

VSS-귀환 신경망을 이용한 로봇트 매니플레이터 제어

Control of Robot Manipulator using VSS-Recurrent Neural Networks

최 영 길*, 김 성 현*, 전 흥 태*

Young-Keel Choi*, Seong-Hyun Kim*, Hong-Tae Jeon*

요 약

비선형 동적 시스템을 제어하기에 적합한 귀환 신경망에 대한 연구는 안정성(stability) 유도 및 학습 알고리즘(learning algorithm) 개발의 두 가지 방향으로 지금까지 많은 연구가 이루어져 왔다. 본 논문에서는 비선형 동적 시스템 제어시 온라인(on-line) 학습이 가능하고 안정성을 보장하도록 귀환 신경망의 학습 알고리즘에 VSS 이론을 도입하여 개발한다. 또한 개발한 학습 알고리즘을 사용한 귀환 신경망을 전형적인 비선형 동적 시스템인 로봇트 매니플레이터의 제어 시스템에 적용하고 기존의 학습 방법의 적용 결과와 비교하여 개발한 제어 알고리즘의 효용성을 입증한다.

ABSTRACT

Since recurrent neural networks(RNNs) have the dynamical property due to the internal state feedback, the RNNs are more relevant to control of nonlinear dynamical systems than static forward neural networks. The RNNs have been studied in two directions, inducement of the stability condition and development of the learning algorithm during the past decade.

In this paper, we will develop the learning algorithm of the RNNs to learn a dynamic systems on-line without the precondition for the stability. The proposed learning algorithm will be introduced the VSS(Variable Structure System) method which is effective to identify a nonlinear system and able to learn with stable and fast performance. Finally, the ability and effectiveness of the proposed learning algorithm will be illustrated by implementing and comparing the control systems used the various RNNs.

I. 서 론

신경망을 이용한 제어기는 정확한 수학적 모델링이 필요치 않으며 신경망의 병렬 처리 특성으로 인하여

여 실시간 처리 및 시스템 변화에 강건한 제어가 가능하다[1]. 비선형 동적 시스템 제어에서 다루는 신호의 형태는 시변 신호나 시계열이다. 따라서 신경망을 이용한 제어기 구성에 비선형 동적 시스템의 입·출력 관계의 학습은 시변 신호나 시계열동적 사상을 신경망을 이용하여 학습해야 한다. 시변 신호나 시계열

*중앙대학교 전자공학과

동적 사상의 학습은 정적 전방향 신경망(static forward neural networks)을 이용하는 방법과 동적 귀환 신경망(dynamic recurrent neural networks)을 이용하는 방법의 두 가지로 분류될 수 있다.

정적 전방향 신경망은 구조상 정적 사상만을 학습할 수 있으므로 제어기에 시스템의 입력을 tapped delay line(TDNN)으로 구성하거나, 시스템의 출력을 신경망의 입력으로 피드백하는 등의 변형이 필요하다. 반면 동적 귀환 신경망은 내부적으로 상태 피드백(state feedback)이 있기 때문에 입·출력 사이에 동적 사상을 학습할 수 있다. 따라서 제어기 구성에 정적 전방향 신경망과 같은 변형은 필요하지 않다. 그러므로 내부적으로 상태 피드백이 있어 동특성을 갖는 동적 귀환 신경망은 정적 귀환 신경망보다 비선형 동적 시스템을 제어하기에 적합하다[2][3][4].

이러한 귀환 신경망에 대한 연구는 뉴런 상태가 평형점으로 안정하게 수렴하게 하는 가중치 제한 조건인 안정성 유도과 신경망의 출력 오차를 최소화하는 규칙인 학습 알고리즘 개발의 두 가지 방향으로 과거 10여년 동안 많은 연구가 이루어져 왔다.

안정성의 측면으로 Guez[5]는 Gershgorin's circle theorem을 이용하여 연속 귀환 신경망의 가중치 제한 조건을 유도하였으며, Jin[6]는 Ostrowski's theorem을 이용하여 이산 귀환 신경망의 가중치 제한 조건을 유도하였다. 그러나 이러한 조건에 맞는 학습 알고리즘의 개발은 연구되지 않았다.

한편, 학습 알고리즘 측면으로 Pineda[7]와 Pearmutter[8]가 뉴런 상태의 고정점에 대하여 역전파망을 연속 시간 귀환 신경망에 확장하여 학습 알고리즘을 개발하였고, Almeida[9]와 Williams[10]등은 이산 귀환 신경망에 역전파 학습을 적용하여 학습 규칙을 개발하였다. 그러나 이러한 학습 알고리즘은 뉴런의 상태가 이미 평형점으로 수렴했다는 전제 조건하에서 연구되었다. 하지만 이 전제 조건이 만족하지 않을 경우 위의 안정성이 고려되었다고 볼 수 없다. 또한 Sato[11]와 Uchikawa[12]등은 이러한 전제 조건 없이 최적 제어 이론의 한 방법인 Lagrange Multiplier를 이용하여 학습 규칙을 개발하였다. 하지만 이 방법은 전체 궤적을 저장하여야 하기 때문에 온라인 학습이 불가능하며 많은 저장 공간을 필요로 한다는 단점이 있다.

