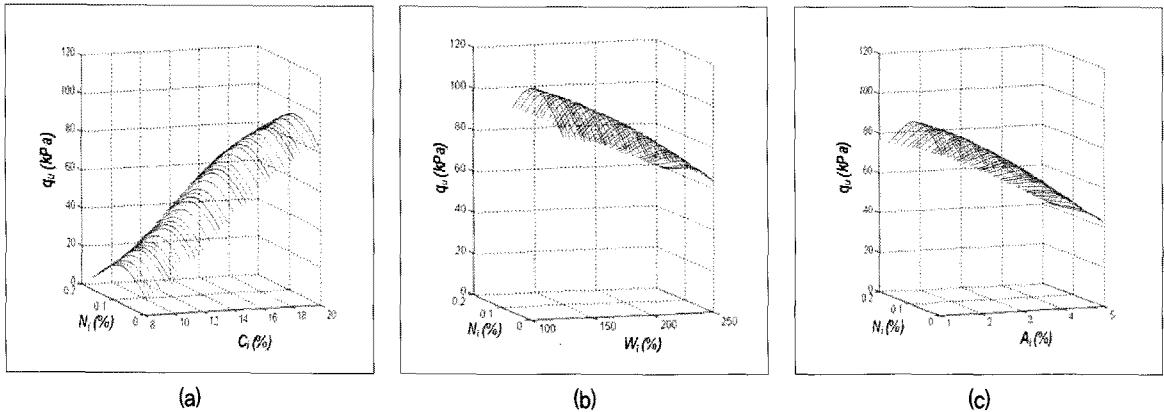


그림 7. The unconfined compressive strength with variation of input parameters (Park과 Kim, 2010)

foam), 폐그물망(waste fishing net)으로 구성되어 있으며, 준설토와 폐그물망을 재활용하는 측면에서 친환경 뒷채움재로 활용 가능하다. 연구자들은 RLS의 강도특성을 파악하기 위하여 다양한 혼합비율에 대하여 일죽압축시험을 수행하였다. 그러나, RLS의 압축강도는 구성재료들의 혼합비율 간에 복잡한 연관성을 갖으므로, 구성재료들의 혼합비율과 RLS 강도 간의 경험식을 도출하기 매우 어렵다. 따라서, 다양한 혼합비율에 대하여 수행된 실험 결과들을 사용하여 주어진 혼합비율에 대한 RLS의 강도를 예측할 수 있는 ANN 모델식을 제안되었다.

제안된 ANN 모델의 구조는 그림 6(a)에 나타나 있다. 학습 및 검증단계에서 예측된 압축강도에 대한 예측값들과 실험값들이 서로 비교되어 있으며, 비교적 좋은 상관관계를 보여주고 있다. 그림 7에서는 ANN 모델을 사용하여 얻어진 구성재료들의 혼합비율의 변화에 따른 RLS의 강도값의 복잡한 변화양상이 나타나 있다.

4.3 말뚝 지지력

말뚝 지지력 및 거동에 대하여 다양한 실험 및 이론적인 연구들이 수행되었음에도 불구하고 말뚝거동에 대한 전반적인 이해는 현재까지 미흡한 실정이다. 이는 지반조건(흙의 종류와 지반의 응력상태 및 상대밀도 등)과 말뚝조건(말뚝의 직경과 벽면마찰각과 관입깊이 및 말뚝 선단부의 개폐단 여부 등)과 말뚝의 향타조건(향타방법 혹은

향타에너지)과 시간경과효과(set-up 및 relaxation 현상) 등과 같은 많은 인자들이 말뚝 거동에 영향을 미치며, 이러한 영향인자들 간의 복잡한 상호작용을 적절하게 정량화하기가 매우 어렵기 때문이다(Kraft, 1991; Bruey 등, 1991; Baik 2002).

기존의 정역학적 극한지지력 공식들은 영향인자들의 선별과 고려 방식에 따라 형태를 크게 달리한다. 현재까지 많은 말뚝 지지력 공식들이 제안되었으나, 앞에서 언급한 말뚝 지지력에 영향을 미치는 많은 인자들을 적절하게 고려한 공식은 제안되지 않은 실정이다(Hansen 1961; Broms, 1964; Meyerhof, 1976). 이는 말뚝 지지력에 미치는 중요인자들을 도출함과 동시에 그 영향을 정량적으로 평가하는 것이 매우 힘들기 때문이다. 또한, 공식의 지나친 복잡화를 피하는 과정에서 일부 영향인자가 제외되거나 영향인자간의 상관성이 결여되기도 한다. 시공과정에서 재하시험을 통해 말뚝의 지지력을 확인할 수는 있지만, 설계 시점에서 적절한 물량 산출 및 공기 예측을 위해서는 말뚝 지지력에 대한 신뢰성 있는 예측이 반드시 필요하다. 따라서 말뚝 지지력에 대한 여러 영향인자들 사이에 이루어지는 복합적인 상호작용을 고려하여 수식화할 수 있는 새로운 지지력 공식에 대한 개발이 필요하다고 할 수 있다.

