

## 전역 최적 경로가 향상되지 않는 반복 탐색 횟수를 고려한 개미 집단 시스템

이 승 관\*, 이 대 호\*

### Ant Colony System Considering the Iteration Search Frequency that the Global Optimal Path does not Improved

Seung-Gwan Lee \*, Dae-Ho Lee \*

#### 요 약

개미 집단 시스템은 조합 최적화 문제를 해결하기 위한 메타 휴리스틱 탐색 방법이다. 기존 개미 집단 시스템은 전역갱신과정에서 탐색된 전역 최적 경로에 대해서만 페로몬 갱신을 수행하는데, 전역 최적 경로가 탐색되지 않으면 페로몬 증발만 일어나며 주어진 종료 조건을 만족할 때까지 아무리 많은 반복 수행에도 페로몬 강화가 일어나지 않는다. 본 논문에서 제안된 개선된 개미 집단 시스템은 전역 최적 경로의 길이가 주어진 반복 사이클 횟수 동안 더 이상 향상되지 못하면 국부최적에 빠졌다고 평가하고 상태전이 규칙에서 파라미터 감소를 통해 다음 노드를 선택하게 하였다. 이로 인해, 상태전이 규칙에서 파라미터 감소에 의한 다양화 전략으로 탐색하는 결과가 최적 경로 탐색뿐만 아니라, 평균 최적 경로 탐색과 평균 반복 횟수의 성능이 우수함을 보여 주었으며, 실험을 통해 그 성능을 평가하였다.

#### Abstract

Ant Colony System is new meta heuristic for hard combinatorial optimization problem. The original ant colony system accomplishes a pheromone updating about only the global optimal path using global updating rule. But, If the global optimal path is not searched until the end condition is satisfied, only pheromone evaporation happens to no matter how a lot of iteration accomplishment. In this paper, 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. This method has effectiveness of the search for a path through diversifications is enhanced by decreasing the value of parameter of the state transition rules for the select of next node, and escape from the local optima is possible. Finally, the performance of Best and Average\_Best of proposed algorithm outperforms original ACS.

▶ Keyword : Ant Colony System, Optimization, Heuristic

• 제1저자 : 이승관 교신저자 : 이대호  
• 투고일 : 2008. 11. 7, 심사일 : 2008. 12. 2, 게재확정일 : 2008. 12. 28.  
\* 경희대학교 국제캠퍼스 학부대학 교수

## I. 서론

개미 집단 시스템(Ant Colony System, ACS)은 조합 최적화 문제를 해결하기 위한 메타 휴리스틱 탐색 방법으로, 그리디 탐색뿐만 아니라 긍정적 피드백을 사용한 모집단에 근거한 접근법으로 순회 판매원 문제를 풀기 위해 처음으로 제안되었다[1, 2]. ACS의 원리는 에이전트라 불리는 개미들이 목적지를 향해 나아가는 동안 각 경로에 페로몬을 분비하고, 이후에 지나가는 에이전트들은 그 경로에 쌓여있는 페로몬(Pheromone) 정보를 이용해 다음 경로를 선택하는 원리를 휴리스틱 탐색에 적용시킨 시스템으로, 에이전트들은 각 경로에 있는 페로몬 양을 기반으로 서로 간의 정보 교환을 통해 최적의 경로를 찾아가고 이러한 에이전트들의 행동 양식을 그대로 적용한 알고리즘으로 조합최적화 문제인 순회 외판원 문제(Traveling Salesman problems, TSP), Job-shop scheduling, Quadratic assignment, vehicle routing, sequential ordering, graph coloring, routing in communication networks[3, 4]에서 최적의 해를 구하기 위해 사용되고 있다.

본 논문에서는 다양한 최적화 문제를 해결하기 위해 제안된 ACS의 기본 알고리즘[5, 6, 7, 8, 9, 10]을 소개한다. 그리고, TSP 문제를 해결하기 위해 기존 방법보다 개선된 ACS 알고리즘을 제안한다.

