

집단간 긍정적·부정적 상호작용을 이용한 다중 집단 개미 모델

이승관[†]·정태충^{††}

요약

개미 집단 최적화는 최근에 제안된 조합 최적화 문제를 해결하기 위한 메타 헤리스틱 탐색 방법으로, 그리디 탐색뿐만 아니라 긍정적 반응의 탐색을 사용한 모집단에 근거한 접근법으로 순회 판매원 문제를 풀기 위해 처음으로 제안되었다. 본 논문에서는 기존의 개미 집단 시스템의 성능을 향상시키기 위해 강화와 다양화를 통한 집단간 긍정적 상호작용과 부정적 상호작용을 수행하는 다중 집단 개미 모델을 제안한다. 이 알고리즘은 TSP 문제를 해결하기 위해 몇 개의 에이전트 집단으로 이루어진 ACS 집단간의 상호작용을 통해 문제를 해결하는 방법이다. 본 논문에서는 이 제안된 방법을 TSP 문제에 적용해 보고 그 성능에 대해 기존의 ACS 방법과 비교 평가해, 문제 해결의 질적 수준이 우수하다는 것을 실험을 통해 알아보자 한다.

Multi Colony Ant Model using Positive · Negative Interaction between Colonies

SeungGwan Lee[†]·TaeChoong Chung^{††}

ABSTRACT

Ant Colony Optimization (ACO) is new meta heuristics method to solve hard combinatorial optimization problem. It is a population based approach that uses exploitation of positive feedback as well as greedy search. It was firstly proposed for tackling the well known Traveling Salesman Problem (TSP). In this paper, we introduce Multi Colony Ant Model that achieve positive interaction and negative interaction through Intensification and Diversification to improve original ACS performance. This algorithm is a method to solve problem through interaction between ACS groups that consist of some agent colonies to solve TSP problem. In this paper, we apply this proposed method to TSP problem and evaluates previous method and comparison for the performance. and we wish to certify that qualitative level of problem solution is excellent.

키워드 : 개미집단최적화(Ant Colony Optimization : ACO), 개미시스템(Ant System : AS), 개미집단시스템(Ant Colony System : ACS), 강화(Intensification), 다양화(Diversification), 메타 헤리스틱(Meta Heuristics)

1. 서론

조합최적화 문제인 순회 외판원 문제(Traveling Salesman Problems), 일정 계획 문제(Job-shop scheduling), 이차배정문제(Quadratic assignment problem), 차량 경로 문제(vehicle routing problem), 그래프 칠색 문제(graph coloring problem) 등에서 전통적으로 최적의 해를 구하기 위해 사용되는 널리 알려진 메타 헤리스틱(Meta Heuristics)방법으로 유전자 알고리즘(Genetic Algorithm, GA)[3], 타부서치(Tabu Search, TA), 시뮬레이티드 어닐링(Simulated Annealing, SA), Lin-Kernighan(LK) Algorithm[10]등이 있다.

본 논문에서는 TSP문제를 풀기 위해 Colomi, Dorigo 그리고 Maniezzo[1, 2]에 의해 제안된 지역 갱신과 전역 갱신

과정을 거쳐 최적해를 구하는 메타 헤리스틱 방법인 개미집단 시스템(Ant Colony System, ACS)[4, 7, 8]에 대해 소개를 하고, 특히 본 논문에서는 ACS의 성능을 개선하기 위해 기존의 ACS를 확장한 강화(Intensification)와 다양화(Diversification)를 통해 집단간 긍정적 상호작용과 부정적 상호작용을 수행하는 다중 집단 개미 모델(Multi Colony Ant Model)을 제안한다. 이것은 TSP 문제를 해결하기 위해 몇 개의 에이전트 집단으로 이루어진 ACS 집단간의 특별한 상호작용을 통해 문제를 해결하는 방법으로, 집단간 상호작용, 즉 긍정적 상호작용과 부정적 상호작용으로 나누는 제안된 방법을 이용해 탐색영역이 큰 문제에 대해서도 쉽게 접근할 수 있음을 여러 조건 하에서 TSP 문제에 적용해 보고 그 성능에 대해 기존의 ACS 방법과 제안된 방법을 비교 평가해, 해의 질과 문제를 해결하는 속도가 우수하다는 것을 비교 분석해 본다.

† 준희원 : 경희대학교 대학원 전자계산공학과

†† 정희원 : 경희대학교 컴퓨터공학과 교수

논문접수 : 2003년 8월 8일, 심사완료 : 2003년 11월 19일

2. 개미 집단 최적화

2.1 개미 시스템

개미 시스템(Ant System, AS)은 실제 개미들이 먹이에서 집까지 가장 짧은 경로를 찾는 능력을 모방한 메타 휴리스틱 탐색[1, 2, 5, 8]으로 최근에는 강화학습(Reinforcement Learning)의 특별한 한 분야로 소개되고 있다[6].

