

SOFM(Self-Organizing Feature Map)형식의 Travelling Salesman 문제 해석 알고리즘

○석 진욱, 조 성원, 최 경삼
동의대학교 전기·제어공학과

Self Organizing Feature Map Type Neural Computation Algorithm for Travelling Salesman Problem

Jinwuk Seok, Seongwon Cho, Gyung-sam Choi
Dept. of Electrical & Control Eng., Hong Ik University.

Abstract

In this paper, we propose a Self Organizing Feature Map (SOFM) Type Neural Computation Algorithm for the Travelling Salesman Problem(TSP). The actual best solution to the TSP problem is computationally very hard. The reason is that it has many local minimum points. Until now, in neural computation field, Hopfield-Tank type algorithm is widely used for the TSP. SOFM and Elastic Net algorithm are other attempts for the TSP. In order to apply SOFM type neural computation algorithms to the TSP, the object function forms a euclidean norm between two vectors. We propose a Lagrangian for the above request, and induce a learning equation. Experimental results represent that feasible solutions would be taken with the proposed algorithm.

I. 서 론

Travelling Salesman Problem(TSP)은 N개의 도시를 모두 연결하는 최단의 경로를 찾아내는 문제로서, 계산 시간이 도시의 숫자 N의 지수함수로 증가하는 NP-Complete 문제중의 하나이다. 이 문제는 N 도시의 순서를 일부분 바꾸었을 때 경로가 증가하게 되는 국소 최소점이 많이 있는 문제이다. 이렇게 국소 최소점이 많은 올불통증인 표면(Rugged Landscape)에서 전체적인 최소점을 찾는 문제는 변수공간 전체에 대한 검색을 하지 않는 한 불가능하다. 따라서 근사적인 전체 최소점을 찾는 데 주안점을 둔 몇 가지 최적화 알고리즘이나 첫번재로 담금질(Simulated Annealing)방법이 있으며, 두번재로 신경회로망을 사용한 방법이 있다[3][8]. 이중 잘 알려진 Simulated Annealing 방법을 제외한 방법은 최근에 패런인식등에 많이 적용되는 신경회로망을 TSP에 적용하여 경로를 최적하게 학습을 시키는 것으로 Hopfield-Tank 모델의 적용 예제로서 10 city 이하의 간단한 문제에서는 항상 최적한 해답을 내온다. 반면 Hopfield-Tank 모델은 국소 최소점에 매우 취약하여 city의 수가 클 경우 Feasible한 해를 구하기가 어려운 단점이 있다[8][9].

Hopfield-Tank 모델이외에 신경회로망을 사용하여 TSP 문제를 해결한 예는 SOFM(Self Organizing Feature Map) 알고리즘과 Durbin-Wilshaw 알고리즘으로 알려진 Elastic Net 방법이 있다. SOFM 알고리즘을 사용한 TSP 문제 해결은 SOFM 알고리즘이 가지고 있는 Weight vector의 정렬 특성을 이용한 해석(B.Angelini, H.Ritter 등)으로서 다른 알고리즘에 비해 비교적 City 수가 많은 문제에 대하여 전역 최소점 근처로 Weight Vector를 위치시킬 수 있는 장점이 있다. Elastic Net 방법은 SOFM 알고리즘에 Weight Vector의 거리를 또 하나의 Energy 항으로 부가하여 보다 거리 최적화를 이루도록 하는 방법으로서 SOFM 알고리즘의 Weight vector 정렬 특성을 대수적으로 보다 명확히 한 특징이 있다. 하지만 SOFM 알고리즘과 Elastic Net 두 알고리즘은 Weight Vector와 City Location으로 표현되는 입력 Vector가 동일 Dimension의 Vector Space에 위치하기 때문에 Kalman Filter의 특성, 즉 입력 Vector Cluster의 중심으로 Weight Vector가 위치하는 특징이 사라지지 않는다는 단점이 있다. 이 경우 몇 개의 city 중심에 Weight Vector가 위치하므로 좁은 영역에 다수의 city가 물려

있을 경우 이때의 최적 경로를 구해내기가 어려울 뿐만 아니라 이러한 단점을 없애기 위해 Weight Vector를 많이 사용할 경우 볼 필요한 Weight Vector를 지워가는 후처리가 또 다시 요구되며 연산시간의 연장, Network 효율의 저하를 피할 수 있을뿐 아니라 이 단점을 완전히 없앨 수도 없다[8][9].

