

自己組織化写像による画像修復に関する検討

前田 道治[†]

† 久留米工業高等専門学校
〒 830-8555 福岡県久留米市小森野 1-1-1
E-mail: †maedami@kurume-nct.ac.jp

あらまし 本研究では、画像修復のための自己組織化写像アルゴリズムを提案する。自己組織化写像はこれまで荷重ベクトルの順序付けや収束に関して、議論がなされてきた。自己組織化のそれ以外の手法として、画像修復の新たなアルゴリズムを提案する。本手法は、各画素に対し一つの素子が対応する写像を形成する。入力として画素値を用い、画像推定は自己組織化によって行なわれる。そのために、入力値と推定画素との間の差に応じたしきい値をもつ更新関数を導入する。この関数により、ノイズを含む入力に過敏に反応しなくなる。また、近傍の設定により周囲の画素に影響を受け、原画像の推定が適切に推進する。次に、しきい値の初期値及び近傍の初期値を変化させ精度に及ぼす影響を調べる。数値計算により、品質の面で有効であることを示す。

キーワード 自己組織化写像、画像修復、学習、ピーク信号対ノイズ比

Consideration for Image Restoration by Self-Organizing Maps

Michiharu MAEDA[†]

† Kurume National College of Technology
1-1-1 Komorino, Kurume, Fukuoka Pref., 830-8555 Japan
E-mail: †maedami@kurume-nct.ac.jp

Abstract In this study, an algorithm of self-organizing maps for image restoration is presented. Self-organizing maps have been hitherto studied for the ordering process and the convergence phase of weight vectors. As another approach of self-organizing maps, a novel algorithm of image restoration is proposed. The present algorithm creates a map containing one unit for each pixel. Utilizing pixel values as input, the image inference is carried out by self-organizing maps. Then, an updating function with a threshold according to the difference between the input value and the inferred pixel is introduced, so as not to respond to a noisy input sensitively. Therefore, the inference of original image proceeds appropriately since any pixel is influenced by surrounding pixels corresponding to the neighboring setting. In the restoration process, the effect of the initial threshold and the initial neighborhood on accuracy is examined. Experimental results are presented in order to show that the present method is effective in quality.

Key words self-organizing maps, image restoration, learning, peak signal to noise ratio

1. まえがき

自己組織化は、神経細胞間の側抑制の機構を用い、局所的な位相秩序を持った回路網を実現する。更に、近傍の入力に対して、常に近傍の神経細胞が応答するようになる[1], [2]。つまり、明白に局在した入力に対して、出力側の応答も局在したものとなる。従って、自己組織化では、膨大な情報を局在化して表現され、その表現は位相的秩序を持つ配列を形成する。自己組織化の適用例として、組合せ最適化問題、パターン認識、ベクトル量化、及びクラスタリングなどがある[3]。よって、様々な自己組織化モデルは存在するが、適用できる分野が異なっている。自己組織化写像に関して、主な研究の目的は、荷重ベクトルの順序付け過程や収束状態である[4]。第一の手法は位相保持写像の形成に関する問題であり、入力特性に対応した出力を構築する[5]–[7]。特徴写像の応用としては、例えば、巡回セールスマントラック問題があり、入力信号と比較して非常に多くの素子を用いて、弹性輪を採用することにより良好な結果を得ることができる[8], [9]。第二の手法はパターンベクトルの近似に関する問題であり、膨大な入力情報を少ない出力で表現する方法である。特に、荷重ベクトルの収束に関しては重要な問題であり、自己組織化をベクトル量化へ適用した場合に多くの議論されている[10]–[15]。一方、画像修復に関して、任意の画素は周囲の画素に影響を受けるという概念から、統計的に定式化されたマルコフ確率場モデルを用いて、原画像の推定が行なわれている[16], [17]。

