

# 예비 구조설계를 위한 유전알고리즘을 이용한 다단계 인공신경망에 관한 연구

## A Study on the Multi-Level Artificial Neural Networks Using Genetic Algorithm for Preliminary Structural Design

최 병 한<sup>1)</sup>

Choi, Byoung Han

요 약 : 인간의 뇌와 유사한 병렬 연산 모델을 활용하여 다양하고 복잡한 비선형적인 문제에 효과적으로 연관관계를 조직화 할 수 있는 인공신경망에 관한 연구가 근래에 공학의 넓은 분야에서 도입되고 그에 따른 많은 성과가 나타나고 있다. 본 연구에서는 설계자의 판단력과 경험에 의존 하던 기존의 예비구조설계 단계에 효과적인 인공신경망을 적용하여 예비 구조설계 단계에 컴퓨터를 이용한 정형화된 방법을 제시하고자 한다. 이를 위해 각 구조물의 일반적인 설계과정에 따른 다단계 신경망을 제시하고 인공신경망의 학습은 역전파알고리즘과 유전알고리즘을 적용하여 예비구조설계의 원형을 구현한다. 이와 같이 구성된 다단계 신경망을 사장교의 예비구조설계 단계에 활용하여 본 연구의 적용성과 두가지 학습기법에 따른 결과를 비교 분석 한다.

ABSTRACT : Recently, the Artificial Neural Network(ANN) which can organize complex non-linear problems by effectively applying the parallel computational model that is similar to the human brain, was adopted in the wide department of technology and resulted in many successful applications. In this study, a more appropriate formal method is suggested for the preliminary structural design stage controlled merely by the designer's experience and intuition. To do so, this study proposes a multi-level ANN according to the general progressive structural design procedure, using Back-Propagation Algorithm (BP) and Genetic Algorithm (GA) for the ANN learning. The preliminary structural design of cable-stayed bridges was applied to illustrate the applicability of the study formulated as stated above, and the results of two different learning methods were compared.

핵심용어 : 다단계 인공신경망, 역전파알고리즘, 유전알고리즘, 예비구조설계, 사장교

KEYWORDS : Multi-Level Artificial Neural Networks, Back-Propagation Algorithm, Genetic Algorithm, Preliminary Structural Design, Cable-Stayed Bridges

### 1. 서론

인공신경망은 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 인공신경망(Artificial Neural Network: ANN)은 각 연산요소의 병렬처리로 빠른 연산 및 정보의 분

산표현이 가능하고 역전파알고리즘(Back-Propagation Algorithm:BP) 학습법의 개발로 인해 패턴인식, 제어, 설계, 지식정보처리 등과 같은 다양한 공학 분야에 널리 도입되고 그에 따른 성과가 나타나고 있다.

특히 토목공학 분야에서는 수문학, 교통공학 및 구조물 손상탐지와 같은 연구에 활발히 적용되고 있으며, 최근에는 인공신경망을 구조설계과정에 도입한 설계시스템 개발에 관한 몇몇 연구가 이루어지고 있다.(Abhijit 등, 1995; 김남희 등, 2001)

1) 정회원, 전북대학교 부설 공학연구원 공업기술연구센터 연구원,  
호원대학교 건축·토목공학부 겸임교수, 공학박사  
(Tel.063-270-2420, Fax.063-270-2421, E-mail:han1020@shinbiro.com)

본 논문에 대한 토의를 2005년 2월 28일까지 학회로 보내주시면 토의 회답을 게재하겠습니다.

통상적인 구조설계란 여러 과정을 거쳐 이루어지는데, 대별하면 예비설계(기본설계)단계와 구조해석단계 및 본 설계(상세설계)단계로 분류할 수 있다. 이들 중 예비설계 단계는 가장 중요한 단계로써 구조시스템 전반의 최적계획을 수립하는 과정이다. 즉, 구조적으로 효율적인 기능과 성능을 발휘 할 수 있는 최적의 구조형식, 형태, 형상, 및 구조배치 등의 중요한 대안을 선정하는 과정이다. 그런데 이러한 과정은 모두 다년간의 구조설계 경험과 설계전문가의 창의성, 판단력 및 직관 등에 의해 이루어지며, 이때 결정된 인자들은 설계전반에 걸쳐 커다란 영향을 미친다. 따라서 본 연구에서는 매우 복잡적이며 다양성을 갖는 기존의 경험과 설계자의 직관 및 판단력에 의한 예비설계단계에 컴퓨터를 이용한 정형화된 설계방법을 제시하고자 복잡하고 불확실성이 내재하는 비선형관계에서 보편성과 적응성을 충분히 갖춘 설계대안을 도출할 수 있는 순차인공신경망(Feed-Forward ANN)을 도입한다. 순차인공신경망은 입력과 출력의 정보흐름이 입력층(Input Layer), 은닉층(Hidden Layer), 출력층(Output Layer)의 방향으로 일정하게 흐르는 형태의 인공신경망을 말하는데, 이는 정보흐름의 측면에서 회귀인공신경망(Recurrent ANN)과 대조된다. 이러한 순차인공신경망이 인공신경망을 이용한 연구의 90%이상을 차지한다(Welstead, 1994)(이후로 순차인공신경망을 인공신경망으로 기술한다.)

