

개선된 인공신경망의 학습방법에 의한 강구조물의 설계

Design of Steel Structures

Using the Neural Networks with Improved Learning

최 병 한¹⁾ . 임 정 환²⁾

Choi, Byoung Han . Lim, Jung Hwan

요약: 본 연구에서는 많은 양의 함수 계산을 요구하는 확률론적 최적화 기법을 보다 효과적으로 강구조물에 적용하여 수행하고자 한다. 다양한 과학, 응용공학 분야에서 많은 시간이 소요되는 과정을 대체하는데 효과적인 도구로 출현한 인공신경망을 최적화 과정 중 많은 수의 유한요소 해석이 요구되는 재해석 문제에 적용함으로써 유한요소법의 평형방정식의 해의 근사해를 추정하여 재해석과정을 보다 간단하고 용이하게 수행하고자 한다. 또한 이용된 인공신경망의 학습효과의 개선을 위해 유전알고리즘을 적용한다. 확률론적 구조최적화 기법으로는 진화론적 방법에 기초한 알고리즘을 사용한다. 수치 예로서 전형적인 체적(중량)문제와 실 경비함수를 목적함수로 갖는 강구조물 모형에 본 연구의 알고리즘을 적용하여 본 알고리즘의 적용성과 타당성을 증명하였다.

ABSTRACT: For the efficient stochastic optimization of steel structures for which a large number of analyses is required, artificial neural networks, which have emerged as a powerful tool that could have been used to replace time-consuming procedures in many scientific or engineering applications, are applied. They are utilized for the solution of the equilibrium equations resulting from the application of the finite element method in connection with the reanalysis type of problem, for which a large number of finite element analyses are required in this study. As such, the use of artificial neural networks to predict finite element analysis outputs simplifies and facilitates the performance of the stochastic optimal design of structural systems where a trained neural network is used to replace the structural reanalysis phase. Moreover, to improve efficiency of used artificial neural networks, genetic algorithm is utilized. The stochastic optimizer used in this study is an algorithm based on the evolution theory. The efficiency of the proposed procedure is examined in problems with both volume (weight) functions and real-world cost functions

핵심용어: 인공신경망, 구조최적화, 역전파알고리즘, 유전알고리즘, 진화이론, 재해석, 학습개선

KEYWORDS: Artificial Neural Networks, Structural Optimization, Back Propagation, Genetic Algorithm, Evolution Theory, Reanalysis, Learning Improvement.

1. 서론

구조물의 최적설계는 공학자들 사이에 많은 관심의 대상이 되어 이에 관한 연구가 상당히 진행되었다. 초기의 최적설계에 관한 연구의 대부분은 수학적 계획법(Mathematical programming method)이었으나 최적화 과정의 소요시간을 개선하기 위하여 최적성 기준법(Optimality criteria method)을 도입하였다. 최근에는 보다 더 소요시간을 향상시키고자 근사기법(Approximation method)에 관한 연구(Schmit

등, 1974; Storaasli 등, 1974; Noor 등, 1975; Fleury 등, 1986; 한상훈 등, 1989; Fadel 등, 1990; 임정환 등, 1991; 이규원 등, 1993; 정영식 등, 1995; 이상근 등, 1995; Wang 등, 1995; Wang 등, 1996; Zhang 등, 1997; Chung 등, 2000; 조효남 등, 2002; 조효남 등, 2003; 이규원 등, 2004)가 활발히 진행되고 있는 실정이다.

또한 수학적계획법과 최적성 기준법과 같은 결정론적 최적화 기법(Deterministic Optimization Technique)처럼 설계점의 탐색방향 및 이동거리가 현재의 설계점의 위치에 따

1) 정희원, Noth Carolina State Univ. Postdoc. Researcher, 공학박사
(Tel.:1-336-263-6865, E-mail:han1020@hotmail.com)

2) 정희원, 전주공업대학 토목환경과 교수, 공학박사

본 논문에 대한 토의를 2006년 6월 30일까지 학회로 보내주시면 토의 회답을 게재하겠습니다.

라 결정되는 것이 아니고 어떤 조건에 의해 임의로 선택될 수 있는 방법 즉, 확률론적 최적화 기법(Stochastic Optimization Technique)으로 1960년대 이래로 다양한 최적화 문제를 해결하기 위하여 자연현상을 모사한 확률론적 최적화 기법들[유전알고리즘(Genetic Algorithms:G.A), 진화전략(Evolution Strategies:ES), 시뮬레이티드 어닐링(Simulated Annealing :S.A) 등]이 개발되었다. 결정론적 최적화 기법은 연속형 변수를 사용하고 경사도 정보를 이용하는 최적화기법으로 현재의 설계점에서 개선된 설계점으로 이동이 목적함수 및 제약함수의 연속성과 미분가능성을 필요로 하는 기법으로 초기 설계점의 선정은 매우 중요한 역할을 한다. 이 때문에 초기 설계점에 따라 최적해가 달라질 수 있으므로 국부적 최적해(Local Optimum Solution)에 도달할 가능성이 크다고 할 수 있다. 반면에, 일반적으로 확률론적 최적화 기법은 넓은 영역의 설계영역을 다룰 수 있으므로 전역적 최적해(Global Optimum Solution)를 구하는 면에서 결정론적 기법보다 월등히 뛰어나다고 할 수 있는 반면에, 많은 양의 함수 계산을 수행해야 하므로 즉, 최적화 과정 중에 상당한 회수의 구조 재해석이 필요함을 상기하면 막대한 설계시간이 요구되는 단점이 있다. 이러한 확률론적 기법을 적용한 기존의 많은 최적화에 관한 연구들이 국외는 물론 국내에서도 많이 발표되었으나 결정론적 기법에 관한 연구와 비교 시 상대적으로 소요시간을 개선하려는 연구는 매우 미미한 현실이다. 물론 본 연구의 일부 구조해석과 연관된 기 발표된 연구로써 인공지능망을 이용한 구조해석의 적용성을 잘 나타낸 연구들(이승창 등, 1997,1998;조효남 등, 2002)이 이미 선행되었다.

따라서 본 연구에서는 강구조물의 최적설계를 위한 확률론적 최적화 기법을 활용함에 있어 많은 계산시간이 요구되는 재해석 부분을 개선된 학습방법을 사용한 인공지능망(Artificial Neural Networks:A.N.N)으로 대체하여 보다 효율적이며 용이하게 수행하고자 한다. 수치 예로써 전형적인 구조물의 체적(중량)과 실 경비함수를 목적함수로 갖는 강구조물을 예로 들었다.

2. 연구내용

인공지능망은 기본적으로 경험에 의해 학습하고 학습을 통해 얻어진 지식을 새로운 상황에 일반화 시켜 적용하며, 전형적이지 못한 많은 자료로부터 근본이 되는 특징을 추출해 내는 능력을 가지고 있다. 1946년 Warren McCulloch와 Walter Pitts에 의해 최초로 개발된 이래 인간의 신경과 뇌 판단을 모사한 인공지능망은 각 연산요소의 병렬처리로 빠른

연산 및 정보의 분산표현이 가능하고 역전파알고리즘(Back-Propagation Algorithm:B.P.) 학습법의 개발로 인해 패턴인식, 제어, 설계, 지식정보처리 등과 같은 다양한 공학 분야에 널리 도입되고 그에 따른 성과가 나타나고 있으며, 이 밖에도 다양한 과학, 응용공학 분야에서 많은 시간이 소요되는 과정을 대체하는데 효과적인 도구로 출현하게 되었다.

이러한 인공지능망을 본 연구에서는 최적화 과정 중 많은 수의 유한요소 해석이 요구되는 재해석 문제에 적용함으로써 유한요소법의 평형방정식의 해의 근사해를 추정하여 재해석 과정을 보다 간단하고 용이하게 수행하고자 한다.

