

Ant Colony System에서 효율적 경로 탐색을 위한 지역갱신과 전역갱신에서의 추가 강화에 관한 연구

이 승 관[†] · 정 태 충^{††}

요 약

Ant Colony System(ACS) 알고리즘은 조합 최적화 문제를 해결하기 위한 메타 휴리스틱 탐색 방법이다. 이것은 greedy search뿐만 아니라 exploitation of positive feedback을 사용한 모 집단에 근거한 접근법으로 Traveling Salesman Problem(TSP)를 풀기 위해 제안되었다. 본 논문에서는 전통적 전역갱신과 지역갱신 방법에 개미들이 방문한 각 간선에 대한 방문 횟수를 강화값으로 추가한 새로운 방법의 ACS를 제안한다. 그리고 여러 조건 하에서 TSP 문제를 풀어보고 그 성능에 대해 기존의 ACS 방법과 제안된 ACS 방법을 비교 평가해, 최적해에 더 빨리 수렴함을 실험을 통해 알 수 있었다.

A Study about Additional Reinforcement in Local Updating and Global Updating for Efficient Path Search in Ant Colony System

SeungGwan Lee[†] · TaeChoong Chung^{††}

ABSTRACT

Ant Colony System (ACS) Algorithm is new meta heuristic for hard combinatorial optimization problem. It is a population based approach that uses exploitation of positive feedback as well as greedy search. It was first proposed for tackling the well known Traveling Salesman Problem (TSP). In this paper, we introduce ACS of new method that adds reinforcement value for each edge that visit to Local/Global updating rule. and the performance results under various conditions are conducted, and the comparison between the original ACS and the proposed method is shown. It turns out that our proposed method can compete with the original ACS in terms of solution quality and computation speed to these problem.

키워드 : 개미 시스템(Ant System, AS), 개미 집단 시스템(Ant Colony System, ACS), 전역 갱신(Global Updating), 지역 갱신(Local Updating), 강화 학습(Reinforcement Learning), 메타 휴리스틱(Meta Heuristic)

1. 서 론

조합 최적화 문제를 해결하기 위해 현재 많은 휴리스틱 방법들이 제안되었다. 그 중 Genetic Algorithm(GA)[3], Tabu Search(TA), Simulated Annealing(SA), Lin-Kernighan(LK) Algorithm[13, 14]등은 조합최적화 문제인 Traveling Salesman problems[12], Job-shop scheduling, Quadratic assignment, vehicle routing, sequential ordering, graph coloring, routing in communication networks에서 전통적으로 최적의 해를 구하기 위해 사용되는 널리 알려진 메타 휴리스틱 방법이다.

본 논문에서는 Symmetric TSP(STSP)문제를 풀기 위해 Colomni, Dorigo 그리고 Maniezzo[1, 2]에 의해 처음 제안된

지역갱신과 전역갱신 과정을 거쳐 최적해를 구하는 메타 휴리스틱 방법인 ACS 알고리즘[5, 6, 9, 10]에 대해 소개를 하고, 기존 ACS 알고리즘의 전역갱신에서 일반적으로 최적 경로(Best-Tour)만을 갱신하는 것과 달리 각각의 개미들이 경로 사이클을 이루는 동안 방문한 모든 경로에 대한 방문 횟수를 강화값으로 적용하는 방법과 지역갱신에서 탐색과정을 거치면서 탐색한 각 경로에 분비한 페로몬(Pheromone)을 갱신하는 방법에 현재 방문한 간선에 이미 방문한 다른 개미들의 방문 횟수를 강화값으로 적용하는 방법이 기존ACS 알고리즘 성능에 어떤 영향을 미치는지 비교 분석해 본다.

