

EM アルゴリズムによるリモートセンシング画像の カテゴリー分類におけるミクセルデータの影響と改善

小林 幸夫[†] 稲村 實^{††}

多重分光画像を教師あり分類法でカテゴリー分類する際、各カテゴリーの代表性を有するトレーニングサンプルを用いることが分類精度の観点から重要である。しかし、トレーニングサンプルの選択は一般に統計的手段を用いないため、その特徴量が偏ることがある。トレーニングサンプルの代表性を改善するために EM アルゴリズムが用いられている。しかし、従来の EM アルゴリズムではミクセルデータ（センサの瞬時視野内に複数カテゴリーが存在する画素）について考慮されていないため、抽出されたトレーニングサンプルの特徴量を歪めてしまうことがある。本論文では、EM アルゴリズムを適用する際のミクセルデータの影響を明らかにするとともに、改善方法を提案する。この方法は、ミクセルデータが多重分光画像内のエッジ領域に存在する可能性が高いことを利用し、エッジ領域を EM アルゴリズムの反復過程から排除するという簡便なものである。実際の TM 画像を用いて提案する方法の有効性を示す。

An Influence due to Mixel in Category Classification Using EM Algorithm and Its Improvement

YUKIO KOBAYASHI[†] and MINORU INAMURA^{††}

In supervised classification of multispectral images, it is important to use training samples that has representative of the categories to be classified. However, as the selection of the training samples is not based on statistical procedures, the estimated distribution parameters for each categories often show biased properties. EM algorithm is used to improve the representativeness of training samples. In conventional EM algorithm, an influence due to neglect the dealing of mixel data (a pixel that exist multiple categories in an instantaneous field of view of sensor) in the iterative procedure is occurred. In this paper, we not only clarify this influence but also propose a simplified countermeasure algorithm. This proposed algorithm is based on definition of mixel data that defined by edge region of multispectral image. In the iterative procedure, if incomplete data is not included in such edge region, this data use estimation step, then mixel data is excluded from EM algorithm. It is shown that this proposed algorithm is successfully applied to the classification of Landsat TM data.

1. まえがき

人工衛星や航空機搭載のセンサによって得られるリモートセンシング多重分光画像の利用の中で、基礎的かつ広い用途を持つものとして土地被覆図の作成がある。これは地上対象物をいくつかのカテゴリーに分類したマップで、これから土地利用状況や環境の変化、都市化の様子や緑地率等の情報を得ることができる。最近では衛星データによる国土情報の整備が行われつつある¹⁾。土地被覆図作成等のために用いるカテ

ゴリ一分類手法には、教師付き推定または教師なし推定によって求められたトレーニングサンプルを用いて最尤法、最短距離法等の統計的判別法により分類する手法や、ニューラルネットワークによる分類手法がある²⁾。このうち、ニューラルネットワークによる分類はネットワークの構成方法等解決すべき問題³⁾があり、実用的にはあまり用いられていない。

一方、統計的判別法による分類の前提条件は、トレーニングサンプルの統計的性質が同じ対象物の統計的性質を代表している（代表性を満たした）トレーニングサンプル（教師データ）の利用であり、最尤法や線形判別法等の妥当性は、この前提のうえに成り立っている。しかし、通常トレーニングサンプルの抽出は対象領域全体からではなく、各カテゴリーを最も代表

[†]群馬職業能力開発短期大学校

Gunma Polytechnic College

^{††}群馬大学工学部

Faculty of Engineering, University of Gunma

していると思われる領域を教師である人間が有している情報を総合的に活用して各トレーニングエリアを設定している。このため、抽出したトレーニングサンプルの統計量に偏りが生ずることが避けられない⁴⁾。実際、画像全体の分類精度を検証するためのテストデータの分類精度は、有限サンプルからの学習による凡化の影響より統計量の偏りの影響を支配的に受けるため、トレーニングサンプルの分類精度に比べて20~30%低下する⁵⁾。特に、一般利用者が多用している最尤法のようにパラメトリックな統計理論に基づいて忠実にトレーニングサンプルの情報を有効利用している手法では、トレーニングサンプルの代表性の欠如の影響が大きい。

トレーニングサンプルの代表性の欠如に対する対策のひとつとして、飯倉らは有限混合モデルに対するEMアルゴリズム^{6),7)}を利用して代表性を改善する反復的な方法を検討している⁸⁾。その基本的な視点は、トレーニングサンプルを「完全データ」、所属が分からぬ画像データを「不完全データ」とする混合尤度法である。

しかし、この方法では画像中に多数含まれているであろうミクセルデータについては検討されていない。ミクセルデータは、たとえば、リモートセンサの瞬時視野（たとえばランドサット MSS では 80 m 平方、同じく TM でも 30 m 平方）が、緑地と道路の中間に位置し、したがって、そこで画素データがそれらの分光特性を合成した中間的なパターンとなってしまうデータや、瞬時視野内に複数のカテゴリーが存在し、それらの分光特性の合成によって得られるデータのことをいう。通常、我が国のような複雑かつ細分化された土地被覆形態を有する地域の画像にはミクセルデータが多数含まれている⁹⁾。それゆえ、EMアルゴリズムの反復過程でミクセルデータが混入した場合、トレーニングサンプルから求めた初期特徴量を大きく歪めてしまい、結果として、トレーニングサンプルの代表性を損なうことにもなりかねない。

ミクセルデータに対する検討として、文献9)では、ミクセル内のカテゴリー占有率を面積比として算出するカテゴリー分解を提案しているが、これは、1画素を分類する場合のミクセルの取扱い方法であり、トレーニングサンプルの代表性を改善する視点では論じられていない。また、カテゴリー分解を行う場合でも、代表性を満たしたトレーニングサンプルの使用が前提となっており、この点に関しては従来の最尤法等の手法と同様である。

