

# 순회 판매원 문제를 위한 국소 탐색으로 개선된 문화 알고리즘

김용준<sup>o</sup> 조성배

연세대학교 컴퓨터과학과

yjkim@scslab.yonsei.ac.kr, sbcho@cs.yonsei.ac.kr

## An Improved Cultural Algorithm with Local Search for Traveling Salesman Problem

Yongjun Kim<sup>o</sup> Sung-Bae Cho

Department of Computer Science, Yonsei University

### 요 약

본 논문에서는 순회 판매원 문제(Traveling Salesman Problem)를 풀기 위한 새로운 방법을 제안한다. 사회적 지성(social intelligence)을 통하여 개체의 진화 방향을 인도하여 보다 나은 전역적인 해를 구하는 문화 알고리즘(Cultural Algorithm)을 활용하고, 국부적 최적화를 수행하는 국소 탐색(Local Search) 방법을 보완적으로 적용하여 적은 세대의 진화 연산을 통해서도 더 좋은 성능의 해를 찾을 수 있도록 하였다. 문화 알고리즘에 의해 개체들은 단순 진화가 아니라 사회적 지성에 의해 더 좋은 해를 향해 인도되고, 국부 탐색에 의해 가능한 최적의 해에 수렴하게 된다. 따라서, 보다 빠르게 좋은 해에 접근할 수 있다. 다양한 TSP 문제에 적용하여 수행한 실험 결과는 제안한 방법이 매우 효율적인 성능을 나타냄을 보여준다.

### 1. 서 론

순회 판매원 문제(Traveling Salesman Problem, TSP)는 전형적인 조합 최적화 문제로서, 여러 개의 도시를 순회 방문하는 판매원의 최단 방문 거리를 계산하는 문제이다. 즉, 가중치 그래프  $G = (V, E)$ 가 있을 때,  $V$ 는  $\{v_1, v_2, \dots, v_N\}$ 의  $N$  개의 도시들의 집합이고,  $E$ 는  $\{e_1, e_2, \dots, e_M\}$ 의  $M$  개의 도시간의 연결선들의 집합이 되며, 각 연결선에 해당하는 비용의 집합인  $D$ 는  $\{d_1, d_2, \dots, d_M\}$ 의  $M$  개의 집합이 된다. 순회 판매원이 각 도시  $V$ 를 정확히 한 번만 방문하면서 방문에 소요되는 비용  $D$ 를 최소화할 수 있는 해밀턴 순환(Hamiltonian Cycle)을 찾아 내는 것이 TSP의 목적이다.

TSP가 NP-hard 문제에 속한다는 것은 이미 알려져 있는 사실로,  $n$ 개의 도시를 방문하는 문제를 풀기 위해서는  $\frac{(n-1)!}{2}$  개의 경우의 수를 다 확인해봐야 한다는 어려움이 있다. 이를 해결하기 위해서 simulated annealing, tabu search, ant colony optimization, particle swarm optimization, genetic algorithm (GA)[1][2], local search[3] 등의 여러 가지 경험적 방법이 사용되어 왔다.

본 논문에서는 사회적 지성을 모델링 하는 대표적인 방법인 문화 알고리즘(Cultural Algorithm)을 사용하여 TSP의 문제를 해결하도록 하고, 국부적 최적화를 수행하는 국소 탐색(Local Search) 방법을 보완적으로

적용하는 방법을 제안한다. 이에 따라, 전역적인 최적화를 수행하는 문화 알고리즘에 의해 진화된 해들이 국부 탐색 방법에 의해 최적화되어 진화 수행 시 세대 수를 작게 하더라도 효과적으로 최적화가 수행되어 최적의 해를 구할 수 있게 된다. 결국, 문화 알고리즘의 사회적 지성과 국부 탐색의 제한된 지식이 합쳐져서 효과적으로 TSP 문제를 풀 수 있게 된다.

본 논문의 구성은 다음과 같다. 2장에서 기존 연구 방법에 대해 설명하고, 3장에서 제안하는 방법에 대해서 논한다. 실험 결과가 4장에 제시되고, 마지막으로 5장에서 결론에 대해서 다룬다.

