

# 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†

中山 寛††\* 曾根 光 男††\*\* 高木 幹 雄††

気象衛星画像では、雲頂高度の低い雲と積雪とが同程度の輝度温度になるので、輝度温度のみを用いて雲と積雪とを分類することは難しい。そこで、本文では気象衛星 NOAA の赤外画像を対象とし、雲と積雪との分類、雲の種類分類をフラクタル次元と低次統計量とを用いて階層的に行う手法を提案する。なお、フラクタル次元とは、形状の複雑さを表す非整数次元であり、本文では、画像濃度面の起伏の複雑さを表す特徴量とする。本手法の有意性をグラントルースを用いて検証する。また、従来の統計的なテクスチャー特徴量を用いる手法と本手法とを認識率、処理時間で比較して、本手法の有効性を示す。

## 1. ま え が き

気象衛星画像では様々な種類の雲を観測することができる。これらの雲を解析し、雲のエネルギー分布、雲の移動ベクトルなどを知ることは気象学上重要な問題である。このために、今まで雲の種類分類、解析が盛んに研究されている<sup>1),2)</sup>。しかし、衛星画像中に積雪が存在する場合、可視画像では、雲と積雪はともに太陽光を強く反射して反射光が高くなり、また、赤外画像では、雲頂高度の低い雲と積雪が同程度の輝度温度となる。したがって、雲と積雪との分類は、濃度ヒストグラムの2値化の方法<sup>3)</sup>では難しい。このような雲と積雪とを分類するためには、画素単位の放射輝度のみでなくテクスチャーを考える必要がある。

従来から統計的なテクスチャー特徴量の計算法として、同時生起行列<sup>4)</sup>、フーリエパワースペクトラム<sup>5)</sup>などが提案されているが、近年、自然界のランダムな複雑さを表す特徴量としてフラクタル次元を適用する試みが行われている<sup>6)-9)</sup>。Mandelbrot によって提唱されたフラクタルは、数学的に統一された定義はないが、狭い意味で無限の繰り返しパターンを持つ自己相似な形状、現象である<sup>10)</sup>。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<sup>11),12)</sup>、その複雑さを表すフラクタル次元が、自然界の画像のテクスチャー解析に有効であると考えられる。

本文では、画像濃度面を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 $N(r)$ を求める方法を新たに定義し、粗視化<sup>13)</sup>の度合を変える方法により画像のフラクタル次元を計算する。次に、フラクタル次元と低次統計量とを用いて、気象衛星 NOAA の赤外画像の解析を行い<sup>14)</sup>、雲と積雪との分類、雲の種類分類を行う。また、同時生起行列、フーリエパワースペクトラムから得ら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. 画像のフラクタル次元<sup>13),14)</sup>

画像濃度面の起伏の複雑さを表す画像のフラクタル次元を、粗視化の度合を変える方法を用いて計算する。

画像濃度面を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 $N(r)$ とし、立方体の1辺の画素間隔をスケールと呼ぶことにすると、スケール $r$ によらず、

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

ただし、 $C$  は定数

となる時、 $D$  をフラクタル次元とする。したがって、式(1)は、

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

となり、 $\log r$  と  $\log N(r)$  は直線関係になり、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面を被覆するスケール $r$ の立方体の個数 $n(r)$ を、

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

† Analysis and Evaluation of Meteorological Satellite NOAA Image by Fractal Dimension and Lower Order Statistics by HIROSHI NAKAYAMA, MITSUO SONE and MIKIO TAKAGI (Institute of Industrial Science, The University of Tokyo).

†† 東京大学生産技術研究所

\* 現在 (株)富士通研究所

\*\* 現在 富士通(株)




図1 単位領域の画像濃度面を被覆する立方体  
Fig. 1 Image intensity surface covered with cubes.

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ブロック領域 (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 \$\overline{n(r)}\$ であるとき,

$$N(r) \triangleq \overline{n(r)} \cdot \frac{S}{r^2} \quad (4)$$

をブロック領域の濃度面を被覆する立方体の個数とする. 最後に, 各スケール \$r\$ における \$N(r)\$ を求め, 式(2)より, \$\log r\$ と \$\log N(r)\$ とをプロットして回帰直線を最小二乗法により計算し, その傾きの大きさをフラクタル次元とする.

