

フラクタル次元と低次統計量とを用いたテクスチャの自動分類†

吉 沢 達 也^{††*} 曾 根 光 男^{†††} 高 木 幹 雄^{††††}

衛星写真や航空写真による地形や森林の解析では、画像をブロックに直和分割して、ブロックをテクスチャ分類している。この分類においては同時生起行列などから導出される統計的特徴量がよく用いられているが、どのくらいの大きさのブロックを用いればよいか、また、どの特徴量を用いればよいかは画像に依存している。また最近、フラクタル次元を用いた分類が Pentland によって提案されているが、どのくらいの大きさのブロックを用いればよいかは画像に依存し、分類する際の閾値の決定は人手によって行われている。そこで、本文では、テクスチャ分類の分野で広く用いられている Brodatz の写真集から選んだ任意の2つのテクスチャを組み合わせた画像1,065枚を対象とし、フラクタル次元と低次統計量とを有機的に結合させ、階層的にテクスチャを自動分類する方法を提案する。本手法は、柔軟性を持たせるために画像のブロックの大きさが異なるものを複数用いて階層的に行うものであり、ISODATA クラスタリングを用いたフラクタル次元と最小被覆値とによる分類を基本にする。フラクタル次元と最小被覆値とで分類できなかったブロックは、フラクタル次元と最小被覆値とで分類できた複数のブロックの低次統計量（知識源）から算出される知識を用いて分類される。本手法と従来の統計的特徴量を用いる手法とを認識率および演算時間で比較して、本手法の有効性を示す。

1. ま え が き

領域の持つ重要な特徴の1つにテクスチャがある。人間は、テクスチャの違いにより画像における領域を区別することができる。衛星写真や航空写真による地形や森林の解析では、画像をブロックに直和分割して、ブロックをテクスチャ分類している^{1)~4)}。

従来、テクスチャの分類では、テクスチャの統計的特徴量として、同時生起行列¹⁾から導出される角2次モーメントや相関など、また、差分統計量²⁾から導出されるコントラストやエントロピーなどが用いられている。Weszka ら³⁾や、Connors ら⁵⁾はテクスチャの統計的特徴量の性能評価を行い、同時生起行列を用いた手法が、最も解析能力が高いことを述べている。しかし、どの特徴量を用いればよいかは画像に依存している。

一方、自然界の対象物を数学的に記述することができるフラクタル^{6),7)}が最近、画像解析^{4),8)~15)}にも用いられてきている。筆者らが知る限り、フラクタル次元によるテクスチャの分類を最初に提案した人は Pentland⁴⁾である。しかし、Pentland の方法では閾

値の決定は人手によって行われている。しかも、文献8)では、フラクタル次元だけで解析するのは困難であると報告している。

そこで、本文では、フラクタル次元を画像濃度曲面の起伏の複雑さを表す特徴量とし、フラクタル次元と低次統計量とを有機的に結合させ、階層的にテクスチャを自動分類する方法を提案する。なお、本文ではフラクタル次元を筆者ら⁹⁾が先に提案した方法で算出する。また、同時生起行列、差分統計量、ランレングス行列から導出される特徴量を用いた手法と本手法とを比較検討し、本手法の有効性を示す。

2. フラクタル次元と低次統計量

2.1 フラクタル次元

フラクタルは数学的に統一された定義はないが、狭い意味で無限の繰返しパターンを持つ自己相似な形状、現象である。自然界の諸形状、諸現象は厳密に自己相似ではないが、統計的に自己相似と考えられるものが多く⁶⁾、その複雑さを表す非整数次元がフラクタル次元である。ここでは、画像濃度曲面の起伏の複雑さを表すフラクタル次元を、筆者ら⁹⁾が先に提案した粗視化の度合いを考える方法で計算する。

画像濃度曲面を1辺の画素間隔が r 画素の立方体で被覆するときに必要な個数を $N(r)$ とすると、スケール r に依らず、

$$N(r) \cdot r^D = C \quad (1)$$

ただし、 C は定数

† Automatic Classification for Texture Using Fractal Dimension and Lower Order Statistics by TATSUYA YOSHIZAWA (Tokyo University of Agriculture and Technology), MITSUO SONE (Fujitsu Limited) and MIKIO TAKAGI (Institute of Industrial Science, University of Tokyo).

†† 東京農工大学

††† 富士通(株)

†††† 東京大学生産技術研究所

* 現在 東京工業大学総合理工学研究科




図 1 単位領域の画像濃度曲面を被覆する立方体

Fig. 1 Image intensity surface covered with cubes.

