

空間情報を利用する多重分光画像分類手法の実験的評価

正員 渡辺 孝志[†] 非会員 鈴木 齊[†]

An Experimental Evaluation of the Classifiers Using Spatial Context for Multispectral Images

Takashi WATANABE[†], *Member* and Hitoshi SUZUKI[†], *Nonmember*

あらまし リモートセンシングで得られる多重分光画像を分類処理する際に、従来は主として画素単位の分類が用いられてきた。分光情報のみを利用する画素単位での分類には限界があり、分光情報以外に空間情報を利用して分類精度の向上をはかる手法がいくつか提案されてきている。しかし、これらの手法を定量的に評価し、系統的に比較した例はあまり報告されていない。本研究では、物体の空間的連続性や空間的隣接性などの局所的空間情報を利用した代表的な分類手法として、複合決定法、多数決法、適応的分類法、確率的弛緩法とその変形手法を取り上げ、その分類精度を比較評価する実験を行なった。特に、客観的で定量的な評価が下せるよう、実験には LANDSAT 画像を模擬して作成した多重分光画像データを使用した。本論文では、これらの実験結果とその検討結果について述べる。

1. ま え が き

リモートセンシングにより得られた多重分光画像から土地利用、環境調査、資源探査、災害調査などに関する各種情報を抽出する上で、分類処理は有用な手段として広く利用されている⁽¹⁾⁽²⁾。分類は各物体の分光反射特性の違いを利用して行なわれるが、従来は多くの場合、画素単位での処理がなされてきた。しかしながら、実際には、分光特性の分布の推定に誤差が避けられないことや、1画素内に複数の物体が含まれたり、分布が互いに重なり合うなどの問題があり、分光情報のみを利用した画素単位の分類には限界がある。

そこで、分光情報以外に、空間情報を利用して分類精度の向上をはかることが考えられる⁽²⁾。我々が画像を認識する際、色(分光情報)だけで対象物が何かを識別することは極めて困難であり、多くの場合、物体の形や大きさ、位置関係、テクスチャなどの空間情報を用いて認識している。従って、空間情報の利用は画素単位の分類に比べてより人間に近い分類を実現することでもあり、分類精度を向上する上でかなり有効な手段と考えられる。

空間情報を利用した分類手法はこれまでにいくつか提案されているが、それらを定量的に評価し、系統的に比較した例はあまり報告されていない。分類処理の一層の展開をはかるためにも、現段階でこのような評価を行うことは重要な検討課題である。

本研究では、物体がある程度の広がりを持って存在すること(空間的連続性)や隣接する物体の種類に制約があること(空間的隣接性)などの局所的空間情報を利用した代表的な分類手法として、次の4種類

- (1) 複合決定法⁽³⁾⁻⁽⁵⁾
- (2) 多数決法
- (3) 適応的分類法⁽⁷⁾
- (4) 確率的弛緩法⁽⁸⁾⁽⁹⁾とその変形手法⁽¹⁰⁾⁽¹¹⁾

を取り上げ、その分類精度を比較評価する実験を行った。実験には、LANDSAT 画像を模擬して作成した人工的な分光画像データを用いて、客観的な評価が下せるよう特に配慮した。本論文では、これらの実験結果とその検討結果について述べる。従来のベイズ決定⁽¹²⁾による画素単位の分類に対して、上記の分類手法はいずれも空間情報の有効性を示したが、総合的には新型弛緩法⁽¹¹⁾と複合決定法が良い成績を示し、適応的分類法がその後に続いた。

[†] 岩手大学工学部情報工学科, 盛岡市
Faculty of Engineering, Iwate University, Morioka-shi, 020 Japan

2. 評価対象に選んだ分類手法

ここでは、評価の対象とした分類手法について簡単に説明する。

本研究では、物体の空間的な連続性や隣接性などの局所的空間特性を利用する分類手法に評価対象を限定している。その他の空間情報を利用する分類手法としてテクスチャ解析⁽¹³⁾によるものがあるが、その多くはより広い空間での確率的特性に着目しており、分類の視点に質的な違いがあるので比較評価する対象から除外した。

2.1 ベイズ決定法⁽¹²⁾

ベイズ決定法は、各画素ごとに損失の期待値を最小にするような決定規則である。

いま、クラスの集合を $\Lambda = \{\lambda_1, \dots, \lambda_m\}$ 、画素の特徴ベクトルを x とする。1-0 損失関数を用いた場合には、ベイズ決定は平均誤り率を最小にする意味で最適な決定規則となるが、これは x のクラスを次式が最大となる λ_i に決定することである。

$$g_i = p(\lambda_i) \cdot p(x/\lambda_i) \quad (1)$$

ここで、 $p(\lambda_i)$ はクラス λ_i の生起する事前確率を、 $p(x/\lambda_i)$ は x の生起する条件付き確率を表す。多くの場合、 $p(x/\lambda_i)$ は正規分布 $N(\mu_i, S_i)$ に従うものと仮定し、 μ_i と S_i にはクラス λ_i を代表する訓練領域を選び、その平均ベクトルと共分散行列をそれぞれ用いている。このとき、ベイズ決定は次式

$$g_i' = 2 \log p(\lambda_i) - \log |S_i| - (x - \mu_i)^T S_i^{-1} (x - \mu_i) \quad (2)$$

