法政大学学術機関リポジトリ

HOSEI UNIVERSITY REPOSITORY

PDF issue: 2025-05-14

成長型自己組織化マップと成長型ニューラル ガスの工学的応用に対する基礎研究

砂川, 一樹 / SUNAKAWA, Kazuki

(発行年 / Year) 2012-03-24

(学位授与年月日 / Date of Granted) 2012-03-24

(学位名 / Degree Name) 修士(工学)

(学位授与機関 / Degree Grantor) 法政大学 (Hosei University)

2011年度 修士論文

論文題名 成長型自己組織化マップと 成長型ニューラルガスの 工学的応用に対する基礎研究

指導教授 斎藤 利通 教授

法政大学大学院工学研究科

電気工学専攻修士課程

学生証番号: 10R3127

スナカワ カズキ

氏名 砂川 一樹

あらまし

本論文は自己組織化マップとニューラルガスのアルゴリズム改良と工学的応用につい て研究する。

2章では成長型ニューラルガスを画像認識の基礎技術である画像骨格抽出に応用する。 また成長型自己組織化マップを用いた手法と比較し考察する。画像データを入力デー タとして与え、学習をしマップはトポロジーを獲得する。適切にパラメータを選ぶこ とによって、効率よく抽出することが可能になる。

3章では自己組織化マップの勝者セルと近傍セルとの関係に注目する。近傍関係を現 在の情報だけでなく、過去の情報を取り入れる。このアルゴリズムを最適化問題の1 種である巡回セールスマン問題へ応用する。この手法を取り入れることによって従来 手法より解のばらつきが少なくなることが分かる。

4章では並列化に注目する。並列化アルゴリズムを自己組織化マップに応用する。またこのアルゴリズムを巡回セールスマン問題に応用する。並列化を行い探索時間が大幅に減少することを示す。並列化の手法を自己組織化マップと適応共鳴理論写像で比較する。

Abstract

This paper studies application of Self-Organizing Maps (SOM) and Neural Gas (NGA). In chapter 2, we introduce growing structure to the NGA and SOM. The growing NGA is applied to skeltonization of the basic technology of image recognition. And we compare NGA to Growing SOM (GSOM). As image data input is given, the map topology can vary to adapt the input. If parameter are selected suitably. The skelton can be extracted efficiently.

In chapter 3, we consider relationship between winner cell and neighbor cell the SOM. In update of neighbor cells of the winner, the learning coefficient changes depending on the past history of distance between cells. We apply the GSOM to Traveling Sales person Problems (TSP). We can find suitable tour with relatively small variation. In chapter 4, we consider parallel algorithm. We apply SOM to parallel algorithm. Performing parallel processing, we are indicated that execution time is considerably reduced. We compare parallel algorithm by SOM and to that by Radial Basis Adaptive Resonance Theory maps.

目 次

第1章	はじめに	8
1.1	自己組織化マップ................................	8
1.2	成長型自己組織化マップ................................	8
1.3	成長型ニューラルガス	9
第2章	GNG と GSOM の画像骨格抽出への応用	12
2.1	まえがき...................................	12
2.2	GNG の学習アルゴリズム	12
2.3	GSOM の 学習アルゴリズム	14
2.4	数值実験....................................	16
2.5	まとめ	17
第3章	LDSOM の TSP への応用	31
第3章 3.1	LDSOM の TSP への応用 まえがき	31 31
第3章 3.1 3.2	LDSOM の TSP への応用 まえがき	31 31 32
第3章 3.1 3.2 3.3	LDSOMのTSPへの応用 まえがき LDSOMの学習アルゴリズム 数値実験	 31 31 32 34
第3章 3.1 3.2 3.3 3.4	LDSOMのTSPへの応用 まえがき	 31 32 34 35
第3章 3.1 3.2 3.3 3.4 第4章	LDSOM の TSP への応用 まえがき LDSOM の学習アルゴリズム 数値実験 まとめ 並列化 GSOM を用いた TSP への応用	 31 31 32 34 35 45
第3章 3.1 3.2 3.3 3.4 第4章	LDSOMのTSPへの応用 まえがき	 31 31 32 34 35 45 45
第3章 3.1 3.2 3.3 3.4 第4章 4.1	LDSOMのTSPへの応用 まえがき LDSOMの学習アルゴリズム 数値実験 支め 並列化 GSOM を用いた TSP への応用 まえがき	 31 31 32 34 35 45 45
第3章 3.1 3.2 3.3 3.4 第4章 4.1 4.2	LDSOMのTSPへの応用 まえがき LDSOMの学習アルゴリズム 数値実験 支め ・	 31 31 32 34 35 45 45
第3章 3.1 3.2 3.3 3.4 第4章 4.1 4.2 4.3	LDSOMのTSPへの応用 まえがき LDSOMの学習アルゴリズム 数値実験 支め まとめ 並列化 GSOM を用いた TSP への応用 まえがき 並列化アルゴリズム 並列化 GSOM の学習アルゴリズム	 31 31 32 34 35 45 45 45 46

4.5	まとめ	52
第5章	むすび	64

図目次

1.1	SOM の構造図	11
2.1	GNG アルゴリズムのフローチャート図	18
2.2	GNG の細胞更新	19
2.3	細胞の挿入	20
2.4	トポロジーの生成...............................	21
2.5	枝の追加...................................	22
2.6	枝の削除..................................	23
2.7	GSOM アルゴリズムのフローチャート図	24
2.8	GSOM の細胞更新	25
2.9	GSOM の細胞挿入	26
2.10	GNG の数値実験(円)	27
2.11	GNG の数値実験(法)	28
2.12	GSOM の数値実験(円)	29
2.13	GSOM の数値実験(法)	30
3.1	LDSOM の学習フローチャート	37
3.2	LDSOM の細胞挿入	38
3.3	都市との対応付け・・・・・・・・・・・・・・・・・・・・・・・・・・・・・・・・・・・・	39
3.4	近傍の変化図	40
3.5	数值実験 52 都市	41
3.6	数值実験 100 都市	42
3.7	ヒストグラム 48 都市	43