SOFM 알고리즘과 Elastic Net 알고리즘이 이러한 단점을 가지는 가장 큰 이유는 Weight Vector가 존재하는 위상 공간이 기본적으로 입력 벡터 공간이기 때문이다. 따라서 Weight Vector 공간과 입력 벡터 공간을 분리하고 입력 벡터 공간과의 관계를 선형적으로 가지도록 하면 기존 SOFM 알고리즘이나 Elastic Net 알고리즘으로 TSP 문제를 풀었을 때의 단점을 해결 할 수 있다.

본 연구에서는 이러한 목표를 위해 먼저 City Location을 표시하는 Index Matrix를 도입하여 Weight Vector 공간과 입력 벡터 공간을 분리하고, Index Matrix를 변화시키는 Permutation Matrix를 도입하여 Weight Vector와 City Location과의 관계를 설정하였다. 이때 Weight Vector들은 Permutation Matrix를 구하기 위한 연관 Parameter Matrix의 Component를 의미하게 되며, 여기에 기초하여 기존 Hopfield-Tank Model이나 Simulated Annealing 방법에서 사용한 Perfect Matching 형식의 Lagrangian 대신 실제 Travelling 거리를 목적함수로 놓은 투 학습 규칙을 유도하였다. 본 연구에서는 또한 기존의 최급 강하법으로 유도된 학습 알고리즘이 가지는 약점을 보완하기 위해 이진 강하함수를 도입한 학습 알고리즘을 제안하였다.

II. TSP 문제를 위한 목적함수 유도

기존의 TSP 문제를 위한 목적함수는 Perfect Matching 형식으로서 각 도시 사이의 거리 Matrix를 정의하고 몇 가지 통식 조건들을 포함하여 유도 되었다. 이러한 목적함수의 형태는 Hopfield-Tank 모델과 같은 신경망의 경우 매우 적절하게 적용될 수 있으나, SOFM과 같이 최소 차승법을 목적함수로 삼는 모델의 경우에는 적용하기 어려웠다. 따라서 TSP 문제의 목적함수를 최소 차승법과 같은 형태로 만들기 위해서는 목적함수를 다음과 같이 국부 거리의 합의 형태로 놓아야 한다.

$$\sum_{i=0}^{n-1} \|x_{\phi(\vec{w}_i)} - x_{\phi(\vec{w}_{i+1})}\|^2 \quad (1)$$

식 (1)에서 n은 도시의 수, $\phi(\vec{w}_i)$ 는 Permutation을 위한 Weight 벡터 \vec{w}_i 에 의해 결정되는 도시의 index, $x_{\phi(\vec{w}_i)}$ 는 Weight 벡터 \vec{w}_i 의 i번째 성분으로서 시간 t에서 j번째 도시를 가리기는 Index가 i번째 도시를 가리키는 Index로 바뀔 확률에 비례하는 Parameter가 된다. $x_{\phi(\vec{w}_i)}$ 는 $\phi(\vec{w}_i)$ 번째 도시의 위치 벡터(x, y) 성분을 가지며 다음과으로 결정된다.

$$x_{\phi(\vec{w}_i)} = A \cdot \vec{p}_i \quad (2)$$

식 (2)에서 Matrix A는 $2 \times n$ Matrix로서 도시의 위치 벡터(x, y) 성분으로 이루어져 있으며 j번째 Column Vector는 j 번째 도시의 (x, y) 성분을 가지고 있으며, \vec{p}_i 는 $\phi(\vec{w}_i)$ 로 만들어지는 Index Matrix P의 j번째 Column 벡터 성분이다.

TSP문제를 위한 제한 조건은 일반적으로 다음과 같다.

- ① 각 도시를 한번만 방문할 것
- ② 동시에 두 도시를 방문 할 수 없을 것
- ③ 방문하는 도시의 수가 도시의 전체 수 일것

이 제한 조건들은 Index Matrix에 모두 포함되어 있으므로 Weight Matrix가 Index Matrix와 유사한 형태로 나타나면 제한 조건들은 만족되므로 제한조건 식은 다음과 같은 형식 제한조건식으로 유도 된다.

$$\sum_{i=0}^{n-1} \sum_{j=1}^{n-1} \|w_i' - p_j'\|^2 = 0 \quad (3)$$

제한조건은 이외에도 $0 \leq w_i' \leq 1$ 이 필요하나 부분적으로 (3)식에 포함된다. 따라서 TSP를 위한 Lagrangian은 다음과 같이 정의할 수 있다.

$$\mathcal{L} = \sum_{i=0}^{n-1} \|x_i(p_i) - x_i(p)\|^2 + \lambda \sum_{i=0}^{n-1} \sum_{j=1}^{n-1} \|w_i' - p_j'\|^2 \quad (4)$$

식 (4)에서 λ 는 Lagrangian Multiplier이다.

