

## 多重分光画像における複合決定法と適応的分類法の検討

正員 渡辺 孝志<sup>†</sup>      非会員 鈴木 齊<sup>†</sup>

### A Study on Compound Decision Theory and Adaptive Classification for Multispectral Image Data

Takashi WATANABE<sup>†</sup>, *Member* and Hitoshi SUZUKI<sup>†</sup>, *Nonmember*

あらまし 先に、筆者らは局所的空間情報を利用する多重分光画像分類手法の評価実験について報告したが、その中で、複合決定法と適応的分類法は識別率と処理時間の両面で比較的良好な結果を示した。本論文では、この2手法について更に高い識別率をあげようような改良法を検討し、その効果を検証する実験結果について述べた。具体的には、複合決定法については context 分布を3画素間の依存関係に基づいて推定する改良法を、適応的分類法については分類領域の形状を方形以外にも拡張して「適応性」を高めた拡張形適応的分類法を新たに提案した。特に、拡張形適応的分類法はベイズ決定などの画素単位分類に比べてかなり高い識別率をあげうる実用性の高い手法であり、今後標準的な分類手法として幅広く利用されることが期待される。

#### 1. ま え が き

リモートセンシングにおいて、多重分光画像データから土地利用、環境調査、資源探査、災害調査などの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<sup>(1)</sup>。従って、分類精度を上げることはリモートセンシング技術の有効性を高める上での重要な検討課題であり、これまでに多くの研究がなされてきた<sup>(2)</sup>。

従来、分類手法としてはベイズ決定法、最ゆう法、決定木分類などの分光情報のみを用いる画素単位の分類が一般的に利用されているが、画素単位の分類では、その識別能力に限界がある。分光情報以外に画像に含まれている、物体の形や大きさ、テクスチャ、位置関係などの空間情報を利用することは、そのような限界を乗り越えるための有力なアプローチである<sup>(3)</sup>。

筆者らは、先に、空間的な連続性や隣接性などに基づく局所的な空間情報を利用する分類手法として、多数決法、複合決定法、適応的分類法、確率的し緩法の4種類を取り上げ、その識別能力に関して統一的な評

価実験を行った<sup>(4)</sup>。その中で、複合決定法と適応的分類法は識別率と処理時間の両面で比較的良好な結果を示したが、これら二つの分類手法についても検討すべき点や改良すべき点のあることが評価実験を通して明らかとなった。

複合決定法<sup>(5)-(8)</sup>は、隣接する複数個の画素の集まり(context array)に着目して決定にかかわる損失の期待値を最小とするような決定規則であり、空間情報を利用する分類手法の中では統計論的な意味での最適性に関する裏付けが最もよくなされている手法といえる。しかしながら、この手法を適用する上で必要となる context 分布を正確に推定することは極めて難しく、実際には何らかの仮定をおいて分布を簡略化して推定しなければならない。従来は2画素間の依存関係で context 分布を推定していたが、その効果や妥当性など、実用化の上で考慮すべき事項に関する検討はまだ十分になされていない。

適応的分類法<sup>(9)</sup>は、対象物が画像上で連続した領域を占めるという性質を利用して、分類の単位を画素でなく方形領域とした手法である。この手法は同じ領域単位分類である ECHO 法<sup>(10)</sup>に比べて処理時間や所要メモリ量の上で有利な手法であるが、分類に用いる領域の形状が方形に限定されている点で「適応性」がまだ

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

十分ではなく検討の余地を残している。

本論文では、まず複合決定法について、分類に用いる context array のサイズを変化させた場合の識別率への影響を検討すると共に、新たに3画素間の依存関係を考慮した context 分布の推定法を提案し、その効果を評価実験で検証した。次に、適応的分類法について、分類に用いる領域の形状を方形以外にも拡張して識別率の向上を図る拡張形適応的分類法を提案した。評価実験の結果、拡張形適応的分類法は従来の適応的分類法に比べてかなり高い識別率が得られることを確認した。

## 2. 評価に用いた画像データ

分類手法の識別能力を実験で検証しようとする際に画像データとして実際の多重分光画像を用いると、人間の判読に依存した判定作業が不可避となるために主

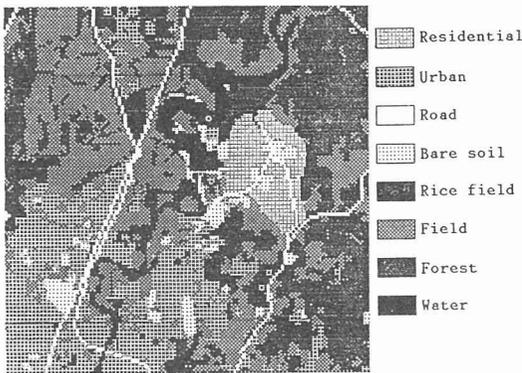


図1 盛岡の土地利用図(参照パターン)  
Fig. 1 Land use map of Morioka(Reference pattern).

