

계층 구조의 신경회로망에 의한 로보트 PTP 궤적 계획

Robot PTP Trajectory Planning Using a Hierarchical Neural Network Structure

慶 桂 顯* · 高 明 三** · 李 範熙***
 (Kye-Hyun Kyung · Myoung-Sam Ko · Bum-Hee Lee)

요 약

본 논문에는 로보트 매니퓰레이터의 PTP 궤적 계획을 위한 계층적 구조의 신경회로망이 서술되었다. 그 첫 단계인 연기구학 신경회로망은 다층구조의 Perceptron 신경회로망으로 구현되었으며, BP(back-propagation) 학습 방법으로 신경회로망의 학습이 수행되었다. 두번째 단계에서는 saccade 발생 모델에 근거하여 관절 궤적 계획 모델이 제안되었고 그 모델의 특성 분석이 수행되었다. 제안된 신경회로망의 특성을 분석하기 위한 다양한 시뮬레이션이 수행되었다.

Abstract- A hierarchical neural network structure is described for robot PTP trajectory planning. In the first level, the multi-layered Perceptron neural network is used for the inverse kinematics with the back-propagation learning procedure. In the second level, a saccade generation model based joint trajectory planning model is proposed and analyzed with several features. Various simulations are performed to investigate the characteristics of the proposed neural networks.

1. 서 론

최근에 신경회로망에 대한 새로운 관심이 크게 증가하고 있다. 신경회로망은 첫째 간단한 연산자

*正 會 員: 서울大 大學院 制御計測工學科 博士課
程

**正 會 員: 서울大 工大 制御計測工學科 教授 · 工
博

***正 會 員: 서울大 工大 制御計測工學科 副教授 ·
工轉

接受 日 字: 1990年 5月 12日

1次 修 正: 1990年 8月 28日

(신경세포)와 그들의 분산적인 연결로 구성되며 학습능력을 갖는 인공신경회로망(Artificial Neural Network)과, 둘째 생명체의 신경세포를 모델링하는 생물학적 신경회로망(Biological Neural Network)의 두 가지 의미로 사용되고 있다. 본논문에서는 로보트 매니퓰레이터의 PTP(point to point) 운동의 궤적 계획을 계층적구조의 신경회로망으로 구성하고 그 특성을 파악한다.

로보트 매니퓰레이터의 PTP 궤적 계획은 두 단계로 나눌 수 있다. 첫 단계는 매니퓰레이터 핸드의 목표 공간 위치를 그에 대응하는 관절 위치로

바꾸어 주는 역기구학이고, 두 번째 단계는 현재 관절 위치로부터 목표 관절 위치까지 매니퓰레이터를 제어하기 위한 제어 셀 포인트의 시퀀스를 발생시키는 관절 궤적 계획이다[1]. 본 논문에서 역기구학은 인공신경회로망으로 구현되었으며, 관절 궤적 계획은 생물학적 신경회로망으로부터 새롭게 제안되었다.

기존의 대부분의 로보트 매니퓰레이터의 역기구학은 매니퓰레이터의 기구학적 구조에 따라 미리 수학적으로 수식화되어 사용되고 있다. 기존의 방법들은 다음과 같은 문제점들을 갖는다.

- 1) 매니퓰레이터에 대한 정확한 기구학적 특성을 알아야 한다.
- 2) 역기구학 문제를 해결하는데 사용되는 수식의 수가 매니퓰레이터의 자유도에 따라 증가한다.
- 3) 역기구학의 해가 closed form으로 존재하지 않고 iterative form으로 존재하는 경우에 역기구학 문제 해결에 많은 계산 시간이 소요된다.
- 4) 각 매니퓰레이터의 역기구학 해는 단지 그 매니퓰레이터 모델 한 종류에 대해서만 유효하다.
- 5) 매니퓰레이터의 기구학적 특성이 시간에 따라 계속 변화한다.

한편, Atkeson은 운동신경(motor) 시스템의 기구학과 동역학의 모델을 디지털 컴퓨터 프로그램이나 아날로그 컴퓨터 회로와 같은 구조적 모델과 둑 업 테이블과 같은 테이블 모델로 나누고 각 모델에 대한 리뷰와 장단점을 비교하였는데[2], 그는 제어 대상 시스템의 구조가 알려지지 않았거나 단지 근사적으로 알려졌다면 테이블 모델이 제어 시스템의 학습에 중요한 역할을 한다고 주장하고 테이블 모델이 보다 일반적(general)이고 유연하다고(flexible) 주장하였다. 이것은 앞에서 서술한 기존의 역기구학 해결 방법에서 발생하는 대부분의 문제점들이 일반성과 유연성의 문제로부터 발생하므로 이와 같은 문제점들은 역기구학을 테이블 모델로 해결함으로써 제거될 수 있음을 나타낸다.

역기구학 문제 해결에 사용되고 있는 테이블 모델 중에는 CMAC(The Cerebellar Model Articulation Controller)[3-5]와 다층 Perceptron[6-10]과 같은 신경회로망 모델이 있는데, 이들은 모두 간단한 연산자와 연결 네트워크로 구성되며 연결 강도를 학습시킬 수 있다. 이들은 일반성과 유연성을 가지며 self organizing 성질을 가지고 있기

때문에 시스템 자체나 외부 환경에서 발생하는 변화에 적응 능력을 갖는다.

Josin[12]과 Guez 등[11]은 다층 Perceptron 구조의 신경 회로망을 사용하고 BP(back-propagation) 학습방법[9], [10]으로 학습을 수행하여 역기구학 문제 해결을 시도하였다. Josin은 주로 학습의 표본수에 대한 역기구학 문제 해결의 성능 분석을 수행하였으며, Guez 등은 2자유도와 3자유도를 갖는 매니퓰레이터에 대한 역기구학 문제의 해결을 비슷한 구조의 신경회로망으로 수행하여 신경회로망이 매니퓰레이터의 기구학적 구조의 복잡성에 관계없이 비슷한 성능을 수행함을 보였다. 또한 Guez 등은 기존의 알고리즘으로 표현되는 역기구학의 문제점을 제시하고 신경 회로망을 사용한 역기구학 문제 해결의 장점에 대해 서술하였다. Kuperstein[19]은 인간의 시각 처리시스템과 유사한 신경회로망을 사용하여 매니퓰레이터의 역기구학을 자율 학습으로 학습시키는 방법에 대해 설명하고 매니퓰레이터의 실시간 시작추적에 관해 연구하였다.

본 논문에서는 다층구조의 Perceptron 신경 회로망을 사용하고 BP 학습 방법으로 학습시킨 로보트 매니퓰레이터의 역기구학에 관해 서술한다. 본 논문에서는 신경회로망의 구조에 따른 역기구학 신경 회로망의 성능을 분석하고, 학습 회수에 따른 역기구학 신경 회로망의 오차분석을 수행하였다.

영장류의 생명체의 운동 중에서 로보트 매니퓰레이터 PTP 궤적 계획의 두 번째 단계인 관절 궤적 계획과 유사한 행동을 보이는 운동으로는 수평 방향으로의 saccadic eyemovement[13-15]가 있다. Saccadic eye movement는 응시 방향으로의 눈동자의 빠른 움직임을 의미한다. Saccade에서 눈동자의 속도계적은 벨 형태이며 특히 수평방향의 saccade에서 눈동자 움직임의 자유도는 1이 된다. 따라서 수평 방향의 saccade는 우리가 원하는 관절 궤적과 비슷하게 된다.

