



Title	改良型GLDBによるハイパースペクトル画像の高精度クラスタリング
Author(s)	青木, 賢; 石村, 康生; 妹尾, 一弘 他
Citation	電子情報通信学会論文誌 D, J90-D(2), 416-426
Issue Date	2007-02-01
Doc URL	https://hdl.handle.net/2115/30287
Rights	Copyright © 2007 社団法人 電子情報通信学会(IEICE). 許諾番号: 07RB0224
Type	journal article
File Information	IEICE-J90D2.pdf



改良型 GLDB によるハイパースペクトル画像の高精度クラスタリング

青木 賢[†] 石村 康生^{†a)} 妹尾 一弘[†] 和田 充雄[†]
佐島 新^{††}

Precise Clustering Method for Hyper-Spectral Images by Improved GLDB

Satoshi AOKI[†], Kosei ISHIMURA^{†a)}, Kazuhiro SEO[†], Mitsuo WADA[†],
and Shin SATORI^{††}

あらまし ハイパースペクトル画像は、従来のマルチスペクトル画像と比較して、高周波数分解能であることから、対象物の分光スペクトル分布をより詳細に取得できる。そのため、従来よりも精確な画像分類が可能と期待される。一方で、データ量が増大することから計算コストが膨大となるといった課題点も指摘されている。そこで、本論文では、従来の特徴抽出・選択を行うクラスタリング手法の一つである GLDB (Generalized-Local Discriminant Bases) アルゴリズムを改良することにより、高速性を維持し、かつ高精度な画像分類を実現する三つのクラスタリング手法の有効性の検証を行った。実データを用いて実験を行った結果、本論文で用いた画像に関しては、特徴抽出処理により得られた平均特徴数は従来手法よりも減少し、処理時間の短縮、分類精度の向上が実現できた。最後に、三つの改良手法の特徴を比較し、各手法の用途に関する考察を行った。

キーワード ハイパースペクトル画像, Generalized-Local Discriminant Bases, 特徴抽出, 最尤法, サポートベクタマシン

1. ま え が き

近年、リモートセンシング分野でハイパースペクトルセンサ^(注1)と呼ばれる新しいセンサに関心が高まっている [1]。このセンサは、可視光から赤外領域の対象物の分光スペクトル分布をほぼ連続的に観測できる。このため、分光器の測定値と比較することにより、対象物の質的な分析への利用が期待されている。応用分野としては、農作物の生育状況の観察、地球環境の把握、食品の品質管理等がある [2]。現在、衛星用のセンサとして、人工衛星 EO-1 に搭載されている Hyperion、航空機用のセンサとしてカリフォルニア工科大学のジェット推進研究所 (JPL) が開発し運用を行っている Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) が広く利用されている [3]。

また、国内においても、2007 年に打上げを予定している北海道衛星“大樹”に搭載予定の COSMOS Eye [4] が北海道工業大学で開発されている。

しかしながら、ハイパースペクトルセンサで撮影された画像 (以下、ハイパースペクトル画像と称する) はそのデータの性質から以下の課題点をもつ [5]。

- データ量の増加に伴い、計算コストが膨大
- 次元数の上昇に伴う Hughes Effect [6], [7]
- 観測バンド幅が狭まり、SN 比が減少

ここで、Hughes Effect とは、トレーニングデータ数が有限な場合に特徴数を増加させると、次元の呪いの影響により、統計的な信頼度が減少し、識別性が低下する現象を指す。また、次元の呪いとは、次元数の上昇に伴い必要とされるトレーニングデータ数が指数関数的に増加することである。

これらの課題点を解消するため、特徴抽出・特徴選択手法の適用が考えられる。しかしながら、高次元空間において特徴選択手法を適用すると、選択する特徴の組合せが膨大となり、組合せ爆発が起こる。また、

[†] 北海道大学 大学院情報科学研究科 複合情報学専攻, 札幌市
Division of Synergetic Information Science, Graduate School
of Information Science and Technology, Hokkaido University,
Sapporo-shi, 060-0814 Japan

^{††} 北海道工業大学, 札幌市
Hokkaido Institute of Technology, Sapporo-shi, 006-8585
Japan

a) E-mail: ishimura@chaos1.complex.eng.hokudai.ac.jp

(注1): 本論文では「ハイパースペクトル」を「ハイパースペクトル」と呼ぶ。




図 1 ハイパースペクトルセンサと撮影風景

Fig. 1 Hyper-spectral sensor and condition of photographing.

表 1 COSMOS Eye の仕様 [4]

Table 1 Specifications of COSMOS Eye.

撮影画像サイズ	640×480
測定波長域	400～900 nm のうち任意の 400 nm (本研究では、400～800 nm)
バンド数	72
バンド幅	5.6 nm
本体サイズ (mm)	63(Height)×63(Width)×140 (Depth)
撮影スピード	72 スペクトル・チャンネルで 15 あるいは 30 フレーム/s

K-L 変換や Fisher discriminant, Bhattacharya 距離等の特徴抽出手法は、共分散行列を使用するため高次元空間では、Hughes Effect により正しく推定できない。

このため、従来手法の一つに、隣接バンド間を併合して 2 クラスごとに特徴抽出及び分類を行う GLDB (Generalized-Local Discriminant Bases) -TD (Top Down), GLDB-BU (Bottom Up) が提案されている [8]。しかしながら、これらの手法は、処理時間は短縮するが、双方ともバンド間の併合方法に課題点をもち、もとのハイパースペクトル画像の分類精度が低下してしまう場合がある。

そこで、本論文では、GLDB-TD と GLDB-BU の課題点を改良することにより、従来手法の高速性を維持し、更に高精度な三つのクラスタリング手法の検討を行う。三つの手法のうち、一つ目は参考文献 [8] で論じられているものの、その有効性が検証されていない手法であり、残る二つは本論文で新規に提案する手法である。はじめに、これら三つの手法について手法の説明を行い、それから分類実験を通して有効性を検証する。最後に、三つの手法の特徴を比較し、各手法の用途に関して考察を行う。




図 2 ハイパースペクトル画像のデータ構造

Fig. 2 Data structure of hyper-spectral image.