となるとき、 D をフラクタル次元と呼ぶ。したがって、式(1)は、

$$\log N(r) = -D \log r + \log C \quad (2)$$

となり、 $\log r$ と $\log N(r)$ は直線関係になる。そして、その傾きの大きさがフラクタル次元となる。

フラクタル次元 (式(2)の D) を実際に計算する方法を以下に述べる。

まず、画素間隔が $r \times r$ 画素の領域を単位領域として考える。図1のように単位領域の画像濃度曲面を被覆する1辺の画素間隔が r の立方体の個数 $n(r)$ を

$$n(r) = \text{floor} \left[\frac{\max_{1 \leq i \leq 4} \{I_i\} - \min_{1 \leq i \leq 4} \{I_i\}}{r} \right] + 1 \quad (3)$$

ただし、floor は整数化 (切り捨て)

とする。次に、フラクタル次元を求める領域 (図1の面積 S) 内のすべての単位領域で $n(r)$ を求め、その平均値が $\bar{n}(r)$ であるとき、 $N(r)$ を

$$N(r) = \bar{n}(r) \cdot (S/r^2) \quad (4)$$

とする。最後に、各スケール r における $N(r)$ の値を求め、式(2)より、 $\log r$ と $\log N(r)$ とをプロットし、回帰直線を最小2乗法により計算し、その傾きの大きさをフラクタル次元とする。

式(2)より、直線の傾きと Y 軸切片を求めることができる。 Y 軸切片の値である $\log N(1)$ の $N(1)$ を最小画素間隔における被覆値と呼ぶことにする。以後略して、最小被覆値と呼び、詳細については3.1節で述べる。

2.2 フラクタル次元を導出する際の直線度の検討

フラクタル次元を計算するとき注意しておかなければいけないことは、プロットされたデータ点列が直線上に並んでいるかどうかである。そこで文献16)で提

案されている直線度 (式(5)) を用いて検討する。

$$I = \{4 \mu_{11}^2 + (\mu_{20} - \mu_{02})^2\}^{1/2} / (\mu_{20} + \mu_{02}) \quad (5)$$

ただし、 μ_{ij} は平面上のデータ点列の2次の中心モーメントである。 I は $0 \leq I \leq 1$ の値をとる。データ点列が完全に直線上に並ぶときには $I=1$ となり、またデータ点列が無相関、等方的にランダムに分布するときには $I=0$ となる。実際の検討は、4章で述べる。

2.3 自動分類する際の知識源となる低次統計量

3章で述べる分類法は、柔軟性を持たせるために画像のブロックの大きさが異なるものを複数用いて階層的に行うものである。そこでは、複数の単一ブロックに関する処理は完全に独立して行われるので、最終的には処理結果の整合性を保つ必要性が生じてくる。このような階層処理は、フラクタル次元と最小被覆値とを用いる分類を基本としているが、フラクタル次元と最小被覆値だけでは分類できなかったブロックは、フラクタル次元と最小被覆値とにより分類された複数のブロックの低次統計量を知識源とし、特徴空間上における知識源の中心を用いて分類する。本文では、低次統計量として、平均値と分散とを使用し、知識源の中心を知識と呼ぶことにする。この知識を用いた分類は3.1節で述べる。このように、フラクタル次元と低次統計量 (知識源) とを有機的に用いることにより、分類された結果は排反になっている。排反性については、3.3節で述べる。

3. テクスチャの自動分類法

3.1 自動分類法の概要

テクスチャの種類が1つの画像 f (256×256 画素) とテクスチャの種類が1つの画像 g (256×256 画素) とを Brodatz の写真集¹⁷⁾の中から任意に選んで組み合わせ、512×256 画素の画像とする。以後、これを入力画像と呼ぶことにする。本文で提案される分類法は、柔軟性を持たせるために画像のブロックの大きさが異なるものを複数用いて階層的に行うものである。ここでは、その数を3として、図2に自動分類のフローチャートを示す。以下、それについて図2中の①、②、③の順で概要を述べる。

① 図2のように、入力画像をブロックに直和分割する。大きさの異なる3種類 (64×64 画素, 32×32 画素, 16×16 画素) のブロックを、それぞれ A_i , B_{4i-j} , $C_{4(4i-j)-k}$, ($i=1, 2, \dots, 32$, $j=0, 1, 2, 3$, $k=0, 1, 2, 3$) とし、以下に述べる処理を、それぞれ独立に行う。

まず、直和分割されたすべてのブロックのフラクタル次元と最小被覆値とを求める。ただし、スケール r は、ブロックの大きさが 64×64 画素のときは $1 \leq r \leq 32$ 、ブロックの大きさが 32×32 画素のときは $1 \leq r \leq$

16、ブロックの大きさが 16×16 画素のときは $1 \leq r \leq 8$ である。これらの特徴量を用いて特徴空間上でISODATAクラスタリング¹⁸⁾(反復演算を基本とする教師なしクラスタリングで、詳細なことは3.2節を参




図2 テクスチャの自動分類のフローチャート (異なるブロックの数が3の場合)

Fig. 2 Flow chart of automatic texture classification.




図3 最小被覆値が異なりフラクタル次元が同じである例

Fig. 3 An example with the same fractal dimension but different $N(1)$.





図4 各大きさのブロックにおける1, 0パターンの例
Fig. 4 An example of 1's or 0's pattern at each block.