2. 조합 최적화를 위한 ACS 접근법

2.1 The Ant System

Ant System(AS)은 실제 개미들이 먹이에서 집까지 가장 짧은 경로를 찾는 능력을 모방한 탐색 기법으로, 현실 상황

[†] 준 회원 : 경희대학교 대학원 전자계산공학과

^{††} 정 회원 : 경희대학교 컴퓨터공학과 정교수

논문접수 : 2003년 4월 10일, 심사완료 : 2003년 5월 20일

에서 대형의 수리 최적화 문제들 중에서 많은 문제가 NP-Hard로서 문제크기가 커짐에 따라 컴퓨터의 용량과 계산시간의 한계를 갖는데 이러한 문제의 근사최적해(near optimal solution)를 빠른 시간에 찾을 수 있는 발견적 기법(heuristic)인 메타 휴리스틱 계열의 한 탐색 방법이며[1, 2, 7, 10, 17], 최근에는 강화학습의 특별한 한 분야로 소개되고 있다[8].

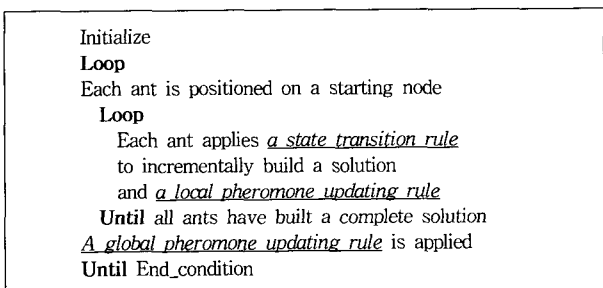
개미들은 목적지를 향해 나아가는 동안 각 경로에 페로몬을 분비하고, 이후에 지나가는 개미들은 그 경로에 쌓여 있는 페로몬 정보를 이용해 다음 경로를 선택하는 원리를 휴리스틱 탐색에 적용시킨 시스템이 Ant System(AS)이다 [6, 7, 9, 10, 16]. 그러나, 이 AS는 개미들이 짧은 경로가 있으면 그것만을 선택하고자 하는 성질로 인하여 국부 최적(Local Minima)에 빠질 확률이 높아지기 때문에, 이 문제를 쉽게 해결하기 위해 정규확률분포를 이용해서 다음 노드를 선택하는 과정을 추가한 ACS 알고리즘이라는 방법이 새롭게 연구되었다.

2.2 The Ant Colony System

ACS 알고리즘은 AS의 성능을 향상시키기 위해 Dorigo and Gambardella[6, 7, 11]에 의해 소개되었다.

일반적으로 ACS는 다음과 같은 방법으로 수행을 한다. 먼저 m개의 개미들이 초기화 규칙(initialization rule)에 따라 무작위로 n개의 노드(node)를 선택한 다음, 각 개미들은 상태전이 규칙(state transition rule)에 따라 다음에 방문할 노드를 선택하고 계속해서 탐색과정을 거친다. 이러한 탐색과정을 거치는 동안 개미들은 지역갱신 규칙(Local Updating Rule)에 따라 방문한 각 간선에 페로몬 양을 변경하게 된다. 그리고 일단 모든 개미들이 탐색과정을 마치게 되면 전역갱신 규칙(Global Updating Rule)에 따라 다시 한번 페로몬 양을 변경하게 된다[7]. 결국, AS처럼 각 개미들은 짧은 간선을 선택하려는 휴리스틱 정보와 많은 양의 페로몬을 가진 간선을 선택하려는 페로몬 정보에 따라 탐색경로를 완성하게 된다.

ACS 알고리즘에 대한 기본 구조는 (그림 1)에 잘 나타나 있으며, 계속해서 상태 전이 규칙(State Transition Rule), 지역 갱신 규칙(Local Updating Rule), 전역 갱신 규칙(Global Updating Rule)에 대해 살펴보고자 한다[6, 7].



(그림 1) The ACS Algorithm

2.2.1 The State Transition Rule

식 (1)은 노드 (r)에 있는 개미 k가 노드 (s)로 이동할 확률을 나타낸 것으로 pseudo random proportional action choice rule으로 불린다. 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 개미 k가 방문할 수 있는 남아있는 노드들의 집합이다. 그리고 β 는 페로몬과 간선 길이의 상대적인 중요도를 결정하는 파라미터이다($\beta > 0$).

