

수정된 직교 신경망을 이용한 비선형 시스템 제어기 설계

김 성 식*, 이 영 석**, 서 보 혁*

* 경북대학교 전기공학과

** 영진전문대 전기과

Design of Controller for Nonlinear System Using Modified Orthogonal Neural Network

Sung-Sik Kim*, Young-Seog Lee**, Bo-Hyeok Seo*

* Department of Electrical Engineering, Kyungpook National University

** Department of Electrical Engineering, Yeungjin College

Abstract - This paper presents an modified orthogonal neural network(MONN) based on orthogonal functions and applies the network to nonlinear system control. The accuracy of orthogonal neural network is essentially dependent on the choice of basic orthogonal functions. Modified orthogonal neural network is modified model of orthogonal neural network with input transformation to adapt its basic orthogonal functions. The results show that the modified orthogonal neural network has the excellent performance of approximating and controlling nonlinear systems and the input transformation make the ability of modified orthogoneural neural network better than one of orthogonal neural network.

$$\lim_{n \rightarrow \infty} \int_a^b (f(x) - F(x))^2 dx = 0 \quad (2)$$

$$\int_a^b \phi_i(x) \phi_j(x) dx = \begin{cases} 0 & i \neq j \\ A_i & i = j \end{cases} \quad (3)$$

$$w_i = \frac{1}{A_i} \int_a^b f(x) \phi_i(x) dx, \quad i = 1, 2, 3, \dots \quad (4)$$

2.2 기존의 직교 신경망의 구조

그림 1은 Yang과 Tseng이 제안한 m 개의 입력층, N 개의 중간층, 그리고 1개의 출력층으로 구성된 직교 함수를 이용한 직교 신경망[1]을 보인 것으로 이를 수식으로 나타내면 식 (5)와 같다.

$$y = \sum_{i=1}^N w_i \phi_i(X) = W^T \Phi(X) \quad (5)$$




그림 1. Yang과 Tseng이 제안한 직교 신경망.
Fig. 1. ONN proposed by Yang and Tseng.

각 입력 변수에 대해 n 차의 직교 함수로 신경망을 구성한 경우 중간층의 수 N 은 식 (6)과 같다.

$$N = n^m \quad (6)$$

이러한 직교 신경망은 요구되는 정확성을 기준으로 직교 함수의 급수를 증가시키므로써 직교 신경망의 구조를 결정할 수 있다. 또한, 중간층과 출력층 사이에만 가중치가 존재하기 때문에 목적 함수를 식 (7)과 같이 설정하였을 때, 학습 알고리즘이 식 (8)과 같이 간단하며 수렴 속도도 빠르다.

$$J = \frac{1}{2} e^2 \quad (7)$$

$$\Delta W = \eta \frac{\partial J}{\partial W} = \eta e \frac{\partial e}{\partial W} = \eta e \Phi(X) \quad (8)$$

그러나 기존의 직교 신경망은 구조의 골격이 되는 직교 함수를 변형할 수 없는 구조를 가진다. 따라서 직교 신경망이 우수한 성능을 나타내게 하기 위해서는 설계자가 주어진 시스템에 적당한 직교 함수를 설정해 주어야 한다.

I. 서 론

최근 Yang과 Tseng이 제안한 직교 신경망(ONN)[1]은 직교 함수를 이용하여 신경망을 구성한 것으로서, 다층 신경망이 가지는 층의 구조에 대한 어려움 없이 전체 구조를 결정할 수 있다는 장점이 있다. 또한 요구되는 정확성을 기준으로 직교 함수의 급수를 증가시키므로써 학습하는 동안에 전체 구조를 변형하는 것이 가능하고 가중치의 학습 알고리즘이 오차 역전파법 학습 알고리즘에 비해 간단하며 수렴 속도가 빠르다는 장점이 있다. 그러나 이러한 직교 신경망은 구조의 골격이 되는 직교 함수를 변형할 수 없는 구조를 가진다는 문제점이 있다.

본 논문에서는 입력 변환을 이용하여 직교 함수를 변형할 수 있는 새로운 알고리즘과 입력 변환의 조건을 제시한다. 그리고 입력 변환을 이용하여 직교 함수를 학습할 수 있는 구조를 가지는 수정된 직교 신경망(MONN)을 제안하고 수정된 직교 신경망을 이용하여 비선형 시스템을 제어하기 위해 식별기, 제어기, 그리고 기준 모델로 구성된 제어 구조를 설정하고 제어 목적을 달성하기 위한 수정된 직교 신경망의 학습 알고리즘을 유도한다. 사례연구를 통하여, 본 논문에서 제안한 수정된 직교 신경망의 비선형 시스템 모형화 능력, 제어능력, 그리고 입력 변환의 유용성을 다층 신경망, 직교 신경망과 비교하여 검증한다.

