

진화 프로그래밍 기법을 이용한 신경망의 자동설계에 관한 연구

A Study on an Artificial Neural Network Design using Evolutionary Programming

강 신 준, 고 택 범, 우 천 희, 이 덕 규, 우 광 방
(Sin-Jun Kang, Taek-Beom Koh, Chun-Hee Woo, Deog-Kyoo Lee, and Kwang-Bang Woo)

Abstract : In this paper, a design method based on evolutionary programming for feedforward neural networks which have a single hidden layer is presented. By using an evolutionary programming, the network parameters such as the network structure, weight, slope of sigmoid functions and bias of nodes can be acquired simultaneously. To check the effectiveness of the suggested method, two numerical examples are examined. The performance of the identified network is demonstrated.

Keywords : genetic algorithm, evolutionary programming, artificial neural network

I. 서론

신경망은 여러 가지 응용분야에서 많이 사용되고 있으며, 성능 개선을 위해 많이 연구되고 있다. 응용분야의 특성에 적절한 신경망을 설계하기 위해서는 우선 신경망의 구조를 결정해야 하며, 또한 각 노드와 링크를 구성하는 함수 및 하중치를 적절한 학습 알고리즘을 사용하여 동정해야 한다. 경사 수렴법을 이용한 학습 알고리즘, 즉, 신경망 파라미터를 오차 함수의 기울기에 따라 오차를 줄이는 방향으로 변경시키는 학습 알고리즘은 그들이 최적화하는 신경망의 노드 숫자와 그들의 연결과 같은 토폴로지를 학습하는 것에는 부적절하다. 이와 같이 파라미터 동정에는 여러 가지 알고리즘이 제안되고 있으나, 신경망의 구조는 대부분 경험에 의한 시행착오를 통해 결정된다. 이러한 방식은 연산량의 증가와 비효율 등의 문제를 가지고 있다.

유전 알고리즘 및 진화 프로그래밍은 자연 선택의 원리와 자연계의 생물 유전학에 기본 이론을 두며 병렬적이고 전위적인 탐색 알고리즘으로, 모든 생물은 주어진 다양한 환경속에 적응함으로써 살아남는다는 다윈의 적자생존의 이론을 기본 개념으로 한다[1]. 유전 알고리즘 및 진화 프로그래밍은 해결하고자 하는 문제에 대한 가능한 해들을 정해진 형태의 자료 구조로 표현한 다음 이들을 점차적으로 변형함으로써 점점 더 좋은 해들을 만들어내게 된다.

이러한 알고리즘은 주어진 문제의 해가 될 가능성이 있는 것들에 대한 표현을 적절히 하는 것과 그에 적합한 연산자를 정의하는 것에 의해 그 성능이 직접적으로 결정된다. 신경망 역시 이러한 접근 방식을 통하여 설계할 수 있으며, 최근 유전 알고리즘 등을 사용하여 여러 가

지 문제해결에 적합한 신경망을 설계하는 데 있어 만족할 만한 결과가 얻어졌다[3]-[8]. 하지만 대부분의 경우 신경망의 구조 및 연결하중의 동정에 국한되고 있다.

본 논문은 하나의 은닉층을 갖는 순방향 신경망 모델의 생성을 하는 데 있어서 진화 프로그래밍에 기초를 둔 설계방법을 제안한다. 신경망의 성능에 영향을 미치는 신경망의 구조, 하중치, 뉴런의 바이어스 및 시그모이드 함수의 기울기와 같은 파라미터들을 전역 탐색 알고리즘인 진화 프로그래밍에 알맞은 형태로 표현하였으며 미리 설정된 최대값 이내에서 노드 및 링크의 생성/삭제가 가능하도록 연산자를 구현하였다. 구현된 기법을 이용하여 주어진 문제에 적합한 신경망 구조 및 파라미터를 동정한다. 제안된 기법을 통해 생성된 신경망의 성능을 제시하기 위해 수치적인 데이터를 통한 시뮬레이션 결과를 나타내었다.

