

PSO를 이용한 인공면역계 기반 자율분산로봇시스템의 군 제어

Swarm Control of Distributed Autonomous Robot System based on Artificial Immune System using PSO

김 준 업, 고 광 은, 박 승 민, 심 귀 보*
(Jun Yeup Kim¹, Kwang-Eun Ko¹, Seung-Min Park¹, and Kwee-Bo Sim¹)
¹Chung-Ang University

Abstract: This paper proposes a distributed autonomous control method of swarm robot behavior strategy based on artificial immune system and an optimization strategy for artificial immune system. The behavior strategies of swarm robot in the system are depend on the task distribution in environment and we have to consider the dynamics of the system environment. In this paper, the behavior strategies divided into dispersion and aggregation. For applying to artificial immune system, an individual of swarm is regarded as a B-cell, each task distribution in environment as an antigen, a behavior strategy as an antibody and control parameter as a T-cell respectively. The executing process of proposed method is as follows: When the environmental condition changes, the agent selects an appropriate behavior strategy. And its behavior strategy is stimulated and suppressed by other agent using communication. Finally much stimulated strategy is adopted as a swarm behavior strategy. In order to decide more accurately select the behavior strategy, the optimized parameter learning procedure that is represented by stimulus function of antigen to antibody in artificial immune system is required. In this paper, particle swarm optimization algorithm is applied to this learning procedure. The proposed method shows more adaptive and robustness results than the existing system at the viewpoint that the swarm robots learning and adaptation degree associated with the changing of tasks.

Keywords: distributed autonomous control, swarm robot control, artificial immune system, particle swarm optimization

I. 서론

최근 로봇 응용연구의 한 축으로 군집로봇 제어 기술에 대한 연구가 활발히 진행되고 있다. 그 중에서도 자연계 생물의 자율분산성을 모방한 군집 로봇에 대한 제어 기술이 집중적인 관심을 받아왔다. 군집 로봇에 대한 자율분산제어 연구는 생물학적인 관찰 및 근거에 기반한 행동 기반 패러다임이다. 개미, 벌, 철새 등의 군집화 된 행동을 수행하는 자연계 생물 군(群)에 유사한 행동을 수행할 수 있도록 하기 위하여 군집 로봇을 활용하는 경우가 대부분인데, 주로 flock, disperse, aggregate, forage, follow trails 등의 행동을 군집 또는 군집을 구성하는 각 개체가 결정하여 수행한다 [8]. 이러한 형태의 연구에서 가장 중요한 특징은 군집을 구성하는 각 로봇 개체가 주어진 개별적인 환경과 다른 개체 등을 인식함으로써, 수행해야할 작업을 독립적으로 결정하는 기능과 중앙 관리형태의 작업 수행이 아닌 협동에 기반한 작업 수행기능이라고 할 수 있다. 이를 통해 군집 로봇 자율분산 제어 시스템은 중앙 관리식 제어 시스템에 비해 높은 강건성(robustness)와 유연성(flexibility)을 가진다.

이를 위해 다양한 알고리즘과 방법론들이 선행되어져 왔

다. Social potential fields를 통해 VLSR (Very Large Scale Robotics) 시스템의 로봇 개체 간, 로봇 군집 간의 인위적인 force law를 정의하고 이를 이용한 자율분산 제어를 구현하 거나[9], 진화적 상호작용을 기반으로 군집로봇의 환경적응을 구현하기도 하였다 [16].

하지만 이와 같은 기하학적 방법으로는 동적환경에 대응하여 보다 적응적인 학습을 수행하는 자율분산 시스템의 구현이 어렵다. 이를 해결하기 위하여 최근 많은 관심을 받고 있는 방법이 인공 면역 시스템이다. 기존의 연구된 면역 시스템 기반 군집로봇 제어 기술을 살펴보면, Ishiguro 등이 면역네트워크 가설 기반 로봇 행동제어기를 제안하였으며, Mitsumoto는 B-Cell 클론 선택 기반 군집 로봇 시스템 전략 복제 기법을 제안하였다. Singh 등은 자연계 면역시스템을 기반으로 적응적 학습 메커니즘을 개발하고 이에 대한 응용으로 두 개의 개체로 구성된 군집 로봇의 주행 제어 시스템을 제안하였다[10]. 본 연구실에서도 면역시스템의 생체적 기능을 모방한 자율분산 시스템을 제안하였는데, 면역 시스템의 외적 인식, 정보처리, 학습 및 기억, 자기/비자기 (self/non-self) 구분, 분산계 조화유지 기능에 대한 공학적 모델을 제시한 바 있다[7].

