

論文98-35S-12-4

면역화된 귀환 신경망을 이용한 지능형 제어 시스템 설계

(On Designing a Intelligent Control System using Immunized Neural Network)

元敬載*, 徐在龍*, 延貞欽*, 金成炫**, 全洪兌*

(Kyoung-Jae Won, Jae-Yong Seo, Jung-Heum Yon, Seong-Hyun Kim,
and Hong-Tae Jeon)

요약

본 논문에서는 동적으로 변화하는 제어 환경에 잘 대처하여 제어를 수행할 수 있는 면역 귀환 신경망 제어 시스템을 소개한다. 시스템 내외부의 제어 환경 변화를 병원체로 규정하고 이러한 변화들에 대처할 수 있는 제어 입력을 병원체에 대한 항체로 규정하여 제어를 수행한다. 항체는 이전의 제어 정보들을 이용하며 생성되며, 만일 시스템 안에 항체가 생성되지 않은 병원체가 침투할 경우 면역 시스템은 유전자 조작으로 새로운 항체를 생성한다. 이같은 면역제어 시스템을 로봇 매니퓰레이터에 적용하여 효율성을 입증한다.

Abstract

In this paper we will develope the immunized recurrent neural network control system with high robustness in dynamically changing environmental conditions. The variation of internal parameters of a system and external(or internal) disturbances can be considered as antigen, and the control input which can be regarded as antibody can be generated against uncertainties. The antibody will be generated from previous control informations and if a antibody for an antigen can not be generated from the corresponding information, the immune system produces another antibody by genetic operations. We apply this concept to a robot manipulator and evaluate the effectiveness of the above proposed system.

I. 서 론

실제 물리 시스템을 수학적 모델로 표현할 때 정확히 측정할 수 없거나 수식화할 수 없는 물리적 특성들을 고려하기 위하여 불확실성(uncertainty)이란 용어

를 사용한다. 불확실한 환경에서 우수한 제어기를 설계하기 위해 지능제어(intelligent control) 기법이 도입되었다. 지능제어 기법은 자기학습과 적응능력을 통해 불확실한 환경에서 우수한 제어 성능을 보여주고 있다. 신경망 제어는 이러한 지능제어 기법중의 하나로 정확한 수학적 모델링이 필요 없으며, 시스템 변화에 강건한 특성을 갖는다. 그러나 일반적으로 신경망의 학습 알고리즘으로 사용하는 최급하강법^[4]은 학습 속도가 느리며 지역 최소치로의 수렴성 문제를 갖는다. 또한 불확실성이 급격히 변화하는 환경에서 귀환 신경망의 학습 속도가 환경의 변화를 보상해주지 못하게 될 경우 제어 성능이 저하되며 안정 상태를 유지하기 까지 많은 학습 시간이 요구된다. 지역 최소치로의 수

* 正會員, 中央大學校 電子工學科

(Dept. of Electronic Eng., Chung-Ang Univ.)

** 正會員, 東元大學 電子科

(Dept. of Electronic Eng., Tong-Won College)

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

接受日字: 1998年5月30日, 수정완료일: 1998年11月23日

럼 문제를 해결하기 위해 Petridis^[5] 등은 유전 알고리즘을 사용하였다. 그러나 오프라인으로 동작하는 유전 알고리즘을 사용한 학습은 동특성이 급격히 변화하는 환경에 적당하지 못하다. 상기의 어려움을 극복하고 동특성이 급격히 변화하는 환경에 적응적이고 강健하게 대처할 수 있는 시스템을 구축하기 위해 면역 시스템(Immune System) 이론^[7]이 도입되었다^[10].

생물학적 면역 시스템은 생물을 불확실한 외부 환경으로부터 보호해주는 역할을 하며, 외부 환경 변화에 강건한 특성을 갖는다. 이러한 면역 시스템의 특성을 제어 시스템에 적용한다. 현재까지의 적용 사례는 면역 네트워크 이론을 적용한 것과, 면역 알고리즘 자체의 의미로 공학적 접근을 시도한 두가지로 분류된다. 면역 네트워크 이론은 Jerne^[7]에서 시작하여 이론적 근간이 되고 있으며, Ishiguro^[8] 등은 이를 이용하여 방해물과의 거리 방향, 목적지 등의 정보로 면역 네트워크를 구성하여 이동 로보트의 동작을 결정하도록 하였다. 면역 알고리즘의 의미를 사용하여 공학적으로 접근해 본 시도는 Ishida^[9]와 KrishnaKumar^[10] 등이 있다. Ishida는 외란이 시스템에 주는 패턴을 분석하여, 외란에 대한 외란 중화 신호를 항체로 내보내는 제어방식을 도입하였으며, KrishnaKumar는 간단한 선형 시스템에 대한 각각의 외란에 대응하는 항체를 신경망으로 구성하여 외란이 침투했을 때, 적절한 가중치를 구성하여 제어를 수행할 수 있도록 하였다. 그러나 KrishnaKumar의 면역 알고리즘은 선형 시스템 문제에 제한을 두었으며, 시스템 내부의 변화 등 다양한 불확실성에 대해서는 고려하지 못하였고 regulator 문제에 국한하였다. 본 논문에서는 이러한 면역 시스템 이론을 도입하여 비선형 시스템의 추종 제어 시스템을 설계한다. 우선 2장에서 생물학적 면역 시스템에 대해 설명하고, 3장에서 귀환신경망의 학습 알고리즘과 또한 면역화된 귀환신경망 제어 시스템을 구성해본다. 4장에는 면역 제어 시스템을 로봇 매니퓰레이터에 적용하여 제안한 제어시스템의 성능을 평가해본다.

