

분류자 시스템과 인공면역네트워크를 이용한 자율 분산 로봇시스템 개발

Development of Distributed Autonomous Robotic System Based on Classifier System and Artificial Immune Network

심귀보 · 황철민

Kwee-Bo Sim and Chul-Min Hwang

중앙대학교 전자전기공학부

요 약

본 논문에서는 인공 면역 시스템과 분류자 시스템에 기반하여 동작하는 자율분산로봇 시스템을 제안한다. 시스템에서 로봇들의 행동은 전역행동과 지역행동으로 분류된다. 전역행동은 환경에서 작업을 탐색하는데 이를 빠르게 수행하기 위하여 집합과 분산의 두 가지 행동으로 이루어져 있다. 이때 인공 면역 시스템은 로봇이 어떤 행동을 선택하여 행동할 것인가를 결정한다. 지역행동은 탐색된 작업을 수행하는 부분으로서 어떤 로봇들이 협조행동을 할지를 학습하고, 학습한 결과에 따라 작업을 수행하는 행동을 한다. 이를 위해 분류자 시스템을 이용하여 각 로봇들은 주어진 작업에 대하여 학습을 한다. 제안된 시스템에서 학습 알고리즘은 주어지는 작업의 변화로봇들은 주어진 작업을 수행하기 위해 학습을 하고, 주어진 작업이 변할 경우 스스로 대처한다는 면에서 기존의 자율 분산 시스템보다 적응성에서 향상된 시스템이다.

Abstract

This paper proposes a Distributed Autonomous Robotic System(DARS) based on an Artificial Immune System(AIS) and a Classifier System(CS). The behaviors of robots in the system are divided into global behaviors and local behaviors. The global behaviors are actions to search tasks in environment. These actions are composed of two types: aggregation and dispersion. AIS decides one among these two actions, which robot should select and act on in the global. The local behaviors are actions to execute searched tasks. The robots learn the cooperative actions in these behaviors by the CS in the local. The proposed system is more adaptive than the existing system at the viewpoint that the robots learn and adapt the changing of tasks.

Key words : Distributed Autonomous Robotic System, Artificial Immune System, Classifier System

1. 서 론

과거 시스템을 제어하기 위하여 중앙 집중식 제어가 많이 사용되었다. 중앙집중식 제어는 중앙에서 필요에 따라 모든 부분을 일괄적으로 처리하기 때문에 빠르고 정확한 제어가 가능하다는 장점이 있다. 하지만 현대에 이르러 기술이 비약적으로 발전함에 따라 제어해야할 시스템이 거대화되고 복잡해 졌다. 이에 따라 시스템 제어의 유연성과 강인함이 점점 중요시되어졌다. 이를 만족시키기 위하여 여러 가지 알고리즘들이 제안되었는데 자율 분산 제어시스템도 그 중의 하나이다. 자율 분산 제어시스템은 인간 사회나 곤충의 군집 체계, 생체 면역시스템 등을 모델링하여 구성하는 모델 등이 있다. 자율 분산 로봇시스템은 이러한 자율 분산 제어시스템의 알고리즘을 이용하여 다개체(Multi-Agent) 로봇의 협조행동을 구성하고 있다[1].

본 논문에서는 자율 분산 로봇시스템에 학습의 개념을 도입함으로써 환경의 변화에 적응이 가능한 시스템을 제안한다. 시스템 구성을 위하여 인공 면역 알고리즘에 기반을 둔 인공 면역 네트워크[2]와 분류자 시스템[3-5]을 이용하여 하나의 시스템을 구성한다[6-8]. 인공 면역 네트워크를 이용하여 자율 분산 시스템을 구성을 함으로서 환경의 변화에 대하여 적절한 행동을 선택하여 적응행동을 하는 것이 가능하다[8]. 또한 분류자 시스템은 학습을 통하여 알려지지 않은 환경에서 보다 나은 보상을 받는 행동을 선택하는 것이 가능하다[3-5].