II. 진화 프로그래밍

진화 프로그래밍은 유전 알고리즘과 같이 자연 선택의 원리와 자연계의 생물 유전학에 기본 이론을 두는 탐색 알고리즘으로, 모든 생물은 주어진 다양한 환경속에 적응함으로써 살아남는다는 다윈의 적자생존의 이론을 기본 개념으로 하며 각 세대를 구성하는 여러 개체의 상호작용에 의해 탐색이 진행된다. 또한 전역적인 최적의 해를 발견할 높은 가능성을 가진다는 장점과 목적 함수값에 대한 수학적 제약이 거의 없기 때문에 여러 분야에 적용할 수 있다.

제조업 연산자로서 교배와 돌연변이 연산자를 사용하는 유전 알고리즘과는 달리 진화 프로그래밍은 최적화에 사용될 때, 제조업 연산자로서 돌연변이 연산만을 가지고 있다. 또한 유전 알고리즘은 염색체로서 0과 1로 구성된 이진 스트링을 사용한다. 따라서 논리적인 의미의 표현에는 적절하나 필연적으로 양자화 오차를 가지고 있다. 반면 진화 프로그래밍은 실수값을 그대로 염색체로 사용할 수 있기 때문에 그와같은 문제는 발생하지 않는

접수일자 : 1998. 2. 25., 수정완료 : 1999. 2. 9.

강신준, 우천희, 이덕규, 우광방 : 연세대학교 전기공학과

고택범 : 경주대학교 컴퓨터전자공학부

* 본 연구는 ERC-ACI의 연구비 지원에 의해 진행되었습니다.

(과제번호 : ERC-ACI 96K3-0912-01-07-3)

다. 따라서 교배 연산을 위해 최적화할 변수를 이진 스트링으로 변형하여 사용하는 유전 알고리즘과는 달리 최적화할 변수의 변환이 필요 없으므로 문제를 더 자연스럽게 표현할 수 있다.

진화 프로그래밍은 다음과 같은 단계를 통하여 각 개체들을 진화시킨다.

- 1) 난수로 초기화되는 초기세대를 생성한다.
- 2) 각 개체의 적합도를 계산한 후, 그들의 적합도로 석차를 구한다.
- 3) 석차가 상위 50%인 개체를 다음 세대의 자손으로 선택한다. 그리고는 각각의 개체에 아무런 변경 없이 다음 세대로 복사한다.
- 4) 선택된 개체들에게 돌연변이 연산자를 적용한 후, 나머지 50%의 자손세대를 생성한다.
- 5) 종료조건이 만족될 때까지 (2)를 반복한다.

유전 알고리즘과 진화 프로그래밍 모두 신경망의 구조와 연결 하중치를 찾기 위해 사용할 수 있다[3]-[8]. 비록 유전 알고리즘이 몇몇 경우에 성공적으로 신경망의 구조를 찾을 수는 있지만, Angeline 등은 유전 알고리즘은 재조합 공간(recombination space)과 평가 공간(evaluation space)과 같은 두 개의 서로다른 관념적인 탐색 공간에 의존하기 때문에 유전 알고리즘은 신경망을 진화시키기 적절한 구조가 아니라고 제안했다[7]. 유전 알고리즘이 최적의 신경망의 구조를 탐색할 때 개체를 재조합 공간으로부터 평가 공간으로 변환시키기 위해 이진 스트링으로 변수를 표현하는 등 어떠한 변환이 요구된다. 이러한 변환 함수관계를 정의할 때 많은 잠재적으로 중요하고 의미있는 신경망이 배제될 수 있기 때문이다. 더군다나 유전 알고리즘에서 교배 연산을 사용한다는 것으로 인해 탐색과 선택과정에서 필요한 변환함수관계를 정의하기가 더 어렵게 만들 수 있다. 반면에 진화 프로그래밍은 오로지 유전자 재조합 연산자로 돌연변이 연산만을 사용하기 때문에 주어진 문제를 더 자연스럽게 표현할 수 있고 따라서 신경망을 진화시키기 더 적절하다.

