

工學碩士 學位論文

유전알고리즘을 이용한 신경 회로망 기반 시스템
식별기의 최적화 설계 및 응용에 관한 연구

A Study on the Optimal Design and Application of a System
Identifier Based on Neural Networks Using Genetic Algorithms

指導教授 黃 勝 郁

2002 年 2 月

韓國海洋大學校 大學院

制 御 計 測 工 學 科

金 洪 福

목 차

Abstract	iii
제 1 장 서 론	1
제 2 장 신경 회로망 기반 시스템 식별	4
2.1 다층 퍼셉트론 및 Levenberg-Marquardt 알고리즘	4
2.1.1 뉴런	4
2.1.2 다층 퍼셉트론	5
2.1.3 Levenberg-Marquardt 알고리즘	6
2.2 신경 회로망 기반 시스템 식별	11
2.2.1 시스템 식별 절차	11
2.2.2 시스템 모델의 구조	13
2.2.3 ARX Model	14
제 3 장 유전알고리즘을 이용한 신경 회로망 기반 시스템 식별기 구조의 최적화	16
3.1 유전알고리즘의 구조 및 역할	16
3.2 신경 회로망 구조의 부호화 및 적합도	18
3.3 시스템 식별기 최적화의 구조 및 연산과정	21
제 4 장 시뮬레이션 및 검토	24
4.1 최적 구조 신경 회로망 모델 도출	24

4.2 최적 구조 신경 회로망을 이용한 시스템 식별	29
4.3 Direct Inverse Control	33
4.4 결과 검토	35
제 5 장 실험 및 검토	38
5.1 선박용 안정화 위성 안테나의 구조	38
5.2 선박용 안정화 위성 안테나의 최적 구조 신경 회로망 모델 도출	41
5.3 최적 구조 신경 회로망을 이용한 선박용 안정화 위성 안테나 시스템의 식별	46
5.4 결과 검토	50
제 6 장 결 론	51
참고문헌	52

A Study on the Optimal Design and Application of a System Identifier Based on Neural Networks Using Genetic Algorithms

By

Hong Bok Kim

Department of Control and Instrumentation Engineering.
Graduate School, Korea Maritime University

Abstract

This paper deals with nonlinear system modelling using neural networks and genetic algorithms.

Applications of neural networks to control and identification have been actively studied because of their approximating ability of nonlinear functions.

It is important to design the neural network which has optimal structure for minimum error and fast response time. Nowadays, genetic algorithms have been getting more popular because of their simplicity and robustness.

In this paper, We optimize neural network structure using a genetic algorithms. The genetic algorithm uses binary coded chromosomes for neural network structure and searches for an optimal neural network structure of minimizing error and fast response time. Through extensive simulation and practical tests, It is verified that the proposed method is effective for identification of nonlinear system.

제 1 장 서 론

시스템의 식별(identification) 혹은 모델링(Modeling)은 입출력 데이터로부터 동적 시스템의 모델을 결정하는 것으로써 효과적인 제어시스템을 구현하기 위해서 선행되어야 한다. 그러나 현장에서 접할 수 있는 많은 제어 대상의 경우 수학적으로 모델링하기 어렵거나, 복잡한 비선형성을 가지고 있어 기존의 선형 이론에 근거하여 해석하는 데에는 한계가 있어 좋은 결과를 얻지 못한다. 따라서 입출력 데이터로부터 복잡한 비선형 사상관계를 학습할 수 있는 신경 회로망은 시스템을 식별하고 모델링 하는데에 응용되어질 수 있다.

신경 회로망(Neural Network)은 인간이나 동물들이 가지고 있는 생물학적인 뇌의 신경세포를 모델화하여 인공적으로 지능을 만드는 것이다. 즉, 인간의 뇌에 존재하는 생물학적 신경세포와 이들의 연결 관계를 단순화시켜 수학적으로 모델링하여 인간의 두뇌가 나타내는 지능적 형태를 구현하는 것이다. 병렬 시스템인 인간의 두뇌를 수학적으로 모델링하여 만든 인공적인 두뇌를 공학이나 기타 여러 분야에 적용시키려고 하는 것이 신경 회로망의 연구 목적이다.

최초의 신경 회로망 개념은 1943년 W. McCulloch 와 W. Pitts에 의하여 제시되었다.^[1] 이들은 단순한 뉴런(Neuron)들의 수많은 결합이 바로 인간 두뇌에서 계산 능력의 원천이라고 생각하였다. 이들이 제시한 모델에서는 논리 기능을 수행하기 위하여 뉴런간의 결합에 가중치를 주고, 뉴런의 반응 여부를 결정하는 임계치를 설정하였다. 이 모델에서는 뉴런의 가중 입력합이 임계치 보다 크면 뉴런들이 활성화되고, 그렇지 않으면 뉴런들이 반응하지 않는 개념으로써 단순한 논리 기능의 수행이 가능하였다.

1949년에는 D. Hebb가 처음으로 신경 회로망의 학습 방법을 제안하였다.^[2] 기본적인 Hebb의 학습 방법은 두 자극이 동시에 입력하면 뉴런의 학습이 빨라지며, 일단 학습이 완료된 후에는 한가지 자극만 입력하여도 뉴런이 활성화 된다는 것이다. 1950년대와 1960년대는 신경 회로망에 대한 연구가 활발히 이루어졌고, 대표적인 것이 F. Rosenblatt의 퍼셉트론(Perceptron)과 B. Widrow의 ADALINE(ADaptive LInear NEuron)이 있다.^{[3][4]} 퍼셉트론은 인지가 가능한 관점에서 상당한 관심을 모았으나, AND 및 OR 연산 등 선형 분리 가능한 문제

의 해결에만 사용될 수 있었다.

J. Hopfield는 1982년에 Hopfield 모델 즉, 순환 신경망 구조의 연상 메모리를 제안하여 부분 입력 데이터로도 완벽한 데이터의 복원이 가능함을 입증하였다.^[5]

그후, 여러 가지 모델들이 제시되었고, 더욱 괄목할만한 점은 오류 역전파 알고리즘(Back Propagation Algorithm : BP)의 개발이다. BP 알고리즘은 일반적인 다층 신경 회로망(Multilayer Neural Network)을 학습시키는데 있어서 현재까지도 매우 유용하게 사용되고 있다. 이후 신경 회로망에 대한 연구가 활발히 이루어 졌으며, 음성 합성과 인식, 문자 인식, 영상 처리, 제어 시스템, 연상 메모리 등 많은 분야에서 응용되어지고 있다.

그 중에서 다층 퍼셉트론은 비선형 시스템의 모델링이나 제어에 효과적으로 응용되고 있으며 시스템의 비선형 특성뿐만 아니라, 불확실성에도 강인하게 대처 할 수 있다. 그러나 신경 회로망의 구조가 복잡해지면 노드수가 증가함에 따라 학습시간 및 응답 시간이 많이 걸리며, 학습시 초기 값에 따라 전역 최소점에 도달하지 않는 단점이 있다. 따라서, 실제 시스템을 효과적으로 표현할 수 있는 최적 구조 신경 회로망을 설계하여야 한다. 여기서 최적 구조 신경 회로망이란 주어진 시스템에 대해 최소의 노드수와 그에 따른 연결구조, 그리고 원하는 출력과 학습된 신경 회로망의 출력사이의 오차가 최소가 되며, 응답시간 역시 최소가 되는 구조를 가진 신경 회로망을 의미한다. 다층 신경 회로망을 구성하는 데에는 일반적으로 은닉층의 개수, 각 은닉층에서 뉴런의 개수, 초기 연결 가중치, 학습율 등이 있으며 이러한 요소들은 신경 회로망의 출력에 많은 영향을 끼친다. 특히, 은닉층의 개수와 뉴런의 수는 신경 회로망의 학습시간과 출력에 상당한 영향을 미친다. 은닉층의 개수와 뉴런의 수가 많으면 그 만큼 뉴런간의 연결강도가 증가되어 학습이 느려진다. 단순히 생각하면 은닉층의 개수가 증가하면 뉴런수가 많아지므로 신경 회로망의 성능이 개선될 것처럼 여겨지지만, 실제로는 학습이 오히려 안 되는 경우도 있으며, 비록 학습이 되었더라도, 실제 응용 시에 많은 시간이 소모되므로 처리 및 응답 시간이 느려지는 단점이 있다. 한편, 은닉층의 개수와 뉴런의 수가 작다면 학습시간은 짧아지지만, 학습이 충분히 이루어지지 않아 원하는 결과를 얻어내기가 어렵다. 만약, 많은 수의 은닉층과 뉴런수를 가지는 신경 회로망이라 할지라도 그 보다 적은 요소를 가지는 신경 회로망보다 오차가 같거나, 크다면 많은 요소의 신경 회로망 구조를 택할 수 없다.

특히, 비선형 시스템의 식별기(Identifier)같은 경우에는 매우 복잡한 입출력 관계가 존재한다. 그러한 입출력 관계를 적절히 사상(Mapping)하기 위해서는 구조의 최적화가 절실히 요구된다. 신경 회로망 제어기에서도 시스템이 빠르게 응답을 하거나 빠른 제어기의 성능을 요구하는 경우에도 학습 시간이나, 응답 시간이 가장 빠르면서 오차를 최소로 하는 신경 회로망 구조가 요구된다. 따라서 신경 회로망 구조의 최적화가 다른 어떠한 요소보다 먼저 선행되어야 한다.