본 논문에서는 안정성을 고려한 귀환 신경망의 학습 알고리즘을 제안한다. 귀환 신경망 뉴런의 상태가 이미 평형점으로 수렴했다는 전제 조건이 없는 동시에 동적 시스템 제어기 설계에 이용할 수 있는 온라인 학습이 가능한 귀환 신경망의 학습 알고리즘을 개발한다. 제안한 학습 알고리즘은 비선형 동적 시스템의 제어에 많이 사용되어온 VSS(variable structure systems)[13] 방법을 이용하여 개발한다. 또한 제안되는 학습 알고리즘을 사용한 귀환 신경망을 전형적인 비선형 동적 시스템인 매니플레이터의 관절 변수 제어 시스템에 적용하고 기존의 학습 방법의 적용 결과와 비교하여 개발한 학습 알고리즘의 안정성과 효용성을 입증한다.

II. 귀환 신경망의 구조와 학습 규칙

2.1 연속 귀환 신경망의 구조와 학습 규칙

정적 전방향 신경망의 뉴런은 단순히 가중치가 가해진 입력의 합을 활성화 함수에 통과시켜 출력을 이끌어 낸다. 반면 동적 귀환 신경망의 뉴런은 상태 변수가 비선형 미분 방정식 형태로 정의하여 출력량을 계산한다. 그림 1은 일반적인 연속 귀환 신경망을 전체 구조를 나타낸 그림이다.




그림 1. 연속 귀환 신경망의 구조
Fig. 1. Structure of Continuous Recurrent Neural Networks

귀환 신경망은 입력층과, 귀환층과 출력층으로 구성되며, 정적 전방향 다층 신경망과 비교할 때 은닉층(hidden layer)이 귀환층(recurrent layer)으로 대체된다. 귀환층에 있는 하나의 동적 뉴런은 그림 2와 같은 구조를 갖는다.




그림 2. 동적 뉴런
Fig. 2. A dynamic Neuron

이 동적 뉴런의 구조는 다음과 같은 미분 방정식에 의해 표현된다.

$$\begin{aligned} \dot{x}_i(t) &= -\gamma_i x_i(t) + \sum_{j=1}^N w_{ji} f(x_j(t)) + \sum_{j=1}^M r_j(t) \\ y_k(t) &= f(x_k(t)) \quad (k=1, \dots, K; K \text{는 출력 갯수}) \end{aligned} \quad (1)$$

여기서 $x_i(t)$ ($i=1, \dots, N; N$ 은 뉴런 갯수)는 뉴런의 현재 상태이며, $y_k(t)$ 는 뉴런의 출력, γ_i 는 뉴런의 시상수(time constant)이고, $r_j(t)$ ($i=1, \dots, M; M$ 은 입력 갯수)는 뉴런으로 들어오는 외부의 입력이다. 또한 w_{ji} 는 뉴런들 사이에 가해지는 가중치이다. 비선형 함수 $f(\cdot)$ ($= \tanh(\cdot)$)는 뉴런의 활성화 함수이다.

귀환 신경망이 제어기와 식별기에 적용될 때 제어 목적과 제어대상에 따라 귀환 신경망의 파라메타 w_{ji} 는 학습 규칙에 의해 조정되어야 한다. 이러한 학습 규칙은 Pineda[7]와 Pealmutter[8]가 역전파 학습 규칙을 확장하여 개발하였으며, Sato[11]와 Uchikawa[12]는 최적 제어 이론의 한 방법인 Lagrange Multiplier를 이용하여 개발하였다.

2.1.1 역전파 규칙을 확장한 학습 규칙[8][9]

다층 신경망의 학습 알고리즘에 자주 사용되는 오

차 역전파는 다음과 같은 오차 함수를 최소화하도록 가중치를 조정하는 감독 학습 규칙(supervised learning rule)이다.

$$E(\mathbf{w}) = \frac{1}{2} \sum_{k=1}^K (\hat{x}_k - x_k)^2 = \frac{1}{2} \sum_{k=1}^K E_k^2 \quad (2)$$

여기서, \mathbf{w} 는 신경망의 모든 가중치 집합을 나타내며 \hat{x}_k 와 x_k 는 각각 신경망의 목표 출력치와 실제 출력치를 나타낸다. 목표 출력치가 명확하게 지정되었다면 최급 하강법(steepest descent method)인 델타 규칙을 이용하여 가중치 변화량을 구할 수 있다. 이 오차 역전파 학습 규칙을 귀환 신경망의 학습 규칙으로 확장하기 위하여 식 (1)에서 뉴런의 상태 x_i 가 점근적으로 안정한 평형점 x_i^* 가 적어도 하나 존재한다고 가정하면, 평형점은 다음 식과 같이 주어진다.

$$x_i^* = \sum_{j=1}^N w_{ji} f(x_j^*) + \sum_{j=1}^M r_j(t) \quad (3)$$

학습의 목적은 실제 출력값 \mathbf{x} 가 궁극적으로 입력 \mathbf{r} 에 대한 목표 출력값 $\hat{\mathbf{x}}^*$ 이 되는 것이다. 즉 식 (2)의 오차 함수를 최소화하는 것이 된다. Pineda등이 기울기 하강 탐색(gradient descent search)을 이용하여 개발한 가중치 w_{qp} 를 수정하는 규칙은 다음과 같다.

$$\Delta w_{ji} = \eta z_i^* f(x_j^*) \quad (\eta > 0) \quad (4)$$

여기서 η 는 오차 역전파 학습 규칙의 학습률이며, z_i^* 는 귀환 역전파로 정의되는 미분 방정식 (5)에 의하여 구해진다.