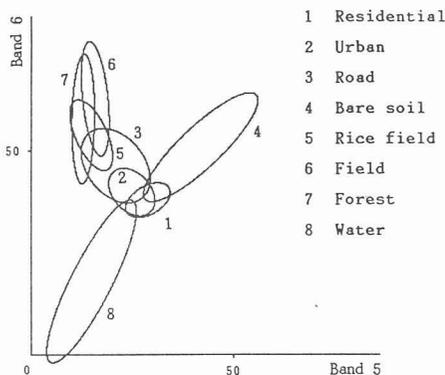


図2 各クラスの分布状態  
Fig. 2 Distributions of data of classes.

観的要素が入りやすく評価の客観性が保証されないという問題が生ずる。そこで、各分類手法の客観的かつ定量的な評価を得るために、本研究でも先の評価実験で使用した擬似 LANDSAT MSS 画像<sup>(4)</sup>を用いることとした。

この擬似画像は次のようにして作成した。まず、国土地理院発行の2万5千分の1地形図(盛岡)を50m幅のメッシュに分割して、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。クラスの種目は住宅地、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、この地域が含まれている実際の LANDSAT MSS 画像(1983年8月6日撮影, Band 5, 6)から各クラス  $w$  の平均値ベクトル  $\mu_w$ 、共分散行列  $S_w$  を求めた後、図1に基づいて正規分布  $\{N(\mu_w, S_w)\}$  に従う2次元正規乱数を発生させ、これを画素値とすることで評価用画像データを得た。この画像データにおける各クラスの分布特性を図2に示すが、図中のだ円は標準偏差の2倍に相当する範囲を示している。なお、この画像データについての詳細は参考文献<sup>(4)</sup>を参照されたい。

また、各クラスの識別率の評価式としては

$$(\text{クラス識別率}) = \frac{(\text{正しく識別された画素数})}{(\text{クラスの全画素数})} \quad (1)$$

を用いた。以下、クラス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付けした加重平均を全体識別率と呼ぶことにする。

## 3. 複合決定法の検討

### 3.1 原理

クラス数を  $m$ 、クラスの集合を  $\mathcal{Q} = \{1, 2, \dots, m\}$  とする。画像は  $N$  個の画素からなるものとし、 $i$  番目の画素の観測値 ( $n$  次元ベクトル) を  $x_i$  で表す。未知の真のクラスが  $\theta_i$  である観測値  $x_i$  をクラス  $a_i$  と決定する際の損失を  $L(\theta_i, a_i)$  とすれば、画像全体の平均損失の期待値は

$$R = E \left[ \frac{1}{N} \sum_{i=1}^N L(\theta_i, a_i) \right] \quad (2)$$

で与えられる。従って、 $R$  が最小となるように  $a_i$  を決定すればよい。 $a_i$  は画像全体の観測値を用いて決定するのがよいと考えられるが、実現は困難である。そこで、隣接する  $p$  個の観測値のみから決定することを考える。この  $p$  個の画素の組合せを  $p$ -context array という<sup>(6)</sup>。図3に  $p$ -context array の例を示すが、分類対象の画素は  $p$  番目の要素とする ( $p=3$  は対称性が悪いの

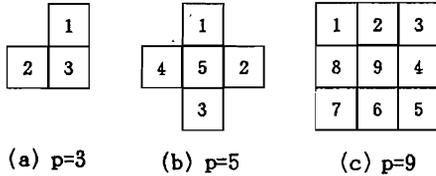


図3  $p$ -context array の例  
Fig. 3 Examples of  $p$ -context arrays.

あまり用いられることはない。このとき、 $p$ -context array を

$$X = [x_1, x_2, \dots, x_p] \quad (3)$$

で表し、対応する未知の真のクラスの組を

$$\Theta = [\theta_1, \theta_2, \dots, \theta_p] \in \Omega^p \quad (4)$$

で表せば、 $X$  のみに着目して平均損失の期待値を最小とすように決定するには、次式

$$\sum_{\Theta \in \Omega^p} G(\Theta) L(\theta_p, a_p) p(X/\Theta) \quad (5)$$

を最小とすように注目画素  $x_p$  のクラス  $a_p$  を決定すればよい<sup>(6)</sup>。ここで、 $G(\Theta)$  は  $\Theta$  の出現確率を表し、context 分布と呼ばれる。 $p(X/\Theta)$  は条件付き確率を表す。特に、1-0 損失関数

$$L(\theta, a) = \begin{cases} 0 & \theta = a \\ 1 & \theta \neq a \end{cases} \quad (6)$$