そこで本論文では、トレーニングサンプルの代表性

を改善するためにEMアルゴリズムを適用する際の上記の影響を明らかにするとともに、ミクセルデータの存在を前提としたEMアルゴリズムの適用方法について簡便な対策を提案する¹⁰⁾。最後に、リモートセンシング多重分光画像により、本手法が有効であることを確認する。

本論文においては、トレーニングサンプルの代表性をその特徴量が本来のカテゴリーの特徴に近いかどうか（特徴を代表しているかどうか）を表すものとしており、分類精度向上のためのカテゴリー設定の問題、すなわちカテゴリーの設定数や設定基準の問題についてはここでは言及せず、今後の研究課題とした。

2. EMアルゴリズムと有限混合モデル

EMアルゴリズムは欠測値や打ち切り標本などいわゆる不完全データに対する処理法を統一的にまとめたものであり、EステップとMステップの2つのステップの反復からなっている。Eステップ（Expectation Step）において不完全データを疑似的に完全データに置き換えることにより、Mステップ（Maximization Step）における母数の最尤推定を見通し良く行うことが可能になる。EMアルゴリズムの特徴は、上記の見通しの良さに加えて、良好な大域的収束性にある。このアルゴリズムの概要と、そのカテゴリー分類への従来の適用法は以下のように要約できる。

2.1 有限混合モデルの母数の最尤推定

有限混合モデルは複数のカテゴリーが存在する場合の確率密度関数であり、 \mathbf{x} を確率変数、 k 番目のカテゴリーの確率密度関数を $f_k(\mathbf{x}|\boldsymbol{\theta}_k)$ ($k = 1, \dots, m$)、混合比を p_k ($k = 1, \dots, m$; $p_1 + \dots + p_m = 1$)としたとき次式で与えられる。

$$f(\mathbf{x}|\boldsymbol{\theta}, p) = \sum_{k=1}^m p_k f_k(\mathbf{x}|\boldsymbol{\theta}_k). \quad (1)$$

ここで、 $\boldsymbol{\theta}_k$ は k 番目のカテゴリーに対する分布の母数である。有限混合モデルの n 個の標本 $\mathbf{x}_1, \dots, \mathbf{x}_n$ から $\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_m$ および p_1, \dots, p_m を推定する問題が母数推定の問題である。

この問題に対し、EMアルゴリズムを適用すると以下のようになる。

いま、 p_1, \dots, p_m と $\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_m$ が無関係であるとき、 i 番目の標本 \mathbf{x}_i がどのカテゴリーに所属するかが分かれれば母数推定は自明な問題となる。そこで、補助変数 $z_{ik} = (z_{i1}, \dots, z_{im})$ を導入し、 z_{ik} は \mathbf{x}_i がクラス k からの標本であれば1、そうでなければ0と定義する。すなわち、理想的完全データを (\mathbf{x}_i, z_i)

($i = 1, \dots, n$) とし、観測データを z_i が欠測した不完全データとみなす。 (\mathbf{x}_i, z_i) ($i = 1, \dots, n$) の対数尤度は、

$$\ln L = \sum_{i=1}^n \sum_{k=1}^m z_{ik} [\ln p_k + \ln f_k(\mathbf{x}_i | \boldsymbol{\theta}_k)]. \quad (2)$$

となる。

そこで、E ステップは z_{ik} の推定となり、それには

$$\begin{aligned} E(z_{ik} | \mathbf{x}_i) &= p(k | \mathbf{x}_i) \\ &= \frac{p_k f_k(\mathbf{x}_i | \boldsymbol{\theta}_k)}{\sum_{k=1}^m p_k f_k(\mathbf{x}_i | \boldsymbol{\theta}_k)}. \end{aligned} \quad (3)$$

を用いる。一方、M ステップでは、(2) 式が p_1, \dots, p_m 部と $\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_m$ 部に分離され、前者については、(2) 式が $\ln p_1, \dots, \ln p_m$ の一次関数であることから、

$$p_k = \frac{\sum_{i=1}^n p(k | \mathbf{x}_i)}{n}. \quad (4)$$

と閉じた形で推定値が更新される。また、 $\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_m$ についても、それぞれのカテゴリーごとに分離するので、尤度最大化は $k = 1$ の場合に帰着する。

2.2 EM アルゴリズムのカテゴリー分類への適用

上記 EM アルゴリズムのカテゴリー分類への適用を考える。教師データをトレーニングサンプルと考えると、以下のようなアルゴリズムとなる。

初期化： 最尤推定の対象となる母数の初期値を設定する。教師データから混合比 p_{k0} 、平均ベクトル m_{k0} および分散共分散行列 \sum_{k0} を計算する。

E ステップ： 不完全データ（画像データ）のカテゴリー推定を (3) 式を用いて行い、疑似的な完全データ z とする。ただし、確率密度関数は多次元正規分布を仮定する。なお、 z は完全データの場合と異なり、[0,1] の実数である。

M ステップ： 完全データおよび疑似的な完全データを用いて、次のように最尤法に基づいた母数の推定値の更新を行う。

$$p_k = \frac{\mathbf{N}_k + \mathbf{M}_k}{\mathbf{N} + \mathbf{M}}. \quad (5)$$

$$m_k = \frac{\sum_{i=1}^n z_{ik} \mathbf{x}_i + \mathbf{M}_k m_{k0}}{\mathbf{N}_k + \mathbf{M}_k}. \quad (6)$$

$$\sum_k = \frac{\sum_{i=1}^n z_{ik} (\mathbf{x}_i - \mathbf{m}_k)^t (\mathbf{x}_i - \mathbf{m}_k) + \sum_{k0}}{\mathbf{N}_k + \mathbf{M}_k}. \quad (7)$$

