システム制御情報学会論文誌, 4 巻, 1 号, pp. 48~56 (1991)

神経回路モデルによる最適化計算 —回路ブロック配置問題を例として—

喜多 一・小谷 英之・西川 禎一

Hopfield 型ニューラルネットワークによる組合せ最適化については、多くの報告があるが、その有効性と問題点の解明は未だ不十分である。本論文ではこの手法の有効性を回路ブロック配置問題を例として検討する。シミュレーションの結果、本手法では対象問題の特性を十分に吟味してネットワークを設計する必要があり、適切な設計が可能なとき、かなり良い解が見い出されることが示された。また良いパラメータ値の設定についての、理論的な考察も合わせて行なう。

システム制御情報学会論文誌, 4 巻, 号, pp. 57~59 1991)

ニューラルネットワークによる巡回セールスマン問題の一解法 —Kohonen の自己組織化特徴図における抑制入力信号の導入

田村 担之・寺岡 照彦
鳩野 逸生・山縣 敬一

本稿では、ニューラルネットワークの一モデルである Kohonen の自己組織化特徴図 (Self-organizing feature map) に対して、抑制入力信号を導入することにより、高速に巡回セールスマン問題の近似解（準最適解）を求める方法について述べる。

研究速報

ニューラルネットワークによる巡回セールスマン問題の一解法
—Kohonenの自己組織化特徴図における抑制入力信号の導入*

田村 坦之**・寺岡 照彦***・鳩野 逸生**・山縣 敬一**

A Method of Solving Traveling Salesman Problems Using a Neural Network
—Introducing the Inhibitory Signal into Kohonen's Self-organizing Feature Maps*Hiroyuki TAMURA**, Teruhiko TERAOKA****,
Itsuo HATONO** and Keiichi YAMAGATA**

1. まえがき

ニューラルネットワークの応用分野の一つとして、巡回セールスマン問題 (Traveling Salesman Problem, TSP) などの組合せ最適化問題の近似解法が注目されている¹。巡回セールスマン問題は、いくつかの都市と、それらの間の距離が与えられたときに、すべての都市を巡回する最短の経路を求める問題として与えられる。これは組合せ最適化問題における NP 完全問題²の一つで、大規模な問題に対して最適解を求めることが非常に困難な問題であることが知られている。

ニューラルネットワークによる解法は、準最適解を高速に求めることを目的としている。TSP を解くにあたり、Hopfield モデル³やボルツマンマシン⁴、および Kohonen によって提案された自己組織化特徴図⁵ (Self-organizing Feature Map, SFM) の応用⁶などが提案されている。本稿では、抑制性の入力信号を導入することにより、SFM を用いたアルゴリズムを拡張し、TSP 求解を高速化することを試みる。

2. 拡張 SFM による TSP の解法

Kohonen の SFM を用いた TSP の解法は、大規模な問題に適用可能で、解を求めるまでに要する計算時間が他の方法にくらべて飛躍的に少ないという利点がある。

しかし、このアルゴリズムは、入力信号に対する分解能が低く、問題によっては収束が悪い、あるいは収束しないという欠点がある。本稿では、このような問題点を克服するため、SFM に抑制入力信号および抑制入力信号に対する学習を導入した拡張 SFM (Ex-SFM) を提案する。本稿における TSP 求解のための拡張 SFM モデルを Fig. 1 に示す。このモデルは、二つの入力ニューロン、一つの抑制入力ニューロンおよび円状に配置した M 個の出力ニューロンからなり、出力ニューロンは入力ニューロンおよび抑制入力ニューロンとそれぞれ重みつきで結合されている。

Fig. 1 Ex-SFM model for solving TSP

求解のアルゴリズムは次のようになる。ここで、都市の数を N 、ニューロンの数を $M = 2.2 \sim 2.5 N$ 、各都市の座標を $A_i (i = 1, \dots, N)$ 、ニューラルネットワークへの入力信号を x 、シナプス荷重を $w_j (j = 1, \dots, M)$ 、抑制入力信号を x_0 (定数で 1)、抑制入力に対するシナプス荷重を $-w_{j0} (j = 1, \dots, M)$ とする ($A_i, x, w_j \in$

* 原稿受付 1990. 6. 5

** 大阪大学 工学部 Faculty of Engineering, Osaka University; 2-1, Yamada-oka, Suita 565, JAPAN.

*** 大阪大学 大学院 工学研究科

Key Words : neural network, traveling salesman problem, suboptimal solution, Kohonen's self-organizing feature map, inhibitory signal.

$[0, 1]^2$).

Step 1. シナプス荷重の初期化

シナプス荷重 $w_j (j=1, \dots, M)$ は N 個の都市の座標 $A_i (i=1, \dots, N)$ の重心を中心として, $j=1$ から M まで順番に円状に配置する. ただし, その半径は任意とする. また, 抑制入力に対するシナプス荷重は $-w_{j0} = 0 (j=1, \dots, M)$ とする.

Step 2. 入力の選択

$x(t)$ として $A_i (i=1, \dots, N)$ の中からランダムに選択する.

Step 3. 最も近いニューロン c を選定する.

$$\min_j \{ \|x(t) - w_j(t)\|^2 + \|x_0(t) + w_{j0}(t)\|^2 \}$$

Step 4. c およびその近傍 N_c のニューロンのシナプス荷重を修正する.

$$w_j(t+1) = \begin{cases} w_j(t) + \alpha(t) [x(t) - w_j(t)] & j \in N_c(t) \\ w_j(t) & \text{otherwise.} \end{cases}$$

$$-w_{c0}(t+1) = -w_{c0}(t) - \beta(t) [x_0(t) + w_{c0}(t)]$$

$$-w_{j0}(t+1) = \begin{cases} -w_{j0}(t) + \gamma\beta(t) [x_0(t) + w_{j0}(t)] & \text{for } j = c+1, c-1 \\ -w_{j0}(t) & \text{otherwise.} \end{cases}$$

ここで, $0 < \alpha, \beta, \gamma < 1$, α, β, N_c はそれぞれ繰り返しステップ t の減少関数である.