인공 면역 네트워크는 면역계에서 항원과 항체간의 반응을 모델링하여 나타낸 식이다. 항원과 항체간의 관계를 살펴보면 특정한 항원이 침투했을 때, 그것을 인식하는 B세포가 자극을 받아 활성화된다. 활성화된 B세포는 클론 복제를 통하여 기억세포를 만들거나 스스로 성숙해 혈장세포로 변한다. 보조 T세포는 이 과정을 촉진시키는 역할을 하는데, 항원과 결합한 매크로파지의 자극에 의해 활동을 개시한다. 혈장세포는 침입한 항원을 인식할 수 있는 항체를 분비하여 항원이 사라지면 억제 T세포의 자극과 억제 관계를 식으로 나타내고 있다[2]. 인공 면역 네트워크 방식의 항원과 항체를 적절히 설정하여 줌으로써 자율 분산 로봇 시스템을 구현

접수일자 : 2004년 8월 30일

완료일자 : 2004년 10월 12일

감사의 글 : 본 논문은 2004년도 중앙대학교 학술연구비(일반연구비) 지원에 의한 것입니다. 연구비 지원에 감사드립니다

할 수 있다.

한편, 분류자 시스템은 기계학습의 한 종류로서 환경에 대한 행동을 나타내는 전체의 물들 중에서 유용한 물들을 찾아낸다. 물들의 strength를 할당하기 위하여 'bucket brigade algorithm'을 사용하며 할당받은 strength에 근거하여 유용한 물들을 탐색한다. 본 연구에서는 여러 분류자 시스템 중에서 XCS[4-5]를 이용한다. XCS는 전통적인 분류자 시스템이 가지는 문제를 해결하기 위해 제안된 형태로서 기존에 제안되었던 ZCS (Zeroth Level Classifier System)[3]와 유사한 형태를 가지나 보다 진보한 형태라고 할 수 있다. 기존의 분류자 시스템은 유전자 알고리즘을 이용하여 새로운 물을 탐색할 때에 전체 개체군에서 strength를 적합도처럼 이용하여 선택과 삭제를 하기 때문에 낮은 strength를 갖지만 유용한 물이 파괴되기 쉽다는 단점을 가진다. 이런 문제점을 해결하기 위하여 XCS에서는 기존의 strength를 대신하여 예측값과 오차값, 적합도를 이용하였으며 유전자 알고리즘을 개체군이 아닌 Action Set에서 수행하였다. 그 외에도 개체군의 크기가 고정되지 않고 필요에 따라 물이 추가되고 삭제됨에 따라 적절한 개체군의 크기가 유지되도록 구성되어 있다[4-5].

자율 분산 로봇시스템이 환경에 따라 적절한 학습행동이 가능하도록 인공지능 네트워크에 의한 행동과 XCS에 의한 학습을 전역행동과 지역행동으로 분류한다. 면역 네트워크 방정식을 이용한 전역행동에서는 로봇들이 빠른 속도로 작업을 탐색하고 작업을 처리가 가능한 환경을 조성하도록 로봇의 행동을 선택한다. 다음으로 분류자 시스템을 이용한 지역행동에서는 작업을 인식하고 인식된 종류에 따라 로봇의 역할을 결정한다. 이때 로봇의 역할에 따른 효율을 학습함으로써 점차 효율이 좋은 역할을 수행하도록 한다. 이러한 작업을 통하여 알려지지 않은 작업이 인식되었다 하여도 수행할 수 있는 역할 중에서 최대한의 작업 효율을 얻을 수 있는 역할을 수행하기 때문에 보다 좋은 결과를 이끌어 낼 수 있도록 한다.

2. 인공면역 네트워크

2.1 면역 네트워크

면역 네트워크가 어떻게 동작하는지는 아직 정확히 밝혀져 있지 않다. 하지만 그에 관하여 제안된 몇 가지의 가설들이 존재한다. 본 논문에서는 면역학자인 Jerne가 제안한 면역 네트워크 가설[2]에 보조 및 억제 T세포의 모델이 추가된 면역 네트워크 방정식을 사용하였다. Jerne에 의해 최초 제안된 면역계의 모델은 사실이 아님이 입증되었지만 결과만으로 보았을 때 면역계의 동작을 나타내고 있다는 점만으로도 충분한 가치가 있는 것으로 평가되고 있다. 다음 식은 본 논문에서 자율분산로봇시스템에 적용한 면역 네트워크 방정식이다[2,8].

