

論文96-33B-12-11

유전 알고리즘을 이용한 전방향 신경망 제어기의 구조 최적화

(Structure Optimization of a Feedforward Neural Controller using the Genetic Algorithm)

曹 喆 鉉 *, 公 聖 坤 *

(Cheol-Hyeon Cho and Seong-Gon Kong)

要 約

본 논문에서는 유전 알고리즘을 이용하여 전방향(feedforward) 신경망 제어기의 구조를 최적화하였다. 신경망 제어기는 플랜트의 응답에 대하여 실시간 학습 및 응답이 가능하도록 빠른 처리가 요구되므로 최소구조의 신경망으로 구현하는 것이 중요하다. 전방향 신경망의 구조와 실수 가중치를 유전자로 부호화하고, 유전 알고리즘에 의한 전역 탐색과 전방향 신경망 온라인 학습 알고리즘에 의한 국부 탐색을 동시에 행하여 전방향 신경망의 구조를 최소화하였다. 유전 알고리즘의 적합도를 상대 적합도로 설계하여, 점진적인 유전 탐색이 가능하였으며, 탐색 공간의 크기에 비해 유전자 집단의 크기가 매우 작은 경우에도 유전 알고리즘이 초기 수렴하지 않고 탐색이 가능하였다. 모의 실험 결과, 최적화한 전방향 신경망 제어기가 경험적으로 설계한 디瘴퍼셉트론 신경망 제어기보다 더 작은 크기이면서 더 좋은 성능을 보여주고 있음을 확인하였다.

Abstract

This paper presents structure optimization of a feedforward neural network controller using the genetic algorithm. It is important to design the neural network with minimum structure for fast response and learning. To minimize the structure of the feedforward neural network, a generalization of multilayer neural networks, the genetic algorithm uses binary coding for the structure and floating-point coding for weights. Local search with an on-line learning algorithm enhances the search performance and reduce the time for global search of the genetic algorithm. The relative fitness defined as the multiplication of the error and node functions prevents from premature convergence. The feedforward neural controller of smaller size outperformed conventional multilayer perceptron network controller.

I. 서 론

신경망 제어기는 복잡한 비선형 시스템의 모델링과 제어에 효과적으로 응용되고 있으며 시스템의 비선형 특성 뿐만 아니라 불확실성에 대해서도 강인하게 대처 할 수 있다.^{[1][2]} 그러나 신경망의 구조가 복잡해지

고 노드수도 증가함에 따라 응답시간 및 학습시간이 많이 걸리며, 학습시 초기값에 따라 가중치가 전역 최소에 도달하지 않는 단점이 있다. 따라서 실제 시스템에 효과적으로 적용하기 위해서는 대상 시스템에 맞는 최적구조의 신경망을 설계하여야 한다. 최적구조의 신경망이란 주어진 시스템에 대해 최소의 노드수와 그에 따른 연결구조, 그리고 원하는 출력과 학습된 신경망의 출력과의 오차를 최소로 하는 가중치들로 구성되는 것을 의미한다.

신경망의 구조를 최적화하기 위해서 먼저 충분히 큰 크기의 신경망을 구성한 다음 학습과정에서 불필요하

* 正會員, 崇實大學校 電氣工學科

(Dept. of Electrical Eng., Soongsil Univ.)

※ 본 연구는 한국전력공사의 지원에 의하여 기초전력

공학공동연구소주관으로 수행되었음 (94-지-2)

接受日字: 1996年8月13日, 수정완료일: 1996年12月6日

다고 판단되는 연결이나 노드를 삭제하는 신경망 감소(network pruning) 방법이나^[3], 작은 크기에서부터 노드와 연결강도를 하나씩 증가시키는 신경망 성장(network growing) 방법^[4]이 연구되어 왔다. 신경망 감소방법은 초기 가중치에 따라 해가 달라질 수 있고, 신경망 성장방법은 제한된 구조를 가지며, 층의 수가 지나치게 많아질 우려가 있다.

일반적인 구조의 신경망을 설계하고 학습하는 방법으로 진화연산을 이용하는 연구가 행해지고 있다. 이러한 연구는 몇 가지 문제를 포함하고 있는데, 예를 들어 신경망의 파라미터들을 진화연산을 위해 어떻게 부호화할 것인가? 어떤 연산자를 사용할 것인가? 어떻게 평가할 것인가? 하는 것들이다. 신경망의 구조를 표현하기 위해 구조행렬(connectivity constraint matrix)을 사용하거나^[5], 구조행렬 원소의 값을 바로 가중치의 값으로 설정하여 구조와 가중치를 동시에 탐색하는 방법도 연구되었다^[6]. 또한 신경망을 이진의 구조행렬과 가중치 행렬로 표현하여 다른 추가적인 정보 없이 유전 알고리즘만으로 최적화하는 방법도 연구되었다^{[7][8]}.

본 논문에서는 유전 알고리즘을 이용하여 전방향 신경망 제어기의 구조를 최적화하고 온라인 학습 알고리즘에 의하여 최적 가중치를 찾아내었다. 전방향 신경망(FNN)은 다층퍼셉트론(MLP) 신경망의 개념을 확장시킨 것으로 인접한 층 사이의 노드뿐만 아니라 전방향으로 모든 가중치의 연결을 허용한 네트워크이다. 제어기에 적용하였을 때 전방향 신경망은 다층퍼셉트론 신경망의 경우보다 더 적은 노드수와 가중치로도 같은 문제를 해결할 수 있도록 최적화시킬 수 있다.^[9] 전방향 신경망의 구조 및 실수 가중치를 유전 알고리즘에 의해 전역적 탐색을 하고 온라인 학습 알고리즘^[10]에 의해 전방향 신경망의 실수 가중치를 국부 탐색하여, 유전 알고리즘만을 사용하여 실수 가중치의 탐색이 잘 되지 않는 단점을 보완하였다. 즉 유전 알고리즘으로 신경망의 구조를 표현할 때 가중치 정보도 포함하여 새로운 구조가 탐색될 때마다 이에 대한 가중치도 탐색하고, 이것을 초기값으로 하여 온라인 학습 알고리즘으로 적절한 가중치를 찾아내었다. 전방향 신경망의 적합도를 상대 적합도로 정의하여 유전 알고리즘의 초기 수렴을 막고 유전 연산을 통해 생성된 유전자 집단의 상태 변화가 목표를 향해 단계적으로 진행하도록 한다. 유전 알고리즘에 의한 신경망의 구조최적화 방법을 비선형 플랜트의 제어에 적용한 결과, 최적화된 전방향

신경망 제어기가 기존에 연구되어진 다층퍼셉트론 신경망 제어기에 비해 더 적은 노드수와 간단한 구조를 가지고도 더 좋은 응답특성을 보여주었다.