を用いると、この決定は  $x_p$  のクラスとして次式

$$d(w) = \sum_{\Theta \in \Omega^p} G(\Theta) p(X/\Theta) \quad (7)$$

$$E_w = \{\Theta \in \Omega^p \mid \theta_p = w\}$$

を最大にするクラス  $w \in \Omega$  を選ぶことに帰着する。この決定は、 $p$ -context array  $X$  を考慮して  $x_p$  のクラスを決定する決定規則の中で、平均誤り率を最小とする意味で最適な決定規則である<sup>(7)</sup>。

しかし、式(7)に現れる  $G(\Theta)$  と  $p(X/\Theta)$  は一般に未知であり、何らかの方法により画像から推定する必要がある。これらは  $p$  次元の分布であり、 $\Theta$  として出現可能なパターン数は  $m^p$  個となり、その計算量と所要メモリ量は  $p$  に対し指数的に増大し、直接推定することは極めて困難であり、現実的とはいえない。そこで、何らかの仮定を置いて分布の推定を簡略化することが考えられてきた。

従来用いられてきた仮定は次の二つである。

[仮定 1]<sup>(5)</sup>  $p(X/\Theta)$  について、次式が成立するものとする。

$$p(X/\Theta) = \prod_{j=1}^p p(x_j/\theta_j) \quad (8)$$

[仮定 2]<sup>(5),(8)</sup>  $G(\Theta)$  について、次式が成立するものとする。

$$G(\Theta) = p(\theta_p) \prod_{j=1}^{p-1} p(\theta_j/\theta_p) \quad (9)$$

仮定 1 は、 $p(X/\Theta)$  において、画素値  $x_j$  の発生がその所属するクラス  $\theta_j$  にのみ依存することを意味する。仮定 2 は、 $G(\Theta)$  において、 $\theta_1, \theta_2, \dots, \theta_{p-1}$  間の依存関係が無視できることを意味する。これらはかなり強い仮定であるので、厳密には成立しないものと考えられるが、ここでは分布を近似するという立場で導入する。

式(8), (9)を用いると式(7)は次式となる。

$$d(w) = p(\theta_p = w) p(x_p/\theta_p = w) \cdot \prod_{j=1}^{p-1} \left\{ \sum_{w' \in \Omega} p(\theta_j = w'/\theta_p = w) p(x_j/\theta_j = w') \right\} \quad (10)$$

ここで、 $p(\theta_p = w)$  はクラス  $w$  の生起する事前確率であり、 $p(\theta_j = w'/\theta_p = w)$  は注目画素  $x_p$  の真のクラスが  $w$  であるときに近傍画素  $x_j$  の真のクラスが  $w'$  となる条件付き確率である。

### 3.2 高次の依存関係による $G(\Theta)$ の推定

仮定 2 では、分布  $G(\Theta)$  の推定に注目画素との 2 画素間の依存関係 ( $p(\theta_j/\theta_p)$ ) のみを考慮した。この場合、面的な広がりをもつクラスではあまり問題とならないが、道路などの線状に分布するクラスの識別能力は十分でないと考えられる。そこで、同一直線上に存在する 3 画素間の依存関係を考慮した  $G(\Theta)$  の推定法を新たに提案する。但し、本方法で対象とする context array は図 3 の  $p=5, 9$  とする。

この場合、仮定 2 の代わりに次を用いる。

[仮定 2']  $q = (p-1)/2$  とするとき、 $G(\Theta)$  において、 $\theta_p, \theta_j, \theta_{j+q} (1 \leq j \leq q)$  以外の依存関係は無視できるとする。すなわち、次式が成立するものとする。

$$G(\Theta) = p(\theta_p) \prod_{j=1}^q p(\theta_j, \theta_{j+q}/\theta_p) \quad (11)$$

明らかに、仮定 2' は仮定 2 より緩い条件となっており、式(9)は式(11)の特別な場合 ( $\theta_j$  と  $\theta_{j+q}$  が独立) に相当している。

式(8)と式(11)から、式(7)は式(12)となり、 $x_p$  は次式を最大にするクラス  $w$  に決定される。

$$d(w) = p(\theta_p = w) p(x_p/\theta_p = w) \cdot \prod_{j=1}^q \left\{ \sum_{w'} \sum_{w''} p(\theta_j = w', \theta_{j+q} = w''/\theta_p = w) \right\}$$

$$p(x_j/\theta_j=w')p(x_{j+q}/\theta_{j+q}=w'') \quad (12)$$

ここで、 $p(\theta_j=w', \theta_{j+q}=w''/\theta_p=w)$ は、注目画素  $x_p$ の真のクラスが  $w$  であるときに同一直線上にある近傍画素  $x_j, x_{j+q}$ の真のクラスがそれぞれ  $w', w''$  となる条件付き確率である。

### 3.3 実験結果と検討

実験には三菱電機の計算機 MX/3000 を用いた。表 1には、評価を行った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、処理時間の実験結果を示す。括弧内の数字はそのクラスが画像全体に占める面積率を示す。実用的立場から、ベイズ決定法と複合