또한 예비 구조설계단계 특성 상 적은 입력자료로부터 상대적으로 많은 출력자료를 얻어야 하므로 인공신경망의 학습 과정의 시간문제와 수렴에 대한 안정성 문제가 발생되며, 이에 대한 해결책으로 실무중심의 설계 흐름에 따라 설계과정을 몇 단계로 구분하고 각단계에 적합한 인공신경망을 개발하는 다단계 인공신경망(Multi-Level ANN)을 제시한 바(김남희 등, 2001)있어 본 연구에서도 설계 단계가 진행됨에 따라 이전 단계에서 도출된 출력자료를 다시 현 단계의 입력자료에 추가하여 인공신경망을 구성함으로써 설계 단계를 진행하는 다단계 인공신경망을 적용한다.

인공신경망의 학습방법으로는 인간이 어떠한 사실을 학습하여 자신의 지식으로 축적시킨 뒤 학습된 사실들과 유사한 것에 대해 학습된 것과 비교 검토하여 답을 구하는 방법과 같은 Werbos가 개발한 역전파알고리즘이 대표적인 학습방법으로, 패턴인식, 함수근사화, 적응제어 등의 매우 복잡한 문제를 성공적으로 수행하는 인공신경망에 적합하다.

그러나 근래에는 이러한 역전파 알고리즘의 활발한 활용과 더불어 역전파 알고리즘이 갖는 문제점을 지적하고 이를 개선하려는 연구도 병행되고 있는게 사실이다.(문상우 등, 1998; Aaron 등, 1993; Arena 등, 1993; Torreele, 1991)

역전파 알고리즘이 갖는 문제점은 크게 두가지로 구분된다.

첫번째로 인공신경망의 구조가 학습성능에 매우 큰 영향을 주는데도 불구하고 적합한 인공신경망 구조 결정을 위한 일반적인 접근방법이 없어 시행착오법(Trial-Error Method)을 사용한다는 것이고, 다른 하나는 역전파알고리즘이 사용하는 학습규칙인 델타규칙(Delta Rule)이 인공신경망의 올바른 학습을 항상 보장하지는 못한다는 것이다. 즉, 일반적인 최적화 기법의 관점에서 보면 델타규칙은 인공신경망의 오차를 최소화하기 위해 최대경사법(Steepest Descent Method)을 이용하는 규칙인데, 이러한 최대경사법의 근본적인 문제점으로는 초기값의 선정에 따라 발생될 수 있는 국부 최적해(Local Optimal Solution)에 수렴 가능성이다.

이와 같은 역전파 알고리즘의 문제점을 개선하려는 연구로 최근에 대두되고 있는 방법은 유전알고리즘(Genetic Algorithm:GA)을 이용한 인공신경망의 학습이다. 유전알고리즘은 자연진화의 법칙인 적자생존(Survival of Fittest)과 자연도태(Natural Selection)의 원리를 근간으로 정립된 최적화 알고리즘이다. 인공신경망과 유전알고리즘의 결합이론은 다시 두가지로 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; 김시녕, 1996) 또한 간과 할수 없는 연구 결과로는 유전알고리즘에 의한 학습이 반드시 역전파 알고리즘에 의한 학습결과에 비해 항상 더 좋은 결과를 도출한다고는 단언할 수 없다는 것이다.(임승현 등, 2002)

본 연구에서는 대표적인 인공신경망의 학습방법인 역전파 알고리즘을 이용한 학습방법을 적용하고, 또한 인공신경망에 유전알고리즘을 결합하여, 학습시간과 국부최적해에 수렴가능성의 문제를 해결할 수 있으며 프로그래밍이 용이한 인공신경망의 연결가중치의 최적화 방법에 의한 학습방법을 사용하고 자 하며 이 두가지 학습방법에 따른 결과를 비교하려 한다.

학습방법에 따른 예측력 평가를 위해 본 연구에서는 미시적 비교방법으로 이용되는 평균제곱근오차(Root Mean

Square Error:RMSE)를 두가지 모형간의 예측력 비교척도로 삼았다.

이상과 같이 기술된 본 연구의 알고리즘을 케이블(Cable)과 보강형(Girder), 주탑(Pylon)으로 구성된 교량형식으로 케이블의 장력으로 인해 보강형의 단면의 크기를 작게하여 경제적인 교량을 가설할 수 있으며, 모멘트의 분포도 균일하게 할 수 있고 교각의 수도 일반교량보다 크게 경감시킬 수 있고, 구조형식의 다양성과 미관의 우수성 등으로 일본과 구미 유럽에서 많이 건설 되었고, 1980년대 초반 이후로 국내에서도 장대교량 형식으로 널리 쓰이는 사장교의 예비설계 단계에 적용하여 그 결과를 살펴보고자 한다. 연구범위로는 구조적 성능 및 시공성, 경제성, 주변경관과의 조화에 매우 큰 영향을 주며, 사장교 예비구조설계에서 중시되는 구조 형상 결정에 국한한다.

본 연구내용의 구성으로는 먼저, 학습될 사장교의 설계 자료를 선정하고 일반적인 실제 예비설계 단계에 따른 인공신경망을 선정하며, 두가지 학습방법을 적용하여 각 단계별 인공신경망을 구동하여 그 결과를 비교 분석한다. 또한 본 다단계 인공신경망의 학습결과의 신뢰성을 살펴보기 위해 학습되지 않은 실제 사장교의 예를 통해 검증한다.

## 2. 학습 자료 선정

본 연구의 다단계 인공신경망의 학습을 위한 사장교의 예비설계자료로는 한국건설기술연구원의 보고자료(방명석 등, 1995)에서 표 8과 같이 준비하였으며, 이해를 돕기 위해 변수설명을 표 7과 같이 기입하였다. 또한 준비된 학습자료는 다음과 같은 이유로 변환될 필요성이 있다. 첫째, 입력자료(Input Data)의 중요도는 동일해야 하며, 둘째, 출력자료(Output Data) 및 목표자료(Target Data)는 출력 전달함수(Transfer Function)또는 활성화 함수(Active Function))가 가질 수 있는 범위에 대응되어야 한다. 따라서 본 연구의 다단계 인공신경망의 입, 출력 자료 및 목표자료는 선형변환을 이용하여 0~1의 범위를 갖도록 자료변환 하였다.

