

최적의 인공신경망 구조 설계를 통한 지반 물성치 추정

Evaluation of Geotechnical Parameters Based on the Design of Optimal Neural Network Structure

박 현 일¹ Park, Hyun-Il

권 기 철² Kweon, Gi-Chul

황 대 진³ Hwang, Dae-Jin

이 승 래⁴ Lee, Seung-Rac

Abstract

This paper proposes a selection methodology composed of neural network (NN) and genetic algorithm (GA) to design optimal NN structure. We combine the characteristics of GA and NN to reduce the computational complexity of artificial intelligence applications and increase the precision of NN' prediction in the design of NN structure. Genetic selection approach of design parameters of NN is introduced to obtain optimal NN structure. Analyzed results for geotechnical problems are given to evaluate the performance of the proposed hybrid methodology.

요 지

본 연구에서는 최적의 인공신경망 구조 설계를 위하여 인공신경망과 유전자 알고리즘이 결합된 신경망구조 설계기법이 제안되었다. 저자들은 신경망 구조설계시 인공지능 적용에 따른 계산적인 복잡함을 줄이며, 신경망에 의한 예측의 정확성을 증가시키기 위하여 인공신경망과 유전자 알고리즘의 특성을 조합하였다. 최적의 신경망 구조를 얻기 위하여 신경망 구조의 설계변수들에 대한 유전자 선별기법을 적용하였다. 제안된 합성 기법의 적용성을 평가하기 위하여 여러 지반공학 물성치들을 추정하는 해석에 적용되었다.

Keywords : Artificial neural network, Genetic algorithm, Geotechnical parameter, Hybrid methodology

1. 서 론

신경망(Neural Network, NN)은 인간 뇌의 처리과정을 모사하기 위해 개발된 정보처리방법으로서, 국내외 지반공학분야에도 활발히 적용되고 있다(김병탁 등, 2001; 이성진 등 2002; 황명기 등, 2003; 박현일 등, 2005; Lee & Lee, 1996; Rahman 등, 2001). 인공신경망이 공학문제를 해결할 수 있는 효율적인 방법임에도 불구하고, 최적의 신경망 구조와 설계변수 값들을 결정

할 수 있는 기법에 대한 연구는 활발하지 않다. 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.

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

1 정회원, 삼성물산(주) 건설부문 기술연구소, 선임연구원 (Member, Senior Researcher, R & D Team, Samsung Corporation, gomdori7@empal.com)

2 정회원, 동의대학교, 토목공학과, 조교수 (Member, Assistant Prof., Dept. of Civil. Engrg., Univ. of Dong-Eui)

3 정회원, 삼성물산(주) 건설부문 기술연구소, 수석연구원 (Member, Principal Researcher, R & D Team, Samsung Corporation)

4 정회원, 한국과학기술원, 건설 및 환경공학과, 정교수 (Member, Prof., Dept. of Civil & Envir. Engrg., KAIST)

* 본 논문에 대한 토의를 원하는 회원은 2006년 5월 31일까지 그 내용을 학회로 보내주시기 바랍니다. 저자의 검토 내용과 함께 논문집에 게재하여 드립니다.

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(박찬란, 1998; 홍동현, 1999). 따라서, 주어진 문제에 적합한 최적의 은닉층의 노드 수가 신경망의 성능에 매우 큰 영향을 미칠 수 있다.

유전자 알고리즘(Genetic Algorithm, GA)이 인공지능망 기법과 접목되어 다양한 분야에서 적용되고 있다. Huang과 Liu(1997)는 변형된 패턴을 효율적으로 인식하기 위하여 GA와 NN으로 구성된 패턴인식시스템을 제안하였으며, 탐색과정과 계산시간에 대해 장점을 갖는다고 보고하였다. Marcellin(1999)는 헬리콥터 꼬리날개의 구조 최적화를 위하여 GA와 NN에 근거한 방법을 적용하였다. Mok 등(2001)은 분사 주형(injection moulding)에 필요한 초기처리변수들의 결정을 위해 GA와 NN에 근거한 방법을 제안하였다. NN은 변수들간의 관계를 모델링하는 데에 적용되었고, GA는 NN에 적용되는 분사 주형의 처리변수들을 최적화하는데 적용되었다. Yu와 Liang(2001)는 직업소개소의 일정관리 문제를 해결하기 위하여 GA와 NN이 결합된 방법을 제안하였다. NN의 계산능력과 GA의 효율적인 탐색능력이 조합됨으로 변수들이 복잡하게 얽혀있는 일정문제를 충분히 해결할 수 있다고 보고하였다. 기존의 연구내용을 살펴보면, 신경망 구조에 필요한 설계변수들 가운데 입력변수 혹은 신경망 구조의 일부 변수들에 대한 최적화를 수행하였다. 이 경우에 신경망의 예측정도는 개선될 수 있지만, 신경망 구조가 복잡해짐으로 인해 유발되는 과적합을 피하기 어려운 단점을 갖고 있다.

본 연구에서는 복잡한 공학문제에 대하여 신경망 구조의 복잡함을 피하면서, 동시에 예측에 대한 정확성이 높은 최적의 신경망 구조를 탐색할 수 있는 설계기법을 제안하고자 하였다. 연구내용은 다음과 같이 간략히 정리 될 수 있다. 첫째, 입력층의 노드수 및 입력변수 조합, 은닉층의 수 및 각 은닉층의 노드수, 각 층에 적용되는 전이함수의 형태와 같은 인공지능망 구조 설계에 필요한 대부분의 설계변수값들을 유전자 알고리즘에 근거하여 최적화하고자 하였다. 둘째, 신경망의 출력값과 예측값과의 오차로부터 얻어진 오차(error)함수와 신경망 구조의 총 노드수와 노드간의 연결갯수로 정의되는 구조 복잡도함수를 함께 사용하여 목적함수를 구성하였

다. 셋째, 여러 지반공학문제에 대하여 적용함으로써 개발된 기법을 검증하고자 하였다.