II. 전방향 신경망 제어기

전방향 신경망은 인접한 층 사이의 노드뿐만 아니라 전방향으로 모든 가중치의 연결을 허용하는 네트워크로서 다층퍼셉트론 신경망보다 더 적은 노드수와 가중치를 갖도록 최적화시킬 수 있다. CFCM(Coordination of feedforward control method) 제어기를 바탕으로 설계된 신경망 제어기^[2]는 플랜트의 역모델 학습에 의한 제어기로서, 이 제어기는 플랜트를 통해 오차를 역전파하지 않고 온라인 학습을 통해 제어하기 때문에, 플랜트의 응답에 대하여 신경망의 실시간 학습 및 응답이 가능하도록 빠른 처리가 요구된다. 본 논문에서는 유전 알고리즘을 이용하여 전방향 신경망제어기의 구조를 최적화함으로써 최소구조를 갖는 플랜트 역모델 학습에 의한 전방향 신경망 제어기를 설계하였다.

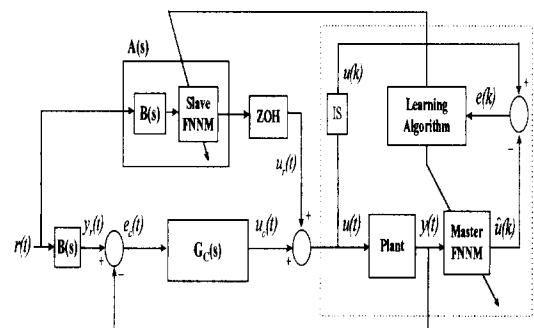


그림 1. 플랜트 역모델 학습구조를 바탕으로 설계된 전방향 신경망 제어기

Fig. 1. Feedforward neural controller based on the learning of the inverse plant.

그림 1은 플랜트 역모델 학습 구조를 바탕으로 설계된 전방향 신경망 제어기를 나타낸다. 여기서 $r(t)$ 는 기준입력, $y(t)$ 는 플랜트의 출력, 그리고 $u(t)$ 는 플랜트의 제어입력이다. $B(s)$ 는 기준 모델이며 $A(s)$ 는 전방향 제어기를, 그리고 $G_c(s)$ 는 채환 제어기를 나타낸다. IS(Ideal Sampler)는 연속신호를 이산신호로 바꾸어주고, ZOH(Zeroth Order Hold)는 이산신호를 다시 연속신호로 변환하는 장치를 가리킨다.

전방향 신경망 모듈 FNNM(Feedforward neural network module)은 다층 퍼셉트론 신경망을 확장시킨 것으로 인접하지 않은 뉴론들간의 연결도 허용한다. 주 FNNM의 전방향 신경망은 플랜트의 동작중 온라인으로 학습되며^[10], 학습된 주 FNNM은 부 FNNM에 복제되어 실제 온라인 제어에 사용된다. $\hat{u}(k)$ 는 플랜트의 역모델로 동작하는 주 FNNM이 추정한 플랜트의 제어입력이고, 오차 $e(k) = u(k) - \hat{u}(k)$ 는 전방향 신경망을 학습하는 데 사용한다. $y_c(t)$ 는 기준 모델의 출력으로 요구되는 플랜트의 출력이다. $e_c(t)$ 는 플랜트의 출력과 기준모델의 출력과의 오차이며 채환 제어기의 입력이 된다. $u_c(t)$ 은 전방향 제어기의 출력이고 $u_c(t)$ 는 채환 제어기의 출력이며, 플랜트의 제어입력은 $u(t) = u_c(t) + u_c(t)$ 이다.

채환제어기 $G_C(s)$ 는 입력 $e_c(t) = y_c(t) - y(t)$ 과 출력 $u_c(t)$ 에 대해 식 (1)과 같이 선형 전차예측기(linear full-order estimator)를 이용하여 안정한 채환루프를 갖도록 설계한다.

$$\begin{aligned} \dot{z}(t) &= (\hat{A} - \hat{L}\hat{C})z(t) - \hat{L}e_c(t) + \hat{B}u_c(t) \\ u_c(t) &= -\hat{K}z(t) \end{aligned} \quad (1)$$

여기서 \hat{A} , \hat{B} , \hat{C} 는 선형화 모델의 상태방정식의 계수행렬, z 는 예측 상태, \hat{K} 는 상태채환이득, \hat{L} 은 예측 이득을 나타낸다. 시스템의 성능은 상태 채환에 의한 폐루프의 극의 위치에 따라 달라지므로, 강인성이나 민감도 등을 고려하여 극의 위치를 결정한다.

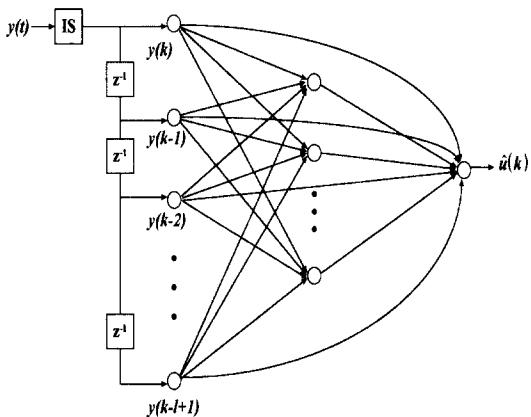


그림 2. 전방향 신경망 모듈(FNNM)의 구조
Fig. 2. Structure of the feedforward neural network module(FNNM).

그림 2는 입력노드의 수가 10이고, 출력노드가 1인 전방향 신경망 모듈의 구조를 나타낸다. 연속신호 $y(t)$ 가 IS에 의해 이산신호 $y(k)$ 로 변환되고, 시간지연 소자 z^{-1} 에 의해서 신경망의 입력 $y(k), y(k-1), \dots, y(k-l+1)$ 을 얻는다. 이 신호는 중간층의 뉴론을 통하여 출력층의 뉴론과 연결된다.

III. 전방향 신경망의 최적화

1. 유전 탐색과 신경망의 온라인 학습

신경망의 구조를 최적화하기 위해서는 먼저 새로운 구조의 신경망을 형성하고 이 신경망이 요구되는 성능을 만족하는지, 즉 신경망의 실제출력이 원하는 출력과 충분히 가까운지 평가하여야 한다. 본 논문에서는 유전 알고리즘과 전방향 신경망의 온라인 학습 알고리즘을 통합하여 전방향 신경망의 구조와 실수 가중치를 최적화하는 방법을 연구하였다. 유전 알고리즘은 전방향 신경망의 구조와 실수가중치를 전역 탐색하고, 온라인 신경망 학습 알고리즘은 실수 가중치를 미세 조정함으로써 신경망의 성능을 향상시킨다. 또한 상대 적합도를 정의하여 사용함으로써 유전 알고리즘의 초기 수렴을 방지한다. 신경망 최적화의 관점이 노드의 수를 최소화하는 것이므로, 학습이 용이한 충분히 큰 노드수부터 탐색하고 신경망이 요구되는 오차에 도달하도록 충분히 학습한다.

