

# 개미 집단 최적화에서 강화와 다양화의 조화

## Balance between Intensification and Diversification in Ant Colony Optimization

이승관, 최진혁  
경희대학교 후마니타스칼리지

Seung-Gwan Lee(leesg@khu.ac.kr), Jin-Hyuk Choi(jinhchoi@khu.ac.kr)

### 요약

휴리스틱 탐색에서 강화(Intensification)와 다양화(Diversification)의 조화는 중요한 연구 부분이다. 본 논문에서는 개미 집단 최적화(Ant Colony Optimization, ACO) 접근법의 하나인 개미 집단 시스템(Ant Colony System, ACS)에서 강화와 다양화의 조화를 통한 성능 향상시키는 방법을 제안한다. 제안 방법은 다양화 전략으로 전역 최적 경로가 향상되지 않는 경우 반복 탐색 구간을 고려해 상태전이 규칙의 파라미터를 변경해 탐색하고, 이러한 다양화 전략을 통해 발견된 전역 최적 경로에서 이전 전역 최적 경로와 현재 전역 최적 경로의 중복 간선에 대해 페로몬을 강화시켜 탐색하는 혼합된 탐색 방법을 제안한다. 그리고, 실험을 통해 제안된 방법이 기존 ACS-3-opt 알고리즘, ACS-Subpath 알고리즘, ACS-Iter 알고리즘, ACS-Global-Overlap 알고리즘에 비해 최적 경로 탐색 및 평균 최적 경로 탐색의 성능이 우수함을 보여 준다.

■ 중심어 : | 개미 집단 시스템 | 개미 집단 최적화 | 순회 외판원 문제 | 최적화 | 휴리스틱 | 강화 | 다양화 |

### Abstract

One of the important fields for heuristic algorithm is how to balance between Intensification and Diversification. In this paper, we deal with the performance improvement techniques through balance the intensification and diversification in Ant Colony System(ACS) which is one of Ant Colony Optimization(ACO). In this paper, we propose the hybrid searching method between intensification strategy and diversification strategy. First, the length of the global optimal path does not improved within the limited iterations, we evaluates this state that fall into the local optimum and selects the next node using changed parameters in the state transition rule. And then we consider the overlapping edge of the global best path of the previous and the current, and, to enhance the pheromone for the overlapping edges increases the probability that the optimal path is configured. Finally, the performance of Best and Average-Best of proposed algorithm outperforms ACS-3-opt, ACS-Subpath, ACS-Iter and ACS-Global-Overlap algorithms.

■ keyword : | Ant Colony System | Ant Colony Optimozation | Traveling Salesman Problem | Optimization | Heuristic | Intensification | Diversification |

## I. 서론

개미 집단 최적화(Ant Colony Optimization, ACO)는 조합 최적화 문제를 해결하기 위한 메타 휴리스틱 탐색 방법으로, 에이전트라 불리는 개미들이 목적지를 향해 나아가는 동안 각 경로에 페로몬을 분비하고, 이후에 지나가는 에이전트들은 그 경로에 쌓여있는 페로몬(Pheromone) 정보를 이용해 다음 경로를 선택하는 방법이다[1]. 에이전트들은 각 경로에 있는 페로몬 양을 기반으로 서로 간의 정보 교환을 통해 최적의 경로를 찾아가고 이러한 에이전트들의 행동 양식을 그대로 적용한 휴리스틱 탐색 방법으로 조합 최적화 문제인 순회 외판원 문제(traveling salesman problem), 순서 문제(sequential ordering problem), 이차 배정 문제(quadratic assignment problem), 차량 경로 문제(vehicle routing problem), Job-shop 스케줄링 문제(scheduling problems), 그래프 착색 문제(graph coloring problem), telecommunications networks 등에서 최적의 해를 구하기 위해 사용되고 있다. 이러한 다양한 조합 최적화 문제를 풀기 위한 휴리스틱 탐색에서 강화와 다양화의 조화를 맞추는 문제는 해당 알고리즘의 성능에 많은 영향을 미치고 있다

이에 본 논문에서는 순회 외판원 문제를 풀기 위해 ACO 접근법의 하나인 Colormi, 외에 의해 제안된 메타 휴리스틱 방법인 개미 집단 시스템(Ant Colony System, ACS)[1-4]에 강화와 다양화의 조화를 통해 기존 개미 집단 시스템의 성능을 향상시키는 개선된 ACS 알고리즘을 소개한다.