II. 면역 시스템 (Immune System)

1. 생물학적 면역 시스템

생물학적 면역 시스템은 외부의 병원체에 대항하는 방어 체계로, 신체 내부의 모든 세포를 인식하여 자기

(self)와 비자기(nonself)로 분류하여 몸 안에서 자기 세포로 분류가 되지 않는 세포나 물질을 제거해나간다. 신체 내에서 항체는 림프구의 일종인 B세포에 의해 생성된다. 항체는 항원 수용기(antigen receptor)에서 항원의 에피톱(epitope)을 인식하여 항원의 침투 여부를 판별한다. 항원과 항체가 인식되는 정도에 따라 친화도(fitness)가 결정된다. 형태가 유사한 것끼리 결합이 이루어진다면 항체에 대해 높은 친화도를 갖게 되고 그렇지 않을 경우 낮은 친화도를 갖게 된다. 결국에는 친화도가 높은 항체가 많아져 병원체를 퇴치하게 된다.

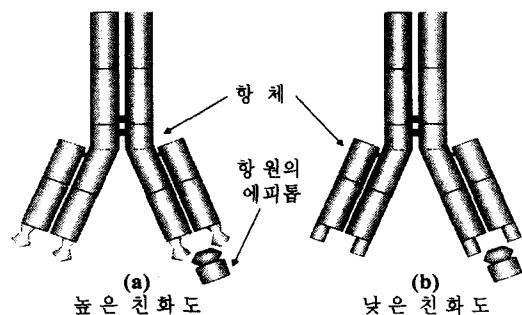


그림 1. 항원과 항체의 결합

Fig. 1. Binding of an Antibody to an Antigen.

이러한 면역 시스템은 초기 방어체계와 적응 방어체계의 두 가지 과정으로 이루어진다. 병원체가 몸 안으로 들어오면 선천성 면역 반응에 의해 초기 방어 체계가 동작된다. 이 단계에서는 기존에 몸 안에 내재되어 있는 항체를 이용한다. 퇴치되지 못한 항원은 다음 단계인 후천성 면역 반응 단계에서 퇴치된다. 후천성 면역 반응동안 침투한 항원에 대한 학습이 이루어진다. 이 과정에서 유전 연산자를 이용하여 새로운 항체를 계속 생성시키며, 이들 중 친화도가 높은 항체만이 살아남는다. 따라서 이후에 같은 항원이 침투할 경우 생성된 항원에 대한 정보를 사용하여 초기 방어체계로써 대응하게 되어 빠른 시간에 항원을 퇴치할 수 있게 된다.

2. 면역 제어 시스템

시스템엔 여러 가지 불확실성이 존재한다. 시스템의 불확실성을 고려하지 않고 제어기를 설계할 경우 원하는 결과를 얻지 못하게 된다. 또한 시간에 따라 파라메터가 변하여 동특성이 급격히 변할 경우 이전의 지능제어 기법(신경망이나 유전 알고리즘)으로는 바뀐

특성에 대해 빠르게 대처하지 못하므로 새로운 상황에 따른 제어기를 재설계해야 한다.

동특성이 급격히 변화하는 시스템에 능동적으로 대처하는 시스템을 구축하기 위해, 생물학적 면역 시스템의 특성을 모방하여 면역 제어 시스템(immunized control system)을 구성한다. 시스템의 관점에서 볼 때, 시스템 내외부의 불확실성은 시스템에 에러를 유발하여 시스템을 불안정하게 하는 원인으로 생물학적 면역 시스템에서의 항원으로 볼 수 있으며, 이러한 불확실한 요소에 강건하게 대처할 수 있는 제어 입력을 항원에 대응하는 항체라 볼 수 있다. 따라서 각각의 불확실성과 제어 파라미터들은 생물학적 면역 시스템에서의 항원과 항체의 관계와 유사하다.

생물학적 면역 시스템과 공학적인 면역 제어 시스템을 비교해보면 표 1과 같다.

표 1. 생물학적 면역 시스템과 면역 제어 시스템과의 비교

Table 1. Comparison between Biological Immune System and Immune Control System.

생물학적 면역 시스템	면역 제어 시스템
항 원	시스템 내·외부의 불확실성
항 체	불확실성에 대처할 수 있는 제어입력
에피톱으로 항원 인식	에러 유형 분석을 통한 불확실성 예측
DNA 조합으로 항체 생성	돌연변이, 교배등의 유전 연산자로 항체 생성
항원과 항체의 모양으로 친화도 계산	에러의 크기로 친화도 계산
몸 전체에서 중앙 제어 없이 분산적으로 반응, 대처	평가함수를 통한 중앙 집중식
골수에서 생성, 소멸, 몸 전체에 저장	신경망 학습으로 생성, 항원 뱅크에 저장

III. 면역화된 귀환 신경망

1. 귀환 신경망과 학습 알고리즘

그림 3에 입력층이 M 개, 출력층이 K 개의 뉴런으로 이루어지고 은닉층(hidden layer)을 N 개의 뉴런으로 귀환층(recurrent layer)을 구성한 귀환 신경망을 보인다.

