

# 멀티캐스트 라우팅을 위한 Ant Colony System 설계에 대한 연구

이 성 근<sup>†</sup> · 한 치 근<sup>††</sup>

## 요 약

조합 최적화 문제를 풀기 위한 개미 알고리즘(Ant Algorithm)은 실제 개미 집단의 행동을 모방하여 만들어진 것이다. Ant Colony System (ACS)은 여러 유형의 개미 알고리즘 중 비교적 최근에 소개된 것이다. ACS의 설계를 위해 순회 외판원 문제(Traveling Salesman Problem, TSP)를 사용하여 실험을 수행하였다. ACS를 다양한 조합 최적화 문제에 적용할 때 순회 외판원 문제에 사용된 ACS의 파라미터와 전략을 사용하고 있다. 본 논문에서는 조합 최적화 문제들 중 하나인 멀티캐스팅 라우팅 문제를 해결하기 위해 ACS를 이용하였다. 멀티캐스트 라우팅은 데이터를 하나의 송신자에서 여러 수신자들로 보내기 때문에 모든 노드를 포함하는 순회 외판원 문제와는 속성이 다르고, 송신자에서 각 수신자에 하나의 최단경로를 설정하는 문제와도 다른 속성을 지니고 있다. 본 논문에서는 멀티캐스트 라우팅에 ACS를 적용하기 위해 알고리즘의 동작을 수정하고, 수정한 ACS의 성능을 향상시키기 위한 최적의 전략과 파라미터를 설계한다.

## A Study of Ant Colony System Design for Multicast Routing

Sung-Geun Lee<sup>†</sup> · Chi-Geun Han<sup>††</sup>

## ABSTRACT

Ant Algorithm is used to find the solution of Combinatorial Optimization Problems. Real ants are capable of finding the shortest path from a food source to their nest without using visual informations. This behavior of real ants has inspired ant algorithm. There are various versions of Ant Algorithm. Ant Colony System (ACS) is introduced lately. ACS is applied to the Traveling Salesman Problem (TSP) for verifying the availability of ACS and evaluating the performance of ACS. ACS finds a good solution for TSP. When ACS is applied to different Combinatorial Optimization Problems, ACS uses the same parameters and strategies that were used for TSP. In this paper, ACS is applied to the Multicast Routing Problem. This Problem is to find the paths from a source to all destination nodes. This definition differs from that of TSP and differs from finding paths which are the shortest paths from source node to each destination nodes. We introduce parameters and strategies of ACS for Multicasting Routing Problem.

**키워드 :** 개미 알고리즘(Ant Algorithm), 멀티캐스트 라우팅(Multicast Routing), Ant Colony System, Steiner Tree

## 1. 서 론

현재 사용되는 많은 멀티미디어 응용프로그램은 통신망을 통하여 하나의 송신자로부터 여러 개의 수신자들에게 데이터를 전송하는 멀티캐스팅을 사용하고 있으며, 멀티캐스팅을 지원하는 응용프로그램은 앞으로 계속하여 증가할 것이다. 멀티캐스팅을 효과적으로 지원하기 위해서는 최소 비용을 갖는 멀티캐스트 트리를 결정해야 한다[1]. 멀티캐스트 트리를 결정하는 문제는 NP-complete로써 Steiner tree 문제와 동일시된다. Steiner tree 문제를 풀기 위한 좋은 성능의 휴리스틱 알고리즘은 이미 제안되어 있고[2, 3], 개미 알고리즘(ant algorithm)을 이용한 연구도 이미 제안되었다[4, 5].

개미 알고리즘은 실제 개미들이 자신들의 둉지에서 먹이

가 있는 곳까지 시각적인 정보 없이 폐로문이라는 화학적인 정보만을 이용하여 최단경로를 찾는 것에 기초하여 만들어진 것이다[6]. 개미 알고리즘은 사용되는 전략과 적용되는 규칙에 따라 다양한 유형이 존재하며, 각 유형에 따른 성능 평가를 위해 TSP에 적용하였다[7, 8]. 개미 알고리즘은 실험에서 사용되는 전략과 파라미터에 따라 많은 성능의 차를 보이고 있다. 하지만, 멀티캐스팅 문제에 개미 알고리즘을 적용한 기존의 논문에서는 사용된 전략과 파라미터 값에 대한 설명이 부족하며 파라미터가 멀티캐스트 트리에 미치는 영향도 설명되어 있지 않다.