본 논문에서 제안하는 개선된 ACS 알고리즘은 기존 강화전략과 다양화전략을 혼합한 방법으로, 첫째, 다양화 전략으로 전역 최적 경로의 길이가 주어진 반복 사이클 횟수 동안 더 이상 향상되지 못하면 국부최적에 빠졌다고 평가하고 상태전이 규칙에서 파라미터 감소를 통해 다음 노드를 선택하게 한다[7]. 둘째, 강화전략으로 이전 전역 최적 경로와 현재 전역 최적 경로의 중복 간선을 고려한 탐색 방법으로 두 전역 최적 경로에서 중복된 간선은 최적 경로로 구성될 가능성이 높으므로, 중복 간선의 페로몬을 강화시킨다[13]. 이 다양화전

략과 강화전략을 혼합한 방법의 성능이 기존 방법보다 우수함을 실험한다.

본 논문은 다음과 같이 구성되어 있다. 2장에서는 관련된 개미 집단 시스템, 기존 강화와 다양화 전략에 대해 소개하고, 3장에서는 다양화전략과 강화전략을 혼합한 탐색 방법을 설명한다. 그리고 4장에서는 시뮬레이션을 통해 제안된 방법의 성능을 평가하고 5장에서 결론을 맺는다.

## II. 기존 연구

### 2.1 개미집단시스템

개미 집단 시스템(Ant Colony System, ACS)은 조합 최적화 문제를 해결하기 위해 소개되었으며, 실제 개미들이 먹이에서 집까지 가장 짧은 경로를 찾는 능력을 모방한 메타 휴리스틱 기법이다[1-4].

일반적으로 ACS는 다음과 같은 방법으로 수행을 한다. 먼저  $m$ 개의 에이전트들이 초기화 규칙(initialization rule)에 따라 무작위로  $n$ 개의 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 갱신하게 된다. 그리고 일단 모든 에이전트들이 탐색과정을 마치게 되면 전역 갱신 규칙(Global Updating Rule)에 따라 다시 한번 페로몬 양을 갱신하게 된다. 결국, 각 에이전트들은 짧은 간선을 선택하려는 휴리스틱 정보와 많은 양의 페로몬을 가진 간선을 선택하려는 페로몬 정보에 따라 탐색 경로를 완성하게 된다.

ACS 알고리즘에서 노드( $r$ )에 있는 에이전트( $k$ )가 노드( $s$ )로 이동할 때 수식(1)을 사용해 다음 노드로 이동하며, 상태전이 규칙이라 불린다. 여기서  $\tau(r, u)$ 는 노드( $r$ )과 노드( $u$ )사이 간선의 페로몬의 양,  $\eta(r, u) = 1/\delta(r, u)$ 로써  $\delta(r, u)$ 는 노드( $r$ )과 노드( $u$ )사이 거리이며,,  $J_k(r)$ 은 노드( $r$ )에 있는 에이전트( $k$ )가 방문할 수 있는 남아있는 노드들의 집합이다. 그리

고  $\alpha, \beta$ 는 페로몬과 간선 길이의 상대적인 중요도를 결정하는 파라미터이다. ( $\alpha > 0, \beta > 0$ ).

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

$q$ 는  $[0,1]$  사이에 분포된 무작위 파라미터이고,  $q_0$ 는  $[0,1]$  사이의 값을 가지는 인자,  $S$ 는 수식(2)에서 주어진 확률분포에 따라 선택된 무작위 파라미터이다. 이것은 무조건 페로몬과 간선 길이의 연산에 의한 다음 노드 선택이 아니라 확률분포를 이용해서 다음 노드를 선택하는 과정이 추가됨으로써 국부 최적에 빠지기 쉬운 한계에서 어느 정도 벗어나고자 하고 있다.

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

지역갱신은 에이전트들이 방문한 각 간선들에 대해 아래의 지역 갱신 규칙을 적용시켜 페로몬의 양을 갱신시킨다.

