

Prefilter 형태의 카오틱 신경망 속도보상기를 이용한 로봇 제어기 설계

論 文
50D-4-4

Prefilter Type Velocity Compensating Robot Controller Design using Modified Chaotic Neural Networks

洪壽東* · 崔雲夏** · 金相熙***
(Su-Dong Hong · Un-Ha Choi · Sang-Hee Kim)

Abstract - This paper proposes a prefilter type velocity compensating control system using modified chaotic neural networks for the trajectory control of robotic manipulator. Since the structure of modified chaotic neural networks(MCNN) and neurons have highly nonlinear dynamic characteristics, MCNN can show the robust characteristics for controlling highly nonlinear dynamics like robotic manipulators. For its application, the trajectory controller of the three-axis robot manipulator is designed by MCNN. The MCNN controller acts as the compensator of the PD controller. Simulation results show that learning error decrease drastically via on-line learning and the performance is excellent. The MCNN controller showed much better control performance and shorter calculation time compared to the RNN controller. Another advantage of the proposed controller could be attached to conventional robot controller without hardware changes.

Key Words : Chaotic Neural Networks(CNN), PD controller, prefilter type compensator

1. 서 론

로봇 매니플레이터의 제어는 일반적으로 수학적 모델링에 기초한 궤환 제어나 적응 제어 기법 등이 연구되어 왔다 [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 어렵기 때문에 일정한 형태의 수식에 의한 제어 규칙을 정하는 데는 한계가 있다.

인공 신경망을 이용한 제어방식은 이러한 한계를 극복하기 위한 새로운 시도로 Kawato[3]등의 연구는 신경망을 로봇의 제어기로 이용 가능성을 시사하였고, Miyamoto[4] 등은 로봇의 역동역학(Inverse Kinematics)을 계층 신경망(Hierarchical Neural Networks) 모델에 의해 학습시킴으로써 로봇의 경로 제어 효과를 한층 더 개선하였다. Ozaki[5] 등은 모델 학습 개념을 이용하여 2축 로봇 매니플레이터의 경로 제어 문제에 다층 신경망을 적용하였다. 그러나, 동적 시스템을 구현할 경우, 정해진 입력에 정해진 출력을 가지는 고전적인 다층신경망은 구조적인 한계를 가진다. 이러한 한계 극복하기 위하여 Yabuta[6]는 시간지연 신경망(TDNN) 모델을 제안하여 동적 시스템에 적용될 수 있음을 보였다. 그러나, 시간 지연 신경망은 대상 시스템에 대한 지연차수의 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 적용력이 떨어진다. 이러한 문제를 해결하기 위한 연구로 리커런트 신경망(Recurrent Neural Network, RNN)을 들 수 있다[7-8]. 그러나, 리커런트 신경망은 시간지연 신경망에 비하여 동적인 특성은 강화되었으나 비선형성이 강한 시스템에 적용력이 부족하며, 학습속도가 느리기 때문에 온라인 학습이 어려운 단점 때문에 로봇과 같이 커플링이 있는 비선형성이 강한 시스템에 적용에는 한계를 가진다. 이러한 신경망 자체의 한계를 극복하기 위하여 RBF 신경망 등과 같이 학습능력을 향상시키기 위한 연구가 진행되어 왔으나 비선형 동적시스템에 적용은 아직 미흡한 형편이다.

기존의 신경망의 한계를 극복하기 위한 연구로서 최근 Nagumo 와 Sato가 제안한 카오틱 뉴런[11]을 이용한 카오틱 신경망(Chaotic Neural Networks, CNN)모델에[9,12-17] 관한 연구가 진행되고 있다. Aihara[9,12,14,16,17]에 의하여 제안된 카오틱 신경망은 기존의 리커런트 신경망이 가지는 특징들 외에 생리학적 신경세포의 특징인 1)적응 응답(Graded Response), 2)상관 불응성(Relative Refractoriness) 그리고 3)입력의 시·공간적인 합을 충분히 표현한다는 특징을 가지고 있음에도 불구하고 학습방법에 있어서 카오틱 신경망의 층간 결합계수는 역전파 알고리즘에 의해 오차함수(Cost Function)의 값이 최소가 되도록 학습되고, 층내 결합계수는 홉필드(Hopfield)의 시간 발전 규칙에 의해 에너지 함수가 최소가 되도록 학습을 하게되어 있다. 두 개의 학습 규칙은 동시에 이루어지기 때문에 기존의 카오틱 신경망은 연속적인 학습이 요구되는 동적 시스템의 제어 및 모사에 부적절하다. 연속적인 학습을 위하여 김 등은 층간 및 층내