Robinson은 1975년 이래로 saccade 모델을 제안하고 있다[13, 14].

Robinson의 saccade 발생 모델[14-16]은 EBN(excitatory burst neuron), IBN(inhibitory burst neuron), OPN(omnipause neuron), TN(tonic neuron), MN(motor neuron)으로 구성된다. EBN은 saccade의 위치 명령과 TN으로부터의 위치 되먹임 신호를 입력받아 눈동자의 위치 오차를 발생한다. TN은 EBN의 출력을 적분하여 눈동자 위치의 되먹임 신호로 EBN에 전달하며, TN과

EBN의 출력은 MN에 입력되어 눈동자 근육을 제어하게 된다. 한편 Bias에 의해 활성화되는 OPN은 IBN과 함께 saccade를 동기화시키는 역할을 수행한다. 따라서 이 모델에서 saccade의 궤적 형성에서 중요한 역할을 수행하는 것은 EBN과 TN이 된다. 그런데 Robinson의 saccade 모델에서 눈동자의 위치 오차에 해당하는 EBN의 출력을 그대로 적분하는 TN의 출력은 수학적 관점에서 볼 때 실제 눈동자의 위치와 같을 수 없다. 뿐만 아니라 brainstem에서 EBN으로부터 TN까지의 경로는 가정된 것으로[15], Robinson모델에서 TN의 출력이 실제의 눈동자 위치되먹임이 되기 위해서는 이 가정된 경로상에 EBN의 출력을 눈동자의 속도 궤적으로 변환시켜주는 다른 신경세의 개입이 필요하다.

한편 Grossberg등[16-18]은 팔 움직임의 궤적 형성을 시뮬레이션하는 실시간 신경회로망 VITE(vector integration to endpoint)모델을 제안하였다. VITE모델은 목표위치명령과 현재위치되먹임 신호의 차이인 위치 오차를 시간에 대해 평균시키는 DV(difference vector)와 DV에 곱해져서 속도 궤적을 만드는 온셋(onset)함수 그리고 이 값을 적분하여 현재위치명령을 만드는 적분기로 구성된다. 적분기를 통한 현재위치명령은 현재위치의 되먹임신호로 사용된다. 이 모델에 의해 형성된 궤적은 벨 형태이며, 모델의 파라미터를 바꿈에 의해 생성되는 속도 궤적의 대칭 형태를 조정할 수 있도록 모델이 구성되어 있다. 그러나 VITE모델에서 위치 방정식은 2차의 선형 미방으로 표현되어 위치의 해가 closed-form으로 존재하지 않고 따라서 실제 motor를 제어하는데 필요한 제한을 고려한 궤적을 발생시킬 수 없다.

VITE모델에서 온셋 함수의 역할은 목표위치와 현재위치의 차이인 위치 오차의 시간에 대한 평균 값을 속도 궤적으로 변환시켜주는데 있다. 이것은 Robinson의 saccade모델에서 TN의 출력이 실제 눈동자의 위치 되먹임 신호가 되기 위하여 EBN으로부터 TN까지의 경로상에서 요구되는 역할이다. 본 논문에서는 Robinson이 제안한 saccade모델의 EBN으로부터 TN으로의 경로에 VITE모델에서 제시한 온셋 함수의 곱함을 추가한 관절 궤적 모델을 제안하였다. 제안한 모델에서 온셋 함수는 시간의 함수로 at^n 으로 하였는데 이것은 상수를 n 번 적분하여 얻을 수 있는 것으로 실제 생명체의 신경 세포의 활동에서 발생될 수 있다. 제안한 모델에서 속도 궤적은 벨 형태로 나타나며 VITE모델에서와 마찬가지로 모델의 파라미터를 바꿈에

의해 속도 궤적의 대칭성을 조정할 수 있도록 되어 있다. 제안한 모델에서 위치 방정식은 1차의 선형 미방으로 표현되며 따라서 위치의 해가 closed-form으로 존재하고 실제 motor의 제어에 필요한 여러 제한(속도 제한, 가속도 제한, 저크 제한)을 만족시키는 관절 궤적을 계획할 수 있다.

2장에서는 역기구학과 관절 궤적 계획에서 사용한 신경회로망의 구조에 대해 각각 서술한다. 3장에서는 역기구학 신경회로망의 학습 법칙과 학습 방법에 대해 설명하고, 4장에서는 관절 궤적 계획 모델의 특징에 대해 분석하고 관절 궤적 계획 방법에 대해 서술한다. 5장에서는 시뮬레이션 결과를 나타내었고 6장에는 결론을 제시하였다.

2. PTP 궤적 계획을 위한 계층적 신경회로망의 구조

2.1 첫번째 단계 구조 : 역기구학

최근에 간단한 연산자의 연결 회로망으로 구성되는 신경 회로망에 대한 관심이 다시 일어나고 있다. 다층 신경 회로망에 적용되는 학습 방법의 새로운 개발은 고전적인 Perceptron의 잘 알려진 한계[7]를 극복할 수 있도록 하였다. 본 논문에서 역기구학 신경회로망은 Rumelhart 등[9], [10]에 의해 제안된 다층 Perceptron구조로 하였다(그림 1). 이 구조에서 n -번재층의 j -번재 세포의 활성 O_j 는 $n-1$ -번재층의 세포의 활성 O_i 으로부터 (1)식과 같이 계산된다.

$$O_j = f(N_j) = f(\sum_i W_{ij} O_i + b_j) \quad (1)$$

(1)식에서 W_{ij} 는 $n-1$ -번재층의 i -번재 세포와 n -번재층의 j -번재 세포사이의 연결강도이고, b_j 는 바이어스 입력이다. 바이어스는 활성이 항상 1인 세포

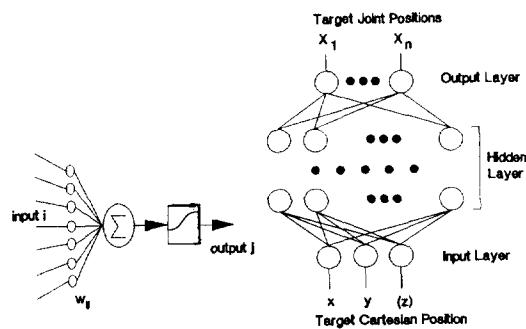


그림 1 다층 Perceptron
Fig. 1 Multi-layered Perceptron

로부터의 연결강도와 동일하다. 각 세포의 활성은 함수 f 에 의해 0과 1사이의 값을 갖게 되는데 함수 f 는 감소하지 않고 미분 가능한 함수이어야 한다. 일반적으로 함수 f 는 식 (2)와 같이 sigmoid 함수로 한다.

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (2)$$

입력층의 입력 패턴은 중간층을 통해 출력층으로 전파되어 (propagate) 출력 패턴을 형성하게 된다. 역기구학 신경 회로망의 입력 패턴은 매니퓰레이터 핸드의 카티시안위치가 되며, 출력 패턴은 그것에 대응하는 매니퓰레이터 각 축의 관절 위치가 된다.

