

論文00-37SC-5-5

카오틱 신경망과 PD제어기를 이용한 푸마 로봇의 궤적제어에 관한 연구

(A Study on Trajectory Control of PUMA Robot using
Chaotic Neural Networks and PD Controller)

張昶華*, 金相熙*, 安熙旭*

(Chang-Wha Jang, Sang-Hee Kim, and Hee-Wook Ahn)

요 약

본 논문은 카오틱 신경망과 PD 제어기를 이용한 로봇 시스템의 직접적응제어 방식에 관한 것이다. 카오틱 신경망은 상·하층 결합계수 외에 궤환 결합계수와 동일 층 내의 결합계수를 가지며, 뉴런자체의 충분한 비선형성 때문에 강한 동적특성을 가지고 있다. 그러나 신경망의 구조 및 학습의 문제점으로 인하여 동적 시스템의 제어에 적용되지 못하고 있다. 본 논문에서는 기존의 카오틱 신경망을 제어 분야에 적용하기 위하여 적합한 구조로 수정하고 수정된 신경망의 학습에 관하여 고찰하였다. 제안된 신경망은 모의 실험을 통하여 3축 푸마 로봇의 경로 제어에 적용하였다. 카오틱 신경망 제어기는 PD 제어기와 병렬로 구성하여 학습 초기의 안정성을 확보하였고, 제어대상의 비선형성을 보상하는 보상 제어기의 역할을 수행하도록 하였다.

Abstract

This paper presents a direct adaptive control of robot system using chaotic neural networks and PD controller. The chaotic neural networks have robust nonlinear dynamic characteristics because of the sufficient nonlinearity in neuron itself, and the additional self-feedback and inter-connecting weights between neurons in same layer. Since the structure and the learning method are not appropriate for applying in control system, this neural networks have not been applied. In this paper, a modified chaotic neural networks is presented for dynamic control system. To evaluate the performance of the proposed neural networks, these networks are applied to the trajectory control of the three-axis PUMA robot. The structure of controller consists of PD controller and chaotic neural networks in parallel for conforming the stability in initial learning phase. Therefore, the chaotic neural network controller acts as a compensating controller of PD controller.

I. 서 론

산업계 전반에서 사용되고 있는 로봇은 그 활용의 범위가 지속적으로 증가하고 있으며, 특히 로봇의 궤적을 제어하기 위한 연구가 활발히 진행되고 있다. 이러한 문제와 관련하여 수학적 모델링에 기초한 궤환제어나 적응제어 등이 연구되었다^[1-2]. 그러나 수학적 모델링에 의한 제어 방법을 로봇 시스템에 적용할 경우, 공간 또는 평면상에서 중력과 관성을 포함한 로봇의 동역학 및 기구학적인 문제를 정확히 기술하기 어

* 正會員, 金烏工科大學校 電子工學部

(School of Electronic Engineering, Kumoh National University of Technology)

※ 본 연구는 1998년도 금오공과대학교 학술연구비와 한국과학재단 지정 금오공과대학교 전자부품산업고품질화 및 공정자동화연구센터의 지원에 의한 것입니다.

接受日字:2000年1月28日, 수정완료일:2000年8月4日

렵기 때문에 일정한 형태의 수식에 의한 제어 규칙을 정하는 데는 한계가 있다. 또한, 제어 기법 중 PD제어기는 적용하기가 간단하기 때문에 산업계에서 가장 널리 사용되고 있으며, 대표적인 로봇 제어기법은 수학적 해석 기법에 근거한 토크 계산법(computed torque techniques)이 있다. 토크 계산법은 로봇의 동역학 모델을 이용하여 계획된 로봇의 궤적을 추적하기 위해 필요한 각 관절의 토크를 계산하는 방법이다. 그러나, 제어 대상의 동역학 모델을 정확히 모를 경우 로봇 시스템과 같이 비선형성이 강한 시스템에 적용은 정확성을 떨어뜨린다.

신경망 제어기는 적응학습 능력과 정확한 제어 모델과 제어 법칙이 불필요한 장점을 가지므로 복잡한 비선형 시스템의 모델링과 로봇 제어 분야에서 많은 연구가 이루어지고 있다. Kawato^[3] 등은 궤환 오차에 의한 학습을 이용하여 로봇의 역 동역학 모델(inverse kinematics model)을 얻는 신경 회로망을 제안하였다. Miyamoto^[4] 등은 로봇의 역 동역학을 계층 신경망(hierarchical neural networks) 모델에 의해 학습 시킴으로서 로봇의 경로 제어 효과를 한층 더 개선하였다. Ozaki^[5] 등은 모델 학습 개념을 이용하여 2축 로봇 매니퓰레이터의 경로 제어 문제에 다층 신경망을 적용하였다. 이러한 연구에서 사용된 신경회로망은 순방향(feed forward) 구조의 신경망으로 동적 시스템의 구현에는 한계가 있다. Yabuta^[6]는 시간지연 신경망(Time Delayed Neural Network, TDNN) 모델을 제안하여 동적 시스템에 적용될 수 있음을 보였다. 그러나, 시간 지연 신경망은 대상 시스템에 대한 지연 차수의 결정이 선행되어야 하고, 시스템 환경 변화에 따라 대응할 수 있는 유연성을 적절히 제공해 주지 못하는 단점이 있어서 시스템 구현 시 어려움이 있으며 동적 비선형 시스템에 적응력이 떨어진다. 이를 극복하기 위하여 출력의 일부를 입력으로 궤환시켜 동적 특성을 향상시키는 리커런트 신경망(recurrent neural networks) 구조를 사용하게 되었다^[6-8]. 그러나 리커런트 신경망은 초기의 학습속도가 느리며, 상호 커플링이 심한 로봇을 제어하는 경우 리커런트 신경망에 사용되는 뉴런의 수가 지나치게 증가함으로써 온-라인(on-line) 학습이 어렵고 학습 시간이 오래 걸린다는 단점을 가진다. 이러한 단점 때문에 로봇과 같이 정확성과 빠른 궤적 추적이 요구되는 분야에는 적합하지 않다. 이러한 신경망 자체의 한계를 극복하기 위하여

RBF 신경망 등과 같이 학습능력을 향상시키기 위한 연구가 진행되어 왔으나 아직은 미흡한 형편이다.