* 正 會 員 : LG電子 製品研究所 主任研究員 · 博士修了

** 正 會 員 : (柱)午星電子 研究所 先任研究員 · 碩士

*** 正 會 員 : 金鳥工大 電子工學部 副教授 · 工博

接受日字 : 2000年 1月 25日

最終完了 : 2001年 4月 14日

의 결합계수의 갱신을 위하여 역전과 알고리즘을 적용하여 동적시스템의 제어 및 모사에 적용 가능성을 제시하였다.[13,15]

본 논문에서는 기존의 카오틱 신경망의 구조적인 면과 학습에 대하여 논하고 이론적인 배경을 정리하였으며, 동적특성을 갖는 카오틱 신경망(MCNN)에 대하여 제안하였다. 제안된 카오틱 신경망은 층내 결합계수를 단 방향성을 갖도록 구성하여 동적 특성을 강화하였으며, 학습방법을 층간과 층내 모두 역전과 알고리즘을 적용하여 연속적인 학습을 가능하게 하였다. 또한, 중복되는 항을 간략화 함으로서 초기에 설정해야 되는 변수를 학습을 통하여 설정되도록 구성하였다. 본 논문에서는 제안된 카오틱 신경망의 성능을 검증하기 위하여 prefilter 형태의 카오틱 신경망 제어를 PD제어의 속도 보상기로 사용하는 3축 푸마 로봇(PUMA Robot)의 경로 제어에 적용하였다. Prefilter 형태의 보상제어기는 오차를 prefilter의 형태로 속도를 보상하여 정밀한 위치제어를 수행하므로 신경망이 제어대상의 비선형성을 보상할 수 있어야 한다. 모의 실험 결과를 기존의 리커런트 신경망 제어기의 결과와 비교하여 카오틱 신경망 제어기가 보다 우수한 제어 능력을 가지며 온라인(on-line)·실시간 제어능력을 가짐을 보였다.

2. 카오틱 신경망의 개요

2.1. 카오틱 뉴런 모델

기존의 카오틱 뉴런 모델은 일반적인 신경망의 뉴런 모델과는 달리 두 종류의 입력, 즉 같은 층의 뉴런에 의한 입력 $h_M(x_M(t))$ 과 외부로부터의 입력 $I_M(t)$ 을 동시에 가지는 구조를 가진다. 또한, 자신의 과거 값에 의한 불응항(Refractory Term)을 가진다. 카오틱 뉴런의 고전적인 모델은 Caianiello[10]에 의해 제시되었으며 다음 식과 같다.

$$x(t+1) = f \left[\sum_{r=1}^N w_{ij}^{(r)} \cdot x(t-r) - \theta \right] \quad (1)$$

여기서 $x(t-r)$ 은 시각 $t-r$ 에서의 뉴런의 출력, f 는 뉴런의 활성화 함수, $w_{ij}^{(r)}$ 는 r 번째 수정된 i 와 j 번째 뉴런의 결합계수, θ 는 문턱치를 의미한다.

Nagumo와 Sato[11]의 모델은 식 (1)에 대해 과거의 출력에 의한 불응성의 영향이 시간에 따라 지수 함수적으로 감소한다는 가정 하에서 단일 입력에 적용한 경우로 식 (2)으로 표현하였다.

$$x(t+1) = f \left[A(t) - \alpha \sum_{r=0}^k k^r g(x(t-r)) - \theta \right] \quad (2)$$

여기서 $A(t)$ 는 시각 t 에서의 입력 신호의 크기, α 는 상수 파라메타 ($\alpha \geq 0$), k 는 불응성의 시간 감쇠 상수 ($0 \leq k < 1$), g 는 불응 함수를 의미한다.

카오틱 뉴런의 내부 상태는 식 (3),(4)로 표현된다.

$$y(t+1) = A(t) - \alpha \sum_{r=0}^k k^r g(x(t-r)) - \theta \quad (3)$$

$$x(t+1) = f [y(t+1)] \quad (4)$$

Aihara에 의하여 제안된 카오틱 뉴런의 기본 구조는 그림 1과 같으며 식(5)로 표현된다[9,12,16,17].