2.2 두 번째 단계 구조 : 궤적 계획

본 논문에서 관절 궤적 계획은 1장에서 설명한 것과 같이 Robinson의 saccade모델에 VITE모델에서 사용한 온셀 함수를 보충하여 구성하였다.

관절 궤적 계획기는 목표관절위치와 현재관절위치 사이의 오차를 계산하는 차이 유닛(difference unit: DU), 온셀 함수 at^n , 온셀 함수와 DU의 출력을 곱해서 속도제작을 생성하는 곱셈기, 그리고 속도 제작을 적분하여 현재관절위치를 계산하는 적분기로 구성된다(그림 2). 제안 모델에서 DU는 서로에서 설명한 Robinson의 saccade 발생 모델의 EBN의 역할을 담당하며, 적분기는 TN의 역할을 담당한다. 관절 궤적의 속도 제한, 가속도 제한, 그리고 저그의 제한은 파라미터 α 와 n 에 의해 결정되고 속도 궤적의 대칭성은 파라미터 n 에 의해 결정된다(4장). 제안된 모델은 실제 영장류의 신경 세포 활동의 모델로부터 구성되었으므로 학습을 필요로 하지 않는다. 그림 2의 관절 궤적 계획에서 초기 방정식은 식 (3)과 같이 1차 선형미방으로 표시된다.

$$\frac{d\theta(t)}{dt} + \alpha \cdot t^n \cdot \theta(t) = \alpha \cdot t^n \cdot \theta_d \quad (3)$$

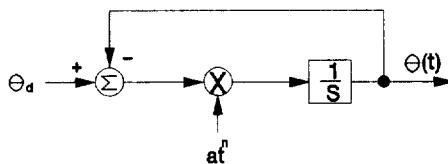


그림 2 관절 계획 신경회로망

Fig. 2 A Neural Network for Joint Trajectory Planning

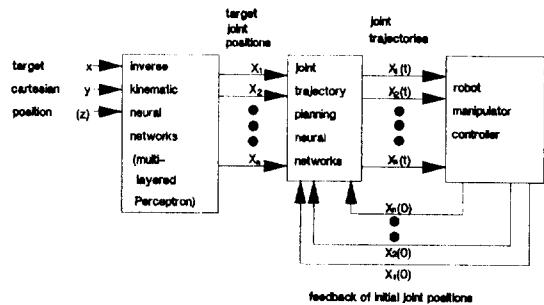


그림 3 PTP 궤적 계획 시스템 구성

Fig. 3 Overall System for PTP Trajectory Planning

식 (3)에서 θ_d 는 목표 관절 위치이고, $\theta(t)$ 는 관절 궤적을, 그리고 t 는 시간을 나타낸다.

2.3 두 구조의 결합

로보토 매니퓰레이터의 PTP 궤적 계획은 매니퓰레이터의 작업 공간상의 핸드의 목표카티시안 위치를 목표 관절 위치로 변환해 주는 역기구학과 이 값과 매니퓰레이터의 초기관절위치를 입력받아 여러 제한을 만족하는 관절 궤적을 계산하여 매니퓰레이터의 제어기에 전달하는 관절 궤적 계획기로 구성된다(그림 3). 역기구학은 다층의 perceptron 신경회로망으로 구성하였는데, 신경회로망의 입력 층은 작업공간이 3차원이면 3개의 세포로 2차원이면 2개의 세포로 구성되며 출력층은 매니퓰레이터의 관절수와 동일한 수의 세포로 구성된다. 관절 궤적 계획기는 역기구학 신경회로망으로부터 목표 관절위치를 입력받아 각 관절의 제한들을 모두 만족시키면서 매니퓰레이터의 각관절의 궤적을 독립적으로 또는 동기적으로 발생시킨다.

3. 첫 번째 단계(역기구학 신경회로망)에서의 학습 구조

역기구학 신경 회로망은 그림 1에서와 같은 3층, 4층, 또는 그 이상의 층을 갖는 신경 회로망으로 구현된다. 신경 회로망에 의한 역기구학은 회로망의 연결된 층(successive layers) 간의 링크 연결강도에 의해 수행된다. 이 연결강도들은 BP 학습과정에 의해 형성된다. 학습은 입력과 출력의 활성쌍(activity pairs)을 반복적으로 제시(presentation)함으로서 수행되는데, 매 학습 시 행에서 입력 활성은 매니퓰레이터 핸드의 공간위치가 되고 출력 활성은 그에 해당하는 관절위치가

된다. 입력 활성은 회로망을 통해 전파되고, 출력 층의 활성은 목표 활성과 비교되어 출력 오차 벡터를 형성한다. 이 오차는 출력 오차를 감소시키는 방향으로 회로망의 연결 강도를 조정하는데(update) 사용된다.

오차를 조정하기 위한 BP 학습은 연결강도 공간위에서 오차표면(error surface)에서의 그래디언트 디센트(gradient descent)를 수행한다. 이 방법에서 BP스텝은 중간층의 각 신경세포가 출력층에서 관측된 오차에 어떻게 기여하는가를 분석함에 의해 중간층의 오차벡터를 예측하는 것이다. BP 학습 방법에는 코스트는 (4)식과 같이 입력/출력 제시 p 의 모든 셀에 대해 더해진 j 번째 출력세포의 관측출력 O_j 와 목표 출력 T_j 사이의 오차로 정의 된다.

$$E = \frac{1}{2} \sum_p E_p = \frac{1}{2} \sum_p \sum_j (T_{pj} - O_{pj})^2 \quad (4)$$

연결강도는 E_p 를 감소시키도록 각 제시 p 에서 조금씩 조정된다. 중간층으로부터 출력층으로 연결된 각 연결강도의 조정량은 (5)식에 비례하며, 제시 p 에서 조정되는 연결강도의 양 ΔW_{jk} 는 (6)식과 같다. η 은 학습율을 제어하는 파라미터이다.

$$\frac{\partial E_p}{\partial W_{jk}} = \frac{\partial E_p}{\partial O_k} \frac{\partial O_k}{\partial N_k} \frac{\partial N_k}{\partial W_{jk}} = -\delta_{pk} \cdot f'(N_k) \cdot O_j \quad (5)$$

$$\Delta W_{jk} = \eta \cdot \delta_{pk} \cdot f'(N_k) \cdot O_j \quad (6)$$

입력층과 중간층, 또는 중간층과 중간층 사이의 연결강도의 조정은 (7)식에 비례하며, 제시 (presentation) p 에서 조정되는 연결강도의 양 ΔW_{ij} 는 출력에서의 오차가 회로망을 통해 역전파(backpropagation)하는 (8)식으로 표현된다.

$$\begin{aligned} \frac{\partial E_p}{\partial W_{ij}} &= \frac{\partial E_p}{\partial O_j} \frac{\partial O_j}{\partial N_j} \frac{\partial N_j}{\partial W_{ij}} \\ &= \left(\sum_k \frac{\partial E_p}{\partial O_k} \frac{\partial O_k}{\partial N_k} \frac{\partial N_k}{\partial O_j} \right) \frac{\partial O_j}{\partial N_j} \frac{\partial N_j}{\partial W_{ij}} \\ &= -\sum_k (\delta_{pk} \cdot f'(N_k) \cdot W_{jk}) \cdot f'(N_j) \cdot O_i \\ &= -\delta_{pj} \cdot f'(N_j) \cdot O_i \end{aligned} \quad (7)$$

$$\Delta W_{ij} = \eta \cdot \delta_{pj} \cdot f'(N_j) \cdot O_i \quad (8)$$

실용적 목적에서는 연결강도 공간에서 계적을 부드럽게 하기 위해 모우멘텀 계수를 사용한다. 학습의 $n+1$ 번째 반복에서 사용되는 실제의 연결강도 조정은 (9)식으로 주어진다.

$$\Delta W_{ij}(n+1) = \eta \cdot \delta_{pj} \cdot f'(N_j) \cdot O_i + \beta \cdot \Delta W_{ij}(n) \quad (9)$$

(9)식에서 β 는 n 번째 학습에서의 연결강도의 조정량이 $\Delta W_{ij}(n+1)$ 에 기여하는 비를 나타내는 파라

미터이다.