実際の画像は, すべてのスケールで自己相似とは限らない. そこで, 各スケールでの近傍でのみ自己相似性を考え, スケール \$r\$ における変化率,

$$D(r) = -\frac{d \log N(r)}{d \log r} \quad (5)^{9), 11)}$$

を文献 9) では局所的フラクタル次元として定義している. 式(5)の実際の計算法は文献 8), 9) で論じられている. 本文では文献 8) の手法と同様に, スケール \$r\$ における局所的フラクタル次元を \$(\log(r-1), \log N(r-1)), (\log r, \log N(r)), (\log(r+1), \log N(r+1))\$ の3点から最小二乗法により求めた回帰直線の傾きの大きさとする.

### 3. 気象衛星 NOAA 画像の解析<sup>14)</sup>

#### 3.1 使用データ

解析に使用するデータは, NOAA 7号から1984年1月29日14時51分~15時5分に受信された赤外チャンネル (チャンネル4) のデータである. 赤外チャンネルを使用したのは, 太陽光の影響が少なく, また夜間のデータが使用できるためである. 前処理として, センサの校正を行い, 出力値を輝度温度に変換する. そして, 幾何学的歪みの補正を行い, 地図画像 (メルカトル図) に変換する<sup>15), 16)</sup>. この画像を本文で解析する原画像とした. これを図2に示す.

#### 3.2 雲と積雪との分類

前処理を行った原画像に対し, 階層的処理, すなわち, 以下の処理①, ②を行い, 雲と積雪とを分類する.

① 原画像を \$1/4\$ に間引き, \$32 \times 32\$ 画素のブロックに直和分割する. 各ブロックをフラクタル次元 (局所的フラクタル次元を含む) と低次統計量とを用いて, 雲, 積雪, 海のいずれかに分類する. なお, 積雪のない陸については, 文献 13) で示したように画像の濃度から積雪と分類可能であるが, 今回使用したデータには, 積雪のない陸は含まれていなかった.

② ①で分類できないブロックについては, ブロックを4分割し, 間引きをしないデータに対して, フラ



(a) 北海道

(b) 東北地方西部

図2 NOAA 赤外画像 (512×480 画素)

Fig. 2 NOAA infrared images (512×480 pixels).

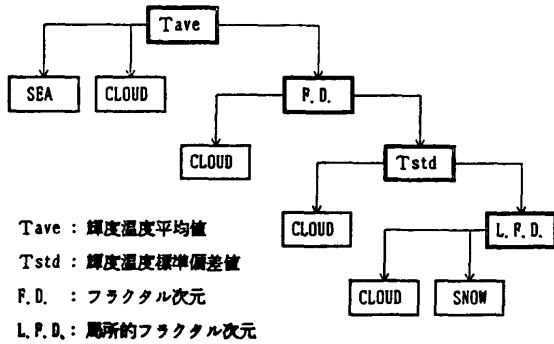


図 3 分類ツリー  
Fig. 3 Classification tree.

フラクタル次元と低次統計量とを用いて分類を行う。

処理①②は、①で大局的に分類を行い、うまく分類できないものについては②で局所的に分類を行うことを意図している。

処理①②ともに各特徴量を用いてツリー型分類を行う。基本的には図 3 の分類ツリーに従って、雲、積雪、海を分類する。分類に用いた各特徴量の閾値は実験的に決定した。閾値は、ある特徴量を用いて必ず分類できるものを分類し、不確かなものを次の特徴量で分類するように決定している。なお、各ブロックのフラクタル次元はスケールを 1~8 画素まで変えて計算される。

以下、図 2 のデータに対して行った処理の要点を Step 1.~4. で説明する。

Step 1. 輝度温度の平均値 (Tave) による分類

輝度温度は地表面の実際の温度と 2~3°K の誤差がある。しかし、輝度温度の分布は地表面の相対的な温度分布を良く表している<sup>17)</sup>。冬期における海は輝度温

度が高く、雲頂高度の高い雲は輝度温度が低い。そこで、

$$Tave < 256^\circ K \Rightarrow \text{雲}$$

$$Tave \geq 275^\circ K \Rightarrow \text{海}$$

とする。256°K ≤ Tave < 275°K では、雲と積雪のブロックが存在するので Step 2. に進む。

Step 2. フラクタル次元 (F. D.) による分類

海上に細かく浮かんでいる雲は輝度温度分布の起伏が複雑で F. D. が非常に高い。そこで、

$$F. D. \geq 2.55 \Rightarrow \text{雲}$$

とする。F. D. < 2.55 では、F. D. の値によって次のようなブロックが存在する。

(1) 2.40 ≤ F. D. < 2.55 ならば

ブロック A : 山岳地帯の積雪 (例 : 図 4 A)