잘 훈련된 인공지능망의 주요 이점으로는 아주 적은 계산학적 노력을 통해 근사해를 얻을 수 있다는 것이다. 이와 같은 근사화는 계산시간 및 빠른 추정이 필요한 경우 매우 가치가 있다. 잘 훈련된 인공지능망은 적절하게 선택된 많은 자료와 그 자료로부터 생성되어진 정보를 이용하여 학습됨으로써 구성될 수 있다. 이와 같은 인공지능망의 학습과정 역시 목적함수가 예측의 오차를 최소화하고자 하는 무제약 최소화 문제이다.

인공지능망의 학습방법으로는 Werbos가 개발한 역전파알고리즘이 대표적인 학습방법으로, 패턴인식, 함수근사화, 적응제어 등의 매우 복잡한 문제를 성공적으로 수행하는 인공지능망에 적합하다.

그러나 근래에는 이러한 역전파 알고리즘의 활발한 활용과 더불어 역전파 알고리즘이 갖는 문제점을 지적하고 이를 개선하려는 연구도 병행되고 있는 게 사실이다(Aaron 등, 1993; Arena 등, 1993; Torreale, 1991; 양영순 등, 1998; 최병한, 2004).

역전파 알고리즘이 갖는 문제점은 크게 두 가지로 구분된다. 첫번째로 인공지능망의 구조가 학습성능에 매우 큰 영향을 주는데도 불구하고 적합한 인공지능망 구조 결정을 위한 일반적인 접근방법이 없어 시행착오법(Trial-Error Method)을 사용한다는 것이고, 다른 하나는 역전파알고리즘이 사용하는 학습규칙인 델타규칙(Delta Rule)이 인공지능망의 올바른 학습을 항상 보장하지는 못한다는 것이다. 즉, 일반적인 최적화 기법의 관점에서 보면 델타규칙은 인공지능망의 오차를 최소화하기 위해 최대경사법(Steepest Descent Method)을 이용하는 규칙인데, 이러한 최대경사법의 근본적인 문제점으로는 초기값의 선정에 따라 발생될 수 있는 국부 최적해에 수렴 가능성이 있다.

이와 같은 역전파 알고리즘의 문제점을 개선하려는 연구로써 근래에 대두되고 있는 방법으로는 유전알고리즘을 이용한 연구가 대표적이다. 유전알고리즘은 자연진화의 법칙인 적자생존과 자연도태의 원리를 근간으로 정립된 최적화 알고리즘이다. 인공지능망과 유전알고리즘의 결합이론은 다시 두 가지

로 분류할 수 있다. 첫째로 인공신경망 연결가중치의 최적화이다. 이는 인공신경망의 초기 연결가중치에 따라 국부최적해에 수렴하는 문제점을 해결하고자 하는 방법이다. 인공신경망의 구조는 변화시키지 않고 적합한 연결가중치를 유전알고리즘의 전역탐색능력을 이용하여 탐색하는 방법이다. 둘째로 인공신경망 구조의 최적화이다. 이는 은닉층의 뉴런수와 연결수에 따라 학습 수렴 속도가 변화한다는 연구 결과를 바탕으로 하여 은닉층의 뉴런수를 결정하기 위해 유전알고리즘을 이용하는 방법으로 많은 시간과 노력이 소요되는 단점이 있으며 불필요한 은닉층의 뉴런과 연결수를 제거함으로써 하드웨어적인 비용을 줄이는데 궁극적인 목적이 있으며 프로그램 구성이 복잡해지고 최적의 구조를 구현했다 하더라도 인공신경망의 과도한 학습시간 및 국부최적해에 수렴가능성의 문제를 극복했다고 말할 수 없다(Wolfram 등, 1990; 김시영, 1996).

본 연구에서는 최적화 과정 중 재해석 부분을 대체하는 인공신경망의 학습을 위하여 대표적인 학습방법인 역전파알고리즘을 적용하고, 또한 인공신경망에서 유전알고리즘을 이용하여, 학습시간과 국부최적해에 수렴가능성의 문제를 해결할 수 있으며 프로그래밍을 용이하게 할 수 있는 인공신경망의 연결가중치의 최적화 방법에 의한 학습방법을 사용하고자 한다. 학습방법에 따른 예측력 평가를 위해 본 연구에서는 평균 제곱오차(Mean Square Error: MSE)와 학습 반복회수(Epoches)를 예측력 비교척도로 삼았다.

본 연구에 사용된 확률론적 최적화 기법으로는 대표적인 진화론적 기법인 유전알고리즘을 적용한다.

이상에서 기술된 본 연구의 내용을 요약하면, 유전알고리즘을 활용하여 구조물의 전역적 최적설계를 수행한 연구로서 해의 획득에 있어 효율성을 위해 구조최적화 과정 중 많은 소요시간을 요구하는 재해석 부분에 인공신경망 기법을 사용하며, 특히 인공신경망의 학습방법에 역전파알고리즘 외에 최적화 기법으로 사용된 유전알고리즘을 적용함으로써 종합적인 최적화 과정을 보다 효율적이며 용이하게 수행하고자 한다.

3. 최적화 문제형성

3.1 유전알고리즘을 이용한 무제약 최적화

본 연구의 수치 예에서 다루게 될 트러스 구조물의 단면 최적화 문제는 전형적인 최소 체적(중량)설계와 보다 현실적인 경비함수를 갖는 최소 경비설계의 문제이다.

먼저, 최소 체적(중량)설계 문제의 경우 허용응력설계법에 의한 응력제약조건과 처짐제약조건 및 설계변수한계 제약조

건을 고려한 종합적인 최적화 문제로 정규화하면 다음과 같다.

$$\text{Minimize } F(X) = \sum_{i=1}^n A_i L_i \quad (1)$$

Subject to :

$$\cdot \text{응력 제약조건} : g_1 = \frac{\{\sigma\}}{\{\sigma_a\}} - \{1.0\} \leq \{0\} \quad (2)$$

$$\cdot \text{좌굴응력제약조건} : g_2 = \frac{\{\sigma_b\}}{\{\sigma_{ba}\}} - \{1.0\} \leq \{0\} \quad (3)$$

$$\cdot \text{처짐제약조건} : g_3 = \frac{\{u\}}{\{u_a\}} - \{1.0\} \leq \{0\} \quad (4)$$

$$\cdot \text{설계변수한계제약} : g_4 = \frac{\{X\}}{\{X^U\}} - \{1.0\} \leq \{0\} \quad (5)$$

$$g_5 = \frac{\{X^L\}}{\{X\}} - \{1.0\} \leq \{0\} \quad (6)$$

여기서,

$F(X)$: 목적함수

n : 트러스 부재 총수

A_i : i 번째 부재 단면적

L_i : i 번째 부재 길이

$\{\sigma_a\}$: 허용응력

$\{\sigma_{ba}\}$: 허용 좌굴응력

$\{u_a\}$: 허용변위

$\{X^U\}$: 설계변수 상한치

$\{X^L\}$: 설계변수 하한치

또한 다양한 경비를 포함하는 실 경비함수를 갖는 트러스 구조물의 이산형 변수로 표현되는 최적설계로는 다음과 같은 매우 포괄적인 실 경비함수를 고려한다. 제약조건으로는 하중 저항계수법에 따른 응력과 처짐제약조건을 고려한다.

