

저차원화된 리커런트 뉴럴 네트워크를 이용한 비주얼 서보잉

김 대준*, 이동욱, 심귀보

로보틱스 및 지능제어시스템 연구실

중앙대학교 공과대학 제어계측공학과

Tel : 02)820-5319, Fax : 02)817-0553, Homepage : //irslab.cie.cau.ac.kr/

E-mail : djkim@jupiter.cie.cau.ac.kr, kbsim@juno.cie.cau.ac.kr

Visual Servoing of Robot Manipulators using Pruned Recurrent Neural Networks

Dae-Joon Kim*, Dong-Wook Lee, and Kwee-Bo Sim

Robotics and Intelligent Control Lab.

Dept. of Control and Instrumentation Engineering, Chung-Ang Univ.

Tel : +82-2-820-5319, Fax : +82-2-817-0553, Homepage : //irslab.cie.cau.ac.kr/

E-mail : djkim@jupiter.cie.cau.ac.kr, kbsim@juno.cie.cau.ac.kr

Abstract

This paper presents a visual servoing of RV-M2 robot manipulators to track and grasp moving object, using pruned dynamic recurrent neural networks(DRNN). The object is stationary in the robot work space and the robot is tracking and grasping the object by using CCD camera mounted on the end-effector. In order to optimize the structure of DRNN, we decide the node whether delete or add, by mutation probability, first in case of delete node, the node which have minimum sum of input weight is actually deleted, and then in case of add node, the weight is connected according to the number of case which added node can reach the other nodes. Using evolutionary programming(EP) that search the structure and weight of the DRNN, and evolution strategies(ES) which train the weight of neuron, we pruned the net structure of DRNN. We applied the DRNN to the Visual Servoing of a robot manipulators to control position and orientation of the end-effector, and the validity and effectiveness of the proposed control scheme will be verified by computer simulations.

Keyword : dynamic recurrent neural network, evolutionary programming, evolution strategies, visual servoing.

1. 서 론

비주얼 서보잉에 대한 지금까지의 제어 방법은 크게 위치에 기반한 방법과 특징에 기반한 방법으로 나눌 수 있다. 위치에 기반한 방법은 물체의 위치와 자세를 실시간으로 측정해 그 3차원 정보를 end-effector의 궤도 생성에 이용한 방법이다. 이 방법은 2차원의 센서 출력으로부터 3차원 정보를 얻기 때문에 잡음에 약한 단점이 있고 이를 위하여 Kalman filter와 같이 잡음제거를 위한 기구가 필요하다. 또 하나의 방법으로서 특징에 기반한 방법이 있다. 이 방법은 화면 위의 물체의 특징량을 이용하여 end-effector의 궤도를 생성하고 물체의 위치 추정이 필요하지 않기 때문에 잡음에 강한 반면 궤도 생성 방법에 대한 연구가 필요하다.

본 논문에서는 특징에 기반한 비주얼 서보잉을 실현하였으며 제어기로서는 저차원화된 동적 귀환 신경망을 이용하였다. 제어기를 설계할 때 뉴럴 네트워크의 중간 층의 개수와 연결강도의 수를 적절히 결정하는 것은 매우 중요한 문제이다. 만일 은닉층과 연결강도의 수가 너무

많으면 자유 파라메타의 수가 많아져서 학습시간 및 학습시간이 많이 걸리며, 학습시 초기값에 따라 가중치가 전역 최소값에 도달하지 않고 계산량이 증가하는 등의 문제가 있다. 반대로 은닉층과 연결강도의 수가 너무 작으면 입출력 패턴을 기억하지 못하고 학습이 최적화에 수렴하지 않는다. 따라서 일반적으로 허용오차를 만족하는 범위 내에서 최소의 네트워크를 구하는 것이 가장 이상적이다^[1].