이러한 선행 연구들은 실제 군집 로봇 제어 시 동적으로 변화하는 환경을 고려하지 않았기에 적응이 불안정하고, 그 학습 속도가 느리다는 한계를 보인다. 본 논문에서는 이를 극복하고자 particle swarm optimization 알고리즘을 인공 면역계 기반 군집 로봇 자율 분산 제어 학습과정에 적용하여 보다 빠르고 안정적인 학습을 수행하고자 한다.

* 책임저자(Corresponding Author)

논문접수: 2012. 2. 26., 수정: 2012. 3. 20., 채택확정: 2012. 3. 27.
김준업, 고광은, 박승민, 심귀보: 중앙대학교 전자전기공학부
(jy915@cau.ac.kr/kkeun@cau.ac.kr/sminpark@cau.ac.kr/kbsim@cau.ac.kr)
※ 본 논문은 한국연구재단 중견연구자지원사업(No. 2011-0029861)에서 지원하여 연구하였으며 연구비 지원에 감사드립니다.

II. 인공면역계 기반 자율분산로봇 군 제어 알고리즘

1. 면역시스템과 인공면역계

생체 방어계인 면역시스템은 박테리아, 기생균, 병원균, 독소, 바이러스 등의 항원이라 통칭하는 외부 유기체 및 단백질 군에 대한 방어수단으로 진화 메커니즘과 유사한 형태의 학습과정을 통하여 체내 순환 세포와 외부 항원과의 구분 및 인식이 가능하다고 알려져 있으며, 이 때 가장 중요한 역할을 수행하는 두 가지 면역시스템 구성요소가 B-cell(B-lymphocyte)과 T-cell(T-lymphocyte)이다. B-cell은 항체를 분비하는 체액성 반응을 수행하며, T-cell은 면역관련 세포를 자극 또는 억제하거나 감염 세포를 제거하는 세포성 반응을 담당한다. 하나의 항체는 하나의 항원만을 인식 가능하므로 자연계의 수많은 항원에 대응하는 항체를 생성하기 위해서 면역시스템은 적응적 학습과정을 수행한다. 이는 면역시스템의 기능이 단순한 외부인자에 대한 거부 및 제거 기능뿐만 아니라 동적 변화하는 환경에 대한 시스템 자체의 적응적 기능도 담당하고 있음을 나타낸다[2]. 컴퓨터 공학 분야에서는 수학적 문제처리를 목적으로 하여 이와 같은 생체 면역시스템에 대하여 모방한 인공면역계(AIS: Artificial Immune System) 이론을 주장하였다[3].

2. 면역 네트워크 기반 인공면역계 모델링

새로운 항원에 대한 학습은 유사 항원에 대응하는 항체 생산 기능의 B-cell의 증식 및 재생산을 통해 이루어진다. 또한 침입한 항원을 제거하면 그 항원에 대해서는 또 다시 인식 가능한 기억세포가 만들어져 뇌가 아닌 세포 단위에서 패턴인식 개체에 기억되는 것으로 알려졌다. 또한 항체도 하원 특이적인 수용체인 *idiotope*를 가지고 있기 때문에 항체 상호간의 복잡한 작용에 의해 상호 자극 및 억제를 수행하는 네트워크를 구성하고 있다고 가정되며 이를 면역 네트워크 가설이라 칭한다[4]. 다음의 그림 1은 면역네트워크에 기반한 면역시스템의 동작 원리를 나타낸다.

특정 항원 침투 시, 그것을 인식하는 B-cell이 자극을 받아 활성화되면 B-cell은 클론 복제를 통해 기억세포를 생성하거나 스스로 혈장세포로 변화한다. 이 때 보조 T-cell이 촉진제 역할을 하는데, 항원과 결합한 매크로파지의 자극에 의해 활동을 개시한다. 혈장세포는 침입 항원을 인식 가능

한 항체를 분비하여 항원이 완전히 제거되면 억제 T-cell에 의해 그 분비가 멈추게 된다. 이러한 일련의 과정은 B-cell과 T-cell 상호 간의 자극과 억제 관계를 통해 면역네트워크를 이루고 있음을 나타낸다.