귀환 신경망 구조에서 뉴런 i 의 상태 방정식은 다음과 같다.

$$\tau \dot{y}_i = -y_i + a(\sum_j w_{ij} y_j + x_i) = -y_i + f(net_i) \quad (1)$$

y_i 는 뉴런의 현재 상태이며 τ 는 뉴런의 시상수(time constant)이고 x_i 는 뉴런으로 들어오는 입력이며 $a(\cdot)$ 는 뉴런의 활성화 함수이다. 평형점에서는 $\dot{y}_i = 0$ 이 된다.

$$y_i = a(net_i) = a(\sum_j w_{ij} y_j + x_i) \quad (2)$$

원하는 출력값 d_i 과 출력 뉴런과의 값의 차가 E_i 가 된다. 뉴런의 실제 출력값과 원하는 출력값이 같도록 만들기 위해 다음과 같이 오차함수를 세워 최소화하도록 한다.

$$E = \frac{1}{2} \sum_i (d_i - y_i)^2 = \frac{1}{2} \sum_i E_i^2 \quad (3)$$

여기서 i 가 출력 뉴런인 경우 $E_i = d_i - y_i$, 출력 뉴런이 아닌 경우는 $E_i = 0$ 이다.

기종치 w_{pq} 를 개선하기 위해 역전파 학습 알고리즘을 적용한다. 일련의 학습 데이터가 주어졌을 때 귀환 신경망의 기종치 w_{pq} 의 변화량은 다음 식에 의해 조정된다.

$$\Delta w_{pq} = -\eta \frac{\partial E}{\partial w_{pq}} = \eta \sum_i E_i \frac{\partial y_i}{\partial w_{pq}} \quad (4)$$

$\frac{\partial y_i}{\partial w_{pq}}$ 은 다음과 같이 구할 수 있다.

$$\frac{\partial y_i}{\partial w_{pq}} = a'(net_i) [\delta_{ip} y_q + \sum_j w_{ij} \frac{\partial y_j}{\partial w_{pq}}] \quad (5)$$

이 식에서 δ_{ip} 는 Kronecker delta 함수(i 가 p 와 같을 경우에만 $\delta_{ip} = 1$)이다.

위 식을 고쳐 쓰면 다음과 같다.

$$\begin{aligned} \frac{\partial y_i}{\partial w_{pq}} &= \sum_j a'(net_i) w_{ij} \frac{\partial y_j}{\partial w_{pq}} \\ &= \sum_j [\delta_{ij} - a'(net_i) w_{ij}] \frac{\partial y_j}{\partial w_{pq}} = \delta_{ip} a'(net_i) y_q \end{aligned} \quad (6)$$

여기서, $L_{ij} = \delta_{ij} - a'(net_i) w_{ij}$ 라 놓으면,

$$\sum_j L_{ij} \frac{\partial y_i}{\partial w_{pq}} = \delta_{ip} a'(net_i) y_q \quad (7)$$

이고 $\frac{\partial y_i}{\partial w_{pq}}$ 는 식 (7)의 선형 방정식을 풀어서 구할 수 있다. 역행렬을 취하면

$$\frac{\partial y_i}{\partial w_{pq}} = [L^{-1}]_{ip} a'(net_p) y_q \quad (8)$$

이고, 식 (2.8)을 식 (2.4)에 대입하면 학습 규칙은 다

음과 같은 식이 된다.

$$\Delta w_{pq} = \eta \sum_i E_i [L^{-1}]_{ip} a'(net_p) y_q \quad (9)$$

뉴런들간에 완전히 연결(fully connected)^[5] 이루어진 경우 행렬 L 은 $N \times N$ 행렬이 된다.

역행렬을 피하기 위해 z_p 를 정의하여 다음과 같이 나타낸다.

$$z_p = \sum_i E_i [L^{-1}]_{ip} \quad (10)$$

$$\sum_p L_{pi} z_p = E_i \quad (11)$$

이미, 학습규칙은

$$\Delta w_{pq} = \eta z_p a'(net_p) y_q \quad (12)$$

가 된다. 식 (2.11)에 $L_{ii} = \delta_{ii} - a'(net_i)w_{ii}$ 를 대입해 보면,

$$z_i - \sum_p a'(net_p) w_{pi} z_p = E_i \quad (13)$$

가 된다. 따라서 z_i 를 구하면 식(12)에 의해, 학습 규칙을 결정할 수 있다.

상기의 식 (13)은 식 (2)와 같은 형태로 다음과 같이 나타내어질 수 있다.

$$\tau \dot{z}_i = -z_i + \sum_p a'(net_p) w_{pi} z_p + E_i \quad (14)$$

식 (1)과 식 (14)를 비교해 보면 오차 역전파의 형태는 원래의 망과 같으며, 단지 가중치 w_{ii} 가 w_{ji} 로 바뀌었다는 것을 확인할 수 있다. 따라서 식 (14)와 식 (12)을 사용하여 개신되는 가중치를 얻는다. 이상의 과정을 귀환 역전파(recurrent back-propagation) 학습 알고리즘^[4]이라 하며, 행렬 역변환을 피하고 계산량을 줄여준다.