2. ハイパースペクトル画像と分類手順

2.1 ハイパースペクトルセンサと撮影環境

本研究で使用したハイパースペクトルセンサ (COSMOS Eye [4]) の外観と撮影状況を図 1 に、センサの仕様を表 1 に示す。COSMOS Eye は、北海道工業大学で開発されたセンサである。撮影は、センサを対象物から鉛直方向 75 cm 上部に取り付け、鉛直下向きに行った。また、光源には分光スペクトルの変動が少ないハロゲンライト (250 W) を使用し、対象物を中心とした円周上に 120 度間隔に設置した。

2.2 ハイパースペクトル画像のデータ構造

ハイパースペクトル画像のデータ構造を図 2 に示す。ハイパースペクトル画像は、ある観測バンドに着目すれば、二次元モノクロ画像として利用でき、ある画素に着目すれば、分光器と同様の数十～数百バンドのスペクトル情報として利用できる特殊な画像である。このことから、画像としての空間的な次元とスペクトル次元の双方を有する三次元データとしてとらえられ、“Hyper-spectral Image Cube” と称される。

ハイパースペクトル画像の分類は、画素単位で行う。よって、画素数がデータ数に対応し、バンド数が個々のデータの次元数に対応する。すなわち、各画素はバンド数と同じ次元数をもつベクトルデータと考えられる。

2.3 画像分類の手順

画像分類の手順を図 3 に示す。はじめに、ユーザが K-平均法等の教師なし分類 [9] の結果をもとに、適切にトレーニングデータ位置を設定する (Acquisition of Training data)。次に、前ステップで得られたトレーニングデータを使用し、クラス間の分類に最適な特徴の抽出を行う (Feature Extraction)。本論文では、




図 3 画像分類の手順

Fig. 3 The procedure of image clustering.

このステップに力点を置く．特徴抽出後は，分類器の学習を行う（Classifier Learning）．ここで，本論文の分類器には，分類器の種類にかかわらず有効であることを示すため，統計的手法と幾何的手法の二つの観点から最ゆう法 [10] と SVM-OAO [11] を使用した．分類器の学習後は，トレーニングデータも含めた全画素（テストデータ）に対して分類を行う（Classification of Test data）．分類結果後，結果に対して分析・評価を行う（Analysis of clustering result）．本論文では，平均特徴数・分類精度・処理時間の三つの観点から評価を行う．

3. GLDB アルゴリズム

GLDB アルゴリズム [8] は，多クラス問題を 2 クラス問題へ分解し，特徴抽出と分類を 2 クラスごとに行う．これは，各 2 クラス問題ごとで必要とされる特徴が異なるためである．したがって，すべての 2 クラスの組合せに対してこれを行い，得られたすべての結果を統合し最終的な分類結果とする．最終決定方法は，多数決による方法をとる．

GLDB アルゴリズムの特徴抽出処理では，相関が高いと想定される隣接バンド間に対して局所的に低次元化がなされる．局所的である理由は，Hughes Effect を回避するためである．低次元化の方法としては，平均化と Fisher 方向への射影の二つを考察する．

以下では，文献 [8] で記載されている GLDB アルゴリズムのトップダウン手法（GLDB-TD）とボトムアップ手法（GLDB-BU）の二つの手法について説明し，それらの課題点を指摘する．




図 4 GLDB-TD 特徴抽出アルゴリズム

Fig. 4 Feature extraction algorithm in GLDB-TD.

3.1 GLDB-TD とその課題点

3.1.1 GLDB-TD 特徴抽出アルゴリズム

GLDB-TD は，初期時点では全バンドを一つのグループバンドと仮定し，最適な特徴が得られるまで複数のグループバンドに再帰的に分割を行う．再帰分割のアルゴリズムは以下のとおりである．

Decompose(l,u)

- (1) $l \leq k < u$ の各 k に対し， $T(l,k)$ と $T(k+1,u)$ を計算し，最適な分割位置を決定

$$\tilde{k} = \arg \max_{l \leq k < u} \max\{T(l,k), T(k+1,u)\}$$

- (2) if($T(l,\tilde{k}) > T(l,u)$ かつ $\tilde{k} - l \geq 1$)

Decompose($l,\tilde{k}$).

- (3) if($T(\tilde{k}+1,u) > T(l,u)$ かつ $u - \tilde{k} > 1$)

Decompose($\tilde{k}+1,u$).

ここで， l と u は，グループバンドの最初と最後のバンドの添字とする．つまり，画像の総バンド数が N であるとする， $1 \leq l \leq u \leq N$ となり，初期化時点では， $l = 1$ ， $u = N$ となる．また， $T(l,u)$ は，グループバンドの評価値を表す．GLDB-TD では，トレーニングデータの最ゆう法による分類精度とする．

再帰分割後，各グループバンド内のバンドを平均し，新しい特徴とする．グループバンドの平均化後は，評価値の高い特徴から選択し，トレーニングデータの分類精度が向上しなくなるまでこれを繰り返す．すなわち，ここで選択された特徴数が特徴抽出後の最終的な各画素データの次元数に対応する．以上の GLDB-TD の特徴抽出の一連の流れを図 4 に示す．




図 5 平均化と Fisher 方向への射影の違い
Fig. 5 Average and Fisher projection.