면역 네트워크 모델에서는 항체가 항원뿐만 아니라 다른 항체와의 상호작용에 의해 그 농도가 변한다는 가정을 기반으로 한다. 이 가정을 동적 방정식으로 표현한 결과는 다음 식과 같다[5].

$$S_i(t+1) = S_i(t) + \left(\alpha \frac{\sum_{j=1}^N (m_{ij} - m_{ji}) s_j(t)}{N} + \beta m_i - c_i(t) - k_i \right) s_i(t) \quad (1)$$

$$s_i(t) = \frac{1}{1 + e^{(0.5 - S_i(t))}} \quad (2)$$

$$c_i(t) = \eta(1 - g_i(t)) S_i(t) \quad (3)$$

단, $i = 0, \dots, N-1$, N 은 항체 종류 수, $S_i(t)$ 는 i 항체의 자극 값, $s_i(t)$, $s_j(t)$ 는 i 항체, j 항체의 농도, $c_i(t)$ 는 i 항체의 농도 조절보조 및 억제 T-cell 농도, m_{ij} , m_{ji} 는 i 항체와 j 항체 간의 상호자극계수, m_i 는 i 항체와 항원 간의 상호자극계수, α , β , η 는 다른 항체와 항원의 반응을 파라미터, k_i 는 자연소멸계수이다.

식 (3)에서 T-cell의 농도 $c_i(t)$ 는 항원의 자극 값에 반비례하고, 항체의 자극 값에 비례하기 때문에 보조 T-cell 및 억제 T-cell의 역할을 수행할 수 있다. 이를 기반으로 T-cell의 역할을 정의하면 다음 표와 같다.

3. 인공면역계 기반 자율 분산 로봇 군 제어 알고리즘

본 연구실은 인공면역계를 이용한 여러 선행연구를 수행해왔다[11-13]. 그 중에서도 분산 로봇 제어연구를 참조하여 인공 면역계 모델을 군집 로봇의 제어에 적용함으로써 군집 내 모든 로봇 개체가 주어진 환경 내에 흩어진 작업을

표 1. 다양한 상태에서의 T-cell의 역할.

Table 1. The roll of T-cell in the various environmental condition.

$g_i(t)$	$S_i(t)$	$c_i(t)$	상태	T-cell 역할
high	low	very low	항원침투초기	보조 T-cell
high	high	low	항원제거 중	-
low	high	high	항원제거완료	억제 T-cell
low	low	low	안정 상태	-

표 2. 군집 로봇 시스템과 인공 면역계 변수 간 대응 관계.

Table 2. The corresponding relationship between the swarm robot system and variables of artificial immune system.

군집 로봇 시스템	인공 면역계
작업 분포 환경	항원
행동 전략	항체 (B-cell)
제어 변수	T-cell
행동 전략의 적합/부적합	자극/억제
우수 전략 수행 개체	혈장세포
열등 전략 수행 개체	비활성화 세포

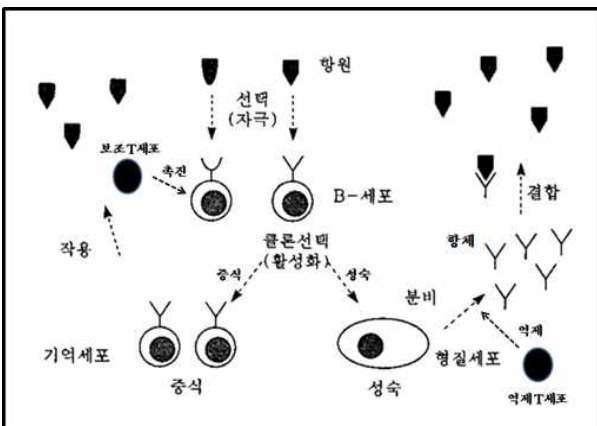


그림 1. 면역시스템 동작 원리.

Fig. 1. The performance property of the immune system.

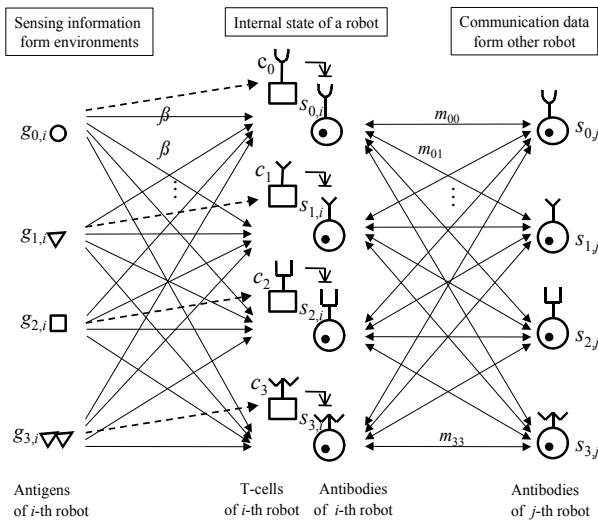


그림 2. 군집 로봇의 자율 분산 제어를 위하여 제안된 T-cell, B-cell 모델링 기반 면역네트워크.

