

다단 동적 신경망을 이용한 비선형 시스템 제어

정희원 노용기* 유인호** 오훈***

Nonlinear System Control using MDNN

Yong-Gi Roh* , In-Oh Ryu**, Hun Oh*** *Regular Members*

요 약

본 연구에서는 신경망구조라 불리는 MDNN에 대해서 집중적으로 설명하였고, 컴퓨팅 로봇 역 기구학에 의한 변화에 대해 학습이득 반복을 이용하여 관찰하였다. 다층 동적 신경망의 구조인 MDNN의 구성 및 학습을 제안하였으며, MDNN을 이용한 제안된 학습을 컴퓨터 모의실험과 논증으로 효과적으로 설명하였다.

ABSTRACT

The intent of this paper is to describe a neural network structure called multi dynamic neural network(MDNN), and examine how it can be used in developing a learning scheme for computing robot inverse kinematic transformations. The architecture and learning algorithm of the proposed dynamic neural network structure, the MDNN, are described. Computer simulations are demonstrate the effectiveness of the proposed learning using the MDNN.

I. 서 론

미지의 변수를 가진 선형 시스템의 식별과 적응 제어에 관한 연구는 지난 30년간 꾸준히 연구되어 왔으며 괄목할 만하게 진보되었다. 하지만 기존의 적응제어 기법은 동적 시스템의 수학적 모형을 필요로 하지만 동적 시스템은 비선형성을 가지고 있으며, 비선형 특성이 심한 시스템의 제어가 아주 어렵다. 실제로 동적 시스템의 모형은 비선형성, 불확정성, 시간지연, 시변 시스템의 변수, 구조 등에 의해서 정확하게 기술한다는 것은 불가능하다. 특히 로봇 조작기의 정밀도는 주어진 특정 작업 공간에서 직각 좌표의 목표 지점으로의 이동 능력에 좌우된다. 따라서, 목표하는 조작 단말의 위치에 대한 관찰각들을 계산하기 위해 역 기구학적인 문제는 실시간으로 풀려야만 한다. 역 기구학적인 문제는 대수적으로 또는 기하학적인 방법이나 반복법에 의해 풀 수 있다.^[1] 신경망 분야의 발전으로 인해 로봇 제어에 새로운 방향이 제시되고 있으며 신경망

은 함수 사상과 동적 반복 능력이라는 장점에 의해 좌표 변환 학습에 사용될 수 있다. 병렬 분산 처리에 기인하여 신경망은 예제 패턴들의 조합에 대한 학습 능력을 갖는다. 본 논문에서 논의된 신경망 구조는 임의 복잡도의 신경활동이 여기(excitatory, 양성)와 금지(inhibitory, 음성)의 신경 부차집단 사이의 상호 작용의 결과이고 신경 생리학적인 근거에 기초하여 개발된 MDNN이다. 따라서 MDNN의 구조와 신경망의 적응적인 가중치에 대한 학습 알고리즘을 제시한다. 그리고 학습 방법과 컴퓨터 모의실험에 의한 결과를 고찰한다.^[2-5]

II. 신경망의 구조

1. MDNN의 구조와 수학적 모델

적응적인 시냅스 강도를 갖는 MDNN의 기본적인 기능은 dynamic neural unit(DNU)에 기초한다.^[6-8]

* 원광대학교 대학원 전자공학과(ygroh@kccips.or.kr),

** 익산대학 전기과(ryin@iksan.ac.kr),

*** 익산대학 전기과

논문번호: T01001-0321, 접수일자: 2001년 3월 21일

1.1 Dynamic Neural Unit(DNU)

DNU는 기억 요소와 그림 1과 같이 전환경로 및 폐환경로 시냅스 가중치로 구성된다. 이 동적 구조의 출력은 시변 비선형 활성화 함수에 대한 인자를 구성한다. DNU는 크게 (i)synaptic operation (ii) somatic operation의 두가지의 동작을 수행한다. 전자는 전환경로 및 폐환경로 시냅스 가중치의 적응에 대응되고 후자는 비선형 활성화 함수의 이득(형태)의 적응에 대응된다. DNU는 각각 비선형 활성화 함수에 이어지는 2차 구조를 나타내는 시냅스 가중치 a_{ff} 와 a_{fb} 에 의해 가중되는 전환경로 및 폐환경로 지연 요소가 구성된다.