ブロック B : 東北地方西部の薄い雲 (例 : 図 4 B)

ブロック C : オホーツク海上のすじ雲 (例 : 図 4 C) である。

(2) 2.25 ≤ F. D. < 2.40 ならば

ブロック D : 平野部の積雪 (例 : 図 4 D)

ブロック E : 日本海上の平坦な雲 (例 : 図 4 E) である。

(3) F. D. < 2.25 ならば

領域のエッジのブロックである。

(1), (2) の場合については、Step 3. に進む。

Step 3. 輝度温度の標準偏差値 (Tstd) による分類

Step 2. A~E のブロックで、雲の隙間から海が見えるブロックでは Tstd が高い。そこで、

$$Tstd \geq 4.5 \Rightarrow \text{雲}$$

とする。Tstd < 4.5 ならば Step 4. に進む。




図 4 各ブロックの位置 (レーザープリンタによる表示)  
Fig. 4 Position of each block.

## Step 4. 局所的フラクタル次元 (L. F. D.) による分類

Step 2. で(1)に分類された A, B, C のブロックの L. F. D. の例を図 5 (a), (b), (c)に示す。ブロック A の山岳地帯の L. F. D. はスケールが大きくなるに従ってやや高くなる傾向がある。これはスケールが大きいかほど山の起伏が見えやすいためである。ブロック B の雲は非常にきめ細かいため、小さいスケールでの L. F. D. が高い。ブロック C の雲は細かい起伏があるが起伏の変化が小さいため、スケールが大きくなると L. F. D. が急峻に減少する。ここでは、最小スケール 2 の L. F. D. を考え、(以後、L. F. D. (2)を略して LFD(2)と書くことにする)

$$\text{LFD}(2) \geq 2.51 \Rightarrow \text{雲}$$

$$\text{LFD}(2) < 2.51 \Rightarrow \text{積雪}$$

とする。

Step 2. で(2)に分類された D, E のブロックの L. F. D. の例を図 5 (d), (e)に示す。ブロック D, E ともにスケールが大きくなるに従って L. F. D. が減少している。これは、ともに起伏の変化が小さく、スケールが大きくなると平坦に見えるためである。しかし、ブロック D の平野部の積雪に比べて、ブロック E の雲は非常にきめ細かいため LFD(2)の値が高く、L. F. D. の減少が急峻である。したがって、LFD(2)と LFD(3)の差を考慮、

$$\text{LFD}(2) - \text{LFD}(3) \geq 0.12 \Rightarrow \text{雲}$$

$$\text{LFD}(2) - \text{LFD}(3) < 0.12 \Rightarrow \text{積雪}$$

とする。

本解析は Step 1. ~ 4. で大部分できるが、分類できないブロックは領域のエッジにあたるので、分割して、閾値を少し変えて分類を行う。

以上の手順に従い、分類した結果を図 6 に示す。図 6 はブロック単位の分類である。なお、分類は画素単位で行われるものであるが<sup>14)</sup>、処理時間がかかるだけで、本質的に変わらないので、ブロック単位で示した。

図 6 の分類結果は、気象庁気象衛星センターの専門家によって提供されたグランドトゥルス\* に良く一致している。オホーツク海上の流水は積雪に分類されているが、これは流水と北海道東部の凍りついた積雪の各特徴量が同程度になるためである。

紙面の関係で、本文では図 6 のようなメルカトル図を示したが、ポーラステレオ図でも同様の考え方で雲と積雪とを分類することができる。

特徴量としてのフラクタル次元を考えると、単一パラメータで分類できるのは、フラクタル次元が非常に高い値になる雲だけである。しかし、局所的フラクタル次元の傾向は輝度温度分布の起伏の状態を良く表しており、局所的フラクタル次元を考慮することによって分類の精度が向上する。また、山岳地帯の積雪のフラクタル次元は平野部に比べて高く、実際の地形の複雑さの感覚と良く一致している。