3.8	ヒストグラム 100 都市	44
4.1	都市の領域分け	53
4.2	端細胞の更新	54
4.3	RB-ART アルゴリズムのフローチャート	55
4.4	領域分割 (280 都市)	56
4.5	並列化 GSOM の学習過程 (280 都市)	57
4.6	領域分割 (436 都市)	58
4.7	並列化 GSOM の学習過程 (436 都市)	59
4.8	RB-ART を用いた領域分割 (280 都市)	60
4.9	RB-ART を用いた並列化 GSOM の学習過程 (280 都市)	61
4.10	RB-ART を用いた領域分割 (436 都市)	62
4.11	RB-ART を用いた並列化 GSOM の学習過程 (436 都市)	63

表目次

3.1	48都市を用いた数値実験	35
3.2	100都市を用いた数値実験	36
4.1	数值実験 280 都市	51
4.2	数値実験 436 都市	51
4.3	RB-ART を使用した数値実験 280 都市	51
4.4	RB-ART を使用した数値実験 436 都市	51

第1章 はじめに

1.1 自己組織化マップ

ニューラルネットワークの中には学習によって情報処理能力を獲得することがある。 学習には教師あり学習と教師なし学習があり、本論文で扱うT.Kohonenの自己組織化 マップ (Self-Organizing Maps :SOM) は教師なし学習の代表例として知られている[1]。 図 1.1 に SOM の構造図を示す。この図は2層1次元のマップである。すべての入力は SOM のすべてのノードに与えられる。また、独立した出力層は存在せず、平面内のす べてのノードはそれがそのまま出力ノードとなる。SOM は入力データの特徴を抽出で きる簡素な学習アルゴリズムである。簡単にまとめると

・入力データに最も近い重みベクトルを持つセルを探し勝者セルとする

・勝者セルを決定し、そのセルと近傍関係を持つセルの距離を減少させる

応用例として特徴抽出やデータクラスタリング、領域分割等の様々な例に応用されている。

1.2 成長型自己組織化マップ

SOM の機能をより効率よく学習させるために、入力の状態に合わせてマップの大きさ やトポロジーといったものを変化せる必要がある。これらの論文はSOM に成長構造を 持たせたアルゴリズムを提案している。このアルゴリズムを成長型自己組織化マップ (Growing SOM :GSOM)と呼ぶ。このアルゴリズムはパラメータを適切に設定するこ とで SOM の本来の機能がより改良され効率よく学習を行うことが可能になる。このア ルゴリズムによってより複雑な問題に応用がされている。例として、最適化問題や画 像認証やカラー量子化など様々なものに応用されている[2]-[6]。

1.3 成長型ニューラルガス

ニューラルガス (Neural Gas)[7] は自己組織化マップと同じく教師なしニューラルネッ トワークスの1種であり、入力に近い重みベクトルから順位付けし順位に基づいてす べての重みが更新されるアルゴリズムである。これはクラスタリングやパターン認識 などに応用されている。しかしこのアルゴリズムだと初期値に依存することが多く、初 期値に依存することなく効率よく学習を行うために成長構造を持ったニューラルガス (Growing NG :GNG) が提案された [8]。このアルゴリズムは SOM と同様にパラメー タを適切に設定することによりマップの大きさに関係なく学習することが出来る [9]。

本論文は以下のように構成される。

まず2章では画像骨格抽出について説明する。画像骨格抽出は画像認識の1種であり 最先化の1つとして様々な方法によって研究がおこなわれている。本章ではGNGに応 用する。GNG は入力データに文字データを与え学習終了後に各細胞を線でつなげるこ とで骨格を形成する。またこの章ではGSOM を使用したデータと比較を行う。

3章ではSOMのアルゴリズムの中でも近傍細胞との繋がりを考察する。近傍細胞は現 在の勝者細胞とマップ上の結合関係によって決定される。しかし現在の情報が優れた 値を取っていても過去の情報が同じく優れた情報とは限らない。この章ではSOMの近 傍細胞の更新過程に現在の情報だけではなく過去の情報を取り入れた成長型自己組織 化マップ (GSOM using Local Distance Information :LDSOM)を提案する。またこの 手法を最適化問題の1種である巡回セールスマン問題へ応用する。

4章では並列化について考える。SOM はアルゴリズムが簡素ではあるが、入力データ 数が増加することによって計算速度が増加していく。この問題を解決するための方法

9

の1つとして並列化がある。入力データを複数の領域に分割し各領域にて学習を行う。 今回は3章と同じく巡回セールスマン問題に応用する。最初に基本的なSOMを使用し 領域分割を行う。細胞数が領域分割数となる。また学習終了後にすべての細胞と入力 データを比較し、一番距離が近い細胞のカテゴリに入力を所属させる。その後GSOM を利用し学習を行う。

5章では2章から4章までのまとめを行い考察する。



図 1.1: SOM の構造図

第2章 GNGとGSOMの画像骨格抽出 への応用

2.1 まえがき

本章では画像骨格抽出への応用例を考える。画像骨格抽出は画像認識技術の基礎的な 技術の1つであり様々な研究がされている。応用例として指紋認証や文字認証などが ある。本論文はGNGが使用した画像骨格抽出を提案しGSOMを使用した手法と比較 考察を行う。最初にGNGのアルゴリズムを説明する。GNGの学習終了後にマップの トポロジーを形成する。形成方法として、最少全域木の生成、木の追加、削除がある。 これをマップの状況によって選択しトポロジーを獲得する。

2.2 GNGの学習アルゴリズム

以下に GNG を用いた画像骨格抽出のアルゴリズムを示す。入力データ、各細胞の重み ベクトルは 2 次元座標のデータを持つ。以下にいくつかの定義をする。

離散空間 A の各細胞は i は、入力データ空間 X における入力ベクトル x と同次元の結合重みベクトル w_i を持つものとする。離散空間 A の各細胞 i はカウンタ C_i を持つものとする。以下に学習アルゴリズムを示す。

STEP 1(初期化)

初期の繰り返し回数を t = 0 とし初期細胞数 N(0) を任意に、各重みベクトル $w_i(0)$ を 適当な値に初期化する。また、各重みのカウンタ $C_i(0) = 0$ とする。入力データを x と し時間 t の入力データを x(t) とする。 STEP 2(入力の提示)

画像データから一様分布に入力データを与える。

STEP 3(入力との比較)

与えられた入力データをすべての細胞と次式にて計算する。

$$D_i = ||x(t) - w_i(t)||$$
(2.1)