따라서 본 논문에서는 멀티캐스트 라우팅 문제에 비교적 최근에 개발된 Ant Colony System(ACS)를 적용한다. ACS의 동작을 멀티캐스트 라우팅 문제에 맞도록 변경하고, 멀티캐스팅 문제에 적합한 파라미터와 전략을 파악하는 것이 본 논문의 목표이다.

논문의 구성을 다음과 같다. 2장에서는 멀티캐스트 라우

† 준 회 원 : 청강문화산업대학 겸임교수  
 †† 정 회 원 : 경희대학교 컴퓨터공학과 교수  
 논문접수 : 2003년 5월 21일, 심사완료 : 2003년 9월 30일

팅 문제를 정의하고, 3장에서는 ACS를 설명한다. 4장에서는 멀티캐스트 라우팅 문제를 위한 ACS의 동작 원리를 설명한다. 5장에서는 멀티캐스트 라우팅을 위한 ACS의 전략과 파라미터에 대한 실험을 하고, 마지막으로 6장에서 결론을 맺는다.

## 2. 멀티캐스트 라우팅 문제 정의

네트워크의 모델은 무향, 연결, 가중 그래프인  $G = (V, E)$ 로 표현한다.  $V = \{1, \dots, n\}$ 는 노드의 집합으로 한다. 에지의 집합을  $E$ 라 하고, 각 에지  $(i, j)$ 에 할당되어 있는 비용을  $c_{ij}$ 로 한다.  $Q(Q \subseteq V)$ 는 기본노드로 서비스를 요청하는 수신자 노드들과 송신자 노드의 집합이다. 이 때,  $Q$ 를 포함하는 최소비용의 서브 트리  $T$ 를 구하는 것이 멀티캐스트 라우팅 문제이다.

## 3. Ant Colony System(ACS)

ACS는 개미 알고리즘 중 비교적 최근에 발표된 것으로 [8], 본 논문에서 멀티캐스트 라우팅에 사용할 기본적인 알고리즘이다. ACS는 상태 전이 규칙(state transition rule), 전역 페로몬 갱신 규칙(global pheromone updating rule)과 지역 페로몬 갱신 규칙(local pheromone updating rule)으로 구성된다.

### 3.1 상태 전이 규칙

개미가 현재의 노드에서 다음에 이동할 노드를 선택할 때 사용하는 규칙이다. 우선 노드  $r$ 에 위치한 개미  $k$ 는 현재의 노드에서 이동 가능한 모든 노드들에 식 (1)을 사용하여 확률값  $p_k(r, s)$ 를 할당한다. 할당된 확률값을 바탕으로 노드를 선택하는 방법은 두 가지이다. 하나는 탐색(exploration)으로 노드들 중에 확률값이 가장 큰 것을 선택하는 방법이다. 다른 하나는 룰렛 휠 방식을 이용하여 이동 가능한 노드들 중 임의로 하나의 노드를 선택하는 것으로 탐험(exploration)이라 한다. 탐험의 경우에도 룰렛 휠 방식을 사용하기 때문에 확률값이 큰 노드가 다른 노드에 비해 선택될 가능성이 높다.

탐험과 탐색을 선택하는 방법은 다음과 같다. 상수  $q_0$ 는 0과 1사이의 고정값이고, 변수  $q$ 는 균등분포(uniform distribution)를 따르는 0과 1사이의 임의의 수로 상태 전이 규칙을 실행할 때마다 변하는 값이다.  $q \leq q_0$ 이면 탐색을 하게 되고,  $q > q_0$ 이면 탐험을 하게 된다.

$$p_k(r, s) = \begin{cases} \frac{[\tau(r, s)] \times [\eta(r, s)]^\beta}{\sum_{u \in f_s(r)} [\tau(r, u)] \times [\eta(r, u)]^\beta}, & \text{if } s \in J_k(r) \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

식 (1)에서  $J_k(r)$ 은 노드  $r$ 에 있는 개미  $k$ 가 이동할 수 있는 노드들의 집합을 나타낸다.  $\tau(r, s)$ 는 에지  $(r, s)$ 의 페로몬 양을 나타내고,  $\eta(r, s)$ 는  $c_{r,s}$ 의 역수이다[8].  $\beta$ 는 비용과 페로몬 사이의 중요도를 반영하는 파라미터로,  $\beta$ 의 값이 커지면 확률값에 에지 비용의 영향이 커지게 된다.

