

---

# 직교함수 신경회로망에 대한 연구

권성훈\*, 이현관\*, 엄기환\*

## The Study of Orthogonal Neural Network

Sung-hoon Kwon, Hyun-kwan Lee, Ki-hwan Eom

### 요 약

본 논문에서는 제어대상의 사전정보가 미지인 경우의 동정 및 제어를 위하여 직교함수 신경회로망을 제안한다. 제안하는 직교함수 신경회로망은 은닉층 앞에 버퍼층을 사용하고 은닉층에는 시그모이드 함수와 시그모이드 함수의 도함수로 유도한 RBF를 이용한 직교함수를 사용하였다. 제안한 방식의 유용성을 확인하기 위하여 Narendra 모델의 동정 시뮬레이션에 의해 동정능력을 검토하였다. 또한, 제어 시스템을 구성하고 시뮬레이션 및 실험을 통하여 유용성을 확인하였다.

### Abstract

In this paper we proposed the orthogonal neural network(ONN) to control and identify the unknown controlled system. The proposed ONN used the buffer layer in front of the hidden layer and the hidden layer used the sigmoid function and its derivative a derived RBF that is a derivative of the sigmoid function. In order to verify the property of the proposed, it is examined by simulation results of the Narendra model. Controlled system is composed of ONN and confirmed its usefulness through simulation and experimental results.

### I. 서 론

신경회로망은 인간의 뇌신경세포를 모방한 정보처리 모델로서, 비선형함수 구성기능, 범화능력에 의한 패턴분류, 지능제어 등 많은 분야에 응용

되고 있다.[1][2][3]

제어분야에서의 신경회로망 응용도 직접 역모델을 구성하여 조작량을 구하는 방법, 플랜트 동정을 하여 조작량을 구하는 방법 등 다양한 연구가 이루어져 왔다. 이러한 문제에 사용되는 신경회

---

\* 동국대학교 전자공학과

접수일자 : 1999년 12월 6일

로망은 입력층과 출력층 사이에 하나 이상의 은닉층을 갖고 있는 다층 신경회로망으로 비선형 사상(mapping)능력이나 학습능력이 우수하다고 볼 수 있다.[4][5][8]

다층 신경회로망의 은닉층 활성화함수(Active Function)로는 선형이나 비선형 함수로 주어진 문제에 따라 해결될 수 있도록 선택되어 진다. 일반적으로 역전파 알고리즘을 이용하여 훈련되는 다층 신경회로망의 활성화함수로는 미분이 가능한 시그모이드 함수(Sigmoid Function)가 널리 쓰이고 있지만, 가우스 함수 등의 Radial Basis Function(RBF)를 사용하는 경우도 많이 있다. 하지만, 순조롭고 연속적인 응답을 나타내는 포화함수인 시그모이드 함수와 입력에 대해 부분적으로 응답하는 RBF는 각각 적용대상이 다르다. 따라서, 시그모이드 함수와 RBF는 사상대상에 따라 알맞게 선택되어지고 있다. 그러나, 사상대상의 사전정보를 전혀 모르는 경우에는 시그모이드 함수나 RBF의 하나의 함수를 사용하는 것보다는 시그모이드 함수와 RBF를 혼성시켜 사용하는 것이 타당한 근사결과를 얻을 수 있다고 기대된다.[6][7]

제어시스템의 함수근사화 문제로서의 혼성방식은 시그모이드 함수와 RBF를 활성화함수로 한 범함수급수전개로 생각할 수 있지만, 단순히 함수를 공존시킨 경우에는 각 함수 사이의 관계가 반드시 분명한 것은 아니다. 그러므로 시그모이드 함수와 시그모이드 함수의 도함수에서 정의된 DRBF(Derives RBF)를 이용하여 구성한 혼성 네트워크는 직교하는 함수계를 기저함수로 하는 범함수 급수전개로 보는 것이 가능하다.[1]

본 논문에서는 시그모이드 함수와 시그모이드 함수의 도함수로 유도한 RBF의 직교관계에 차안하여 은닉층에 직교함수를 활성화함수로 갖는 신경회로망(Orthogonal Neural Network, ONN)을 제안한다. 제안한 방식의 유용성을 확인하기 위하여 비선형 시스템인 Narendra 모델의 동정 시뮬레이션에 의한 사상능력을, 시그모이드 함수를 사용한 신경회로망인 SNN(Sigmoid Neural Network), 시그모이드 함수의 도함수로 정의되는 DRBF를 사용한 신경회로망인 DRBFN(DRBF Network)과 비교·검토한다.

또한, DC 서보 모터 제어기에 각각의 네트워크를 적용하여 추종제어에 대한 시뮬레이션을 통해서 실제 제어기에 적용 가능한지를 확인한다. 마지막으로 시뮬레이션에서 사용한 조건들과 동일한 상태에서 ONN을 실험을 통해서 그 유용성을 확인한다.