ただし、 \mathbf{M}_k ：カテゴリー k に属する完全データの標本数、 \mathbf{N}_k ：カテゴリー k に属する疑似的な完全データ

の標本数、 \mathbf{N} 、 \mathbf{M} はそれらのカテゴリーに関する総和である。

E ステップと M ステップを繰り返すことにより、より代表性のあるカテゴリーの統計量が得られる。

文献 8)においては、疑似的な完全データの標本数が少ない場合に完全データの影響が強くなる（初期特微量の拘束）ことを避けるため信頼度を導入している。これは、M ステップにおいて完全データを単に複数の標本としてではなく、初期特微量に信頼度に応じた重みを掛けた形で利用するもので、E ステップで得られた各カテゴリーの疑似的な完全データの標本数 \mathbf{N}_k に信頼度に応じた重み β_k を掛けた数の完全データが仮想的に存在するとしている。すなわち \mathbf{M}_k を繰り返しごとに

$$\mathbf{M}_k = \beta_k \mathbf{N}_k. \quad (8)$$

により与えている。これは、反復対象画素を全画素ではなく再サンプリングした画素を対象とすることで処理時間の短縮を行う際、反復対象画素が少ない場合に抽出特微量が偏ることを避けるために考えられている。しかしこの偏りは後述するようにミクセルデータの影響を考慮していないために発生すると考えられ、本論文で提案する手法を用いれば、再サンプリングすることなく処理時間を短縮しつつ、代表性の改善された特微量を推定することができる。

3. EM アルゴリズムにおけるミクセルデータの影響とその改善法

3.1 1EM アルゴリズムにおけるミクセルデータの影響

ミクセルデータは、センサの瞬時視野（1 画素）内に複数のカテゴリーが混在している画素のことを言う。

いま、分類対象地域には m 種類のカテゴリー $\omega_1, \dots, \omega_m$ が存在、または混在しているものとし、各カテゴリー ω_i の分光特性を n 次元分光ベクトル \mathbf{m}_i ($i = 1, \dots, m$) により表現する。

もし、この画像内のある画素が单一のカテゴリー ω_i で覆われているピュアピクセルならば、理想的には、そこでの画素データ \mathbf{p} は \mathbf{m}_i に一致する。しかし、一般にはこのようなピュアピクセルだけでなく、瞬時視野内には複数のカテゴリーが混在している画素（ミクセルデータ）も多い。

一般に、ある画素がカテゴリー ω_i の面積占有率を a_i とするミクセルデータならば、この場合の画素データ \mathbf{p} は、

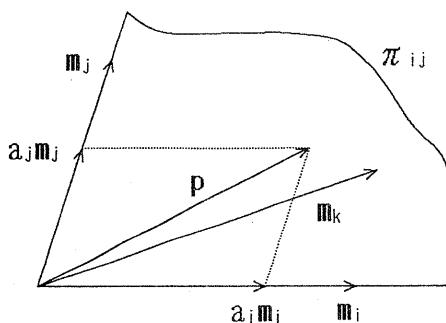


図1 分光ベクトルの位置と一画素が複数カテゴリーにより構成されている画素データ（ミクセル）の誤分類の関係

Fig. 1 Relation between positions of spectral vectors and missclassification of mixel data.

$$\mathbf{p} = \sum_{i=1}^m a_i \mathbf{m}_i. \quad (9)$$

ただし、

$$a_i \geq 0, \quad (i = 1, \dots, m). \quad (10)$$

$$\sum_{i=1}^m a_i = 1. \quad (11)$$

とモデル化される。

汎距離最短を基準とする最尤法、最短距離法等の分類手法において問題となるミクセルデータの誤分類について述べる。

いま、図1に示すように、ある合成された画素がカテゴリー ω_i と ω_j の混在地点であるとき、その地点のデータ \mathbf{p} は \mathbf{m}_i と \mathbf{m}_j の一次結合となり、したがって、 \mathbf{p} は \mathbf{m}_i と \mathbf{m}_j とで張られる平面 π_{ij} 上に存在する。ところが、このように合成された \mathbf{p} の場合、カテゴリー ω_k の分光ベクトル \mathbf{m}_k との汎距離が最短となり、したがって \mathbf{p} は ω_i でも ω_j でもない ω_k に分類されることが生ずる。

このような誤分類は、2章で述べたEMアルゴリズムのEステップにおいてカテゴリーの推定を行う際にも生じていることになる。その結果、Mステップでの更新の際、本来のカテゴリーを代表する特微量に収束するのではなく、別の特微量に徐々に置き換わることになる。このことは、分類対象画像内にミクセルデータが多数存在する場合ほど顕著になる。

3.2 ミクセルデータを考慮したEMアルゴリズム

従来の処理方法のように、上述のようなミクセルデータの誤分類をそのまま含めてEステップを実行すれば、当然、トレーニングエリアから求めた特微量の代表性は大きく歪められる。すなわち、カテゴリー

ω_i と ω_j のミクセルデータが ω_k に誤分類された場合、このデータはカテゴリー ω_k の代表性の改善に使用されることになる。ところが、このようなミクセルデータは ω_k のみならず、 ω_i や ω_j の特微量の代表性をも改善しないことになる。

したがって、Mステップでの母数推定値の更新に用いる疑似的な完全データとしてミクセルデータを含む全画像データとする従来の方法には問題がある。すなわち、リモートセンシング画像にEMアルゴリズムを適用する際には、全画像データからミクセルデータを排除したデータを擬似的な完全データとする必要がある。

一方、ピュアピクセル（センサの瞬時視野内が单一カテゴリーで覆われている画素）であっても各画素のデータはその所属するカテゴリーの特微量のまわりで統計的にはらついており、これをミクセルデータと厳密に判別することは不可能である。すなわち、特徴空間内でミクセルデータとピュアピクセルを完全に同定することは不可能である。

しかし、多重分光画像内のエッジ領域はカテゴリーとカテゴリーの境界部分であり、センサの瞬時視野内に複数のカテゴリーが混在するミクセルデータが存在する可能性が大きい。そこで本論文では、このエッジ領域をEMアルゴリズムの反復過程から除外し、上記ミクセルデータの影響を改善することを提案する。

ミクセルデータは対象物が瞬時視野内に複雑に混在する市街地等のデータとも考えられる。しかしこのようなデータの場合、むしろそれらを1つのカテゴリーとして分類処理を行う方が適切である。現在広く行われているカテゴリー分類においては、都市域または市街地、住宅地等のカテゴリーを設定することが一般的である。