照)を行う。ただし、特徴空間の第1軸にはフラクタル次元をとり、第2軸には最小被覆値をとる。第2軸を最小被覆値とした理由は、図3のような T_1 と T_2 とは異なる対象物であると判断したいからである。また、ISODATA クラスタリングでは、特徴空間上での各パターンの位置とクラスタの中心とのユークリッド距離を計算するため、本文では前処理として、特徴軸の正規化（すなわち、各特徴軸の平均値の周りの分散を等しくすること）を行っている。次に、ISODATA クラスタリングにより各ブロックを1か0に分類し、ブロック A_i , B_{4i-j} , $C_{4(4i-j)-k}$ の1, 0パターンを、それぞれ a_i , b_{4i-j} , $c_{4(4i-j)-k}$ と記述する。

② ①で、独立に行われた処理結果の整合性を保つために、以下のような階層処理を行う。

図4に示すブロック A_i の1, 0パターン a_i と、ブロック B_{4i-j} の1, 0パターン b_{4i-3} とが共に1または0であるかを調べる。同様に、 b_{4i-2} , b_{4i-1} , b_{4i} についても調べる。 a_i , b_{4i-j} が、共に1または0である場合を分類可能なブロック、一致していない場合を未分類ブロックと呼ぶことにする。例えば、図4は、 a_i



ただし、○は共に0であるブロックの低次統計量の分布
●は共に1であるブロックの低次統計量の分布

図5 知識を用いた分類

Fig. 5 Knowledge-based classification.

と b_{4i-3} , a_i と b_{4i} が共に1の場合であり、 a_i と b_{4i-2} , a_i と b_{4i-1} が一致していない場合である。次に、分類可能なブロック B_{4i-j} で、未分類ブロックを分類するための知識源Iとなる低次統計量、すなわち、平均値および分散を求める。そして、 a_i , b_{4i-j} が、共に1である時のブロック B_{4i-j} の低次統計量の中心と、共に0である時のブロック B_{4i-j} の低次統計量の中心とを特徴空間上で求める。これを知識Iと呼ぶ。この知識Iと未分類ブロックの低次統計量とのユークリッド距離を、それぞれ求め、ユークリッド距離の短い方に未分類ブロックを分類する。このような分類、すなわち、知識を用いた分類を図5に示す。図5中の●, ○は、それぞれ、共に1である時のブロックの低次統計量、共に0である時のブロックの低次統計量である。△は●の中心、△は○の中心である。図5では、×と△とのユークリッド距離の方が、×と△とのユークリッド距離より長いので、×は0に分類される。なお、このような知識を用いた分類でも、前処理として、特徴軸の正規化を行っている。

③ ②と同様な理由で、以下のような階層処理を行う。

図4に示すブロック B_{4i-j} の1, 0パターン b_{4i-j} と、ブロック $C_{4(4i-j)-k}$ の1, 0パターン $c_{4(4i-j)-k}$ とが共に1または0であるかを調べる。 b_{4i-j} と $c_{4(4i-j)-k}$ とが一致していれば、ブロック $C_{4(4i-j)-k}$ は分類されたとみなす。そして、そのブロック $C_{4(4i-j)-k}$ の低次統計量（知識源II）を算出する。 b_{4i-j} と $c_{4(4i-j)-k}$ とが、共に1である時のブロック $C_{4(4i-j)-k}$ の低次統計量の中心と、共に0である時のブロック $C_{4(4i-j)-k}$ の低次統計量の中心とを特徴空間上で求める。これを知識

識Ⅱと呼ぶ。 b_{4i-j} と $c_{4(i-j)-k}$ とが一致していない場合には、未分類ブロック $C_{4(i-j)-k}$ の低次統計量と知識Ⅱとのユークリッド距離を、それぞれ求め、ユークリッド距離の短い方に未分類ブロック $C_{4(i-j)-k}$ を分類する。

以上、自動分類法の概要を述べた。なお、先記の②、③の知識は、解析中に自動的に獲得される動的な情報であり、解析前の学習によりあらかじめ与えられるものではない。この意味で知識を用いた分類は、教師付き分類とは異なる手法である。

3.2 自動分類する際の閾値の決定法

図3を考慮して、本手法では、フラクタル次元と最小被覆値との特徴空間上で、ISODATA クラスタリング¹⁸⁾を用いることにより、分類する際の閾値を自動決定している。ISODATA クラスタリングの概要を以下に述べる。

- 1) N 個のクラスタ (図6では $N=3$) の中心位置の初期値 (図6(a)中の+) を与える。
- 2) すべてのパターン (図6(a)中の●) が、どの中心位置に最も近いかを調べる。各パターンは最も近い中心位置のクラスタに属するとし、パターンの集合を N 個のクラスタに分割する。なお、図6(a)、(b)、(c)中の直線がクラスタの境界線である。
- 3) 各クラスタに属するパターンの平均値を、それぞれ求める (図6中の○)。
- 4) 中心位置と平均値とを比較する。図6(c)のように、それらがすべて一致すれば処理を停止する。しかし、図6(b)のように、一致しなければ平均値を新たな中心位置として、2)、3)の処理を反復する。




図6 ISODATA クラスタリング¹⁸⁾
Fig. 6 ISODATA clustering.