## II. 일반적인 신경회로망 구조

신경회로망은 외부로부터 주어지는 정보에 따라서 뉴런 사이의 연결 강도와 바이어스를 조정하고, 외부의 정보를 신경회로망 내부에 반영한다.

일반적으로 사용되는 역전파 신경회로망은 선형 뉴런의 입력층과 출력층 사이에 하나 이상의 비선형 뉴런층으로 구성된 은닉층(hidden layer)을 갖는 다층구조(multi-layer)의 회로망으로 하나의 은닉층을 갖는 역전파 알고리즘의 다층 신경회로망 구조는 그림 2.1과 같다.

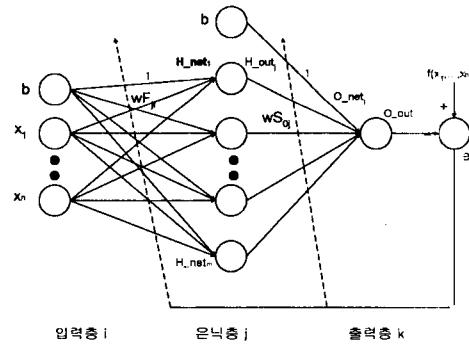


그림 2.1 역전파 알고리즘의 다층 신경회로망의 구조

Fig 2.1 Multi-layered neural network with back-propagation algorithm

입력층과 은닉층 사이의 연결강도를  $w_{ji}$ 라 하고 입력층의 입력값을  $u_i(k)$ 라 할 때, 은닉층의 각 뉴런에 대한 입력은 식(2.1)과 같고, 출력은 식(2.2)과 같다.

$$net_j(k) = \sum_{i=1}^L w_{ji}(k) u_i(k) \quad \dots \dots \dots (2.1)$$

$$x_i(k) = f(\text{net}_i) \quad \dots \dots \dots \quad (2.2)$$

- 은닉층 출력함수로는 시그모이드 함수와 가우스 함수 등이 주로 사용된다.

$$net_k(k) = \sum_{j=1}^M w_{kj}(k)x_j(k) \quad \dots \dots \dots \quad (2.3)$$

$$y_k(k) = f(\text{net}_k) \quad \dots \dots \dots \quad (2.4)$$

목표값을  $y_d$ 라 할 때, 목적함수는 식(2.5)와 같이 정의된다.

$$J = \frac{1}{2} [y_d - y_k]^2 \quad \dots \dots \dots \quad (2.5)$$

각 층의 연결강도는 목적함수  $J$  가 최소가 되도록 식(2.6)과 같이 조정된다.[1][2]

### III. 제안하는 신경회로망

은닉층 활성화함수로서 식(3.1)과 같은 시그모이드 함수를 갖고, 은닉층을 1개 갖는 구조의 다층 신경회로망(Sigmoid NN, SNN)을 생각한다.

$$f(x, a) = \frac{1.0 - \exp\left(-\frac{x}{a}\right)}{1.0 + \exp\left(-\frac{x}{a}\right)} \quad \dots \quad (3.1)$$

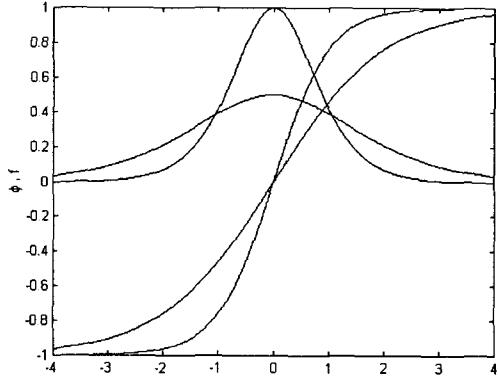
단,  $a$ 는 함수형상을 변화시키는 파라미터로 네트워크를 구성할 때에 이 파라미터  $a$ 를 개개의 은닉층 유니트에서 독립적으로 조정하는 것으로 사상특성을 개선할 수가 있다. 이 SNN으로의 입력벡터를  $I(k)$ , 입력층과 은닉층 사이의 가중치를  $W_s^{hi}$ , 은닉층과 출력층의 가중치를  $W_s^{oh}$ 로 하면 신경회로망의 출력  $u_s(k)$ 는 식(3.2)와 같다.

$$u_s(k) = \sum_j \left\{ W_{s_i}^{ph} f_j \left[ \sum_i W_{s_h}^{hi} I_i(k), a_j \right] \right\} \dots \dots \dots (3.2)$$

여기서,  $k$ 는 샘플링 상수이고, 입력벡터  $I(k)$ 에  
문턱값 1을 포함시키고 있다. 이 SNN에 유도연산  
자  $\frac{\partial}{\partial I(k)}$ 를 작용시켜 유도한 네트워크는 은닉층  
활성화함수에 다음 식으로 정의되는 시그모이드  
함수  $f$ 의 1차도함수가 사용된다.

$$\phi(x, a) = \frac{2.0 \exp\left(-\frac{x}{a}\right)}{a \left[1.0 + \exp\left(-\frac{x}{a}\right)\right]^2} \quad \dots \dots \dots (3.3)$$

식(3.1)과 식(3.3)의 파라미터  $a$ 를 변화시킨 경우  
의 함수의 형상은 그림 3.1과 같다.