최근 유전알고리즘(Genetic Algorithm : GA)을 이용한 신경 회로망 최적화에 대한 연구가 활발히 진행되고 있다. [6][7][8] GA를 이용하여 신경 회로망의 가중치를 최적화 하는 방법은 신경 회로망의 구조를 결정하는 문제의 해결이 선행되어야 한다. 따라서, 본 논문에서는 수학적으로 해석이 어려운 복잡한 대상이나 많은 비선형 요소를 포함하는 시스템을 신경 회로망을 이용하여 식별하기 위해 GA를 이용한 최적의 신경 회로망 모델 도출기법을 제안한다.

본 논문에서는 먼저 신경 회로망의 구조를 GA의 유전자로 이진 코딩하여 최적 구조 신경 회로망을 탐색하고, 신경 회로망의 학습 방법에 의해 가중치를 최적화 하였다. 이 최적 신경 회로망을 이용하여 시스템을 식별하였다. 본 논문의 구성은 다음과 같다. 2장에서는 신경 회로망 기반 시스템 식별, 3장에서는 GA를 이용한 신경 회로망 기반 시스템 식별기 구조의 최적화, 4장에서는 제안한 방법을 이용한 시뮬레이션 및 검토, 5장에서는 선박용 안정화 위성 안테나에서의 적용 및 검토, 마지막 6장에서는 결론을 맺는다.

제 2 장 신경 회로망 기반 시스템 식별

2.1 다층 퍼셉트론 및 Levenberg-Marquardt 알고리즘

2.1.1 뉴런

노드(Node) 혹은 단위(Unit)라고 일컬어지는 뉴런(Neuron)은 신경 회로망을 구성하는 기본 단위이다. 뉴런은 식 (2.1)과 같이 신경 회로망의 입력값과 각각의 연결 강도(Weight)를 가지고, 그들을 합하여 활성화 함수에 의하여 결과치를 내고, 그 값을 사용하게 된다.

$$y_i = f_i(h_i) = \left(\sum_{j=1}^n \phi_j w_{i,j} + w_{i,0} \right) \quad (2.1)$$

그림 2.1은 뉴런의 기본 구조를 나타낸다.




그림 2.1 뉴런

Fig. 2.1 A Neuron

그림 2.1에서 ϕ_j 는 입력을 나타낸다. 뉴런의 입력으로는 외부에서 가해질 수도 있고, 다른 뉴런의 출력이 입력으로 가해질 수도 있다. $w_{i,j}$ 는 각각의 연결 강도이며, $w_{i,0}$ 는 바이어스이다.

2.1.2 다층 퍼셉트론 (Multilayer Perceptron : MLP)

뉴런은 다양한 형태로 결합하여 하나의 신경 회로망을 이룬다. 현재 다양한 형태의 신경 회로망이 존재하는데, 그 중에서 가장 일반적인 것이 MLP이다.

MLP에서 가장 널리 사용되는 것은 3계층 신경 회로망 구조이며, 그 구조는 그림 2.2와 같다.

3계층 신경 회로망은 외부 입력을 받아들이는 입력층(Input Layer), 처리된 결과가 출력되는 출력층(Output Layer), 입력층과 출력층 사이에 위치하여 외부로 나타나지 않는 은닉층(Hidden Layer)의 3계층으로 구성되어 있다. MLP의 동작을 수학적으로 표현하면 식 (2.2)과 같다.

$$y_i(t) = g_i[\Phi, \theta] = F_i\left[\sum_{j=1}^{n_h} W_{i,j} f_j\left(\sum_{l=1}^{n_o} w_{j,l} \Phi_l + w_{j,0}\right) + W_{i,0}\right] \quad (2.2)$$

θ 는 연결 강도와 바이어스 $\{w_{j,l}, W_{i,j}\}$ 등, 신경 회로망에서 조정 가능한 모든 파라미터를 포함하는 파라미터 벡터(Parameter Vector)이다.




그림 2.2 다층 퍼셉트론
Fig. 2.2 Multilayer Perceptron

신경 회로망에서 연결 강도의 값을 결정하는 것은 입력 ϕ_i 과 출력 y_i 를 연관시키는 방법에 의해 정의된다. 연결 강도의 값을 결정하는 것을 학습(Training or Learning)이라고 한다. 즉 신경 회로망에서 학습이라 함은 특정한 응용 목적에 적합하도록 뉴런간의 연결 강도를 적응시키는 과정이다.

2.1.3 Levenberg-Marquardt 알고리즘

본 논문에서는 신경 회로망을 학습하기 위해 Levenberg-Marquardt 학습 알고리즘을 사용한다. 학습시킬 데이터를 식 (2.3)과 같이 표현한다.

$$Z^N = \{ [u(t), y(t)], T= 1 \dots N \} \quad (2.3)$$

여기서 $u(t)$ 는 신경 회로망의 입력이고, $y(t)$ 는 목표치이다. 학습의 목적은 신경 회로망의 출력 $\hat{y}(t)$ 가 실제 출력 $y(t)$ 에 가까이 접근하도록 하는 것이다.

Levenberg-Marquardt 알고리즘은 평균 제곱 오차(Mean Square Error)를 정의함으로써 신경 회로망의 출력과 실제 출력과의 근접성을 평가한다.

$$V_N(\theta, Z^N) = \frac{1}{2N} \sum_{t=1}^N [y(t) - \hat{y}(t; \theta)]^2 = \frac{1}{2N} \sum_{t=1}^N \epsilon^2(t, \theta) \quad (2.4)$$

따라서, 신경 회로망 학습의 최종 연결 강도는 다음과 같다.

$$\hat{\theta} = \arg \min_{\theta} V_N(\theta, Z^N) \quad (2.5)$$

신경 회로망의 학습에서 오차 E 를 최소화하는 업데이트 룰은 다음과 같다.

$$\theta^{(i+1)} = \theta^{(i)} + \mu^{(i)} f^{(i)} \quad (2.6)$$

$\theta^{(i)}$ 는 i 단계의 파라미터를 나타내며, $f^{(i)}$ 는 탐색 방향, $\mu^{(i)}$ 는 스텝 사이즈를 나타낸다. Levenberg-Marquardt 알고리즘은 Gauss-Newton Method를 근간으로 하므로 Gauss-Newton Method를 살펴보면 다음과 같다.

실제 출력 $y(t)$ 와 신경 회로망의 출력 $\hat{y}(t|\theta)$ 의 오차를 정의하면, 오차 $\varepsilon(t, \theta)$ 는 식 (2.7)과 같이 정의된다.

$$\varepsilon(t, \theta) = y(t) - \hat{y}(t|\theta) \quad (2.7)$$

Gauss-Newton Method는 식 (2.7)의 오차를 최소화하기 위해 식 (2.8)과 같은 선형 근사화 식을 사용한다.

$$\begin{aligned} \tilde{\varepsilon}(t, \theta) &= \varepsilon(t, \theta^{(i)}) + [\varepsilon'(t, \theta^{(i)})]^T (\theta - \theta^{(i)}) \\ &= \varepsilon(t, \theta^{(i)}) - [\phi(t, \theta^{(i)})]^T (\theta - \theta^{(i)}) \end{aligned} \quad (2.8)$$

$$\text{단, } \phi(t, \theta) = \frac{d\hat{y}(t|\theta)}{d\theta}$$

신경 회로망 학습 과정의 i 번째 iteration에서 criterion $V_N(\theta, Z^N)$ 을 정의하면,

$$V_N(\theta, Z^N) \simeq L^{(i)}(\theta) = \frac{1}{2N} \sum_{t=1}^N \tilde{\varepsilon}^2(t, \theta) \quad (2.9)$$

이며,

$\theta = \theta^{(i)}$ 일 때, Gradient $G(\theta^{(i)})$ 는 다음과 같다.

$$G(\theta^{(i)}) = \frac{dL^{(i)}(\theta)}{d\theta} \Big|_{\theta = \theta^{(i)}} = \frac{1}{N} \sum_{t=1}^N \phi(t, \theta^{(i)}) [y(t) - \hat{y}(t|\theta^{(i)})] \quad (2.10)$$

또한, Gauss-Newton Hessian $R(\theta^{(i)})$ 는 다음과 같다.

$$R(\theta^{(i)}) = \frac{d^2 L^{(i)}(\theta)}{d\theta^2} \Big|_{\theta=\theta^{(i)}} = \frac{1}{N} \psi(t, \theta^{(i)}) \psi^T(t, \theta^{(i)}) \quad (2.11)$$

Gauss-Newton Hessian $R(\theta^{(i)})$ 는 양의 반한정이 되며, Gauss-Newton Method는 일차미분만을 필요로 하므로 구현하기 쉽다는 장점이 있다.

따라서, Gauss-Newton Method의 탐색 방향(Search Direction)은 식 (2.12)과 같고, 오차 E 를 최소화하는 업데이트 룰은 식 (2.12)을 식 (2.6)에 대입하면 식 (2.13)과 같다.

$$R(\theta^{(i)}) f^{(i)} = -G(\theta^{(i)}) \quad (2.12)$$

$$\theta^{(i+1)} = \theta^{(i)} - R^{-1}(\theta^{(i)}) G(\theta^{(i)}) \quad (2.13)$$

Levenberg-Marquardt 알고리즘은 Gauss-Newton Method의 업데이트 룰 식 (2.12)에서 파라미터 λ 를 첨가하여 식 (2.14)과 같은 형태를 취한다.

$$[R(\theta^{(i)}) + \lambda^{(i)} I] f^{(i)} = -G(\theta^{(i)}) \quad (2.14)$$

그림 2.3은 파라미터 λ 값에 대한 Levenberg-Marquardt 알고리즘의 탐색 방향과 다른 알고리즘의 탐색 방향을 비교한 것이다.