BP에 의한 학습은 입력과 동시에 출력의 세시를 필요로 한다. 따라서 역기구학 신경회로망을 BP으로 학습시키기 위해서는 매니퓰레이터핸드의 공간위치 뿐만 아니라 그에 대응하는 관절위치를 정확하게 알아야 한다. 이 문제점은 sensory-motor circular reaction hypothesis[19]를 통해 해결될 수 있다. 그러나 Sensory-motor circular reaction에 의한 신경회로망의 학습은 실제 매니퓰레이터를 구동하여야 하고, 또한 매니퓰레이터 핸드의 공간 위치를 정확하게 감지하는 센서를 필요로 한다. 본 논문에서는 작업을 간단히 하기 위하여 매니퓰레이터의 역기구학적 구조를 미리 정확히 안다고 가정하고 학습을 수행하였다. 매니퓰레이터의 표본 공간 위치값이 역기구학 신경 회로망에 입력되면, 입력 활성은 출력층으로 전파되고 출력층에서 관측된 활성과 매니퓰레이터의 정확한 기구학으로부터 계산된 목표출력 사이의 오차가 구해진다. 이 오차는 신경회로망의 연결 강도를 조정하는데 사용된다.

4. 두 번째 단계에서는 관절 궤적 계획

관절 궤적 계획은 매니퓰레이터의 각 관절을 초기 위치로부터 목표 위치까지 제어하기 위한 관절 궤적을 각 관절에 대한 여러 제한을 만족하도록 계획하는 것이다. 본논문에서는 관절 궤적의 위치 방정식은 (3)식의 1차 선형 미방으로 표현되며, (3)식에서 α 와 n 은 관절 궤적을 결정하는 파라미터이다. 관절 궤적계획은 관절 궤적을 여러 제한을 만족하도록 (3)식에서 α 와 n 을 결정하는 것이다. (3)식의 위치 방정식의 해는 관절의 초기위치를 $\theta(0)$ 라고 할 때 (10)식으로 표현된다.

$$\theta(t) = \theta_d + (\theta(0) - \theta_d) \cdot \text{EXP}(-\alpha t^{n+1}/(n+1)) \quad (10)$$

이때 $\theta(t)' = \theta(t) - \theta(0)$, $\theta_d' = \theta_d - \theta(0)$ 라고 하면 관절의 궤적은 (11)식으로 표현된다. (11)식에서 $\theta(t)'$ 는 초기 위치 0으로부터 목표위치 θ_d' 까지의 궤적을 의미하며, 실제 궤적 $\theta(t)$ 는 $\theta(t) = \theta(t)' + \theta(0)$ 로부터 구한다. 본논문에서 수식의 전개는 (11)식을 이용한다.

$$\theta(t)' = \theta_d' \cdot (1 - \text{EXP}(-\alpha t^{n+1}/(n+1))) \quad (11)$$

4.1 동기성

로보트 매니퓰레이터의 PTP운동은 일반적으로 매니퓰레이터의 각 관절이 동시에 운동을 시작하

여 동시에 운동을 끝낼 수 있는 궤적을 필요로 한다. 매니퓰레이터의 i 번째 관절의 목표 위치와 관절 궤적을 θ_{id}' , $\theta_i(t)'$ 라고 하고 j 번째 관절의 목표 위치와 관절 궤적을 θ_{jd}' , $\theta_j(t)'$ 라고 하면 (11)식에 의해 다음의 관계가 성립한다.

$$\theta_i(t)' = \frac{\theta_{id}'}{\theta_{jd}'} \cdot \theta_j(t)' \quad (12)$$

로보트 매니퓰레이터의 j 번째 관절이 궤적에 의해 시간 t_f 에 목표 위치에 도달하면 $(\theta_j(t_f))'$, (12)식에 의해 i 번째 관절도 $\theta_i(t_f)' = \theta_{id}'$ 를 항상 만족하게 된다. 따라서 α 와 n 이 일정할 때 (11)식에 의해 계획된 관절 궤적은 매니퓰레이터의 각 관절이 동시에 운동을 시작하면 매니퓰레이터의 각 관절이 항상 동시에 운동을 끝내는 것을 만족시킨다.

4.2 궤적의 속도, 가속도, 저크

(11)식에 의해 구해지는 매니퓰레이터의 관절 궤적의 속도 $v(t)$, 가속도 $a(t)$, 그리고 저크 $j(t)$ 는 다음과 같다. 이들은 연속이다.

$$v(t) = \alpha \cdot \theta_d' \cdot \text{EXP}(-at^{n+1}/(n+1)) \cdot t^n \quad (13)$$

$$a(t) = \alpha \cdot \theta_d' \cdot \text{EXP}(-at^{n+1}/(n+1)) \cdot (n - at^{n+1}) \cdot t^{n-1} \quad (14)$$

$$j(t) = \alpha \cdot \theta_d' \cdot \text{EXP}(-at^{n+1}/(n+1)) \cdot (n(n-1) - 3ant^{n+1} + a^2t^{2(n+1)}) \cdot t^{n-2} \quad (15)$$

위의 식들로부터 관절 궤적의 속도, 가속도, 그리고 저크의 초기값은 θ_d' 와 α 가 주어졌을 때 n 에 따라 결정됨을 알 수 있다. n 이 0보다 크게 되면 속도의 초기값이 0이 되며, n 이 1보다 크게 되면 가속도의 초기값이 0이 된다. n 이 2보다 크게 되면 저크의 초기값이 0이 된다. n 이 0보다 크면 이들의 최종값은 모두 0이 된다.

4.3 대칭율

관절 궤적의 대칭율 SR은

$$SR = \frac{\text{the time taken to move half the distance}}{\text{the total movement duration}}$$

으로 정의되어[17], SR에 의해 속도 궤적의 대칭성이 결정된다. 관절 궤적의 대칭율은 식 (11)에서 n 에 의해 결정되는데, $n=3$ 인 경우에는 약 0.495가 된다.