本研究では、画像修復のための自己組織化写像による新たなアルゴリズムを提案する。本手法は、各画素に対し一つの素子が対応する写像を形成する。入力として画素値を用い、画像推定は自己組織化によって行なわれる。まず、入力値と推定画素との間の差に応じたしきい値をもつ更新関数を導入する。この関数により、ノイズを含む入力に過敏に反応しなくなる。また、近傍の設定により周囲の画素に影響を受け、原画像の推定が適切に推進する。次に、しきい値の初期値及び近傍の初期値を変化させ精度に及ぼす影響を調べる。数値計算は本手法が有効であることを示している。

2. 自己組織化写像

自己組織化において、簡単でしかも効率の良い Kohonen のアルゴリズムがある。このアルゴリズムでは、荷重の更新則が出力配列で近傍の関係を含むように修正されている。通常、このアルゴリズムは図 1 のような構造に適応される。入力空間 R^n に対して、確率密度関数 $p(x)$ で生成される入力 x が定義される。従って、 x は x_1 から x_n までの成分を持つ。出力ユニット y_i は一般に一次元もしくは二次元写像の配列で与えられ、 w_{ij} を経て入力と完全に結合している。

$x(t)$ をステップ t の入力ベクトルとし、 $w_i(0)$ を R^n 空間の初期値として k 個で構成される荷重ベクトルとする。入力ベクトル $x(t)$ に対して、この $x(t)$ と荷重ベクトル $w_i(t)$ の距離を計算し、距離が最小となるように勝者 c として荷重ベクトル

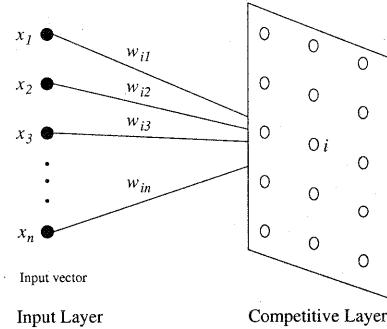


図 1 自己組織化写像の構造.
Fig. 1 Structure for self-organizing maps.

を選択する。この過程は次のように記述される：

$$c = \arg \min_i \{\|x - w_i\|\}, \quad (1)$$

ここで、 $\arg(\cdot)$ は勝者の指標 c を与える。

この勝者 c を用いて、荷重ベクトル $w_i(t)$ は次のように更新される：

$$\Delta w_i = \begin{cases} \alpha(t)(x - w_i) & (i \in N_c(t)), \\ 0 & (\text{otherwise}), \end{cases} \quad (2)$$

ここで、 $\alpha(t)$ は学習率であり、時間で減少する関数である ($0 < \alpha(t) < 1$)。また、 $N_c(t)$ はステップ t における勝者 c に対する位相的近傍の指標の集合である。

3. 画像修復

自己組織化写像を巡回セールスマントラック問題へ適応する場合、入力に対して非常に多くの荷重を用い、学習後の荷重の位置に基づいて良好な近似解を得ている。また、ベクトル量化へ適用する場合、膨大な情報を少数の素子で表現する目的のため、入力に対して少ない荷重が用いられ、多くの議論がなされている。

本研究では、あらかじめ与えられた劣化画像から原画像を推定するために、入力と荷重の同じ個数による自己組織化写像を提案する。ここで、劣化画像としての入力 x 及び推定画像としての荷重 r_i を定義する。各画素に対し一つの素子が反応する写像を形成し、入力として画素値を用いて、自己組織化によって画像推定が実行される。

まず、 r_i を初期値として階調値の中心付近の値をランダムに与える。次に、 $l \times m$ サイズの劣化画像が与えられ、その中から任意に x を選び、 x に対応する推定画素を r_c とする。図 2 に示すように、 x と r_c の位置は画像上で一致する。従って、推定画像 r_i は次式のように更新される：

$$\Delta r_i = \begin{cases} \alpha(t)\Theta(x - r_i) & (i \in N_c(t)), \\ 0 & (\text{otherwise}), \end{cases} \quad (3)$$