3.1.2 GLDB-TD の課題点

GLDB-TD はグループバンド内のバンドを平均化し、新しい特徴を得る。これは、2 バンドによる二次元特徴空間の場合、図 5 の左側の対角線のように斜め 45 度の特徴軸に射影することと等価となる。この場合、各バンドの分布が重なりクラス間の識別性が下がるケースがある。よって、図 5 右側のようにクラス間の識別性を最大化する方向をとるように Fisher 方向への射影を考慮に入れる必要がある。

3.2 GLDB-BU とその課題点

3.2.1 GLDB-BU 特徴抽出アルゴリズム

GLDB-BU は、初期時点では個々のバンドを一つのグループバンドと仮定し、最適なグループバンドが得られるまでバンド間のグループ化を行う。GLDB-BU の特徴抽出の一連の流れを図 6 に示す。

GLDB-BU のグループバンドの評価値 $T(l, u)$ は、以下で定義される相関指標 $C(l, u)$ (式 (2)) と識別指標 $D(l, u)$ (式 (3)) の積とする。これにより、相関と識別性がともに高いグループバンドがグループ化の候補として選ばれることとなる。

$$T(l, u) = C(l, u)D(l, u) \quad , \quad 1 \leq l \leq u \leq N \quad (1)$$

相関指標 $C(l, u)$ は、相関の高いバンド間のグループ化を促進させる因子であり、以下の式で表される。

$$C(l, u) = \min_{1 \leq i < j \leq u} q_{i,j} \quad (2)$$

$q_{i,j}$ は、 $N \times N$ の相関行列 $\mathbf{q}$ の i 行 j 列目の要素を表す。以下に、相関行列 $\mathbf{q}$ 、共分散行列 $\mathbf{Q}$ 、平均ベクトル μ を導出する式を示す。

$$\mathbf{q} = \frac{|Q_{i,j}|}{\sqrt{Q_{i,i}Q_{j,j}}}$$

$$\mathbf{Q} = \frac{1}{|\chi_\alpha| + |\chi_\beta|} \sum_{\mathbf{x} \in \chi_\alpha \cup \chi_\beta} (\mathbf{x} - \mu)(\mathbf{x} - \mu)^T$$




図 6 GLDB-BU 特徴抽出アルゴリズム

Fig. 6 Feature extraction algorithm in GLDB-BU.

$$\mu = \frac{1}{|\chi_\alpha| + |\chi_\beta|} \sum_{\mathbf{x} \in \chi_\alpha \cup \chi_\beta} \mathbf{x}$$

ここで、 $\mathbf{x}$ はトレーニングデータ、 α, β は各クラスの番号、 χ_α と χ_β はそれぞれ各クラスのトレーニングデータの集合を表し、それらの絶対値はトレーニングデータ数を示す。

一方、識別指標 $D(l, u)$ は、識別性を評価する因子であり、以下の式で表される。

$$D(l, u) = \frac{\mathbf{w}_{l,u}^T \mathbf{B}_{l,u} \mathbf{w}_{l,u}}{\mathbf{w}_{l,u}^T \mathbf{W}_{l,u} \mathbf{w}_{l,u}} \quad (3)$$

ここで、 $\mathbf{w}_{l,u}$ はグループバンド $[l, u]$ の Fisher 射影ベクトル、 $\mathbf{B}_{l,u}$ 、 $\mathbf{W}_{l,u}$ はグループバンド $[l, u]$ のクラス間分散行列、クラス内分散行列を表し、以下の式によって導出される。

$$\mathbf{w}_{l,u} = \mathbf{W}_{l,u}^{-1} (\mu_{l,u}^\alpha - \mu_{l,u}^\beta)$$

$$\mathbf{W}_{l,u} = \frac{1}{P(\alpha) + P(\beta)} (P(\alpha) \Sigma_{l,u}^\alpha + P(\beta) \Sigma_{l,u}^\beta)$$

$$\mathbf{B}_{l,u} = (\mu_{l,u}^\alpha - \mu_{l,u}^\beta)(\mu_{l,u}^\alpha - \mu_{l,u}^\beta)^T$$

次に、GLDB-BU のボトムアップによるバンド間のグループ化のアルゴリズムを示す。ここで、 $B^m(k) = [l_k^m, u_k^m]$ をレベル m の k 番目のグループバンドとし、 N_m をレベル m のグループバンド数とする。

- (1) 初期化: $m = 0$, $B^0(b) = [b, b]$, $\forall b = 1, \dots, N$, $N_m = N$
- (2) 最もグループ化すべきペアの探索 (for $i = 1, \dots, N_m - 1$)

- (2a) $B^m(i)$ と $B^m(i+1)$ をグループ化し、新しいグループバンドを形成： $[l_i, u_i] \leftarrow [l_i^m, u_{i+1}^m]$
- (2b) 新しいグループバンド $[l_i, u_i]$ を評価： $T(l_i, u_i) = C(l_i, u_i)D(l_i, u_i)$
- (2c) レベル m のグループ化するべき最適なペアであるか判定：

$$I = \arg \max_{i=1, \dots, N_m-1} T(l_i, u_i)$$

- (3) グループ化の終了判定

$$if(T(l_I, u_I) < \max\{T(l_I^m, u_I^m), T(l_{I+1}^m, u_{I+1}^m)\}) \text{ end.}$$

- (4) バンド間のグループ化を行い、グループバンド情報を更新。

$$(for \ i = 1, \dots, N_m - 1)$$

- (4a) $if(i < I) \ B^{m+1}(i) \leftarrow B^m(i)$
すなわち、 $[l_i^{m+1}, u_i^{m+1}] \leftarrow [l_i^m, u_i^m]$
- (4b) $else \ if(i == I) \ B^{m+1}(I) \leftarrow B^m(I) \cup B^m(I+1)$
すなわち、 $[l_I^{m+1}, u_I^{m+1}] \leftarrow [l_I^m, u_{I+1}^m]$
- (4c) $else \ B^{m+1}(i) \leftarrow B^m(i+1)$
すなわち、 $[l_i^{m+1}, u_i^{m+1}] \leftarrow [l_{i+1}^m, u_{i+1}^m]$