### 3.2 전역 페로몬 갱신 규칙

모든 개미가 각자의 경로를 완성한 후, 경로들 중에서 최소 비용을 갖는 경로를 찾아 경로에 속한 모든 에지의 페로몬 양을 증가시키기 위해 사용하는 규칙이다. 최단 경로에 속한 에지들의 페로몬 양은 식 (2)에 의해 조정된다.

$$\tau(r, s) \leftarrow (1 - \alpha) \times \tau(r, s) + \alpha \times \Delta\tau(r, s) \quad (2)$$

식 (2)에서  $\alpha$ 는 페로몬의 증발율을 나타내는 파라미터( $0 < \alpha < 1$ )이고,  $\Delta\tau(r, s)$ 는 최단경로 총비용의 역수이다[8].

### 3.3 지역 페로몬 갱신 규칙

개미가 에지를 방문한 후 방문한 에지의 페로몬 양을 변화시키기 위해 적용하는 규칙으로 아래의 수식이 적용된다.

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

$\rho$ 는 페로몬의 증발율을 나타내는 파라미터이다( $0 < \rho < 1$ ).  $\Delta\tau(r, s)$ 의 값을 선택할 때는 다음의 세 가지 전략이 가능하다[8].

첫 번째 전략은 강화학습 문제의 알고리즘에 사용되는 Q-learning과 유사한 방법이다[9]. 에이전트(agent)가 각각의 가능한 상태와 그 상태 중 하나를 선택했을 때 처하게 되는 다음 상태를 동시에 평가하여 최선의 선택을 하는 것이다. 이 경우  $\Delta\tau(r, s)$ 는 다음과 같이 설정한다.

$$\Delta\tau(r, s) = \max_{z \in J_s(s)} \tau(s, z)$$

이 전략을 Ant-Q라고 한다[8, 10].

두 번째 전략은  $\Delta\tau(r, s)$ 의 값을 초기의 페로몬 값으로 설정하는 것으로 단순 ACS(simple ACS)라고 한다[8].

세 번째 전략은  $\Delta\tau(r, s)$ 의 값을 0으로 설정하는 것이다[8].

### 3.4 ACS의 동작

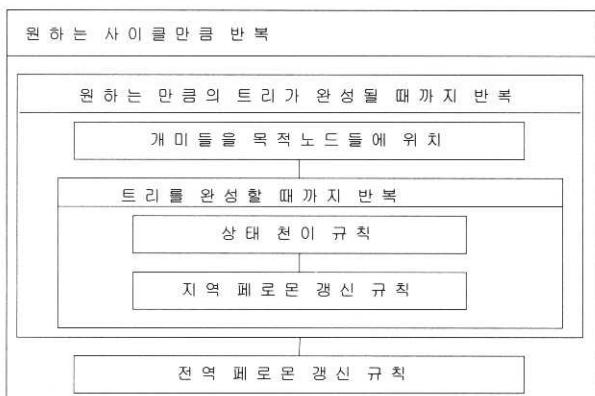
우선 개미들을 임의의 규칙에 따라 노드들에 위치시킨다. 개미들이 자신의 결과를 만들어 낼 때까지 상태 전이 규칙에 따라 에지를 선택하고, 선택된 에지에 지역 페로몬 갱신 규칙을 적용하여 페로몬의 양을 갱신하는 것을 반복하게 된다. 마지막으로 여러 개의 결과들 중에 가장 좋은 결과에 속한 에지의 페로몬 양을 전역 페로몬 갱신 규칙을 이용하여 갱신한다. 위의 과정을 원하는 싸이클만큼 반복하게 된다.

#### 4. 멀티캐스트 라우팅을 위한 ACS

TSP와 멀티캐스트 라우팅 문제는 특성이 다르므로 TSP에 적용한 ACS를 그대로 사용할 수 없다. 본 논문에서 ACS의 동작은 다음과 같다.