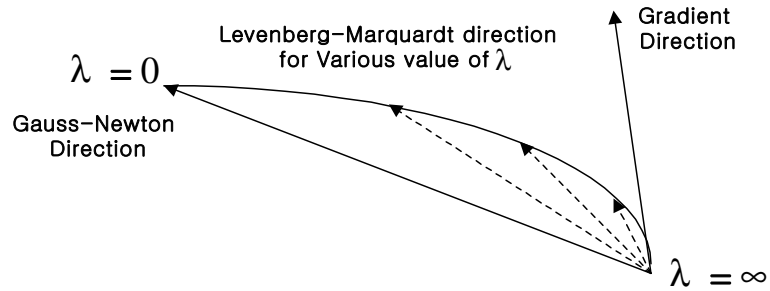


그림 2.3 λ 값에 대한 Levenberg-Marquardt 알고리즘의 탐색방향
Fig 2.3 The Levenberg-Marquardt Direction for various value λ

λ 값이 ∞ 에 근접함에 따라 학습 알고리즘은 Gradient Method 즉, BP 알고리즘의 형태가 되며, 0에 근접함에 따라 Gauss-Newton Method 형태가 된다.

즉, Levenberg-Marquardt 알고리즘은 λ 값을 변형해 가며 적절한 탐색 방향을 찾게 된다.

Levenberg-Marquardt 알고리즘의 λ 값은 파라미터 γ 에 의해 결정된다.

γ 는 식 (2.15)에 의해 구해진다.

$$\gamma^{(i)} = \frac{V_N(\theta^{(i)}, Z^N) - V_N(\theta^{(i)} + f^{(i)}, Z^N)}{V_N(\theta^{(i)}, Z^N) - L^{(i)}(\theta^{(i)} + f^{(i)})} \quad (2.15)$$

식 (2.15)의 분모 $V_N(\theta^{(i)}, Z^N) - L^{(i)}(\theta^{(i)} + f^{(i)})$ 는 식 (2.16)에 의해 구해진다.

$$V_N(\theta^{(i)}, Z^N) - L^{(i)}(\theta^{(i)} + f^{(i)}) = \frac{1}{2} [(f^{(i)})^T (G(\theta^{(i)}) + [\lambda^{(i)} I] f^{(i)})] \quad (2.16)$$

식 (2.15)의 γ 값에 의해 λ 가 결정되게 되는데, γ 가 0.75 보다 크게 되면 $\lambda = \lambda / 2$ 가 되며, γ 가 0.25 보다 작으면 $\lambda = 2 * \lambda$ 가 된다.

Levenberg-Marquardt 알고리즘의 구현 절차는 [표1]과 같다.

[표1] Levenberg-Marquardt Algorithm

1. Select an initial parameter vector $\theta^{(0)}$ and an initial value $\lambda^{(0)}$.
2. Determine the search direction from
$$[R(\theta^{(i)}) + \lambda^{(i)} I] f^{(i)} = -G(\theta^{(i)}) .$$
3. $\gamma^{(i)} > 0.75 \Rightarrow \lambda^{(i)} = \lambda^{(i)} / 2 .$
4. $\gamma^{(i)} < 0.25 \Rightarrow \lambda^{(i)} = 2 * \lambda^{(i)} .$
5. If $V_N(\theta^{(i)} + f^{(i)}, Z^N) < V_N(\theta^{(i)}, Z^N)$ then accept
$$\theta^{(i+1)} = \theta^{(i)} + f^{(i)}$$
 as a new iterate and let $\lambda^{(i+1)} = \lambda^{(i)} .$
6. If the stopping criterion is not satisfied, go to Step 2 .

Levenberg-Marquardt 학습방법은 비선형 문제를 푸는데 효과적인 학습방법으로 해의 발산을 막고 안정된 해를 구할 수 있다는 장점이 있다. 본 논문에서 제시하는 최적 구조 신경 회로망 탐색 알고리즘은 학습오차와 응답시간을 산출하여야 하므로 각 구조에서 신경 회로망의 학습이 충분히 이루어 져야한다. 따라서, 기존의 BP 알고리즘보다 더욱 효과적인 Levenberg-Marquardt 학습방법을 사용한다.

2.2 신경 회로망 기반 시스템 식별

2.2.1 시스템 식별 절차

MLP는 시스템의 입출력 데이터 사이에 비선형을 갖는 비선형 동적 시스템 (Nonlinear Dynamic System)의 이산 시간 모델링(Discrete-Time Modelling)에 적용될 수 있다.




그림 2.4 단일 입력 $u(t)$ 와 단일 출력 $y(t)$ 를 가지는 동적 시스템

Fig. 2.4 A Dynamic System with One Input $u(t)$ and One Output $y(t)$

t 는 샘플링 시간(Sampling Time)을 의미하며, $y(t)$ 는 현재의 출력, $y(t-1)$ 는 한 단계 이전 시간의 출력을 나타낸다. 동적 시스템의 입출력이 이산 시간에서 측정 가능하다면, 동적 시스템은 식 (2.17)과 같이 나타낼 수 있다.

$$y(t) = S[y(t-1), \dots, y(t-n), u(t-1), \dots, u(t-m)] \quad (2.17)$$

즉, MLP 신경 회로망은 식 (2.17)의 S 를 근사화 시키는데 사용 될 수 있다.

이때, 신경 회로망의 입력 (ϕ_1, ϕ_2, \dots)은 시스템의 n 차 과거 출력, m 차 과거 입력 값으로 선택된다. 따라서 MLP 신경 회로망의 출력은 식 (2.18)과 같다.

$$\hat{y}(t|\theta) = g[\theta, \phi(t)] = \sum_{j=1}^{n_h} W_j f_j \left[\sum_{l=1}^{n+m} w_{j,l} \phi_l(t) + w_{j,0} \right] + W_{i,0} \quad (2.18)$$

신경 회로망을 이용하여 시스템을 식별하는 절차는 다음과 같다.

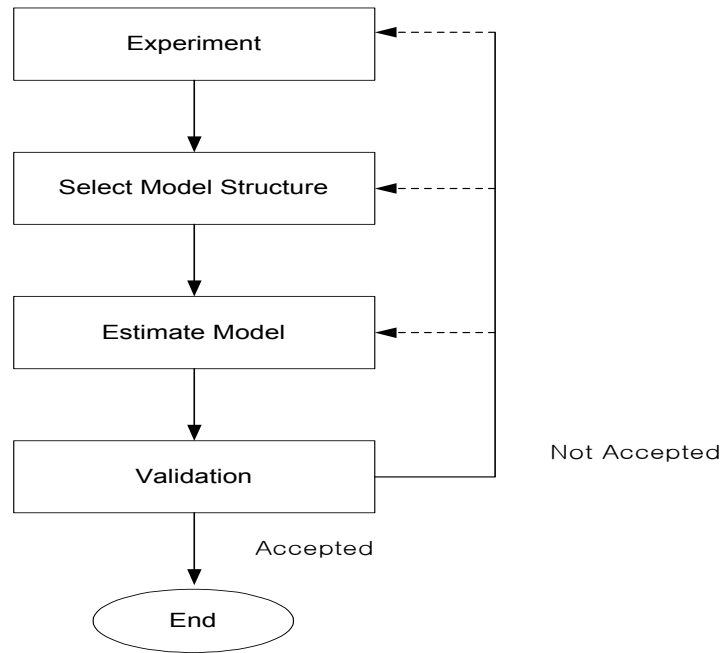


그림 2.5 기본 시스템 식별 절차

Fig 2.5 Basic System Identification Procedure

신경 회로망을 이용한 시스템의 식별 절차는 그림 2.5와 같다. 플랜트(Plant)에 대한 동 특성을 파악하기 위해 적절한 샘플링 시간에 의해 시스템이 거동 할 수 있는 전 영역에 대한 입출력 데이터를 얻는 실험작업이 선행된다. 그후, 시스템에 적합한 신경 회로망 모델을 선정한다. 여기서는 입출력 모델(Input-Output Model)이나 상태 공간 모델(State Space Model)등이 고려될 수 있다. 이들 중 적절한 모델을 선택하여 시스템 식별 작업을 수행하게 되는데, 선택한 모델이 시스템을 정확히 표현 할 수 있도록 다양한 방법으로 시스템을 추정한다. 즉, 신경 회로망 모델에서는 이 작업이 신경 회로망을 학습시키는 단계가 되는 것이

다. 마지막으로 신경 회로망을 학습한 후, 신경 회로망의 출력과 실제 시스템의 출력을 비교하여 원하는 목표치의 결과가 도출되었는지를 확인(Validation)하는 작업이 수행된다. 이 확인 작업의 결과가 적절하지 못한 경우 처음으로 되돌아가서 다시 시스템 식별 절차에 따라 반복수행 한다.

2.2.2 시스템 모델의 구조

일반적으로 선형 시스템은 식 (2.19)처럼 표현 될 수 있다.

$$y(t) = G(q^{-1})u(t) + H(q^{-1})e(t) \quad (2.19)$$

여기서, G 와 H 는 시간 지연 연산자(Time Delay Operator) q^{-1} 을 가지는 전달 함수(Transfer Function)이며, $e(t)$ 는 임의의 확률 밀도 함수(Probability Density Function)이며, 과거 입력에 독립적인 백색 잡음 신호(White Noise Signal)이다. 시스템이 이와 같이 표현될 수 있다면, 시스템 식별(System identification)은 두 전달함수 G 와 H 가 좋은 특성을 갖도록 정의하는 것이다.