STEP 4(細胞の更新)

すべての D_i を比較し、距離の小さい順に細胞を並べ替え、その添え字を k する $(D_k : D_0 < D_1 < < D_{N-2} < D_{N-1})$ 。すべての細胞の重みベクトルおよびカウンタは式 (2.2)(2.3)によって更新される。

$$w_i(t+1) = w_i(t) + h_k(t)(x(t) - w_i(t))$$
(2.2)

$$h_k = \alpha \exp(-k_i) \tag{2.3}$$

 α は学習係数。k = 0の細胞をa、aに1番距離が近い細胞をbとして式 (2.4)を満たす ときカウンタを更新する。

$$||x(t) - w_a(t)|| > (||w_a(t) - w_b(t)||)^{\frac{t}{T_{max}}}$$
(2.4)

$$C_a(t+1) = C_a(t) + 1 \tag{2.5}$$

STEP 5(細胞の増加)

繰り返し回数tが T_{int} 回毎に各細胞のカウンタを比較し最大のカウンタの持つ細胞cを 探す。そして次式を満たす時新規細胞を挿入する。

$$C_c(t) > (t/N) \tag{2.6}$$

新規細胞をrとし細胞cに1番近い細胞をdとして次式により更新する。

$$w_r(t+1) = \frac{(w_c(t) + w_d(t))}{2}$$
(2.7)

$$N(t+1) = N(t) + 1$$
(2.8)

$$C_r(t+1) = \frac{C_c(t)}{3}$$
(2.9)

$$C_c(t+1) = \frac{C_c(t)}{3} \tag{2.10}$$

t = t + 1

もし $t < T_{max}$ の場合はSTEP2に戻る。

STEP 6(トポロジーの生成)

プリムのアルゴリズムを用い各細胞を最短の木で結ぶ最小全域木 (MST: Minimum Spanning Tree)を生成する [10]。すべての細胞に対し1番目2番目に近い細胞を探す。その 2つの細胞が繋がっていない場合その細胞同士を繋げる。また繋がり関係がある細胞 間の距離を求め、あるしきい値を超えた場合繋がりを削除する。

$$||w_i - w_j|| > \epsilon_{cut} \cdot d_{ave} \tag{2.11}$$

 d_{ave} はすべての枝の平均距離、 ϵ_{cut} はパラメータである。

2.3 GSOMの学習アルゴリズム

次に GSOM を使用した画像骨格抽出のアルゴリズムを示す。NGN のアルゴリズムと 同じく入力データ x(t)、i 番目の細胞の重みベクトル w_i(t) は 2 次元の座標を持つ。ま た各細胞には成長構造を促すカウンタ C_i(t) を持つ。また初期状態では各細胞はラダー 型のトポロジーで細胞がつながっている。ある細胞とつながっている細胞のことを近 傍細胞と定義する。以下に学習アルゴリズムを示す。

STEP 1(初期化)

初期の学習回数 t = 0 とし初期細胞数 N(0) を任意に、重みベクトル $w_i(0)$ を適当な値 に初期化する。また、各重みのカウンタ $C_i(0) = 0$ とする。入力データを x とし i 番目 の入力を x_i とする。

STEP 2(入力の提示)

画像データから一様分布に入力データを与える。

STEP 3(勝者細胞の決定)

与えられた入力データをずべての細胞と比較し1番距離が近い細胞cを決定しそれを

勝者細胞とする。

$$||x(t) - w_c(t)|| = \min ||x(t) - w_i(t)||$$
(2.12)

STEP 4(細胞の更新)

勝者細胞 c とその近傍細胞 k は次式によって更新される。

$$w_{i}(t+1) = \begin{cases} w_{i}(t) + \alpha(t)(x(t) - w_{i}(t)) & \text{if } i = c \\ w_{i}(t) + \alpha(t)(x(t) - w_{i}(t)) & \text{if } i = k \\ w_{i}(t) & \text{otherwise} \end{cases}$$
(2.13)

k:*c*の近傍

$$C_i(t+1) = \begin{cases} C_i(t) = C_i(t) + 1 & \text{if } i = c \\ C_i(t) & \text{otherwise} \end{cases}$$
(2.14)

 α は学習係数。

STEP 5(細胞の増加)

繰り返し回数 t が T_{int} 回毎に各細胞のカウンタを比較し最大のカウンタの持つ細胞 c を 探す。そして次式を満たす時新規細胞を挿入する。

$$C_c(t) > (t/N) \tag{2.15}$$

新規細胞をrとし細胞cに1番近い細胞をdとして次式により更新する。

$$w_r(t+1) = \frac{(w_c(t) + w_d(t))}{2}$$
(2.16)

$$N(t+1) = N(t) + 1$$
(2.17)

$$C_r(t+1) = \frac{C_c(t)}{3}$$
(2.18)

$$C_c(t+1) = \frac{C_c(t)}{3}$$
(2.19)

STEP 6(トポロジーの更新)

*T_{con}*回毎にマップの更新を行う。プリムのアルゴリズムを用い各細胞を最短の木で結 ぶ最小全域木を生成する。すべての細胞に対し1番目2番目に近い細胞を探す。その 2つの細胞が繋がっていない場合その細胞同士を繋げる。また繋がり関係がある細胞 間の距離を求め、あるしきい値を超えた場合繋がりを削除する。

$$||w_i - w_j|| > \epsilon_{cut} \cdot d_{ave} \tag{2.20}$$

 d_{ave} はすべての枝の平均距離、 ϵ はパラメータである。

STEP 7(終了の判断)

t = t + 1

もし $t < T_{max}$ の場合はSTEP2に戻る。

2.4 数值実験

まず、GNG を用いた画像骨格抽出を行うにつれて基本的な実験を行った。図 2.10 は ドーナッツ型の画像データであり、これを入力データとして使用した。以下に図 2.10 にて使用したパラメータを示す。

$$\alpha = 0.2, \ \epsilon_{cut} = 3, \ T_{int} = 100, \ T_{cut} = 100$$
 (2.21)

次第に細胞が成長しており入力データに対応していくのが分かる。最終的には入力デー タの中心に細胞が広がり、トポロジーの生成を行うことによってマップが形成し骨格 抽出が行われていることが分かる。