이러한 문제를 해결하기 위하여 카오틱 신경망(Chaotic Neural Networks, CNN)모델에^[9,10] 관한 연구가 진행되고 있다. Aihara^[11-15]에 의하여 제안된 카오틱 신경망은 층간 뿐 아니라 층내의 뉴런간에 결합계수를 가지고 있으며, 생리학적 신경세포의 특징인 1)적응 응답(Graded Response), 2)상관 불응성(Relative Refractoriness) 그리고 3)입력의 시·공간적인 합을 충분히 표현한다는 특징을 가지고 있다. 카오틱 신경망은 일반적인 신경망의 대표적인 단점인 지역 최소값(local minimum)에 빠질 확률이 적으며, 뉴런 자체에 충분한 비선형성을 포함하고 있는 장점을 가지고 있다. 그러나 기존의 다층 카오틱 신경망의 구조는 층간에는 다층 퍼셉트론의 구조를 가지며, 층내의 구조는 홉펠드 신경망의 구조를 가지고 있다. 그러므로 층내 결합계수에 의한 출력의 연산은 홉펠드의 시간발전 규칙을 따라 에너지 함수가 최소가 될 때까지 반복 연산이 요구되고 있다. 이러한 구조는 정해진 패턴을 사용하는 정적시스템의 구현에는 적용 가능하나, 시간의 변화에 따라 지속적으로 변화하는 입출력의 연속적인 학습이 요구되는 동적 시스템의 구현에 적용이 불가능하다. 또한 층내 뉴런간 결합계수들은 뉴런의 카오틱 특성을 제어하기 위한 목적으로만 사용되고 있으므로 커플링을 갖는 동적시스템의 모사와 제어에는 직접적인 도움을 주지 못하는 단점을 갖고 있다.

본 논문은 기존의 카오틱 신경망을 제어분야에 적용하기 위하여 카오틱 특성을 가지며 동적 특성이 강조되도록 카오틱 뉴런의 구조를 수정하고, 학습방법은 기존의 역전파 학습 알고리즘을 사용한 개선된 카오틱 신경망을 제안한다. 제안된 신경망의 동적 특성을 조사하기 위하여 3 관절의 푸마 로봇의 경로 제어에 적용한다. 제어방식은 카오틱 신경망 제어기의 학습 초기 안정성을 확보하며, PD 제어기의 출력을 보상하는 토크 보상의 역할을 수행하도록 PD 제어기와 병렬로 구성하여 직접 적응 제어 방식을 적용한다. 제안된 카오틱 신경망 제어기의 상대적인 성능 비교를 위하여 모의 실험을 통하여 리커런트 신경망 제어기의 수렴성, 오차 감소율, 그리고 연산시간의 성능을 확인한다.

II. 카오틱 신경망 구조와 학습

1. 카오틱 뉴런 모델

카오틱 신경망은 기존의 인공 신경망으로 구현할 수 없었던 생물학적 신경세포의 카오스적 특성을 구현할 수 있다. Nagumo와 Sato^[10]는 Caianiello^[9]의 고전적인 카오틱 뉴런 모델을 과거의 출력에 의한 불응성(refractoriness)의 영향이 시간에 따라 지수 함수적으로 감소한다는 가정 하에서 단일 입력에 대한 응답 특성을 다음과 같이 제안하였다.

$$x(t+1) = f_h \left(A(t) - \alpha \sum_{r=0}^t k^r g(x(t-r)) - \theta \right) \quad (1)$$

여기서 $x(t)$ 는 시간 t 에서의 뉴런의 출력을 나타내며, $f_h(\cdot)$ 는 뉴런의 활성화함수로서 단위 계단함수이다. $A(t)$ 는 시간 t 에서 외부 입력신호의 크기, α 는 상수 파라메타 ($\alpha \geq 0$), k^r 은 불응성의 시간 감쇠 상수 ($0 \leq k \leq 1$), $g(\cdot)$ 는 불응함수, θ 는 문턱치를 나타낸다.

Aihara에 의하여 제안된 다층 카오틱 신경망은 그림 1과 같은 단일 뉴런 모델이 각각의 노드로 구성된 다입력 다출력(MIMO)의 구조를 가진다. 카오틱 신경망에서 은닉층과 출력층의 뉴런 i 의 출력은 다음과 같다.^[11,12]

$$x_i(t+1) = f \left(\sum_{j=1}^N V_{ij} \sum_{r=0}^t k_I^r I_j(t-r) + \sum_{j=1}^M W_{ij} \sum_{r=0}^t k_H^r h(x_j(t-r)) - \alpha \sum_{r=0}^t k_G^r g(x_i(t-r)) - \theta_i \right) \quad (2)$$