에이전트라 불리는 개미들이 목적지를 향해 나아가는 동안 각 경로에 페로몬을 분비하고, 이후에 지나가는 에이전트들은 그 경로에 쌓여있는 페로몬 정보를 이용해 다음 경로를 선택하는 원리를 휴리스틱 탐색에 적용시킨 방법이 AS이다[4, 5, 7, 8]. 그러나, 이 AS는 에이전트들이 짧은 경로가 있으면 그것만을 선택하고자 하는 성질로 인하여 국부 최적(Local Minima)에 빠질 확률이 높아지기 때문에, 이 문제를 쉽게 해결하기 위해 확률분포를 이용해서 다음 노드를 선택하는 과정을 추가한 ACS 알고리즘이라는 방법이 새롭게 연구되었다.

2.2 개미 집단 시스템

개미 집단 시스템(Ant Colony System, ACS)은 AS의 성능을 향상시키기 위해 Dorigo and Gambardella[4, 5, 9]에 의해 소개되었다.

일반적으로 ACS는 다음과 같은 방법으로 수행을 한다. 먼저 m개의 에이전트들이 초기화 규칙(initialization rule)에 따라 무작위로 n개의 노드(node)를 선택한 다음, 각 에이전트들은 상태전이 규칙(state transition rule)에 따라 다음에 방문할 노드를 선택하고 계속해서 탐색과정을 거친다. 이러한 탐색과정을 거치는 동안 에이전트들은 지역 갱신 규칙(Local Updating Rule)에 따라 방문한 각 간선에 페로몬 양을 변경하게 된다. 그리고 일단 모든 에이전트들이 탐색과정을 마치게 되면 전역 갱신 규칙(Global Updating Rule)에 따라 다시 한번 페로몬 양을 변경하게 된다[5]. 결국, AS처럼 각 에이전트들은 짧은 간선을 선택하려는 휴리스틱 정보와 많은 양의 페로몬을 가진 간선을 선택하려는 페로몬 정보에 따라 탐색경로를 완성하게 된다.

다음은 ACS 알고리즘의 상태 전이 규칙(State Transition Rule), 지역 갱신 규칙(Local Updating Rule), 전역 갱신 규칙(Global Updating Rule)에 대해 살펴보고자 한다.

2.2.1 상태전이 규칙

노드(r)에 있는 에이전트 k가 노드(s)로 이동하기 위해 식(1)을 이용한다. 여기서 $\tau(r, u)$ 는 노드(r)과 노드(u)사이 간선의 페로몬의 양, $\eta = 1/\delta$ 은 $\delta(r, u)$ (노드 r과 u의 거리)의 역수이고, $J_k(r)$ 은 노드(r)에 있는 에이전트 k가 방문할 수 있는 남아있는 노드들의 집합이다. 그리고 β 는 페로몬과 간선 길이의 상대적인 중요도를 결정하는 파라미터이다 ($\beta > 0$).

$$s = \begin{cases} \arg \max_{u \in J_k(r)} \{ [\tau(r, u)] \cdot [\eta(r, u)]^\beta \} & \text{if } q \leq q_0 (\text{exploitation}) \\ S & \text{otherwise (biased exploration)} \end{cases} \quad (1)$$

q 는 [0, 1]사이에 분포된 무작위 파라미터(random parameter)이고, q_0 는 [0, 1]사이의 값을 가지는 인자, S는 식(2)에서 주어진 확률분포(Probability distribution)에 따라 선택된 무작위 파라미터이다. 이것은 무조건 페로몬과 간선 길이의 연산만으로 다음 노드를 선택하는 전통적인 AS와는 달리, 확률분포를 이용해서 다음 노드를 선택하는 과정이 추가됨으로 인해 AS가 가지고 있는 국부 최적에 빠지기 쉬운 한계에서 어느 정도 벗어나고자 하고 있다.

$$\rho_k(r, s) = \begin{cases} \frac{[\tau(r, s)] \cdot [\eta(r, s)]^\beta}{\sum_{u \in J_k(r)} [\tau(r, u)] \cdot [\eta(r, u)]^\beta} & \text{if } s \in J_k(r) \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

2.2.2 지역 갱신 규칙

에이전트들은 TSP 문제를 해결하기 위해 각 간선들을 방문하는 동안 아래의 지역 갱신 규칙을 적용시켜 페로몬의 양을 갱신시킨다.

$$\tau(r, s) \leftarrow (1 - \rho) \cdot \tau(r, s) + \rho \cdot \Delta \tau(r, s) \quad (3)$$

ρ ($0 < \rho < 1$)는 페로몬 자연 파라미터(pheromone decay parameter)이고 $\Delta \tau(r, s) = \tau_0 = (n * L_{nn})^{-1}$ 는 초기 페로몬 양으로, 여기서 L_{nn} 은 nearest neighbor heuristic에 의해 생성된 경로길이, n 은 노드수이다.