決定法で用いる確率  $p(\theta_p), p(\theta_j/\theta_p), p(\theta_j, \theta_{j+q}/\theta_p)$ は最ゆう法による分類結果から算出した。

複合決定法の context array のサイズと識別率の関係を図 4 に示す。  $p=1$  の場合は従来のベイズ決定法であり、 $p=3, 5, 9$  は context 分布を仮定 2 で推定した場合である。  $p=9^*$  は、  $p=9$  の context 分布を仮定 2' で推定した場合である。図 4 からサイズが大きいくほど識別率は向上する傾向があるといえるが、  $p=5$  から  $p=9$  では水田と道路を除いてあまり変化していない。道路の識別率が低下したのは、道路の幅が 1 画素分しかないことと道路の走る方向が局所的には縦横のものが多いことによるものと考えられる。水田の識別率が他と比

表 1 各分類手法の識別率の比較

クラス (面積率 %)	最ゆう法	ベイズ 決定法	複合 決定法 $p=5$	複合 決定法 $p=9$	複合 決定法 $p=9^*$	適応的 分類	拡張型適 応的分類 4 pixels	拡張型適 応的分類 3 pixels
住宅地 (4.45)	82.60 (8.98)	76.66 (7.71)	92.50 (6.54)	95.05 (5.96)	94.20 (6.00)	90.00 (6.54)	91.37 (6.55)	90.95 (5.93)
市街地 (20.01)	64.83 (14.26)	76.72 (17.39)	82.99 (17.42)	81.81 (17.09)	83.42 (17.38)	79.01 (16.75)	84.66 (21.36)	86.61 (21.61)
道路 (2.75)	59.96 (5.42)	39.37 (2.29)	60.40 (3.31)	54.36 (4.66)	58.84 (3.87)	58.61 (4.63)	59.73 (5.38)	69.80 (5.63)
裸地 (3.62)	90.71 (3.34)	87.78 (3.17)	96.90 (3.50)	97.07 (3.66)	97.42 (3.74)	94.16 (3.55)	96.04 (4.27)	96.73 (4.35)
水田 (5.97)	53.90 (12.68)	39.08 (7.06)	66.60 (8.95)	74.88 (9.53)	80.56 (9.99)	67.47 (8.97)	71.90 (9.98)	73.24 (9.64)
畑 (29.09)	73.10 (25.34)	78.12 (27.73)	86.05 (27.53)	86.75 (27.26)	87.41 (27.39)	82.91 (26.95)	87.03 (33.21)	87.93 (33.43)
樹林域 (29.39)	69.46 (25.42)	81.42 (30.19)	85.47 (28.06)	85.24 (27.12)	85.13 (26.90)	87.15 (27.97)	84.45 (33.38)	85.38 (33.48)
水域 (4.72)	94.61 (4.55)	94.47 (4.45)	99.74 (4.69)	99.47 (4.71)	99.47 (4.72)	96.71 (4.64)	97.37 (5.60)	98.55 (5.66)
クラス平均識別率	73.64	71.70	83.83	84.33	85.81	81.45	84.07	86.15
全体識別率	70.83	76.32	84.63	84.99	85.93	81.79	85.08	86.43
CPU時間(秒)	35	35	195	310	1200	30	149	259

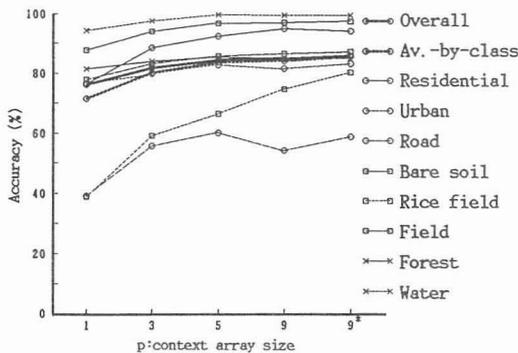


図 4 複合決定法の識別率  
Fig. 4 Accuracy of compound decision.

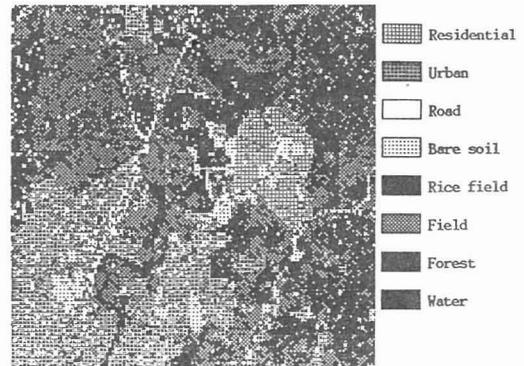


図 5 最ゆう法による全体分類図  
Fig. 5 Classification map by MLH.

