

로봇 매니플레이터 제어를 위한 개조된 자기조직화 신경망 개발

구태훈 · 이종태

동국대학교 산업시스템 공학부

Development of the Revised Self-Organizing Neural Network for Robot Manipulator Control

Taehoon Koo · Jongtae Rhee

Industrial robots have increased in both the number and applications in today's material handling systems. However, traditional approaches to robot controlling have had limited success in complicated environment, especially for real time applications. One of the main reasons for this is that most traditional methods use a set of kinematic equations to figure out the physical environment of the robot. In this paper, a neural network model to solve robot manipulator's inverse kinematics problem is suggested. It is composed of two Self-Organizing Feature Maps by which the workspace of robot environment and the joint space of robot manipulator is inter-linked to enable the learning of the inverse kinematic relationship between workspace and joint space. The proposed model has been simulated with two robot manipulators, one, consisting of 2 links in 2-dimensional workspace and the other, consisting of 3 links in 2-dimensional workspace, and the performance has been tested by accuracy of the manipulator's positioning and the response time.

1. 서론

오늘날 산업현장에서는 물류비 감소와 생산성 향상을 위한 많은 요소기술들이 적용되고 있으며 그 중에서도 로봇틱스는 이미 광범위한 응용분야를 갖는 핵심기술이 되고 있다. 종래의 로봇은 대량생산시스템 환경에서 일괄적인 재생방법(teach and play method) 또는 제약적 프로그래밍으로 작업이 계획되었으나 오늘날 제품의 수명주기가 짧아진 다품종 소량생산시스템 환경의 단속적 공정에서는 공정의 변화에 빠르게 적용할 수 있는 능력이 필요하게 되었다.

이러한 다양한 로봇작업을 위한 입력 자료를 생성하기 위해 컴퓨터를 이용하여 작업 데이터를 미리 생성하는 오프라인 프로그래밍(off-line Programming)기법이 연구되어 왔다. 오프라인 프로그래밍을 이용한 로봇 프로그래밍을 위해 기본적으로 해결해야 할 문제로서 로봇 위치제어를 위한 역방향 기구학 문제(inverse kinematic problem)와 작업장의 환경변수를 고려한 충돌 회피경로 발견 문제를 들 수 있다[2,4]. 본 연구의 목적은 로봇 오프라인 프로그래밍의 선결 문제인 역방향 기구학을 해결

하는데 있어서 신속하고도 정확하게 해를 발견할 수 있으며 로봇 매니플레이터의 구조에 종속되지 않는 방법론을 제시하는 것이다.

역방향 기구학은 로봇 매니플레이터의 제어와 설계 측면에서 많은 연구가 진행되어 왔는데, 이러한 기존연구는 접근방법에 따라서 두 가지 방법론으로 구분할 수 있다. 첫째는 수리적인 해법을 이용한 알고리즘적 방법으로, Baillieul(1986)과 Klein and Huang(1983)의 의사 역행렬 방법(Pseudo inverse Method)은 이에 속한다. 또한, Nakamura(1987)는 매니플레이터의 현위치와 목표점의 위치를 고려하고 기구학의 제약식을 만족하면서 관절각의 궤적이 최소화하는 최적화 기법을 제안하였다. 그리고 Asada(1986) 등은 리아푸누프 안정이론을 바탕으로 한 방법인 리아푸누프 방법(Liapunov Method)을 제안하였다. 이러한 방법들은 작업공간에서의 닫힌 궤적이 관절공간의 닫힌 궤적과 항상 대응되지 못하는 단점 때문에 로봇 매니플레이터의 궤적을 프로그래밍에 반영하기 어렵다는 단점을 가지고 있으며 해를 구하는 계산량과 계산시간에 제약을 받는다. 둘째는 비수리적인 해법으로서 반응 시간(response time)을 단축하기 위한 신경망에 의한 접근방법이 대표적이다. Jordan(1992)과 Aylor

(1992)는 역전파 신경망(Backpropagation Network)을 이용한 작업공간과 관절공간의 기구학적 해결을 위한 학습 방법을 제안했다. Guo(1989)와 Kindermann(1990)은 신경망 모형 중에서 최적화 문제를 해결하는 모형으로 많이 적용되는 회귀 신경망(Recurrent Network)을 이용하는 방법을 제안하였다. 또한 Demers(1995)와 Pan(1993)은 자기조직화신경망(Self-Organizing Neural Network)을 이용한 방법을 제안했다. 신경망을 이용한 이러한 접근방법들은 수리적 방법에 비해 간단하며 적용시 반응시간의 개선 등 많은 장점을 가지고 있다. 그러나 이러한 방법들 대부분은 작업공간의 위치와 관절공간의 관절각과의 일대일 관계만을 학습한 경우가 대부분이어서 다관절 로봇의 경우 작업공간과 관절공간은 일대일이 아닌 일대다인 경우가 일반적이므로 목표점에 대한 연속적인 궤적을 프로그램할 때 어려운 점을 갖고 있었으며 다관절 로봇의 구조에 따라 적용이 제한되었다.

이 연구는 작업공간(workspace)과 관절공간(joint space)의 함수적 사상관계를 연속공간상에서 학습할 수 있도록 구축한 개조된 자기조직화형상지도(Self-Organizing Feature Map : SOFM) 신경망을 개발, 이를 이용하여 로봇 제어에 필요한 역방향 기구학 문제를 해결하는 것을 목적으로 한다. 특히, 로봇 매니플레이터의 구조적 특성에 따라서 탐색 영역을 분할, 학습 속도와 정밀도를 높이고 유연한 로봇작업 경로를 얻을 수 있도록 하는 방법을 제시한다. 그리고 제안된 방법의 수행도를 측정하기 위해 정방향 기구학으로 얻어지는 최적해와 차이를 비교 분석하고 제안된 신경망의 구조와 학습 모수의 변화에 따른 민감도 분석을 수행한다.

2. 로봇 매니플레이터의 기구학

로봇 매니플레이터란 관절(joint)과 링크(link)로 연결된 연쇄(chain) 물체의 조합으로서 각 관절은 양쪽으로 각각 하나의 링크에 연결되어 관절의 수는 매니플레이터의 자유도(degree of freedom)를 결정한다(Groover, 1987; Rudolph, 1993).