2.2.3 전역 갱신 규칙

전역갱신은 에이전트들이 모든 경로 사이클을 완성후에 수행되는데, 가장 짧은 전체 경로를 완성한 에이전트의 경로에 대해 다음 전역 갱신 규칙을 적용한다.

$$\tau(r, s) \leftarrow (1 - \alpha) \cdot \tau(r, s) + \alpha \cdot \Delta \tau(r, s) \quad (4)$$

$$\text{where } \Delta \tau(r, s) = \begin{cases} (L_{gb})^{-1} & \text{if } (r, s) \in \text{global_best_tour} \\ 0 & \text{otherwise} \end{cases}$$

α ($0 < \alpha < 1$)는 페로몬 자연 파라미터, L_{gb} 는 현재까지의 전역 최적 경로 길이이다. $\tau(r, s)$ 는 노드(r)과 노드(s) 사이의 페로몬 양으로, 전역 최적 경로에 속해 있으면 $(1/L_{gb})$, 아니면 0으로 주어지며, 결국 자연 파라미터에 의해 페로몬 양은 줄어들게 된다.

3. 다중 집단 개미 모델

휴리스틱 알고리즘 연구에 있어서 중요한 분야 중 하나가 강화(Intensification)와 다양화(Diversification)의 균형을 맞추는 문제이다. 본 논문에서는 서로 독립적인 탐색과정을 거치는 여러 개의 에이전트 집단을 으로 이루어진 집단간에 긍정적 페로몬 상호작용과 부정적 페로몬 상호작용을 하는 다중 집단 에이전트 구조를 제안하고, 집단간의 강화와 다양화 적용에 따른 성능을 비교한다.

3.1 강화와 다양화의 조화

일반적으로 강화(Intensification) 전략은 역사적으로 발견

된 좋은 해의 장점을 이용하여 움직이게 하고, 다양화(Diversification) 전략은 아직까지 탐색하지 않은 새로운 영역으로 다양하게 찾아가게 하는 것이다.

사실, 강화 그 자체만으로 일반적인 최적화 문제에 가장 좋은 결과를 얻는 데는 불충분하다. 강화에만 의존하는 시스템은 최적해에 도달하는 올바른 움직임을 찾는데 실패한다. 즉 적당한 새로운 지역으로 탐색을 이끄는 충분한 다양화 도입에 실패한다. 현재 문제 해결 방법으로 본능적인 대응은 임의적으로 움직여 운좋게 효과적인 움직임을 찾는 것이다. 그러한 움직임도 가능성이 있다. 그러나 이것은 다양화를 얻기 위한 우연적인 방법이다. 이러한 임의적인 탐색방법은 좋은 움직임을 추구하는데 필요한 계속적인 균형을 잡는 효과를 잃는다. 임의적인 방법은 다양화를 추구하는 목적에는 맞지만, 눈먼 선택을 하는 것으로 나쁜 결과가 도출될 수 있다.

따라서, 다양화 전략은 강화와 상보적인 작용으로 가장 효과적인 탐색을 위하여 함께 사용되어야 한다. 다양화 성질로 해를 전략적으로 추구하는 것은 강화작용에서 약점을 보완하여 내부적으로 강화탐색단계와 반대영역을 가로질러 확장된 다양화 탐색단계 사이에 연속적으로 탐색방법을 추구해 본질적인 균형을 이뤄야 한다.

강화는 수렴 속도를 빠르게 하고 다양화는 좋은 해를 찾도록 하는데 필요한 요소이다. 하지만, 강화를 강조하면 에이전트들은 국부 최적해에 수렴하게 되고, 다양화를 강조하면 부적절한 상태(해의 발견)의 원인이 되기 때문에, 휴리스틱 탐색과정에 있어서 강화와 다양화 사이의 적절한 균형이 필수적이다.

따라서, 본 논문에서 적용되는 ACS 알고리즘의 성능을 향상시키는 중요한 요소 중의 하나로 강화와 다양화 사이의 적절한 균형을 통한 탐색 방법을 적용한다.

ACS에서 상태전이 규칙을 적용하는 것은 탐색의 다양화 보장을 위한 방법이다. 이것은 먼저 발견된 좋은 해를 포함한 지역에 집중적으로 탐색하는 대신에, 더 멀리 검토되지 않은 지역으로 진행을 유도한다. 이것은 새로운 시작점을 만들기 위하여 특수하게 설계된 개선기준을 휴리스틱 탐색 과정에 사용하는 것이다. 이로 인해 임의로 시작점을 찾는 대신에 목적을 갖고 그러한 점을 찾게 된다(확률배정방법에 의하여 제약된 무작위 방법을 사용하는 것). 이 방법은 임의의 시작점들을 연속적으로 만듬으로써 다양성을 찾는 방법인 시뮬레이티드 어렐링(SA) 방법과는 다른 것으로, SA는 과거로부터 배운 학습을 이용하지 않는다. 그리고 유전자 알고리즘(GA)에서는 교차만을 독립적으로 적용한 경우에는 다양한 해가 생성되지 못하여 모집단 내의 개체들이 지역 최적해로 조기 수렴하는 현상을 보완하고자 돌연변이 유전 연산자를 이용해 좋은 해를 탐색하는데 있어서 다양한 해를 생산하게 한다.