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

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

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

단 $i=0, \dots, N-1$; N 은 항체 종류의 수, $S_i(t)$ 는 항체 i 의 자극값, $s_i(t)$ 는 항체 i 의 농도, $s_j(t)$ 는 항체 j 의 농도, $c_i(t)$ 는 항체 i 의 농도를 조절하는 보조 및 억제 T세포의 농도, m_{ij} 는 항체 i 와 j 의 상호 자극 계수, $g_i(t)$ 는 항체 i 에 대한 항원의 자극값, α, β, η 는 상수이다. 식 (3)에서 T세포의 농도 $c_i(t)$ 는 항원의 자극값($g_i(t)$)이 크고 항체의 자극값($S_i(t)$)이 작은 경우 값이 작아지기 때문에 결국 식 (1)에서 보조 T세포의 역할을 하고 반대로 항원의 자극값이 작고 항체의 자극값이 클 경우 값이 커져서 억제 T세포의 역할을 한다. 이때 보조 T세포는 B세포를 자극하고, 억제 T세포는 B세포를 억제한다[2,8].

표 1. 항체간의 상호 자극 계수
Table 1. Mutual stimulus coefficients

m_{ij}	집합	분산
집합	1	-0.1
분산	-0.1	1

2.2 면역 시스템의 동작

본 논문에서는 면역 네트워크 방정식을 이용하여 각 로봇의 전역행동을 결정하였다. 각 로봇의 전역행동은 수행할 작업을 탐색하고, 탐색한 작업을 수행하기 위하여 필요한 다른 로봇들을 모으는 과정이다. 따라서 이에 필요한 행동을 집합과 분산의 두 가지로 나타내었다. 각 로봇들은 자신의 주변 환경을 탐색하여 상황을 판단하고 어떤 전역행동을 할지를 결정한다. 우선 주변에 수행할 작업이 없는 경우 각 로봇들이 서로 근접한 거리에 있다는 것은 전체적인 탐색공간을 줄이게 된다. 따라서 작업의 양에 비해 너무 많은 로봇들이 집합해있는 경우 분산됨으로써 전체적인 탐색 공간을 넓혀 다른 작업을 찾기 쉽게 한다. 또한 작업을 발견한 경우 작업에 필요한 로봇들이 모여야 작업을 수행할 수 있다. 탐색된 작업 주변으로 로봇들이 모임으로써 작업을 수행할 수 있는 조건을 만족시킬 수 있도록 하였다. 이 과정에서 작업의 존재와 로봇의 수에 따라 어떤 전역행동을 할 것인가를 판단하는 것이 중요한 문제이다. 따라서 주변에서 탐색된 작업과 로봇을 항원으로 하고, 선택할 전역행동들을 항체로 하여 면역 네트워크 방정식을 적용하였다.

면역 네트워크 방정식을 적용하기 위해서 항원이 어떤 자극값을 가지는지를 설정해야 한다. 항원의 자극값은 앞에서 언급한 것과 같이 작업과 로봇으로 설정된다. 그림 2는 이 항원의 설정을 나타내고 있다. 우선 그림 2(a)에서 나타내는 집합을 자극하는 항원은 감지범위 내에서 작업이 얼마나 오랫동안 감지되었는가를 이용하여 설정하였다. 과거 10회 동안 탐지범위 내에서 작업에 감지된 회수를 계산하고 10회 모두 감지되었을 경우는 1을 한번도 감지되지 않은 경우는 0을 자극값으로 가진다. 그리고 그 사이의 값들은 선형으로 설정하였다. 이는 감지범위 내에서 작업이 지속적으로 감지되는 경우 작업이 제대로 수행되지 않는 것으로 판단하고 작업을 수행하기 위해 필요한 다른 로봇들을 집합하여 작업이 수행되게 하기 위함이다. 이 경우 작업을 수행하고 있는 로봇은 수행중인 작업에 의하여 지속적으로 자극을 받기는 하지만 시간이 경과함에 따라 수행중인 작업이 없어지기 때문에 무시하였다. 그림 2(b)에서 나타내고 있는 분산을 자극하는 항

원의 설정은 감지범위 내에 얼마나 많은 로봇이 있는가를 이용하여 설정하였다. 감지범위 내에 존재하는 로봇의 대수가 4대 이상일 경우 자극값을 1로 하고, 감지된 로봇이 없는 경우를 0으로 하였다. 그 사이의 값들은 역시 선형으로 설정하였다. 4대의 로봇이 감지된 상황을 기준으로 항원의 자극값이 최대를 가짐으로써 로봇이 5대 이상 모여 있을 경우 로봇이 하나의 작업을 수행하기 위하여 필요한 로봇의 수보다 많은 로봇이 모여 있는 경우로 판단을 하여 분산행동을 취하게 설정하였다. 항체간의 자극 계수는 표 I 과 같이 설정을 하였다. 같은 항체는 서로 자극을 해주고 다른 항체간에서 약간의 억제작용을 하도록 설정을 하였다. 그 외에 α 는 0.001, β 는 0.8, η 는 0.05, k_i 는 0.1로 설정을 하였다. 파라미터 값은 실험을 통하여 선정하였다.