II. 기존의 직교 신경망

2.1 직교 함수

임의의 함수 $f(x)$, $f: [a, b] \rightarrow R$ 에 대해서 식 (1), (2), (3)을 만족하는 $F(x)$ 가 존재한다.

$$F(x) = w_1 \phi_1(x) + w_2 \phi_2(x) + \dots + w_n \phi_n(x) \quad (1)$$

III. 수정된 직교 신경망

3.1 직교 함수의 변형

정리 1.

$\phi_i(x)$ 가 구간 $[a, b]$ 에서 서로 직교인 함수일때, 연속함수 $T(\theta)$, $T: [a, \beta] \rightarrow [a, b]$ 가 구간 $[a, \beta]$ 에서 미분가능하고 $\frac{dT(\theta)}{d\theta} > 0$ 을 만족하면, $\sqrt{\frac{dT(\theta)}{d\theta}} \phi_i(T(\theta))$ 또한 구간 $[a, \beta]$ 에서 서로 직교인 함수이다.

3.2 수정된 직교 신경망의 구조




그림 2. 수정된 직교 신경망.

Fig. 2. Modified orthogonal neural network.

본 논문에서 제안하는 수정된 직교 신경망의 구조는 그림 2와 같이 5개의 층으로 되어있다. 입력층 I는 m 개의 뉴런으로 되어있으며, 중간층 J에서는 입력 변환 $T_i(x_i)$ 를 행하고 그 미분 $T'_i(x_i)$ 을 구한다. 그리고 중간층 K에서는 입력 변환된 값과 그 미분값으로부터, 미분값을 모두 곱한 값의 제곱근 ρ 와 직교 함수 $\phi_k(X_T)$ 의 출력을 구하고, 중간층 L은 ρ 와 $\phi_k(X_T)$ 의 출력을 곱하여 변형된 직교 함수의 출력을 구한다. 그리고 출력층 O는 변형된 직교 함수에 가중치를 곱한 값을 모두 더하여 전체 출력을 구한다. 이를 수식으로 나타내면 식 (9)와 같다.

$$y = W^T \Psi(X_T) \prod_{i=1}^m \sqrt{T'_i(x_i)} = \rho W^T \Psi(X_T) \quad (9)$$

여기서,

$$\Psi(X_T) = [\phi_1(X_T) \ \phi_2(X_T) \ \dots \ \phi_M(X_T)]^T$$

$$x_{Ti} = T_i(x_i)$$

이다.

N 은 전체 직교 함수의 개수로서 식 (10)과 같다.

$$N = n^m \quad (10)$$

여기서, m 은 입력 변수의 수, n 은 각 변수에 대한 단일변수 직교 함수의 차수를 각각 나타낸다.

본 논문에서는 식 (11)과 같은 단일 변수 레전드레 다항함수 [1-3]의 곱으로된 다변수 함수를 기본적인 직교 함수 $\phi_k(X_T)$ 로 사용하며, 레전드레 다항함수의 도함수는 식 (12)와 같다.

$$L_1(x) = 1, \quad L_2(x) = x$$

$$L_{i+1}(x) = a_i x L_i(x) - b_i L_{i-1}(x) \quad (11)$$

$$l_1(x) = 0, \quad l_2(x) = 1$$

$$l_{i+1}(x) = a_i (L_i(x) + x l_i(x)) - b_i l_{i-1}(x) \quad (12)$$

$$a_i = 2 - 1/i, \quad b_i = 1 - 1/i$$

$$-1 \leq x \leq 1 \quad (13)$$

여기서, L_i 는 레전드레 다항함수, l_i 는 그 도함수를 나타내고 식 (13)은 레전드레 다항함수가 직교성을 가지는 입력 범위를 나타낸다.

본 논문에서는 x_i 에 대한 입력 변환 함수를 식 (14)와 같이 간단한 3차 다항함수로 설정한다.

$$T_i(x_i) = \alpha_i x_i^3 + \beta_i x_i \quad (14)$$

여기서,

$$x_{is} = \frac{x_i - x_{i,\min}}{D_i/2}$$

$$D_i = x_{i,\max} - x_{i,\min}$$

$$x_{i,\min} = \frac{x_{i,\max} + x_{i,\min}}{2}$$

이다.