## 3. 사장교의 예비설계 단계에 따른 다단계 인공신경망 결정

실제 설계에서 설계자의 주관과 경험 및 각종 요구조건에 따라 설계 절차는 다양하게 달라질 수 있으나, 본 연구에서는 일반적인 사장교의 예비 설계절차를 표 1과 같이 국한하여 정리하였다.

표 1. 사장교의 예비구조설계 단계

| 단 계    | 설계 조건              | 결정 인자                  |
|--------|--------------------|------------------------|
| step 1 | 차선 폭               | 케이블거치면 수               |
| step 2 | 교량연장               | 타워 개수/ 경간분할            |
| step 3 | 경간길이               | 주탑높이/<br>주탑높이와주경간길이의 비 |
| step 4 | 주경간길이, 주탑높이        | 케이블형상 및 개수             |
| step 5 | 케이블거치면 수, 형상, 및 개수 | 타워형상                   |

표 1과 같은 예비설계단계에 따른 다단계 인공신경망의 결정을 위하여 김남희 등(2001)이 제시한 것과 동일한 표 2와 같이 예비설계과정을 4단계로 구분하고 각 단계별 입, 출력층의 노드를 결정하였다.

표 2. 입력층과 출력층의 결정

| 단 계    | 입력층(Input Layer)  | 출력층(Output Layer)          |
|--------|---|----------------------------|
| step 1 | => 교량연장/타워높이/차선폭  | => 타워개수/타워형상               |
| step 2 | => 교량연장/타워높이/차선폭<br>=> 타워개수/타워형상  | =>주탑높이/주경간길이/<br>케이블수      |
| step 3 | => 교량연장/타워높이/차선폭<br>=> 타워개수/타워형상<br>=> 주탑높이/주경간길이/<br>케이블수                            | =><br>BR4/BR5/BR6/TR2/TR3* |
| step 4 | => 교량연장/타워높이/차선폭<br>=> 타워개수/타워형상<br>=> 주탑높이/주경간길이/<br>케이블수<br>=> BR4/BR5/BR6/TR2/TR3* | => BR1/BR2/BR3/TR1*        |

(\* : 표 7 참조)

또한 단계별 은닉층의 결정은 일반적으로 은닉층의 수를 2층이상으로 구성한 인공신경망의 경우 1층으로 구성된 인공신경망에 비해 뚜렷한 성능향상을 얻기 어렵다는 경험을 참고하여 인공신경망의 은닉층을 1층으로 결정하고 각 단계별 은닉층 노드 수의 결정은 시행착오법에 의해 입력노드의 증감에 따라 5, 10, 15, 20으로 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 그림 1과 같은 시그모이드 함수(Sigmoid Function)을 사용한다. 변환된 입력노드의 값이 0 또는 1에 가까운 값과 같이 변방의 값일 경우 중앙 값의 비하여 상대적으로 적은 값을 가지는 출력을 생성하고 중앙값의 경우는 반대로 상대적으로 큰 값을 가지는 출력을 생성하게된다. 이는 인공신경망에 사용되는 문제들이 통계적으로 정규분포를

따르는 임의 값이라 가정하면 그 수가 많은 중앙 값들은 학습 시 변방의 값들보다 많은 영향을 미치게 된다. 그런데 시그모이드 함수는 입력값이 작으면 크게 변하고 크면 작게 변하는 특성을 가지는데 이는 매우 큰 입력값에 대해서는 급격히 변화하는 것을 방지하고 매우 작은 입력값에 대해서는 간과하지 않는다는 장점이 있다.


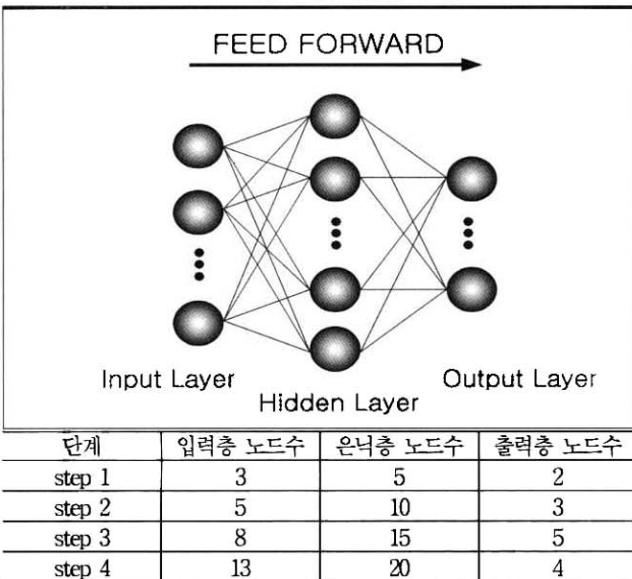


그림 1. 시그모이드 함수

이상에서 기술한 바와 같이 본 연구에서 결정된 다단계 인공신경망의 구조는 표 3과 같다.

표 3. 다단계 인공신경망의 구조



#### 4. 다단계 인공신경망의 학습

본 연구에서는 기존의 사장교 예비설계자료에 대한 학습을 위하여 두가지 방법을 제안한다. 먼저, 인공신경망의 대표적인 학습방법인 역전파알고리즘을 적용하고, 두 번째 최적화 기법인 유전알고리즘과 결합한 학습방법을 적용한다.