2. 신경망 구조

NN은 뉴런(neuron) 혹은 노드(node)로 불리는 단위 처리개체(simple processing unit)로 이루어져 있다. 각 노드는 입력신호에 대한 연산을 수행한 후 연결고리(connection)들을 통하여 다음 뉴런에 정보를 전달하는 처리개체이다. 여기서, 연결고리는 하나의 노드로부터 다음 노드로의 정보 흐름을 의미한다. 가중치는 연결고리를 통하여 할당되며, 결과적으로 가중치가 고려된 입력신호값이 다음 뉴런에 전달된다. 일반적으로, NN은 그림 1에 나타난 바와 같이 입력층(input layer), 은닉층(hidded layer), 출력층(output layer)으로 구성된다. 여기서, 입력층에서 노드들은 해석에서 고려되어야 하는 입력 설계변수이고, 반면에 출력층의 노드는 목표 출력값을 의미한다. 각층의 노드들은 전이함수(transfer function) 혹은 활성화함수(activation function)를 사용하여 가중치 및 바이어스(bias)가 고려된 합인 형태로 표현된다. 가장 일반적으로 사용되는 전이함수는 선형(linear), 시그모이드(logsig) 및 쌍곡탄젠트(tansig) 함수이다. 따라서, 신경망 구조 설계 시에 입력층-은닉층, 은닉층-은닉층, 은닉층-출력층에 적합한 전이함수의 조합이 적용되어야 한다.

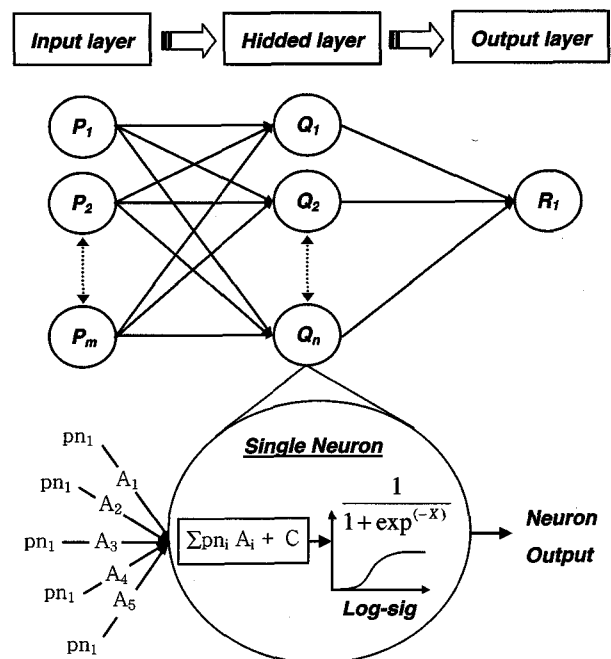


그림 1. 인공지능망 구조의 개략도

NN 구조를 설계하기 위해서는 최종 출력값에 영향을 미치는 중요 물성치들로 구성된 입력층이 선정되어야 하며, 또한 은닉층의 갯수 및 각 은닉층의 노드수 및 각 층을 연결하는 전이함수 형태가 적합하게 결정되어야 한다. 일반적인 NN 구조설계 과정에서는 먼저 적은 입력층의 노드 수 및 은닉층의 노드 수를 갖는 가장 간단한 구조부터 검토하기 시작한다. 이후에 입력변수와 출력의 관련성을 탐색하기 위하여 점차 각층의 노드수를 증가시킨다(Ozturk와 Ozturk, 2001).

3. GA를 사용한 NN 구조의 설계

GA는 전통적인 최적화 기법으로 해결하기 어려운 다차원 최적화 문제에 적합한 방법으로, 임의적으로 개체군을 형성하여 반복적인 유전적 처리과정을 거쳐 최적의 개체를 탐색하게 된다(Glodberg, 1989). 유전자들(chromosomes)로 구성된 모집단이 무작위로 생성되어 교배(crossover) 및 돌연변이(mutation)와 같은 유전자 처리과정(genetic operator)을 통하여 보다 해에 근접한 개체군으로 발전된다는 개념이다. 본 연구에서 GA는 최적의 NN 구조 탐색을 위하여 다음과 같은 과정을 따른다(그림 2 참고). 임의적으로 생성된 개체군에서 각 개체는 NN 구조에 필요한 설계변수에 대한 정보를 갖고 있으므로, 각 개체에 대한 NN 구조의 목적 함수를 계산할 수 있다. 이후에 각 개체들에 대한 유전자 처리과정을 거치게 되며, 다음 세대에 필요한 개체군을 생성하게 된다. 이러한 유전적 처리에 대한 반복과정을 거쳐서 최적의 신경망 구조를 갖는 개체를 탐색하게 된다. 유전자 처리과정에 관한 세부적인 내용은 다음과 같다.