以上述べた ISODATA クラスタリングは、クラスタの中心位置の初期値は任意に与えればよく、その値によって最終結果が大きく変わることはない¹⁸⁾。

3.1 節では、入力画像は2種類のテクスチャが存在するので、 $N=2$ として、ISODATA クラスタリングを行っている。

3.3 分類結果の排反性

画像からあるテクスチャ領域を抽出することを目的とする場合には、それ以外の領域に関して必ずしも排反性が保証されている必要はない¹⁵⁾。しかし、本文のように隣接する領域のテクスチャの分類を目的とする場合には、文献15)、19)、20)のように、複数の異なる大きさのブロック間で、単に論理積演算を行ったのでは、結果が排反にならないことがある。例えば、図4の a_i と b_{4i-3} と $c_{4(i-3)-2}$ との論理積演算の結果は0である。一方、図4の1、0パターンを反転させて、先記の論理積演算を行っても結果は同じで0になる。したがって、両者ともブロック $C_{4(i-3)-2}$ は、必ず0と判定されてしまう。この矛盾を解消するのに、知識を用いた分類が有効に機能している。すなわち、3.1 節で示したように、知識を用いた分類は、ユークリッド距離を比較しているので、図4の1、0パターンが反転しても分類された結果は、排反になっていることがわかる。

4. 本手法の実験結果

実験では、Brodatz の写真集¹⁷⁾にあるテクスチャ画像 (256×256 画素に標本化、64 濃度レベルに量子化) を112枚使用した。これらの一部を、図7に示す。なお、テクスチャ画像作成時に生じた雑音は、前処理として、ウィンドウサイズ 3×3 のメディアンフィルタ²¹⁾を用いて軽減されている。前処理は、図2の入力画像を作成する前に、各テクスチャ画像 (256×256 画素) に対して行われる。これは、定型処理ではないので図2には記入しなかった。実験では任意の2つのテクスチャ画像を組み合わせた入力画像 (512×256 画素) を1,065枚作成した。1,065枚の内訳は、Brodatz の写真集の D1 と D2, D3, ..., D112 とを組み合わせた111枚、D2 と D3, D4, ..., D112 とを組み合わせた110枚、D3 と D4, D5, ..., D112 とを組み合わせた109枚、D4 と D5, D6, ..., D112 とを組み合わせた108枚、D5 と D6, D7, ..., D112 とを組み合わせた107枚、D6 と D7, D8, ..., D112 とを組み合わせた106枚、D7 と D8, D9, ..., D112 とを組み合わせた


図 7 テクスチャ画像の例¹⁷⁾

Fig. 7 Texture samples.

表 1 本手法の認識率と演算時間


Table 1 Classification ratio and CPU time by proposed method.

	異なる ブロックの 数	ブロックの大 きさ (画素)	認識率の 平均値 (%)	認識率の 標準偏差	演算時間 の平均 (秒)
ケース 1	1	16×16	80.9	14.6	8.7
ケース 2	1	32×32	85.0	14.9	17.3
ケース 3	1	64×64	88.3	14.2	34.9
ケース 4	2	16×16, 32×32	85.9	14.7	27.2
ケース 5	2	32×32, 64×64	89.6	13.5	52.9
ケース 6	2	16×16, 64×64	87.3	13.6	45.1
ケース 7	3	16×16, 32×32, 64×64	80.6	14.3	62.3


た 105 枚, D8 と D9, D10, ..., D112 とを組み合わせ
た 104 枚, D9 と D10, D11, ..., D112 とを組み合わ
せた 103 枚, D10 と D11, D12, ..., D112 とを組み合
わせた 102 枚である。

表 1 に, 1,065 枚の入力画像に対して, 本手法を用
いた時の認識率の平均値と標準偏差, 演算時間の平均
値を示す。ここで, 認識率は次のようにして算出され
ている。入力画像中に 2 つのテクスチャが存在するの

で, それぞれのテクスチャ画像において, 正しく分類
されたブロック数を分類すべきブロック数で割った値
を求め, それらの相加平均を求める。この相加平均を
認識率とする。例えば, すべてのブロックを同一のテ
クスチャであると判定すると, 半数のブロックはすべ
て正しいので 100%, 残りの半数のブロックはすべて
正しくないで 0% となるので, 相加平均は 50% と
なる。以上のことより, 認識率の値は 50% から 100
% をとることになる。また, 本手法はすべて FOR-
TRAN 77 で記述され, FACOM M-170F を用いて
行われている。表 1 中の演算時間には, 画像の入出力
時間は含まれていない。表 1 中のケース 1 から 3 は,
図 2 中の①のみが行われる場合に相当する。これは知
識を用いた分類を行っていない。表 1 中のケース 4 か
ら 6 は, 図 2 中の①, ②が行われる場合に相当する。
表 1 中のケース 7 は, 図 2 中の①, ②, ③が行われる場
合に相当する。表 1 より, 認識率は 1 種類のブロック
(表 1 中のケース 1 から 3) で分類するより 2 種類の
ブロック (表 1 中のケース 4 から 6) を用いて分類し
た方が高いことがわかる。ところが, 3 種類のブロッ
ク (表 1 中のケース 7) を用いた場合には, 1 種類の
ブロックを用いた場合と比べて, 認識率の向上はほと




(a) 入力画像




(b) 分類結果

図 8 入力画像と分類結果

Fig. 8 Input image and classification result.



(a) 入力画像



(b) 分類結果

図 9 入力画像と分類結果

Fig. 9 Input image and classification result.

