

衛星マルチスペクトルデータを用いた土地被覆分類図の精度向上について

○東京理科大学 正会員 Tashpolat Tiyyip

東京理科大学 正会員 大林成行

東京理科大学 正会員 小島尚人

東京理科大学 学生員 伊藤誠敏

1. はじめに

広域性、周期性、同時性といった特徴を有する衛星データから作成される土地被覆分類図は、土地利用基本計画や地域計画、環境影響評価等、一般に建設分野に分類される領域において利用ニーズが高い。時代の変遷とともに、都市の一極集中から多極分散を念頭に置いた国土の保全・開発に関わる一連の計画プロセスにおいて、より一層きめこまかに土地被覆の状態を把握・分析することの必要性が一層高くなってきた証拠である。衛星データが高分解能になる程、土地被覆分類精度の向上を目指した研究の成果が、今後ますます期待される。しかし、SPOT・HRVデータのようにデータ自体の精度が高分解能になる程、分類しようとするクラス間の分散が大きくなるため、地上分解能の向上が必ずしも土地被覆分類精度の向上に反映されないといった問題が指摘されている^{1)・2)}。このようなことから、最近では人間が認識する画像の「きめ」や「あらさ」のパターン、いわゆるテクスチャ等の「空間情報」を分類に用いるスペクトル情報に付加して分類精度を向上させようとする研究が見られる^{2)・3)}。

従来から統計的なテクスチャ特徴量の計算法として同時生起行列⁴⁾、フーリエパワースペクトラムなどが提案されているが⁵⁾、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注目されている^{6)・7)}。コンピュータビジョンの分野ではフラクタルを用いた自然形状の生成など、様々な利用が考えられているが、画像特徴の解析という視点からフラクタルを利用する例はまだ少なく、実用的な利用方法を模索するといった基礎研究段階にあると言える。そこで、本研究では画像濃度曲面に対するフラクタル特徴量を分類に用いる多次元データの一つに付加した場合、分類精度が向上するか否かといった問題について検討し、さらに従来から空間情報の一つとして利用されているテクスチャ特徴量を用いた場合の分類精度と比較する。

第2章では、本研究で使用した衛星データ（SPOT・HRVデータ）と対象領域について述べる。第3章では、本研究で採用したフラクタル特徴量を算出する方法に触れ、第4章では、設定した検討ケースおよび本研究で用いた分類精度の評価指標について述べる。第5章でこれらの指標を用いて分類精度を比較した結果を整理、考察する。さらに、第6章ではフラクタル特徴量を算出するために要する時間を計測し、作業効率の面からの評価を加える。結論として土地被覆分類精度の向上に寄与する有効な空間情報としてフラクタル特徴量が利用できるか否かについて言及する。

2. 使用データおよび対象領域

本研究で使用したデータは、1988年10月4日に観測されたSPOT・HRVデータ（PATH：331、ROW：280）である。また、分類精度を評価する上で土地被覆項目がよく識別でき、東京理科大学リモートセンシング研究所によって詳細なグランドトゥースデータが収集・整備されている千葉県印旛沼周辺を対象領域として選定した。設定した土地被覆項目は、水田、畑、樹林、人工構造物（市街地等）、芝地、裸地、水域の7種類である。

3. フラクタル特徴量

フラクタル次元の定義は種々のものが考案されているが、主なものは次の5つがあげられる⁸⁾。

- ①粗度化の度合を変える方法
- ②測度の関係より求める方法
- ③相関関数より求める方法
- ④分布関数より求める方法
- ⑤スペクトルより求める方法

コンピュータグラフィックスの分野においては自然形状を含む現実感のある画像を生成することに主眼がおかれている。その場合のフラクタル特徴は人間が経験的かつ意図的に与えることが多い。さらに、形状や

画像特徴を解析するといった研究では、その多くがフラクタル次元の算出と次元の違いに着目した物理的な意味解釈に重点が置かれている。本研究ではこのような状況の中、画像濃度曲面や自然形状を記述するための代表的なモデルとして有効であると報告されている「フラクタルブラウン関数」を採用した。これは上述した④の方法に対応する。

