

属性値付加型自己組織化マップによるクラス分類最適化

日大生産工(院) ○佐藤 哲哉 日大生産工 山内 ゆかり

1. まえがき

近年手書き文字認識の需要が増している。手法は様々だが、中でも自己組織化マップ(Self-Organizing Map: SOM)¹⁾は簡易なアルゴリズムで、データ全体の形を捉えられる。

SOMの研究には古川²⁾の高階SOMがある。これはSOMのノード1つ1つがSOMの構造を持ち、マップの関係性を獲得するが階層構造上メモリが膨大である。また間所ら³⁾の適応的カテゴリー写像ネットワークはSOMを含む3つのモジュールを組合せ、オンライン学習するが複数モジュールを使う為処理が複雑になる。

そこで我々は簡易なアルゴリズムのSOMを改良し認識率向上を目指す。しかしSOMは出力層に同じクラスが集約するとは限らず、クラスが離れて形成すると別々の領域で学習が進む。この為クラスの散らばりがあると他クラスに干渉し、クラスの境界が不鮮明になる。そこでデータの属性値から各クラスへの所属度合いを学習するSOMを提案する。実験で数字手書き文字データを用い、従来SOMと比較し提案手法の有効性を示す。

2. 提案手法

本研究では、属性値から属性値情報 L を定義する。属性値とは入力データの正解ラベルを示す値で、属性値情報 L はノードが各クラスにどの程度属するかを示す値である。また属性値情報 L が最も高いクラスをノードのクラス番号 j とする。以下に提案手法の処理を説明する。

- 出力層ノード n の参照ベクトル m_i を乱数で初期化する。 i はノード番号である。
- ノードの属性値情報 L を1に設定する。
- I 個の入力データからランダムに選び、入力ベクトル x_t とする。
- 式(1)で入力ベクトル x_t と出力層ノードの参照ベクトル m_i のユークリッド距離最小ノードを勝者ノード c とする。

$$c = \arg \min_i \|x_t - m_i\| \quad (1)$$
- 式(2)を用い属性値情報 L の更新する。 num は入力データの属性値である。

$$L_{num}(i) = L_{num}(i) + \exp\left(-\frac{\|r_c - r_i\|^2}{2\sigma_t^2}\right) \quad (2)$$

- 近傍関数 $h_{ci}(t)$ を求める。 α_t は学習率、 σ_t は学習範囲、 T は最大学習回数、 W は学習率 α_t に対する重みである。

$$h_{ci}(t) = \alpha_t * \exp\left(-\frac{\|r_c - r_i\|^2}{2\sigma_t^2}\right) \quad (3)$$

$$\alpha_t = \alpha_0 * \left(1 - \frac{t}{T}\right) * W \quad (4)$$

$$W = \frac{L_{num}(i)}{\max_j L_j(i)} \quad (5)$$

$$\sigma_t = \sigma_0 * \left(1 - \frac{t}{T}\right) \quad (6)$$

- 式(7)を用い出力層の各ノードの参照ベクトル m_i を更新する。

$$m_i = m_i + h_{ci}(t) * (x_t - m_i) \quad (7)$$

- C)~G)を最大学習回数 T まで繰り返す。

従来SOMは勝者ノード c から距離に応じ学習率 α_t を変化させるが、他クラスに属するノードにも干渉する。そこで学習率 α_t に重み W をかけ入力データ属性値に一致していないほど学習率 α_t は低くし、他クラスへの干渉を抑制する。図1ではクラスの境界付近に勝者ノード c があり、学習の様子を色の濃淡で示している。従来SOMは学習の影響が他クラスへ及ぶが、提案手法は抑えられる。

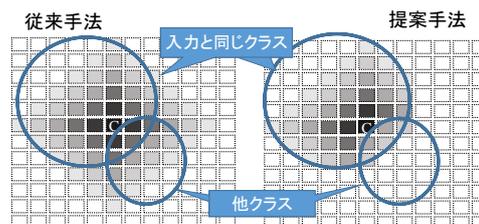


図1 従来手法と提案手法の学習イメージ

3. 実験方法および測定方法

実験ではOptidigits⁴⁾を用いる。Optidigitsは0~9の数字手書き文字を64次元で表現したデータとその属性値が有する。また表1に実験パラメータを示す。

また評価はクラスの散らばりと認識率で行う。クラスの散らばりは出力層で各クラス領域面積から算出する。まず出力層に分布するクラスの X , Y 座標から最大、最小を求めノードを含む範囲面積を計算する。そしてマップ全体に