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

q 는 [0, 1]사이에서 정규적으로 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, 정규확률분포를 이용해서 다음 노드를 선택하는 과정이 추가됨으로 인해 AS가 가지고 있는 국부 최적에 빠지기 쉬운 한계에서 어느 정도 벗어나고자 하고 있다.

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

2.2.2 The Local Updating Rule

개미들은 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 지연 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 경로 길이, n은 노드수이다.

2.2.3 The Global Updating Rule

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

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

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

$0 < \alpha < 1$ 는 페로몬 지연 파라미터(Pheromone decay pa-

parameter), 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 지연 파라미터 α 에 의해 페로몬 양은 줄어들게 된다.

이 전역갱신은 더 짧은 경로 사이클에 더 많은 강화를 제공한다. 어떤 점으로는, 이것은 더 좋은 해가 발견되면 더 높은 강화를 하는 강화학습(Reinforcement Learning)과 유사하다.

3. ACS에서 페로몬 갱신에 관한 방법

ACS에서 각 개미들은 지역갱신과 전역갱신 방법에 의해 갱신된 각 간선들의 페로몬 정보를 이용해 다음 노드를 선택한다.

ACS에서 중요한 요점은 각 간선들의 페로몬을 어떻게 갱신 하는가이다. 본 논문에서는 각 개미들이 방문한 모든 간선에 대한 방문 횟수를 강화값으로 적용한 방법을 기존 전역갱신과 지역갱신을 통해 탐색하는 방법과의 비교를 통해 효율적 방법을 도출한다.

3.1 일반적 전역갱신과 지역갱신 방법

ACS알고리즘에서의 일반적인 전역갱신 방법은 각 개미들이 모든 경로 사이클을 완성 후 이루어지며, 전역 최적 경로에 속해 있는 간선만 갱신시키는 방법[6, 7, 9]과 Current Iteration Best tour에 속해 있는 간선의 페로몬을 갱신시키는 방법[8]이 있다. 이 두 방법은 거의 유사한 결과를 보이고 있지만, 그 중 Current Iteration Best tour 갱신방법이 좀 더 향상된 결과를 보이고 있다.

또 다른 방법은 각 경로 사이클마다 우성과 열성 인자들로 구분하고 각각의 우성과 열성 인자들에 대해 전역 갱신 규칙에 기반해 생성된 모든 경로 사이클에 페로몬 값을 갱신시키는 방법[15]이 있다. 여기서 우성과 열성을 구분하는 방법은 각 경로 사이클 중 상위 50%를 우성, 그 이하를 열성으로 채택했으며, 우성 간선인 경우엔 경로 길이의 역수를 적용시켜 우성이 높으면 높을수록 더 큰 가중치가 더해지도록 한다. 반대로 열성 간선인 경우엔 서로 대칭되는 경로 길이의 역수를 적용시켜 열성이 강하면 강할수록 더 큰 가중치로 감하고 있다. 그러나, 여기서 우성과 열성을 구분하는 기준과 가중치 부여 방법이 모호하고, 열성인 경우 추가적인 페로몬 감소로 인해 개미들이 다음 경로 사이클 동안 검색할 간선의 페로몬 정보를 회색 시키는 영향을 미칠 수 있다.

그리고, 일반적인 지역갱신 방법은 탐색과정을 통해 방문한 각 간선에 페로몬을 갱신시킨다. 이 방법은 식 (3)의 $\tau(r, s)$ 에 Neighborhood heuristic 거리를 대입하여 갱신시킨다. 이것은 다음 노드를 방문할 때마다 각 간선을 갱신 시킴으로서 특정 간선만을 선호하는 것을 막는 효과가 발생한다.