次に入力データに文字を扱った場合の考察を行う。今回は文字データに漢字の「法」を 使用した。この文字は部首にさんずいを使用しており、比較的難しい漢字になってい る。これを入力データとして使用した。図 2.11 に動作過程を示す。また使用したパラ メータを以下に示す。

$$\alpha = 0.15, \ \epsilon_{cut} = 3, \ T_{int} = 100, \ T_{cut} = 100$$
 (2.22)

前者と同じく細胞が成長を行い入力データに対応していくのが分かる。また、さんずいなどの離れている部分にも細胞が行き渡っており、学習終了後にマップのトポロジー

を生成するとすべての部位に対して骨格が形成されていることが分かる。 次にGSOMを用いた手法との比較を行う。図 2.12 図 2.13 にそれぞれ GNG と同じ入 カデータを使用し実験を行う。各図にて使用したパラメータを以下に示す。

$$\alpha = 0.1, \ \epsilon_{cut} = 2.5, \ T_{int} = 100, \ T_{cut} = 100$$
 (2.23)

学習が進むにつれマップ枝の追加や削除といったトポロジーの変化が行われ、学習終了後に骨格が形成されることが分かる。また T_{max} はGNGの終了時間と同じ $T_{max} = 10000$ に設定した。以下にそれぞれの手法での比較を行う。GNGの方がマップのトポロジーの生成をまとめて行うためより効率的な学習が可能になる。入力が円状のモデルでは両方の手法において抽出が完了し骨格が形成されている。文字入力においてはGNGの方が鮮明に抽出がされている。

2.5 まとめ

成長型ニューラルガスを提案し画像骨格抽出に応用した。本アルゴリズムは簡素な特 徴を持つ。基本的な数値実験によって本アルゴリズムによる有効性を示した。また従 来手法である成長型自己組織化マップと比較を行い本アルゴリズムの有効性を示した。 今後の課題としてより効率のよいアルゴリズムの改良や入力データにノイズを入れた 場合の解法の提案などが挙げられる。



図 2.1: GNG アルゴリズムのフローチャート図



図 2.2: GNG の細胞更新



図 2.3: 細胞の挿入



図 2.4: トポロジーの生成



図 2.5: 枝の追加



図 2.6: 枝の削除



図 2.7: GSOM アルゴリズムのフローチャート図



図 2.8: GSOM の細胞更新



図 2.9: GSOM の細胞挿入







図 2.11: GNG の数値実験(法)







図 2.13: GSOM の数値実験(法)

第3章 LDSOMのTSPへの応用

3.1 まえがき

巡回セールスマン問題は最適化問題の1種でありNP完全問題と呼ばれるクラスに属 する。この問題は入力データとしてある任意の数の都市データを与えた場合、すべて の都市を1巡回し最初の都市に戻り、その時の最短経路を求める問題である。都市数 を増加させると計算時間が指数関数的に増加する。ニューラルネットワーク(ポップ フィールドネット)を使用した計算方法など提案されているが複雑な計算を使用しな ければならない。本論文で論じる自己組織化マップは1次元のリング構造と成長構造 を持っているため、簡素な学習を進めることが出来る[11]-[13]。

本項目ではこの TSP に自己組織化マップの改良アルゴリズムである、局所距離情報を 使用した成長型自己組織化マップ (LDSOM)を提案する。このアルゴリズムは近傍細 胞とのつながりに注目する。。近傍細胞は現在の勝者細胞とマップ上の結合関係によっ て決定される。しかし現在の情報が優れた値を取っていても過去の情報が同じく優れ た情報とは限らない [14]。本アルゴリズムでは自己組織化マップの近傍細胞の更新過程 に現在の情報だけではなく過去の情報を使用する。

本章ではまず学習アルゴリズムを説明し、次に基本的な数値実験を行う。最後に従来のGSOMを使用した方法と比較し考察する。

31

3.2 LDSOMの学習アルゴリズム

本項目の SOM は離散空間 A の N 個の細胞で構成される。また細胞の結合を 1 次元リ ング配列にしている。また離散空間 A の各細胞は i は、入力データ空間 X における入 カベクトル x と同次元の結合重みベクトル w_i を持つものとする。各入力ベクトル x は 重みベクトル w_i を介して細胞 i と結合している。各細胞 i はカウンタ C_i を持つものと する。各細胞 i と近傍細胞 j 間には更新に作用する学習係数 $\alpha_{i,j}$ を持ち、その初期値は 学習係数 α_i と同じ 0.1 とする。

以下に LDSOM の学習アルゴリズムを示す。

Step 1 (初期化)

tを離散時間とする。t = 0の時、細胞の数をN(0)とする。 $w_i(i = 0 \sim N(0))$ を適当な 値に初期化し、各細胞のカウンタ $C_i(0) = 0$ とする。

Step 2 (入力の提示)

ある分布に従う入力データ x(t) を与える

Step 3 (勝者の決定)

入力信号に最も類似した結合重みベクトルを次式によって決定する。そして対応する 合志望を勝者 c する。

$$||x(t) - w_c(t)|| = \min ||x(t) - w_i(t)||$$
(3.1)

ただし||・||はユークリッド距離を用いることとする。

Step 4(細胞の更新)

勝者細胞 c とその近傍細胞 k は次式で更新される。ただし α_c は勝者 c を更新する学習

係数である。細胞 c が勝者になった回数をカウンタ C_c 更新式により更新する。

$$w_{i}(t+1) = \begin{cases} w_{i}(t) + \alpha_{c}(t)(x(t) - w_{i}(t)) & \text{if } i = c \\ w_{i}(t) + \alpha_{c,k}(t)(x(t) - w_{i}(t)) & \text{if } i = k \\ w_{i}(t) & \text{otherwise} \end{cases}$$
(3.2)

k:*c*の近傍

$$C_i(t+1) = \begin{cases} C_i(t) = C_i(t) + 1 & \text{if } i = c \\ C_i(t) & \text{otherwise} \end{cases}$$
(3.3)

Step 5(学習係数の更新)

