

モルフォロジーにおける構造要素の GA による最適化と テクスチャ解析への適用

山本慎一 小谷一孔
北陸先端科学技術大学院大学 情報科学研究科
〒923-12 石川県能美郡辰口町旭台 1-1
0761-51-1699(内線 1384)
s-yamamt@jaist.ac.jp ikko@jaist.ac.jp

本研究の目的は、モルフォロジーで定義された画像処理に対し、その処理目的に最適な構造要素を求める手法の獲得である。これまで、Simulated Annealing を用いて構造要素の最適化を試みたが、対象画像が濃淡画像の場合、構造要素の取り得るパターンの多さから、構造要素のモデル化を行なう必要があった。そのため、複雑な形状の構造要素を得ることができず、目的の処理結果を得るには充分ではなかった。そこで本研究では、Genetic Algorithm を用いて複雑な形状の最適構造要素の設計を試みる。また、処理目的をパターンスペクトルに基づくテクスチャ解析とし、構造要素の最適化により、その高精度化を計る。特に顔画像の表情解析へ適用し、その妥当性を確かめる。

キーワード：モルフォロジー、GA、テクスチャ解析、パターンスペクトル

Optimization of Structuring Element on Mathematical Morphology by GA and Its Application to Textur Analysis

Shinichi YAMAMOTO Kazunori KOTANI
Graduate School of Information Science, Japan Advanced Institute of Science and Technology
1-1 Asahidai, Tatsunokuchi-machi, Nomi-gun, Ishikawa, 92 3-12, Japan
0761-51-1699 (ext.1384)
s-yamamt@jaist.ac.jp ikko@jaist.ac.jp

This paper proposes the method to decide a optimum structuring element that attain the object of a image processing defined by Mathematical Morphology. We have tried to optimize the structuring element by Simulated Annealing. But, we must make the model of the gray scale structuring element, because a structuring element can change to many pattern in the case of gray scale image. Consequently, we can't achieve the object of a image processing sufficiently because of difficulty of modeling the gray scale structuring element that has intricate shape.

Therefore, this paper proposes an optimization method for a gray scale structuring element that has intricate shape by Genetic Algorithm, and it apply to the textur analysis based on pattern spectrum. Specially, we prove adequacy for application to expression analysis of facial image.

Key Words: Mathematical Morphology, Genetic Algorithm, Textur Analysis, Pattern Spectrum

1 はじめに

モルフォロジーは、対象画像と構造要素との集合演算で定義される。基本的なモルフォロジー演算の組合せと構造要素によって様々な画像処理を実現することができる。しかし、演算式は理論的に設計できても、画像情報のプローブとも言うべき構造要素は集合であるため、対象画像から抽出しようとする特徴が数学的な表現が困難な場合には、その設計は困難なものとなる。

そこで、本研究の目的は、モルフォロジーで定義された画像処理に対し、その処理目的に最適な構造要素を求める手法の獲得である。これにより、対象とするものの特徴が、数学的に表現が困難な場合でも最適な構造要素の設計が可能となる。

これまで、Simulated Annealing を用いて構造要素の最適化を試みた [1] が、対象画像が濃淡画像の場合、構造要素の取り得るパターンの多さから、構造要素のモデル化を行なう必要があった。そのため、複雑な形状の構造要素を得ることができず、目的の処理結果を得るには充分ではなかった。そこで本研究では、Genetic Algorithm を用いて複雑な形状の最適構造要素の設計を試みる。

また、モルフォロジーで定義されたパターンズベクトルを用いることにより、対象画像のテクスチャの特徴捉えることができる。この特徴は、構造要素を任意に変えることにより、その構造要素特有のテクスチャの特徴を得ることができるところにある。そこで、構造要素の最適化手法の有効性を確かめるために、処理目的をパターンズベクトルに基づくテクスチャ解析とし、特に実画像への適用として、顔画像の表情解析への適用を試みる。