3.2 전역 갱신에서 추가 강화값을 이용한 페로몬 갱신

3.1절에서 설명한 전역 최적 경로나 Current Iteration Best tour에 속해 있는 간선만 갱신하는 일반적 전역 갱신과는 달리 본 논문에서 제시한 전역 갱신 방법은 먼저, 각 경로 사이클에서 방문한 각 간선들이 최적해를 이루는데 얼마나 적합한지를 구분하는 기준으로 현재 단계(current history)의 모든 경로 사이클을 완성 후 각 간선에 방문한 개미들의 방문 횟수를 강화값으로 표현하고, 그 강화값을 경로 사이클을 구성한 모든 간선의 페로몬 갱신에 추가하는 방법을 채택함으로써 방문 횟수가 많을수록 강화값을 높게 평가하는 방법이다. <표 1>에 기존 알고리즘과 제안된 알고리즘의 전역 갱신 방법의 차이가 잘 비교되어 있다.

<표 1> 전역 갱신 방법의 차이

| | 기존 방법 | 제안된 방법 |
|----------|------------------------------------------------------------------|----------------------------|
| 전역 갱신 방법 | 현재 사이클 최적 경로 or 전역 최적 경로 or 우성열성 경로구분에 의한 갱신(50% 기준) | 모든 경로 갱신 + 강화값(방문횟수) |

갱신 방법은 Current Iteration Best Tour Cycle에 속한 간선 갱신과 일반 경로 사이클(General tour Cycle)에 속한 간선 갱신 두 유형으로 나눌 수 있으며, 다음의 식 (5)에 의해 갱신된다.

$$\tau(r, s) \leftarrow (1 - \alpha) \cdot \tau(r, s) + \alpha \cdot (\Delta\tau(r, s) + \gamma \cdot \text{InfoT}(r, s))$$

$$\text{where } \Delta\tau(r, s) = \begin{cases} (L_k)^{-1} & \text{if } (r, s) \in \text{best_tour} \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

$$\text{InfoT}(r, s) = \frac{\text{freqT}(r, s)}{m}$$

여기서, L_k 는 Current Iteration Best Tour 길이, $\gamma(0 < \gamma < 1)$ 는 할인계수(discount factor), m은 개미 수, freqT(r, s)는 개미들이 간선 (r, s)에 방문한 횟수, InfoT(r, s)는 전체 개미수에 대한 각 간선별 방문 횟수를 나타낸다. 여기서 할인계수(γ)를 사용하는 것은 지속적인 환경에서 강화를 무한대로 할 수 없기 때문에 일정비율로 할인을 하는 것이다.

결국, 이 방법은 Current Iteration Best Tour만 페로몬 양을 갱신하는 방법이 아니라, 각 경로 사이클마다 개미들이 방문한 모든 간선에 대하여 각 간선에 방문한 횟수를 강화값으로 적용하여 페로몬을 갱신하는 방법으로, 일반 경로 사이클까지 확대한 갱신방법으로 개미들은 각 방문한 간선을 휴리스틱 정보로 이용해 탐색할 수 있게 된다.

(그림 2)(a), (그림 2)(c)를 살펴보면, ABDCFEA가 Current Iteration Best tour cycle을 구성하는 경우 각 간선의 강화값은 2/3, 2/3, 2/3, 2/3, 1, 2/3로 강화한다.

