

遺伝的アルゴリズムに基づく教師つき テクスチャ分類用トレーニングエリアの自動選定

Automatic selection of reasonable training areas for supervised texture classification based on the genetic algorithm

○奥村 浩, 内山克史 (長岡技科大), 梶原康司 (千葉大 CERESe), 張 熙, 吉川敏則 (長岡技科大)
Hiroshi Okumura, Katsushi Uchiyama (Nagaoka Univ. Tech.), Koji Kajiwar (CERESe, Chiba Univ.),
Xi Zhang and Toshinori Yoshikawa (Nagaoka Univ. Tech.)

Abstract

An automatic selection method of reasonable training areas for supervised texture classification is proposed. This method is based on both the texture representation method using rotation invariant moments and the genetic algorithm (GA). In the proposed method, first, sets of candidates for each texture category are roughly given. The chromosomes for the GA are formed by the indexed candidates and their extent. The fitness function for the GA is obtained by the mixed texture model and quantified pure textures. In this paper, summary of the texture representation method and comparison of texture discrimination ability with the conventional Haralick's method are described. Furthermore, the details of the proposed automatic selection method are presented, and some simulation results are also shown.

Keywords

supervised texture classification, complex Zernike moment, training areas, genetic algorithm

1. はじめに

今秋打ち上げられ、その有用さが期待される IKONOS(米 Space Imaging Inc.) をはじめとした近年の衛星搭載センサの高解像度化により、地上の情報がより詳しく得られるようになった。しかしながら、従来のリモートセンシング画像分類手法では、主として分光(スペクトル)情報や空間(形状)情報が利用されているため、本来同一カテゴリに分類されるべき場所が、輝度のわずかな違いで別のカテゴリに分類されてしまうといった新たな問題が生じるようになった。本研究では、人間の感覚により近い画像分類を行う目的で、画像内のテクスチャ情報の新しい定量化手法を開発するとともに、その手法を教師つきテクスチャ分類に適用してきた。本稿では、まず、画像の空間パワースペクトル分布パターンを回転不変モーメントの一つである Zernike モーメント⁵⁾を用いたテクスチャ定量化手法の概要を示す。次に、従来のテクスチャ定量化手法とのテクスチャ識別能力の比較実験結果を示す。比較対象には、従来手法の一つである同時生起行列に基づく Haralick の特徴量ベクトル¹⁾を用いた。さらに、教師つきテクスチャ分類において重要な、適切なトレーニングエリアの選定作業を自動化するために、遺伝的アルゴリズム^{6),7)}に基づく新しいトレーニングエリア自動選定手法を提案し、実際の航空機 MSS 画像を用いたトレーニングエリア選定実験により、その有効性を検証する。また、本手法により選定されたトレーニングエリアを用いた教師つきテクスチャ分類の結果も併せて報告する。

2. Zernike モーメントに基づくテクスチャ定量化手法

画像のテクスチャは、通常ある程度の広さの領域を対象に定義される。ここでは、画像中のある大きさの正方形の視野内に入る部分のテクスチャについて定量化を行い、以後この視野を正方視野と呼ぶことにする。リモートセンシング画像のテクスチャ定量化で重要なことは、同じテクスチャであれば、正方視野内での位置や、テクスチャ回転角度の大きさに関わらず、同一のテクスチャとして扱われなければならない点である。そこで、本手法では、パターンの平行移動成分の影響を抑えるため、画像そのものではなく、2次元 DFT を用いて画像を空間振幅スペクトル分布に変換した上で、回転に対する影響を抑えるために、回転不変量として知られている Zernike モーメント⁵⁾を適用している。

本手法は、次の5つの手順からなっている。

- 1) 異常値の置換およびヒストグラムストレッチ：正方視野中にノイズが混入している可能性があるため、画素の輝度値分布ヒストグラムの両端5%を異常値と見なし、隣接8画素の輝度値の平均で置換した後、ヒストグラムをストレッチする。
- 2) 窓処理：2次元DFTを適用する際の境界効果を回避するために、窓処理を行う。ここでは、Hanning関数を採用した。
- 3) 空間スペクトルの振幅成分の算出と正規化：2次元DFTにより、正方視野内の画像の空間スペクトルの振幅成分を算出し、DC成分以外の値を正規化する。
- 4) Zernike モーメントの算出：空間スペクトルの振幅成分の分布から複素 Zernike モーメントの絶対値

$$A_{nl} = \frac{n+1}{\pi} \int_0^{2\pi} \int_0^1 [V_{nl}(r, \theta)]^* \cdot f(r \cos \theta, r \sin \theta) r \, dr \, d\theta \quad (1)$$

