

---

# 신경망모델과 자기 동조 제어를 이용한 이산신호의 추적 성능 개선

최수열\*, 정연만\*\*, 최부귀\*\*\*

## Tracking Performance Improvement of Discrete Signal using Neural Networks and Self Tuning Controller

Choi-Soo Yeol\*, Jung-Yun Man\*\*, Choi-Boo Kwi\*

### 要 約

본 논문에서는 추적 성능 개선을 위해 기존의 신경망 제어기에 PID제어기를 직렬로 연결하여 시뮬레이션 결과를 고찰했다. 추적 성능을 평가하기 위해 신경망모델은 2계층으로 구성하고 Widrow-Hoff델타 규칙을 이용하여 예측 오차가 최소화되도록 정규적인 동특성을 학습하였다. 이 학습 결과, 기존의 신경망제어기의 경우보다 PID를 연결하였을 경우가 추적 성능이 다소 개선되었음을 확인했으며, 251샘플에서 추적할 플랜트 파라미터가 시변인 경우에도 빠른 속도로 수렴되는 결과를 얻었다.

### Abstract

In this paper, Simulation result was studied by PID controller in series to the estblised neural networks controller. Neural network model is composed of two layers to evaluate tracking performance improvement. The regular dynamics was also studied for the expected error to be minimized by using Widrow-Hoff delta rule. As a result of the study, We identified that tracking performance improvement was developed more in case of connecting PID than conventional neural network controller and that tracking plant parameter in 251 sample was approached rapidly in case of time varying

---

\* 서일전문대학 정보통신과 전임강사

\*\* 국립원주전문대학 전자통신과 조교수

\*\*\* 동아대학교 전자공학과 교수

접수일자: 1997년 12월 22일

I. 서론

오늘날 제어 이론의 발달과 더불어 마이크로프로세스가 대량 보급됨에 따라 제어 시스템의 최적 조정법[1]과 자동 동조법[2] 등이 연구되고 있으나, 여기에도 많은 문제점이 수반되고 있다. 대부분 제어 시스템은 여러 가지 기능을 가지고 있으며 특성이 복잡해지고 주위의 변화에도 민감한 특성을 갖고 있다. 이를 극복하기 위해 주위의 변화에 덜 민감하고 추적 성능이 빠른 제어 시스템 설계가 요구되고 있다. 이러한 부합된 연구를 위해 그 동안 많은 연구진들이 노력해 왔는데, 그 중 하나가 강인성 제어와 자기 동조 제어기라 할 수 있다. 강인성 제어는 시스템 파라미터 변화의 어떤 범위에 대해 선형 시스템을 안정화시키는 이득 제어기를 설계하는 것이고, 적응 제어는 미지 파라미터를 갖는 시스템에 원하는 출력을 얻기 위해 제어기의 특성을 조절하는 것이다[3]. 이들 제어기는 시스템의 파라미터 변화에 대해 어느 정도 대처 할 수 있는 장점이 있으나, 계산 시간이 많이 소요되며 경우에 따라서는 왜란에 의해 추적 성능이 저하되는 단점을 가지고 있다[4-5].

이러한 문제점을 해결하기 위해 신경망 제어 시스템의 이론적 배경을 토대로 한 연구가 활발히 진행되고 있다[6-11]. 1995년 Zhang[12] 등은 산업용 추적 시스템에 적합한 적응 신경 제어기를 온라인으로 학습하는 방법을 제안하였다.

본 논문에서는 Zhang 등이 제안한 온라인 학습 방법을 이산 시스템에 적용하여 추적 성능을 개선하고자 한다. 우선 이산 시스템에 적합한 2계층 신경 모델을 설정하여 플랜트의 출력과 신경망에 의해 예측한 출력의 차를 최소화 되도록 시스템의 정규적인 동특성을 학습하였다. 이 학습 방법은 Widrow-Hoff델타 규칙에 적용하여 2계층 신경망의 가중치를 조절하였으며 성능 지수를 최적화 시키는 제어 신호를 구하였다.

그리고 추적 성능을 개선하기 위해 산업 현장에 많이 사용하고 있는 PID(Proportional Integral Derivative) 제어기를 신경망과 직렬로 구성하여 성능을 분석하였으며, 추적할 플랜트의 파라미터가 시변인 경우에도 추적 성능이 개선됨을 확인하였다.