3.3 지역 갱신에서 추가 강화값을 이용한 페로몬 갱신

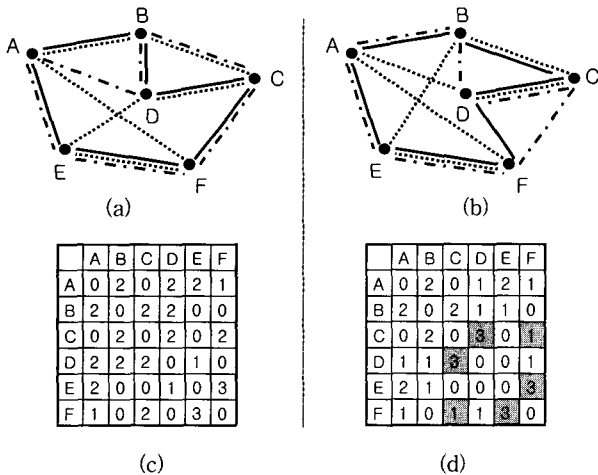
탐색과정을 통해 방문한 각 간선에 페로몬을 갱신하는 일반적인 지역갱신 방법은 다음 노드를 방문할 때마다 각 간선을 갱신 시킴으로서 특정 간선만을 선호하는 것을 막는 효과가 발생한다. 그러나, 이 방법은 단순히 개미들이 방문한 간선에 대한 페로몬 갱신일 뿐, 특정 개미가 방금 방문한 간선이 최적 경로를 구성하는데 얼마나 공헌한지에 대한 평가는 되지 못하고 있다. 따라서, 본 논문에서는 현재 방문한 간선에 이미 방문한 다른 개미들의 방문 횟수를 강화값으로 적용하는 방법을 채택해 방문 간선에 대한 공헌도로 나타내고, 그 값을 지역갱신에서 페로몬 갱신의 강화값으로 사용한다. 이 방법은 최적해를 찾기 위해 방문한 각 노드의 공헌도를 특성 값으로 표현하고 그 값을 페로몬 갱신에 추가함으로써 최적해를 도출하는데 그 정보를 제공한다.

본 논문에서는 노드 (r)에 있는 개미 k가 방문할 수 있는 남아있는 노드들 $J_k(r)$ 의 개수와 현재 방문한 간선에 대해 다른 개미들이 방문한 횟수를 식 (6)과 같이 표현해 현재 상태전이한 간선의 새로운 강화값으로 적용한다. 이때 적용한 강화값은 현재 방문한 간선에 대해 다른 개미들의 학습 결과를 적용함으로써 공헌도가 높은 간선에 대해 페로몬 증가 값을 주어 다른 개미들이 더 나은 간선을 선택할 확률을 높이는 효과가 발생한다.

$$\tau(r, s) \leftarrow (1 - \rho) \cdot \tau(r, s) + \rho \cdot (\Delta \tau(r, s) + \gamma \cdot \text{InfoE}(r, s))$$

$$\text{where } \text{InfoE}(r, s) = \frac{\text{freqE}(r, s)}{J_k(r) + m} \quad (6)$$

여기서, $\text{freqE}(r, s)$ 는 현재 경로 사이클에서 현재까지 개미들이 간선 E(r, s)에 방문한 횟수, $\text{InfoE}(r, s)$ 는 현재 선택한 노드에 대한 평가값으로 전체 개미수와 노드 (r)에 있는 개미 k가 방문할 수 있는 남아 있는 노드들의 집합에 대한 현재 경로 사이클에서 현재까지 개미들이 간선 E(r, s)에 방문한 횟수를 나타낸 것이다.



(그림 2) Tour Cycle

(그림 2)(b), (그림 2)(d)를 살펴보면, 경로 사이클을 구성하기 위해 ABD(C, E, F)노드에 있는 개미가 C노드를 선택할 경우 해당 간선(D, C)의 강화값은 $2/(3+3)$ 으로 강화한다.

(그림 2)는 각 경로 사이클 동안 각 간선에 방문한 횟수를 나타낸 것으로, Ant's # = 3으로 가정했을 때, (그림 2)(a)는 t시간의 경로 사이클이며, (그림 2)(c)는 t시간의 경로 사이클에 각 간선에 방문한 개미 수이다(previous). (그림 2)(b)는 t+1시간의 경로 사이클이며, (그림 2)(d)는 t+1시간의 경로 사이클에 각 간선에 방문한 개미수이다(current).

4. 성능측정 및 분석

본 논문에서 제안하고 있는 방법을 실험하기 위해서 도시들의 위치는 TSP 예제로 널리 알려진 TSPLIB에서 추출하여 실험을 하였다. 사용된 파라미터들의 값은 실험에 의해 다음과 같이 결정되었으며, 실험에 의해 결정된 값은 $\beta = 2, \alpha = \rho = 0.1, q_0 = 0.9, \gamma = 0.1, \tau_0 = (n * L_{mm})^{-1}$ 이다. 그리고 각각의 실험에 사용된 개미 수 $m = 10$ 이고 초기 위치 결정은 개미들을 각 노드에 1마리씩 무작위로 배치하였다.

