Binary Decision Tree による多重分光画像の高速処理[†]

稲村 実*・豊田 弘道*・上田 和紀*
大森 隆司*・藤村 貞夫**

High-Speed Processing of the Multispectral Images by Means of Binary Decision Tree

Minoru INAMURA*, Hiromichi TOYOTA*, Kazunori UEDA*, Takashi OOMORI*
and Sadao FUJIMURA**

Remotely sensed multispectral images are analyzed by the methods of maximum likelihood, Euclidean minimum distance and correlation etc. But a new fast analyzing method is searched because the processing speed of the conventional is slow.

This paper describes the multispectral image processing by means of a binary decision tree. To appreciate the ability of the image analysis, the efficiency of the binary decision tree is compared with the efficiency of the maximum likelihood method under the same conditions.

As a result, the processing speed of the binary decision tree was shown to be twenty times as fast as that of the maximum likelihood with a nine-classes six-features classification. Moreover, the processing time of the binary decision tree method does not increase even if the number of the features increases. This property is another strong point of the binary decision tree. On the contrary, the processing time of the maximum likelihood method is in proportion to the square of the number of selected features. On the other hand, the classification accuracy of the binary decision tree was about equal to that of the maximum likelihood method.

1. はじめに

リモートセンシングによって得られた多重分光画像の解析法には最尤法, ユークリッド距離法, 相関法な

どがある。特に最尤法は, 対象の分光特性の分布に正規性を仮定した場合, 理論上最も正答率の高い解析法として広く利用されている。

ところが上記解析法はいずれも多数回の乗算を実行しなければならず, しかも分光特性に著しい特徴を有する対象物であっても, その分類の難易とは無関係に全画素に対して同一の計算を行うので処理効率も悪い。したがって, 一層多くの処理時間を要する事となり, 膨大なデータ量の処理を必要とするリモートセンシング画像解析には, これらの方法は適さない。そのために分類精度を下げる事なく, 処理時間を大きく短縮する新たな処理法が望まれていた。

そこで本論文では, この問題の一解決法として Binary Decision Tree (以下 B. D. T) の手法による多重分光画像の解析について考察した。Decision Tree による分類法は, すでにパターン認識の各分野では行われているもので^{1), 2)}, さらにこれを多重分光画像解析にも適用しようという提案もある³⁾。しかし Decision Tree による分類法が多重分光画像の解析にも利用できるのは, いわば当然である。さらに重要なことは, 多くの処理時間を必要とするリモートセンシング画像解析への, この手法の適用が, 処理時間の短縮と分類精度の向上とに関して, いかに効果的であるかにある。

そのため筆者らは, 現在最も多用されている最尤法と, この B. D. T との両解析法により, 同一条件のもとで実際のリモートセンシング・データを解析し, その比較検討を行った。その結果, 6 チャンネルを使って 9 対象へ分類した B. D. T の処理時間は最尤法の 1/20 に短縮し, しかも分類の正答率は理論上最も良いといわれている最尤法に比べても, 目立った低下は見られないという成績を得た。さらに本論文では, 各チ

† 第 17 回計測自動制御学会学術講演会で発表 (昭 53・8)

* 東京大学工学部 東京都文京区本郷 7-3-1

** 電気通信大学 調布市調布ヶ丘 1-5-1

* Faculty of Engineering, University of Tokyo, Bunkyo-ku, Tokyo

** University of Electro-Communications, Chofu

(Received August 8, 1978)

チャネル間の比を新たに一つのチャネルとみなし、全チャネルを 36 chs. として B. D. T を適用する試みも行った。このようなチャネルの増加に対しても、B. D. T では処理時間の増加がほとんどないことを確認した。これは B. D. T による解析法の、もう一つの大きな特長である。

2. Binary Decision Tree アルゴリズムとその特徴

2.1 Binary Decision Tree アルゴリズム

ここでは画像解析のための B. D. T を、筆者らの場合にはどのように構成したかについて、そのアルゴリズム順に説明していく。ただし使用するチャネル数を m とし、 n 種類の対象物 $W_i (i=1, \dots, n)$ に分類するものとする。また、B. D. T による処理法は教師付きの解析であるから、適当な方法によって各対象ごとのトレーニング・エリアを定めておく。