$$W_{ij} = W_{ji}, \quad W_{ii} = 0$$

여기서 W_{ij} 는 같은 층내의 j 번째 뉴런과 i 번째 뉴런과의 결합계수이고, V_{ij} 는 하위층의 j 번째 뉴런과 상위층의 i 번째 뉴런과의 결합계수를 의미한다. $f(\cdot)$ 는 뉴런의 활성화함수로 시그모이드함수, $I_j(\cdot)$ 는 하위층의 j 번째 뉴런에서 상위층의 i 번째 뉴런으로의 입력 세기에 대한 함수, $h(\cdot)$ 는 층내 뉴런 사이의 전승 활성화전위에 대한 축삭의 전달함수로 Hard limiter logic 혹은 연속함수를 가짐, 그리고 $g(\cdot)$ 는 뉴런 자신의 불응함수로 Hard limiter logic 혹은 연속함수 가진다. N 과 M 은 하위 층으로부터 인가되는 뉴런의 수와 신경망 내의 은닉층의 뉴런 수를 나타낸다. k_I^r ,

k_H^r 그리고 k_G^r 은 0와 1사이의 값을 가지며 각각 시간 r 에서의 외부 입력항, 다른 뉴런으로부터의 궤환 입력 항, 그리고 뉴런 자신에 대한 시간 감쇠상수이며, θ_i 는 i 번째 뉴런의 문턱치이다.




그림 1. 카오틱 뉴런 모델

Fig. 1. Chaotic neuron model.

식 (2)에서 시간 감쇠상수가 시간의 변화에 따라 동일할 경우 $k_I^r = k_I$, $k_H^r = k_H$, $k_G^r = k_G$ 로 정의된다. 또한, 식 (2)에서 시간 $t+1$ 에서의 임의의 뉴런 i 의 하위층으로부터의 입력에 의한 내부 상태 값을 $\xi_i(t+1)$, 신경망내의 동일층에서 다른 뉴런으로부터의 궤환에 의한 내부 상태 값을 $\eta_i(t+1)$, 그리고 불응성에 의한 내부 상태 값을 $\zeta_i(t+1)$ 로 정의하면 다음과 같이 표현될 수 있다.^[12]

$$\xi_i(t+1) = k_I \xi_i(t) + \sum_{j=1}^N V_{ij} I_j(t) \quad (3)$$

$$\eta_i(t+1) = k_H \eta_i(t) + \sum_{j=1}^M W_{ij} h(f(y_j(t))) \quad (4)$$

$$\zeta_i(t+1) = k_G \zeta_i(t) - \alpha g(f(y_i(t))) - \theta_i(1 - k_G) \quad (5)$$

$$y_i(t+1) = \xi_i(t+1) + \eta_i(t+1) + \zeta_i(t+1) \quad (6)$$

$$x_i(t+1) = f(y_i(t+1)) \quad (7)$$

식 (3)-(7)에서 외부 입력항, 다른 뉴런으로부터의 궤환 입력 항, 그리고 뉴런 자신에 대한 시간 감쇠상수가 같다고 ($k = k_I = k_H = k_G$)로 정의하고, $h(\cdot)$ 와 $g(\cdot)$ 를 항등함수($h(x) = x$, $g(x) = x$)로 정의하면 식 (6)과(7)은 식 (8)과 (9)로 표현된다.^[13,14]

$$y_i(t+1) = k y_i(t) + \sum_{j=1}^N V_{ij} I_j(t) + \sum_{j=1, j \neq i}^M W_{ij} f(y_j(t)) - \alpha f(y_i(t)) - \theta_i(1 - k) \quad (8)$$

$$x_i(t+1) = f(y_i(t+1)) \quad (9)$$

여기서 $W_{ij} = W_{ji}$, $W_{ii} = 0$ 으로 정의된다.

기존의 다층 카오틱 신경망의 구조는 층간 뉴런간의 결합계수는 일반적인 퍼셉트론의 형태를 가지며, 층내 뉴런간의 결합계수는 양방향의 대칭의 형태를 갖는다. 그러므로, 신경망의 학습은 층간의 경우는 오차 역전파 알고리즘에 의해 이루어지고, 층내의 학습은 홉필드의 시간 발전 규칙에 의해 이루어지므로 2가지 학습 규칙이 동시에 적용된다. 층내 결합계수는 식 (10)과 같이 상호상관행렬(auto-correlation matrix)에 의하여 설정된다.

$$W_{ij} = \frac{1}{P} \sum_{M=1}^P (2x_i^M - 1)(2x_j^M - 1) \quad (10)$$

여기서 P 는 저장된 패턴의 수, x_i^M 은 저장된 M 번째 패턴의 i 번째 요소를 나타낸다.

카오틱뉴런의 출력은 홉필드의 시간발전 규칙 (Chaotic Simulated Annealing: CSA)에 의하여 이루어진다. CSA의 방법은 식 (11)에 보인 것과 같이 에너지를 최소화하여 안정점을 찾아 출력이 변화가 없을 때까지 계속된다. [14-16]

$$-\frac{\partial E}{\partial x_i(t)} = \sum_{j=1, j \neq i}^M W_{ij}x_j(t) + \theta_i \quad (11)$$

이러한 학습 구조는 제어 분야에서의 사용에 다음과 같은 문제점을 가지고 있다. 첫째, 층내 결합계수는 스토캐스틱한 방법에 의한 갱신이 아니라 제한된 입력패턴을 사용하여 상호상관행렬에 의하여 결정되므로 정적(static) 패턴에 적용 가능하나 시간의 변화에 따라 연속적으로 변화하는 동적시스템에 적용은 불가능하다. 둘째, 제어대상을 제어하기 위해서는 원하는 출력을 가지는 교사가 있는 학습 방법을 적용하여 각 결합계수를 갱신하여야 한다. 그러나 기존의 카오틱 신경망은 외부의 교사 신호에 의해 출력의 값이 결정되지 않고 CSA 방법을 사용하여 내부 상태에 따라 출력 값이 결정된다. 셋째, 층간 결합계수는 오차 역전파 알고리즘을 사용하여 갱신되며, 층내 결합계수는 CSA방법이 적용되어 안정점을 찾기 위하여 사용되므로 두 방법이 상충되는 효과를 가져올 수 있다. 또한, 층내 결합계수의 설정은 뉴런의 카오틱 신호를 제어하기 위하여 사용되므로, 커플링을 갖는 동적시스템의 구현에는 도움을 주지 못하고 있는 문제점을 갖고 있다.