$$\dot{z}_i = -z_i + \sum_{j=1}^N w_{ji} f(x_j^*) z_j + E_i^* \quad (5)$$

2.1.2 Lagrange Multiplier를 이용한 학습 규칙[11]

신경망의 감독 학습은 평가함수 E 로 가중치 \mathbf{w} 를 수정함으로써 원하는 값 \hat{x}_i 와 실제값 x_i 의 차이를 최소화하는 수치적인 처리 과정이다. 이 방법으로는 어떤 시간 구간동안 신경망을 동작시킨 후에 오프-라인으로 가중치를 수정하는 방법과 신경망을 동작시키면서 온라인으로 가중치를 수정하는 방법이 있다. Uchikawa등이 Lagrange Multiplier를 이용하여 개발

한 학습 규칙은 전자의 방법으로 주어진 시간 구간 0~T 동안의 오차를 이용하여 다음과 같은 평가 함수를 정의한다.

$$E(w) = \int_0^T \sum_{k=1}^K \frac{1}{2} \{x_k(t) - \hat{x}_k(t)\}^2 dt \quad (6)$$

가중치 벡터 w 를 한 회 학습마다 기울기를 따라 다음 식과 같은 변화량 Δw 씩 변화시킨다.

$$\Delta w = -\eta \frac{\partial E(w)}{\partial w_{ji}} (\eta > 0) \quad (7)$$

여기서 η 는 학습률로 임의의 작은 양의 정수이다. Δw 에 대한 평가 함수의 변화량 ΔE 는 다음과 같다.

$$\Delta E = \sum_{j,i}^N \frac{\partial E}{\partial w_{ji}} \Delta w_{ji} = -\eta \sum_{j,i}^N \left\{ \frac{\partial E}{\partial w_{ji}} \right\}^2 \leq 0 \quad (8)$$

이것은 w 를 Δw 만큼 수정할 때마다 E 가 ΔE 만큼씩 감소한다는 것을 의미한다. 따라서 Lagrange Multiplier L_i 를 도입하여 부분 변이 Δw 를 구하면 다음과 같다.

$$\Delta w = -\eta \int_0^T L_i(t) y_j(t) dt \quad (9)$$

여기서 Lagrange Multiplier L_i 는 식 (1)과 식 (6)에 의하여 얻은 식 (10)과 같은 미분 방정식에서 구해진다.

$$\dot{L}_i(t) = \gamma_i L_i(t) - \sum_j^N L_j w_{ji} f'(x_i(t)) - (x_i - \hat{x}_i) \quad (10)$$

식 (1)의 뉴런 상태 방정식은 시간이 증가하는 전방향으로 계산하는 반면 식 (10)의 미분 방정식은 뉴런의 상태를 주어진 시간 주기동안 구한 후에 역방향으로 계산되어야 한다.

2.2 이산 귀환 신경망의 구조와 학습 규칙[9][10]

연속 귀환 신경망의 미분 방정식 형태의 뉴런 상태 방정식에서 뉴런 상태 x_i 가 시간 $t=1$ 에 대한 변화가 매우 적고 γ_i 는 1로 가정하고, Euler 근사화하면 이산 귀환 신경망의 뉴런 상태 방정식과 출력 방정식은 식 (11)과 같이 구해진다.

$$\begin{aligned} \dot{x}_i(t+1) &= \sum_{j=1}^N w_{ji} f(x_j(t)) + \sum_{j=1}^M r_j(t) \\ y_i(t+1) &= f(x_i(t+1)) \end{aligned} \quad (11)$$

상기의 식은 다음 순간의 뉴런 상태를 현재 순간의 뉴런 상태에 대한 이산 방정식으로 구하여 다음 순간의 출력을 얻을 수 있다는 것을 의미한다. 그림 3은 이와 같은 이산 귀환 신경망을 나타낸 그림이다.




그림 3. 이산 귀환신경망의 구조

Fig. 3. Structure of Discrete Recurrent Neural Networks

그림 3에서 보는 바와 같이 신경망의 현재 출력이 다음의 출력에 영향을 주도록 피드백된다. 이산 귀환 신경망의 학습 알고리즘은 “일시 교사 학습(temporal supervised learning)”, 즉 특정 시간에 신경망의 출력치를 고정된 목표치와 일치하도록 것을 의미한다. 목표치를 $d_k(t)$ 라 하고 신경망의 출력값을 $y_k(t)$ 라 하면 학습 알고리즘을 위한 오차 함수는

$$E(t) = \frac{1}{2} \sum_{k=1}^K \{d_k(t) - y_k(t)\}^2 = \frac{1}{2} \sum_{k=1}^K e_k(t)^2 \quad (12)$$

로 정의된다.

William등은 이 오차 함수가 감소하도록 하는 가중치 수정 규칙을 역전과 규칙에 의하여

$$\Delta w = \eta \sum_{k=1}^K e_k(t) p_{ji}^k(t) \quad (13)$$

로 구하였다. $p_{ji}^k(t)$ 는 $p_{ji}^k(t) \equiv \partial y_k(t) / \partial w_{ji}$ 로 정의되고 다음과 같은 이산 상태 방정식에 의하여 구해진다.

$$p_{ji}^k(t+1) = f'(x_k(t)) \left\{ \sum_{i=1}^N w_{ik} p_{ji}^l(t) + \delta_{ki} x_j(t) \right\} \quad (14)$$

여기서, $p_{ji}^k(t) = 0$.