기존의 전방향(feedforward) 네트워크를 최적화 하기 위한 시도는 여러방면에서 많이 시도^{[2][3]}가 되었다. 예를 들면 신경망을 이진의 구조행렬과 가중치 행렬로 표현한 유전알고리즘을 이용하여 최적화하는 방법, 유전 알고리즘을 이용하여 전방향 구조를 최적화하고 온라인 학습 알고리즘에 의하여 최적의 가중치를 찾아내는 방법^[2] 등이 있다. 이러한 전방향 네트워크는 구조상 정적인 사상만을 학습할 수 있으므로 시변 신호나 시계열 동적 사상을 학습하기 위해서는 제어기에 시스템의 입력을 tapped delay line으로 구성하거나, 시스템의 출력을 신경망의 입력으로 피드백하는 등의 변형이 필요하다. 반면 동적 귀환 신경망(DRNN)은 내부적으로 상태

피드백이 있기 때문에 입·출력 사이의 동적사상을 학습할 수 있다. 따라서 정적 전방향 신경망과 같은 변형은 필요하지 않고 비선형 동적 시스템을 제어하는데 내부적으로 상태 피드백이 있어 동특성을 가지는 동적 귀환 신경망이 적합하다^[4].

동적 귀환 신경망의 구조를 최적화하는 연구는 아직까지는 많이 이루어져 있지 않다. Giles와 Omlin은 입력 연결 강도의 총합이 작은 뉴런을 소거한 후에 재학습하는 방식^[5]을 제안하였고, Yamamoto 등은 비선형 시스템을 선형시스템으로 근사한 후 Moore의 수법을 적용하여 중간층의 개수를 감소시킨 후에 재학습하는 방식^[6]을 제안하였다.

본 논문에서는 동적 귀환 신경망의 구조를 간략화하기 위하여 진화 프로그래밍의 확률적 선택방식과 입력 연결 강도의 총합이 작은 뉴런을 소거하는 방식을 결합하여 노드 및 연결 강도의 추가 및 삭제를 행하였으며 진화전략을 사용하여 연결 강도를 학습시킴으로써 전역적 최적해를 구하고자 하였다.

2장에서는 동적 귀환 신경망의 개요와 구조, 3장에서는 본 연구에서 제안하는 진화 연산에 의한 구조의 저차원화 및 학습, 4장에서는 저차원화된 동적 귀환 신경망을 이용한 비주얼 서보잉과 시뮬레이션 결과를 보이고 5장에서 결론을 맺는다.

2. 동적 귀환 신경망의 개요와 구조

80년대 후반부터 뉴럴 네트워크의 연구는 BP학습과 대칭결합의 네트워크에 의한 에너지 최소화라고 하는 2개의 원리를 축으로 해서 전개되어 왔는데 이를 기본 모델의 능력과 한계가 명확하게 되자 전방향 혹은 대칭이라고 하는 결합형태의 제한이 있는 임의의 동적 귀환 신경망이 등장하였고 생물학적, 공학적 응용에 초점을 맞춘 연구가 진행되고 있다^[6].

본 연구에서 사용하는 동적 귀환 신경망은 그림 1에 보는 바와 같이 뉴런이 서로 비대칭 결합하고 있는 상호 결합형 뉴럴 네트워크이다. 따라서 내부적으로 상태 feedback과 self-feedback이 존재하고, 입력신호를 비선형 처리해서 네트워크는 동적인 특성을 보이고 시계열 데이터를 용이하게 처리할 수 있다^[7].




그림 1. 동적 귀환 신경망의 구조

동적 귀환 신경망에 있는 하나의 동적 뉴런은 아래의

그림 2와 같은 구조를 가진다. 즉, 각각의 뉴런은 self feedback에 의한 입력, 외부 입력, 다른 뉴런으로부터 들어오는 입력의 합을 전체 입력으로하여 비선형 함수(시그모이드 함수)를 사용함으로써 -1 ~ 1로 정규화된 출력값을 얻는다.




그림 2. 동적 뉴런

그림 1에서 보인 동적 귀환 신경망의 상태 방정식과 출력방정식을 아래와 같이 끝나.

$$\tau_i \frac{dx_i}{dt} = -x_i(t) + f(\sum_{j=1}^N w_{ij} y_j(t)) + \sum_{j=1}^M X_j, \quad (1)$$

$$y_k(t) = f(x_k(t)) \quad (k=1, \dots, K : K는 출력갯수) \quad (2)$$

또, 본 연구에서는 출력으로서 -1 ~ 1까지의 값을 얻기 위해서 아래와 같은 시그모이드 함수를 사용한다.

$$f(x) = \frac{2}{1+e^{-\alpha x}} - 1 \quad (3)$$

여기서,

w_{ij} : 뉴런 j에서 뉴런 i로의 결합하중

τ_i : relaxation time scale

x_i : 시각 t에서의 뉴런 i의 내부 상태

y_i : 시각 t에서의 뉴런 i의 출력

X_i : 시각 t에서의 뉴런 i의 외부입력
이 된다.