1) 各対象 W_i のトレーニング・エリアに指定されたそれぞれの領域において、チャネル j における分光強度の平均を m_{ij} 、分散を $\sigma_{ij}^2 (i=1, \dots, n; j=1, \dots, m)$ とする。始めに ch. 1 では、その平均値 $m_{i1} (i=1, \dots, n)$ が増加の順となるように、対象物の置換 ρ_1 を行う。したがって置換された後では、各対象物が $W_{\rho_1(1)}, \dots, W_{\rho_1(n)}$ の順にならび、それらの平均値は $m_{\rho_1(1)1} < \dots < m_{\rho_1(n)1}$ となる。

チャネルが異なれば、平均値が増加するように並べかえる置換も異なる。一般に ch. j において、 n 種類の対象 $W_1, \dots, W_n$ の平均値 $m_{1j}, \dots, m_{nj}$ が増加の順にならぶための置換を ρ_j とすれば、対象を $W_{\rho_j(1)},$

1: Sea 2: Woods 3: Bare soil 4: Field (dark)
 5: Field (light) 6: Ground 7: Road 8: Glass-house 9: Vinyl-house

Fig. 1 Coincident spectral plot (mean ± one std. dev.) for classes

Fig. 2 Example of binary decision tree (B.D.T.)

$\dots, W_{\rho_j(n)}$ と並びかえる事により、その平均値は $m_{\rho_j(1)j} < \dots < m_{\rho_j(n)j}$ となる。

2) すべてのチャネルに対して 1) の置換のあと、各 ch. j において、隣り合った二つの対象 $W_{\rho_j(i)}$ と $W_{\rho_j(i+1)} (i=1, \dots, n-1; j=1, \dots, m)$ に対して、両者の標準偏差で規格化した

$$g_{ij} = \frac{m_{\rho_j(i+1)j} - m_{\rho_j(i)j}}{\sigma_{\rho_j(i+1)j} + \sigma_{\rho_j(i)j}}, \quad \begin{matrix} (i=1, \dots, n-1) \\ (j=1, \dots, m) \end{matrix} \quad (1)$$

を距離として分離度を評価する。

ところが (1) 式に定めた分離度の評価では、隣り合った対象物の外側に分散の大きな対象が存在する場合には都合が悪い (Fig. 1 参照)。そこで、このような場合をも考慮して (1) 式を

$$g_{ij} = \min_{\substack{1 \leq u \leq i \\ i+1 \leq v \leq m}} \frac{m_{\rho_j(v)j} - m_{\rho_j(u)j}}{\sigma_{\rho_j(v)j} + \sigma_{\rho_j(u)j}}, \quad \begin{matrix} (i=1, \dots, n-1) \\ (j=1, \dots, m) \end{matrix} \quad (2)$$

のように拡張し、以下では (2) 式を距離として分離度を評価する。

3) (2) 式により得られた g_{ij} の中から最大のものを $g_{kl} = \max_{i,j} g_{ij}$ とすれば、ch. l を使い、 n 対象 $W_1, \dots, W_n$ を $\{W_{\rho_l(1)}, \dots, W_{\rho_l(k)}\}$ と $\{W_{\rho_l(k+1)}, \dots, W_{\rho_l(n)}\}$ の 2 グループに分離する。このとき、分離のためのしきい値 T_1 は、ここでは簡単に $m_{\rho_l(k)l}$ と $m_{\rho_l(k+1)l}$ の $\sigma_{\rho_l(k)l}$ と $\sigma_{\rho_l(k+1)l}$ による内分点

$$T_1 = \frac{m_{\rho_l(k)l} \cdot \sigma_{\rho_l(k+1)l} + m_{\rho_l(k+1)l} \cdot \sigma_{\rho_l(k)l}}{\sigma_{\rho_l(k)l} + \sigma_{\rho_l(k+1)l}} \quad (3)$$

なる値にとった。このようにして Fig. 2 の第 1 分枝が得られる。

4) つぎに、3) により分けられた各グループに対し同様の手続きを行うことにより、それぞれの組に対して第 2 分枝が決定する。この手続きを順次繰り返せば、最大でも $(n-1)$ の節をもつ Fig. 2 のような B. D. T により、 n 種類への分類が完全に終了する。もちろん、対象の分離に一度も用いられないチャネルがあることも、逆に複数回用いられるチャネルがある場