#### 4.1 역전파알고리즘에 의한 학습

역전파알고리즘은 다층(Mult-Layer)이고, 인공신경망에서 사용되는 대표적인 방법으로 학습방법은 지도학습(Supervised Learning)이다. 구성된 인공신경망의 초기 연결강도(Connection Weight)와 Bias를 선정하고 입력자료를 입력노드에 적용하여 출력한다. 그리고 얻어진 출력과 목표자료간의 오차를 계산하고 이 오차를 최소화 하기 위해 반복적으로 연결강도와 Bias를 갱신하는 방법이다.

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

$$new W_{kj} = old W_{kj} + \Delta W_{kj} \quad (1)$$

$$여기서 \quad \Delta W_{kj} = -\eta \frac{\partial E}{\partial W_{kj}} \quad (2)$$

$W_{kj}$  : k번째 층에서 j번째 층간의 연결강도.

$\eta$  : 학습률

$E$  : 오차

위 식 (2)의 구배를 계산하면,

$$\Delta W_{kj} = \eta \delta_k^o H_j \quad (3)$$

$$여기서, \delta_k^o = \delta_k f'_k \quad (4)$$

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

$f_k$  : k 층의 전달함수

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

$f'_k$  : k 층 전달함수의 도함수.

$H_j$  : j 층의 활성화 값

따라서 식 (1)을 다시쓰면

$$new W_{kj} = old W_{kj} + \eta \delta_k^o H_j \quad (5)$$

그런데, 이와 같은 과정은 적절한 해에 도달하기위해 많은 반복을 요하는 매우 느린 알고리즘이다. 이를 개선하기위해 본 연구의 역전파알고리즘은 다음과 같은 모멘텀항을 고려한다. 모멘텀은 이전 반복에 사용된 연결강도와의 변화함수로써, 반복적인 진동을 제거할 수 있으며, 속도 향상에 도움이 된다.

$$new W_{kj} = old W_{kj} + \eta \delta_k^o H_j + \xi old \Delta W_{kj} \quad (6)$$

여기서,  $\xi$ : 모뎀 상수

$$old\Delta W_{kj} = old W_{kj} - older W_{kj} : 모뎀$$

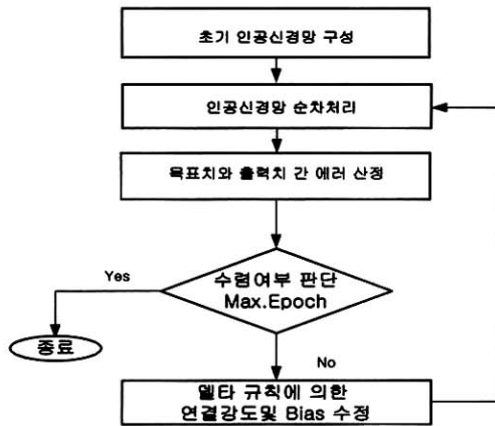


그림 2. 임의 설계단계의 역전파알고리즘을 이용한 인공신경망 순서도

#### 4.2 유전알고리즘과 역전파알고리즘과의 결합에 의한 학습

최적화 관점에서 인공신경망의 학습은 목적함수가 목표치와 출력치의 차이인 에러이고 설계변수가 각 층간의 연결강도와 Bias인 비제약최적화 문제(Unconstrained Optimization Problem)이다. 따라서 현재 주류를 이루는 학습방법인 역전파알고리즘은 결정론적(Deterministic) 최적화 기법인 최대경사법을 사용한 것이고 이외는 대조적으로 확률론적(Stochastic) 최적화 기법의 적용도 연구대상으로 다룰 수 있다.

기존의 많은 최적화 연구에 의하면 결정론적 기법은 현재 설계점에서 항상 탐색방향과 이동구간이 정해져 있으므로 빠르게 설계점의 이동이 가능하지만 국부최적해에 수렴할 가능성이 늘 존재한다. 확률론적 기법은 탐색방향(Search Direction)과 이동구간(Step Size)을 임의(Random)로 선택할 수 있고 넓은 설계영역을 다룰 수 있어 전역적 최적해(Global Optimum Solution)를 구하는 능력이 탁월한 반면에, 많은 양의 계산을 수행해야하므로 계산시간이 많이 소요되며 설계점이 최적해 부근에 이르러서는 더 이상 효율적이지 못하는, 즉 국부탐색(Local Search)에는 수렴속도가 대단히 느린 것으로 알려져 있다. 결국 전역적 최적해를 구하면서 시간을 줄일 수 있는 대안으로 두가지 최적화기법을 결합한 방법을 들 수 있다.

본 연구에서는 이러한 목적으로 다단계 인공신경망의 연결강도와 Bias 결정을 위해 확률론적 기법인 유전알고리즘을 이용하여 전역적 최적해 부근까지 탐색을 수행하고 그 다음으

로 최대경사법을 이용하는 역전파알고리즘에 의한 학습에 의해 최종 연결강도와 Bias를 결정하려 한다.

그림 3과 같은 결합모형도에 의해 본 결합알고리즘을 수행하며, 본 연구 유전알고리즘에 사용되는 매개변수(Parameters)는 표 4와 같이 선정하였다.