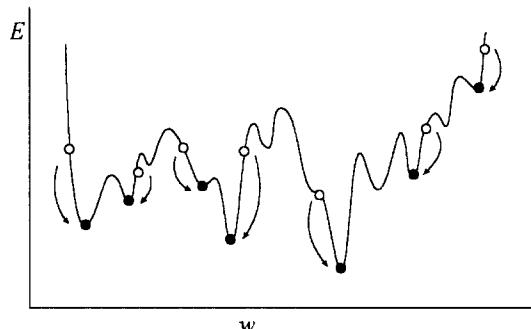


그림 3. 유전 알고리즘과 신경망 학습에 의한 가중치의 전역탐색

Fig. 3. Global search using the genetic algorithm and neural network learning.

그림 3은 유전 알고리즘과 신경망 학습 알고리즘에 의한 전역탐색 과정의 개념을 나타낸다. 그림에서 ○는 유전 알고리즘에 의해 전역 탐색된 가중치이며, ●는

온라인 학습 알고리즘에 의해 미세조정된 가중치를 의미한다. 신경망의 연결구조와 가중치를 모두 유전연산을 위한 부호로 표현함으로써 유전연산에 의해 신경망의 구조뿐만 아니라 가중치도 전역탐색 하였다. 특히 가중치에 유전연산을 적용함으로써, 신경망의 학습 알고리즘이 국부 최소에 빠지더라도 다른 탐색영역으로 전이가 가능하다.

2. 전방향 신경망 최적화를 위한 유전 알고리즘

유전 알고리즘은 자연계의 적자생존과 유전학에 근거한 병렬, 전역적 탐색 알고리즘^[11]이다. 탐색 공간이 미분가능하거나 연속이라는 가정이 필요하지 않으며, 해의 집단을 취급하기 때문에 해공간 내에서 동시에 여러개의 상태들을 평가하여 전역최적해를 찾을 가능성이 크다. 유전 알고리즘의 계산은 부호화, 유전자 집단의 크기 설정, 적합도 함수의 설계, 재생산, 교배 연산, 돌연변이 연산으로 구성되어 있다. 유전 알고리즘의 성능은 유전자 집단의 크기, 적합도의 분포, 재생산 방법, 교배 연산 방법 및 확률, 돌연변이 연산 및 확률 등에 따라 변화한다.

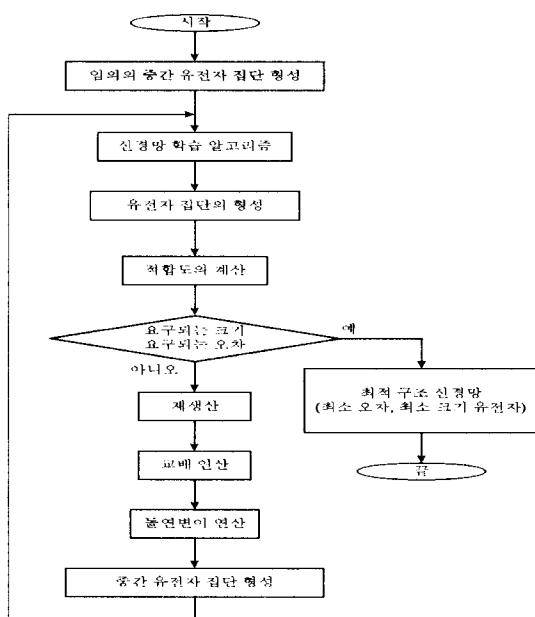


그림 4. 유전 알고리즘에 의한 전방향 신경망 구조 최적화의 순서도

Fig. 4. Flowchart of the genetic algorithm for feedforward neural network structure optimization.

그림 4는 본 논문에서 제안하는 전방향 신경망의 최

적화를 위한 유전 알고리즘의 순서도를 나타낸다. 유전자 집단이 형성되면 유전자 모두에 학습 알고리즘으로 가중치를 미세 조정하고 적합도를 계산하여 요구되는 성능을 만족하는지 평가한다. 요구되는 성능에 도달하지 않으면 유전연산을 행하여 새로운 해공간을 형성한 다음 조정한 파라미터로 유전 알고리즘의 진화를 계속한다. 오차에 의해 정의되는 적합도를 계산하여 요구되는 오차를 만족하고 요구되는 크기 이하의 신경망이 탐색되면 종료한다.

3. 신경망의 유전자 부호화

부호화는 주어진 문제의 변수들을 유전 알고리즘내에서 표현하는 방법을 나타낸다. 유전 알고리즘에서 하나의 유전자는 여러개의 유전인자들로 구성되며, 하나의 변수에 해당하는 유전인자는 지정된 비트 수의 2진수로 구성된다. 유전자 집단의 크기가 작으면, 최적해를 찾기 위한 유전인자가 부족하거나 포화되어 최적해를 찾지 못하고 초기수렴할 가능성이 있다.^[12] 상당히 큰 유전자 집단을 사용하면 최적해를 찾기 위한 충분한 유전인자를 유지할 수 있지만 수렴 속도가 늦어지는 경향이 있으므로, 유전자 집단의 크기를 변화시키는 방법^[13]과, 작은 크기의 유전자 집단에서 선택 정도를 유전자의 적합도에 비례하지 않게 하는 방법^[11], 균일교배 연산이나 돌연변이 비트 수를 변경하는 방법^[14], 돌연변이 연산에 시뮬레이터드 어닐링을 적용하는 방법^[15] 등 유전 연산자를 다르게 적용하거나, 돌연변이 연산 확률을 진화 과정에서 재조정^[16]하여 성능을 향상시키는 방법이 제안되었다.

신경망의 가중치를 $\{-1, 0, 1\}$ 로 제한하고 가중치 정보를 구조행렬의 원소로 직접 할당하여 구조와 가중치를 동시에 탐색하였으나^[7], 이는 이진의 정보를 다른 신경망으로 국한된다. [8]에서는 구조와 가중치를 이진으로 부호화하여 유전 탐색을 하였다. 이러한 부호화 방법은 제한된 신경망 부호화이므로, 본 논문에서는 구조행렬을 이진으로 부호화하고, 가중치를 실수로 부호화하였다.

그림 5는 신경망의 유전자 부호화를 나타낸다. 주어진 전방향 신경망은 구조행렬과 가중치행렬로 표현할 수 있다. 구조행렬은 입력노드부터 출력노드까지 모든 노드에 순서대로 번호를 매겨 신경망의 연결상태를 행렬로 표현한 것으로 어떤 노드가 연결되어 있으면 1, 연결되어 있지 않으면 0으로 나타낸다. 예를 들어, 구조

행렬의 원소 c_{ij} 가 1이면 i 번째 노드의 출력이 j 번째 노드의 입력에 연결되어 있음을 나타낸다. 전방향 신경망은 피드백 성분을 가지고 있지 않으므로 빛금친 부분을 제외하면 모두 0값을 가지므로 빛금친 부분들만을 유전자로 부호화한다. 가중치행렬은 구조행렬과 같은 모양으로 신경망의 가중치 정보를 가지고 있다.