- (5) 次のレベルへ移動： $m \leftarrow m + 1, N_m \leftarrow N_{m-1} - 1$ とし
Step2へ。

以上のアルゴリズムをレベル M まで繰り返したとすると、 N_M 個のグループバンド $\{B^{(M)}(i)\}_{i=1}^{N_M}$ が得られ、これから基底を形成する Fisher 射影ベクトル $\{\mathbf{w}_{l_i^M, u_i^M}^M\}_{i=1}^{N_M}$ が求められる。これらのベクトルは互いに直交しており、各 Fisher 射影ベクトルと内積をとることにより、各画素データを新しい特徴軸へ射影できる。よって、Fisher 射影ベクトルの数 N_M が新しく得られる特徴数に対応する。Fisher 射影ベクトルにより新しい特徴ベクトルが得られると、次に GLDB-TD と同様の方法により分類に必要な特徴の選択を行う。特徴選択の結果、 K 個の特徴が選択されたとすると、 K 個の直交基底を含むクラスペア (α, β) の $N \times K$ 変換行列 $W_{\alpha\beta}$ が得られる。この行列 $W_{\alpha\beta}$ を用いて、各画素データ $\mathbf{x}$ や平均ベクトル μ^α, μ^β 、共分散行列 $\Sigma^\alpha, \Sigma^\beta$ を、 $W_{\alpha\beta}^T \mathbf{x}$ 、 $W_{\alpha\beta}^T \mu^\alpha$ 、 $W_{\alpha\beta}^T \mu^\beta$ 、 $W_{\alpha\beta}^T \Sigma^\alpha W_{\alpha\beta}$ 、 $W_{\alpha\beta}^T \Sigma^\beta W_{\alpha\beta}$ とすれば、 N 次元から K 次元へ低次元化し特徴を抽出できる。

3.2.2 GLDB-BU の課題点

GLDB-BU のグループ化では、評価値 $T(l, u)$ が一番高い隣接バンド間からグループ化を行うことを検討

する。グループ化されると、識別指標 $D(l, u)$ は増加するため、関連指標 $C(l, u)$ の値が下らない限り、評価値 $T(l, u)$ は下らず、グループ化されたバンドが次のグループ化候補として再び選択される。ハイパースペクトル画像の隣接バンド間の相関は高いため、関連指標 $C(l, u)$ が極端に下がることは少ない。よって、繰り返し同じバンドがグループ化候補となる可能性が高い。グループ化の必要がなくなると、隣接バンド間のグループ化を終了するため、グループ化がある 1 箇所偏ってしまうケースが多い。言い換えると、グループ化した新たなバンドの評価値 $T(l, u)$ が、他のバンドと比較して高くはないが、グループ化することで評価値が著しく上昇するバンドに対して、グループ化がなされない可能性がある。そのため、必要とする特徴数が複数である場合には、適切な特徴集合は得ることが難しい。適切な特徴集合が得られなければ、適切な分類を行うことはできないため、複数箇所のグループ化が望まれる。

4. 提案手法

本章では、前章で述べた GLDB アルゴリズムの課題点を改良した三つの手法について説明する。一つ目は、GLDB-TD の課題点を改良した手法であり、“GLDB-TD with Fisher Projection”（以下、TD-FP と略記）とする。二つ目は、GLDB-BU の課題点を改良した手法であり、“GLDB-BU with Multi Grouping”（以下、BU-MG と略記）とする。三つ目は、GLDB-TD with Fisher Projection を高速化するように改良を加えた手法であり、“GLDB-TD with Bi-Directional Scanning”（以下、TD-BS と略記）とする。

4.1 GLDB-TD with Fisher Projection

TD-FP は、GLDB-TD のグループバンド内の平均化を、GLDB-BU と同様、Fisher 方向への射影に置き換えた手法である。よって、評価値も Fisher 射影ベクトルを用いた式 (1) とする。厳密にいうと、式 (1) において、 $C(l, u)$ は関連指標であり、Fisher 方向への射影の評価値として、より重要なのは識別指標 $D(l, u)$ である。

GLDB-TD からの変更箇所は以下の 2 点である。

- 評価値 $T(l, u)$ を式 (1) とする。
- グループバンド内の併合方法を、平均化から Fisher 方向への射影に変更する。

4.2 GLDB-BU with Multi Grouping

BU-MG は、GLDB-BU の課題であった複数箇所




図 7 BU-MG の特徴抽出アルゴリズム
Fig. 7 Feature extraction algorithm in BU-MG.

のグループ化を行うように改良を加えた手法である。図 7 に示すように、初期化時点のグループバンドは、GLDB-BU 同様、個々のバンドとする。GLDB-BU と大きく異なる点は、グループ化を行う候補となるペアを見つけ、Step 3 の条件によって、そのペアをグループ化した後の処理である。BU-MG では、グループ化を行ったバンドと隣接バンドとのグループ化を評価値が向上する限り行い続ける。その後、グループ化を行ったバンドを除いて Step 2 へ再度戻る。グループ化を行ったバンドを除く処理によって、評価値 $T(l, u)$ 自体は他バンドと比較して高くないが、グループ化することで評価値が著しく上昇するバンドのグループ化が期待できる。以下にボトムアップによるバンド間のグループ化アルゴリズムを示す。アルゴリズムの記号の定義は GLDB-BU と同様である。

- (1) 初期化: $m = 0$, $B^0(b) = [b, b]$, $\forall b = 1, \dots, N$, $N_m = N$
- (2) 最もグループ化すべきペアの探索 ($\text{for } i = 1, \dots, N_m - 1$)
 - 一度グループ化が終了したバンドは除く。
 - (2a) $B^m(i)$ と $B^m(i+1)$ をグループ化し、新しいグループバンドを形成: $[l_i, u_i] \leftarrow [l_i^m, u_{i+1}^m]$
 - (2b) 新しいグループバンド $[l_i, u_i]$ を評価: $T(l_i, u_i) = C(l_i, u_i)D(l_i, u_i)$
 - (2c) レベル m のグループ化すべき最適なペアであるか判定: $I = \arg \max_{i=1, \dots, N_m-1} T(l_i, u_i)$
- (3) グループ化の終了判定
 $\text{if}(T(l_I, u_I) < \max\{T(l_I^m, u_I^m),$