\* カテゴリの分かったサンプルデータ

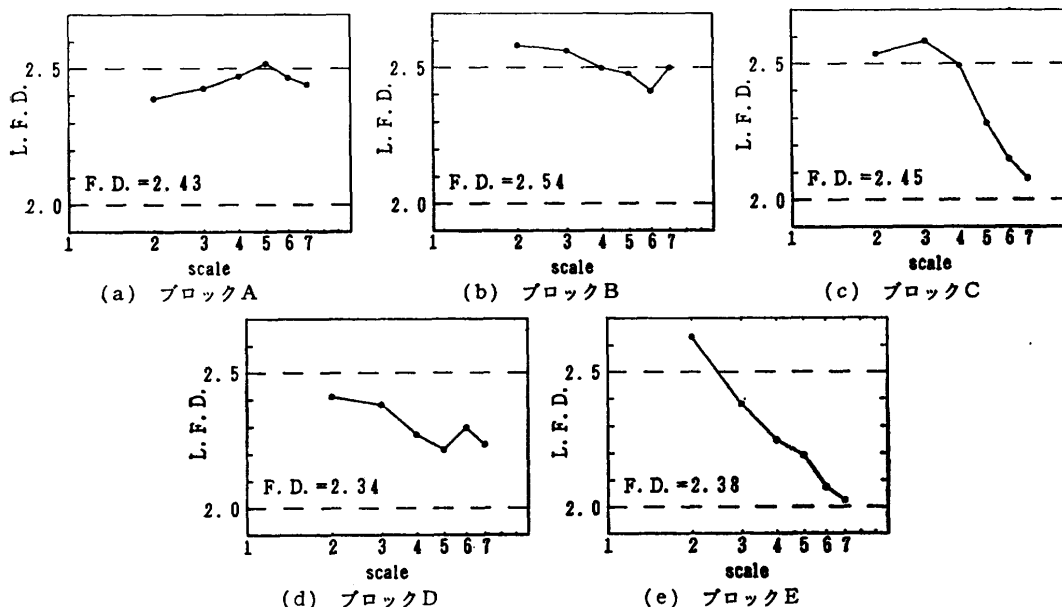


図 5 局所的フラクタル次元 (図 4, すなわち 1984 年 1 月 29 日受信データ)  
Fig. 5 Local fractal dimension.




(a) 北海道




(b) 東北地方西部

図 6 雲と積雪との分類結果

Fig. 6 Classified cloud and snow.



(a) 図 4 ブロック A に相当



(b) 図 4 ブロック D に相当

図 7 局所的フラクタル次元 (1985年1月7日受信データ)

Fig. 7 Local fractal dimension.

図 7 に、3.1 節のデータと異なる日 (NOAA 7 号, 1985 年 1 月 7 日) に受信されたデータのブロック A, D の局所的フラクタル次元を示す。これを図 5 (a), (d) と比較すると良く似た傾向になっていることが分かる。つまり、積雪の局所的フラクタル次元は、積雪の状態によって多少異なるものの、地形の影響で地域固有の傾向を示すと考えられる。実際の応用を考える

と、雲と積雪との分類が問題となるのは陸上である。したがって、陸上の各地域のフラクタル次元と局所的フラクタル次元を調べて一つの知識としておけば、ある地域が雲か積雪かを判定する有効な手法になると思われる。

実際に 1985 年 1 月 7 日受信の NOAA 画像について、図 3 の分類ツリーに従って図 2 の NOAA 画像と同様の処理手順で雲と積雪との分類を行い、良好な結果を得ることができた。これは、雲の特徴

量はその種類の多さから画像が異なれば様々な値になるものの、積雪の特徴量を特定することができるからである。

### 3.3 雲の種類分類

図 2 (b) 東北地方西部の画像では多種類の雲が観測されている。気象衛星画像から、雲のエネルギー分布、雲の移動ベクトルなどを考える場合、雲の分類結

果が必要である。ここでは、局所的フラクタル次元と低次統計量とを用いて雲の種類分類を行う。分類方法は教師付き分類を行い、最短距離法を用いて分類する<sup>1)</sup>。分類距離として、マハラノビスの距離

$$Q^2 = (x - \mu_i)' \Sigma_i^{-1} (x - \mu_i) \quad (6)$$

$x$ : 雲特徴パラメータの観測ベクトル

$\mu_i$ : 雲形  $i$  の特徴パラメータの平均値ベクトル

$\Sigma_i$ : 雲形  $i$  の特徴パラメータの共分散行列

を用いる。以下、処理手順を(i)~(ii)で述べる。

(i) 原画像を  $32 \times 32$  画素のブロックに直和分割し、気象庁気象衛星センターの専門家によって提供されたグランドトゥルスより、分類すべき雲の種類を図8に示す五つのクラスに分ける。