4.4 궤적 계획

관절 궤적 계획은 매니퓰레이터의 각 관절을 초기 위치로부터 목표 위치까지 제어하기 위하여 시간에 대한 제어 셀 포인트의 시퀀스를 속도 제한, 가속도 제한, 그리고 저크 제한을 만족하도록 계

획하는 것이다. 제안된 모델에서 고려된 관절 궤적의 속도 제한, 가속도 제한, 그리고 저크 제한은 다음과 같다.

1) 속도 제한 : 속도 궤적이 연속이고 그 절대값이 제한 속도보다 작아야 한다. 초기 속도와 최종 속도는 '0'이어야 한다.

2) 가속도 제한 : 가속도 궤적이 연속이고 그 절대값이 제한 가속도보다 작아야 한다. 초기 가속도와 최종 가속도는 '0'이어야 한다.

3) 저크 제한 : 저크 궤적이 연속이어야 한다.

그런데 제안 모델에서 (13), (14), (15)식으로 표현되는 속도 궤적, 가속도 궤적, 그리고 저크 궤적은 연속이며, 속도 궤적과 가속도 궤적의 최종값은 0임을 알고 있으므로 관절 궤적 계획은 제한 속도와 제한 가속도 조건과 초기 속도와 초기 가속도 조건을 만족하도록 관절 궤적을 결정하는 파라미터인 α 와 n 을 결정하는 것이 된다. n 은 SR과 속도 궤적과 가속도 궤적의 초기값을 결정하는 파라미터인데 n 이 1보다 크면 속도 궤적과 가속도 궤적의 초기값이 0이 되므로 n 은 1보다 큰 값중에서 관절 궤적의 SR이 사용 목적에 맞게 되도록 결정한다. 제한 속도와 제한 가속도 조건은 양의 수인 파라미터 α 에 의해 결정하는데 파라미터 α 의 결정 방법은 다음과 같다.

속도 궤적의 최대 절대값 MAX_V는 $a(t)=0$, $0 < t < t_f$ 을 만족시키는 시간 $t = \sqrt{n+1}/(\sqrt{n}\alpha)$ 에서 구해지며, 가속도 궤적의 최대 절대값 MAX_A는 $j(t) = 0$, $0 < t < t_f$ 을 만족시키는 시간 $t = \sqrt{n+1}/\sqrt((3n \pm \sqrt(5n^2 + 4n))/(2\alpha))$ 에서 구해진다. MAX_V와 MAX_A는 (16)과 (17)식으로 나타난다. 이때 제한 속도를 VEL_CON이라고 하고 제한 가속도를 ACCEL_CON이라고 하면, (16)과 (17)식으로부터 MAX_V가 항상 VEL_CON보다 작은 값을 갖게 하는 α 의 수프리멈 α_v 와 MAX_A가 항상 ACCEL_CON보다 작은 값을 갖게 하는 α 의 수프리멈 α_a 는 (18), (19)식과 같이 나타난다. 제한 속도와 제한 가속도 조건을 동시에 만족시키는 파라미터 α 의 수프리멈 α_s 는 α_v 와 α_a 중 작은 것이 된다((20)식).

$$MAX_V = |\theta_d' \cdot \alpha^{1/(n+1)} \cdot n^{n/(n+1)} \cdot \text{EXP}(-n/(n+1))| \quad (16)$$

$$\begin{aligned} MAX_A = \max \{ & |\theta_d' \cdot \alpha^{2/(n+1)} \\ & \cdot (n - (3n + \sqrt(5n^2 + 4n))/2)/ \\ & \cdot ((3n + \sqrt(5n^2 + 4n))/2)^{(n-1)(n+1)} \\ & \cdot \text{EXP}(-(3n + \sqrt(5n^2 + 4n))/(2n+2))|, \end{aligned}$$

$$\begin{aligned} & |\theta_d' \cdot \alpha^2 / (n+1) \cdot (n - (3 - \sqrt{(5n^2 + 4n)})/2) \\ & \cdot ((3n - \sqrt{(5n^2 + 4n)})/2)^{(n-1)/(n+1)} \\ & \cdot \text{EXP}(-(3n - \sqrt{(5n^2 + 4n)})/(2(n+2)))| \end{aligned} \quad (17)$$

$$a_v = \left[\frac{\text{VEL_CON}}{|\theta_d' \cdot n^{n/(n+1)} \cdot \text{EXP}(-n/(n+1))|} \right]^{(n+1)} \quad (18)$$

$a_a = \max\{$

$$\left[\frac{\text{ACCEL_CON}}{\left[\frac{|\theta_d' \cdot (n - (3n - \sqrt{(5n^2 + 4n)})/2) \\ \cdot ((3n - \sqrt{(5n^2 + 4n)})/2)^{(n-1)/(n+1)} \\ \cdot \text{EXP}(-(3n - \sqrt{(5n^2 + 4n)})/(2(n+2)))|}{\text{ACCEL_CON}} \right]^{(n+1)} \right] \quad (19)$$

$$\left[\frac{|\theta_d' \cdot (n - (3n + \sqrt{(5n^2 + 4n)})/2) \\ \cdot ((3n + \sqrt{(5n^2 + 4n)})/2)^{(n-1)/(n+1)} \\ \cdot \text{EXP}(-(3n + \sqrt{(5n^2 + 4n)})/(2(n+2)))|}{\text{ACCEL_CON}} \right]^{(n+1)} \quad (20)$$

$$a_s = \min\{a_v, a_a\}$$

5. 시뮬레이션 결과

로보트 매니퓰레이터의 PTP 궤적 계획은 첫번째 역기구학 단계와 두번째 관절 궤적 계획 단계의 두 가지 문제로 구성된다. 본 장에서는 이 두 단계에 대한 시뮬레이션 결과를 나누어 나타낸다.

5.1 첫번째 단계 : 역기구학

신경 회로망에 의한 역기구학 시뮬레이션에 사용한 대상 로보트 매니퓰레이터는 2자유도를 가지며 기구학적 구조는 그림 4와 같다. 이 매니퓰레이터의 기구학과 역기구학 해는 식 (21)과 (22)와 같다. 역기구학 신경회로망으로는 다층 perceptron이 사용되었으며 BP 학습 법칙으로 역기구

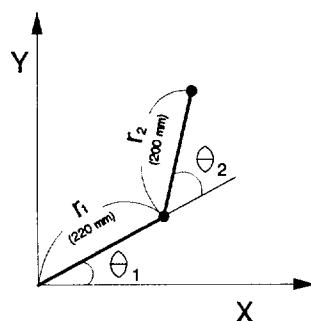


그림 4 시뮬레이션에 사용된 대상 로보트 매니퓰레이터

Fig. 4 Target Robot Manipulator for Simulation

학의 학습이 수행되었다. 역기구학 신경회로망의 입력은 식 (22)의 (x, y) 가 되며, 출력은 (θ_1, θ_2) 가 된다. 신경회로망의 연결 강도의 초기치는 -0.3에서 +0.3 사이의 random number로 설정되었다. 3장에서 설명한 학습 방법에 의해 역기구학 신경회로망의 연결 강도는 신경회로망이 식 (22)의 역할을 수행하도록 조정된다. 시뮬레이션에서 학습율은 0.2로 설정되었고 모우멘텀은 0.9로 설정되었다.