占める割合を求める。これを100回行い、各クラス平均を求め、そこから全体平均を求める。

また認識率は入力データに対する勝者ノード c を求め、属性値が一致したらカウントする。これをテストデータ分行い、一致数がテストデータ数に占める割合を求める。

表 1 実験パラメータ

出力層サイズ N	12
ノード数	144
最大学習回数 T	12000
初期学習率 α_0	0.95
学習範囲 σ_0	$N/3.0$

4. 結果および考察

図 2 に従来手法、図 3 に提案手法の学習済出力層を示す。図 2, 3 では左に Optidigits を 8*8 サイズに整形し出力層 12*12 に敷き、右に文字の属性値を示す。図 2 は文字がクラス境界に点在している。これよりクラス境界付近の認識が困難だとわかる。対して図 3 では文字の散らばりが少なくクラスの散らばりが抑制している。また散らばりが減少しクラス境界が明確になっている。

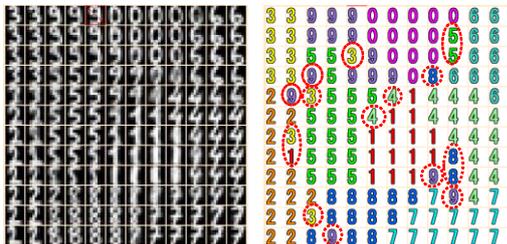


図 2 従来手法の学習済出力層

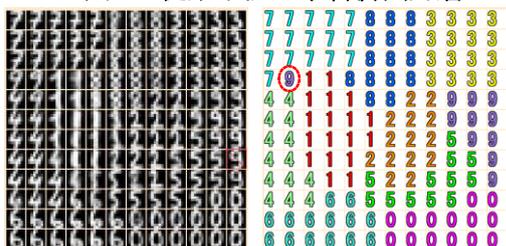


図 3 提案手法の学習済出力層

また表 2 表 2 にクラスの散らばりを示す。表 2 から提案手法は平均で約 50%抑制した。これは属性値情報 L の高い程良く学習し、また勝者ノード c を中心に行いクラスが集中し局所的に学習が行われる為と考えられる。

また表 3 に認識率を示す。表 3 より提案手法は平均認識率を 2.6%改善した。これはクラスの散らばりを抑制し他クラスへの干渉を減少

させ、境界を明確に表現でき識別困難なノードが減少した為、認識率が向上したと考えられる。

表 2 クラスの散らばり度合い

	従来手法	提案手法
クラス 0	0.169	0.130
クラス 1	0.445	0.243
クラス 2	0.220	0.141
クラス 3	0.304	0.142
クラス 4	0.405	0.160
クラス 5	0.409	0.180
クラス 6	0.156	0.144
クラス 7	0.215	0.157
クラス 8	0.508	0.173
クラス 9	0.568	0.263
平均	0.340	0.173

表 3 文字認識率

	従来手法	提案手法
最大	0.942	0.954
平均	0.909	0.935
最小	0.866	0.915

5. まとめ

本研究では SOM の認識率向上を目標に、属性値からクラスへ所属度合いを学習する手法を提案した。提案手法は属性値情報 L から学習率 α_t を制御する。実験で従来 SOM と比較し提案手法はクラスの散らばりを約 50%抑制し、平均認識率を 2.6%改善した。

今後の課題として、SOM は追加学習が困難である為、Shenら5)の自己増殖型ニューラルネットワークを適用することを検討していく。

参考文献

- 1) T. Kohonen, Self-Organizing Maps, Berlin, Springer, vol.30, 1995
- 2) 古川哲夫, "SOM の SOM : SOM 集合をマップする SOM", 知能と情報, Vol.19, No.6, pp.618-626, 2007
- 3) 間所洋和, 佐藤和人, "データの位相構造をカテゴリマップとして可視化する適応的写像ネットワーク", 知能と情報 (日本知能情報ファジィ学会誌) Vol.26, No.6, pp. 903-912, 2014
- 4) Optical recognition of handwritten digits: <https://archive.ics.uci.edu/ml/datasets/optical+recognition+of+handwritten+digits>, (最終アクセス:2019年9月7日20時)
- 5) Furoo Shen and Osamu Hasegawa, "An Incremental Network for On-line Unsupervised Classification and Topology Learning", Neural Networks, Vol.19, No.1, pp.90-106, 2006