んどみられなかった。これは、本手法では、図 2 中の知識源 I に誤差が混入されると、この誤差が知識源 II に伝搬して、特徴空間上でのクラスタリングを正しく行うことができないからであると思われる。いかにして知識源 I の精度をあげるかが今後の課題である。

図 8, 9, 10 に、入力画像と表 1 中のケース 7 を用いて分類した結果を示す。図 8, 9 は認識率が高い場合であり、図 10 は認識率が低い場合である。図 10 では、2 種類のテクスチャの特徴量が、非常に類似していたため、特徴空間上でのクラスタリングを正しく行うことができなかった。例えば、図 8 の 2 つのテクスチャ領域のフラクタル次元の平均値の差は 0.49 (表 1 中のケース 1 の場合) であるのに対し、図 10 の場合には 0.05 (表 1 中のケース 1 の場合) であった。


表 2 は、2.2 節で述べた直線度を 112 枚のテクスチャ画像に対して算出した結果である。ここでは、1 枚のテクスチャ画像 (256×256 画素) に対し、ブロックの大きさが 16×16 画素であれば 256 個のブロックについて直線度を求め、その平均値を、ブロックの大きさが 16×16 画素のときの直線度と呼んでいる。同様に、ブロックの大きさが 32×32 画素であれば 64 個の平均値を、ブロックの大きさが 64×64 画素であれば 16 個の平均値を、それぞれ、ブロックの大きさが 32×32 画素のときの直線度、ブロックの大きさが 64×64 画素のときの直線度と呼んでいる。表 2 より、ブロックの大きさに関係なく 112 枚のテクスチャ画像における直線度の平均値は 0.999 以上であり、直線性が保存されていると考えられる。表 2 中の最大値、最小値は、112 枚のテクスチャ画像の直線度のうち、最大、最小であった直線度である。

5. 従来の統計的特徴量を用いる手法との比較

3 章では、フラクタル次元と低次統計量を用いた自動分類法について述べた。ここでは、本手法と従来の統計的特徴量を用いる手法とを認識率、演算時間により比較する。従来の統計的特徴量を用いる手法では、ブロックの大きさは単一 (16×16 画素, 32×32 画素, 64×64 画素) とし、2 つの特徴量を用いて ISODATA クラスタリングを行うことにより、入力画像 (512×256 画素) 中の

表 2 直線度
Table 2 Linearity value of regression line.


	平均値	最大値	最小値	標準偏差 ($\times 10^{-4}$)
ブロックの大きさが 16×16 画素の時の直線度	0.9992	0.9995	0.9986	5.90
ブロックの大きさが 32×32 画素の時の直線度	0.9994	0.9999	0.9984	3.87
ブロックの大きさが 64×64 画素の時の直線度	0.9995	0.9999	0.9975	3.97



D1

D5

(a) 入力画像



(b) 分類結果

図 10 入力画像と分類結果

Fig. 10 Input image and classification result.

各ブロックを分類する。

5.1 同時生起行列

同時生起行列の要素は、濃度 i の点からある一定の変位 $\delta = (d, \theta)$ だけ離れた点の濃度が j である確率 $P_\delta(i, j)$, ($i, j = 0, 1, \dots, n-1$) により定義される。ただし、 d は変位、 θ は方向である。Haralick ら¹⁾は、この同時生起行列からテクスチャを特徴づける 14 種類の特徴量を導出している。これらの特徴量のうち、本文では、よく用いられる次の 3 つの特徴量を使用する。

(i) 角 2 次モーメント

$$f1 = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} \{P_\delta(i, j)\}^2 \quad (6)$$

(ii) 相関

$$f2 = \left\{ \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} ij P_\delta(i, j) - \mu_x \mu_y \right\} / (\sigma_x \sigma_y) \quad (7)$$

$$\text{ただし, } \mu_x = \sum_{i=0}^{n-1} i \sum_{j=0}^{n-1} P_\delta(i, j),$$

$$\mu_y = \sum_{j=0}^{n-1} j \sum_{i=0}^{n-1} P_\delta(i, j)$$

$$\sigma_x^2 = \sum_{i=0}^{n-1} (i - \mu_x)^2 \sum_{j=0}^{n-1} P_\delta(i, j)$$

$$\sigma_y^2 = \sum_{j=0}^{n-1} (j - \mu_y)^2 \sum_{i=0}^{n-1} P_\delta(i, j)$$

(ii) コントラスト

$$f3 = \sum_{k=0}^{n-1} k^2 \left\{ \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} P_\delta(i, j) \right\}_{|i-j|=k} \quad (8)$$

式(6)~(8)は、それぞれ、画素対の相対的位置関係 (d, θ) の関数である。ここでは、文献 9) のようにテクスチャの方向性を考慮しないで、変位 $d=1, 2, 4, 8$ (画素) に対して、 $\theta=0^\circ, 45^\circ, 90^\circ, 135^\circ$ の 4 方向の平均値を d に対する特徴量としている。したがって、変位 d のときの角 2 次モーメント $ASM(d)$ を式(6)の $f1$ を用いて、

$$ASM(d) = \{f1(d, 0^\circ) + f1(d, 45^\circ) + f1(d, 90^\circ) + f1(d, 135^\circ)\} / 4 \quad (9)$$