### 2. 관련연구

#### 2.1. 문화 알고리즘

문화 알고리즘(Cultural Algorithm, CA)은 Reynolds 에 의해 제안된 진화연산 모델이다[4]. CA 는 사회적 지성(social intelligence)을 모델링 하여 개체의 진화에 영향을 주어 진화의 방향을 인도하고 조정할 수 있도록 하였다. 이를 위해 전통적인 GA 가 가지고 있는 기본적인 구성인자(component)와 연산자(operator)들 외에 추가로 사회적 지성을 대표할 수 있는 모델을 마련하여 진화되는 개체와 공존하며 상호 영향을 끼칠 수 있도록 하였다. 이러한 CA 의 기본 구조는 그림 1 과 같다.




그림 1. 문화 알고리즘의 기본 구조

그림 1 이 보여주는 것처럼 CA 는 크게 3 부분으로 되어 있다. 먼저 일반적인 GA 의 특성을 그대로 가지고 있는 Population Space 이 있고, 다음으로 사회적 지성을 모델링 하는 Belief Space 가 있으며, 마지막으로 두 영역간의 통신을 담당하고 있는 Protocol 이 있다. 각 영역이 담당하는 기능은 표 1 과 같다.

표 1. 문화 알고리즘 컴포넌트의 기능

컴포넌트	함수	기능
Population Space	evaluate	개체의 성능 평가
	generate	자식 개체의 생성
	select	다음 세대를 위한 개체 선택
Belief Space	update	사회적 지성을 위한 지식 데이터 갱신
Protocol	accept	update 를 위한 개체 선택
	influence	개체들의 진화 방향 유도

Population Space 는 일반적인 GA 의 특성을 그대로 가지고 있으므로 교차 연산자(Crossover Operator)나 돌연변이 연산자(Mutation Operator) 등을 그대로 사용할 수 있다. 한편, Belief Space 는 사회적 지성을 모델링 하기 위해 새로 추가된 것으로 Reynolds 에 의해 제안된 지식 근원(Knowledge Source)들을 포함한다. 즉, 상황 지식(Situational Knowledge)과 지형 지식(Topographical Knowledge), 규범 지식(Normative Knowledge), 영역 지식(Domain Knowledge), 역사 또는 시간 지식(Historical or Temporal Knowledge)의 5 가지가 현재까지 제안되었다. 이들 지식 근원들을 사용하여 Population Space 의 개체들의 진화를 인도함으로써 보다 좋은 해를 얻을 수 있게 된다.

## 2.2. 국소 탐색(Local Search) 방법

TSP 를 위해 주로 사용되는 국소 탐색(Local Search) 방법은 2-opt 방법과 3-opt 방법, 그리고 Lin-

Kernighan 방법 등이 있으며, 순서대로 보다 효율적이면서도 복잡한 계산을 필요로 한다. 이 중에서 가장 간단한 2-opt 탐색 방법에 대한 순서도가 그림 2 에 나타나 있다.

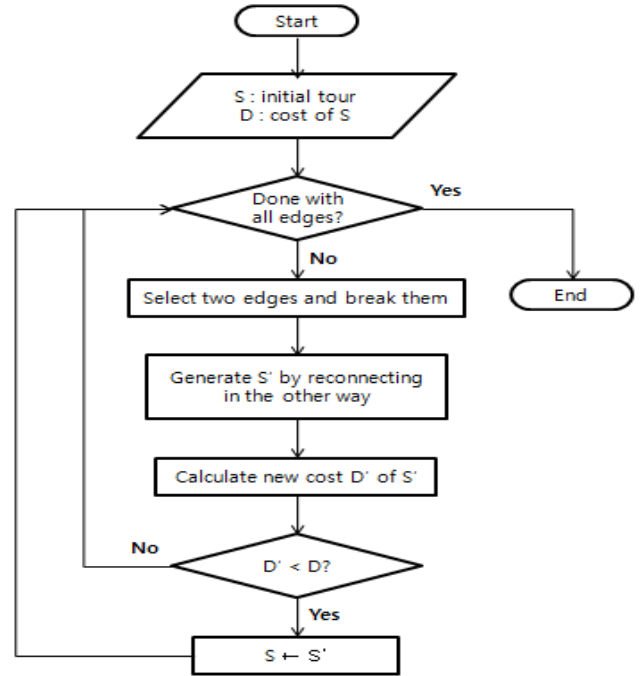


그림 2. 2-opt 국소 탐색 방법의 순서도

이 순서도에서 Initial Tour  $S$  에서  $S'$  을 생성하는 방법은 그림 3 과 같다.