エッジ領域は画像の全領域から分光特性が急激に変化する部分を抽出した領域であり、特徴空間内で異質な分光特性を持つカテゴリーが接する一種の空間情報を与えていると考えられる。ミクセルデータが本質的に特徴空間上で同定できないことから、このエッジ領域を効果的に利用することによりトレーニングサンプルの代表性改善におけるミクセルデータの影響をある程度避けることができる。当然、エッジ領域以外にもミクセルデータが存在することが考えられるが、それらを同定する手法を現在までに得ていないため、エッジ領域のみを用いてミクセルデータの排除を行った。

一般に、トレーニングサンプルは、人間がそのカテゴリーを代表しているであろうと思われる地点を数十～数百標本程度ランダムに抽出するか、または、特定

の領域をトレーニングエリアとして抽出して用いられる。いずれの場合も全画像内には、トレーニングサンプルとして用いられることが可能な他の標本も多く含まれている。これらの標本を適切にトレーニングサンプルに加えることにより、各カテゴリーの代表性を改善することができる。そこで、上記のようにミクセルデータを定めることにより、ミクセルデータの影響をある程度排除することができ、EM アルゴリズムを用いて反復的にトレーニングサンプルの更新を行えば、従来の EM アルゴリズムと比較してさらに代表性の改善能力が向上すると考えられる。

上記の点を考慮して従来の EM アルゴリズムを改善すれば以下になる。

初期化：母数の初期値設定（2.2 節と同様）

E ステップ：不完全データのカテゴリー推定（2.2 節と同様）

M ステップ：推定されたデータのうち、エッジ領域以外の標本を疑似的な完全データとする。（母数更新の式は、2.3 節と同様）

また、この方法は全画素を反復対象としないため処理時間を増大させず、かつ、処理画像地域に依存しない（新たなパラメータを用いない）という利点もある。

4. 実画像データでの処理例

4.1 適用例 1

ここでは、3.2 節で述べた改善 EM アルゴリズムを実際のリモートセンシング多重分光画像に適用し、その有効性を確認するとともに、カテゴリー分類にとってはこの改善が必要であることを示す。

使用した分類対象多重分光画像の諸元および分類カテゴリーを表 1、表 2 に示す。また、分類対象画像に初期トレーニングサンプルを色分けして重ねて表示した画像を図 2（各 512×400 画素）に示す（p. 46 参照）。表 2 の各カテゴリーについて初期特微量（平均ベクトル、分散共分散行列；初期混合比は各カテゴリーの標

本数が 30 のため 1/12 一定）を算出し、従来の EM アルゴリズムおよび改善 EM アルゴリズムに従い処理を行った。なお、EM アルゴリズムでは最初の数回で推定値が大幅に更新されるが、それ以降の収束が遅いことから⁷⁾、ここでの繰り返し数は一定（5 回）とした。

また、E ステップで確率密度関数として多次元正規分布を仮定したことから、抽出した初期トレーニングデータの正規性を確認した。多次元分布をそのまま扱うことは困難であるため、その周辺分布である各バンドのデータについて確認した。多次元分布が正規分布であれば周辺分布も正規分布となる（逆は成立しない）ことから、各バンドのデータに対してひずみ（skewness）と尖度（kurtosis）を求め、それらが一次元正規分布に従うか否かを調べた。一部の代表的なカテゴリーについての結果を表 3 に示す。ここで、* は帰無仮説 H_0 「データの分布は正規分布である」が危険率 5% で棄却されることを示している。データが正規分布に従うとすれば、ひずみは 0、尖度は 3 となるが、このデータは厳密には正規分布に従っておらず、したがって、多次元分布も正規分布ではない。しかし、文献⁵⁾より、データの正規性が厳密には成立していないてもこの程度の相違であれば、識別結果に本質的な

表 2 分類カテゴリー一覧

Table 2 Classification categories.

ω	Name of category	Abbre. name
1	River (light)	riv-l
2	River (dark)	riv-d
3	Forest area (light)	gr-l
4	Forest area (middle)	gr-m
5	Forest area (dark)	gr-d
6	Bare soil	gnd
7	Urban area	city
8	Suburban area	town
9	High way	h-way
10	Shinkansen	yama
11	Cloud	clod
12	Shadow of cloud	shdw

表 3 初期トレーニングサンプルの正規性

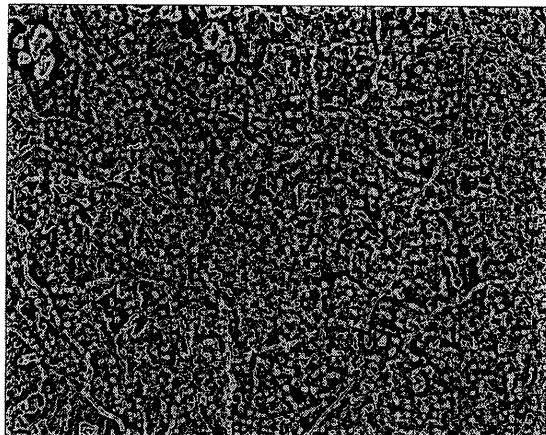
Table 3 Skewness and kurtosis for training samples.