식 (2.19)에 의해 시스템 예측자(System Predictor)는 식 (2.20)과 같이 정의된다.

$$\hat{y}(t|t-1) = H^{-1}(q^{-1}) G(q^{-1}) u(t) + [1-H^{-1}(q^{-1})] y(t) \quad (2.20)$$

즉, 예측자(Predictor)는

$$\hat{y}(t|\theta) = \hat{y}(t|t-1, \theta) = g(\Phi(t), \theta) \quad (2.21)$$

단, θ 는 파라미터 벡터이고, g 는 신경 회로망에 의해 구현되는 함수이다. 따라서, 식 (2.19)은 다음과 같이 쓸 수 있다.

$$y(t) = G(q^{-1}, \theta) u(t) + H(q^{-1}, \theta) e(t) \quad (2.22)$$

2.2.3 ARX Model

동적 시스템을 표현하는 모델 구조는 식 (2.22)과 같이 나타낼 수 있으나, 더욱 일반적인 모델 구조(General Model Structure)는 다음과 같고,

$$A(q^{-1})y(t) = q^{-d} \frac{B(q^{-1})}{F(q^{-1})} u(t) + \frac{C(q^{-1})}{D(q^{-1})} e(t) \quad (2.23)$$

단,

$$\begin{aligned} A(q^{-1}) &= 1 + a_1 q^{-1} + \dots + a_n q^{-n} \\ B(q^{-1}) &= b_0 + b_1 q^{-1} + \dots + b_m q^{-m} \\ C(q^{-1}) &= 1 + c_1 q^{-1} + \dots + c_k q^{-k} \\ D(q^{-1}) &= 1 + d_1 q^{-1} + \dots + d_l q^{-l} \\ F(q^{-1}) &= 1 + f_1 q^{-1} + \dots + f_r q^{-r} \end{aligned}$$

ARX(AutoRegressive eXternal input)모델 구조는 다음과 같은 형식을 취한다.

$$G(q^{-1}, \theta) = q^{-d} \frac{B(q^{-1})}{A(q^{-1})} \quad H(q^{-1}, \theta) = \frac{1}{A(q^{-1})} \quad (2.24)$$

따라서, 예측자(Predictor)는 다음과 같다.

$$\begin{aligned} \hat{y}(t | \theta) &= q^{-d} B(q^{-1})u(t) + [1 - A(q^{-1})]y(t) \\ &= \Phi^T(t) \theta \end{aligned} \quad (2.25)$$

단,

$$\begin{aligned} \Phi(t) &= [y(t-1) \dots y(t-n), u(t-d) \dots u(t-d-m)]^T \\ \theta &= [-a_1 \dots -a_n, b_0 \dots b_m]^T \end{aligned} \quad (2.26)$$

선형 시스템의 경우 ARX모델을 이용하여 시스템을 식별할 수 있으나, 실제 대부분의 시스템은 비선형이고, 이러한 비선형 시스템에 선형 시스템 식별이론을 적용하여 해석하는 데에는 한계가 있다. 따라서 본 논문에서는 비선형 시스템을 식별하기 위해 선형 시스템을 식별하는 ARX모델 구조를 근간으로 하며, 실제 시스템의 출력과 입출력 데이터 사이의 사상관계를 신경 회로망을 이용하여 적절히 사상하여 시스템 식별을 구현한다.

제 3 장 유전알고리즘을 이용한 신경 회로망 기반 시스템 식별기 구조의 최적화

신경 회로망을 이용하여 시스템을 식별할 경우 대상 시스템에 맞는 최적 구조 신경 회로망을 설계하여야 한다. 여기서 최적 구조 신경 회로망이란 주어진 시스템에 대해 최소의 노드수와 그에 따른 연결구조, 그리고 원하는 출력과 학습된 신경 회로망 출력사이의 오차를 최소로 하고 응답시간 역시 최소로 하는 가중치들로 구성되는 것을 의미한다.

본 장에서는 유전알고리즘을 이용하여 신경 회로망의 구조를 최적화 하는 방법에 대해 기술한다.

3.1 유전알고리즘의 구조 및 역할

유전알고리즘(Genetic Algorithm : GA)은 자연계의 적자 생존과 유전학에 근거한 병렬, 전역적 탐색 알고리즘이다. 탐색 공간이 미분 가능하거나 연속이라는 가정이 필요하지 않으며, 해의 집단을 취급하기 때문에 해 공간 내에서 동시에 여러 개의 상태들을 평가하여 전역 최적해를 찾을 가능성이 크다. 유전알고리즘의 계산은 부호화, 유전자 집단의 크기 선정, 적합도 함수의 설계, 재생산, 교배 연산, 돌연변이 연산으로 구성되어 있다. 유전알고리즘의 성능은 유전자 집단의 크기, 적합도의 분포, 재생산 방법, 교배 연산 방법 및 확률, 돌연 변이 연산 방법 및 확률 등에 따라 변화한다. 그림 3.1은 유전알고리즘의 기본 연산 구조와 전체 흐름도를 나타낸 것이다.

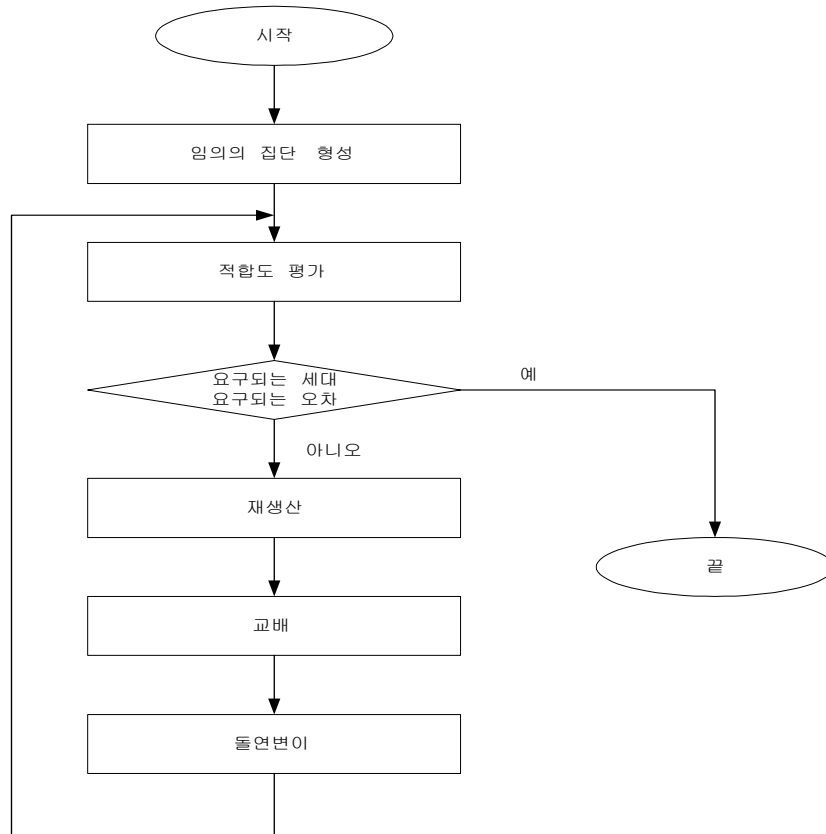


그림 3.1 유전알고리즘의 기본 연산 구조

Fig. 3.1 Basic Operation Structure Of Genetic Algorithms

본 논문에서는 GA를 이용하여 신경 회로망의 구조를 최적화 하므로, 유전알고리즘의 역할은 신경 회로망 구조에서 은닉층의 개수와 뉴런의 수를 염색체로 표현하여 적합도 함수에 의해 최적의 구조를 신경 회로망에 전달하는 역할을 하게 된다. GA는 신경 회로망 구조의 요소를 전역 탐색함으로써 최적의 은닉층 개수 및 각 은닉층에서의 뉴런의 개수를 신경 회로망으로 전달함으로써, 응답 시간과 오차가 최소가 되는 최적의 신경 회로망 구조를 찾게된다.

탐색된 최적의 신경 회로망 구조를 이용하여 그림 3.2와 같은 구조로 비선형 시스템을 식별하게 된다.




그림 3.2 시스템 식별 구조
Fig. 3.2 System Identification Structure

3.2 신경 회로망 구조의 부호화 및 적합도

GA를 이용하여 어떠한 문제를 해결하고자 할 때, 풀고자 하는 문제에 대한 가능한 해들을 염색체(Chromosome)로 표현하고 이들을 점차 변형해 나감으로써 점점 더 좋은 성능의 해들을 생성해 나간다. 본 논문에서는 신경 회로망의 구조를 염색체로 표현하여 최적 구조 신경 회로망을 도출하여야 하므로, 다음과 같은 방법으로 신경 회로망의 구조를 코드화 하였다. 신경 회로망의 구조에서 은닉층의 수와 각 은닉층에서의 뉴런수를 GA의 이진 코딩(Binary Encoding)을

사용하여 코딩한 후 GA의 연산과정을 통해 최적의 신경 회로망 구조를 탐색한다. 각 진화 단계에서 GA는 신경 회로망의 구조를 결정하게 되고, 이 구조를 바탕으로 신경 회로망의 학습 방법에 의해 학습을 하게 된다. 학습 후 실제 출력과 신경 회로망 출력 사이의 오차와 신경 회로망 구조가 가지는 응답 시간을 산출하며 이것을 적합도 함수 값으로 산출하여 GA의 개체를 진화하는데 사용한다.