$$\text{Minimize } F(X) = C_t = C_m + C_p n_p + C_j n_j \quad (7)$$

$$C_m = \sum_{i=1}^n c(p_i) l_i \quad (8)$$

$$c(p) = \rho(m_p) A_p c_w(m_p, s_p) \quad (9)$$

여기서,

C_t : 총 경비함수

C_m : 총 재료 단가

C_p : 사용 제품 종류 수 당 단가

C_j : 부재 연결 당 단가

n_p : 제품 종류의 수

- n_j : 부재 연결 수
- l_i : i 번째 부재의 길이
- n : 트러스 부재의 총 수
- $c(p_i)$: i 번째 부재 제품 p 의 길이 당 단가
- m_p : 제품 p 의 재료 타입
- $\rho(m_p)$: m_p 의 단위중량
- A_p : 제품 p 의 단면적
- s_p : 제품의 단면형상
- $c_w(m_p, s_p)$: 제품 p 의 단위중량 당 단가
- p_i : 이산형집합 S 의 j 번째 제품
즉 $p_i = S(j)$
($i \leq j$ 이면 $\cos t(S(i)) \leq \cos t(S(j))$)

Subject to :

· 응력 제약조건 :

$$g_1 = \frac{\{F_c(i)\}}{\{S_c(p_i)\}} - \{1.0\} \leq \{0\} \text{ (압축)} \quad (10)$$

$$g_2 = \frac{\{F_t(i)\}}{\{S_t(p_i)\}} - \{1.0\} \leq \{0\} \text{ (인장)} \quad (11)$$

· 처짐 제약조건 : $g_3 = \frac{\{d_j\}}{\{s_j\}} - \{1.0\} \leq \{0\}$ (12)

여기서,

$$S_c(p_i) : \text{제품 } p_i \text{의 압축설계저항} \\ = \begin{cases} 0.9(0.66^{\lambda} \sigma_{yr} A_i), & \lambda \leq 2.25 \\ 0.9(\frac{0.88 \sigma_{yr} A_i}{\lambda}), & \lambda > 2.25 \end{cases} \quad (13)$$

$$\lambda_i = \frac{\sigma_{yr} A_i L_i^2}{\pi^2 E I_i} \quad (14)$$

$$S_t(p_i) : \text{제품 } p_i \text{의 인장설계저항} \\ = 0.95(\sigma_{yr} A_i) \quad (15)$$

$F_c(i)$: i 번째 부재의 최대압축력

$F_t(i)$: i 번째 부재의 최대인장력

d_j : 자유도 j 의 최대 처짐량

s_j : 자유도 j 의 최대허용 처짐량

E_i : i 번째 부재의 탄성계수

σ_{yr} : i 번째 부재의 항복응력

L_i : i 번째 부재의 길이

A_i : 제품 p_i 의 단면적

I_i : 제품 p_i 의 단면2차모멘트

최적화 기법으로 유전알고리즘을 이용하기 위하여 위의 정규화된 최적화 문제형식은 벌칙함수법(Penalty Function Method)을 이용한 무제약 최적화 문제(Unconstrained Optimum Problem)로의 변환이 요구된다.

벌칙함수법은 비선형설계문제를 다음과 같은 일련의 무제약 최적화문제로 바꾸어 근사적으로 최적해를 찾아가는 기법으로, 내부벌칙함수법(Interior Penalty Function Method)과 외부 벌칙함수법(Exterior Penalty Function Method)으로 대별 된다. 공학적인 견지에서 보면 근사적인 수치해로써 유용설계값을 얻을 수 있는 내부벌칙함수법이 외부벌칙함수법 보다 효과적이다. 그러나 초기설계점이 반드시 유용영역에서 선택해야만 하는 어려움이 존재하므로 본 연구에서는 외부벌칙함수법을 사용하며, 벌칙 매개변수로는 시행착오법에 의해 초기치와 증감치를 결정한다. 최초에 임의 스칼라량(벌칙매개변수) $\alpha^r = \alpha^1$ 로 작은 값을 취하고 초기설계점 $\bar{x} = \bar{x}^0$ 를 사용하여 다음과 같은 일련의 무제약함수의 최솟치를 구함으로써 일련의 설계점 $\bar{x}^r (r = 1, 2, \dots)$ 를 구할 수 있다.

$$\text{Min } \Phi^r(\bar{x}, \alpha^r) \quad (16)$$

여기서

$$\Phi^r(\bar{x}, \alpha^r) = F(\bar{x}) + \alpha^r \sum_{j=1}^n \max\{0, g_j(\bar{x})\}^2 \quad (17)$$

이때

$$g_j(\bar{x}) = \begin{pmatrix} g_j(\bar{x}) & : & g_j(\bar{x}) > 0 \\ 0 & : & g_j(\bar{x}) < 0 \end{pmatrix}$$

따라서, 본 연구의 최적화 문제 형식인 식 (1) ~ (15)로부터 무제약 최적화 문제를 형성하면,

$$\Phi = F(x) + \alpha \sum_{i=1}^n \{\max(0, g_i)\}^2 \quad (18)$$

이에 따른 유전알고리즘의 적합도 함수는 목적함수의 역수를 사용하였다.

3.2 인공신경망을 이용한 재해석 과정의 대체

3.2.1 학습자료 선정

본 연구에서는 최적화 과정 중 재해석 부분의 대체를 위하여 인공신경망을 적용한다. 이러한 인공신경망의 학습자료의

선택기법으로는 설계공간의 중앙점을 기준으로 설계변수의 분포를 가오스 분포로 가정하고 이들 분포로부터 인공신경망에서 요구하는 패턴 수 만큼 자동으로 선택하여 입력자료를 선정하고 이로부터 유한요소해석을 수행하여 각 입력자료에 대응하는 목표자료를 얻는다. 또한 준비된 학습자료는 다음과 같은 이유로 변환될 필요성이 있다. 첫째, 입력자료의 중요도는 동일해야 하며, 둘째, 출력자료 및 목표자료는 출력 전달 함수(Transfer Function) 또는 활성화 함수(Active Function)가 가질 수 있는 범위에 대응되어야 한다. 따라서 본 연구의 인공신경망의 입·출력 자료 및 목표자료는 선형변환을 이용하여 0~1의 범위를 갖도록 자료변환 하였다.

3.2.2 인공신경망의 구조 결정

본 연구의 인공신경망은 순차(Feed Forward) 인공신경망 구조이며, 입력층의 노드 수(n1)는 구조응답에 영향을 주는 변수들의 수와 일치하고, 출력층의 노드 수(n3)는 유한요소 해석을 통해 얻고자하는 구조응답의 수와 일치한다.

또한 은닉층의 결정은 일반적으로 은닉층의 수를 2층 이상으로 구성된 인공신경망의 경우 1층으로 구성된 인공신경망에 비해 뚜렷한 성능향상을 얻기 어렵다는 경험을 참고하여 인공신경망의 은닉층을 1층으로 결정하고 은닉층 노드 수(n2)의 결정은 입력노드 수(n1)의 증감에 따라 시행착오법에 의해 $n2=n1+5$ 로 결정하였다.

전달함수는 인공신경망이 해결하고자 하는 문제의 성격에 따라 선택될 수 있으며, 학습속도에 많은 영향을 미친다. 본 연구의 인공신경망에서는 비선형이며 형태가 단순하고 미분가능하며 가장 많이 사용되는 시그모이드 함수(Sigmoid Function)를 사용한다.

이상에서 기술한 바와 같이 본 연구에서 최적화 과정 중 재해석 부분의 대체로 쓰이는 인공신경망의 구조는 그림 1과 같다.