종료 조건은 1,000,000회의 고정된 수행 횟수 또는 여러 실험에 의해 최적값으로 알려진 값을 찾았을 경우 종료한다.

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

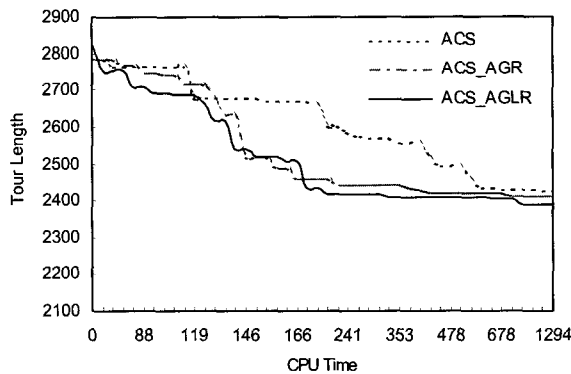
(그림 3)과 <표 2>, <표 3>는 TSPLIB에서 임의로 선택한 Eil51, St70, Kroa150, Rat195, Gil262, Pr439, Rat783의 노드 집합들에 대해, 전통적인 전역갱신과 지역갱신을 하는 ACS 알고리즘과 본 논문에서 제안된 방법의 성능 결과를 수치화 한 것으로, ACS는 전역갱신에 Current Iteration Best Tour만 페로몬 양을 갱신하는 방법, ACS_AGR (ACS_Additional Global Reinforcement)는 전역 갱신부분에 방문 횟수를 강화값으로 추가한 방법이고 ACS_AGLR(ACS_Additional Global and Local Reinforcement)은 전역갱신에 방문 횟수를 강화값으로 추가하고, 지역갱신에 공헌도로서 방문 횟수를 강화값으로 추가한 혼합된 방법을 나타낸다.

(그림 3)은 Rat195 집합에 대해 반복횟수를 2000회로 고정했을 경우 수행 결과로 제안된 ACS_AGR이나 ACS_AGLR 알고리즘이 전통적인 ACS 알고리즘보다 더 빠르게 해에 수렴함을 볼 수 있다.

<표 2>를 살펴보면 각각의 알고리즘(ACS, ACS_AGR, ACS_AGLR)에 대해 경로의 평균 길이와 최적 길이를 비교한 것으로서 문제 영역이 작은 경우(노드수가 적은 경우)에는 ACS_AGR이나 ACS_AGLR 알고리즘이 더 나은 결과 값을 보여 준다. 그러나, 문제영역이 큰 경우(Rat783)에는 일반적인 ACS 알고리즘이 더 나은 결과를 보여주는데, 이

것은 페로몬 갱신에 방문 횟수를 추가 적용함에 있어서 문제 영역이 큰 경우는 상대적으로 문제 영역이 작은 경우에 비해 동일 간선에 대해 개미가 방문하는 횟수가 작기 때문에 각 노드별 방문 횟수를 강화값으로 적용하기에는 한계가 있음을 나타낸다. 즉 페로몬이 증발하는 양에 크게 영향을 미치지 못하고 있는 것이다. 하지만, 대체적으로 제안된 방법의 성능이 우수하다는 것을 보여준다.

<표 3>에서는 ACS_AGLR 알고리즘에 대한 성능 평가로 첫 번째 칼럼은 노드집합을 나타내며, 두 번째 칼럼은 15 시행 중에 ACS_AGLR 알고리즘에 의해 획득된 최대 결과를 나타낸다. 다음 칼럼들은 15 시행에서 ACS_AGLR의 평균 길이, 사이클 횟수를 나타낸다. 다섯 번째 칼럼은 이미 알려진 최적 결과를 나타내고 마지막 칼럼은 에러율을 나타내며, 그 결과를 살펴보면 문제영역이 크면 클수록 에러율이 높게 나타나는 경향이 있다. 그러나, 제안된 방법이 대체적으로 기존의 ACS 알고리즘보다 더 빠르게 수렴하는 모습을 보이고 있다. 이것은 전역갱신에서 일반적으로 최적 경로만을 갱신하는 것과 달리 각각의 개미들이 경로 사이클을 이루는 동안 방문한 모든 경로에 대한 방문 횟수를 적용하는 방법, 그리고 지역갱신에서 현재 방문한 간선에 대해 다른 개미들이 방문한 횟수를 확률적으로 적용한 결과가 기존의 ACS에 비해 더 개선된 결과를 보여주고 있다.