$$v_1(k) = -b_1 v_1(k-1) - b_2 v_1(k-2) + a_0 s(k) + a_1 s(k-1) + a_2 s(k-2) \quad (1)$$

이때 $s(k) \in R^n$ 은 신경 입력벡터이고 $v_1 \in R^1$ 은 동적 구조의 출력이며, $u(k) \in R^1$ 는 신경 출력, k 는 이산 시간 지표, z^{-1} 은 단위 지연 연산자, $a_{ff} = [a_0, a_1, a_2]$ 와 $b_{fb} = [b_1, b_2]$ 는 다음과 같이 정의 된다.

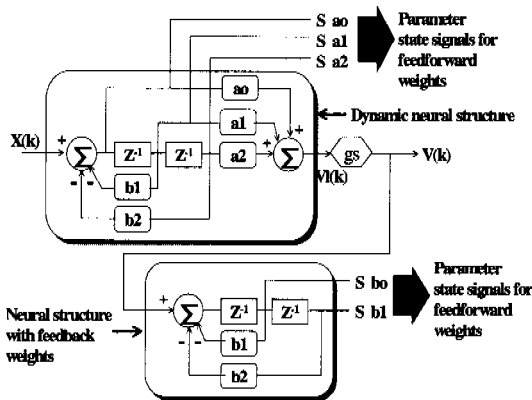


그림 1. DNU 매개변수의 상태신호 모델

$$\Gamma^T(k, v_1, s) = [v_1(k-1) \ v_2(k-1) \ s(k) \ s(k-1) \ s(k-2)] \quad (2)$$

$$\zeta^T(a_{ff}, b_{fb}) = [-b_1 \ -b_2 \ a_0 \ a_1 \ a_2] \quad (\Gamma: \text{transpose}) \quad (3)$$

(2)와 (3)에 의해 식(1)은 다음과 같이 된다.

$$v_1(k) = \Gamma(k, v-1, s) \zeta^T(a_{ff}, b_{fb}) \quad (4)$$

$v_1(k)$ 에 대한 비선형 사상은 다음과 같은 출력을 낸다.

$$u(k) = \Psi[g_s v_1(k) - \theta] \quad (5)$$

이때 $\Psi[\cdot]$ 는 비선형 활성화 함수로서 보통은 sigmoidal 함수이고 g_s 는 활성화 함수의 기울기를 제어하는 시태틱 이득이며, θ 는 뉴런을 점화시키기 위한 임계치이다. 여기와 금지 입력 모두에 대한 수학적 동작을 확장하기 위해 [-1,1]에 대한 활성화 함수를 다음과 같이 정의한다.

$$\Psi[u(k)] = \tanh[g_s v_1(k) - \theta = \tanh[u(k)]] \quad (6)$$

이때 $u(k) = g(s) v_1(k)$ 이다.

1.2 Multi Dynamic Neural Network(MDNN)

MDNN은 그림 2에서와 같이 여기와 금지 방식으로 결합된 두 개의 DNU로 구성된다.