べて低いのは、テスト画像中では小さな領域として散在しているためである。仮定 2' の 3 画素間の依存関係で推定した  $p=9^*$  の場合には、全体識別率を大きく改善することはできなかったが、小面積の水田と道路の識別率が改善された。道路が改善されたのは、仮定 2' による線状クラスの強調効果が現れたためと考えられる。なお、仮定 2' を用いた全体の処理時間は仮定 2 によるものの 4 倍を要した。

図 5 に最ゆう法による全体分類図を、図 6 に複合決定法 ( $p=9^*$ ) による全体分類図を示す。最ゆう法ではごま塩雑音状に誤分類の画素が散在しているが、複合決定法では良好に除去されていることがわかる。

以上のことから、仮定 1 と仮定 2 を用いる限りにおいては、context array のサイズ  $p$  は 5 または 9 で十分であるといえる。更に識別率を上げるためには  $p$  を増やすのではなく、より正確に推定された分布  $G(\theta)$  と  $p(X/\theta)$  を用いるべきであることを実験結果は示している。このため、本論文では 3 画素間の依存関係を考慮した  $G(\theta)$  の推定法を提案したが、それでも全体識別率を大きく改善するまでには至らなかった。これは、複合決定法が仮分類の結果に強く依存するためと考えられる。すなわち、仮分類に用いた最ゆう法ではごま塩状に誤分類が多数発生するために、小面積のクラスに対する  $p(\theta_j, \theta_{j+q}/\theta_p)$  が正確に求まらず、その結果これらの識別率が低くなっていると考えられる。従って、次章で述べる適応的分類法などを仮分類に用いれば、更に全体識別率の向上が期待できよう。しかし、道路などの線状クラスの識別率を向上させるためには、これらのクラスの  $p(\theta_j, \theta_{j+q}/\theta_p)$  を先見的に与えるなどの工夫が必要である。

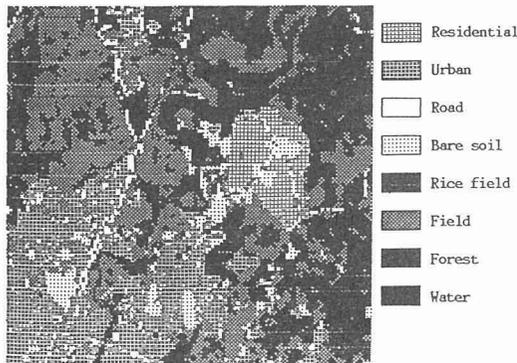


図 6 複合決定法 ( $p=9^*$ ) による全体分類図  
Fig. 6 Classification map by compound decision ( $p=9^*$ ).

## 4. 適応的分類法の検討

### 4.1 原理

適応的分類法<sup>(9)</sup>は、画像を均質な領域に逐次的に分割し、分類を均質な領域単位に行う手法である。

分割領域の形状は  $2^k \times 2^k$  画素 ( $k \geq 1$ ) の方形であり、領域が均質となるまで方形領域の四分分割を繰り返していくが、 $2 \times 2$  画素の方形領域で分類できない場合には画素単位に分類する。このため、境界部や線状部における画素の大部分は画素単位に分類されてしまうので、複雑な画像ではそれほど識別率が上がらないという問題がある<sup>(4)</sup>。ECHO 法<sup>(10)</sup>でも領域を統合する際の初期均質領域は  $2 \times 2$  画素の方形領域であり、境界部や線状部ではやはり画素単位に分類されて適応的分類法と同じ問題が生じている。

本論文では、適応的分類法の改良法として、分割領域の形状を方形以外にも拡張して「適応性」を高めた拡張型適応的分類法を提案する。

拡張型適応的分類法の処理手順を次に示す。

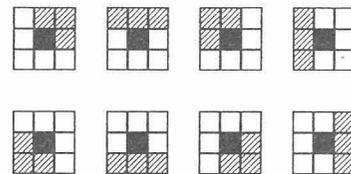
手順 1: 全画面をある大きさの初期方形領域に分割する。

手順 2: 一つの方形領域を対象領域に選び、判定 1 と判定 2 (後に示す) による分類を試みる。判定 1 と判定 2 の結果がともに YES ならば対象領域内の全画素を候補クラスに分類し、そうでなければ対象領域を四分分割する。

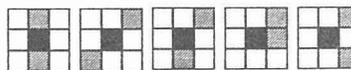
手順 3: 分類がなされていない方形領域がある間、手順 2 を繰り返す。

手順 4: 画素まで分割されたものは、画素ごとに次の方法で分類する。

(1) 図 7 (a) に示す注目画素を中心とする 8 種類の 4 画素領域の中で分散が最小なものを求め、これを対象



(a) Four pixels.



(b) Three pixels.

図 7 拡張型適応的分類におけるブロックパターン  
Fig. 7 Block patterns of extended adaptive classifiers.