(그림 3) Rat195 집합을 이용한 최적해 수렴 속도

<표 2> 각각 알고리즘간의 성능 평가

| Node Set | ACS | | ACS-AGR | | ACS-AGLR | |
|----------|----------------|-------------|----------------|-------------|----------------|-------------|
| | Average Length | Best length | Average Length | Best length | Average length | Best length |
| Eil51 | 428.86 | 426 | 427.94 | 426 | 427.90 | 426 |
| St70 | 679.35 | 675 | 677.51 | 675 | 676.72 | 675 |
| KroA150 | 26949.25 | 26524 | 26812.96 | 26524 | 26781.12 | 26524 |
| Rat195 | 2411.63 | 2328 | 2328.84 | 2326 | 2325.38 | 2324 |
| Gil262 | 2509.83 | 2391 | 2492.29 | 2384 | 2462.58 | 2381 |
| Pr439 | 109853.06 | 108937 | 108109.76 | 107328 | 109176.92 | 108361 |
| Rat783 | 9066.64 | 9015 | 9102.76 | 9031 | 9146.23 | 9046 |

<표 3> ACS_AGLR 알고리즘 성능평가

| Node Set | ACS-AGLR Best Length(1) | ACS-AGLR Average Length | ACS-AGLR # of Tour | Optimum (2) | Relative error (1-2)/2*100 |
|----------|-------------------------|-------------------------|--------------------|-------------|----------------------------|
| Eil51 | 426 | 427.90 | 1120 | 426 | 0.0 % |
| St70 | 675 | 676.72 | 42840 | 675 | 0.0 % |
| KroA150 | 26524 | 26781.12 | 3047 | 26524 | 0.0 % |
| Rat195 | 2324 | 2325.38 | 97952 | 2323 | 0.04% |
| Gil262 | 2381 | 2462.58 | 386809 | 2378 | 0.13% |
| Pr439 | 108361 | 109176.92 | 202021 | 107217 | 1.07% |
| Rat783 | 9046 | 9146.23 | 880047 | 8806 | 2.73% |

5. 결론과 앞으로의 연구 방향

본 논문은 전통적인 ACS 알고리즘의 성능을 향상시키는 방법을 제시하고 있다.

전역갱신에 있어서 Current Iteration Best Tour만 페로몬 양을 갱신하는 방법보다, 방문한 모든 간선에 추가 강화값을 적용해 페로몬 양을 갱신하는 방법과 지역갱신에서 현재 방문한 간선에 대해 다른 개미들이 방문한 횟수를 확률적으로 적용해 방문한 각 간선에 대해 최적해를 구성하기 위한 공헌도로 강화값을 추가한 방법은 다른 개미들이 더 나은 간선을 선택할 확률을 높이는 효과가 발생할 뿐 아니라 더 빨리 최적해에 수렴한다. 그러나, 일부의 도시에서 좋지 않은 결과가 나왔는데, 이것은 제안된 추가 강화값에 의한 갱신 방법이 모든 도시에 포괄적이지 않다는 것을 뜻한다. 이것은 바로 개미 개수가 고정적으로 지정이 되어 있기 때문에, 도시 개수의 유동성만으로는 강화값을 정형화하는데 한계가 있다는 것을 의미한다.