II. 플랜트의 신경망 모델 구성

1. 문제 정식화

선형 DARMA(Deterministic Autoregressive Moving-Average)모델의 전달 함수는 다음처럼 표현된다.

$$A(q^{-1})y(k) = B(q^{-1})u(k) \dots\dots\dots (1)$$

여기서  $A(q^{-1})$ 과  $B(q^{-1})$ 의 다항식은

$$\begin{aligned} A(q^{-1}) &= 1 + a_1q^{-1} + \dots + a_{na}q^{-na} \\ B(q^{-1}) &= b_1q^{-1} + \dots + b_{nb}q^{-nb} \end{aligned} \dots\dots\dots (2)$$

이며,  $q^{-1}$ 은 후향 연산자 ( $q^{-1}y(k) = y(k-1)$ ),  $u(k)$   $y(k)$ , 는 플랜트 입출력을 나타낸다. 여기서 플랜트는 기지의 다항식으로 가정된다. 다항식의 파라미터가 미지인 경우 입출력 시계 열의 자기회귀이동평균로 파라미터를 식별하는 방법과 신경망을 이용하여 학습하는 방법이 있다. 본 논문에서는 신경망 모델을 설정하여 동특성을 학습시키는 방법을 다음절에서 언급한다.

한편 플랜트 모델을 설정하기 위해 다음과 같은 세 가지 가정을 전제로 하고 있다.

- 가정 1: 차수의 상한선  $na, nb$ 는 기지이다.
- 가정 2:  $B(q^{-1})$ 는 안정한 다항식이다.
- 가정 3: 계수  $b_1 \neq 0$

이러한 가정은 자기 동조 제어 법칙[13]에서도 적용되지만, 가정 1은 본 논문에서는 신경망(추정자, 제어기)의 입력 노드수를 결정하는 데 필요하다. 즉 입력계층수를  $n, m(= na, nb)$ 으로 한다. 일반적으로 가정 2는 제어기에 대해 완전한 추적과 페루프 안정도를 얻기 위한 것이고, 가정 3은 제어기가 순차적으로 수행됨을 의미한다[14].

2. 플랜트 인식 모델

본 논문의 신경망모델은 문제 정식화에 의해서 기본 모델 선형 2계층으로 구성하였다. 앞에서 언급한 입력 계층을  $n+m$  개로 구성한 플랜트 인식 모델은 그림 1과 같다. 이러한  $n+m$  입력은 플랜트에서 이미 측정된 입·출력 신호이다. 그리고 신

경망의 출력 층은 한 개의 노드만 가지며 플랜트의 출력을 예측한다. 따라서 그림에 나타난 것처럼 신경망 추정 자는 플랜트의 출력을 정확하게 예측하도록 Widrow-Hoff 델타 규칙을 적용하여 플랜트 동특성을 학습시킨다.




그림 1. 플랜트 인식 모델  
Fig. 1. Recognition model of the plant

그림 1의 입력 신호는  $n+m$ 개의 망 입력 벡터로 다음과 같이 표현할 수 있다.

$$x(k) = [x_1(k), \dots, x_n(k), x_{n+1}(k), \dots, x_{n+m}(k)]^T \\ = [-y(k), \dots, -y(k-na+1), u(k), \dots, u(k-nb+1)]^T \quad (3)$$

각 노드에 주어진 가중치는 다음과 같이 가중치 벡터로 표현된다.

$$w(k) = [w_1(k), \dots, w_n(k), w_{n+1}(k), \dots, w_{n+m}(k)]^T \quad (4)$$

그리고 가중치는 Widrow-Hoff 규칙[14]를 이용하여 다음과 같이 갱신한다.

$$w(k+1) = w(k) + \frac{\alpha e(k+1)x(k)}{\beta + x^T(k)x(k)} \quad (5)$$

여기서  $\alpha$ 는 가중치의 학습률을 높이기 위한 감소 인자로서 보통 0~2의 값을 갖도록 해 준다. 그리고 두 번째 항의 분모 항에서  $x^T(k)x(k)=0$ 이 되면 가중치가 발산되므로 이를 피하기 위해 임의의 상수  $\beta$ 를 추가하였으며, 이 상수는 거의 영에 가까운 작은 값으로 선정한다.