Fig. 2. Proposed immune network including T-cell and B-cell model for distributed autonomous control of swarm robot.

탐색하고, 작업량에 따라 개체를 모으거나 분산하는 두 가지 형태의 군집제어를 수행하고자 한다. 군집제어의 각 독립변수를 면역네트워크 방정식의 각 변수에 대응함으로써 군집 제어를 수행할 수 있다. 이 경우 면역계와 대응하는 군집로봇 분산시스템의 각 변수는 표 2와 같다.

식 (1)-(3)의 면역네트워크 방정식을 기반으로 군집 로봇 환경에서의 전역행동은 작업 분포 환경에 따라 집합과 분산의 행동 전략에 따라 결정된다. 우선, 작업 분포 환경이 작업 밀도가 0에 수렴할 경우 군집 로봇 각 개체들의 밀도 또한 분산 행동 전략을 통해 작아지게 하고, 작업 밀도가 커지는 경우 로봇 개체들의 밀도를 집합 행동 전략을 통해 커지게 하는 방식으로 군집 로봇을 제어 할 수 있다. 이는 작업 공간 내의 작업 밀도와 로봇 개체 수에 따라 어떠한 행동 전략을 선택할 것인가에 대한 문제라고 볼 수 있다. 따라서 주어진 환경에서의 작업 밀도와 로봇 개체 수를 포함하는 작업 분포 환경을 항원으로 정의하고, 선택 가능한 네 가지 행동 전략 {집합, 탐색, 확산, 귀향} 을 항체로 정의하는 면역네트워크를 다음과 같이 구축할 수 있다.

군집로봇의 행동 전략을 면역네트워크 방정식에 적절히 적용하기 위해서는 항원의 자극 값 (작업 밀도 p , 로봇 개체 수 q)으로 구성되는 함수에 대한 파라미터 설정이 적절하게 학습되어야 한다. 본 연구실에서 선행된 관련 연구에서는 현재 시점부터 과거 시점까지의 정해진 작업 공간 내의 작업 감지 횟수와 로봇 개체 감지 수에 통계적 결과에 따라 선형적으로 증가하는 작업 밀도와 로봇 개체 수를 가정하였다. 그러나 보다 실제적인 작업 환경을 고려한다면, 작업의 발생빈도와 로봇개체의 감지 횟수는 시간에 따라 비선형적으로 발생한다는 점을 간과해서는 안 된다. 본 논문에서는 이러한 비선형성을 항원 자극 값에 대한 학습문제로 정의하여, 최적의 자극 값을 탐색할 수 있도록 하기 위한 방법을 제안한다.

III. Particle Swarm Optimization 기반 인공지능계 최적화

1. Particle Swarm Optimization

PSO (Particle Swarm Optimization)는 확률 기반 최적화 기법으로서 군집 체계를 이루는 생태계의 사회적 행동패턴에서 영감을 받았다. 최근 국내에서는 이와 관련하여 퍼지논리 기반 비선형 시스템 모델링[14], 신경망 기반 퍼지추론 메커니즘 최적화[15], 또는 영상기반 객체 추적과 같은 응용 연구[17] 형태로 다양한 분야 간에 적용된 바 있다. PSO는 유전 알고리즘 등의 진화연산과 유사점을 가지지만 유전 알고리즘의 진화 연산자해당부가 존재하지 않으며, particle로 정의되는 해 공간상의 잠재적 해들이 현재 시점에서의 최적 해를 따라가기 위한 random velocity와 이전 시점의 잠재적인 해들의 결합으로 구성된다[6]. 각각의 particle들은 특정시점까지의 최적 해와 관련된 문제공간 (problem space) 내에서 적합도 평가 및 해 갱신의 반복을 통해 최적 해를 추적한다. 이와 관련된 파라미터가 pbest이며 해당 particle의 이웃 particle까지의 거리와 관련된 파라미터가 lbest이다. 만약 하나의 particle이 모든 개체군을 위상적인 이웃으로 취한다면, 그 때의 pbest, lbest 값은 전역 해로 여겨지며, gbest로 표현한다. 만약 특정 파라미터 집합 \mathbf{P} 에 의해 최적화되어야 하는 함수 $f(\mathbf{P})$ 를 가정한다면 다음과 같이 PSO를 적용할 수 있다.