領域として判定1による分類を試みる。YESならば注目画素を候補クラスに分類し、NOならば(2)へ行く。

(2) 図7(b)のような注目画素を中心とする任意の3画素領域(パターンは全部で28種類)の中で分散が最小なものを求め、これを対象領域として判定1による分類を試みる。YESならば注目画素を候補クラスに分類し、NOならば最ゆう法などで画素単位に分類する。

対象領域の分類判定基準は次の二つによる<sup>(9)</sup>。

[判定1](平均ベクトルによる判定)  $M$ を対象領域内の画素数とし、 $\bar{x}$ を対象領域内の画素 $\{x_1, \dots, x_M\}$ の平均ベクトルとする。 $\bar{x}$ とクラス $w$ とのマハラノビス距離

$$d_M(w) = M(\bar{x} - \mu_w)^T S_w^{-1} (\bar{x} - \mu_w) \quad (13)$$

を求め、次式

$$d_M(w) + \log |S_w| \quad (14)$$

が最小となるクラス $w$ を選び、それが

$$d_M(w) \leq r_M \quad (r_M: \text{しきい値}) \quad (15)$$

を満足するならばYESを返し、 $w$ を分類の候補クラスとする。そうでなければNOを返す。

[判定2](総和による判定) 判定1の候補クラス $w$ に対する対象領域内のマハラノビス距離和

$$D_M(w) = \sum_{j=1}^M (x_j - \mu_w)^T S_w^{-1} (x_j - \mu_w) \quad (16)$$

を求め、これが

$$D_M(w) \leq t_M \quad (t_M: \text{しきい値}) \quad (17)$$

を満足するならばYESを返し、 $w$ を候補クラスとする。そうでなければNOを返す。

手順4の(1)では面状の広がりをもつ4画素パターンの検出を行い、同(2)では面状と線状の広がりをもつ3画素パターンの検出を行っている。ここで、5画素以上のパターンを考慮することは、パターン数を飛躍的に増大させて処理時間を非実用的レベルのものになってしまうので、本研究では採用していない。

手順4を次の手順4'に置き換えたものが従来の適応的分類法である。

手順4':画素まで分割されたものは、最ゆう法などで画素単位に分類する。

なお、式(14)の第2項は $M=1$ で最ゆう法と一致するように付け加えられた項である<sup>(9)</sup>。

また、仮説H:「対象領域内の全画素は正規分布 $N(\mu_w, S_w)$ に従う母集団からの無作為標本である」のもとで、 $d_M(w)$ と $D_M(w)$ はそれぞれ自由度 $n$ および $nM$ の $\chi^2$ 分布に従うので、棄却率(上側確率) $\alpha_M, \beta_M$ を用いて、しきい値 $r_M$ と $t_M$ は次の関係式

$$\text{Prob}[d_M(w) > r_M | H] = \alpha_M \quad (18)$$

$$\text{Prob}[D_M(w) > t_M | H] = \beta_M \quad (19)$$

から定めることができる<sup>(9),(10)</sup>。但し、 $\alpha_M$ と $\beta_M$ の値は実験に基づいて決定する必要がある(次に示す筆者らの実験では、0.1~0.25の範囲にある)。

### 4.2 実験結果と検討

対象領域を考慮して分類された画素はブロック化されたという。ブロック化された画素の割合をブロック化率と呼ぶ。図8に棄却率とブロック化率の関係を示す。この図で、 $n \times n$ 画素( $n$ 画素)の線は $n \times n$ 画素( $n$ 画素)以上の対象領域でブロック化された画素の割合を示している。図8から棄却率が1に近づくときと画素単位に分類される画素が多くなり、棄却率が0に近づくときと $2 \times 2$ 画素領域以上で分類される画素が多くなることとわかる。特に、4画素および3画素領域で分類さ

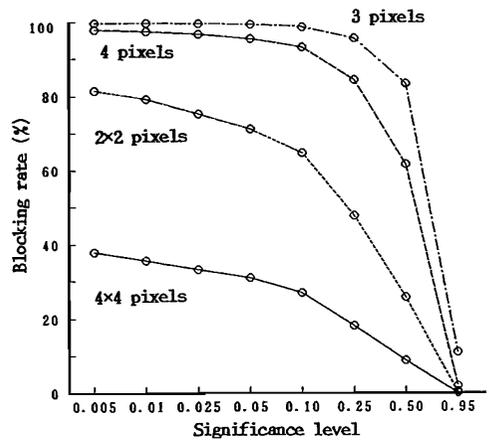


図8 拡張形適応的分類のブロック化率  
Fig. 8 Blocking rate of extended adaptive classifier.