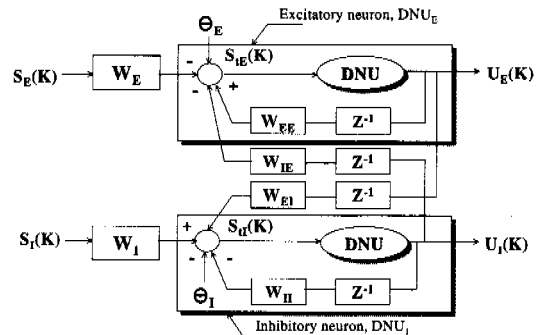


그림 2. MDNN의 구조

이 구조에서 $s_\lambda(k)$ 와 u_λ 는 첨자 λ 가 여기 E나 금지 I 상태를 가르킬 때 신경 계산 단위의 자극(입력)과 상태 반응(출력)을 나타낸다. $s_{i\lambda}(k)$ 는 신경 단위의 총 입력을 나타내고 $w_{\lambda\lambda}$ 는 한 뉴런에서 다른 뉴런으로의 상호 시냅스 연결 강도(그림2의 $w_{IE} \ w_{EI}$)를 나타낸다. 신경 계산 단위인 DNU에 의해 여기되는 기능적 동역학은 식(1)에 나타낸 바와 같이 2차 차분 방정식으로 정의된다. 제안된 신경 프로세서의 여기 및 금지 신경 단위에 의해 시간(K+1)에 발생하는 상태 변수 $u_E(k+1)$ 와 $u_I(k+1)$ 는 다음과 같이 모델링된다.

$$u_E(k+1) = E[u_E(k), v_E(k)], \text{ and} \quad (7)$$

$$u_I(k+1) = I[u_I(k), v_I(k)]$$

이때 $v_E(k)$ 와 $v_I(k)$ 는 내부 임계치 보다 더 큰 입력을 받아들이는 신경단위에서 뉴런의 비를 나타내고 E와 I는 뉴런의 여기와 금지 작용을 나타낸다. 임계치 보다 더 큰 입력을 받아들이는 뉴런은 비선형 함수 $v_\lambda(k)$ 로 주어진다. 여기서 금지 신경 단위에 수반되는 총 입력은 각각 다음과 같다.

$$s_{uE}(k) = w_E s_E(k) + w_{EE}u_E(k-1) - w_{EI}u_I(k-1) - \theta_E \quad (8)$$

$$s_{uI}(k) = w_I s_I(k) - w_{II}u_I(k-1) + w_{EI}u_E(k-1) - \theta_I \quad (9)$$

이때 W_E 와 W_I 는 각각 여기와 금지 신경 단위의 비례상수 (scaling factor)이고, W_{EE} 와 W_{II} 는 자기 시냅스 연결 강도를, W_{IE} 와 W_{EI} 는 상호 뉴런 시냅스 연결 강도, θ_E 와 θ_I 는 여기 및 금지 뉴런의 임계치를 각각 나타낸다. 뉴런의 여기와 금지 뉴런의 absolute refractory period(뉴런이 재 점화할 수 없는 기간)를 나타낸다.

$$u_E(k+1) = u_E(k) + [1 - r_E u_E(k)] \Psi_{E[s_{uE}(k)]} : \text{여기뉴런} \quad (10a)$$

$$u_I(k+1) = u_I(k) + (1 - r_I u_I(k)) \Psi_{E[s_{uI}(k)]} : \text{금지뉴런} \quad (10b)$$

식(8),(10a)에 의해 등복각 곡선에 대한 방정식은 다음과 같이 쓸 수 있다.

$$u_I(k) = \frac{1}{w_{IE}} [(w_E s_E(k) - \theta_E) + \Psi_{E^{-1}}[\frac{u_E(k)}{(1 - r_E u_E(k))}] + w_{EE} u_E(k)] \quad (11a)$$

for $u_E(k+1) = 0$

$$u_E(k) = \frac{1}{w_{EI}} [(-w_I s_I(k) - \theta_I) + \Psi_I^{-1}[\frac{u_I(k)}{(1 - r_I u_I(k))}] + w_{II} u_I(k)] \quad (11b)$$

for $u_I(k+1) = 0$

sigmoid 함수의 수학적 성질에 의하여, Ψ_E 와 Ψ_I 는 $[-\infty, \infty]$ 의 범위에서 단조 증가 하는 유일한 역을 가진다. 그러므로, 식 (11a)로 정의되는 u_I 는 언제나 u_E 의 단조 증가 함수이다. 반면에, 식(11b)에서 Ψ_I^{-1} 앞의 (-) 부호에 의해 u_E 는 점차적으로 감소하는 u_I 의 함수가 될 것이다. 두 등복각 곡선 사