3.2 다중 집단 개미 모델 구조

일반적인 ACS 알고리즘은 에이전트 집단간의 상호작용

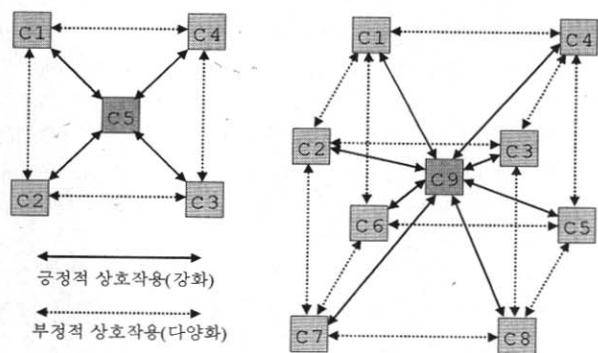
이 없는 하나의 집단에서 여러 개의 에이전트들이 서로 상호작용을 한다. 본 논문에서는 서로 독립적인 탐색과정을 거치는 여러 개의 에이전트 집단을 가진 다중 집단 에이전트를 구조에서 집단간에 공정적 상호작용과 부정적 상호작용을 하는 다중 집단 에이전트 구조를 제안한다.

서로간의 상호 작용하는 다중 집단 에이전트는 몇 개의 독립적 ACS 집단 구조로 이루어져 있다. 이 구조에서 상호 작용은 집단간의 폐로몬 정보를 교환함으로써 이루어 진다. 여기서 긍정적 상호작용은 특정 집단의 에이전트들이 다른 에이전트 집단에 의해 그들의 집단에서 좋은 경로를 결정하는 것을 가능하게 하고, 또한 그러한 정보를 다른 집단에 제공하는 긍정적 상호작용에 의한 강화를 하고, 부정적 상호작용은 에이전트들이 다른 에이전트 집단의 탐색 정보에 의해 표시된 탐색 영역의 사용과 공유를 억제하게 하는 부정적 상호작용에 의한 다양화를 수행한다. 이것은 강화에 의한 집단간 긍정적 상호작용은 다른 집단에 속한 에이전트들로 하여금 특정 간선 선택을 선호하게 하고, 다양화에 의한 부정적 상호작용은 그 특정 간선 선택을 회피하게 만든다.

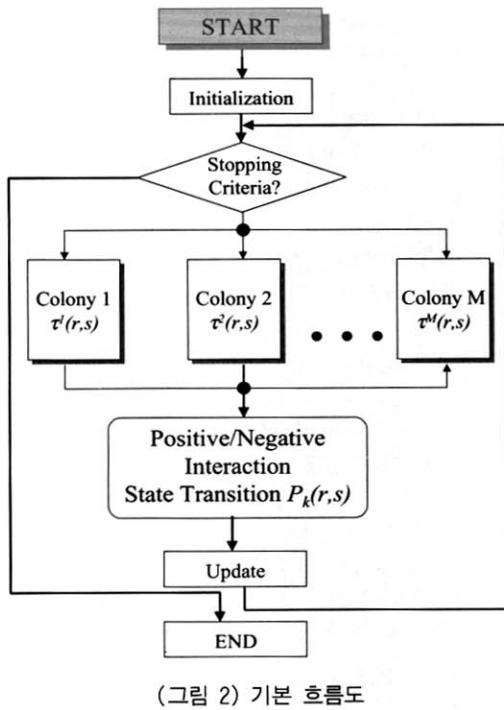
(그림 1)은 다중 집단 개미 모델(Multi Colony Ant Model)에서 집단간 상호작용 연결 구조를 보여주고 있다.

(그림 1)(a)는 Mesh구조를 나타내는 것으로 문제 영역이 작은 경우에 효과적으로 적용 될 수 있으며, (그림 1)(b)는 Cubic구조로 문제 영역이 복잡하고 큰 경우에 효과적으로 적용 될 수 있는 구조이다.

특히, (그림 1)(a)에서 집단(C1, C2), (C2, C3), (C3, C4), (C1, C4) 사이에는 부정적 상호작용에 의한 다양화를, 집단(C1, C5), (C2, C5), (C3, C5), (C4, C5) 사이에는 긍정적 상호작용에 의한 강화를 한다. (그림 1)(b)에서는 집단(C1, C9), (C2, C9), (C3, C9), (C4, C9), (C5, C9), (C6, C9), (C7, C9), (C8, C9) 사이에는 긍정적 상호작용을, 그 외의 집단 사이에서는 부정적 상호작용을 한다. 여기서 (그림 1)(a)에서 C5, (B)에서 C9는 여왕집단(Queen Colony)으로써 중심 에이전트 집단이고 나머지 집단은 일개미 집단으로 나눈다. (그림2)는 다중 개미 집단 시스템의 기본 흐름도로 분기 조건은 고정된 수행 횟수 또는 여러 실험에 의해 최적해로 알려진 값을 찾았을 경우 종료한다.