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

$\rho$  ( $0 < \rho < 1$ )는 페로몬 지연 파라미터이고  $\Delta\tau(r,s) = \tau_0 = (n * L_{nn})^{-1}$ 는 초기 페로몬 양으로, 여기서  $L_{nn}$ 은 nearest neighbor heuristic에 의해 생성된 경로길이,  $n$ 은 노드 수이다. 전역갱신은 모든 에이전트들의 해당 경로 사이클을 완성 후에 수행되는데, 그 중 전역 최적 경로에 대해 다음 전역 갱신 규칙을 적용한다.

$$\tau(r,s) = (1 - \alpha) \cdot \tau(r,s) + \alpha \cdot \Delta\tau(r,s)$$

$$\text{where } \Delta\tau(r,s) = \begin{cases} (L_{gb})^{-1} & \text{if } (r,s) \in \text{global best tour} \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

$\alpha$  ( $0 < \alpha < 1$ )는 페로몬 지연 파라미터,  $\tau(r,s)$ 는

노드( $r$ )과 노드( $s$ ) 사이의 페로몬 양,  $L_{gb}$ 는 전역 최적 경로 길이이다. 그리고, 여기서  $\Delta\tau(r,s)$ 는 전역 최적 경로에 대한 강화값으로 전역 최적 경로이면  $(1/L_{gb})$ , 아니면 0으로 주어진다.

## 2.2 강화와 다양화 전략

강화(Intensification) 전략은 역사적으로 발견된 좋은 해의 장점을 이용하여 움직이게 하고, 다양화(Diversification)은 아직까지 탐색하지 않은 새로운 영역으로 다양하게 찾아가게 하는 것이다.

Randall[8]의 연구에서는 TSP 문제를 해결하기 위해 강화(intensification)와 다양화(diversification) 전략을 제시하였다. 이것은 파라미터  $\alpha$  값을 변경하는 4가지 전략을 통해 ACS의 성능을 평가하였다. Ruoying[9]의 연구에서는 다음 노드 선택시 해당 간선에 대해 이제까지 에이전트들이 방문한 방문 빈도수를 파라미터  $\alpha$ 에 적용한 T-ACS 모델을 제시하였다. 마찬가지로, Lee[10]의 연구에서도 에이전트들이 구성한 경로 사이클(Tour Cycle)에 대해 긍정적 강화를 받을 엘리트 경로를 구분하고, 구분된 경로 사이클에 대해 방문 횟수를 추가 전역 강화하는 방법과 각각의 에이전트들이 경로 사이클을 이루는 동안 방문한 모든 간선에 대한 방문 횟수를 상태전이 규칙에 적용해 에이전트들이 탐색 영역을 더욱 다양하게 검색한다. Kim[6]의 연구에서는 다음 노드 선택을 인접한 노드에 대한 거리로만 결정하지 않고 길이가  $w$ 인 부경로 정보를 이용해 다음 노드를 선택하는 방법을 제시하고 있다. Lee[7]의 연구에서는 전역 최적 경로의 길이가 주어진 반복 사이클 횟수 동안 더 이상 향상되지 못하면 국부최적에 빠졌다고 평가하고 상태전이 규칙에서 파라미터 감소를 통해 다음 노드를 선택하는 다양화 전략을 적용하고 있다. Lee[11]의 연구에서는 각 경로 사이클마다 우성과 열성 인자들로 구분하고 각각의 우성과 열성 인자들에 대해 전역 갱신 규칙에 기반해 생성된 모든 경로 사이클에 페로몬 값을 갱신시키는 방법을 적용하고 있다. Lee[12]의 연구에서는 각 경로 사이클에서 방문한 각 간선들이 최적해를 이루는데 얼마나 적합한지를 구분하는 기준으로 현재 단계의 모든 경로 사이클을 완성 후 각 간선에 방

문한 에이전트들의 방문 횟수를 강화값으로 표현하고, 그 강화값을 경로 사이클을 구성한 모든 간선의 페로몬 갱신에 추가하는 방법을 채택함으로써 방문 횟수가 많을수록 강화값을 높게 평가한다. Lee[13]의 연구에서는 이전 전역 최적 경로와 현재 전역 최적 경로의 중복 간선을 고려한 탐색 방법으로 두 전역 최적 경로에서 중복된 간선은 최적 경로로 구성될 가능성이 높으므로, 중복 간선의 페로몬을 강화시킨다.

본 논문에서는 이러한 다양한 강화전략과 다양화전략 중에서 Lee[7]와 Lee[13] 두 방법을 혼합한 탐색을 통해 강화와 다양화의 조화가 해당 알고리즘의 성능에 어떠한 영향을 미치는지 알아본다.