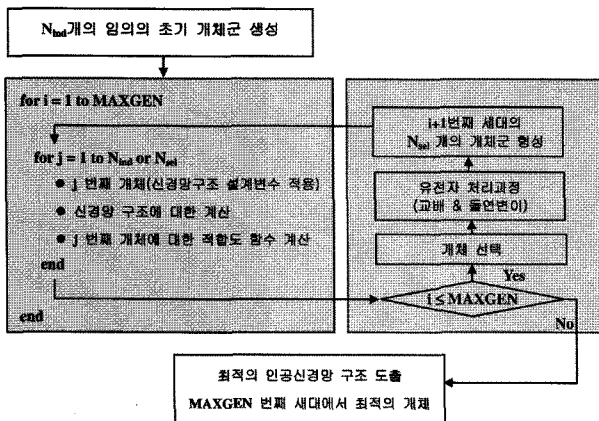


그림 2. 최적의 인공신경망 탐색 과정에 대한 흐름도


3.1 초기 개체군의 생성

설계변수를 표현하기 위하여 이진수를 사용하였으며, 각 개체에는 NN 구조에 필요한 설계변수정보들이 포함되어 있다. 예로써, 다음과 같은 설계조건이 적용되었을 경우, 생성가능한 임의의 한 개체가 아래 그림 3에 나타나 있다.

- 사용가능한 총 입력변수 개수, $N_{ini} = 5$
- 사용가능한 총 은닉층 수 $N_{HL} = 2$
- 각 은닉층에서 사용가능한 은닉층 최대 노드 수 $N_{HN} = 15$
- 입력층-은닉층 및 은닉층-출력층에 적용되는 전이함수

개체는 총 15개의 이진수로 이루어졌으며, 5번째 칸까지 입력 층에 대한 정보를 포함하고 있다. 이진수 값이 1인 경우에는 해당 입력변수가 사용되고, 0인 경우에는 사용되지 않는 것을 의미한다. 본 개체에서 3번째 및 5번째 입력변수는 사용되지 않으므로, 입력층의 총 노드수는 3개이다. 또한 은닉층 정보는 이후의 다섯 개의 이진수들에 포함되어 있다. 은닉층 노드수의 최소 및 최대값은 각각 1과 15이다. 은닉층 정보를 나타내는 첫번째 이진수 값은 0인 경우 한개의 은닉층이 적용되며, 1인 경우 두개의 은닉층이 적용된다. 여기서, 두개의 은닉층이 적용된 경우, 동일한 값의 은닉층의 노드수가 적용되는 것으로 가정하였다. 본 연구에서 q 개의 개체군을 사용할 경우 다음 식 (1)과 같은 개체수의 모집단이 생성된다.

$$\begin{aligned}
 P^1 &= 1011 \dots 010 \\
 P^2 &= 0010 \dots 011 \\
 &= \vdots \\
 P^q &= 1101 \dots 101
 \end{aligned} \tag{1}$$



- 입력층 노드수, $N_{in} = 3$ (세번째 및 5번째 입력자료는 입력층에 사용되지 않음)
- 은닉층 개수 $N_{hl} = 1$ (0일 경우 $N_{hl} = 1$, 1일 경우 $N_{hl} = 2$)
- 은닉층 노드수, $N_{hn} = 2^3 \times 1 + 2^2 \times 0 + 2^1 \times 1 + 2^0 \times 0 = 10$
- 전이함수 정보 : 5개의 이진수 조합을 이용하여 입력층-은닉층, 은닉층-은닉층 및 은닉층-출력층에 적용되는 전이함수 조합을 결정(전이함수 : logsig, tansig, linear)

그림 3. 개체에 포함된 인공신경망 설계정보

3.2 유전자 선택 및 처리과정

각 개체의 적합도에 근거하여 유전적 처리과정(genetic manipulation process)에 사용될 개체들을 선별하게 된다. 동일한 개체수를 갖는 다음 세대를 생산하기 위하여 개체들이 각 적합도에 근거하여 선정되므로, 이전 세대보다 평균적으로 해에 보다 근접된 개체들로 구성될 수 있다. 이를 위해 여러 선택방법들이 개발되어 있으며, 본 연구에서는 순위적합선별법이 사용되었다(Bäck와 Hoffmeister, 1991). 순위적합선별법에서는 개체들이 목적함수의 순위에 따라 정렬되는데, 각 개체의 적합도는 실질적인 목적함수의 값보다는 개체군의 순위로서 표현된다. 본 연구에서는 전체 개체수의 90%의 개체들이 유전자 처리과정을 위해 선별되었다.

선택된 개체들에 대하여 교배와 돌연변이에 근거한 유전자 처리과정을 거쳐서 다음 세대에 적용될 수 있는 개체들이 생성된다. 개체군에서 교배를 위하여 무작위로 두 개체(parents)가 선택된다. 선택된 두 개체(parents)는 다음 세대에 적용될 새로운 개체(offspring)를 생산하기 위하여 교배된다. 그림 4에 나타난 바와 같이 본 연구에서 적용된 삼 점절 교배처리를 통하여 두 개의 새로운 개체(offspring)가 생성된다. 여기서, i, j 및 k 절점은 무작위로 설정된다.

다른 영역에 존재하는 해에 가장 근접한 개체가 현 세대의 개체군에 포함되어 있지 않은 경우에는 재생산 과정을 거치더라도 해에 보다 근접한 개체로 발전될 수 있는 가능성은 매우 낮다. 이 경우에 돌연변이 과정을 통하여 개체군과 다른 영역에 존재하는 개체를 생성시킴으로써 유전자 알고리즘의 조기 수렴을 방지할 수 있다. 본 연구에서는 돌연변이 발생확률($P_{mut} = 0.005$)에 해당되는 임의의 개체의 임의의 순번에 해당하는 이진 수 값이 바뀌도록 적용하였다.