合もある。

2.2 Binary Decision Tree アルゴリズムの特徴

2.1 で述べた手順により構成された B. D. T は、そのアルゴリズムのうえではどのような特徴を有しているかについて、現在最も広く用いられている最尤法との比較において、その主なるものを検討しよう。

1) 最尤法では⁴⁾、各対象ごとに指定されたトレーニング・フィールドから、まず平均ベクトル $\mathbf{M}_i$ 、共分散行列 Σ_i を求める。つぎに、最尤法の判別関数 $g_i(\mathbf{X})$ は

$$g_i(\mathbf{X}) = -\frac{1}{2}(\mathbf{X} - \mathbf{M}_i)^T \Sigma_i^{-1}(\mathbf{X} - \mathbf{M}_i) - \frac{1}{2} \ln |\Sigma_i| \quad (4)$$

(ここに T は転置、 $|\Sigma_i|$ は Σ_i の行列式とする) により与えられるから、画像処理の前段階として Σ_i^{-1} 、 $\ln |\Sigma_i|$ ($i=1, \dots, n$) を計算しておくものとする。したがって、実際の画像処理における各画素 (l, m) の分類は、ベクトル $\mathbf{X}_{lm}$ に対して (4) 式により $g_i(\mathbf{X}_{lm})$ ($i=1, \dots, n$) を計算し、これを最大とするカテゴリーに $\mathbf{X}_{lm}$ を対応させることである。したがって、1 画素の分類に必要な乗算はあるカテゴリーについて、(4) 式第 1 項の 2 次形式を求める m^2 回の乗算 (m は使用チャンネル数) を、全カテゴリーについて計算するから、少なく見積っても $n \cdot m^2$ 回の乗算を必要とする事がわかる。しかも乗算の他に加減、大小判断が加わる。

2) 最尤法では、分類に使用するチャンネル数が m のとき、1) に示したように、分類に必要な 1 画素あたりの乗算回数は m^2 に比例する。したがって、特に使用するチャンネル数は極力おさえなければならない。

3) 対象物の中には水や裸地などのように、分光特性に著しい特徴をもつものがあり、一方、一般に人工物は分光特性の似ているものが多い。最尤法では、判別すべきベクトル $\mathbf{X}$ が著しい特徴を有しているか否かに関係なく、全画素に対して同一の計算を行うので、処理効率も悪い。いわば最尤法は、 $\mathbf{X}$ のもつ特徴に対して適応性のない、固い処理法といえる。

1)' 一方、B. D. T では各トレーニング・フィールドから平均 m_{ij} 、標準偏差 σ_{ij} ($i=1, \dots, n, j=1, \dots, m$) を求め、つぎに 2.1 で述べた手順により Tree を構成する。この Tree を構成する前処理の段階までは加減乗除算が必要である。Tree ができあがれば各画素の分類作業に入るが、ここでは最大でも $(n-1)$ 回の大小判断のみであり加減乗除算はまったく不要である。処理時間の大幅な短縮はこれによっている。

2)' B. D. T では分類に使用するチャンネル数が増加

しても、最大でも $(n-1)$ 個の節をもつ Tree である事に変わりはない。すなわち B. D. T では、分類のための処理時間は使用するチャンネル数によらない。

3)' 分類に必要な大小判断は、最大が $(n-1)$ 回であり、著しい特徴をもつ対象の場合には 1~2 回の大小判断のみで分類が終了することもある。すなわち B. D. T は、対象のもつ特徴に対して適応性のある処理法という事ができる。

3. 処理結果とその考察

最尤法と B. D. T の両処理法における処理時間と分類結果を比較するため、例として昭和51年12月に愛知県渥美町福江地区 (Fig. 3) で収集した画像データを使用した。計算機に入力するデータは全 13 チャンネルの FM テープに収集した画像データの中から、Fig. 1 に示した 6 チャンネルを CCT (8 bit のバイナリ整数データ) に変換し、さらに解析に使用した計算機 (東京大学教育用計算機センター, Melcom-Cosmo 700 型) に入力できるよう、32 bit の整数値へと変換しておいた。