2. 개선된 동적 카오틱 뉴런모델

기존의 카오틱 뉴런의 구조는 식 (8)의 $\sum_{j=1, j \neq i}^M W_{ij}f(y_j(t))$ 항과 같이 층내 뉴런간 홉필드의 학습을 위하여 같은 층내의 결합계수 W_{ij} 를 $i=j$ 인 경우 $W_{ii}=0$ 으로 정의하였으며, 대칭의 양방향 결합계수 ($W_{ij}=W_{ji}$)로 정의하였다. 그리고 자기회환을 보상하기 위하여 $-af(y_i(t))$ 항을 첨가하였다. 이와 같은 대칭의 결합계수의 설정은 같은 층내의 두 뉴런이 서로 같은 영향을 준다는 가정 하에 설정되었으나, 커플링을 갖는 비선형 동적 시스템의 모사에 적용하는 경우 다른 영향을 주고 있으므로 적절하지 못하며 신경망의 데이터의 저장능력을 약화시키고 있다. 또한, 파라미터 α 는 자기회환 결합계수로 최적화를 위하여 학습을 통하여 갱신되도록 하는 것이 이상적이며, 신경망의 구성 시 파라미터의 값을 경험에 의하여 설정하여야 하는 어려움을 가지고 있다. 개선된 동적 카오틱 뉴런모델은 커플링을 갖는 다변수 비선형 동적 시스템의 모사에 적용하기 쉬우며 신경망의 데이터의 저장능력을 향상 시키기 위하여 단방향의 비대칭의 결합계수 ($W_{ij} \neq W_{ji}$)로 설정하였다. 자기회환 파라미터 α 는 결합계수 W_{ii} 로 설정하여 $W_{ij}f(y_j(t))$ 로 설정하여 학습을 통하여 파라미터의 값이 결정되도록 구성하였다. 이와 같이하여 층내 회환입력은 $\sum_{j=1}^M W_{ij}f(y_j(t))$ 항으로 간략화 된다. 또한, 신경망의 구성 시 설정해야 될 파라미터를 최소화하기 위하여 문턱치 항인 $\theta_i(1-k)$ 항을 영으로 정의하여 간략화 하였다. 개선된 카오틱 뉴런의 모델은 그림 2와 같다.




그림 2. 개선된 카오틱 뉴런 모델
Fig. 2. Modified chaotic neuron model.

개선된 동적 카오틱 뉴런모델은 다음과 같이 표현된다.

$$y_i(t+1) = ky_i(t) + \sum_{j=1}^M V_{ij}I_j(t) + \sum_{j=1}^M W_{ij}f(y_j(t)) \quad (12)$$

$$x_i(t+1) = f(y_i(t+1)) \quad (13)$$

$$f(y_i(t+1)) = \frac{1}{1 + e^{-y_i(t+1)/\epsilon}} \quad (14)$$

여기서 ϵ 은 시그모이드 함수의 기울기이다.

그러므로 카오틱 뉴런의 출력은 불응항 $ky_i(t)$, 제한 입력 $\sum_{j=1}^M W_{ij}f_j(y_j(t))$, 그리고 외부입력 $\sum_{j=1}^N V_{ij}I_j(t)$ 의 합으로 구성하였다. 식 (12)와 같이 신경망의 구성 시 설정해야 될 뉴런의 파라미터는 불응항의 시간 감쇠상수 k 만을 설정하면 된다.

3. 개선된 카오틱 신경망

기존의 카오틱 신경망은 같은 층 내의 뉴런사이에 대칭의 양방향 연결을 가지는 한 개의 결합계수로 이루어진 반면, 제안된 신경망 구조는 층 내 뉴런간에 비대칭의 단방향 결합을 갖는 2개의 결합계수를 갖도록 구성하였다. 이 구조는 생물의 신경망에서 뉴런간의 시냅스 결합이 완전히 비대칭이라는 사실에 충실한 것으로서 기존의 카오틱 신경망 모델 보다 좀더 생리학적인 신경망에 접근함을 의미한다. 또한 자기회환 결합계수도 갱신하도록 구성하였다. 이와 같은 신경망의 구조는 커플링을 갖는 다변수 비선형 시스템에 적용하여 카오틱 신경망의 동적 특성을 향상시키며, 신경망의 데이터 저장능력을 향상시킨다.

그림 3은 개선된 카오틱 신경망의 구조로 N 개의 뉴런을 갖는 입력층 i , M 개의 뉴런을 갖는 은닉층 j , 그리고 P 개의 뉴런을 갖는 출력층 k 로 구성된 구조를 보여 주고 있다. V^H , V^O 은 입력층과 은닉층 그리고 은닉층과 출력층 사이의 결합계수 벡터, 그리고 W^H , W^O 은 은닉층과 출력층 내부의 결합계수를 나타




그림 3. 제안된 카오틱 신경망

Fig. 3. Proposed chaotic neural networks.

