

면역 알고리즘을 이용한 강건한 제어 시스템 설계

On Designing a Robust Control System Using Immune Algorithm

서재용 · 원경재 · 김성현* · 조현찬** · 전홍태
Jae-Yong Seo, Kyoung-Jae Won, Seong-Hyun Kim*,
Hyun-Chan Cho** and Hong-Tae Jeon

중앙대학교 전자공학과, *동원대학 전자과
**한국과학기술교육대학교 전자공학과

요 약

제어 환경의 변화에 강건하게 대처할 수 있는 제어 시스템을 개발하기 위해서, 본 논문에서는 자연계의 면역 시스템과 다층 신경망을 결합한 제어 시스템을 제안한다. 제안한 제어 시스템은 면역 알고리즘을 이용하여 다층 신경망의 가중치를 조절한다. 면역 알고리즘은 초기 방어 단계인 선천성 면역 알고리즘과 적응 단계인 적응 면역 알고리즘으로 구성되어 있다. 과거에 학습한 경험이 있는 환경과 유사한 환경에 대해서 선천성 면역 알고리즘이 동작하고, 학습한 경험이 없는 새로운 제어 환경의 변화에 대해서는 적응 면역 알고리즘이 동작한다. 면역 알고리즘을 이용한 제어 시스템을 로봇 매니플레이터의 제적 추종 제어에 적용하였으며, 컴퓨터 모의 실험을 통해 제어 시스템의 성능을 평가하였다.

ABSTRACT

As an approach to develop a control system with high robustness in changing control environment conditions, this paper will propose a robust control system, using multilayer neural network and biological immune system. The proposed control system adjusts weights of the multilayer neural network (MNN) with the immune algorithm. This algorithm is made up of two major divisions, the innate immune algorithm as a first line of defence and the adaptive immune algorithm as a barrier of self-adjustment. Using the proposed control system based on immune algorithm, we will work out a design for the controller of a robot manipulator. And we will demonstrate the effectiveness of the control system of robot manipulator with computer simulations.

1. 서 론

지능형 제어 알고리즘은 동적 시스템과 제어환경과의 상호작용을 통해서 얻어진 정보를 바탕으로 제어변수를 조정하는 공통점을 가지고 있지만, 새롭게 변하는 외부환경이나 시스템의 변화에 대한 재학습 및 재 진화가 필요하다.

본 논문은 상기의 단점을 극복하고자 학습 기능과 적응 능력을 갖는 신경망[1,2]과 최적화 능력을 보유한 유전 알고리즘[3]의 장점에 면역 시스템[4]의 특징을 공학적인 관점에서 적용하여, 제어 환경에 강력하게 대응할 수 있는 새로운 제어 시스템을 개발하는데 그 목적이 있다. 제안한 제어 시스템은 다층 신경망(multilayer neural network)의 가중치(weight) 집단을 면역 알고리즘(immune algorithm)을 이용해서 조정한다.

면역 알고리즘은 선천성 면역 알고리즘과 적응 면역 알고리즘으로 구성된다.

제어 환경의 변화를 수용할 수 있는 선천성 항체(innate antibody) 집단(신경망의 가중치 집단)을 미리 준비하고, 외부 환경이 변하게 되면 면역 알고리즘은 항원(antigen)의 침투를 인식(오차의 패턴을 인식)하여, 초기 방어 단계인 선천성 면역 알고리즘(innate immune algorithm)이 동작하게 된다. 선천성 면역 알고리즘의 적응이 실패하면, 적응 단계로서 적응 면역 알고리즘(adaptive immune algorithm)이 동작한다.

적응 면역 알고리즘은 침투한 항원과 친화력(affinity)이 가장 높은 항체 집단을 면역 네트워크의 조절 이론을 이용해서 선택한다. 여기서 선택된 항체를 이용하여 신경망을 가지고 미세조정을 수행한다.

본 논문의 구성은 다음과 같다. 2장에서는 신경망

*본 논문은 한국 과학재단의 KOSEF 971-0901-006-2의 핵심 전문 연구로 수행되었습니다.