3.1 フラクタルブラウン関数⁹⁾

E次元ユークリッド空間内の点Xの実数値関数F(x)について

$$Pr\left\{\frac{|f(x+\Delta x)-f(x)|}{|\Delta x|^H} < l\right\} = F(l) \quad (1)$$

(P_r は確率)

がXと変位 ΔX に無関係に一定の分布F(t)をもつような定数Hが存在するとき、 $f(X)$ を(一般化された)フラクタルブラウン関数と呼ぶ。このとき、 $f(X)$ で構成される曲線は統計的にフラクタルであると言う。ここで、Hは自己相似パラメータである($0 \leq H \leq 1$)。F(X)のフラクタル次元Dは次式で与えられ、一般には非整数の値をとる。

$$D = E + 1 - H \quad (2)$$

また、地形や画像濃度等の3次元曲面におけるフラクタル次元は次式で与えられる⁹⁾。

$$D = 3 - H \quad (3)$$

ここで分布関数F(t)として平均0の正規分布N($0, \sigma^2$)を仮定する。即ち

$$F(l) = \int_{-\infty}^l \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{s^2}{2\sigma^2}} dS \quad (4)$$

である。

フラクタルブラウン関数の定義式(1)は、次のように書き換えることができる。

$$E[|f(x+\Delta x)-f(x)|] \cdot |\Delta x|^{-H} = C \quad (5)$$

但し、E: 期待値

C: 定数

Cは確率変数|t|の期待値に等しいので式(2)より、

$$C = 2\sigma / 2\pi \quad (6)$$

また、式(3)は次式と等価である。

$$\begin{aligned} \log E[|f(x+\Delta x)-f(x)|] - H \cdot \log |\Delta x| \\ = \log C \end{aligned} \quad (7)$$

式(7)はHとCが定数なので、 $\log |\Delta x|$ を横軸に





図-1 フラクタルブラウン関数の基本概念

とり、 $\log E[|f(x+\Delta x)-f(x)|]$ を縦軸として値をプロット(以下フラクタルプロットと呼ぶ)したとき、それらの点が傾きHの直線上に乗っていることを意味する。

以上のフラクタルブラウン関数の基本的な性質を分かりやすくするために図-1に概念図を示した。

3.2 フラクタル特徴量の物理的意味

画像濃度値 $f(X, Y)$ で表される曲面を前節で説明したフラクタルブラウン関数で近似した場合の特徴量の物理的意味は以下のとおりである。

(1) フラクタル次元: D

フラクタルモデルを用いた場合に最も重要な特徴量であり、自己相似パラメータHを求めることと等価である。フラクタル次元Dは画像濃度曲面の起伏の状態を表した特徴量として考えることができる。つまり、同一の分布関数F(t)を仮定した場合、Dが小さい(Hが大きい)濃度曲面の起伏はゆるやかであり、Dが大きい(Hが小さい)濃度曲面の起伏は激しい。

(2) 自己相似パラメータ: H

$E[|f(x+\Delta x)-f(x)|]$ は、一定の変位 $|\Delta x|$ だけ離れたすべての点対について計算した関数値の差の絶

対値の平均であり、 $f(x)$ に関する同時生起行列から導かれるテクスチャ解析における2次の差分統計量となる。つまり、 H は2次統計量を反映したある種のテクスチャ特徴量である。

(3) 分布関数 $F(t)$ と分散 σ^2

D (あるいは H) とともに形状を特徴づけるのが式(1)における確率分布 $F(t)$ である。本研究では正規分布 $N(0, \sigma^2)$ を仮定しているため、分布を決定づけるのは分散 σ^2 である。つまり、(6)式から求められる σ の値が一つのフラクタル特徴量となる。

本研究では、 H と σ の2つのフラクタル特徴を算出し、それぞれをスペクトル情報に付加して分類に使用する空間情報とした。

3.3 フラクタル特徴量の算出

フラクタルブラウン関数を用いて画像濃度曲面のフラクタル特徴量を算出する場合、次の2点に留意する必要がある。

(1) フラクタルプロットのスケール範囲の決定

すべてフラクタルプロットが直線上に乗り、一定のフラクタル次元を持っているとは限らない。フラクタルプロットが成立する上限と下限、すなわち ΔX_{min} 、 ΔX_{max} が重要な特徴となる。