Band no.	Categories					
	riv-l		gr-m		city	
	skew.	kurt.	skew.	kurt.	skew.	kurt.
1	0.02	2.90	0.90	5.15	0.72	2.61
2	-0.22	2.10	-0.11*	2.15	0.53	2.47
3	-0.16	1.80	-0.06	2.05	0.01	3.02
4	0.24	1.88	0.18	2.16	0.56	2.90
5	0.23	1.92	-0.31	2.54	0.41	3.67
7	0.27	1.90	-0.10	3.07	1.30	6.70

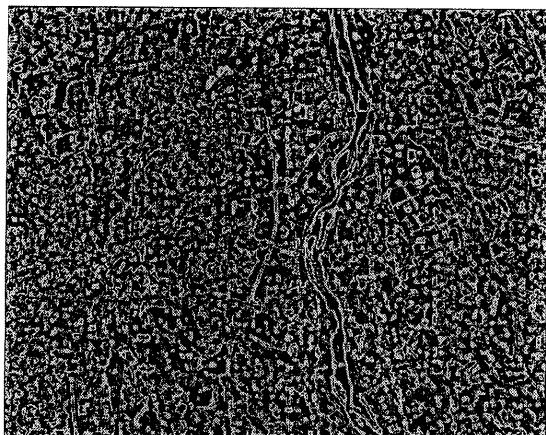
表 1 分類対象多重分光画像の仕様（適用例 1）

Table 1 Specification of multi spectral image
(Example 1).

Observation satellite	LANDSAT No.5
Observation sensor	TM (6 bands excluding the heat band)
Observation date (month/date/year)	August 6, 1986
Observation area	Kanuma city, Utsunomiya city
Number of pixels	1024×400



(a)



(b)

図3 エッジ画像. (a) 鹿沼市, (b) 宇都宮市

Fig. 3 Edge image. (a) Kanuma area, (b) Utunomiya area.

影響を及ぼさないとされていることから、ここではこれらのデータを初期トレーニングデータとして使用することとした。

次にミクセルデータを排除するため、エッジ画像を作成した。まず各バンドごとに 3×3 画素のソーベルフィルタを施しエッジの強さを求め、次に 11×11 画素の小領域における移動平均法による2値化（小領域のエッジ強度の平均値以上のエッジ強度を持つ画素をエッジ画素とし、この処理を画像全体に施す）を行った。さらに2値化された各バンドの画像を用いて多数決フィルタ（同一座標の各バンド画素についてエッジと判定されている数の多数決）により1枚のエッジ画像を作成した。図3に作成したエッジ画像を示す。エッジと判定された画素は189311である、全画素数に対して46.2%である。これらの準備のもと、従来EMア

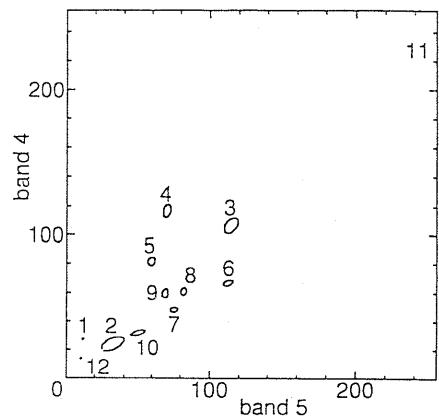


図4 初期トレーニングサンプル特微量

Fig. 4 Original statistics of the categories on the feature plane of band 4 and 5.

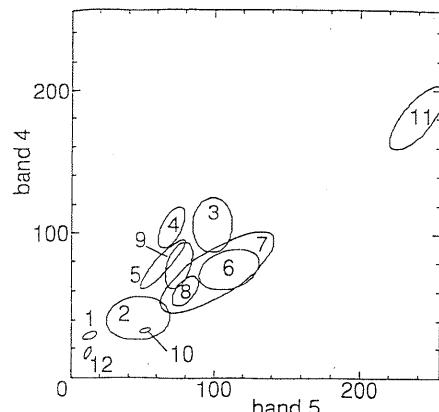


図5 従来EMアルゴリズムによる特微量

Fig. 5 The statistics estimated by the EM algorithm.

ルゴリズム、信頼度 β_k を一律1とした従来アルゴリズム、提案手法を実行しそれぞれトレーニングサンプルの特微量を推定した。推定したトレーニングサンプルの特微量を視覚的に示すため、図4～図7にTMバンド4とバンド5の特徴空間上に各カテゴリーの特微量をマハラノビス距離1の等距離楕円

$$(\mathbf{x} - \mathbf{m}_i)^t \sum_i^{-1} (\mathbf{x} - \mathbf{m}_i) = 1 \quad (12)$$

で示した。図4は初期トレーニングエリアから定まる初期特微量、図5は従来EMアルゴリズムを5回反復した後の特微量、図6は文献8)における信頼度 β を1.0としてEMアルゴリズムを5回反復した後の特微量、図7は改善EMアルゴリズムを5回反復した後の特微量である。これより、従来EMアルゴリズムでは各カテゴリーの分散が増大し特徴空間内での重な

表 4 テストデータ分類正答率（適用例 1）
Table 4 Classification correct answer of test data (Example 1).

Technique	riv-l	riv-d	gr-l	gr-m	gr-d	gnd	city	town	h-way	yama	clod	shdw	Ave.
MLH	100.0	83.3	100.0	86.7	100.0	86.7	56.7	80.0	86.7	60.0	90.0	93.3	85.3
EM	100.0	80.0	100.0	90.0	100.0	100.0	23.3	80.0	20.0	53.3	100.0	100.0	78.9
EM ($\beta = 1.0$)	100.0	90.0	100.0	90.0	100.0	100.0	56.7	80.0	56.7	73.3	100.0	100.0	87.2
Improved EM	100.0	100.0	100.0	100.0	100.0	100.0	100.0	96.7	93.3	100.0	100.0	100.0	99.2

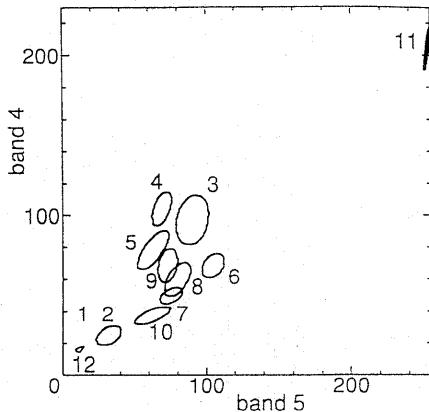


図 6 従来 EM アルゴリズム $\beta = 1.0$ による特微量
Fig. 6 The statistics estimated by the EM algorithm
 $\beta = 1.0$.