3.3 목적함수 정의

본 연구에서 i 번째 개체에 대한 목적함수, $ObjV(i)$ 는




그림 4. 교배에 의한 유전자 처리과정

출력값과 예측값의 차이에 근거한 오차(error)함수, E_i 와 신경망 구조의 복잡도에 근거한 벌점(penalty)함수, P_i 를 함께 적용하여 다음과 같이 정의되었다.

$$ObjV(i) = E_i + P_i \quad (2)$$

먼저, 오차함수, E_i 는 각 개체의 설계정보로 이루어진 신경망의 출력값(t)과 목표값(T)과의 차이를 이용하여 식 (2)과 같이 가정하였다.

$$E_i = \left(\sum_{k=1}^{N_{mea}} \frac{|T_k - t_k|}{T_{max}} \right) / N_{mea} \quad (3)$$

여기서, N_{mea} = 계측자료의 총 개수, T_{max} = 출력값 가운데 최대치, T_k = k 번째 출력값, t_k = k 번째 예측값을 의미한다. 인공신경망 구조가 복잡해질수록 오차함수 값은 감소할 가능성이 증가하지만, 과적응(overfitting)으로 인하여 일반성이 떨어질 수 있으므로, 복잡한 인공신경망을 피하기 위하여 벌점함수, P_i 를 다음과 같이 정의하였다.

$$P_i = \alpha \cdot \left(\frac{N_n^i / N_{max} + CW^i / CW_{max}}{2} \right) \quad (4)$$

여기서, N_n^i = i 번째 개체에서 사용되는 총 노드 개수, N_{max} = 대상 문제에서 인공신경망 구조가 가질 수 있는 최대 노드 수, CW^i = i 번째 개체에서 사용되는 연결강도의 총 개수, CW_{max} = 대상 문제에서 인공신경망 구조가 가질 수 있는 최대 연결강도 개수이며, $\alpha = 0.01$ 로 가정되었다.


4. 예제해석

인공신경망이 적용되었던 여러 지반공학 문제들에 대하여 본 연구에서 제안된 신경망구조 탐색기법을 적용하여 기법의 타당성을 검토하고자 하였다. 기존 연구에서 저지들에 의해 제안된 신경망 모델(ANN 모델)과 GA-NN 기법에 근거한 신경망구조 최적화 과정을 통해 얻어진 신경망 모델(GA-NN 모델)이 서로 비교되었다.

4.1 Suction Cassion의 인발력 추정(Rahman 등, 2001)

Rahman 등(2001)은 Suction Cassion의 인발력을 산정하기 위하여 인공신경망에 근거한 인발력 추정식을 제

안하였다. 문헌들에 수록되어 있는 원심모형(centrifuge) 시험 및 모형 시험결과들을 포함한 총 60개의 시험자료들이 해석에 사용되었다. 그림 5에는 Suction Cassion에 대한 개략도가 나타나 있다. 입력자료로는 케이슨의 형상계수(L/d), 케이슨이 설치되는 지반의 비배수전단강도(s_u), 지반의 투수계수와 관련된 하중재하계수(T_k), 체인력의 작용 각도(θ), 케이슨에 가해진 힘의 작용지점에 대한 상대적 깊이(D/L)이며, 출력값은 인발력(p)이



L : the length of the caisson;
d : the diameter of the caisson in plan;
D : the depth of the load application point from the soil surface;
P : load applied to caisson;
 θ : inclined angle;

그림 5. Suction Cassion의 개략도

표 1. GA-NN 기법의 적용을 위한 설계조건

	변수	값
GA 관련변수	세대당 개체수, N_{mut}	400
	총 세대 수, $MAXGEN$	40
	유전자 처리를 위한 선별 개체수, N_{sel}	$400 \times 0.9 = 360$
	돌연변이 확률, P_{mut}	0.005
NN 관련변수	최대 입력변수 개수, IL_{max}	11
	은닉층 최대 개수, HL_{max}	2
	은닉층 최대 노드 수, NH_{max}	16

표 2. 각 방법들로부터 얻어진 NN 구조의 설계변수 값들


대상 예제	적용방법	입력층 노드수	은닉층 노드수	전이함수		R^2	
				I-H	H-O	학습	검증
케이슨 지지력 (Rahman 등, 2001)	ANN	5	10	tansig	logsig	0.970	0.971
	GA-NN	2	7	tansig	linear	0.984	0.982
노상토 탄성계수 (박현일 등, 2005)	ANN	5	4	logsig	linear	0.969	0.958
	GA-NN	4	7	logsig	tansig	0.975	0.964
보조기층 탄성계수 (박현일 등, 2005)	ANN	3	5	logsig	linear	0.988	0.921
	GA-NN	4	5	tansig	linear	0.993	0.959
오염저반투수계수 (황명기 등, 2003)	ANN	5	5	tansig	linear	0.912	0.986
	GA-NN	4	4	tansig	linear	0.990	0.990

* I-H는 입력층과 은닉층을 연결하는 전이함수를 의미하고, H-O는 은닉층과 출력층을 연결하는 전이함수를 의미한다. 전이함수의 경우 logsig, tansig 및 linear는 각각 시그모이드, 쌍곡탄젠트 및 선형을 의미한다.