勝者細胞 c とその近傍細胞 k の距離 $D_{c,k}(t)$ をそれぞれ計算する。その距離 $D_{c,k}(t)$ と勝 者細胞 c から $n(n = 1, 2, ..., \frac{N}{2})$ 近傍間の平均距離 $d_{ave}(t)$ を比較し $\alpha_{c,k}(t)$ を更新する。 n の変化による近傍の変化の様子を図 3.4 に示す。n = 1 の場合は勝者細胞 c から 1 近 傍の平均距離となり、 n_{max} はすべての枝の平均距離となる。これによって $d_{ave}(t)$ より $D_{c,k}(t)$ が小さければ $\alpha_{c,k}(t)$ の値が大きくなり近傍関係がより深まる。逆に $\alpha_{c,k}(t)$ の値 が小さくなることによって、近傍関係が浅くなる。 β は更新式を調整するためのパラ メータである。 $\beta = 0$ の場合は近傍とのつながりを均一にするアルゴリズムになる。近 傍学習係数には値の上限下限を設けている。

$$D_{c,k}(t) = ||w_c(t) - w_k(t)||$$
(3.4)

$$\alpha_{c,k}(t+1) = \alpha_{c,k}(t) + \beta(d_{ave}(t) - D_{c,k}(t))$$
(3.5)

$$\begin{aligned}
\alpha_{c,k}(t) &= \alpha_{max} & \text{if } \alpha_{max} < \alpha_{c,k}(t) \\
\alpha_{c,k}(t) &= \alpha_{min} & \text{if } \alpha_{min} > \alpha_{c,k}(t)
\end{aligned} \tag{3.6}$$

Step 6(細胞の挿入)

tが T_{int} 回ごとにカウンタが最大となる細胞qを探す。

$$C_q(nT_{int}) \ge C_i(nT_{int})$$
 for all i (3.7)

もしカウンタが最大のものが複数見つかった場合ランダムに選択する。qの近傍の中からqに最も遠い細胞fを探す。 $q \geq f$ の間に新規セルrを挿入する。細胞qと細胞rの

位置、カウンタを更新する。

$$w_r(t+1) = \frac{(w_q(t) + w_f(t))}{2}$$
(3.8)

(3.9)

$$C_q(t+1) = \frac{C_q(t)}{2}, C_r(t+1) = \frac{C_q(t)}{2}$$
(3.10)

$$\alpha_{r,j}(t+1) = 0.1\tag{3.11}$$

$$N(t+1) = N(t) + 1$$
(3.12)

Step 7 (繰り返し)

t = t + 1とする。 $t < t_{max}$ なら STEP2 へ戻る。 $t = t_{max}$ なら Step 8 へ進む Step 8 (都市への対応)

学習終了後にすべての細胞を各都市と比較し、一番距離が近い都市を選択し細胞と対応付ける。(ただし以前選択された都市は除く)対応付けした都市を細胞のつながりに 合わせて線を結ぶことで経路が決定される。

3.3 数值実験

本項目のアルゴリズムの有効性を示すために、基本的なTSPを使用した数値実験を行った。まず基本的なパラメータを以下に示す。

$$N(0) = 3, T_{int} = 100, \alpha_c = 0.1, \beta = 0.005$$
 (3.13)

本項目では2つの都市を使用し数値実験を行った。基本的な実験として48都市のTSP を使用した。また計算コストがよりかかる問題として、100都市のTSPデータを使用 した。この2つのデータは http://comopt.ifi.uni-heidelberg.de/software/TSPLIB95/ の都市データを使用した。図 3.5、図 3.6 に LDSOM を使用した数値実験の動作過程を 示した。繰り返し時間 t が進むにつれ入力データを学習し細胞が成長し次第に都市を 獲得していくことが分かる。学習終了後に都市と細胞を対応付けを行い経路が決定さ れる。この実験によって準最適解が獲得できることが分かる。次に表1、2に同じ実 験を100回行い、その際の最短、最長、平均経路長と標準偏差を横軸に示した。縦 軸は従来手法である GSOM および Step 5 にて設定した n を変化させた場合の実験結 果を示した。すべての値は最適解を1に正規化した場合の結果になっている。また図 3.7、図 3.8 に各都市の実験結果におけるヒストグラムを示した。

まず従来のアルゴリズムと提案アルゴリズムを比較する。提案アルゴリズムの方が短 い値を取っていることが分かる。従来手法は近傍関係を均一にし学習を行う。そのた めこの実験から近傍関係にばらつきを持たせることで、より良い解を求めることが出 来るのではないかと考える。次にLDSOM内での比較を行う。nは近傍学習係数を更 新する際に作用するパラメータである。表からn = 2の時が平均的に短い距離を獲得 している。またヒストグラムや標準偏差からもnは小さい値の方が解のばらつきが抑 えられることが分かる。そのためnを小さい値に設定することで安定した解の探索に 向いていると言える。

	最短経路長	最長経路長	平均経路長	標準偏差
GSOM	1.0019	1.0874	1.0401	1.5314E-2
LDSOM $n = 1$	1.0019	1.0801	1.0374	1.4741E-2
LDSOM $n = 2$	1.0019	1.0727	1.0350	1.4650E-2
LDSOM $n = 3$	1.0020	1.0772	1.0367	1.8767E-2
LDSOM $n = n_{max}$	1.0019	1.0812	1.0406	1.8694E-2

表 3.1:48都市を用いた数値実験

3.4 まとめ

本章ではSOMの近傍関係に注目し、局所距離情報を用いたGSOMを提案しこのアル ゴリズムを考察した。提案したアルゴリズムは近傍関係にばらつきを持たせる特徴が

	最短経路長	最長経路長	平均経路長	標準偏差
GSOM	1.0101	1.0875	1.0392	1.3830E-2
LDSOM $n = 1$	1.0098	1.0801	1.0358	1.3173E-2
LDSOM $n = 2$	1.0129	1.0723	1.0332	1.1141E-2
LDSOM $n = 3$	1.0090	1.0802	1.0367	1.5576E-2
LDSOM $n = n_{max}$	1.0079	1.0809	1.0392	1.3878E-2

表 3.2: 100都市を用いた数値実験

ある。基本的な数値実験を行い準最適解が求められることを確認した。またパラメー タを変化させた場合の特性を調べ考察を行った。このアルゴリズムは解のばらつきが 少なく安定した解を求めたい場合に比較的有効であると考える。今後の課題としては より詳しい動作解析や適切なパラメータの自動設定、大規模問題への応用等である。