은닉층의 개수와 각 은닉층에서의 뉴런수를 염색체로 표현하기 위해, 본 논문에서는 [표2]와 같이 탐색 범위를 가정하였으며, 다음과 같이 표현하였다.


[표2] 탐색 범위

Bit	Bit Value	Value
1(MSB)	0	은닉층의 수 1
	1	은닉층의 수 2
2 ~ 4	0 0 0	첫 번째 은닉층의 뉴런수 5
	⋮	⋮
	1 1 1	첫 번째 은닉층의 뉴런수 12
5 ~ 7	0 0 0	두 번째 은닉층의 뉴런수 5
	⋮	⋮
	1 1 1	두 번째 은닉층의 뉴런수 12

염색체를 전체 7 bit로 이진 코딩하며 염색체의 최상위 비트는 은닉층의 개수, 다음 3 bit는 첫 번째 은닉층의 뉴런수, 나머지 3 bit는 두 번째 은닉층의 뉴런수를 나타낸다.

그림 3.3은 본 논문에서 사용할 이진 코딩의 예를 나타낸 것이다.

Number of hidden layer	Number of first hidden layer neurons				Number of second hidden layer neurons		
S =	0	0	1	0			



Number of hidden layer	Number of first hidden layer neurons				Number of second hidden layer neurons		
S =	1	1	0	0	0	1	0




그림 3.3 신경 회로망 구조의 이진 코딩
 Fig. 3.3 Binary Encoding of Neural Network

본 논문에서 제안한 최적 구조 신경 회로망 탐색은 크게 두 가지의 조정기구에 의해 얻어진다. 우선 GA를 이용하여 은닉층 수, 각 은닉층에서의 뉴런수와 같은 신경 회로망 구조를 최적화하는 과정을 거치게 되며, 다음으로 각 구조에 대해서 뉴런간의 연결강도는 신경 회로망 학습 방법인 Levenberg-Marquardt 알고리즘에 의해 결정되어진다. 최적의 신경 회로망 구조를 얻기 위해서는 평가 기준이 있어야 하므로 본 논문에서는 식 (3.1)과 같은 적합도 함수를 설정하며, 이 적합도 함수가 최소가 되도록 조정되어 최적 구조 신경 회로망을 탐색한다.

$$fit_{GA} = W_1 f_e(e) + W_2 f_t(t) \quad (3.1)$$

여기서 $f_e(e)$ 는 실제 출력과 신경 회로망 출력 사이의 오차이고, $f_t(t)$ 는 신경 회로망 구조가 가지는 응답시간이며, W_1, W_2 는 적절한 연결 강도 값이다.

3.3 시스템 식별기 최적화의 구조 및 연산과정

은닉층의 개수와 각 은닉층에서의 뉴런의 수를 유전알고리즘의 이진 코딩을 사용하여 염색체로 표현하며, 각 탐색 단계에서 염색체의 값을 신경 회로망 구조로 변환하여 신경 회로망으로 전달하게 된다. 신경 회로망은 전달된 구조를 가지고 동일한 조건하에서 학습하게 되며, 학습이 끝난 후 오차와 응답 시간을 산출하여 저장하게 된다. 오차와 응답 시간의 값을 적합도 함수를 이용하여 적합도를 산출하며, 재생산, 교배 연산, 돌연 변이 연산 과정을 거쳐 진화하게 된다. 진화 후 개체들은 최적 구조의 신경 회로망 구조를 가지게 된다.

그림 3.4는 본 논문에서 제안한 유전알고리즘을 이용한 시스템 식별기 최적화의 메카니즘을 나타낸 것이다. 그림 3.5는 본 논문에서 제안한 유전알고리즘을 이용한 시스템 식별기 최적화의 연산 과정을 나타낸 것이다.

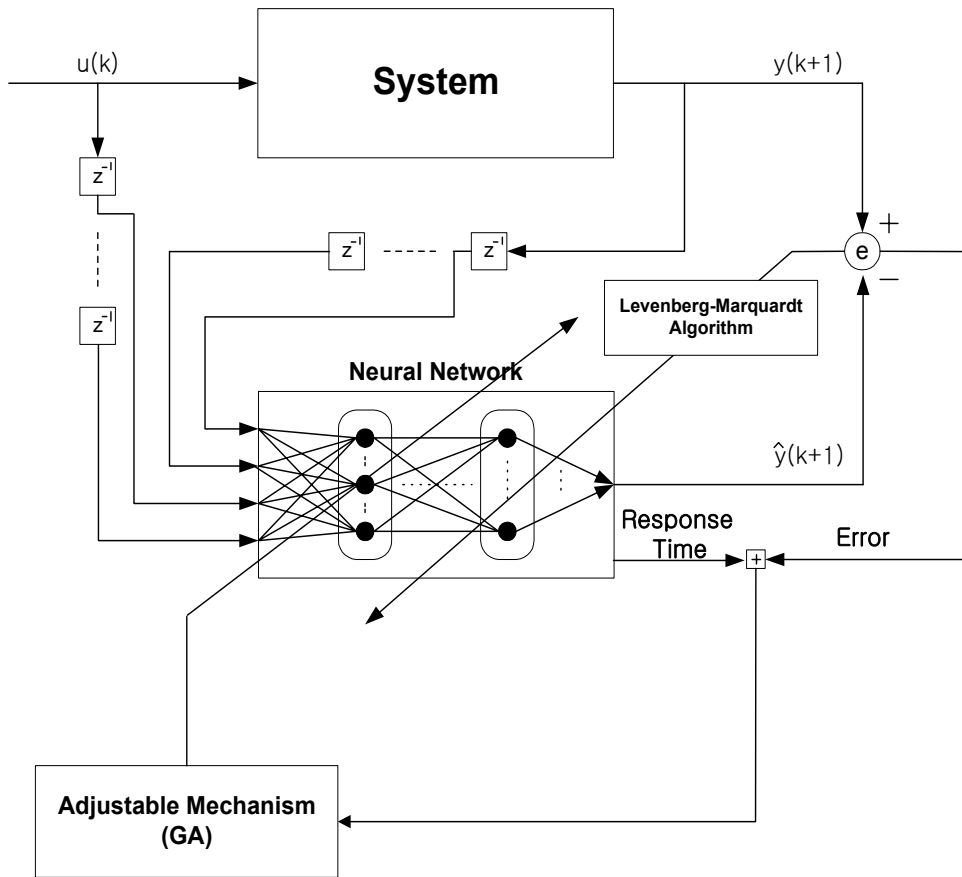


그림 3.4 유전알고리즘을 이용한 시스템 식별기의 최적화 구조
 Fig 3.4 Structure of System Identifier Optimization
 Using Genetic Algorithms

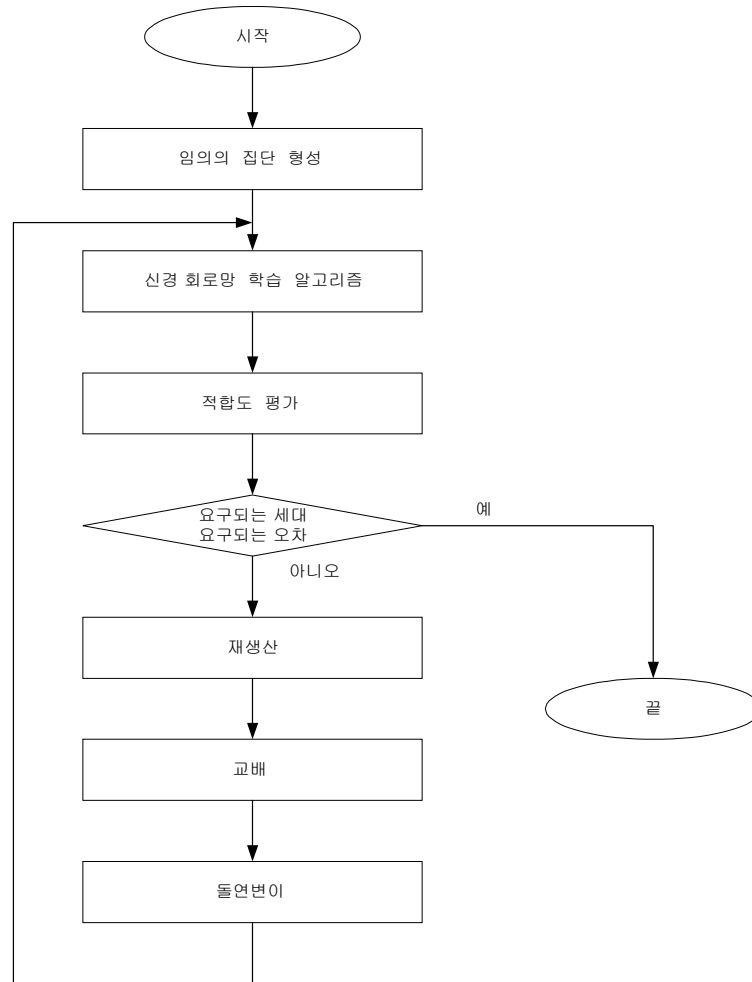


그림 3.5 유전알고리즘을 이용한 시스템 식별기의 최적화 과정
 Fig. 3.5 Flowchart of System Identifier Optimization
 Using Genetic Algorithms


제 4 장 시뮬레이션 및 검토

4.1 최적 구조 신경 회로망 모델 도출


제안한 방법을 비선형 시스템에 적용하여 그 유효성을 검증한다. 시스템은 식 (4.1)과 같은 차분방정식으로 표현 가능한 비선형 시스템을 가정한다.

$$y(k+1) = \frac{1.2y(k)}{0.8 + y(k)^2} + 0.5 y(k-1) + 0.5 u(k) \quad (4.1)$$

시스템이 식 (4.1)과 같이 표현가능 하다면, 시스템의 신경 회로망 기반 시스템 식별기를 구현하기 위해서는 시스템의 전 영역을 표현하고 동 특성을 파악할 수 있는 입력신호를 가하여 출력을 얻는다. 그림 4.1과 같은 입력신호가 시스템의 특성을 파악할 수 있다고 가정하며 시스템에 입력으로 가하여 출력을 얻었다.