기존 ACS 알고리즘은 전역갱신과정에서 탐색된 전역 최적 경로에 대해서만 페로몬 갱신을 수행하는데, 전역 최적 경로가 탐색되지 않으면 페로몬 증발만 일어나며 주어진 종료 조건을 만족할 때까지 아무리 많은 반복 수행에도 페로몬 강화가 일어나지 않는다.

이에 비해 본 논문에서 제안된 개선된 개미 집단 시스템은 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. 이로 인해, 상태전이 규칙에서 파라미터 감소에 의한 다양화 전략으로 탐색하는 결과가 최적 경로 탐색뿐만 아니라, 평균 최적 경로 탐색과 평균 반복 횟수의 성능이 우수함을 보여 준다.

본 논문은 다음과 같이 구성되어 있다. 2장에서는 관련된 개미 집단 시스템에 대해 소개하고, 3장에서는 전역 최적 경로가 향상되지 않는 반복 탐색 횟수를 고려한 제안된 방법을 설명한다. 그리고 4장에서는 시뮬레이션을 통해 제안된 방법의 성능을 평가하고 5장에서 결론을 맺는다.

## II. 개미 집단 시스템

개미 집단 시스템(Ant Colony System, ACS)은 조합 최적화 문제를 해결하기 위해 Dorigo 와 Gambardella 등에 의해 소개되었으며, 실제 개미들이 먹이에서 집까지 가장 짧은 경로를 찾는 능력을 모방한 메타 휴리스틱 기법이다[1, 2].

일반적으로 ACS는 (그림 1)과 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 다시한번 페로몬 양을 갱신하게 된다. 결국, 각 에이전트들은 짧은 간선을 선택하려는 휴리스틱 정보와 많은 양의 페로몬을 가진 간선을 선택하려는 페로몬 정보에 따라 탐색경로를 완성하게 된다.

```

Initialize
Loop /* at this level each loop is called an
iteration */
    Each ant is positioned on a starting node
    Loop /* at this level each loop is called a
step */
        Each ant applies a state transition rule to
incrementally build a solution and a local
pheromone updating rule
    Until all ants have built a complete solution
    A global pheromone updating rule is applied
Until End_condition
    
```

그림 1. 개미 집단 시스템  
Fig 1. Ant Colony System

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  $\pi(r, u)$ 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 집합이

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

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

$q$ 는  $[0,1]$  사이에 분포된 무작위 파라미터이고,  $q_0$ 는  $[0,1]$  사이의 값을 가지는 인자,  $S$ 는 식(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.

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

지역갱신은 에이전트들이 방문한 각 간선들에 대해 다음 지역 갱신 규칙을 이용해 페로몬 양을 갱신한다.

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

$\rho (0 < \rho < 1)$ 는 페로몬 자연 파라미터이고  $\Delta\tau(r,s) = \tau_0 = (n * L_{nn})^{-1}$ 는 초기 페로몬 양,  $L_{nn}$ 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.

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

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

$\alpha (0 < \alpha < 1)$ 는 페로몬 자연 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 강화값

으로 전역 최적 경로이면  $(1/L_{gb})$ , 아니면 0으로 주어진다.

### III. 전역 최적 경로 탐색이 일어나지 않는 반복 탐색 구간을 고려한 파라미터 변경

#### 3.1 기존의 상태전이 규칙 개선 방법

ACS의 상태전이 규칙에서 페로몬과 간선 길이의 상대적인 중요도를 결정하는 파라미터인  $\alpha, \beta$ 를 변경한 다양한 실험들이 있다.