(2) フラクタル性の評価

実際の画像濃度曲面をフラクタルブラウン関数で記述するためには、フラクタル性の有無を評価しなければならない。

以上の2点に対して、本研究ではフラクタルブラウン関数による近似誤差 $\log|\Delta X|$ に対する $\log E[|f(x+\Delta x) - f(x)|]$ のプロットの直線性によって評価する。具体的には次式の「直線度 I 」によって評価した¹⁰⁾。この方法はフラクタル次元の局所的変動を抽出する上で非常に重要であり、よく利用されるものである。

$$I = \sqrt{4\mu_{11}^2 + (\mu_{20} + \mu_{02})^2} / (\mu_{20} + \mu_{02}) \quad (8)$$

$$\text{但し、} \mu_{pq} = (1/n) \sum_{i=1}^n (X_i - \bar{X})^p (Y_i - \bar{Y})^q$$

(2次の中心モーメント)

(X_i, Y_i) : フラクタルプロット図上のデータ点列

直線度は $0 \leq I \leq 1$ の値をとり、 $I = 1$ に近い程直線性が保証され、 $I = 0$ に近い程点列が無相関、等方的にランダムに分布することを意味する。この直線度

はデータの相似変換、つまり平行移動、回転、伸縮に関して不変であるという不変式論から導かれたものである。

さて、実際の濃度曲面 $f(x)$ をフラクタルブラウン関数で近似する場合には、最小2乗誤差基準を用いて定数 H と $\log C$ を同時に決定する。式(7)から得られる2乗誤差の評価式

$$e^2 = \sum_p^q \{ \log E[|f(x+\Delta x) - f(x)|] - H \log |\Delta x| - \log C \}^2 \quad (9)$$

但し、 $P: |\Delta x| = |\Delta x|_{min}$

$q: |\Delta x|_{max}$

を最小にする定数 H と $\log C$ を同時に決定する。最終的に求まる H と $\log C$ は式(10)で与えられる。

$$\begin{pmatrix} H \\ \log C \end{pmatrix} = \begin{pmatrix} \sum (\log |\Delta x|)^2 & \sum \log |\Delta x| \\ \sum \log |\Delta x| & \sum 1 \end{pmatrix}^{-1} \begin{pmatrix} \sum \log |\Delta x| \cdot \log E[|f(x+\Delta x) - f(x)|] \\ \sum \log E[|f(x+\Delta x) - f(x)|] \end{pmatrix} \quad (10)$$

但し、 $\Sigma: |\Delta x| = |\Delta x|_{min} \sim |\Delta x|_{max}$ までの和

フラクタル次元 D および分布関数 $F(t)$ の標準偏差 σ は、式(10)から求まる H と C を式(3)および式(6)に代入することによって求めることができる。

本研究では、画像濃度曲面は2次元のデータ配列であることから等方性フラクタルで近似する。つまり、ある着目画素を中心にして全方向の ΔX について e^2 を評価することとなる。

H RVデータ・バンド1を対象に全方向の変位 ΔX ($= 1, 2, \dots, 12$ 画素) について $\log |\Delta X|$ と $\log E[|f(x+\Delta x) - f(x)|]$ をプロットした例を図-2に示す。直線度 I の値を見てもこの画像の局所的な濃度曲面はあるスケール範囲内 (X 軸) において統計的にフラクタル性をもっていると言える。

図-2で示した処理をすべての画素に対して行い、その都度 H と σ を算出する。それぞれを8ビットデータに規格化し、局所的なフラクタル特徴量の変動を画像として出力したものが図-3および図-4である。

なお、フラクタル特徴量の規格化のレベルの違いによる分類精度への影響も考えられるが、この点については本論では触れず今後の課題とする。




図-2 画像濃度曲面のフラクタルプロットの一例 (HRV・BAND-1)





図-3 自己相似パラメータHの局所的変動 (HRV・BAND-1)



図-4 標準偏差σの局所的変動 (HRV・BAND-1)