그림 1 카오틱 뉴런의 기본구조
Fig 1. Structure of Chaotic Neuron

$$x_i(t+1) = f_i \left[\sum_{j=1}^N V_{ij} \sum_{r=0}^k k_s^r I_j(t-r) + \sum_{j=1, j \neq i}^M W_{ij} \sum_{r=0}^k k_m^r h_j(x_j(t-r)) - \alpha \sum_{r=0}^k k_r^r g_i(x_i(t-r)) - \theta_i \right] \quad (5)$$

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

여기서 $x_i(t+1)$ 는 시각 $t+1$ 에서 i 번째 뉴런의 출력, W_{ij} 는 j 번째 뉴런에서 i 번째 뉴런으로의 결합계수, V_{ij} 는 외부입력 $I_j(t)$ 에서 i 번째 뉴런으로의 결합계수, $h_j(x_j(t-r))$ 는 시각 $t-r$ 에서 j 번째 뉴런의 축삭의 전달 함수, $g_i(x_i(t-r))$ 는 i 번째 뉴런의 불응 함수, $I_j(t-r)$ 는 j 번째 외부 뉴런의 입력세기, N 은 외부에서 인가되는 뉴런의 수, M 은 신경망내의 카오틱 뉴런의 수, k_s^r 는 외부입력 항에 대한 시간 감쇠 상수 ($0 \leq k_s^r < 1$), k_m^r 는 다른 뉴런으로부터의 레환 입력 항에 대한 시간 감쇠 상수 ($0 \leq k_m^r < 1$), k_r^r 는 i 번째 뉴런 자신의 불응 시간 감쇠 상수 ($0 \leq k_r^r < 1$), θ_i 는 i 번째 뉴런의 문턱치를 의미한다. 카오틱 신경망의 내부상태를 다음 식으로 표현할 수 있다.

$$\xi_i(t+1) = k_I \xi_i(t) + \sum_{j=1}^N V_{ij} I_j(t+1) \quad (6)$$

$$\eta_i(t+1) = k_H \eta_i(t) + \sum_{j=1}^M W_{ij} h_j(f_j(y_j(t))) \quad (7)$$

$$\zeta_i(t+1) = k_G \zeta_i(t) - \alpha g_i(f_i(y_i(t))) - \theta_i(1-k) \quad (8)$$

따라서 $k_I = k_H = k_G$ 라 가정하면 시간 $t+1$ 에서 i 번째 뉴런의 내부상태는 식 (9)로 표현된다.

$$y_i(t+1) = ky_i(t) + \sum_{j=1}^N V_{ij}I_j(t+1) + \sum_{j=1, j \neq i}^M W_{ij}h_j(f_j(y_j(t))) - ag_i(f_i(y_i(t))) - \theta_i(1-k) \quad (9)$$

여기서 $\xi_i(t)$, $\eta_i(t)$ 와 $\zeta_i(t)$ 는 각각 i 번째 뉴런에 있어서, 외부입력에 관한 내부상태항, 신경망 내의 다른 뉴런으로부터의 계환에 의한 내부상태항 그리고 불응성에 의한 내부 상태항을 나타낸다.

식 (9)에 의한 i 번째 뉴런의 출력은 식 (10)으로 표현된다.

$$x_i(t+1) = f[y_i(t+1)] \quad (10)$$

여기서 f 는 뉴런의 활성화 함수를 나타낸다.

(9)식의 복잡성으로 인하여 Aihara는 다음과 같이 간략화하였다.

$$y_i(t+1) = ky_i(t) + \sum_{j=1}^N V_{ij}I_j(t+1) + \sum_{j=1, j \neq i}^M W_{ij}f_j(y_j(t)) - af_i(y_i(t)) - \theta_i(1-k) \quad (11)$$

여기서 $W_{ij} = W_{ji}$, $W_{ii} = 0$

2.2. 카오틱 신경망

카오틱 신경망의 학습은 2가지의 학습규칙이 동시에 적용된다[9,12,16,17]. 카오틱 신경망의 층간 결합계수는 역전파 알고리즘에 의해 오차함수의 값이 최소가 되도록 학습되고, 층내 결합계수는 시간 발전 규칙에 의해 에너지 함수가 최소가 되도록 학습한다.

층간 결합계수 V_{ij} 는 일반적으로 가장 널리 사용되고 있는 역전파 알고리즘을 사용하여 카오틱 신경망의 오차함수의 값이 최소가 되도록 층간 결합계수를 학습시킨다. i 번째 뉴런에 대한 카오틱 신경망의 출력층 오차함수는 목표값 $x_j^d(t)$ 과 신경망의 실제출력 $x_j(t)$ 과의 차이로 다음과 같이 정의된다.

$$J(t) = \frac{1}{2} [x_j^d(t) - x_j(t)]^2 \quad (12)$$

각 층 사이의 결합계수가 최종 출력오차에 미치는 영향은 오차함수를 각 층의 연결강도에 대하여 편미분 함으로서 구할 수 있다.