(그림 1) 디중 진단 게임 모델 구조



3.3 다중 집단간 긍정적·부정적 상호작용

다중 에이전트 구조에서 어떤 집단에 속한 폐로몬은 다른 집단에 다른 의미를 가지고 있다. 긍정적 상호작용은 다른 집단에 속한 에이전트들로 하여금 경로 선택을 선호하게 하고, 부정적 상호작용은 그 경로 선택을 회피하게 만든다. 이 구조는 에이전트들로 하여금 다른 집단에 속한 에이전트들에게 좋은 휴리스틱 정보를 제공하게 되고 서로 탐색 영역을 공유하게 된다.

이미, 앞서 2절에서 ACS에서 노드(r)에 있는 에이전트 k 가 노드(s)로 이동하기 위해서는 식 (1)의 상태전이 규칙(state transition rule)에 의해 수행됨을 보았다. 여기서 q 와 q_0 에 대해 기술하였는데, 이것은 새로운 간선에 대한 다양한 탐험(다양화)과 축적된 정보에 대한 탐색(강화) 사이에서의 균형을 직접적으로 유지하기 위하여 이용됨을 보았다.

에이전트들은 경로를 탐색동안 휴리스틱 정보와 폐로몬 정보를 이용하는데, 만약 $q < q_0$ 인 경우 에이전트는 탐색(exploitation) 행동을 취하며, 그것은 오랜 기간동안 최선의 선택으로 폐로몬 정보와 짧은 기간동안 경험적 지식으로서 거리와 관련된 휴리스틱 값을 사용한다. $q > q_0$ 인 경우에는 에이전트는 다양한 탐험(exploration)을 수행하기 위하여 확률 분포(S)를 사용하여 길이가 더 짧고 많은 양의 폐로몬을 가진 간선 선택을 선호하게 된다.

그러나, 식 (2)를 적용한 일반적인 ACS에서의 상태전이는 좋은 간선을 선택하는 확률만 높게 만들기 때문에 에이전트들은 확률 분포(S) 적용의 기본 목적인 다양한 탐험 수행을 할 수 없게 된다.

따라서, 다양한 탐험 수행을 위해서 확률분포로 방문 빈

도수를 적용할 수 있는데, 이것은 새로운 이웃 간선 선택시 다양한 탐험의 역할을 고려해 각 간선에 다른 에이전트들의 방문 빈도수를 확률값으로 적용해 방문 빈도수가 적을 수록 탐험의 비율을 높이고 탐험의 정확성을 점차로 개선함으로써 강화학습에 효과적으로 적용할 수 있다.

여기서, 새로운 탐색 공간으로의 다양한 탐색을 위해 축적된 폐로몬과 방문 빈도수를 동시에 적용하기 위해 식(2)를 다음에 기술될 식 (6)과 같이 수정할 수 있다.

이러한 집단간 상호작용은 병렬 처리하는 ACS 알고리즘 구현을 가능하게 하고, ACS 알고리즘의 기본 성능을 향상 시킬 수 있다.

계속해서 다중 집단간 상태전이 규칙(state transition rule), 지역갱신 규칙(Local Updating Rule), 전역갱신 규칙(Global Updating Rule)에 대해 살펴보자 한다.

3.3.1 상태전이 규칙

다중 집단 개미 모델에서 집단(I)에 있는 에이전트 k 가 노드(r)에서 노드(s)로 이동하기 위해 식 (5)를 수행하며, 각 집단 간에는 서로 독립적으로 임무를 수행한다. $\tau^l(r,u)$ 는 집단(I)에 있는 간선 $E(r,u)$ 사이의 폐로몬의 양, $\eta^l(r,u)$ 는 집단(I)의 간선 $E(r,u)$ 길이의 역수이다. $J_k^l(r)$ 은 집단(I)에서 노드(r)에 있는 에이전트 k 가 방문할 수 있는 남아있는 노드들의 집합이다. 그리고 $\beta(l)$ 은 집단(I)에서 폐로몬 양과 간선 길이의 상대적인 중요도를 결정하는 파라미터이다.

$$s = \begin{cases} \arg \max_{u \in J_k^l(r)} \{ [\tau^l(r,u)] \cdot [\eta^l(r,u)]^\beta \} & \text{if } q \leq q_0 \text{ (exploitation)} \\ S & \text{otherwise (biased exploration)} \end{cases} \quad (5)$$

q 는 $[0, 1]$ 사이에 정규적으로 분포된 무작위 파라미터, q_0 는 $[0, 1]$ 사이의 값을 가지는 인자, S 는 식 (6)에서 주어진 확률분포에 따라 선택된 무작위 파라미터이다. 여기서, 다양한 탐험의 적용을 위해 집단(I)의 에이전트 k 가 다음 노드를 선택하기 위해 다른 집단의 폐로몬에 영향을 받는데 다음 식 (6)을 적용한다. 이것은 집단(I)의 에이전트 k 가 다음 노드를 선택하는데 다른 집단의 폐로몬 영향에 따라 다양한 상태전이를 하는 것으로, 집단 간의 폐로몬 영향은 긍정적 상호작용과 부정적 상호작용으로 나눈다. 집단간의 상호작용이 긍정적인 경우는 파라미터 δ 에 양의 수(positive value), 부정적인 경우에는 파라미터 δ 에 음의 수(negative value)를 적용 함으로써 긍정적부정적 조화에 의한 다양한 탐색을 가능하게 한다.