ここで、 $\Theta(a)$ は次式で表されるようなしきい値 $\theta(t)$ によって値が変わる関数である：

$$\Theta(a) = \begin{cases} a & (|a| \leq \theta(t)), \\ 0 & (\text{otherwise}). \end{cases} \quad (4)$$

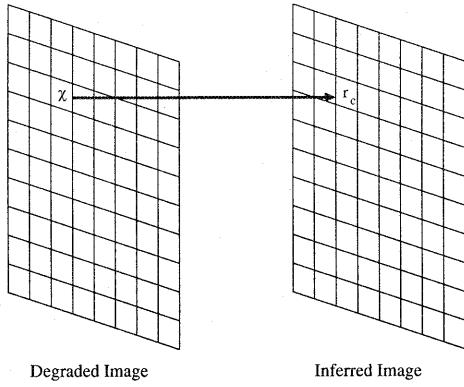


図 2 劣化画像と推定画像の対応.

Fig. 2 Correspondence between degraded image and inferred image.

自己組織化写像による学習の場合、荷重はノイズを含んだ入力にあまりにも敏感に反応する傾向がある。従って、これを回避するために、式(2)の代わりに式(3)を採用している。

これらの関数を用いて、終了条件が満たされるまで、荷重が更新される。そして、次章で与えられるように、画像修復が適切に推進する。

ここで、図3に位相的近傍の配列を示す。丸は荷重を表し、それを結ぶ線は位相的な近傍を表す。この図では、黒い丸は勝者 c の荷重を表し、時刻が t_1, t_2, t_3 と変化すると、位相的近傍の集合は $N_c(t_1), N_c(t_2), N_c(t_3)$ と変化し、集合の数は少なくなっていることを示している。

画像修復(IR)アルゴリズムは次のように与えられる。

[IR アルゴリズム]

Step 1 初期化:

初期値 $\{r_1(0), r_2(0), \dots, r_{lm}(0)\}$ 及び最大学習回数 T_{max} を与える。 $t \leftarrow 0$.

Step 2 自己組織化:

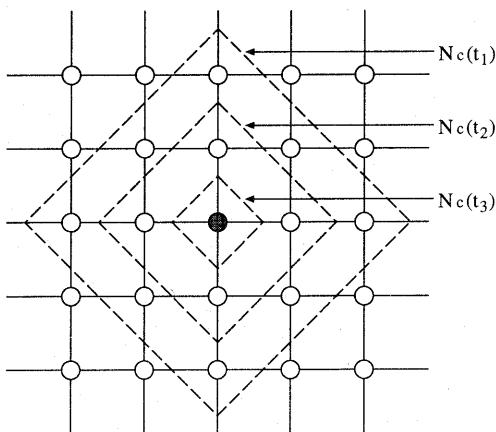


図 3 位相的近傍の配列.

Fig. 3 Distribution of topological neighborhoods.

(2.1) 入力 χ をランダムに $\{\chi_1, \chi_2, \dots, \chi_{lm}\}$ から選ぶ.

(2.2) χ に対応する r_c を選択する.

(2.3) 式(3)に従って、 r_c 及びその近傍を更新する.

(2.4) $t \leftarrow t + 1$.

Step 3 条件:

$t = T_{max}$ であれば終了。そうでなければStep 2へ。

本研究では、修復画像の品質測度として、ピーク信号対ノイズ(PSN)比 P を用いる。PSN比は次のように表現される:

$$P = 10 \log_{10}(\sigma/E) [\text{dB}] \quad (5)$$

ここで、 σ 及び E はそれぞれ最大階調数の二乗(つまり、 $\sigma = (Q - 1)^2$)及び原画像と修復画像の平均二乗誤差である。

4. 数値計算

数値計算において、画像推定はサイズ $l \times m = 512 \times 512$ 及び階調値 $Q = 256$ の劣化画像を修復する。図4(a)及び(b)に原画像*i*及び劣化画像*i*を示す。劣化画像は原画像と比較して25%の一様ノイズを含んでいる。すなわち、512×512画素のうちランダムに選ばれた25%の画素にノイズが含まれる。そして、選ばれた画素には0~255階調値がランダムに与えられる。初期荷重は階調値 Q の中心値付近に分布している。パラメータを次のように選択した: $l = 512, m = 512, T_{max} = 100 \cdot lm, N(t) = N_0 - \lfloor N_0 t / T_{max} \rfloor$, 及び $\theta(t) = \theta_0 - \lfloor \theta_0 t / T_{max} \rfloor$ 。