Step 5. 収束判定

次の収束条件を満たせば終了し, そうでなければ $t+1 \rightarrow t$ として Step 2 に戻る.

$$\forall i, \exists j \|A_i - w_j\| \leq \lambda$$

ここで Step 4 において, 最近接ニューロン c のシナプス荷重は入力信号へさらに接近するが, それと同時に抑制入力に対するシナプス荷重の値も大きくなる. このため, 同じ入力信号に対して次の繰り返しでは最近接ニューロンになりにくくなり, 他のニューロンが最近接になる可能性が生じる. これにより, 繰り返しの初期において特定の入力信号に対して特定のニューロンが最近接になることが避けられ, 入力信号のより効率的な量子化を実現している.

このアルゴリズムによって巡回が求められる原理は次のように説明できる. 最近接ニューロン c は自分にいちばん近い都市へ, その近傍 N_c を引き連れて近づいていく. 最終的に, N 個のニューロンのシナプス荷重が, N 個すべての都市のベクトルと一致するように特定されたとき, 巡回が完成する. この結果, ネットワークにおいて隣り合うニューロンの近き関係が巡回上に写像され, 都市の間の距離が近くなるように巡回が形成される

ことになる.

3. シミュレーションおよび結果

上記のアルゴリズムを用いて 100 都市の TSP を解いた結果が Fig. 2 であり, この都市配置での拡張 SFM と従来の SFM の結果の比較を Table 1 に示す. また, Fig. 2 よりも, 少しかたよりを持った都市配置での比較を Table 2 に示す. ここで, 計算パラメータはそれ

(a) Start configuration

(b) After 10,000 steps

(c) Final configuration (25,509 steps)

Fig. 2 100-cities TSP

Fig. 3 The neighbor ($t_1 < t_2 < t_3 < t_4$)

Table 1 Comparison between SFM and Ex-SFM

	Neurons	Tour length	Time	Steps	Probability
SFM	220	9.611	90.8	45939	24.0
	250	9.604	100.9	46659	57.1
Ex-SFM	220	9.741	53.8	21971	86.4
	250	9.844	58.8	22227	87.0

Table 2 Comparison between SFM and Ex-SFM
(another configuration)

	Neurons	Tour length	Time	Steps	Probability
SFM	220	8.425	85.3	44521	24.9
	250	8.419	113.0	51976	20.0
Ex-SFM	220	8.691	47.9	19610	91.4
	250	8.712	55.1	20114	79.1

Neurons : Number of neurons
 Time : Computation time (sec)
 Steps : Number of iterative steps
 Probability : Probability of convergence (%)

ぞれ次のように設定した。 $\alpha = 0.3/(1.0 + \log(\text{step}))$, $\beta = 0.001 \alpha$, $\gamma = 0.025$, $\lambda = 0.01$. なお近傍 N_c は, Fig. 3 に示すようにヒューリスティックに, 時間と共にその範囲を狭くしていく。また, 計算はいずれも, ワークステーション Sun SPARC station 1 で行なった。

2 種類の都市配置のどちらにおいても, 拡張 SFM では, 従来よりも繰り返し計算ステップ数がかなり少なくなっているため, 計算に必要な時間が減少している。さらに, ニューロン数が少なくても非常に高い収束性が得

られている。これは都市配置にかたよりのある場合に顕著である。また, パラメータ調整が多少いい加減であっても収束するという結果も得られた。これらは信号に対する分解能の向上のためである。よって都市の数が多くなるほど, SFM に比べて拡張 SFM の有用性が増すものと思われる。

4. むすび

組合せ最適化問題の難問, 巡回セールスマン問題を, ニューラルネットワークによって解く一つの方法として拡張 SFM を提案した。この方法による解も従来の方法と同様に最適解が求まるという保証は全くない。しかし, 長い時間をかけて最適解を求めても実用的には役に立たず, 近似解であってもできるだけ速く解を求めることが重要である。拡張 SFM は TSP に関するかぎりはその性質を満たし, 様々な解法の中でも優れたものと思われる。ただし, 本アルゴリズムでは, 求められる解の精度や収束特性は実験で評価せざるを得ず, 現段階では理論的な議論を展開するには至っていない。

参考文献

- 1) 喜多：ニューラルネットワークと組合せ最適化；システム/制御/情報，34 巻，4 号，pp. 241～248 (1990)
- 2) 茨木：組合せ最適化，産業図書(1983)
- 3) J. J. Hopfield & D. W. Tank：Neural Computation of Decisions in Optimization Problems；Biological Cybernetics, Vol. 52, pp. 141～152 (1985)
- 4) E. H. L. Aarts & J. H. M. Korst：Boltzmann Machines for Travelling Salesman Problems；European Journal of Operational Research, Vol. 39, pp. 79～95 (1989)
- 5) T. Kohonen：Self-Organization and Associative Memory (2nd Ed.), Springer-Verlag (1988)
- 6) H. Ritter & K. Schulten：Kohonen's Self-Organizing Maps：Exploring their Computational Capabilities；Proc. IEEE 2nd International Conference on Neural Networks (ICNN-88), Vol. I, pp. 109～116 (1988)