- $T(l_{I+1}^m, u_{I+1}^m)\}) \text{ end.}$
- (4) バンド間のグループ化を行い、グループバンド情報を更新。
 - (for $i = 1, \dots, N_m - 1$)
 - (4a) $\text{if}(i < I) B^{m+1}(i) \leftarrow B^m(i)$
すなわち, $[l_i^{m+1}, u_i^{m+1}] \leftarrow [l_i^m, u_i^m]$
 - (4b) $\text{else if}(i = I) B^{m+1}(I) \leftarrow B^m(I) \cup B^m(I+1)$
すなわち, $[l_I^{m+1}, u_I^{m+1}] \leftarrow [l_I^m, u_{I+1}^m]$
 - (4c) $\text{else } B^{m+1}(i) \leftarrow B^m(i+1)$
すなわち, $[l_i^{m+1}, u_i^{m+1}] \leftarrow [l_{i+1}^m, u_{i+1}^m]$
- (5) 次のレベルへ移動: $m \leftarrow m + 1$, $N_m \leftarrow N_{m-1} - 1$.
- (6) I 番目のグループバンドの隣接バンドとのグループ化を判定
 - (6a) $\text{if}(T(l_{I-1}^m, u_I^m) \leq T(l_I^m, u_{I+1}^m) \text{ かつ } T(l_I^m, u_I^m) < T(l_I^m, u_{I+1}^m))$ Step 4 へ。
 - (6b) $\text{else if}(T(l_{I-1}^m, u_I^m) \geq T(l_I^m, u_{I+1}^m) \text{ かつ } T(l_I^m, u_I^m) < T(l_{I-1}^m, u_I^m))$ $I \leftarrow I - 1$ とし Step 4 へ。
 - (6c) else Step 2 へ。

以上のアルゴリズムをレベル M まで繰り返し、得られた N_M 個の Fisher 射影ベクトルを用いて、GLDB-BU 同様に $N \times N_M$ の変換行列 $W_{\alpha\beta}$ により特徴抽出を行う。BU-MG はバンドのグループ化と選択をセットで行うため、得られた特徴数は N_M となる。

また、式 (1) の評価値 $T(l, u)$ を以下のように変更した。これにより、評価値 $T(l, u)$ に対する相関指標 $C(l, u)$ の影響を調整できる。

$$T(l, u) = (C(l, u) + \alpha)D(l, u) \quad (4)$$

$$(1 \leq l \leq u \leq N, 0 \leq \alpha \leq 100)$$

$\alpha = 0$ のとき、式 (1) の評価値 $T(l, u)$ と等価になる。相関指標 $C(l, u)$ は 1 以下であるため、 α の値を 1 よりも大きくすると、相関指標 $C(l, u)$ の評価値に対する影響が弱められる。このとき、相関の低いバンドでも、識別指標 $D(l, u)$ に依存し、グループ化が進むため、グループバンド内のバンド数を増加できる。ここで、評価値 $T(l, u)$ はその大小関係が重要なものであり、絶対的な値には意味がないことに注意されたい。

4.3 GLDB-TD with Bi-Directional Scanning

TD-BS は、TD-FP の高速化を図るため、探索方




図 8 単方向探索と双方向探索の違い

Fig. 8 Uni-directional and bi-directional scanning.

向を単方向から双方向に切り換えた手法である．図 8 に，単方向と双方向の探索方法の違いを示す．ここで， k, k_1, k_2 をグループバンドの添字とする．

単方向探索では，左端から右端へ k を移動させ①と②の二つのグループバンドの評価値 $T(l, u)$ を計算する．一方，双方向探索では，左端と右端の両方から， k_1 は左端から右端へ， k_2 は右端から左端へ移動させ①～③のグループバンドの評価値 $T(l, u)$ を計算する． k_1 と k_2 のうち，移動方向の隣接バンドの相関係数が高い方を移動させる． k_1 が移動したときには，①と②のグループバンドを評価し， k_2 が移動したときには，②と③のグループバンドを評価する．

ここで， k の移動量と k_1 と k_2 の移動量は等しく，評価するグループバンドは従来の二つから三つとなる．よって，各グループバンドの行列サイズを小さくすることができ，探索は単方向に比べ網羅的ではないが，探索範囲を絞り込み高速化を図ることができる．

以下に，双方向探索の場合の再帰分割のアルゴリズムを示す．アルゴリズムの記号の定義は GLDB-TD と同様である．

Decompose(l, u)

(1) $l \leq k_1 < k_2$ の各 k_1, k_2 対し， $T(l, k_1)$ と $T(k_1 + 1, k_2)$ を計算し最適な分割位置を決定．

(1a) $k_1 = l, k_2 = u (l \leq k_1, k_2 \leq u)$ に初期化

(1b) while($k_1 \neq k_2$) {

if($(C(k_1, k_1) > C(k_2, k_2))$)

k_1++ ; $T(l, k_1)$ と $T(k_1 + 1, k_2)$ の更新．

else

k_2++ ; $T(k_1 + 1, k_2)$ と $T(k_2 + 1, u)$ の更新．

$\tilde{k}_1 = \arg \max_{l \leq k_1 < k_2} \max\{T(l, k_1),$

$T(k_1 + 1, k_2)\}$

$\tilde{k}_2 = \arg \max_{k_1 < k_2 \leq u} \max\{T(k_1 + 1, k_2),$

表 2 手法，射影の方法，評価値の組合せ

Table 2 Combination of methods, projections and indexes of the evaluation.

手法	射影	評価値 T
TD	平均	最ゆう法による分類精度
BU	Fisher Projection	$T = C \times D$
TD-FP	Fisher Projection	$T = C \times D$
BU-MG	Fisher Projection	$T = (C + \alpha) \times D$
TD-BS	Fisher Projection	$T = C \times D$

表 3 本研究で実験を行った PC のスペック

Table 3 Specifications of PC.