Randall[11]의 연구에서는 TSP 문제를 해결하기 위해 강화(intensification)와 다양화(diversification) 전략을 제시하였다. 이것은 파라미터  $\alpha$  값을 변경하는 4가지 전략을 통해 ACS의 성능을 평가하였다. 첫 번째 전략은 기존 파라미터 값인  $\alpha = 1$ 을 그대로 사용하는 방법, 두 번째 전략은 직선 방정식과 같이 점차적으로  $\alpha$  값을 증가시키는 방법, 세 번째 전략은 시뮬레이티드 어닐링(Simulated Annealing, SA)과 유사한 reheating-like 방법으로 최적 경로가 갱신되지 않으면  $\alpha$ 를 감소하는 방법, 네 번째 전략은 타부 서치(Taboo Search, TS)를 적용한 strategic oscillation 방법을 사용하였다. 여기에서는 기존의  $\alpha = 1$ 로 고정된 방법이 가장 좋은 성능을 보여주고 있다. Ruoying[12]의 연구에서는 다음 노드 선택시 해당 간선에 대해 이제까지 에이전트들이 방문한 방문 빈도수를 파라미터  $\alpha$ 에 적용한 T-ACS 모델을 제시하였다. 마찬가지로, Lee[13]의 연구서도 다음 노드 선택시 해당 간선에 대해 이제까지 에이전트들이 방문한 방문 빈도수를 적용하고 있다. 그리고, Kim[14]의 연구에서는 다음 노드 선택을 인접한 노드에 대한 거리로만 결정하지 않고 길이가  $w$ 인 부경로 정보를 이용해 다음 노드를 선택하는 방법을 제시하고 있다.

#### 3.2 반복 탐색 구간을 고려한 상태전이 규칙에서의 파라미터 변경

기존의 ACS 알고리즘은 지역갱신과 전역갱신을 통해 에이전트들이 짧은 간선을 선택하려는 휴리스틱 정보와 많은 양의 페로몬을 가진 간선을 선택하려는 페로몬 정보에 따라 탐색경로를 완성하게 된다. 특히, 전역갱신과정에서는 탐색된 전역 최적 경로에 대해서만 페로몬 갱신을 수행하는데, 전역 최적 경로가 탐색되지 않으면 페로몬 증발만 일어나며 주어진

종료 조건을 만족할 때까지 아무리 많은 반복 수행에도 페로몬 강화가 일어나지 않는다.

본 논문에서 제안된 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 (그림 2)와 같이 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. (그림 2)는 개선된 ACS 알고리즘의 상태전이 규칙이다.

```

/* Agents build their towns. 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
formula(1) and formula(2) using
changed parameter(= 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_k1
            Tour_k(i) := (r_k, s_k)
        else
          Choose the next node s_k according to
formula(1) and formula(2) using
default parameter(= 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
    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

```

그림 2. 개선된 상태전이 규칙  
Fig 2. The Improved State Transition Rule

### IV. 성능 평가

개선된 ACS 알고리즘 평가하기 위해, 실험을 위한 모델 집합들은 TSP 예제로 널리 알려진 TSPLIB[15]에서 추출하여 실험을 하였다. 실험 환경은 Core(TM)2 2GHz, 1024MB RAM 환경에서 수행되었다.

본 논문에서는 기존 ACS에 3-opt 지역 탐색 기법을 적용한 ACS-3-opt 방법[1], 연구[14]에서 제시된 부경로(w)를 적용한 방법, 그리고 제안된 알고리즘을 비교 평가한다.

실험에 사용된 모든 알고리즘들을 동일한 조건에서 실험하기 위해 ACS-3-opt 알고리즘과 부경로를 적용한 방법에 사용된 환경변수는  $\rho=0.1, \alpha=1, \beta=2, q_0=0.95, time=100, m=10, w=3$  (부경로 적용)으로 설정, 제안된 ACS 알고리즘에 사용된 환경변수는 위의 방법과 동일한 환경변수에서 주어진 반복 사이클 횟수(100회) 동안 최적 경로 갱신이 일어나지 않는 경우  $\alpha=0.6, \beta=1.1$  로 변경하여 10회 반복 탐색하였다.

<표 1>과 <표 2>는 노드 개수에 따라 전역 최적 경로가 100회 반복 동안 향상되지 않을 경우 상태전이 규칙의 파라미터( $\alpha, \beta$ )를 변경한 실험 결과이다.