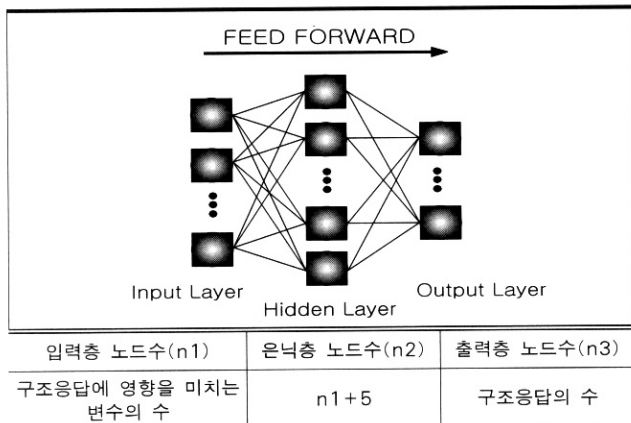


그림 1. 본 연구의 인공신경망의 구조

3.2.3 인공신경망의 학습

본 연구에서는 인공신경망의 학습을 위하여 두 가지 방법을 제안한다. 먼저, 인공신경망의 대표적인 학습방법인 전파알고리즘을 적용하고, 두 번째 최적화 기법인 유전알고리즘을 이용한 학습방법을 적용한다.

(1) 역전파알고리즘에 의한 학습

역전파알고리즘은 다층이고, 인공신경망에서 사용되는 대표적인 방법으로 학습방법은 지도학습이다.

본 연구에 적용된 역전파알고리즘은 연결강도에 대한 오차의 구배(Gradient)을 구하여 연결강도의 변화에 적용하는 최적화방법으로서 이를 간략히 설명하면 다음과 같다.

$$new W_{kj} = old W_{kj} + \Delta W_{kj} \quad (19)$$

$$여기서 \quad \Delta W_{kj} = -\eta \frac{\partial E}{\partial W_{kj}} \quad (20)$$

W_{kj} : k번째 층에서 j번째 층간의 연결강도.

η : 학습률

E: 오차

위 식 (20)의 구배를 계산하면,

$$\Delta W_{kj} = \eta \delta_k^o H_j \quad (21)$$

$$여기서, \delta_k^o = \delta_k f_k' \quad (22)$$

$\delta_k = T_k - O_k$: k층의 목표출력과 실제출력의 차

f_k : k 층의 전달함수

$$(\text{시그모이드 함수}) f_k(x) = \frac{1}{1 + e^{-x}}$$

f_k' : k 층 전달함수의 도함수.

H_j : j 층의 활성화 값

또한 반복적인 진동을 제거할 수 있으며, 속도 향상에 도움이 되는 모멘텀항을 고려하여 식 (19)을 다시 쓰면

$$new W_{kj} = old W_{kj} + \eta \delta_k^o H_j + \xi old \Delta W_{kj} \quad (23)$$

여기서, ξ : 모멘텀 상수

$$old \Delta W_{kj} = old W_{kj} - older W_{kj} \quad \text{모멘텀}$$

(2) 유전알고리즘에 의한 학습

최적화 관점에서 인공신경망의 학습은 목적함수가 목표치와 출력치의 차이인 에러이고 설계변수가 각 층간의 연결강도와 Bias인 무제약최적화 문제이다. 따라서 현재 주류를 이루는

학습방법인 역전파알고리즘은 결정론적 최적화 기법인 최대경사법을 사용한 것이고 이와는 대조적으로 확률론적 최적화 기법의 적용도 연구대상으로 다를 수 있다.

본 연구에서는 이러한 목적으로 인공신경망의 연결강도와 Bias 결정을 위해 확률론적 기법인 유전알고리즘을 이용하여 전역적 최적해 부근까지 탐색을 수행하고 그 다음 국부탐색으로 결정론적 최적화 기법인 최대경사법을 이용하는 역전파알고리즘에 의한 학습에 의해 최종 연결강도와 Bias를 결정하려 한다.

그림 4와 같은 순서도에 의한 알고리즘을 수행하며, 본 연구 유전알고리즘에 사용되는 매개변수는 시행착오에 의해 표 1과 같이 선정하였다.

표 1. 인공신경망 학습을 위한 유전알고리즘의 매개변수 선정

| | |
|---------------------------------|------|
| 개체집단의 크기(Population Size) | 50 |
| 최대 세대수 (Max. Generation No.) | 1000 |
| 교배확률(Probability of Crossover) | 0.9 |
| 돌연변이확률(Probability of Mutation) | 0.02 |

일반적인 유전알고리즘의 수행과정으로는 먼저 초기 개체집단을 발생시킨다. 이를 위해 인공신경망의 연결강도와 Bias를 그림 2와 같이 실수 코딩(Real Coding)을 사용하여 표현하였다.

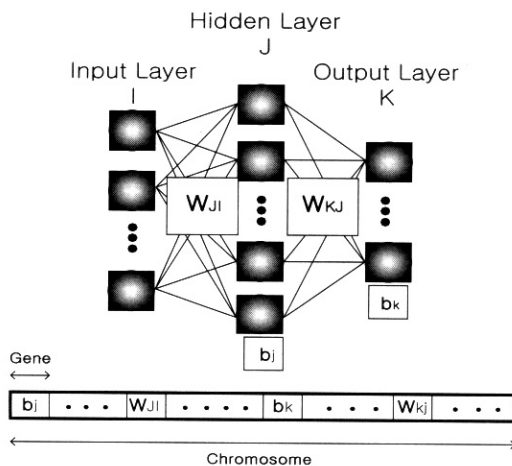


그림 2. 연결강도와 Bias의 염색체 표현

이와 같이 표현된 개체집단을 인공신경망에 따라 처리하고 다음으로 개체집단을 평가하기 위해 전체 학습자료에 대한 평균제곱오차를 계산하여 그 역수를 적합함수로 사용하여 적합도를 평가한다.

$$MSE = \frac{1}{N} \sum_k \{T_k - O_k\}^2 \quad (24)$$

여기서, T_k : k층의 목표출력 값
 O_k : k층의 실제출력 값

$$F = \frac{1}{MSE} \quad (25)$$

인공신경망의 학습을 위한 유전알고리즘의 연산과정에 사용되는 연산자로는, 먼저 재생산을 위한 개체선택 도구로는 Gradient Based Selection을 사용하였다. 교배방법으로는 개선된 단순교배(Modified Simple Crossover)를, 돌연변이 과정은 동적돌연변이(Dynamic Mutation)를 사용하였다. 또한 탐색과정 중 개체집단 내에서 가장 적합도가 높은 엘리트 개체가 교배나 돌연변이 과정을 거치지 않고 다음 세대로 남기는 De Jong이 소개한 엘리트 보존전략(Elitist Strategy)을 사용하였다. 이와 같은 연산과정을 거쳐 생성된 개체에 대하여 적합도를 평가하고 수렴조건에 이를 때까지 반복과정을 거쳐 연결강도와 Bias를 찾는다.

이상의 유전알고리즘에 의해 결정된 연결강도와 Bias를 역전파알고리즘에 의한 인공신경망의 학습과정에 전달한다. 역전파알고리즘에 의한 학습과정에 넘겨진 연결강도와 Bias는 학습종료조건에 도달할 때까지 학습을 수행하게 된다.

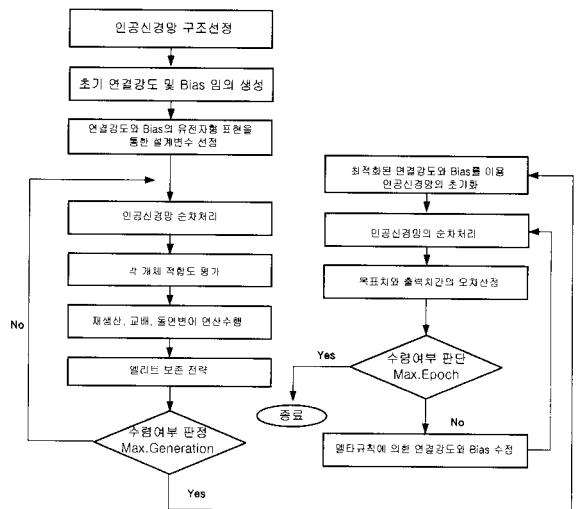


그림 3. 유전알고리즘을 이용한 인공신경망 순서도

3.3 유전알고리즘에 의한 종합적인 최적화 과정의 순서도

이상과 같이 기술된 본 연구의 일련의 최적화 과정 순서를 도식화 하면 그림 4와 같다.