그림 3. 2-opt 국부 탐색에 의한 새로운 Tour 생성

2-opt 국소 탐색 방법을 사용하여 새로운 Tour 를 생성하고자 할 때는 먼저 두 도시 A 와 H 를 연결하는 선인  $E_{AH}$  와 다른 두 도시 C 와 D 를 연결하는 선인  $E_{CD}$  를 제거한다. 다음으로 새롭게 두 도시 A 와 D 를 연결하는  $E_{AD}$  와 다른 두 도시 C 와 H 를 연결하는  $E_{CH}$  를 만든다. 이렇게 연결하여 새롭게 생성된 Tour 인  $S'$  을 원래의 Tour 인  $S$  와 비교해서 비용이 더 작으면 원래의  $S$  를 대체한다. 이런 식으로 더 작은 순회 비용을 가지는 새로운 Tour 를 생성할 수 있다.

## 3. 제안하는 방법

본 논문에서 제안하고자 하는 방법은 다음과 같다. CA 는 2 장에서 논의한 바와 같이 전역적인 해를 찾는

데에 뛰어난 성능을 가지고 있다. 하지만, 적합한 해를 찾기 위해서는 상당한 진화 세대를 거쳐야 한다. 이를 해결하기 위해 2-opt 로 대표되는 국부 탐색 방법을 CA 에 적용하면 국부적 최적화를 통해서 진화 세대 수를 줄일 수 있다. 또한, 두 방법의 상승 효과에 의해 더욱 최적화된 해를 구할 수 있을 것으로 기대된다. 그림 4 에 제안하는 방법의 기본 구조가 표시되어 있다.

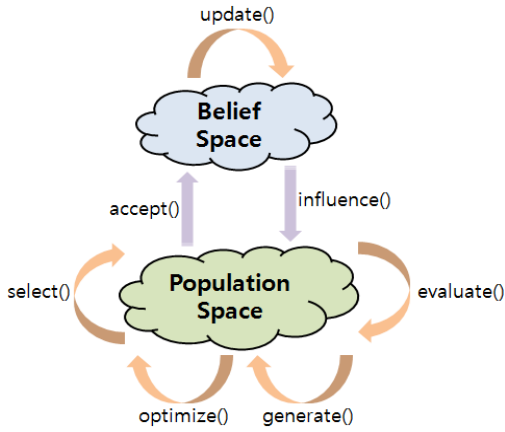


그림 4. 제안하는 방법의 기본 구조

표 2 에 제안하는 방법에 새로 추가된 함수의 기능이 기술되어 있다.

표 2. 제안하는 방법에 추가된 함수의 기능

컴포넌트	함수	기능
Population Space	optimize	2-opt 국소 탐색을 사용하여 개체들의 성능 최적화

CA 를 사용하기 위해서는 Belief Space 에서 사용할 지식 근원들을 추출해야 한다. TSP 문제 해결을 위해 필요한 지식 근원들을 추출하면 표 3 과 같다. 각 지식 근원들은 Roulette Wheel 방식에 의해서 선택되어 개체들의 진화 방향에 영향을 주게 된다.

표 3. TSP 를 위한 지식 근원들

지식 근원	설명
상황 지식	개체(Tour)들 중에 가장 Tour Cost 가 작은 개체
지형 지식	초기 개체들 중에서 도시와 도시간의 거리가 가장 큰 값을 기준으로 일정 영역으로 분할하여 각 영역에 개체들을 위치시킴
규범 지식	Tour Cost 가 가장 작은 개체의 도시간의 거리가 가장 큰 값
역사 지식	규범 지식이 갱신될 때의 세대 수와 갱신된 규범 지식

그림 5 에 제안하는 방법의 알고리즘에 대한 순서도가 나타나 있다.