とする。また、変位 d における相関、コントラストをそれぞれ、 $CONT(d)$, $CORR(d)$ で表す。

実験では、ISODATA クラスタリングに用いる 2 つの特徴量を、 $ASM(d)$, $CONT(d)$, $CORR(d)$, ($d=1, 2, 4, 8$) から任意に 2 つ選び、分類を行う。なお、2 つの特徴量の組合せは全部で 12 通りである。

5.2 差分統計量

画像内で、一定の変位 $\delta = (d, \theta)$ だけ離れた 2 点の濃度差が k である確率 $P_\delta(k)$, ($k=0, 1, \dots, n-1$) を求める。Weszka ら²⁾は、この確率からテクスチャを特徴づける 4 種類の特徴量を導出している。本文でも、これらを使用する。

(i) 角 2 次モーメント

$$f1 = \sum_{k=0}^{n-1} \{P_\delta(k)\}^2 \quad (10)$$

(ii) コントラスト

$$f2 = \sum_{k=0}^{n-1} k^2 P_s(k) \quad (11)$$

(iii) エントロピー

$$f3 = - \sum_{k=0}^{n-1} P_s(k) \log P_s(k) \quad (12)$$

(iv) 平均

$$f4 = \sum_{k=0}^{n-1} k P_s(k) \quad (13)$$

式(10)~(13)は (d, θ) の関数であるので, 5.1節の場合と同様に, 変位 $d=1, 2, 4, 8$ (画素)に対して $\theta=0^\circ, 45^\circ, 90^\circ, 135^\circ$ の4方向の平均値を d に対する特徴量としている. したがって, 変位 d における角2次モーメント $asm(d)$ を式(10)の $f1$ を用いて,

$$asm(d) = \{f1(d, 0^\circ) + f1(d, 45^\circ) + f1(d, 90^\circ) + f1(d, 135^\circ)\} / 4 \quad (14)$$

とする. また, d におけるコントラスト, エントロピー, 平均をそれぞれ, $cont(d)$, $ent(d)$, $mean(d)$ で表す.

実験では, ISODATA クラスタリングに用いる2つの特徴量を $asm(d)$, $cont(d)$, $ent(d)$, $mean(d)$, ($d=1, 2, 4, 8$)から任意に2つ選び, 分類を行う. なお, 2つの特徴量の組合せは全部で24通りである.

5.3 ランレンジ行列

ランレンジ行列の要素は, 画像内の特定の方向 θ に同じ濃度 i を持つ画素の列ランが長さ l である確率 $P_\theta(i, l)$, ($i=0, 1, 2, \dots, n-1$)により定義される. Galloway ら³⁾は, このランレンジ行列からテクスチャを特徴づける5種類の特徴量を導出している. 本文でも, これらを使用する.

(i) 短いランの強調

$$f1 = \sum_{i=0}^{n-1} \sum_{l=1}^L \frac{P_\theta(i, l)}{l^2} \bigg/ \sum_{i=0}^{n-1} \sum_{l=1}^L P_\theta(i, l) \quad (15)$$

(ii) 長いランの強調

$$f2 = \sum_{i=0}^{n-1} \sum_{l=1}^L l^2 P_\theta(i, l) \bigg/ \sum_{i=0}^{n-1} \sum_{l=1}^L P_\theta(i, l) \quad (16)$$

(iii) 濃度レベルの非一様性

$$f3 = \sum_{i=0}^{n-1} \left\{ \sum_{l=1}^L P_\theta(i, l) \right\}^2 \bigg/ \sum_{i=0}^{n-1} \sum_{l=1}^L P_\theta(i, l) \quad (17)$$

(iv) ラン長の非一様性

$$f4 = \sum_{i=1}^L \left\{ \sum_{i=0}^{n-1} P_\theta(i, j) \right\}^2 \bigg/ \sum_{i=0}^{n-1} \sum_{l=1}^L P_\theta(i, j) \quad (18)$$

(v) ランの割合

$$f5 = \sum_{i=0}^{n-1} \sum_{l=1}^L P_\theta(i, j) / A \quad (19)$$

ただし, A は画像の面積

式(15)~(19)は θ の関数であるので, 5.1節の場合と同様に, $\theta=0^\circ, 45^\circ, 90^\circ, 135^\circ$ の4方向の平均値を特徴量としている. したがって, 短いランの強調SREを式(15)の $f1$ を用いて,

$$SRE = \{f1(0^\circ) + f1(45^\circ) + f1(90^\circ) + f1(135^\circ)\} / 4 \quad (20)$$

表3 従来の特徴量とISODATA クラスタリングとを用いた時の認識率と演算時間

Table 3 Classification ratio and CPU time of analysis using conventional statistical features.