III. 귀환 신경망의 VSS 학습 알고리즘

본 절에서는 안정성을 고려한 귀환 신경망의 학습 알고리즘 개발하기 위하여 VSS(variable structure systems) 이론[13]을 도입한다. VSS 이론은 1965년 소련에서 개발되어 철강, 전력, 화학, 항공 등 산업의 공정 제어에 광범위하게 응용되어 왔다. VSS의 두드러진 특징은 스위칭 평면에서 슬라이딩 모드가 일어난다는 것이다. 슬라이딩 모드에 있을 때 시스템은 파라메타의 변화와 외란에 영향을 받지 않는다. 슬라이딩 모드를 일으키는 가변 구조 제어는 시스템의 정확한 모델링을 필요로 하지 않고, 단지 파라메타의 범위만을 안다고 가정된다. 제어하는 안정성을 고려한 귀환 신경망의 학습 알고리즘은 뉴런 상태가 안정한 평형점으로 수렴하였다는 전제 조건을 가지지 않으며 온라인 학습이 가능하도록 하는 학습 알고리즘이다. 이러한 학습 알고리즘을 개발하기 위하여 위에서 설명한 VSS 이론을 도입한다.

뉴런 상태가 $x_i (i=1, \dots, N)$ 인 귀환 신경망의 상태 방정식 (1)에서 상태 \hat{x}_i 를 갖는 실제 시스템을 완전히 표현하는 가중치 w_{ji} 가 존재한다고 가정하면 실제 시스템을 귀환 신경망으로 모델링한 상태 방정식은

$$\dot{\hat{x}} = -\gamma_i \hat{x}_i + \sum_{j=1}^N w_{ji} f(\hat{x}_j) + \gamma_i \quad (15)$$

와 같이 된다. 귀환 신경망의 상태와 실제 시스템의 상태 사이의 오차를 다음과 같이 정의하면,

$$e_i = x_i - \hat{x}_i \quad (16)$$

식 (1)와 식 (15)로부터 오차 방정식은 식 (17)와 같이 구할 수 있다.

$$\dot{e}_i = -\gamma_i e_i + \sum_{j=1}^N w_{ji} \{f(x_j) - f(\hat{x}_j)\} + \sum_{j=1}^N \tilde{w}_{ji} \{f(\hat{x}_j)\} \quad (17)$$

여기서, $\tilde{w}_{ji} = w_{ji} - w_{ji}^*$.

VSS 방법을 사용하기 위하여 오차 방정식 (17)을 시간에 대하여 미분하면, $\dot{\tilde{w}}_{ji} = \dot{w}_{ji} - \dot{w}_{ji}^*$ 이므로 \ddot{e}_i 는 다음과 같이 유도될 수 있다.

$$\begin{aligned} \ddot{e}_i &= -\gamma_i \dot{e}_i + \sum_{j=1}^N \dot{w}_{ji} \{f(x_j) - f(\hat{x}_j)\} + \sum_{j=1}^N w_{ji} f'(x_j) \dot{x}_j \\ &\quad - \sum_{j=1}^N w_{ji} f'(\hat{x}_j) \dot{\hat{x}}_j + \sum_{j=1}^N \dot{w}_{ji} f'(\hat{x}_j) + \sum_{j=1}^N \tilde{w}_{ji} f'(\hat{x}_j) \dot{\hat{x}}_j \\ &= -\sum_{j=1}^N \gamma_i \delta_{ji} \dot{e}_j + \sum_{j=1}^N w_{ji} \{f'(x_j) - f'(\hat{x}_j)\} \dot{x}_j + f'(\hat{x}_i) \dot{e}_j \\ &\quad + \sum_{j=1}^N \dot{w}_{ji} f(x_j) + \sum_{j=1}^N \tilde{w}_{ji} f'(\hat{x}_j) (\dot{x}_j - \dot{e}_j) \\ &= -\sum_{j=1}^N \{-\gamma_i \delta_{ji} + w_{ji} f'(\hat{x}_j)\} \dot{e}_j + \sum_{j=1}^N w_{ji} \{f'(x_j) - f'(\hat{x}_j)\} \dot{x}_j \\ &\quad + \sum_{j=1}^N \{\dot{w}_{ji} f(x_j) + \tilde{w}_{ji} f'(\hat{x}_j) \dot{x}_j\} + \sum_{j=1}^N \tilde{w}_{ji} f'(\hat{x}_j) \dot{e}_j \end{aligned}$$

따라서 VSS 제어 방법을 위한 오차 상태 방정식을 다음과 같이 식으로 구해진다.

$$\begin{aligned} \dot{e}_i &= \sum_{j=1}^N \{-\gamma_i \delta_{ji} e_j + w_{ji} \{f(x_j) - f(\hat{x}_j)\} + \sum_{j=1}^N \tilde{w}_{ji} f(\hat{x}_j)\} \\ \ddot{e}_i &= \sum_{j=1}^N \{-\gamma_i \delta_{ji} + w_{ji} f'(\hat{x}_j)\} \dot{e}_j + \sum_{j=1}^N w_{ji} \{f'(x_j) - f'(\hat{x}_j)\} \dot{x}_j \\ &\quad + \sum_{j=1}^N \{\dot{w}_{ji} f(x_j) + \tilde{w}_{ji} f'(\hat{x}_j) \dot{x}_j\} + \sum_{j=1}^N \tilde{w}_{ji} f'(\hat{x}_j) \dot{e}_j \end{aligned} \quad (18)$$