Goh (1996)는 점토지반에 설치된 마찰말뚝의 지지력을 산정하기 위하여 ANN 모델을 적용하였다. 모래질지반에 설치된 말뚝에 대하여 ANN 모델이 Hiley 식,

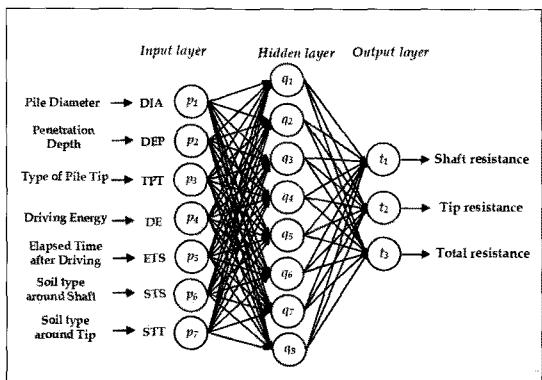


그림 8. 말뚝지지력을 산정하기 위해 제안된 ANN 모델 구조
(Park과 Cho, 2010)

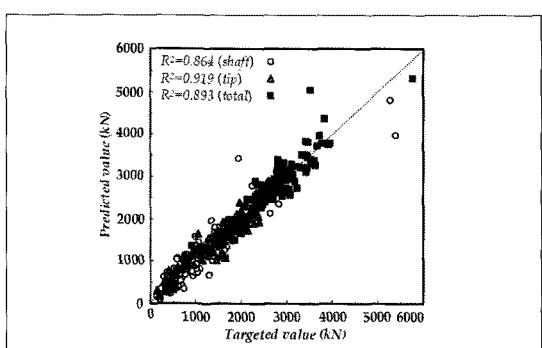
Janbu 식들 보다 개선된 극한지지력 예측 값을 제공한다고 보고하였다. Goh (1996) Chan 등 (1995)과 Teh 등 (1997)은 ANN 모델이 CAPWAP (GRL, 1972) 프로그램에 의해 산정된 정적지지력과 유사한 정도의 예측을 수행한다고 보고한 바 있다. Lee와 Lee (1996)는 현장 및 실내 모형실험 결과에 근거하여 말뚝의 극한 지지력을 산정할 수 있는 ANN 모델을 제안하였다. Abu-Kiefa (1998)는 비접성(cohesionless) 지반에 설치된 말뚝들에 대하여 선단(tip), 주면(shaft) 및 전체(total) 지지력을 예측할 수 있는 확률 신경망의 일종인 GRNN(generalized regression neural network) 모델을 제안하였다.

Park과 Cho (2010)는 국내 시공현장들에서 수행된 개단(driven) 말뚝에 대한 165개의 동적재하시험 결과들에 대하여 ANN이론을 적용하여 선단, 주면 및 전체 지지력

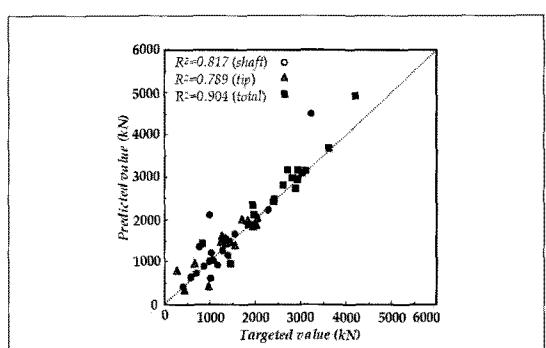
을 예측하는식을 제안하였다. 그림 8에 나타난 바와 같이 제안된 ANN 모델은 입력층, 은닉층 및 출력층으로 구성되어 있으며, 은닉층 노드 수는 8이다. 각 층 사이에 적용되는 전이함수는 입력층-은닉층 및 은닉층-출력층에 대하여 탄젠트-시그모이드(tan-sigmoid), 선형(linear) 함수가 각각 적용되었다. 그림 9에는 학습 및 검증 단계에서 ANN 모델에 의한 예측값과 실제값이 서로 비교되어 있으며, 주면, 선단 및 전체지지력에 대하여 0.8~0.9 사이의 상관계수 값을 제공하고 있다.