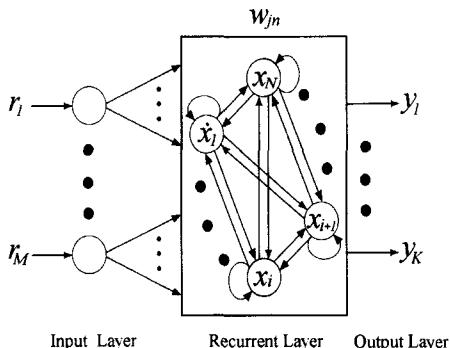


그림 2. 귀환 신경망

Fig. 2. Recurrent Neural Network.

2. 면역화된 귀환 신경망에 의한 지능 제어 시스템

① 항체 생성

전체 제어 과정은 항체 생성과 면역 제어과정으로 구성된다. 우선 주어진 제어 시스템에 대한 항체와 항원에 대해 정의해 본다. 시스템 내외부의 불확실성은 시스템에 에러를 유발하여 시스템을 불안정하게 하는 원인이 되므로 항원으로 정의할 수 있다. 또한 이러한 불확실한 요소에 강건하게 대처할 수 있는 제어 입력을 항원에 대응하는 항체라 볼 수 있다. 본 논문에서는 학습이 마쳐진 후의 귀환 신경망의 가중치를 항체로 고려하였다.

신경망의 가중치를 얻기 위해 다음의 귀환 신경망 제어 시스템을 구성한다.

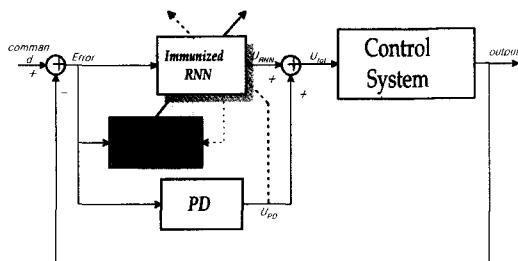


그림 3. 면역 제어 시스템

Fig. 3. Immunized Control System.

그림 3의 시스템의 제어 대상에 인가되는 전체 입력 U_{tot} 는

$$U_{tot} = U_{NN}(t) + U_{PD}(t) \quad (15)$$

로 선형 제어기의 출력 U_{pd} 와 귀환 신경망의 출력 U_{NN} 의 합에 의해 결정된다. PD제어기의 출력을 교사신호로 하여 신경망을 학습시킨다. 귀환 역전파 학습을 각각의 제어 환경에 대해 수행할 경우, 여러 제어 환경에 대해 서로 다른 가중치를 얻을 수 있다. 얻어진 가중치들은 각각의 제어 환경에 대한 입력이 되며, 외란에 대한 항체라 볼 수 있다. 각각의 항체들을 스트링으로 표현하여 항체 뱅크에 저장해 두어 이후에 유전 연산자를 통해 새로운 항체를 생성시킬 수 있도록 한다.

② 면역 제어

제어 환경의 변화는 오차를 유발하므로, 오차를 판별하여 제어 환경의 변화가 생겼음을 알 수 있다. 면역 제어기는 오차가 생길 경우 즉각적으로 대응하여

제어기를 새로운 환경에 맞도록 바꾸어준다. 변화된 제어환경의 특성과 제어 대상의 동적 특성의 변화는 오차의 특성을 변화시키게 된다. 따라서 이러한 오차 특성을 이용하여 변화된 제어 환경의 특성을 어느정도 예측할 수가 있다. 이는 다음 세대의 항체를 만들 때 사용된다. 항체 뱅크로부터 부집단을 선택하여 다음 세대의 항체를 구성할 경우 다음과 같은 오차정보를 사용한다.

$$\cdot \text{평균 } \bar{e}(t) = \frac{\int_t e(t) dt}{t} \quad (16)$$

• 상관계수(r)

$$r(e, q_d) = \frac{\sum_t (e(t) - \bar{e}(t)) \cdot (q_d(t) - \bar{q}_d)}{\sqrt{\sum_t (e(t) - \bar{e}(t))^2} \sqrt{\sum_t (q_d(t) - \bar{q}_d)^2}} \quad (-1 < r < 1) \quad (17)$$

여기서, e_1 , e_2 는 로봇 매니퓰레이터의 실제 출력인 관절각(θ_1 , θ_2)과 원하는 추종 궤적(q_{d1} , q_{d2})의 차로 정의한다.