양의 상수 $c_i (i=1, 2, \dots, n)$ 로 스위칭 선을 $s_i = c_i e_i + \dot{e}_i$ 와 같이 설정하면, 식 (18)로부터 \dot{e}_i 는 다음과 같이 구할 수 있다.

$$\begin{aligned} \dot{s}_i &= \sum_{j=1}^N \{-c_i \gamma_i \delta_{ji} e_j + w_{ji} \{c_i (f(x_j) - f(\hat{x}_j)) e_j + \dot{x}_j (f'(x_j) - f'(\hat{x}_j))\} \\ &\quad + \sum_{j=1}^N (-\gamma_i \delta_{ji} + w_{ji} f'(\hat{x}_j)) \dot{e}_j \\ &\quad + \sum_{j=1}^N \{\dot{w}_{ji} f(x_j) + \tilde{w}_{ji} \{c_i f(\hat{x}_j) + f'(\hat{x}_j) \dot{x}_j\}\} \end{aligned}$$

이때 s_i 의 값이 0으로 접근함에 따라서 \dot{e}_i 는 $-c_i e_i$ 로 접근하므로 \dot{s}_i 의 값은

$$\dot{s}_i = \sum_{j=1}^N \{-c_i \gamma_i \delta_{ji} e_j + w_{ji} \{c_i (f(x_j) - f(\hat{x}_j)) e_j\}$$

$$\begin{aligned}
 & + \dot{x}_j (f'(x_j) - f'(\hat{x}_j))) \\
 & + \sum_{j=1}^N (-\gamma_i \delta_{ji} + w_{ji} f'(\hat{x}_j)) (-c_j e_j) \\
 & + \sum_{j=1}^N \{ \dot{w}_{ji} f(x_j) + \tilde{w}_{ji} \{ c_i f(\hat{x}_j) + f'(\hat{x}_j) \dot{x}_j \} \} \\
 = & \sum_{j=1}^N \{ w_{ji} \{ c_i (f(x_j) - f(\hat{x}_j)) + \dot{x}_j (f'(x_j) - f'(\hat{x}_j)) \\
 & - c_j f'(\hat{x}_j) e_j \} \} \quad (19) \\
 & + \sum_{j=1}^N \{ \dot{w}_{ji} f(x_j) + \tilde{w}_{ji} \{ c_i f(\hat{x}_j) + f'(\hat{x}_j) \dot{x}_j \}
 \end{aligned}$$

이다. 여기서 가중치의 변화량을 구하기 위한 입력 u_i 를 다음과 같이 정의한다.

$$\begin{aligned}
 u_i = & \sum_{j=1}^N \{ \dot{w}_{ji} f(x_j) + \tilde{w}_{ji} \{ c_i f(\hat{x}_j) + f'(\hat{x}_j) \dot{x}_j \} \} \\
 = & \sum_{j=1}^N \{ \dot{w}_{ji} f(x_j) e_j^{-1} + \tilde{w}_{ji} \{ c_i f(\hat{x}_j) + f'(\hat{x}_j) \dot{x}_j \} e_j^{-1} \} e_j \\
 = & \sum_{j=1}^N \phi_{ji} e_j
 \end{aligned}$$

이때 VSS 제어 규칙에 따라서 $s_i \rightarrow +0$ 이면 $\dot{s}_i < 0$ 이어야 하고 $s_i \rightarrow -0$ 이면 $\dot{s}_i > 0$ 이어야 하므로 ϕ_{ji} 는 다음과 같이 구해진다.

$$\phi_{ji} = \begin{cases} \alpha_{ji} & \text{if } e_j s_i > 0, \\ -\alpha_{ji} & \text{if } e_j s_i < 0, \end{cases} \quad \alpha_{ji} > 0 \quad (21)$$

$f_e(x_j) = f(x_j) - f(\hat{x}_j)$, $f_a(x_j) = f(x_j) + f(\hat{x}_j)$ 로 놓으면

$$\dot{s}_i = \sum_{j=1}^N \{ w_{ji} \{ c_i f_e(x_j) e_j^{-1} + \dot{x}_j + \dot{x}_j f_a(x_j) f_e(x_j) e_j^{-1} - c_j f'(\hat{x}_j) + \phi_{ji} \} e_j \} \quad (22)$$

이 되어 α_{ji} 는 다음 식과 같이 파라메타의 범위로 구

$$\begin{aligned}
 \alpha_{ji} & > \max |w_{ji}| \\
 & \{ c_i f_e(x_j) e_j^{-1} + \dot{x}_j + \dot{x}_j f_a(x_j) f_e(x_j) e_j^{-1} - c_j f'(\hat{x}_j) \} \\
 \alpha_{ji} & > \max |w_{ji}| \cdot \\
 & \max \{ \{ c_i f_e(x_j) e_j^{-1} + \dot{x}_j + \dot{x}_j f_a(x_j) f_e(x_j) e_j^{-1} \\
 & \quad - c_j f'(\hat{x}_j) \} \}
 \end{aligned}$$

여기서, $|\dot{x}_j| < (\sigma > 0)$ 일때 $0 < f_e(x_j) e_j^{-1} < 1$ 이고, $-2 < f_a(x_j) < 2$, $0 < f'(\hat{x}) \leq 1$ 이므로 위의 식은 다음과 같이 된다.

