

# 追加学習型自己組織化マップにおける不要ニューロンの削除法 Elimination of Unnecessary Neurons in Incremental Learnable Self-Organizing Map

島田 敬士 (PY)<sup>†</sup>, 谷口 倫一郎<sup>†</sup>

Atsushi Shimada(PY) and Rin-ichiro Taniguchi

<sup>†</sup>九州大学大学院システム情報科学研究所

{atsushi,rin}@limu.is.kyushu-u.ac.jp

**Abstract**— We propose a method to eliminate unnecessary neurons in Variable-Density Self-Organizing Map. We have defined an energy function which denotes the error of the map, and optimize the energy function by using graph cut algorithm. We conducted experiments to investigate the effectiveness of our approach

**Keywords**— Self-Organizing Map, Elimination of Neurons, Graph Cut

## 1 はじめに

Kohonen らが提案した自己組織化マップ (Self-Organizing Map: SOM) は, ニューラルネットワークのひとつで, 中間層のない 2 層型の教師なし競合近傍学習モデルである [1]. SOM の学習法は, 一括学習型と追加学習型に分類でき, 本稿では後者の追加学習型 SOM のひとつである密度可変型自己組織化マップ (VDSOM) [2] を取り扱う. VDSOM は, 連続的に入力される学習ベクトルに対して, 適応的にニューロンを追加しながら自己組織化学習を達成できる SOM である. 一方で, ニューロンの追加時に, 初期に学習したデータ間の位相関係が破壊されるという問題が生じていた.

そこで本稿では, マップ内で元データ空間の位相を破壊しているニューロン不要ニューロン候補として探し出し, それらのニューロンがマップから削除された場合にマップに影響を及ぼす誤差エネルギーを定式化し, エネルギー最小化問題を解くことで不要ニューロンを決定し, 削除する手法を提案する.

## 2 不要ニューロンの削除法

### 2.1 ニューロンのラベル付け

マップの位相誤差を式 (1) で定義する [3].

$$E_t = \frac{1}{K} \sum_{k=1}^K f(x_k) \quad (1)$$

$$f(x_k) = \begin{cases} 1, & u_f^k \text{ and } u_s^k \text{ non-adjacent} \\ 0, & \text{otherwise} \end{cases}$$

ここで,  $K$  は学習データ数,  $x_k$  は学習データの入力ベクトルである. 位相誤差が小さいと  $E_t$  は 0 に近づく.

次に, ニューロン  $u_i$  に対して, 位相誤差に関するラベル (式 (2)) と勝者ノードに関するラベル (式 (3)) を定義する.

$$l_i^E = \begin{cases} 1, & \text{all } u_i \text{ between } u_f^k \text{ and } u_s^k \text{ when } f(x_k) \text{ is } 1 \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

ここで,  $u_f^k, u_s^k$  はそれぞれ,  $k$  番目の学習データに対する第 1 勝者, 第 2 勝者ノードである.

$$l_i^W = \begin{cases} 1, & \text{if } u_i \text{ is best-match unit} \\ 2, & \text{if } u_i \text{ is second-best-match unit} \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

以上のラベル付けにより, マップ上のニューロンはラベルの組み合わせにより 6 種類に分類される. これらのラベルは, 次節でマップの誤差エネルギーを計算する際に利用される. 最後に, ニューロン  $u_i$  が不要であれば 1, 必要であれば 0 となるラベル  $l_i^D$  を定義しておく.

### 2.2 マップの誤差エネルギー

マップの誤差エネルギーを式 (4) により定義する.

$$P(l^D; u) = \sum_{i \in N} P_L(l_i^D; u_i) + \sum_{(i,j) \in M} P_S(l_i^D, l_j^D; u_i, u_j) \quad (4)$$

上式右辺第 1 項はニューロンのラベル  $l_i^D$  に関するデータ項であり, 第 2 項はラベルに対する平滑化項である.  $N, M$  はそれぞれ, 全ニューロンの集合および近傍ニューロンの集合である.

データ項は, 次式 (5) によって計算される.

$$P_L(l_i^D = 0; u_i) = \begin{cases} 0, & \text{if } l_i^E = 1, l_i^W = 0 \\ 1, & \text{if } l_i^E = 0, l_i^W = 1 \\ 1/d_{f,s}, & \text{if } l_i^E = 0, l_i^W = 2 \\ \alpha, & \text{if } l_i^E = 1, l_i^W = 1 \\ \alpha/d_{f,s}, & \text{if } l_i^E = 1, l_i^W = 2 \\ 1/2, & \text{otherwise} \end{cases} \quad (5)$$

$$P_L(l_i^D = 1; u_i) = 1 - P_L(l_i^D = 0; u_i)$$

ここで,  $\alpha (0 \leq \alpha \leq 1)$  は  $l_i^E = 1$  かつ  $l_i^W \geq 1$  であるニューロンの必要度を定めるパラメータである. また,  $l_i^W = 2$