기구학은 로봇 매니플레이터를 통제하고 목표점과 관절각의 관계를 해석하여 로봇의 움직임에 대한 해를 발견하는 방법론이다(Craig, 1989). 로봇의 움직임은 로봇 매니플레이터의 회전관절 크기를 규정하는 관절공간과 작업장에서 로봇 매니플레이터의 위치를 결정하는 작업공간상에서 정의될 수 있는데, <그림 1>과 같이 두 공간의 사상(mapping)으로 로봇 매니플레이터의 기구학을 설명할 수 있으며 또한 로봇 매니플레이터 기구학에서 사상의 방향에 따라서 정방향과 역방향으로 구분한다.

정방향 기구학은 한 조의 관절각이 주어졌을 때, 기저계에 대한 엔드이펙터(end-effector)의 위치와 방향을 계산하는 정적 기하학이다. 공구의 위치와 방향은 각 링크의 공간적 관계와 관절의 회전 중심점으로부터의 각도를 이용하여 식(2.1)과 같




그림 1. 로봇 매니플레이터의 기구학.

이 계산할 수 있다. 이것은 관절공간 Θ 의 관절각 θ 를 도달 가능한 작업공간 W 의 엔드이펙터의 위치 x 로 사상하는 것이다.

$$x = f(\theta), \theta \in \Theta \text{ 그리고 } x \in W \triangleq f(\Theta) \quad (2.1)$$

역방향 기구학은 엔드이펙터의 작업공간상의 위치로부터 관련된 관절각의 해를 구하는 것을 말한다. 만약 그러한 해가 존재하지 않으면 로봇의 엔드이펙터의 위치는 가능한 작업공간에 없음을 의미한다. 역방향 기구학 함수(inverse kinematics function)는 다음 식(2.2)와 같다.

$$f^{-1}(x^{desire}) = \theta^{desire} \quad (2.2)$$

이것은 목표좌표 $x^{desire} \in W$ 가 주어졌을 때

$\theta^{desire} \in \Theta$ 인 집합을 찾는 것이다. 역방향 기구학의 해결은 정방향 기구학에 비해 복잡하게 되는데 그 이유는 기구학 방정식이 비선형이라는 점, 그리고 무한개의 해가 존재할 수 있기 때문이다(Craig, 1989; Rudolph, 1993).

3. 제안된 방법

3.1 신경망 모형

본 연구에서 제안된 방법의 기본적인 개념은 로봇 매니플레이터의 기구학 문제를 관절공간과 작업공간 사이의 사상 문제로 규정하고, 두 공간상의 사상관계를 신경망의 학습을 통해서 신경망 내의 노드간의 연결 관계 가중값으로 저장, 역방향 기구학 문제를 해결하는데 있다. 또한 실시간 프로그램이 가능하기 위해 학습된 신경망을 통한 역방향 기구학의 계산속도는 빨라야 한다.

기존의 Jordan(1992)과 Aylor(1992)는 이와 같은 로봇 매니플레이터의 기구학 문제의 특징인 관절공간과 사상관계의 일대일 사상관계를 교사학습(supervised learning scheme)인 역전파신경망(Backpropagation)을 이용한 모형을 제안하였다. 그러나 이와 같은 방법론은 로봇 자유도가 증가할 경우 몇 가지 문제점을 발생시킬 소지가 있다. 즉 일대일 사상(mapping)문제로 취급할 경우 얻어진 해로부터 유연한 로봇 작업경로를 설정하기 어려워진다는 점이다. 또한, 로봇의 자유도가 증가하게 되면 작업공간상의 한 점이 관절 공간상의 여러 점에 대응하게 되므로 신경망의 학습과정상 지역해에 귀착하거나 수렴하지 못하게 될 위험성이 있다. 지금까지의 기존연구는 (Aylor et al., 1992; Jordan and Rumelhart, 1992) 관절공간과 작업공간의 관절공간과 작업공간이 1대 1대응이 되는 경우만을 고려한 것이다.

따라서 제안된 방법에서는 위와 같은 요건을 만족하기 위해 신경망 모델 중 위상학습능력이 우수한 SOFM의 개념을 도입하여 관절공간과 작업공간에 대응하는 두 개의 SOFM 모델을 이용, 위상관계를 학습하도록 하였으며 두 공간을 연계시킬 수 있는 추가적인 학습방법을 개발하여 두 공간의 사상문제를 해결하고자 하였다. 또한, 환경적 제약조건인 로봇 매니플레이터의 자세들을 위상공간의 분할을 통해 분류함으로써 신경망의 계산속도와 로봇 매니플레이터의 정확도를 향상시켰다.

신경망 모형은 학습 방법에 따라서 크게 지도학습(supervised learning)을 하는 모형과 비지도학습(unsupervised learning)을 하는 모형으로 분류되는데 본 연구에서 기반으로 하는 SOFM은 비지도학습을 하는 자기조직화 신경망 모형으로 1984년 T. Kohonen(1984)에 의해 제안된 모형이다. 여기서 자기조직화 신경망의 연결강도가 입력패턴에 스스로 적응 학습하는 것을 말한다.

일반적인 SOFM의 구조는 <그림 2>와 같은 두 개의 층으로 이루어져 있다. 첫 번째 층은 입력층(input layer)이고, 두 번째 층은 경쟁층(competitive layer)이다. 첫 번째 층으로부터 두 번째 층으로는 모든 노드간의 완전한 연결이 이루어져 있으며 두 번째 층의 각 노드들은 상호 연결이 되어 있다. SOFM의 학습은 경쟁학습의 일종으로 입력 패턴이 입력층에 주어지면 경쟁층의 노드들이 학습할 수 있는 정도가 제한적으로 주어지는데, 입력 패턴과 가장 유사한 입력 연결가중치를 갖는 승자 노드(winner node)와 그 이웃 노드(neighborhood)들이 학습에 참여하게 된다. 경쟁층에서 승자 노드를 중심으로 한 이웃 노드의 학습영역범위는 학습이 진행됨에 따라서 축소된다. 이것은 SOFM의 학습의 중요한 특징으로 입력 패턴의 위상관계를 경쟁층상에 보존하는 요인이 된다.