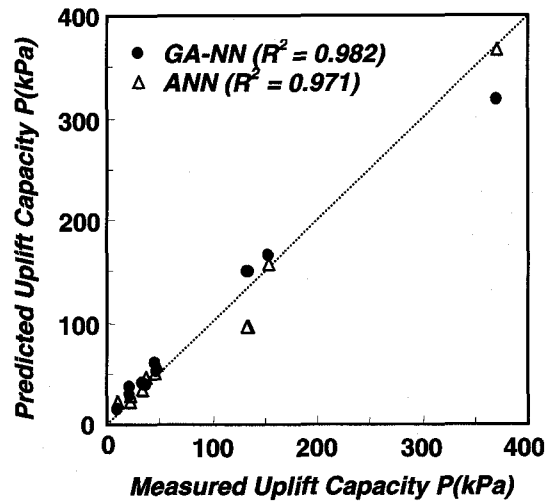
다. 입력층-은닉층 및 은닉층-출력층에 적용된 전이함수는 쌍곡탄젠트 함수와 시그모이드 함수이다. 은닉층의 노드수는 6-12로 변화시키며 해석을 수행한 후에 최종적으로 12개로 결정하였다.

GA-NN 기법을 적용하기 위해 필요한 초기 설계조건이 표 1에 정리되어 있으며, 설계변수 값들이 다음과 같이 구해졌다. GA-NN 기법을 사용하여 구해진 신경망 구조의 설계변수값들이 표 2에 정리되어 있다. ANN 모델에서 사용된 3개의 입력변수들이 GA/NN 기법에 근거한 최적화 과정을 거쳐서 제외되었다. 은닉층 갯수는 ANN 모델과 동일하며, 은닉층 노드수는 7개로 ANN 모델보다 작게 구해졌다. 입력층-은닉층 및 은닉층-출력층에 적용된 전이함수는 쌍곡탄젠트 함수와 선형 함수로 구해졌다.

그림 5에는 Rahman 등(2001)이 제안한 ANN 모델과 GA-NN 모델의 예측정도가 함께 비교되어 있다. 최적화 과정을 통해 세 개의 입력변수, GA-NN 기법으로부터 얻어진 신경망 구조를 적용할 경우 D/L 와 T_k 및 θ 가 입력변수에서 제외되었음에도 불구하고 훈련 및 검증 과정에서 상관관계는 더욱 개선되었음을 알 수 있다. 이는 주어진 자료에서 설계변수 D/L 와 T_k 및 θ 가 인발력에 미치는 영향이 반영되지 않았음을 의미한다. 따라서, 주어진 자료들만으로 위 세 변수들의 영향이 실제적으로 반영된 ANN 모델을 도출하기 어려우며, 이들 변수들의 영향이 충분히 고려된 추가적인 자료가 학습에 적용되어야 함을 의미한다. 그림 7에서는 구해진 GA-NN 모델에서 은닉층 노드수와 전이함수의 변화에 따른 상관관계수값이 구해져 있다. 제안된 GA-NN 모델의 설계변수들 가운데 은닉층 노드수와 전이함수 형태만을 변화시켰을 경우, 은닉층 노드수가 증가함에 따라 6 혹은 7



(a) 훈련



(b) 검증

그림 6. Suction Cassion의 인발력에 대한 ANN 모델과 GA-NN 모델의 해석결과 비교




그림 7. Suction Cassion에 대한 GA-NN 모델의 설계변수 변동시 상관계수값의 변화

보다 큰 경우에는 상관관계는 더 이상 개선되지 않았다. 은닉층 노드수의 증가는 신경망구조는 더욱 복잡하게 되어 목적함수 값의 증가를 유발하므로, 최종적인 은닉층 노드수는 7로 구해졌음을 알 수 있다. 따라서, 은닉층 노드수 7인 경우에 입력층-은닉층 및 은닉층-출력층에 대하여 가장 좋은 상관계수값을 갖는 쌍곡탄젠트 함수와 선형 함수로 구성된 전이함수 조합이 최종적으로 선택되었음을 알 수 있다.

4.2 노상토 및 보조기층에 대한 탄성계수 추정(박현일 등, 2005)

기본적인 실내시험 및 설계조건으로부터 구해진 노상토 및 보조기층에 대한 입력자료는 최적함수비(OMC), 최대건조단위중량(γ_{dmax}), 95% 통과 직경(D_{95}), 균등계수(C_u), 곡률계수(C_c), 4번체 통과량(#4), 200번체 통과

량(#200), 소성지수(PI), 구속응력(σ_0), 축차응력(σ_d), 체적응력(σ_v)으로 총 11개이며, 출력자료에 해당하는 노상토 및 보조기층의 탄성계수 값은 정적반복 삼축압축시험을 통하여 구해졌다. 따라서, 정적반복 삼축압축시험과 같은 복잡한 시험과정을 거치지 않고, 기본적인 실내시험 자료만으로 탄성계수값을 추정하고자 인공신경망이 적용되었다. 노상토와 보조기층에 대하여 각각 236 및 164개의 시험자료가 훈련과정에 적용되었고, 각각 36 및 26개의 시험자료가 검증과정에 사용되었다.

박현일 등(2005)은 시행착오과정을 따르는 일반적인 신경망 구조 추정방법인 NN방법을 통하여 다음과 같은 신경망 구조를 제안하였다. 노상토의 경우 입력노드 5개, 은닉노드 4개 및 출력 노드 1개를 갖는 신경망구조(5×4×1)이며, 보조기층의 경우 입력 유니트 3개, 은닉 유니트 5개 및 출력 유니트 1개의 노드를 갖는 신경망구조(3×5×1)이다. 각 층을 연결하는 전이함수의 경우, 입력층-은닉층 및 은닉층-출력층에 대하여 시그모이드 함수와 선형 함수가 각각 선택되었다.