4. 検討ケースおよび分類精度評価指標

4.1 テクスチャ

本研究では、比較のために一般に広く利用されているテクスチャ特徴量を検討ケースに加えた。

テクスチャは、3×3の近傍画素から生成される同時生起行列によって定義される次の6種類を設定した。

この他にも種々の空間情報が考えられているが²⁾、それらについては今後の課題とする。

①角2次モーメント (Angular Second Moment)

$$ANG = \sum_i \sum_j P_{ij}^2 \quad (11)$$

②同質性 (Homogeneity)

$$HOM = \sum_i \sum_j P_{ij} / \{1 + (i-j)^2\} \quad (12)$$

③コントラスト (Contrast)

$$CON = \sum_i \sum_j (i-j)^2 P_{ij} \quad (13)$$

④非類似度 (Dissimilarity)

$$DIS = \sum_i \sum_j |i-j| P_{ij} \quad (14)$$

⑤平均情報量 (Entropy)

$$ENT = \sum_i \sum_j P_{ij} \cdot \log P_{ij} \quad (15)$$

⑥相関 (Correlation)

$$COR = \{ \sum_i \sum_j (ij) P_{ij} - \mu_x \cdot \mu_y \} / \sigma_x \cdot \sigma_y \quad (16)$$

ここで P_{ij} は、画素値の同時生起行列の要素であり、 i, j は行および列番号、 μ_x, μ_y および $\sigma_x \cdot \sigma_y$ はそれぞれ行列方向の平均および標準偏差である。同時生起行列は、画像の濃度 i の点から一定の変位 $\delta = (r, \theta)$ だけ離れた点の濃度 j の点から一定の変位 $(i, j = 1, 2, \dots, n)$ を要素とするものである。 r, θ については、種々の組合せが考えられるが、本研究では $\theta = 0^\circ, 90^\circ$ の場合に $r = 1$ を、また、 $\theta = 45^\circ, 135^\circ$ の場合に $r = \sqrt{2}$ を採用した。さらに、この4方向の θ に対して算出される値の平均をとって最終的に求めるテクスチャとした。算出されたテクスチャは、8ビットデータに規格化してスペクトル情報

に付加する多次元データのの一つとした。

4.2 検討ケース

本研究で設定した検討ケースは、表-1に示す9ケースである。数種類にわたる空間情報の組合せも考えられるが、ケース数が膨大となるばかりでなく、分類精度について考察する際に、空間情報の組合せについて物理的な意味付けが難かしいこと等の理由からあまり得策とは言えない。そこで、本研究では原データに空間情報を一種類だけ付加する検討ケース（ケース2～ケース9）を設定した。つまり分類に使用するバンドは、原データ・3バンドと空間情報・3バンドを併せて6次元のデータとなる。

一般に衛星データの分類では教師付分類に代表される最尤法が比較的分類精度が高く、実用的な手法として多用されている。本研究においても実用性の観点からこの教師付最尤法を用いた。この時、トレーニングクラスの多次元正規性が問題とされるが、一般にバンド別、クラス別にデータの正規性が保証されるとは限らず、むしろ正規分布とならない場合が多い。このようなことから多次元正規性の問題が本質的に分類精度に及ぼす影響は大きくないとの研究報告もある¹¹⁾。

そこで、本研究では空間情報をスペクトル情報に付加して分類した場合に、多次元正規性の仮定のもとに定義されるクラス間発散が大きくなることを確認することによって、対処することとした。この結果については後述する。

表-1 検討ケース

空間情報	ケース名	分類に使用するデータの組合せ
テクスチャ特徴量	ケース1	Original data (ORG) IRV-BAND-1, 2, 3
	ケース2	ORG + 角2次モーメント (ANG)
	ケース3	ORG + 同質性 (HOM)
	ケース4	ORG + コントラスト (CON)
	ケース5	ORG + 非類似度 (DIS)
	ケース6	ORG + 平均情報量 (ENT)
	ケース7	ORG + 相関 (COR)
フラクタル特徴量	ケース8	ORG + 自己相似パラメータ (FRA-H)
	ケース9	ORG + 標準偏差 (FRA-σ)

