

# 色情報を含む点群データの位相構造学習における 重みつき距離尺度に関する検討

## Study of Weighted Distance for Topological Structure Learning of Point Cloud with Color Information

○正 戸田 雄一郎 (岡大) 学 和田 亮雅 (岡大)  
正 松野 隆幸 (岡大) 正 見浪 護 (岡大)

Yuichiro TODA, Okayama University, ytoda@okayama-u.ac.jp  
Akimasa WADA, Okayama University  
Takayuki MATSUNO, Okayama University  
Mamoru MINAMI, Okayama University

Recently, point cloud processing technologies have been expected for intelligent robotics because the intelligent robot needs to perceive the space accurately in an unknown environment. For realizing the real-time processing of the point cloud data, we proposed a modified Growing Neural Gas with Utility (GNG-U II) in our previous researches. For learning the topological structure of the point cloud data with color information, GNG-U II has the weighted distance called as a relative importance. However, we did not discuss how to design the relative importance of the point cloud with color information. Therefore, this paper shows that GNG-U II could cluster the 2D simulation dataset by designing the relative importance correctly.

**Key Words:** Growing Neural Gas, Topological structure, Point cloud processing

### 1. 緒言

空間の構造を把握しつつその位置に含まれる特徴となる属性を抽出する能力は、未知環境において自律ロボットがタスクを適応的に遂行していく上で、必要不可欠な能力である。特に、カメラや RGB-D センサなどの視覚センサから取得された情報をもとに、目標となる物体が空間中のどこに存在しており、どこに注意を向ければ効率よく行動できるかを決定する上においても非常に重要な役割を果たす。視覚センサから空間的な構造を学習すると同時に、形状や物体の位置関係を記述するためのノードとエッジから構成された位相構造を学習する手法として、Kohonen が提案した自己組織化地図に基づく手法が提案されている[1]。その中でも、Fritzke によって提案されている Growing Neural Gas (GNG)[2]は、ノードを追加しつつ、冗長なノードやエッジを削除するアルゴリズムを含んでおり、未知なデータ分布に対して、空間の構造を適切に学習することが可能な手法となっているため、GNG を用いた空間構造の学習に関する様々な研究が提案されている。

このような中、著者らは、属性ごとに異なる重みつき距離を用いた手法として改良型 GNG-U (GNG-U II) を提案してきた[3]。重みを適切に設計することによって、空間的な構造を保ちながら色情報の学習も同時に行えていることをどちらの手法とも示しているが、位置情報と色情報を含んだ入力ベクトルの中で、適切なクラスタリングがこれまで行えてこなかった。

そこで本稿では、GNG-U II における関連重要度の重みを適切に設計することによって、色情報を含む点群データを用いたクラスタリングが可能であるかの検討を行う。

### 2. 改良型 Growing Neural Gas with Utility

GNG は、入力ベクトルの空間構造の学習と位相構造の構築を同時に行うことが可能な手法であるが、空間の座標情報や色情報などの属性を複数含む入力ベクトルを学習しようとすると上述の図 1 のように、空間情報の属性以外に入力ベクトルに引っ張られてしまい、空間構造を学習できなくなってしまうといった問題点が存在する。そこで、著者らの研究では、

関連重要度と呼ばれる重みを用いた距離尺度によって空間構造を保ちつつその他の属性の情報も同時に学習を行う手法である改良型 GNG with Utility (GNG-U II) をこれまで提案してきた。本稿における提案アルゴリズムも基本的に GNG-U II のアルゴリズムに基づいて学習を行なっていくため、以下に GNG-U II のアルゴリズムを示す。

$h_i$ : The  $n$ th dimensional vector of a node

$A$ : A set of nodes

$N_i$ : A set of nodes connected to the  $i$ th node

$C = \{c_{1,2}, \dots, c_{i,j}, \dots\}$ : A set of edges

$g_{ij}$ : Age of the edge between the  $i$ th and  $j$ th nodes

Step0. 初期化として、二つのノードの参照ベクトル  $h_1$  と  $h_2$  をランダムに生成し、結合関係  $c_{1,2}=1$ 、エッジの年齢  $g_{1,2}=0$  とする。