본 연구에서 GA-NN 기법에 근거한 최적화 과정을 거쳐서 GA-NN 모델이 도출되었으며, ANN 모델과 서로 비교되었다. 최적화 과정에 필요한 설계조건은 표 1과 동일하며, 최대 입력변수 개수, IL_{max} 는 11개이다. 표 2 및 3에는 GA-NN방법과 NN 방법으로부터 각각 산출된 신경망구조의 설계인자들이 서로 비교되어 있다. 표 3에서 입력변수들 중에 출력값인 탄성계수 값에 가장 큰 영향을 미치는 것으로 알려진 구속응력(σ_0) 값은 두 모델에서 공통적으로 입력변수로 선택되었지만, 다른

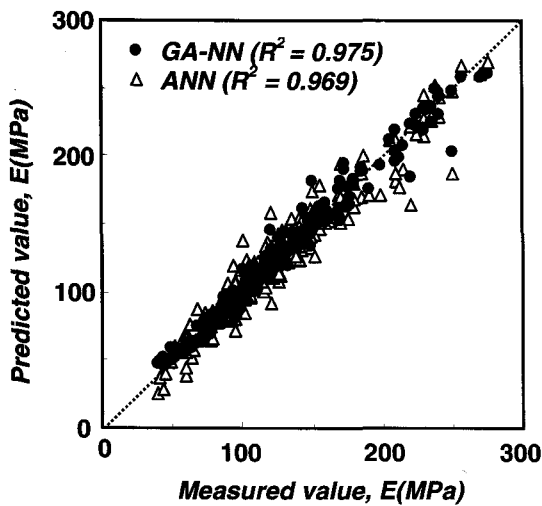
입력변수들의 경우에는 차이를 보이고 있다. 본 예제와 같이 입력변수들과 출력값과의 관계가 명확하지 않고, 동시에 입력변수 후보의 수가 비교적 많은 경우, 반복적인 신경망 구조의 적용에 근거한 시행착오과정으로는 적합한 입력변수 조합을 안정성 있게 도출하기 쉽지 않음을 알 수 있다. 이는 NN 구조에서 출력값과 예측값의

상관관계가 입력변수를 포함한 여러 NN 구조 설계변수에 의존해서 복잡하게 영향을 받기 때문이다.

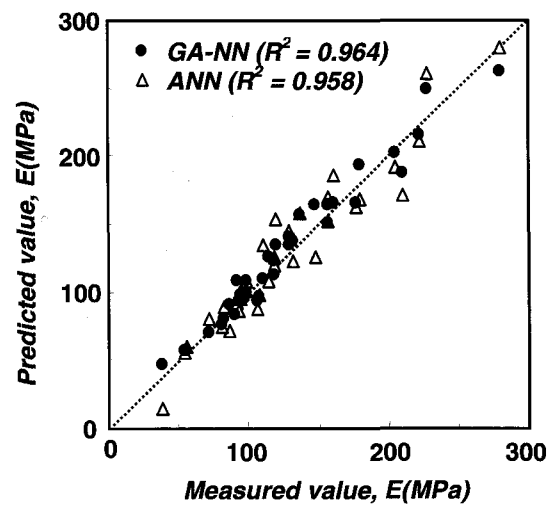
그림 8과 9에는 훈련 및 검증과정에서 두 모델로부터 얻어진 예측값과 측정값과의 상관관계가 나타나 있으며, GA-NN 모델의 신경망 구조를 적용할 경우에 상관관계가 보다 개선됨을 알 수 있다. 그림 10과 11에서는

표 3. NN 방법과 GA-NN 방법에 의해 선택된 입력변수

		입력자료										
		OMC	γ_{dmax}	D_{95}	C_u	C_c	#4	#200	PI	σ_0	σ_d	σ_v
노상토	NN	×	○	×	○	×	×	○	×	○	○	×
	GA-NN	○	×	×	×	×	×	○	×	○	×	○
보조기층	NN	×	○	×	○	×	×	×	×	○	×	×
	GA-NN	×	×	×	○	×	○	×	×	○	×	○




(a) 훈련

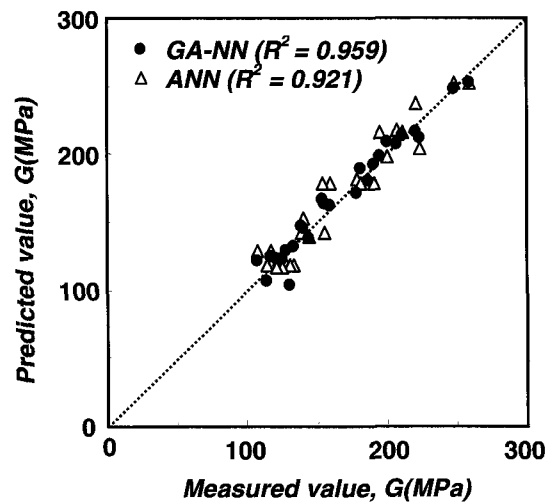


(b) 검증

그림 8. 노상토의 탄성계수에 대한 ANN 모델과 GA-NN 모델의 해석결과 비교



(a) 훈련



(b) 검증

그림 9. 보조기층의 탄성계수에 대한 ANN 모델과 GA-NN 모델의 해석결과 비교




그림 10. 노상토의 탄성계수에 대한 GA-NN 모델의 설계변수 변동시 상관계수값의 변화




그림 11. 보조기층의 탄성계수에 대한 GA-NN 모델의 설계변수 변동시 상관계수값의 변화


구해진 GA-NN 모델의 설계 변수들 가운데 은닉층 노드수와 전이함수만의 변화에 따른 상관계수값이 구해져 있다. 은닉층 노드수의 증가는 신경망구조는 더욱 복잡하게 되어 목적함수 값의 증가를 유발하므로, 최종적

인 은닉층 노드수는 표 2에 나타난 바와 같이 구해졌음을 알 수 있다. 따라서, 선택된 은닉층 노드수에서 입력층 은닉층 및 은닉층-출력층에 대하여 가장 좋은 상관계수값을 갖는 쌍곡탄젠트 함수와 선형 함수의 전이함수 조합이 최종적으로 선택되었다.