なお、多次元正規性を厳密に検定し、ノンパラメトリックな分類手法を用いる手順を踏む分類の精度については今後の課題とする。

4.3 本研究における土地被覆分類精度の評価指標

土地被覆分類精度の評価指標には様々なものが適用されており、どの指標を用いれば的確に分類精度を評価できるのかといったことが問題となる。そこで、本研究ではトレーニングデータに対する評価指標として、①区分精度、②誤分類率、③クラス間発散度の3つを適用する。さらに、分類後の画像に対して、あらかじめ整備した評価用データを基に算出されるPCC (Probability of Correct Classification) を用いる。

①区分精度 (Division Accuracy)

$$P_i = M_i / N_i \tag{17}$$

②誤分類率¹²⁾ (Error Ratio)

$$F_i = \sum_j (M_{ij} + M_{ji}) / N_i \tag{18}$$

但し、 i : トレーニングデータ内の分類クラス

M_i : クラス i のうちクラス i に分類されたピクセル数

M_{ij} : トレーニングデータ内のクラス i のうちクラス j に分類されたピクセル数
(Omission errors)

M_{ji} : トレーニングデータ内のクラス j のうちクラス i に分類されたピクセル数
(Commission errors)

N_i : i 項目のトレーニングデータのピクセル数

③クラス間発散度 : D_{ij}

$$D_{ij} = \text{Log}_{10} (d_{ij}) \tag{19}$$

$$d_{ij} = (1/2) \text{Tr} [(S_i - S_j)(S_j^{-1} - S_i^{-1})] + (1/2) \text{Tr} [(S_i^{-1} + S_j^{-1})(M_i - M_j)(M_i - M_j)^{-1}]$$

但し、 S_i : クラス i でのバンド間の分散共分散行列

M_i : 項目 i における平均値行列

Tr : トレース

t : 転置行列

なお、本文では、 D_{ij} の平均値を用いて表-1で示したケース別に比較する。

④PCC²⁾

PCCとは、あらかじめ整備された評価用データを基に算出される判別効率マトリックスの対角要素(正答率)の総和平均を言う。

5. 土地被覆分類精度の比較および考察

表-2に分類精度の評価指標の値を算出した結果を整理した。この結果を基に分類精度の比較および考察を加える。なお、以下の考察においては表-1で示した英略字を用いて空間情報を表現する。

(1) 区分精度に関する考察

区分精度の平均値の高いケース順にグラフ化した結果を図-5(a)に示す。この結果を見るとDISを用いた場合の区分精度が最も高く、次いでFRA- σ 、HOM、FRA-Hの順である。フラクタル特徴量のうち分布関数を決定づける「標準偏差 σ 」が他のテクスチャに比べてかなり有効であることが判る。FRA-Hを用いた場合でもスペクトル情報のみを用いた場合に比べて区分精度が高くなっている。

(2) 誤分類率に関する考察

誤分類率の平均値の低い順にグラフ化した結果を図-5(b)に示す。FRA- σ を用いた場合の誤分類率が最も低く、次いでDIS、COR、FRA-Hの順である。区分精度による評価結果と同様に、他のテクスチャに比べてフラクタル特徴としての「標準偏差 σ 」が有用であることが判る。FRA-Hを用いた場合でも、スペクトル情報のみを用いた場合に比べて誤分類率が5%程度低下している。

(3) クラス間発散度に関する考察

クラス間発散度の平均値の高い順にグラフ化した結果を図-5(c)に示す。発散度はCONを用いたケース4が最も高く、スペクトル情報のみを用いたケース1が最も低い。しかし、表-2で示した区分精度や誤分類率、PCCの値を見ても判るように、発散度の値が高ければ、必ずしも分類精度が高くなるとは限らない。発散度は、あくまでもクラス間の分離性を表す指標にとどめる方が肝要であると言える。以上のことから前述したように多次元正規性の問題が分類精度に本質的な影響を及ぼさないことも推察できる。むしろ、トレーニングデータの代表性が問題になると言えるが、この点については本論の範囲外であるので今後の課題とする。

(4) PCCに関する考察

PCCの平均値の高い順にグラフ化した結果を図-5(d)に示す。FRA- σ を用いた場合のPCCが最も高く、次いでDIS、HOM、CORの順である。区分精度、誤分類率、発散度およびPCCといったい