의 구조와 학습 방법에 대해서 살펴본다. 3장에서는 면역 네트워크의 조절 이론에 대해서 살펴본다. 4장에서는 면역 시스템을 이용하여 외부 환경의 변화에 강건하게 적용할 수 있는 제어 시스템을 설계한다. 5장에서는 제안한 제어 시스템을 2축 로봇 매니퓰레이터의 궤적 추종 제어에 적용하고, 제안한 제어 시스템의 성능을 평가하기 위한 모의 실험의 수행과 결과를 검토한다. 마지막으로 6장에서는 본 논문의 결론을 기술한다.

2. 다층신경망과 학습 알고리즘

정적 신경망(static neural network)의 일종인 다층 신경망은 입력층(input layer)과 출력층(output layer) 사이에 하나 이상의 은닉층(hidden layer)이 존재하는 그림 1과 같은 계층적 구조를 갖는다. 그림 1과 같은 3층 구조(입력층, 중간층, 출력층)인 다층 신경망의 최종출력은 식 (1)과 같다.

$$y_k = f_k^o \left(\sum_{j=1}^l f_j^h \left(\sum_{i=1}^n f_i^i (x_i \cdot w_{ij}^h) \cdot w_{ji}^h \right) \cdot w_{kj}^o \right) \quad (1)$$

여기서, f_i^i , f_j^h , f_k^o 는 각각 입력층, 중간층, 출력층의 비선형 활성화 함수들이고, w_i^i 는 실제 신호를 정규화하는 입력 가중치이며, w_{ij}^h 와 w_{kj}^o 는 각각 입력층과 중간층, 중간층과 출력층 사이의 가중치를 의미한다.

교사학습(supervised learning)방식의 한 분류인 오차 역전파 학습 알고리즘(Error Back-Propagation Learning Algorithm)은 강화학습 방법으로서 구현이 쉽고 학습 능력이 뛰어나 다층 신경망에 많이 사용되는 학습방법이다.

오차를 감소시키기 위한 출력단에 있는 가중치들의 변화량은 최급하강법(gradient descent)과 연쇄규




그림 1. 다층 신경망의 구조.

칙(chain rule)을 사용한다. 최종 결과식은 식 (2), (3)과 같다.

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji} + \alpha [w_{ji}(t) - w_{ji}(t-1)] \quad (2)$$

$$w_{kj}(t+1) = w_{kj}(t) + \Delta w_{kj} + \alpha [w_{kj}(t) - w_{kj}(t-1)] \quad (3)$$

여기서, α 는 운동량(momentum term)이고, 입력층과 중간층 사이의 가중치인 Δw_{ij} 와 중간층과 출력층 사이의 가중치인 Δw_{kj} 는 식 (4), (5)와 같이 정의된다.

$$\Delta w_{ji} = -\eta \frac{\delta E}{\delta w_{ji}} = -\eta \delta_j x_j \quad (4)$$

$$\Delta w_{kj} = -\eta \frac{\delta E}{\delta w_{kj}} = -\eta \delta_k y_k \quad (5)$$

식 (2)와 식 (3)을 출력단에서 입력단까지 반복적으로 적용하면 각 뉴런의 출력오차가 감소하도록 가중치가 조정되어, 결국 신경망의 최종 출력치가 목표 값에 도달하게 된다.

3. 면역 네트워크 이론

자연계의 면역 시스템[4]은 박테리아(bacteria), 균(fungi), 바이러스(viruses) 등과 같은 항원(antigen)이라고 통칭하는 매우 다양한 외부 유기체나 단백질에 대항하여 인간의 몸을 방어할 수 있는 복잡한 시스템이다. 생체 내에 한 셀(set)으로 존재하는 항체분자 및 B-림프구는 모두 서로 반응하여 생체 내에서의 동적인 평형상태(dynamic equilibrium)에 있다고 생각하는




그림 2. Jerne의 idiotope 네트워크 이론.