本稿では、2章でモルフォロジーの定義について述べた後に、3章で構造要素の最適化手法を提案し、4章でパターンズベクトルに基づくテクスチャ解析手法について述べ、5章で4章で述べたテクスチャ解析手法へ構造要素の最適化の適用を行なう。

2 モルフォロジーの定義

モルフォロジーは、集合論にその基盤をもち、画像処理が数学的に体系化されているところに特徴がある。また、基本的なモルフォロジー演算の組合

せと構造要素により様々な画像処理を可能とする。モルフォロジーの基本演算として、*dilation, erosion* と、*opening, closing* がある。

2値画像では、以下のように定義される。

$$\text{dilation: } A \oplus B = \{x \in B^N | x = a + b, a^v \in A, b^v \in B\} \quad (1)$$

$$\text{erosion: } A \ominus B = \{x \in B^N | x + b \in A, b^v \in B\} \quad (2)$$

$$\text{opening: } A_B = (A \ominus B) \oplus B \quad (3)$$

$$\text{closing: } A^B = (A \oplus B) \ominus B \quad (4)$$

ただし、 A, B は、それぞれ対象画像と構造要素の図形を構成する画素の座標を表す位置ベクトル a, b を要素とする集合である。

濃淡画像では、以下のように定義される。

$$\text{dilation: } (f \oplus g)(x) = \max_{\substack{z \in G \\ x - z \in F}} \{f(x - z) + g(z)\} \quad (5)$$

$$\text{erosion: } (f \ominus g)(x) = \min_{\substack{z \in G \\ x + z \in F}} \{f(x + z) - g(z)\} \quad (6)$$

$$\text{opening: } f_g = (f \ominus g) \oplus g \quad (7)$$

$$\text{closing: } f^g = (f \oplus g) \ominus g \quad (8)$$

ただし、 $f(x)$ は対象画像、 $g(x)$ は構造要素である。また、 F, G は、それぞれの定義域である。

3 最適構造要素の設計法

本手法では、まず目的とする処理を実現するようなモルフォロジー演算を論理的に定義する。また、構造要素が適切であるか評価を行なうための評価関数を与える。このとき、評価値が改善されるようにトレーニングを行なうことにより、最適な構造要素を設計する。




図 1: 構造要素の最適化手法

しかし、構造要素は、2次元もしくは3次元空間における位置ベクトルを要素とする集合であるため、そのような部分集合は無数に存在する。

このような、無数に存在する構造要素の中から最適なものを効率良く求めるためのアルゴリズムが必要である。

本研究では最適化アルゴリズムとして、Simulated Annealing(SA)とGenetic Algorithm(GA)を用いて構造要素の最適化を行なう。

3.1 SAによる構造要素の最適化手法

SAのアルゴリズムを、図2に示す。SAは、評価値が改善される時は常に構造要素を変形し、評価値が改悪される場合でも、ある確率 $P(\Delta E)$ でその構造要素の変形を認めることによって、局所解から脱出することが可能となり最適な構造要素を求めることができる。 $P(\Delta E)$ は、

$$P(\Delta E) = \exp(-\Delta E/T(t)) \quad (9)$$

で与えられる。ただし、改悪量 ΔE は、次式で与えられる。

$$\Delta E = E(g(t)) - E(g_{tmp}(t)) \quad (10)$$

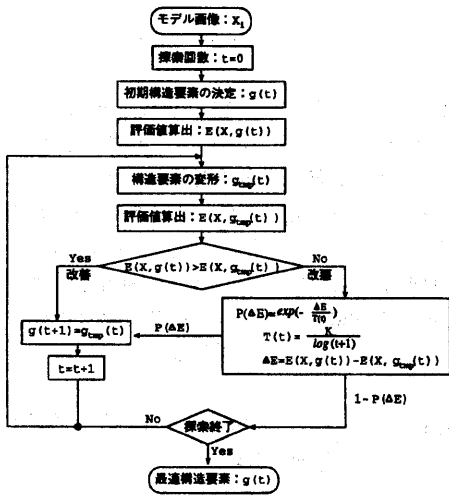


図2: SA アルゴリズム

3.1.1 構造要素のモデル化

SAでは、現在の構造要素の近傍の構造要素を探索するため、SAの探索範囲はGAに比べて大きくない。そこで、対象画像が濃淡画像の場合、構造要素のとり得るパターンの多さから、SAでは、