층내 결합계수 W_{ij} 는 다수의 뉴런이 상호 결합한 상호결합형 모델인 홉펠드 신경망의 모델을 사용하여 상호 결합의 결합계수가 단 방향성이 아닌 양방향성을 가지며, 각 뉴런이 완전히 비 동기적으로 동작한다는 제약조건을 가지고 있다. 층내의 결합계수는 홉펠드의 시간 발전 규칙에 의해 학습된

다. [12,16,17]. 홉펠드가 제안한 신경망의 에너지 함수 $E(t)$ 는 식 (13)으로 표현된다.

$$E(t) = -\frac{1}{2} \sum_{i \neq j} w_{ij} \cdot x_i(t) \cdot x_j(t) - \sum_i \theta_i \cdot x_i(t) \quad (13)$$

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

여기서 $x_i(t)$ 와 $x_j(t)$ 는 각각 시각 t 에서의 뉴런 i 와 j 의 활성화함수 값을 표현한다. 층내의 결합계수는 신경망이 학습됨에 따라 시간 발전 규칙에 의해 식 (13)의 값이 최소가 되도록 각 결합계수를 학습하게 된다.

3. 개선된 카오틱 신경망

기존의 카오틱 신경망은 학습에 두 가지의 학습규칙이 동시에 적용되어 층내 학습에는 홉펠드 시간발전규칙이 적용되고 있으므로 연속적인 학습이 어려우며 신경망의 구조상 동적 특성이 떨어지기 때문에 동적시스템의 모사와 제어시스템의 적용이 부적절하므로 뉴런과 신경망의 구조를 개선하였다.

3.1 개선된 동적 카오틱 뉴런모델

Aihara에 의하여 제안된 기존의 카오틱뉴런은 동적시스템에 적용이 힘들기 때문에 연산시간을 줄이며 동적시스템에 적용하기 쉬운 구조로 변경하였다. 기존의 카오틱 뉴런은 층내 결합계수의 갱신에 홉펠드의 학습방법을 적용하기 위하여 (11)식의 $\sum_{j=1, j \neq i}^M W_{ij}f_j(y_j(t))$ 항은 $W_{ii} = 0$, $W_{ij} = W_{ji}$ 으로 정의하였으며, 자기계환을 보완하기 위하여 $-af(y_i(t))$ 항을 추가하였다. 개선된 신경망은 동적 특성을 향상시키기 위하여 층내 연결강도를 단방향성의 연결강도 $W_{ij} \neq W_{ji}$ 로 정의하였으며, 그리고 자기계환 연결강도를 $W_{ii} \neq 0$ 로 정의하여 α 를 연결강도로 대체하여 $\sum_{j=1}^M W_{ij}f_j(y_j(t))$ 로 정의하였다. 또한, 문턱치 항인 $\theta_i(1-k)$ 항을 영으로 정의하여 초기에 설정하여야 될 파라미터의 수를 줄였다.




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

개선된 카오틱 뉴런의 모델은 그림 2과 같다. 카오틱 뉴런의 입력은 불응항 $ky_i(t)$, 재환입력 $\sum_{j=1}^m W_{ij}f_j(y_j(t))$, 그리고 외부입력 $\sum_{j=1}^m V_{ij}I_j(t+1)$ 의 합으로 구성하였다. 그러므로 뉴런의 상태 식은 다음과 같이 표현된다.


$$y_i(t+1) = ky_i(t) + \sum_{j=1}^m V_{ij}I_j(t+1) + \sum_{j=1}^m W_{ij}h_j(f_j(y_j(t))) \quad (14)$$

$$x_i(k+1) = f[y_i(k+1)] \quad (15)$$


$$f[y_i(k+1)] = \frac{1}{1 + e^{-y_i(k+1)/\epsilon}} \quad (16)$$

여기서 ϵ 은 시그모이드 함수의 기울기이다.


카오틱 뉴런의 카오틱 특성은 k 의 설정과 W_{ii} 의 학습을 통하여 제어되며 카오스적 출력의 발생 시는 일시적인 카오스(transient chaos)현상을 보이고 있다.



a) 시간에 따른 뉴런의 내부상태 변화



b) Lyapunov Exponent



c) 연결강도의 변화

그림 3. 개선된 카오틱뉴런의 일시적 카오틱 특성
Fig 3. Transient Chaotic Characteristics for MCNN

3.2. 개선된 카오틱 신경망

제안된 카오틱 신경망은 그림 4와 같이 기존의 카오틱 신경망과는 달리 층내 뉴런사이에 단 방향을 가지는 결합계수를 두개씩 설정하였으며, 층간 결합계수와 층내 결합계수를 오차 역전파 알고리즘을 이용하여 학습하였다. 이는 출력층의 오차가 감소하는 방향으로 각 결합계수를 갱신함을 의미하며 생체 신경망의 구조와 비슷한 형태를 갖도록 하여 동적 특성을 강화하며 커플링을 갖는 시스템에 적합한 특성을 가진다. 층간의 결합계수는 일반적인 다층신경망의 경우와 같이 하위층에서 상위층으로의 단방향 결합계수를 가지게 하였고, 같은 층내의 뉴런들 사이의 결합계수는 단방향을 가지도록 하였다. $x_j^d(t)$