$$\alpha_{ji} > \max |w_{ji}| \cdot \{ c_i + 3\sigma \} \quad (23)$$

식 (20)의 정의에서 $\tilde{w}_{ji} = -\alpha \dot{w}_{ji}$ ($\therefore w_{ji}^* = w_{ji} + \alpha \dot{w}_{ji}$) 이므로 ϕ_{ji} 의 값은 다음 식과 같이 구해진다.

$$\begin{aligned}
 \phi_{ji} = & \dot{w}_{ji} f(x_j) e_j^{-1} + \alpha \dot{w}_{ji} \{ c_i f(\hat{x}_j) + f'(\hat{x}_j) (\dot{x}_j - c_j e_j) \} e_j^{-1} \\
 = & \dot{w}_{ji} \{ \{ f(x_j) - \alpha c_i f(\hat{x}_j) \} e_j^{-1} - \alpha f'(\hat{x}_j) \dot{x}_j e_j^{-1} \}
 \end{aligned}$$

따라서 가중치의 변화량 \dot{w}_{ji} 는 다음 식과 같이 유도 된다.

$$\dot{w}_{ji} = \phi_{ji} e_j / \{ f(x_j) - \alpha c_i f(\hat{x}_j) - \alpha f'(\hat{x}_j) \dot{x}_j \} \quad (24)$$

IV. 귀환 신경망을 이용한 로봇 매니퓰레이터 제어

4.1 로봇 매니퓰레이터의 제어

본 논문에서 제안한 귀환 신경망의 효율성을 입증하기 위하여 로봇 매니퓰레이터의 관절 변수(joint variable)의 제어 시스템을 설계한다. 그림 4는 귀환 신경망을 이용한 제어 시스템 구조를 나타낸 그림이다.

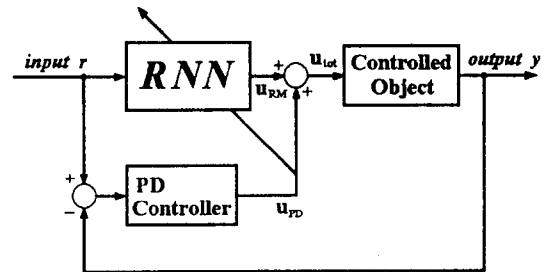


그림 4. 귀환 신경망을 이용한 제어기의 구조
Fig 4. Robot manipulator control system

상기의 제어 시스템은 전방향형의 제어 구조로서 병렬로 연결되어 있는 RNN과 PD 제어기, 그리고 제어 대상으로 구성되어 있다. RNN은 적응 학습을 통해 제어 대상 시스템의 역동력학 특성을 모델링하여 기준 입력에 대한 제어 입력을 생성한다. 그리고 PD 제어기는 순간적인 제어환경의 변화 등에 대하여 시

시스템의 안정성을 보장하며, 귀환 신경망의 온라인 학습시 제어 대상 시스템의 자코비안(jacobian)을 알 수 없는 경우에 간접적인 교차 신호를 제공하는 역할을 한다.

이 제어 시스템의 제어 대상에 인가되는 전체 입력 u_{tot} 은

$$u_{tot}(t) = u_{RM}(t) + u_{PD}(t) = u_{RM}(t) + K_p e(t) + K_d \dot{e}(t) \quad (25)$$

와 같이 선형 제어기의 출력 u_{RM} 와 RNN의 출력 u_{RM} 의 합에 의해 결정된다. 여기서 $e(t) = r(t) - y(t)$ 이며, $r(t)$ 는 기준 입력, $y(t)$ 는 시스템의 실제 출력이다.

본 논문에서는 제어 대상으로 전형적인 비선형 동적 시스템인 로봇트 매니플레이터를 선정한다. 일반적인 로봇트 매니플레이터의 동적 방정식은 식 (26)와 같이 표현된다.

$$\tau = M(\theta) \ddot{\theta} + V(\theta, \dot{\theta}) + G(\theta) \quad (26)$$

여기서 $\theta (\in \mathbb{R}^{n \times 1})$ 는 관절 벡터, $\tau (\in \mathbb{R}^{n \times 1})$ 는 토크 벡터, $M(\theta) (\in \mathbb{R}^{n \times n})$ 는 관성 행렬, $V(\theta, \dot{\theta}) (\in \mathbb{R}^{n \times 1})$ 는 원심력과 코리올리 힘 벡터, $G(\theta) (\in \mathbb{R}^{n \times 1})$ 는 중력 벡터이다. 로봇트 매니플레이터는 여러 가지 비선형 항을 갖는 고도의 비선형 항을 갖는 고도의 비선형 시스템이다.

본 논문에서는 2축 로봇트 매니플레이터를 고려하고 로봇트의 위치 제어에 정적 전방향 신경망과 귀환 신경망을 적용, 비교하여 귀환 신경망의 효율성을 입증한다. 로봇트 매니플레이터의 링크 길이 및 질량은 $l_1 = 0.53(m)$, $l_2 = 0.47(m)$, $m_1 = 3(kg)$, $m_2 = 2.5(kg)$ 으로 각각 설정하고 주행 경로는 타원형 궤적을 설정하였다.

그림 5과 6은 각각 정적 신경망과 제안된 VSS-귀환 신경망을 이용한 제어기로 2000회 학습한 후 추정 결과를 보인다. 그림 7과 8은 이러한 두 신경망의 학습 효율성을 보이기 위하여 2000회 학습하는 동안 관절 변수에 대한 오차의 변화를 나타낸 그림이다. 그림 5~8로부터 학습 속도와 학습 결과측면에서 제안된 VSS-귀환 신경망이 정적 전방향 신경망보다 로봇트 매니플레이터를 효율적으로 제어함을 알 수 있다.