이 그림에서 나타난 것처럼 오차 신호  $e(k)$ 는 플랜트 응답  $y(k)$ 와 신경 모델에 의해 예측된 응답

$y(k)$ 의 차로 나타내며, 이 값을 최소화하는 것으로 적응 알고리즘이라 한다.

따라서 신경망의 예측 출력은 다음과 같이 선형적으로 계산된다.

$$y(k) = \sum_{i=1}^{n+m} w_i(k-1)x_i(k-1) \quad (6)$$

플랜트의 동특성은 신경 추정 자의 결합 가중치에 좌우되며, 이러한 가중치를 이용하여 식 (6)처럼 플랜트 출력을 예측할 수 있다[15-16].

### III. 신경망제어기 구성

#### 1. 기존의 신경 제어기

위에서 언급한 플랜트 인식 모델은 플랜트 동특성을 학습하여 파라미터를 추정한다. 그 다음 학습된 가중치를 직접적으로 신경제어기의 연결 가중치를 조절하여 제어신호  $u(k)$ 를 발생되도록 한다. 따라서 이 제어 신호가 플랜트 입력에 가해 질 경우 플랜트 출력  $y(k)$ 는 기준 신호  $r(k)$ 에 추적됨을 의미한다.




그림 2. 신경 제어기  
Fig. 2. Neural Control

계산 속도를 개선하기 위해 앞에서 언급 한처럼 그림 2와 같이 2계층 신경망으로써  $n+m$ 개의 노드를 갖는 입력 층과 한 개의 출력 층으로 구성하였다.

여기서  $n+m$ 개 제어기의 입력 벡터는 다음과 같이 표현된다.

$$z(k) = [r(k+1), -x_1(k), -x_2(k), \dots, -x_n(k), x_{n+1}(k), \dots, x_{n+m}(k)]^T \quad (7)$$

여기서도 플랜트의 신경망 모델에 주어지는 결합

가중치 벡터는 다음과 같은 벡터 적으로 표현한다.

$$w'(k) = \frac{1}{w_{n+1}(k)} [1, w_1(k), w_2(k), \dots, w_n(k), w_{n+2}(k), \dots, w_{n+m}(k)]^T \dots (8)$$

여기서  $w'(k)$ 는 플랜트의 신경 모델에 가중치  $w_i(i=1, \dots, n+m)$ 를 조절하게 된다.

따라서 식 (8)~(9)을 신경 제어기에 적용하여 성능 지수가 최적화 되는 제어 법칙을 구한다. 따라서 이 그림에 나타난 것처럼  $u(k)$ 는 입력 벡터  $z(k)$ 와 새로운 가중치  $w'_i(k)$ 의 일차 결합으로써 제어 신호를 발생한다.

$$u(k) = \sum_{i=1}^{n+m} w'_i(k) z_i(k) \dots (9)$$

그러므로 전반적인 페루프 추적 제어 시스템은 그림 3으로 나타낸다.




그림 3. 자기 동조 제어 구조  
Fig. 3. Self-tuning control scheme

### 2. PID 신경 제어기

추적 성능을 개선하기 위해 그림 4와 같이 신경망제어기에 고전적인 PID제어기를 직렬 연결하였다. 이 때 플랜트의 동특성 학습은 II장에서 제시한 Widrow-Hoff델타 규칙으로 학습하였다.

이 때 제어기 이득을 적절하게 자동적으로 조절함으로써 추적 성능을 개선할 수 있다.

한편 PID신경망 제어기는 PID이득을 출력한 신경망과 이 이득을 사용한 제어 입력을 연산하는 노드로 구성한다.

그림 4에서 나타난 PID제어기는 종래의 PID이득

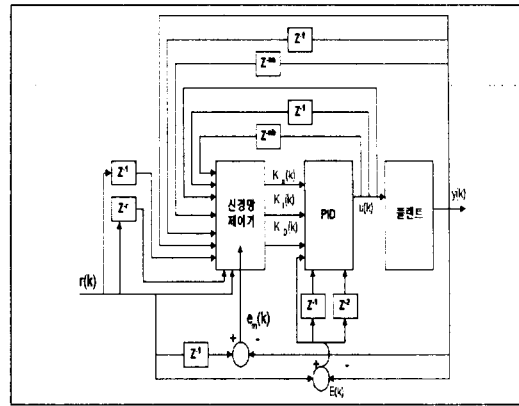


그림 4. 신경 제어기의 자기 동조PID  
Fig. 4. Self-tuning PID of neural controller

계산 식으로부터 다음과 같이 얻어진다.