그림 4. 개선된 카오틱 신경망의 구조
Fig. 4. The Structure of MCNN

개선된 카오틱 신경망의 출력층의 p 번째 뉴런의 내부상태는 식 (17)와 같이 표현될 수 있다.

$$y_p^O(t+1) = \sum_{j=1}^m V_{jp}^O(t) f\left[\sum_{i=1}^m V_{ij}^H(t) u_i\right] + \sum_{q=1}^m W_{pq}^H(t) x_q^H(t) + k y_j^H(t) + \sum_{r=1}^m W_{rp}^O(t) x_r^O(t) + k y_p^O(t) \quad (17)$$

여기서 $y_p^O(t)$ 는 시간 t 에서 출력층의 p 번째 뉴런의 내부상태, $x_r^O(t)$ 는 출력층의 r 번째 뉴런의 출력, $y_j^H(t)$ 는 은익층의 j 번째 뉴런의 내부상태, $x_q^H(t)$ 는 은익층의 q 번째 뉴런의 출력, $V_{jp}^O(t)$ 는 은익층의 j 번째 뉴런과 출력층의 p 번째 뉴런의 연결강도, $V_{ij}^H(t)$ 는 입력층의 i 번째 뉴런과 은익층의 j 번째 뉴런의 연결강도, $W_{rp}^O(t)$ 는 출력층의 r 번째와 p 번째 뉴런의 연결강도, 그리고 $W_{pq}^H(t)$ 는 은익층에서 j 번째와 q 번째 뉴런 사이의 연결강도를 나타낸다.

식 (17)을 다시 정리하면 식 (18)과 같이 표현된다. 식 (18)에서 보인 것과 같이 시간에 따라 변화하는 신경망의 모든 파라미터들을 포함하며 파라미터들 사이에 커플링된 상태를 포함하고 있으므로 신경망의 출력은 식 (19)과 같이 표현할 수 있다.

$$\begin{aligned}
 y_p^O(t+1) = & \sum_{j=1}^m V_{jp}^O(t) f \left[\sum_{i=1}^l V_{ij}^H(t) u_i(t) \right. \\
 & + \sum_{q=1}^m W_{iq}^H(t) f \left[\sum_{i=1}^l V_{iq}^H(t-1) u_{iq}(t-1) \right. \\
 & + \sum_{j=1}^m W_{jq}^H(t-1) x_q^H(t-1) + k y_j^H(t-1) \left. \right] \\
 & + \sum_{j=1}^m W_{jp}^H(t) f \left[\sum_{j=1}^m V_{jp}^O(t) x_j(t) \right. \\
 & + \sum_{q=1}^m W_{qp}^O(t-1) y_q(t-1) + k y_p(t-1) \left. \right] + k y_p(t) \quad (18)
 \end{aligned}$$

$$x_p^O(t+1) = f(U(t), X^O(t), X^H(t), Y^O(t), Y^H(t)) \quad (19)$$

; all l for $1 \leq l \leq l$

여기서 $U(t)$ 은 시간 t 에서의 신경망의 입력벡터, $X^O(t)$ 은 신경망의 출력벡터, $X^H(t)$ 은 신경망의 은닉층의 출력벡터, $Y^O(t)$ 은 신경망의 출력층 뉴런의 내부상태 벡터, 그리고 $Y^H(t)$ 은 신경망의 은닉층 뉴런의 내부상태 벡터를 나타낸다.

식 (19)에 보인 것과 같이 신경망의 출력은 시간의 변화에 따른 모든 입력, 출력, 그리고 뉴런의 내부상태들을 포함하며, 파라미터 사이의 커플링을 포함하고 있으므로 커플링을 갖는 비선형 다변수 동적시스템의 모델링 및 제어에 효과적으로 작용될 수 있다.

제안된 카오틱 신경망의 학습은 층간의 결합계수와 층내의 결합계수에 동일하게 오차 역전파 알고리즘을 적용하여 갱신하였다. 카오틱 신경망의 오차함수는 원하는 출력 $x_j^d(t)$ 와 실제출력 $x_j(t)$ 의 차이로 정의하였다.

$$J_j(t) = \frac{1}{2} [x_j^d(t) - x_j(t)]^2 \quad (20)$$

기존의 신경망이 오차 발생의 책임을 하위 뉴런과의 결합 계수에 분산하고 이를 오차 역전파 알고리즘에 의해 하위층으로 역전파 하여 학습한 반면, 제안된 카오틱 신경망은 오차 발생의 원인을 하위 층의 입력뿐만 아니라 같은 층내의 입력에도 같은 비중을 가지도록 하여 신경망의 동적 특성을 향상시키도록 신경망의 구조를 개선함으로써 학습 시 학습 오차의 급격한 감소를 가지게 된다. 또한 같은 층 내의 결합계수를 갖도록 구성함으로써 변수간의 커플링을 갖는 비선형 시스템의 구현에도 탁월한 능력을 갖도록 구성하였다.