(그림 1)의 다중 집단 개미 모델의 구조를 살펴보면, 하부 집단(일개미 집단)간에는 부정적 상호작용, 하부 집단과 상부 집단(중심집단, 여왕개미 집단)사이에는 긍정적 상호작용을 한다. 이것은 하부 집단간에는 다른 집단에서 자주 방문된 간선 선택을 회피하게 함으로써 다양한 탐색을 하게 하고, 그 결과를 상부 집단에 전달해 폐로몬 효과를 강화하는 구조로 되어 있다.

$$P_k^l = \begin{cases} \frac{[\tau^l(r, s)]^{\delta(l, n)} \cdot [\eta(r, s)]^{\beta(l)}}{\sum_{s \in J_k^l(r)} [\tau(r, s)]^{\delta(l, n)} \cdot [\eta(r, s)]^{\beta(l)}} & \text{if } s \in J_k^l(r) \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

where $[\tau^l(r, s)]^{\delta(l, n)} = \left(\sum_{n=1}^M [\tau^n(r, s)]^{\delta(l, n)} \right)^{-1}$

여기서, M은 전체 집단 수이고, $\delta(l, n)$ 은 집단(l)과 집단(n)간의 상호작용 정도를 나타내는 것으로 긍정적 상호 작용인 경우는 집단(l)에 대해 집단(n)에서 해당 간선에 방문한 에이전트의 방문 빈도수의 역수를 지수승으로 적용하며, 부정적 상호 작용인 경우는 해당 간선에 방문한 에이전트의 방문 빈도수의 역수를 음의 지수승으로 적용하며, 식(2)와 비교해 식(6)에서 $\delta(l, n)$ 에 방문 빈도수로 지수승을 적용한 가장 큰 이유는 강화와 다양화의 적절한 균형을 이루기 위해서이다. 식(2)에서는 각 간선의 폐로몬 양과 간선 길이만을 이용해 다음 경로를 선택하기 때문에 에이전트들은 확률적으로 좋은 경로만을 선택하는 경향을 보인다. 식(6)과 같이 폐로몬 양에 음의 지수승으로 간선의 방문 빈도수를 적용함으로써 에이전트들이 더욱 다양하게 탐색 영역을 탐색 할 수 있게 하고, 양의 지수승으로 간선의 방문 빈도수를 적용함으로써 좋은 경로를 선호하게 한다.

따라서 $\tau^l(r, s)$ 는 해당 간선에 대해 각 독립적인 집단간의 상호작용에 의한 폐로몬 영향 정도를 나타내는 변수로 표현할 수 있다.

결국 집단(l)에 속한 에이전트 k는 모든 집단간의 상호작용 정도에 따라, 즉 상태전이 확률에 따라 다음 노드를 선택하고 탐색한다.

3.3.2 지역 개신 규칙

에이전트들은 TSP 문제를 해결하기 위해 각 간선들을 방문하는 동안 아래의 지역개신 규칙을 적용시켜 폐로몬의 양을 개신 시킨다.

$$\tau^l(r, s) \leftarrow (1 - \rho) \cdot \tau^l(r, s) + \rho \tau_0 \quad (7)$$

$\rho(0 < \rho < 1)$ 는 폐로몬 지역 파라미터, $\tau_0 = (n * L_{nn})^{-1}$ 는 초기 폐로몬 양으로, 여기서 L_{nn} 은 nearest neighbor heuristic에 의해 생성된 경로 길이, n은 노드수이다.

3.3.3 전역 개신 규칙

전역개신은 에이전트들이 모든 경로 사이클을 완성 후에 수행되는데, 가장 짧은 전체 경로를 완성한 에이전트의 경로에 대해 다음 전역개신 규칙을 적용한다.

$$\tau^l(r, s) \leftarrow (1 - \alpha) \cdot \tau^l(r, s) + \alpha \cdot \Delta \tau^l(r, s) \quad (8)$$

$$\text{where } \Delta \tau^l(r, s) = \begin{cases} (L_{gb})^{-1}, & \text{if } E(r, s) \in \text{global_best of colony } l \\ 0, & \text{otherwise} \end{cases}$$

$0 < \alpha < 1$ 는 폐로몬 지역 파라미터, L_{gb} 는 집단(l)의 전역 최적 경로 길이이다.