III. 신경망의 구조 및 파라미터 동정

신경망의 동정은 크게 두 가지 종류로 구분된다. 하나는 신경망의 구조와 파라미터를 분리하여 구조만을 적절한 알고리즘에 의해 결정된 다음 오차 역전파 알고리즘 등의 방법을 통해 최소의 학습오차를 갖는 파라미터를 결정하는 방법이고, 다른 방법은 신경망의 구조와 파라미터를 하나의 인자로 정의한 다음 최적화 기법을 통하여 동시에 동정하는 방식이다. 본 논문에서는 구조와 파라미터를 동시에 동정하기 위해 후자의 방법을 사용하며, 그에 대한 최적화 기법으로 진화 알고리즘을 사용한다. 신경망을 진화 프로그래밍에 적합하게 표현하기 위해 하나의 인자는 신경망의 구조, 연결하중치, 기울기 및 바이어스와 같은 염색체를 적절히 코딩하는 것으로 구성되며 각각의 연산에 적합한 돌연변이 연산자를 정의한다.

1 신경망의 표현

본 논문에서 고려되는 신경망은 하나의 은닉층을 갖

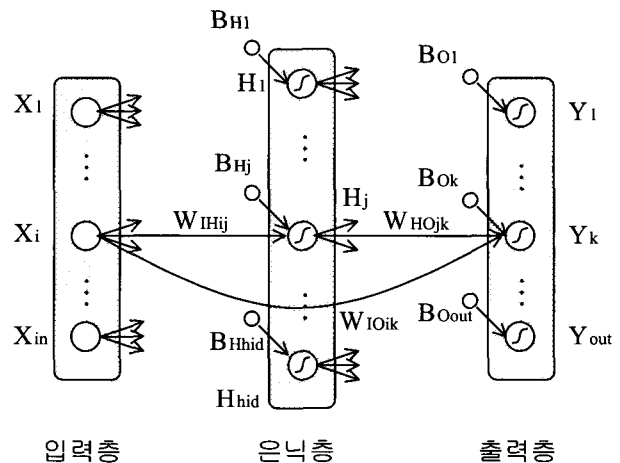


그림 1. 신경망의 구성.

Fig. 1. Structure of an artificial neural network.

는 순방향 신경망이다(그림 1). 신경망은 최대값과 최소값에 의해 정규화된 데이터를 학습한다. 은닉층 뉴런 및 출력층 뉴런은 각각 (1), (2)와 같은 함수 특성을 가지며, 각 뉴런의 출력은 (3)과 (4)가 성립한다. 이때 H_j 및 O_k 는 각각 은닉층 및 출력층 뉴런의 시그모이드 함수의 기울기이며 W_{Hij} 는 i 번째 입력층 뉴런과 j 번째 은닉층 뉴런간의 연결하중치, W_{HOjk} 는 i 번째 은닉층 뉴런과 k 번째 출력층 뉴런간의 연결하중치, 그리고 B_{Hj} , B_{Ok} 는 각각 은닉층 뉴런과 출력층 뉴런에서의 바이어스 값을 나타낸다.

$$S_{Hj}(x) = \frac{1}{1 + \exp(-H_j x)} \tag{1}$$

$$S_{Ok}(x) = \frac{1}{1 + \exp(-O_k x)} \tag{2}$$

$$H_j = S_{Hj}(\sum_{i=1}^n X_i W_{Hij} + B_{Hj}) \tag{3}$$

$$Y_k = S_{Ok}(\sum_{j=1}^{hid} N_j W_{HOjk} + \sum_{i=0}^n X_i W_{IOik} + B_{Ok}) \tag{4}$$

진화 프로그램을 구성하는 하나의 개체는 입력-은닉층, 은닉-출력층, 입력-출력층의 연결상태 및 연결하중값, 은닉층과 출력층 각 뉴런의 시그모이드 함수 기울기 및 바이어스 등과 같이 신경망을 구성하는 모든 정보를 가지도록 구성된다(그림 2). 코딩될 파라미터의 특성에 의해 연결정보는 0, 또는 1의 이진 스트링으로 구성되며, 나머지 유전인자는 실수형 스트링으로 구성된다. L_{HI} , L_{IO} , L_{HO} 및 W_{HI} , W_{IO} , W_{HO} 는 각각 입력-은닉층, 입력-출력층 및 은닉-출력층 노드의 연결상태와 하중치 정보를 0, 또는 1과 실수형 값으로 나타내며, B_H , B_O 및 S_H , S_O 는 각각 은닉층 노드와 출력층 노드의 바이어스 값 및 시그모이드 함수의 기울기를 나타낸다.