TSP에서는 모든 노드에 개미가 한 마리씩 위치하였으나, 멀티캐스트 라우팅 문제에서는 개미들은 수신자 노드들에만 위치한다. 상태 전이 규칙을 이용하여 개미들은 노드를 선택하여 이동하게 되는데, 경로 상에 싸이클을 만들지 않기 위해 자신이 방문한 노드는 타부 목록에 저장한다. 개미들은 송신자 노드에 도착을 하거나 다른 개미가 이미 방문한 노드를 방문하게 될 경우 동작을 멈추게 된다. 이러한 동작에 따라 멀티캐스트 라우팅을 위한 ACS에서는 TSP에서처럼 개미 한 마리가 하나의 투어를 완성하는 것이 아니라 여러 마리의 개미가 하나의 멀티캐스트 트리를 완성하게 된다. 그러므로 전역 폐로몬 갱신 규칙을 적용하기 위해 만들고자 하는 멀티캐스트 트리의 수만큼의 개미 집합을 하나의 싸이클 안에서 이용하여야만 한다.

아래 그림은 멀티캐스팅을 위한 ACS의 동작을 나타내는 흐름도이다.



(그림 1) 흐름도

#### 5. 실험

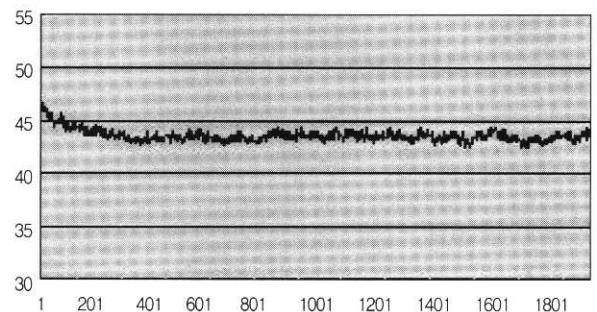
실험은 노드의 수가 100개이고, 각 노드에 연결된 에지 수가 30개이며, 각 에지는 1과 10사이의 비용을 갖는 그래프를 임의로 10개를 생성하여 실행하였다. 각 실험은 각 그래프에서 ACS의 파라미터의 값과 지역 폐로몬 갱신 규칙에 사용되는 전략을 변화시키면서 수행하였다. 각 실험의 차트에서 세로축은 멀티캐스트 트리의 총비용이고, 가로축은 싸이클의 진행을 나타낸다.

##### 5.1 지역 폐로몬 갱신 규칙의 전략

본 실험은 ACS의 지역 폐로몬 갱신 규칙의 전략 중 멀티캐스트 라우팅 문제에 효율적인 전략을 알아보는 것이다. TSP에서는 Ant-Q와 단순 ACS가 실험적으로 좋은 것으로

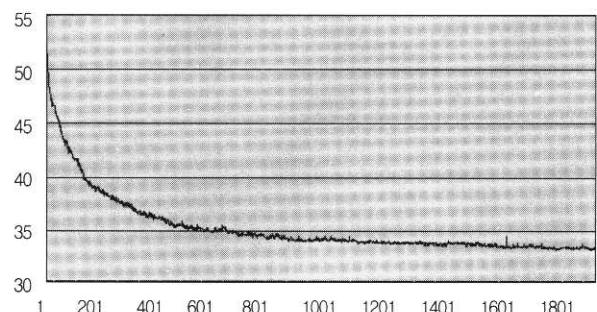
확인되었다[8]. 각 실험에서 사용되는 파라미터는 TSP에 적용된 ACS의 파라미터 값을 그대로 사용하기 위해, 식 (1)의 파라미터  $\beta = 2$ , 식 (2)의 증발율 파라미터  $\alpha = 0.1$ , 식 (3)의 증발율 파라미터  $\rho = 0.1$ , 상수  $q_0 = 0.9$ 로 하고, 초기 폐로몬은  $\tau_0 = (n \times \lambda)^{-1}$ 로 하였다. 여기서  $n$ 은 노드의 수이고,  $\lambda$ 는 일반적인 휴리스틱으로 구한 트리의 비용이다. 하나의 싸이클에서 생성되는 멀티캐스트 트리의 수는 10개로 하였다.

(그림 2)는 지역 폐로몬 갱신 규칙에 단순 ACS를 적용한 경우 트리 비용의 변화를 나타낸 것이다.