4.4 사면 안정

많은 국가들에서 유발되고 있는 사면파괴재해는 분석이 매우 어려운 자연현상 가운데 하나이다. 제한된 자료로 인하여 사면파괴를 정확히 이해하기 어려운 경우들이 많다. 이와 같은 사면파괴를 예측하거나 방지하기 위해서는 사면안정해석 및 안정화 방안을 수립할 수 있도록 사면거동을 평가할 수 있는 프로세스가 필요하다. 안정을 평가할 수 있는 지수로서 지반공학 모델에 근거한 안정계수값이 필요하다. 최근에 많은 연구자들이 비선형 다변수 문제에 대한 성공적인 적용사례들을 참고하여 사면안정을 평가하기 위하여 ANN 이론을 적용하고 있다 (Ni 등, 1995; Neupane과 Achet, 2004; Sakellariou와 Ferentinou, 2005; Cho, 2009; Wang 등, 2005). 사면의 안정계수값을 계산하기 위해서는 지형정보, 지반의 물리특성자료 및 강도정수 등이 필요하다.



(a) 학습단계



(b) 검증단계

그림 9. 학습 및 검증단계에서 예측값과 실제값의 비교 (Park과 Cho, 2010)

5. 인공신경망의 실제 계산 예

5.1 수학적 전개

신경망을 특정한 목적으로 사용하기 위해서는 신경망의 내부 설계변수인 weight와 bias 값들을 추정하여야 하며, 이러한 일련의 추정과정을 학습(learning)이라 한다. 학습은 일반적으로 신경망의 실제 출력값(t)과 목표값(T)과의 차이를 이용하여 식 (5)와 같이 오차함수를 정의한 후 이 값이 최소화되도록 하는 weight와 bias 값들을 구한다. 식 (5)에서 $\| \cdot \|$ 은 벡터의 2-norm을 의미한다.

$$E = \| T - t \| ^2 \quad (5)$$

역전파(back-propagation) 알고리즘은 weight와 bias 값을 조정함으로써 오차함수 값을 최소화하는 역할은 수행한다. 이와 같은 반복적인 조정과정을 거쳐서 최종적인 weight와 bias 값들이 결정되면 학습단계는 완료되는 것이다. 학습에 사용되는 자료의 선처리 과정으로서 입력자료(p_n) 및 목표출력값(t_n)을 -1과 +1 사이로 규준화할 수 있다(Kurup와 Dudani, 2002).

$$\begin{aligned} p_n &= 2(p - \min p) / (\max p - \min p) - 1, \\ t_n &= 2(t - \min t) / (\max t - \min t) - 1 \end{aligned} \quad (6)$$

여기서, p = 입력행렬, t = 목표출력값, p_n = 정규화된 입력행렬, t_n = 정규화된 목표출력값, $\max p$ = 입력물성치에서 최대값으로 구성된 입력행렬, $\min p$ = 입력물성치에서 최소값으로 구성된 입력행렬, $\max t$ = 목표출력값들 중에서 최대값, $\min t$ = 목표출력값들 중에서 최소값이다.

정규화된 자료들이 가중치 값들을 구하기 위해 인공신경망 모델의 학습과정에 사용된다. 따라서, 최종적으로 구해진 정규화된 출력값은 식 (7)을 통하여 실제적인 지지력값(t)으로 환산될 수 있다.

$$t = 0.5 \cdot (t_n + 1) \cdot (\max t - \min t) + \min t \quad (7)$$

정규화된 출력값 t_n 은 식 (8)과 같이 내부입력벡터의 전파에 의하여 구할 수 있다.

$$t_n = W_2 \times \text{logsig}(W_1 \times p_n + B_1) + B_2 \quad (8)$$

여기서, W_1 = 입력층 뉴런들과 은닉층 뉴런들과의 연결 가중치 행렬, B_1 = 은닉층 뉴런들에 대한 bias 벡터, W_2 = 은닉층 뉴런들과 출력층 뉴런과의 가중치 행렬, B_2 = 출력층 뉴런의 bias 값이다. 시그모이드 함수는 식 (3)으로 정의되어 있다.

정규화된 입력물성치와 최종적인 지지력 값의 관계식은 식 (7)과 식 (8)로부터 (9)와 같이 최종적으로 정리될 수 있다.

$$\begin{aligned} t &= 0.5 \cdot (\text{logsig}(W_1 \times p_n + B_1) + B_2 + 1) \cdot \\ &(\max t - \min t) + \min t \end{aligned} \quad (9)$$

5.2 ANN 모델을 이용한 말뚝지지력 계산 예 (Park과 Cho, 2010)

말뚝지지력 산정에 적용된 ANN 모델 구조는 그림 8에 나타나 있으며, 지반조건에 입력물성 정보는 표 2에 정리되어 있다. 표 3에는 식 (9)에 필요한 Weight 행렬과 bias 행렬 값들이 정리되어 있다.