を最大にするクラス λ_i に決定することとなる。ここで、 T は転置操作を表す。上式で、事前確率 $p(\lambda_i)$ を同一と仮定した場合が最ゆう法 (MLH) であり、更に、共分散行列がすべて単位行列であると仮定した場合が最短ユークリッド距離法 (MED) である。

ベイズ決定は画素単位の分類では最適な分類結果を与えるので、以下これを比較の基準に用いる。

2.2 複合決定法⁽³⁾⁻⁽⁵⁾

複合決定法は、隣接する p 個の画素に着目して損失の期待値を最小にするような決定規則である。

p 個の画素の組を p -context array と呼び、

$$\underline{x}^p = [x_1, x_2, \dots, x_p] \quad (3)$$

で表し、対応する未知の真のクラスの組を

$$\underline{\theta}^p = [\theta_1, \theta_2, \dots, \theta_p] \in \Lambda^p \quad (4)$$

で表す。ただし、分類対象画素は p 番目の画素 x_p とする。 x_p のクラスは p 個の画素 x^p のみに着目して平均

損失を最小にするよう決定される。特に、1-0 損失関数の場合には、この決定は次式

$$\underline{\theta}^p \sum_{\substack{\theta^p \in \Lambda^p \\ \theta_p = \lambda}} G^p(\underline{\theta}^p) p(\underline{x}^p / \underline{\theta}^p) \quad (5)$$

を最大にする λ を選ぶことである⁽⁴⁾。ここで、 $G(\underline{\theta}^p)$ は context 分布と呼ばれ、 $\underline{\theta}^p$ の出現確率を表す。

分布 $G(\underline{\theta}^p)$ を画像データから不偏推定する方法があるが⁽⁵⁾、相当大きな訓練データと計算時間を必要とし現実的ではない。そこで、いくつかの仮定を置いて式(5)を簡単化することが考えられる^{(3),(6)}。その結果だけを述べると、 $p(\underline{x}^p / \underline{\theta}^p)$ が \underline{x}^p 内の各画素について独立であり、 $G(\underline{\theta}^p)$ において $\theta_1, \theta_2, \dots, \theta_{p-1}$ の依存関係が無視できるものとすれば、決定は

$$p(\lambda_i) p(x_p / \lambda_i) \prod_{k=1}^{p-1} \left\{ \sum_{j=1}^m p_k(\lambda_j / \lambda_i) p(x_k / \lambda_j) \right\} \quad (6)$$

を最大にする λ_i とすれば良い。ここで、 $p_k(\lambda_j / \lambda_i)$ は、位置 p における画素の所属クラスが λ_i であるときの位置 k における画素の所属クラスが λ_j となる確率を表す。式(6)で $p=1$ とすれば、この決定は式(1)のベイズ決定に帰着する。

なお、本研究では p -context array として 3×3 近傍を用い、 $p=9$ とした。

2.3 多数決法

ベイズ決定や最ゆう法などによる分類結果から孤立点を除去する方法に多数決処理がある。これは、近傍内において多数を占めるクラスに注目画素を書き換える手法である。過度の平滑化が起らないように、書き換えに必要な画素数をしきい値として与える。この手法は簡便であり、反復使用による効果が期待される。

2.4 適応的分類⁽⁷⁾

適応的分類は、分類の対象単位を画素ではなくブロック (方形領域) とする手法である。

処理手順としては、最初、全画面をある大きさのブロックに分ける。次に、ブロックが一つのクラスにまとめて分類できるかどうかをブロックの均質性で判定する。分類できない場合にはブロックを均等に4分割し再び分類を試みる。これをすべての画素が分類されるまで繰り返す。画素まで分割されたものは最ゆう法などにより画素単位で分類する。

ブロックの均質性の判定は次の二つによる。

[判定1] 平均ベクトルによる判定

M をブロック内の画素数、 \bar{x} をブロック内の画素 $\{x_1, \dots, x_M\}$ の平均ベクトルとする。 \bar{x} のクラス λ_i に対するマハラノビス距離を d_M^i とする。

$$d_M^i = M(\bar{x} - \mu_i)^T S_i^{-1} (\bar{x} - \mu_i) \quad (7)$$

このとき、次式

$$d_M^i + \log |S_i| \quad (8)$$

を最小とするクラス λ_i を選び、それが

$$d_M^i \leq r_M \quad (r_M: \text{しきい値}) \quad (9)$$

を満足するとき、 λ_i を候補クラスとする。このようなクラスが存在しなければ、ブロックを分割する。

[判定2] 総和による判定

上記の判定1で選ばれた候補クラスを λ_i として、ブロック内の各画素 x_j とクラス λ_i とのマハラノビス距離の総和 D_M^i を求める。

$$D_M^i = \sum_{j=1}^M (x_j - \mu_i)^T S_i^{-1} (x_j - \mu_i) \quad (10)$$

このとき、適当なしきい値 t_M に対して

$$D_M^i \leq t_M \quad (11)$$

という条件を満たす場合には、このブロックは均質であるとして全体を λ_i に分類する。そうでない場合には、ブロックを分割する。

なお、仮説 H: 「ブロック内の全画素の特徴ベクトルは正規分布 $N(\mu_i, S_i)$ に従う母集団からの無作為標本である」のもとで、 d_M^i と D_M^i の分布はそれぞれ自由度 n および nM の χ^2 分布となる。従って、しきい値を求める目安として、棄却率 α_M , β_M を用いて、