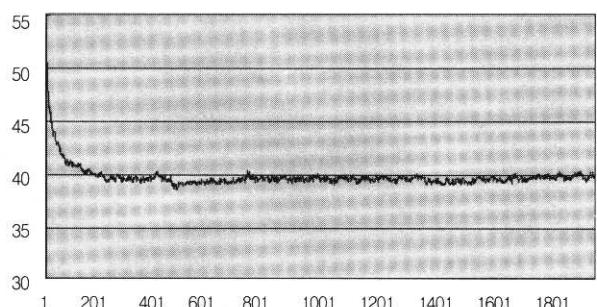
(그림 2) 단순 ACS 전략을 적용했을 때 트리 비용의 변화

(그림 3)은 지역 폐로몬 갱신 규칙에서 단순 ACS 대신  $\Delta\tau(r, s)$ 의 값으로 0을 설정하는 전략을 적용한 경우 트리 비용의 변화를 나타낸 것이다.



(그림 3)  $\Delta\tau(r, s)=0$ 으로 하는 전략을 적용했을 때 트리 비용의 변화

(그림 4)는 지역 폐로몬 갱신 규칙에서 Ant-Q 전략을 적용한 경우 트리 비용의 변화이다.



(그림 4) Ant-Q 전략을 적용했을 때 트리 비용의 변화

위의 3개의 실험 결과를 통해 보면 멀티캐스트 라우팅 문제에 대한 ACS에서 지역 폐로몬 갱신 규칙의 전략으로 Ant-Q와 단순 ACS보다  $\Delta\tau(r,s)$ 의 값으로 0을 설정하는 것이 차트의 진동도 작고 싸이클이 반복될수록 점점 좋은 결과값을 보이는 것을 알 수 있다.  $\Delta\tau(r,s)$ 의 값으로 0을 설정하는 전략은 세 개의 전략 중에 한 번 선택된 에지의 폐로몬 값을 가장 많이 감소시키는 전략으로 트리의 구성 을 좀 더 다양하게 하는 결과를 초래하게 된다.

<표 1>은 각 그래프에서 전략을 실험하는 동안 나온 트리 중 최소 비용의 평균값이다.

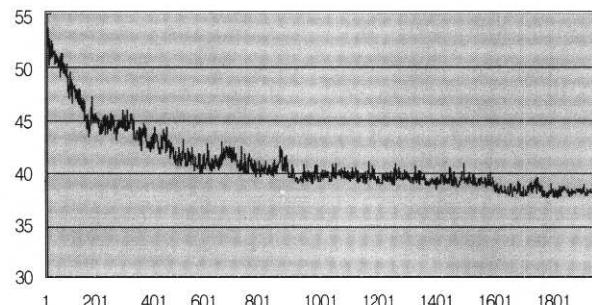
<표 1> 전략에 따른 최소 비용 트리의 평균

전략	평균값
단순 ACS	35.41
$\Delta\tau(r,s) = 0$	32.69
Ant-Q	33.79

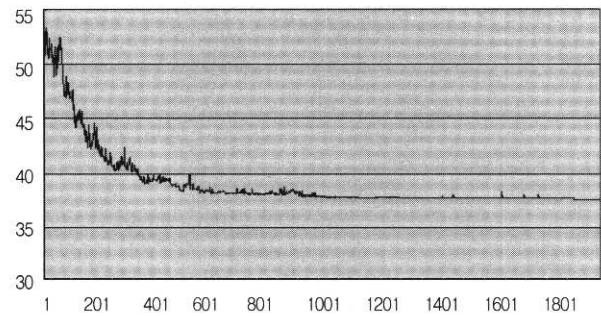
<표 1>을 통해  $\Delta\tau(r,s) = 0$ 의 전략에 의해 생성된 트리의 최소 비용 트리의 평균도 가장 우수하다는 것을 알 수 있다.

5.2 전역 폐로몬 갱신 규칙을 적용하기 위한 트리의 개수 본 실험은 전역 폐로몬 갱신 규칙을 적용하기 위한 트리의 개수( $\Gamma$ )를 알아보기 위한 것이다. 순회 외판원 문제의 경우 하나의 싸이클에서 생성되는  $\Gamma$ 가 그래프 노드의 수와 동일하기 때문에 고려의 대상이 되지 않지만 멀티캐스트 라우팅의 경우 하나의 싸이클에서 생성되는  $\Gamma$ 도 실험의 성능에 영향을 미칠 수 있는 파라미터이다. (그림 5)는  $\Gamma$ 를 10개로 하였고, (그림 6)은  $\Gamma$ 를 20개로 하였으며, 나머지 파라미터는 5.1절과 동일하게 설정하였다. 그리고, 지역 폐로몬 갱신 규칙의 전략은 앞의 실험에서 좋은 결과를 생성해내는  $\Delta\tau(r,s) = 0$ 로 하였다.