학설이며, Jerne[5]가 제창하였다. Jerne는 항원에 의해 만들어진 각각의 항체는 면역 시스템에 의해서 독특한 유전형인 이디오타입(idiotype)을 소유한 항원으로 또 다시 간주된다고 생각했다(그림 2 참조).

4. 강건한 제어 시스템 설계

본 제어 시스템은 다층 신경망(MNN)과 선형제어기(PD)가 병렬로 연결되어 있으며, 다층 신경망의 구조를 갱신할 수 있는 면역 알고리즘으로 그림 3과 같이 구성되어 있다.

4.1 항원과 항체 정의

항원정의: 본 제어 시스템에 적용되는 항원은 제어환경의 변화로 한정한다.

항체정의: 항원 결정기를 인식하는 패래톱과 이디오타입은 제어환경을 고려하여 제어대상에 따라 다르게 정의된다.

4.2 제어 시스템 동작과정

본 장에서는 면역 알고리즘을 이용해서 신경망의 가중치(weight)를 외부 환경의 변화에 따라 알맞게 선택하는 동작 과정을 설명한다(그림 4 참조).

1) 선천성 면역 알고리즘

다층 신경망 제어기와 PD 제어기를 이용하여 선천성 면역 알고리즘과 적응 면역 알고리즘에 이용할 항체집단을 미리 준비한다.

오차가 임의의 한계 값을 초과하면, 초기 방어 시스템으로서 선천성 면역 알고리즘이 동작한다. 먼저, 침투한 항원의 형태를 구분하기 위해 상관 계수(r)를 이용하여 준비된 항체의 신호와 오차 신호의 유사성을 비교한다[6]. 두 신호의 유사성을 판단하는 기준이 되는 상관계수는 식 (6)과 같다.

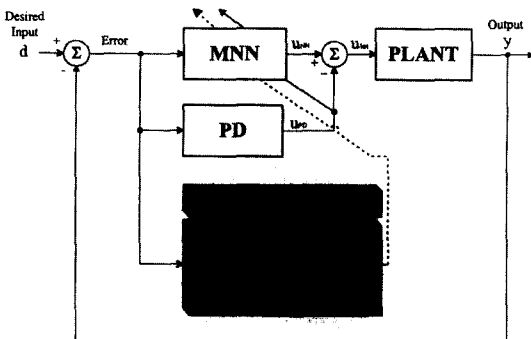


그림 3. 제어 시스템의 구성도.

$$r(E_{A_i}, E_{A_g}) = \frac{\sum_{t=0}^{N-1} (E_{A_i}(t) - \overline{E_{A_i}}) \cdot (E_{A_g}(t) - \overline{E_{A_g}})}{\sqrt{\sum_{t=0}^{N-1} (E_{A_i}(t) - \overline{E_{A_i}})^2} \sqrt{\sum_{t=0}^{N-1} (E_{A_g}(t) - \overline{E_{A_g}})^2}} \quad (6)$$

여기서, E_{A_i} 는 항체가 보유하고 있는 오차 패턴이고, E_{A_g} 는 제어할 때 발생하는 오차 패턴이다. $\overline{E_{A_i}}, \overline{E_{A_g}}$ 는 E_{A_i}, E_{A_g} 의 평균값이고, t 는 계적을 수행한 시간이다.

상관 계수의 값을 근거로 두 오차신호의 유사성을 판단하고, 선천성 면역 알고리즘은 유사한 오차 신호를 갖는 항체를 선택하고 수행을 종료한다. 만약 선천성 면역 알고리즘이 실패하면 적응 면역 알고리즘으로 처리를 넘긴다.

2) 적응 면역 알고리즘

이디오타입 네트워크 이론을 이용하여 침투한 항원에 가장 큰 적응성이 있는 항체집단을 적응 면역 알고리즘의 초기 단계에서 선택하고, 진화과정을 통해 임의의 크기를 가지는 새로운 항체집단을 생성한다.