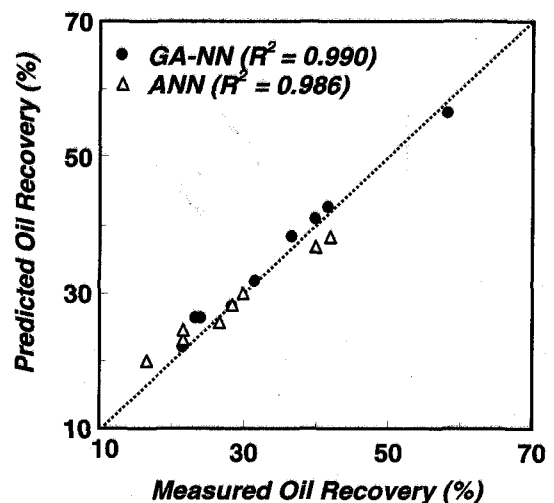
4.3 토양수세법의 효율성 추정(황명기 등, 2003)

오염된 지반의 정화 및 복원기술인 토양수세법(soil flushing)은 계면활성제 등과 같은 용액을 흙에 통과시킴으로써 지반의 오염물질을 추출하는 기법이다. 이에 대한 연구의 일환으로서 수행된 토양수세법 실내실험에서는 초음파를 이용한 오염물 세척물에 미치는 영향을 살펴보기 위하여 세척수량(pore volume), 초음파강도(sonication power), 간극비(void ratio), 동수경사(hydraulic gradient), 유효입경(D_{10})과 같은 초기 입력조건들에 따라 총 116세트의 초기 조건에 대하여 오염세척율(oil recovery, %) 값들이 계속되었다.

황명기 등(2003)은 초기 입력조건과 오염세척율과의 관계를 도출하기 위하여 인공신경망 기법을 적용하였다. 해석에서 5개의 초기입력값들이 모두 적용되었으며, 은닉층 노드수는 1~11로 다양하게 변화시키며, 인공신경망 구조를 적용하였다. 신경망에 사용되는 전이함수는 시그모이드(sigmoid) 함수와 쌍곡탄젠트(tanh)를 각각 적용하여 적합한 전이함수를 선택하고자 하였다. 연구자들은 다양한 인공신경망 구조에 대한 사례연구를 통하여 다음과 같은 최종적인 인공신경망을 제안하였다.



(a) 훈련



(b) 검증

그림 12. 오염지반 복원율에 대한 ANN 모델과 GA-NN 모델의 해석결과 비교

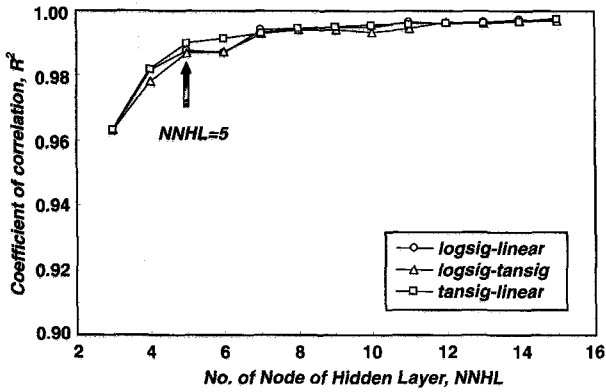


그림 13. 오염지반 복원율에 대한 GA-NN 모델의 설계변수 변동시 상관계수값의 변화

GA-NN 기법을 적용하기 위해 필요한 초기 설계조건이 표 1과 동일하며, 최대 입력변수 개수, I_{max} 는 5개이다. 최종적으로 얻어진 결과는 다음과 같다. GA-NN 방법에 선정된 중요입력 변수는 ANN 방법에서 사용한 입력변수 가운데 1개가 제외되었다. 은닉층 개수 및 적용된 전이함수는 ANN 모델과 동일하며, 은닉층 노드수는 4개로 NN 방법보다 작게 구해졌다. 그림 12에는 각 방법으로부터 훈련과 검증과정에 대한 상관계수 값들이 구해져 있다. GA-NN 모델은 ANN 모델보다 작은 입력변수를 사용하여 보다 적합한 상관관계를 도출할 수 있음을 알 수 있다. 그림 13에는 GA-NN 모델의 은닉층 노드수와 전이함수만의 변화에 따라 구해진 상관계수 값들이 나타나 있다. 상관관계는 전이함수의 형태에 영향을 크게 받지 않는 것으로 나타났으며, 상관계수 값은 GA-NN 모델에 적용된 은닉층 노드수, 5를 넘어섬에 따라 거의 수렴됨을 알 수 있다.

5. 결론

본 연구에서는 최적의 인공신경망 구조를 설계하기 위하여 유전자 알고리즘과 인공신경망이 조합된 설계 기법인 GA-NN 기법이 제안되었다. 제안된 기법에서는 신경망 구조 설계의 단점을 보완하기 위하여 유전자 알고리즘과 인공 신경망의 특성을 조합하였다. 유전자 알고리즘과 인공신경망이 조합된 설계기법은 출력값에 영향을 미치는 적합한 중요 입력변수, 은닉층 개수 및 노드수와 전이함수 조합을 포함한 신경망구조 설계변수들을 가장 적합하게 선별할 수 있는 안정적인 신경망 구조 설계기법임을 알 수 있다. 본 연구에서 수행된 예제해석결과는 다음과 같이 정리될 수 있다.