提案した画像修復アルゴリズムに従って、初期近傍 $N_0 = 3$ 及び初期しきい値 $\theta_0 = 97$ に対する修復画像の例を図4(c)に示す。本文で与えた手法に従って、劣化画像は修復できることが分かる。

図5は画像*i*に対する初期しきい値 θ_0 (図では I)と各初期近傍 $N_0 = 1, 2, \dots, 5$ におけるPSN比 P に及ぼす影響を示している。初期しきい値 θ_0 が70から120へ変化する中で、初期近傍 N_0 が1のとき、最も悪くなっていることが分かる。これは与えられた劣化画像のみから推定を行なっているためである。 N_0 が2のとき、前半の画素更新は着目した画素及びその周囲4画素から行なわれ、後半では着目した画素のみの更新により、PSN比 P が良い結果を与えていることが分かる。そして、 N_0 が3のとき、初期の周囲画素数は12であり、次に4となり、最終的に着目した画素のみからの更新が行なわれ、初期しきい値100付近で最も良い値を示している。さらに、 N_0 が4または5に増加した場合、 N_0 が3のときほど改善は見られない。この場合、 P は $N_0 = 3$ 及び $I = 97$ のとき、最大値を与える。図4(c)はこれらの値を用いて修復した。

複雑な画像の例として、図6(a)及び(b)に原画像*ii*及び劣化画像*ii*を示す。前述の画像と同様、劣化画像は原画像と比較して25%の一様ノイズを含んでいる。計算の条件は前述と同じである。提案した画像修復アルゴリズムに従って、初期近傍 $N_0 = 2$ 及び初期しきい値 $\theta_0 = 113$ に対する修復画像の例を図6(c)に示す。この場合も、劣化画像は修復できることが分かる。

図7は画像*ii*に対する θ_0 (図では I)と N_0 における P の値を示している。画像*i*の画像推定と異なり、 N_0 が2のとき、



(a) 原画像 i



(b) 劣化画像 i



(c) 修復画像 i

図 4 サイズ 512×512 及び階調値 256 の原画像 i に対する劣化画像 i と修復画像 ii の例。

Fig. 4 Original image i with 512×512 size and 256 gray-scale, degraded image i, and example of restored image i.

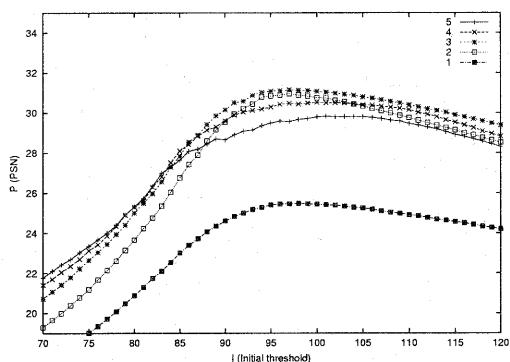


図 5 画像 i に対する PSN 比と初期しきい値。

Fig. 5 PSN ratio and initial threshold for image i.

表 1 提案手法及びメディアンフィルタの結果に対する PSN 比。

Table 1 PSN ratio for results of the present method and the median filter.