따라서, 향후 연구과제로서는 이런 결과들을 기반으로 가급적 많은 수의 표본들을 통해 모든 도시들을 포괄할 수 있는 강화값의 정형화에 관한 더 많은 연구가 이루어진다면 현재보다 더 좋은 결과를 보일 수 있을 것이다. 그리고, 더 나아가 개미들에게 지능을 부여하고, 그것을 바탕으로 개미들을 이동 에이전트화하여 서로간의 통신과 자율적 판단으로 전체 경로를 이루어 나갈 수 있게 시스템을 구성한다면, 국부최적에 빠질 수 있는 확률을 최소로 줄이고, 좀 더 넓은 범위의 공간을 효율적으로 탐색해 현재보다 향상된 성능을 보일 것이다.

참 고 문 헌

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

mization by ant colonies," Proceedings of ECAL '91 - European Conference of Artificial Life, Paris, France, F. Varela and P. Bourguine(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] D. S. Johnson and L. A. McGeoch, "The travelling salesman problem : a case study in local optimization," in Local Search in Combinational Optimization, E. H. L. Aarts and J. K. Lenstra(Eds.), New York : Wiley and Sons, 1997.

[5] L. M. Gambardella, E. Taillard and M. Dorigo, "Ant Colonies for QAP," IDSIA, Lugano, Switzerland, Tech. Rep. IDSIA 97-4, 1997.

[6] L. M. Gambardella and M. Dorigo, "Solving symmetric and asymmetric TSPs by ant colonies," Proceedings of IEEE International Conference of Evolutionary Computation, IEEE-EC '96, IEEE Press, pp.622-627, 1996.

[7] 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.

[8] 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.

[9] M. Drigo, V. Maniezzo and A. Colomi, "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.

[10] M. Dorigo and G. D. Caro, "Ant Algorithms for Discrete Optimization," Artificial Life, Vol.5, No.3, pp.137-172, 1999.

[11] M. Dorigo & L. M. Gambardella, "Ant Colonies for the Traveling Salesman Problem," *BioSystems*, 43, pp.73-81, 1997.

[12] P.-C. Kanellakis and C. H. Papadimitriou, "Local search for the asymmetric traveling salesman problem," Operations Research, Vol.28, No.5, pp.1087-1099, 1980.

[13] S. Lin and B. W. Kernighan, "An Effective Heuristic algorithm for the Traveling Salesman Problem," Bell Telephone Laboratories, Incorporated, Murray Hill, N. J., 1997.

[14] S. Lin and B. W. Kernighan, "An effective Heuristic algorithm for the traveling salesman problem," Operations Research, Vol.21, pp.498-516, 1973.

[15] SeungGwan Lee, TaeUng Jung and TaeChoong Chung, "Improved Ant Agents System by the Dynamic Parameter Decision," Proceedings of IEEE International Conference on FUZZ-IEEE '01, IEEE Press, pp.666-669, 2001.

[16] T. Stutzle and H. Hoos, "The ant system and local search for the traveling salesman problem," Proceedings of ICEC '97, IEEE 4th International Conference of Evolutionary, 1997.

[17] T. Stutzle and M. Dorigo, "ACO Algorithms for the Traveling Salesman Problem," In K. Miettinen, M. Makela, P. Neittaanmaki, J. Periaux, editors, Evolutionary Algorithms in Engineering and Computer Science, Wiley, 1999.



이 승 관

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

1997년 경희대학교 전자계산공학과(공학사)

1999년 경희대학교 대학원 전자계산공학과(공학석사)

2001년~현재 경희대학교 대학원 전자계산공학과 박사과정 수료

관심분야 : 인공지능, 멀티에이전트, 최적화, 스케줄링 등



정 태 충

e-mail : tchung@khu.ac.kr

1980년 서울대학교 전자공학과(공학사)

1982년 한국과학기술원 대학원 전자계산공학과(공학석사)

1987년 한국과학기술원 대학원 전자계산공학과(공학박사)

1987년~1988년 KIST 시스템 공학센터 선임 연구원

1988년~현재 경희대학교 컴퓨터공학과 정교수

관심분야 : 인공지능, 자연어처리, 로봇에이전트, 최적화, 정보 보호 등