(ii) 雲特徴パラメータとして、輝度温度の平均値 Tave, 輝度温度の標準偏差値 Tstd, 局所的フラクタ

ル次元 LFD(2), LFD(3) の四つの特徴量を用い、各パラメータの平均値、ベクトル共分散行列を求め、ここで、LFD(2), LFD(3) を用いたのは、3.2節で示したように、局所的フラクタル次元の傾向が画像の特徴を良く表していると考えられるからである。

(ii) 原画像の各ブロックについてマハラノビスの距離を計算し、距離が最小のクラスにブロックを分類する。ただし、最小の距離が 10 を超えるブロックについてはどのクラスにも属しないと判定する。

以上の手順に従って分類した結果を図9に示す。図9の従属のデータ<sup>1)</sup> (平均ベクトル、共分散行列の計算に使用したデータ) の認識率を表1に示す。表1を見ると非常に高い認識率が得られている。


このような雲の種類分類は、気象専門家が行う雲のエネルギー分布の推定などに有効と思われ、今後、



: Cloud 1   
  : Cloud 2   
  : Cloud 3  
 : Cloud 4   
  : Cloud 5

図8 分類すべき雲の種類

Fig. 8 The classes of clouds classified by meteorologists.



: Cloud 1   
  : Cloud 2   
  : Cloud 3  
 : Cloud 4   
  : Cloud 5

図9 雲の種類分類結果

Fig. 9 Classification results of clouds.

表1 従属データの認識率  
Table 1 Correct classification ratio.

特徴量	分類すべきクラス	認識数 (認識率 (%))		誤認識したクラス					$Q^2 \geq 10$
				Cloud 1	Cloud 2	Cloud 3	Cloud 4	Cloud 5	
Tave Tstd LFD (2) LFD (3)	Cloud 1	26 (96.3)	total 96 (94.1)	※	0	0	0	0	1
	Cloud 2	8 (85.2)		1	※	0	0	0	0
	Cloud 3	43 (93.5)		0	0	※	2	1	0
	Cloud 4	10 (100.)		0	0	0	※	0	0
	Cloud 5	9 (90.0)		0	0	1	0	※	0

さらに多くのデータについて検討する必要がある。

#### 4. 他の特徴量を用いた分類との比較

3.2 節では、雲と積雪とを分類する特徴量として、輝度温度の平均値、輝度温度の標準偏差値、フラクタル次元、局所的フラクタル次元を用いた。ここではフラクタル次元、局所的フラクタル次元の代わりに従来からテクスチャー解析で使用されている特徴量を用いて、分類の認識率、処理時間等を比較検討する。

##### 4.1 同時生起行列から得られる特徴量

同時生起行列  $M(d, \theta)$  の要素は、図 10 の特定相対位置関係にある画素対  $[(i, j), (k, l)]$  において、濃度対  $(m, n)$  が生起する確率  $p(m, n)$  である。Haralick らは、 $M(d, \theta)$  からテクスチャーを特徴づける特徴量を提案しているが<sup>4)</sup>、本文ではよく用いられる 3 つの特徴量を使用する。以下の式では濃度レベルは  $0 \sim l-1$  である。

(i) 角二次モーメント

$$f1 = \sum_{m=0}^{l-1} \sum_{n=0}^{l-1} p(m, n)^2 \quad (7)$$

$f1$  は、 $p(m, n)$  がある濃度対に対して大きな値を持つと大きな値になり、テクスチャーの一様性を表す。

(ii) コントラスト

$$f2 = \sum_{m=0}^{l-1} \sum_{n=0}^{l-1} (m-n)^2 \cdot p(m, n) \quad (8)$$

$f2$  は画素対の濃度差の 2 乗平均を表し、 $f2$  が大きいほどコントラストが強い。

(iii) 相関

$$f3 = \frac{\sum_{m=0}^{l-1} \sum_{n=0}^{l-1} mn p(m, n) - \mu_m \cdot \mu_n}{\sigma_m \sigma_n} \quad (9)$$




図 10 画素対の変位と角度

Fig. 10 The displacement and angle of a pixel pair.