マザーボード	型番	945G7MA-8KS2
	ベースクロック	FSB200 MHz
CPU	型番 (クロック数)	Pentium® 4 CPU 3.20 GHz
メモリ	型 (種類)	PC4300(DD2-533)
	容量	1.00 GByte RAM

$T(k_2 + 1, u)\}$

ここで， $T(l, u) = C(l, u)D(l, u)$ ， $1 \leq l \leq u \leq N$

(2) if($T(l, \tilde{k}_1) > T(l, u)$ かつ $\tilde{k}_1 - l \geq 1$)

Decompose($l, \tilde{k}_1$).

(3) if($T(\tilde{k}_1 + 1, \tilde{k}_2) > T(l, u)$ かつ $\tilde{k}_2 - \tilde{k}_1 > 1$)

Decompose($\tilde{k}_1 + 1, \tilde{k}_2$).

(4) if($T(\tilde{k}_2 + 1, u) > T(l, u)$ かつ $u - \tilde{k}_2 > 1$)

Decompose($\tilde{k}_2 + 1, u$).

5. 評価実験

5.1 実験条件

まずはじめに，本実験で比較を行う手法，分類器，射影の方法，評価値の組合せを表 2 に示す．ここで，比較の基準となる GLDB-TD, GLDB-BU は，文献 [8] をもとに設定した．次に本実験に使用した PC のスペックを表 3 に示す．また，本実験では葉を分類の対象物とし，以下の二つの条件下で行った．

- 実験 1：同樹木種の生育度の分類（重なりなし）
- 実験 2：異樹木種の分類（重なりあり）

実験 1 では，同樹木種の葉の生育度の分類を目的とし簡単のため葉と葉の重なりはなしとした．また，実験 2 では，異樹木種の葉の分類を目的とし，森林等の実環境下を想定するため葉と葉の重なりをありとした．

また，分類結果の比較は，以下で定義する擬似マルチスペクトル画像（以下，マルチと略記），ハイパースペクトル画像（以下，ハイパーと略記），GLDB-TD（以下，TD と略記），GLDB-BU（以下，BU と略記），TD-FP，BU-MG，TD-BS（4. で定義）の七つの結

表 4 Landsat-7 [3] と本実験の観測波長帯
Table 4 Wavelength range of Landsat-7 and this experiment.

Landsat-7 の観測波長帯 (μm)		本研究で扱う波長帯 (バンド No.1 ~ 72)
Band 1	0.45 ~ 0.52	0.45 ~ 0.52 (10 ~ 21)
Band 2	0.52 ~ 0.60	0.52 ~ 0.60 (23 ~ 36)
Band 3	0.63 ~ 0.69	0.63 ~ 0.69 (43 ~ 52)
Band 4	0.76 ~ 0.90	0.76 ~ 0.80 (66 ~ 72)
Band 5	1.55 ~ 1.75	-
Band 7	2.08 ~ 2.35	-
Band 6	10.42 ~ 12.50 (熱赤外)	-
Band 8	0.50 ~ 0.90 (バンクロ)	-




図 9 実験 1 の画像プロパティ
Fig. 9 Image property in experiment 1.

果に対して行った．ここで，マルチは 4 バンドとし，表 4 の Landsat-7 の Band1-4 の観測波長帯に対応するハイパーのバンドを平均化し，作成した．

5.2 実験 1: 同樹木種の生育度の分類 (重なりなし)

実験 1 の画像は，8 枚のポプラの葉を撮影した画像である．図 9 に，画像とそのプロパティ，トレーニングデータ取得位置・数を示す．また，図 10 には，各クラスの平均分光スペクトルをプロットした．

各クラスについて，class1 ~ class4 は採取してから 1 日経過した葉であり，class5 ~ class8 は 2 週間経過した葉である．また，それぞれの 4 クラスは更に以下の特徴をもつポプラの葉である．

- 正常な樹木の葉 (normal) - class1, class5
- 樹齢の若い樹木の葉 (young) - class2, class6
- 補強具を必要とする樹木の葉 (reinforcing) - class3, class7
- 異なる土壌の樹木の葉 (different soil) - class4, class8

以上の画像に対して，画像分類を行った結果が表 5 ~ 7, 図 11 である．




図 10 実験 1 の平均分光スペクトルの比較
Fig. 10 Comparison of 8 spectra in experiment 1.

表 5 実験 1 の全体の分類精度と処理時間
Table 5 Overall accuracy and processing time in experiment 1.

	分類精度 (%)		処理時間 (s)	
	最ゆう法	SVM-OAO	最ゆう法	SVM-OAO
マルチ	89.1	89.5	4	89
ハイパー	93.1	90.8	625	2,714
TD	81.4	81.7	39	71
BU	89.4	90.5	29	45
TD-FP	93.3	92.4	61	65
BU-MG	93.3	92.6	57	64
TD-BS	93.5	93.2	53	60

表 6 実験 1 の各クラス ($\omega_1 \sim \omega_8$) の分類精度
Table 6 Accuracy of each class in experiment 1.

最ゆう法	ω_1	ω_2	ω_3	ω_4	ω_5	ω_6	ω_7	ω_8
マルチ	96.4	95.3	73.5	97.0	97.8	91.5	86.0	82.5
ハイパー	96.5	97.3	89.1	97.0	90.2	98.0	88.9	87.3
TD	87.3	83.3	65.9	88.4	98.4	89.2	68.1	86.9
BU	89.2	97.8	79.2	91.0	99.6	94.6	85.2	87.1
TD-FP	99.6	98.2	89.0	94.4	93.3	98.4	86.4	87.3
BU-MG	99.1	98.5	88.6	95.4	93.6	98.3	86.6	87.7
TD-BS	99.7	98.8	89.7	95.4	93.6	98.0	85.9	87.4

太字は，各クラスの最大値，分類器：最ゆう法

表 7 実験 1 の各手法の平均特徴数
Table 7 Averaged feature number in experiment 1.