이의 이러한 정성적인 차이는 여기와 금지 간의 반대칭에 대한 직접적인 결과이다. 신경 집단의 기능적인 동작이 선형 시스템 이론에 의해 근사 될 수 있다는 사실에 기인하여 MDNN의 응답 $u(k)$ 는 신경 부차집단에서 여기와 금지의 개별적인 응답인 $u_E(k)$ 의 중첩이며 다음으로 주어진다.

$$u(k) = u_E(k) + u_I(k) \quad (12)$$

식 (12)의 의미는 신경 집단의 총체적인 활동이 여기와 금지 후 시냅스 응답의 합이다.

III. MDNN 학습 알고리즘 개발

3.1 MDNN 제어기 학습 알고리즘

학습 과정은 전향경로 및 역향경로 가중치와 오차 함수를 최소화하기 위한 소매틱 이득의 적응과정을 포함한다. 반복 학습 기법에서 제어의 순서는 각 반복 학습 단계에서 목표 상태 $u_d(k)$ 에 도달하기 위한 신경 출력 $u(k)$ 를 발생하기 위해 변형된다. 학습의 반복 횟수가 증가함에 따라 오차 $e(k)$ 가 무한히 작은 값으로 줄어들 수 있다면 학습 방법은 수렴한다고 말한다. 즉, 초기조건의 임의 집합에 대해

$$u(k) \rightarrow u_d(k) \text{ as } k \rightarrow \infty \text{ or,} \\ \lim_{k \rightarrow \infty} [u_d(k) - u(k) = e(k)] \rightarrow 0 \quad (13)$$

오차 $e(k)$ 와 매개변수 벡터 $\Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda})$ 의 성분은 각 학습 횟수 k 와 함께 변한다. $\Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda})(k+1)$ 을 구하기 위해 정보집합 $\{e(k-m), e(k), \Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda})(k)\}$ 만이 필요한데 이때 $m=1,2,\dots$ 이며 창의 크기를 결정하다. 학습 횟수가 증가함에 따라 정보 집합은 다만 $\{\Omega^*(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda})(k), e^*(k)\}$ 로 감소하며 이것은 DNU 매개변수와 오차가 최적치에 수렴하였음을 가리킨다. 이를 위해 각 매개변수 벡터에 대해 최적화되어야 하는 성능 지표는 다음과 같이 정의되며 이때 E는 기대 연산자(expectation operator)이다.

$$J = EF[e(k; \Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda}))] \quad (14)$$

식 (14)에서 $E[e(k; \Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda}))]$ 의 일반적인 형태는 오차의 우함수이다. 즉,

$$J = \frac{1}{2} E[e^2(k; \Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda}))] \quad (15)$$

이때 $e(k)$ 는 목표 신호 $u_d(k)$ 와 실제 신호 $u(k)$ 간의 차이로 정의되는 오차 신호이다. 벡터 $\Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda})(k)$ 의 각 성분은 급경사 감소 알고리즘에 의해 J 를 최소화 하는 방식으로 적용되었다. 이 적응 알고리즘은 다음과 같이 쓸 수 있는데 이때 $\Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda})(k+1)$ 은 새로운 매개변수 벡터이고 $\Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda})(k)$ 는 현재 매개변수 벡터이며 $\delta\Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda})(k)$ 는 매개변수 벡터의 적응 조절량이다. 급경사 감소법에서 매개변수 벡터의 조절은 성능지표 J 의 음의 기울기에 비례하도록 되어진다. 즉,

$$\delta\Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda})(k) \propto (-\nabla J) \quad \text{여기서,}$$

$$\nabla J = \frac{\delta J}{\delta \Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda})} \quad (16)$$