그림 1. (a) 집합과 (b) 분산을 담당하는 항체를 자극하는 항원의 자극값 설정 함수

Fig. 2. The stimulus function of antigen that stimulates antibodies, which are related to (a) aggregation and (b)dispersion.

3. 분류자 시스템

3.1 분류자 시스템의 개요

분류자 시스템은 유전자 알고리즘에 기반한 기계학습 (Genetic Based Machine Learning, GBML)의 한 종류로서 적응형 시스템이다. 'Holland'에 의해 제안된 이 시스템은 규칙 기반의 학습 시스템으로서 분류자라 표현되는 규칙들은 조건부와 실행부, 강화값(condition, action, and strength)으로 구성되어 있다. 조건부는 {0, 1, #}로 구성되며 실행부는 {0, 1}로 구성되며 강화값은 분류자가 얼마나 강화되어 유용한 규칙인지를 나타낸다. 학습을 크게 세 부분으로 분류할 수 있는데 실행 시스템, 학습 시스템, 탐색 시스템(the performance system, the learning system, and rule discovery system)이 바로 그것이다. 실행 시스템은 검지기에서 외부 입력을 이진 스트링으로 변환한 뒤 검지기로부터의 메시지를 이용하여 규칙 베이스에서 사용할 분류자를 선택하고, 선택한 규칙을 효과기에서 환경에 적용시킬 수 있게 변환한다. 이런 주기를 반복하면서 학습을 수행한다. 만약 규칙 베이스에서 환경으로부터의 입력을 만족시키는 분류자가 없는 경우 환경의 입력값을 적당량 선택하여 '#로 대체하고 행동부는 임의로 지정하여 규칙 베이스에 삽입함으로써 만족하는 규칙을 유지한다. 이때 다른 분류자를 삭제하여 전체 크기를 일정하게 유지한다. 학습 시스템은 'bucket brigade algorithm'을 이용하여 환경으로부터 얻는 보상을 분배한다. 이때 강화값은 보상값에 기반하여 갱신된다. 따라서 분류자가 가지는 강화값은 그 규칙을 선택했을 때 얻을 수 있는 보상값에 대한 예측값이라 할 수 있다. 규칙 탐색 시스템은 유

전자 알고리즘을 기반으로 구성되어 있다. 유전자 알고리즘을 적용하기 위하여 분류자의 적합도를 결정하고, 그 적합도에 의하여 알고리즘을 적용함으로써 새로운 규칙을 탐색한다. 최초 제안된 분류자 시스템에서 적합도는 강화값을 그대로 이용하였다. 강화값을 이용하여 부모세대를 선택하고 유전자 알고리즘을 이용하여 자식세대를 생성하여 규칙 조합 (Rule Set)에 추가한다. 이때도 추가되는 만큼 삭제를 하여 크기를 유지한다. 모든 삭제는 강화값에 근거하여 이루어진다[3].

3.2 XCS 시스템

XCS는 Wilson에 의해 제안된 분류자 시스템의 한 형태이다. 기존의 분류자 시스템은 새로운 룰을 탐색할 때에 전체 개체군에서 강화값을 적합도처럼 이용하여 선택과 삭제를 하기 때문에 낮은 강화값을 갖지만 유용한 규칙의 경우 파괴되기 쉽다는 단점을 가진다. 이런 문제점을 해결하기 위하여 XCS에서는 기존의 강화값을 대신하여 예측값과 오차값, 적합도를 이용하였으며 유전자 알고리즘을 개체군이 아닌 Action Set에서 수행하였다[4,5]. 그 외에도 개체군의 크기가 고정되지 않고 필요에 따라 룰이 추가되고 삭제됨에 따라 적절한 개체군의 크기가 유지된다.