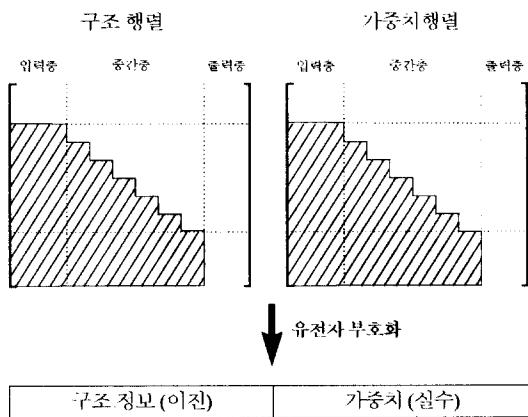


그림 5. 전방향 신경망 파라미터의 유전자 부호화
Fig. 5. Genetic coding of the feedforward neural network parameters.

4. 적합도 함수

전방향 신경망의 구조를 최적화하기 위해서는 원하는 성능을 얻을 수 있으면서 노드의 수를 최소로 하는 것이 중요하다. 신경망의 최소 구조와 그에 따른 적절한 가중치를 탐색하기 위해서는 신경망의 최적구조와 최적 가중치에 대한 평가기준이 있어야 한다. 본 논문에서는 오차 함수와 노드수에 따른 함수의 조합으로 유전 알고리즘의 적합도 함수를 정의한다. 오차함수는 신경회로망의 최적 가중치를 탐색하기 위해서 필요하고, 노드함수는 신경회로망의 구조를 최적화하기 위한 것이다. 유전 알고리즘의 적합도 함수는 상대 적합도 (relative fitness)로 하고 식 (2)과 같이 오차함수 $f_e(E)$ 와 노드함수 $f_n(n)$ 의 곱으로 정의한다.

$$\text{fitness} = f_e(E) \cdot f_n(n) \quad (2)$$

만일 오차함수와 노드함수의 합으로 적합도를 설정하면 오차함수의 값이 큰 경우 노드함수의 값이 고려되지 않거나, 노드함수의 값이 큰 경우 역으로 오차함수의 값이 적합도에 적절히 고려되지 않을 수 있다. 따라서 두 함수의 곱으로 적합도를 설정하여 노드함수의 역할이 오차함수의 값을 적합도로 변환하는 비율이 되도록 한다.

그림 6(a)는 오차함수의 형태를 나타낸다. 오차함수 f_e 는 식 (3)과 같이 오차 E 가 증가함에 따라 감소하는 형태로 정의한다. E_d 를 요구되는 오차값이라고 했을 때 $E \leq E_d$ 이면, 오차함수는 일정한 값 f_{\max} 을 갖도록 하고, $E > E_d$ 이면, 오차에 반비례하도록 한다. 계수 a_e 와 b_e 는 (E_d, f_{\max}) 와 $(1.5E_d, f_{mid})$ 의 두 점을 지나도록 설정한다. f_{mid} 가 f_{\max} 에 비해 작은 값이면, 함수의 경사가 심하므로 오차함수의 값은 오차 E 가 E_d 보다 큰 경우 급격하게 작아지게 된다.

$$f_e(E) = \begin{cases} f_{\max}, & \text{if } E \leq E_d \\ \frac{1}{a_e \cdot E + b_e}, & \text{if } E > E_d \end{cases} \quad (3)$$

노드함수 f_n 은 0과 2사이의 값을 가지며 노드수 n 이 증가함에 따라 감소하는 함수로 식 (4)와 같이 정의한다.

$$f_n(n) = a_n \cdot n + b_n \quad (4)$$

그림 6(b)는 노드함수의 n_{best} 에 따른 변화를 나타내고 있다. 계수 a_n 과 b_n 은 진화과정 중 유전자 집단에서의 최소 노드수 n_{best} 와, 탐색하고자 하는 최대 노드수 $Unit_{max}$, 탐색하는 최소 노드수 $Unit_{min}$, 최소와 최대의 중간값 $Unit_{mid}$ 에 따라 식 (5), (6)와 같이 항상 $(n_{best}, 1)$ 의 점을 지나도록 설정한다.

$$a_n = \begin{cases} \frac{1}{n_{best} - Unit_{max} - 1}, & \text{if } n_{best} \geq Unit_{mid} \\ \frac{1}{Unit_{min} - n_{best} - 1}, & \text{if } n_{best} < Unit_{mid} \end{cases} \quad (5)$$

$$b_n = \begin{cases} \frac{-Unit_{max} - 1}{n_{best} - Unit_{max} - 1}, & \text{if } n_{best} \geq Unit_{mid} \\ \frac{Unit_{min} - 2n_{best} - 1}{Unit_{min} - n_{best} - 1}, & \text{if } n_{best} < Unit_{mid} \end{cases} \quad (6)$$

n_{best} 는 유전자 집단에서 요구되는 오차에 도달한 유전자 중 최소의 노드, 혹은 어떤 유전자도 요구되는 오차에 도달하지 않았다면 탐색하는 최대 노드수 $Unit_{max}$ 를 나타낸다. 노드함수는 만일 유전자 집단 내의 최소 노드수가 계속 $Unit_{max}$ 의 값을 유지하고 있으면, 노드함수는 거의 일정한 값이기 때문에 노드함수의 값은

적용되지 않는다.

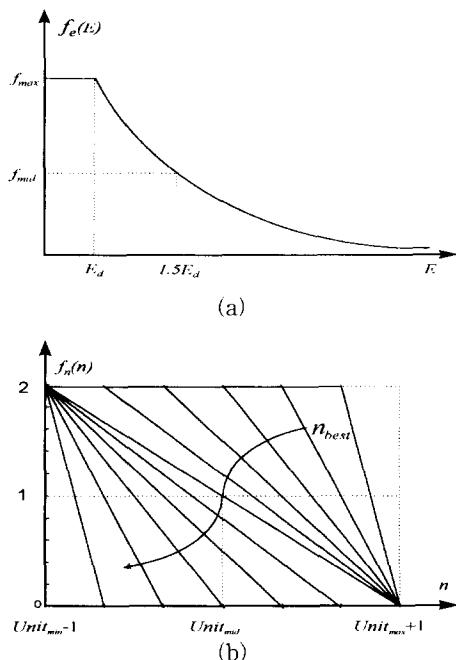


그림 6. 적합도 함수를 위한 오차함수와 노드함수
(a) 오차함수 (b) 노드함수

Fig. 6. Error and node functions for the fitness.
(a) Error function (b) Node function

또한 유전 연산에서 재생산은 유전자 집단 내의 유전자들 사이에서 경쟁하여 이루어지기 때문에, 형성된 유전자 집단에 대하여 그 집단의 상태를 결정하고, 상태에 따라 노드함수의 값을 다르게 설정하여, 유전자들의 적합도를 계산한다. 유전자 집단의 상태는 최소 노드수 n_{best} 로 설정한다. 따라서 이러한 적합도는 유전자 집단의 상태에 따라 상대적으로 계산하기 때문에, 상대 적합도로 정의하며, 재생산은 적합도가 큰 유전자에 대하여 확률적으로 많이 이루어지기 때문에 다음의 유전자 집단의 상태는 현재의 유전자 집단의 상태보다 더 목표에 가깝게 된다. 즉 본 논문에서는 상대적합도를 이용하여 초기 수렴을 막고 유전 연산을 통해 생성된 유전자 집단의 상태 변화가 목표를 향해 단계적으로 진행하도록 하고 있다.