3.1.1 제안된 신경망 구조

전술한 바와 같이 제안된 신경망은 관절공간과 작업공간의 위상을 학습할 수 있는 두 개의 SOFM의 결합 구조를 갖는다. 입력패턴에 반응하는 입력층이 있고, 관절공간과 작업공간의 위상관계를 보존하는 두 개의 경쟁층으로 구성된다. 관절공간

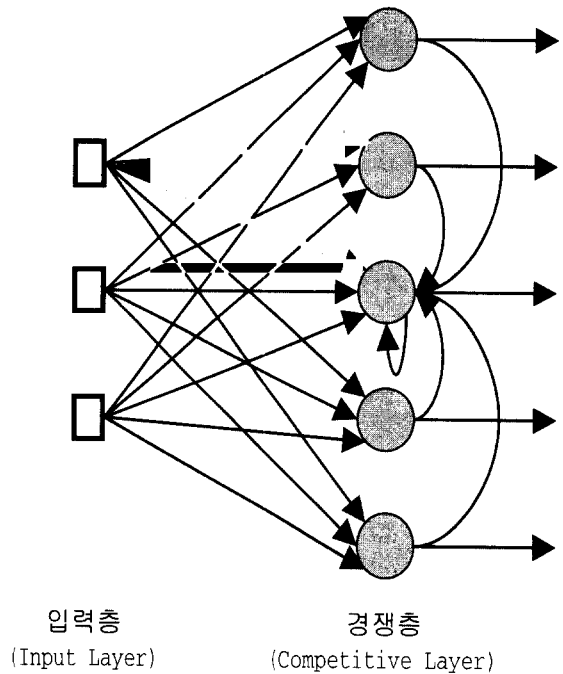


그림 2. 일반적인 SOFM의 구조.

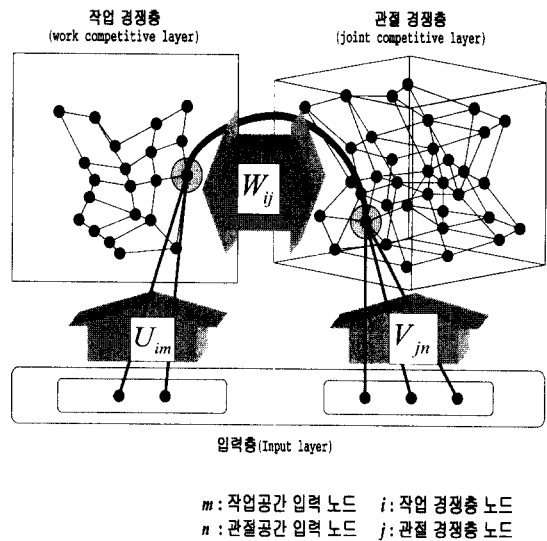


그림 3. 제안된 신경망의 구조.

이 3차원이고 작업공간이 2차원인 경우 <그림 3>과 같은 구조를 갖게 된다.

제안된 신경망의 각 입력패턴 I^k 는 관절공간 패턴과 식 (2.1)의 정방향 기구학으로부터 얻어진 작업공간의 패턴으로 구성된다. 따라서 입력층의 노드의 수는 입력패턴의 차원인 관절공간과 작업공간의 차원의 합이 된다.

경쟁층의 구조는 관절공간과 작업공간의 차원에 따라 결정된다. 관절공간을 학습하는 경쟁층을 관절 경쟁층(joint compe-

tive layer)이라 하고, 작업공간을 학습하는 경쟁층을 작업 경쟁층(work competitive layer)이라 하자. 관절공간이 2차원인 경우는 관절 경쟁층이 2차원의 평면적인 형태를 취하고, 3차원인 경우에는 관절 경쟁층이 3차원 격자 형태를 취한다. 두 경쟁층의 노드는 상호간에 완전 결합되며 입력패턴에 대한 승자노드를 구하기 위해 측면 제어(lateral inhibition)를 하게 되는데 편의상 이 연결구조는 모형에 나타내지 않기로 한다. 또한 작업 경쟁층의 각 노드는 관절 경쟁층의 각 노드와 완전한 상호 연결되며 연결강도는 대칭적이다.

따라서 제시된 모형의 연결강도는 입력층과 작업 경쟁층의 연결강도 $U_{im}(t)$, 입력층과 관절 경쟁층의 연결강도 $V_{jn}(t)$, 그리고 관절 경쟁층과 작업 경쟁층과의 연결강도 $W_{ij}(t)$ 로 구성된다. $U_{im}(t)$ 와 $V_{jn}(t)$ 는 각 공간의 위상관계를 학습하게 되고 $W_{ij}(t)$ 는 두 공간상의 사상관계를 학습하게 된다.

3.1.2 제안된 신경망의 학습 단계

신경망의 학습은 신경망을 구성하는 연결강도를 제시되는 입력패턴에 따라서 조정해 나가는 절차를 말하는데 제안된 신경망의 학습은 두 부분으로 구분된다. 첫째는 SOFM의 학습규칙을 적용한 두 개의 경쟁층의 연결강도 $U_{im}(t)$ 와 $V_{jn}(t)$ 의 자기조직화 학습이고, 둘째는 기구학적 사상관계를 표현할 경쟁층간의 연결강도 $W_{ij}(t)$ 의 학습이다.




그림 4. 이웃노드간의 위상관계.

경쟁층의 학습은 제시되는 입력패턴과 가장 유사한 연결강도를 가지는 노드를 승자 노드로 결정하는 경쟁 단계부터 시작된다. 승자노드가 결정되면 승자노드와 그 이웃한 노드들이 이웃 함수의 크기에 따라 학습에 동참하게 되는데 <그림 4>에서는 본 연구에서 사용하고 있는 격자형태의 연속형 위상관계에서 승자노드와 이웃노드를 보여주고 있다. 또한 <그림




그림 5. 가우스 이웃함수(Gaussian neighborhood function).