### 그림 3.1 함수의 형상

Fig 3.1 Function shape

그림 3.1과 같이 함수  $\phi$ 는 가우스함수  $(g(x, b) = \exp\left[-\left(\frac{x}{b}\right)^2\right])$ 와 형상이 유사하므로 이 것을 은닉층 활성화함수로서 이용한 네트워크를 DRBFN이라고 한다. 이 DRBFN 출력  $u_r(k)$ 를 다음 식으로 정의한다.

$$u_r(k) = \sum_i \{ W_{r_i}^h \phi_j [ \sum_i W_{r_i}^{hi} I_i(k), a_j ] \} \quad \dots \dots \quad (3.4)$$

여기에서  $W_i^{hi}$ 는 입력층과 은닉층 사이의 가중치,  
 $W_i^{oh}$ 는 은닉층과 출력층 사이의 가중치이다.[2]

로 다른 함수를 혼성시킨 네트워크를 사용하는 것에 의해 타당한 사상특성이 얻어진다고 생각된다. 따라서, 여기에서는 시그모이드함수  $f$ 와 DRBF  $\phi$ 를 공존시킨 직교함수 신경회로망(Orthogonal NN, ONN)을 제안한다.

제안하는 ONN에 의한 함수의 사상은 직교하는 기저함수를 이용한 범함수급수전개의 일종이라고 생각할 수 있다. 그림 3.2는 제안한 ONN의 구성도이다.

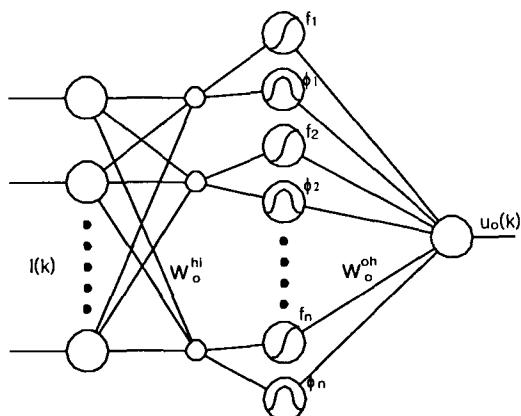


그림.3.2 직교 신경회로망의 구성  
Fig 3.2 Network architecture

그림 3.2와 같이 비선형처리를 하는 은닉층 앞에 버퍼층을 사용하여 시그모이드함수  $f_i$ 와 DRBF  $\phi_i$ 에 대한 입력을 동일한 값으로 하고,  $i$ 에 대해서 함수형상 파라미터  $a_i$ 도 동일한 값으로 하는 것으로 직교관계를 유지하도록 한다. 이 경우, ONN의 출력  $u_o(k)$ 는 다음 식과 같이 주어진다.

$$u_o(k) = \sum_i [W_o^{hi} f_i (\sum_i W_o^{hi} I_i(k), a_i) + W_o^{oh} \phi_i (\sum_i W_o^{hi} I_i(k), a_i)] \quad (3.5)$$

여기에서  $W_o^{hi}$ 는 입력층과 은닉층 사이의 가중치,  $W_o^{oh}$ 는 시그모이드함수 출력을 지닌 은닉층과 출력층 사이의 가중치,  $W_o^{oh\phi}$ 는 DRBF 출력을 지닌 은닉층과 출력층 사이의 가중치이다.

여기에서는 시그모이드 함수  $f$  와 DRBF  $\phi$ 를 공

존시킨 신경회로망(ONN)을 다음과 같이 정의한다.

[정의] 식(3.1)의 시그모이드 함수  $f$  와 식(3.3)의 DRBF  $\phi$ 는 직교한다.

[증명] 임의의 실수구간  $[-\alpha, \alpha]$ 에서 식(3.6)으로 정의되는 2개의 함수의 내적을 생각한다.

$$(f, \phi) \equiv \int_{-\alpha}^{\alpha} f(x, a) \phi(x, a) dx \quad (3.6)$$

위의 식에 식(3.1)과 식(3.3)을 대입하면,

$$\begin{aligned} (f, \phi) &= \int_{-\alpha}^{\alpha} (f, f') dx \\ &= [f^2(x, a)] \Big|_{-\alpha}^{\alpha} - (f, f') \end{aligned} \quad (3.7)$$

$$\therefore (f, f') = \frac{1}{2} [f^2(\alpha, a) - f^2(-\alpha, a)] = 0 \quad (3.8)$$

따라서, 시그모이드 함수  $f$  와 DRBF  $\phi$ 의 직교성을 나타낼 수 있다.