- 1) Random으로 잠재적 해집합 $\{\mathbf{P}_{i0}\}$ 를 결정한다.
- 2) 각 iteration j 에 대해 다음 과정을 반복한다.
 - 2-1) 각 \mathbf{P}_{ij} 에 대하여 $f(\mathbf{P}_{ij})$ 를 계산한다.
 - 2-2) 최적 $f(\mathbf{P}_{ij})$ 의 변화를 계산하고, 수렴 시 루프를 빠져나간다.
 - 2-3) 각 i 에서 $\{0, \dots, j-1\}$ 에 대하여 가장 최적인 해를 pbest _{i} 로 저장한다.
 - 2-4) 모든 pbest _{i} 에서 가장 최적인 해를 gbest _{i} 로 저장한다.
 - 2-5) 각 particle의 속도를 다음 식으로 계산한다.

$$v_{ij} = v_{ij-1} + c_1r_1(pbest_{ij} - P_{ij-1}) + c_2r_2(gbest_{ij} - P_{ij-1}) \quad (4)$$

- 2-6) 각 particle의 값을 (4)에 따라 갱신한다.

$$P_{ij} = P_{ij-1} + v_{ij} \quad (5)$$

- 3) gbest _{j} 를 최적 해로 결정한다.

이 때, c_1 과 c_2 는 상수이고, r_1 과 r_2 는 임의의 실수이다.

2. 항원 자극 값 학습의 최적화를 위한 Particle Swarm Optimization 알고리즘

일반적으로 PSO를 적용할 경우 중요한 요소 2가지가 “parameter 설정(acceleration coefficient, inertia weight) 최적화”와 “fitness function 설계”로 정의된다. 본 논문에서는 항체 i 에 대한 항원의 자극 값을 나타내는 g_i 결정과정에 PSO를 적용함으로써, 기존의 g 를 구하는 문제를 해결하고 보다 높은 정확도의 로봇 제어를 구현할 수 있다.

기존 연구에서 항원의 자극 값은 그림 3과 같이 정의되었다[11]. 이 값들은 작업분포 환경 내에서 일정시간 (항




그림 3. 시행착오를 통한 항체 (g_i)에 대한 항원 자극 값 함수.
Fig. 3. Stimulus function of antigen to antibody (g_i) by trials.

표 3. 상호 자극 계수 (m_{ij}).

Table 3. Mutual stimulus coefficient (m_{ij}).

Agent i \ Agent j	Aggregation	Search	Dispersion	Homing
Aggregation	1	-0.4	-0.2	-0.4
Search	-0.4	1	-0.4	-0.2
Dispersion	-0.2	-0.4	1	-0.4
Homing	-0.4	-0.2	-0.4	1

원평가시간 T_c 동안 감지된 작업개수의 비율에 따라 정의된다. 선행 연구에서는 다수의 실험데이터베이스를 기반으로 통계적인 시행착오에 기반으로 동적 환경 변화를 고려하지 않은 고정된 파라미터 분포를 제안하였다.

시그모이드 함수로 표현된 항원 자극 값 함수를 최적화하기 위해서는 최적화 함수 또는 목적함수 f 를 정의해야한다. 본 논문에서는 항원 자극 값을 기반으로 하였을 경우 항체의 적합정도를 목적함수로 정의하였다. 최적화 함수를 수식으로 전개한 결과는 다음과 같다.

$$f(a,b) = \frac{\sum_{k=1}^K \sum_{l=1}^{L_k} \delta(\arg_m \max(P_m(X_{kl}), k)}{k \sum_{k=1}^K L_k} \quad (6)$$

위 식에서 $\delta(i,j)$ 는 $i = j$ 일 때 1이고, 그 외의 경우 0인 함수로 X_{kl} 은 k 작업 밀도에 l 개의 개체가 존재함을 나타낸다. P_m 은 주어진 항원에 대하여 m 번째 항체의 관측 확률이고, $\arg_m \max P_m$ 은 가장 큰 확률을 가지는 항체의 인덱스를 나타낸다. 식 (6)은 비선형 함수로 항원 자극 값 함수의 파라미터인 (a,b)를 만족할 수학적 해를 구하기 어려우므로 PSO를 통하여 최적 해를 구할 수 있다.

IV. 인공면역계 최적화 기반 자율분산 로봇 제어 시뮬레이션

1. 시뮬레이션 환경 설정

제안된 알고리즘을 자율분산로봇시스템에 적용하기 위한 시뮬레이션의 조건은 다음과 같다. 직경이 50 mm인 50대의 로봇이 10 m × 10 m 의 작업공간에 흩어져 있다. 이때 시스템의 목적은 작업영역에 무작위로 흩어져 있는 500개의 작업을 수행할 때 보다 정확한 행동전략을 선택하여 동적 변화에 대한 적응성 및 강인성을 향상하는 것이다. 작업분

포 환경에서의 작업밀도를 계산하기 위해서는 항원의 평가 시간 (T_c)를 40 time으로 설정하고, 1 time 동안 로봇은 25mm를 이동하거나 방향을 변경할 수 있거나 또는 1회의 통신을 할 수 있다. 주어진 환경에서 하나의 작업을 수행하는데 걸리는 시간은 15 time이며 나머지 파라미터는 $\alpha = 0.3, \beta = 0.05, k_i = 0.002$ 로 고정 설정하였다.