이때 항체의 선택기준은 항체가 소유하고 있는 농도(concentration) 값이 된다. 항체의 농도 식[7,8]은 i 번째 항체의 농도를 c_i 로 정의하면, 식 (7)와 같이 나타낼 수 있다.

$$c_i = \left(a_i + \sum_{j=1}^M a_{ji} \cdot c_j - \sum_{k=1}^N a_{ik} \cdot c_k + k_i \right) \cdot K_c \quad (7)$$

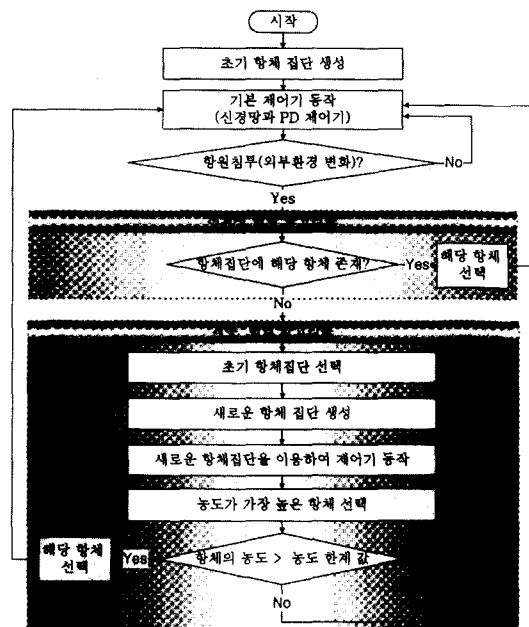


그림 4. 면역 알고리즘의 흐름도.

여기서, a_i 는 항원에 대한 항체의 친화력, a_{ji} 는 i 번째 항체와 j 번째 항체의 친화력, a_{ik} 는 k 번째 항체와 i 번째 항체의 친화력을 나타낸다. 또한 K_c 는 항체의 농도와 친화력의 계산 영역을 동일하게 해주는 비례상수이고, k_i 는 자연사한 항체를 의미한다.

5. 로봇 매니플레이터의 궤적 추종 제어에 적용

본 논문에서 제안한 면역 알고리즘을 이용한 제어 시스템을 일반적으로 산업현장에서 많이 사용되는 로봇 매니플레이터의 궤적추종에 적용하고자 한다. 궤적 추종 제어 문제는 목표 궤적 $P_d(t)$, $t \in [0, t_f]$ 이 주어졌을 때 특정 영역내의 임의의 초기치로부터 추종 오차 $e(=P_d(t)-P(t))$ 가 0이 되도록 제어 규칙 $u(t)$ 를 찾는 것을 의미한다. 로봇 매니플레이터의 작업영역을 직교좌표계(cartesian space)의 모든 영역으로 확대하고 해당 영역별로 제시되는 궤적의 변화를 작업환경의 변화로 정의한다.

일반적인 로봇 매니플레이터는 다음과 같은 동적 방정식으로 나타낼 수 있다.

$$M(q) = \begin{bmatrix} (m_1+m_2)l_1^2 + m_2l_2^2 + 2m_2l_1l_2 \cos(q_2) & m_2l_2^2 + m_2l_1l_2 \cos(q_2) \\ m_2l_2^2 + m_2l_1l_2 \cos(q_2) & m_2l_2^2 \end{bmatrix} \quad (8)$$

$$V_m(q, \dot{q}) = \begin{bmatrix} -2m_2l_1l_2 \sin(q_2) \dot{q}_1 \dot{q}_2 - m_2l_1l_2 \sin(q_2) \dot{q}_2^2 \\ m_1l_1l_2 \sin(q_2) \dot{q}_2^2 \end{bmatrix} \quad (9)$$

$$G(q) = \begin{bmatrix} (m_1+m_2)gl_1 \cos(q_1) + m_2gl_2 \cos(q_1+q_2) \\ m_2gl_2 \cos(q_1+q_2) \end{bmatrix} \quad (10)$$

5.1 제어 시스템의 항원 정의

본 논문에서 적용되는 외부 환경의 변화는 직각좌표 공간에서 모든 영역을 이동하는 로봇 매니플레이터의 경로와 이전에 학습되지 않은 새로운 형태의 궤적을 모두 항원으로 간주한다. 그림 5는 항원으로 인식될 수 있는 궤적의 예를 보인 것이다.