4. 성능측정 및 분석

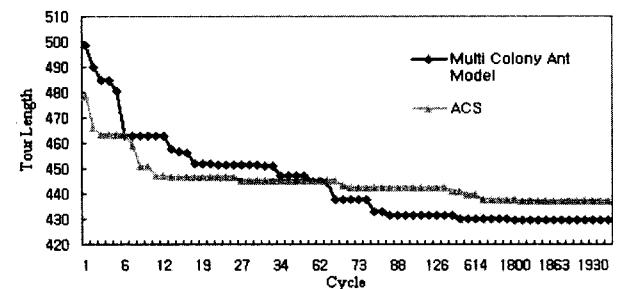
본 논문에서 제안하고 있는 방법을 실험하기 위해서 도

시들의 위치는 TSP 예제로 널리 알려진 TSPLIB[11]에서 추출하여 실험을 하였다. 실험 환경은 PentiumIV 1700MHz, 512MB RAM 환경에서 수행되었다. 사용된 파라미터들의 값은 실험에 의해 결정된 값으로, 기존 ACS의 실험 환경은 $\beta = 2$, $\alpha = \rho = 0.1$, $q_0 = 0.9$, $\delta = 1$ 로 실험 하였다. 그리고, 제안된 모델의 실험 환경은 집단의 수는 노드의 수가 100개를 기준으로 Mesh 구조인 경우 $M = 5$, Cubic 구조인 경우 $M = 9$, $\beta(l)=2$, $\alpha = \rho = 0.1$, $q_0 = 0.9$, $\delta(l, n)$ 은 긍정적 상호작용을 하는 경우 (1/방문 빈도수), 부정적 상호작용을 하는 경우는 (1/방문 빈도수), $\tau_0 = (n * L_{nn})^{-1}$ 이다. 그리고 각 집단에 사용된 에이전트 수 $m = 10$ 이고 초기 위치 결정은 에이전트들을 각 노드에 1개씩 무작위로 배정하였다.

종료 조건은 고정된 수행 횟수 또는 여러 실험에 의해 최적해로 알려진 값을 찾았을 경우 종료한다.

전통적인 ACS 방법과 본 논문에서 제안한 방법의 효율성 분석을 위해 최적 해에 얼마나 빨리 수렴하는 가를 각각 비교 분석하였다.

(그림 3)은 Mesh 구조로 집단 수 $M = 5$ 그리고 10회 시행에 2,000번 사이클을 반복했을 경우의 결과로 제안된 알고리즘을 이용해 노드집합(Eil51.TSP)을 이용한 최적해로의 수렴 결과를 보여주고 있다. 전통적인 알고리즘은 초기 수렴은 원활하게 되지만 시간이 지날수록 각 간선에 대해 좋은 휴리스틱 정보만 가지고 있는 경로들로만 탐색하려는 성향 때문에 수렴 속도가 느리게 된다. 그러나, 하부집단에서 다양한 탐색과정을 거치고, 그 결과를 바탕으로 상부집단에서 강화과정을 거치는 제안된 방법은 초기 수렴속도는 느리지만 학습과정을 거칠수록 더욱 빠르게 최적해에 수렴함을 볼 수 있다.



(그림 3) 수렴속도 평가

<표 1>은 문제영역이 작은 집합(Eil51, St70)에 대해서는 Mesh 구조를 적용해 집단 수 $M = 5$, 10회 시행에 20,000번 사이클을 반복 실험했으며, 상대적으로 문제영역이 큰 나머지 집합(KroA150, Rat195, Gil262, A280, Pr299, Lin318, Pr439)에 대해서는 Cubic 구조를 적용해 집단의 수 $M = 9$, 10회 시행에 100,000번 사이클을 반복 실험한 결과로 제안된 방법이 우수한 결과를 보이고 있다.

이것은 하부 집단간 상호작용에서는 다른 하부 집단에서 자주 방문된 간선 선택을 회피하게 함으로써 선호하지 않는 탐색 영역으로의 다양한 탐색을 가능하게 하고, 그 결과

를 상부 집단에 전달해 폐로문 효과를 강화하는 구조로 되어 있어서 결국, 상부집단은 최적 경로 탐색을 위한 좋은 휴리스틱 정보를 하부 집단에서 제공받기 때문에 효과적으로 최적해를 탐색할 수 있다.

그러나, 노드수가 증가함에 따라 집단간 상호작용에 따른 계산량이 증가하는 문제점은 발생하지만, 다양하지 못한 상태전이로 인해 기존 ACS에서 발생되는 어느 정도 해의 개선이후 해의 수렴현상을 극복할 수 있다.

〈표 1〉 다중 집단 개미 모델 성능 평가

Node Set	ACS		Multi Colony Ant Model	
	Average Length	Best Length	Average Length	Best Length
Eil51	431.82	426	429.48	426
St70	684.35	677	683.42	675
KroA150	28908.8	27824	27037.08	26647
Rat195	2571.63	2461	2484.35	2357
Gil262	2636.75	2526	2516.63	2453
A280	2892.58	2768	2691.28	2645
Pr299	53497.8	51395	50326.83	48903
Lin318	46244.4	44837	44018.38	43297