Step1. 入力データ  $v$  をデータの確率密度分布  $p(v)$  に従ってランダムに取得する。

Step2. 入力データ  $v$  に対する勝者ノード  $s_1$  と第 2 勝者ノード  $s_2$  を選択する。

$$\begin{aligned} s_1 &= \arg \min_{i \in A} \|w * (v - h_i)\| \\ s_2 &= \arg \min_{i \in A \setminus s_1} \|w * (v - h_i)\| \end{aligned} \quad (1)$$

ここで、 $w$  は関連重要度、 $*$  は要素ごとの積を表す演算子となっている。

Step3. ノード  $s_1$  について入力データ  $v$  との二乗誤差を積算誤差  $E_{s_1}$  に加算する。また、ノード  $s_2$  と  $s_1$  の二乗誤差の差を Utility 値  $U_{s_1}$  に加算する

$$\begin{aligned} E_{s_1} &\leftarrow E_{s_1} + \left\| w * (v - h_{s_1}) \right\|^2 \\ U_{s_1} &\leftarrow U_{s_1} + \left\| w * (v - h_{s_2}) \right\|^2 - \left\| w * (v - h_{s_1}) \right\|^2 \end{aligned} \quad (2)$$

Step4. ノード  $s_1$  及びノード  $s_1$  と結合関係があるノードの参照ベクトルを更新する. ただし,  $\eta_1$  と  $\eta_2$  を学習係数とする ( $\eta_1 > \eta_2$ ).

$$\begin{aligned} h_{s_1} &\leftarrow h_{s_1} + \eta_1 \cdot (v - h_{s_1}) \\ h_j &\leftarrow h_j + \eta_2 \cdot (v - h_j) \quad \text{if } c_{s_1,j} = 1 \end{aligned} \quad (3)$$

Step5. エッジの年齢を 0 にリセットする ( $g_{s_1,s_2}=0$ ). また, ノード  $s_1$  と  $s_2$  との間にエッジが存在しなければ, 新たにエッジを作成する ( $c_{s_1,s_2}=1$ ).

Step6. ノード  $s_1$  と結合関係のある全てのエッジの年齢をインクリメントする.

$$g_{s_1,j} \leftarrow g_{s_1,j} + 1 \quad \text{if } c_{s_1,j} = 1 \quad (4)$$

Step7. 事前に設定した閾値  $g_{\max}$  を超える年齢のエッジを削除する ( $c_{s_1,s_2}=0$ ). その結果, 他のノードと結合関係を持たないノードが現れた場合は, そのノードを削除する.

Step8. データ入力が  $\lambda$  回ごとに, 次の操作を行う.

i. 積算誤差が最大のノード  $u$  を選択する. また, 最小の Utility 値を持つノード  $l$  を選択する

$$\begin{aligned} u &= \arg \max_{i \in A} E_i \\ l &= \arg \min_{i \in A} U_i \end{aligned} \quad (5)$$

ii. ノード  $u$  と結合関係のあるノードの中で最も積算誤差の大きいノードを  $f$  とし,  $u$  と  $f$  を結合するエッジを 2 分するようにノード  $r$  を挿入する.

$$h_r = 0.5 \cdot (h_u + h_f) \quad (6)$$

iii. 最大積算誤差と最小の Utility 値が以下の式を満たす場合, ノード  $l$  の削除を行なう.

$$E_u / U_l > k \quad (7)$$

iv. 次に, ノード  $u, f$  間のエッジを削除し ( $c_{u,f}=0$ ), ノード  $u, r$  及び  $r, f$  間にエッジを追加する ( $c_{u,r}=1, c_{r,f}=1$ ).

v. ノード  $q, f$  の積算誤差を以下の式により更新する.

$$\begin{aligned} E_u &\leftarrow E_u - \alpha E_u \\ E_f &\leftarrow E_f - \alpha E_f \end{aligned} \quad (8)$$

vi. ノード  $u, f$  の積算誤差の平均をノード  $r$  の積算誤差とする.

$$E_r = 0.5 \cdot (E_u + E_f) \quad (9)$$

Step9. GNG へのデータ入力が  $\kappa (< \lambda)$  回ごとに, Step 8 における, i と iii を行うことによって, ノード数の調整を行なう.