ずれの指標を見ても「FRA- σ 」は上位3番以内にある。紙面の都合上、分類図を掲載することは割愛するが、FRA- σ を用いた場合の分類図は、一つの土地被覆項目内の混在ピクセルが少なくなることを確認している。この視覚的な違いについては、口頭発表時にスライドにて説明する。

一方、FRA-Hについては、PCCの値はスペクトル情報のみを用いた場合よりも若干低下し、期待された分類精度の向上は認められなかった。これは、画像のエッジ部分や種類の異なる土地被覆項目の境界部分等のように濃度差が極端に異なる箇所での自己相似パラメータHの信頼性が低下する（フラクタル性が保証されなくなる）ことによるものであると推察される。画像濃度曲面を等方的フラクタルで近似するのではなく、方向性を考慮することも必要になると考えられる。

6. 作業効率

同時生起行列を算出し、画像全体にわたってテクスチャを算出するためには、コンピュータ処理にかなりの時間（CPU時間）を要することは誰しもが経験する。空間情報をスペクトル情報に付加して分類し、実利用を目指した精度の高い土地被覆分類図を作成しようとする場合、空間情報を作成するまでの処理時間が重要な問題となる。そこで、本研究で設定した空間情報を作成するまでに要する時間を表-3に整理してみた。テクスチャ特徴量は、最も分類精度が高かった「非類似度（ケース5）」を算出する場合を掲載した。なお、CPU時間は著者が使用しているIBM3090汎用コンピュータを用いて500カラム×500ラインの画像データを処理した場合である。


この結果からフラクタル特徴量は、テクスチャ特徴量に比べてかなり短時間で算出できることが判る。土地被覆分類図を作成する上で、作業効率の面から見てもフラクタル特徴は実用性があると言える。

表-3 空間情報を作成するために要するCPU時間


空間情報	ケース		CPU時間
テクスチャ特徴	ケース5	非類似度	33分25秒
フラクタル特徴	ケース8	自己相似パラメータH	5分10秒
	ケース9	標準偏差 σ	5分10秒

表-2 土地被覆分類精度の算出結果


		スペクトル 情報のみ	スペクトル情報に付加する空間情報							
			テクスチャ特徴							フラクタル特徴
			ケース1	ケース2	ケース3	ケース4	ケース5	ケース6	ケース7	
区分 精度 (%)	水田	98.3	97.8	98.9	99.4	98.9	97.8	97.2	98.8	98.9
	畑	73.9	67.7	77.2	78.3	80.9	72.1	79.0	79.4	82.0
	森	89.0	87.9	90.8	93.6	89.6	87.3	92.5	88.4	90.8
	人工構造物	93.7	93.1	97.4	94.2	97.9	95.8	96.3	96.8	97.4
	芝地	89.9	95.2	95.2	88.5	97.1	94.2	94.7	96.6	95.7
	裸地	93.6	91.1	94.9	94.5	94.9	93.6	94.5	94.4	93.7
	水域	98.4	98.4	98.4	86.0	98.8	98.4	97.5	97.9	99.2
	平均	91.0	90.2	93.3	90.6	94.0	91.3	93.1	93.2	93.9
誤分 類率 (%)	水田	5.0	6.2	2.8	2.8	1.1	5.6	5.0	3.9	1.1
	畑	41.5	42.6	32.4	34.9	28.7	39.0	26.1	29.2	29.4
	森	35.8	37.8	28.9	47.4	27.2	39.9	27.2	31.8	26.0
	人工構造物	14.3	26.5	13.8	14.8	12.2	18.0	11.6	13.8	12.7
	芝地	25.5	22.6	16.3	19.2	11.1	19.2	16.8	12.0	5.8
	裸地	9.3	12.3	6.4	9.3	7.6	8.1	9.3	7.0	9.3
	水域	1.6	1.7	1.6	14.0	1.2	1.7	2.5	2.1	0.8
	平均	19.0	21.4	14.6	20.3	12.7	18.8	14.1	14.3	12.2
発散度 平均値 (無次元)		1.70	1.90	1.86	2.37	1.97	1.86	2.28	1.87	2.00
PCC (%)		88.1	86.4	89.1	87.3	89.8	87.2	88.4	87.7	90.2