5. 결론과 앞으로의 연구 방향

본 논문에서는 ACS의 성능을 향상 시키고자 다중 집단 개미 모델 구조를 제안하였다. 제안된 모델은 서로 독립적인 탐색과정을 거치는 여러 개의 에이전트 집단을 가진 다중 집단 에이전트 구조로 집단간에 궁정적 상호작용과 부정적 상호작용을 한다. 이것은 각 에이전트 집단간에 문제 해결을 위해 휴리스틱 정보를 서로 상호 교환함으로써 탐색 과정에서 그들 자신의 다양화를 유지할 수 있게 하는 것으로. 궁정적 상호작용은 다른 집단에 속한 에이전트들로 하여금 경로 선택을 선호하게 하고, 부정적 상호작용은 그 경로 선택을 회피하게 만든다. 따라서, 이 구조는 에이전트들로 하여금 다른 집단에 속한 에이전트들에게 좋은 휴리스틱 정보를 제공하게 되고 서로 탐색 영역을 공유하게 된다.

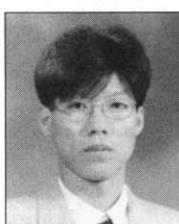
이러한 다중 집단간 상호작용은 문제 영역이 복잡하고 큰 경우에 효과적으로 적용 될 수 있는 구조로 병렬 처리하는 ACS 알고리즘 구현을 가능하게 하고, ACS 알고리즘의 기본 성능을 향상 시킬 수 있다.

향후 연구과제는 이런 결과들을 기반으로 각 집단간 상호작용에 영향을 미치는 파라미터들에 대한 더 많은 연구와 다른 일반적인 휴리스틱 탐색 방법과의 비교, 그리고 병렬처리 문제에 대해 더 많은 연구가 필요하다.

참 고 문 헌

- [1] A. Colomni, M. Dorigo and V. Maniezzo, "An investigation of some properties of an ant algorithm," Proceedings of the Parallel Parallel Problem Solving from Nature Conference(PPSN 92), R. Manner and B. Manderick (Eds.), Elsevier Publishing, pp.509-520, 1992.

- [2] A. Colomni, M. Dorigo and V. Maniezzo, "Distributed optimization by ant colonies," Proceedings of ECAL91 - European Conference of Artificial Life, Paris, France, F. Varela and P. Bourgine(Eds.), Elsevier Publishing, pp.134-144, 1991.
- [3] B. Freisleben and P. Merz, "Genetic local search algorithm for solving symmetric and asymmetric traveling salesman problems," Proceedings of IEEE International Conference of Evolutionary Computation, IEEE-EC 96, IEEE Press, pp. 616-621, 1996.
- [4] L. M. Gambardella and M. Dorigo, "Solving symmetric and asymmetric TSPs by ant colonies," Proceedings of IEEE International Conference of Evolutionary Computation, IEE E-EC 96, IEEE Press, pp.622-627, 1996.
- [5] L. M. Gambardella and M. Dorigo, "Ant Colony System : A Cooperative Learning approach to the Traveling Salesman Problem," IEEE Transactions on Evolutionary Computation, Vol.1, No.1, 1997.
- [6] L. M. Gambardella and M. Dorigo, "Ant-Q : a reinforcement learning approach to the traveling salesman problem," Proceedings of ML-95, Twelfth International Conference on Machine Learning, A. Prieditis and S. Russell (Eds.), Morgan Kaufmann, pp.252-260, 1995.
- [7] M. Dorigo, V. Maniezzo and A. Colomni, "The ant system : optimization by a colony of cooperation agents," IEEE Transactions of Systems, Man, and Cybernetics-Part B, Vol.26, No.2, pp.29-41, 1996.
- [8] M. Dorigo and G. D. Caro, "Ant Algorithms for Discrete Optimization," Artificial Life, Vol.5, No.3, pp.137-172, 1999.
- [9] M. Dorigo and L. M. Gambardella, "Ant Colonies for the Traveling Salesman Problem," BioSystems, 43, pp.73-81, 1997.
- [10] S. Lin and B. W. Kernighan, "An effective Heuristic algorithm for the traveling salesman problem," Operations Research, Vol.21, pp.498-516, 1973.
- [11] <http://www.iwr.uniheidelberg.de/groups/comopt/software/TSPLIB95/>.



이 승 관

e-mail : lee@iislab.kyunghee.ac.kr

1997년 경희대학교 전자계산공학과(공학사)

1999년 경희대학교 대학원 전자계산공학과

(공학석사)

2001년~현재 경희대학교 대학원 전자

계산공학과 박사과정 수료

주관심분야 : 인공지능, 지능에이전트, 메타알고리즘, 스케줄링



정 태 총

e-mail : tcchung@khu.ac.kr

1980년 서울대학교 전자공학과(공학사)

1982년 한국과학기술원 대학원 전자계산

공학과(공학석사)

1987년 한국과학기술원 대학원 전자계산

공학과(공학박사)

1987년~1988년 KIST 시스템 공학센터 선임 연구원

2001년 미국 Iowa 대학 교환교수

1988년~현재 경희대학교 컴퓨터공학과 정교수

관심분야 : 인공지능, 지능에이전트, 메타알고리즘