IV. 최적구조 신경망의 성능평가

1. 플랜트 모델링

제안한 유전 알고리즘으로 역모델에 대한 전방향 신

경망의 구조를 최적화하여 전방향 신경망 제어기를 구성하고, 이 전방향 신경망 제어기의 성능을 기준에 연 구된 다층퍼셉트론 신경망 제어기의 성능과 비교한다. 신경망 제어기의 설계 및 성능을 고찰하기 위하여 기 어를 통해 직류 전동기로 각도를 제어하는 역진자 시스템을 비선형 플랜트로 설정한다.

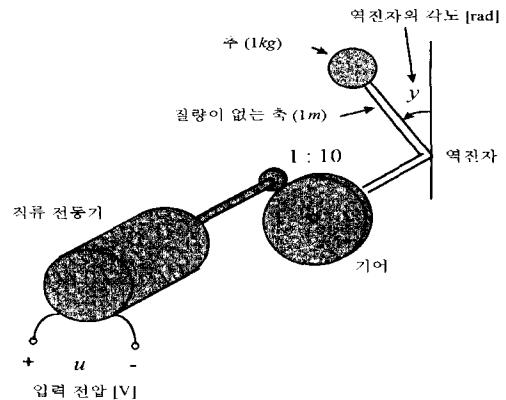


그림 7. 기어에 의해 구동되는 역진자 시스템 모델
Fig. 7. The inverted pendulum model driven by the gear train.

그림 7은 플랜트 모델로 사용하는 역진자 시스템을 나타낸다. 문제를 단순화하기 위하여, 직류 전동기는 전기자로만 제어되는 1차 시스템이고, 전동기의 회전 관성은 역진자의 회전 관성과 비교하여 무시할 정도로 작고, 역진자의 회전 관성은 축의 질량을 무시하여 축 끝에 있는 물체의 질량만으로 계산할 수 있으며, 전동기로부터 역진자로 연결된 축과 기어는 어떤 역동도 없고 모든 연결 부분은 단단하게 연결되어 있다고 가정한다.

플랜트에 대한 상태 방정식은 식 (7)와 같다^[2]. 이 때 거꾸로 서 있는 경우의 역진자의 각도를 $y=0$ 으로 설정하고 직류 전동기의 저항이 $1 [\Omega]$, 인터턴스가 $100 [mH]$, 토오크 상수가 $0.1 [Nm/A]$ 이며 그리고 역기전력 상수가 $0.1 [Vs/rad]$ 로 한다.

$$\begin{aligned} \begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \\ \dot{x}_3 \end{bmatrix} &= \begin{bmatrix} x_2 \\ 9.8 \sin x_1 + x_3 \\ -10x_2 - 10x_3 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 10 \end{bmatrix} u \\ y &= [1 \ 0 \ 0] \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} \end{aligned} \quad (7)$$

2. 플랜트 역모델에 대한 신경망의 최적화

유전 알고리즘과 온라인 학습알고리즘을 이용하여

비선형 플랜트의 역모델을 최소구조 전방향 신경망에 의해 학습시킨다. 유전 알고리즘에서 오차 E는 식 (8)와 같이 신경망의 온라인 학습시 각각의 이산 시간에 서의 오차 제곱의 합으로 설정한다.

$$E = \sum_{k=0}^{K/T} [u(k) - \hat{u}(k)]^2 \quad (8)$$

샘플링 시간은 $T=0.05$ [sec] 으로 하였고, K는 신경망의 역모델 학습을 위해 플랜트에 입력이 인가된 시간으로 30초 [sec] 이다. 탐색하고자 하는 신경망의 모델을 설정하기 위한 파라미터는 표 1에 나타내었다.

표 1. 탐색하고자 하는 신경망 모델의 설정
Table 1. Setting of the neural network model to search.

| 구 분 | 설정한 값 |
|------------|-------|
| 입력 노드의 수 | 6 |
| 출력 노드의 수 | 1 |
| 중간 노드의 최소수 | 1 |
| 중간 노드의 최대수 | 10 |

중간노드의 최대수를 10으로하여 탐색하고자하는 신경망의 크기를 제한한 것은 신경망의 성능이 노드수의 증가에 비례하지 않으며^{[2][10]}, 노드수가 증가하면, 탐색영역이 크게 증가하여 유전 탐색이 어려워지기 때문이다. 표 1에서 구조에 대한 탐색대상인 신경망의 개수는 $2^{121} - 2^{64}$ 정도이다. 전방향 신경망의 학습은 경사학습알고리즘을 수정한 온라인 학습 알고리즘^[10]을 사용하였고, 이에 대한 파라미터는 실험결과^{[2][10]}을 토대로 설정하였다. 중간노드의 활성함수와 중간노드 및 출력노드의 가중치를 학습하기 위한 학습함수는 모두 tanh함수를 사용하였고, 학습상수는 0.5로 하였다. 그리고 초기 가중치의 범위는 [-0.1, 0.1]로 하였다.

유전 알고리즘을 시뮬레이션하기 위해서 유전자 집단의 크기는 40으로 하였고, 최대 진화수는 100으로 정하였다. 최적값을 탐색하기 위한 교배연산은 균일교배 연산이며, 이진으로 부호화된 구조 정보와 실수로 부호화된 가중치 정보에 동일하게 적용하였는데, 그 이유는 이진 정보와 실수 정보에 대해 다른 연산률을 적용하는 것이 타당하지만, 실수 정보에 대한 부가적인 탐색 방법이 동시에 사용되기 때문이다. 교배연산률은 0.8로 하였고, 교배하려고 하는 각 유전자는 0.25의 확률로 교배를 실시하였다. 이것은 유전자 집단의 모든 유전자들의 쌍중에서 80%정도의 쌍이 선택되어 교배

가 이루어 지며, 교배가 이루어지는 유전자쌍의 각 염색체중에서 25%정도가 실제로 교환된다는 것을 의미 한다. 돌연변이 연산은 각각의 유전인자에 대하여 돌연변이 확률로 이루어진다. 연산이 행해지는 유전인자는, 만일 이진의 구조정보라면 '0' 혹은 '1'로 변화시키고, 실수의 가중치 정보라면 초기 가중치의 범위내의 임의의 값으로 바꾸도록 하였다. 돌연변이 확률은 0.001로 하였다.