5>에서는 이웃간의 거리에 따른 가우스 이웃함수(Gaussian neighborhood function)의 크기를 보여 주고 있다. 이웃의 범위는 학습초기에는 전체 노드를 포함하게 되고 학습이 진행됨에 따라서 축소된 형태를 가지게 된다. 아래의 식(3.1), (3.2)는 경쟁층의 승자노드와 이웃노드의 연결강도의 변화량을 나타낸다. 여기서 $x^\mu = [x_1, x_2, \dots, x_p]$ 는 작업공간의 입력 패턴, $\theta^n = [\theta_1, \theta_2, \dots, \theta_q]$ 는 관절각의 입력 패턴, $\eta^U(t), \eta^V(t)$ 는 시간에 따라 감소하는 학습률 함수, $N^U(t), N^V(t)$ 는 가우스 이웃함수, 그리고 i^*, j^* 는 경쟁층의 승자 노드를 나타낸다.

$$U_{im}(t+1) = U_{im}(t) + \eta^U(t) N^U(t) \{x_m^\mu - U_{im}(t)\} \quad (3.1)$$

$1 \leq m \leq p$

$$V_{jn}(t+1) = V_{jn}(t) + \eta^V(t) N^V(t) \{\theta_n^n - V_{jn}(t)\} \quad (3.2)$$

$1 \leq n \leq q$

$$\eta^U(t) = \eta^U_0 \exp\left(-\frac{t}{\tau^U}\right) \quad (3.3)$$

$$\eta^V(t) = \eta^V_0 \exp\left(-\frac{t}{\tau^V}\right) \quad (3.4)$$

$$N^U(t) = \exp\left[-\frac{\{U_{i^*} - U_{im}(t)\}^2}{B^U}\right] \quad (3.5)$$

$$N^V(t) = \exp\left[-\frac{\{V_{j^*} - V_{jn}(t)\}^2}{B^V}\right] \quad (3.6)$$

τ^U, τ^V : 관절 경쟁층과 작업 경쟁층의 시간상수
 B^U, B^V : 관절 경쟁층과 작업 경쟁층의 이웃범위상수

경쟁층간의 학습에서는 두 경쟁층의 승자노드만 학습에 참여하게 된다. 이것은 지도학습의 개념을 반영한 형태로서 학습된 두 경쟁층간의 연결강도는 학습 종료 후에 역방향 기구학의 해를 구하는 역할을 하게 된다. 아래의 식(3.7)은 승자노드간의 연결강도의 변화를 나타내고 있다.

$$W_{ij}(t+1) = \begin{cases} W_{ij}(t) + \varepsilon, & i=i^* \text{ 이고 } j=j^* \text{ 인 경우,} \\ W_{ij}(t) & i \neq i^* \text{ 이고 } j \neq j^* \text{ 인 경우} \end{cases} \quad (3.7)$$

여기서 경쟁층간의 학습은 학습률 ε 으로 작업 경쟁층과 관절 경쟁층의 사상관계를 학습한다. 제안된 신경망의 학습을 단계별로 요약하면 다음과 같다.

단계 1. 초기화: 학습에 필요한 연결강도와 학습 모수를 초기화 한다. $U_{im}(t)$, $V_{jm}(t)$ 그리고 $W_{ij}(t)$ 를 작은 값의 임의의 수로 초기화한다.

단계 2. 입력 패턴 제시: 정방향 기구학으로 얻어진 입력 패턴 I^μ 를 제시한다.

$$I^\mu = [x_m^\mu, \theta_n^\mu] \quad 1 \leq m \leq p, \quad 1 \leq n \leq q \quad (3.8)$$

p, q 는 입력패턴의 차원으로 p 는 작업공간의 차원, q 는 관절공간의 차원의 크기이다. 따라서 $x^\mu = [x_1, x_2, \dots, x_p]$ 는 작업공간의 입력 패턴, $\theta^\mu = [\theta_1, \theta_2, \dots, \theta_q]$ 는 관절각의 입력 패턴이다.

단계 3. 승자 노드 선택: 입력층에 제시된 입력패턴과 두 개의 경쟁층과 입력층의 연결강도 $U_{im}(t)$, $V_{jm}(t)$ 사이의 유클리드 거리(Euclidean distance) D_i^U, D_j^V 를 계산한다. 그리고 입력 패턴과 최소 거리에 있는 작업 경쟁층의 승자노드 i^* , 관절 경쟁층의 승자노드 j^* 를 선택한다.

$$D_i^U = \sqrt{\sum_{m=1}^p \{x_m^\mu - U_{im}(t)\}^2} \quad (3.9)$$

$$D_j^V = \sqrt{\sum_{n=1}^q \{\theta_n^\mu - V_{jm}(t)\}^2}$$

단계 4. 경쟁층 학습: 입력 패턴에 대하여 각각의 경쟁층의 위상관계를 표현하기 위해 경쟁층의 승자노드와 이웃노드의 연결강도를 식(3.1), (3.2)에 의해 조정한다. 또한 경쟁층의 승자노드 i^* 와 j^* 간의 $W_{i^*j^*}(t)$ 를 식 (3.7)에 의해 조정한다.

단계 5. 단계 2로 가서 반복한다. 학습이 수렴되면 반복은 종료한다.

3.2 로봇 자세에 의한 학습 영역 분할

로봇 매니플레이터의 기구학은 그것의 관절 형태와 구조에 따라서 달라지며 하나의 목표점에 대응하는 역방향 기구학의 해가 유일하지 않을 수 있다. <그림 6>과 같이 관절공간이 2차원이고 작업공간이 2차원일 경우에는 작업공간에서의 특정 목표점에 대응되는 로봇 매니플레이터의 대안이 2개가 되고 <그림 7>과 같이 관절공간이 3차원이고 작업공간이 2차원인 중복 매니플레이터(redundant manipulator)의 형태에서는 작업공간에서의 특정 목표점에 대응되는 로봇 매니플레이터의 대안이 다수가 된다(Baillieu, 1986).




그림 6. 매니플레이터의 예 1.
(관절공간 2차원, 작업공간 2차원)




그림 7. 매니플레이터의 예 2.
(관절공간 3차원, 작업공간 2차원)

특히, 중복 매니플레이터는 특정 목표점에 대응되는 대안이 매니플레이터의 설정자세(configuration posture)에 따라서 <그림 8>과 같이 유사자세(similar posture)와 비유사자세(dissimilar

posture)로 나눌 수 있으며 이러한 자세들은 사전에 분류하는 것이 학습 및 유연한 궤적생성에 도움이 된다. 이러한 분할 학습을 하지 않는 경우 일부 자세들에 대한 학습에 치중되어 관절공간상의 연속적인 해를 구할 수는 있으나 목표점에 대한 유연한 궤적을 얻지 못할 위험성이 있다. 따라서 본 연구에서는 2관절 및 3관절 로봇의 자세를 분류하여 각각의 유사자세에 대한 학습을 분할, 수행도를 높이도록 하였다.