표 2. 말뚝 선단 및 주면 지반에 대한 입력정보

Classification of soil	Value
Clay	1
Silt – Clay	2
Silt	3
Sand – Clay	4
Sand – Silt	5
Fine Sand	6
Sand	7
Sand – Gravel	8

표 3. ANN 모델에 사용되는 Weight 행렬과 bias 행렬 값들

W1	0.910	-1.070	3.323	1.594	0.376	-1.196	-2.252	B1	1.189
	-0.785	0.189	-1.658	-0.106	0.133	1.922	-0.266		0.169
	2.505	0.625	-1.354	-0.422	-4.459	-0.615	1.252		-1.676
	2.871	2.612	-1.622	-0.413	-4.854	0.259	0.277		-0.712
	1.397	2.235	0.354	-0.972	0.194	-1.625	-2.250		-0.889
	0.227	4.302	-2.049	-0.753	0.391	1.649	-1.787		2.777
	-0.153	-0.506	-0.284	-3.868	-0.795	-1.434	1.386		-3.926
	0.058	-4.905	-0.370	0.882	-0.158	-0.712	-3.116		1.408
W2	1.510	-0.472	-3.371	3.190	0.110	-1.474	-0.079	-1.192	0.598
	-0.417	-3.524	3.203	-2.910	-3.145	3.588	-0.768	1.880	-0.899
	1.230	-2.128	-1.662	1.631	-1.397	0.317	-0.441	-0.231	0.543

*. 행렬 W1 (8×7), B1 (8×1), W2 (3×8), 및 B2 (3×1)이 식(9)에 사용된다.

표 4. 인공 신경망모델 입력 및 출력값의 최대 및 최소값

	Input parameters							Output values		
	DIA (m)	DEP (m)	TPT	DE (kN·m)	ETS (day)	STS	STT	Shaft (kN)	Tip (kN)	Total (kN)
Max.	0.273	9.6	0	1.3	0	1	1	154	158	360
Min	0.610	42.8	1	102.0	43	5	8	5401	2742	6126

*. 말뚝 선단부 조건(TPT)이 0인 경우 폐단조건이고, 1인 경우 개단조건을 의미한다.

입력벡터 p에 값들은 다음과 같이 주어져 있다.

$$p = \begin{bmatrix} DIA \\ DEP \\ TPT \\ DE \\ ETS \\ STS \\ STT \end{bmatrix} = \begin{bmatrix} 0.508 \\ 9.6 \\ 0 \\ 36.3 \\ 31 \\ 3 \\ 3 \end{bmatrix} \quad pn = \begin{bmatrix} 0.396 \\ -1.0 \\ -1.0 \\ -0.473 \\ 0.442 \\ 0 \\ -0.429 \end{bmatrix}$$

정규화된 입력벡터 pn은 식 (6)을 사용하여 구해지며,
min p와 max p값은 표 4에 주어져 있다.

정규화된 출력값은 다음과 같이 정규화된 입력벡터 pn
의 전파로 구해질 수 있다.

$$A \times pn + B = \begin{bmatrix} 0.910 & -1.07 & -3.323 & 1.594 & 0.376 & -1.196 & -2.252 \\ -0.785 & -0.189 & -1.658 & -0.106 & 0.133 & 1.922 & -0.266 \\ 2.505 & 0.625 & -1.354 & -0.422 & -4.459 & -0.615 & 1.252 \\ 2.871 & 2.612 & -1.622 & -0.413 & -4.854 & 0.259 & 0.277 \\ 1.397 & 2.235 & 0.354 & -0.972 & 0.194 & -1.625 & -2.250 \\ 0.227 & 4.302 & -2.049 & -0.753 & 0.391 & 1.649 & -1.787 \\ -0.153 & -0.506 & -0.284 & -3.868 & -0.795 & -1.434 & 1.386 \\ 0.058 & -4.905 & -0.370 & 0.882 & -0.158 & -0.712 & -3.116 \end{bmatrix} \times \begin{bmatrix} 0.396 \\ -1.0 \\ -1.0 \\ -0.473 \\ 0.442 \\ 0 \\ -0.429 \end{bmatrix} + \begin{bmatrix} 1.189 \\ 0.169 \\ -1.676 \\ -0.712 \\ -0.889 \\ 2.777 \\ -3.926 \\ 1.408 \end{bmatrix} = \begin{bmatrix} 6.321 \\ 1.550 \\ -2.262 \\ -2.633 \\ -1.415 \\ 1.908 \\ -2.314 \\ 7.554 \end{bmatrix}$$

$$\log sig(A \times pn + B) = \begin{bmatrix} 0.998 \\ 0.825 \\ 0.094 \\ 0.067 \\ 0.196 \\ 0.871 \\ 0.090 \\ 1.000 \end{bmatrix}$$