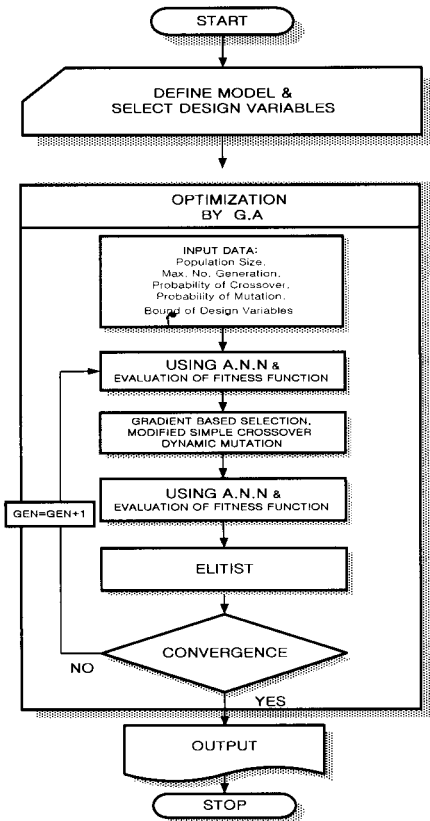


그림 4. 본연구 최적화 과정 순서도




그림 5. 7부재 트러스 구조물

그림 5와 같은 7부재 트러스 구조물의 설계조건은 표 2와 같다.

표 2. 설계조건

| | | |
|----------------|----------------|----------------|
| 제 하 조 건 (절점 2) | | 6864.65KN(↓) |
| 제 약 조 건 | 허용응력 (인장·압축) | ± 186326.35KPa |
| | 좌굴응력 | EULER 좌굴응력 |
| | 변위제약 절점 : 2 | 2.1 cm |
| 단 성 계 수 | | 205939.65MPa |

설계변수로는 각 부재 단면적으로 선정하고, 목적함수는 구조물의 체적으로 하고 위의 설계조건에서 제시한 바와 같은 재하조건과 제약조건을 고려하여 7부재 트러스 구조물의 단면 최적화를 수행한다.

유전알고리즘에 사용되는 매개변수의 선정에 관한 명확한 지침은 현재까지 아직 미흡한 상태이다. 따라서 본 연구에서는 시행착오를 통해 매개변수를 선정하였다.

본 연구의 수치 예 7부재 트러스에 적용된 유전알고리즘 매개변수와 사용된 연산자 및 표현방법은 표 3과 같다.

또한 구조재해석부분을 대체할 인공지능망의 구조(n1-n2-n3)는 부재단면적의 수와 요구되는 구조응답의 수에 따라 7-12-3이다.

표 3. 유전알고리즘의 매개변수, 연산자 및 표현방법

| 유전알고리즘 변수 | 벌칙매개변수 | 연산자 | 표현 |
|-----------|----------------------|---|-------|
| 세대수 | 100 | | |
| 개체집단의 크기 | 초기치 : 1 증감치 : 1.1 | • 룰렛휠 선택 • 개선된단순교배 • 동적돌연변이 • 엘리트 보존전략 | 실수 코딩 |
| 교배확률 | 0.9 | | |
| 돌연변이 확률 | 0.01 | | |

이상과 같은 설계조건에 의한 7부재 트러스 구조물의 최적설계를 위해서 기술한 바와 같이 최적화 기법을 달리하며 최적화를 수행한 결과 진동현상 없이 표 4와 같은 최적해에 수렴하였다.

4. 수치 예

강구조물의 최적설계를 위하여 본 연구에서 제안한 최적화 방법을 몇 가지 구조모형의 단면최적화에 적용하여 본 알고리즘의 타당성 및 적용성을 비교 분석하고자 한다. 사용된 수치 예로는 전형적인 최적설계 예인 최소체적(중량)설계와 좀더 현실적인 하중 조건과 실 경비함수를 갖는 최소 소요경비설계를 위한 트러스 구조물을 예를 들었다.

본 연구에서 소개한 최적화 기법의 타당성과 적용성을 검토 하기 위하여, 최적화 기법으로는 유한요소법을 이용하여 구조재해석을 수행하며 유전알고리즘으로 최적화 하는 기법(Type I) 및 구조재해석 부분을 인공지능망으로 대체하여 구조응답을 예측하며 유전알고리즘으로 최적화 하는 기법(Type II - VII)으로 분류하였다. 이때 사용되어지는 인공지능망의 구조(n1-n2-n3)는 목표값에 영향을 미치는 변수의 수 및 요구되는 구조응답의 수에 따라 결정 되어 진다.

후자의 기법은 다시 인공지능망의 학습방법 및 입력자료의 패턴 수에 따라 재 분류 됨으로써 총 7가지 최적화 기법으로 본 연구의 수치 예를 수행하였다.

4.1 최소 체적 설계를 목적함수로 하는 7부재 트러스

표 4. 7부재 트러스 구조물의 최적설계 결과

| Optimization Type | | Number of FE Analysis | Number of ANN Analysis | Number of Iteration | Optimum Volume (cm ³) | Computing Time(sec) | Relative Error(%) | Learning of ANN | |
|-------------------|--------------|-----------------------|------------------------|---------------------|-----------------------------------|---------------------|-------------------|-----------------|--------------|
| Type | OPT+Analysis | | | | | | | M.S.E | No. of Trial |
| I | GA + FEM | 15 | - | 15 | 1479100 | 3.3450 | - | - | |
| II | GA + ANN(a) | - | 8 | 8 | 1506389 | 3.2812 | 1.845 | 0.01 | |
| III | GA + ANN(b) | - | 8 | 8 | 1506389 | 3.2812 | 1.845 | 0.01 | |
| IV | GA + ANN(c) | - | 8 | 8 | 1491737 | 3.2812 | 0.854 | 0.01 | |
| V | GA + ANN(d) | - | 8 | 8 | 1491737 | 3.2812 | 0.854 | 0.01 | |
| VI | GA + ANN(e) | - | 13 | 13 | 1489335 | 3.3444 | 0.692 | 0.01 | |
| VII | GA + ANN(f) | - | 13 | 13 | 1489335 | 3.3444 | 0.692 | 0.01 | |

GA : 유전알고리즘, FEM : 유한요소해석법
 ANN(a) : 인공신경망(학습방법 : 역전파알고리즘, 패턴 수 : 200) , ANN(b) : 인공신경망(학습방법 : 유전알고리즘+역전파알고리즘, 패턴 수 : 200)
 ANN(c) : 인공신경망(학습방법 : 역전파알고리즘, 패턴 수 : 300) , ANN(d) : 인공신경망(학습방법 : 유전알고리즘+역전파알고리즘, 패턴 수 : 300)
 ANN(e) : 인공신경망(학습방법 : 역전파알고리즘, 패턴 수 : 400) , ANN(f) : 인공신경망(학습방법 : 유전알고리즘+역전파알고리즘, 패턴 수 : 400)
 Number of FE analysis : 최적화 과정 중 유한요소법에 의한 재해석 수 , Number of ANN analysis : 최적화 과정 중 인공신경망에 의한 재해석 수
 Number of Iteration(Number of Generation) : 최적화 과정의 반복회수 , Computing Time : 계산시간 , Relative Error : Type I 과의 상대오차
 M.S.E : 인공신경망의 평균제곱오차 , No. of Trial : 인공신경망의 평균제곱오차에 수렴하기위한 시도 회수.