그림 3. 레전드레 다항함수.

Fig. 3. Legendre polynomials.

IV. 제어 시스템의 구성과 학습

본 논문에서 설정한 제어 시스템은 그림 4와 같이 기준 모델과 수정된 직교 신경망으로 된 식별기와 제어기로 구성된다.

4.1 식별기의 학습

플랜트의 동특성을 모형화하기 위한 목적 함수는 식 (16)과 같다.

$$e(k+1) = y'(k+1) - \hat{y}'(k+1) \quad (15)$$

$$J_1 = \frac{1}{2} \sum_{k=1}^N e(k+1)^2 \quad (16)$$

여기서 $y'(k)$ 는 플랜트의 출력, $\hat{y}'(k)$ 은 식별기의 출력, $e'(k)$ 는 플랜트와 식별기의 출력 오차를 각각 나타낸다.

식별기를 최적화하기 위한 가중치 $W_i = [w_1 \ w_2 \ \dots \ w_m]^T$ 의 증분량 ΔW_i 는 식 (17)과 같이 구한다.

$$\Delta W_i = \eta_w \left(-\frac{\partial J_1}{\partial W_i} \right)$$

$$= \eta_w \sum_{k=1}^N e'(k+1) \rho'(k) \Psi(X'_T(k)) \quad (17)$$

여기서,

$$\Psi(X'_T(k)) = [\phi_1(X'_T(k)) \ \phi_2(X'_T(k)) \ \dots \ \phi_m(X'_T(k))]^T$$

$$\rho'(k) = \prod_{i=1}^m \sqrt{T'_i(x'_i(k))}$$

이며, η_w 는 학습률로서 양의 작은 값이다.

식 (18), (19)는 식별기의 입력 변환 계수인 α_n 와 β_n 에 대한 목적 함수의 변화율을 구한 것이다.

$$\frac{\partial J_1}{\partial \alpha_n} = \sum_{k=1}^N \frac{\partial J_1}{\partial e'_i(k+1)} \frac{\partial e'_i(k)}{\partial \alpha_n} \quad (18)$$

$$\frac{\partial J_1}{\partial \beta_n} = \sum_{k=1}^N \frac{\partial J_1}{\partial e'_i(k+1)} \frac{\partial e'_i(k+1)}{\partial \beta_n} \quad (19)$$

또한, α_n 와 β_n 의 증분량 $\Delta \alpha_n$ 와 $\Delta \beta_n$ 는 식 (20)을 만족하여야 하며 식 (18)과 (19)로부터 식 (21), (22)와 같이 구할 수 있다.




그림 4. 수정된 직교 신경망으로 구성된 제어 시스템의 블록선도.
Fig. 4. Block diagram of control system using MONN

$$\Delta a_n + \Delta \beta_n = 0 \quad (20)$$

$$\Delta a_n = -\frac{\eta_T}{2} \left(\frac{\partial J_c}{\partial a_n} - \frac{\partial J_c}{\partial \beta_n} \right) \quad (21)$$

$$\Delta \beta_n = -\Delta a_n \quad (22)$$

여기서, η_T 는 a_n 와 β_n 의 학습률로서 양의 작은 값이다.

4.2 제어기의 학습

제어기의 학습은 전체 제어 시스템이 식 (23)과 같은 이산시간 선형 시스템의 입출력 특성을 담도록, 식별기로부터 시스템의 정보를 받아서 식 (25)로 정의한 목적 함수를 최소화 하는 것이다.

$$y_i'(k+1) = b_m y_i'(k) + b_{m-1} y_i'(k-1) + \dots + b_0 y_i'(k-m) + a_m y_i'(k) + a_{m-1} y_i'(k-1) + \dots + a_0 y_i'(k-m) \quad (23)$$

$$e_i'(k+1) = y_i'(k+1) - \hat{y}_i'(k+1) \quad (24)$$

$$J_c = \frac{1}{2} \sum_{k=1}^N e_i'(k+1)^2 \quad (25)$$

여기서 $y_i'(k+1)$ 은 기준 모델의 출력이고 $e_i'(k+1)$ 는 기준 모델 출력과 플랜트 출력의 오차이다. 제어기 학습에 필요한 가중치 W_c 의 증분량 ΔW_c 는 식 (26)으로부터 식 (27)과 같이 구할 수 있으며 미지의 플랜트이므로 식별기로부터 그 추정치 $\frac{\partial \hat{y}_i'(k+1)}{\partial u'(k)}$ 을 받아서 식 (28)과 같이 구한 근사값 \hat{W}_c 를 이용한다.