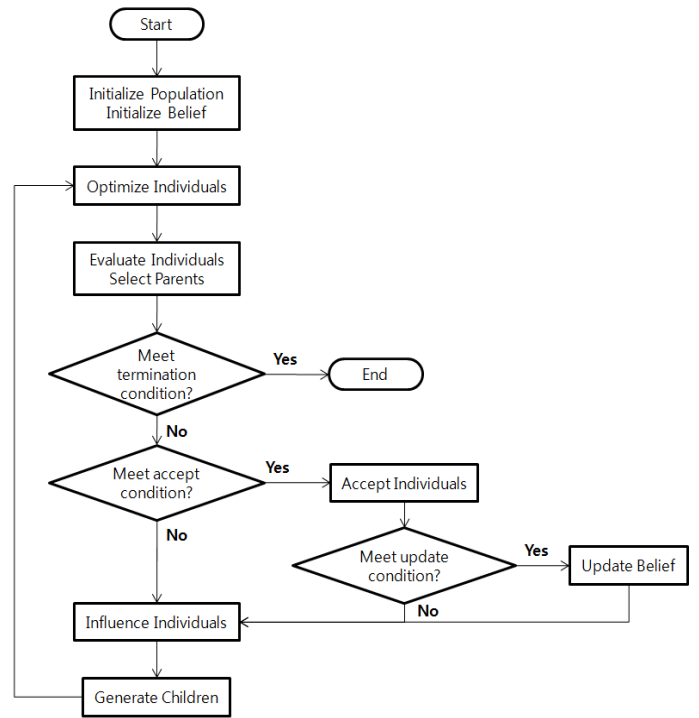


그림 5. 제안하는 방법의 알고리즘 순서도

Belief Space 와 달리 Population Space 는 일반적인 GA 와 동일한 방법이 적용될 수 있다. 표 4 에 제안하는 방법에서 사용된 Population Space 의 사양을 표시하였다.

표 4. 제안하는 방법의 Population Space 사양

항목	설명
Representation	방문되는 도시의 경로(Path)에 따라 표시 (1→2→3→4→1 => 1 2 3 4)
Selection	Tour cost 가 적은 순서로 일정 개수의 부모를 선택
Crossover	Order Crossover 를 사용. 즉, 일정한 두 지점을 기준으로 두 부모의 정보를 교환 (두 지점 사이에 동일한 값이 있을 경우는 무시) - 부모 A : 1 4 5   8 9 3 6   7 2 - 부모 B : 3 5 6   7 4 2 1   9 8  - 자식 A : 4 2 1   8 9 3 6   5 7 - 자식 B : 9 3 6   7 4 2 1   5 8
Mutation	Inversion 을 사용. 즉, 두 지점 간의 도시 정보를 역으로 변경 - 부모 : 1 4 5   8 9 3 6   7 2 - 자식 : 1 4 5   6 3 9 8   7 2

Belief Space에 있는 지식 근원들은 Population Space에 있는 개체들에 표 5에 나온 것과 같은 방식으로 영향을 줄 수 있다.

표 5. 지식 근원의 개체 영향 방식

지식 근원	설명
상황 지식	개체가 지식 근원의 값과 유사한 값을 가지게 함
지형 지식	개체가 낮은 성능을 나타내는 영역에 포함되어 있을 경우 높은 성능을 나타내는 영역으로 이동 시킴
규범 지식	개체가 가진 도시간 최대 거리를 지식 근원의 값으로 변경 시킴
역사 지식	개체의 값을 지식 근원의 초기 값으로 변경 시킴

#### 4. 실험 결과

실험은 TSPLIB[5]에 있는 예제들을 대상으로 수행되었으며, 결과 비교는 현재까지 알려진 가장 최적의 값과, 국부 탐색 방법만 적용한 LOCAL 방법, 국부 탐색 방법을 GA 와 결합하여 Local Evolutionary Algorithm(LEA)라는 방법을 제안한 Xuan [3]의 결과 값과 비교하였다. 표 6 에 실험에 사용된 파라미터 값들이 표시되어 있다.