特徴量	ブロックの大きさ (画素)	認識率の 平均値 (%)	認識率の 標準偏差	演算時間 の平均 (秒)
ASM(1) + CONT(1)	16×16画素 32×32画素 64×64画素	79.4 85.1 87.5	14.0 14.7 14.4	60.9 20.5 9.2
ASM(2) + CONT(2)	16×16画素 32×32画素 64×64画素	78.2 83.5 87.0	13.9 15.2 14.8	60.5 19.5 9.1
ASM(4) + CONT(4)	16×16画素 32×32画素 64×64画素	76.1 82.3 85.5	13.8 14.9 15.3	60.1 19.2 9.0
ASM(8) + CONT(8)	16×16画素 32×32画素 64×64画素	75.1 81.3 84.5	14.6 14.9 15.4	58.4 18.3 8.6
ASM(8) + CORR(8)	16×16画素 32×32画素 64×64画素	70.2 77.7 80.3	17.8 16.8 16.3	101.6 29.2 11.4
SRE + GLN	16×16画素 32×32画素 64×64画素	70.7 72.0 70.7	11.4 13.7 17.9	23.6 17.9 15.5
SRE + RLN	16×16画素 32×32画素 64×64画素	74.5 74.9 72.0	11.9 14.4 18.5	22.8 17.5 14.9
SRE + RP	16×16画素 32×32画素 64×64画素	72.1 72.6 69.1	11.9 14.1 18.3	22.5 17.3 14.8
GLN + RLN	16×16画素 32×32画素 64×64画素	70.0 70.9 73.6	11.0 13.7 16.2	19.5 15.8 14.4
RLN + RP	16×16画素 32×32画素 64×64画素	72.1 72.1 74.2	11.6 13.4 16.1	18.9 15.6 14.1

ASM : 角2次モーメント (同時生起行列から導出)

CONT : コントラスト (同時生起行列から導出)

CORR : 相関

SRE : 短いランの強調

RLN : ラン長の非一様性

GLN : 濃度レベルの非一様性

RP : ランの割合

表 4 認識率と演算時間の評価
Table 4 Evaluation of classification ratio
and CPU time.

特徴量	本手法	同時生起 行列	差分統計量	ランレン グス行列
認識率	◎	○	×	△
演算時間	△	△	◎	○

ただし、この表の評価は 64 濃度レベルに量子化した場合。

表 5 濃度レベルが大きくなった時の演算時間の評価
Table 5 Evaluation of CPU time.

特徴量	本手法	同時生起行列
演算時間	○	×

とする。また、長いランの強調を LRE、濃度レベルの非一様性を GLN、ラン長の非一様性を RLN、ランの割合を RP で表す。

実験では、ISODATA クラスタリングに用いる 2 つの特徴量を SRE, LRE, GLN, RLN, RP から任意に 2 つ選び、分類を行う。なお、2 つの特徴量の組合せは全部で 10 通りである。

5.4 本手法との比較

5.1~5.3 節より、1 つのブロックの大きさについて、従来の特徴量と ISODATA クラスタリングとを用いる分類法は全部で 46 通りである。これらの方法を、1,065 枚の入力画像に対して用いた時、認識率の平均値が 70% 以上のものを表 3 に示す。

表 3 と表 1 中のケース 1 から 3 とを比較すると、表 3 中の 1 か所 (特徴量が ASM(1)+CONT(1) で、ブロックの大きさが 32×32 画素)を除いて、表 1 中のケース 1 から 3 の方が認識率が高い。2 種類のブロックを用いた表 1 中のケース 4 から 6 は、表 1 中のケース 1 から 3 の場合より、認識率が高い。表 1、表 3 より、認識率、演算時間を相対的基準で評価すると表 4 のようになる。表 4 の認識率は◎を基準にして、◎、○、△、×の順で低くなることを示している。同様の順で、表 4 の演算時間も長くかかることを示している。表 4 より、本手法による認識率が一番高く、次に高いのが同時生起行列から導出される特徴量を用いる手法であることがわかる。演算時間は、同時生起行列から導出される特徴量を用いる手法と同程度と考えられる。ところで、文献 11)、22) では、本実験で用いた Brodatz の写真集を、それぞれ、128 濃度レベルに量子化、256 濃度レベルに量子化している。濃度レベルが大きくなると、本手法と同時生起行列から導出さ

れる特徴量を用いる手法との演算時間の評価は表 5 のようになる。本手法の演算時間は量子化レベルに依存しないが、同時生起行列から導出される特徴量による手法は、行列のサイズが大きくなると演算時間が膨大にかかる。

6. む す び

本文では、テクスチャ分類の分野で広く用いられている Brodatz の写真集から選んだ任意の 2 つのテクスチャを組み合わせた画像 1,065 枚を対象とし、フラクタル次元と低次統計量とを有機的に結合させ、階層的にテクスチャを自動分類する手法を提案した。本手法は柔軟性を持たせるために、画像のブロックの大きさが異なるものを複数用いて階層的に行うものである。本手法の有効性を、認識率および演算時間で従来の統計的特徴量を用いる手法と比較して示した。

本手法で用いた ISODATA クラスタリングは N (≥ 2) 個のクラスに適用可能であるので、本手法は N 種類のテクスチャを分類する問題に容易に拡張することができる。

本手法のような階層処理は、従来の統計的特徴量を用いても行うことができるが、どの特徴量を選択すべきかは対象画像に依存するという問題が残る。

今後の課題として、認識率向上のために、4 章で述べたように、いかにして知識源の精度をあげるかがある。この課題は、本手法ではフラクタル次元が同じで、平均値が異なる 2 つの領域を分類することができないので、これをいかに解決するかでもある。