따라서, $\text{dia}[\mu]$ 가 독립적인 적응 이득 행렬일 때 다음과 같이 된다.

$$\delta\Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda}) = -\text{dia}[\mu] \frac{\delta J}{\delta \Omega(a_{ff}, b_{fb}, g_s, w_{\lambda\lambda})} = -\text{dia}[\mu] \nabla J \quad (17)$$

위의 식에서 $\text{dia}[\mu]$ 는

$$\text{dia}[\mu] = \begin{bmatrix} \mu_{a_i} & 0 & 0 & 0 \\ 0 & \mu_{b_j} & 0 & 0 \\ 0 & 0 & \mu_{g_s} & 0 \\ 0 & 0 & 0 & \mu_{w_{\lambda\lambda}} \end{bmatrix} \quad (18)$$

이때 $\mu_{a_i}, i=0,1,2$, $\mu_{b_j}, j=1,2$, μ_{g_s} 는 DNU의 적응 매개변수의 독립적인 학습 이득이고, $\mu_{w_{\lambda\lambda}}$ 는 자기 및 상호 뉴런 시냅스 연결의 학습 이득을 나타낸다. $\Phi(a_{ff}, b_{fb})$ 로 DNU의 시냅스 가중치 벡터를 나타내며 $\Phi(a_{ff}, b_{fb})$ 에 대한 성능 지표의 기울기는 다음으로 구해진다.

$$\frac{\delta J}{\delta \Phi(a_{ff}, b_{fb})} = \frac{1}{2} E \left[\frac{\delta [u_d(k) - u(k)]^2}{\delta \Phi(a_{ff}, b_{fb})} \right] = E \left[e(k) - \frac{\delta \Psi(v)}{\delta \Phi(a_{ff}, b_{fb})} \frac{\delta v}{\delta \Phi(a_{ff}, b_{fb})} \right] \quad (19)$$

$$= E [e(k) \sec h^2[v(k)] P\Phi(a_{ff}, b_{fb})]$$

이때

$$P\Phi(a_{ff}, b_{fb})(k) = \frac{\delta v(k)}{\delta \Phi(a_{ff}, b_{fb})} = g_s \frac{\delta v_1(k)}{\delta \Phi(a_{ff}, b_{fb})}$$

는 매개변수-상태(또는 감도) 신호의 벡터를 나타낸다. 전환경로와 궤환경로 가중치에 대한 매개변수 상태 신호는 각각 다음 관계로 주어진다^[9-10].

$$P\Phi(a_{ff}(k)) = g_s [s(k-i)], i=0,1,2 \quad P\Phi(b_{fb}(k)) = -g_s [v_1(k-i)], j=1,2 \quad (20)$$

비슷한 방법으로 스매틱 이득 g_s 에 대한 성능지표의 기울기는 다음 식으로 주어진다.

$$\frac{\delta J}{\delta g_s} = \frac{1}{2} E \left[\frac{\delta [u_d(k) - u(k)]^2}{\delta g_s} \right] = E [-e(k) \{ \sec h^2[v(k)] v_1(k) \}] \quad (21)$$

자기 및 상호 뉴런 시냅스 연결에서의 적응은 다음과 같이 구할 수 있다.

$$\frac{\delta J}{\delta w_{\lambda\lambda}} = \frac{1}{2} E \left[\frac{\delta [u_d(k) - u(k)]^2}{\delta w_{\lambda\lambda}} \right] = E [-e(k) \sec h^2[v(k)] g_s u_{\lambda}(k-1)] \quad (22)$$

$$= E [-e(k) \frac{\delta \Psi(v)}{\delta v} \frac{\delta v}{\delta w_{\lambda\lambda}}]$$