$$\text{Prob}[d_M^i > r_M | H] = \alpha_M \quad (12)$$

$$\text{Prob}[D_M^i > t_M | H] = \beta_M \quad (13)$$

から r_M と t_M が定められる。

2.5 確率的弛緩法

(1) 従来型弛緩法^{(8),(9)}

この手法は、分類された結果を各画素ごとにその周囲とつじつまが合うように修正する反復的な処理からなっている。修正は、 k 回目の反復で画素 i がクラス λ に属する確率 $p_i^k(\lambda)$ を次式により更新することによって行われる。

$$p_i^{k+1}(\lambda) = \frac{p_i^k(\lambda)[1+q_i^k(\lambda)]}{\sum_{\lambda'} p_i^k(\lambda)[1+q_i^k(\lambda)]} \quad (14)$$

$$q_i^k(\lambda) = \sum_j d_{ij} \sum_{\lambda'} r_{ij}(\lambda, \lambda') p_j^k(\lambda') \quad (15)$$

ここで、 $r_{ij}(\lambda, \lambda')$ は画素 i のクラスが λ で近傍の画素 j のクラスが λ' であるときの適合係数であり、その値は区間 $[-1, 1]$ の値をとり、

$$r_{ij}(\lambda, \lambda') = \begin{cases} 1: \lambda \text{ と } \lambda' \text{ が適合する} \\ 0: \lambda \text{ と } \lambda' \text{ は独立である} \\ -1: \lambda \text{ と } \lambda' \text{ が矛盾する} \end{cases} \quad (16)$$

とされる。 d_{ij} は重み係数である。これにより、 $p_i^k(\lambda)$

は周囲とつじつまが合うように修正され、初期分類のあいまいさが次第に減少していく。最終的に、画素 i は $p_i^k(\lambda)$ を最大にするクラス λ に分類される。

本研究では、初期値 $p_i^0(\lambda)$ は

$$p_i^0(\lambda) = p(\lambda/x_i) \quad (17)$$

とした。また、8近傍のみを考慮し、重み係数は等しく $d_{ij}=1/8$ とした。

適合係数 r_{ij} は画素 i と j の相対的位置にのみ依存するものとされ、一般に次の二つがよく用いられる。

(a) 相互形 (mutual type)

$$r_{ij}(\lambda, \lambda') = c \log \frac{p_{ij}(\lambda, \lambda')}{p(\lambda)p(\lambda')} \quad (18)$$

ただし、 c は正の定数である。これは、画素 i がクラス λ で画素 j が λ' であることの同時確率 $p_{ij}(\lambda, \lambda')$ を λ および λ' の発生確率 $p(\lambda)$, $p(\lambda')$ で正規化したものの対数である。 r_{ij} が区間 $[-1, 1]$ をはみだす場合は、クリッピング操作を行うものとする。なお、本研究では $c=0.2$ とした。

(b) 相関形 (correlation type)

$$r_{ij}(\lambda, \lambda') = \frac{E[(p_i(\lambda) - \bar{p}(\lambda))(p_j(\lambda') - \bar{p}(\lambda'))]}{\sigma(\lambda)\sigma(\lambda')} \quad (19)$$

ここで、 $\bar{p}(\lambda)$ は $p_i(\lambda)$ の全画素 i に関する平均、 $\sigma(\lambda)$ はその標準偏差であり、 E は全画素 i に対する平均を表し、右辺の添字 j は i の関数として相対位置を保って変化する。式(19)は $p_i(\lambda)$ と $p_j(\lambda')$ との相関係数であり、式(16)の制約を満たす。

(2) 高型弛緩法⁽¹⁰⁾

これは、弛緩法を早く収束させるため $p_i^k(\lambda)$ を下式により更新する手法である。

$$p_i^{k+1}(\lambda) = \frac{\{p_i^k(\lambda)\}^s [1+q_i^k(\lambda)]^s}{\sum_{\lambda'} \{p_i^k(\lambda')\}^s [1+q_i^k(\lambda')]^s} \quad (20)$$

これは、1回の反復で従来の s 回分の処理を近似的に行うもので、従来型弛緩法より収束が早まるとされている。なお、本研究では $s=2$ とした。

(3) 新型弛緩法⁽¹¹⁾

これは、下式により $p_i^k(\lambda)$ を更新する手法である。

$$p_i^{k+1}(\lambda) = \sum_j c_j p_{ij}^{k+1}(\lambda) \quad (21)$$

$$p_{ij}^{k+1}(\lambda) = \frac{p_a^k(\lambda) Q_{ij}^k(\lambda)}{\sum_{\lambda'} p_i^k(\lambda') Q_{ij}^k(\lambda')} \quad (22)$$

$$Q_{ij}^k(\lambda) = \sum_{\lambda'} p_j^k(\lambda') r_{ij}(\lambda, \lambda') \quad (23)$$

$$r_{ij}(\lambda, \lambda') = \frac{p_{ij}(\lambda, \lambda')}{p(\lambda)p(\lambda')} \quad (24)$$