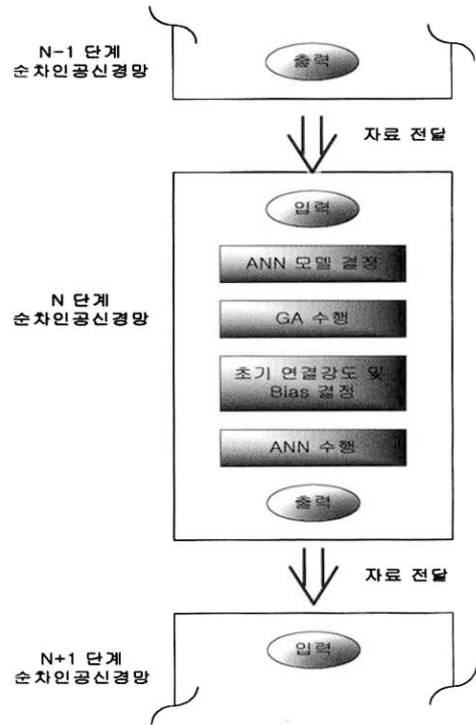


그림 3. 유전알고리즘과 인공신경망 결합 모형도

표 4. 유전알고리즘의 매개변수 선정

|                                 |      |
|---------------------------------|------|
| 개체집단의 크기(Population Size)       | 50   |
| 최대 세대수 (Max. Generation No.)    | 5000 |
| 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 4와 같이 실수 코딩(Real Coding)을 사용하여 표현하였다. 이는 이진코딩(Binary Coding)에 의한 유전알고리즘의 표현은 실수형 변수로 구성된 문제를 해결하기 위해 컴퓨터 주 기억용량을 많이 사용하게 되며, 또한 계산과정 중 이진형태에서 실수형으로 상호변환으로 계산시간이 무척 많이 소요되기 때문이다.

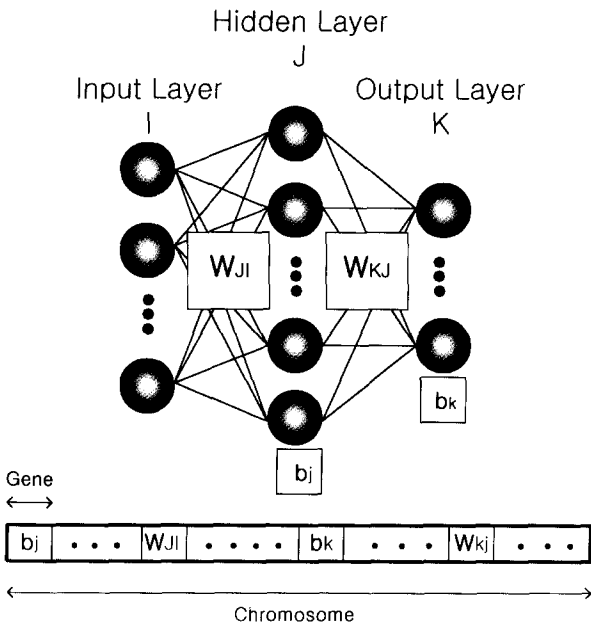


그림 4. 연결강도와 Bias의 염색체 표현

이와 같이 표현된 개체집단을 인공신경망에 따라 처리하고 다음으로 개체집단을 평가하기 위해 전체 학습자료에 대한 평균제곱근오차를 계산하여 그 역수를 적합함수(Fitness Function)로 사용하여 적합도를 평가한다.

$$RMSE = \sqrt{\frac{1}{N} \sum_k (T_k - O_k)^2} \quad (7)$$

여기서, \$T\_k\$ : k층의 목표출력 값

\$O\_k\$ : k층의 실제출력 값

$$F = \frac{1}{RMSE} \quad (8)$$

유전알고리즘의 연산과정에 사용되는 연산자로는, 먼저 재생산을 위한 개체선택 도구로는 초기세대에 초우량 개체가 출현함으로써 유전적 다양성을 감소시키고 확률적으로 최적개체를 반드시 선택하지 못하는 점을 극복하기 위해 Gradient-

Based Selection을 사용하였다. 교배방법으로는 개선된 단순교배(Modified Simple Crossover)를, 돌연변이과정은 동적돌연변이(Dynamic Mutation)을 사용하였다. 또한 탐색과정 중 개체집단내에서 가장 적합도가 높은 엘리트 개체가 교배나 돌연변이 과정을 거치지 않고 다음 세대로 남기는 De Jong이 소개한 엘리트 보존전략(Elitist Strategy)를 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.

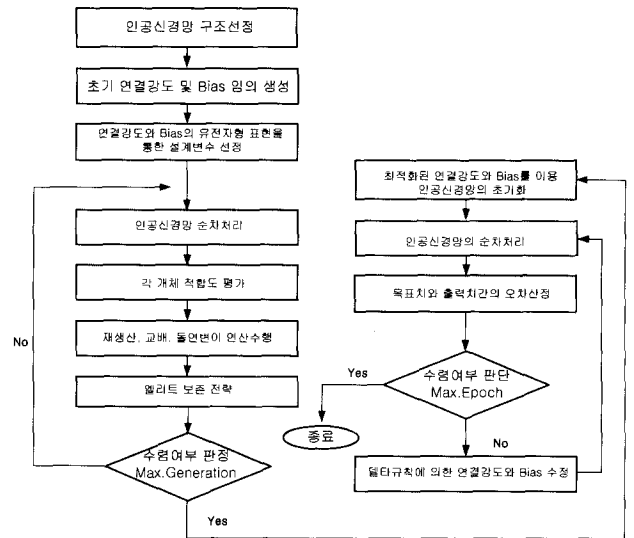


그림 5. 임의 설계단계의 유전알고리즘과 결합한 인공신경망 순서도

### 5. 다단계 인공신경망의 학습결과 비교 및 검증

본 연구에서는 사장교의 예비설계를 위한 다단계 인공신경망의 학습을 위해 두가지 방법을 사용하였다.