$$tn = C \times \log sig(A \times pn + B) + D = \begin{bmatrix} 1.510 & -0.472 & -3.371 & 3.190 & 0.110 & -1.474 & -0.079 & -1.192 \\ -0.417 & -3.524 & 3.203 & -2.910 & -3.145 & 3.588 & -0.768 & 1.880 \\ 1.230 & -2.128 & -1.662 & 1.631 & -1.397 & 0.317 & -0.441 & -0.231 \end{bmatrix} \times \begin{bmatrix} 0.998 \\ 0.825 \\ 0.094 \\ 0.067 \\ 0.196 \\ 0.871 \\ 0.090 \\ 1.000 \end{bmatrix} + \begin{bmatrix} 0.598 \\ -0.899 \\ 0.543 \end{bmatrix} = \begin{bmatrix} -0.848 \\ 0.205 \\ -0.299 \end{bmatrix}$$

정규화된 tn값은 다음과 같이 실제적인 주면 및 선단지지력값으로 환산될 수 있다.

$$t = 0.5 \times (tn+1) \times (\max t - \min t) + \min t =$$

$$0.5 \cdot \left(\begin{bmatrix} -0.848 \\ 0.205 \\ -0.299 \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} \right) \times \left(\begin{bmatrix} 5401 \\ 2742 \\ 6126 \end{bmatrix} - \begin{bmatrix} 154 \\ 158 \\ 360 \end{bmatrix} \right) + \begin{bmatrix} 154 \\ 158 \\ 360 \end{bmatrix} = \begin{bmatrix} 543.7 \\ 1715.1 \\ 2258.8 \end{bmatrix}$$

시험결과로부터 도출된 결과는 주면마찰력, 선단 및 전체지지력값은 각각 529.7, 1785.4 and 2315.2 kN이며, 인공신경망 모델을 통하여 도출된 값은 543.7, 1715.1 and 2258.8 kN이다.

6. 결론

ANN 기법은 현재까지 땅, 옹벽, 지반환경, 지반앵커, 액상화, 말뚝 기초, 직접 기초, 사면안정, 지반물성치, 지반거동, 터널, 지하구조물 등의 다양한 지반공학분야에서

활발히 적용되고 있다. 이와 같은 분야의 대상자반에 대한 수학적 모델링 시에 복잡한 역학적 거동을 명확히 규명하기 어렵기 때문에 수학적으로 단순화하거나 많은 가정사항이 필요하게 된다. 이로 인해 대상자반의 복잡한 거동을 정확히 모사하기 곤란하기 쉽다. 이에 반해 ANN 기법은 입력과 출력의 관계를 자료의 학습을 통하여 모델링하기 때문에, 거동에 대한 가정이나 단순화 과정이 불필요하다. 지반공학 분야는 다른 역학 분야들에 비해 매우 복잡성을 갖고 있기 때문에 ANN 기법이 지반거동을 모델링하는데 활용성이 높으며, 기준은 전통적인 접근방법들에 비해 예측에 있어서 상당한 장점을 갖고 있다.

ANN 기법이 공학문제를 해결할 수 있는 효율적인 방법임에도 불구하고, 최적의 신경망 구조와 설계변수 값들을 결정할 수 있는 기법에 대한 연구는 활발하지 않다. 신경망 구조설계는 어떤 공식화된 설계원칙이 존재하지 않는 분야로서 ANN 전문가의 주관적인 경험적 지식(heuristic)과 많은 수의 신NN 구조를 반복적으로 적용하는 시행착오(trial-error)에 의존하고 있다. 따라서, ANN 구조 설계를 위한 적합한 가이드라인이 제안될 필요성이 있다. 또한 지반공학 분야에서 ANN 기법의 활용도를 증가시키기 위해서는 시료채취, 운반 및 실험자의 미숙 등으로 인해 데이터에 포함된 불확실성을 줄일 수 있는 연구가 필요하다. 이를 통해 지반공학 분야에 적용된 ANN 모델이 보다 현실적인 예측결과들을 제공할 수 있을 것이다.