(a) Input Signal



(b) Output Signal

그림 4.1 시스템 식별을 위한 입출력 신호

Fig. 4.1 Input-Output Signals for System Identification

비선형 시스템의 입출력 신호를 사용하여 본 논문에서 제안한 방법으로 최적 구조 신경 회로망 기반 시스템 식별기를 탐색한다.


시스템의 입출력 신호는 그림 4.1의 데이터를 사용하였으며, 탐색 범위는 [표 3]과 같이 설정하였다.

[표3] 탐색 범위


	설정 값
입력층 뉴런수	4
출력층 뉴런수	1
최소 은닉층 수	1
최대 은닉층 수	2
은닉층의 최소 뉴런수	5
은닉층의 최대 뉴런수	12

[표3]의 탐색 범위를 바탕으로 최적 구조 신경 회로망 기반 시스템 식별기의 구조를 탐색하였다. 유전알고리즘의 파라미터에서 최대 진화 수는 50세대, 개체 수는 20, 교배 확률 0.8, 돌연변이 확률 0.01로 설정하였으며, 적합도 함수의 웨이트 값은 $W_1 = 100$, $W_2 = 1$ 로 설정하였다. 탐색 결과 주어진 적합도 함수를 최소로 하는 신경 회로망 구조는 2개의 은닉층과 첫 번째 은닉층의 뉴런수는 12, 두 번째 은닉층의 뉴런수는 5로 탐색되었다.

그림 4.2는 탐색 결과를 나타낸 것이고, 그림 4.3은 탐색된 최적 구조 신경 회로망의 구조를 나타낸 것이다.



(a) Objective Function



(b) Parameter

그림 4.2 BCGA를 이용한 파라미터 추정
 Fig. 4.2 Parameter Estimation Using a BCGA





그림 4.3 최적의 구조를 갖는 신경 회로망
 Fig. 4.3 Optimally Structured Neural Network


4.2 최적 구조 신경 회로망을 이용한 시스템 식별

비선형 시스템을 식별하기 위해 탐색된 최적 구조 신경 회로망 기반 시스템 식별기로 시스템을 식별하였다. 입력층과 첫 번째 은닉층, 첫 번째 은닉층과 두 번째 은닉층과의 활성화 함수는 시그모이드 함수(Sigmoid Function)를 사용하였으며, 두 번째 은닉층과 출력층과의 활성화 함수는 선형 함수(Linear Function)를 사용하였다. 신경 회로망이 시스템의 입출력 관계를 충분히 학습 할 수 있도록 학습 횟수는 4,000번을 사용하였다. 그림 4.4는 시스템의 식별결과를 나타낸 것이다. 신경 회로망을 이용하여 시스템을 식별할 경우 학습된 신경 회로망이 학습 시 사용된 입력과 다른 입력에 대해서도 실제 시스템의 출력과 근접한 신경 회로망 출력을 가지는지를 판단하는 Validation작업을 수행하여야 한다.

따라서, 본 논문에서는 그림 4.5와 같이 다른 입력신호를 비선형 시스템에 가하여 출력을 얻었다. 이 입출력 신호를 가지고 학습된 최적 구조 신경 회로망에 가하여 실제 시스템의 출력과 신경 회로망의 출력을 비교하였다. 그림 4.6은 이때의 실제 시스템의 출력과 신경 회로망의 출력을 나타낸 것이다.

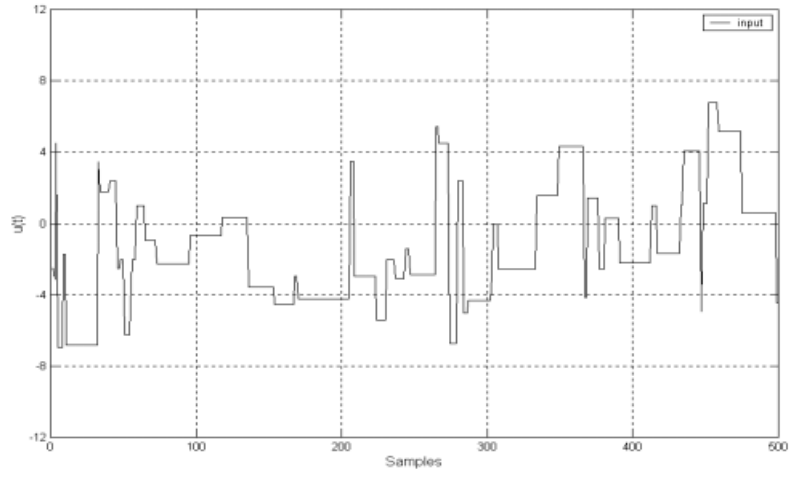


(a) Identification Output




(b) Error

그림 4.4 시스템 식별 결과 및 오차
 Fig. 4.4 System Identification Result and Error




(a) Input Signal




(b) Output Signal

그림 4.5 Validation을 위한 입출력 신호
 Fig 4.5 Input-Output Signals for validation



(a) Identification Output



(b) Error

그림 4.6 Validation 작업의 시스템 식별 결과 및 오차
 Fig. 4.6 System Identification Result and Error of Validation

4.3 Direct Inverse Control

비선형 시스템을 제어하기 위해 신경 회로망이 효과적으로 사용될 수 있다.

신경 회로망을 이용하여 비선형 시스템을 제어하는 방법 중에 하나인 Direct Inverse Control 방법을 사용하여 본 논문에서 제안한 방법의 유효성을 검증한다. Direct Inverse Control의 방법은 시스템의 역 모델로써 동작하는 신경 회로망을 구현하고, 이를 제어 시스템의 제어기로써 사용하는 것이다. 일반적인 시스템 식별기로써의 신경 회로망의 구조는 식 (4.2)과 같다.

$$y(t) = f[y(t-1), \dots, y(t-na), u(t-nk), \dots, u(t-nk-nb+1)] \quad (4.2)$$

식 (4.2)에서 $u(t)$ 는 입력신호, $y(t)$ 는 출력 신호이며, na 는 출력 신호의 시간 지연 계수, nb 는 입력 신호의 시간 지연 계수, nk 는 시스템의 시간 지연 계수이다.

시스템의 역 모델은 식 (4.3)의 구조를 가진다.

$$\hat{u}(t) = f^{-1}[y(t+nk), \dots, y(t+nk-na), u(t-1), \dots, u(t-nb+1)] \quad (4.3)$$

Direct Inverse Control의 제어는 시간 $t+1$ 에서의 출력 $y(t+1)$ 을 Reference $r(t+1)$ 로 대체함으로써, 시스템을 제어하는 방식을 가진다. 만약 신경 회로망이 시스템의 역 모델을 정확히 표현한다면, 시간 $t+1$ 에서 Reference를 정확히 추종하는 제어 입력 $u(t)$ 를 시스템의 역 모델이 만들어 산출하게 된다. 그림 4.7은 Direct Inverse Control의 구조를 나타낸 것이다.

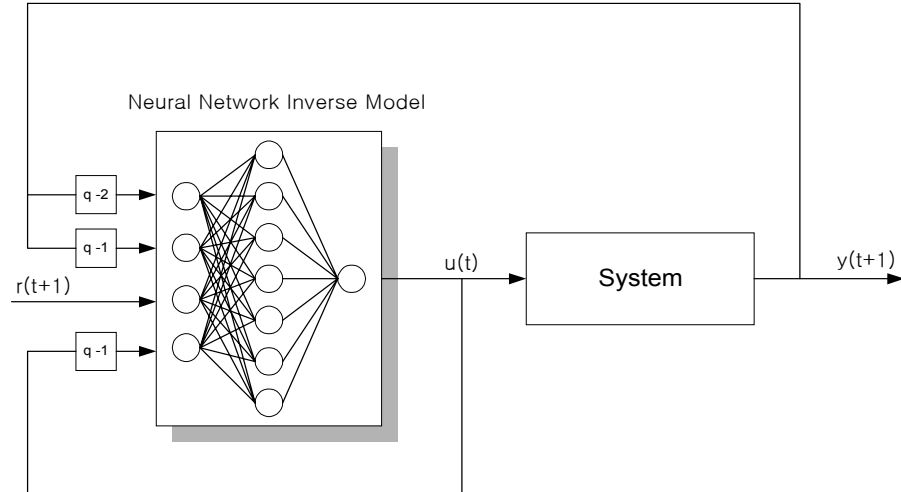


그림 4.7 Direct Inverse Control

Fig. 4.7 Direct Inverse Control


식 (4.1)의 비선형 시스템을 Direct Inverse Control 방법을 사용하여 비선형 시스템을 제어하였다. 비선형 시스템을 식별하기 위해서 도출한 최적 신경 회로망의 구조(2개의 은닉층과 첫 번째 은닉층의 뉴런수는 12, 두 번째 은닉층의 뉴런수는 5)를 시스템의 역 모델 도출의 신경 회로망 구조에도 적용하여 시스템의 역 모델을 구현하였다. 시스템의 식별기에서와 같은 조건하에서 신경 회로망을 학습하였다. 그림 4.8은 시스템 역 모델 식별의 결과를 나타낸 것이다.