	提案手法	メディアンフィルタ
画像 i	31.1 dB	29.3 dB
画像 ii	22.7 dB	19.5 dB

θ_0 が 70 から 140 へ変化する中で 110 付近で最も良い結果を与えており、この場合、前半の画素更新は着目した画素及びその周囲 4 画素であり、後半では着目した画素のみの更新である。 N_0 が 1, 3, 4, 及び 5 のとき、 N_0 が 2 のときほど改善は見られない。 P の最大値は $N_0 = 2$ 及び $I = 113$ のときである。この値を用いた画像推定の結果の例が図 6 (c) である。

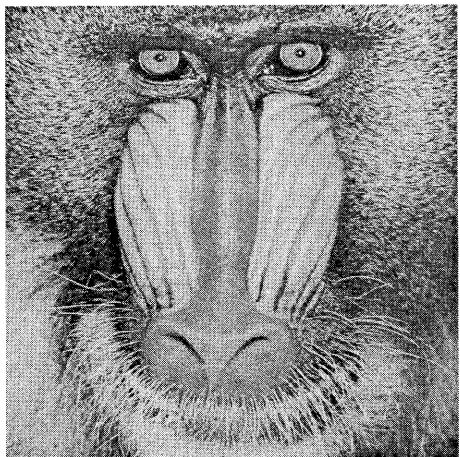
表 1 に提案手法及びメディアンフィルタの結果に対する PSN をまとめる。提案手法は画像 i 及び ii に対してメディアンフィルタより優れていることが分かる。このことは、入力値と推定画素との間の差に応じたしきい値をもつ更新関数を導入したことにより、ノイズを含む入力に過敏に反応しなくなり、また、近傍の設定により周囲の画素に影響を受け、原画像の推定が適切に行なわれたことによる。

5. む す び

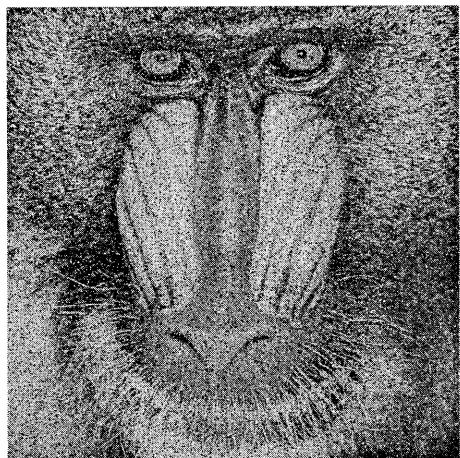
本研究では、画像修復のための新たな自己組織化写像アルゴリズムを提案し、数値実験により本手法の有効性を示した。本手法は、各画素に対し一つの素子が対応する写像を形成し、入力として画素値を用い、画像推定は自己組織化によって行なわれた。そのために、入力値と推定画素との間の差に応じたしきい値をもつ更新関数を導入し、ノイズを含む入力に過敏に反応するのを回避した。そして、近傍の設定により周囲の画素に影響を受け、原画像の推定が適切に行なわれた。最後に、より有効な手法や理論的考察は今後の課題としたい。

文 献

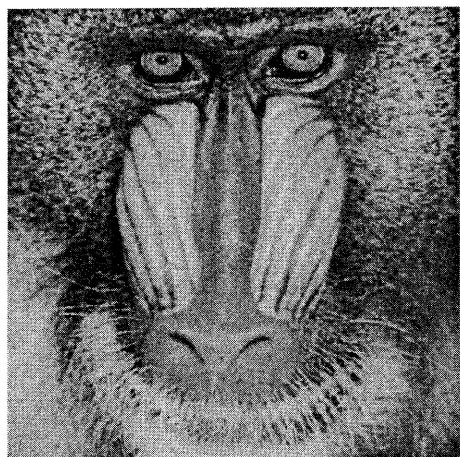
- [1] S. Grossberg, "Adaptive pattern classification and universal recoding; I. Parallel development and coding of neural feature detectors," Biol. Cybern., vol.23, pp.121-134, 1976.
- [2] D.J. Willshaw and C. von der Malsburg, "How patterned neural connections can be set up by self-organization," Proc.