この地区は裸地、畑地、温室などが多かったので、カテゴリーとしてはつぎの 9 種類を選び、分類の結果をそれぞれ、海 “=”，森 “?”，畑の裸地 “—”，畑 (明) “/”，畑 (暗) “:”，グラウンド “□”，道路 “X”，温室 “I”，ビニールハウス “Y” の記号によりプリントマップとして出力させた。

トレーニングエリアの選定は、主に画像データ収集と同時に撮影されたハッセルカラー写真や現地の 1/2500 地図を用いた。また同地区は、1 年後にグラ

Fig. 3 Aerophotograph for the classified area shown in Figs. 4 (a), (b) and 5

(a) Maximum likelihood method (MLH)

(b) Binary decision tree method (BDT)

Fig. 4 Examples of classification map

ンド・トルースを含めた総合観測を再び実施したので、その時の調査記録も参考にして決定した。また、トレーニングエリアは必ずしも1対象1領域とはしなかった。すなわち、海のトレーニングエリアは1領域であるが、畑地や温室などのように、場所によって大きく異なっている対象については、それぞれ2~4の間で複数のトレーニングエリアを指定した。

3.1 最尤法と Binary Decision Tree との比較

データの入力、トレーニングエリア、結果の出力などの条件を同一にして処理を行った結果を、Fig. 4 (a), (b)に示す。また、Fig. 4の各地点には、Fig. 3の写真との間の位置関係を示す(1)~(7)の番号をつけておいた。

(A) 処理時間の比較。始めに処理時間には、(1)テープを読み始めてから、結果(分類マップ)を出力し終るまでに要したCPU時間、またはそれを処理した画素数で割った時間、(2)プログラムの中で、与えられたデータに対して所属すべきカテゴリーを決定するルーチンが、1画素あたりの処理に要した平均的な時間、の二つが考えられる。本論文ではより実際の立場から、処理時間を(1)の意味にとるものとする。

両者での処理時間はつぎのような結果であった。

(B. D. T) (最尤法)

処理行数: 449, 130 (時間切れ)
 処理画素数: 53880, 15600
 全所要時間: 約 54 秒, 300 秒
 1 行当たり所要時間: 約 0.12 秒, 約 2.3 秒
 1 画素当たり所要時間: 約 1 m 秒, 約 19 m 秒

ここで1行当たりの所要時間とは、ラインスキップを必要回行って分類すべき行を読み取り、その分類を行ってプリントマップ出力をするのに要する時間であり、1画素当たりの所要時間とは、1行当たりの所要時間を1行当たりの画素数で割った値である。

上の結果から明らかなように、B. D. T は最尤法に比較して約 19 倍の処理速度であった。この値は、現在使われている各種の画像処理法を含めても大幅な時間短縮であり、十分に評価できる。これにより、B. D. T に解決を求めた処理時間の短縮については、その有効性が明確に示された事になる。しかも B. D. T のほうは、処理時間の大半がデータの入出力に要するもので、現在 Fortran の書式付 write 文で書かれているマップ出力ルーチンをアセンブラ化すれば、処理時間はさらに数十%の短縮が可能である。一方、最尤法の場合にはアセンブラ化しても短縮率としてはあまり期待できない。結局、両処理法の処理速度は、最終的には 30 倍以上の差ができるものと思われる。

(B) 分類結果の検討。まずトレーニングエリアを選定したのと同様な方法により、分類の結果やその正答率を調べるためのテストフィールドを決定した。

Table 1 はおのおののテストフィールドから得られたカテゴリーごとの分類比である。したがって Table 1 の対角線上にある数字はそのカテゴリーでの正答率であり、そのグラフを Fig. 5 に示す。つぎに9種類のカテゴリーに分類された対象物のそれぞれを、データ収集と同時に撮影された航空写真やグラントルースデータにより比較検討した結果を要約すれば以下のようになる。