図3のように水平成分(HSE)と垂直成分(VSE)のdilationで与えられる屋根型の構造要素でモデル化し、この構造要素の頂点の位置を変えることにより、構造要素を変形することにより探索空間を小さくし効率的に最適構造要素を求める。

$$HSE_{h_p, h_l}(x, 0) = \begin{cases} \frac{h_p}{h_l}x & : 0 \leq x \leq h_p \\ \frac{h_p}{4-h_l} - x + 4 & : h_p \leq x \leq 4 \end{cases} \quad (11)$$

$$VSE_{v_p, v_l}(0, y) = \begin{cases} \frac{v_p}{v_l}y & : 0 \leq y \leq v_p \\ \frac{v_p}{4-v_l} - y + 4 & : v_p \leq y \leq 4 \end{cases} \quad (12)$$

$$SE = HSE \oplus VSE \quad (13)$$




図3: 構造要素のモデル化

3.2 GAによる構造要素の最適化手法

GAは、生物新化の原理に着想を得たアルゴリズムである。遺伝子型に相当する構造要素の集団に対し、自己再生・交叉・突然変異などの遺伝的操作を繰り返し行ない、評価値の高い構造要素を選んで残していくことにより、構造要素の集団全体の評価値を向上させていく方法である。




図4: 遺伝的アルゴリズム GA

3.2.1 本手法における遺伝的操作

通常、遺伝子型は1次元配列で表されるが、本手法で求める解は2次元配列で表される構造要素であるため、1つの構造要素を2次元の遺伝子型とみなす。そのときの遺伝的操作は、以下のように行なう。

(a) 交叉

交叉は、縦または横に構造要素を切りつなぎ合わせるにより、新しい構造要素を生成する。




図 5: 交叉

交叉を受ける構造要素の選択方法は、良い評価値の構造要素が子孫を残せるように構造要素の評価値に比例した確立より選択する。構造要素 i が選ばれる確立 $p(i)$ は次式で与えられる。ただし、 N は集団中の個体数、 $E(i)$ は、構造要素 i の評価値である。

$$p(i) = \frac{E(i)}{\sum_{j=1}^N E(j)} \quad (14)$$

(b) 突然変異

突然変異は、乱数によって選ばれた画素の値を変化させることにより、新しい構造要素を生成する。




図 6: 突然変異

突然変異を受ける構造要素の選択方法も、交叉と同様に式 (14) の確立 $p(i)$ により選択する。

(c) 自己再生

評価値の良い構造要素を次世代で失うことがないように、構造要素の集団中の評価値が上位のものを次世代にそのまま残す。

4 パターンスペクトルに基づくテクスチャ解析

本研究では、テクスチャが幾つかのカテゴリ ($i: i = 1, 2, \dots, N$) に分類できるような画像群 X_i を対象とし、入力画像 X がどのカテゴリに属するかについて解析する。

その際に、テクスチャの特徴を捉えるものとしてパターンスペクトルを用い、そのパターンスペクトルに基づいて入力画像のカテゴリを判別する。

4.1 パターンスペクトル

対象画像 f に対する構造要素 g によるパターンスペクトル $PS_f(s, g)$ は、

$$PS_f(s, g) = A[f \otimes g] - A[f_{(s+1)}g] \quad (15)$$

$$sg = \underbrace{g \oplus g \oplus \dots \oplus g}_s \quad (16)$$

ただし、 $A[\]$ は、 $[\]$ 内の輝度値の総和である。

パターンスペクトルは、スケール s が小さいところでは、画像の局所的な凹凸の状況を示し、スケールの大きいところは、画像の大局的な情報を表している。このように、パターンスペクトルは、画像特徴を表していることから、異なるテクスチャを有する画像間では、それらの画像特徴の差異がパターンスペクトルに現れる。