연결 정보의 경우 연결하중값과는 달리 1 또는 0으로 각 노드의 연결 상태를 나타내며, 이들은 각각 두 노드




그림 2. 각 개체의 염색체 구성.
Fig. 2. Structure of a chromosome.




그림 3. 신경망 구조의 표현. (a) 간단한 신경망의 구조, (b) 연결정보 유전인자의 값.
Fig. 3. Encoding of a simple network structure. (a) Simple network structure, (b) A value of a chromosome structure.

가 연결되어 있거나 또는 연결되어 있지 않은 상태를 의미한다. 입력층 노드 두 개, 은닉층 노드 두 개 및 출력층 노드가 하나인 신경망의 예(그림 3(a))에서, 입력층 뉴런과 은닉층 뉴런간의 링크 중 L_{IH00} , L_{IH01} 과 L_{IH11} 만 연결되었으므로 신경망 구조 배열 중 L_{IH} 의 00, 01, 11은 True, 그리고 입력층 노드와 출력층 노드간의 연결은 없으므로 L_{IO00} , L_{IO10} 는 False가 되며, 은닉층 뉴런과 출력층 뉴런간의 연결 L_{HO00} , L_{HO10} 역시 연결되어 있으므로 True가 된다. 따라서 연결정보의 표현은 그림 3(b)와 같이 11010011이 된다.

2 초기세대의 생성

초기세대는 미리 결정된 짝수개의 개체를 발생시키게 된다. 각각의 개체는 하나의 신경망의 구조, 하중치, 시그모이드 함수의 기울기 및 바이어스를 가지며, 입력층 및 출력층 뉴런의 수는 학습하고자 할 데이터에 의해 결정된다. 본 논문에서는 최대 P_{max} 개의 초기세대를 가정하였으며 은닉층 뉴런의 수는 최대 H_{max} 개로 결정된다. 초기 세대의 신경망들의 구조 및 파라미터들은 랜덤하게 발생된다. 각 노드들을 연결하는 링크는 P_{link} 의 확률에 의해 연결이 결정되며, 각 하중치는 $[-1,1]$, 시그모이드 함수의 기울기는 $[0.1, 1.5]$, 바이어스는 $[-1,1]$ 의 범위 내에서 생성된다(그림 4).

3 돌연변이 연산

진화 프로그래밍은 유전 알고리즘과는 달리 돌연변이 연산을 유일한 재결합 연산자로 정의한다. 따라서 돌연




그림 4. 개체집단과 하나의 개체의 구성.
Fig. 4. A population pool and a chromosome structure.

변이 연산은 최적의 성능을 얻어내기 위해 유전자 형에 적합하게 정의되어야 한다. 하나의 개체는 연결하중값, 바이어스 및 시그모이드 함수의 기울기와 같은 실수형태의 인자와, 노드의 연결 상태를 나타내는 논리치 형태의 인자로 구성되어 있으므로 결국 돌연변이 연산은 이들의 형태에 맞게 두 가지로 정의된다.