謝辞 本研究で用いたテクスチャ画像を御提供して頂いた電子技術総合研究所の坂上勝彦氏に感謝致します。

参 考 文 献

- 1) Haralick, R. M., Shanmugam, K. and Dinstein, I.: Texture Features for Image Classification, *IEEE Trans.*, Vol. SMC-3, No. 6, pp. 610-621 (1973).
- 2) Weszka, J. S., Dyer, C. R. and Rosenfeld, A.: A Comparative Study of Texture Measures for Terrain Classification, *IEEE Trans.*, Vol. SMC-6, No. 4, pp. 269-285 (1976).
- 3) Galloway, M. M.: Texture Analysis Using Gray Level Run Lengths, *CGIP*, Vol. 4, No. 2, pp. 172-179 (1975).
- 4) Pentland, A. P.: Fractal-Based Description of Natural Scenes, *IEEE Trans.*, Vol. PAMI-6, No. 6, pp. 661-674 (1984).

- 5) Connors, R. W. and Harlow, C. A.: A Theoretical Comparison of Texture Algorithms, *IEEE Trans.*, Vol. PAMI-2, No. 3, pp. 204-222 (1980).
- 6) 広中 (監訳): フラクタル幾何学, 日経サイエンス社 (1985).
- 7) 高安: フラクタル, 朝倉書店 (1986).
- 8) Medioni, G. G. and Yasumoto, Y.: A Note on Using the Fractal Dimension for Segmentation, *Proc. of IEEE Workshop on Computer Vision*, pp. 25-30 (1984).
- 9) 中山, 曾根, 高木: フラクタル次元と低次統計量とを用いた気象衛星 NOAA 画像の解析とその評価, 情報処理学会論文誌, Vol. 30, No. 1, pp. 91-100 (1989).
- 10) 金子: フラクタルとその応用, テレビ誌, Vol. 41, No. 4, pp. 359-366 (1987).
- 11) 金子: フラクタル特徴とテクスチャ解析, 信学論(D), Vol. J70-D, No. 5, pp. 964-972 (1987).
- 12) 横矢, 山本, 舟久保: フラクタルによる3次元自然形状の解析とその地形モデル作成への応用, 信学論(D), Vol. J70-D, No. 12, pp. 2605-2614 (1987).
- 13) 山本, 高木: 非晶質合金薄膜の腐食パターンのモデル化とその画像生成, 信学技法, IE 87-6, pp. 63-68 (1987).
- 14) 吉沢, 高木: フラクタル次元を用いた不織布繊維顕微鏡画像のテクスチャー解析, 昭 63 テレビ学全大, pp. 421-422 (1988).
- 15) 吉沢, 高木: フラクタル次元を用いた ISODATA クラスタリングによる不織布繊維のテクスチャー解析, 信学技報, IE 88-77, pp. 41-47 (1988).
- 16) 大津: 平面上のデータ点列の直線度, 昭 59 信学総全大, 1571 (1984).
- 17) Brodatz, P.: *Textures*, Dover, New York (1966).
- 18) 田村 (監修): コンピュータ画像処理入門, 総研出版, pp. 159-160 (1985).
- 19) 吉沢, 高木, 伊東: フラクタル次元と ISODATA クラスタリングを用いたテクスチャー解析, 産業における画像センシング技術シンポジウム予稿集, pp. 155-160 (1989).
- 20) 吉沢, 高木, 伊東: フラクタル次元を用いた ISODATA クラスタリングによるテクスチャー

解析, 平成 1 テレビ学全大, pp. 423-424 (1989).

- 21) 画像処理 サブルーチン・パッケージ Spider User's Manual, pp. III 335-III 337, 電子技術総合研究所 (1980).

- 22) 松山, 三浦, 長尾: フーリエ変換を用いたテクスチャの構造解析, 情報処理学会論文誌, Vol. 23, No. 2, pp. 142-149 (1982).

(平成元年 8 月 31 日受付)

(平成 2 年 4 月 17 日採録)



吉沢 達也

1964 年生. 昭和 63 年日本大学生産工学部電気工学科卒業. 平成 2 年東京農工大学大学院工学研究科電子工学専攻修士課程修了. 現在, 東京工業大学大学院総合理工学研究科物理情報工学専攻博士課程在学中. 視覚情報処理に関する研究に従事.



曾根 光男 (正会員)

昭和 51 年関西大学工学部電気卒業. 昭和 54 年大阪大学大学院修士(電子)課程修了. 同年三洋電機(株)入社. 昭和 55 年東京大学生産技術研究所に転じ, 同大学助手を経て, 昭和 62 年富士通(株)に入社, 現在に至る. 画像処理の研究に従事. 電子情報通信学会, TV 学会各会員.



高木 幹雄 (正会員)

昭和 35 年東京大学工学部電気卒業. 昭和 40 年同大学院博士課程修了. 工学博士. 同年同大生産技術研究所助教授. 昭和 54 年同大教授. 昭和 59 年機能エレクトロニクス研究センター長(兼), 現在に至る. 昭和 46~47 年カリフォルニア大学(サンタバーバラ)研究員. 昭和 40 年稲田賞, 昭和 59 年 TV 学会丹羽・高柳賞業績賞. 画像処理の研究などに従事.