図 3.1: LDSOM の学習フローチャート



図 3.2: LDSOM の細胞挿入



図 3.3:都市との対応付け











図 3.4: 近傍の変化図



図 3.5: 数値実験 52 都市



図 3.6: 数値実験 100 都市



図 3.7: ヒストグラム 48 都市



図 3.8: ヒストグラム 100 都市

第4章 並列化GSOMを用いたTSPへ の応用

4.1 まえがき

本章では並列化について考察する。巡回セールスマン問題のような最適化問題は入力 データが増加するにつれ莫大な計算コストを有することが多い。そのため、入力デー タ数が少ない状況で最適解を求めることが出来ても、データ数が多くなることで莫大 な時間が必要になり計算が困難になることもある。そのため様々な方法で計算時間の 短縮方法が研究されている。並列化はこの中でも比較的一般的な方法である。本章で は基本的な SOM を使用し任意に設定した領域数に入力データを分割する。そして1つ 1つの領域にラダー型の GSOM を配置し学習させる。学習終了後に各領域とマップを 繋げ経路を得る。

基本的な数値実験を行い並列化を行わない手法と結果を比較する。また、領域分割に 適応共鳴理論写像(Radial Basis Adaptive Resonance Theory maps :RB-ART)を使用 した手法との比較考察を行う [15][16]。

4.2 並列化アルゴリズム

本章のアルゴリズムは3つのサブルーチンに分けられ学習を行う。以下にそれぞれの サブルーチン内でのアルゴリズムを示す。

Step 1 (入力データの分割)

一般的な SOM を使用し領域を分割する。細胞数に分割数を設定し、入力データにす

べての都市データを使用する。学習終了後にすべての細胞を各都市ごとに比較し一番 距離が近い細胞を決定する。決定した細胞のカテゴリに入力都市データを所属させる。 この作業をすべての都市に行う。

Step 2 (結合する領域の決定)

すべての入力データの所属が決定した後に、先ほど学習した細胞の座標データを都市 データとみなし TSP を GSOM を用いて解く。そしてこのつながりを基に隣り合う領 域を決定する。これは Step 3 にて個々のラダー SOM をつなげ1つの経路を決定する 際に必要になる。

Step 3 (並列化 GSOM の学習)

並列化した領域ごとにラダー型のGSOMをそれぞれ配置する。学習中にStep2にて 決定した隣り合う領域の細胞をお互いに近づける。学習終了後にすべての領域をStep 2にて決定した経路にて繋げる。

4.3 並列化 GSOM の学習アルゴリズム

以下にラダー型 GSOM を用いた並列化学習アルゴリズムを示す。分割された領域ごと にラダー型の GSOM を配置する。*j* 番目の領域における細胞*i* の重みベクトル *w_{ij}* には 2 次元の座標データと細胞増加に関するパラメータであるカウンタ *C_{ij}* をそれぞれ持 つ。

Step 1 (初期化) t を離散時間とする。t = 0の時、j番目の領域の細胞の数を $N_j(0)$ とする。 $w_{ij}(i = 1 \sim N(0))$ を適当な値に初期化し、各細胞のカウンタ $C_{ij}(0) = 0$ とする。各領域ごとに細胞の上限 N_{max} を設ける。これは次式で表され、この条件より各領域の細胞数が多くなった場合はその領域の学習を終了する。また I_i はj番目の領域の

都市数である。

$$N_{maxj} = 2T_{int}I_j \tag{4.1}$$

また端の細胞は隣の領域の端の細胞と対応付けを行う。

Step 2 (入力の提示)

各領域ごとにランダムに入力データ $x_i(t)$ を与える

Step 3 (勝者の決定)

入力信号に最も類似した結合重みベクトルを次式によって決定する。そして対応する 細胞を勝者 c する。

$$||x_j(t) - w_{cj}(t)|| = \min ||x_j(t) - w_{ij}(t)||$$
(4.2)

ただし||・||はユークリッド距離を用いる。

Step 4(細胞の更新)

勝者細胞 c とその近傍細胞 k は次式で更新される。ただし α は勝者 c を更新する学習係数である。細胞 c のカウンタを更新する。

$$w_{ij}(t+1) = \begin{cases} w_{ij}(t) + \alpha(x_j(t) - w_{ij}(t)) & \text{if } i = c \\ w_{ij}(t) + \alpha(x_j(t) - w_{ij}(t)) & \text{if } i = k_j \\ w_{ij}(t) & \text{otherwise} \end{cases}$$
(4.3)

k:cの近傍

$$C_{ij}(t+1) = \begin{cases} C_{ij}(t) = C_{ij}(t) + 1 & \text{if } i = c \\ C_{ij}(t) & \text{otherwise} \end{cases}$$
(4.4)

αは学習係数。Step 1にて設定した隣り合う領域の端の細胞同士をお互いに近づける。 Step 5(細胞の挿入)

tが T_{int} 回ごとにカウンタが最大となる細胞qを探す。

$$C_{qj}(nT_{int}) \ge C_{ij}(nT_{int})$$
 for all i (4.5)

もしカウンタが最大のものが複数見つかった場合ランダムに選択する。qの近傍の中か らqに最も遠い細胞fを探す。 $q \geq f$ の間に新規細胞rを挿入する。細胞qと細胞rの 位置、カウンタを更新する。

$$w_{rj}(t+1) = \frac{(w_{qj}(t) + w_{fj}(t))}{2}$$
(4.6)

$$C_{qj}(t+1) = \frac{C_{qj}(t)}{2}, C_{rj}(t+1) = \frac{C_{qj}(t)}{2}$$
(4.7)

$$N_j(t+1) = N_j(t) + 1 \tag{4.8}$$

Step 6 (繰り返し)

t = t + 1とする。 $t < t_{max}$ なら STEP2 へ戻る。 $t = t_{max}$ なら Step 7 へ進む。また次式を満たしている領域は学習をここで終了させる。すべての領域の学習が終了した後に Step 7 へ進む。

$$N_{maxj} < N_j(t) \tag{4.9}$$

Step 7(経路の決定)

学習終了後にすべての領域を2番目のサブルーチンで決定した順で繋げる。また領域 ごとの端の細胞同士を線でつなげることによって1つの線ですべての細胞が繋がれる。 その後、各都市ごとに1番近い細胞を見付け都市ごとに対応させる。対応させた都市 を先ほど決定された線に基づき線を描いていくと経路が決定される。