그림 6(a)의 오차함수에서 $E_d=3$, $f_{max}=2$, $f_{mid}=1.8$ 로 하였고, 역모델 학습을 위한 플랜트 입력 $u(t)$ 는 식 (9)와 같이 설정하였다.

$$u(t) = \begin{cases} 1 & , 0 \leq t \leq 10 \\ 2 & , 10 \leq t \leq 20 \\ 1 & , 20 \leq t \leq 30 \end{cases} \quad (9)$$

그림 8은 표 1에서 설정한 파라미터에 대해서 유전 알고리즘을 통해 전방향 신경망의 최적구조를 탐색한 결과를 나타낸다. 그림에서 실선은 전방향 신경망의 노드수(중간 노드수+출력 노드수)를 나타내고, 점선은 노드들을 연결하고 있는 신경망의 가중치 수를 나타낸다. 여기서 노드수와 가중치수들은 진화 과정에서 상대적인 적합도로 최대의 적합도를 갖는 신경망에 대한 값이다.

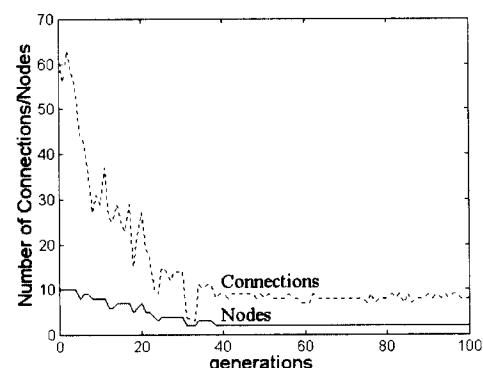
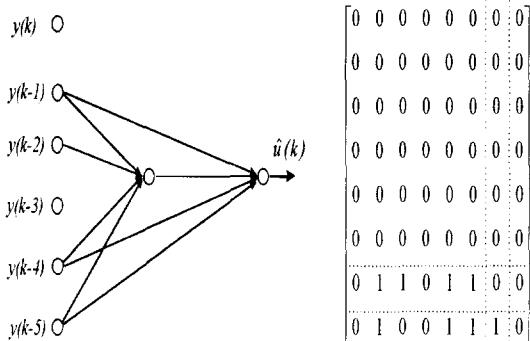


그림 8. 유전 알고리즘에 의한 전방향 신경망의 최적구조 탐색

Fig. 8. Genetic search for optimal structure of the feedforward neural network.

그림 8에서 유전 알고리즘의 탐색에 따라 단계적으로 신경망의 노드수와 가중치수들이 감소되었으며 가중치의 수는 8로, 노드의 수는 2로 각각 수렴하였다. 따라서 신경망의 오차가 요구되는 오차보다 작으면서 최소

의 노드를 갖는 신경망은 중간 노드의 수가 1개인 전방향 신경망이라는 것을 알 수 있다.



(a) 구조(Structure) (b) 구조행렬(Connection matrix)

그림 9. 탐색된 최소의 크기를 갖는 전방향 신경망
(a) 구조 (b) 구조행렬

Fig. 9. The feedforward neural network with minimum size.

(a) Structure (b) Connectivity constraint matrix

그림 9(a)는 유전자 알고리즘에 의해서 탐색된 최적 전방향 신경망의 구조를 나타내고, 그림 9(b)는 유전연산에 의해 탐색된 구조행렬을 나타낸다. 구조행렬에서의 점선은 입력층과 중간층, 출력층을 구분하기 위한 것이다. 탐색하는 신경망의 입력 노드의 수를 6으로 설정하였으나, 4개의 입력 노드만을 사용하여, 중간노드의 수가 1이고 가중치의 수가 8인 전방향 신경망으로 수렴하였다.

3. 최적구조 전방향 신경망 제어기의 성능평가
경험적으로 설계한 다층퍼셉트론 신경망 제어기^[12]와 유전 알고리즘에 의해 최적화한 전방향 신경망 제어기의 성능을 비교하였다. 제어 대상에 대한 신경망 제어기는 [2]에서 주어진 값을 사용한다. 비선형 플랜트에 대한 평형 상태에서 선형화한 플랜트 모델 $\hat{P}(s)$ 는 식 (10)과 같다.

$$\hat{P}(s) = \frac{10}{s^3 + 10s^2 + 0.2s - 9.8}, \quad (10)$$

$$= \frac{10}{(s-2.76)(s+8.67)(s+4.09)}$$

정정 시간(settling time)을 4초, 감쇄율(damping ratio)을 $1/\sqrt{2}$, 정정 시간 범위(settling time criterion)를 초기 오차의 2%로 설정한 기준 모델 $B(s)$ 는 다음과 같다.

$$B(s) = \frac{2}{(s^2 + 2s + 2)} \cdot \frac{10}{(s+10)}, \quad (11)$$

$$= \frac{20}{s^3 + 12s^2 + 22s + 20}$$

제한제어기 $G_C(s)$ 는 제한 루프의 극이 $\lambda_1 = -8$, $\lambda_2 = -10 + j4$, $\lambda_3 = -10 - j4$ 이 되도록 제한 루프 이득 \hat{K} 을 식 (12)과 같이 설정하고, 다시 예측기의 극은 $\mu_1 = -16$, $\mu_2 = -20 + j8$, $\mu_3 = -20 - j8$ 이 되도록 예측 이득 \hat{L} 을 식 (13)으로 설정한 것이다.

$$\hat{K} = [120.2 \ 27.6 \ 1.8] \quad (12)$$

$$\hat{L} = [46 \ 643.8 \ 624]^T \quad (13)$$

따라서 설계된 보상기 $G_C(s)$ 는 식 (14)와 같다.

$$G_C(s) = \frac{24410.2(s^2 + 13.5s + 41.4)}{s^3 + 74s^2 + 2207.8s + 32725.2}$$

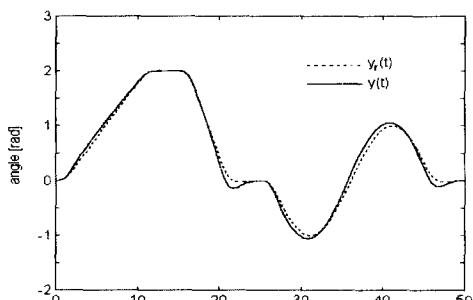
$$= 24410.2 \cdot \frac{(s+8.7)(s+4.8)}{(s+38.9)(s+17.6-j23.1)(s+17.6+j23.1)} \quad (14)$$

플랜트 역모델에 대한 신경망 학습시 사용한 학습상수는 신경망의 오차감소율에 해당한다. 주 FNNM에서 학습된 역모델은 부 FNNM으로 복사되어 다음 이산 시간에서 사용되기 때문에, 오차감소율이 너무크면, 부 FNNM과 실제의 역모델과의 차이가 커질 수 있다. 따라서 학습상수를 0.025로 작게 하였다. 그리고 샘플링 시간은 0.005초로 하였으나, 신경망 학습을 위한 계산이 많아지므로 매 0.04 [sec]마다 학습이 이루어지도록 하였다. 그리고 플랜트의 초기 상태는 $x_1 = x_2 = x_3 = 0$, 초기 가중치의 범위는 $[-0.1, 0.1]$ 으로 설정하였다.