を算出する。ここで、* は複素共役を意味し、 n, l はそれぞれ、次数、繰り返し数と呼ばれるパラメータである。次数 n は、正の整数であり、繰り返し数 l は、 $n - |l| = \text{even}$ ($|l| \leq n$) なる条件を満たす整数である。また、 $V_{nl}(r, \theta)$ は複素 Zernike 多項式²⁾⁻⁴⁾と呼ばれ、次式で定義される。

$$V_{nl}(r, \theta) = R_{nl}(r) e^{il\theta} \quad (2)$$

複素 Zernike 多項式系 $\{ V_{nl}(r, \theta) \}$ は単位円内 $|r| \leq 1, 0 \leq \theta \leq 2\pi$ で完備な直交関数系を構成する³⁾。ここで、 $R_{nl}(r)$ は動径多項式と呼ばれ、

$$R_{nl}(r) = \sum_{s=0}^{(n-|l|)/2} (-1)^s \cdot \frac{(n-s)!}{s! \left(\frac{n+|l|}{2} - s \right)! \left(\frac{n-|l|}{2} - s \right)!} r^{n-2s} \quad (3)$$

で定義される。本手法では、次数 n は、計算量や各次数のモーメントが持つ情報量の大きさから考えて、 $0 \leq n \leq 20$ の範囲を用いることとし、さらに、空間スペクトルの対称性から偶数次のみを用いる。また、複素モーメントの絶対値を用いるため、繰り返し数 l は n 以下の正数のみを用いた。

5) Zernike モーメントベクトルの正規化：算出した66種類の Zernike モーメントをまとめてひとつのベクトルと考え、このベクトルの大きさが1になるように正規化を行う。これは、Zernike モーメント算出の際に空間スペクトル分布を単位円へ写像するため、各 Zernike モーメントがほぼ一律に正方視野の大きさの影響を受けるためである。

以上の手順で得られた正規化 Zernike モーメントベクトルを定量化されたテクスチャと考える。前述のように、このベクトルの各要素は互いに直交している。従って、画像のテクスチャは、用いた Zernike モーメントで張られる66次元直交空間の、原点から半径1の超球面上のある1点へのベクトルとして一意に表現できる。この定量化手法を教師つきテクスチャ分類に適用する際に重要な他のテクスチャとの相互識別には、各テクスチャから得られた正規化 Zernike モーメントベクトルで形成される偏角を利用し、最小角度を示す教師カテゴリに分類を行う。

3. 従来手法とのテクスチャ識別能力比較

提案したテクスチャ定量化手法の有効性を検証するために、自然界に実在するテクスチャの写真を用いて従来手法とのテクスチャ識別能力比較実験を行った。比較対象とした従来手法には、同時生起行列に基づく Haralick の特徴量¹⁾を用いた。従来手法1では、4種類の同時生起行列から得られた各々13種類、合計52種類の特徴量をそのままベクトルとして扱い、従来手法2では、上記13種類の特徴量の4種類の同時生起行列間での平均値と範囲をベクトルとして扱った。実験に用いた画像は、Brodatzの写真集⁸⁾から選んだ15種類の写真 (Fig.1 参照) を、フラットベッドスキャナ上で30度刻みで回転させながら取り込んだ画像である。画像の大きさ、正方視野の大きさは、ともに128×128で、これらの画像には、各々若干の平行移動も加わっている。これら180枚の画像総てを参照画像 (教師画像) と考え、180枚の画像がどの参照画像に分類されるかというクロスマッチ分類を試みたところ、Fig.2のようになった。各黒点は分類候補の上位12位以内を示している。これらの点が同じ種類の (回転していることを除けば同じ対象物を撮影した) 参照画像に集結していれば、回転の影響による誤分類がないことを