1) 링크의 돌연변이 연산

링크의 돌연변이 연산에 의해 링크의 생성 또는 링크의 제거가 발생할 수 있다. 링크의 돌연변이는 확률 M_i 에 의해 발생된다. 링크가 새로 생성된 경우, 초기 연결하중값은 0으로 결정되며, 이 경우 돌연변이 이전 신경망과는 적합도 면에서는 완전히 동일한 결과를 가진다. 연결하중값을 제외한, 연결에 의해 추가되는 뉴런의 바이어스 및 시그모이드 함수의 기울기는 그 뉴런이 신경망의 다른 부분과 연결되어 있을 가능성도 있으므로 이전의 값을 그대로 유지하여야 한다. 결국 돌연변이에 의해 새로 생성된 링크를 갖는 신경망은 다음 세대에서도 살아남을 확률이 크다. 링크의 돌연변이 연산의 기본 알고리즘은 다음과 같다.

do

if generate a random probability and is smaller than M_i then

if previously connected link exists then
 $Link_{ij} = False$

else

$$w_{ij} = 0$$

$$Link_{ij} = True$$

endif

endif

while visit every link of every node

2) 링크생성/삭제를 통한 노드생성/삭제

노드의 추가, 삭제는 그 자체로는 정의되어 있지 않으며, 링크의 추가, 삭제를 통하여 구현된다. 신경망에서, 입력, 출력층 한쪽이 존재하지 않는 노드, 또는 둘 다 연결되어 있지 않는 노드는 그 노드에 관한 정보는 유전자 내에 존재하나 논리적으로는 신경망으로부터 제거된다. 또한, 한 노드의 입력, 또는 출력 중 한 쪽만 존재할 때 링크 생성 돌연변이에 의해 존재하지 않는 다른쪽 링크가 생성된다면 그 노드는 다시 신경망에 추가된다.

그림 5(a)에서, 은닉층 노드 H_j 는 두 개의 링크 L_{IHj} , L_{HOjk} 에 의해 입력, 출력이 정의된다. 이때, 은닉층 노드




그림 5. 노드의 추가, 삭제 돌연변이. (a) 돌연변이에 의한 바이어스로의 변환, (b) 돌연변이에 의한 노드의 제거.

Fig. 5. Mutation of a hidden node. (a) Convert a hidden node into an output node bias, (b) Delete a hidden node with deleting its link.

의 입력링크 \$L_{IHk}\$가 돌연변이 연산에 의해 연결이 끊어진 경우, 노드 \$H_j\$의 출력은 시그모이드 함수와 바이어스만으로 결정되는 상수이다.(5)

$$H_j = S_{H_j}(B_{H_j}) \tag{5}$$

은닉층 노드 \$H_j\$는 바이어스 \$B_{OK}\$와 함께 상수값으로 출력노드 \$Y_k\$에 작용하며, 따라서 새로운 바이어 \$B_{OK}^*\$를 (6)과 같이 정의하면 은닉층 노드 \$H_j\$는 신경망으로부터 완전히 분리된다.

$$B_{OK}^* = B_{OH} + S_{H_j}(B_{H_j}) \tag{6}$$

그림 5(b)에서는 은닉층 노드 \$H_j\$의 출력층 링크가 돌연변이 연산에 의해 끊어지는 경우이며, 이 경우 은닉층 노드 \$H_j\$는 신경망으로부터 완전히 제거된다.

3) 하중치의 돌연변이

초기 세대의 하중치는 제한된 구간 내에서 발생되었으나, 알고리즘 수행시 링크의 하중치가 가질 수 있는 값에 대한 제약은 없다. 자손 세대의 하중치는 부모의 값에 가우시안 노이즈를 통한 교란으로 생성된다. \$W_{ij}\$를 노드 \$i\$와 노드 \$j\$간의 연결의 하중치라 할 때, (7)과 같이 돌연변이 과정을 수행할 수 있다. 이때, \$W_d\$는 미리 설정된 상수이며, \$N(0, W_d)\$는 가우시안 랜덤 변수이다.