4.2 パターンスペクトルに基づくテクスチャ解析手法

テクスチャ解析手法を、図 7 に示す。予め各カテゴリを代表するモデル画像から、辞書となるパターンスペクトル $PS_{X_i}(s, g)$ を求めておく。そして、入力画像のパターンスペクトル $PS_X(s, g)$ と $PS_{X_i}(s, g)$ の類似度を求め、入力画像がどのカテゴリに属するかを判別する。

ただし、類似度は、式 (17) を用いる。

$$S[PS_X(s, g), PS_{X_i}(s, g)] = \frac{\sum_{s=0}^S PS_X(s, g) PS_{X_i}(s, g)}{\sqrt{\sum_{s=0}^S PS_X(s, g)^2} \sqrt{\sum_{s=0}^S PS_{X_i}(s, g)^2}} \quad (17)$$

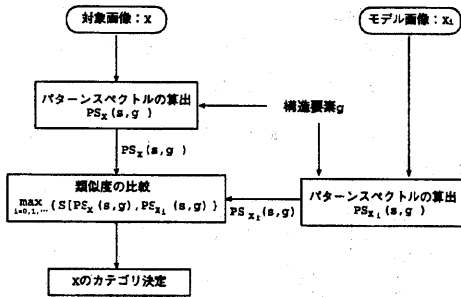


図 7: パターンスペクトルに基づくテクスチャ解析手法

4.3 顔画像の表情解析への適用

本手法の実画像への応用として、顔画像の表情解析へ適用する。笑い、怒り…など数種の表情カテゴリのうち、入力された顔画像がどのカテゴリに属するかを判別する。

今回実験では、無表情・笑い・悲しみ・怒りの4つの表情カテゴリに対して、図8の各カテゴリを代表する顔画像(100 × 120 pixels)を用いて、それぞれの人物に対する辞書パターンスペクトルを作成し、オープンデータとして図8とは別に撮影した顔画像を入力画像として与えたとき、それぞれの表情の顔画像がどのカテゴリに属するか判別を行なった。

また、実験で使用した構造要素は、一般的によく用いられる式(18)のSQUAREを用いた。

$$g(x, y) = 0 : \{-2 \leq x \leq 2, -2 \leq y \leq 2\} \quad (18)$$



(a) 人物 1



(b) 人物 2

図 8: 辞書に用いた画像(無表情、笑い、悲しみ、怒り)

4.3.1 実験結果

SQUAREを用いて作成した辞書パターンスペクトルと各表情の入力画像のパターンスペクトルとの類似度を表1に示す。表1において、辞書パターンスペクトルの中で、各入力画像のパターンスペクトルと最も類似しているものをアンダーラインで示す。

表 1: 入力画像と辞書画像のパターンスペクトルの類似度

(a) 人物 1

辞書画像 入力画像	無表情	笑い	悲しみ	怒り
無表情	<u>0.9908</u>	0.9671	0.8900	0.9574
笑い	0.8482	<u>0.8874</u>	0.8102	0.8396
悲しみ	0.7511	<u>0.8675</u>	0.8555	0.8266
怒り	0.9112	<u>0.9321</u>	0.8255	0.8831

(b) 人物 2

辞書画像 入力画像	無表情	笑い	悲しみ	怒り
無表情	0.9863	0.9821	<u>0.9961</u>	0.9858
笑い	0.9731	0.9958	0.9819	<u>0.9974</u>
悲しみ	0.9824	0.9791	<u>0.9915</u>	0.9863
怒り	0.9845	<u>0.9964</u>	0.9913	0.9950