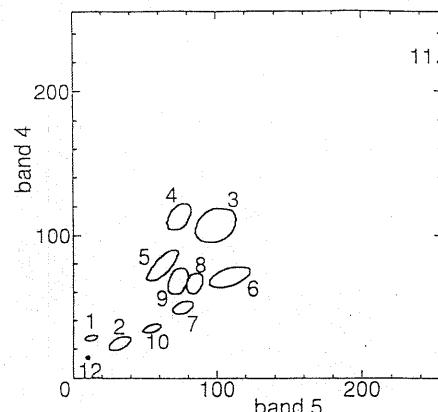


図 7 改善 EM アルゴリズムによる特微量
Fig. 7 The statistics estimated by the modified EM
algorithm.

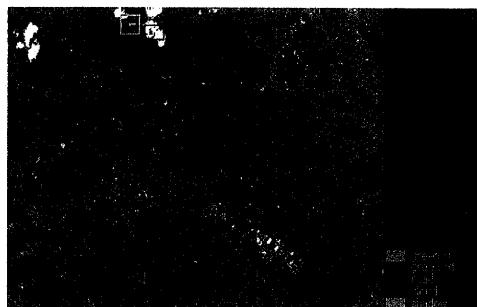
りが大きく、信頼度 β を付加した場合においても分光特性の相似したカテゴリー ($\omega_7, \omega_8, \omega_9$) での重なりが生じておりミクセルデータを排除しなかった影響が現れたものと考えられる。これに対し、改善 EM アルゴリズムではカテゴリー間の重なりもなく良好に特微量を抽出していることが分かる。

以上のことから確認し、また、画像全体での分類精度を推定するために、テストデータによる分類正答率を求めた。テストデータによる評価にはテストデータの選定等の問題が指摘されているが、代表性の改善により分類精度がどの程度改善されたかを示す定量的な指標が現在のところ得られていないため、対象領域全体にわたって各カテゴリーを代表していると思われる 30 標本を各カテゴリーのテストデータとして評価を行った。また、比較のため、初期特微量を用いた最尤法の分類結果についても正答率を求めた。結果を表 4 に示す。

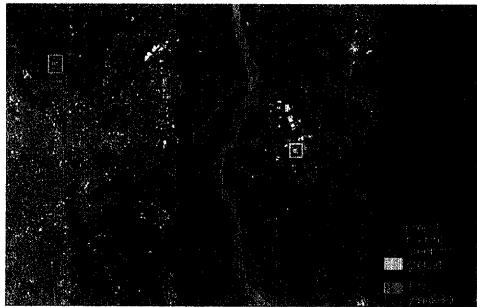
これより、従来 EM アルゴリズム、最尤法、従来 EM アルゴリズム（信頼度 $\beta = 1.0$ ）、改善 EM アルゴリズムの順で正答率が高くなっていることが分かる。前述したように、従来 EM アルゴリズムでは各カテゴリーの特微量が近づき、分散が大きくなつたことにより誤分類が生じ、正答率が低下している。特に ω_7 、

ω_8, ω_9 においてはその傾向が強く正答率も低下している。また信頼度を付加した場合でも特微量空間での重なりを生じたカテゴリーで正答率が低下している。これに対し、改善 EM アルゴリズムでは、全カテゴリーで高い正答率を得ており、特微量が比較的近づいた ω_7, ω_8 においても高い正答率を得ていることが分かる。

従来 EM アルゴリズムおよび従来 EM アルゴリズム（信頼度付加）、改善 EM アルゴリズムの分類結果画像を図 8～図 10 に示す。これより、従来 EM アルゴリズムの結果は ω_9 が都市域において支配的に分類されており明らかに誤分類されている。また、信頼度を付加した結果においても図 9(a) の雲の影の部分で ω_{10} に誤分類されており、(b) の中央を流れる川の境界領域では ω_7 に誤分類されている画素が多数ある。これに対し改善 EM アルゴリズムでは支配的なカテゴリーがなく、図 10(a) の雲の影の部分でも誤分類が減少し、左下を斜めに横切る川がはっきりと分類されており、(b) の川の境界領域においても ω_7 への明らかな誤分類は減少している。以上のことから定性的にもトレーニングサンプルの代表性が改善されていることが確認でき、本論文で提案した手法が有効であることが分かる。



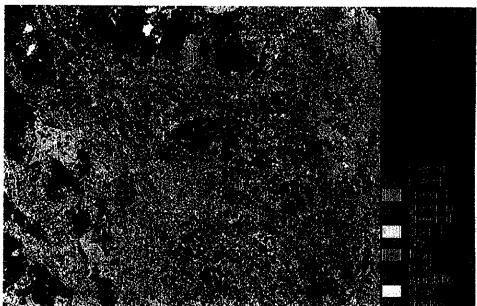
(a)



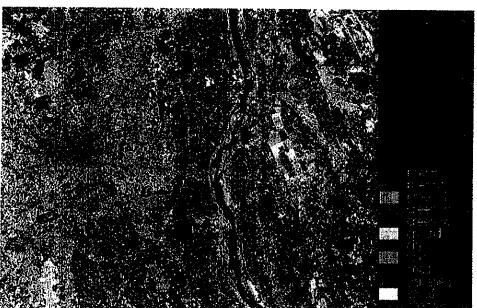
(b)

図2 分類対象画像および初期トレーニングサンプル。(a) 鹿沼市, (b) 宇都宮市

Fig. 2 True color multi spectral image and initial training samples. (a) Kanuma area, (b) Utunomiya area.