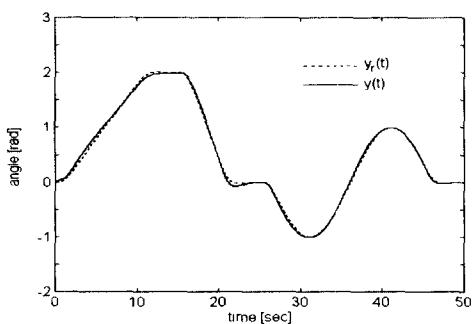
신경망 제어기에 식 (15)와 같이 표현되는 기준 입력 $r_1(t)$ 을 인가하였을 경우, 비선형 플랜트에 대한 다층퍼셉트론 신경망과 유전 알고리즘에 의해 최소구조를 갖는 전방향 신경망의 성능을 비교하였다.

$$r_1(t) = \begin{cases} 0.2t & , 0 \leq t \leq 10 \\ 2 & , 10 \leq t \leq 15 \\ -0.4t + 8 & , 15 \leq t \leq 20 \\ 0 & , 20 \leq t \leq 25 \\ -\sin(\frac{\pi}{10}(t-25)) & , 25 \leq t \leq 45 \\ 0 & , 45 \leq t \leq 50 \end{cases} \quad (15)$$

그림 10(a)는 경험적으로 설계한 입력 노드수 3, 중간 노드수 3, 그리고 출력 노드수가 1인 다층퍼셉트론 신경망 제어기^[12]의 출력을 나타낸다. 그림 10(b)는 유전 알고리즘에 의해 탐색된 입력 노드수 4, 중간 노드 수 1, 그리고 출력 노드수가 1인 전방향 신경망 제어기의 출력을 나타낸다. 여기서, 점선은 기준 모델의 출력 $y_r(t)$ 이고, 실선은 플랜트의 출력 $y(t)$ 을 나타낸다.



(a)



(b)

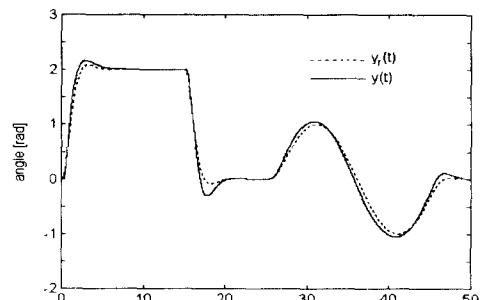
그림 10. 기준입력 $r_1(t)$ 에 대한 다층 퍼셉트론 및 전방향 신경망의 성능비교
(a) 다층퍼셉트론 신경망 제어기 (b) 전방향 신경망 제어기

Fig. 10. Comparison of the performance of neural controllers for the reference input $r_1(t)$
(a) Multilayer perceptron neural controller (b) Feedforward neural controller.

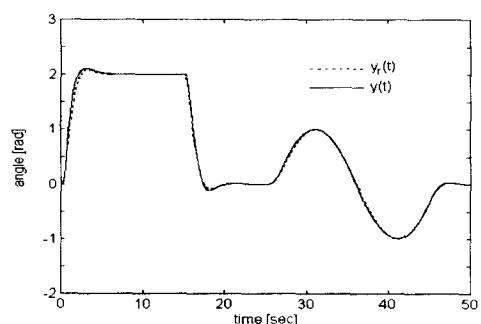
같은 조건에서 기준 입력을 바꾸어 두 신경망 제어기의 성능을 비교하였다. 식 (16)은 기준입력 $r_2(t)$ 를 나타낸다. 그림 11(a)는 다층 퍼셉트론 신경망의 출력을 나타내고, 그림 11(b)는 전방향 신경망 제어기 성능을 나타낸다. 전방향 신경망 제어기가 더 작은 노드수

와 가중치를 가지고 있음에도 불구하고 기준입력을 성공적으로 추종하고 있다는 것을 보여준다.

$$r_2(t) = \begin{cases} 2 & , 0 \leq t \leq 15 \\ 0 & , 15 \leq t \leq 25 \\ \sin\left(\frac{\pi}{10}(t-25)\right) & , 25 \leq t \leq 45 \\ 0 & , 45 \leq t \leq 50 \end{cases} \quad (16)$$



(a)



(b)

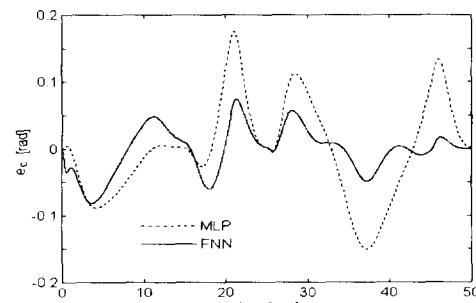
그림 11. 기준입력 $r_2(t)$ 에 대한 다층 퍼셉트론 및 전방향 신경망의 성능비교
(a) 다층퍼셉트론 신경망 제어기 (b) 전방향 신경망 제어기

Fig. 11. Comparison of the performance of neural controllers for the reference input $r_2(t)$.
(a) Multilayer perceptron neural controller (b) Feedforward neural controller.

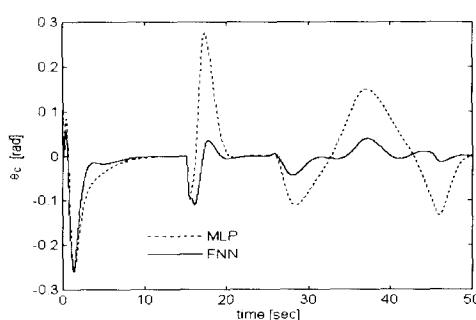
그림 12는 기준 입력에 대한 다층퍼셉트론 신경망과 전방향 신경망 제어기의 오차 $e_c(t)$ 를 나타낸다. 전방향 신경망 제어기의 오차가 다층퍼셉트론 신경망 제어기의 오차에 비해 상당히 작다는 것을 알 수 있다.

이상에서 다층퍼셉트론 신경망보다 더 작은 수의 노

드와 가중치를 가진 전방향 신경망의 성능이 감소하지 않음을 알 수 있다. 표 2는 다층퍼셉트론 신경망 제어기와 전방향 신경망 제어기의 성능을 50 [sec] 동안의 제곱오차 ISE와 최대오차 MAE를 평가지표로 하여 비교한 것이다.



(a)



(b)

그림 12. 다층퍼셉트론 신경망 제어기와 전방향 신경망 제어기의 오차비교
(a) $r_1(t)$ (b) $r_2(t)$

Fig. 12. Comparison of errors of multilayer perceptron and feedforward neural controller.