위의 식들로부터 MDNN 매개변수 갱신 알고리즘은 다음과 같이 쓸 수 있다.

$$a_{ff}(k+1) = a_{ff}(k) + \mu_{a_i} E [e(k) \sec h^2[v(k)] P\Phi_{a_{ff}}(k)], i=0,1,2 \quad (23a)$$

$$b_{fb}(k+1) = b_{fb}(k) + \mu_{b_j} E [e(k) \sec h^2[v(k)] P_{\Phi_{b_{fb}}} b_{fb}(k)], i=1,2 \quad (23b)$$

$$g_s(k+1) = g_s(k) + \mu_{g_s} E [e(k) \sec h^2[v(k)] v_1(k)] \quad (23c)$$

$$W_{\lambda\lambda}'(k+1) = W_{\lambda\lambda}'(k) + \mu_{w_{\lambda\lambda}} E [-e(k) \sec h^2[v(k)] g_{su} \lambda(k-1)] \quad (23d)$$

식 (23a)와 (23b)은 시냅스 가중치에서 식(23c) MDNN의 활성화 함수 이득에서 식 (23d)는 외부 시냅스 가중치에서 적용되도록 한다.

$$w_{EE}(k+1) = w_{EE}(k) + \mu_{EE} E [-e(k) \{ \sec h^2[v(k)] g_s u_E(k-1) \}] \quad (24a)$$

$$w_{IE}(k+1) = w_{IE}(k) + \mu_{IE} E [-e(k) \{ \sec h^2[v(k)] g_s u_I(k-1) \}] \quad (24b)$$

$$w_{EI}(k+1) = w_{EI}(k) + \mu_{EI} E [-e(k) \{ \sec h^2[v(k)] g_s u_E(k-1) \}] \quad (24c)$$

$$w_{II}(k+1) = w_{II}(k) + \mu_{II} E \quad (24d)$$

$$[-e(k) \{ \sec^2 h^2 [v(k)] g_s u_f(k-1) \}]$$

3.2 비선형 동적 시스템 제어기법

비선형 플랜트의 제어상태를 최적으로 유지시키기 위해서는 MDNN 제어기가 신경회로망의 초기포화 상태를 인식하고 비선형 활성화 함수의 기울기를 적절히 변화 시켜주어야 한다. 기존의 DNU 제어기와 제안된 MDNN 제어기의 비교를 위해 주어지는 파라메터 값은 동일한 값으로 하였다. 따라서 신경회로망의 초기 가중치는 0.8694로 고정하고, 학습율 η 는 0.0003, 그리고 운동량 항의 값은 0.15, 이산시간은 800으로 설정하였다. 이를 바탕으로 다음과 같은 3가지 방법의 시뮬레이션을 행하였다.^[11-16]




그림 3. MDNN 알고리즘을 이용한 비선형 동적 시스템 제어기법

3.3 컴퓨터 모의 실험

경우1. 미지의 비선형 모델

제어하고자 하는 플랜트의 수학적 모델은 식 (25)와 같은 차분 방정식으로 기술된다.

$$y(k) = f[y(k-1), y(k-2), u(k), u(k-1), u(k-2)] \quad (25)$$

이때 미지의 비선형 함수 $f[\cdot]$ 은 식 (26)과 같다.

$$f[\cdot] = [2 + \cos 7\pi(y^2(k-1) + y^2(k-2)) + e^{-u(k)} / (1 + u^2(k-1) + u^2(k-2))] \quad (26)$$

여기서 시스템 입력 $x(k) = \sin(2\pi k/250)$ 이다.