낸다. $x_1^i(t)$, $x_j^j(t+1)$, $x_k^o(t+1)$ 는 각각 입력층, 은닉층, 그리고 출력층의 뉴런의 출력을 나타낸다. 제안된 카오틱 신경망의 초기 결합계수들은 임의로 설정되고, 입력층의 뉴런은 입력신호를 처리하지 않고 그대로 출력하게 하였으며, 입력 층을 제외한 모든 층의 뉴런은 활성화함수와 불응성을 갖도록 하였다. 뉴런의 활성화함수 $f(\cdot)$ 는 시그모이드 함수를 선택하였다.

4. 카오틱 신경망의 학습

카오틱 신경망의 결합계수의 학습은 오차 역전파 알고리즘을 이용하였다. 층간 및 층내 결합계수의 학습에 사용되는 시각 t 에서의 원하는 출력 $\hat{x}_k^o(t)$ 과 신경망의 실제 출력 $x_k^o(t)$ 과의 차이에 대한 제곱으로 정의되며 신경망의 오차함수는 다음과 같이 표현된다.

$$e_k(t) = \hat{x}_k^o(t) - x_k^o(t) \quad (15)$$

$$J(t) = \frac{1}{2} \sum_k [e_k(t)]^2 \quad (16)$$

층간의 결합계수는 최종 출력 오차가 최소화되도록 갱신되며 오차함수를 각 층의 결합계수에 대하여 편미분함으로써 구할 수 있다. 출력층과 은닉층 사이의 결합계수의 변화율은 다음과 같이 계산된다.

$$\frac{\partial J(t)}{\partial V_k^o(t)} = \frac{\partial J(t)}{\partial x_k^o(t)} \cdot \frac{\partial x_k^o(t)}{\partial y_k^o(t)} \cdot \frac{\partial y_k^o(t)}{\partial V_k^o(t)} \quad (17)$$

$$= -\delta_k(t) x_j^H(t)$$

$$\delta_k(t) = e_k(t) \cdot x_k^O(t) \cdot (1 - x_k^O(t)) \quad (18)$$

여기서 $y_k^o(t)$ 는 출력층 k 번째 뉴런의 내부상태 값이다. 은닉층의 j 번째 뉴런과 입력층의 i 번째 뉴런 사이의 결합계수의 변화율은 동일한 방식으로 계산된다.

$$\frac{\partial J(t)}{\partial V_{jk}^o(t)} = \frac{\partial J(t)}{\partial x_j^H(t)} \cdot \frac{\partial x_j^H(t)}{\partial y_j^H(t)} \cdot \frac{\partial y_j^H(t)}{\partial V_{jk}^o(t)} \quad (19)$$

$$= -\delta_j(t) x_i^i(t)$$

$$\delta_j(t) = x_j^H(t) (1 - x_j^H(t)) \sum_k \delta_k(t) V_{jk} \quad (20)$$

여기서, $x_i^i(t)$ 는 입력층 i 번째 뉴런의 출력으로 입력 뉴런의 활성화함수를 항등함수로 설정함으로써 실제 입력값에 해당한다. 오차 역전파 알고리즘에 의한 층간 결합계수의 갱신은 다음 식으로 표현된다.

$$\Delta v_{jk}(t+1) = \eta \cdot \delta_j(t) \cdot x_i(t) + \alpha \cdot \Delta v_{jk}(t) \quad (21)$$

여기서 $i=1,2,\dots,N, j=1,2,\dots,M$ 이며 M 은 상위층의 뉴런의 수를, N 은 하위층의 뉴런의 수를 의미한다. 층내의 뉴런사이의 결합계수는 층간 결합계수에 적용된 식(17)-(20)에 층내 뉴런사이의 결합계수를 적용하여 사용하며 결합계수의 갱신은 다음 식으로 표현된다.

$$\Delta w_{ji}(t+1) = \eta \cdot \delta_j(t) \cdot x_i(t) + \alpha \cdot \Delta w_{ji}(t) \quad (22)$$

여기서 $i, j=1, 2, \dots, M$, η 와 α 는 각각 학습률과 모멘텀을 의미한다. 상기 식에서 i 와 j 가 동일한 값을 가질 경우 뉴런 자신의 자기회환 결합계수가 갱신된다.

III. 로봇 경로 제어를 위한 적응 카오틱 신경망 제어기의 설계

제안된 카오틱 신경망을 이용하여 푸마 로봇의 경로를 제어하기 위한 적응제어 시스템 구조는 그림 4와 같다.

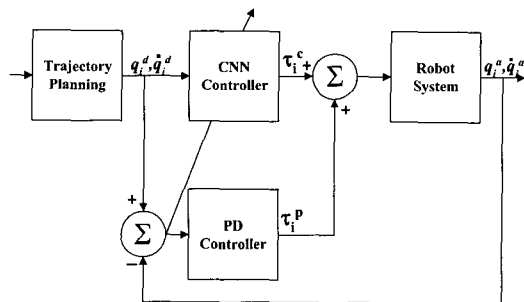


그림 4. 로봇 경로제어 시스템의 구조
Fig. 4. Structure of robotic trajectory control system.