5.2 제어 시스템의 항체 정의

항체는 패래톱과 이디오템으로 구성되어 있다. 항원을 인식하고 항원을 제거하는 패래톱은 현재의 궤




그림 5. 항원으로 인식될 수 있는 로봇 매니플레이터의 궤적 예.

적이 직교좌표계에서 속하는 영역과 제어기의 오차 패턴을 감지하며, 주입된 항원(궤적의 변화)을 제거하는데 필요한 새로운 항체 집단을 선택하게 된다. 다른 항체들을 인식하는 이디오템은 계획한 로봇의 궤적과 로봇의 실제 궤적의 차인 오차의 평균 제곱근 합(RMS)을 가지고 판단하게 된다. 그림 6은 항체의 구조를 나타낸 것이다.

1) 해당 영역(q) 정의

직교 좌표계를 4개의 영역(I, II, III, IV 영역)으로 나누고, 로봇 매니플레이터의 궤적이 시작되는 위치를 판단해서 현재의 영역을 결정한다(그림 7 참조). 해당 식은 식 (11), (12)와 같다.

$$x = L \cos(\theta_L), \quad y = L \sin(\theta_L) \quad (11)$$

$$\theta_L(x, y) = \tan^{-1} \left(\frac{y}{x} \right) \quad (12)$$

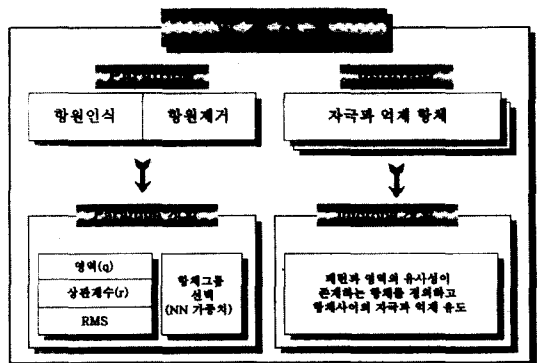


그림 6. 항체 구조.




그림 7. 제시되는 궤적의 해당 영역 결정.

2) 오차의 평균 제곱근(RMS) 정의

본 제어 시스템에서는 설정된 경로를 2축 로봇 매니퓰레이터가 궤적을 추종하도록 설계되었다. 2π 주기 동안의 수행을 1회 반복(iteration)으로 정의하고, 1회 반복을 수행하면서 식 (13)과 같은 RMS를 구한다. 여기서, K_{RMS} 는 공헌도를 나타내는 상수이다.

$$RMS = \left(\int_0^T \sqrt{e_1^2(t) + e_2^2(t) + e_3^2(t) + e_4^2(t)} dt \right) \times K_{RMS} \quad (13)$$

여기서, e_1, e_2 는 로봇 매니퓰레이터의 실제 출력인 관절각(θ_1, θ_2)과 원하는 추종 궤적에 의해 얻을 수 있는 관절각(θ_{d1}, θ_{d2})의 차로 정의하고, e_3, e_4 는 실제 관절속도($\dot{\theta}_1, \dot{\theta}_2$)와 원하는 추종 궤적의 관절속도($\dot{\theta}_{d1}, \dot{\theta}_{d2}$)인 오차로 정의한다. 또한 t 는 궤적을 수행한 시간이다.

3) 상관 계수 정의

상관 계수를 포함한 이유는 각 영역에서 관절각의 오차 패턴을 살펴보면 동일한 영역의 오차 패턴은 유사성이 존재하기 때문이다. 오차 패턴이 유사할수록 상관 계수의 값이 크기 때문에 충분히 친화력에 좋은 결과로 영향을 줄 수 있다.