(그림 5)는 (그림 6)에 비해 진동은 심하지만 싸이클이 반복될수록 총비용이 감소한다. (그림 6)은 진동은 없으나 초기에 수렴하거나 총비용의 감소가 매우 느리게 진행되는 것을 보이고 있다.



(그림 5)  $\Gamma = 10$ 으로 하였을 경우 트리 비용의 변화



(그림 6)  $\Gamma = 20$ 으로 하였을 경우 트리 비용의 변화

<표 2>는 그래프 10개를 생성하여 각 그래프마다 10번씩 실험하여 나온 최소비용의 값을 평균한 것이다.

<표 2> 최소 비용 트리의 평균

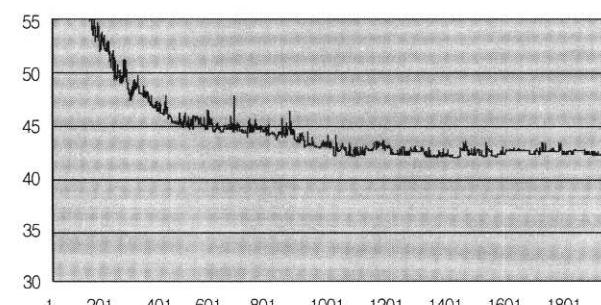
$\Gamma$	10	20
1	36.90	37.60
2	31.70	32.60
3	30.10	32.10
4	31.60	33.20
5	33.90	34.30
6	32.00	32.40
7	30.10	30.80
8	33.40	34.00
9	34.50	36.10
10	32.70	34.80
평균	32.69	33.79

모든 그래프에서  $\Gamma$ 가 10개인 것이 더욱 좋은 결과를 보여주고 있다.

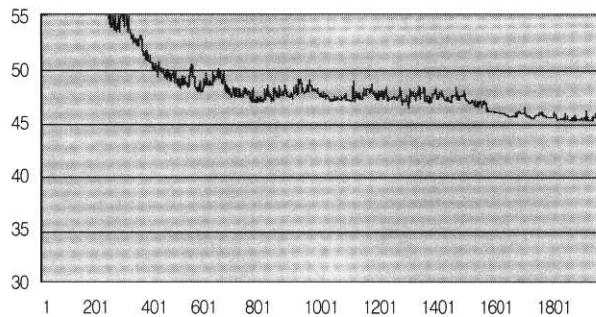
### 5.3 폐로몬의 증발율의 변화

본 실험은 지역 폐로몬 갱신 규칙과 전역 폐로몬 갱신 규칙에 적용되는 폐로몬의 증발율을 변화시켜 실시한 것이다.

파라미터와 전략은 (그림 5)의 실험과 동일하다. (그림 7)은 각각의 증발율을 0.5로 하고, (그림 8)은 각각의 증발율을 0.9로 하였다.



(그림 7) 증발율을 0.5로 하였을 경우 트리 비용의 변화



(그림 8) 증발율을 0.9로 하였을 경우 트리 비용의 변화

(그림 5)와 (그림 7), (그림 8)을 비교해 보면 폐로몬의 증발율이 높을수록 결과가 좋지 않은 것을 알 수 있다. 개미 알고리즘에서 이동할 노드를 선택할 때 사용하는 값은 에지의 비용과 에지의 폐로몬 값뿐이다. 여기서 비용은 변하지 않고 폐로몬의 값만 변하게 되는데, 폐로몬의 증발율이 높다는 것은 알고리즘의 수행 과정에서 얻어진 지식을 많이 사용하지 않은 것이 된다.

<표 3>은 10개의 그래프에서 각각 10번씩 실험하여 만들어진 트리 중 최소비용의 트리 값을 평균한 것이다. 실험에서 사용된 10개의 모든 그래프에서 폐로몬의 증발율이 증가할수록 나쁜 결과가 관찰되었다.