로봇의 경로제어 시스템은 카오틱 신경망 제어기와 PD 제어기가 병렬로 연결되어 있으며, 적응 카오틱 신경망 제어기는 로봇의 경로 계획에 따라서 각 관절 각과 관절 각속도를 신경망 제어기의 입력으로 사용하였다. PD제어기의 출력 토크는 식 (23)과 같으며 각 관절 각과 관절 각 속도의 오차에 의해 결정된다.

$$\tau_{b_i}(t) = k_p(q_i^d(t) - q_i^i(t-1)) + k_d(\dot{q}_i^d(t) - \dot{q}_i^i(t-1)) \quad (23)$$

각 관절의 경로가 경로 계획기에 의해 결정되면, 이를 이용하여 PD 제어기와 카오틱 신경망 제어기는 각

각의 출력 토크를 계산하여 로봇의 각 관절 구동 모터의 입력으로 들어간다. 구동 모터에 의해 실제의 경로가 결정되고 이때의 각 관절 각의 오차에 의해 카오틱 신경망이 학습되며 이러한 반복적인 과정을 통하여 원하는 허용 오차까지 감소하게 되면 신경망의 학습은 종료된다. 카오틱 신경망 제어기는 로봇의 각 관절 각의 오차를 최소화하는 방향으로 지속적으로 학습이 이루어지므로 실제적으로 직교 좌표계에서의 각 좌표 값의 오차를 최소화하게 되어 원하는 경로에 접근하게 된다.

PD 제어기는 선형 궤환제어기(feedback controller)로서 제어시스템의 안정성을 보장하여 주고 있으나 제어대상의 비선형성에 적응하지 못한다. 그러므로 카오틱 신경망을 이용한 피드포워드(feedforward) 제어기를 첨가하여 비선형성을 보상하는 제어기를 구성하였다. 따라서 최종적인 로봇의 경로제어는 PD제어기와 카오틱 신경망의 토크 출력의 합에 의해 제어된다. 그러므로 제어초기 혹은 순간적인 외부 입력의 변화가 있을 경우 PD 제어기에 의하여 안정성이 보장되며, 동시에 신경망 제어기가 학습을 통하여 비선형성을 보상하여 정밀한 제어를 수행하게 된다.

상기에서 제안된 카오틱 신경망 제어기의 장점은 다음과 같다.

- 1) 직접 적응 제어 기법을 이용하여 제어기를 설계할 수 있으므로 추가적인 신경망 추정기가 불필요하여 제어 대상을 추정하기 위한 시간이 단축되었다.
- 2) 카오틱 신경망은 층내 결합에 의한 상호 커플링이 존재하여 일반적인 수학적 제어 규칙을 정하기 어려운 제어 대상의 모델링에 더욱 효과적으로 사용할 수 있으며, 층내와 층간 결합 계수의 갱신을 오차 역전파 알고리즘을 사용하여 오차 함수의 값을 최소화함으로써 제어 대상의 제어에 효율성을 향상시켰다.

IV. 시뮬레이션 및 결과

제안된 카오틱 신경망 제어기의 성능을 평가하기 위하여 비교 대상 제어기로 리커런트 신경망을 사용하였으며, 카오틱과 리커런트 신경망 구조는 다음과 같다.

카오틱 신경망은 은닉층이 하나인 다층 신경망 구조로서 입력은 경로 계획에 의한 관절 각 3개($q_x, q_y,$

q_z)와 각속도 3개($\dot{q}_x, \dot{q}_y, \dot{q}_z$)로 구성된 6개의 입력 뉴런을 가지며, 은닉 층은 10개 뉴런으로 실험에 의해 설정되었으며, 출력 층은 PD 제어기를 보상하는 토크 성분을 출력하기 위해 3개의 뉴런을 갖도록 설계하였다. 각 층 사이의 결합계수와 각 층내의 결합계수는 $-0.5 \sim +0.5$ 범위 내에서 임의의 값으로 초기화하였다. 기울기가 1.0인 시그모이드 함수를 활성화함수로 사용하였으며, 학습률은 0.3, 바이어스는 1.0, 모멘텀률은 0.6, 시간 감쇠지수는 모두 0.7로 동일하게 사용하였다. 리커런트 신경망의 입·출력 뉴런의 수는 카오틱 신경망과 동일하며, 은닉층에 40개의 뉴런을 두고 이들 중 10개의 뉴런이 입력층으로 재환되는 부분 리커런트 신경망(partially connected RNN)을 사용하였다. 각 층사이의 결합계수는 $-0.5 \sim +0.5$ 내의 임의의 값으로 초기화하였고, 기울기가 1인 중형함수를 활성화함수로 사용하였으며, 학습률은 0.08로 설정하였다. 학습법칙은 카오틱 신경망과 동일한 오차 역전파 알고리즘을 적용하였다. 3축 푸마 로봇의 경로 제어 시스템에 적용된 오차는 로봇 링크 i 의 원하는 관절 각 $q_i^d(t)$ 과 실제로 로봇이 움직인 관절 각 $q_i^e(t)$ 의 차이 함수를 사용하였다. 따라서 신경망의 학습은 로봇의 각 관절 각 오차를 최소화하는 방향으로 결합계수가 갱신된다. 카오틱 신경망과 병렬로 연결된 PD 제어기는 로봇의 각 축에 대하여 독립적으로 제어하도록 3개로 구성하였으며, 비례 이득과 미분 이득을 각각 50과 10으로 고정하였다.