示している。Fig.2 から明らかなように、従来手法は2種類とも誤分類を生じているのに対して、提案手法は正しく分類が行われている。処理に要する時間は、提案手法は正方視野の大きさに、従来手法は1画素あたりの階調数(同時生起行列の大きさ)にそれぞれ比例して増大するため単純には比較できないが、今回用いた128×128, 8bitを例にとると、提案手法は従来手法より約70倍高速であった。

4. 遺伝的アルゴリズムに基づくトレーニングエリア自動選定

提案したテクスチャ定量化手法を、教師つきテクスチャ分類に適用する際には、どのように適切なカテゴリを設定し、画像中のどこに各カテゴリのトレーニングエリアを設定し、正方視野の大きさをどのくらいにするかといった点が重要となる。従来は、実際に分類を試みた後に結果を評価して、必要に応じてこれらのパラメータを設定し直すという試行錯誤が主であった。しかしながら、提案したテクスチャ定量化手法は、性能はよいがある程度の処理時間が必要なため、こうした試行錯誤をできるだけ回避したい。そこで、探索空間の全域探索をせずに準最適解を得られる遺伝的アルゴリズム(GA)を用いて、適切なトレーニングエリアの場所と正方視野の大きさを決定する手法GATS(GA-based Training area Selection)法を開発した。GAは、環境に対する適応度の高い個体ほどその形質が後の世代に受け継がれるように、増殖と淘汰を繰り返して進化していく生物の進化過程を模倣した最適値探索アルゴリズムで、1960年代にHolland⁶⁾によって提唱され、後にGoldberg⁷⁾らによって様々な応用が模索された。

GATS法は、以下の手順からなっている。

- 1) カテゴリ数と種類を決定する。
- 2) 各カテゴリ毎にトレーニングエリア探索領域を指定する。
- 3) 初期染色体群を生成する。なお、これらの染色体の個々の遺伝子座には、トレーニングエリアの中心座標につけたインデックスとサイズが入る。
- 4) 適応度を算出する。なお、適応度には、次章で定義するトレーニングエリアの適切さの尺度を採用する。
- 5) 次世代に残す染色体を選択し、適応度の最も低い染色体を淘汰する(選択・淘汰)。ここでは染色体の選択にエリート保存戦略を採用した。
- 6) 染色体群から2つの染色体を選び、それらを親として次世代の子を生成する(交叉)。なお、親の選択にはルーレット(モンテカルロ)戦略を、また交叉方法として、一様多点交叉を採用した。
- 7) ある確率で1つの染色体の組成を変化させる(突然変異)。なお、ここでの突然変異率は0.1とした。
- 8) 4) から7) までの手順を、適応度が収束する(準最適な染色体で上位が独占される)まで繰り返す。

こうして得られた最終的な(進化を遂げた)染色体群のうち、最も適応度の高い染色体が、教師つきテクスチャ分類に適したトレーニングエリアの場所と正方視野の大きさを示している。

5. トレーニングエリアの適切さの尺度

GATS法で用いる適応度として、以下のように「トレーニングエリアの適切さの尺度」を定義する。教師つきテクスチャ分類に用いるトレーニングエリアに求められることは、正方視野内に複数カテゴリが混在した場合でもできるだけ誤分類を起こしにくい参照(教師)データを提供すること、すなわち、テクスチャ混在時の分類信頼性(Classification Reliability in Mixed Texture Cases: CRMTC)が高いことである。そこで、Fig.3(a)に示すような混在モデルを考える。正方視野内にはテクスチャAとテクスチャBの2種類しか存在しないと仮定する。Fig.3(a)に示すように、正方視野内にテクスチャAのみが含まれている状態(C1)から、2種類のテクスチャの混在状態(C2)を経て、テクスチャBのみが含まれている状態(C3)に至る場合を考える。状態C1, C3で得られる正規化Zernikeモーメントベクトルを、それぞれ a , b とすると、C1からC3への遷移中の状態C2で得られるNZMV c には、正方視野内におけるテクスチャAとテクスチャBの面積占有率に応じて a , b が寄与していると考えられる。そこで、テクスチャBの面積占有率を α とおくと、 c は次式のように定義できる。

$$c = \frac{W(1-\alpha)a + W(\alpha)b}{|W(1-\alpha)a + W(\alpha)b|} \quad (4)$$

ここで、 $\beta = W(\alpha)$ は、テクスチャ定量化の際に用いる窓関数によって決まる重み関数で、窓関数に Hamming 関数を用いた場合の $1 - \beta$ と β との比は、Fig.3(b) の左右の体積比となる。このモデルを用いて、CRMTC を次のような手順で算出する。