참고문헌

- USA.
- Agrawal, G.; Chameau, J.A. & Bourdeau, P.L. (1997). Assessing the liquefaction susceptibility at a site based on information from penetration testing. In Artificial neural networks for civil engineers: fundamentals and applications, N. Kartam, I. Flood, J.H. Garrett, (Ed), 185~214, ASCE, ISBN 0784402256, New York, USA
 - Ali, H.E. & Najjar, Y.M. (1998). Neuronet-based approach for assessing liquefaction potential of soils, Transportation Research Record, No. 1633, (January 1998), pp. 3~8, ISSN 0361-1981.
 - Baik, K. (2002). Optimum Driving Method for Steel Pipe Piles in Sands, J. of Civil Engineering, Vol.22, No.1-C, pp. 45~55.
 - Bea, R.G.; Jin, Z.; Valle, C. & Ramos, R. (1999). "Evaluation of reliability of platform pile foundations." J. Geotech. Geoenvir. Eng., ASCE, Vol.125, No.8, (August 1999), pp. 696~704, ISSN 1090-0241
 - Bounds, D.G.; Lloyd, P.J.; Mathew, B.; and Waddell, G. (1988). A multilayer perceptron network for the diagnosis of low back pain, Proc. of 2nd IEEE Annual Int'l Conf. on Neural Networks, pp. 481~489, San Diego, NJ, USA, June 21~24, 1988
 - Broms, B.B. (1964). Lateral resistance of piles in cohesive soils, J. of Soil Mech. Found. Eng., ASCE, Vol.90, No.2, (March 1964), pp. 27~63, ISSN 0038-0741
 - Brucy, F.; Meunier, J.; and Nauroy, J.F. (1991). Behavior of Pile Plug in Sandy Soils during and after Driving, Proc. 23rd Annual Offshore Technology Conf., 1, pp. 145~154.
 - Chan, W.T.; Chow, Y.K. & Liu, L.F. (1995). Neural network: an alternative to pile driving formulas. Comput Geotech, Vol.17, No.2, pp. 135~156, ISSN 0266-352X
 - Chen, B.S.Y. (1994). Profiling stress history of clays

- using piezocone with dual pore pressure measurements, Ph.D thesis, Georgia Institute of Technology, p350.
12. Chester, D.L. (1990). Why two hidden layers are better than one, Proc. of 4th IEEE Annual Int'l Conf. on Neural Networks, pp. 1.265-1.268, Washington, DC, NJ, USA, Jan. 15-19.
13. Cho, S.E. (2009). Probabilistic stability analyses of slopes using the ANN-based response surface, Computers and Geotechnics, Vol.36, pp. 787-797, ISSN 0266-352X
14. Chung, Y. & Kusiak, A. (1994). Grouping parts with a neural network, Journal of Manufacturing Systems, Vol.13, No.4, pp. 262-75
15. Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function, Mathematics of Control Signals and Systems, Vol.2, No.4, pp. 303-314.
16. Das, S.K. & Basudhar, P.K. (2006). Undrained lateral load capacity of piles in clay using artificial neural network, Computers and Geotechnics, Vol.33, pp. 454-459.
17. Ellis G.W.; Yao, C; Zha,o R. & Penumadu, D. (1995). Stress-strain modeling of sands using artificial neural networks, J Geotech Eng, Vol.121, No.5, pp. 429-435, ISSN 1089-3032.
18. Fahlman, S.E. & Lebiere, C. (1990). The cascade correlation learning architecture, In: Advances in Neural Information Processing Systems, H, D.S. Touretzky, (Ed.), Morgan Kaufmann , San Mateo, CA, USA
19. Ferentinou, M.D. & Sakellariou, M.G. (2007). Computational intelligence tools for the prediction of slope performance, Computers and Geotechnics, Vol.34, No.5, pp. 362-384, ISSN 0266-352X
20. Ghaboussi J. & Sidarta, D.E. (1998). New nested adaptive neural networks (NANN) for constitutive modeling, Computers and Geotechnics, Vol.22, No.1, pp. 29-52, ISSN 0266-352X
21. Ghaboussi J.; Pecknold, D.A.; Zhang, M. & Haj-Ali, R.M. (1998). Autoprogressive training of neural network constitutive models, International Journal for Numerical Methods in Engineering, Vol. 42, pp. 105-126, ISSN 0029-5981
22. Goh, A.T.C. (1996). Pile driving records reanalyzed using neural networks, J Geotech Engrg, ASCE, Vol.122, No.6, pp. 492-495, ISSN 1938-6362
23. Goh, A.T.C. (2002). Probabilistic neural network for evaluating seismic liquefaction potential, Canadian Geotechnical Journal, Vol.39, pp. 219-232, ISSN 0008-3674.
24. Goh,A.T.C. (1995). Modeling soil correlations using neural networks. J. Comput. Civil Engrg., ASCE, Vol.9, No.4, pp. 275-278, ISSN 1598-2351
25. Goh, A.T.C.; Kulhawy, F.H. & Chua, C.G. (2005). Bayesian neural network analysis of undrained side resistance of drilled shafts, Journal of Geotechnical and Geoenvironmental Engineering, Vol.131, No.1, pp. 84-93.
26. Gribb, M. M. & Gribb, G. W. (1994). Use of neural networks for hydraulic conductivity determination in unsaturated soil." Proc., 2nd Int. Conf. Ground Water Ecology, , Water Resources Assoc., pp. 155-163
27. Hansen, B. (1961). The ultimate resistance of rigid piles against transversal force, Copenhagen: Danish Geotechnical Institute; 1961, Bulletin No. 12, p. 5-9.
28. Hashash, Y.M.; Jung, S. & Ghaboussi, J. (2004). Numerical implementation of a neural network based material model in finite element analysis, International Journal for Numerical Methods in Engineering, Vol.59, pp. 989-1005
29. Hecht-Nelson, R. (1987). Kolmogorov's mapping neural network existence theorem, Proc. of 1st IEEE Annual Int'l Conf. on Neural Networks, pp. III.11-111.14, San Diego, NJ, USA, June 21-24