Fig. 5 Correct classification rate (%) for test field

Table 1 Classified rate for test field

U; M.L.H M; B.D.T L; B.D.T (ratio ch.)		Classified rate (%)								
		Sea (=)	Woods (?)	Bare soil (-)	Field (light) (/)	Field (dark) (:)	Ground ()	Road (X)	Glass- house (I)	Vinyl- house (Y)
Category of test field	Sea	100 91 99	— 9 1	— — —	— — —	— — —	— — —	— — —	— — —	— — —
	Woods	— 1 1	100 99 99	— — —	— — —	— — —	— — —	— — —	— — —	— — —
	Bare soil	— — —	— — —	98 94 98	— 4 —	— — —	2 2 2	— — —	— — —	— — —
	Field (light)	— — —	— — —	8 4 4	86 78 86	6 18 10	— — —	— — —	— — —	— — —
	Field (dark)	— — —	— — —	— 14 —	14 12 24	86 74 76	— — —	— — —	— — —	— — —
	Ground	— — —	— — —	— 2 —	— — —	— — 2	92 80 88	1 — —	2 12 3	5 6 7
	Road	— — —	— 1 1	4 4 4	— — —	— — —	50 33 54	39 41 28	6 21 13	1 — —
	Glasshouse	— — —	— 29 29	13 3 3	— — —	— — —	1 1 1	— — —	79 66 66	7 1 1
	Vinylhouse	— — —	— — —	8 — —	— — —	— — —	2 2 1	— — —	12 20 19	78 78 80

(1) 森, グランド, 海の分類は大変に良好で, 正答率は両者とも 90% 以上, 特に海は 100% に近い.

(2) B. D. T では裸地の一部が畑地に分類された所がある. ただし, そのような場所は雑草が多く, カラー写真によっても, 作物のある畑地に差がない. 裸地に雑草が生えている場合, それを裸地とみなすべきか否かは人間でも判断に苦しむ場合が多い. (3)

2種類の畑地への分類は良好であったが, B. D. T と最尤法とは畑(明)と畑(暗)との間に多少の相違がみられた. これは明るさの程度としきい値の関係によるものと思われる. 明・暗の畑地を合せると, 正答率は 90% を十分に上回っている. (4) 道路やビニールハウスなどでは, 共に誤分類が多かった. これは経年変化や屋根の両面での反射光の違いなどによるもので, 分類能力の有無よりもトレーニングエリアの代表性と対象物の著しい多様性に起因する.

全体的に見て, 自然物に対しては両者とも良い成績を示し, 両者間での分類結果の相違もほとんどない. ただし, 雑草の多い裸地や畑(明)と畑(暗)の分類では両者の間には多少の差があった. しかし計算機による現在の自動分類では, そこまで立ち入った分類は期待

できないと考えられるので, このような微妙な領域での性能の比較はあまり意味をもたない. このような領域の分類には, トレーニングエリアの代表性が, より大きく影響する. 一方, 人工物に対しては両者とも正答率が悪く, 最尤法がわずかに良い程度であった. 一般に, どのような解析法でも人工物の分類には驚くほど弱い. これは市街地などを考えてもわかるように, それほど人工物は多様であり, 1~2 の代表ベクトルでは到底表現しきれないという事であろう.

カテゴリーへの分割境界面からいえば, 最尤法では (4) 式からもわかるように m 次元空間内の 2 次超曲面であり, B. D. T では分離に使用するチャンネルの座標軸を法線とする超平面である. よって B. D. T の分割境界面は最尤法のその特別な場合であるから, B. D. T による分類結果が最尤法の場合よりも良好な結果を与えることは考えられない. それ故, 問題は B. D. T では分類精度がどの程度低下するかにあった. しかし最尤法で正答率が高い対象の分類は B. D. T でも同様程度の成績を示し, B. D. T で誤分類の多い対象は最尤法による分類でもほとんど改善がみられなかった事から, B. D. T の分類能力は最尤法に比べても

Fig. 6 Result of binary decision tree classification inclusive of the ratio channels

目立った低下や弱点はなく、ほぼ同等の性能をもっていと結論する事ができる。

3.2 使用チャンネルの増加と Binary Decision Tree

Fig. 6 は 3.1 で使用した 6 チャンネル (Fig. 1) の他にこれらの比 $ch. j/ch. i (i \neq j)$ のおのおのを一つのチャンネルとみなし、全部で 36 チャンネルとして B. D. T の解析を行った分類マップである。