#### IV. 시뮬레이션

##### 4-1. Narendra 모델을 이용한 시스템 동정

ONN의 동정특성을 검토하기 위해서 그림 4.1의 순방향 동정기를 구성하여 시스템 동정 시뮬레이션을 하여 SNN, DRBFN과 비교 검토한다.

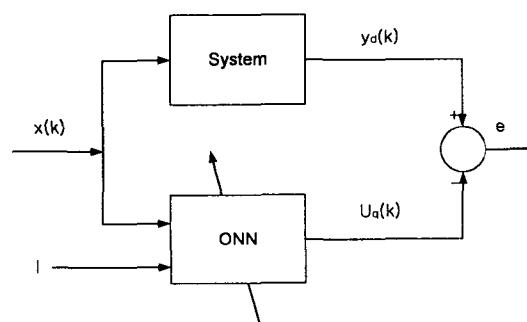


그림 4.1 순방향 함수동정기의 블록도  
Fig 4.1 Block diagram of direct function identifier

각 네트워크의 학습은 식(4.1)으로 정의되는 평가함수  $J(p)$ 를 최소화하기 위하여 일반화 델타규

칙에 의해 식(4.3)에 따라 각 시행마다 가중치  $\mathbf{W}_q^{hi}$ ,  $\mathbf{W}_q^{oh}$  ( $q = o, s, r$ )의 조정을 하는 학습형으로 한다.

$$J(p) = \frac{1}{2} \sum_{k=0}^p e^2(k) \quad \dots \dots \dots (4.1)$$

$$e(k) = y(k) - u_q(k) \quad \dots \dots \dots (4.2)$$

$$\mathbf{W}_q(p+1) = \mathbf{W}_q(p) - \eta_w \frac{\partial J(p)}{\partial \mathbf{W}_q(p)} \quad \dots \dots \dots (4.3)$$

여기에서  $p$ 는 시행횟수,  $\rho$ 는 1회시행당 총샘플링수,  $\eta_w$ 는 학습계수,  $y_d(k)$ 는 목표출력,  $u_q(k)$ 는 네트워크 출력 ( $q = o, s, r$ )이다. 또한, 함수형상 파라미터  $a$ 도 최급강하법에 따라 식(4.1)을 최소화하도록 개개의  $i$ 에 대해서 조정하여 함수의 최적형상을 탐색한다.[3][4]

$$a_i(p+1) = a_i(p) - \eta_a \frac{\partial J(p)}{\partial a_i(p)} \quad \dots \dots \dots (4.4)$$

여기에서  $\eta_a$ 는 학습계수이다. 파라미터  $a$ 의 초기값은 DRBF가 입력 0일 때에 출력 1인  $a=0.5$ 로 한다. 시뮬레이션에서는 1회시행당 총샘플링수를 100, 네트워크 구조는 입력층 2 ( $I^T(k) = [x(k) \ 1]$ ), 출력층 1이다. ONN에서 은닉층 유니트수를  $m$ 으로 했을 때, 네트워크의 가조절 파라미터수는  $5m$ 이 되며, SNN 및 DRBFN에서 은닉층 유니트수를  $n$ 으로 했을 때, 가조절 파라미터수는  $4n$ 이 된다. 따라서, 각 네트워크에서 가조절 파라미터수가 같아지도록 은닉층을 결정하기 위하여  $m=4$ ,  $n=5$ 로 한다.

비선형 네트워크의 학습과정에는 가중치의 초기값이 영향을 미치기 때문에, 서로 다른 네트워크의 학습을 비교하기 위해서는 이 초기값문제에 조건이 필요하다. 이를 위해 각 네트워크의 초기값을 다음과 같이 설정하여 네트워크 출력의 초기상태를 맞춘다.

- (1) ONN을 [-1.0 1.0]의 범위에서 랜덤하게 초기화하고, 입력  $x(k)$ 를 가한 경우의 SNN 출력  $u_{oinit}(k)$ 를 준비한다.
- (2) SNN(DRBFN)을 [-1.0 1.0]의 범위에서 랜덤하게 초기화하고, 입력  $x(k)$ 를 가해

$u_{oinit}(k)$ 를 교사신호로 하여 학습한다.

- (3) 학습수렴 후의 가중치를 SNN(DRBFN)의 초기값으로 하여 목표함수의 동정에 사용한다. ONN의 초기값은 (1)에서 사용한 가중치를 사용한다.