- 1) 最初に設定した m 種類の分類カテゴリのうち 2 種類を選択する。
- 2) この 2 種類の分類カテゴリに対応するトレーニングエリアから得られる正規化 Zernike モーメントベクトル a , b を算出し、式 (4) を用いて様々な面積占有率 α に対応する合成ベクトル c を求める。なお、面積占有率は、対象トレーニングエリアの大きさに対応して変化するものとする。
- 3) 合成ベクトル c と、各カテゴリに対応するトレーニングエリアから得られる正規化 Zernike モーメントベクトルとの偏角を求めると、【Case1】1) で着目した a か b かのどちらかが必ず最小偏角を呈する場合と【Case2】そうではない場合 (Fig.4) がある。Case1 では、最小偏角を呈する方のベクトルと、それ以外のベクトルとの偏角差の積分 ε_1 を、Case2 では、正常な分類が行われる混在比での最小偏角を呈する方のベクトルと、それ以外のベクトルとの偏角差の積分 ε_2 と、誤分類を起こす可能性のある混在比での本来は最小偏角を呈するべきベクトルと、実際に最小偏角を呈しているベクトルとの偏角差の積分 ε_3 を求め、次式によって CRMTC を定義する。

$$CRMTC = \frac{\sum_{i,j,k}^q \varepsilon_{1ijk} \cdot \sum_{i,j,k}^{p-q} \varepsilon_{2ijk}}{1 + \sum_{i,j,k}^{p-q} \varepsilon_{3ijk}} \quad (5)$$

ここで、 i, j は着目している 2 カテゴリ、 k はそれ以外のカテゴリを示す。 q は Case1 の数、 q は i, j, k の組み合わせの数 $((m-2)_m C_2)$ である。

また、正規化 Zernike モーメントベクトルには、正方視野の大きさが小さい場合、同じテクスチャ内であっても、得られるベクトルが不安定になるという性質がある。そこで、Fig.5 に示すように、現在着目している染色体が示す各カテゴリのトレーニングエリアから得られる正規化 Zernike モーメントベクトルを基準として、それより 1 まわり小さなトレーニングエリアから得られる正規化 Zernike モーメントベクトルとの偏角差 ($S1$) と 1 まわり大きなトレーニングエリアから得られる正規化 Zernike モーメントベクトルとの偏角差 ($S2$) を用いて、正方視野の大きさに関する正規化 Zernike モーメントベクトルの安定性 (Stability of NZMV in FOV Mask Size: SNFMS) を次式のように定義する。

$$SNFMS = \prod_i^m \{1 - (S1_i + S2_i)\} \quad (6)$$

以上のことから、トレーニングエリアの適切さの尺度、すなわち GATS 法における適応度値は、次式のように定義する。

$$fitness = CRMTC \times SNFMS \quad (7)$$

6. 数値実験

GATS 法の有効性を検証するために、テスト画像と実際の航空機搭載センサ画像を用いて、GATS 法によりトレーニングエリアの自動選定を行い、選定されたトレーニングエリアを用いて教師つきテクスチャ分類を試みた。実験に用いるテスト画像は、前述の Brodatz の写真集から選んだ「煉瓦の壁」、「爬虫類の皮膚」、「矢はず状の刺繍」の 3 つの写真と、「煉瓦の壁」を 30 度回転させた画像の合計 4 種類を組み合わせで作成した。Fig.6 に処理結果を示す。Fig.6(a) は、原画像と初期段階でのトレーニングエリアの例とを重ねたものを、(b) は、そのトレーニングエリアを用いた場合の教師つきテクスチャ分類結果を、(c) は、原画像と収束後のトレーニングエリアとを重ねたものを、(d) は、そのトレーニングエリアを用いた場合の教師つきテクスチャ分類結果をそれぞれ示している。これらの結果を見ると、GATS 法で選定されたトレーニングエリアを用いると、精度よくテクスチャ分類を行うことができることがわかる。なお、適応度値は、(a) では約 2.3、(c) では約 66 であった。