IV. 면역화된 귀환 신경망을 이용한 로봇 매니퓰레이터의 제어

1. 항체 생성과 면역 제어

본 논문에서는 2 관절 로봇 매니퓰레이터 시스템에 면역 알고리즘을 도입하여 불확실성에 강건한 제어 시스템을 구축한다. 일반적인 로봇 매니퓰레이터는 다음과 같은 동적 방정식으로 나타낼 수 있다.

$$U = M(q) \ddot{q} + 2B(q) \dot{q} \dot{q} + C(q) \dot{q}^2 + D(q) \quad (19)$$

$$M(q) = \begin{bmatrix} (m_1 + m_2)l_1^2 + m_2l_2^2 2m_2l_1l_2 \cos(q_2) & m_2l_2^2 + m_2l_1l_2 \cos(q_2) \\ m_2l_2^2 + m_2l_1l_2 \cos(q_2) & m_2l_2^2 \end{bmatrix} \quad (20)$$

$$2(B) \dot{q} \dot{q} + (C) \dot{q}^2 = \begin{bmatrix} -2m_2l_1l_2 \sin(q_2) \dot{q}_1 \dot{q}_2 - m_2l_1l_2 \sin(q_2) \dot{q}_2^2 \\ m_1l_1l_2 \sin(q_2) \dot{q}_1^2 \end{bmatrix} \quad (21)$$

$$D(q) = \begin{bmatrix} (m_1 + m_2)gl_1 \cos(q_1) + m_2gl_2 \cos(q_1 + q_2) \\ m_2gl_2 \cos(q_1 + q_2) \end{bmatrix} \quad (22)$$

로봇 매니퓰레이터에서 질량 m_1 과 m_2 의 변동, 그리고 마찰항 등이 시스템에 에러를 유발하는 불확실한 요소들이며, 이들의 변동은 시스템의 제어 성능에 영향을 준다. 본 논문에서는 로봇 매니퓰레이터의 질량

m_1 과 m_2 가 30kg~50kg 사이에서 변하며, 마찰력이 부가된다고 고려한다.

그림 4와 같이 항체를 정의한다. 항체 정보 구간에서는 신경망의 가중치를 나타내며, 항체 특성 구간에서는 주어진 항체로 로봇 매니퓰레이터 제어할 때의 오차 평균과 상관에 대한 내용을 담고 있다.

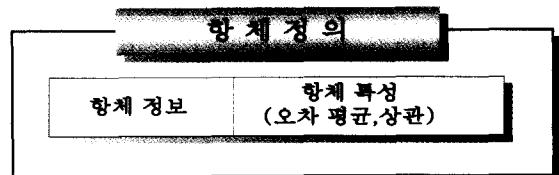


그림 4. 항체정의

Fig. 4. Definition of an Antibody.

입력층, 출력층, 은닉층이 각각 4개, 2개, 8개의 뉴런으로 이루어지고 은닉층이 귀환층인 귀환 신경망을 구성한다. 따라서 항체 정보 스트링은 112개의 가중치로 이루어진다.

항체를 생성시키기 위해 각각의 제어 환경에 대하여 귀환 신경망을 학습시킨다. 매 환경마다 학습을 3000번 반복하여 정현파를 따라가도록 오차 역전파 학습 알고리즘을 이용하여 로봇 매니퓰레이터의 추종 제어를 수행한다. 학습이 끝난 후의 귀환 신경망의 가중치들은 항체 뱅크에 저장된다. 각각의 가중치를 저장하여 50개의 가중치 스트링을 얻는다. 이후 면역 제어를 수행한다.

면역 제어 과정의 초기 가중치는 항체 유전자들로부터 임의로 얻는다. 생성된 항체가 항원에 대응하는 정도를 나타내는 적합도(Fitness)는 다음과 같은 함수로 주어진다.

$$Fitness = \frac{K}{\int_t \sqrt{e_1^2(t) + e_2^2(t) + (\dot{e}_1^2(t) + \dot{e}_2^2(t)) dt}} \quad \text{단, } K > 0 \quad (18)$$

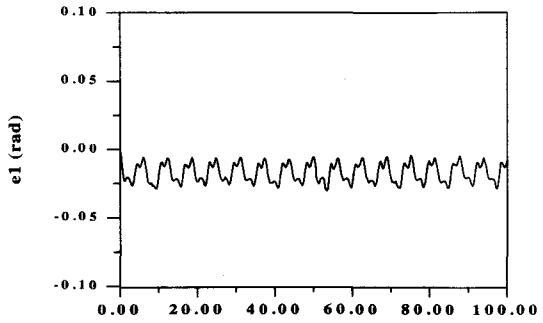
초기 항체로부터 생성된 가중치로 제어가 잘 수행된다면 기존의 항체들로 제어를 수행하며, 제어가 수행이 잘 이루어지지 않거나 동특성이 변화하여 현재의 파라미터들로 제어가 원활히 수행되지 못할 경우 저장된 항체 정보를 다시 읽게 된다. 로봇 매니퓰레이터의 특성상 질량 변화는 에러의 평균에 영향을 주고 마찰항은 에러의 형태를 변화시키게 된다. 따라서 이들 에러의 평균과 에러 형태라는 정보를 사용하여 다음 세

대의 항체를 구성하게 된다. 본 논문에서는 부집단으로 5개의 항체를 부모 세대로부터 선택하도록 하였으며, 빠른 진화 속도를 얻기 위해 자손을 2개로 삼으며, 그 중 하나는 친화도가 가장 높은 것을 선택하도록 구성하였다. 선택된 항체 유전자가 부적격하여 제어를 원활히 수행하지 못할 경우, 항체 뱅크에서 새로이 항체 유전자를 선택하여 새로운 제어 파라미터를 찾아나간다. 면역 제어를 위해 샘플링 시간을 0.01로 삼고, 적합도 계산에 0.3초가 경과된다고 두었다.