4. Prefilter 형태의 카오틱 신경망 제어기

기존의 로봇 제어기의 설계에 관한 연구는 로봇에 부착된 제어기를 대체할 새로운 제어기의 구성에 초점을 맞추어 연구되어 왔으나 제어 하드웨어 및 인터페이스의 교체 등의 어려운 점을 갖고 있다. 본 논문에서는 기존에 보급된 로봇 시스템의 하드웨어의 변경 없이 로봇의 움직임의 정밀성을 향상할 수 있는 prefilter 형태의 보상제어기를 구성하였다. 3축 푸마 로봇의 경로를 제어할 prefilter 형태의 카오틱 신경망 제어기의 구조는 그림 5와 같다.




그림 5 Prefilter 형태의 카오틱 신경망 제어기의 구조
Fig 5. The structure of prefilter type MCNN controller

기존의 prefilter 형태의 보상제어기는 위치와 속도를 보상하는 방식을 채택하고 있으나 본 연구에서는 카오틱 신경망을 이용하여 직접적용제어 방식으로 PD 제어기의 속도만을 보상하여 신경망의 연산량을 줄이며 정밀 위치제어를 수행하도록 설계하였다. 개선된 카오틱 신경망은 식 (19)에서 보인 것과 같이 커플링을 갖는 비선형 다변수 동적시스템에 효과적으로 작용될 수 있으므로 로봇의 경로 계획에 따른 각 관절각과 관절 각속도를 카오틱 신경망 제어기의 입력으로 설정하여 출력으로 수정된 속도계획을 구함으로써 로봇 시스템의 비선형성을 보상하게 된다. 신경망 제어기는 오차 역전파 알고리즘에 의해 로봇의 각 관절각의 오차를 최소화하는 방향으로 지속적으로 학습을 수행하게 된다.

PD 제어기는 각 관절각과 관절각 속도의 오차에 의하여 토오크 출력을 최종적인 로봇의 경로 제어의 역할을 수행하게 된다. PD제어기의 출력 토오크는 각 관절 위치 및 각속도의 오차에 의해 결정된다.

로봇의 입력 토크값 τ_i 는 식 (21)과 같이 정의된다.

$$\tau_i = Kd(\dot{q}_i^d - \dot{q}_i^a) + Kp(q_i^d - q_i^a) \quad (21)$$

여기서 K_p 는 비례요소, K_d 는 미분요소, q_i^d 는 로봇 링크 i 의 원하는 관절각의 목표값, \dot{q}_i^d 는 신경망에 의해 보상된 목표값, q_i^a 는 로봇의 실제 출력값을 의미한다.

카오틱 신경망 제어기는 은닉층이 하나인 다층 신경망의 구조를 가진다. 카오틱 신경망 제어기의 입력은 경로 계획에 의한 각 관절각 3개와 각속도 3개를 합하여 6개의 입력 뉴런을 가지며 은닉층은 10개의 뉴런, 출력층은 PD 제어기의 미분이득을 보상 출력하는 3개의 뉴런을 가지도록 하였다. 각층 사이의 결합계수는 -0.5에서 0.5 범위내의 임의의 값으로 초기화하였고, 각 층내 뉴런사이의 결합계수 또한 같은 범위내의 임의의 값으로 설정하였다. 학습률은 0.3, 바이어스는 1.0, 모멘텀 룰 0.8, 시간 감쇠 지수는 모두 0.7로 동일하게 사용하였다. PD제어기는 로봇의 각 축에 대하여 독립적으로 담당하도록 3개로 구성하였으며 비례이득과 미분이득을 300과 10으로 고정하였다.

Prefilter 형태의 카오틱 신경망 보상 제어기의 성능을 평가하기 위하여 기존의 리커런트 신경망을 이용한 제어기와 비교하였다. 입력층과 출력층 뉴런의 수는 카오틱 신경망과 동일하며 은닉층에 40개의 뉴런을 두고 이들 중 10개의 뉴

런이 입력층으로 리커런트 되도록 하였다. 리커런트 신경망은 기울기가 1인 중형함수를 활성화함수로 선택하였으며 학습률은 0.08을 설정하였다.