次に、実際の航空機搭載センサ画像を用いた結果を示す。用いた画像は、愛知県渥美郡渥美町福江地区のもので、飛行高度は1450フィート、観測波長帯は近赤外域、画像の大きさは256×256である。ここでは、分類カテゴリとして、水田、ビニールハウス、人工建造物の3種類を選択した。他に道路などがあるが、非常に細い対象物なので、独立テクスチャとしては不的確と判断した。Fig.7(a)に原画像を、(b)～(d)に設定したカテゴリ、及びそれらの探索領域をそれぞれ示す。また、Fig.8に処理結果を示す。Fig.8 (a)～(d)の各図が示す意味は、Fig.6と同じである。これらの結果からも、GATS法で得られたトレーニングエリアが適切であることが明らかである。なお、適応度値は、(a)では約10.7、(c)では約101.8であった。

7. まとめ

本稿では、前回提案した画像のテクスチャを空間周波数の振幅成分分布から得られる正規化 Zernike モーメントベクトルを用いて定量化する手法と、従来手法のひとつである Haralick の特徴量ベクトルに基づく手法とのテクスチャ識別能力比較実験の結果を示すとともに、教師つきテクスチャ分類を行う上で重要な、適切なトレーニングエリアの場所と大きさを決定するための遺伝的アルゴリズムに基づく新しい手法 GATS 法を提案し、数値実験により、その有効性を確認した。今後の課題は、より適切な適応度関数の検討と、教師なしテクスチャ分類への拡張である。

なお、本研究は千葉大学環境リモートセンシング研究センター共同利用研究(11-49)により行われたものである。

参考文献

- 1) R.M.Haralick, K.Shanmugam and Its'hak Dinstein: "Textural Features for Image Classification", IEEE Trans. SMC, 3, No.6, pp.610-621, 1973
- 2) F.Zernike: "Beugungstheorie des Schneidenver-Fahrens und Seiner Verbesserten Form: Der Phasenkontrast-methode", Physica, 1, pp.689-704, 1934
- 3) A.B.Bhatia and E.Wolf: "On The Circle Polynomials of Zernike and Related Orthogonal Sets", Proc. Camb. Phil. Soc., 50, pp.40-48, 1954
- 4) M.Born and E.Wolf: "Principles of Optics 5th Ed., Chapter 9", Pergamon Press, 1975
- 5) C.H.Teh and R.T.Chin: "On Image Analysis by the Methods of Moments", IEEE Trans. PAMI, 10, 4, pp.496-513, 1988
- 6) J.H.Holland: "Adaptation in Natural and Artificial Systems", MIT Press, 1992 (First Ed.: Univ. Michigan, 1975)
- 7) D.E.Goldberg: "Genetic Algorithms in Search, Optimization and Machine Learning", Addison Wesley, 1989
- 8) P.Brodatz: Textures : A Photographic Album for Artists and Designers, DoverPubl. Inc., 1966




Fig.1 Sample images from Brodatz's album.




Fig.2 Evaluation result by the proposed method(a), the conventional method 1(b) and 2(c).




Fig.3 Mixed texture model(a) and the weighting function based on Hanning window function(b).




Fig.4 Typical mixed texture cases for calculation of the classification reliability.




Fig.5 Schematic diagram for calculation of the stability of the normalized Zernike moment vector in field of view mask size.




Fig.6 Processing results for test image, example of selected training areas before convergence(a), classification result with the training areas(a)(b), selected training areas after convergence(a), and classification result with the training areas(c)(d).




Fig.7 Actual airborne MSS image for processing(a), selected 3 classification categories, and the candidates of the center of training areas for each category.




Fig.8 Processing results for actual airborne MSS image, example of selected training areas before convergence(a), classification result with the training areas(a)(b), selected training areas after convergence(c), and classification result with the training areas(c)(d).