그림 2는 XCS의 개략적인 진행 순서를 나타내고 있다. 최초에 시스템은 환경으로부터 입력과 보상값을 받는데 입력은 시스템 내에서 사용하는 형식으로 변환을 한다. 이를 개체군과 비교를 하여 Match Set을 구성한다. 구성된 Match Set에서 룰들의 행동에 대한 이용하여 Prediction Array를 구성한다. Prediction Array에서 확률적 선택 또는 최대 선택을 이용하여 하나의 행동을 선택하고 그 행동을 출력행동으로 선택한다.

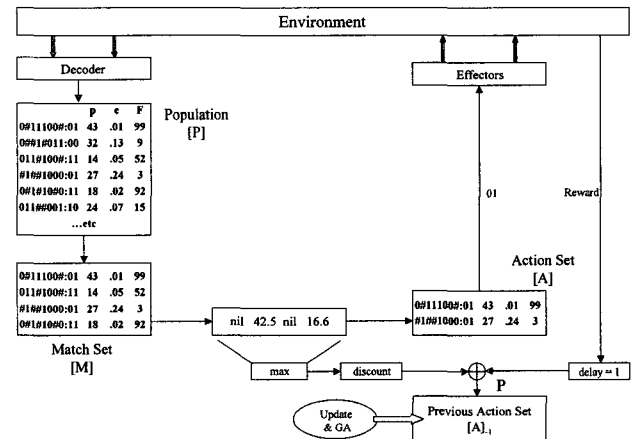


그림 2. XCS의 학습 메커니즘
Fig. 2. Learning mechanism of XCS.

Match Set에서 행동이 출력행동과 일치하는 룰들을 이용하여 Action Set을 구성한다. 출력행동은 환경에 영향을 미치게 된다. 환경에서 받은 보상값과 Prediction Array의 최대값을 이용하여 이전에 사용된 Action Set의 예측값(\hat{p})과 오차값(ϵ), 적합도(F)를 갱신한다. 마지막으로 이전의 Action Set내에서 유전자 알고리즘을 적용하여 새로운 규칙을 생성하고, 적합도가 낮은 룰들을 삭제한다. 파라미터 갱신식을 살펴보면

$$p \leftarrow p + \beta(P - p) \tag{4}$$

$$\epsilon \leftarrow \epsilon + \beta(|P - p| - \epsilon) \tag{5}$$

$$k = \exp[(\ln \alpha)(\epsilon - \epsilon_0) / \epsilon_0] \tag{6}$$

$$F \leftarrow F + \beta(k' - F) \tag{7}$$

으로 나타난다. 여기에서 β 는 학습 계수로서 0~1 사이의 실수값을 가진다. k 는 분류자의 예측값에 대한 정확도를 나타내며 이때 ϵ_0 는 허용오차로서 $\epsilon < \epsilon_0$ 일 경우 오차가 없다고 간주한다. α 는 ϵ 가 ϵ_0 보다 클 때 정확도의 감소율을 결정하는 계수로서 0~1 사이의 값을 가진다[4,5]. 이렇게 파라미터가 갱신되는 개념은 기존의 분류자가 사용하는 'bucket brigade algorithm'보다는 'Q-Learning'의 학습 개념과 유사하다.

개체군(Population)의 경우 기존의 알고리즘에서는 분류자들이 일치하는 경우 추가하지 않도록 하여 개체군의 크기와 같은 수의 분류자를 유지하였다. 하지만 XCS에서는 중복이 가능하게 하고 중복이 가능한 분류자를 거시분류자(macroclassifier)라 정의하였다[4,5]. 각 거시분류자는 개수(numerosity)를 표시하여 중복된 분류자가 몇 개인지를 나타내고, 실제 표현할 때는 하나로 나타내었다. 분류자가 추가될 때 같은 규칙을 갖는 분류자가 있는 경우 개수를 1 추가하고 없는 경우 거시 분류자를 개체군에 새롭게 추가하면서 개수는 1로 정의된다. 이런 개념을 사용함으로써 개체군 내의 분류자의 수는 일정하나 거시분류자의 수는 그보다 작게 표현된다. 학습이 진행되어 분류자들의 정확도가 증가함에 따라 전체 거시분류자의 수는 감소한다. 따라서 이 수는 전체 탐색공간의 복잡도를 표현하는 것으로 볼 수 있다.