5. 모의 실험 및 결과 고찰

Prefilter 형태의 카오틱 신경망 제어기를 3축 푸마 로봇의 PD 제어기의 속도를 보상하여 실시간으로 로봇의 경로를 제어할 수 있음을 확인하였고 그 결과를 리커런트 신경망 제어기의 결과와 비교하였다. 3축 푸마 로봇의 경로는 다음과 같이 계획하였다.

$$x = -0.149100 - 0.09 \cdot \cos(100\pi/180) + 0.09 \cdot \cos(u(t)\pi/180) \tag{22}$$

$$y = 0.798218 - 0.09 \cdot \sin(100\pi/180) + 0.09 \cdot \sin(u(t)\pi/180) \tag{23}$$

$$z = 0.428613 \tag{24}$$

$$u(t) = 3.6 \cdot t \quad (0 \leq t \leq 180) \tag{25}$$

식 (22)~(25)은 중심이 (x, y, z)=(-0.133472, 0.719585, 0.428613)에 있으며 반경이 0.09m인 원궤적을 의미한다. 로봇의 초기 위치는 (x, y, z)=(-0.149100, 0.798218, 0.428613)이고 기본자세는 LEFT & ABOVE arm의 구조를 가진다. 로봇이 원궤적을 따라 움직일 때의 원궤적의 운동시간은 5.0초, 샘플링 주기는 0.05초로 설정하였고 평균속도는 0.1131 m/sec이다.

그림 6, 7에 500회, 1000회 학습에 따른 로봇의 경로 추적 상태를 3차원으로 나타내었다. 학습초기에 카오틱 신경망 제어기의 학습오차가 큰 폭으로 떨어져 진행됨에 따라 로봇의 경로 추적 오차가 리커런트 신경망 제어기보다 급격히 감소하는 것을 볼 수 있다. 500회 학습 후의 경로 추적상태를 보면, 카오틱 신경망 제어기는 주어진 경로에 거의 접근한 반면 리커런트 신경망 제어기는 목표 값과 상당한 차이를 가지며, 1000회 학습 후의 카오틱 신경망은 목표 값과 일치함을 볼 수 있지만 리커런트 신경망은 경로 추적상태가 불안정한 것을 볼 수 있다.




그림 6. 500회 학습에 따른 로봇의 경로추적
Fig 6. Trajectory Tracking result after 500 iterations




그림 7. 1000회 학습에 따른 로봇의 경로추적
Fig 7. Trajectory Tracking result after 1000 iterations

그림 8, 9, 10은 1000회 학습 후 각 축의 경로 추적 상태이다.




그림 8. 1000회 학습 후 x축의 경로 추적
Fig 8. Trajectory tracking result of X axis after 1000 iterations

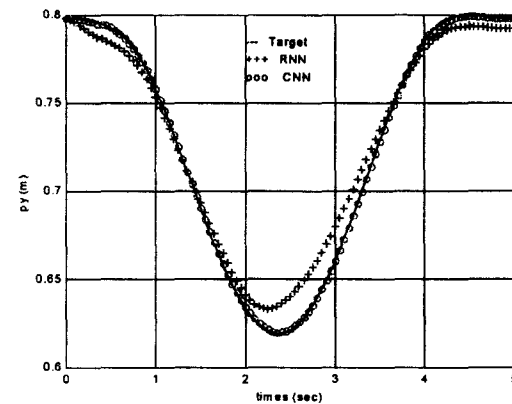


그림 9. 1000회 학습 후 y축의 경로 추적
Fig 9. Trajectory tracking result of Y axis after 1000 iterations




그림 10. 1000회 학습 후 z축의 경로 추적
 Fig 10. Trajectory tracking result of Z axis after 1000 iterations

그림 11은 1000회 학습하는 동안의 최대 위치오차의 변화 과정을 표시하였으며, 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 제어기를 온라인으로 이용하여 실시간으로 제어 가능함을 의미한다. 카오틱 신경망 제어기는 거의 목표 값에 수렴한 반면, 리커런트 신경망 제어기는 좀 더 많은 학습이 이루어져야 함을 알 수 있다.




그림 11. 학습에 따른 최대 위치 오차
 Fig 11. Maximum position error with learning

6. 결 론

본 논문에서는 동적특성을 갖는 개선된 카오틱 신경망이 비선형 동특성을 가지는 시스템의 제어에 효율적으로 적용할 수 있음을 확인하였다. 제어 시스템의 구조는 3축 푸마 로봇의 경로를 제어하기 위하여 PD제어기 앞단에 prefilter 형태의 카오틱 신경망 속도보상 제어기를 설계하고, 그 결과를 기존의 리커런트 신경망 제어기와 비교하였다.