4.2 최소 체적설계를 목적함수로 하는 10부재 트러스

그림 6과 같은 10부재 트러스 구조물의 설계조건은 표 5와 같다.




그림 6. 10부재 트러스 구조물

설계변수로는 각 부재 단면적으로 선정하고, 목적함수는 구조물의 체적으로 하고 위의 설계조건에서 제시한 바와 같은

재하조건과 제약조건을 고려하여 10부재 트러스 구조물의 단면최적화를 수행한다. 또한 10부재 트러스 구조물에 적용된 유전알고리즘의 매개변수와 연산자 및 표현방법은 표 6과 같다. 구조 재해석부분에 사용되는 인공신경망의 구조는 10-15-1이다.

표 5. 설계조건

| 설계조건 | | |
|---------------|--------------|---------------|
| 재하조건 (절점 2,4) | 444.83KN (↓) | |
| 제약조건 | 허용응력 | +172376.39KPa |
| 탄성계수 | 68950.56MPa | |

표 6. 유전알고리즘의 매개변수, 연산자 및 표현방법

| 유전알고리즘 변수 | 별적매개변수 | 연산자 | 표현 |
|-----------|--------|-----------------------|---|
| 세대수 | 200 | 초기치 : 1 증감치 : 1.1배 | • 룰렛휠 선택 • 개선된단순교배 • 동적돌연변이 • 엘리트 보존전략 |
| 개체집단의 크기 | 50 | | |
| 교배확률 | 0.9 | | |
| 돌연변이 확률 | 0.01 | | |

표 7. 10부재 트러스 구조물의 최적설계 결과

| Optimization Type | | Number of FE Analysis | Number of ANN Analysis | Number of Iteration | Optimum Volume (cm ³) | Computing Time(sec) | Relative Error(%) | Learning of ANN | |
|-------------------|--------------|-----------------------|------------------------|---------------------|-----------------------------------|---------------------|-------------------|-----------------|--------------|
| Type | OPT+Analysis | | | | | | | M.S.E | No. of Trial |
| I | GA + FEM | 62 | - | 62 | 245440 | 5.9290 | - | - | |
| II | GA + ANN(a) | - | 56 | 56 | 249668 | 4.9838 | 1.723 | 0.01 | |
| III | GA + ANN(b) | - | 56 | 56 | 249668 | 4.9838 | 1.723 | 0.01 | |
| IV | GA + ANN(c) | - | 60 | 60 | 248439 | 5.0211 | 1.221 | 0.01 | |
| V | GA + ANN(d) | - | 60 | 60 | 248439 | 5.0211 | 1.221 | 0.01 | |
| VI | GA + ANN(e) | - | 61 | 61 | 246856 | 5.0424 | 0.577 | 0.01 | |
| VII | GA + ANN(f) | - | 61 | 61 | 246856 | 5.0424 | 0.577 | 0.01 | |

GA : 유전알고리즘, FEM : 유한요소해석법
 ANN(a) : 인공신경망(학습방법 : 역전파알고리즘, 패턴 수 : 200) , ANN(b) : 인공신경망(학습방법 : 유전알고리즘, 패턴 수 : 200)
 ANN(c) : 인공신경망(학습방법 : 역전파알고리즘, 패턴 수 : 300) , ANN(d) : 인공신경망(학습방법 : 유전알고리즘, 패턴 수 : 300)
 ANN(e) : 인공신경망(학습방법 : 역전파알고리즘, 패턴 수 : 400) , ANN(f) : 인공신경망(학습방법 : 유전알고리즘, 패턴 수 : 400)
 Number of FE analysis : 최적화 과정 중 유한요소법에 의한 재해석 수 , Number of ANN analysis : 최적화 과정 중 인공신경망에 의한 재해석 수
 Number of Iteration(Number of Generation) : 최적화 과정의 반복회수 , Computing Time : 계산시간 , Relative Error : Type I 과의 상대오차
 M.S.E : 인공신경망의 평균제곱오차 , No. of Trial : 인공신경망의 평균제곱오차에 수렴하기위한 시도 회수.

이상과 같은 설계조건에 의한 10부재 트러스 구조물의 최적 설계를 최적화 기법을 달리하여 최적화를 수행한 결과 진동현상 없이 표 7과 같은 최적해에 수렴하였다.

4.3 실 경비합수를 갖는 21부재 트러스 구조물

그림 7과 같은 21부재 트러스 구조물의 설계조건은 표 8과 같다.




그림 7. 21부재 트러스 구조물

표 8. 설계조건

| 단가 및 재료 물성치 | | | |
|----------------------------|-----------------------------|-------------------------|-------------------------|
| C_p (천원) | 600 | | |
| C_j (천원) | 150 | | |
| $c_w(m_p, s_p)$ (천원/kg) | 단면 | Bar | Tube |
| | 재료 | | |
| | Carbon Steel | 3150 | 5040 |
| | High Strength Steel | 4200 | 6250 |
| | Tempered Steel | 5700 | 7950 |
| 탄성계수(E) | 200000000 KN/m ² | | |
| 단위중량(ρ) | 7850 Kg/m ³ | | |
| 항복응력(σ_y) | Carbon Steel | High Strength Steel | Tempered Steel |
| | 250000KN/m ² | 345000KN/m ² | 485000KN/m ² |
| | | | |
| 하중조건 | | | |
| | 하중군 (Load Case) | 재하위치 | 하중크기 |
| 사하중 | - | 절점 2,3,4,5,6 | 189.94 (KN) |
| | I | 절점 2 | 418.95 (KN) |
| 활하중 | II | 절점 2,3 | 418.95 (KN) |
| | III | 절점 3,4 | 418.95 (KN) |
| | IV | 절점 4,5 | 418.95 (KN) |
| | V | 절점 5,6 | 418.95 (KN) |
| | VI | 절점 6 | 418.95 (KN) |

목적함수로는 식 (7)과 같은 실 경비합수를 사용하며, 총 재료단가 C_m 은 식(8)에 의해 결정되며, 부재의 해당 제품 p 의 길이 당 단가 $c(p)$ 는 식(9)에 의해 결정된다. 제약조건으로는 표 8의 각 재료별 항복응력을 고려한 응력제약조건

을 고려하며, 하중조건으로는 사하중과 활하중의 조합에 의한 6가지 하중조합을 고려하였다.

제품의 타입에 따라 사용되는 종류는 모두 210개의 제품을 사용하였다. 즉 두 가지의 단면 형상(Bar/Tube)과 3가지의 재료(Carbon steel/ High Strength steel/ Tempered steel)별로 35가지의 단면치수를 가지는 것으로 총 210개의 제품을 이산형 설계변수로 하였다. 이들을 본 설계에 적용하기 위해 가격에 따라 표 9와 같이 오름차순으로 정리하였다.

표 9. 설계에 적용된 제품

| 제품번호 | 제품 재료 | 단면 형상 | 단면 치수 |
|------|---------------------|-------|-------------|
| 1 | Carbon Steel | Bar | 10 × 10 |
| 2 | Carbon Steel | Tube | 10 × 10 × 2 |
| 3 | High Strength Steel | Tube | 10 × 10 × 2 |
| 4 | High Strength Steel | Bar | 10 × 10 |
| 5 | Tempered Steel | Tube | 10 × 10 × 2 |
| · | · | · | · |
| · | · | · | · |
| · | · | · | · |
| · | · | · | · |
| 206 | High Strength Steel | Bar | 400 × 400 |
| 207 | Carbon Steel | Bar | 500 × 500 |
| 208 | Tempered Steel | Bar | 400 × 400 |
| 209 | High Strength Steel | Bar | 500 × 500 |
| 210 | Tempered Steel | Bar | 500 × 500 |

21부재 트러스 구조물에 적용된 유전알고리즘의 매개변수, 연산자 및 표현방법은 표 10과 같다.