	TD	BU	TD-FP	BU-MG	TD-BS
平均特徴数	1.06	1.06	1.00	1.00	1.00

表 5 から，TD-BS が最も精度が高いが，三つの提案手法とハイパーがほぼ同程度の精度であり，マルチや従来手法に対して最ゆう法では 4(%)，SVM-OAO では 1(%) 向上していることが分かる．

表 6 において，各クラスの分類精度で比較すると， ω_4 , ω_5 に関しては，従来手法よりも精度が低い．これは，識別面の偏りにより起こった結果と考えられる．




図 11 実験 1 の分類結果 (手法: TD-BS) (分類器: 最
ゆう法)

Fig. 11 Result of classification in experiment 1.




図 12 実験 2 の画像プロパティ

Fig. 12 Image property in experiment 2.

その他のクラスと総合的に見てみるとどのクラスにおいても提案手法が 85(%) 以上を維持していることから、提案手法の結果の方が汎化性の高い結果が得られていると推測できる。

表 5 に示した処理時間については、最ゆう法では、提案手法 (TD-FP, BU-MG, TD-BS) とハイパーを比較すると、約 11 分の 1 に済んだが、従来手法 (TD, BU) と比べると約 2 倍かかる結果となった。この理由は、Fisher 方向への射影のための変換行列を求める計算量が多くなったためである。SVM-OAO については、提案手法 (TD-FP, BU-MG, TD-BS) の処理時間が TD やマルチより 5~20(s) 程度短い。これは、SVM の学習時間の短縮による。

表 7 の平均特徴数で比較を行うと、TD, BU が 1.06 であったのに対し、提案手法ではいずれも 1.00 であった。高精度にもかかわらず、特徴数は少なく済んだことから、従来手法よりも適切な特徴抽出が行えたと推測される。

5.3 実験 2: 異樹木種の分類 (重なりあり)

実験 2 の画像は、アカナラ、ミズナラ、イチョウ、ハルニレ、シラカバの 5 種の葉を複数枚重ね合わせた画像である。実験 1 と同様、図 12 にはプロパティ、ト




図 13 実験 2 の平均分光スペクトルの比較

Fig. 13 Comparison of 5 spectra in experiment 2.




図 14 実験 2 の分類結果 (分類器: 最ゆう法)

Fig. 14 Result of classification in experiment 2.

レーニングデータ取得位置・数を、図 13 には各クラスの平均スペクトルをプロットした。

この画像に対して、分類を行った結果が図 14、表 8~表 10 である。表 8 から、提案手法 (TD-FP, BU-MG, TD-BS) とハイパーの結果はいずれの分類器に

表 8 実験 2 の全体の分類精度と処理時間

Table 8 Overall accuracy and processing time in experiment 2.

	分類精度 (%)		処理時間 (s)	
	最ゆう法	SVM-OAO	最ゆう法	SVM-OAO
マルチ	71.8	72.8	3	300
ハイパー	87.3	81.8	362	3,577
TD	65.9	66.5	39	223
BU	71.5	71.7	20	198
TD-FP	84.2	83.9	35	50
BU-MG	85.2	80.1	29	93
TD-BS	81.9	82.0	28	49

表 9 実験 2 の各クラス ($\omega_1 \sim \omega_6$) の分類精度

Table 9 Accuracy of each class in experiment 2.

SVM-OAO	ω_1	ω_2	ω_3	ω_4	ω_5	ω_6
マルチ	52.4	62.7	80.2	96.1	69.6	85.4
ハイパー	67.6	76.3	87.6	94.9	79.9	78.3
TD	57.2	67.1	75.2	75.0	36.0	72.8
BU	65.9	58.2	86.1	72.6	72.6	85.6
TD-FP	71.2	73.6	92.4	96.1	85.0	90.1
BU-MG	67.7	68.0	90.0	94.2	77.2	88.7
TD-BS	68.0	71.4	92.0	95.0	80.9	89.5

太字は、各クラスの最大値、分類器: SVM-OAO

表 10 実験 2 の各手法の平均特徴数

Table 10 Averaged feature number in experiment 2.

	TD	BU	TD-FP	BU-MG	TD-BS
平均特徴数	1.47	1.67	1.40	1.27	1.27

においても 80(%) を上回り、従来手法やマルチに対して約 10~20(%) 向上していることが分かる。

各クラスの分類精度について、表 9 から、 ω_3 (イチヨウ) と ω_4 (ハルニレ) の分類結果が 90(%) を上回っていることが分かる。このことは、図 14 から確認できる。また、その他のクラスにおいても従来手法やマルチよりも高い精度が得られた。

表 8 から、最ゆう法では、実験 1 同様に提案手法 (TD-FP, BU-MG, TD-BS) はマルチや BU よりも処理時間が多くかかることが分かる。TD が提案手法 (TD-FP, BU-MG, TD-BS) よりも処理時間がかかるのは、再帰分割で特徴数が増え、データの次元数が高くなったためと考えられる。SVM-OAO については、提案手法 (TD-FP, BU-MG, TD-BS) の処理時間が、従来手法の約 2 分の 1 となった。この理由は、実験 1 と同様であり、分類が困難な問題ほど、提案手法の効果が期待できると推測される。

表 10 から、平均特徴数においても実験 1 同様、提案手法 (TD-FP, BU-MG, TD-BS) の方が従来手法よりも特徴数が少ないことが分かった。実験 1 同様、

表 11 提案手法間の比較

Table 11 Comparison of proposed methods.