— 기구학

$$x = r_1 \cos(\theta_1) + r_2 \cos(\theta_1 + \theta_2) \quad (21-1)$$

$$y = r_1 \sin(\theta_1) + r_2 \sin(\theta_1 + \theta_2) \quad (21-2)$$

— 역기구학

$$\begin{aligned} \theta_1 &= \text{atan}2\left(\frac{y}{x}\right) - \cos^{-1}\left(\frac{x^2 + y^2 - (r_2^2 - r_1^2)}{2r_1\sqrt{x^2 + y^2}}\right) \\ (22-1) \end{aligned}$$

$$\theta_2 = \pi - \cos^{-1}\left(\frac{r_1^2 + r_2^2 - x^2 - y^2}{2r_1r_2}\right) \quad (22-2)$$

시뮬레이션에서 매니퓰레이터의 작업 공간은 그림 5와 같이 전체 매니퓰레이터의 작업 공간의 일부로 제한하였다. 학습을 수행하기 위한 표본 학습점은 그림 5의 주어진 작업 공간에서 그림 6에서와 같이 28점과 81점을 선택하였다. 시뮬레이션은 이들에 대해 각각 수행하였다. 그림 6의 (b)에서와 같이 81점의 표본 학습점을 선택한 이유는 그림 6의 (a)와 같이 학습 표본을 선택한 경우,

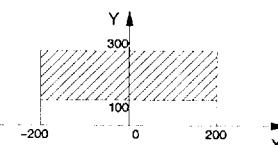
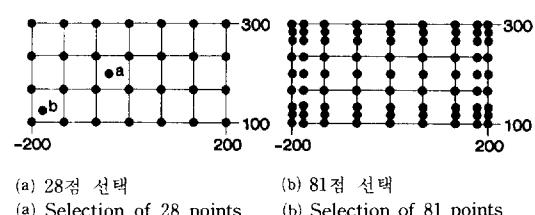


그림 5 역기구학 문제 해결에 사용된 작업공간
Fig. 5 Workspace Used for the Inverse Kinematics



(a) 28점 선택

(a) Selection of 28 points

(b) 81점 선택

(b) Selection of 81 points

그림 6 표본 학습점의 선택

Fig. 6 Selection of Learning Points

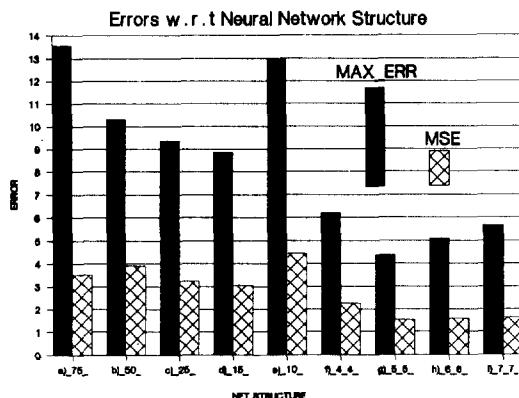


그림 7 신경 회로망 구조에 따른 오차 분석
Fig. 7 Error Analysis w.r.t. Neural Network Structures

충분히 학습시킨 역기구학 신경회로망의 performance가 작업공간의 중심부에 비해 경계부에서 떨어졌기 때문이다.

그림 7은 28점의 표본 학습점으로 각각 학습시킨 28개의 시뮬레이션 결과를 시뮬레이션 결과를 보여주고자 한다.

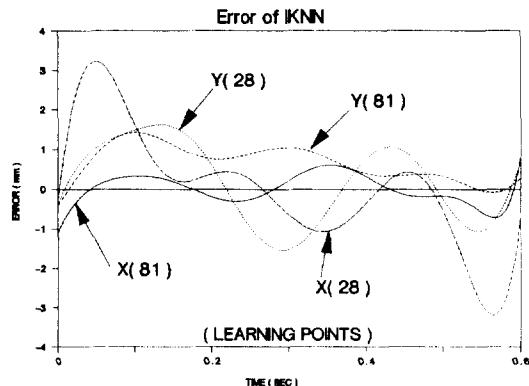


그림 8 55 신경 회로망을 사용한 역기구학 시뮬레이션 결과
Fig. 8 Simulation Results Using a 55 Neural Network

회로망이 역기구학에 가장 좋은 성능을 보였다. 81점의 표본 학습점에 대한 시뮬레이션도 같은 결과를 보였다.

그림 8은 28개와 81개의 표본 학습점으로 각각 학습시킨 55 신경회로망의 시뮬레이션 결과를 보여준다.

과이다. 이때 학습 회수는 각 회로망 구조에 대해 10⁵번 수행하였으며, 오차는 작업 공간에서 14641 점을 선택하여 구하였다. 그림 7에서 N 은 역기구학 신경회로망이 3층이고 중간층의 신경세포가 N 개인 회로망에 대한 시뮬레이션 결과를 나타내며, N 은 신경회로망이 4층이고 각 중간층의 신경 세포의 수가 각각 N 개인 경우를 나타낸다. Mean Square Error(MSE)는 식 (23)과 같이 정의되며, 최대 오차(MAX_ERR)는 식 (24)와 같이 정의된다.

$$MSE = \sum_{i=1}^N \sqrt{((X_{id} - \bar{X}_i)^2 + (Y_{id} - \bar{Y}_i)^2)} / N \quad (23)$$

$$MAX_ERR = \max_{1 \leq i \leq N} \{\sqrt{((X_{id} - \bar{X}_i)^2 + (Y_{id} - \bar{Y}_i)^2)}\} \quad (24)$$

(23)과 (24)에서 (X_{id}, Y_{id}) 는 매니퓰레이터 핸드의 목표 공간 위치를 의미하며 (\bar{X}_i, \bar{Y}_i) 는 역기구학 신경회로망의 출력에 의한 매니퓰레이터 핸드의 실제 이동 위치를 의미한다. N 은 시뮬레이션 점의 수이다. 그림 7로부터 역기구학 신경회로망의 performance는 신경회로망의 중간층의 수나 각

의 신경 세포의 수가 5개씩인 경우)의 신경 회로망을 사용한 역기구학 시뮬레이션 결과를 나타낸다. 이때 매니퓰레이터는 작업 공간상에서 $Y = \frac{1}{2}X + 200$ 인 직선을 따라 이동한다고 가정한다. 그림 8로부터 표본 학습점이 증가할수록 신경회로망의 성능이 향상됨을 볼 수 있다. 또한 작업 공간에

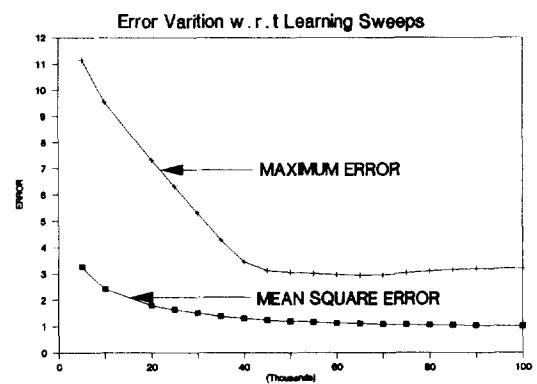


그림 9 학습 횟수에 따른 역기구학 시뮬레이션 결과
Fig. 9 Simulation Results According to the Number of Learning Sweeps

서 균일하게 28개의 표본 학습점을 선택하여 신경회로망을 학습시킨 경우 역기구학 신경회로망은 작업공간의 경계부분에서 큰오차를 나타냄을 볼 수 있으며, 작업공간의 경계부분에서 표본밀도가 크게 81개의 표본학습점을 선택하여 신경회로망은 학습시킨 경우 역기구학 신경회로망은 작업공간의 전 영역에서 비교적 고른 오차 분포를 나타냄을 볼 수 있다. 이것은 등간격으로 표본 학습점을 선택한 경우 작업공간의 중심부에서는 한 공간 점에 대해 주변에 고른 표본 학습점의 분포를 갖게 되나 (예: 그림 6-(a)의 a점), 경계선 부분의 공간 점들은 중심부에 비해 보다 적은 이웃한 표본 학습점을 공유하기 때문이다(예: 그림 6-(a)의 b점).