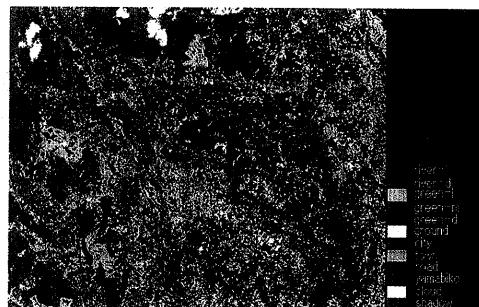
(a)



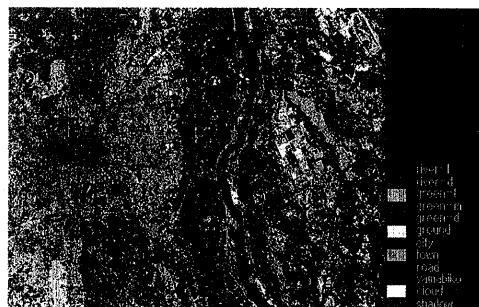
(b)

図8 従来EMアルゴリズムによる分類結果。(a) 鹿沼市, (b) 宇都宮市

Fig. 8 Classification image of conventional EM algorithm. (a) Kanuma area, (b) Utunomiya area.



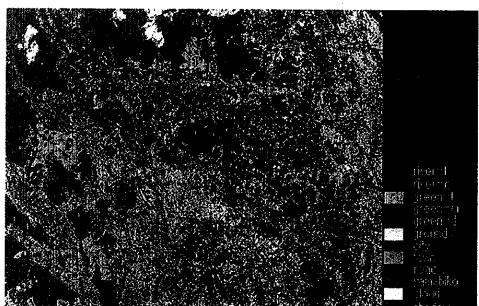
(a)



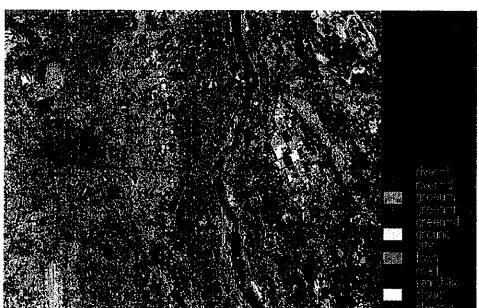
(b)

図9 従来EMアルゴリズム($\beta = 1$)による分類結果。(a) 鹿沼市, (b) 宇都宮市

Fig. 9 Classification image of conventional EM algorithm ($\beta = 1$). (a) Kanuma area, (b) Utunomiya area.



(a)



(b)

図10 改善EMアルゴリズムによる分類結果。(a) 鹿沼市, (b) 宇都宮市

Fig. 10 Classification image of improved EM algorithm. (a) Kanuma area, (b) Utunomiya area.

表 5 多重分光画像仕様（適用例 2）

Table 5 Specification of multi spectral image
(Example 2).

Observation satellite	LANDSAT No.5
Observation sensor	TM (6 bands excluding the heat band)
Observation date (month/date/year)	August 6, 1986
Observation area	Kashima city
Number of pixels	512×400

表 6 分類カテゴリー（適用例 2）

Table 6 Classification categories (Example 2).

ω	Name of category	Abbre. name
1	River (light)	riv-l
2	River (dark)	riv-d
3	Sea	sea
4	Forest area (light)	gr-l
5	Forest area (middle)	gr-m
6	Forest area (dark)	gr-d
7	Urban area	city
8	Factory area	fctry
9	Road	road
10	Tank (Oil refining)	tank
11	Cloud	clod

4.2 適用例 2

提案した手法の有効性をさらに明らかにするため、他の画像データについて改善 EM アルゴリズムを適用した。使用した多重分光画像の諸元および分類カテゴリーを表 5、表 6 に示す。4.1 節と同様に各カテゴリーについて初期特徴量を求め、従来の EM アルゴリズムおよび従来 EM アルゴリズム（信頼度付加）、改善 EM アルゴリズムに従い処理を行った（繰り返し回数は 5 回）。エッジ領域の決定は適用例 1 と同様に行なった。表 7 に初期トレーニングサンプルの平均、標準偏差を示す。これより、カテゴリーによって標準偏差の大きいカテゴリー ($\omega_9, \omega_{10}, \omega_{11}$) と小さいカテゴリー (ω_5, ω_6) が混在していることが分かる。

画像全体での分類結果を推定するために、テストデータ（各カテゴリー 30 標本）による分類正答率を求めた。比較のため初期特徴量を用いた最尤法についても正答率を求めた。結果を表 8 に示す。

これより、4.1 節と同様に従来 EM アルゴリズム、最尤法、従来 EM アルゴリズム（信頼度付加）、改善 EM アルゴリズムの順で正答率が高くなっていることが分かる。最尤法、従来 EM アルゴリズムでは初期特徴量の標準偏差が大きいカテゴリーほど誤分類を発生し、正答率が低下している。これに対し、改善 EM アルゴリズムでは全カテゴリーで高い正答率を得てお

表 7 トレーニングデータ特徴量。

Table 7 Mean (m) and standard deviation (σ) of initial training data (Example 2).

Category (abbre.)	Band number of TM sensor					
	1	2	3	4	5	7
riv-l m	89.0	43.7	51.9	23.9	5.4	2.2
	σ	4.5	4.2	5.9	1.0	0.9
riv-d m	69.2	28.4	23.7	10.5	5.5	2.7
	σ	3.2	2.3	3.1	1.7	2.0
sea m	71.9	26.5	19.2	9.5	7.0	3.6
	σ	3.3	2.3	2.5	2.4	2.2
gr-l m	75.0	39.6	32.5	98.8	82.3	26.3
	σ	3.9	3.8	5.7	29.3	22.7
gr-m m	65.8	28.9	21.0	109.4	63.2	18.0
	σ	1.7	1.2	1.2	14.1	6.7
gr-d m	62.1	23.2	17.5	66.7	44.2	12.2
	σ	0.9	0.8	0.9	16.1	10.6
city m	103.1	47.7	58.6	59.8	82.8	45.6
	σ	13.3	7.2	10.1	7.8	10.7
fctry m	101.1	48.0	67.0	50.6	66.9	42.7
	σ	19.1	11.8	14.3	11.1	23.2
road m	95.0	46.0	50.3	75.6	75.6	33.5
	σ	23.5	15.1	22.9	19.5	21.2
tank m	207.0	121.1	160.5	123.2	147.5	82.6
	σ	44.4	37.6	50.6	35.3	46.5
clod m	195.8	95.2	112.5	113.6	140.2	67.0
	σ	32.1	20.6	26.7	18.0	28.2