비선형 시스템의 동정을 위하여 Narendra의 4가지 모델 중 모델 III을 이용한다. Narendra 모델 III의 이산시간 차분모델은 식 (4.5)와 같으며, 그림 4.2와 같이 나타낼 수 있다.[5][6]

$$\begin{aligned} y(k+1) &= f[y(k), y(k-1), \dots, y(k-n+1)] \\ &+ g[x(k), x(k-1), \dots, x(k-m+1)] \end{aligned} \quad \dots \dots \dots (4.5)$$

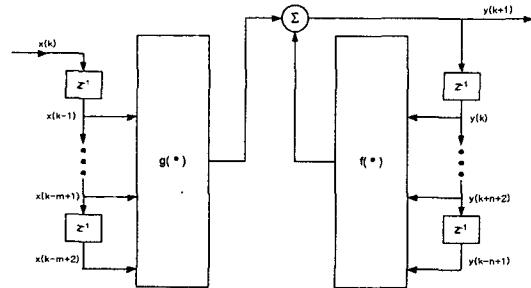


그림 4.2 Narendra 모델 III

Fig 4.2 Narendra Model III

동정하고자 하는 시스템은 식(4.6), 식(4.7), 식(4.8)과 같이 표현된다.

$$y(k+1) = f[y(k)] + g[x(k)] \quad \dots \dots \dots (4.6)$$

$$f[y(k)] = \frac{y(k)}{1 + y^2(k)} \quad \dots \dots \dots (4.7)$$

$$g[x(k)] = u^3(k) \quad \dots \dots \dots (4.8)$$

시스템을 동정하기 위한 모델은 식(4.9)와 같다.

$$u_q(k+1) = \hat{f}[y(k)] + \hat{g}[x(k)] \quad \dots \dots \dots (4.9)$$

입력신호는 식(4.10)과 같다.

$$x(k) = \sin\left(\frac{2\pi k}{25}\right) + \sin\left(\frac{2\pi k}{10}\right) \quad \dots \dots \dots (4.10)$$

ONN은  $\hat{f}[y(k)]$  와  $\hat{g}[x(k)]$  를 동정하기 위해 두 개로 구성된다.

먼저  $\hat{f}[y(k)]$  를 동정하기 위해서 입력층은 1개의 신호  $y(k)$  를 입력으로 받고, 은닉층의 뉴런수는 4개, 출력의 뉴런수는 1개이다.

$\hat{g}[x(k)]$  를 동정하기 위해서 입력층은 1개의 신호  $x(k)$  를 입력으로 받고, 은닉층의 뉴런수는 4개, 출력의 뉴런수는 1개이다.

그림 4.3은 ONN의 학습과정을 식(4.1)의 평가함수  $J$ 에 의해 나타낸 것으로 실선은 가중치의 학습과 함수형상의 탐색을 동시에 한 경우, 점선은 함수형상을 고정하고 가중치만을 학습한 경우이다. 어느 경우에서도 시행이 진행됨에 따라 평가함수  $J$ 는 감소하고 있다. 그림 4.3의 비교로부터 가중치의 학습과 함수형상의 탐색을 동시에 하는 것으로 평가함수를 작게 할 수 있다는 것을 알 수 있다.

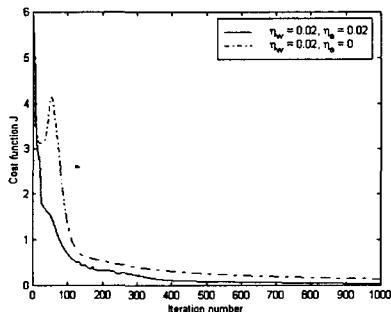


그림 4.3 직교 신경회로망에 의한 동정기의 학습 과정

Fig 4.3 Learning process of direct function identifier using ONN

그림 4.4는 ONN, SNN, DRBFN의 학습과정을 평가함수  $J$ 로 비교한 것으로, 모두 가중치와 함수형상의 탐색을 동시에 하고 있고, 각각의 학습률은  $\eta_w = 0.002$ ,  $\eta_a = 0.02$ 이다. 각 네트워크 모두 시행이 진행됨에 따라 학습은 수렴하고 있다. 그림 4.4에서는 DRBFN의 고속학습과 시그모이드함수 네트워크의 학습지연 특징이 잘 나타나 있고, ONN에 의한 학습속도는 그 중간정도인 것을 알 수 있다. 즉, 학습종료후( $\rho=1000$ )에서 평가함수값의 크기를

비교하면,  $J_{ONN} \approx J_{SNN} < J_{DRBFN}$  으로 되어있다. 따라서, 학습속도에서는 SNN에 대해서, 사상특성에서는 DRBFN에 대해서 ONN이 유리하다는 것을 알 수 있다.

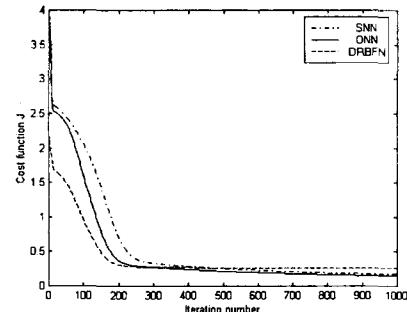


그림 4.4 각 네트워크에 의한 동정기의 학습과정  
Fig 4.4 Learning process of direct function identifier

그림 4.5는 ONN을 이용한 모델 III의 동정특성이다.