그림 9는 81개의 표본학습점으로 학습시킨 5_5 구조의 역기구학 신경회로망의 학습회수에 따른 performance를 나타낸다.

5.2 두번째 단계 : 관절 궤적 계획

관절 궤적 계획에 관한 시뮬레이션은 첫째 매니퓰레이터의 한 관절에 대해 둘째 두관절을 갖는

매니퓰레이터에 대해 각각 실행하였다.

그림 10은 제안 모델로부터 발생시킨 관절 궤적을 나타낸다. 목표관절 위치 θ_d' 는 1 radian이다. 제안 모델에서 제한 속도는 1.1 rad/sec, 그리고 제한 가속도는 2 rad/sec²으로 하였다. 제안모델로부터 발생된 관절 궤적, 속도 궤적, 가속도 궤적, 그리고 저크 궤적이 모두 부드러운 연속의 곡선으로 표현됨을 알 수 있다. 이때 제안 모델에서 모델 파라미터 n 이 결정되었을 때 식 (18) -(20)에 의해 결정되는데, 제안모델에 의해 계획된 관절궤적이 항상 모든 제한을 만족시킴을 볼 수 있다.

그림 11은 제안한 모델로 계획한 2자유도를 갖는 매니퓰레이터에 대한 관절 궤적 시뮬레이션 결과이다. 매니퓰레이터 관절 1의 목표 관절 위치 θ_{1d}' 는 2 radians, 제한 속도는 2.5 rad/sec, 그리고 제한 가속도는 6 rad/sec²으로 하였으며, 관절 2의 목표 관절 위치 θ_{2d}' 는 3 radians, 제한 속도는 4 rad/sec, 그리고 제한 가속도는 8 rad/sec²으로 하였다. 이때 n 은 3으로 하였으며 매니퓰레이터

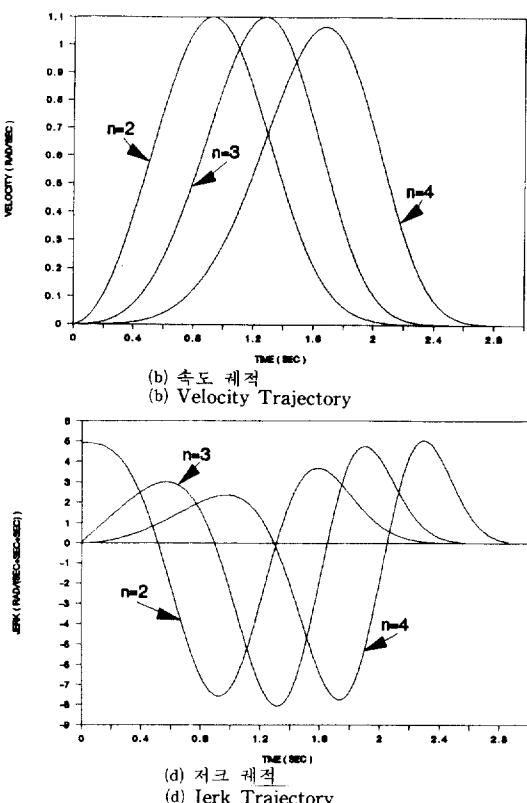
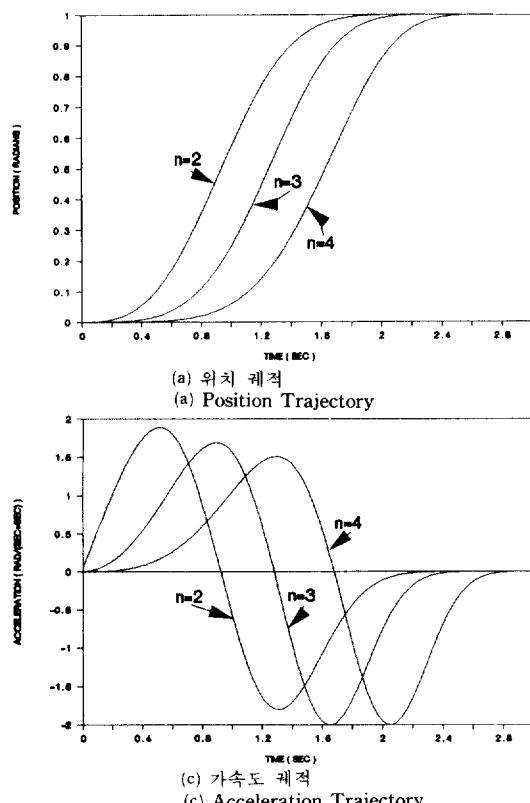