### III. 다양화전략과 강화전략을 혼합한 탐색 방법

강화는 수렴 속도를 빠르게 하고 다양화는 좋은 해를 찾도록 하는데 필요한 요소이다. 하지만, 강화를 강조하면 에이전트들은 국부 최적해에 수렴하게 되고, 다양화를 강조하면 부적절한 상태(지역 최적해)의 원인이 되기 때문에, 휴리스틱 탐색과정에 있어서, 특히 본 논문에서 적용되는 ACS 알고리즘의 성능을 향상시키는 중요한 요소 중의 하나로 강화와 다양화사이의 적절한 균형을 취하는 것이다.

본 논문에서 제안하는 개선된 ACS 알고리즘은 전역 최적 경로의 길이가 주어진 반복 사이클 횟수(iteration) 동안 더 이상 향상되지 못하면 국부최적에 빠졌다고 평가하고 상태전이 규칙에서의 파라미터( $\alpha, \beta$ )를 변경(감소,  $\alpha=0.6, \beta=1.1$ )하여 다음 노드를 선택한다. 그리고, 새로운 최적 경로를 탐색하게 되면 다시 기본 파라미터 값( $\alpha=1, \beta=2$ )으로 바꾼다. 이러한 노드 선택과 탐색 과정을 종료 조건까지 계속 수행한다. 이것은 전역 최적 경로 길이가 주어진 반복 횟수 동안 향상되지 않으면 다음 경로 탐색의 상태전이 규칙에서 파라미터( $\alpha, \beta$ )를 감소시킴으로서 다양화를 통한 경로 탐색이 가능하며 국부최적으로부터 벗어나는 효과가 있다. 즉, 탐색 공간을 확장하는 역할을 수행한다.

그리고, 이러한 다양화 전략을 통해 발견된 전역 최

적 경로에서 이전 전역 최적 경로와 현재 전역 최적 경로의 중복 간선을 고려한 탐색을 수행한다. 수행 방법은 두 전역 최적 경로에서 중복된 간선은 최적 경로로 구성될 가능성이 높으므로, 중복 간선의 페로몬을 강화시켜 최적 경로를 구성할 확률을 높이는 강화전략을 적용한다.

이때 강화전략은 수식(5)와 같이 전역 최적 경로 중에서 중복 간선에 대해서 페로몬을 강화한다. 여기서,  $E_d$ 는 중복 간선 강화 파라미터이다. [그림 1]은 다양화 전략과 강화전략이 적용된 개선된 ACS 알고리즘이다.

$$\tau(r, s) = ((1 - \alpha) \cdot \tau(r, s) + \alpha \cdot \Delta\tau(r, s)) * E_d$$

$$\text{where } \Delta\tau(r, s) = \begin{cases} (L_{gb})^{-1} & \text{if } (r, s) \in \text{global best tour} \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

```

1. /*초기화 단계*/
   For each edge(r,s) :=  $\tau_0$  End-for
   For k := 1 to m do
     Let  $r_{kl}$  be the starting node for agent k
      $J_k(r_{kl}) := \{1, \dots, n\} - r_{kl}$ 
     /*  $J_k(r_{kl})$  is the set of yet to be visited nodes for agent k in
        city  $r_{kl}$  */
      $r_k := r_{kl}$  /*  $r_k$  is the node where agent k is
        located */
   End-for

2. /* 상태전이 단계. The tour of agent k is stored in  $Tour_k$  */
   For i := 1 to n do
     If  $i < n$  then
       For k := 1 to  $s_k$  do
         for Cycle := 1 to  $C_i$  do
           if(not find  $L_{gb}$  in limit cycle)
             Choose the next node  $s_k$  according to Eq(1)
             and Eq(2) using changed parameter
             ( $\alpha = 0.6, \beta = 1.1$ )
             If  $i < n - 1$  Then
                $J_k(s_k) := J_k(r_k) - s_k$ 
             If  $i = n - 1$  Then
                $J_k(s_k) := J_k(r_k) - s_k + r_{kl}$ 
              $Tour_k(i) := (r_k, s_k)$ 
           else
             Choose the next node  $s_k$  according to Eq(1)
             and Eq(2) using default parameter