<표 1>의 1000개 미만의 노드 집합에서는 기존의 ACS-3-opt 방법, 부경로(w)를 적용한 방법과 개선된 방법의 성능 차이는 크지 않다. 하지만, <표 2>의 1000개 이상의 노드 집합에서는 개선된 방법이 좋은 성능을 보여주고 있다. 이것은 노드의 개수가 적은 집합은 상대적으로 반복 탐색 횟수가 적고, 노드 개수가 많은 집합에서는 탐색 공간이 커져 반복 탐색 횟수가 많아지기 때문에 상태전이 규칙에서 파라미터 감소에 의한 다양화 전략으로 탐색하는 결과가 최적 경로 탐색뿐만 아니라, 평균 탐색 시간과 평균 반복 횟수의 성능이 훨씬 우수함을 보여주고 있다. 결국, 문제 영역이 커질수록 개선된 방법을 통한 다양화 탐색이 최적해 탐색에 효율적임

을 보여주고 있다.

(그림 3)은 a280 TSP 문제에서 이미 최적 경로 길이라고 알려진 최적값 2579를 탐색한 다양한 경로를 보여주고 있다.

### V. 결론

본 논문은 개선된 ACS 알고리즘을 제안하였다. 기존

ACS 알고리즘은 전역갱신과정에서 탐색된 전역 최적 경로에 대해서만 페로몬 갱신을 수행하는데, 전역 최적 경로가 탐색되지 않으면 페로몬 증발만 일어나며 주어진 종료 조건을 만족할 때까지 아무리 많은 반복 수행에도 페로몬 강화가 일어나지 않는다.

본 논문에서 제안된 개선된 ACS 알고리즘은 전역 최적 경로의 길이가 주어진 반복 사이클 횟수 동안 더 이상 향상되지 못하면 국부최적에 빠졌다고 평가하고 상태전이 규칙에서의

표 1. 전역 최적 경로가 100회 반복 동안 향상되지 않을 경우 상태전이 규칙의 파라미터를 변경한 실험 결과(노드수가 1000개 미만)  
Table 1. The experimental result which changes the parameter of state transition rule, when the global optimal path does not improve during 100 iterations(less than 1000 nodes)

	Known Best	ACS-3-opt			ACS-부경로			개선된 ACS		
		Best	Average Best	Average Iterations	Best	Average Best	Average Iterations	Best	Average Best	Average Iterations
eil51	426	426	426.0	34.1	426	426.0	103.6	426	426	22.6
d198	15780	15780	15780.0	1195.7	15780	15780.0	1878.4	15780	15780	2075.5
a280	2579	2579	2579.0	22.4	2579	2579.0	113.9	2579	2579.0	184.9
pr439	107217	107217	107234.6	1262.6	107217	107225.8	175.6	107217	107225.8	214.2
pcb442	50778	50778	50876.0	2111.1	50778	50845	4360.8	50778	50860.1	2342.9
att532	27686	27686	27701.4	1925.6	27686	27699.3	1900.0	27686	27702.5	1987.2
rat783	8806	8806	8826.6	3485.5	8806	8817.7	3141.9	8806	8813.2	2730.1

표 2. 전역 최적 경로가 100회 반복 동안 향상되지 않을 경우 상태전이 규칙의 파라미터를 변경한 실험 결과(노드수가 1000개 이상)  
Table 2. The experimental result which changes the parameter of state transition rule, when the global optimal path does not improve during 100 iterations(more than 1000 nodes)

	Known Best	ACS-3-opt			ACS-부경로			개선된 ACS		
		Best	Average Best	Average Iterations	Best	Average Best	Average Iterations	Best	Average Best	Average Iterations
vm1084	239297	239297	239417.7	920.1	239349	239484.4	1423.4	239297	239399.4	1236.6
pcb1173	56892	56893	56998.1	1589.5	56901	56991.1	1980.8	56893	56987.3	1508.3
d1291	50801	50801	50843.5	940.6	50801	50856.5	665.3	50801	50841.8	621.8
rl1323	270199	270547	270935.3	1280.5	270755	270882.9	1106.7	270254	270758.8	1116.1
nrv1379	56638	56697	56791.9	1671.6	56695	56754.6	1749.6	56688	56751.4	1413.4
u1432	152970	153284	153464.1	2336.7	153265	153599.2	2808.3	153260	153457.7	2600.4
vm1748	336556	336834	337164.7	888.7	336925	337232.2	879.9	336834	337192.9	843.8
rl1889	316536	317693	318646.4	1030.8	317268	318458.1	995.6	317526	318416.1	720.6