	利点	欠点
TD-FP	高精度である	処理時間がかかる
BU-MG	分析しやすい	パラメータの調整が必要
TD-BS	高速である	探索が網羅的ではない

従来手法よりも適切な特徴抽出が行えていると推測できる。

5.4 提案手法間の比較

提案手法の利点と欠点を表 11 に示す。TD-FP は、GLDB-TD の平均化を Fisher 方向への射影に置き換えたことで、射影軸も 2 クラス間の分離度が最大になる軸を選ぶ一方で、計算コストが増大する。BU-MG は、グループバンドの評価値 $T(l, u)$ に α 項を設けることで相関指標 $C(l, u)$ の影響を緩和できるように改良した。これにより、グループバンド内のバンド数を調節できるようになった。TD-BS は、TD-FP の探索方法を単方向から双方向に切り換えることで高速化を図ったため、分割位置の探索をより効率良く行える。しかし、分割位置の探索が網羅的に行えないため分類精度は TD-FP よりも劣る可能性がある。

以上から、精度を重視するのであれば TD-FP、速度を重視するのであれば TD-BS、またグループバンド内のバンド数を調節し分類に重要なバンドを特定するなどの分析に利用する場合には BU-MG が適しているといえる。

6. む す び

本論文では、従来の GLDB アルゴリズムを改良し、高速かつ高精度な三つのクラスタリング手法の有効性を検証した。同種の葉の分類と異種の葉の分類実験を行った結果、特徴抽出未適用時には、分類精度は高くなるが、処理時間が膨大となった。従来手法の GLDB アルゴリズム適用時には、処理時間は大幅に短縮することができたが、分類精度はもとのハイパースペクトル画像を下回る結果となった。そこで、提案手法を適用した結果、本論文で用いた画像に関しては、最ゆう法では処理時間を従来手法よりも短縮できなかったが、分類精度はもとのハイパースペクトル画像の精度よりも向上できた。また、SVM-OAO では、分類精度の向上に加え、処理時間を従来手法と比べて大幅に短縮できた。

以上の結果から、本研究での提案手法はハイパースペクトル画像の高速高精度クラスタリング手法として

非常に有効に働いているといえる。また、本論文で適用、提案した三つの手法をその特徴に応じて使い分けることにより、精度及び速度の調整、分類に有効なバンドの特定などが可能となる。

謝辞 本研究を行うにあたり、貴重な御意見を下さった(株)エイティーエフの江良聡氏、産業技術総合研究所の池上真志樹氏に深く感謝致します。

文 献

- [1] 北本朝展, “リモートセンシング: 画像情報処理から時空間情報処理へ,” 信学技報, PRMU2002-255, March 2003.
- [2] (財)資源・環境観測解析センター, 地球観測データからの情報抽出, 資源・環境リモートセンシング実用シリーズ, pp.98-103, 東京, 2003.
- [3] (財)資源・環境観測解析センター, 宇宙からの地球観測, 資源・環境リモートセンシング実用シリーズ, pp.97-229, 東京, 2001.
- [4] 日本ハイパースペクトル応用学会 (JSHA), <http://www.hit.ac.jp/~satori/hyper-spectrum/>
- [5] D.A. Landgrebe, Signal Theory Methods in Multispectral Remote Sensing, pp.237-272, Wiley-Interscience, 2003.
- [6] A.K. Jain, R.P.W. Duin, and J. Mao, “Statistical pattern recognition: A review,” IEEE Trans. Pattern Anal. Mach. Intell., vol.22, no.1, pp.4-37, Nov. 2000.
- [7] 石井健一郎, 上田修功, 前田英作, 村瀬 洋, わかりやすいパターン認識, オーム社, 東京, 1998.
- [8] S. Kumar, J. Ghosh, and M.M. Crawford, “Best-bases feature extraction algorithms for classification of hyperspectral data,” IEEE Trans. Geosci. Remote Sens., vol.39, no.7, pp.1368-1380, July 2001.
- [9] 星 仰, リモートセンシングの画像処理, 森北出版, 東京, 2003.
- [10] 日本リモートセンシング研究会, 改訂版図解リモートセンシング, 日本測量協会, 東京, 2001.
- [11] F. Melgani, “Classification of hyperspectral remote sensing images with support vector machines,” IEEE Trans. Geosci. Remote Sens., vol.42, no.8, pp.1778-1783, Aug. 2004.

(平成 18 年 4 月 17 日受付, 8 月 25 日再受付)



青木 賢

2004 北大・情報工学卒。同年同大学院情報科学研究科修士課程入学, 現在に至る。



石村 康生

2001 東京大学大学院工学系研究科航空宇宙工学専攻博士課程了。工博。現在北海道大学大学院情報科学研究科複合情報学専攻助手。宇宙システムの研究に従事。日本航空宇宙学会, リモートセンシング学会, AIAA 各会員。



妹尾 一弘

2005 北大・情報工学卒。同年同大学院情報科学研究科修士課程入学, 現在に至る。



和田 充雄 (正員)

1971 東工大・理工・応用物理卒。1971 ~ 1993 通産省(現経産省)工業技術院製品科学研究所。1986 工博(東京大学)。1994 ~ 1995 通産省(現経産省)工業技術院生命工学工業技術研究所。1995 ~ 2004 北海道大学大学院工学研究科システム情報工学専攻教授。2005 北海道大学大学院情報科学研究科複合情報学専攻教授。ロボティクス, ニューラルネットワーク, 複雑システムなどの研究に従事。日本ロボット学会, 計測自動制御学会, 日本機械学会, バイオメカニズム学会各会員。



佐鳥 新 (正員)

1989 東京大学大学院修士課程航空学専攻了。1993 同大学院博士課程了。工博。1994 宇宙科学研究所宇宙推進研究系助手。1997 北海道工業大学応用電子工学科講師。1999 北海道工業大学応用電子工学科助教授, 有限会社先端技術研究所取締役(大学と兼務)。2001 北海道工業大学電気電子工学科助教授。2003NPO 法人宇宙空間産業研究会理事長。2004(有)Catch the Dreams 代表取締役社長, 北海道衛星株式会社代表取締役社長(大学と兼務)。アメリカ航空宇宙学会, 日本航空宇宙学会, 日本リモートセンシング学会各会員。