$$u(k) = u(k-1) + (K_p(k) + K_I(k) + K_D(k)) E(k) - (K_p(k) + 2K_D(k)) E(k-1) + K_D(k) E(k-2) \dots (10)$$

단,  $K_p(k) = C_1 O_p(k)$ ,  $K_I(k) = C_1 O_i(k)$ ,

$K_D(k) = C_1 O_d(k)$ ,  $E(k) = r(k) - y(k)$ 이다.

여기서  $u(k)$ 는 제어 입력이고  $K_p(k)$ ,  $K_I(k)$ ,  $K_D(k)$ 는 비례, 적분, 미분의 이득,  $O_p(k)$ ,  $O_d(k)$ ,  $O_i(k)$ 는 각 이득의 신경망제어기 출력이다.  $C_1$ 은 각 이득을 조정하는 정수이고  $r(k)$ 는 기준 신호,  $y(k)$ 는 플랜트 출력이다[17-18].

그림 4의 신경망 제어기는 3계층으로 구성하였다. 그림에 나타난 것처럼  $n+m+r$  개의 노드를 갖는 입력층과 PID이득을 출력하는 3개의 노드를 갖는 출력층으로 구성한다.

신경망 제어기의 학습은 역전파법으로 행하고 평가 함수  $J$ 를 최소화하도록 한다.

$$J = e_m(k)^2 / 2 \dots (11)$$

여기서,  $e_m(k) = r(k) - y(k)$ 이다.

이와 같은 경우 신경망제어기의 가중치를 수정하는 데 사용하는 평가 함수  $J$ 를 다시 쓰면 다음과 같다.

$$\begin{aligned} \frac{\partial J}{\partial w_{ij}(k-1)} &= e_m(k) \times \frac{\partial e_m(k)}{\partial w_{ij}(k-1)} \\ &= -e_m(k) \frac{\partial y(k)}{\partial w_{ij}(k-1)} \end{aligned} \quad \dots\dots\dots (12)$$

여기서,  $w_{ij}(k-1)$ 은 시각  $k-1$ 에 대한  $j$ 번째 노드와  $i$ 번째 노드과의 결합 가중치를 나타낸다.

$$\frac{\partial y(k)}{\partial w_{ij}(k-1)} = \frac{\partial y(k)}{\partial u(k-1)} \times \frac{\partial u(k-1)}{\partial w_{ij}(k-1)} \quad \dots\dots (13)$$

식 (13)의 제 1항은 입출력의 비를 결정하고 차분 및 신경망모델의 역전파법에 의해 구해질 수 있다. 식 (13)의 제 2항은 다음 식처럼 구한다.

$$\frac{\partial u(k-1)}{\partial w_{ij}(k-1)} = \frac{\partial u(k-1)}{\partial K(k-1)} \times \frac{\partial K(k-1)}{\partial w_{ij}(k-1)} \quad \dots\dots (14)$$

여기서,  $K(k-1)$ 은 신경망 제어기의 출력이며  $K(k-1) = [K_p(k-1), K_i(k-1), K_d(k-1)]^T$ 가 된다. 식 (14)의 제 2항은

$$\begin{aligned} \frac{\partial K(k-1)}{\partial w_{ij}(k-1)} &= \left[ \frac{\partial K_p(k-1)}{\partial w_{ij}(k-1)}, \frac{\partial K_i(k-1)}{\partial w_{ij}(k-1)}, \right. \\ &\left. \frac{\partial K_d(k-1)}{\partial w_{ij}(k-1)} \right]^T \end{aligned} \quad \dots\dots\dots (15)$$

된다. 식(15)은 신경망제어기에 대해 역 전파법을 이용하여 쉽게 구할 수 있다.