표 10. 유전알고리즘의 매개변수, 연산자 및 표현방법

| 유전알고리즘 변수 | | 별책매개변수 | 연산자 | 표현 |
|-----------|-------|------------|---|------|
| 세대수 | 15000 | 100000(고정) | <ul style="list-style-type: none"> • 룰렛휠 선택 • Uniform교배 • 동적틀연변이 • 엘리트 보존전략 | 이진코딩 |
| 개체집단의 크기 | 1000 | | | |
| 교배확률 | 0.9 | | | |
| 돌연변이 확률 | 0.1 | | | |

구조해석 부분을 대체할 인공지능경망의 학습을 위한 자료는 앞의 두 예제와는 달리 각 부재별로 같은 수의 자료를 랜덤하게 선택하였으며, 인공지능경망의 구조는 각 부재에 해당되는 제품번호 및 하중조합번호로 구성되는 입력노드($n1$)와 은닉층 노드는 $n1+10$ 이고 출력층의 노드는 각 부재의 부재력이다.

이상과 같은 설계조건에 의한 21부재 트러스 구조물의 최적 설계를 최적화 기법을 달리하여 최적화를 수행한 결과 진동현상 없이 표 11과 같은 최적해에 수렴하였다.

표 11. 21부재 트러스 구조물의 최적설계 결과

| Optimization Type | | Number of FE Analysis | Number of ANN Analysis | Number of Iteration | Optimum Cost (천원) | Computing Time(sec) | Relative Error(%) | Learning of ANN | |
|-------------------|--------------|-----------------------|------------------------|---------------------|-------------------|---------------------|-------------------|-----------------|-------------|
| Type | OPT+Analysis | | | | | | | M.S.E | No.of Trial |
| I | GA + FEM | 7802 | - | 7802 | 73,591 | 279.60 | - | - | - |
| II | GA + ANN(a) | - | - | - | - | - | - | 0.05 | 수렴불가 |
| III | GA + ANN(b) | - | 7748 | 7748 | 74,894 | 24.29 | 1.771 | 0.05 | 1 |
| IV | GA + ANN(c) | - | 7775 | 7775 | 74,430 | 65.44 | 1.140 | 0.05 | 27 |
| V | GA + ANN(d) | - | 7775 | 7775 | 74,430 | 65.44 | 1.140 | 0.05 | 1 |
| VI | GA + ANN(e) | - | 7811 | 7811 | 73,979 | 174.13 | 0.527 | 0.05 | 5 |
| VII | GA + ANN(f) | - | 7811 | 7811 | 73,979 | 174.13 | 0.527 | 0.05 | 1 |

GA : 유전알고리즘, FEM : 유한요소해석법

ANN(a) : 인공신경망(학습방법 : 역전파알고리즘, 패턴 수 : 630) , ANN(b) : 인공신경망(학습방법 : 유전알고리즘, 패턴 수 : 630)

ANN(c) : 인공신경망(학습방법 : 역전파알고리즘, 패턴 수 : 840) , ANN(d) : 인공신경망(학습방법 : 유전알고리즘, 패턴 수 : 840)

ANN(e) : 인공신경망(학습방법 : 역전파알고리즘, 패턴 수 : 1050) , ANN(f) : 인공신경망(학습방법 : 유전알고리즘, 패턴 수 : 1050)

Number of FE analysis : 최적화 과정 중 유한요소법에 의한 재해석 수 , Number of ANN analysis : 최적화 과정 중 인공신경망에 의한 재해석 수

Number of Iteration(Number of Generation) : 최적화 과정의 반복회수 , Computing Time : 계산시간 , Relative Error : Type I 과의 상대오차

M.S.E : 인공신경망의 평균제곱오차 , No. of Trial : 인공신경망의 평균제곱오차에 수렴하기위한 시도 회수.

4.4 수치 예 결과의 비교 분석

이상의 수치 예는 다음과 같은 몇 가지 결과를 나타내었다

- (1) 표 4.7,11에서, 최적화 과정 중 인공신경망을 이용하여 재해석 부분을 대체한 경우(Type II,III,IV,V)와 실제 유한요소해석법에 따른 재해석을 수행한 최적화 기법(Type I)과의 상대오차는 7부재 트러스 구조물 1.845 - 0.692%, 10부재 트러스구조물 1.723 - 0.577%, 21부재 트러스 구조물 1.771 - 0.527% 와 같이 만족할 만한 오차 범위를 보였다. 인공신경망의 학습자료의 증가에 따라 이 오차는 감소하였다. 그러나 7부재 21부재 트러스 구조물의 최적설계의 경우 인공신경망에서 입력자료에 비해 상대적으로 다소 많은 출력결과를 유도하는 경우 좀 더 큰 오차를 보였다.
- (2) 모든 수치 예에서 유한요소해석에 의한 재해석을 이용한 최적화 방법(Type I)에 비해 인공신경망을 활용한 최적화 방법 모두(Type II,III,IV,V,VI,VII) 해석에 소요되는 계산시간 면에서 효율적임을 나타내었다. 구조물의 규모가 커질수록 이 차이는 더욱 증가하고 인공신경망의 학습자료의 수의 증가에 따라 줄어들었다.
- (3) 동일 오차에 도달하는데 소요되는 인공신경망의 학습 효율을 고려해 보면 유전알고리즘의 경우 최적의 연결가중치와 bias를 결정하는데 대략 4~250 (sec)의 시간이 소요되는바 소요시간에 따른 효율은 역전파알고리즘에 비해 효율적이라고 단언할 수는 없으나 역전파알고리즘의 경우 본 수치 예의 표 4.7,11에서와 같이 수차례의 시도를 통해 동일오차에 수렴하도록 하는 설계자의 노력을 감안하고, 또한 역전파 알고리즘은 수

렴을 보장하지 못함을 고려한다면 유전알고리즘에 의한 인공신경망의 학습방법은 보다 편리하고 신뢰성이 있다고 사료된다.

5. 결론

본 연구에서는 확률론적 최적화 기법에 의한 강 구조물의 최적화 과정 중 많은 수의 유한요소 해석이 요구되는 재해석 문제에 인공신경망을 적용함으로써 유한요소법의 평형방정식의 해의 근사해를 추정하여 재해석과정을 보다 간단하고 용이하게 수행하고자 하였다.

최적화 기법으로는 진화론적 최적화 기법인 유전알고리즘을 사용하였으며 최적화 과정 중 재해석 부분에 역전파알고리즘과 유전알고리즘에 의한 두 가지 학습방법을 활용한 인공신경망을 적용하는 방법을 사용해 실제 구조해석을 통한 결과와 비교하고자 하였다. 본 연구의 알고리즘을 연속형 설계변수를 갖는 전형적인 최소 체적(중량)문제와 이산형 설계변수를 갖으며 실제 경비함수를 갖는 최소경비문제에 적용하여 수행한 결과로부터 얻은 결론을 요약하면 다음과 같다.

- (1) 구조 재해석 부분을 인공신경망으로 대체한 결과와 실제 재해석을 유한요소법에 의해 수행한 결과를 서로 비교 시 상대오차가 만족할만한 오차 범위에 존재하며, 학습자료의 증가에 따라 오차가 감소하였다. 또한 인공신경망에 의한 구조해석 결과의 예측을 통해 구조해석에 소요되는 시간이 줄어들었다. 이는 구조물의 규모가 커질수록 그 차이는 커졌으며 사용된 인공신경망의 학습자료의 수의 증가에 따라 줄어들었다.
- (2) 유전알고리즘을 인공신경망에 적용하여 학습시킴으로

써 대표적인 학습방법인 역전파알고리즘의 문제점을 개선할 수 있음을 기존의 다른 분야의 연구에서 확인할 수 있었듯이 구조최적화에 활용되는 인공신경망에서도 유전알고리즘은 역전파알고리즘의 학습을 보장할 수 없는 점과 선정된 오차에 수렴하는데 소요되는 설계자의 많은 노력 등과 같은 문제점을 개선하는데 효과적임을 알 수 있었다.