역전파알고리즘에 의한 방법과 유전알고리즘과의 결합에 의한 방법에 의해 각각 5000번의 반복학습(Epoches) 후, 예측력을 평가하기 위해 평균제곱근오차를 각 단계별로 계산하여 이를 비교함으로써 두가지 학습방법을 평가하고자 하며, 이 오차가 매우 작은 경우에 타당성이 있다고 판단할 수 있다.

각 학습방법에 따른 사장교 예비설계를 위한 다단계 인공신경망의 단계별 목표자료와 출력자료와의 평균제곱근 오차는 표. 5 와 같다.

표 5. 다단계 인공신경망의 검증

| 단 계     | 학습방법에 따른 평균제곱근오차:RMSE |             |
|---------|-----------------------|-------------|
|         | 역전파알고리즘               | 유전알고리즘과의 결합 |
| Step. 1 | 0.1529                | 0.1041      |
| Step. 2 | 0.0688                | 0.0546      |
| Step. 3 | 0.0445                | 0.0445      |
| Step. 4 | 0.0438                | 0.0430      |

표 6. 학습되지 않은 설계자료에 대한 다단계인공신경망의 검증

|             | 입·출력 자료*       |                |               |                 |                 |                  |      |       |       |       |       |       |       |       |       |
|-------------|----------------|----------------|---------------|-----------------|-----------------|------------------|------|-------|-------|-------|-------|-------|-------|-------|-------|
|             | 교량연장<br>(Blen) | 타워높이<br>(Tlen) | 폭원<br>(Width) | 타워개수<br>(Btype) | 타워형식<br>(Ttype) | 케이블수<br>(NumCab) | BR1  | BR2   | BR3   | BR4   | BR5   | BR6   | TR1   | TR2   | TR3   |
| 원 설계        | 455.8          | 43             | 23            | 2               | 6               | 9                | 0    | 76    | 28.5  | 28.5  | 80    | 12.5  | 0     | 27    | 16    |
| 방법 A*       | 455.8          | 43             | 23            | 2               | 5.67            | 8.75             | 2.05 | 65.50 | 34.04 | 42.87 | 68.78 | 15.16 | -1.59 | 26.13 | 16.50 |
| 상대오차<br>(%) | -              | -              | -             | 0               | 5.5             | 2.8              | 100  | 13.8  | 19.4  | 50.4  | 14.0  | 21.3  | 100   | 3.2   | 3.1   |
| 방법 B*       | 455.8          | 43             | 23            | 2               | 6               | 9.11             | 1.86 | 67.12 | 34.03 | 42.93 | 68.64 | 14.44 | -1.08 | 25.98 | 16.41 |
| 상대오차<br>(%) | -              | -              | -             | 0               | 0               | 1.2              | 100  | 11.7  | 19.4  | 50.6  | 14.2  | 15.5  | 100   | 3.8   | 2.6   |

방법 A\* : 역전파알고리즘에 의한 학습  
 방법 B\* : 유전알고리즘과의 결합에 의한 학습  
 입·출력자료\* : 표. 7 참조

두가지 학습방법 모두 각 단계에서 평균제곱근오차가 0.1529 ~ 0.0430 의 오차범위로 매우 만족스러운 결과를 얻었으며, 미소하게 유전알고리즘과의 결합에 의한 학습방법이 좀더 나은 결과를 낳았다.

그러나 역전파알고리즘에 의한 학습결과는 수차례 시행착오를 겪어 얻은 값임을 감안한다면 유전알고리즘과의 결합에 의한 방법이 좀더 설계자의 노력면에서 유리함을 알 수있다.

또한 본 연구 사장교의 예비설계를 위한 다단계 인공신경망의 보다 객관적인 검증을 위해 학습자료로 쓰이지 않은 설계자료에 대한 시도가 필요하다. 여기에서 유의할 점으로는 본 연구의 인공신경망과 동일한 방식으로 먼저 자료변환이 이루어져야 한다는 것이다. 따라서 학습되지 않은 설계자료로서 기 사용된 일본의 쇼난신도 교량을 대상으로 먼저 자료변환을 하고 두가지 학습방법에 의한 다단계 인공신경망을 검증 하였다. 그 결과는 표. 6과 같이 비교적 적은 오차범위를 보여준다.

## 6. 결 론

본 연구는 예비구조설계 절차에 따른 인공신경망을 단계별로 설정하고 학습방법으로 대표적인 학습방법인 역전파알고리즘에 의한 학습과, 역전파알고리즘의 문제점을 개선하기 위하여 확률론적기법과 결정론적기법의 결합의 형태인 유전알고리즘과 역전파알고리즘을 결합한 학습 방법을 사용하여 사장교의 예비구조설계를 실시하였다. 그 결과를 요약하면 다음과 같다.

- (1) 본 연구에서는 예비 구조설계와 같은 적은 수의 입력자료로부터 상대적으로 많은 출력자료를 구해야 하는 경우 하나의 인공신경망 모델을 이용할 경우 발생하는 학습시간문제와 수렴성의 불안정성 등을 피하기 위해 설

계 단계가 진행됨에 따라 이전 단계에서 도출된 출력자료를 다시 현 단계의 입력자료에 추가하여 인공신경망을 구성하면서 설계 단계를 진행하는 다단계 인공신경망을 구축하여 만족할 만한 결과를 얻었다.