시스템은 개체군 내의 분류자들을 최대한 일반화함으로써 거시분류자의 수를 줄인다. 만약 분류자가 조금 더 자세하게 규칙을 표현한다면 보다 정확한 예측이 가능할 것이다. 그렇기 때문에 분류자를 일반화하기 위해서는 정확도가 감소되지 않는다는 전제조건이 따른다. 이를 만족하기 위하여 최초 일정 이상의 정확도를 가지는 분류자를 선택하여 복사한다. 선택된 분류자의 조건부중 '0'이나 '1'을 선택하여 '#'로 대체하여 개체군에 삽입된다. 새롭게 생성된 분류자의 경우 기존의 분류자보다 더욱 많이 일반화 되어있기 때문에 선택될 확률이 높아지게 된다[4,5]. 따라서 일반화로 인하여 잘못된 적용이 있는 분류자의 경우 정확도가 낮아지게 되고 시간이 지남에 따라 삭제될 확률이 높아진다. 반대로 일반화되었음에도 모든 적용에 정확한 예측을 한다면 높은 확률로 인하여 적합도가 기존의 분류자보다 높아지게 된다. 따라서 기존의 적합도가 삭제될 확률이 높아진다.

3.3 XCS의 적용

XCS은 시스템에서 지역 행동을 결정한다. 지역행동은 로봇이 작업을 수행하는데 있어서 어떠한 역할을 담당하는지를 나타낸다. 작업의 종류는 최대 4가지로 하고 로봇이 수행할 수 있는 역할의 종류를 4종류로 제한하였다. 하나의 작업을 수행하기 위하여 4대의 로봇이 동시에 작업을 수행한다. 작업을 발견한 순서대로 로봇을 배치하였으며, 각 로봇은 자신의 순서를 인식할 수 있다. 규칙은 이진코드로 나타내었으며 조건부 4비트와 행동부 2비트를 배치하였다. 조건부의 최초 2비트는 작업의 종류를 후반부 2비트는 수행하여야 할 작업의 순서를 나타내었고 행동부는 2비트로서 로봇이 수행할 작업의 역할을 나타내었다. XCS에서 파라미터의 설정은 'Wilson'이

논문에서 제안한 파라미터를 기본으로 사용하고 필요에 따라 몇몇 파라미터만 약간의 변화를 주었다. 개체군의 크기는 100으로 하였고, '#'의 생성 확률은 0.1로 설정하였다.

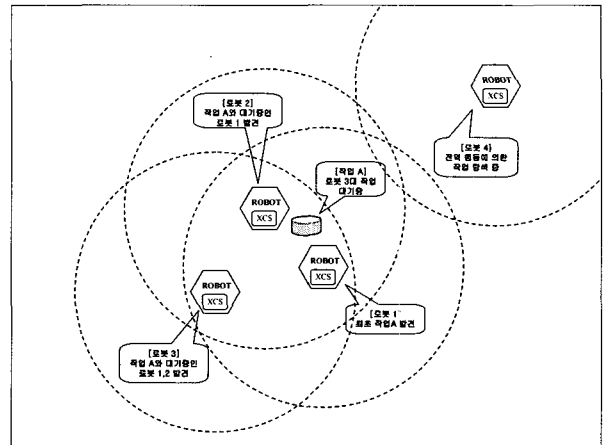


그림 3. 모의실험 환경

Fig. 3. Environment of simulation

4. 모의실험

4.1 환경 설정

실험의 목표는 로봇들이 환경에서 작업을 감지하고 감지한 작업을 처리하는 것을 목표로 한다. 작업을 처리하기 위해서는 4대의 로봇이 동시에 작업을 수행하여야 한다. 또한 최적의 작업 수행 성능을 얻기 위해서 필요한 로봇의 역할이 존재한다. 각 로봇은 작업을 수행하는데 있어서 4가지 역할 중 하나의 역할을 선택하여 작업을 수행한다. 모의실험은 3가지 방법으로 이루어 졌다. 작업은 20개를 일정한 공간에 랜덤하게 배치하였다. 각 작업의 크기는 10으로 하고 한번에 최대 처리할 수 있는 작업의 크기를 1로 하였다. 작업이 모두 처리된 경우 작업의 위치를 랜덤하게 재배치하고 작업의 양을 10으로 초기화함으로써 전체 작업의 수를 일정하게 유지하였다. 로봇은 작업의 종류와 자신의 수행 위치에 따라 작업을 수행을 위한 역할을 결정한다. 이때 작업 수행에 필요한 로봇의 역할과 로봇이 수행하는 역할에 따른 성능은 표 2과 같이 설정하였다. 로봇이 선택한 규칙에 대한 평가는 작업을 수행하는 성능에 따라 평가하였다. 첫 번째 실험에서는 2가지 작업을 각 10개씩 배치하여 평가하였고, 두 번째 실험에서는 일정한 시간을 주기로 재배치되는 작업의 종류를 바꾸어 주었다. 마지막 실험에서는 작업의 수를 4개로 확장하여 실험하였다.