식 (14)의 제 1항

$$\frac{\partial u(k-1)}{\partial K(k-1)} = [u_{a1}(k-1), u_{a2}(k-1), u_{a3}(k-1)]$$

다음 식을 사용하여 계산된다.

$$\begin{aligned} u_{a1}(k-1) &= \frac{\partial u(k-1)}{\partial K_p(k-1)} = E(k-1) - E(k-2) \\ u_{a2}(k-1) &= \frac{\partial u(k-1)}{\partial K_i(k-1)} = E(k-1) \\ u_{a3}(k-1) &= \frac{\partial u(k-1)}{\partial K_d(k-1)} = E(k-1) - 2E(k-2) \\ &+ E(k-3) \end{aligned} \quad \dots\dots\dots (16)$$

식 (10) ~ 식 (16)으로부터 평가 함수를 신경망제어기에 적용한 가중치는 다음과 같다.

$$\begin{aligned} \frac{\partial J}{\partial w_{ij}(k-1)} &= -[r(k-1) - y(k)] \frac{\partial y(k)}{\partial u(k-1)} \left[ \right. \\ &u_{a1}(k-1) \frac{\partial K_p(k-1)}{\partial w_{ij}(k-1)} + u_{a2}(k-1) \frac{\partial K_i(k-1)}{\partial w_{ij}(k-1)} + \\ &\left. u_{a3}(k-1) \frac{\partial K_d(k-1)}{\partial w_{ij}(k-1)} \right] \end{aligned} \quad \dots\dots\dots (17)$$

여기서,  $\frac{\partial J}{\partial w_{ij}(k-1)}$ 를 순차적으로 가중치를 갱신하고 그 식은 다음과 같다.

$$\begin{aligned} \Delta w_{ij}(k-1) &= -\epsilon \frac{\partial J}{\partial w_{ij}(k-1)} + \alpha \Delta w_{ij}(k-2) + \\ &\beta \Delta w_{ij}(k-3). \\ w_{ij}(k) &= w_{ij}(k-1) + \Delta w_{ij}(k-1) \end{aligned} \quad \dots\dots\dots (18)$$

여기서,  $\epsilon$ 은 역전파의 학습률 증가를 나타내며 보통 0.001~0.05값을 선정한다. 그리고 학습 시간을 단축하고 학습 성능을 개선하기 위한  $\alpha$ 는 모멘트 항으로서 보통 0.9~0.7값을 선정하고,  $\beta$ 는 진동감쇄로서 보통 -0.1로 사용한다.

따라서  $k$  순간에서 제어루프의 순차적인 동작은 다음과 같다.

- (a)  $r(k)$ 과  $y(k)$ 측정한다.
- (b) 과거 가중치  $w_{ij}(k-1)$ 을 이용하여 출력  $s(k)$ 를 예측을 계산하기 위해 플랜트의 신경 모델 사용한다.
- (c) 오차신호  $e(k) = y(k) - \hat{y}(k)$ 를 계산하고 새로운 가중치  $w_{ij}(k)$ 를 델타 규칙 적용
- (d) 식(8), 식(10)을 이용하여 신경 제어기 가중치  $w'_i(k), w_{ij}(k)$ 를 갱신한다.
- (e) 최적화 되는 제어 신호를 발생하기 위해 기존 신경 제어기와 PID신경 제어기를 사용한다.

#### IV. 시뮬레이션 결과 및 비교 검토

본 논문에서 제안한 적응 신경망 제어의 추적 성능 개선은 시뮬레이션을 통하여 입증한다.

1. 제어 대상 모델링

본 논문에서 제어 대상 모델링은 다음과 같이 불안정한 시스템으로 모델링한다.

$$y(k) = 0.55y(k-1) + 0.46y(k-2) + 0.07y(k-3) + 0.1u(k-1) + 0.02u(k-2) + 0.03u(k-3) + e(k)$$

본 연구의 시뮬레이션을 위해 플랜트 파라미터를 일정한 값으로 하였고 각 변수 및 크기 값을 다음과 같이 선정하였다.