그림 4. 경우 1의 시스템 입력 $x(k)$ 와 미지의 비선형 함수 $f[\cdot]$ 특성




그림 5. DNU 제어의 100번째 학습에서의 플랜트 출력과 오차 응답 $e(k)$




그림 6. MDNN 제어의 100번째 학습에서의 플랜트 출력과 오차 응답 $e(k)$

경우2. 비선형 특성이 변화하는 플랜트 제어

미지의 비선형 함수 $f[\cdot]$ 은 식 (27), (28) 과 식 (29)같이 제어 공정이 진행되는 동안 세개의 비선형 함수로 변화한다.

$$f[\cdot] = \frac{[\sin \pi(y^2(k-2) + 0.5)] + 0.3 \sin(2\pi u(k))}{1 + u^2(k-1) + u^2(k-2)} \quad (27)$$

for $0 \leq k < 99$ and $500 \leq k < 599$

$$f[\cdot] = \frac{e^{-(y^2(k-1) + y^2(k-2))}}{\sqrt{|u^2(k) + u^2(k-1) + u^2(k-2)|}} \quad (28)$$

for $200 \leq 299, 400 \leq 499$ and $600 \leq k < 800$

$$f[\cdot] = \frac{[0.5 - 0.5 \cos(7\pi(y^2(k-1) + y^2(k-2)))] + e^{-u(k)}}{4 + u^2(k-1) + u^2(k-2)} \quad (29)$$

for $100 \leq k \leq 199$ and $300 \leq k < 399$




그림 7. 경우 1의 시스템 입력 $x(k)$ 와 미지의 비선형 함수 $f[\cdot]$ 특성




그림 8. DNU 제어의 100번째 학습에서의 플랜트 출력과 오차 응답 e(k)




그림 10. MDNN 제어의 100번째 학습에서의 플랜트 출력과 오차 응답 e(k)

경우3. 미지의 비선형 특성이 변화하는 플랜트 제어
 플랜트와 미지의 비선형 함수 $f[\cdot]$ 은 경우1에
 서와 같이 동일하며 입력 신호 $x(k)$ 가 식 (30)과
 같이 변화한다.

$$\begin{aligned}
 x(k) &= \cos(2\pi k/250) \quad 0 \leq k < 75 \\
 x(k) &= 0.8 \quad \text{for } 76 \leq k < 125 \\
 x(k) &= 0.6 \quad \text{for } 126 \leq k < 175 \\
 x(k) &= 0.4 \quad \text{for } 176 \leq k < 300 \\
 x(k) &= -0.6 \quad \text{for } 301 \leq k < 350 \\
 x(k) &= 0.5 \cos(2\pi k/150) \quad \text{for } 351 \leq k < 600 \\
 x(k) &= \cos(2\pi k/250) \quad \text{for } k \geq 601
 \end{aligned} \tag{30}$$




그림 11. 경우 3의 시스템 입력 x(k)와 미지의 비선형 함수 f[·] 특성




그림 12. DNU 제어의 100번째 학습에서의 플랜트 출력과 오차 응답 e(k)




그림 13. MDNN 제어의 50번째 학습에서의 플랜트 출력과 오차 응답 e(k)

IV. 결론 및 추후 연구 방향

MDNN 제어기는 플랜트의 기준 입력의 변화와 외란의 영향, 시스템 파라메타 값의 변화 등 제어환경의 변화에 대해서 DNU의 단독제어기 보다 추종성과 강인성, 적응성 등에 대해서 MDNN이 전체적 수렴속도가 향상됨을 알 수 있다. 한편 추후 연구하여야 할 분야는 다음과 같다. MDNN의 전체적 수렴 속도는 향상되었으나 안정도에서 문제가 발생하였다. 속도와 안정도를 복합적으로 제어할 수 있는 방법에 대해 연구할 필요가 있을 것이다.