(a) 区分精度



(b) 誤分類率



(c) 発散度



(d) PCC

図-5 土地被覆分類精度の整理

7. 結 論

本研究の成果は、次の3点にまとめられる。

①フラクタル特徴量のうち「自己相似パラメータH」よりも分布関数を決定づける「標準偏差 σ 」の方が分類精度の向上に寄与する空間情報であることが判った。

②テクスチャ特徴量では「非類似度」を用いた場合の分類精度が最も高いという従来どおりの結果となったが、フラクタル特徴量を用いた場合これと同程度の分類精度を得ることができた。

③空間情報を作成するまでの作業時間を比較した結果、フラクタル特徴量の算出時間は、テクスチャを算出する時間に比べて短く、作業効率上実用性があることが判った。

空間情報をスペクトル情報に付加して分類する方法は、特別な処理手順を踏まなくとも従来手法を用いてだれしもが容易に処理を行うことができることから、今後広く利用されることが期待される。さらに本検討の結果、フラクタル特徴量をスペクトル情報に付加して分類すれば分類精度を向上できるといった興味深い結果を得ることができた。

今後の課題として次の2点があげられる。

①フラクタルブラウン関数以外の方法によっても画像濃度曲面をモデル化する方法も考案されている。このような方法から算出されるフラクタル特徴量についても同様な検討を試みる。

②本研究では、等方的なフラクタルブラウン関数で画像濃度曲面を近似したが、画像濃度曲面は必ずしも等方的ではない。したがって、方向性を考慮した近似方法を用いる検討が必要となる。これにより、本研究ではあまり有効ではないと判断された「自己相似パラメータH」も分類精度の向上に寄与するものと期待できる。

土木・建設分野における衛星マルチスペクトルデータの利用は実用化へ向けて着実にその歩みを続けている。一方、「フラクタル」の応用は未だ尾についたばかりといっても過言ではないが¹³⁾、衛星マルチスペクトルデータの有効利用を図る上で、今までに蓄積された多くの画像処理／解析のノウハウとこのような新しい技術を融合する研究アプローチが今後益々重要になると言える。本研究が今後の衛星マルチスペクトルデータの有効利用に際して何らかの参考ともなれば幸いである。

参 考 文 献

- 1) 堀江潔也、坂田俊文：土地被覆分類におけるLANDSAT・TMおよびSPOT・HRVデータの特徴評価、写真測量とリモートセンシング、Vol.27、No.3、PP.4～PP.15、1988年
- 2) 新井康平：空間情報を用いたマルチスペクトル画像分類、日本リモートセンシング学会誌、Vol.7、No.4、PP.17～PP.24、1988年
- 3) 竹内章司、富田強：衛星画像のスペクトル情報と空間情報を併用した市街地の分類、写真測量とリモートセンシング、Vol.27、No.2、PP.6～PP.15、1988.
- 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 Terrain Classification, IEEE Trans., Vol. SMC, No. 4, PP.269～PP.285, 1976.
- 6) 中山寛、曾根光男、高木幹雄：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解析、情報処理学会論文誌、Vol.30、No.1、PP.36～PP.45、1989年
- 7) 金子博：画像特徴としてのフラクタル次元、信学技報、PRL85-30、PP.31～PP.39、1985年
- 8) 高安秀樹：フラクタル、朝倉書店
- 9) 横矢直和、山本和彦、舟久保登：フラクタルによる3次元自然複雑形状の解析とその応用、信学技法、PRU86-23、PP.19～PP.28、1986年
- 10) 大津展之：平面上のデータ点列の直線度、電子通信学会総合全国大会講演集、NO.1571、PP.124、1984年
- 11) 藤村貞夫、椿広計：リモートセンシングにおける多次元画像の分類、計測と制御、Vol.24、No.11、PP.25～PP.30、1985年11月
- 12) Russell G. Congalton, Richard G. Odeh, 1983, Assessing Landsat Classification Accuracy Using Discrete Multivariate Analysis Statistical Techniques, Photo. Eng. and Remote Sensing, Vol.49, No.12, PP.1671-1678.
- 13) 中川昌美、他2名：ライフラインシステムの震害評価におけるフラクタル次元の応用、土木学会論文集NO.428/I-15、PP.177～PP.182、1991.4