Weight 벡터의 각 요소 w_i' 와 Index Matrix의 i번째 Row, j번째 Column사이의 관계는 다음과 같다.

$$p_j' = u \left(\sum_{k=0}^{n-1} M_{ik} w_k' - e' \right) = w_k' f(\vec{w}', m) \quad (5)$$

여기에서 $M_{ik} = \delta(k-i)(1+\epsilon) - \epsilon$ 이며, ϵ, ϵ' 는 매우 작은 일의 양수, m 은 \vec{w}' 의 성분중 하나만 e' 보다 클때까지의 수이며 $f(\vec{w}', m)$ 은 가장 큰 \vec{w}' 의 성분중 하나에 대하여 $1/w_k'$ 의 값을 가지고 나머지에 대하여 0을 갖는 함수이다.

III. SOFM형식의 학습 방정식 유도

학습을 위한 목적함수는 2절에서 구한 Lagrangian을 사용하여 다음과 같은 Entropy함수로 놓는다.

$$H = -\sigma^2 \log \sum_i \exp(-\mathcal{L}_i / \sigma^2) \quad (6)$$

이 함수는 Lagrangian이 최소의 값을 가질때와 정보의 양이 가장 작도록 하는 각 k , 즉 전체 도시의 수에 대한 라그랑지안이 평균값에 접근 할때 가장 작은 값을 가지도록 하여 Energy Contour의 변화가 극소 최소점의 경우보다 비교적 작은 전역점 주변을 찾아갈 수 있도록 한다.

학습 방정식은 (6)식에 최고 경하법(Gradient Descent Rule)을 적용하여 다음과 같이 유도한다.

$$\begin{aligned} w_k'^{t+1} &= w_k' - \frac{\partial H}{\partial w_k'} \\ &= w_k' - \eta \frac{\partial H}{\partial \mathcal{L}_i} \cdot \frac{\partial \mathcal{L}_i}{\partial w_k'} \\ &= w_k' - \eta \log \sum_i \exp(-\mathcal{L}_i / \sigma^2) \frac{\partial \mathcal{L}_i}{\partial w_k'} \end{aligned} \quad (7)$$

식 (7)에서 $\frac{\partial \mathcal{L}_i}{\partial w_k'}$ 를 구하기 위해 먼저 $\frac{\partial \mathcal{L}_i}{\partial p_k'}$ 를 구하면

$$\begin{aligned} \frac{\partial \mathcal{L}_i}{\partial p_k'} &= -2(a_{1k}^2 + a_{2k}^2)(p_{k+1}' + p_{k-1}' - 2p_k') - 2(\beta'_{k+1} - \beta'_k) \\ \frac{\partial \mathcal{L}_i}{\partial w_k'} &= \frac{\partial \mathcal{L}_i}{\partial p_k'} \frac{\partial p_k'}{\partial w_k'} = \frac{\partial \mathcal{L}_i}{\partial p_k'} f(\vec{w}', m) \end{aligned} \quad (8)$$

식 (5)에서 $\frac{\partial \mathcal{L}_i}{\partial p_k'}$ 는 $\frac{\partial \mathcal{L}_i}{\partial w_k'}$ 와 $f(\vec{w}', m)$ 함수의 특성 상 비례 관계에 있으므로 다음과 같이 근사화 할 수 있다.

$$\frac{\partial \mathcal{L}_i}{\partial p_k'} = \alpha \frac{\partial \mathcal{L}_i}{\partial w_k'} \quad (9)$$

식 (9)에 의해 $\frac{\partial \mathcal{L}_i}{\partial w_k'}$ 는 다음과 같이 유도 된다.

$$\begin{aligned} \frac{\partial \mathcal{L}_i}{\partial w_k'} &= -2\alpha(a_{1k}^2 + a_{2k}^2)(w_{k+1}' + w_{k-1}' - 2w_k') \\ &\quad - 2\lambda\alpha(\beta'_{k+1} - \beta'_k) \\ &= -2\alpha(a_{1k}^2 + a_{2k}^2)(w_{k+1}' + w_{k-1}') - 2\lambda\alpha\beta'_{k+1} \\ &\quad + 4(a_{1k}^2 + a_{2k}^2)\alpha w_k' + 2\lambda\alpha w_k' \\ &= -2\alpha((a_{1k}^2 + a_{2k}^2)(w_{k+1}' + w_{k-1}') + \lambda\beta'_{k+1}) \\ &\quad - (2(a_{1k}^2 + a_{2k}^2) + \lambda)w_k' \end{aligned} \quad (10)$$