```

```

        ( $\alpha = 1, \beta = 2$ )
        If  $i < n - 1$  Then
             $J_k(s_k) := J_k(r_k) - s_k$ 
        If  $i = n - 1$  Then
             $J_k(s_k) := J_k(r_k) - s_k + r_{k1}$ 
             $Tour_k(i) := (r_k, s_k)$ 
        End-for
    Else
        For  $k := 1$  to  $m$  do
            /* all the agents go back to the initial node  $r_{k1}$  */
             $s := r_{k1}$ 
             $Tour_k(i) := (r_k, s_k)$ 
        End-for
    End-for

/* 지역갱신 단계, In this phase local updating is computed and  $\tau$ -values are updated using Eq(3) */
For  $k := 1$  to  $m$  do
     $\tau(r_k, s_k) := (1 - \rho)\tau(r_k, s_k) + \rho\tau$ 
     $r_k := s_k$  /*New node for agent  $k$  */
End-for

3. /* 전역갱신 단계, In this Phase delayed reinforcement is computed and  $\tau$ -values are updated */
For  $k := 1$  to  $m$  do
    Compute  $L_k$  /*  $L_k$  is the length of the tour done by agent  $k$  */
End-for

/*  $L_{global\_best}$  is the length of global best path by agent  $k$ 
 $E_{overlapping}$  are overlapping  $edge(r, s)$  in a global best path of a previous and the current */

Compute  $L_{global\_best}$ 
Compute  $E_{overlapping}$ 

/* Update edges belong to  $L_{global\_best}$  using Eq.4 */
/* Update edges belong to  $E_{overlapping}$  using Eq.5 */

For each global best  $edge(r, s)$ 
     $\tau(r_k, s_k) := (1 - \alpha) \cdot \tau(r_k, s_k) + \alpha(L_{best-iter})^{-1}$ 
End-for
If ( $E_{overlapping}$ )
    For each overlapping  $edge(r, s)$ 
         $\tau(r_k, s_k) := ((1 - \alpha) \cdot \tau(r_k, s_k) + \alpha(L_{best-iter})^{-1}) * E_d$ 
    /*  $E_d$  is the overlapping parameter */
    End-for
End-if

4. If (End_condition = True)
    then Print shortest of  $L_k$ 
    else goto Phase 2

```

그림 1. 다양화전략과 강화전략이 적용된 개선된 ACS 알고리즘

#### IV. 실험결과

제안된 알고리즘을 평가하기 위해, 실험을 위한 모델 집합들은 TSP 예제로 널리 알려진 TSPLIB[5]에서 추출하여 실험을 하였다. 제안된 다양화전략과 강화전략이 적용된 개선된 ACS 알고리즘에 사용된 기본 환경변수는  $\rho = 0.1, \alpha = 1, \beta = 2, q_0 = 0.95, time = 100, m = 10, E_d = 1.4, \Delta\tau(r, s) = \tau_0 = (n * L_m)^{-1}$ 로 설정하여 10회 반복 탐색하였다.

[표 1]은 ACS-3-opt 알고리즘[1], 부경로( $w$ )를 적용한 ACS-Subpath 알고리즘[6], [표 2]는 전역 최적 경로가 향상되지 않는 경우 반복 탐색 구간을 고려해 상태전이 규칙의 파라미터를 변경하는 ACS-Iter 알고리즘[7], 이전 전역 최적 경로와 현재 전역 최적 경로의 중복간선의 페로몬을 강화시켜 탐색하는 ACS-Global-Overlap 알고리즘[13]과의 비교 실험결과이다.

마지막 열의 Improved Rate의 best와 Average-Best는 기존 방법과 비교하여 제안된 알고리즘이 탐색한 경로의 개선된 비율을 수식(6)과 같이 평가하여 나타내었다.

$$\begin{aligned}
 \text{ImprovedRate}_{\text{best}} &= 100 - \frac{\text{Best}^* - \text{Known\_Best}}{\text{Best} - \text{Known\_Best}} * 100 \\
 \text{ImprovedRate}_{\text{average-best}} &= 100 - \frac{\text{Average\_Best}^* - \text{Known\_Best}}{\text{Average\_Best} - \text{Known\_Best}} * 100
 \end{aligned}
 \tag{6}$$

[표 1]은 제안된 다양화전략과 강화전략이 적용된 개선된 ACS 알고리즘, ACS-3-opt 알고리즘[1], 노드 선택을 인접한 노드에 대한 거리로만 결정하지 않고 길이가  $w$ 인 부경로 정보를 이용해 다음 노드를 선택하는 ACS-Subpath 알고리즘[6]과의 비교 실험결과이다. ACS-3-opt 알고리즘의 실험 결과를 살펴보면, 제안된 알고리즘이 최적 경로 탐색에서는 모든 집합에서 우수한 성능을 보여주며, 평균 최적 경로 탐색에서는 단지 1개의 집합(vm1084)에서 성능 수치 차이가 거의 없을 정도로 약간 떨어질 뿐, 대부분의 집합에서 성능이 우수함을 보여준다.