ここで、 c_j は総和が1となるような重み係数である。この場合、適合係数 r_{ij} の値域は $[0, \infty]$ であり、

$$r_{ij}(\lambda, \lambda') = \begin{cases} >1: \lambda \text{ と } \lambda' \text{ が適合する} \\ =1: \lambda \text{ と } \lambda' \text{ は独立である} \\ =0: \lambda \text{ と } \lambda' \text{ は矛盾する} \end{cases} \quad (25)$$

なる値をとる。この適合係数は相互形適合係数と同じ情報を用いているが、値域を制限することなく確率更新が行える。従って、従来型弛緩法より近傍の影響を強く受け、1回の反復で大きな修正が期待できる。

(4) 積型弛緩法⁽¹¹⁾

積型弛緩法は、下式により $p_i^k(\lambda)$ を更新する。

$$p_i^{k+1}(\lambda) = \frac{p_i^k(\lambda) \prod_j Q_{ij}^k(\lambda)}{\sum_{\lambda} p_i^k(\lambda) \prod_j Q_{ij}^k(\lambda)} \quad (26)$$

新型弛緩法が近傍情報 Q_{ij}^k の和形式により更新を行うのに対し、積型弛緩法は Q_{ij}^k の積形式により更新を行う。このため、近傍の影響がより強くなり、新型弛緩法より更に収束が早くなる可能性がある。

なお、反復を行わない場合、この手法は

$$p_i^0(\lambda) \prod_j Q_{ij}^0(\lambda) \quad (27)$$

を最大にするクラス λ に決定することとなる。導出は省略するが、これは2.2で述べた複合決定法での式(6)に一致することが容易に示せる。すなわち、積型弛緩法の1回目は複合決定法にはかならない。

3. 実験用画像と評価方法

本研究で評価対象に選んだ分類手法は教師つき分類であり、画像上に設定したクラスごとの訓練領域(トレーニングエリア)から、その平均値ベクトルと共分散行列を求めることが必要である。また、分類手法の評価は評価領域(テストエリア)での識別率により行われる。しかし、訓練領域および評価領域の選定は人間の判断に基づいており、同じクラスであっても訓練領域と評価領域ではデータが同じ分布をなすとは限らないため、一般に評価の客観性は保証されない。また、実際の画像による分類では訓練領域のデータの代表性や正規性が保証されないため⁽¹⁾、誤りの原因が特定できない。このような状況下では、各分類手法の定量的評価や比較を行うのは困難である。更に、狭い評価領域のみの検討では各クラスの占有面積や形状が識別に与える影響を考察することも困難である。

そこで、本研究では人工的に疑似LANDSAT画像(128×128画素、2チャンネルMSS画像)を作成して分類

手法の評価に用いることとした。疑似画像の作成手順は、まず国土地理院発行の2万5千分の1地形図(盛岡)から、図1に示すような土地利用図(6.4km×6.4km、128×128画素)を作成した。クラスは住宅地、市街地、道路、裸地、水田、畑、樹林域、水域の8クラスである。次に、盛岡市周辺の実際のLANDSAT画像(1983年6月6日撮影)を用いて各クラスの訓練領域を指定し、その平均値および共分散行列を求めた。最後に、先に作成した土地利用図に基づいて、各クラスの平均値および共分散に従う正規乱数を発生させ疑似LANDSAT画像を得た。図2に各クラスの分布特性を示す。図中の楕円は標準偏差の2倍に相当する範囲を示している。

この画像の特徴は以下の通りである。

(1) 画像の形状と統計量は、市街地周辺地域の実際のLANDSAT画像に十分類似している。

(2) 画像全体に渡って画素の正しいクラスが分かっており、正確に識別率が求められる。

(3) 訓練データは各クラスの統計量を正しく反映している(代表性の確保)。

(4) 各クラスの画素データは正規分布に従い(正規性の確保)、その出現は確率的に独立である。

(5) 各画素は1クラスによって占められ、ミクスチャは存在しない。

従って、この画像データでは分類手法の誤分類は各クラスの分布の重なりによるものに限られ、各手法の客観的で定量的な評価が可能となる。なお、各クラスの識別率の評価は下式により行った。

$$(\text{クラス識別率}) = \frac{(\text{正しく識別された画素数})}{(\text{クラスの全画素数})} \quad (28)$$

以下、各クラスの識別率の単純平均をクラス平均識別率と呼び、各クラスの面積率で重みづけした荷重平均を全体識別率とよぶ。

4. 実験と結果

ここでは、2.に述べた分類手法に対して、前章で説明した実験用画像を用いて行った評価実験の結果について述べる。なお、実験に使用した計算機は三菱電機のMX/3000である。

表1に各分類手法のクラス識別率、クラス平均識別率、全体識別率、処理時間を示す。括弧内は面積率を示す。また、図3に各手法の分類結果の一部を示す。同図の(a)は参照パターンであり、場所は図1の右中央




図1 盛岡の土地利用図(参照パターン)

Fig. 1 Land use map of Morioka (Reference pattern).