식 (10)에서

$$x_j = \frac{(a_{1k}^2 + a_{2k}^2)(w_{k+1}' + w_{k-1}') + \lambda\beta'_{k+1}}{2(a_{1k}^2 + a_{2k}^2) + \lambda} \quad (11)$$

로 놓으면 학습 방정식은 다음과 같이 SOFM학습 방정식의 형태를 따른다.

$$w_k'^{t+1} = w_k' + \eta 2\alpha \log \frac{\exp(-\mathcal{L}_i / \sigma^2)}{\sum_i \exp(-\mathcal{L}_i / \sigma^2)} (x_j - w_k') \quad (12)$$

식 (12)는 그러나 극소 최소점을 않은 유통불통한 표면(Rugged Landscape)에 대하여 극소 최소점에 도달했을 때 Weight 값의 변화가 미소하므로 전역 최소점을 찾는 데 상당한 문제가 있다. 따라서 식 (12)는 적절한 방법으로 이를 빠져 나갈 수 있도록 일부 수정 되어야 한다.

IV. 이진 강화 함수와 학습 방정식의 수정

이진 강화 함수는 \vec{w}' 를 보다 전역 최소점(Global Minimum Point)으로 가깝게 보내게 하는 대체 쓰인다. 이진 강화 함수를 이용한 적용 필터 알고리즘은 다음과 같다[6].

$$\begin{aligned} c_{k+1} &= c_k - \alpha u_k \operatorname{sgn}(e_k) \\ e_k &= c_k \cdot u_k - d_k \\ u_k &= \varphi(x_k, x_{k-1}, \dots) \end{aligned} \quad (13)$$

식 (13)에서 φ 는 관찰 과정(Observable Process) x_k 를 데이터 과정 u_k 로 보내는 사상이며, d_k 는 요구 과정(Desirable Process), α 는 일정 적용 이득(Constant Adaptive gain)이다.

여기에서 $u_k = 1$ 로 놓고 $d_k = c^* \cdot u_k + f_k$ 로 놓으면 f_k 는 데이터 신호가 된다. c_k 와 d_k 가 동일 공간상에 존재한다면 이것 은 학습적 최급 강하법의 한 종류가 된다. 이에 따라 위 방정식을 고쳐쓰면 다음과 같다.

$$\begin{aligned} w_{k+1} &= w_k - \rho(t) \operatorname{sgn}(e_k) \\ e_k &= w_k - x_k \\ x_k &= w^* + n_k \end{aligned} \quad (14)$$

식 (14)에서 x_k 는 데이터 벡터 일, w^* 는 w 의 최적 경향 벡터 n_k 는 오차 혹은 잡음 벡터 일. $\rho(t)$ 는 시간에 따라 1의 발생 확률이 감소하는 멘델법수로서 다음을 만족한다.

$$\rho(t) \rightarrow 0 \text{ as } t \rightarrow \infty$$

이진 강화 함수의 수렴성 판별은 또한 다음과 같이 의하여 구한다.

$$\lim_{n \rightarrow \infty} \sup \frac{1}{n} \sum_{k=1}^n E|e_k| \leq E|e^*| + E\rho(t)h \leq E|e^*|$$

이진 강화 함수를 학습 방정식에 적용하기 위하여 다음과 같이 Fokker-Plank 방정식의 형태로 수정한다. 이때 2차 편미분 항은 일반적인 Fokker-Plank 방정식과는 달리 3차 이상의 편 미분 항도 반영할 수 있다고 가정한다[4].

$$w_k'^{t+1} = w_k' - \alpha \frac{\partial H}{\partial w_k'} + \beta \frac{\partial^2 H}{\partial w_k'^2} \quad (15)$$

이 방정식이 일반적인 Brownian 운동을 기술 할 수 있다면 극소 최소점에서 빠져 나갈 수 있는 충분한 에너지가 Weight Vector에 있는 것으로 생각할 수 있다. Fokker-Plank 방정식에서 Brownian 운동은 1차 편미분 항과 2차 편미분 항의 부호가 같으므로 학습방정식은 다음과 같이 높을 수 있다[4]. 또한 $(x_j - w_k')$ 항 앞의 적용 이득 부분은 시간에 대한 합수로 대치한다.

$$w_k'^{t+1} = w_k' + \alpha(t)(x_j - w_k') + \beta(t)\beta \operatorname{sgn}(x_j - w_k') \quad (16)$$

식 (16)에서 $\alpha(t)$ 는 t 에 대한 단조감소 합수이며 β 는 이진 강화 합수의 적용 이득 $\operatorname{sgn}(\cdot)$ 은 1, 0 혹은 -1의 값을 갖는 Sigmoid 합수이다.