구현된 시스템 식별기 모델과 시스템 역 모델을 이용하여 비선형 시스템을 Direct Inverse Control 방법을 사용하여 시스템을 제어하였다. 비선형 시스템은 구현된 시스템 식별 모델을 사용하였고, 시스템 역 모델 역시 구현된 시스템 역 모델을 사용하였다. 시스템의 Sampling Time은 20 ms로 설정하였고, 500 sample동안의 구형과 형태의 Reference Signal에 대한 시스템의 출력 $y(t)$ 를 관찰하였다.


4.4 결과 검토

비선형 시스템의 경우 최적 구조 신경 회로망 기반 시스템 식별기를 그림 4.3과 같이 탐색하였으며, 그림 4.4와 같이 신경 회로망의 출력이 시스템의 출력을 정확하게 추종함을 알 수 있었다. 이때의 오차 역시 충분히 작은 값들을 가지며 탐색된 최적 구조 신경 회로망의 구조가 적절함을 알 수 있었다. 그리고 학습된 최적 구조 신경 회로망 기반 시스템 식별기가 다른 입력 신호에서는 충분히 실제 시스템의 출력을 추종함을 알 수 있었고, 오차 역시 작은 값들을 가짐을 알 수 있었다. 시스템의 역 모델 산출에서도 그림 4.8과 같이 탐색된 최적 구조가 시스템 역 모델 산출에서 적용 가능하며 시스템의 역 모델을 정확히 구현함을 알 수 있었다.

탐색된 시스템 식별기와 시스템 역 모델을 이용하여 비선형 시스템을 Direct Inverse Control 방법을 사용하여 제어하였으며, 그림 4.9에서와 같이 시스템이 Reference Signal을 잘 추종함을 알 수 있었다. 따라서 본 논문에서 제안한 방법으로 탐색된 신경 회로망의 구조가 시스템 역 모델 도출 및 신경 회로망을 이용한 시스템 제어에도 효과적으로 응용될 수 있음을 알 수 있었다.




(a) Identification Output




(b) Error

그림 4.8 시스템 역 모델 식별 결과 및 오차

Fig. 4.8 System Inverse Model Identification Result and error



(a) System Response



(b) Error

그림 4.9 시스템 응답 및 오차
 Fig. 4.9 System Response and Error

제 5 장 실험 및 검토

5.1 선박용 안정화 위성 안테나의 구조

최근 들어 위성 통신은 망 구성의 광역성, 회선 구성의 신속성 및 효율성, 이동의 용이성 등의 장점이 있어 이에 대한 연구가 활발히 이루어지고 있고, 그 필요성도 차츰 증가되고 있다. 선박에서도 이러한 위성 통신 시스템의 필요성은 점차 증가되고 있고, 선박에서의 위성 통신 시스템을 구축함으로써, 해상 통신 및 조난 구조 통신망, 효율적인 운항관리, 좌표 식별등의 다양한 분야에 응용 될 수 있으므로, 선박에 위성 통신 시스템의 구축은 그 필요성이 충분히 크다고 할 수 있다. 하지만, 위성 통신 시스템을 선박에 이용하기 위해서는 지향성 위성 안테나의 안정화(Stabilization)과 반드시 이루어 져야 한다. 지향성 위성 안테나의 안정화는 선박의 운동특성 중 롤링(Rolling), 피칭(Pitching), 요잉(Yawing)의 세 가지 회전운동에 대하여 안테나가 선박의 운동에 관계없이 일정하게 지향하여야 한다. 이러한 특성에 대하여 능동적 안정화 방식을 갖는 안정화 위성 안테나용 Pedestal 제어 장치를 설계하였다.

본 논문의 실험 대상인 선박용 위성 안테나 시스템은 ADE(Above Deck Equipment)인 SAP(Stabilized Antenna Pedestal)와 안테나 기계 구조를 제어하는 PCU(Pedestal Control Unit), 그리고 UDE(Under Deck Equipment)인 ACU(Antenna Control Unit)로 구성되었다. SAP는 안테나의 기계 구조 부분으로써 디쉬(Dish)와 구동부가 포함된다. PCU는 SAP의 안정화를 담당하는 제어부로써 센서를 이용하여 선박의 운동성분을 실시간으로 계측하고 구동부를 직접 제어하여 안테나의 위성 지향각을 유지시키는 역할을 한다. ACU는 사용자로부터 위성 및 채널 신호를 입력받아 위성 위치와 채널 명령을 PCU에 전달하며, 또한 선택된 위성의 RF 신호세기를 위성 안테나로부터 입력받아 위성을 추종하기 위한 신호를 PCU에 전달하는 기능을 갖는다. 그림 5.1은 선박용 안정화 위성 안테나의 축 구조를 나타낸 것이다.

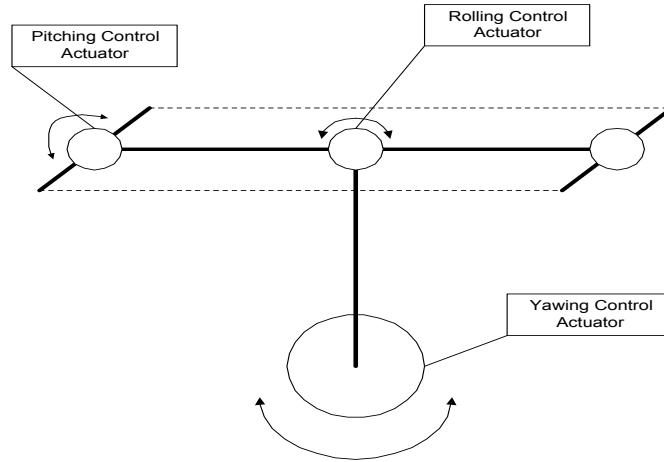


그림 5.1 안테나의 축 구조

Fig. 5.1 Axis Structure of an Antenna

본 논문의 실험 대상인 안정화 안테나 기구의 축 구조는 그림 5.1과 같은 X, Y, Z 축의 3축 구조로써, 축 중앙에 액츄에이터를 장착시켜 축 단위로 제어가 가능하도록 하였으며, 각축에 운동 감지 센서를 부착하여 선박의 운동을 안테나에서 축 단위로 분해하여 감지할 수 있도록 설계하였다. 따라서, 이 구조는 좌표 변환 알고리즘이 불필요하며, 이에 따라 시스템의 제어가 보다 간단해지며, 신뢰성이 높아진다.

안테나 제어부의 하드웨어적 구조는 다음과 같다. 선박의 롤링과 피칭시 절대 각도를 측정하기 위한 센서로는 경사 센서(Tilt Sensor, Spectron사의 SP5000)를 사용하였다. 센서의 특성은 완전한 수평일 때, 약 2.5V의 출력 전압을 내고, 50 mV/deg의 감도를 가지며, 측정 범위는 약 $\pm 30^\circ$ 이다. 경사 센서의 출력을 A/D 컨버터를 사용하여 변환하는 데에는 MAXIM사의 MAX180을 사용하였다.

MAX180의 특징은 8채널 입력이고, 12 bit의 분해능을 가진다. 구동부의 액츄에이터로는 DC Step Motor를 사용하였고, 구동 방식으로는 유니폴라(Unipolar) 방식을 선택하여 사용하였다. 그림 5.2 와 5.3은 선박용 안정화 위성 안테나의 구조를 나타낸 것이다.




그림 5.2 안테나의 측면
Fig. 5.2 Side of an Antenna




그림 5.3 안테나의 후면
Fig. 5.3 Back of an Antenna


지금까지의 선박용 안정화 위성 안테나 시스템의 축 구조와 안테나의 구조를 종합하여 볼 때, 안테나 시스템을 제어하기 위해서는 시스템의 식별 문제가 대두하게 된다. 하지만, 안테나의 구조적 특성으로 인해, 각 축 단위로 독립적으로 제어되며, 구동하는 액츄에이터역시 DC Step Motor를 사용하며, 선박의 복잡한 운동성분에 대한 시스템의 특성을 잘 표현할 수 있는 수학적 모델링 작업이 거의 불가능하다. 선박용 지향성 위성 안테나 시스템은 선박의 불규칙하고 변화가 많은 주위 외란에 대해 일정한 각도를 가지고 위성을 지향해야하는 세밀한 제어가 요구되며, 이에 따라서 시스템을 정확히 모델링 하여 시스템의 특성을 파악하고 제어기를 설계하여야 한다. 따라서 본 논문에서는 선박용 안정화 위성 안테나의 이러한 특성 때문에 시스템을 신경 회로망을 이용하여 식별하며, 본 논문에서 제안한 알고리즘을 사용하여 최적 구조 신경 회로망 기반 시스템 식별기를 사용하여 안테나 시스템의 신경 회로망 모델을 도출하고자 한다.