(a) $r_1(t)$ (b) $r_2(t)$

$$ISE = \sum_k [y_r(k) - y(k)]^2 \quad (17)$$

$$MAE = \max_k |y_r(k) - y(k)| \quad (18)$$

표 2에 비교된 다층퍼셉트론 신경망은 경험적으로 얻은 가중치의 개수가 129이고 노드수가 7(입력 3, 중간 3, 출력 1)인 신경망^[2]이며, 전방향 신경망은 유전 알고리즘으로 최적화한 가중치의 개수가 6이고 노드수가 6(입력 4, 중간 1, 출력 1)인 신경망이다. 따라서 전방향 신경망이 계산시간이나 크기 측면에서, 경험적으로 얻어진 다층퍼셉트론 신경망 제어기에 비해 노드의 수

나 가중치의 수가 작으므로 더 좋으며, 최적화한 전방향 신경망이 더 좋은 성능을 보여주었다.

표 2. 다층퍼셉트론 신경망과 전방향 신경망 제어기의 비교

Table 2. Comparison of multilayer perceptron and feedforward neural controller.

| 기준 입력 | 구 분 | ISE | MAE |
|----------|-----|-------|------|
| $r_1(t)$ | MLP | 54.43 | 0.18 |
| | FNN | 11.94 | 0.08 |
| $r_2(t)$ | MLP | 71.72 | 0.27 |
| | FNN | 16.95 | 0.26 |

V. 결 론

본 논문에서는 유전 알고리즘을 이용하여 전방향 신경망 제어기의 구조와 가중치를 최적화하는 방법을 제안하였다. 유전 알고리즘과 온라인 학습 알고리즘을 통합하여 신경망 제어기의 구조와 가중치를 동시에 최적화하였다. 전방향 신경망의 구조와 실수 가중치를 유전 탐색하고, 신경망의 온라인 학습 알고리즘을 동시에 적용하여 가중치를 미세조정함으로써 유전 알고리즘의 탐색 성능이 향상되었다. 또한 상대 적합도를 사용하여 유전 알고리즘이 조기수렴하지 않고, 유전자 집단의 상태 변화를 목표를 향해 단계적으로 진화하였다.

최적화한 전방향 신경망으로 신경망 제어기를 설계하면, 다층퍼셉트론 신경망에 비해 더 작은 노드와 가중치로 더 좋은 성능을 얻을 수 있음을 알 수 있다. 직류 전동기로 제어되는 비선형 역진자 시스템을 제어 대상으로 선정하여, 제안한 유전 알고리즘으로 전방향 신경망의 구조 및 가중치를 최적화하였다. 신경망 제어기의 제어성능을 제곱오차의 합과 최대절대오차의 평균 지표를 이용하여 비교한 결과, 더 작은 노드수와 가중치 수를 가진 전방향 신경망 제어기가 경험적으로 설계된 다층퍼셉트론 신경망 제어기보다 더 좋은 성능을 발휘하였다. 따라서 제안한 유전 알고리즘에 의한 전방향 신경망 모델의 구조 최소화 및 가중치 최적화를 통해, 크기가 작으면서 더 좋은 성능을 발휘하는 전방향 신경망 제어 시스템을 설계할 수 있었다.

참 고 문 현

- [1] K. S. Narendra and K. Parthasarathy,

- [1] "Identification and Control of Dynamical Systems Using Neural Networks," *IEEE Trans. on Neural Networks*, vol. 1, no. 1, 4-37, March 1990.
- [2] J. G. Kuschewski, S. Hui, and S. H. Zak, "Application of Feedforward Neural Networks to Dynamical System Identification and Control," *IEEE Trans. on Control Systems Technology*, vol. 1, no. 1, 37-49, March 1993.
- [3] R. Reed, "Pruning Algorithms-A Survey," *IEEE Trans. on Neural Networks*, vol. 4, no. 5, September 1993.
- [4] J. R. McDonnell, W. C. Page, and D. E. Waagen, "Neural Network Construction Using Evolutionary Search," *Proc. of Annual Conf. on Evolutionary Programming*, 9-16, 1994.
- [5] K. Balakrishnan and V. Honavar, "Properties of Genetic Representations of Neural Architectures," *Proc. of World Congress on Neural Networks*, Washington, 1995.
- [6] T. Nagao, T. Agui, and H. Nagahashi, "Structural Evolution of Neural Networks Having Arbitrary Connections by a Genetic Method," *IEICE Trans. on Information and Systems*, vol. E76-D, no. 6, June 1993.
- [7] D. Dasgupta and D. R. McGregor, "Designing Neural Networks using the Structured Genetic Algorithm," *Artificial Neural Networks 2*, vol. 1, 263-268, 1992.
- [8] V. Maniezzo, "Genetic Evolution of the Topology and Weight Distribution of Neural Networks," *IEEE Trans. on Neural Networks*, vol. 5, no. 1, January 1994.
- [9] 조철현, 공성곤, "유전 알고리즘을 이용한 전방향 신경망의 구조 최적화," 인공지능, 신경망 및 퍼지 시스템 춘계종합학술대회 논문집, 131-136, 1996.
- [10] 조철현, 공성곤, "전방향 신경망 제어기를 위한 온라인 학습 알고리즘의 수정," 전자공학회 논문지, 논문심사 중, 1996
- [11] D. E. Goldberg, *Genetic algorithms in search, optimization & machine learning*, Addison Wesley, 1989.
- [12] D. B. Fogel, "Introduction to simulated evolutionary optimization," *IEEE Trans. on Neural Networks*, vol. 5, no. 1, 3-14, 1994.
- [13] Z. Michalewicz, *Genetic Algorithms+Data Structures=Evolution Programs*, Second Edition, Springer-Verlag, 1994.
- [14] 박철훈, 박래정, "유전 알고리즘에서 조기포화를 막는 방법," 93년도 제3회 인공지능, 신경망 및 퍼지 시스템 종합학술대회 논문집, 55-59, 1993.
- [15] 이주장, 박활서, 정일권, "적응 시뮬레이터드 어널링 유전 알고리즘의 제어문제에 대한 응용," 전기학회 논문집, 43권, 10호, 1729-1743, 1994
- [16] 조철현, 공성곤, 멀티모드 목적함수에 대한 유전자 알고리즘의 최적 파라미터 설정, 인공지능, 신경망 및 퍼지 시스템 춘계종합학술대회 논문집, 18-22, 1995

저자 소개

曹 喆 鉉(正會員)

1991년 2월 숭실대학교 전기공학과 졸업(공학사). 1996년 8월 숭실대학교 전기공학과 대학원 졸업(공학석사). 현재 대우통신 종합연구소 연구원 재직. 관심분야는 신경망, 유전 알고리즘, 지능제어 통신망 및 운용

公 聖 坤(正會員)

1982년 서울대학교 공과대학 전기공학과 졸업(공학사). 1987년 서울대학교 대학원 전기공학과 졸업(공학석사). 1991년 미국 University of Southern California 졸업(공학박사). 1992년 3월 ~ 현재 숭실대학교 공과대학 전기공학과 부교수. 관심분야는 퍼지시스템, 신경회로망, 영상 및 신호처리, 지능제어, 패턴인식, 유전알고리즘