ただし、

$\mu_m, \sigma_m: p(m, n)$  の  $m$  方向の周辺分布の平均値と分散  
 $\mu_n, \sigma_n: p(m, n)$  の  $n$  方向の周辺分布の平均値と分散

$f3$  は濃度対の相関を測るもので、 $f3$  が大きいときテクスチャーは  $\theta$  方向の方向性を持つ。

$f1, f2, f3$  はそれぞれ、画素対の相対的位置関係  $(d, \theta)$  の関数である。ここでは、ある  $d$  に対して  $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$  の方向の特徴量を求め、4 方向の平均値を  $d$  に対する特徴量の値とする。これは、違う方向性を持った同じ種類の雲が存在する場合、同じテクスチャーと見なす方が妥当であると思われるからである。したがって、 $d=d1$  における角二次モーメント  $ASM(d1)$  を式(7)の  $f1$  を用いて

$$ASM(d1) = \frac{f1(d1, 0^\circ) + f1(d1, 45^\circ) + f1(d1, 90^\circ) + f1(d1, 135^\circ)}{4} \quad (10)$$

とする。また、 $d=d1$  におけるコントラスト、相関をそれぞれ、 $CONT(d1), CORR(d1)$  で表す。

##### 4.2 フーリエ領域から得られる特徴量

画像  $f(i, j)$  のフーリエ変換  $F(u, v)$  は、画像サイズが  $n \times n$  画素の場合、

$$F(u, v) = \frac{1}{n^2} \sum_{i,j=0}^{n-1} f(i, j) e^{-2\pi\sqrt{-1}(iu+jv)} \quad (11)$$

で与えられる。フーリエパワースペクトラム  $|F(u, v)|^2$  の分布は、画像のきめが粗いほど原点付近に集中し、また、きめが細かいほど高周波側に広がる。フーリエパワースペクトラムの分布から得られる特徴量として、

$$RING(r_1, r_2) = \sum_{\substack{r_1^2 \leq u^2+v^2 < r_2^2 \\ 0 \leq u, v \leq n-1}} |F(u, v)|^2 \quad (12)^{5)}$$

が提案されている。

##### 4.3 雲と積雪との分類

分類手法は 3.3 節と同様にマハラノビスの距離を用いた教師付き分類を行う。特徴パラメータとして、低次統計量である輝度温度の平均値、標準偏差値のほか、表 3 に示すように統計的テクスチャーの特徴量二つを用いる。分類すべきブロック数は、雲 173 個、積雪 107 個である。

表 2 分類結果の評価

Table 2 Evaluation of classification results.

特徴量	フラクタル次元	角二次モーメント	コントラスト	相関	パワースペクトラム
認識率	○	△	×	○	×
処理時間	○	△	△	×	○

分類結果を、認識率、処理時間で評価すると表2のようになる。ただし、同時生起行列の大きさは $64 \times 64$ である。これは画像の平坦化を行っていない。認識率が90%以上の場合についてのみ表3に示す。

雲と積雪との認識率を比較すると、雲の方が積雪に比べて高い。これは雲の種類が多く特徴パラメータのばらつきが大きいため、多次元空間で積雪の特徴パラメータがその中に含まれる可能性が高いためと考えられる。例えば、積雪と2種類の雲があり、特徴パラメータが二つの場合と考える。特徴パラメータが図

11(a)のように分布している場合、分類するクラスを積雪と雲の二つのクラスに限ると図11(b)のように積雪が雲に含まれてしまう。しかし、雲の種類を考えると図11(c)のようにうまく分類できる。したがって、雲の種類を考えた分類が必要である。

4.4 雲の種類を考慮した分類

グランドトゥースにより分類すべきクラスは6種類の雲と積雪の七つのクラスとする。雲のクラスは、図8に示した5種類の雲と図2(a)オホーツク海上のすじ雲 (cloud 6 とする) である。各クラスのブロック数は、

- cloud 1 : 27 個, cloud 2 : 9 個,
- cloud 3 : 46 個, cloud 4 : 10 個,
- cloud 5 : 10 個, cloud 6 : 8 個,
- snow : 107 個