V. 실험 결과

본 논문에서 제안한 알고리즘은 10 city ring형 배치, 10 city random 배치, 14 city random 배치, 20 city ring형 배치, 20 city random 배치들에 대하여 수행했다. 각 도시들의 위치 벡터들은

$C^2[0,1]$ 공간 상에 놓았으며 다음의 학습순서에 따라 실험을 수행 하였다.

1. 각 Parameter들을 초기화한다. Matrix $P_{j,ps}^t$, P^t , W^t , PM_j^t 의 (i,j) 번째 Component들은 다음과 같다.

$$p_{ij}^0 = p_{ji}^0 = w_{ij}^0 = p_{mj}^0 = \delta(i-j) \quad (17)$$

식 (17)에서 $P_{j,ps}^t$ 은 Epoch t에서의 j 번째 도시에 대한

Index Matrix로서 j 번째 Column을 제외한 모든 요소는 P^t 와 같다. PM_j^t 는 j 번째 도시에 대한 Permutation Matrix로 Index Matrix를 변화 시키는데 사용된다.

2. city j 에 대한 w_{kj}^{t+1} 를 모든 k에 대하여 제안한 학습 방정식을 통해 구한다.

3. 학습 방정식을 통해 구해진 p_{kj}^{t+1} 을 Normalize한다.

$$w_{kj}^{t+1} = \frac{w_{kj}^{t+1}}{\sum_k w_{kj}^{t+1}}$$

이로서 제한조건 $0 \leq w_{kj}^{t+1} \leq 1$ 이 만족된다.

4. $i = \arg \max_k w_{kj}^{t+1}$ 를 사용하여 j 번째 city에 대한 Permutation Matrix PM_j^{t+1} 를 구한다. i는 다음 도시에 대한 Index, j는 현재 도시에 대한 Index를 의미한다.

5. 현재의 $W_{j,ps}$ Matrix에 대하여 다음을 구한다.

$$P_{j,ps}^{t+1} = PM_j^{t+1} P^t$$

6. 이때의 Index Energy $E_j^{t+1} = \exp(-\mathcal{L}_j/\sigma^2)$ 은 $P_{j,ps}^{t+1}$ 에 대하여 구한다.

7. 전체 j에 대하여 2-5를 반복한다.

8. 현재 Epoch $t+1$ 에서의 최대 Index Energy E_{\max}^{t+1} 와 Index인 max를 구하여 그때까지의 Index Energy E_{\max}^t 와 비교하여 다음에 따라 Index Matrix를 구한다.

$$\begin{cases} E_{\max}^{t+1} \geq E_{\max}^t & P^{t+1} = PM_{\max}^{t+1} P^t \\ E_{\max}^{t+1} < E_{\max}^t & P^{t+1} = P^t \end{cases}$$

9. 이를 정해진 Epoch가 끝날 때 까지 반복한다.

제안한 알고리즘에서 각각의 적용 이득은 다음과 같다.

$$\alpha(t) = 1 - \frac{\text{현재 Epoch 수}}{\text{전체 Epoch 수}}$$

$$\rho(t) = \begin{cases} x_1 \geq x_0 & 1.0 \\ x_1 < x_0 & 0.0 \end{cases}$$

$$\beta = 0.15 \quad \lambda = 0.0025$$

위 식에서 x_i 은 전체 Epoch 수에서 현재 Epoch 수 사이에 random하게 선택된 수이며 x_0 는 현재 Epoch 수의 1/10 사이에 Random하게 선택된 수이다. Ring으로 배치 된 도시의 경우 20 City까지 초기 Random한 배치에서 Ring 배치를 찾아 냈으며 $C^2[0,1]$ 공간 상에 City들이 Random하게 배치된 경우 그림과 같이 20 City 까지 최적 경로를 찾아냈다.