図2 各クラスの分布状態

Fig. 2 Distributions of data of classes.

部の住宅地域である。

(1) ベイズ決定

表1において、事前確率 $p(\lambda_i)$ を図1の参照画像から求めた理想的な場合がベイズ決定1、最ゆう法の分類結果から求めた実際的な場合がベイズ決定2である。全体識別率では、ベイズ決定1、ベイズ決定2、最ゆう法、最短ユークリッド距離法の順に高い値を示した。クラス別に見ると、ベイズ決定では住宅地、道路、水田など面積が小さくて分布が他と重なるクラスの識別率が低くなっている。このため、クラス平均識別率では最ゆう法の方が良い結果を得ている。これは、ベイズ決定法では各クラスの事前確率を考慮するため、事前確率の小さなクラスの損失が過小評価されるためである。また、図3(b)より、ベイズ決定ではごま塩雑音状に誤分類が多数発生していることが分かる。

(2) 複合決定法

表1より、複合決定法はすべてのクラスで識別率がベイズ決定2を上まわり、最ゆう法に対しても道路を除いて上まわった。その結果、クラス平均識別率と全体識別率のいずれでも最ゆう法とベイズ決定を上まわる高い識別率を示した。道路の識別率が最ゆう法をわずかに下まわったのは、面積率が小さいことに加えて、線状パターンのため近傍の中で多くの画素を占められないからである。また、図3(c)より、ごま塩雑音状の誤分類も除去され、領域の輪郭もかなり修復されていることが分かる。

(3) 多数決法

ベイズ決定2を初期分類とした。図4に、多数決法における識別率としきい値 T の関係を反復回数とともに示す。ここで、近傍は 3×3 画素である。最適なしきい値は過半数の $T=5$ であり、しかも2回目以降の反復の効果はなかった。図5に近傍の大きさと識別率の関係を示す。しきい値は近傍の画素数の過半数としたが、 3×3 の場合が最も良い結果を示した。表1にはこの最も良い場合を示した。

表1と図3(d)とから、多数決法は孤立点除去による識別率の改善が認められたが、線状のクラスが浸食されるなどすべてのクラスに有効とはいえない。更に、境界部における修正には原理的に限界がある。また、反復使用することで修正の伝搬が起これ、それによる識別率の改善が期待されたが、過度の平滑化のために識別率が低下することが判明した。

(4) 適応的分類

図6にブロック化のしきい値(棄却率)に対するブロック化率および処理時間の関係を示す。これより、棄却率を大きくするとブロック化の基準が厳しくなり画素単位の分類に近づくことが分かる。図7に棄却率と識別率の関係を示す。棄却率0.1のとき全体識別率が最も高く、それより離れると識別率が低下する。これは棄却率を小さくするとブロックが大きくなって過度の平滑化が行われる一方、棄却率が1に近づくとき画素単位の分類となり最ゆう法に近づくためである。なお、最適なブロック化が行われる棄却率0.1の場合には、処理時間は最ゆう法より小さい。

表1には、最適な棄却率0.1の場合の値を示した。これより、適応的分類は識別率がほぼすべてのクラスで最ゆう法を上まわった。その結果、クラス平均識別率と全体識別率のいずれでも最ゆう法とベイズ決定を上まわった。また、図3(e)により、ごま塩雑音状の誤分

表1 各分類手法の識別率の比較

クラス (面積率 %)	最短 距離法	最尤法	ベイズ 決定1	ベイズ 決定2	複合 決定法	多数決	適応的 分類	従来型 弛緩法	高速型 弛緩法	新 型 弛緩法
住宅地 (4.45)	86.42 (9.97)	82.60 (8.98)	36.78 (2.46)	76.66 (7.71)	95.05 (5.96)	90.95 (5.91)	90.00 (6.54)	98.72 (5.03)	81.61 (7.78)	98.02 (6.69)
市街地 (20.01)	61.82 (13.95)	64.83 (14.26)	95.35 (23.48)	76.72 (17.39)	81.81 (17.09)	86.47 (20.00)	79.01 (16.75)	88.56 (18.26)	77.43 (17.29)	82.05 (16.93)
道路 (2.75)	61.52 (7.97)	59.96 (5.42)	27.29 (1.21)	39.37 (2.29)	54.36 (4.66)	29.08 (1.29)	58.61 (4.63)	57.52 (4.14)	42.51 (2.25)	65.32 (3.00)
裸地 (3.62)	78.83 (2.80)	90.71 (3.34)	90.36 (3.30)	87.78 (3.17)	97.07 (3.66)	89.16 (3.26)	94.15 (3.55)	97.25 (3.52)	88.47 (3.17)	98.80 (4.17)
水田 (5.97)	53.51 (18.85)	53.90 (12.68)	5.58 (0.87)	39.08 (7.06)	74.88 (9.53)	31.76 (3.77)	67.47 (8.97)	84.99 (10.00)	43.02 (7.43)	88.16 (9.78)
畑 (29.09)	69.49 (30.61)	73.10 (25.34)	85.25 (31.98)	78.12 (27.73)	86.75 (27.26)	84.62 (28.34)	82.91 (26.95)	89.47 (27.92)	79.20 (27.56)	88.42 (27.30)
樹林域 (29.39)	26.12 (11.83)	69.46 (25.42)	84.49 (32.26)	81.42 (30.19)	85.24 (27.12)	89.53 (32.78)	87.15 (27.97)	84.99 (26.45)	82.27 (30.08)	87.41 (27.22)
水域 (4.72)	86.58 (4.02)	94.61 (4.55)	94.21 (4.43)	94.47 (4.45)	99.47 (4.71)	96.58 (4.65)	96.71 (4.64)	99.61 (4.69)	94.37 (4.43)	100.00 (4.90)
クラス平均識別率	65.54	73.64	64.91	71.70	84.33	75.14	81.45	87.66	73.66	88.52
全体識別率	55.81	70.83	78.92	76.32	84.99	83.16	81.79	87.96	77.61	87.52
C P U 時間	-----	-----	35 sec	35 sec	5 min	41 sec	30 sec	108 min	41 min	23 min