(a) 原画像 ii



(b) 劣化画像 ii



(c) 修復画像 ii

図 6 サイズ 512×512 及び階調値 256 の原画像 ii に対する劣化画像 ii と修復画像 ii の例。

Fig. 6 Original image ii with 512×512 size and 256 gray-scale, degraded image ii, and example of restored image ii.

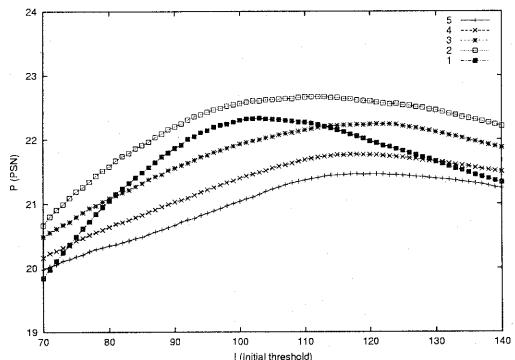


図 7 画像 ii に対する PSN 比と初期しきい値。

Fig. 7 PSN ratio and initial threshold for image ii.

- R. Soc. Lond. B., vol.194, pp.431–445, 1976.
[3] J. Hertz, A. Krogh, and R. G. Palmer, Introduction to the theory of neural computation, Addison-Wesley, 1991.
[4] T. Kohonen, Self-organizing maps, Springer-Verlag Berlin, 1995.
[5] H.-U. Bauer and K.R. Pawelzik, “Quantifying the neighborhood preservation of self-organizing feature maps,” IEEE Trans. Neural Networks, vol.3, pp.570–579, 1992.
[6] T. Martinetz and K. Schulten, “Topology representing networks,” Neural Networks, vol.7, pp.507–522, 1994.
[7] T. Villmann, M. Herrmann, and T.M. Martinetz, “Topology preservation in self-organizing feature maps: Exact definition and measurement,” IEEE Trans. Neural Networks, vol.8, pp.256–266, 1997.
[8] R. Durbin and D. Willshaw, “An analogue approach to the traveling salesman problem using an elastic net method,” Nature, vol.326, pp.689–691, 1987.
[9] B. Angéniol, G. de La C. Vaubois, and J.-Y. Le Texier, “Self-organizing feature maps and the traveling salesman problem,” Neural Networks, vol.1, pp.289–293, 1988.
[10] H. Ritter and K. Schulten, “On the stationary state of Kohonen’s self-organizing sensory mapping,” Biol. Cybern., vol.54, pp.99–106, 1986.
[11] H. Ritter and K. Schulten, “Convergence properties of Kohonen’s topology conserving maps, Fluctuations, stability, and dimension selection,” Biol. Cybern., vol.60, pp.59–71, 1988.
[12] 田中利幸, 斎藤正男, “適応的ベクトル量子化法としての Kohonen のモデルの定量的性質,” 信学論, vol.J75-D-II, pp.1085–1092, 1992.
[13] T. M. Martinetz, S. G. Berkovich, and K. J. Schulten, ““Neural-gas” network for vector quantization and its application to time-series prediction,” IEEE Trans. Neural Networks, vol. 4, pp. 558–569, 1993.
[14] M. Maeda, H. Miyajima, and S. Murashima, “An adaptive learning and self-deleting neural network for vector quantization,” IEICE Trans. Fundamentals, vol.E79-A, pp.1886–1893, 1996.
[15] M. Maeda and H. Miyajima, “Competitive learning methods with refractory and creative approaches,” IEICE Trans. Fundamental, vol.E82-A, pp.1825–1833, 1999.
[16] S. Geman and D. Geman: “Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images.” IEEE Trans. Pattern Anal. Mach. Intel., vol.6, pp.721–741, 1984.
[17] M. Maeda, M. Ohta, and H. Miyajima: “An algorithm of statistical mechanics for image restoration,” Proc. IEICE Int. Symp. Nonlinear Theory and Its Applications, vol.1, pp.107–110, 2001.