파라미터를 변경(감소)하여 다음 노드 선택에서 다양화를 통한 경로 탐색을 가능하게 하였다. 결과로 노드의 개수가 적은 집합은 거의 유사한 성능을 보였지만, 노드 개수가 많은 집합에서는 상태전이 규칙에서 파라미터 감소에 의한 다양화 전략으로 탐색하는 결과가 최적 경로 탐색뿐만 아니라, 평균 최적 경로 탐색과 평균 반복 횟수의 성능이 우수함을 보여주었다. 향후 연구과제는 제안된 방법을 TSP 이외의 다른 문제 영역에 적용해 보고 그 적합성을 평가해 봐야겠다.




그림 3. a280의 최적 경로  
Fig 3. Optimal paths in a280

### 참고문헌

[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, 1997.

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

[3] 정의현, "개미 집단 최적화를 이용한 무선 센서 네트워크의 라우팅 알고리즘", 한국컴퓨터정보학회논문지, 제 12권, 제 5호, 131-137쪽, 2007년 11월.

[4] 이승관, "멀티캐스트 라우팅 문제 해결을 위한 엘리트 개미 시스템", 한국컴퓨터정보학회논문지, 제 13권, 제 3호, 147-152쪽, 2008년 5월.

[5] C. Blum, "Ant colony optimization: Introduction and recent trends", Physics of Life Reviews, 2(4), pp.353-373, 2005.

[6] M. Dorigo, L.M. Gambardella, M. Middendorf, and T.

Stutzle, "Ant Colony Optimization", Vol. 6, No. 4, IEEE Transactions on Evolutionary Computation, July 2002.

[7] M. Dorigo, and C. Blum, "Ant colony optimization theory: A survey", Theoretical Computer Science, 344(2-3), pp.243-278, 2005.

[8] M. Dorigo, M. Birattari, and T. Stutzle, "Ant Colony Optimization - Artificial Ants as a Computational Intelligence Technique", IEEE Computational Intelligence Magazine, 2006.

[9] M. Dorigo, and T. Stutzle, "The Ant Colony Optimization Metaheuristic: Algorithms, Applications, and Advances", Handbook of Metaheuristics, 2002.

[10] M. Dorigo, and K. Socha, "An Introduction to Ant Colony Optimization", Approximation Algorithms and Metaheuristics, CRC Press, 2007.

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

[12] 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.

[13] 이승관, 정태충, "강화와 다양화의 조화를 통한 협력 에이전트 성능 개선에 관한 연구", 전자공학회논문지, 제 40권, CI편, 제 6호, 87-94쪽, 2003년 11월.

[14] 김인걸, 윤민영, "방문판매원 문제에 적용한 개선된 개미 군락 시스템", 한국정보처리학회논문지B, 제 12권, 제 7호, 823-828쪽, 2005년 12월.

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

## 저 자 소 개



### 이 승 관

- 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 학부대학 조교수
- 〈관심분야〉 : 인공지능, 로봇에이전트, 최적화, 데이터마이닝



### 이 대 호

- 1998년 2월 : 경희대학교 전자공학과 공학사
  - 2001년 2월 : 경희대학교 전자공학과 공학석사
  - 2005년 2월 : 경희대학교 전자공학과 공학박사
  - 2005년 9월 ~ 현재 : 경희대학교 학부대학 조교수
- 〈관심분야〉 : 컴퓨터비전, ITS, 신호처리, 영상처리, 인공지능