の場合は，第1勝者と第2勝者ノード間のマップ座標距離  $d_{f,s}$  に応じて第2勝者ノードの必要性を下げるようにしている．

平滑化項は，式(6)によって定義され，近傍のニューロンのラベルに近くなるようにエネルギーが計算される．

$$P_S(l_i^D, l_j^D; u_i, u_j) = \frac{\beta}{d_{i,j}} \frac{|l_i^E - l_j^E| + |l_i^W - l_j^W|}{\ln(\|w_i - w_j\|^2 + 1 + \varepsilon)} \quad (6)$$

ここで， $w_i$  はニューロン  $u_i$  の結合係数ベクトル， $\beta$  は，平滑化項の影響度を調整するパラメータ  $\varepsilon \ll 1$  である．

### 2.3 グラフカットによる最適化とニューロンの削除

マップの誤差エネルギー  $P(l^D; u)$  の最小化を，全ニューロンのラベル  $l^D$  に対して同時に行うことは，組み合わせ最適化問題である．本研究では，グラフカット [4, 5] によりこの最適化問題の大域的最適解を求めている．最後に，グラフカットで求めた最適解で， $l_i^D = 1$  であるニューロンをマップ上から削除する．

## 3 実験結果

R,G,B の3次元からなる色ベクトルを125色生成し，それらをVDSOMに一色ずつ追加学習させた．初期のマップサイズは  $4 \times 4$  (ニューロンの数16) とし，文献 [2] における各パラメータは， $\alpha_0 = 0.9, \sigma_i = 1.0, \sigma_f = 0.3, k = 0.3$  とした．学習後，マップには307個のニューロンが生成された．図1(a)では，各ニューロンの結合係数ベクトルを3次元色ベクトルとして着色している．このマップに対して，位相誤差と量子化誤差を計算したところ， $E_t = 1.7 \times 10^{-1}$ ， $E_q = 2.6 \times 10^{-3}$  であった．位相誤差を大きくしている要因となっている箇所の一例を同図内に矩形で示している．色のグラデーションが壊され，いくつかの色が混在していることがわかる．

次に，マップの誤差エネルギー最小化により不要ニューロンを削除した後の位相誤差と量子化誤差を表1に示す．ここでは，式(5)において， $\alpha = 0.8$  とし，式(6)の  $\beta$  を変化させて実験をしている．表から， $\beta$  を変化させると位相誤差が変化することがわかる．いずれの場合でも，ニューロン削除前よりも位相誤差は小さくなっており， $0.2 \leq \beta \leq 1$  のとき，その値は最も小さくなった．これにより，平滑化項が有効に働いていると考察できる．一方で，量子化誤差はニューロン削除前から変化しなかった．このことから，マップの誤差エネルギー最小化により，不要なニューロンのみを削除することができることが示された．また， $\beta$  が大きくなるにつれ，削除されるニューロンの数も増加していることがわかる．図1(b)は， $\beta = 1$  のときのニューロン削除後のマップの様子である．図1(a)に示した矩形領域内の色の混在が緩和されていることがわかる．

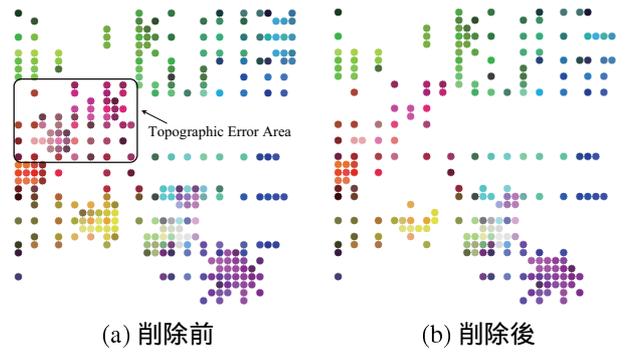


図1: ニューロン削除前後のマップの様子

表1: ニューロン削除後の位相誤差，量子化誤差，ニューロン数の関係

$\beta$	0	0.15	[0.2 - 1]	2
$E_t [\times 10^{-2}]$	8.8	7.2	6.4	7.2
$E_q [\times 10^{-3}]$	2.6	2.6	2.6	2.6
$N$	256	245	[241 - 230]	226

## 4 おわりに

自己組織化マップの学習後のマップに対して誤差エネルギーを計算し，エネルギー最小により不要なニューロンを削除する手法を提案し，実験によりその有効性が示された．今後の課題としては，追加学習過程でニューロン削除のフェーズを適用するタイミングの検証や，削除後の追加学習への影響度の検証などが挙げられる．

### 参考文献

- [1] Teuvo Kohonen. “Self-Organizing Maps”. Springer Series in Information Science, 1995.
- [2] 島田敬士, 谷口倫一郎. “密度可変型自己組織化マップによる追加学習の実現法”. 日本神経回路学会誌, Vol. 14, No. 2, pp.71-78, 2007.
- [3] Kimmo Kiviluoto. “Topology Preservation in Self-Organizing Maps”. *International Conference on Neural Networks (ICNN)*, pp.294-299, 1996.
- [4] 石川博. “グラフカット”. 情報処理学会 コンピュータビジョンとイメージメディア (CVIM), Vol.2007, No.31, pp.193-204, 2007.
- [5] Yuri Boykov and Vladimir Kolmogorov. “An Experimental Comparison of Min-Cut/Max-Flow Algorithms for Energy Minimization in Computer Vision” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 26, pp.1124-1137, 2004.