30. Javadi, A.A.; Rezania, M. & Mousavi Nezhad, M. (2006). Evaluation of liquefaction induced lateral displacements using genetic programming, *Computers and Geotechnics*, Vol. 33, 222–233, ISSN 0266-352X
31. Juang, C.H. & Chen, C.J. (1999). CPT-based liquefaction evaluation using artificial neural networks, *Computer-Aided Civil and Infrastructure Engineering*, 14(3), 221–229.
32. Kim, Y.S. & Kim, B.K. (2006). Use of artificial neural networks in the prediction of liquefaction resistance of sands, *Journal of Geotechnical and Geoenvironmental Engineering*, Vol.132, No.11, pp. 1502–1504.
33. Kraft, L.M., Jr. (1991). Performance of Axially Loaded Pipe Piles in Sand, *J. Geotech. Engrg.*, 117(2), pp. 272–296.
34. Kusiak, A. & Lee, H. (1996). Neural computing based design of components for cellular manufacturing, *International Journal of Production Research*, Vol.34, No.7, pp. 1777–1790
35. Lawrence, J. (1994). *Introduction to Neural Networks: Design, Theory, and Applications*, 6th ed. Nevada City, CA: California Scientific Software.
36. Lawrence, J. & Fredrickson, J. (1998). *BrainMaker User's Guide and Reference Manual*, 7th Ed. Nevada City, CA: California Scientific Software.
37. Lee, C. & Sterling, R. (1992). Identifying probable failure modes for underground openings using a neural network, *Int. Journal of Rock Mechanics and Mining Science & Geomechanics Abstracts*, Vol.29, No. 1, pp. 49–67
38. Lee, I.M. & Lee, J.H. (1996). Prediction of pile bearing capacity using artificial neural networks, *Comput Geotech*, Vo.18, No.3, pp. 189–200, ISSN 0266-352X
39. Marchandani, G. & Cao, W. (1989). On hidden nodes for neural nets, *IEEE Trans. on Circuits and Systems*, Vol.36, No.5, pp. 661–664
40. Meyerhof, G.G. (1976). Bearing capacity and settlement of pile foundations, *J. Geotech Engrg. ASCE*, Vol.102, No.3, pp. 196–228.
41. Millar, D.L. & Calderbank, P.A. (1995). On the investigation of a multi-layer feedforward neural network model of rock deformability behavior, *International congress on rock mechanics*, pp. 933–938, Tokyo, Japan.
42. Moon, H.K.; Na, S.M. & Lee, C.W. (1995). Artificial neural-network integrated with expert-system for preliminary design of tunnels and slopes, *Proc. 8th Int. Congress on Rock Mechanics*, pp. 901–905, Balkema.
43. Najjar, Y.M.; Basheer, I.A. & McReynolds, R. (1996). Neural modeling of Kansan soil swelling, *Transportation Research Record No. 1526*, pp. 14–19
44. Najjar, Y.M. & Basheer, I.A. (1996). Utilizing computational neural networks for evaluating the permeability of compacted clay liners, *Geotechnical and Geological Engineering*, Vol.14, pp. 193–221.
45. Najjar, Y.M. & Ali, H.E. (1998). CPT-based liquefaction potential assessment: A neuronet approach, *Geotechnical Special Publication*, ASCE, Vol.1, pp. 542–553.
46. Najjar, Y.M. & Ali, H.E. (1999). On the use of neuronets for simulating the stress-strain behavior of soils, *7th International symposium on numerical models in geomechanics*, pp. 657–662, Austria
47. Nawari N.O.; Liang, R. & Nusairat, J. (1999). Artificial intelligence techniques for the design and analysis of deep foundations, *Electron. J. Geotech. Eng.*, <http://geotech.civeng.okstate.edu/ejge/ppr9909/index.html>.
48. Neupane, K.M. & Achet, S.H. (2004). Use of backpropagation neural network for landslide monitoring: a case study in the higher Himalaya,