3. 진화 연산에 의한 구조의 저차원화 및 학습

3.1 진화 전략

진화전략은 자연계의 진화현상에 기반한 모델로서 1963년 독일의 I. Rechenberg에 의해 개발되었다. 주연산자로는 돌연변이를 사용하고 주로 실수치 탐색에 쓰인다.

진화전략에서의 개체는 $(\vec{x}, \vec{\sigma})$ 와 같이 실수벡터로 나타낸다. 여기서 \vec{x} 는 상태공간상의 위치벡터이며 $\vec{\sigma}$ 는 표준편차 벡터가 된다. 이 때 돌연변이에 의한 다음 세대의 개체는 다음과 같이 표현된다.

$$\vec{x}^{t+1} = \vec{x}^t + N(\vec{0}, \vec{\sigma}) \quad (4)$$

단, $N(\vec{0}, \vec{\sigma})$: 평균 $\vec{0}$, 표준편차 $\vec{\sigma}$ 인 임의의 수

진화전략의 선택은 확률적이 아니고 결정적으로 행해

진나. 즉, 부모벡터의 선택방법에 의해 나누어진 (μ, λ) -ES와 $(\mu + \lambda)$ -ES 중에서 적합도가 높은 순서대로 μ 개의 개체를 선택한다.

진화전략에서 최적해를 찾기 위해 수렴율을 최적화하는 1/5규칙은 다음과 같다.

[1/5규칙] 성공적인 돌연변이의 비율을 관측하여 이 비율이 1/5보다 커지면 \vec{o} 를 크게하고 1/5보다 작아지면 \vec{o} 의 값을 작게한다.

3.2 진화 프로그래밍

진화 프로그래밍은 1960년대에 L.J. Fogel에 의해서 개발되었으며, 예측문제의 해를 구하기 위하여 유한상태 기계를 진화시키는 방법이고, 근래에는 돌연변이 연산자를 이용한 최적화 문제의 해를 구하는 방법으로 많이 사용되어지고 있다.

본 논문에서는 N개의 노드를 가진 동적 귀환 신경망의 연결 강도를 (5)식과 같이 나타내었다. (5)식에서 행과 열은 각각 노드로 들어오는 입력과 다른 노드로 나가는 출력값을 나타낸다.

구조의 탐색시에는 위의 $N \times N$ 행렬을 1(연결)과 0(연결되어 있지 않음)으로 표현하고, 학습시에는 연결강도의 값을 -1 ~ 1의 실수로 한다. 이 때 주연산자로는 돌연변이를 사용하고 적합도 비례선택을 하였다.

$$\begin{array}{c} \text{입력} \\ \text{출력} \end{array} \left[\begin{array}{cccc} w_{11} & w_{12} & w_{13} & \cdots & w_{1N} \\ w_{21} & w_{22} & w_{23} & \cdots & w_{2N} \\ w_{31} & w_{32} & w_{33} & \cdots & w_{3N} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ w_{N1} & w_{N2} & w_{N3} & \cdots & w_{NN} \end{array} \right] \quad (5)$$

노드 및 weight의 추가 및 삭제는 아래와 같은 방식으로 행하였다.

- 1) 돌연변이 확률에 의하여 노드의 추가 및 삭제를 결정한다.
- 2) 노드를 삭제할 경우 진화전략에서 구한 $N \times N$ 행렬에서 입력하중의 합이 가장 작은 것을 선택한다.
- 3) 노드를 추가할 경우 행과 열을 추가하고 연결강도는 다른 노드와의 관계에 의해서 다음과 같이 확률적으로 더해준다.

- 임의의 a 노드에서 추가된 노드로 연결될 확률 : $\frac{C_{out,a}}{T_N}$
- 추가된 노드에서 임의의 a 노드로 연결될 확률 : $\frac{C_{in,a}}{T_N}$

여기서

$C_{out,a}$: a 노드에서 나가는 연결의 수

$C_{in,a}$: a 노드로 들어오는 연결의 수

T_N : 전체 노드수

가 된다.