Step10. 全てのノードの誤差と Utility 値を減らす.

$$\begin{aligned} E_i &\leftarrow E_i - \beta E_i \quad (\forall i \in A) \\ U_i &\leftarrow U_i - \chi U_i \quad (\forall i \in A) \end{aligned} \quad (10)$$

Step11. 終了条件が満たされない場合は, step1 に戻る.

GNG-U II においては, 式(1), (2)において, 関連重要度と呼ばれる重み  $w$  を用いた重み付きの距離尺度を用いた学習を行っている.

### 3. 実験結果

本実験では, 入力ベクトルの構成を, 位置情報と色情報 ( $v = (x, y, R, G, B)$ ) とし, 関連重要度を  $w = (1.0, 1.0, 0.0, 0.0, 0.0)^T$  と  $w = (0.8, 0.8, 0.2, 0.2, 0.2)^T$  としたときの比較実験を行なった. 学習に用いたデータは, 図 1 に示すとおり, 緑背景の中心に赤い円が含まれる点群データとなっており, 点群の層数は 10000 点となっている. この時学習に用いたパラメータは, [] で用いたものと同様のものを用い, ノード数が 250 になるまで学習を行なった. 実験結果を図 2 に示す. 図 2 (a) より空間の情報のみを学習した結果において, 背景と中心の円は, エッジによって接続されており, クラスタリングされていないことが分かる. 一方で, 空間と色情報に適切に重み付けを行なった図 2(b) においては, 背景と円の境界部分に抜けが存在するものの 2 つを適切にクラスタリングできている事がわかる. このように, 属性ごとのスケールを考慮し, 適切に関連重要度を設計することによって, GNG-U II を用いた視覚センサからのクラスタリングが可能であることが分かる.

### 4. 結言

本研究では, 位相構造の学習手法である改良型 Growing Neural Gas with Utility における関連重要度を適切に設計することによって, 色情報を含む点群データをクラスタリング可能であることを示した. しかしながら, 関連重要度の設計は, 学習したい属性ごとの空間的なスケールをお互いに考慮し設計を行う必要がある. 今後の課題としては, スケールフリーな学習手法の提案を行なっていく予定である.

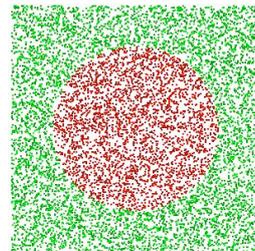
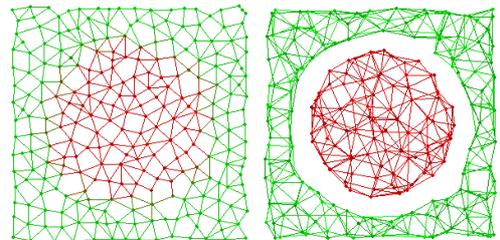


Fig.1 Data set



(a)  $w = (1.0, 1.0, 0.0, 0.0, 0.0)$  (b)  $w = (0.8, 0.8, 0.2, 0.2, 0.2)$

Fig.2 Experimental results

### 参考文献

[1] Kohonen, T. Self-Organization and Associative Memory.

Springer-Verlag , 1984.

- [2] B. Fritzke: A growing neural gas network learns topologies, *Advances in Neural Information Processing Systems*, Vol. 7, pp. 625-632, 1995.
- [3] Y. Toda, H. Yu, Z. Ju, N. Takesue, K. Wada, N. Kubota, "Real-time 3D Point Cloud Segmentation using Growing Neural Gas with Utility", *The 9th International Conference on Human System Interaction*, pp.418-422, 2016.