사용된 3축 푸마 로봇의 경로는 다음과 같이 계획하였다.

$$x(t) = -0.149100 - 0.09 \cdot \cos\left(\frac{100}{180}\pi\right) + 0.09 \cdot \cos\left(\frac{\pi}{180}r(t)\right) \quad (24)$$

$$y(t) = 0.798218 - 0.09 \cdot \sin\left(\frac{100}{180}\pi\right) + 0.09 \cdot \sin\left(\frac{\pi}{180}r(t)\right) \quad (25)$$

$$z(t) = 0.428613 \quad (26)$$

$$r(t) = 3.6t, \quad 0 \leq t \leq 180 \quad (27)$$

식 (24)~(27)은 중심이 $(x, y, z) = (-0.133472, 0.719585, 0.428613)$ 이며 반경이 0.09[m]인 원 궤적을 의미한다. 로봇의 초기위치 $(x, y, z) = (-0.149100, 0.798218, 0.428913)$ 이고 기본자세는 LEFT와 ABOVE arm의 구조를 가진다. 원 궤적의 운동시간

은 5.0초, 샘플링 주기는 0.05초로 설정하였고 평균 속도는 0.1131[m/sec]이다. 최종적인 원 궤적 추적에 있어서 허용오차는 각 축 방향으로 ± 0.002 [m] 이내로 하였다. 1000회 학습 후 경로추적 상태를 그림 5에 나타내었다. 그림에서 알 수 있듯이 1000회 학습 후의 카오틱 신경망과 리커런트 신경망 제어기는 원하는 경로를 위한 PD 제어기의 출력 토크 보상에서 현격한 차이를 나타내었다. 카오틱 신경망 제어기는 주어진 경로에 거의 접근하여 학습이 완료됨을 보인 반면 리커런트 신경망 제어기는 목표 값과 여전히 큰 오차가 보여 더욱 많은 학습이 필요함을 나타내었다. 또한, 학습 초기에 결합계수의 임의 설정으로 카오틱 신경망 제어기의 오차가 리커런트 신경망 제어기보다 더 큰 오차를 가졌으나 학습이 진행됨에 따라 경로 추적 오차가 급격히 감소하여 8회 학습 후, 카오틱 신경망 제어기의 정규화 오차가 리커런트 신경망 제어기의 오차보다 더 작은 값을 갖게 됨을 확인할 수 있었다.





그림 5. 1000회 학습후의 궤적 추적 상태

Fig. 5. Status of trajectory tracking after 1000 iterations. (----:target oooo:CNN +++++:RNN)


그림 6은 1000회 학습 후, 로봇 매니플레이터의 운동 시간 동안 각 축방향에 대한 카오틱 신경망 제어기와 리커런트 신경망 제어기의 추적 상태를 보여주고 있다. 카오틱 신경망 제어기는 모든 축에 대한 추적상태가 양호하나, 리커런트 신경망 제어기의 경우 x축만을 제외하고는 실제경로와의 오차가 크다. 특히 z축의 값은 일정하게 유지되어야 하나 리커런트 신경망 제어기에서는 현격한 오차를 보여주고 있으며 실험에 의하면 6000회 이상의 많은 학습이 요구되었다.

카오틱 신경망 제어기와 리커런트 신경망 제어기의 최대 위치오차를 비교하여 보면 x축에 대해서 카오틱 신경망은 0.004281의 최대 위치오차를 가지는 반면 리커런트 신경망 제어기는 0.009386의 값을 가진다. y


축의 경우 카오틱 제어기와 리커런트 제어기는 각각 0.001539와 0.015878의 최대 오차 값을 가짐을 확인 하였다. z-축에 대해서는 카오틱 제어기가 0.001820의 최대 위치오차를 가지는 반면 리커런트 제어기는 0.022909의 값으로 원하는 오차의 범위(0.002)로 수렴 하지 않았다.



(a) X 축



(b) Y 축



(c) Z 축

그림 6. 1000회 학습 후의 각 축의 경로 추적
Fig. 6. Trajectory tracking of each axis after 1000 iterations.
(---:target ooo:CNNs +++:RNNs)

학습회수에 따른 카오틱 신경망 제어기와 리커런트 신경망 제어기의 정규화 오차를 표 1에 제시하였다.

표 1. 학습에 따른 정규화 오차 비교
Table 1. Comparison of normalized errors with iterations.

	CNN[m]	RNN[m]
1회	0.019232	0.005543
5회	0.003444	0.005522
100회	0.002796	0.004350
200회	0.001289	0.003823
500회	0.000178	0.001952
1000회	0.000172	0.000760

그림 7은 1000회 학습하는 동안의 각 축에 대한 정규화 오차(Normalized Error)의 변화 과정을 보여주고 있다. 리커런트 신경망 제어기는 완만한 오차의 감소를 보이는 반면 카오틱 신경망 제어기는 학습 초기에 급격한 오차 감소를 가진다는 것을 알 수 있다. 이는 로봇의 경로 제어에 카오틱 신경망 제어기가 온라인 제어가 가능함을 의미한다.




그림 7. 정규화 오차의 변화
Fig. 7. Normalized error curves.

V. 결론

본 논문에서는 수정된 카오틱 신경망과 PD제어기를 사용하여 직접 적응 제어 방식으로 3축 푸마 로봇의 경로 추적제어기의 구성에 관한 연구를 하였다. 기존의 카오틱 신경망을 제어기로 사용하기 적합한 구조로 변형하였고 수정된 신경망을 오차 역전파 알고리즘을 이용하여 학습하였다. 카오틱 뉴런 각각이 하위 층의