&lt;표 3&gt; 최소 비용 트리의 평균

증발율 그래프 번호	0.1	0.5	0.9
1	36.90	41.40	45.00
2	31.70	35.20	37.70
3	30.10	34.50	38.50
4	31.60	36.70	41.50
5	33.90	37.10	40.20
6	32.00	34.90	37.40
7	30.10	34.30	38.20
8	33.40	36.00	39.30
9	34.50	38.90	40.10
10	32.70	37.50	41.60
평균	32.69	36.65	39.95

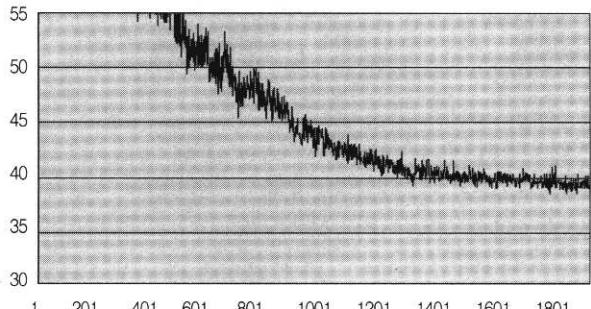
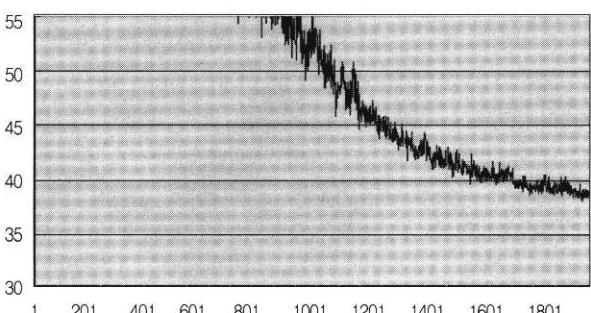
#### 5.4 탐험과 탐색의 비율 변화

본 실험은 탐험과 탐색의 비율을 조정하여 결과를 관찰하기 위한 것이다. 상수  $q_0$ 의 수치를 제외한 나머지 파라미터와 전략은 (그림 5)의 실험과 동일하게 설정하였다.

$q_0$ 의 수치가 높을수록 탐색을 할 확률이 높아지게 되고,  $q_0$ 의 수치가 낮아지면 탐험을 할 확률이 높아진다. 탐색의 경우 현재까지 진행된 알고리즘을 통해 얻은 지식을 그대로 반영하게 되는 것이고, 탐험의 경우 좀 더 다양한 에지를 선택하게 하는 것이다. 하지만 탐험의 경우도 룰렛 휠 방식이기 때문에 확률이 높은 에지가 선택될 가능성이 상

대적으로 높다.

(그림 9)는  $q_0 = 0.5$ 로 하고, (그림 10)은  $q_0 = 0.1$ 로 하였다.

(그림 9)  $q_0 = 0.5$ 로 하였을 경우 트리 비용의 변화(그림 10)  $q_0 = 0.1$ 로 하였을 경우 트리 비용의 변화

$q_0$ 의 값이 낮을수록 알고리즘의 초기에는 노드를 선택할 때 폐로몬의 영향을 적게 받게 되므로 진동이 심해지지만 싸이클이 반복 될수록 에지의 폐로몬 값이 높아지면서 좋은 결과를 만들어낸 에지를 선택할 확률이 높아지게 된다. 그러므로 (그림 5)에 비해 (그림 9)와 (그림 10)은 싸이클의 초기 단계에 총비용이 높은 트리를 생성하게 되지만 싸이클이 반복될수록 점점 개선된 해로 접근하는 과정을 관찰할 수 있다.

<표 4>는 10개의 그래프에서 각각 10번씩 실험하여 만들어진 트리 중 최소비용의 트리 값을 평균한 것이다.

&lt;표 4&gt; 최소 비용 트리의 평균

그래프 번호 $q_0$	0.9	0.5	0.1
1	36.90	37.30	37.00
2	31.70	31.10	31.60
3	30.10	30.70	30.40
4	31.60	31.40	32.00
5	33.90	33.40	33.90
6	32.00	32.20	32.70
7	30.10	29.40	29.40
8	33.40	32.70	34.50
9	34.50	34.10	34.50
10	32.70	32.50	32.50
평균	32.69	32.48	32.85

<표 4>에서 알 수 있듯이  $q_0$ 의 값이 0.1이나 0.9 일 때 보다 0.5 일 때 평균이 아주 근소하게 좋은 것으로 나타나지만, 그래프마다 성능의 차이가 있으므로  $q_0$ 의 값이 0.5인 것이 다른 값에 비해 성능이 더욱 좋다고 하기는 어렵다.