$$W_{ij}^* = W_{ij} + N(0, W_d) \tag{7}$$

4) 시그모이드 함수 기울기 및 바이어스의 돌연변이

초기 세대의 함수 기울기 및 바이어스 역시 미리 설정된 구간 내에서 발생되었으나, 알고리즘 수행시 이들 값이 가질 수 있는 범위의 제약은 없다. \$S_i, O_i\$를 각각 노드 \$i\$의 시그모이드 함수의 기울기, 바이어스라고 할 때 (8)과 같이 다음 세대의 기울기와 바이어스를 계산할 수 있다. 이때, \$S_d, O_d\$는 미리 설정된 상수이며, \$N(0, S_d), N(0, O_d)\$는 각각 분산 \$\beta, \gamma\$를 가지는 가우시안 랜덤 변수이다.(8)

$$S_i^* = S_i + N(0, S_d) \tag{8}$$

$$O_i^* = O_i + N(0, O_d)$$

4 생성된 신경망의 평가

신경망을 주어진 작업에 맞게 동정하는데 있어서 필요한 것은 각 개체의 적합도 함수값이다. 만약, 주어진 학습 집합에서, 신경망의 출력을 \$y^*\$라고 할 때 각 개체의 학습오차 \$E_p\$는 (9)와 같이 정의한다.

$$E_p = \frac{1}{N} \sum_{i=0}^{N-1} (y_i - y_i^*)^2 \tag{9}$$

이때, \$N\$: 학습 데이터 갯수

\$y_i\$: 실제 데이터 출력

\$y_i^*\$: 학습 데이터 출력

만약, 신경망을 구성하는 노드의 개수가 많고 연결이 복잡하게 구성되어 있다면 신경망 생성비용이 많이 들며 학습시간이 길게 된다. 따라서 신경망의 구조는 가능할수록 단순하게 구성되는 것이 더 좋은 결과를 가질 수가 있다. 이러한 개념을 적합도 계산시에 반영하기 위해 신경망을 구성하는 은닉층 뉴런의 개수를 나타내는 \$N_H\$로 별점 함수를 부여하여 신경망의 적합도를 계산한다. 학습 오차 \$E_p\$를 가지는 신경망의 적합도 \$Fit\$는 (10)과 같이 결정될 수 있다. 이때 \$\alpha\$는 미리 결정된 상수이다.

$$Fit = \frac{1}{(1 + \alpha \log(N_H + 1))E_p} \tag{10}$$

IV. 시뮬레이션

제안된 알고리즘을 Sugeno 데이터 및 Box and Jenkin의 소각로 데이터에 적용하여 신경망을 생성하였다. 각 데이터를 학습할 때 동정된 최적의 개체의 신경망 구조 및 학습오차, 실제값 및 출력값의 결과, 각 세대 별로 개체의 최소적합도의 변화에 대하여 결과를 제시하였다.

1 비선형 Sugeno 데이터의 학습

진화 프로그래밍을 통한 신경망 생성 알고리즘에 (11)에 의해 생성된 50개의 데이터 쌍을 학습 데이터로 사용하였다. 생성에 사용된 파라미터는 최대 은닉층 뉴런 수 \$H_{max}\$ 12개, 반복횟수 2000번, 초기세대 200개체, 초기 세대의 신경망 뉴런 연결확률 \$P_{imk} = 0.3\$, 파라미터 돌연변이 발생확률 \$M_l = 0.1\$, 연결 돌연변이 발생확률 \$M_w =




그림 6. 생성된 신경망 구조.
Fig. 6. Generated network structure.




그림 7. 진화에 따른 오차 변화.
Fig. 7. A change of a model error.




그림 8. 최적 은닉층 수의 변화.
Fig. 8. A change of the hidden node numbers.

0.1, 적합도 상수 $\alpha = 0.05$ 이다. 알고리즘에 의해 생성된 최적의 신경망 구조를 그림 6, 그리고 진화가 진행되면서 각 세대가 반복됨에 따라, 각 세대별로 (9)에 의한 최소의 학습오차를 갖는 개체의 학습오차와 은닉층 뉴런 수들 중 초기 300세대까지의 결과를 그림 7과 그림 8에 나타내었다. 2000세대 후 생성된 최적의 신경망에서 최




그림 9. 실제 데이터 출력 및 모델 출력.
Fig. 9. A reference output and a model output.




그림 10. 생성된 신경망 구조.
Fig. 10. Generated network structure.