2. 시뮬레이션 결과

본 논문에서 제안하는 PSO 기반 인공면역 시스템의 최적화 목적이 동적으로 변화하는 작업 환경에 흩어져 있는 n 개의 작업을 군집 로봇의 인공면역 시스템 기반의 자율분산 알고리즘을 기반으로 최적의 행동전략을 선택하여 수행 하는 것이다. 본 논문에서는 동적 작업환경에서 $n = 500$ 이고 최적화된 항체에 대한 항원 자극 값 함수를 이용하였을 때 시스템의 성능이 개선되어 작업을 수행하는 시간이 더 짧게 걸린다고 가정하였다. 그리하여 PSO를 이용하여 최적화된 항체에 대한 항원 자극 값 함수를 구할 때 fitness를 500개 작업을 완료 하는데 걸리는 시간으로 설정하였다. 기본 그래프의 형태는 그림 3을 이용하였고 가로축 10, 20, 66에 해당하는 점들을 particle로 설정하였다. 즉 3개의 particle을 이용하여 PSO에 적용하였다. gbest는 500개 작업을 완료하는데 걸리는 시간이 가장 작을 때의 particle 위치로 설정하였고 pbest는 작업을 완료하는데 걸리는 시간이 두 번째로 작을 때의 particle 위치로 설정하였다.

그림 5는 B-cell 모델과 그림 4의 항원 자극 값 함수를 사용했을 때의 실험 결과이고 그림 6은 그림 3의 항원 자극 값 함수를 사용했을 때의 실험 결과이다. 시뮬레이션 환경에서 항원의 평가시간을 40 time으로 설정하였기 때문에 처음부터 40 time전까지는 기본전략은 탐색을 선택 하였고 40 time 이후부터는 평가된 작업 밀도와 그림 5에 의해 g_i 값이 변경 되어 그에 따라 로봇이 알맞은 전략을 선택하여 작업을 수행한 결과이다. 그림에서 보다시피 그림 4를 이용하였을 때는 1000 time동안 500개의 작업을 모두 완료하지 못하였음을 보였다. 그림 3을 이용하였을 때는 500개의 작업을 대략 800 time에 완성하였다.

그림 7은 B-cell 모델과 PSO를 기반으로 항원 자극 값 함수를 최적화 한 결과이다. 앞의 그림 5, 그림 6의 실험 조건과의 유일한 차이점은 그림 5, 그림 6은 항체에 대한

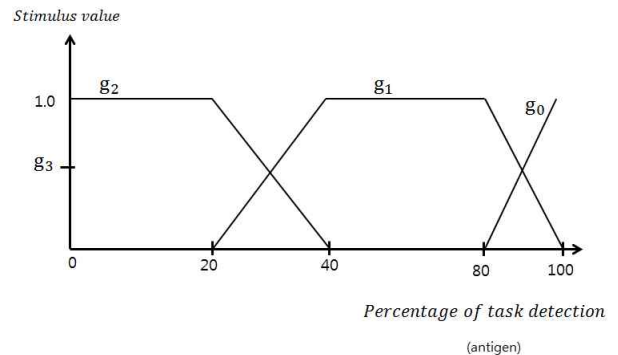


그림 4. 임의로 선택된 항체 (g_i)에 대한 항원 자극 값 함수.
Fig. 4. Stimulus function of antigen to antibody (g_i) by random selection.




그림 5. B-세포 모델 기반 실험 결과 (임의로 선택된 항체에 대한 항원 자극 값 함수 사용).

Fig. 5. Result of B-cell model using stimulus function of antigen to antibody by random selection.




그림 7. B-세포 모델 기반 실험 결과 (PSO를 기반으로 최적화된 항체에 대한 항원 자극 값 함수 사용).

Fig. 7. Result of B-cell model using stimulus function of antigen to antibody by optimization based on PSO.