$$\frac{\partial J_c}{\partial W_c} = -\sum_{k=1}^N e_i'(k+1) \frac{\partial \hat{y}_i'(k+1)}{\partial u'(k)} \rho_i'(k) \Psi_c(X_T'(k)) \quad (26)$$

여기서,

$$\Psi_c(X_T'(k)) = [\phi_{c1}(X_T'(k)) \quad \phi_{c2}(X_T'(k)) \quad \dots \quad \phi_{cn}(X_T'(k))]^T$$

$$\rho_i'(k) = \prod_{i=1}^m \sqrt{T_{c_i}(x_i'(k))}$$

$$\Delta W_c = \eta_w \left(-\frac{\partial J_c}{\partial W_c} \right) \quad (27)$$

$$= \eta_w \sum_{k=1}^N e_i'(k+1) \frac{\partial \hat{y}_i'(k+1)}{\partial u'(k)} \rho_i'(k) \Psi_c(X_T'(k))$$

$$\Delta \hat{W}_c = \eta_w \sum_{k=1}^N e_i'(k+1) \frac{\partial \hat{y}_i'(k+1)}{\partial u'(k)} \hat{\rho}_i'(k) \Psi_c(X_T'(k)) \quad (28)$$

여기서, η_w 는 학습률로서 양의 작은 값이다. 그리고, 학습에 필요한 $\frac{\partial \hat{y}_i'(k+1)}{\partial u'(k)}$ 는 식별기로부터, $x_i'(k) = u(k)$ 라 하면 식 (29)와 같이 구할 수 있다.

$$\frac{\partial \hat{y}_i'(k+1)}{\partial x_i'(k)} = \frac{\partial}{\partial x_i'(k)} (\rho_i'(k) W_c^T \Psi_c(X_T'(k))) \quad (29)$$

식 (30), (31)은 제어기의 입력 변환 계수인 α_n 와 β_n 에 대한 목적 함수의 변화율을 구한 것이다.

$$\frac{\partial J_c}{\partial \alpha_n} = \sum_{k=1}^N \frac{\partial J_c}{\partial e_i'(k+1)} \frac{\partial e_i'(k)}{\partial \alpha_n} \quad (30)$$

$$\frac{\partial J_c}{\partial \beta_n} = \sum_{k=1}^N \frac{\partial J_c}{\partial e_i'(k+1)} \frac{\partial e_i'(k)}{\partial \beta_n} \quad (31)$$

α_n 와 β_n 의 증분량 $\Delta \alpha_n$ 와 $\Delta \beta_n$ 는 식 (32)를 만족하여야 하며 식 (30)과 (31)로부터 식 (33), (34)와 같이 구할 수 있다.

$$\Delta \alpha_n + \Delta \beta_n = 0 \quad (32)$$

$$\Delta \alpha_n = -\frac{\eta_T}{2} \left(\frac{\partial J_c}{\partial \alpha_n} - \frac{\partial J_c}{\partial \beta_n} \right) \quad (33)$$

$$\Delta \beta_n = -\Delta \alpha_n \quad (34)$$

학습에 필요한 플랜트의 입력에 대한 출력의 변화율 $\frac{\partial \hat{y}_i'(k+1)}{\partial u'(k)}$ 을 모르기 때문에 식별기로부터 그 추정치 $\frac{\partial \hat{y}_i'(k+1)}{\partial u'(k)}$ 을 받아서 입력 변환 계수의 증분량의 추정치 $\Delta \hat{\alpha}_n$ 와 $\Delta \hat{\beta}_n$ 를 식 (35), (36)과 같이 구하여 제어기의 학습에 이용한다.