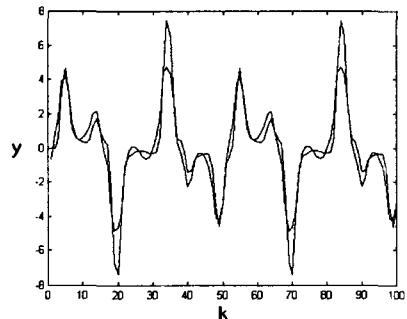


그림 4.5 직교신경회로망을 이용한 모델 III의 동정특성

Fig 4.5 Identification characteristics of model III using ONN

#### 4-2. 제어계에의 적용

제안한 ONN을 제어기로서 사용한 경우의 유효성과 SNN, DRBFN과의 제어성능을 비교·검토하기 위해서 구성한 전체 제어시스템은 그림 4.6과

같다.

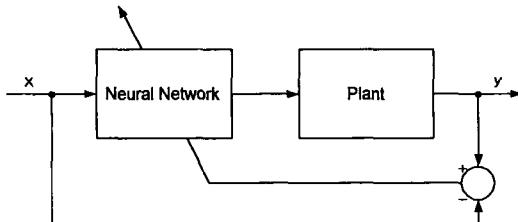


그림 4.6 신경회로망을 이용한 제어시스템  
Fig 4.6 Control system using neural network

제어 대상인 DC 서보 모터의 상태 방정식은 식 (4.11)과 같다.

$$\frac{T}{K_t} \dot{\theta}(t) + \frac{1}{K_t} \ddot{\theta}(t) = V \quad \dots\dots\dots (4.11)$$

여기서  $\theta$ ,  $\dot{\theta}$ ,  $\ddot{\theta}$ 는 각각 DC 서보 모터의 각변위, 각속도, 각가속도를 나타내고,  $V$ 는 DC 서보 모터의 입력전압을 나타내며 시스템의 상수  $T$ 와  $K_t$ 는 각각 다음과 같다.

$$T = \frac{JR}{K_b K_m + Rf} \quad \dots\dots\dots (4.12)$$

$$K_t = \frac{K_m}{K_b K_m + Rf} \quad \dots\dots\dots (4.13)$$

이다.

$J$ 는 관성모멘트로  $28 \times 10^6 [\text{kgm}^2]$ 이고,  $R$ 은 퀸선저항으로  $5.5 [\Omega]$ 이고,  $K_b$ 는 역 기전력으로  $67 \times 10^3 [\text{kgm} \cdot \text{rad}^{-1}]$ 이고,  $K_m$ 은 토크상수로  $68 \times 10^{-3} [\text{Vs}]$ 이고,  $f$ 는 마찰계수로  $10 \times 10^{-3} [\text{Nm}]$ 의 사양을 갖는다.[7][8] 5[msec] 스텝사이즈 간격으로 기존의 신경회로망(SNN, DRBFN)을 이용한 제어방식과 제안한 방식(ONN)을 시뮬레이션 하여 제어 성능을 비교 검토한다.

각각의 신경회로망은 SNN과 DRBFN의 경우는 입력층 뉴런수가 4개, 은닉층 뉴런수는 5개, 출력층 뉴런수는 1개이고, ONN의 경우는 입력층 뉴런수 4개, 은닉층 뉴런수는 4개, 출력층 뉴런수는 1개이다. 또한, 각각의 연결강도 초기값은 [-1.0,

1.0]의 랜덤값이고, 학습률은  $\eta_w = 0.002$ ,  $\eta_a = 0.002$ 로 설정한다.

기준궤적을 식 (4.14)으로 주고, 초기상태는 위치 0, 속도 0으로 하여 시뮬레이션을 수행한다.