뉴런, 같은 층의 뉴런 및 자신의 과거 값에 의해 영향을 받아서 뉴런의 동 특성이 증가함으로 복잡한 시스템에 대해서도 제어가 용이하다는 장점을 가진다. 수정된 신경망을 이용하여 3축 로봇의 경로 추적을 위한 직접 적응 제어기를 설계하고 이를 모의 실험하였다. 실험 결과 카오틱 신경망 제어기는 기존의 리커런트 신경망 제어기에 비해 우수한 제어능력을 보여주었으며, 짧은 계산 시간 내에서 제어 가능성이 확인되었다. 컴퓨터 시뮬레이션 결과에 의하면 1000회 학습시 학습 속도가 약 4.38배 향상되었으며 정규화 오차는 1/4.42배로 감소되었다. 카오틱 신경망 제어기가 Pentium II 300MHz 사용 시 로봇 동역학 계산 시간을 포함하여 2.19[ms]가 걸림으로 푸마 로봇의 실시간 제어가 될 수 있는 실용성을 확보할 수 있다. 이러한 빠른 계산 시간과 오차 감소 능력에 의존하여 간접 적응제어 기법에서 요구되는 플랜트 추정기가 필요 없는 직접 적응제어 기법을 도입함으로써 추정기의 오프라인(off-line) 학습에 소요되는 시간을 없애고 단지 관측 각의 오차만으로 카오틱 신경망의 결합계수를 학습시킴으로서 제어기로서의 효율성을 극대화하였다.

참 고 문 헌

- [1] J.J. Craig, P. Hsu, and S. Sastry, "Adaptive Control of Mechanical Manipulators", *IEEE Int. Conf. on Robotics Automat.*, SF, CA, 1986.
- [2] J. J. E. Slotine and W. Li, "Adaptive Manipulator Control: A Case Study", *IEEE Trans. on Automatic Control*, Vol. 33, No. 11, pp. 995-1003, November 1988.
- [3] M. Kawato, Y. Uno, M. Isobe, and R. Suzuki, "Hierarchical Neural Network Model for Voluntary Movement with Application to Robotics," *IEEE Control Systems Magazine*, pp. 8-16, April 1988.
- [4] H. Miyamoto, M. Kawato, T. Setyama, and R. Suzuki, "Feedback Error Learning Neural Network for Trajectory Control of a Robotic Manipulator," *Neural Networks*, Vol. 1, No. 3, pp. 251-265, 1988.
- [5] T. Ozaki, T. Suzuki, T. Furuhashi, S. Okuma, and Y. Uchikawa, "Trajectory Control of Robotic Manipulators Using Neural Networks," *IEEE Trans. on Industrial Electronics*, Vol. 38, No. 3, pp. 195-202, June 1991.
- [6] T. Yabuta and T. Yamada, "Neural Network Controller Characteristics with Regard to Adaptive Control," *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. 22, No. 1, pp. 170-177, 1992.
- [7] L. Jin, P. N. Nikiforuk, and M. M. Gupta, "Dynamics and Stability of Multilayered Recurrent Neural Networks," *Proc. of Int. Joint Conf. on Neural Networks*, pp. 1135-1140, SF, CA, 1993.
- [8] Y. Fang and T. J. Sejnowski, "Faster Learning for Dynamic Recurrent Back-propagation", *Neural Computation*, Vol. 2, No 3, pp. 270-273, 1990.
- [9] E. R. Caianiello, "Outline of a Theory of Thought-Processes and Thinking Machines," *J. Theor. Biol.*, Vol 2. pp 204-235, 1961.
- [10] J. Nagumo and S. Sato, "On a Response Characteristics of a Mathematical Neuron Model," *Kybernetik* 10, pp. 155-164, 1972.
- [11] K. Aihara, T. Takabe and M. Toyoda, "Chaotic Neural Networks," *Phys. Lett A*144, pp. 333-340, 1990.
- [12] K. Shimiza, K. Aihara and M. Kotani, "An Electronic Circuit Model of Chaotic Neural Networks," *Electronics and Communications in Japan Part 3*, Vol. 73. pp. 51-64 1991.
- [13] M. Adachi, K. Aihara, M. Kotani, "An Analysis of Associative Dynamics in A Chaotic Neural Network with External Stimulation," *Proc. of IJCNN*, pp. 409-412, 1993.
- [14] L. Chen, K. Aihara, "Chaotic Annealing by a Neural Network Model with Transient Chaos", *Neural Networks*, Vol. 8, No. 6, pp. 915-930, 1995.
- [15] I. Tokuda, T. Nagashima, K. Aihara,

"Global Bifurcation of Chaotic Neural Networks and its Application to Traveling Salesman Problems", Neural Networks, Vol. 10, No. 9, pp. 1673-1690, 1997.

[16] T.Kwok, K.A.Smith, "A Unified Frame Work for Chaotic Neural-Network Approaches to Combinational Optimization", IEEE Trans. on Neural Networks, Vol. 10, No. 4, pp. 978-981, 1999.

저 자 소 개



張 昶 華(正會員)

1968년 8월 20일생. 1993년 금오공과대학교 전자공학과 학사. 1997년 금오공과대학교 대학원 전자공학과 석사. 1999년 2월 금오공과대학교 박사과정 수료.주관심분야: 비선형 제어 시스템이론, 건설제어, 신경회

로망



金 相 熙(正會員)

1960년 1월 19일생. 1983년 홍익대학교 전기공학과 학사. 1985년 연세대학원 전기공학과 석사. 1992년 Texas A&M University 공학박사. 1993년~현재 금오공과대학교 전자공학부 부교수. 관심분야: 신경

회로망, 카오스 이론, 제어계측



安 熙 旭(正會員)

1960년 2월 20일생. 1982년 서울대학교 전기공학과 학사. 1991년 한국과학기술원, 전기 및 전자공학과 석사. 1997년 한국과학기술원 전기전자공학과 공학박사. 1982년~1998년 산업기술시험원 선임연구원.

1998년~현재 금오공과대학교 전자공학부 전임강사. 관심분야: 디지털전력변환회로, 고주파인버터, 모터제어