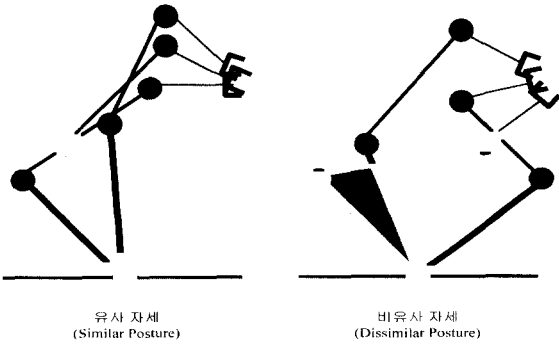


그림 8. 로봇 매니플레이터의 설정자세.

로봇 매니플레이터의 설정 자세에 따른 학습영역 분할은 <그림 9>와 같이 상대적인 관절각 방향을 기준으로 하였다. q 차원의 관절공간 θ 의 관절벡터 $\underline{\theta}$ 는 다음 식(3.10)과 같이 정의된다.

$$\underline{\theta} = [\theta_1, \theta_2, \dots, \theta_q] \quad (3.10)$$




그림 9. 로봇 매니플레이터의 설정 자세 분할.




그림 10. 관절공간상의 로봇 매니플레이터의 설정자세 분할.

<그림 6>과 같은 관절공간이 2차원이고 작업공간이 2차원 일 경우에는 $\theta = [\theta_1, \theta_2]$ 로 정의된다. 이것을 설정 자세에 따른 학습영역 분할을 하면 <그림 10>과 같이 4가지 패턴으로 분류된다. 마찬가지로 <그림 7>과 같이 관절공간이 3차원이고 작업공간이 2차원인 경우에는 $\theta = [\theta_1, \theta_2, \theta_3]$ 로 정의되며 이것을 설정 자세에 따른 학습영역 분할을 하면 8가지로 나눌 수 있다.

이러한 로봇 매니플레이터의 설정 자세에 따른 분할은 목표점에 대한 로봇 매니플레이터의 자세 정보를 제어할 수 있는 장점을 갖게 되며, 또한 신경망의 학습을 향상시키고 학습과정에서 지역해로 귀착되는 위험을 줄이게 된다.

3.3 역방향 기구학 해의 도출

역방향 기구학의 해를 얻기 위해서는 <그림 11>에서 나타난 두 가지의 입력값이 필요하다. 첫째는 로봇 매니플레이터에 대한 작업공간의 목표점 벡터 x^{desire} 이고, 둘째는 목표점에서 로봇 매니플레이터의 목표 자세이다. 목표점과 목표 자세가 주어지면 각 설정 자세에 따라 학습을 완료한 신경망을 이용하여 역방향 기구학의 해를 도출한다. 목표자세는 임의로 선택될 수 있으나 로봇의 유연한 동작을 위해 현재의 로봇자세와 같은 것을 선택하든지, 충돌회피 등 기타 요인을 고려하여 선정할 수 있다.

탐색 알고리즘을 단계별로 보면 다음과 같다.

- 단계 1. 작업공간의 목표점 벡터 x^{desire} 이 입력되고 로봇의 목표자세에 해당하는 신경망을 선정한다.
- 단계 2. 입력 벡터 x^{desire} 와 작업공간의 경쟁층과 입력층과의 연결강도 $U_{im}(t)$ 사이의 유클리드거리 D^U 를 계산한다.

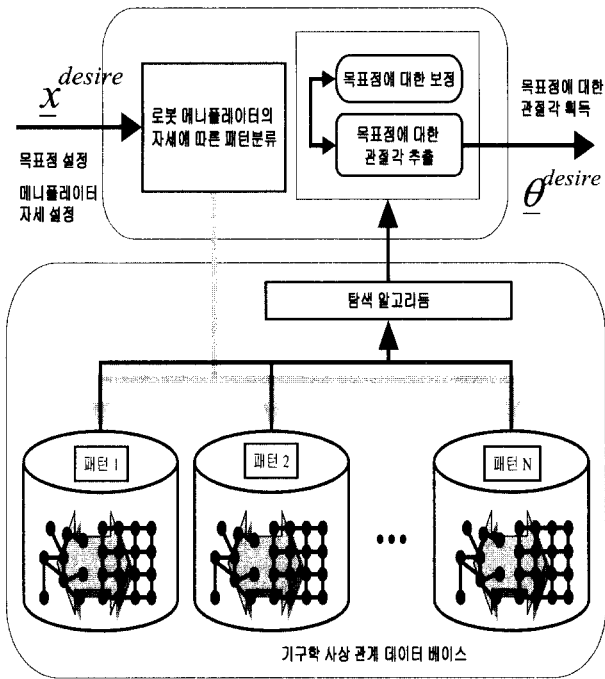


그림 11. 제안된 알고리즘.

$$D^U = \sqrt{\sum_{m=1}^n \{x_m^{desire} - U_{im}(t)\}^2} \quad (3.11)$$

단계 3. 작업경쟁 층상의 승자노드 i^* 를 구한다. i^* 는 단계2 에서 얻어진 D^U 가 최소인 작업 경쟁층 노드의 연결 강도를 의미한다.

단계 4. 작업 경쟁층의 승자 노드 i^* 와 연결된 관절 경쟁층의 노드 중 최대의 연결강도를 갖는 j^* 를 구한다. 즉, $W_{i^*j^*}(t) \geq W_{ij^*}(t), \forall j$

단계 5. 관절 경쟁층의 승자 노드 j^* 와 입력층과의 연결강도 $V_{j^*n}(t)$ 를 목표점에 대한 관절각 θ^{desire} 로 출력한다.

위와 같이 도출한 θ^{desire} 는 오차를 포함할 수 있다. 이러한 오차는 역방향 기구학 해결 방법의 수행도 척도가 되는데 오차의 크기가 로봇의 자세를 변화시킬 만큼 크지 않다면 이는 보정 알고리즘을 통해 제어할 수 있다(Baillieul, 1986; Klein and Huang, 1983; Ran et al., 1993).