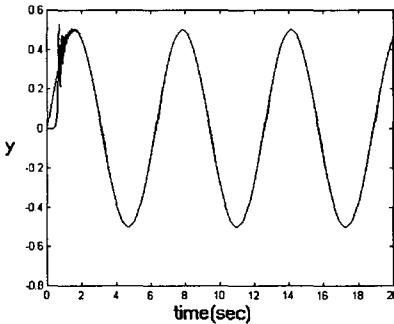


그림 4.7 SNN인 경우의 기준궤적과 추종곡선  
Fig 4.7 DC servo motor control using SNN

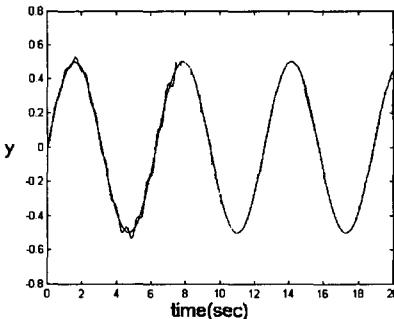


그림 4.8 DRBFN인 경우의 기준궤적과 추종곡선  
Fig 4.8 DC servo motor control using DRBFN

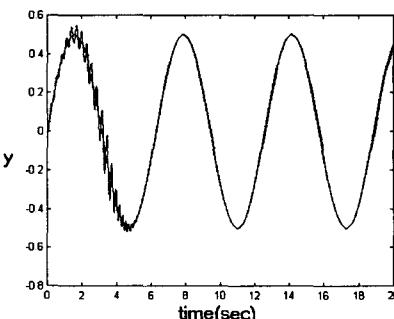


그림 4.9 ONN인 경우의 기준궤적과 추종곡선  
Fig 4.9 DC servo motor control using ONN

그림 4.7은 SNN, 그림 4.8은 DRBFN, 그림 4.9는 ONN의 시뮬레이션 결과이다.

제어시스템의 시뮬레이션 결과인 그림 4.7, 그림 4.8, 그림 4.9에서도 앞 절 4-1의 사상특성과 같이 SNN인 경우는 추종이 안정되는 속도가 늦지만 오차값이 가장 작게 수렴함을 알 수 있고, DRBFN인 경우는 초기의 추종은 빨리 이루어지지만 오차값이 줄어드는데 시간이 많이 걸림을 알 수 있다. ONN인 경우는 SNN과 DRBFN의 중간 정도의 추종능력을 나타냄을 확인했다.

## V. 실험 및 검토

제안하는 ONN을 DC 서보 모터 제어기에 적용한다.

DC 서보 모터에 대하여 제작한 실험장치 블록 선도는 그림 5.1과 같으며, 사양은 표 1과 같다.

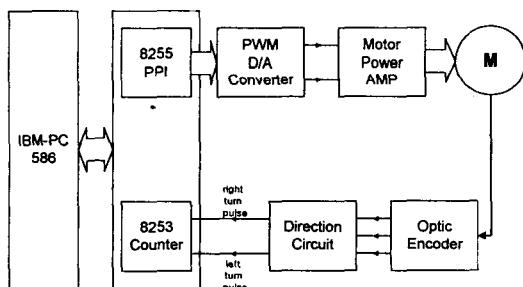


그림 5.1 실험 장치 블록 선도

Fig 5.1 Block diagram of experiment sets

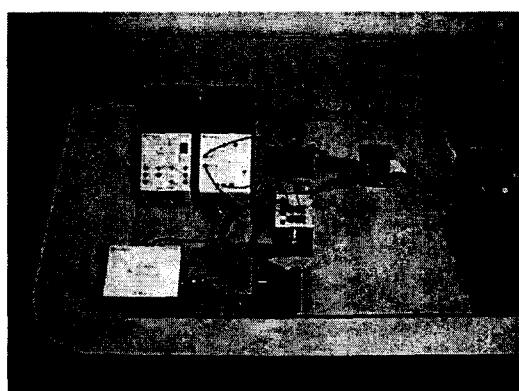
표 5.1 제작된 DC 서보 모터의 사양

Table 5.1 Specification of DC Servo Motor

Actuator inertia Ja	$28 \times 10^{-6}$ Kg m <sup>2</sup>
Back-emf constant of motor Kb	$67 \times 10^{-5}$ Kg m <sup>2</sup>
Torque constant of motor KI	$68 \times 10^{-5}$ V s rad-1
Motor static friction torque Bm	$10 \times 10^{-5}$ N m
Motor armature resistance Ra	5.5 Ohms
Motor armature inductance La	$7.2 \times 10^{-3}$ H
Servo Amp. current limit	2 A

그림 5.1에서 인터페이스 카드는 1개의 8255를 사용하여 8비트 병렬 입출력 포트가 최대 3개, 어드레스 디코딩에 변화를 줄 수 있도록 설계하였다. 전력 증폭기에서 모터 구동시 생길 수 있는 노이즈가 전체회로에 전달되는 것을 방지하고 D/A 변환기의 부하를 감소시키기 위하여 D/A 변환기와 전력 증폭기 회로는 포토커플러로 연결하였다.

이와 같은 실험장치를 제작하였으며 이에 대한 실험 장치도에 대한 사진은 그림 5.2와 같다.



### 그림 5.2 실험 장치

Fig 5.2 Experiment devices

제안한 제어 방식의 실험 조건을 시뮬레이션과  
같은 하여 실험한 결과는 그림 5.3, 그림 5.4와 같다.