표 1. 제안된 알고리즘과 ACS-3-opt 알고리즘[1], ACS-Subpath 알고리즘[6]과의 비교

TSPLIB	Known Best	ACS-3-opt[1] (A)		ACS-Subpath[6] (B)		Proposed (C)		Improved Rate(%)(A : C)		Improved Rate(%)(B : C)	
		Best	Average -Best	Best	Average -Best	Best	Average -Best	Best	Average -Best	Best	Average -Best
eil51	426	426	426.0	426	426.0	426	426.0	0.0	0.0	0.0	0.0
d198	15780	15780	15780.0	15780	15780.0	15780	15780.0	0.0	0.0	0.0	0.0
a280	2579	2579	2579.0	2579	2579.0	2579	2579.0	0.0	0.0	0.0	0.0
pcb442	50778	50778	50876.0	50778	50845.0	50778	50805.5	0.0	71.94	0.0	58.96
att532	27686	27686	27701.4	27686	27699.3	27686	27695.5	0.0	38.31	0.0	28.57
rat783	8806	8806	8826.6	8806	8817.7	8806	8812.8	0.0	66.99	0.0	41.88
pr1002	259045	259045	259487.2	259045	259580.5	259045	259347.2	0.0	31.66	0.0	43.57
u1060	224094	224257	224496.3	224238	224558.1	224181	224318.7	46.63	44.15	39.58	51.58
vm1084	239297	239297	239417.7	239349	239484.4	239297	239419.9	0.0	-1.82	100.00	34.42
pcb1173	56892	56893	56998.1	56901	56991.1	56892	56980.0	100.00	17.06	100.00	11.20
d1291	50801	50801	50843.5	50801	50856.5	50801	50840.9	0.0	6.12	0.0	28.11
r11304	252948	252948	253413.9	252948	253296.0	252948	253296.1	0.0	25.28	0.0	-0.03
r11323	270199	270547	270935.3	270755	270882.9	270291	270708.6	73.56	30.79	83.45	25.49
nrw1379	56638	56697	56791.9	56695	56754.6	56651	56730.9	77.97	39.64	77.19	20.33
u1432	152970	153284	153464.1	153265	153599.2	153201	153415.8	26.43	9.78	21.69	29.15
fl1577	22249	22254	22322.2	22254	22313.4	22253	22318.0	20.00	5.74	20.00	-7.14
d1655	62128	62149	62273.5	62128	62231.0	62128	62263.0	100.00	7.22	0.0	-31.07
vm1748	336556	336834	337164.7	336925	337232.2	336651	337127.8	65.83	6.06	74.25	15.44
u1817	57201	57269	57509.5	57280	57441.9	57234	57385.1	51.47	40.32	58.23	23.58

ACS-Subpath 알고리즘의 실험 결과를 살펴보면, 제안된 알고리즘이 최적 경로 탐색에서는 모든 집합에서 우수한 성능을 보여주며, 평균 최적 경로 탐색에서는 3개의 집합(r11304, fl1577, d1655)에서 성능 수치 차이가 거의 없을 정도로 약간 떨어질 뿐, 대부분의 집합에서 성능이 우수함을 보여준다. 특히 r11304 집합에서는 성능 차이가 없을 정도이다. 이때 실험에 사용된 부경로 환경변수  $w=3$ , 나머지 환경변수는 제안 알고리즘과 동일하다.

[표 2]는 제안된 다양화전략과 강화전략이 적용된 개선된 ACS 알고리즘, 전역 최적 경로가 향상되지 않는 경우 반복 탐색 구간을 고려해 상태전이 규칙의 파라미터를 변경하는 ACS-Iter 알고리즘[7], 이전 전역 최적 경로와 현재 전역 최적 경로의 중복 간선의 폐로문을 강화시켜 탐색하는 ACS-Global-Overlap 알고리즘[13]과의 비교 실험결과이다.