4. 모의실험

본 연구에서는 로봇 매니플레이터의 프로그래밍에 적용할 역방향 기구학의 문제를 해결하는 방법론을 제시하였다. 제안된 방법은 작업공간 내에서 목표점이 주어졌을 때, 관절공간상의

해를 발견하는 것으로서 이 절에서는 제안된 방법론의 수행도를 평가하고 적용성을 분석하기 위한 모의실험 설계 및 분석 결과를 서술한다. 모의실험의 설계에는 적용할 로봇 매니플레이터와 제안된 신경망의 구조를 선정한다. 그리고 수행도를 평가하기 위한 척도를 설정한다.




그림 12. 대상 매니플레이터 A.




그림 13. 대상 매니플레이터 B.

본 연구에서는 로봇 매니플레이터를 <그림 12>, <그림 13>과 같은 2차원 작업공간 로봇 매니플레이터를 가정했다. 모의실험 모형에 고려될 요인은 관절의 개수와 링크의 길이로써 링크는 두께가 0인 선으로 가정하고 엔드이펙터는 고려대상에서 제외하였다. 대상 매니플레이터 A와 B의 구조는 다음

의 <표 1>과 같다.

표 1. 대상 매니플레이터의 구조

구분	대상 매니플레이터 A의 구조				대상 매니플레이터 B의 구조					
	l_1	l_2	θ_1	θ_2	l_1	l_2	l_3	θ_1	θ_2	θ_3
모델링 모수										
적용 수치	50 cm	50 cm	[0-130] °	[0-130] °	50 cm	50 cm	25 cm	[0-130] °	[0-130] °	[0-130] °

학습을 위한 데이터는 임의의 관절각 θ 및 이에 대응되는 작업공간의 위치 x 로서, x 는 θ 와 주어진 대상 매니플레이터들의 정방향 기구학 식(4.1),(4.2)로부터 구해진다. 본 모의 실험에서는 각 분할된 신경망에 대해 이와 같이 구해진 10,000개의 데이터로 학습했다.

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} l_1 \cos(\theta_1) + l_2 \cos(\theta_1 + \theta_2) \\ l_1 \sin(\theta_1) + l_2 \sin(\theta_1 + \theta_2) \end{bmatrix} \quad (4.1)$$

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} l_1 \cos(\theta_1) + l_2 \cos(\theta_1 + \theta_2) + l_3 \cos(\theta_1 + \theta_2 + \theta_3) \\ l_1 \sin(\theta_1) + l_2 \sin(\theta_1 + \theta_2) + l_3 \sin(\theta_1 + \theta_2 + \theta_3) \end{bmatrix} \quad (4.2)$$

표 2. 신경망 구조

대상 매니플레이터 A			대상 매니플레이터 B		
형태	관절 경쟁층	작업 경쟁층	형태	관절 경쟁층	작업 경쟁층
1-1	20×20	20×20	2-1	10×10×10	20×30
1-2	30×30	30×30	2-2	15×15×15	30×40
1-3	40×40	40×40	2-3	20×20×20	40×50

<표 2>는 모의실험에서 사용되는 신경망의 구조이다. 최적의 신경망 구조는 대상 문제에 따라 달라지게 되므로 본 연구에서는 다양한 형태의 신경망 구조를 이용, 학습에 적용하였다.

수행도 평가를 위한 척도는 작업공간상의 목표점과 제안된 모델에 의해 구해진 결과 위치와의 오차 크기를 적용하였다. 즉, 작업공간의 목표점이 주어졌을 때 제안된 방법을 통해 얻어지는 관절각을 정방향 기구학으로 계산한 결과값을 획득하

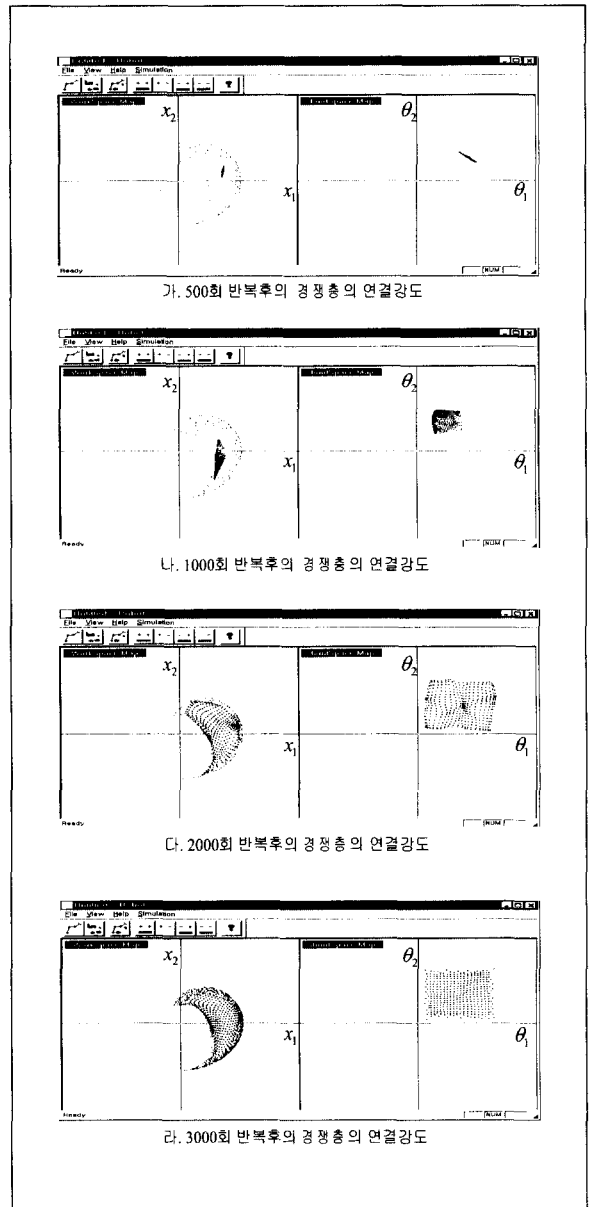


그림 14. 대상 매니플레이터 A의 신경망 학습 예시.

고 목표점과 제안된 방법을 통해 얻어지는 실험값을 비교함으로써 오차를 산출한다. 이 실험에서는 100개의 임의의 목표점을 선정, 오차의 크기를 분석하였다.