- (2) 유전알고리즘을 인공신경망에 결합하는 모델을 다단계 인공신경망에 이용함으로써 여러번 인공신경망을 구동하는 시행착오를 거치지 않아도 적합한 해를 얻을 수 있었으며, 또한 얻어진 해가 국부적인 해에 수렴하는 문제를 완전히 극복했다고는 단정할 수는 없으나 국부적인 해에 수렴할 가능성을 확률적 최적화 기법인 유전알고리즘을 적용함으로써 줄일 수 있었다.
- (3) 유전알고리즘을 인공신경망에 결합하여 학습시키므로써 대표적인 학습방법인 역전파알고리즘의 문제점을 개선할 수 있음을 기존의 연구에서 확인할 수 있었듯이 다단계 인공신경망에서도 유전알고리즘과의 결합을 통해 설계자의 노력과 시간을 절약할 수 있으며, 좀 더 나은 결과 예측력을 보였다.


향후 예비구조설계와 같이 다단계 인공신경망이 적합한 문제는 여러 분야에서 발견될 수 있으리라 본다. 따라서 이러한 다단계 인공신경망의 적용성을 높이기 위해 주변환경, 경비, 미관과 같은 보다 많은 자료의 변수화가 요구되며, 또한 다단계 인공신경망의 효율성을 높이기 위한 노력으로 확률인공신경망 또는 퍼지인공신경망의 적용과, 다단계 인공신경망 구조의 최적화에 관한 연구 등이 진행되어야 할 것이다.

## 감 사 의 글

본 연구는 전북대학교 부설 공학연구원 공업기술연구센터의 지원으로 이루어졌으며 이에 감사드립니다.

표 7. 인공신경망의 입·출력변수 정의

| 설 계 변 수 | 정 의                       |
|---------|---------------------------|
| Blen    | 교량연장                      |
| Tlen    | 타워높이( $TR1 + TR2 + TR3$ ) |
| Width   | 폭원                        |
| Btype   | 타워개수                      |
| Ttype   | 타워형식(1~6)                 |



|   |                     |
|---|---------------------|
| Mslen                                       | 주경간 길이              |
| Plen  | 주탑높이( $TR2 + TR3$ ) |
| NumCab                                      | 케이블 개수              |
| BR1, BR2, BR3, BR4, BR5, BR6, TR1, TR2, TR3 | 케이블 배치 형상           |