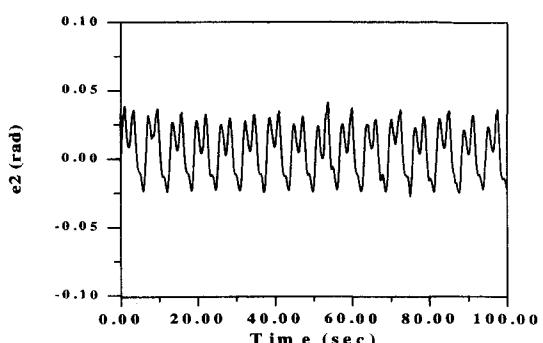
2. 모의 실험

- ▶ (실험 1) 매니퓰레이터의 관절 무게를 각각 $m_1 = 40 \text{ kg}$, $m_2 = 40 \text{ kg}$ 으로 놓고 모의 실험을 진행하였다. 주어진 매니퓰레이터의 무게는 하나의 항원으로 고려된다. 모의 실험 결과에서 초기부터 제어가 커다란 오차 없이 빠르게 이루어짐을 볼 수 있다. 주어진 외란 파라미터 값은 고려한 외란의 전체 파라미터 값(30~50kg)의 중간값이다. 따라서 가해진 외란에 대한 항체는 예비 항체 속에 많이 존재해 있기 때문에 주어진 항원에 대해 빠르게 대처할 수 있게 된다. (a)는 매니퓰레이터의 관절 1의 추종오차(e1)를 보이며 (b)는 관절 2의 추종오차(e2)를 보인다. (그림 5)
- ▶ (실험 2) 외란으로 $m_1 = 50 \text{ kg}$, $m_2 = 50 \text{ kg}$ 으로 설정하고 모의 실험을 하였다. 이 경우 실험 1에서 와는 달리 모의 실험 초기에 외란으로 인한 오차를 보인다. 예비항체에는 이 파라미터 값에 대응하는 정보가 들어있지만 전체 예비 항체 중 일부분에 해당되기 때문에 초기부터 수렴을 보이기는 쉽지 않다. 약간의 평가 기간을 거친후 20초 정도에서 에러 유형을 분석하여 항체를 귀환 신경망 속에 투입하게된다. 항체 투입 후 시스템의 오차가 줄어드는 것을 보인다.(그림 6) 모의 실험 1과 비교해 볼 때, 외란에 대한 항체가 다수 존재할 경우 상대적으로 빠른 수렴 속도를 보이는 것을 알 수 있다.
- ▶ 질량 변화와 함께 마찰항을 고려하였다. (실험 4) $m_1 = 50 \text{ kg}$, $m_2 = 40 \text{ kg}$, $F_d = 50$ 으로 놓고 모의 실험을 진행하였다. 마찰항으로 인해 에러가 유발되지만, 학습된 불확실성에 대한 정보는 예비항체에 들어있기 때문에 이 정보를 사용하여 20초 정도에서 오차를 줄이는 것을 볼 수 있다. (그림 7)

▶ (실험 5) 초기에 $m_1 = 40 \text{ kg}$, $m_2 = 40 \text{ kg}$ 에서 파메터가 $m_1 = 50 \text{ kg}$, $m_2 = 50 \text{ kg}$, $F_d = 50$ 으로 급격히 변하였다. 이 경우 GA 연산자만을 사용하여 제어를 수행한 경우와 면역 알고리즘으로 항체를 투입하여 제어한 것과의 추종오차를 비교하였다. 그림에서 진한 실선은 면역 알고리즘을 사용한 결과이고 얇은 실선은 GA 연산자만을 사용한 경우이다. 60초 정도에서 위에서 설정한 바와 같이 파라미터를 교체하였다. 이전까지 비슷한 수행 결과를 보이지만 항체 투입이 없는 GA연산자만으로는 제어가 잘 수행되지 않는 것을 볼 수 있다. 면역 알고리즘은 알고리즘 수행 초기에는 에러가 생기지만 곧바로 항체투입으로 에러를 줄여나간다. 항체 투입 없이 현재 집단으로 계속 학습을 이루는 경우 돌연변이 연산자나 교배 연산자 때문에 결과적으로 수렴을 이룰 수도 있지만 그 기간이 상당히 길어지게 된다.