- Engineering Geology, Vol.74, pp. 213–226
49. Ni, S.H.; Lu, P.C. & Juang, C.H. (1995). A fuzzy neural network approach to evaluation of slope failure potential, Journal of Microcomputers in Civil Engineering, Vol.11, pp. 59–66.
50. Ozer, M.; Isik, N.S. & Orhan, M. (2008). Statistical and neural network assessment of the compression index of clay-bearing soils, Bull Eng Geol Environ, Vol.67, pp. 537–545
51. Öztürk N. (2003). Use of genetic algorithm to design optimal neural network structure, Engineering Computations, Vol.20, No.8, pp. 979–997
52. Park, H.I.; Keon, G.C. & Lee, S.R. (2009). Prediction of Resilient Modulus of Granular Subgrade Soils and Subbase Materials Based on Artificial Neural Network, Road Materials and Pavement Design, Vol.10, No. 3, pp. 647–665.
53. Park, H.I. & Cho, C.H. (2010). Neural Network Model for Predicting the Resistance of Driven Piles J. Marine Georesources and Geotechnology, In Press
54. Park, H.I. & Lee, S.R. (2010). Evaluation of the compression index of soils using an artificial neural network Computers and Geotechnics, Accepted
55. Park, H.I. & Kim, Y.T. (2010). Prediction of Strength of Reinforced Lightweight Soil Using an Artificial Neural Network, Engineering Computation, In press
56. Penumadu, D. & Zhao, R. (1999). Triaxial compression behavior of sand and gravel using artificial neural networks (ANN), Comput Geotech, Vol.24, pp. 207?30, ISSN 0266-352X
57. Penumadu, D.; Jin-Nan, L.; Chameau, J.L.; Arumugam, S. (1994). Rate dependent behavior of clays using neural networks, Proceedings of the 13th conference of international society of soil mechanics and foundation engineering, pp. 1445–1448, New Delhi
58. Provenzano, P.; Ferlisi, S. & Musso, A. (2004). Interpretation of a model footing response through an adaptive neural fuzzy inference system, Computers and Geotechnics, Vol.31, pp. 251–266
59. Romero, S. & Pamukcu, S. (1996). Characterization of granular material by low strain dynamic excitation and ANN, Geotechnical Special Publication, ASTM-ASCE, Vol.58, No.2, pp. 1134–1148.
60. Rumelhart, D.E.; Hinton, G. & Williams, R. (1986). Learning representation by back-propagation errors. Nature, Vol.32, No.9, pp. 533–536.
61. Sakellariou, M.G. & Ferentinou, M.D. (2005). A study of slope stability prediction using neural networks, Geotechnical and Geological Engineering Vol.23, pp. 419–445
62. Shahin, M.A.; Jaksa, M.B. & Maier, H.R. (2005). Stochastic simulation of settlement prediction of shallow foundations based on a deterministic artificial neural network model, Proc. Int. Congress on Modelling and Simulation, MODSIM 2005, pp. 73–78, Melbourne (Australia)
63. Shi, J.J. (2000). Reducing predicton error by transforming input data for neural networks, Journal of Computing in Civil Engineering, Vol.14, No.2, pp. 109–116.
64. Shin, H.S. & Pande, G.N. (2000). On self-learning finite element codes based on monitored response of structures, Computers and Geotechnics, Vol.27, pp. 161?178, ISSN 0266-352X
65. Sidarta, D.E. & Ghaboussi, J. (1998). Constitutive modeling of geomaterials from non-uniform material tests, Computers and Geotechnics, Vol.22, No.1, pp. 53–71, ISSN 0266-352X
66. Sivakugan, N.; Eckersley, J.D. & Li, H. (1998). Settlement predictions using neural networks, Australian Civil Engineering Transactions, CE40, pp. 49–52.
67. Swingler, K. (1996). Applying Neural Networks: A

- Practical Guide. San Francisco: Morgan Kaufmann Publishers.
68. Teh, C.I.; Wong, K.S.; Goh, A.T.C. & Jaritngam, S. (1997). Prediction of pile capacity using neural networks, *J Comput Civil Eng., ASCE*, Vol.11, No.2, pp. 129–38
69. Ural, D.N. & Saka, H. (1998). Liquefaction assessment by neural networks, *Electronic Journal of Geotechnical Engineering*, <http://geotech.civeng.okstate.edu/ejge/prp9803/index.html>.
70. Wang, H.B.; Xu, W.Y. & Xu, R.C. (2005) Slope stability evaluation using Back Propagation Neural Networks, *Engineering Geology*, Vol.80, pp. 302–315, ISSN 0013-7952
71. Yoo, C. & Kim, J.-M. (2007). Tunneling performance prediction using an integrated GIS and neural network, *Computers and Geotechnics*, Vol.34, pp. 19–30, ISSN 0266-352X
72. Zhao, H.-B. (2007). Slope reliability analysis using a support vector machine, *Computers and Geotechnics*, in press.
73. Zhu, J.H.; Zaman, M.M. & Anderson, A.A. (1998). Modeling of shearing behavior of residual soil with recurrent neural network, *Int J Numer Anal Meth Geomech*, Vol.22, pp. 671–87