소 학습 오차는 0.05197이며, 그 때의 은닉층 뉴런 수는 2개이다. 학습데이터의 출력과 생성된 신경망에 의한 출력을 그림 9에 나타내었다. 모델 오차를 최소로 하는 개체는 약 40세대 후 결정되었으나(그림 7), 그 개체의 은닉층 수는 구조 돌연변이가 계속 진행됨에 따라 약 100세대까지는 그 구조가 계속 변한 다음 100세대 이후에서 최소 은닉층 개수가 결정되었다(그림 8). 결국 40세대에서 100세대동안 진화가 계속됨에 따라 신경망의 기능에 큰 영향을 미치지 않는 은닉층 노드의 제거가 수행되었다.

$$y = (1 + x_1^{-2} + x_2^{-1.5})^2, 1 \leq x_1, x_2 \leq 5 \quad (11)$$

2 Box and Jenkin의 가스로 데이터의 학습

생성에 사용된 파라미터는 최대 은닉층 뉴런 수 M_{max} 12개, 반복횟수 2000번, 초기세대 200 개체, 초기 세대의 신경망 뉴런 연결확률 $P_{link} = 0.3$, 파라미터 돌연변이 발생확률 $M_l = 0.1$, 연결 돌연변이 발생확률 $M_w = 0.1$, $\alpha = 0.05$ 이다. 알고리즘에 의해 생성된 최적의 신경망구조를 그림 10, 그리고 진화가 진행되면서 각 세대가




그림 11. 진화에 따른 오차 변화.
Fig. 11. A change of a model error.




그림 12. 최적 은닉층 수의 변화.
Fig. 12. A change of the hidden node numbers.




그림 13. Box 데이터의 실제값 및 모델값.
Fig. 13. A reference output and a model output.

반복됨에 따라, 각 세대별로 (9)에 의한 최소의 학습오차를 갖는 개체의 학습오차와 은닉층 뉴런 수들 중 초기 300세대 까지의 결과를 그림 11 및 그림 12에 나타내었다. 2000세대 후 생성된 최적의 신경망에서 최소 학습오차는 0.23263이며, 그 때의 은닉층 뉴런 수는 2개이다. 학습데이터의 출력과 생성된 신경망에 의한 출력을 그림 13에 나타내었다. 앞의 실험과 마찬가지로 모델 오차를 최소로 하는 개체는 약 80세대 후 결정되었으나(그림 11.), 그 개체의 은닉층 수는 구조 돌연변이가 계속 진행됨에 따라 약 215세대 까지는 그 구조가 계속 변한 다음 215세대 이후에서 최소 은닉층 개수가 결정되었다.(그림 12.) 결국 80세대에서 215세대동안 진화가 계속됨에 따라 신경망의 기능에 큰 영향을 미치지 않는 은닉층 노드

의 제거가 수행되었다.

V. 결론

신경망은 여러 가지 응용분야에서 많이 사용되고 있으며, 성능 개선을 위해 많이 연구되어 왔다. 응용분야의 특성에 적절한 신경망을 설계하기 위해서는 신경망 구조를 결정해야 하며, 또한 각 노드와 링크를 구성하는 함수 및 하중치를 적절한 학습 알고리즘을 사용하여 동정해야 한다. 신경망을 사용하여 주어진 데이터를 학습하는데 있어서 주된 어려운 점은 신경망의 구조 및 여러 가지 파라미터들을 동정하는 것이다. 파라미터 동정에는 여러 가지의 알고리즘을 사용할 수 있으나, 신경망 구조 동정은 대부분 경험에 의한 반복적인 시행 착오를 통해 결정된다. 유전 알고리즘 및 진화 프로그래밍은 해결하고자 하는 문제에 대한 가능한 해들을 정해진 형태의 자료 구조로 표현한 다음 이들을 점차적으로 변형함으로써 점점 더 좋은 해들을 만들어내게 된다.

본 논문에서는 진화 알고리즘을 사용하여 신경망 구조 및 여러 가지 파라미터들을 동정하였다. 최적의 신경망을 탐색하기 위해 1) 신경망의 구조를 진화 프로그래밍에 적합한 구조로 표현하였으며, 2) 유전인자에 적합한 돌연변이 연산을 정의한 다음 3) 진화 프로그래밍을 통하여 최적의 적합도를 갖는 신경망을 생성하였다.