4.4 数值実験

本章のアルゴリズムの有効性を示すためいくつかの基礎的な実験を行った。まず基本 的なパラメータを以下に示す。

$$N_j(0) = 3 N_{maxj} = 2P_j \text{for all } j \tag{4.10}$$

 $T_{int} = 100, \ \alpha = 0.1 \tag{4.11}$

*P_i*は領域ごとに分割した都市数である。

本章では http://www.tsp.gatech.edu//の TSP データを使用した。都市データとして 280 都市と 436 都市のデータを用いた。図 4.4-図 4.7 に並列化 GSOM を使用した動作 過程を示した。図 4.4、図 4.6 を見ると入力データが複数の領域に分割されていること が分かる。また図 4.5、図 4.7 を見ると並列化された領域にそれぞれラダー GSOM を 配置され、学習終了後に都市と細胞の対応付けを行い経路が決定される。この実験に より本アルゴリズムにて準最適解が求められることが示せた。表 4.1、表 4.2 に同じ実 験を 1 0 0 回行った場合の実験結果を表に示した。横軸として分割数、平均探索時間、 平均経路長、最小経路長および領域分割した際の都市数の最大値と最小値を示した。縦 軸として分割数を 1 から 5 まで変更し実験を行った。なお分割数が 1 の場合は並列化 を使用しない GSOM である。すべての解は最適解を 1 に正規化した場合の結果になっ ている。

表を見ると分割数が上がるにつれて探索時間が減少しているが、経路長は上がってお リ二律背反の関係になっている。探索時間、経路長ともに分割数が増えるからといっ て単調に増加減少していない。並列化は探索時間には莫大な影響を及ぼすが、経路長 にはあまり影響を及ぼさない。

次に並列化手法に動径基底 ART ネットワーク (RB-ART) を使用した手法と比較を行 う。RB-ART は ART ネットワークの 1 種であり様々な特性が盛んに考察されてきた。 代表的な ART ネットワークとして Fuzzy ART や Hyperhere ART ネットワークなどが ある。図 4.3 に RB-ART のフローチャートを示す。以下に使用した RB-ART パラメー タを示す。

$$k = 0, \rho = 0.3 \tag{4.12}$$

またカテゴリの挿入数は分割数を上限とし、分割数まで満たされない場合は最初からやり直す。RB-ARTの学習終了後にGSOMの学習と同じく結合する領域を決定し、並列化GSOMによってマップを学習させる。

4.8-図 4.11 に RB-ART を使用した動作過程を表 4.3、4.4 に数値実験結果を示した。表

の横軸に分割数、平均探索時間、平均経路長、最小経路長、都市分割の最大値最小値を 示した。また縦軸に分割数を2~5と設定した。図から入力データがRB-ARTによっ て分割され、並列化したラダー型GSOMが学習し最終的には都市を獲得していること が見える。また表からは分割数が上昇すると探索時間は減少し、経路長は増加という 二律背反のような傾向が見られる。

次に分割方法を SOM と RB-ART で行った場合の比較考察を行う。まず探索時間で比 較すると RB-ART の方が全体的に短くなっている。これは RB-ART の方が計算コスト がかからないことを示している。そのため探索速度が求められる問題には RB-ART の 方が適していると考える。次に経路長で比較を行う。経路長は SOM を用いた方が短く 解を求められていることが分かる。特に平均距離が短くなっているため安定した長さ を求める場合には SOM を使用した場合の方が適していると考える。この原因として各 領域に分割した場合の都市数のばらつきが挙げられる。分割した時の最大都市と最小 都市との差が RB-ART の方が多くなっている。そのため都市の分割数のばらつきが大 きくなる。ラダー型の GSOM を使用しているためばらつきが大きくなると成長に悪影 響を与えているのではないかと考える。

表 4.1: 数值実験 280 都市

分割数	平均探索時間 [s]	平均経路長	最小経路長	最小都市数	最大都市数
1	4.782E-1	1.112	1.074	-	-
2	1.135E-1	1.216	1.079	137	143
3	8.230E-2	1.373	1.087	86	99
4	7.111E-2	1.389	1.089	53	78
5	6.051E-2	1.388	1.086	50	61

表 4.2: 数值実験 436 都市

分割数	平均探索時間 [s]	平均経路長	最小経路長	最小都市数	最大都市数
1	5.611E-1	1.072	1.042	-	-
2	2.520E-1	1.072	1.042	182	254
3	1.781E-1	1.091	1.060	102	188
4	1.425E-1	1.106	1.062	88	128
5	1.129E-1	1.100	1.071	77	101

表 4.3: RB-ART を使用した数値実験 280 都市

分割数	平均探索時間 [s]	平均経路長	最小経路長	最小都市数	最大都市数
2	1.070E-1	1.188	1.078	130	150
3	7.751E-2	1.251	1.081	72	105
4	6.013E-2	1.401	1.093	51	103
5	4.954E-2	1.461	1.094	30	94

表 4.4: RB-ART を使用した数値実験 436 都市

分割数	平均探索時間 [s]	平均経路長	最小経路長	最小都市数	最大都市数
2	2.521E-1	1.080	1.051	180	250
3	1.705E-1	1.099	1.051	98	204
4	1.356E-1	1.131	1.069	77	156
5	1.113E-1	1.172	1.079	59	123

4.5 まとめ

本章では並列化に注目し、並列化した成長型自己組織化マップを提案し考察した。並 列化を行うことによって探索速度が向上する。しかし探索性能の1つである経路長は 長くなり二律背反のような現象が起きる。また入力データの分割をRB-ARTを用いた 手法と比較を行った。本アルゴリズムの方が探索速度は遅いがより安定した解を求め るには向いているということが分かった。今後の課題としてはより詳しい動作解析や 探索速度の向上などが挙げられる。



図 4.1: 都市の領域分け



図 4.2: 端細胞の更新



図 4.3: RB-ART アルゴリズムのフローチャート



図 4.4: 領域分割 (280 都市)



図 4.5: 並列化 GSOM の学習過程 (280 都市)



図 4.6: 領域分割 (436 都市)



図 4.7: 並列化 GSOM の学習過程 (436 都市)



図 4.8: RB-ART を用いた領域分割 (280 都市)