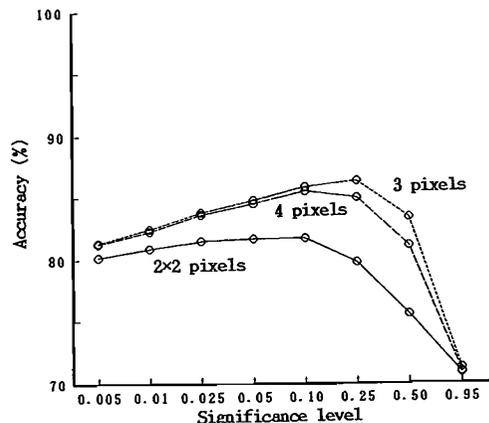


図9 拡張形適応的分類の全体識別率  
Fig. 9 Overall accuracy of extended adaptive classifiers.

れる画素の割合が、棄却率 0.1~0.25 の間で、全体の 30~50% ほども占めることが注目される。従来の手法ではこれらは画素単位に分類されていたものである。

図 9 に、対象領域のサイズと全体識別率の関係を示す。2x2 画素の線は従来の適応的分類、3 画素の線は拡張形適応的分類、4 画素の線は 3 画素領域を用いずに 4 画素領域のみを用いた拡張形適応的分類の識別率である。拡張形適応的分類法を用いることにより分類精度がかなり向上したことがわかる。

図 10 に拡張形適応的分類の領域サイズごとの識別率を示す。従来は画素単位で分類されていた 4 画素領域と 3 画素領域の画素が、画素単位分類よりかなり高い識別率で分類されていることがわかる。このことが分類精度を向上させる元となっている。棄却率が 0 から 0.5 に近づくとつれ、4 画素領域以上の識別率は増大し、1 画素領域と 3 画素領域では減少する傾向が見ら

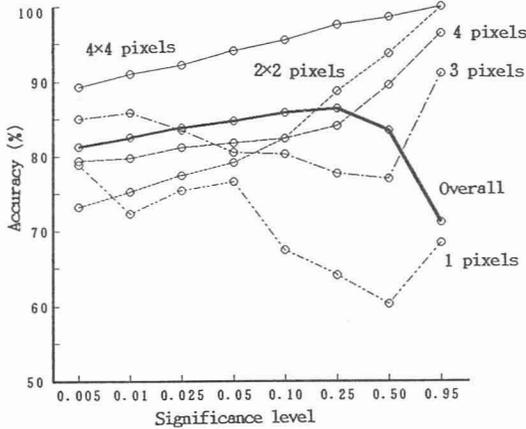


図 10 拡張形適応的分類のブロック識別率  
Fig. 10 Block accuracy of extended adaptive classifiers.

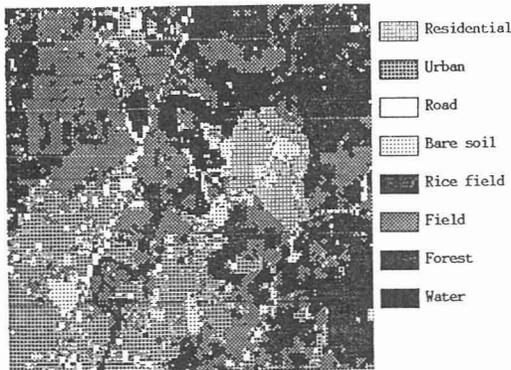


図 11 適応的分類の全体分類図  
Fig. 11 Classification map by adaptive classifier.

れる。棄却率が 1 に近づくと画素単位分類の割合が多くなるので、これらのトレードオフの結果として、最良の全体識別率が棄却率 0.25 のときに得られた。表 1 には、適応的分類と拡張形適応的分類がそれぞれ最も良い全体識別率を上げた場合の値を示した。

図 11 に従来の適応的分類による全体分類図を、図 12 に拡張形適応的分類による全体分類図を示す。図 13 に分類結果の一部を拡大して示す。場所は全体分類図の右中央部の住宅地域である。図 13 (a) は参照画像であり、(b) は最ゆう法、(c) は従来の適応的分類、(d) は拡張形適

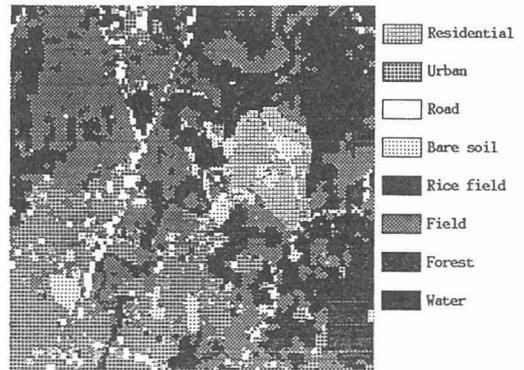


図 12 拡張形適応的分類の全体分類図  
Fig. 12 Classification map by extended adaptive classifier.