제안된 알고리즘은 Sugeno에 의한 데이터와 Box and Jenkin의 가스로 데이터를 학습하기 위한 신경망을 생성하였다. 각 실험에서 알고리즘에 의해 은닉층 뉴런의 개수 및 신경망의 연결하중값, 시그모이드 함수 기울기 및 뉴런의 바이어스값을 생성하였으며, 그에 따른 모델 오차 값 및 학습데이터와 모델 출력값에 대한 결과를 나타내었다.

참고문헌

- [1] D. E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison Wesley, 1989
- [2] T. Back, U. Hammel and H.-P. Schwefel, "Evolutionary computation: comments on the history and current state," *IEEE Trans. Evolutionary Computation*, vol. 1, no. 1, pp. 3-17, April, 1997.
- [3] V. Maniezzo, "Genetic evolution of the topology and weight distribution of neural networks," *IEEE Trans. Neural Networks*, vol. 5, no. 1, pp. 39-53, Jan., 1994.
- [4] X. Yao, "A new evolutionary system for evolving artificial neural networks," *IEEE Trans. Neural Networks*, vol. 8, no. 3, pp. 694-713, May, 1997.
- [5] J. Fang and Yugeng Xi, "Neural network design based on evolutionary programming," *Artificial Intelligence in Engineering* pp. 155-161, 11, 1997.
- [6] P. G. Harrald and M. Kamstra, "Evolving artificial neural networks to combine financial forecasts," *IEEE Trans. Evolutionary Computation*, vol. 1, no. 1, pp. 40-52, April, 1997.

[7] P. J. Angeline, G. M. Saunders and J. B. Pollack, "An evolutionary algorithm that constructs recurrent neural networks," *IEEE Trans. Neural Networks*, vol. 5, no. 1, pp. 54-65, Jan., 1994.

[8] J. M. Renders and S. P. Flasse, "Hybrid methods using genetic algorithms for global optimization,"

IEEE Trans. SMC, vol. 26, no. 2, pp. 243-258, April, 1996.

[9] L. H. Tsoukalas and R. E. Uhrig, *Fuzzy and Neural Approaches in Engineering*, Wiley-Interscience, 1997.

강 신 준

제어 · 자동화 · 시스템공학 논문지 제4권, 제1호, 참조.



고 택 범

1992년 연세대 전기공학과 졸업. 동대학원 석사(1983), 동대학원 박사(1996), 1983년-1995년 LG산전 연구소 선임연구원, 1996년-1998년 LG 하니웰 연구소 책임연구원, 1999년-현재 경주대학교 컴퓨터전자공학부 교수, 관심분야는 지능제어 및 응용, 반도체 생산공정 모델링 및 최적제어, 이상검출, 자기진단.



우 천 희


1985년 연세대 전기과 졸업. 동대학원 석사(1993). 1995년-현재 동대학원 박사과정. 1985년-1995년 현대중공업 중앙연구소 선임연구원. 1995년-현재 명지전문대학 전기과 조교수. 관심분야는 시스템제어, 디지털보호

계전기, 마이크로프로세서 응용.



이 덕 규

1987년 연세대 전기과 졸업. 동대학원 석사(1989). 1989년-현재 동대학원 박사과정. 1991년-1996년 쌍용자동차 기술연구소 주임연구원. 관심분야는 Emergent control, 지능형제어.



우 광 방

1934년 1월 25일생. 1957년 연세대 전기공학과 졸업(석사). 1962년 및 1964년 오레곤주립대학 전기공학과에서 석사 및 박사학위 취득. 1966년-1971년 워싱턴대 전기공학과 조교수, 1971년 미 국립 암연구소 책임연

구원, 1980년 재미한국인과학기술자협회장, 1982년-현재 연세대 전기공학과 교수, 1992년-현재 연세대학교 자동화기술연구소 소장, 1995년 당 학회 회장. 주요 관심분야는 반도체공정자동화 및 스케줄링, 인공지능제어기법, FMS.