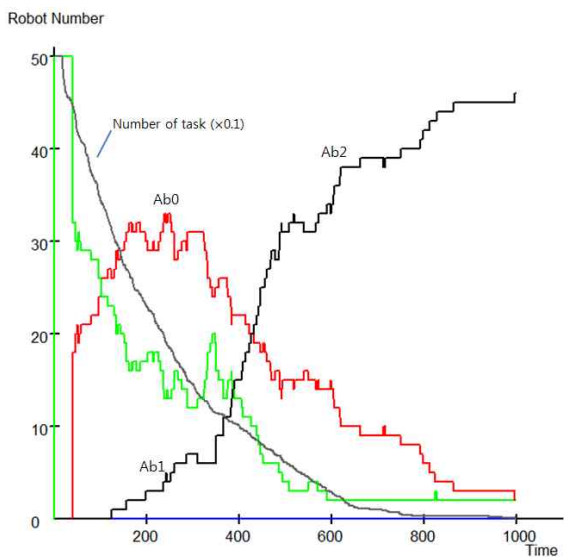


그림 6. B-세포 모델 기반 실험 결과 (시행착오로 선택된 항체에 대한 항원 자극 값 함수 사용).

Fig. 6. Result of B-cell model using stimulus function of antigen to antibody by trials.

항원 자극 값 함수가 임의로 정해진 것이나 시행착오로 얻어진 것임에 반해 그림 7은 PSO를 통해 최적화 된 항원 자극 값 함수가 적용되었다는 점이다. 이 때 그림 7이 작업을 끝내는데 소요된 시간이 그림 5, 그림 6보다 상대적으로 더 짧은 것을 알 수 있다.

이것으로부터 항체에 대한 항원 자극 값 함수에 대한 최적화가 500개의 작업을 완료하는데 걸리는 시간에 영향을 미치는 것을 알 수 있다. 그러므로 시행착오를 거쳐 결정된 그림 3이나 임의의 값을 선택한 그림 4의 경우보다 PSO를

적용함으로써 최적의 항체에 대한 항원 자극 값 함수를 얻게 된다면 더 빠른 시간 내에 500개의 작업을 완료 할 수 있게 된다는 결과를 얻을 수 있다. 이는 기존에 수행된 인공면역계 기반 자율분산제어 연구와 비교하여 상대적으로 개선된 효율성과 시스템 적응성을 보이고 있음을 의미한다.

V. 결론

본 논문에서는 군집 로봇의 자율분산 제어를 수행하기 위하여 인공면역계 시스템을 최적화 학습하는 방법에 대하여 제안하였다. 제안된 최적화 학습 방법은 PSO 알고리즘을 이용하여 작업밀도와 로봇 개체 수로 표현되는 항원 자극 값과 항체 간의 관계에 대한 파라미터들의 목적함수를 구축하고 이를 최적화한다. 제안 방법의 성능평가를 위하여 작업 환경의 동적 변화를 가정하는 시뮬레이션 환경을 설정하고 그에 따른 적응성을 평가하여 보였다. 제안하는 방법은 변화하는 환경이나 작업 등에 대해 지속적이고 안정적인 제어가 불가능할 때 매우 유용하게 활용될 수 있음을 보인다. 뿐만 아니라 자율분산 제어의 목적인 시스템 강건성 및 유연성이 최적화 되지 않은 기존의 방법과 대비하여 상대적으로 높게 평가됨을 알 수 있다.

추후에는 실제적인 작업 환경을 고려하여, 수행 가능한 행동 전략의 개수와 동적 환경의 복잡도를 증가시킨 조건에서의 연구를 진행할 예정이다.

참고문헌

- [1] Y. U. Cao, A. S. Fukunaga, and A. B. Kahng, "Cooperative mobile robotics: Antecedents and directions," *Autonomous Robots*, vol. 4, pp. 1-23, 1997.
- [2] G. Beck and G. S. Habicht, "Immunity and the Invertebrates," *Scientific American*, vol. 275, no. 5, pp.