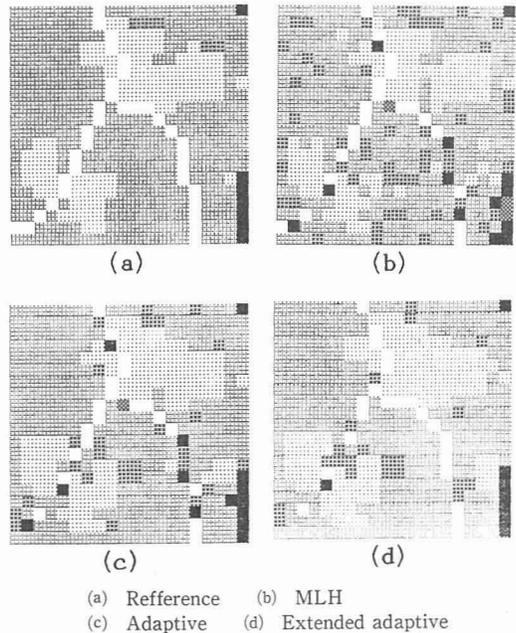


図 13 分類図の比較  
Fig. 13 Comparison of classification map.

応的分類による結果である。図 13 (b), (c)から、従来の適応的分類でも最ゆう法にみられたごま塩状の誤分類は良好に除去できているが、線状部や境界部では最ゆう法と同程度の分類結果にとどまっていることがわかる。図 13 (d)から、拡張形適応的分類により線状部や境界部などもかなり改善されることがわかる。

以上により、拡張形適応的分類では従来の適応的分類に比べてより「適応的な」分類が可能であり、分類精度をかなり向上しうることが確認できた。処理時間は表 1 に示すようにかなり増大する。そこで、処理時間を短縮する必要がある場合には、3 画素領域での分類は行わずに 4 画素領域以上で分類を行えばよい(このようにしても全体識別率の低下はわずかである)。また、原画像データを含む全作業領域の所要メモリ量は、複合決定法が 672 kByte であるのに対し、拡張形適応的分類法では 48 kByte であった。従って、拡張形適応的分類法は実用性の高い分類手法といえる。

## 5. む す び

本論文では、局所的な空間情報を利用する分類手法として複合決定法と適応的分類法を取り上げ、それぞれについて識別能力を更に高めるための改良法を提案し、その効果を実験により検証した。

複合決定法については、context 分布を 3 画素間の依存関係に基づいて推定する方法を提案した。この方法では全体識別率を大きく改善するまでには至らなかったが、小面積で散在するクラスの識別率を改善する効果があった。適応的分類法が対象物体の空間的連続性に着目した分類法であるのに対し、複合決定法はより広い概念である空間的隣接性に着目した分類法である。この意味で、複合決定法には更に分類精度を高めうる改良の余地があるものと考えられるが、これは今後の課題としたい。

適応的分類法については、分類対象領域の形状の種類を増やして分類の「適応性」を改良した拡張形適応的分類法を提案した。その結果、拡張形適応的分類法は従来の適応的分類法に比べてかなり高い識別率をあげられることを評価実験により確認した。拡張形適応的分類法は最ゆう法やベイズ決定などの画素単位分類に比べて 10% 以上も識別率を改善できる一方で、グラントルース領域の選定、処理時間、所要メモリ量などに関しても問題が少なく、実用性の高い手法であるといえる。従って、拡張形適応的分類法は標準的な分類手法として今後幅広く使用されることが期待される。

**謝辞** 日ごろご指導を頂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頂いた同学科応用情報学研究室の諸氏に感謝する。

## 文 献

- (1) 日本リモートセンシング研究会編：“画像の処理と解析”，共立出版(昭 56)。
  - (2) 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)。
  - (3) P. H. Swain：“Advanced interpretation techniques for earth data information system”，Proc. IEEE，**73**，6，pp. 1031-1039 (1985)。
  - (4) 渡辺，鈴木：“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”，信学論(D)，**J70-D**，4，pp. 750-759 (昭 62-04)。
  - (5) 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)。
  - (6) P. H. Swain, S. B. Varclemann and J. C. Tilton：“Contextual classification of multispectral image data”，Pattern Recognition，**13**，6，pp. 429-441 (1981)。
  - (7) J. Kittler and J. Foeglein：“Contextual classification of multispectral pixel data”，Image and Vision Computing，**2**，1，pp. 13-29 (1984)。
  - (8) 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)。
  - (9) 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)。
  - (10) R. L. Kettigh and D. A. Landgrebe：“Classification of multispectral image data by extraction and classification of homogeneous objects”，IEEE Trans. Geosci. Electron.，**GE-14**，1，pp. 19-26 (1976)。
- (昭和 62 年 10 月 5 日受付，63 年 1 月 22 日再受付)

## 渡辺 孝志



昭 44 東北大・工・通信卒，昭 46 同大学院修士課程了，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。現在，

同助教授。この間，パターン学習認識，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 齊



昭 60 岩手大・工・情報卒，昭 62 同大学院修士課程了。同年日本電気株式会社入社。在学中，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。情報処理学会各会員。