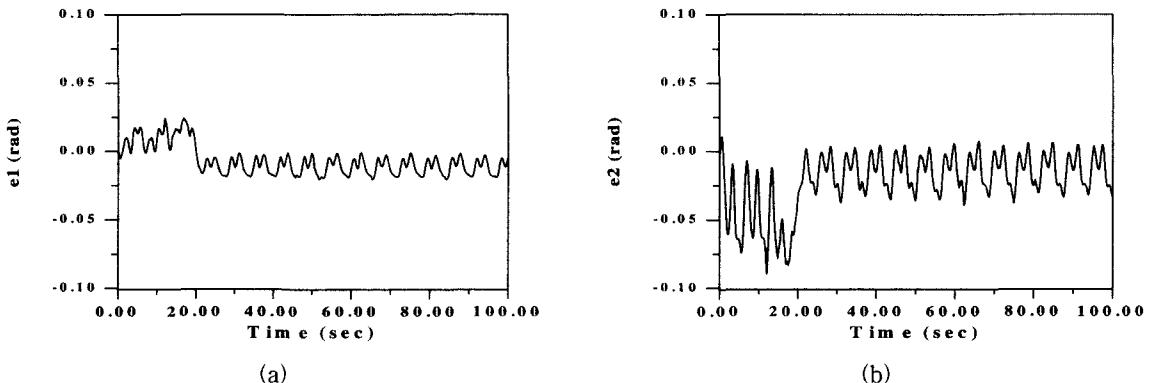
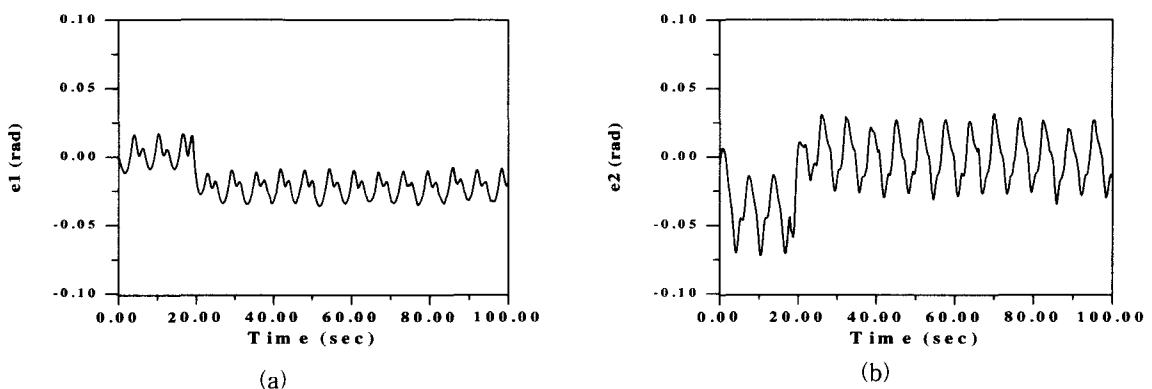
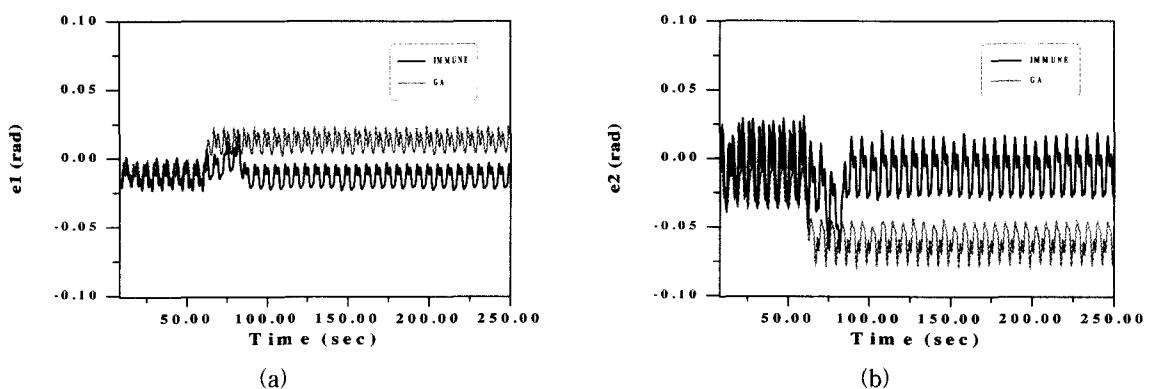
(a)



(b)

그림 5. $m_1 = 40 \text{ kg}$, $m_2 = 40 \text{ kg}$ 일 때 관절 1과 관절 2의 추종 오차

Fig. 5. Tracking Errors of a Immune Controller for $m_1 = 40 \text{ kg}$, $m_2 = 40 \text{ kg}$.

그림 6. $m_1=50\text{ kg}$, $m_2=50\text{ kg}$ 일 때 관절 1과 관절 2의 추종 오차Fig. 6. Tracking Errors of a Immune Controller for $m_1=50\text{ kg}$, $m_2=50\text{ kg}$.그림 7. $m_1=40\text{ kg}$, $m_2=40\text{ kg}$, $F_d=50$ 일 때 관절 1과 관절 2의 추종 오차Fig. 7. Tracking Errors of a Immune Controller for $m_1=40\text{ kg}$, $m_2=40\text{ kg}$, $F_d=50$.그림 8. $m_1=38\text{ kg}$, $m_2=38\text{ kg}$ 에서 $m_1=48\text{ kg}$, $m_2=48\text{ kg}$, $F_d=50$ 으로 변화할 때 GA연산자만을 사용한 경우와 면역 알고리즘과의 비교Fig. 8. Comparison between Immune algorithm and GA operation when parameters vary from $m_1=38\text{ kg}$, $m_2=38\text{ kg}$ to $m_1=48\text{ kg}$, $m_2=48\text{ kg}$, $F_d=50$.