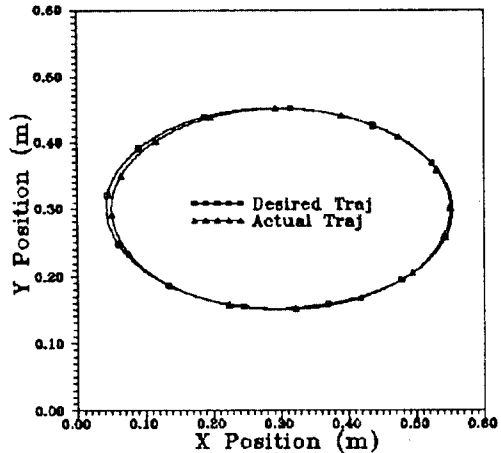


그림 5. 전방향 신경망의 추종 결과
Fig. 5. Tracking result of the forward neural network




그림 6. 제안된 귀환 신경망의 추종 결과
Fig. 6. Tracking result of the proposed RNN

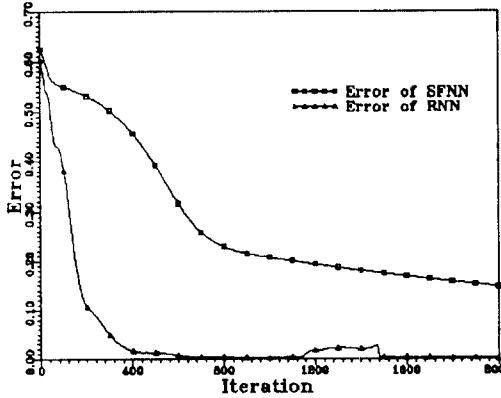


그림 7. 링크 1의 오차의 변화
Fig. 7. Error variations of link 1

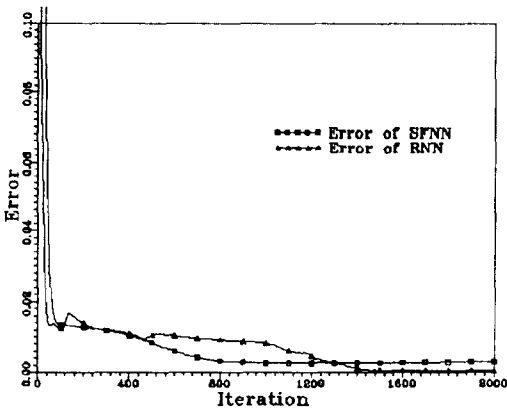


그림 8. 링크 2의 오차 변화
Fig. 8. Error variations of link 2

4.2 로봇트 매니퓰레이터의 모델링

본 절에서는 그림 9와 같은 3 자유도 로봇트 매니퓰레이터의 토크 입력에 대한 관절 상태 변수의 모델링을 통하여 제안한 귀환 신경망의 학습알고리즘의 효율성을 입증한다.




그림 9. 3 자유도 로봇트 매니퓰레이터
Fig. 9. 3 D.O.F. Robot Manipulator

3 자유도 매니퓰레이터의 동적 방정식 (26)을 관절 각과 관절 각속도를 상태 변수로 하는 $X(t)=[\theta_1, \theta_2, \theta_3, \dot{\theta}_1, \dot{\theta}_2, \dot{\theta}_3]^T$ 의 상태 방정식 형태로 변형하면 다음과 같

은 비선형 상태 방정식을 얻는다.

$$\dot{X}(t) = A(X, t)X(t) + B(X, t)\tau(t) \tag{27}$$

여기서,

$$A(X, t) = \begin{bmatrix} 0 & I_n \\ -M^{-1}(\theta)G'(\theta) - M^{-1}(\theta)C'(\theta)K(\theta) \end{bmatrix}$$

$$B(X, t) = \begin{bmatrix} 0 \\ -M^{-1}(\theta) \end{bmatrix}, C(\theta, \dot{\theta}) = C'(\theta)K(\theta)X(t).$$

6계 비선형 미분 방정식의 형태로 표현되는 3 자유도 로봇트 매니퓰레이터는 입력 토크에 대하여 관절 변수 상태가 변하는 비선형 동적 시스템으로 볼 수 있다. 이와 같은 6계 비선형 미분 방정식을 모델링하는 실험을 통해 제안한 학습 알고리즘의 효율성을 입증한다.

그림 10은 모델링한 결과를 기존의 오차 역전파를 확장한 학습 방식과 제안한 학습 방식의 성능을 비교하기 위하여 학습 과정에서 오차의 변화를 보인다. 그림 10으로부터 제안한 학습 알고리즘이 빨리 수렴함을 알 수 있다.