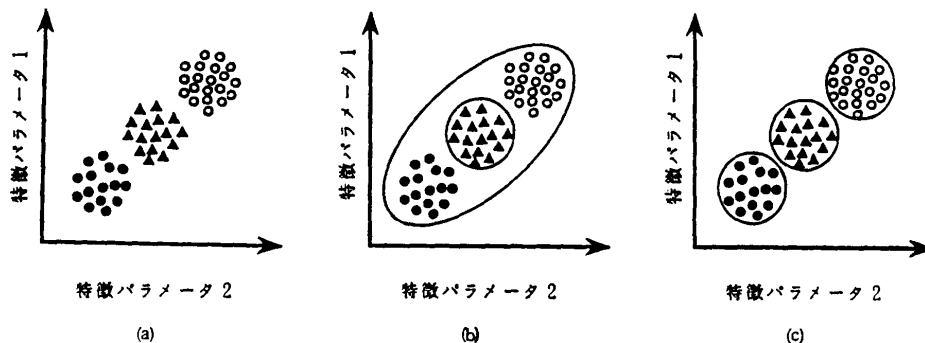
である。表3で認識率の高いF.D.とLFD(2)の組, CORR(2)とCORR(4)の組について分類した結果を表4に示す。

表4を見ると、フラクタル次元、相関とも認識率は同程度である。しかし、比較的データ数の多いcloud 1で相関の認識率が悪いのは問題である。また、処理時間は、フラクタル次元が相関の約1/4で優れている。

相関の処理時間を短縮するために、画像の平坦化を行い、同時生起行列の大きさを $64 \times 64$ から $16 \times 16$ に変換して分類を行うと、処理時間はフラクタル次元と同程度になったが、認識率が低下した。

表3 認識率と処理時間  
Table 3 Classification correct ratio and CPU time.

特徴量 (Tave+Tstd+)	認識数		認識率(%)		CPU TIME (min.: sec.)
	上段:雲	total	上段:雲	total	
	下段:雪		下段:雪		
F.D. + LFD(2)	165	264	95.4	94.2	0 : 45
	99		92.5		
LFD(2) + LFD(3)	165	262	95.4	93.6	0 : 45
	97		90.7		
LFD(2) + LFD(4)	164	262	94.8	93.6	0 : 45
	98		91.6		
ASM(1) + ASM(2)	163	255	94.2	91.1	1 : 16
	92		86.6		
ASM(1) + ASM(4)	166	254	96.0	90.7	1 : 16
	88		82.2		
CORR(1) + CORR(2)	167	252	96.5	90.0	3 : 13
	85		79.4		
CORR(1) + CORR(4)	168	259	97.1	92.5	3 : 10
	91		85.0		
CORR(2) + CORR(4)	169	268	97.7	95.7	3 : 09
	99		92.5		



● : 雲1, ○ : 雲2, ▲ : 積雪

図11 特徴パラメータの分布

Fig. 11 Distribution of feature parameters.



表 4 認識率と処理時間

Table 4 Classification correct ratio and CPU time.

(a) フラクタル次元と局所的フラクタル次元を用いた場合

特徴量	分類すべきクラス	認識数 (認識率(%))	誤認識したクラス								CPU TIME (min.:sec.)
			Cloud 1	Cloud 2	Cloud 3	Cloud 4	Cloud 5	Cloud 6	Snow		
Tave	Cloud 1	25 (92.6)	※	1	0	0	0	0	0	1	0:38
	Cloud 2	7 (77.8)	0	※	0	0	0	2	0		
Tstd	Cloud 3	44 (95.7)	0	0	※	0	2	0	0		
F. D.	Cloud 4	10 (100.)	0	0	0	※	0	0	0		
LFD (2)	Cloud 5	10 (100.)	0	0	0	0	※	0	0		
	Cloud 6	5 (62.5)	0	0	0	0	0	※	3		
	Snow	101 (94.4)	1	0	1	0	2	2	※		

(b) 相関を用いた場合

特徴量	分類すべきクラス	認識数 (認識率(%))	誤認識したクラス								CPU TIME (min.:sec.)
			Cloud 1	Cloud 2	Cloud 3	Cloud 4	Cloud 5	Cloud 6	Snow		
Tave	Cloud 1	23 (85.2)	※	1	0	0	0	0	0	3	2:32
	Cloud 2	8 (88.9)	1	※	0	0	0	0	0		
Tstd	Cloud 3	43 (93.5)	0	0	※	1	2	0	0		
CORR (2)	Cloud 4	10 (100.)	0	0	0	※	0	0	0		
CORR (4)	Cloud 5	9 (90.0)	0	0	1	0	※	0	0		
	Cloud 6	6 (75.0)	0	1	0	0	0	※	1		
	Snow	101 (94.4)	2	0	3	0	0	1	※		