V. 결론 및 검토

본 논문에서는 외부환경에 스스로 대처하는 강건한 지능 제어 기법을 위해 면역 시스템 이론을 적용하였다. 면역 시스템은 외부의 항원에 대항하여 방어하기 위한 체계로 항원에 대한 항체를 생성하여 신체를 유지시키는 역할을 한다. 공학적 측면에서 볼 때 마찰력이나 파라메터 변동 등의 불확실성은 시스템의 항원이라 볼 수 있고, 불확실한 환경에 대응하도록 설계된 제어 파라메터는 항체라 볼 수 있다. 각각의 불확실성에 대한 항체를 생성하여 면역 제어 시스템(Immunized Control System)을 구성하였다.

면역 제어 시스템은 예비 항체를 미리 생성시켜 외란 및 불확실성에 빠르게 대처하여 제어를 수행할 수 있도록 해준다. 면역 제어 시스템은 귀환 신경망과 유전 알고리즘의 장단점을 보완하여 기존의 제어 알고리즘처럼 새로운 정보를 학습해나가기도 하며, 특히 과거의 학습정보를 이용하여 빠르게 주어진 환경에 적응해 나간다. 각각의 환경에 대한 항체를 생성해 놓으므로 다른 지능제어 기법과 비교해볼 때, 면역 제어 기법은 동특성이 급격히 변하는 환경에서 효율적으로 제어를 수행한다.

2232, 1987.

- [5] V.Petridis, S.Kazarlis, A. Papaikonomou, "A Genetic Algorithm for Training Recurrent Neural Networks," IJCNN, pp. 2706-2709, 1993.
- [6] D. E. Goldberg, Genetic Algorithms in Search, Optimization, and Machine Learnings, pp.1-58, Addison-Wesley, 1988.
- [7] N. K. Jerne, "Toward a network theory of the immune system," Ann. Immunol.(Inst. Pasteur), vol.125C, pp.373-389, 1974.
- [8] A. Ishiguro, Y. Watanabe, Y. Ychikawa, "A Gait Acquisition of 6-Legged Walking Robot Using Immune Networks", Journal of Robotics Society of Japan, vol.13, no.3, pp.125-128, 1995.
- [9] Y. Ishida, N. Adachi, "An Immune Algorithm for Multiagent: Application to Adaptive Noise Neutralization," Proc. of IROS 96, pp.1739-1746, 1996.
- [10] K. KrishnaKumar, "Immunized Neuro-control-Concepts and Initial Results," International Workshop on COGANN-92, pp.146-168, 1992.

참 고 문 헌

- [1] P. C. Parks, "Lyapunov redesign of model reference adaptive control systems," IEEE Trans. Automat. Contr., vol.AC-11, pp. 362-365, 1996.
- [2] M. Kawato, Y. Uno, M. Isobe, R. Suzuki, "Hierarchical Neural Network Model for Voluntary Movement with Application to Robotics." IEEE Control Syst. Mag., pp.8-16, Apr, 1988.
- [3] A. Karakasoglu, S. I. Suharsanan, and M. K. Sundaresan, "Identification and Decentralized Adaptive Control Using Dynamical Neural Networks with Application to Robotic Manipulators," IEEE Trans on Neural Networks, vol.4, no.6, pp.919-930, 1993.
- [4] Pineda. F. J. "Generalization of back-propagation to recurrent neural networks," Physical Review Letters, vol.59, pp.2229-

저자소개

元 敬 載(正會員)

1973年 5月 27日生 1996년 2월
중앙대학교 전자공학과 졸업(학사).
1998년 2월 중앙대학교 대학원 전자
공학과 재학중. 주관심분야 : 퍼지, 유전알고
리즘, 신경망, Adaptive, Optimal Control 등임



徐 輽 龍(正會員)



1969年 7月 21日生 1996년 2월
중앙대학교 전자공학과 졸업(학사).
1998년 2월 중앙대학교 대학원 전자
공학과 졸업(석사). 1998년 8월
~ 현재 : 중앙대학교 대학원 전자
공학과 박사과정 재학중. 주관심분야 : 퍼지, 유전알고
리즘, 신경망, FNN 등임

延 貞 欽(正會員)

1970年 9月 23日生 1994년 2월
중앙대학교 전자공학과 졸업(학사).
1996년 8월 중앙대학교 대학원 전자
공학과 졸업(석사). 1996년 9월
~ 현재 : 중앙대학교 대학원 전자
공학과 박사과정 재학중. 주관심분야 : 퍼지, 유전알고
리즘, 신경망 등임



金 成 炫(正會員)

1964年 3月 30日生 1991년 2월 중앙대학교 전자공학
과 졸업(학사). 1993년 2월 중앙대학교 대학원 전자공
학과 졸업(석사). 1997년 2월 중앙대학교 대학원 전자
공학과 박사과정 졸업. 1997년 3월 ~ 현재 : 동원대
학 전자과 전임강사. 주관심분야 : 퍼지, 유전알고리즘,
신경망, Adaptive, Optimal Control 등임

全 洪 兑(正會員) 현재 : 중앙대학교 전자공학과 교
수