표 2. 로봇의 필요역할과 실행역할에 따른 효율
Table 2. Efficiency between necessary role and action role of a robot.

	R0	R1	R2	R3
R0	1	0.5	0	0.5
R1	0.5	1	0.5	0
R2	0	0.5	1	0.5
R3	0.5	0	0.5	1

4.2 실험 결과

설정된 환경에서 모의실험을 하여 로봇들이 작업을 수행하는데 걸리는 시간을 측정하였다. 작업을 수행할 때 최대의 처리 속도를 1이라 하고 일정시간 처리된 작업의 양과 처리한 회수를 이용하여 모의실험 환경에서 평균 작업 속도를 그림 4-6에 나타내었다. 그림 4-6에서 가로축은 시간의 경과를 나타내고 있고, 세로축은 모의실험에서 평균 작업 효율을 나타내고 있다. 그림 4는 첫 번째 실험의 결과를 나타내고 있다. 이 그림을 보면 로봇이 작업을 처리하는 속도가 최초 0.5 정도에서 0.8 정도로 증가하여 진동하는 것을 볼 수 있다. 이는 XCS의 학습에 의하여 전체적인 처리 성능이 향상된 것으로 볼 수 있으며 지속적인 진동이 발생하는 이유는 새로운 룰의 탐색으로 발생하는 것이다. 그림 5는 두 번째 모의실험의 결과를 나타내고 있다. 시간축의 1000단위마다 작업의 종류를 바꾸어 주었다. 이때 바뀌는 작업의 종류는 2000단위를 주기로 반복된다. 처음 작업을 처리하기 시작할 때와 1000단위에서 작업이 바뀔 때 처리 속도가 떨어졌다가 다시 올라가는 것을 볼 수 있다. 하지만 2000단위와 3000단위에서는 속도가 떨어지는 것을 확인할 수 없는데 그 이유는 이미 학습한 분류자를 가지고 있기 때문이다. 평균작업속도가 떨어졌다가 다시 상승하는 것을 볼 수 있다. 이것은 환경에서 감지되는 작업의 종류가 변화할 경우 평균작업 속도가 떨어졌다가 학습을 통하여 다시 상승하는 것을 보여준다. 그림 6은 마지막 모의실험의 결과 그래프이다. 그림과 유사한 결과를 보여주고 있다. 하지만 전체적으로 수렴한 값이 약간 낮고 수렴하는 속도가 느린 것을 알 수 있다. 이는 XCS가 규칙을 구성하는데 있어서 첫 번째 모의실험의 경우 두 가지 작업에 관련된 규칙들로 규칙 베이스를 구성하지만 세 번째의 경우 네 가지 작업으로 수가 늘어난다. 따라서 규칙을 선택할 경우 다른 규칙을 선택할 확률이 높아지기 때문에 전체적인 시스템의 성능에 약간의 영향이 있는 것으로 보인다.

그 외에 전체적으로 평균 작업 속도가 1까지 도달하지 못하는 이유는 룰의 평가가 하나의 룰에 대하여 이루어지는 것이 아니라 서로 협조한 결과에 의하여 이루어지기 때문에 상호간의 간섭으로 인한 문제와 학습을 위한 확률적 행동 선택으로 인하여 발생하는 다른 행동의 간섭으로 인하여 발생한다.




그림 4. 두 가지 작업에서의 평균 작업 속도
Fig. 4. Average speed of operation in two tasks.




그림 5. 환경에서 주어지는 두 가지 작업의 종류가 주기적으로 변화할 때의 평균 작업 속도
Fig. 5. Average speed of operation in periodic change of type of two tasks.




그림 6. 네 가지 작업에서의 평균 작업 속도
Fig. 6. Average speed of operation in four tasks.