図3 各分類手法における分類図

(a)参照パターン (b)ベイズ決定 (c)複合決定 (d)多数決
(e)適応的分類 (f)確率的弛緩法 ($k=28$) (g)新型弛緩法 ($k=5$)

Fig. 3 Classification maps of the tested methods.

(a) Reference (b) Bayes 2 (c) Compound (d) Majority
(e) Adaptive (f) Probabilistic Relaxation ($k=28$) (g) New relaxation ($k=5$)



図4 多数決法のしきい値 T と識別率Fig. 4 Accuracy of the majority decision for different thresholds T .

図5 多数決法の窓サイズと識別率

Fig. 5 Accuracy of the majority decision for different window sizes.




図6 適応的分類のブロック化率とCPU時間
Fig. 6 Blocking rate and CPU time of the adaptive classification.




図7 適応的分類の識別率
Fig. 7 Accuracy of the adaptive classification.

類も良く除去されていることが分かる。

以上から、適応的分類は分類精度の向上と処理時間の短縮に効果が認められた。しかし、ブロックの形状が固定(方形)しているので、点状や線状の物体の識別および境界部の修正に関しては従来の画素単位の分類手法を越えることはできない。

(5) 確率的弛緩法

図8と図9に、相互形と相関形の適合係数を用いた従来型弛緩法による識別率の変化を示す。相互形では全クラスの識別率が改善されている。しかし、相関形では事前確率の小さなクラス(住宅地、道路、水田)が事前確率の大きな他の近接しているクラス(畑、市街地)に浸食されて、識別率が低下していくことがわかる。この原因を表2の適合係数 r_{ij} から考えてみる。ここで、画素 j は画素 i の右隣りである。相互形では r_{ij} (裸地、裸地)=0.5794に対し、 r_{ij} (畑、畑)=0.1900と面積率の大きなクラスの適合係数が低く抑えられている。一




図8 従来型弛緩法の識別率(相互形適合係数)
Fig. 8 Accuracy of the probabilistic relaxation. (Mutual type coefficients)

方、相関形では r_{ij} (裸地、裸地)=0.6413、 r_{ij} (畑、畑)=0.6496と面積の影響を受けない。このため、相関形では面積に関する補正が行われず、初期画像において多数を占めたクラスがそのまま増大したものと考えられる。また、図10に初期値 $p_i^0(\lambda)$ と識別率の関係を示す。ここで、初期値は最短ユークリッド距離法、最尤法、ベイズ決定1、2に相当する $p(\lambda/x_i)$ を用い、適合係数は相互形でその値は参照画像から求めた。いずれの場合も初期分類から改善されているが、修正結果の良否はかなり初期値に依存することが分かる。ベイズ決定1と2が途中で逆転するのは、ベイズ1では小面積のクラスが過小評価され、弛緩法によっても修復できないためである。図3(f)に相互形適合係数を用いた場合の分類結果を示す。孤立点が除去されるだけでなく、境界部や線状部分も極めて良好に修正されていることが分かる。

図11に、高速型弛緩法の識別率の変化を示す。図から、収束は早まるが、ほとんど修正が行われなことが分かる。この結果は、同一情報の反復使用では分類精度の改善が望めないことを示している。

図12に、新型弛緩法の識別率の変化を示す。特に、住宅地、道路、水田など初期分類において $p(\lambda)$ が小さく識別率の低かったクラスが修正された。これらは従来型弛緩法ではあまり修正がなされなかったクラスである。このことは、適合係数の値域が $[0, \infty]$ の範囲であり、 $p(\lambda)$ が小さい程 $r_{ij}(\lambda, \lambda')$ が大きくなる傾向があるためと考えられる。また、識別率は5回目で最高に達し、従来型弛緩法より高速である。しかし、それ以降では識別率は低下する。従って、新型弛緩法では終了判定が重要となる。図3(g)に最良の場合の分類結




図9 従来型弛緩法の識別率（相関形適合係数）
Fig. 9 Accuracy of the probabilistic relaxation. (Correlation type coefficients)




図11 高速型弛緩法の識別率
Fig. 11 Accuracy of the speedy relaxation.