図 4.9: RB-ART を用いた並列化 GSOM の学習過程 (280 都市)



図 4.10: RB-ART を用いた領域分割 (436 都市)



図 4.11: RB-ART を用いた並列化 GSOM の学習過程 (436 都市)

第5章 むすび

本修士論文では自己組織化マップとニューラルガスのアルゴリズム改良と工学的応 用について考察する。第2章では成長型ニューラルガスを提案し画像骨格抽出に応用 した。入力に基本的な画像データを与え、学習後に画像の骨格が抽出されていること を確認した。また従来手法である成長型自己組織化マップを用いた画像骨格抽出と比 較考察を行った。

第3章では局所距離情報を用いた成長型自己組織化マップを提案し考察した。この 手法では細胞の更新を制御するパラメータに注目する。このパラメーターにばらつき を持たせることによって従来より柔軟に解を求めることが出来る。この手法を最適化 問題の1つである巡回セールスマン問題に応用し従来手法との比較考察を行った。

第4章では並列化動作について考察する。より多量の入力データに対応するために並 列化した自己組織マップを提案した。入力データの分割アルゴリズムに一般的な SOM を使用し並列化 GSOM にラダー型の SOM を用いた。基本的な数値実験を用い動作の 解析を行った。また分割アルゴリズムに BR-ART を使用したものと比較を行った。本 アルゴリズムは安定した解を求めるには問題などに有効であると考えられる。

64

参考文献

- T. Kohonen, "Self-Organized formation of topologically correct feature maps," Biological Cybernetics, 43, pp. 59-69(1982)
- [2] B. Fritzke, "Growing cell structure a self organizing network for unsuprevised and supervised learning" Neural Networks, 7, pp. 1441-1460(1994)
- [3] James S. Kirk, Dar-Jen Chang, and Jacek M. Zurads, "A Self-Organizing Map with Dynamical Architecture for Efficient Color Quantization", Proc. of IEEE/INNS IJCNN, 11, 3 pp.2128-2132, 2001
- [4] H. Matsushita, and Y. Nishio, "Competing Cehacior of Two kinds of SOMs and its Application to Clustering Proc. of WSOM, pp. 355-362, 2005.
- [5] R. Ohta and T. Saito, "A growing self-organizing algorithm for dynamic clustering ," Proc. of IJCNN, pp. 469-473 (2001)
- [6] T.Ehara, T.Saito, "Application of growing self-organizing maps to small-world networking" proc. of NOLTA, Brugge, pp. 258-261 (Nov, 2005)
- [7] Martinez, T.M, "Neural-gas network for vector quantization and its to time-series prediction" IEEE Transaction, July 1993, pp.558-569.
- [8] B. Fritzke, "Growing neural gas network learns topologies", Advances in Neural Information processing Systems, 7, pp.625-632, 1995

- [9] H. Sasamura and T. Saito, "A Simple Learing Algorithm for Growing Self-Organizing Maps and Its Application to the Skeletonization, Proc. of IJCNN2003, pp. 787-790(2003)
- [10] Prim, R. C., "Shortest connecting networks and some generalizations." Bell Sysem Technical Journal, 36, pp.1389-1401
- [11] K. Fujimura, H. Tokutaka and M. Ishikawa, "Performance of improved SOM-TSP algorithm for btraveling salesman problem of many cities, "Trans. IEE Japan, 119-C, 7, pp. 875-882
- [12] H. Sasamura, R. Ohta and T. Saito, "A simple learing algorithm for growing ring SOM and Its Application to the TSP, Proc. of ICONIP2002, cr1508
- [13] T. Ehara, H.Sasamura, T.Saito, "An approach to the TSP based on Growing Self-Organizing Maps," Proc. of NOLTA, Fukuoka, pp.709-712 (Dec, 2004)
- [14] T. Haraguchi, H. Matsushita and Y. Nsihio, "Lazy Self-Organizing Maps and its Behaviors, proc. of IJCNN'08, pp.2276-2281, june 2008.
- [15] T. Oshime, T.Saito and H. Torikai, "ART-Based Parallel Learning of Growing SOMs and Its Application to TSP", Proc. of ICONIP2006, pp. 1004-1011
- [16] M. Ohki, H. Torikai, T. Saito, "A Simple Radial Basis ART Network: Basic Learning Characteristics and Application," Proc. of NOLTA2005, Bruge, pp. 1123-1128

研究業績

(国際会議)

<u>K.Sunakawa</u> and T.Saito, "Parallel Learning of Growing SOMs and application to TSP" Proc. 2012 RISP of International Workshop on Nonlinear Circuits, Communications and Signal Processing (NCSP2012), Hawaii, 2012.(accepted)

(国内発表)

<u>砂川一樹</u>、斎藤利通"局所距離情報を用いた成長 SOM の TSP 解法,"電子情報通信学会 信学技報, NLP2011-104, pp. 69-74, 沖縄, 2011 年 11 月

<u>砂川一樹</u>、斎藤利通"粘菌の動作に基づく成長型自己組織化写像について,"電子情報通 信学会 信学技報, NC2010-193, pp. 391-394, 東京, 2011 年 3 月

<u>砂川一樹</u>、斎藤利通"成長型ニューラルガスと画像骨格抽出,"電子情報通信学会 2010 年ソサイエティ大会, A-2-29, 大阪, 2010 年 9 月

<u>砂川一樹</u>、斎藤利通"並列化自己組織化写像を用いた画像骨格抽出,"電子情報通信学会総合大会 ISS 特別企画学生ポスターセッション 105, 宮城, 2010 年 3 月

謝辞

本研究は著者が法政大学大学院工学研究科電気工学専攻在学中に行ったものであ る。この研究は同大学理工学部電気電子工学科教授斎藤利通博士の指導下で行ったも ので、全ての研究活動を遂行するにあたり同教授から大変御参考になる御指導・御鞭 撻を沢山賜りました。ここに心から深謝いたします。

また研究活動中に貴重な御助言・御討論を賜りました。香川大学信頼性情報シス テム工科学科助教松下春奈博士、オムロンヘルスケア株式会社小清水宏氏には感謝の 意を表明いたします。

最後に法政大学工学部情報電気電子工学科 斎藤利通研究室の皆様には、いろいろ な有益な御討論・ご助言を戴きました。ここに感謝の意を表します。