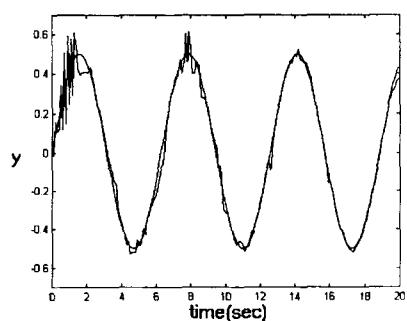


그림 5.6 기준궤적과 추종곡선

Fig 5.6 DC servo motor control using ONN

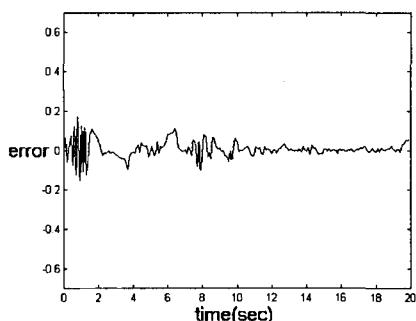


그림 5.4 오차곡선

Fig 5.4 DC servo motor control using ONN

그림과 같이 우수한 제어성능을 나타내고 있으므로 실제 제어계에 적용 가능함을 확인하였다.

## VI. 결 론

제어대상의 사전정보가 미지인 경우의 동정 및 제어를 위하여 은닉층에 직교함수를 사용하는 직교함수 신경회로망(ONN)을 제안하였다. 제안하는 직교함수 신경회로망은 은닉층 앞에 버퍼층을 사용하고 은닉층에는 시그모이드 함수와 시그모이드 함수의 도함수인 DRBF를 이용한 직교함수를 사용하였다. 제안하는 직교함수 신경회로망의 동정 및 제어특성에 대하여 SNN 및 DRBFN과 비교·검토한 결과는 다음과 같다.

- (1) Narendra 모델 III에 적용한 순방향 동정기의 함수동정 시뮬레이션에 의해 ONN에 의한 함수동정이 가능하고, 학습속도는 DRBFN, ONN, SNN순으로 됨을 확인하였고, 평가함수의 오차에 대해서는 SNN, ONN, DRBFN 순임을 확인하였다.
- (2) ONN을 이용한 제어시스템을 구성하고, DC 서보 모터에 대한 추종제어 시뮬레이션을 통해 제안하는 ONN 제어 시스템이 실현가능함을 확인하였다.
- (3) 추종제어 시뮬레이션에 의해 학습속도는 DRBFN이 우수하며, 오차에서는 SNN이 우수함을 확인하였다.
- (4) 시뮬레이션을 토대로 한 실제 DC 서보 모터

추종제어에서도 ONN을 활용한 결과, 실제 제어계에 적용 가능함을 확인하였다.

## 참고문헌

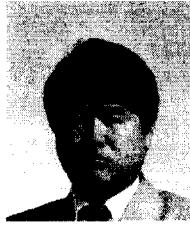
- [1] N. K. Bose, P. Liang, "Neural Network Fundamentals with Graphs, Algorithms, and Applications", McGraw-Hill, 1996.
- [2] Poggio. T., and Edelman. S., "A Network that Learns to Recognize Three-Dimensional Objects", Nature, Vol. 343, No. 18, 263-266, 1990.
- [3] J. G. Kuschewski, S. Hui, S. H. Zak, "Application of Feedforward Neural Networks to Dynamical System Identification and Control", IEEE Trans, Control System Technology, vol. 1, pp. 37-49, 1993. 5.
- [4] Takahashi. K, Yamada. T, "A Radial-Basis-Function-Network-Based Controller Derived from a Neural-Network-Based Controller and its Application to Controlling Mechanical Systems", JSME Int. J, 40-1, C, 42-51, 1997.
- [5] K. S. Narendra, K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks", IEEE Trans, Neural Network, vol. 1, No. 1, March 1990, pp. 4-27.
- [6] Chen. S, and Billings. S. A., "Neural Networks for Nonlinear Dynamics System Modeling and Identification", Int, J. of Control, Vol. 56, No. 2, 319-349, 1992.
- [7] Hagan, Demuth, Beale, "Neural Network Design", PWS Publishing Company, 1995.
- [8] K. J. Hunt, G. R. Irwin and K. Warwick, "Neural Network Engineering in Dynamic Control System", WILEY, 1995.

권 성 훈(Sung-hoon Kwon)

1998년 동국대학교 전자공학과 졸업  
2000년 동국대학교 전자공학과 석사  
2000~현재 동국대학교 전자공학과 박사  
\*관심분야 - 인공지능, 자동제어, 컴퓨터 네트워크

이 현 관(Hyun-kwan Lee)

1991년 Indiana Univ, 전자공학과 졸업  
1992년 Indiana Univ, 전자공학과 석사  
현재 동국대학교 전자공학과 박사  
\*관심분야 : 자동제어, 인공지능, 무선통신



엄 기 환(Ki-Hwan Eom)

1972년 2월 동국대학교 전자공학과(공학사)  
1986년 2월 동국대학교 전자공학과(공학박사)  
1978년 3월 ~ 1994년 유한대학  
전기공학과 교수  
1994년 3월 ~ 1999년 현재 동국대학교 전자공학과  
교수  
\* 관심분야 : 인공지능 및 자동화 시스템 설계