ACS-Iter 알고리즘은 주어진 반복 사이클 횟수 (iteration) 동안 전역 최적 경로의 길이가 향상되지 않

으면 국부최적에 빠졌다고 평가하고, 상태전이 규칙에서의 파라미터( $\alpha=1, \beta=2$ )를 변경( $\alpha=0.6, \beta=1.1$ )하여 다음 노드를 선택한다. 그 외 실험 환경변수는 동일하게 적용하였다. 실험 결과를 살펴보면, 제안된 알고리즘이 최적 경로 탐색에서는 1개의 집합(r11323)에서 성능이 조금 떨어지고, 평균 최적 경로 탐색에서는 2개의 집합(vm1084, u1817)에서 성능 수치 차이가 거의 없을 정도로 약간 떨어질 뿐, 대부분의 집합에서 성능이 우수함을 보여준다.

ACS-Global-Overlap 알고리즘의 실험 결과를 살펴보면, 제안된 알고리즘이 최적 경로 탐색에서는 1개의 집합(u1060)에서 성능이 다소 떨어지고, 평균 최적 경로 탐색에서는 6개의 집합(att532, vm1084, nrw1379, fl1577, d1655, vm1748)에서 성능 수치 차이가 거의 없을 정도로 약간 떨어질 뿐, 대부분의 집합에서 성능이 우수함을 보여준다. 이때 ACS-Global-Overlap 알고리즘에서 사용된 중복 간선 강화 파라미터는  $E_d=0.9$ 로 설정하였다.

표 2. 제안된 알고리즘과 ACS-Iter 알고리즘[7], ACS-Global-Overlap 알고리즘[13]과의 비교

TSPLIB	Known Best	ACS-Iter[7] (A)		ACS-Global-Overlap[13] (B)		Proposed (C)		Improved Rate%(A : C)		Improved Rate%(B : C)	
		Best	Average -Best	Best	Average -Best	Best	Average -Best	Best	Average -Best	Best	Average -Best
eil51	426	426	426.0	426	426.0	426	426.0	0.0	0.0	0.0	0.0
d198	15780	15780	15780.0	15780	15780.0	15780	15780.0	0.0	0.0	0.0	0.0
a280	2579	2579	2579.0	2579	2579.0	2579	2579.0	0.0	0.0	0.0	0.0
pcb442	50778	50778	50860.1	50778	50806.5	50778	50805.5	0.0	66.50	0.0	3.51
att532	27686	27686	27702.5	27686	27691.5	27686	27695.5	0.0	42.42	0.0	-72.73
rat783	8806	8806	8813.2	8806	8813.5	8806	8812.8	0.0	5.56	0.0	9.33
pr1002	259045	259045	259563.0	259045	259459.9	259045	259347.2	0.0	41.66	0.0	27.16
u1060	224094	224241	224629.5	224154	224468.0	224181	224318.7	40.82	58.04	-45.00	39.92
vm1084	239297	239297	239399.4	239297	239419.5	239297	239419.9	0.0	-20.02	0.0	-0.33
pcb1173	56892	56893	56987.3	56892	56995.0	56892	56980.0	100.00	7.66	0.0	14.56
d1291	50801	50801	50841.8	50801	50844.1	50801	50840.9	0.0	2.21	0.0	7.42
r11304	252948	252948	253406.5	252948	253314.6	252948	253296.1	0.0	24.08	0.0	5.05
r11323	270199	270254	270758.8	270450	270751.2	270291	270708.6	-67.27	8.97	63.35	7.71
nrw1379	56638	56688	56751.4	56685	56726.2	56651	56730.9	74.00	18.08	72.34	-5.33
u1432	152970	153260	153457.7	153236	153428.8	153201	153415.8	20.34	8.59	13.16	2.83
fl1577	22249	22255	22326.3	22254	22279.8	22253	22318.0	33.33	10.74	20.00	-124.03
d1655	62128	62220	62398.6	62128	62240.9	62128	62263.0	100.00	50.11	0.0	-19.57
vm1748	336556	336834	337192.9	336735	336967.5	336651	337127.8	65.83	10.22	46.93	-38.96
u1817	57201	57251	57379.1	57263	57442.0	57234	57385.1	34.00	-3.37	46.77	23.61

V. 결론

본 논문에서는 다양화전략과 강화전략을 혼합한 개선된 ACS 알고리즘을 제안하였다. 다양화 전략으로 전역 최적 경로의 길이가 주어진 반복 사이클 횟수 동안 더 이상 향상되지 못하면 국부최적에 빠졌다고 평가하고 상태전이 규칙에서 파라미터 감소를 통해 다음 노드를 탐색하고, 이러한 다양화 전략을 통해 발견된 전역 최적 경로에서 이전 전역 최적 경로와 현재 전역 최적 경로의 중복 간선에 대해 페로몬을 강화시키는 강화전략을 수행하였다. 제안된 방법은 기존 ACS-3-opt 알고리즘, ACS-Subpath 알고리즘, ACS-Iter 알고리즘, ACS-Global-Overlap 알고리즘에 비해 최적 경로 탐색 및 평균 최적 경로 탐색의 성능이 우수함을 보여 주었다.