加えた 30 チャンネルから新たな情報が得られるわけではないが、リモートセンシングでは二つのチャンネルの比の画像が、しばしば対象間の微妙な差異を強調し、それらの区別が明瞭となるので、比のチャンネルを加える事で分類能力の向上を意図したこと、使用チャンネルの増加 (6 倍) に対する B. D. T の処理時間の変化をみるためである。

その結果、分類に関しては 6 チャンネルのみの Fig. 4 (b) にほぼ同じで、わずかに最尤法による分類マップ Fig. 4 (a) に近づいた部分が見られるにとどまった。これに対して注目すべき事は、このようなチャンネル数の増加に対しても処理時間は 6 チャンネルのみを使用した場合に同じであった事である。もしもこれが最尤法であれば乗算回数の単純計算によっても、3.1 に示した約 20 倍の差をもつ B. D. T に対して、さらに 36 倍という途方もない処理時間を要することになる。

すでに 2.2, 1)', 2)' に述べたように、B. D. T ではチャンネル数の増加に対しては Decision Tree を構成するわずかな時間が多少増加するのみで、いったん Tree が構成されれば各画素を分類していく作業に要する時間は短縮される事があっても、増加はしない。したがって、全体の画像処理に要する時間はほぼ変わらない。ここでの結果は、それを実際の画像処理によって実証したことを意味する。ちなみに、 $ch. j/ch. i (i \neq j)$ なる比のチャンネルを使いしきい値 T で分割するならば、もとの 6 次元空間での分割境界面は、 (i, j) 平面内で原点を通る勾配 T の直線と i, j 以外の

座標軸とによって張られる超平面となる。

4. おわりに

多重分光画像解析の中でも最尤法は対象の分光特性分布に正規性を仮定した場合、理論上は最も正答率が高く、それゆえ現在最も広く用いられている解析法である。一方、B. D. T はそのような最尤法と比較しても同等程度の性能を有し、しかも処理時間では 1/20 という大幅な差のある事が判明した。この結果は、分類精度を下げることなく処理時間を大幅に短縮するという当初の問題が B. D. T の手法により一応の解決をみたものといえ、通常の分類マップ作成にはこの手法で十分である。しかも B. D. T による分類は大小判断のみで行うので、他の新しい処理法によってもこれ以上に大幅な処理時間の短縮は考えられない。

最尤法による処理法では解析に使用するチャンネル数の 2 乗で処理時間が増加するのに対して、B. D. T ではその増加によらない。したがって B. D. T では、処理時間に制限されることなく必要数のチャンネルを使用する事ができる。

現在利用されている各種解析法の分類精度は、現実には最尤法が必ずしも最良ではなく、解析対象の分光特性の分布形に大きく依存する⁴⁾。そこで必要に応じて、B. D. T のあるレベル以下には最尤法やユークリッド距離法などの解析アルゴリズムを接続しておく事により、著しい特徴をもつ対象は B. D. T によって分類され、その他のものはそのもつ特徴やその程度により B. D. T に接続した各種解析法によってカバーするという、B. D. T と各種解析法との併用も考えられる。このように、B. D. T は他の解析法に比べて柔軟性のある解析法であるともいえる。

最後に、本研究は「日本国土海洋総合学術診断」プロジェクトの一環として実施したものである。日頃よりご援助を賜っている日本造船振興財団の愛甲敬課長をはじめ財団の方々、プログラム作成にあたってご教示を受けた FIP の鈴木康志氏に感謝の意を表します。

参 考 文 献

- 1) E.G. Henrichon, Jr. and K.S. Fu: A Nonparametric Partitioning Procedure for Pattern Classification, IEEE Trans. on Computers, C-18-7, 614/624 (1969)
- 2) W. S. Meisel and D.A. Michalopoulos: A Partitioning Algorithm with Application in Pattern Classification and the Optimization of Decision Trees, IEEE Trans. on Computers, C-22-1, 93/103 (1973)
- 3) P.H. Swain: The Decision Tree Classifier; Design and Potential, IEEE Trans. on Geoscience Electronics, GE-15-3, 142/147 (1977)
- 4) 藤村, 豊田ほか: マルチスペクトル画像を用いた自動識別手法の比較, 計測自動制御学会論文集, 14-3, 269/276 (1978)