- 60-66, Nov. 1996.
- [3] L. N. Castro and J. Timmis, "Artificial immune systems: A new computational intelligence approach," Springer, pp. 57-58, 2002.
- [4] N. K. Jerne, "Idiotopic network and other preconceived ideas," *Immunological Rev.*, vol. 79, pp. 5-24, 1984.
- [5] J. D. Farmer, N. H. Packard, and A. S. Perelson, "The immune system, adaptation, and machine learning," *Physica 22-D*, pp. 184-204, 1986.
- [6] M. Clerc and J. Kennedy, "The particle swarm - explosion, stability, and convergence in a multidimensional complex space," *IEEE Transactions on Evolutionary Computation*, pp. 58-73, vol. 6, no. 1, Feb. 2002.
- [7] K.-B. Sim and C.-M. Hwang, "Distributed autonomous robotic system based on artificial immune system and distributed genetic algorithm," *Korea Fuzzy Logic and Intelligent Systems (in Korean)*, vol. 14, no. 2, pp. 164-170, 2004.
- [8] L. E. Parker, "Current state of the art in distributed autonomous mobile robotics," *Proc. 5th Int. Symp. Distributed Autonomous Robotic Systems*, pp. 3-12, 2000.
- [9] L. Panait and S. Luke, "Cooperative multi-agent learning: the state of the art," *Autonomous Agents and Multi-Agent Systems*, vol. 11, pp. 387-434, 2005.
- [10] C. T. Singh and S. B. Nair, "An artificial immune system for a multiagent robotics system," *World Academy of Science, Engineering and Technology*, vol. 11, pp. 6-9, 2005.
- [11] K. B. Sim, D. W. Lee, and H. Y. Kim, "Emergent and swarm behavior of multi-agent system based on artificial immune system," *2002 FIRA Robot World Congress Seoul, Korea*, pp. 707-712, May 2002.
- [12] K.-B. Sim, D.-W. Lee, and S.-J. Sun, "Cooperative strategies and swarm behavior in distributed autonomous robotics systems based on artificial immune system," *Journal of Control, Automation and Systems Engineering (in Korean)*, vol. 6, no. 12, pp. 1079-1085, Dec. 2000.
- [13] D. W. Lee, K. B. Sim, and S. H. Park, "An immunity-based security layer against internet antigens," *IEICE Transacion on Communications*, vol. E83-B, no. 11, pp. 2570-2575, Nov. 2000.
- [14] J.-Y. Baek, Y.-I. Lee, and S.-K. Oh, "Design of nonlinear model using type-2 fuzzy logic system by means of C-means clustering" *Korean Institute of Intelligent Systems (in Korean)*, vol. 18 no. 6, pp. 842-848, 2008.
- [15] G.-S. Kim, B.-J. Park, and S.-K. Oh, "The design of polynomial network pattern classifier based on fuzzy inference mechanism and its optimization" *Korean Institute of Intelligent Systems (in Korean)*, vol. 17, no. 7, pp. 970-976, 2007.

- [16] W.-S. Moon, J. W. Jang, and K. R. Back, "Environment adaptation using evolutionary interactivity in a swarm of robots," *Journal of Control, Automation and Systems Engineering (in Korean)*, vol. 16, no. 3, pp. 227-232, Mar. 2010.
- [17] S.-T. An, J.-J. Kim, and J.-J. Lee, "Unified detection and tracking of humans using gaussian particle swarm optimization," *Journal of Control, Automation and Systems Engineering (in Korean)*, vol. 18, no. 4, pp. 353-358, Apr. 2012.



김 준 업

2012년 중앙대학교 전자전기공학부(공학사). 2012년~현재 중앙대학교 대학원 전자전기공학부 석사 1차. 관심분야는 Brain-Computer Interface System, Particle Swarm Optimization, Neuro-Robotics 등.



고 광 은

2007년 중앙대학교 전자전기공학부(공학사). 2007년~현재 중앙대학교 대학원 전자전기공학부 석·박사 통합과정 수료. 관심분야는 Human-Computer Inter-action, Brain-Computer Interface System, Intention Recognition, Neuro-Science, Neuro-Robotics, 소프트웨어컴퓨팅 등.



박 승 민

2010년 중앙대학교 전자전기공학부(공학사). 2010년~현재 중앙대학교 대학원 전자전기공학부 석·박사 통합과정. 관심분야는 Brain-Computer Interface, Intention Recognition, 소프트웨어컴퓨팅 등.



심 귀 보

1984년 중앙대학교 전자공학과(공학사). 1986년 중앙대학교 전자공학과(공학석사). 1990년 The University of Tokyo 전자공학과(공학박사). 1991년~현재 중앙대학교 전자전기공학부 교수. 2002년~현재 중앙대학교 중소기업산업협력센터 센터장. 2006년~2007년 한국지능시스템학회 회장. 2007년~현재 (사)한국산학연협회 서울지역협회 회장. 2009년~2010년 중앙대학교 중앙도서관장 및 박물관장. 2011년~현재 중앙대학교 스마트지능로봇연구센터 센터장. 관심분야는 인공지능, 뇌-컴퓨터 인터페이스, 의도인식, 감성인식, 유비쿼터스 지능형로봇, 지능시스템, 컴퓨테이셔널 인텔리전스, 지능형 홈 및 홈 네트워크, 유비쿼터스 컴퓨팅 및 센서 네트워크, 소프트 컴퓨팅(신경망, 퍼지, 진화연산), 다개체 및 자율분산로봇시스템, 인공면역시스템, 지능형 감시시스템 등.