図10 従来型弛緩法の識別率と初期値
Fig. 10 Overall accuracies of the relaxation method for initial probabilities.




図12 新型弛緩法の識別率
Fig. 12 Accuracy of the new relaxation.

表2 適合係数の値

(a) 相互形適合係数		住宅地	市街地	道路	裸地	水田	畑	樹林域	水域
住宅地	0.5912	-1.0000	0.1725	-0.1066	-0.6047	-0.6048	-0.4081	-1.0000	
市街地	-0.5745	0.2762	0.0671	-0.0579	-0.2300	-0.2537	-0.4592	-0.4356	
道路	0.1343	0.0719	0.3155	0.0922	0.0536	-0.0709	-0.1358	-0.4664	
裸地	-0.0044	0.0699	-0.0099	0.5794	-0.7067	-0.3305	-0.3325	-0.1631	
水田	-1.0000	-0.2403	0.1052	-0.7067	0.4795	-0.2400	-0.1360	-1.0000	
畑	-0.4872	-0.2705	-0.1051	-0.3880	-0.2151	0.1900	-0.1603	-0.1886	
樹林域	-0.5543	-0.4571	-0.1125	-0.3521	-0.2396	-0.1691	0.1995	-0.2266	
水域	-1.0000	-0.5053	-0.3853	-0.0511	-1.0000	-0.1706	-0.2670	0.5531	

(b) 相関形適合係数		住宅地	市街地	道路	裸地	水田	畑	樹林域	水域
住宅地	0.8485	-0.1067	0.0496	-0.0175	-0.0462	-0.1317	-0.1235	-0.0480	
市街地	-0.1019	0.7482	0.0335	-0.0249	-0.0795	-0.2305	-0.2953	-0.0987	
道路	0.0347	0.0373	0.1084	0.0189	0.0152	-0.0322	-0.0552	-0.0338	
裸地	-0.0009	-0.0274	-0.0016	0.6413	-0.0447	-0.1004	-0.1033	-0.0240	
水田	-0.0542	-0.0865	0.0293	-0.0475	0.6353	-0.1129	-0.0829	-0.0560	
畑	-0.1167	-0.2335	-0.0440	-0.1068	-0.0978	0.6496	-0.2342	-0.0870	
樹林域	-0.1332	-0.2857	-0.0466	-0.1041	-0.1050	-0.2357	0.7047	-0.0974	
水域	-0.0480	-0.1011	-0.0320	-0.0100	-0.0820	-0.0820	-0.1083	0.7377	




図 13 積型弛緩法の識別率

Fig. 13 Accuracy of the multiplicative relaxation.

果を示す。境界部や線状部分もかなり良く復元されている。

図 13 に、積型弛緩法の結果を示す。全体およびクラス平均識別率とも 1 回目 が最も良く、反復にしたがい識別率は減少している。1 回目は複合決定法と同じであるので、この改善は複合決定法によるものにほかならない。このことから、積型弛緩法の使用は意味がなく、複合決定法として使用されるべきである。

5. 分類手法の比較検討

各分類手法について、パラメータを変え最良の結果が得られた場合の識別率を図 14 に示す。ここで、事前確率は最尤法の結果から推定し、適合係数は毎回直前の結果から求めた。この詳細を表 1 に示す。

図 14 から、空間情報を利用するすべての手法でベイズ決定法より高い識別率が得られたことが分かる。表 1 から、全体およびクラス平均識別率とも新型弛緩法ならびに従来型弛緩法（相互型適合係数）が高く、次いで複合決定法、適応的分類の順となっている。これは、前の 3 手法が境界部や線状および小面積のクラスの修正が可能なためと考えられる。適応的分類は境界部や線状のクラスに対しては最尤法と同程度の結果しか得られないが、全体およびクラス平均識別率とも良い値を示した。多数決処理では、道路や水田などが周囲に浸食され識別率が低下したため、クラス平均識別率はあまり改善されていない。その他、高速型と積型の弛緩法についてはあまり効果が認められなかった。

処理時間では、適応的分類が最も短くベイズ決定法より若干速い。多数決処理は、ベイズ決定後の処理に要する時間が約 6 秒であり、高速な手法といえる。一




図 14 各分類手法の全体識別率の比較

Fig. 14 Comparison of overall accuracies of the tested classifiers.

表 3 各分類手法の総合評価

分 類 手 法	全 体 識別率	クラス平 均識別率	処理時間	所 要 メモリ
複合決定法	◎ ^{*1}	◎	○	△
多数決法	○	△	◎	◎
適応的分類法	○	○	◎	◎
従来型弛緩法 (相互型適合係数)	◎	◎	×	△
(相関型適合係数)	○	○	×	△
高速型弛緩法	△	△	△	△
新型弛緩法	◎	◎	△	△
積型弛緩法 ^{*2}	(◎)	(◎)	(○)	(△)