5. 결 론

이 논문에서는 자율 분산 로봇 시스템에서 각 로봇들의 협조행동을 학습하는 방법을 제안하고, 모의실험을 통하여 그 성능을 평가하여 보았다. 제안된 학습 방법의 분산 유전자 알고리즘을 이용하여 작업을 수행하기 위하여 어떤 로봇들을 협조하여야 하는가에 관한 협조행동의 문제를 해결하고, 주어진 문제가 변화했을 경우 변화에 대한 적응성도 평가하여 보았다. 또한 로봇이 가지고 있는 유전자의 수를 증가시키므로써 다양한 문제가 존재하는 경우에 대해서도 충분히 적용할 수 있음을 보였다. 이러한 구조는 변화하는 환경이나 작업에 대하여 지속적인 제어가 불가능 할 때 매우 유용하게 사용될 수 있다. 뿐만 아니라 자율 분산 로봇 시스템이 제어의 유연성과 강건함을 위하여 제안된 시스템이라는 관점에서 학습의 개념이 추가된 자율 분산 로봇 시스템은 일반적인 자율 분산 로봇 시스템보다 환경의 변화에 유연하고 강한 시스템으로써 진보된 형태라 할 수 있다.

참 고 문 헌

[1] H. Asama, "Trends of *Distributed Autonomous Robotic Systems*," *Distributed Autonomous Robotic Systems*, vol. 1, pp. 3-8, 1994.

[2] N. K. Jerne, "Idiotopic Network and Other Preconceived Idias," *Immunological Rev.*, vol. 79, pp. 5-24, 1984.

[3] S. W. Wilson, "ZCS: A Zeroth Level Classifier System," *Evolutionary Computation*, Vol. 2, No. 1, pp. 1-18, 1994

[4] S. W. Wilson, "Classifier Fitness Based on Accuracy," *Evolutionary Computation*, Vol. 3, No. 2, 1995

[5] M. V. Butz, S. W. Wilson, "An Algorithmic Description of XCS," *Lecture Notes in Computer Science*, Vol. 1996, pp. 253-270, 2001

[6] D.W. Lee, K.B. Sim, "Behavior Learning and Evolution of Collective Autonomous Mobile Robots using Distributed Genetic Algorithms," *2nd Asian Control conference*, vol. 2, pp. 675-678, 1997. 7.

[7] 이동욱, 심귀보, "강화학습과 분산유전자알고리즘을 이용한 자율이동로봇군의 행동학습 및 진화," *대한전자공학회 논문집*, 제34권, S편, 제8호, pp. 56-64, 1997. 8.

[8] 이동욱, 심귀보, "인공 면역 시스템 기반 자율분산로봇 시스템의 협조 전략과 군행동," *한국퍼지 및 지능시스템학회 논문지*, 제9권, 제6호, pp.627-633, 1999. 12

저 자 소 개



심귀보(Kwee-Bo Sim)

1984년 : 중앙대학교 전자공학과 공학사
 1986년 : 동대학원 전자공학과 공학석사
 1990년 : The University of Tokyo 전자공학과 공학박사
 1991년 ~ 현재 : 중앙대학교 전자전기공학부 교수
 2000년 ~ 현재 : 제어자동화시스템공학회 이사 및 지능시스템연구회 회장
 2002년 ~ 현재 : 중앙대학교 산학연컨소시엄센터 센터장 및 기술이전센터 소장
 2003년 ~ 현재 : 일본계측자동제어학회(SICE) 이사
 2003년 ~ 현재 : 한국퍼지 및 지능시스템학회 부회장

관심분야 : 인공생명, 지능로봇, 지능시스템, 다개체시스템, 학습 및 적응알고리즘, 소프트 컴퓨팅(신경망, 퍼지, 진화연산), 인공면역시스템, 침입탐지시스템, 진화하드웨어, 인공두뇌, 지능형 홈 및 홈네트워킹, 유비쿼터스 컴퓨팅 등

Phone : +82-2-820-5319
 Fax : +82-2-817-0553
 E-mail : kbsim@cau.ac.kr
 Homepage URL : <http://alife.cau.ac.kr>



황철민 (Chul-Min Hwang)

2003년 : 중앙대학교 전자전기공학부 공학사
 2003년 ~ 현재 : 동대학원 전자전기공학부 석사과정

관심분야 : 자율분산로봇 시스템, 기계학습, 분류자 시스템

Phone : +82-2-820-5319
 E-mail : saramsa2@wm.cau.ac.kr