상관 계수는 4장에서 정의했으며 식 (6)으로부터 2개의 관절각에 의해서 얻어진 상관 계수의 합을 최종 상관 계수로 다음 식 (14)와 같이 정의한다.

$$r(E_{A1}, E_{A2})_f = \frac{r(E_{A1}, E_{A2})_{\theta_1} + r(E_{A1}, E_{A2})_{\theta_2}}{2.0} \quad (14)$$

여기서, r_{θ_1} 는 관절 1에 대한 상관계수, r_{θ_2} 는 관절 2에 대한 상관계수, r_f 는 최종상관 계수이다.

4) 이디오톱 정의

적용 면역 알고리즘의 구성 요소인 이디오톱(다른 항체의 인식 부분은 자극하고 억제하는 다른 항체의

목록으로 구성했다. 직관적으로 살펴볼 때, 만약 궤적이 영역 I에 위치하고 있다면, 영역 I에서 만들어진 항체의 자극이 가장 크고, 영역 III에서 만들어진 항체가 가장 크게 억제할 것이다. 영역 II와 영역 IV는 궤적의 모양에 따라 자극과 억제의 효과가 달라진다. 이처럼 영역을 거칠게 분할하고, 기하학적인 해석을 통해서 자극/억제의 항체를 정의했다.

5.3 모의실험

컴퓨터 모의 실험은 선천성 면역알고리즘의 동작 과정과 적용 면역 알고리즘의 동작과정을 확인하기 위해 3과정으로 나누어 실시했다.

1) 모의실험 (1)

선천성 면역 알고리즘의 동작 유무를 확인하기 위해 영역별로 초기 항체집단 형성에 사용했던 궤적과 동일한 모양의 궤적으로 모의실험을 실시하였다. 그림 8은 영역별로 항원이 침투하였을 경우에 선천성 면역 알고리즘과 신경망의 수행결과를 비교한 것이다.

신경망은 학습시킨 영역과 다른 영역의 궤적이 제시되었기 때문에 재학습이 필요하므로 적응성이 우수하지 못했다. 그러나 선천성 면역 알고리즘은 침투한 항원(영역별 궤적)에 대한 항체(영역별 궤적을 학습한 신경망의 가중치 집합)를 보유하고 있기 때문에 동일한 항원이 침투할 경우 신속하게 적응함을 알 수 있었다.

2) 모의실험 (2)


모의실험 (2)에서는 모의실험 (1)에서 사용했던 궤적과는 모양이 다른 타원형 궤적을 영역별로 제시하여 유사한 제어 환경의 변화에 대한 적용 면역 알고리즘의 적응 능력을 검증하였다.

그림 9는 적용 면역 알고리즘의 초기단계에서 만들어지는 새로운 항체집단 중에서 친화력이 가장 우수한 항체에 의한 수행결과와 신경망의 수행 결과를 비교한 것이다. 궤적의 모양과 영역이 기본 제어기로 사용되는 신경망의 학습영역과 다르기 때문에 신경망의 수행결과가 우수하지 못했다. 그러나 적용 면역 알고리즘은 현재 침투한 항원과 가장 유사한 2개의 항체를 선택하여 새로운 항체집단을 만들었기 때문에 우수한 적응성을 보였다.


그림 10은 신경망과 적용 면역 알고리즘을 2000번 반복 수행한 후에 얻은 오차변화를 영역별로 나타낸 것이다. 적용 면역 알고리즘이 초기 수렴성 뿐만 아니라 적응성 역시 우수함을 알 수 있었다.

3) 모의실험 (3)


모의실험 (3)에서는 새로운 제어환경의 변화에 대한 적용 면역 알고리즘의 적응능력과 제한한 제어 시스템의 효율성을 검증하였다. 이용한 궤적은 선천성




영역 II



영역 I




영역 III




영역 VI


그림 8. 선천성 면역 알고리즘의 영역별 수행 결과.




영역 II



영역 I




영역 III

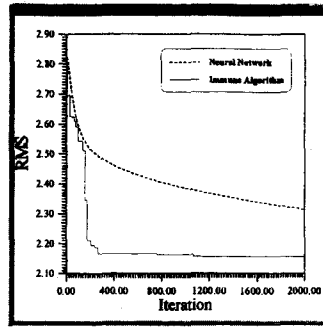


영역 VI

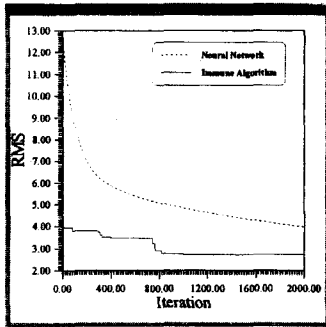
그림 9. 적응 면역 알고리즘의 영역별 수행 결과.