り、良好な結果であるといえる。

以上のことから、標準偏差の小さいカテゴリーと大きいカテゴリーがともに存在する場合でも、トレーニングサンプルの代表性を改善できることが分かった。

以上の 2 つの適用例により、トレーニングサンプルの代表性を改善するために EM アルゴリズムを適用する際、ミクセルデータの存在を考慮し、ミクセルデータを何らかの方法により排除して適用することは、より代表性のあるトレーニングサンプルを得るために有効であることが確認できた。

5. む す び

本論文では、EM アルゴリズムをトレーニングサンプルの代表性の改善に対して適用する際のミクセルデータの影響を明らかにするとともに、ミクセルデータの存在を前提とした EM アルゴリズムの適用方法について提案検討した。

EM アルゴリズムにおいてミクセルデータは、特徴量更新の際、本来の代表性改善効果とは逆に特徴量を大きく歪めてしまう悪影響が生じることを示した。

本論文ではこの影響を避ける改善 EM アルゴリズムを提案した。提案した方法は、EM アルゴリズムの適用に際し、エッジ領域で示されるミクセルデータを排除し、よりピュアピクセルに類似したデータのみを用

表 8 テストデータ分類正答率（適用例 2）
Table 8 Classification correct answer of test data (Example 2).

Technique	riv-l	riv-d	sea	gr-l	gr-m	gr-d	city	fctry	road	tank	clod	Ave.
MLH	100.0	96.7	100.0	100.0	100.0	100.0	83.3	93.3	60.0	100.0	90.0	93.0
EM	100.0	96.7	100.0	100.0	100.0	100.0	53.3	90.0	53.3	100.0	80.0	88.5
EM ($\beta = 1.0$)	100.0	96.7	100.0	100.0	100.0	100.0	83.3	93.3	63.3	100.0	93.3	93.6
Improved EM	100.0	100.0	100.0	100.0	100.0	100.0	86.7	93.3	63.3	100.0	93.3	94.2

いて反復計算を行う簡便な方法である。

また、これを実際のリモートセンシング多重分光画像に適用し、本手法が EM アルゴリズムをトレーニングサンプルの代表性の改善に適用する際に有効であることを確認した。この改善により、EM アルゴリズムの適用の信頼性が向上したと考えられる。

今後、エッジ領域の抽出方法と分類精度との関係の検討およびミクセルデータの抽出能力の向上に加え、カテゴリー設定に関する諸問題についての検討および空間情報の有効利用方法の検討が必要であると考えている。

参考文献

- 1) 建設省国土地理院編：宇宙からの国土情報の整備、大蔵省印刷局（1994）。
- 2) Heermann, P.D. and Khazenie, N.: Classification of Multispectral Remote Sensing Data Using a Back-Propagation Neural Network, *IEEE Trans. Geoscience and Remote Sensing*, Vol.30, No.1, pp.81-88 (1992).
- 3) 倉橋真也、福田太郎、稻村 實：階層型ニューラルネットワークの構成とカテゴリー分類の性能との関係、日本リモートセンシング学会第 15 回学術講演会論文集, pp.61-62 (1993).
- 4) 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、計測制御, Vol.24, pp.1013-1018 (1985).
- 5) 藤村貞夫、豊田弘道、愛甲 敬、鈴木康志：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, Vol.14, No.3, pp.269-276 (1978).
- 6) Dempster, A.P., Laird, N.M. and Rubin, D.B.: Maximum Likelihood from Incomplete Data via the EM Algorithm, *J. Royal Statist. Soc. Ser. B*, Vol.39, pp.1-38 (1977).
- 7) 宮川雅巳：EM アルゴリズムとその周辺、応用統計学, Vol.16, No.1, pp.1-19 (1987).
- 8) 飯倉善和、安岡善文：EM アルゴリズムを用いたトレーニングデータの代表性の改善、日本リモートセンシング学会誌, Vol.9, No.4, pp.341-349 (1989).

9) 稲村 實：カテゴリー分解に基づくリモートセンシング画像データの解析、信学論 (C), Vol.J70-C, No.2, pp.241-250 (1987).

10) 小林幸夫、稻村 實：EM アルゴリズムにおけるミクセルの影響とその改善、日本リモートセンシング学会第 14 回学術講演会論文集, pp.163-164 (1993).

(平成 7 年 5 月 25 日受付)

(平成 7 年 11 月 2 日採録)

小林 幸夫（正会員）



1957 年生。1980 年長岡技術科学大学工学部電子機器工学課程卒業。1982 年同大学大学院修士課程修了。同年松下電器産業（株）入社。1988 年小山職業訓練短期大学校講師。1991 年群馬職業能力開発短期大学校講師、現在に至る。リモートセンシング多重分光画像の解析に関する研究に従事。電子情報通信学会、日本音響学会、計測自動制御学会、日本リモートセンシング学会各会員。

稻村 實

1945 年生。1967 年工学院大学工学部電気工学科卒業。1968 年同大学専攻科、1970 年同大学大学院修士課程修了。1973 年同大学大学院博士課程を単位修得のうえ退学。同年東京大学工学部計数工学科助手、1981 年同講師。1982 年佐賀大学理工学部助教授、1987 年同教授。1989 年群馬大学工学部電気電子工学科教授、現在に至る。1978 年計測自動制御学会論文賞、1985 年度同学会技術賞を受賞。1980 年工学博士（東京大学）。現在、代数的手法に基づく多次元画像処理、リモートセンシングによる定量的遠隔計測などの研究に従事。日本リモートセンシング学会評議員・編集委員、IEEE、電子情報通信学会、日本リモートセンシング学会、計測自動制御学会各会員。