SOFM의 학습과정 및 두 SOFM간의 연결강도의 학습과정은 <그림 14>, <그림 15>에 예시되어 있다. <그림 14>, <그림 15>의 좌측은 작업공간을, 우측은 관절공간을 나타낸다. 학습이 진행됨에 따라서 신경망의 두 경쟁층인 관절 경쟁층과 작업 경쟁층은 관절공간과 작업공간의 위상관계를 학습하게 된다. 이것은 각각의 경쟁층 노드들이 각각의 공간을 자기조직화 과정을 나타내는 것이다. 이 연구에서는 대상 매니플레이터들에 대하여 분류된 로봇 매니플레이터의 자세별로 각각

표 4. 대상 매니플레이터 B의 실험결과 (평균오차 cm)

설정 자세	신경망 설계 형태		
	형태 2-1	형태 2-2	형태 2-3
패턴 1	6.9655	3.4753	3.1297
패턴 2	6.4793	3.8424	3.2756
패턴 3	6.4374	3.1934	3.3761
패턴 4	6.1700	3.8170	3.6670
패턴 5	6.0584	3.7878	3.3840
패턴 6	6.5296	3.3333	2.9617
패턴 7	6.4723	3.8236	3.0984
패턴 8	6.8556	3.5223	3.3294

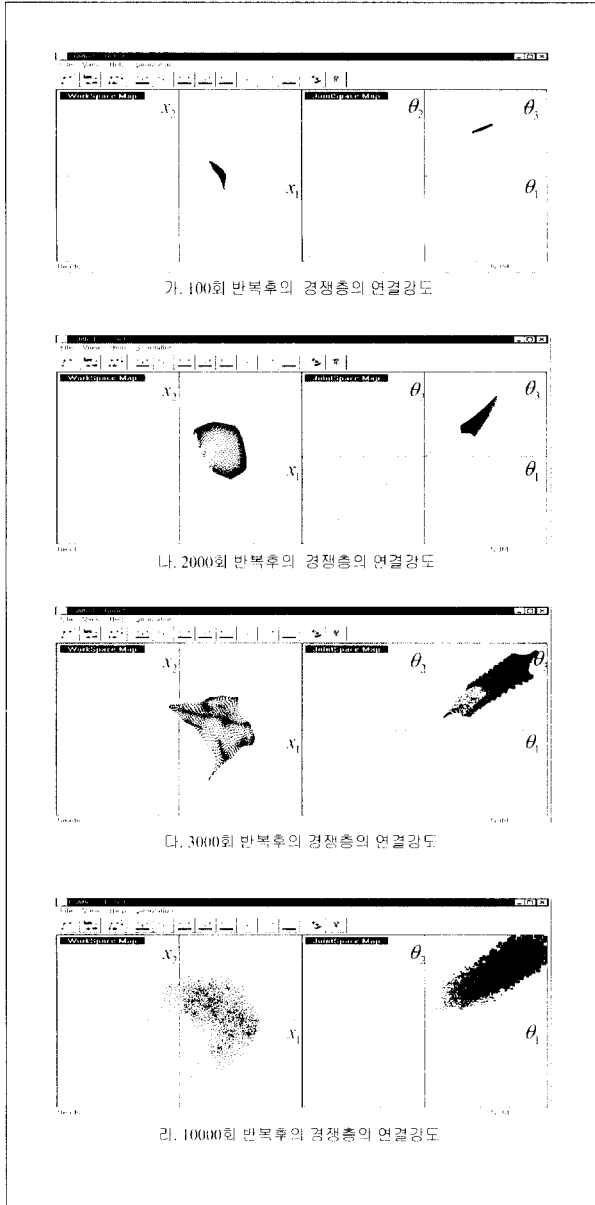


그림 15. 대상 매니플레이터 B의 신경망 학습 예시.

표 3. 대상 매니플레이터 A의 실험결과 (평균오차 cm)

설정 자세	신경망 설계 형태		
	형태 1-1	형태 1-2	형태 1-3
패턴 1	3.4320	2.3478	1.9580
패턴 2	3.0722	2.2576	1.7220
패턴 3	3.1216	2.3453	1.7998
패턴 4	3.3977	2.2572	1.7884




그림 16. 대상 매니플레이터 A의 실험결과.




그림 17. 대상 매니플레이터 B의 실험결과.

학습수행 및 결과 분석을 행하였다. <표 3>, <표 4> 그리고 <그림 16>, <그림 17>은 대상 매니플레이터 A와 B에 대한 실험결과를 보여주고 있다.

본 연구의 실험결과와 경쟁층의 노드가 증가함에 따라서 수행도 평가척도인 오차가 감소함을 알 수 있다. 경쟁층 노드의

증가는 관절공간과 작업공간의 사상관계를 보다 정밀하게 나타낼 수 있음을 의미하는 것으로 로봇 매니플레이터의 정확도인 위상공간 분해능력을 증가시키는 요인이 된다.

이와 같은 정확도를 기존의 방법과 객관적으로 비교하는 것은 실험모형의 차이와 접근방법의 차이로 정확한 분석은 어려우나 작업공간에 대한 평균 오차 백분율로 <표 5>와 같이 비교하면 제안된 방법이 분해능력 측면에서 우수함을 알 수 있다. 또한 제시된 방법에 의하면 기존의 방법들과는 달리 관절공간과 작업공간의 위상정보, 그리고 로봇의 자세정보를 로봇 프로그래밍에 반영할 수 있기 때문에 보다 유연한 로봇 작업을 계획할 수 있는 장점이 있다.

표 5. 평균 오차 백분율(%) 비교

David DeMers[7]	San-Yih Pan[17]	제안된 방법
2.3605	1.6444	1.3110

5. 결론 및 추후 연구방향

이 연구에서는 다관절 로봇의 기본적인 형태인 평면 매니플레이터의 역방향 기구학을 해결하는데 있어 관절공간과 작업공간 사이의 사상관계를 학습할 수 있는 신경망 적용 방법론을 제안하였다. 특히 제안된 신경망은 관절공간과 작업공간에 대응되는 두 개의 SOFM과 이를 연결할 수 있는 신경망 구조를 제시, 각 공간의 위상을 학습할 뿐만 아니라 두 공간의 사상관계를 학습할 수 있도록 하였다. 이러한 방법들은 로봇 기구학과 같이 차원이 다른 두 공간 사이의 사상관계를 학습할 수 있는 방법론이라 생각된다. 또한, 이 연구에서는 로봇 매니플레이터 각 링크의 운동영역을 기준으로한 분할된 학습을 통해 제안된 신경망 학습의 정확성을 향상시켰다.