5.2 선박용 안정화 위성 안테나의 최적 구조 신경 회로망 모델 도출


선박용 안정화 위성 안테나 시스템의 최적 구조 신경 회로망 모델을 도출하기 위해 시스템의 Rolling축에 식 (5.1)과 같이 시스템의 동 특성을 정확히 파악할 수 있도록 선박의 운동 성분과 비슷한 입력 신호를 가하여 시스템의 출력을 얻었다.

$$u(t) = 13 \sin\left(\frac{\pi t}{2}\right) \cos\left(\frac{\pi t}{4}\right) + \sin\left(\frac{2t}{\pi}\right) \quad (5.1)$$

시스템의 샘플링 시간은 0.05s로 설정하여 30 초 동안 시스템에 가하였고, 시스템의 Rolling축 경사각을 측정하였다. 그림 5.4는 이때의 입출력 신호를 나타낸 것이다.



(a) Input Signal



(b) Output Signal

그림 5.4 시스템 식별을 위한 입출력 신호

Fig. 5.4 Input-Output Signals for System Identification

선박용 안정화 위성 안테나 시스템의 입출력 신호를 사용하여 본 논문에서 제안한 방법으로 최적 구조를 가진 신경 회로망 기반 시스템 식별기를 탐색한다.


시스템의 입출력 신호는 그림 5.4의 데이터를 사용하였으며, 탐색 범위는 [표 4]와 같이 설정하였다.

[표4] 탐색 범위


	설정 값
입력층 뉴런수	4
출력층 뉴런수	1
최소 은닉층 수	1
최대 은닉층 수	2
은닉층의 최소 뉴런수	5
은닉층의 최대 뉴런수	12

[표4]의 탐색 범위를 바탕으로 최적 구조 신경 회로망 기반 시스템 식별기의 구조를 탐색하였다. 유전알고리즘의 파라미터에서 최대 진화수는 50세대, 개체수는 20, 교배 확률 0.8, 돌연변이 확률 0.01로 설정하였으며, 적합도 함수의 웨이트 값은 $W_1=100$, $W_2=0.1$ 로 설정하였다. 탐색 결과 주어진 적합도 함수를 최소화 하는 신경 회로망 구조는 2개의 은닉층과 첫 번째 은닉층의 뉴런수는 12, 두 번째 은닉층의 뉴런수는 11로 탐색되었다.

그림 5.5는 탐색 결과를 나타낸 것이고, 그림 5.6은 탐색된 최적구조 신경 회로망의 구조를 나타낸 것이다.



(a) Objective Function



(b) Parameter

그림 5.5 BCGA를 이용한 파라미터 추정
 Fig. 5.5 Parameter Estimation Using a BCGA





그림 5.6 최적의 구조를 갖는 신경 회로망
 Fig. 5.6 Optimally Structured Neural Network

5.3 최적 구조 신경 회로망을 이용한 선박용 안정화 위성 안테나 시스템의 식별


선박용 안정화 위성 안테나 시스템을 식별하기 위해 탐색된 최적 구조 신경 회로망 기반 시스템 식별기로 시스템을 식별하였다. 입력층과 첫 번째 은닉층, 첫 번째 은닉층과 두 번째 은닉층과의 활성화 함수는 시그모이드(Sigmoid Function)를 사용하였으며, 두 번째 은닉층과 출력층과의 활성화 함수는 선형 함수(Linear Function)를 사용하였다. 신경 회로망이 시스템의 입출력 관계를 충분히 학습 할 수 있도록 학습 횟수는 4,000번을 사용하였다. 그림 5.7은 시스템의 식별결과를 나타낸 것이다. 신경 회로망을 이용하여 시스템을 식별할 경우 학습된 신경 회로망이 학습 시 사용된 입력과 다른 입력에 대해서도 실제 시스템의 출력과 근접한 신경 회로망 출력을 가지는지를 판단하는 Validation 작업을 수행하게 된다. 따라서 본 논문에서는 식 (5.2)과 같은 다른 입력신호를 실제 안테나 시스템에 가하여 출력을 얻었다.

$$u(t) = 13 \sin\left(\frac{-\pi t}{2}\right) \cos\left(\frac{-\pi t}{4}\right) + 12 \sin(2t) \quad (5.2)$$

이 입출력 신호를 가지고 학습된 최적 구조 신경 회로망에 가하여 실제 시스템의 출력과 신경 회로망의 출력을 비교하였다. 그림 5.9는 이때의 실제 시스템의 출력과 신경 회로망의 출력을 나타낸 것이다.




(a) Identification Output




(b) Error

그림 5.7 시스템 식별 결과 및 오차
 Fig. 5.7 System Identification Result and Error




(a) Input Signal




(b) Output Signal

그림 5.8 Validation을 위한 입출력 신호
 Fig. 5.8 Input-Output Signals for Validation



(a) Identification Result



(b) Error

그림 5.9 Validation작업의 시스템 식별 결과 및 오차
 Fig. 5.9 System Identification Result and Error of Validation

5.4 결과 검토

실제 시스템인 선박용 안정화 위성 안테나인 경우에도 그림 5.6과 같이 최적 구조 신경 회로망 기반 시스템 식별기를 탐색하였으며, 그림 5.7에서와 같이 신경 회로망의 출력이 시스템의 출력을 정확하게 추종함을 알 수 있었다. 이때의 오차 역시 충분히 작은 값들을 가지며 탐색된 최적 구조 신경 회로망의 구조가 적절함을 알 수 있었다. 복잡한 선박의 운동 특성에 대해 학습된 시스템 식별기가 다른 입력 신호에 대해서도 충분히 실제 시스템의 출력을 추종함도 알 수 있었다.

따라서, 수학적으로 모델링 하기 어려운 선박용 안정화 위성 안테나 시스템을 신경 회로망 기반 시스템 식별기를 이용하여 시스템을 식별하였으며, 실제 선박의 운동 성분에 대해서도 시스템을 잘 표현할 수 있는 최적 구조 신경 회로망 기반 시스템 식별기를 얻었다.

제 6 장 결 론

신경 회로망을 이용한 시스템의 모델링 및 식별에 있어서 신경 회로망의 구조는 오차의 크기 및 응답시간 등에 영향을 미치므로 매우 중요하다. 따라서 본 논문에서는 신경 회로망의 오차 및 응답시간을 목적 함수로 하여 신경 회로망의 최적 구조를 도출하는 기법을 제안하였다.

제안한 방법에 대한 유효성을 검증하기 위하여 비선형 요소가 포함된 시스템으로부터 얻어진 입출력 데이터에 근거하여 제안한 방법으로 최적 구조 신경 회로망 모델을 도출하고 도출한 신경 회로망 기반 시스템 식별기의 출력과 실제 시스템의 출력과 비교하였으며, 만족 할 만한 결과를 얻을 수 있었다. 또한 비선형 시스템을 Direct Inverse Control 방법으로 제어할 경우 본 논문에서 제안한 방법을 사용하여 시스템의 역 모델을 산출에도 적용 가능함을 입증하였고, 직접 제어동작에서도 만족한 결과를 얻을 수 있음을 알 수 있었다.

실제 시스템인 선박용 안정화 위성 안테나 시스템에서도 본 논문에서 제안한 방법을 사용하여 선박의 운동 성분을 잘 표현할 수 있는 시스템 식별기를 얻을 수 있었고, 도출한 식별기가 실제 시스템의 출력을 잘 표현함을 알 수 있었다.

차후 시스템의 특성을 파악하거나 제어를 설계할 경우 신경 회로망 기반 시스템 식별기가 좋은 대상이 될 수 있음을 알 수 있었고, 본 논문에서 제안한 방법 역시 시스템 역 모델 산출이나, 신경 회로망 제어기 설계 시에도 충분히 적용가능하며, 신경 회로망을 구성 할 경우 구조의 불확실성을 제거할 수 있는 방법으로 적용가능 하다고 생각된다.

참고 문헌

- [1] McCulloch, W., W. Pitts, A Logical Calculus of the Ideas Immanent in Nervous Activity, Bulletin of Mathematical Biophysics, Vol. 5, pp. 115-133, 1943
- [2] Hebb, D., The Organization of Behavior, John Wiley & Sons, 1949
- [3] Rosenblatt, F., The Perceptron : A Probabilistic Model for Information Storage and Organization in the Brain, Psychol. Rev., Vol. 65, pp. 386-408, 1958
- [4] Widrow, B., Generalization and Information Storage in Networks of ADALINE Neurons. Self-Organizing Systems, Spartan Books, 1962
- [5] Hopfield, J., Neural Networks and Physical Systems with Emergent Collective Computational Abilities, Proc. of National Academy of Scientists, Vol. 79, pp. 588, 1982
- [6] W. M. Jenkins , A neural network trained by genetic algorithm, Procs of the Advance in Computational structures Technology, pp. 77-84, 1996
- [7] D. J. Montana and L. Davis, Training feedforward neural networks using genetic algorithm, Procs of the IJCAI-89, pp 762-767, 1989
- [8] Z. Michalewicz, Genetic Algorithm + Data Structure = Evolution Programs, 2nd Edition, Springer-Verlag, 1992
- [9] M.norgard , O.ravn , N.K.poulsen and L.K.Hansen , Neural Networks for Modelling and Control of Dynamic System
- [10] Ljung. L , System Identification - Theory for the User. Prentice Hall, Upper Saddle Piver N.J., 2nd edition
- [11] Levenberg, K., A method for solution of certain nonlinear problem in least squares. Quart. Appl. Mathematics, 2, 164-168

- [12] Ljung, L. and sjoberg, J. A system identification perspective on neural net
- [13] He, X. and Asada, H. A new method for identifying orders of input-output models for nonlinear dynamical system In proc. of the American Control Conference, San Francisco. pp 2520-2523
- [14] 진강규, 유전알고리즘과 그 응용, 교우사, 2000
- [15] 오창석, 뉴로 컴퓨터, 내하 출판사