*1: 記号の意味は、◎(秀)、○(良)、△(可)、×(不可)である。

*2: 積型弛緩法は 1 回目のみ有効で、この場合複合決定法に一致する。

方、従来型弛緩法は 1 回の処理に約 4.5 分とベイズ決定法の約 8 倍を要し、更に、有効性が認められるまでに多くの反復が必要なため、実用性に欠けるといえる。新型弛緩法は 3～5 回で最高識別率に達して弛緩法の高速度化が図られた。また、複合決定法は弛緩法の 1 回分の処理時間であり、実画像に対しても十分適用できると考えられる。しかし、弛緩法および複合決定法は大量のメモリを必要とするため、主記憶容量の小さい計算機では処理時間が犠牲となる場合がある。

以上をまとめると表 3 となる。これから、実用的な手法としては、新型弛緩法と複合決定法が高い分類能力を示し、適応的分類がその後に続くといえる。ただし、新型弛緩法は収束の保証がないため何らかの終了判定が必要である。

6. む す び

本論文では、局所的空間情報を用いる多重分光画像の代表的な分類手法を取り上げ、その分類精度について行った比較実験結果を報告した。評価に用いた画像データは実際の LANDSAT 画像を模擬した人工画像であり、データの正規性や独立性、訓練データの代表性などが保証されており、主観的要因を排して客観的で定量的な評価が得られたものとする。

実験の結果、評価対象に選んだ分類手法は、従来の画素単位のベイズ決定による分類に対し、いずれも空間情報利用の有効性を示した。総合的には、新型弛緩法と複合決定法が高い分類能力を示し、適応的分類法がその次に位置するという結果を得た。ただし、これらの手法を適用する際に、各クラスの平均値や共分散行列などの統計量に関して精度良い推定が相変わらず求められることはいうまでもない。

なお、本研究では各分類手法を提案された元の形で忠実にプログラム化したが、本実験を通して、各手法の問題点が明確化され、改良すべき余地のあることも判明している。現在、各分類手法の改良について検討を進めているが、その結果については別の機会に報告したいと考えている。

謝辞 日頃ご指導をいただく本学工学部情報工学科横山隆三教授、ならびに実験にご協力をいただいた同学科応用情報学研究室の諸氏に感謝する。

文 献

- (1) 藤村, 椿: “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, **24**, 11, pp. 25-30 (昭 60).
- (2) P. H. Swain: “Advanced interpretation techniques for earth data information system”, Proc. IEEE, **73**, 6, pp. 1031-1039 (1985).
- (3) J. R. Welch and K. G. Salter: “A context algorithm and image interpretation”, IEEE Trans. Syst. Man, Cybern., **SMC-1**, 1, pp. 24-30 (1971).
- (4) P. H. Swain, S. B. Varcleman and J. C. Tilton: “Contextual classification of multispectral image data”, Pattern Recognition, **13**, 6, pp. 429-441 (1981).
- (5) J. C. Tilton, S. B. Varcleman and P. H. Swain: “Estimation of context for statistical classification of multispectral image data”, IEEE Trans. Geoscience and Remote sensing, **GE-20**, 4, pp. 445-452 (1982).
- (6) 服部, 石井, 鈴木: マルチスペクトル画像の分類の検討, 信学論 (D), **J67-D**, 3, pp. 367-374 (昭 59-03).
- (7) 高橋, 藤村, 豊田: “画像の局所的均質性を利用した多重分光画像の適応的分類”, 計測自動制御学会論文集, **21**, 2, pp. 164-171 (昭 60).
- (8) J. O. Eklund, H. Yamamoto and A. Rosenfeld: “A

relaxation method for multispectral pixel classification”, IEEE Trans. Pattern Anal. Mach. Intell., **PAMI-2**, 1, pp. 72-75 (1980).

- (9) R. Harris: “Contextual classification postprocessing of LANDSAT data using a probabilistic relaxation model”, Int. J. Remote Sensing, **6**, 6, pp. 847-866 (1985).
- (10) S. W. Zucker, E. V. Krishnamurthy and R. L. Haar: “Relaxation processes for scene labeling: Convergence, speed and stability”, IEEE Trans. Syst., Man. & Cybern., **SMC-8**, 1, pp. 41-48 (Jan. 1978).
- (11) S. Peleg: “A new probabilistic relaxation scheme”, IEEE Trans. Pattern Anal. Mach. Intell., **PAMI-2**, 4, pp. 362-369 (1980).
- (12) T. W. Anderson: “An introduction to multivariate statistical Analysis”, John Wiley & Sons, Inc. (1958).
- (13) R. M. Haralick, K. Shanmugam and I. Dinstein: “Textural features for image classification”, IEEE Trans. Syst. Man. & Cybern., **SMC-3**, pp. 610-621 (1973).

(昭和 61 年 10 月 22 日受付)

渡辺 孝志



昭 44 東北大・工・通信卒, 昭 46 同大学院修士課程了, 同年同大助手, 昭 47 株式会社日立製作所入社, 昭 55 東北大・大学院博士課程了, 工博, 同年岩手大・工・情報助手, 昭 57 同講師, 現在, 同助教授。この間, パターンの学習認識, 集積回路の CAD システム, セル構造オートマトン, 画像処理の研究に従事, 情報処理学会, 計測自動制御学会, 日本リモートセンシング学会各会員。

鈴木 斉



昭 60 岩手大・工・情報卒, 現在, 同大学院修士課程在学中, この間, リモートセンシング画像の分類処理, 画像処理の研究に従事, 情報処理学会会員。