$$\Delta \hat{\alpha}_n = \frac{\eta_T}{2} \sum_{k=1}^N e_i'(k+1) \frac{\partial \hat{y}_i'(k+1)}{\partial u'(k)} \left(\rho_i'(k) \sum_{n=1}^N \dots \sum_{n=1}^N w_{c_n} \dots \right) + \prod_{i=1}^m \phi_{w_{c_i}}(x_{T_i}'(k)) \frac{\partial \phi_{c_n}(x_{T_i}'(k))}{\partial x_{T_i}'(k)} [x_{T_i}'(k)^3 - x_i'(k)] + \frac{3x_i'(k)^2 - 1}{3\alpha_n x_{T_i}'(k)^2 + \beta_n} \rho_i'(k) W_c^T \Psi_c(X_T'(k)) \quad (35)$$

$$\Delta \hat{\beta}_n = -\Delta \hat{\alpha}_n \quad (36)$$

V. 사례연구와 검토

제안한 제어 알고리즘을 식 (37)로 표현되는 독립진자 균형문제 [6]에 적용한 사례연구를 통하여 제어 성능을 입증하였다.

$$\begin{cases} (M+m)\ddot{x} + mL\cos\theta\ddot{\theta} - mL\sin\theta\dot{\theta}^2 - u = 0 \\ m\cos\theta\ddot{x} + mL\ddot{\theta} - mg\sin\theta = 0 \end{cases} \quad (37)$$

여기서 M은 수레의 질량, m은 진자의 질량, L은 진자의 길이, x는 수레의 위치, θ 는 진자의 기울어진 각도, u는 플랜트의 입력을 각각 나타낸다.




그림 5. 독립진자 시스템.

Fig. 5. Inverted pendulum system.

식별기는 과거의 입출력 값을 입력으로하고, 각 입력에 대하여 최고 함수는 3차까지로 구성하여 독립진자 시스템을 이산 시간 시스템으로 모형화 하였다. 독립진자 시스템의 과거 운행 자료로부터 매회 난수적으로 40쌍의 학습 자료를 추출하여 식별기를 학습하였으며, 식별기 학습에 필요한 플랜트의 출력은 4차 Runge-Kutta 방법을 사용하여 얻었고 샘플링 시간은 0.1초로 하였다.

제어기는 시스템의 입출력값을 입력으로하여 각 입력에 대하여 최고 함수를 3차까지로 구성하였다. 그리고 기준 모델은 식 (38)와 같이 설정 하였으며, 매회 난수적으로 5쌍의 시작점과 목표점을 설정하여 제어기를 학습하였다.

$$y_i(k+1) = 1.4783y_i(k) - 0.5463y_i(k-1) + 0.0170r(k) - 0.0340r(k-1) + 0.0170r(k-2) \quad (38)$$

표 1은 여러 방식으로 학습한 식별기의 오차제곱평균(MSE)을 비교한 것이다. 그리고 표 2는 수정된 최고 신경망의 입력 변환 계수를 나타낸 것이다.

그림 6은 임의의 정현파 입력에 대한 플랜트의 출력과 식별기의 출력을 보인 것이다. 그림 7은 기존의 최고 신경망을 이용한 식별기와 제안한 수정된 최고 신경망을 이용한 식별기의 오차 제곱 평균의 변화를 비교한 것이다.

표 1과 그림 6은 제안한 수정된 최고 신경망의 비선형 시스템 모형화 능력이 기존의 다층 신경망과 최고 신경망에 비해 더 우수하다는 것을 입증한다.

표 3은 기존의 최고 신경망에 의한 제어결과와 제안한 방식의 제어 결과를 오차 제곱 평균(MSE)을 비교한 것이다. 그리고 표 4는 제어기로 사용한 수정된 최고 신경망의 입력 변환 계수를 나타낸 것이다

그림 8은 기존의 최고 신경망방식과 제안한 입력 변환을 갖는 수정된 최고 신경망으로 학습한 제어기로 제어한 플랜트 출력을 보인 것이다. 그림 9는 기존의 최고 신경망을 이용한 제어기와 제안한 수정된 최고 신경망을 이용한 제어기의 오차 제곱 평균을 비교한 것으로서 수정된 최고 신경망이 보다 안정된 학습을 보인다.

표 3과 그림 8은 제안한 수정된 직교 신경망의 비선형 시스템 제어기로서의 능력이 기존의 직교 신경망에 비해 더 우수하다는 것을 입증한다.