- (3) 최적설계과정 중 실제 구조해석과 인공신경망에 의한 대체 방법의 비교 시 인공신경망의 학습자료의 준비와 학습에 소요되는 시간을 고려한다면 그 효율성은 문제에 따라 달라질 것이다. 그러나 일련의 설계과정 중 최적설계에 의한 결과는 예비설계단계에 해당함을 감안한다면 반복되는 전체 설계과정에서 이미 학습된 인공신경망의 활용은 효율적이라고 사료되며, 특히 규모가 큰 대형구조물의 최적설계와 좀더 현실적인 설계조건 적용 시 최적화 과정 중 구조 재해석을 개선된 학습방법에 의한 인공신경망으로 대체하는 것은 많은 계산시간의 절감을 가져올 것으로 판단된다.
- (4) 본 연구로부터 인공신경망이 적용되는 다른 분야와 마찬가지로 인공신경망을 활용하는 구조최적화 문제의 경우도 적절한 학습자료의 수의 결정문제와 입력패턴의 수에 따라 상대적으로 많은 출력값을 유도하는 경우 해의 수렴의 안정성에 관한 문제가 야기됨을 알 수 있었다. 따라서 출력값들의 상관관계에 따른 다단계 인공신경망의 적용이 추후 연구과제로 바람직하리라 판단된다.
- (5) 수학적 계획법과 같은 결정론적 최적화기법에서 근사기법에 관한 연구가 활발히 진행되었듯이 본 연구에 사용된 유전알고리즘과 같은 확률론적 최적화기법에서 인공신경망의 적용으로 인한 재해석 부분의 대체는 매우 바람직하다고 사료되며, 추후 좀 더 효율적인 최적화 기법의 적용을 통한 개선된 인공신경망의 학습방법에 관한 연구가 요구된다.

감사의 글

본 연구는 전주공업대학의 지원으로 이루어졌으며 이에 감사드립니다.

참 고 문 헌

김시영(1996) 신경회로망 최적학습을 위한 실수형 유전자 알고리즘에 관한 연구. 석사학위논문, 성균관대학교.

양영순, 한상민(1998) 유전알고리즘을 이용한 신경망의 구성 및 다양한 학습알고리즘을 이용한 신경망의 학습. 1998년도 봄학술발표논문집, 한국전산구조공학회.

이규원, 노민래(1993) 부재력 근사기법을 이용한 아치구조물의 형상최적화에 관한 연구. 대한토목학회논문집 대한토목학회 Vol.13 No.2 pp. 95-109

이규원, 유희중(1993) 응력근사해법을 이용한 평면트러스구조물의 형상최적화에 관한 연구. 대한토목학회논문집 대한토목학회 Vol.13 No.2 pp. 73-84

이규원, 최병한, 임연수(2004) 트러스 구조물의 형상최적화에 관한 연구. 한국강구조학회논문집 한국강구조학회, Vol.16 No.1 pp. 123-134

이상근, 한상훈(1995) 복합적층평판의 이산최적설계. 대한토목학회논문집, 대한토목학회 Vol.15 No.3 pp. 563-570

이승창, 박중권, 이병해(1997) 신경망을 이용한 근사해석모델의 원형개발. 전산구조공학회논문집 전산구조공학회 Vol.10 No.2 pp. 273-281

이승창, 박중권, 이병해(1998) 신경망 근사해석모델에 의한 스티브거더의거동예측. 전산구조공학회논문집 전산구조공학회 Vol.11 No.3 pp. 241-251

임정환, 이규원(1991) 혼합조정법에 의한 평면트러스 구조물의 형상최적화에 관한 연구. 대한토목학회논문집, 대한토목학회 Vol.11 No.1 pp. 55-68

정영식, 김창규(1995) 평면뼈대구조물에 적용된 최적기준. 1995년도 가을학술발표논문집 한국전산구조공학회 pp. 17-24

조효남, 민대홍, 김성현(2002) 개선된 고차 Convex 근사회를 이용한 구조최적설계. 2002년도 가을학술발표논문집. 한국전산구조공학회 pp. 271-278.

조효남, 민대홍, 김성현, 이광민(2003) 고차 Convex 근사기법을 이용한 강상자형교의 최적설계. 2003년도 봄학술발표논문집. 한국전산구조공학회. pp. 201-210

조효남, 이성칠, 오달수, 최윤석(2002) 신경망을 재해석기로 사용한 구조물의 손상평가. 2002년도 학술발표논문집 한국강구조학회. pp. 80-86

최병한 (2004) 예비 구조설계를 위한 유전알고리즘을 이용한 다단계 인공신경망에 관한 연구. 한국강구조학회논문집 한국강구조학회, Vol.16 No.4

한상훈, 장동진, 변근주(1989) Force Approximation Method 에 의한 평면트러스 구조의 형상최적화. 1989년도 학술발표회 논문집 대한토목학회 pp. 119-122

Aaron R.L, Aurali F.B and Margarita C.G(1993) Genetic Algorithm like Learning Rule for Neural

- Network. Proc. '93 *IEEE Conf. on SMC*, Le Touquet, France. Vol.1, pp. 137-142.
- Arena P., Caponetto R., Fortuna L. and Xibilia M.G.(1993) MLP Optimal Selection Via Genetic Structural Optimization. *Struct. Optim.* Vol.2, pp. 117-24.
- Fleury C. and Braibant V.(1986) Structural Optimization: A New Dual Method Using Mixed Variable. *Int. Num. Meth. Engng.* Vol.23 pp. 409-428.
- Goldberg D. E.(1989) *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley.
- Noor A. K. and Lowder H. E.(1975) Structural Reanalysis via Mixed Method. *Comput.Struct.* Vol.5 pp. 9-12.
- Schmit L.A. and Farshi B.(1974) Some Approximation Concepts Results in a Higher-Approximation Synthesis. *AIAA* Vol.12 pp. 692-699
- Storaasli O. O. and Sobieszczanski-Sobieski J.(1974) On the Accuracy of the Taylor Approximation for Structure Resizing. *AIAA* Vol.12 pp. 231-233.
- Torreele J.(1991) Temporal Processing with Recurrent Networks : An Evolutionary Approach. Proc. 4th. *Int. Conf. On Genetic Algorithms*. San Diego.
- Algorithms. Proc. *Int. Conf. Neural Networks and Genetic Algorithms*. Innsbruck. Austria.
- Fadel G. M., Riley M. F. and Barthelemy J.M.(1990) Two Point Exponential Approximation Method for
- Wang L.P. and Grandhi R.V.(1995) Improved Two-Point Function Approximations for Design Optimization. *AIAA* Vol.33 pp. 1720-1727.
- Wang L.P., Grandhi R.V. and Canfield R.A.(1996) Multivariate Hermite Approximations for Design Optimization. *Int. J. Num. Meth. Engng.* Vol.39 pp. 787-803.
- Wolfram Schiffmann and Klaus Mecklenburg(1990) *Genetic Generation of Backpropagation Trained Neural Networks*. Elsevier Science Publishers.
- Zhang W.H. and Fleury C.(1997) A Modification of Convex Approximation Methods for Structural Optimization. *Comput. Struct.* Vol.64 pp. 89-95.
- Chung T.T. and Chiou C.H.(2000) Self-Adjusted Convex Approximation Method for Structural Optimization. *Department of Mechanical Engineering National Taiwan University* Taipei 10617, Taiwan, ROC.
- (접수일자 : 2005. 7. 29 / 심사일 2005. 9. 2 / 심사완료일 2005. 11. 15)