以上の実験から、フラクタル次元が気象衛星 NOAA 画像の解析において有効であるということがわかる。

## 5. む す び

画像濃度面を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  $N(r)$  を求める方法を新たに定義し、粗視化の度合を変える方法でフラクタル次元を計算した。次に、気象衛星 NOAA の赤外画像を対象とし、雲と積雪との分類、雲の種類分類をフラクタル次元と低次統計量とを用いて階層的に行う手法を提案した。

本手法の有意性をグラントルースを用いて検証した。また、本手法の有効性を従来の統計的なテクスチャー特徴量を用いる手法と比較して示した。本文では、濃度レベルが同程度のものをフラクタルを用いて

分類できる一例を示したにすぎない。今後、フラクタルがどのようなテクスチャーに有効であるか、さらに検討が必要であろう。フラクタルが画像解析の新たな視点として重要であると筆者らは考えている。

**謝辞** 本研究を進めるにあたり、グラントルースを提供していただきました気象庁気象衛星センターの浜田忠昭、元木敏博両氏に深く感謝します。

## 参 考 文 献


- 1) 加藤：気象衛星の画像データによる客観的雲形判別方法について、気象衛星センター技術報告、第3号 (1981)。
- 2) 加藤、石川：GMS 画像データによる客観的雲頂高度算出処理について、気象衛星センター技術報告、第5号 (1982)。
- 3) 大津：判別および最小2乗規準に基づく自動し

- きい値選定法, 信学論(D), Vol. J 63-D, pp. 349-356 (1980).
- 4) Haralick, R. M., Shanmugam, K. and Dinstein, I.: Textural Features for Image Classification, *IEEE Trans.*, Vol. SMC-3, No. 6, pp. 610-621 (1973).
- 5) Weska, J. S., Dyer, C. R. and Rosenfeld, A.: A Comparative Study of Texture Measures for Terrian Classification, *IEEE Trans.*, Vol. SMC-6, No. 4, pp. 269-285 (1976).
- 6) Pentland, A. P.: Fractal-Based Description of Natural Scenes, *IEEE Trans.*, Vol. PAMI-6, No. 6, pp. 661-674 (1983).
- 7) 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).
- 8) Peleg, S. and Naor, J. et al.: Multiple Resolution Texture Analysis and Classification, *IEEE Trans.*, Vol. PAMI-6, No. 6, pp. 518-523 (1984).
- 9) 金子: フラクタル特徴とテクスチャ解析, 信学論(D), Vol. J 70-D, No. 5, pp. 964-972 (1987).
- 10) B. Mandelbrot 著, 広中訳: フラクタル幾何学, 日経サイエンス社 (1985).
- 11) 高安: フラクタル, 朝倉書房 (1986).
- 12) 形・フラクタル, 別冊数理科学, サイエンス社 (1986).
- 13) 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画像のテクスチャー解析, 情報研報, CV 44-4 (1986).
- 14) 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, 第 17 回画像工学コンファレンス, 16-3, pp. 255-258 (1986).
- 15) 高木, 曾根, 檜山, 坂内, 上野: 気象衛星 (NOAA) 画像と海岸線データの位置合せシステム, 第 15 回画像工学コンファレンス, 6-10, pp. 121-124 (1984).
- 16) 高木, 檜山, 曾根, 尾上: 気象衛星 NOAA 画

- 像における幾何学的ひずみの自動補正法, 信学論(D), Vol. J 71-D, No. 5, pp. 883-893 (1988).
- 17) 曾根, 林, 坂内, 高木: 銚子地方における気象衛星 NOAA データによる輝度温度と実測地表面温度との関係, 第 17 回画像工学コンファレンス, 16-2, pp. 251-254 (1986).

(昭和 62 年 12 月 21 日受付)

(昭和 63 年 11 月 14 日採録)



中山 寛

昭和 60 年東京大学工学部電子卒業。昭和 62 年同大学院修士課程修了。同年(株)富士通研究所に入社, 現在に至る。在学中は画像処理の研究に従事。



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。