그림 10 제안 모델에 의해 계획된 관절 궤적

Fig. 10 Joint Trajectories Planned by the Proposed Model

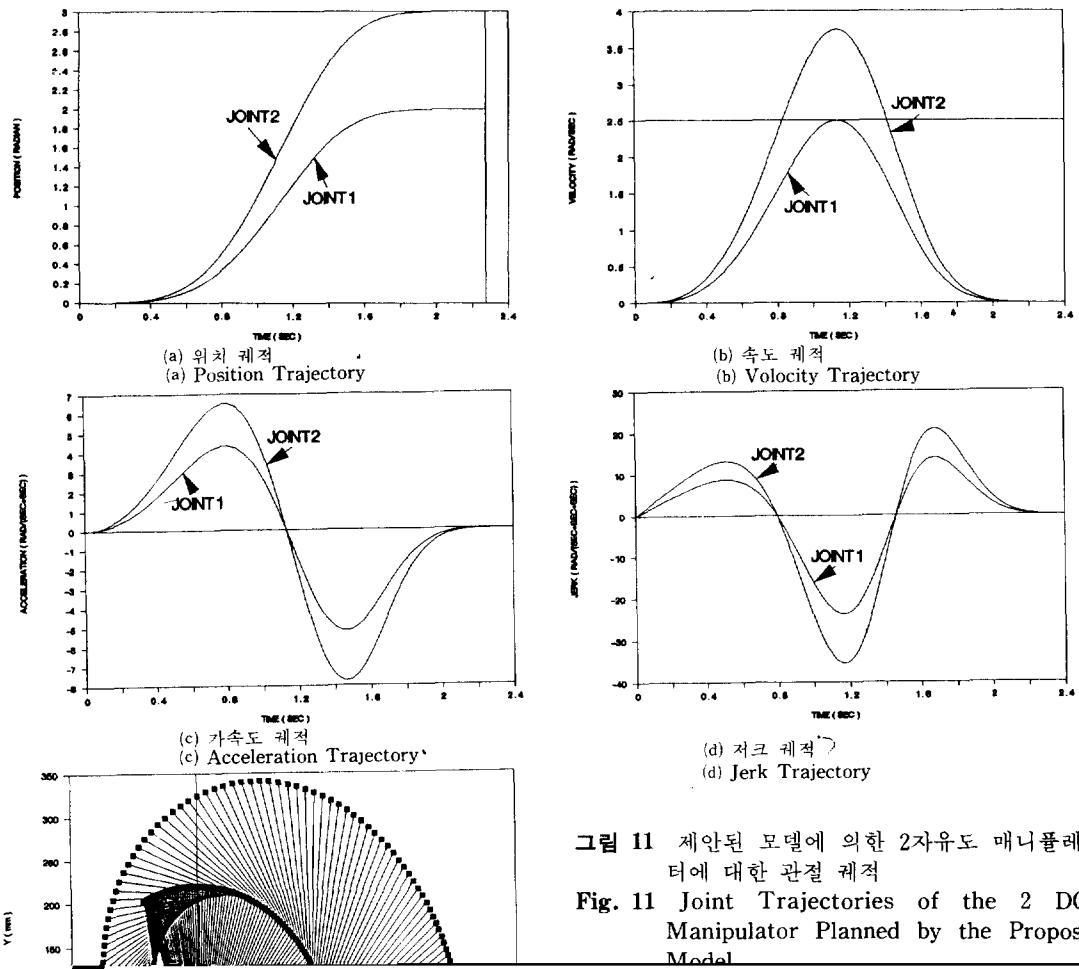


그림 11 제안된 모델에 의한 2자유도 매니퓰레이터에 대한 관절 궤적

Fig. 11 Joint Trajectories of the 2 DOF Manipulator Planned by the Proposed Model

역기구학 신경회로망의 성능을 분석하여 역기구학 해결에 가장 적합한 다층 Perceptron 신경회로망의 구조에 대해 조사하였다.

관절 궤적 계획 모델은 saccadic eye movement에 관한 Robinson 모델에 궤적 형성모델인 VITE 모델에서 제시한 온셀 함수를 보충함에 의해 제안되었다. 제안된 모델은 다음의 특징들을 갖는다.

- 1) 동기성: 매니퓰레이터의 각 관절 궤적은 파라미터 α 와 n 이 모든 관절에 대해 고정되면 동기화 될 수 있다.
- 2) 대칭율(SR): 전체 움직임의 기간을 $1/2$ 거리를 움직이는데 소요되는 시간으로 나눈값으로 정의되는 SR은 파라미터 n 에 의해 조정된다.
- 3) 제한: 제안된 모델에서 고려된 제한 조건들은 다음과 같다.
 - a) 속도 제한: 속도 궤적이 연속이고 속도 궤적의 초기치와 최종치는 0으로 만들수 있다. 속도 궤적은 제한 속도에 의해 바운드 된다.
 - b) 가속도 제한: 가속도 궤적이 연속이며 가속도 궤적의 초기치와 최종치는 0으로 만들 수 있다. 가속도 궤적은 제한 가속도에 의해 바운드 된다.
 - c) 저크 제한: 저크 궤적이 연속이며 저크 궤적의 초기치와 최종치를 0으로 만들수 있다.

참 고 문 헌

- [1] K.S. Fu, R.C. Gonzalez, and C.S.G. Lee, *ROBOTICS : Control, Sensing, Vision, and Intelligence*, McGraw-Hill Book Company, 1987.
- [2] Christopher G. Atkeson, "Learning Arm Kinematics and Dynamics," Annual Review of Neuroscience, vol. 12, pp. 157~183, 1989.
- [3] J.S. Albus, "A New Approach to Manipulator Control : The Cerebellar Model Articulation Controller(CMAC)," Transactions of the ASME, pp. 220~227. September 1975.
- [4] J.S. Albus, "Mechanisms of Planning and Problem Solving in the Brain," Mathematical Biosciences 45, pp. 247~293, 1979.
- [5] W. Thomas Miller, "Sensor-Based Control of Robotic Manipulators Using a General Learning Algorithm," IEEE Journal of Robotics and Automation, Vol. RA-3, No. 2, April 1987.

- [6] F. Rosenblatt, "The Perceptron : A Probabilistic Model for Information Storage and Organization in the Brain," Psychological Review 65, pp. 386~408, 1958.
- [7] Marvin Minsky and Seymour Papert, *Perceptron : An Introduction to Computational Geometry(Second Edition)*, MA : The MIT Press, 1988.
- [8] Richard P. Lippmann, "An Introduction to Computation with Neural Nets," IEEE ASSP Magazine, April 1987.
- [9] D.E. Rumelhart, J.L. McClelland, and the PDP Research Group, "Learning Internal Representations by Error Propagation," Parallel Distributed Processing : Explorations in the Microstructures of Cognition, vol. 1, MA : The MIT Press, pp. 318~362, 1986.
- [10] D.E. Rumelhart, G.E. Hinton, and R.J. Williams, "Learning Representations by Backpropagating Errors," Nature 323, pp. 533~536, 1986.
- [11] Allon Guez, and Ziauddin Ahmad, "Solution to the Inverse Kinematics Problem in Robotics by Neural Networks," IEEE IJCNN'88, vol. II, pp. 617~624, July 1988.
- [12] Gary Josin, "Integrating Neural Networks with Robots," AI Expert, pp. 50~58, August 1988.
- [13] D.A. Robinson, "Oculomotor Control Signals," Basic Mechanisms of Ocular Motility and Their Clinical Implications(G. Lemnerstrand and P. Bach-y-Rita(Eds)), Pergamon Press, pp. 337~374, 1975.
- [14] J.A.M. Van Gisbergen, D.A. Robinson, and S. Gielen, "A Quantitative Analysis of Generation of Saccadic Eye Movements by Burst Neurons," Journal of Neurophysiology, vol. 45, No. 3, March 1981.
- [15] A.F. Fuchs, C.R.S. Kaneko, and C.A. Scudder, "Brainstem Control of Saccadic Eye Movements," Annual Review of Neuroscience, vol. 8, pp. 307~337, 1985.
- [16] Daniel Bullock, and Stephen Grossberg, "A Neural Network Architecture for Automatic Trajectory Formation and Coordination of Multiple Effectors During Variable-Speed Arm Movements," IEEE IJCNN'87, vol. IV,

- pp. 559~566, June 1987.
- [17] D. Bullock and S. Grossberg, "Neural Dynamics of Planned Arm Movements: Emergent Invariants and Speed-Accuracy Properties During Trajectory Formation," *Neural Networks and Neural Intelligence*, MA : The MIT Press, 1988.
- [18] Stephen Grossberg, "Nonlinear Neural Networks : Principles, Mechanisms, and Architectures," *Neural Networks*, vol. 1, pp. 17~61, 1988.
- [19] Michael Kuperstein, "Adaptive Visual-Motor Coordination in Multijoint Robots Using Parallel Architecture," *IEEE Internat. Conf. Robotics & Automat.*, pp. 1595~1602, 1987.