- (1) 요구하는 기준 입력은 크기가 ±1인 계단 파형으로 선정하였다. 또한 신경 추정 자의 초기 가중치 벡터는  $w[0] = [0, 0, 0, 1, 0, 0]^T$ 로 하였다. PID신경망은 입력층의 노드 수가 6개, 은닉층의 노드수가 8개, 출력층의 노드의 수가 3개로 구성하였다. 그리고 가중치의 초기값은 학습시 사전정보이므로 여러번 시뮬레이션에 의해 수렴속도가 빠른 값 즉,  $i=j$ 일 때  $w_{ij} = -0.02$ 로,  $i \neq j$  경우  $w_{ij} = 0.01$ 로 선정하였다. 그 외의 모든 초기 값은 영으로 가정하였고, 신경망 추정 자의 델타 규칙 식 (5)에서  $\alpha = 1, \beta = 0.001$ 으로 선정하였다. 그리고 식 (18)에서  $\alpha = 0.9, \beta = -0.1, \epsilon = 0.04$ 로 하였다.
- (2) 시스템 잡음은 평균값이 영으로 하고 잡음 공분 산은 요구되는 출력의 ±1%범위 내로 가정하여 0.01로 하였다.

2. 비교 검토


그림 5(a)는 플랜트에 잡음을 가한 경우 시스템의 특성을 나타내며 이 그림에 나타난 것처럼 적응과도 후에는 시스템 출력이 요구되는 기준 신호에 매우 잘 추적됨을 알 수 있다.

그림 5(b)는 PID신경 적응 제어기를 이용한 시스템의 특성을 나타낸다. 여기서 그림 5(a)와 그림 5(b)를 고찰하면 그림 5(a)의 경우 첫 번째 스텝과도 현상이 10샘플까지 발생된다. 이러한 현상은 전 구간에서 조금씩 발생되는 데 비해 그림 5(b)의 경우는 6샘플까지 발생하였고, 그 이후 구간에는 현저하게 줄어짐을 알 수 있다. 따라서 그림 5(b)는

그림 5(a)보다 과도 시간이 크게 짧아지고 추적 현상이 개선됨을 알 수 있다.



(a) 기존의 신경망을 이용한 시스템 특성




(b) PID신경망을 이용한 시스템 특성


그림 5. 자기 동조의 시스템 출력

Fig. 5. System output of self-tuning control

그리고 그림 6(a), (b)는 시스템 파라미터가 251 샘플에서  $a_1=0.7, a_2=0.5, a_3=0.1$ 로 변화했을 때 시스템의 출력을 나타낸다.



(a) 기존신경망의 시스템 출력



(b) PID신경망의 시스템 출력

그림 6. 시스템파라미터가 시변인 경우

Fig 6. Time varying of system parameters

이 그림에서도 알 수 있듯이 PID신경 적응 제어가 훨씬 빠르게 추적됨을 알 수 있으며, (b)의 경우는 (a)보다 출력의 변화가 적응을 알 수 있다. 이것은 시스템 파라미터 값을 251샘플에서 변화시켰을 때 그림(a)보다 그림(b)가 전 구간에 걸쳐 제어 시스템에서 가장 중요하다고 사료되는 과도 현상이 현격히 줄어들고 파라메타가 변한 이후에도 추적 성능이 양호하게 나타나는 것은 제어 과정에서 파라메타에 대한 학습을 온라인 방식으로 3개층 PID 이득을 조절하였기 때문이다.

### V. 결론

본 연구에서는 기존의 신경망 제어기에 PID를 직렬 연결하여 시뮬레이션한 결과 추적 성능이 개선되었음을 확인했다.

Widrow-Hoff델타 규칙을 이용하여 미지의 동특성을 학습하고, 가중치를 이용하여 제어 신호를 온라인으로 발생시킨 결과 추적 오차를 줄일 수 있었다. 그리고 페루프 시스템은 전반적으로 안정하였으며 제어 성능도 개선되었음을 확인하였다.

이 알고리즘은 시스템 잡음이 존재하는 SISO (Single Input Single Output)통계학적 동특성을 제어하는 데 사용될 수 있다.

앞으로의 연구 과제는 미지의 기준 입력을 제어기에 포함하여 해석하고 모든 통계학적 조건을 사용할 수 있는 제어 알고리즘 개발에 있다.

### 참고문헌

[1] K.J. Astrom and B. Wittenmark, "On Self tuning regulators," *Automatica*, Vol. 9, pp. 185-199, 1973.  
 [2] P.J. Gawthrop, "Self tuning PID Controllers : algorithm and implementation," *IEEE Trans. Automat.*, Vol. ac-31, No.3, pp. 201-209, 1986.  
 [3] F.C.Chen, "Back-propagation Neural networks for nonlinear self tuning adaptive control," *IEEE Control Systems Magazine*, Vol.10,No.2,pp.44-48,1990.  
 [4] D. Psaltis and A.Sideris and A.A.Yamamura, "A multilayered neural network controller," *IEEE Control Systems Magazine*, Vol. 8, No. 2, pp.