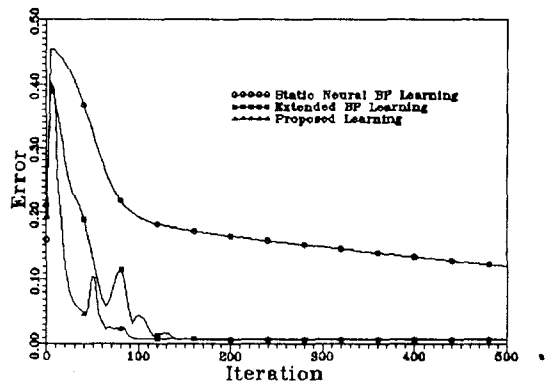


그림 10. RMS 비교
Fig. 10. Comparison of RMSs

V. 결 론

비선형 동적 시스템을 제어하는데 적합한 귀환 신경망은 안정성과 학습 알고리즘 측면에서 각기 많은

연구가 되어왔다. 하지만 학습 알고리즘 개발에 전제 조건인 가정, 즉 뉴런의 상태가 이미 안정한 평형점으로 수렴하였다는 것이 맞지 않을 경우 귀환 신경망의 뉴런 상태의 안정성을 유지할 수 없는 문제가 발생한다. 또한 안정성에 대한 기존의 연구에서는 학습 알고리즘을 개발하지 않았다.

본 논문은 뉴런이 이미 안정한 평형점으로 수렴하였다는 전제 조건 없이 온라인 학습이 가능한 귀환 신경망의 학습 알고리즘을 개발하였다. 개발한 학습 알고리즘은 비선형 동적 시스템의 이산적 제어에 많이 사용되어 온 VSS 이론을 이용하였다. 또한 본 논문에서 평면 2축 로봇트 매니플레이터의 위치 제어를 통해 귀환 신경망이 전방향 신경망보다 효율적이라는 것을 증명하였으며, 3 자유도 로봇트 매니플레이터의 관절 변수 모델링과 같은 6계 비선형 상태 방정식의 모델링에 기존의 학습 알고리즘과 제안한 학습 알고리즘을 갖는 귀환 신경망을 적용하여 제안한 학습 알고리즘의 효율성을 입증하였다.

참 고 문 헌

1. K. S. Narendra, and K. Patharathy, "Identification and Control of Dynamical System Using Neural Networks," *IEEE Trans. on Neural Networks*, Vol. 1, No. 1, pp. 4-27, 1990.
2. A. Karakasoglu, S. I. Suharsanan, and M. K. Sundareshan, "Identification and Decentralized Adaptive Control Using Dynamical Neural Networks with Application to Robotic Manipulators," *IEEE Trans on Neural Networks*, vol. 4, no. 6, pp. 919-930, 1993.
3. George A. Rovithakis, and A. Christodoulou, "Adaptive Control of Unknown Plants Using Dynamical Neural Networks," *IEEE Trans. on SMC*, Vol 24, No. 3, pp. 400-411, March., 1994.
4. Quan N., and T. J. Sejnowski, "Learning to Solve Random-Dot Stereograms of Dense Transparent Surfaces with Recurrent Backpropagation," *Proc. of the 1988 Connectionist Models Summer School*, pp. 435-443, San Mateo, CA.
5. A. Guez, V. Protopopsecu, J. Barhen, "On the Stability, Storage Capacity, and Design of Nonlinear Continuous Neural Networks," *IEEE Trans. on SMC*, Vol. 18, No. 1, pp. 80-87, Jan./Feb., 1988.
6. Liang Jin, Peter N. Nikiforuk, and Madan M. Gupta, "Dynamics and Stability of Multilayered Recurrent Neural Networks," in *Proc. 1993 IEEE Int. Conf. Neural Net.*, 1993. Vol II, pp. 1135-1140.
7. F. J. Pineda, "Recurrent Backpropagation and the Dynamical Approach to Adaptive Neural Computation," *Neural Computation 1*, pp. 161-172 1989.
8. B. A. Pearlmutter, "Learning State Space Trajectories in Recurrent Neural Networks," *Neural Computation 1*, pp. 263-269 1989.
9. L. B. Almeida, "A Learning Rule for Asynchronous Perception with Feedback in a Combinatorial Environment," *1987 Proc. of IEEE First Int. Conf. Neural Networks*, Vol. II, pp. 609-618, 1987.
10. R. J. Williams, and D. Zipser, "A Learning Algorithm for Continually Running Fully Recurrent Neural Networks," *Neural Computation 1*, pp. 270-280 1989.
11. M. Sato, "A Real Time Learning Algorithm for Recurrent Analog Neural Networks," *Biological Cybernetics*, Vol. 62, pp. 237-241, 1990.
12. Y. Uchikawa, H. Takase, T. Watanabe, K. Gouhara, "Recurrent Neural Networks," *Fifth IFSA World Congress*, vol 2, pp. 1005-1008, 1993.
13. V. I. Utkin, *Sliding Modes and Their Application in Variable Structure System*, Mir Publishers, MOSCOW, 1978.



최 영 길(Young-Keel Choi) 정회원
1950년 4월 7일생
1974년 2월: 중앙대학교 전자공학과(공학사)
1981년 2월: 고려대학교 대학원 전자공학과(공학석사)
1990년 3월~현재: 중앙대학교 대학원 전자공학과 박사과정

사과정

1981년 3월~현재: 부천전문대학 컴퓨터제어과 정교수
※ 관심분야: 로보틱스, 퍼지-신경망 제어, 유전 알고리즘등임



김 성 현(Seong-Hyun Kim) 준회원

1964년 3월 30일생

1991년 2월: 중앙대학교 전자공
학과(공학사)

1993년 2월: 중앙대학교 대학원
전자공학과(공학석사)

1993년 3월~현재: 중앙대학교 대
학원 전자공학과 박

사과정

※관심분야: 로보틱스, 퍼지-신경망 제어, 적응 제어,
강인 제어등임

전 흥 태(Hong-Tae Jeon)

정회원

제5권 제1호 참조

현재: 중앙대학교 전자공학과 교수