## 6. 결 론

본 논문에서는 ACS를 멀티캐스트 라우팅에 적용하기 위해 사용되는 파라미터와 지역 폐로몬 갱신 규칙의 전략을 실험해 보았다. ACS가 TSP에 적용될 때 사용된 지역폐로몬의 전략과 파라미터의 값을 멀티캐스트 라우팅에 적용할 경우 성능이 좋지 못하다는 것을 확인할 수 있다. 지역 폐로몬 갱신 규칙의 전략은  $\Delta\tau(r,s)$ 의 값을 0으로 설정하는 전략이 ACS가 TSP에서 사용하는 Ant-Q나 단순 ACS에 비해 효과적인 것으로 나타났는데 이것은  $\Delta\tau(r,s)$ 의 값을 0으로 설정하는 전략이 다른 전략들에 비해 하나의 싸이클 내에서 한번 선택된 경로를 다시 선택될 가능성을 줄임으로써 다양한 트리를 생성하기 때문이다. 나머지 실험은 사용되는 파라미터의 값을 설정하기 위한 것이다. 트리의 수는 많아지면 오히려 조기 수렴하거나 비용의 감소가 매우 느린 속도로 진행하는 것을 관찰 할 수 있다. 폐로몬의 증발율이 높으면 알고리즘의 수행으로 축적된 폐로몬의 값을 사용할 수 없기 때문에 매우 나쁜 성능을 보였다. 탐험과 탐색의 비율은 성능에 큰 영향을 미치지 못하는 것으로 파악되었는데, 이것은 탐험의 경우도 룰렛 휠을 사용하기 때문에 탐색과 같이 확률이 높은 경로가 선택될 확률이 높기 때문이다.

## 참 고 문 헌

- [1] M. R. Garey, D. S. Johnson, "Computer And Interactivity : A Guide to the Theory of NP-Completeness," FREEMAN AND COMPANY, 1983.
- [2] L. Kyou, G. Markowsky and L. Berman, "A Fast Algorithm for Steiner Trees," Acta Info., Vol.15, No.2, pp.141-145, 1981.
- [3] A. Kapsalis, V. J. Rayward Smith and G. D. Smith, "Solving the Graphical Steiner Tree Problem Using Genetic Algorithms," J. Oper. Res. Soc., Vol.44, No.4, pp.397-404, 1993.
- [4] Ying Wang and Jianying Xie, "Ant Colony Optimization for Multicast Routing," The 2000 Asia-Pacific IEEE Conference, pp.243-246, 2000.

- [5] Ying LIU, Jianping WU, Ke Xu and Mingwei Xu, "The Degree-Constrained Multicasting Algorithm Using Ant Algorithm," Telecommunication, ICT 2003. 10th International Conference, Vol.1, pp.370-374, 2003.
- [6] M. Dorigo, "Optimization, Learning and Natural Algorithm," Ph.D. Dissertation, DEI, Politecnico di Milano, Italy, 1992.
- [7] M. Dorigo, V. Maniezzo and A. Colorni, "The Ant System : Optimization by a Colony of Cooperating Agents," IEEE Trans. Syst. Man, Cybern, B., Vol.26, No.2, pp.29-41, 1996.
- [8] Marco 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.
- [9] L. P. Kaelbling, L. M. Littman and A. W. Moore, "Reinforcement Learning : a Survey," J. Artif. Intell. Res., Vol.4, pp.237-285, 1996.
- [10] Luca M. Gambardella and Marco Dorigo, "Ant-Q : A Reinforcement Learning Approach to the Travelling Salesman Problem," Proceedings of ML-95, Twelfth Intern. Conf. on Machine Learning, pp.252-260, 1995.



이 성 근

e-mail : hightop@algorithms.knu.ac.kr

1997년 경희대학교 전자계산공학과(학사)

1999년 경희대학교 대학원 전자계산공학과  
(공학석사)

2001년 경희대학교 대학원 전자계산공학과  
(박사수료)

2002년~현재 청강문화산업대학 겸임교수

관심분야 : 멀티캐스트, 모바일 프로그래밍, 개인알고리즘



한 치 근

e-mail : cghan@knu.ac.kr

1986년~1988년 Master of Science, Computer Science Department, The Pennsylvania State University

1988년~1991년 Ph.D. of Computer Science, Computer Science Department, The Pennsylvania State University

1992년~현재 경희대학교 컴퓨터공학과 교수

관심분야 : 생존망 설계, XML, 멀티캐스팅, DNA Computing