- (1) GA-NN 기법을 적용할 경우 자료의 출력값에 영향을 미치는 최적의 입력변수 조합을 선별할 수 있음을 알 수 있다. 또한 신경망 구조의 과다 설계를 피하면서 출력값을 가장 적합하게 예측할 수 있는 최적의 입력 노드 및 연결강도 수를 결정할 수 있다.
- (2) 기존의 신경망 구조 예비 설계시 필요했던 시행착오법에 근거한 다양한 신경망 구조들에 대한 반복적인 검토에 대한 노력을 줄이면서, 적합한 신경망 구조를 안정적으로 탐색할 수 있도록 한다.
- (3) 본 연구에서 제안된 GA-NN 기법이 적용된 지반공학 문제들의 경우 인공신경망 최적화 과정을 통하여 출력값에 영향을 미치는 않는 입력변수들이 제외된 간편한 신경망 구조를 도출할 수 있음을 알 수 있었다. 따라서 적용 가능한 입력변수들의 수가 많아서 적합한 신경망 구조를 찾기 위해 많은 수의 시행착오를 통한 반복적인 신경망 구조의 적용이 요구되는 지반공학문제에 대하여 복잡한 신경망 구조를 피하면서 입력물성치들과 출력값의 관계를 표현할 수 있는 최적의 신경망 구조를 도출하는 데에 보다 효율적으로 적용 가능한 것으로 사료된다.

감사의 글

본 연구는 과학재단 목적기초 연구과제 “전체 변형률 범위($10^{-4} \sim 10\%$)에서 풍화토 지반구조물 변형거동 평가를 위한 실험·해석 통합시스템 연구”와 스마트 사회 기반시설 연구센터(SISTeC)의 연구비 지원에 대하여 깊은 감사를 드립니다. 또한, 연구를 수행함에 있어서 아낌없는 토의를 통해 도움을 주신 삼성건설에 근무하시는 송종영 박사님과 GS 건설에 근무하시는 이성진 박사님께 깊은 감사를 드립니다.

참고 문헌

1. 김병탁, 김영수, 배상근 (2001), “암축지수의 추정을 위한 인공신경망 적용과 경험식 제안”, *한국지반공학회논문집*, 제17권, 제6호, pp.25-36.
2. 박찬란 (1998), *개선된 유전자 알고리즘을 이용한 최적의 신경망 구조 설계*, 박사학위논문, 조선대학교, 전산통계학과.
3. 박현일, 권기철, 오세봉 (2005), “인공 신경망 모델에 근거한 노상토 및 보조기층의 탄성계수값 추정”, *대한토목학회논문집*, 제25권, 제2-C호, pp.61-72.
4. 이성진, 이승래, 장범수 (2002), “인공신경망 모델을 이용한 불포화 걸보기점착력 추정에 관한 연구”, *대한토목학회논문집*, 제22권, 제3-C호, pp.331-344.

5. 황명기, 김지형, 김영옥 (2003), “초음파-토양수세법을 이용한 오염지반 복원률증대에 인공신경망의 적용”, *한국지반공학회논문집*, 제19권, 제6호, pp.343-350.
6. 홍동현 (1999), *유전자 알고리즘을 이용한 인공신경망 구조의 최적화에 관한 연구*, 박사학위논문, 영남대학교, 경영학과.
7. Bäck, T. and Hoffmeister, F. (1991) Extended Selection Mechanisms in Genetic Algorithms, *4th Int. Conf. of Genetic Algorithm*, San Mateo, California, USA, pp.92-99.
8. Goldberg, D. E. (1989). “*Genetic algorithms in search, optimization, and machine learning*”, New York: Addison-Wesley.
9. Huang, J. S., and Liu, H. C. (1997), “Object Recognition using Genetic Algorithms with a Hopfield’s Neural Model”, *Expert Systems with Applications*, Vol.13, No.3, pp.191-199.
10. Lee, I. M., and Lee, J. H. (1996), “Prediction of Pile Bearing Capacity Using Artificial Neural Networks”, *Computers and Geotechnics*, Vol.18, No.3, pp.189-200.
11. Marcellin, J. L. (1999), “Evolutionary Optimization of Mechanical Structures:Towards an Integrated Optimization”, *Engineering with Computer*, Vol.15, pp.326-333.
12. Mok, S. L., Kwong, C. K., and Lau, W. S. (2001), “A Hybrid Neural Network and Genetic Algorithm Approach to the Determination of Initial Process Parameter for Injection Moulding”, *International Journal of Advanced Manufacturing Technology*, Vol.18, pp.404-409.
13. Ozturk, N., and Ozturk, F. (2001), “Neural Networks Based Non-standard Feature Recognition to Integrate CAD and CAM”, *Journal of Computers in Industry*, Vol.45, No.2, pp.123-135.
14. Rahman, M. S., Wang, J., Deng, W., and Carter, J. P. (2001), “A Neural Network Model for the Uplift Capacity of Suction Caissions”, *Computers and Geotechnics*, Vol.28, pp.269-287.
15. Yu, H. and Liang, W. (2001), “Neural Network and Genetic Algorithm based Hybrid Approach to Expanded Job-Shop Scheduling”, *Computers and Industrial Engineering*, Vol.39, pp.337-356.

(접수일자 2005. 4. 11, 심사완료일 2005. 11. 15)