표 6. 실험에 사용된 파라미터

항목	설명
실험 회수	15 회(실험 후 평균값 사용)
Population 크기	50 개체
Crossover 확률	0.25
Inversion 확률	0.02
최대 세대 수	40 세대
비교 데이터	TSPLIB 최적값, 국부 탐색 실험값, Xuan 실험값

그림 6 은 실험 결과를 비교 데이터와 비교한 결과값을 보여준 것이다. 제안한 방법이 비교 방법에 비해서 Best 값과 Average 값, Worst 값 모두 더 나은 성능을 나타냄을 볼 수 있다. 특히, 국부 탐색 방법만 사용한 LOCAL 방법에 비해서는 전체적으로 고르게 아주 좋은 성능을 나타내었음을 확인할 수 있다. LOCAL 방법은 도시의 개수가 작을 때 좋은 성능을 나타내다가, 도시의 개수가 커질수록 점점 국소 영역의 최적의 해에 빠지게 됨을 알 수 있다. LEA 방법과의 비교에 있어서도 전체적으로 개선이 되었는데, 특히 Best 값과 Average 값에 있어서는 상당한 발전을 보였음을 알 수 있다. 다만, Eil101 의 경우를 제외하고는 모두 현재까지 알려진 최적의 값을

발견하였다. Eil101 에서 최적의 값보다 1 이 더 큰 값을 Best 값으로 발견했는데, 이는 세대 수를 현재 사용한 수보다 조금 더 많이 늘려주면 최적의 값을 발견할 수 있을 것으로 예상된다. 위의 결과를 통해 볼 때, 적은 수의 세대 진화를 통해서 보다 효과적인 결과값이 획득될 수 있다는 것을 확인할 수 있다.




그림 6. 실험 결과 데이터 비교

#### 5. 결론

CA 의 사회적 지성을 이용한 전역적인 해를 찾을 수 있는 능력과 국소 영역의 최적의 해를 찾을 수 있는 국소 탐색 방법의 능력을 결합함으로써 보다 최적화된 해를 찾을 수 있는 방법의 가능성을 확인하였다. 또한, 두 방법의 결합에 의해 빠른 세대의 진화 만에 효율적인 해를 찾을 수 있다는 것은 본 논문에서 제안하는 두 방법의 결합이 TSP 를 해결하는데 적절하게 사용될 수 있다는 것을 의미한다. 이는 CA 의 특성인 사회적 지성에 의해 인도되는 개체들의 진화가 포괄적인 해를 향한 방향성을 가지고 수행될 수 있어서 더욱 쉽게 원하는 영역에 도달할 수 있다는 것을 의미한다. 이를 응용하여 앞으로 더욱 다양한 분야에서 좋은 결과를 낼 수 있을 것으로 기대된다.

다만, 실험에 사용된 TSP 예제의 수와 각 예제들이 가지고 있는 도시들의 수가 충분히 크지 않기 때문에 향후 보다 크고 많은 TSP 예제들을 사용하여 제안한 방법의 효과를 좀 더 깊이 있게 확인해 보는 것이 필요할 것이다.

#### 참고문헌

- [1] D.E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley, 1989.
- [2] Z. Xue and Y. Guo, "Improved Cultural Algorithm based on Genetic Algorithm," in *Proceedings of the IEEE International Conference on Integration Technology*, pp.117-122, 2007.
- [3] W. Xuan and Y. Li, "Solving Traveling Salesman Problem by Using A Local Evolutionary Algorithm," in *Proceedings of the IEEE International Conference on Granular Computing*, Vol.1, pp.318-321, 2005.
- [4] R.G. Reynolds and M. Ali, "Computing with the Social Fabric: The Evolution of Social Intelligence within a Cultural Framework," *IEEE Computational Intelligence Magazine*, Vol.3, Issue 1, pp.18-30, 2008.
- [5] <http://elib.zib.de/pub/mp-testdata/tsp/tsplib/tsplib.html>