표 8. 인공신경망 학습 및 검증에 사용된 설계자료

| No. | Blen | Tlen | Width | Btype | Ttype | BR1   | BR2   | BR3   | BR4   | BR5  | BR6   | TR1  | TR2  | TR3 | NumCab |
|-----|------|------|-------|-------|-------|-------|-------|-------|-------|------|-------|------|------|-----|--------|
| 1   | 796  | 117  | 24.1  | 2     | 3     | 0     | 123.5 | 26.5  | 34    | 196  | 15    | 32.3 | 52.5 | 33  | 14     |
| 2   | 177  | 46.5 | 15.7  | 1     | 5     | 33.5  | 10.2  | 44.8  | 44.8  | 10.2 | 33.5  | 11.4 | 29.1 | 6   | 3      |
| 3   | 274  | 56.5 | 8.2   | 1     | 1     | 0     | 96    | 24    | 24    | 96   | 32.2  | 0    | 47.5 | 9   | 7      |
| 4   | 93   | 33.5 | 5.1   | 1     | 3     | 0     | 20    | 14    | 14    | 28   | 16    | 13   | 17   | 4   | 3      |
| 5   | 230  | 47   | 8.8   | 1     | 5     | 28.5  | 60    | 18    | 18    | 60   | 44.5  | 10.1 | 29.4 | 8   | 6      |
| 6   | 325  | 46   | 10.8  | 2     | 3     | 0     | 61.5  | 3.5   | 3.5   | 60   | 14    | 14.5 | 21.5 | 10  | 6      |
| 7   | 860  | 172  | 40.2  | 2     | 5     | 0     | 156   | 36.5  | 36.5  | 156  | 37.5  | 45   | 87.9 | 39  | 11     |
| 8   | 1170 | 185  | 37.5  | 2     | 3     | 0     | 235   | 50    | 50    | 225  | 20    | 48.7 | 70   | 66  | 17     |
| 9   | 700  | 120  | 37.5  | 2     | 3     | 0     | 110   | 30    | 35    | 155  | 15    | 35.9 | 56.8 | 28  | 12     |
| 10  | 456  | 43   | 23.8  | 2     | 6     | 0     | 76    | 28.5  | 28.5  | 80   | 12.5  | 0    | 27   | 16  | 9      |
| 11  | 249  | 71   | 17.7  | 1     | 5     | 0     | 60    | 26    | 26    | 60   | 78.5  | 16.5 | 26   | 29  | 7      |
| 12  | 314  | 56.5 | 15.8  | 1     | 2     | 0     | 83.9  | 28    | 28    | 108  | 66.35 | 5.5  | 37   | 14  | 7      |
| 13  | 134  | 30   | 12.8  | 1     | 1     | 0     | 27    | 18    | 18    | 48   | 24    | 21   | 0    | 9   | 7      |
| 14  | 89   | 22   | 10.3  | 1     | 5     | 16.59 | 11.2  | 16.5  | 16.5  | 11   | 16.91 | 19.1 | 0    | 2   | 2      |
| 15  | 111  | 18.3 | 3.8   | 1     | 4     | 16.5  | 26    | 13    | 13    | 26   | 16.5  | 1.3  | 14   | 4   | 3      |
| 16  | 292  | 46   | 35.3  | 1     | 6     | 0     | 76.2  | 40.62 | 40.62 | 76.8 | 57.74 | 36   | 0    | 10  | 3      |
| 17  | 210  | 26   | 14.7  | 1     | 6     | 0     | 32.83 | 42.93 | 42.93 | 41   | 56.13 | 22   | 0    | 4   | 2      |
| 18  | 386  | 72.6 | 10.4  | 2     | 5     | 0     | 43.5  | 41.5  | 41.5  | 41.5 | 24.5  | 33.3 | 38.1 | 1   | 2      |
| 19  | 514  | 110  | 29.3  | 1     | 5     | 0     | 146.3 | 63.8  | 63.8  | 191  | 63.8  | 18.6 | 22.9 | 69  | 4      |
| 20  | 378  | 34.3 | 20    | 2     | 1     | 0     | 42.1  | 42.8  | 42.8  | 42.8 | 22.4  | 3.09 | 24.2 | 7   | 2      |
| 21  | 280  | 24   | 17.9  | 2     | 6     | 0     | 30    | 30    | 30    | 30   | 20    | 2.4  | 9.6  | 12  | 2      |
| 22  | 630  | 51.8 | 36.3  | 2     | 6     | 0     | 95    | 45    | 45    | 95   | 35    | 4.75 | 26   | 21  | 3      |
| 23  | 209  | 20.7 | 23    | 2     | 6     | 0     | 0     | 42.96 | 42.96 | 0    | 19.69 | 1.66 | 19.1 | 0   | 1      |
| 24  | 470  | 42.8 | 18.5  | 2     | 6     | 11.75 | 50    | 50    | 50    | 50   | 25    | 1.75 | 35.8 | 5   | 2      |
| 25  | 442  | 46   | 17.8  | 2     | 6     | 0     | 54    | 42    | 42    | 54   | 24    | 3    | 29.5 | 14  | 10     |
| 26  | 354  | 52.2 | 16.5  | 2     | 5     | 0     | 0     | 50.15 | 50.15 | 50.2 | 26.55 | 4.4  | 37.8 | 10  | 2      |
| 27  | 653  | 62.4 | 30    | 2     | 6     | 5.5   | 105   | 38.5  | 38.5  | 105  | 34    | 3.6  | 15.3 | 44  | 4      |
| 28  | 319  | 49.1 | 24.3  | 1     | 6     | 0     | 84.9  | 34    | 34    | 84.9 | 81    | 3    | 35.6 | 11  | 8      |
| 29  | 345  | 54   | 21    | 1     | 6     | 5.8   | 120   | 35    | 35    | 120  | 29.2  | 0    | 36   | 18  | 13     |
| 30  | 479  | 41.9 | 26.5  | 2     | 6     | 5.4   | 84    | 31    | 31    | 80   | 8     | 1.9  | 22.5 | 18  | 11     |
| 31  | 229  | 40.5 | 39.1  | 1     | 6     | 6     | 65    | 17.8  | 17.8  | 65   | 57.6  | 2.5  | 6.6  | 31  | 11     |
| 32  | 884  | 137  | 17    | 2     | 5     | 5.4   | 133.4 | 60.63 | 60.63 | 133  | 48.5  | 28.4 | 42.6 | 66  | 12     |
| 33  | 452  | 111  | 28    | 1     | 4     | 8.5   | 182.9 | 18.29 | 18.29 | 201  | 30.48 | 3.05 | 66.5 | 42  | 12     |
| 34  | 781  | 121  | 33    | 2     | 6     | 14.7  | 115.2 | 36    | 36    | 173  | 16.2  | 40.2 | 4    | 77  | 17     |
| 35  | 400  | 107  | 21    | 1     | 4     | 22.5  | 150   | 27.5  | 27.5  | 150  | 22.5  | 24   | 60   | 23  | 13     |

참 고 문 헌

김시녕(1996) 신경회로망 최적학습을 위한 실수형 유전자알고리즘에 관한 연구. 석사학위논문, 성균관대학교.

김남희, 장승필, 이승철(2001) 점진적 구조설계를 위한 다단계 신경망. 2001년도 봄 학술발표 논문집 한국전산구조공학회 pp.233-240.

문상우, 공성곤(1998) GA를 이용한 신경망 가중치의 최적화. 1998년도 추계학술대회 학술발표 논문집 한국퍼지 및 지능시스템학회

임승현, 이근상, 양옥진, 조기성(2002) 유전자 및 역전파알고리즘을 적용한 신경망연산에 의한 토지적합성분석. 대한토목학회 논문집 대한토목학회 제22권 제6D호 pp.1317-1326.

방명석 등(1995) 장대교량의 설계 및 시공에 관한 연구 건기 연95-SE-112-2 한국건설기술연구원

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.

Abhijit Mukherjee and Jayant M. Deshpande(1995) Modeling Initial Design Process Using Artificial Neural

Network. *J. Computing in Civil Engineering*. ASCE. Vol.9 No.3 pp.194-200.

Arena P. , Caponetto R. , Fortuna L. and Xibilia M.G(1993) MLP Optimal Selection Via Genetic Algorithms. Proc. *Int. Conf. Neural Networks and Genetic Algorithms*. Innsbruck. Austria.

Goldberg D.E(1989) *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley.

Torrelee J.(1991) Temporal Processing with Recurrent Networks : An Evolutionary Approach. Proc. 4th. *Int. Conf. On Genetic Algorithms*. San Diego.

Welstead S.T(1994) *Neural Network and Fuzzy Logic Applications in C/C++*. John Wiley and Sons. New York

Wolfram Schiffmann and Klaus Mecklenburg(1990) *Genetic Generation of Backpropagation Trained Neural Networks*. Elsevier Science Publishers.

(접수일자 : 2004. 6. 15 / 심사일 2004. 6. 30 /  
심사완료일 2004. 7. 26)