향후 연구에서는 일반적으로 최적화 탐색 문제에서 강화와 다양화의 조화는 중요한 요소로 인식되는 만큼, ACS를 이용한 최적화 탐색에서의 강화와 다양화의 조

화를 이루는 방법에 대한 많은 연구가 필요하다. 특히 각 알고리즘의 환경변수 설정에 관한 연구가 제대로 이루어지지 않고 있어서 환경 변수 설정에 관한 연구가 필요하다.

참 고 문 헌

[1] 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, pp.53-66, 1997.  
 [2] M. Dorigo, L. M. Gambardella, M. Middendorf and T. Stutzle, "Ant Colony Optimization," IEEE Transactions on Evolutionary Computation, Vol.6, No.4, 2002.  
 [3] M. Dorigo and C. Blum. "Ant colony

optimization theory: A survey," Theoretical Computer Science, 344(2-3), pp.243-278, 2005.

[4] M. Dorigo, M. Birattari, and T. Stutzle, "Ant Colony Optimization - Artificial Ants as a Computational Intelligence Technique," IEEE Computational Intelligence Magazine, Vol.1, No.4, pp.28-39, 2006.

[5] <http://elib.zib.de/pub/Packages/mp-testdata/tsp/tsplib/tsplib.html>

[6] I. K Kim and M. Y. Youn, "Improved Ant Colony System for the Traveling Salesman Problem," The KIPS transactions. Part B, Vol.12, No.7, pp.823-828, 2005.

[7] S. G. Lee, "Ant Colony System Considering the Iteration Search Frequency that the Global Optimal Path does not Improved," Journal of The Korea Society of Computer and Information, Vol.14, No.1, pp.9-15, 2009.

[8] M. Randall and E. Tonkes, "Intensification and diversification strategies in ant colony system," Complexity International, Vol.9, 2002.

[9] R. Sun, S. Tatsumi and G. Zhao, "Multiagent reinforcement learning method with an improved ant colony system," 2001 IEEE International Conference Systems, Man, and Cybernetics, pp.1612-1617, 2001.

[10] S. G Lee and T. C Chung, "Performance Improvement of Cooperating Agents through Balance between Intensification and Diversification," The IEEK journals : CI, Vol.40, No.6, pp.87-94, 2003.

[11] S. G Lee, T. U Jung and T. C Chung, "Improved Ant Agents System by the Dynamic Parameter Decision," Proceedings of IEEE International Conference on FUZZ-IEEE 2001, pp.666-669, 2001

[12] S. G Lee and T. C Chung, "A Study about Additional Reinforcement in Local Updating and

Global Updating for Efficient Path Search in Ant Colony System," The KIPS Transactions : Part B, pp.237-242, 2003.

[13] S. G. Lee and M. J. Kang, "Ant Colony System for solving the traveling Salesman Problem Considering the Overlapping Edge of Global Best Path," Journal of The Korea Society of Computer and Information, Vol.16, No.3, 2011. In press.

저 자 소 개

이 승 관 (Seung-Gwan Lee) 정회원



- 1997년 2월 : 경희대학교 전자계산공학과 공학사
  - 1999년 2월 : 경희대학교 전자계산공학과 공학석사
  - 2004년 2월 : 경희대학교 전자계산공학과 공학박사
  - 2004년 3월 ~ 2006년 8월 : 가톨릭대학교 컴퓨터정보공학부 강의 전임 교수
  - 2006년 9월 ~ 현재 : 경희대학교 후마니타스칼리지 조교수
- <관심분야> : 인공지능, 에이전트, 최적화, 영상처리

최 진 혁 (Jin-Hyuk Choi) 정회원



- 1990년 2월 : 경희대학교 수학과 이학사
  - 1992년 2월 : 경희대학교 수학과 이학석사
  - 2003년 8월 : 경희대학교 수학과 이학박사
  - 2004년 9월 ~ 2005년 3월 : 경희대학교 강의 전임 교수
  - 2005년 4월 ~ 현재 : 경희대학교 후마니타스칼리지 조교수
- <관심분야> : 리만기하학, 영상처리, 최적화