영역 II



영역 I




영역 III




영역 VI


그림 10. 적응 면역 알고리즘의 영역별 수행 오차.




영역 II



영역 I



영역 III



영역 VI

그림 11. 적응 면역 알고리즘의 영역별 수행 결과.

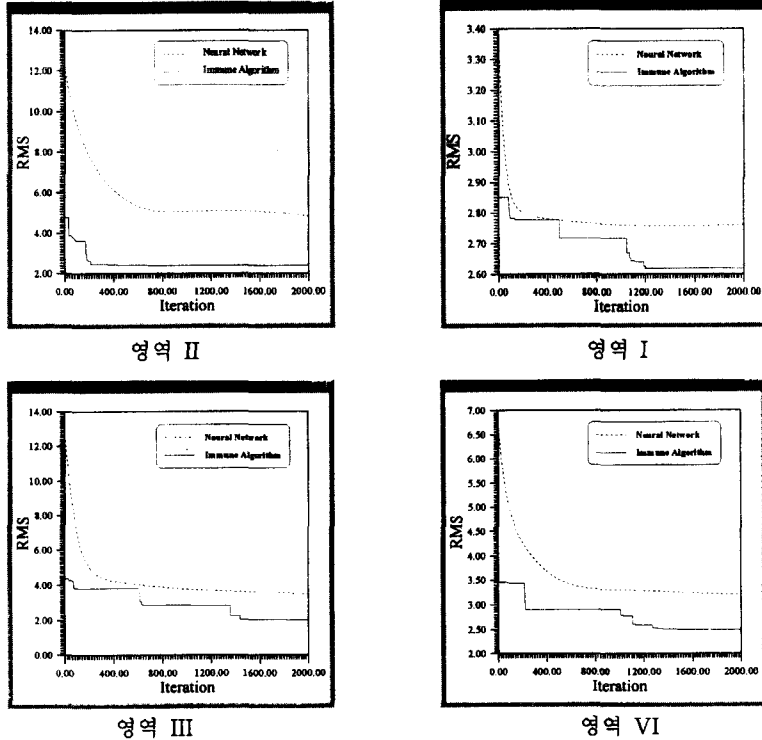


그림 12. 적응 면역 알고리즘의 영역별 수행 오차.

면역 알고리즘의 동작을 확인하기 위해 사용되었던 타원형의 궤적과는 다른 모양의 궤적이다.

그림 11은 적응 면역 알고리즘의 초기 단계에서 새로운 항체집단이 형성된 직후의 주행결과를 나타낸 것이다. 모양이 상이한 궤적이 주입될수록 신경망보다 적응 면역 알고리즘의 초기 적응성이 우수하다는 것을 알 수 있었다.

그림 12는 2000번 반복한 후에 친화력이 가장 우수한 항체를 가지고 제어를 수행해서 얻은 궤적의 결과를 확인하기 위해서 오차를 비교한 것이다. 이 결과 역시 신경망에 비해 적응 면역 알고리즘의 우수한 적응성을 확인할 수 있었다.

6. 결 론

본 논문에서는 제어 환경의 변화에 강건하게 대처할 수 있는 제어 시스템을 설계하기 위해서 자연계의 면역 시스템의 원리와 특성을 기존의 제어 기법과 결합하였다. 제안한 제어 시스템의 설계에 적용된 면역 알고리즘은 크게 선천성 면역 알고리즘과 적응 면역 알고리즘으로 구성되어 있으며, 로봇 매니플레이터의 궤적을 수행하는 모의실험을 통해 제어 시스템의 강

건한 적응성을 입증하였다.