4.3.2 考察

誤判定を生じた原因として、表2に示すように辞書パターンスペクトル間の類似度が高いためと考えられる。

表2において、各表情の辞書パターンスペクトル間で最も類似しているものをアンダーラインで示す。

表 2: 辞書中のパターンスペクトル間の類似度
(a) 人物 1

	笑い	悲しみ	怒り
無表情	0.8927	0.8943	0.9587
笑い		<u>0.9786</u>	0.9505
悲しみ			0.9536

(b) 人物 2

	笑い	悲しみ	怒り
無表情	0.9849	0.9932	0.9764
笑い		0.9858	<u>0.9934</u>
悲しみ			0.9856

ここで、3章で述べた構造要素の最適化の適用を考える。各表情のパターンスペクトル固有の特徴を強調するように構造要素の最適化を行なう。これにより、辞書中のパターンスペクトル間の距離が広がり、分解能が向上し、判別精度の向上が見込まれる。

5 構造要素の最適化によるテキストチャ解析の判別精度の改善

図7のテキストチャ解析に構造要素の最適化を適用したものを図9に示す。

辞書パターンスペクトルを作成する際に、辞書中のパターンスペクトル間の類似度が小さくなるように構造要素の最適化を行なう。このとき、辞書パターンスペクトル間の類似度の最大のが最小になるときの構造要素が、最適な構造要素とし、評価関数として式(19)が最小となる構造要素を最適構造要素とする。

$$E[g] = \max_{\substack{i,j=0,1,\dots,N \\ j \neq i}} S[PS_{X_i}(s,g), PS_{X_j}(s,g)] \quad (19)$$

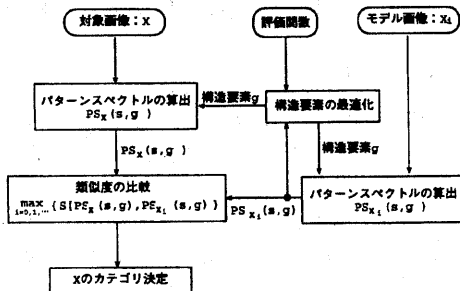


図 9: テキスチャ解析における構造要素の最適化の適用

5.1 表情解析への適用

4.3の表情解析において、各カテゴリの辞書パターンベクトルを作成する際に構造要素の最適化を行ない、表情の解析精度の向上を計る。

実験では、SAとGAのそれぞれの手法により最適な構造要素を求め、その最適構造要素を用いて、4.3と同様に4つの表情カテゴリに対して、図8から辞書パターンベクトルを作成し、4.3と同じ入力画像を用いて判別を行なった。

5.1.1 SAによる構造要素の最適化の適用結果 (a) 人物 1




図 10: 評価値の推移




図 11: 最適構造要素

表 3: 最適構造要素による辞書パターンベクトル間の類似度

	笑い	悲しみ	怒り
無表情	0.9277	<u>0.9530</u>	0.9220
笑い		0.9401	0.8401
悲しみ			0.7637

表 4: 入力画像と辞書画像のパターンスペクトル間の類似度

辞書画像	無表情	笑い	悲しみ	怒り
入力画像				
無表情	0.9867	0.9847	<u>0.9972</u>	0.9756
笑い	0.8425	<u>0.8653</u>	0.8590	<u>0.8653</u>
悲しみ	0.8277	0.8496	<u>0.8527</u>	0.8396
怒り	0.7276	0.7016	0.7405	<u>0.7690</u>