Pentium II 250MHz 컴퓨터로 시뮬레이션한 결과 100개의 패턴을 1000회 반복 학습 후, 소요된 시간은 기존의 리커런트

트 신경망 제어기는 1083.9초가 걸린 반면 카오틱 신경망 제어기의 경우 270.3초로 학습 속도가 약 4.01배 향상되었다. 또한, 오차는 0.000172과 0.000760으로 4.42배 적은 값을 가짐으로서 prefilter 형태의 카오틱 신경망 제어기의 제어 성능이 한층 더 우수함을 입증하였다.

시뮬레이션 결과 제안된 prefilter 형태의 카오틱 신경망 제어기의 장점은 크게 네 가지로 나타낼 수 있다.

1. 기존의 PD제어기가 달린 시스템에 하드웨어의 변경없이 프로그램의 변경으로 제어기의 오차를 바로 보정하여 사용할 수 있다.
2. 실시간으로 제어 가능하며, 제안된 신경망이 빠른 수렴 특성을 보이고 있으며, 기존의 로봇 제어기를 보정하는 형태로 사용하므로 초기의 안정성이 확보되어 on-line 학습이 가능하였다..
3. 제안된 카오틱 신경망은 층간 뿐 아니라 층내 뉴런간의 결합에 의한 상호 커플링이 존재하여 제어대상이 상호 커플링이 존재하며, 비선형성이 강한 동적 시스템의 경우에도 쉽게 학습이 가능하기 때문에 제어 대상의 모델화가 어렵고 일반적인 수학적 제어 규칙을 정하기 어려울 때 더욱 효과적으로 사용할 수 있다.
4. 일반적인 신경망 로봇 제어기의 구현 시 커플링 문제를 해결하기 위하여 여러 개의 신경망을 사용하는 모듈형의 제어기의 구성과는 달리 한 개의 신경망을 사용하여 제어기를 구성하였다. 한 개의 신경망을 사용한 제어기의 구성은 신경망 계산시간의 단축 뿐 아니라 외란 및 상호 커플링을 갖는 다입력 다출력 제어대상에 대한 모델에 보다 근접하여 제어기가 구성될 수 있다는 장점을 갖고 있다.

감사의 글

본 연구는 1999년도 금오공과대학교 학술연구비에 의하여 이루어진 연구입니다.

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] K. Aihara, T. Takabe and M. Toyoda, "Chaotic Neural Networks," Phys. Lett A144, pp 333-340, 1990.
- [10] E. R. Caianiello, "Outline of a Theory of Thought-Processes and Thinking Machines." J. Theor. Biol. vol 2. pp 204-235, 1961.
- [11] J. Nagumo and S. Sato, "On a Response Characteristics of a Mathematical Neuron Model", Kybernetik. 10, pp. 155-164, 1972.
- [12] K. Shimiza, K. Aihira and M. Kotami "An Electronic Circuit Model of Chaotic Neural Networks", Electronics and Communications in Japan Part. 3, Vol. 73. pp. 51-64 1992.
- [13] S. H. Kim, C. W. Jang, " Trajectory Control of Robotic Manipulators using Chaotic Neural Networks", ICNN Vol. 3, pp1685-1688, 1997
- [14] K. Aihara, "Chaos in Neural Systems", Tokyo Denki University Press. Tokyo. 1993.
- [15] 장창화, 김상희, "카오틱 신경망을 이용한 다입력 다출력 시스템의 단일 예측", 대한전자공학회 하계학술대회 논문집. 22권, 1호, 1999.
- [16] L. Chen, K. Aihara, "Chaotic Annealing by a Neural Network Model with Transient Chaos", Neural Networks, Vol. 8, No. 6, pp915-930, 1995.
- [17] 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, pp1673-1690, 1997.

저 자 소 개



홍수동 (洪壽東)

1970년 10월 13일 생. 1996년 금오공과대 전자공학과 졸업. 1998년 동 대학원 전자공학과 졸업(석사). 1998년~현재 동 대학원 전자공학과 박사과정. 2000년~현재 LG전자 제품연구소 주임연구원.

Tel : 054-442-2432

E-mail : sdhong@lge.com



김상희 (金相熙)

1960년 1월 19일 생. 1983년 홍대 전기공학과 졸업. 1985년 연대 대학원 전기공학과 졸업(석사). 1992년 Texas A&M Univ. (공박). 1993년~현재 금오공과대 부교수.

Tel : 054-467-4382

E-mail : shkim@knut.kumoh.ac.kr



최운하 (崔雲河)

1969년 9월 30일 생. 1996년 금오공과대 전자공학과 졸업. 1998년 동 대학원 전자공학과 졸업(석사). 1998년~현재 오성전자 연구소 선임연구원. 2000년~현재 구미기능대 겸임교수.

Tel : 017-514-0117

E-mail : unhachoi@hanmail.net