참고 문헌

- [1] K.s Narendra and K. Parthasarthy, "Identification and Control of Dynamical System Using Neural Network." *IEEE Trans. Neural Network*, pp.1-14, 1990.
- [2] Madan M. Gupat, "Fuzzy Logic and Neural Networks", *Proceeding of the Ten International Conference(TAIPEI'92)*, Vol 3, pp281-294, July, 1992
- [3] 조현섭, "The Neural Network Algorithm Using Control of Nonlinear Dynamic System", *EMB'95(Canada)*, pp167-173, 1997
- [4] 조현섭, "A Study on Korean Digit Recognition Using Semi-Dynamic Neural Network With Sequential Feedback Architecture", *ICCT'94 (Shanghai)*, Vol 1, pp. 1442-1444, 1994. 6. 8
- [5] Robert Hecht-Nielsen, "Neural Computing", *HNC, Inc. and University of California San Diego*, 1991
- [6] D. Stipanicev, M. De Neyer, and R. Gorez, "Self-tuning Self-organizing Fuzzy Robot Control", *Proc., IFAC Symp. Robot Control SYROCO'91, Vienna, Sept.권., 1991*

- [7] M. M. Gupta, and D. H. Roa,, "Dynamic Neural Units with Applications to the Control of Unknown Nonlinear System", *Journal of Intelligent and Fuzzy Systems*, Vol.1, pp. 73-92, 1993
- [8] K. J. Astrom, "Adaptive Feedback Control", *In Proceedings of the IEEE*, Vol.75, pp. 185-217, 1987
- [9] M. D. Peek and P. J. Antsaklis, "Parameter Learning for Performance Adaptation", *IEEE Control Syst. Mag.*, Vol. 10, No. 3, 1990
- [10] M. M. Gupta and D. H. Rao, "Dynamic Neural Unit in the Control of Linear and Nonlinear System", *In Proceeding of the International Joint Conf. on Neural Networks*, pp. 100-105, June, 1992
- [11] M. M. Gupta and D. H. Rao,, "Synaptic and Somatic Adaptations in Dynamic Neural Networks", *In Proceeding of the Second International Conf. on Neural Networks*, pp. 173-177, 1992
- [12] S. Chen, S. A Billings, and P. M. Grant, "Nonlinear System Identification using Neural Networks", *Int. J. Control*, 51, 1990
- [13] Jyh-Shing Roger Jang and Chuen-Tsai Sun, "Neuro-Fuzzy Modeling and Control," *proc., IEEE* vol. 83, no.3, pp. 378-406, March 1995
- [14] S. W. Park and B. H. Seo,"Design of Non-linear System using Dynamic Neural Networks", *proc., KACC*, pp. 60-64, March 1995
- [15] W. J. Free Man, "Dynamics of Image Formation by Nerve Cell Assemblies." *In Synergistics of the Brain*, Berlin, Springer-Verlag, pp102-121, 1983.
- [16] Jack M. Zurada, "Introduction to Artifical Neural Networks" West Publishing Company, 1992.

노 용 기(Yong-Gi Roh)

정회원



1991년 2월; 원광대학교
전기공학과 공학사
1992년 3월~1996년12월:
선도전기(주) 연구원
1995년 2월: 건국대학교
산업대학원 공학석사

1996년 8월~현재: 원광대학교 박사과정수료
<주관심 분야> 퍼지,지능제어, 유전알고리즘,신경망,

유 인 호(In-Ho Ryu)

정회원



1984년 2월: 원광대학교
전기공학과 공학사
1986년 8월: 건국대학교
전기공학과 공학석사
1999년 8월: 원광대학교
전기공학과 공학박사

1993년~현재: 익산대학 전기과 부교수
<주관심 분야> 자동제어, 디지털 신호처리, 컴퓨터 통신

오 훈(Hun Oh)

정회원



1991년 2월: 원광대학교
전기공학과 공학사
1993년 8월: 원광대학교
전기공학과 석사
1997년 8월: 원광대학교
전기공학과 공학박사
현재: 익산대학 전기과 시간강사
<주관심 분야> 공장자동화, 컴퓨터 통신제어