5.1.2 GA による構造要素の最適化の適用結果
(a) 人物 1

(b) 人物 2




図 12: 評価値の推移




図 14: 評価値の推移




図 13: 最適構造要素




図 15: 30 世代で最も良い評価値を示す構造要素

表 5: 最適構造要素による辞書パターンスペクトル間の類似度

	笑い	悲しみ	怒り
無表情	0.7960	0.8770	<u>0.9176</u>
笑い		0.7333	0.7286
悲しみ			0.6688

表 6: 入力画像と辞書画像のパターンスペクトル間の類似度

辞書画像	無表情	笑い	悲しみ	怒り
入力画像				
無表情	<u>0.9005</u>	0.8617	0.8496	0.8274
笑い	0.7288	0.8605	<u>0.8871</u>	0.7557
悲しみ	0.8349	0.8313	<u>0.8992</u>	0.8879
怒り	0.8088	0.8056	0.8450	<u>0.8743</u>

表 7: 最適構造要素による辞書パターンスペクトル間の類似度

(30 世代で最も良い評価値を示す構造要素)

	笑い	悲しみ	怒り
無表情	0.6674	0.7371	0.7990
笑い		0.7894	0.8729
悲しみ			<u>0.9450</u>

表 8: 入力画像と辞書画像のパターンスペクトル間の類似度

辞書画像	無表情	笑い	悲しみ	怒り
入力画像				
無表情	<u>0.9978</u>	0.8966	0.9091	0.9835
笑い	0.8152	<u>0.9262</u>	0.9123	0.7832
悲しみ	0.8003	0.9404	<u>0.9407</u>	0.7307
怒り	0.8374	0.7735	<u>0.9664</u>	0.9556

(b) 人物 2




図 16: 評価値の推移



図 17: 30 世代で最も良い評価値を示す構造要素

表 9: 最適構造要素による辞書パターンスペクトル間の類似度

(30 世代で最も良い評価値を示す構造要素)

	笑い	悲しみ	怒り
無表情	0.7153	<u>0.8625</u>	0.7149
笑い		0.6953	0.8104
悲しみ			0.6577

表 10: 入力画像と辞書画像のパターンスペクトル間の類似度

辞書画像 入力画像	無表情	笑い	悲しみ	怒り
無表情	<u>0.9611</u>	0.8569	0.7137	0.8902
笑い	0.8074	<u>0.9771</u>	0.6966	0.8072
悲しみ	0.8105	0.7777	<u>0.9915</u>	0.9850
怒り	0.7680	<u>0.8659</u>	0.6668	0.8644

6 まとめ

本稿では、モルフォロジーで定義された画像処理に対し、その処理目的に最適な構造要素の設計手法として、GA による構造要素の最適化を試みた。

表情解析への適用では、オープンデータに対する表情の判別精度は、SA と比べてあまり向上は見られなかったものの、SA に比べて GA の方が評価値の良い構造要素を得ることができた。

今回の実験では、30 世代で最も評価値の良い構造要素を用いて表情判別を行なったが、GA では 30 世代以降にも突然変異などによって評価値の良い構造要素が生成される可能性がある。そこで、探索の終了条件として、表情判別に必要な評価値の適切な目標値を設定する必要がある。今後は、その目標値の適切な設定方法と探索を効率的に進めるために、構造要素の最適化に適した遺伝的操作の検討を行なう。

謝辞 本研究の一部は、(財)高柳記念電子科学技術振興財団の援助によるものである。

参考文献

- [1] 山本 慎一、小谷 一孔: “モルフォロジーにおける最適構造要素によるテキスト解析”, 第 2 回映像メディア処理シンポジウム資料, Vol.2, 1997, pp105-106
- [2] 間瀬 茂、上田 修功: “モルフォロジーと画像解析 [I]”, 信学誌, Vol.74, No.2, 1991, pp116-174
- [3] 間瀬 茂、上田 修功: “モルフォロジーと画像解析 [II]”, 信学誌, Vol.74, No.3, 1991, pp271-279
- [4] 北野 宏明: “遺伝的アルゴリズム”, 産業図書, 1993 年
- [5] 小畑 秀文: “モルフォロジー”, コロナ社, 1996 年