표 1. 식별기의 구조와 오차 제곱 평균

	구조 (가중치수)	오차 제곱 평균
다층 신경망	6-50-50-1 (2850)	2.30978×10^{-3}
기존의 직교 신경망	5-243-1 (243)	1.82580×10^{-4}
수정된 직교 신경망	5-10-244-243-1 (253)	1.04469×10^{-5}

표 2. 수정된 직교 신경망을 이용한 식별기의 입력 변환 계수

	α	β
$y(k)$	-0.0750718505	1.0750718505
$y(k-1)$	-0.1257701867	1.1257701867
$y(k-2)$	-0.0119519485	1.0119519485
$u(k)$	0.0001897516	0.9998102484
$u(k-1)$	-0.0004873869	1.0004873869

표 3. 제어기의 구조와 오차 제곱 평균

	구조 (가중치수)	오차 제곱 평균
기존의 직교 신경망	5 - 243 - 1 (243)	1.83391×10^{-3}
수정된 직교 신경망	5-10-244-243-1 (253)	2.74821×10^{-4}

표 4. 수정된 직교 신경망을 이용한 제어기의 입력 변환 계수

	α	β
$y(k)$	-0.0277159083	1.0277159083
$y(k-1)$	0.0963297914	0.9036702086
$y(k-2)$	-0.4999998188	1.4999998188
$u(k-1)$	0.1632479670	0.8367520330
$r(k)$	-0.0107619842	1.0107619842




그림 6. 플랜트의 출력과 신경망을 이용한 식별기의 출력.
Fig. 6. Output of plant and identifier.




그림 7. 직교 신경망을 이용한 식별기와 ONN 식별기의 오차제곱평균 비교.
Fig. 7. MSE Comparison with ONN identifier.




그림 8. 제어 시스템의 출력.
Fig. 8. Output of control system




그림 9. 직교 신경망을 이용한 제어기와 ONN 제어기의 오차제곱평균 비교.
Fig. 9. MSE comparison with ONN controller.

VI. 결 론

본 논문에서는 입력 변환을 이용하여 직교 함수의 형태를 변형하는 방법을 제시하였고 여기에 수반되는 입력 변환의 조건을 제시하였다. 그리고 이러한 입력 변환을 이용하여 직교 함수를 적당한 형태로 학습할 수 있는 새로운 구조를 가지는 수정된 직교 신경망은 기존의 직교 신경망이 가지는 단점을 해결하였다. 그리고, 비선형 시스템을 제어하기 위해 기존 모델과 제안한 수정된 직교 신경망을 이용한 식별기와 제어기로 이루어진 전체 제어 시스템을 구성하고 식별기와 제어기의 학습 알고리즘을 유도하였다.

제안한 제어 알고리즘을 도입 진자 균형문제에 적용한 사례연구를 통하여 다음과 같은 결론을 얻을 수 있었다.

1. 제안한 수정된 직교 신경망은 입력 변환을 이용하여 직교 함수를 변형함으로써 기존의 직교 신경망과 다층 신경망에 비해 비선형 시스템을 모형화하는 능력이 더 우수하다.
2. 제안한 직교 신경망은 기존의 직교 신경망에 비해 비선형 시스템의 특성을 더욱 더 정밀하게 학습하므로 이러한 정보를 이용한 비선형 시스템 제어기의 능력이 더 우수하다.

참 고 문 헌

- [1] Shioh-Shung Yang and Ching-Shioh Tseng, "An Orthogonal Neural Network for Function Approximation," *IEEE Trans. Systems, Man, and Cybernetics*, vol. 26, no. 5, pp. 779-785, 1996.
- [2] R. Courant and D. Hilbert, *Methods of Mathematical Physics*, New York: Interscience Publishers, pp. 49-111.
- [3] F. B. Hildebrand, *Advanced Calculus for Applications*, Englewood Cliffs, NJ: Prentice-Hall.
- [4] K. S. Narendra and K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks," *IEEE Trans. Neural Networks*, vol. 1, no. 1, pp. 4-27, 1990.
- [5] Pierre Baldi, "Gradient Descent Learning Algorithm Overview: A General Dynamical Systems Perspective," *IEEE Trans. Neural Networks*, vol. 6, no. 1, pp. 182-195, 1995.
- [6] Youn-Moon Park, Myeon-Song Choi, "An Optimal Tracking Neuro-Controller for Nonlinear Dynamic Systems," *IEEE Trans. Neural Networks*, vol. 7, no. 5, pp. 1099-1110, 1996.
- [7] 김성식, 이영석, 안대찬, 서보현, "직교 신경망을 이용한 비선형 시스템의 제어," *대한전기학회 하계학술대회 논문집*, pp. 397-399, 1997.