신경망은 유사하거나 새로운 환경변화에 대한 재 학습 과정 때문에 일정기간 동안 적응과정이 필요했다. 그러나 제안한 제어 시스템은 선천성 면역 알고리즘을 이용하여 선천성 항체 집단에 포함되어 있는 항체가 적응한 경험이 있는 궤적과 동일한 형태의 궤적(적응한 경험이 있는 항원)이 제시될 경우, 선천성 항체 집단에서 대응하는 항체를 선택하여 단기간에 침투한 항원을 제거함으로써 제어 환경의 변화에 빠르게 적응했다.

또한 이미 적응한 경험이 있는 항체와 유사하거나 전혀 다른 형태의 궤적(적응한 경험이 없는 항원)이 제시될 경우, 적응 면역 알고리즘은 적응한 경험이 있는 항체 집단의 항체들을 이용하기 때문에 초기 수렴성 및 학습 능력이 우수하고, 강건한 적응성을 보였다.

참고문헌

- [1] A. Guez, J. L. Eilbert and M. Kam, "Neural Network Architecture for Control," *IEEE Control Syst. Mag.*, pp. 22-25, Apr., 1988.
- [2] H. Miyamoto, M. Kawato, T. Setoyama and R. Suzuki, "Feedback Error-Learning Neural Network

- for Trajectory Control of a Robotic Manipulator," *Neural Network*, Vol. 1, No. 3, pp. 123-142, 1988.
- [3] David E. Goldberg, *Genetic Algorithms in Search, Optimization & Machine Learning*, Addison-Wesley Publishing Co., 1989.
- [4] Ivan M. Roitt, *Essential Immunology*, Blackwell Scientific Publications, Osney Mead, 1998.
- [5] N. K. Jerne, "The Immune System", *Scientific American*, Vol. 229, No. 1, pp. 52-60, 1973.
- [6] Y. Ishida and N. Adachi, "An Immune Algorithm for Multiagent: Application to Adaptive Noise Neutralization", *IEEE-RSJ Int'l Conf. on Intelligent Robots and Systems (IROS '96)*, pp. 1739-1746, 1996.
- [7] J. D. Farmer, N. H. Packard and A. S. Perelson, "The Immune system, Adaptation, and Machine Learning.", *Evolution, Games and Learning*, pages 187-204, 1986.
- [8] A. Ishiguro, Y. Shirai, T. Kondo and Y. Uchikawa, "ImmunoId: An Architecture for Behavior Arbitration Based on the Immune Networks," *IEEE-RSJ Int'l Conf. on Intelligent Robots and Systems (IROS '96)*, pp. 1730-1738, 1996.



서재용(Jae-Yong Seo)

1996년 2월 : 중앙대학교 전자공학과 졸업(학사)
1998년 2월 : 중앙대학교 대학원 전자공학과 졸업(석사)
1998년 8월~현재 : 중앙대학교 대학원 전자공학과 박사과정 재학중

주관심분야 : 퍼지, 신경망, 유전알고리즘, 인공생명



원경재(Kyoung-Jae Won)

1996년 2월 : 중앙대학교 전자공학과 졸업(학사)
1998년 2월 : 중앙대학교 대학원 전자공학과 졸업(석사)
1998년 3월~현재 : 중앙대학교 대학원 전자공학과 박사과정 재학중

주관심분야 : 퍼지, 유전알고리즘, 신경망, Adaptive, Optimal Control

김성현(Seong-Hyun Kim)

1991년 2월 : 중앙대학교 전자공학과 졸업(학사)
1993년 2월 : 중앙대학교 대학원 전자공학과 졸업(석사)
1997년 2월 : 중앙대학교 대학원 전자공학과 박사과정 졸업
1997년 3월~현재 : 동원대학 전자과 전임강사
주관심분야 : 퍼지, 유전알고리즘, 신경망, Adaptive, Optimal Control

조현찬(Hyun-Chan Cho)

현재 : 한국기술교육대학교 전자공학과 교수

전홍태(Hong-Tae Jeon)

현재 : 중앙대학교 전자공학과 교수