제시된 방법의 평가를 위해 작업공간상의 랜덤한 좌표를 발생시켜 제안된 방법으로 구해진 해와 목표점과의 거리를 비교함으로써 수행도를 평가하고 분석하였다. 분석 결과를 토대로한 제안된 방법의 장점은 다음과 같다.

첫째, 역방향 기구학을 계산하는 시간이 짧다. 일반적인 수리적 방법을 이용할 경우 하나의 해를 계산하는데 10 milliseconds(Manocha and Zhu, 1994)가 소요되는 반면에 제안된 방법은 0.1 milliseconds가 소요됨을 알 수 있었다. 이 연구의 컴퓨터 실험환경은 팬티엄급 PC이나 비교한 연구논문(Manocha and Zhu, 1994)의 경우는 워크스테이션급에서 실험한 결과이다. 이것은 제안된 방법의 해를 구하는 과정이 크게 목표점에 따른 로봇의 자세가 선택되면 해당자세에 대응되는 SOFM의 선정 및 연결강도를 이용해 역방향 기구학을 해결함으로써 기존의 알고리즘을 적용시켜 계산하는 수리적인 방법보다는 계산시

간상 효율성이 높다는 것을 의미한다.




그림 18. 로봇 가상 실험실의 경로 계획.

둘째, 제안된 방법론은 로봇 매니플레이터의 구조에 종속되지 않는 일반적인 방법론이다. 관절공간과 작업공간의 사상관계를 일반적인 위상학습 및 연결함수 학습 방법론이라 할 수 있는 신경망적 방법으로 해결함으로써 대부분의 로봇 매니플레이터의 형태에 일반적으로 적용할 수 있다.

셋째, 로봇 매니플레이터의 궤적을 유연하게 할 수 있는 자동 프로그램에 용이해진다. SOFM(이종우와 이종태, 1996)의 특징을 이용 각 목표점에 대해 하나의 관절각 해를 구하는 기

존의 방법과 달리 로봇 자세는 입력요소를 선택할 수 있도록 함으로써 유연한 궤적의 도출 및 장애물 회피 경로 설정을 위한 작업공간의 탐색이 용이하게 되는 장점이 있다.

제안된 방법은 <그림 18>과 같이 Web상에서 로봇 가상실험(virtual experiment)의 형태를 구현하고 가상 로봇의 경로를 생성하는 연구가 진행중이다. 또한 추후의 연구과제로는 로봇의 역방향 기구학을 구할 뿐 아니라 장애물 회피 경로를 탐색하여 자동 로봇 프로그래밍을 완성하는 것을 들 수 있다. 또한 지금까지는 컴퓨터 시뮬레이션을 통해 제안된 방법을 구현하였으나 로봇 컨트롤러(robot controller)를 직접 구현해서 현실적으로 응용성 있는 연구가 필요하다.

참고문헌

- 이종우, 이종태(1996), SOM(Self-Organization Map)을 이용한 로봇트 매니플레이터 충돌회피 경로 계획, *대한산업공학회지*, 22(3).
- 최진섭, 김동원(1996), 다관절 로봇을 위한 충돌회피경로 계획, *대한산업공학회지*, 22(4).
- Asada, H. and Slotine, J. (1986), *Robot Analysis and Control*, John Wiley & Sons.
- Aylor, Stephen, Luis Rabelo and Sema Alptekin (1992), Artificial neural networks for robotics coordinate transformation, *Computers & Industrial Engineering*, 22(4).
- Baillieul, J. (1986), Avoiding obstacles and resolving kinematic redundancy, *Proc. IEEE Int. Conf. Robotics Automation*.
- Craig, John J. (1989), *Introduction to Robotics Mechanics and Control*, Addison-Wesley.
- DeMers, D. and Kenneth Kreurz-Delgado (1995), Canonical parameterization of excess motor degree of freedom with self-organizing maps, *IEEE Transactions on Neural Networks*.
- Groover, Mikell P. (1987), *Automation Production Systems, and Computer Integrated Manufacturing*, Prentice-Hall.
- Guo, Jenhwa and Vladimir, Cherkassky (1989), A solution to the inverse kinematics problem in robotics using neural network processing, *Proc. Int. Conf. Neural Network*, 2.
- Jablonski, J. and Posey, J. W. (1985), Robotics terminology, *Handbook of Industrial Robotics*, John Wiley & Sons.
- Jordan, M. I. and Rumelhart, D. E. (1992), Forward Models : Supervised learning with a distal teacher, *Cognitive Science*, 16.
- Kindermann, J. and Linda, A. (1990), Inversion of neural networks by gradient descent, *Parallel Comput.*, 14.
- Klein, C. and Huang, C. (1983), Review of pseudoinverse control for use with kinematically redundant manipulators, *IEEE Trans. Syst. Man, Cyber*, SMC-13(3).
- Kohonen, T. (1987), *Self-organizing and associative memory*, springer-verlag.
- Nakamura, Y. and Hanasufa, H. (1987), Optimal redundancy control of robot manipulators, *Robotics Res.*, 6(1).
- Manocha, Dinesh and Zhu, Yunshan (1994), A fast algorithm and system for the inverse kinematics of general serial manipulators, *IEEE Conf. on Robotics and Automation*.
- Pan, S., Jackson C., Yang, S. and Qi, Gui-Zhong (1993), A neural network methodology to solve robotic manipulator's inverse kinematic problem, *World Congress on Neural Network*, 3.
- Rudolph, F. J. (1993), A trajectory planner with multiple interconnected CMACs : Supervised learning in a redundant system using direct inverse modeling, *World Congress on Neural Network*, 3.
- Spong, Mark W. and Vidyasagar, M. (1989), *Robot Dynamics and Control*, John Wiley & Sons.
- Yoshikawa, T. (1985), Manipulability of robotic mechanisms, *Proc. Robotics Research*.