진화 프로그래밍의 적합도 함수는 다음과 같이 정하였다.

$$fitness = fit_{ES} \cdot f(n) \cdot f(w) \quad (6)$$

$$f(n) = \frac{a}{n_{max} - n_{min}} (n - n_{min}) \quad (0 < a \leq 1) \quad (7)$$

$$f(w) = \frac{b}{w_{max} - w_{min}} (w - w_{min}) \quad (0 < b \leq 1) \quad (8)$$

여기서 fit_{ES} 는 진화전략에서 구한 적합도 함수, $f(n)$ 은 노드의 함수, $f(w)$ 는 연결강도의 함수를 나타내고 a, b 의 계수를 조정하여 가중치를 조절한다.

본 논문에서는 4장의 비주얼 서보잉 시뮬레이션에서 진화전략에서 구한 좋은 개체에 대한 비중을 높이기 위하여 a 는 0.5, b 는 0.75로 정하였다. 여기서 b 의 값을 a 보다 크게 한 것은 연결강도의 수가 많아서 그 변화의 영향을 민감하게 반도록 하기 위해서다.

4. 저차원화된 제어기를 이용한 비주얼 서보잉

본 논문에서는 저차원화된 동적 귀환 신경망 제어기를 이용하여 RV-M2 로봇 매니퓰레이터의 비주얼 서보잉에 적용하였다. 아래의 그림은 진화연산을 이용한 동적 귀환 신경망을 비주얼 서보잉에 적용한 블록 다이어그램이다.




그림 4. 전체 시스템의 블록 다이어그램

그림 4에서 모델로 설정한 RV-M2 로봇 매니퓰레이터의 5개 관절각의 범위는 다음과 같다.

θ_1	θ_2	θ_3	θ_4	θ_5
$-150^\circ \sim 150^\circ$	$-30^\circ \sim 100^\circ$	$-120^\circ \sim 0^\circ$	$-200^\circ \sim 20^\circ$	$-180^\circ \sim 180^\circ$

표 1. RV-M2 로봇 매니퓰레이터의 관절각 범위

대상 물체는 가로와 세로 각각 50mm, 높이 30mm인 직육면체로 하였고 시뮬레이션은 다음과 같은 가정하에 실시하였다.

[1] 물체의 초기위치와 각각의 특징점 좌표에 대한 정보는 이미 알고 있다.

[2] 대상물체는 매니퓰레이터의 작업공간에서 정지해 있으며, 모든 특징점이 카메라에 포착되어 있다.

최소 노드의 수를 13개, 최대 노드의 수를 20개로 하여 구조를 탐색하였다. 13개의 노드는 입력(4개의 특징 점에 대한 x, y좌표편차)과 출력(로봇 매니퓰레이터의 관절각)만을 가지는 경우이고 노드수를 20개로 제한한 것은 신경망의 성능이 노드수의 증가에 단순히 비례하지 않으며 노드수가 증가하면 탐색영역이 증가하여 유전 탐색이 어려워지기 때문이다.

시뮬레이션을 위하여 로봇 매니퓰레이터의 초기 관절 각은 $\theta_1 = 0^\circ$, $\theta_2 = 5^\circ$, $\theta_3 = -90^\circ$, $\theta_4 = -95^\circ$, $\theta_5 = 0^\circ$ 로 아래쪽 방향을 바라보도록 설정하였으며, 진화전략은 (10+90)-ES, 돌연변이 확률 0.2, 표준편차 0.1로 설정을 하였으며 또한 진화프로그래밍의 개체군의 크기를 20, 노드의 추가 및 삭제 확률을 0.1, 연결강도의 추가 및 삭제 확률을 0.2로 설정하여 3장에서의 적합도 함수에 따라서 신경회로망의 구조를 탐색하였다.

입력

출력	1 0 0 0 0 1 0 1 1 0 0 0 1 1 1 1 1 1 0 0 1 1 0 0 1 0 1 1 1 1 1 0 1 0 0 1 0 0 0 1 1 0 0 1 0 0 0 0 1 1 0 0 1 0 1 1 0 0 1 0 0 0 1 0 0 1 1 1 1 1 1 1 0 1 1 0 1 0 0 1 1 0 0 1 1 0 1 1 0 1 1 0 1 1 1 1 1 0 0 1 0 1 0 0 1 0 1 1 0 1 1 1 1 0 0 1 1 0 0 1 0 1 0 1 1 0 0 1 1 1 0 0 1 1 1 1 1 1 0 1 0 0 0 1 1 0 0 1 0 0 0 1 0 1 1 1 1 1 0 0 1 1 1 0 0 1 1 0 0 0 0 1 1 1 1 1 1 1 1 1 0 0 1 1 1 1 0 1 0 0 0 1 0 0 0 1 0 0 1 1 0 1 0 1 0 1 0 0 0 1 0 0 0 0 0 0 1 0 0 1 0 0 0 1 0 0 0 1 0 0 0 0 0 0 1
----	---