17-21, 1988.  
 [5] L.Gordon Kraft and David P.Campagna, "A Comparison Between CMAC Neural Network Control and Two Traditional Adaptive Control Systems," *IEEE Control Systems Magazine*, Vol. 10, No.2, pp.36-43, 1990.  
 [6] D.H.Nguyen and B.Widrow, "Neural networks for self-learning control systems", *IEEE Control Systems Magazine*, Vol. 10, No. 3, pp. 18-23, 1990.  
 [7] K.J.Hunt and D.Sbarbaro, "Neural Networks for nonlinear internal model control," *IEE Proceeding-D*, Vol.138,No.5,pp.431-438,1991.  
 [8] Fu-Chuang Chen and Hassan K.Khalil, "Adaptive control of nonlinear systems using neural Networks," *INT.J.control*, Vol.55, No.6, pp.1299-1317, 1992.  
 [9] L.Jin and P.N.Nikiforuk and M.M.Gupta, "Direct adaptive output tracking control using multilayered neural network," *IEE proceeding-D*, Vol.140, No.6, pp.393-398, 1993.  
 [10] S.Bittanti and L.Piroddi, "GMV technique for nonlinear control with neural networks," *IEE proceeding\_d*, Vol.141, No.2, pp.57-69, 1994.  
 [11] L.Jin and P.N.Nikiforuk and M.M.Gupta, "Adaptive control of discrete-time nonlinear systems using recurrent neural networks," *IEE proceeding-D*, Vol.141, No.3, pp.169-176, 1994.  
 [12] Yao Zang and Pratyush Sen, and Grant E. Hearn, "An On-Line Trained Adaptive Neural Controller," *IEEE Control Systems Magazine*, Vol.10, No.4, pp.67-75, 1995.  
 [13] N.G.Goodwin and K.Sin, "Adaptive filtering prediction and control," Prentice-Hall, 1984.  
 [14] 정연만, "확률적 미지 기준 신호에 대한 자기동조 제어기의 추적성능 개선에 관한 연구", *숭실대학교 대학원 박사학위 논문*, pp. 8-11, 1991년 6월.  
 [15] B.Widrow and M.A. Lehr, "30years of adaptive neural networks:perceptron madaline and back-propagation," *Proc.IEEE*, Vol.

78, pp.1415-1442, 1990.

- [16] 임영도, 이상부, "퍼지 신경망·유전진화", 영과일, pp.127-133 1997년 1월.
- [17] 조원철, 전기준, "최소분산 자기동조 PID 제어기", 제어·자동화 시스템공학 논문지 제2권, 제1호, pp.14-15, 1996년 3월.
- [18] 추연규, "유전알고리즘을 이용한 퍼지-신경망 적응 제어기 설계에 관한 연구", 동아대학교 대학원 박사학위 논문, pp.22-29, 1996년 12월.



최 수 열(Choi-Soo Yeol)

1984년 한양대학교 전자공학과 졸업(공학사)  
1993년 연세대학교 전기공학과 졸업(공학석사)  
1995년~1998년 현재 동아대학교 대학원 전자공학과

박사과정 수료

1986년~1991년 쌍용양회공업(주) 기술부 근무  
1994년~1998년 현재 서일전문대학 정보통신과 전  
임강사

\* 주관심분야: 신경회로망, 퍼지, 적응및계측제어



정 연 만(Jung-Yun Man)

1983년 숭실대학교 전자공학과 졸업(공학사)  
1985년 숭실대학교 대학원 전자공학과 졸업(공학석사)  
1991년 숭실대학교 대학원 전자공학과 졸업(공학박사)

1993년~1998년 현재 국립원주전문대학 전자통신과 조교수

\* 주관심분야: 신경망회로, 퍼지, 적응제어, 로보틱스



최 부 귀(Choi-Boo Kwi)

1960년 연세대학교 전기공학과 졸업(공학사)  
1980년 경희대학교 대학원 전자공학과 졸업(공학석사)  
1970년~1998년 현재 동아대학교 전자공학과 교수

\* 주관심분야: 비선형제어, 로보틱스, 퍼지-신경회로망