VI. 결 론

본 논문에서는 이진 강화 핵수와 결합된 SOFM형식의 TSP문제 해결 알고리즘을 제안하고 이를 위한 Lagrangian을 유도 하였으며 실험을 통해 제안한 알고리즘의 타당함을 보았다. 본 알고리즘은 도시의 수가 N으로 증가할 경우 연산시간은 거의 N²배 증가하므로 비고적 빠르게 해를 구할 수 있으며 Lagrangian Multiplier를 고려할 필요 없이 고정된 값으로도 Feasible한 해를 구할 수 있다. 제안한 알고리즘은 국소 최소점에 빠지더라도 이진 강화 핵수와 1차 편미분량의 상호 작용으로 국소 최소점을 빠져 나갈 수 있는 특징이 있다. 그러나 제안한 알고리즘은 언제나 최적해를 보장 할 수 있는 것은 아니며 비고적 최적해에 가까운 근사해를 보장 할 뿐이다. 그 이유는 국소 최소점에서 1차 편미분 항의 크기가 매우 작을 뿐 아니라 이진 강화 핵수는 양자화 된 값만을 발생 시키므로 이에 의해 보다 넓은 범위에 대한 검색을 할 수 없기 때문이다. 이 경우 Epoch수를 보다 크게 할 경우 그 만큼 넓은 범위에 대한 검색을 행할 수 있다. 제안한 알고리즘은 TSP문제를 응용한 여러 문제에 모두 적용할 수 있으며 앞으로 알고리즘의 동적 특성을 분석하여 보다 최적해를 찾을 확률을 높이는 연구도 진행 될 것이다.

참고문헌

- [1] H.Ritter K.Schulten "Convergence Properties of Kohonen's Topology Conserving Maps : Fluctuations, Stability, and Dimension Selection" Biol.Cybern. 60,59-71 (1988)
- [2] T.Kohonen 'Self Organization and Associative Memory' Springer-Verlag 3rd printing 1989
- [3] E.Dormany J.L.van Hemmen K.Schulten (Eds.) 'Models of Neural Networks' Springer-Verlag 2nd printing 1992
- [4] van Kampen Stochastic Processes in Physics and Chemistry North-Holland 1981. Amsterdam
- [5] C.Darken J.Moody 'Note on Learning Rate Schedule for Stochastic Optimization'
- [6] A.Gersho "Adaptive Filtering with Binary Reinforcement" IEEE Trans.Inform. vol IT-30, 2,March 1984
- [7] L.Bottou P.Gallinari "A Framework for the Cooperation of Learning Algorithm" pp781 - 788
- [8] S.Y.Kung Digital Neural Networks Prentice Hall, Englewood Cliffs, NJ, 1993
- [9] H.Ritter K.Schulten T.Martinetz 'Neural Computation and Self-Organizing Maps' Addison Wesley Publishing Company, 1992.

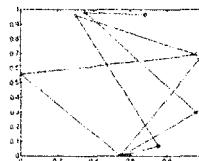


그림 1
10City Ring형 초기배치

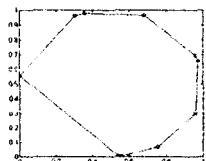


그림 2
100 Epoch 학습결과

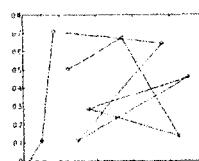


그림 3
10 City Random 초기 배치

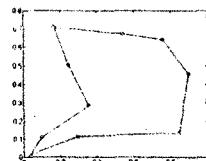


그림 4
100 Epoch 학습결과
총 길이 0.902072

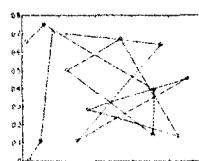


그림 5
14 City Random 초기 위치

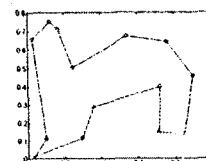


그림 6
400 Epoch 학습결과
총 길이 0.904554

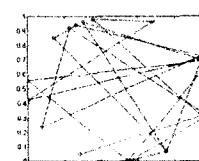


그림 7
20City Ring형 초기배치

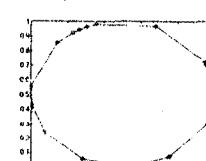


그림 8
400 Epoch 학습결과

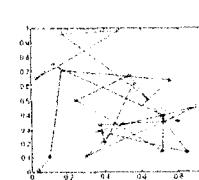


그림 9
20 City Random 초기배치

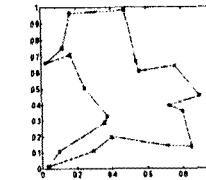


그림 10
400 Epoch 학습결과
총 길이 0.909072