그림 5. 저차원화된 구조행렬

그림 5에서 1은 연결되어 있는 weight, 0은 연결되어 있지 않은 weight를 나타내고 진화 프로그래밍 14세대 진화후 14개의 노드와 102개의 연결강도를 가진 구조를 나타낸 것이다. 즉, 8개의 좌표편차와 5개의 관절각 이외 1개의 노드를 가지고 196개의 완전연결된 연결강도 중에서 102개의 연결강도만을 이용한 구조이다.




그림 6. EP를 사용한 x, y좌표편차의 변화량
(14세대 후)

그림 6에서는 4가지의 패턴에 대하여 학습시킨 후 x, y 좌표편차의 변화량을 나타낸 것이다. 단,

dx : 특징점 x좌표의 변화량의 평균

dy : 특징점 y좌표의 변화량의 평균




그림 7. 학습시킨 패턴에 대한 시뮬레이션 결과




그림 8. 학습시키지 않은 패턴에 대한 시뮬레이션 결과

위의 시뮬레이션 결과에서 볼 수 있듯이 학습시키지 않은 데이터에 대해서도 잘 추종해 감을 알 수 있다.

5. 결 론

본 논문에서는 진화프로그래밍과 진화전략을 이용하여 동적 귀환 신경망의 구조를 간단하게 하는 방법을 제안하였다. 노드의 삭제시에 진화 프로그래밍의 확률적 선택방식과 입력 연결강도의 총합이 작은 뉴런을 소거하는 방식을 결합하였고, 연결강도의 추가시에는 연결되어있지 않은 다른 노드로 갈 수 있는 경우의 수를 고려하여 확률적으로 추가하였다. 저차원화된 제어기를 이용하여 로봇 매니퓰레이터의 비주얼 서보ing에 적용함으로서 14개의 노드와 102개의 연결강도만을 가진 구조로서 완전 연결된 구조보다 더욱 좋은 성능을 얻을 수 있었다. 본 논문의 내용에서는 정적인 물체에 대한 결과이지만 동적인 물체에 대한 결과는 추후 발표할 예정이다.

참고문헌

- [1] H. Nishida, Y. Matsumoto, Y. Yamamoto, "A Pruning Method of Recurrent Neural Networks," 計測自動制御學會論文集, Vol. 32, No. 3, pp. 379-388, 1996.
- [2] 조철현, 공성곤, "유전 알고리즘을 이용한 전방향 신경망 제어기의 구조 최적화," 전자공학회 논문지, pp. 95-105, 1996. 12.
- [3] 김대준, 이동욱, 진효병, 심귀보, "최적구조의 신경회로망을 이용한 로봇 매니퓰레이터의 비주얼 서보ing," 대한 전기학회, pp. 1269-1271, 1996. 7.
- [4] CHIN-TENG LIN, C. S. GEORGE LEE, NEURAL FUZZY SYSTEMS, Prentice Hall, 1996.
- [5] C. L. Giles, C. W. Omlin, "Pruning Recurrent Neural Networks for Improved Generalization Performance," IEEE Trans. Neural Networks, Vol. 5, No. 5, pp. 848-851, 1994.
- [6] P. J. Angelino, G. M. Saunders, J. B. Pollack, "An Evolutionary Algorithm that Constructs Recurrent Neural Networks," IEEE Trans. Neural Networks, Vol. 5, No. 1, pp. 54-64, 1994. 1.
- [7] T. FUKUDA, T. KOHNO, T. SHIBATA, "Learning Scheme for Recurrent Neural Network by Genetic Algorithm," 日本機械學會論文集, Vol. 59, No. 564, pp. 34-40, 1993. 8
- [8] 김대준, 이동욱, 심귀보, "진화연산을 이용한 리커런트 뉴런 네트워크의 저차원화에 대한 연구," 로보틱스 · 제어계측 · 자동화 종합학술대회, 1997. 3.