

ミクセルを考慮したNOAA-AVHRRデータのクラス分類アルゴリズム

Use of Mixels in Classification Algorithm for NOAA-AVHRR Data

正会員 景山陽一[†], 佐藤郁磨[†], 正会員 西田 眞[†]

Yoichi Kageyama[†], Ikuma Sato[†] and Makoto Nishida[†]

Abstract National Oceanic and Atmospheric Administration (NOAA) and Advanced Very High Resolution Radiometer (AVHRR) data are available on a daily basis and have been frequently used for global observation. The ground image can be resolved 1.1 km immediately below the satellite on a horizontal scale. Both pure and mixed pixels (mixels) can be used to accurately classify land-, sea-, and cloud- cover conditions. We propose the use of a classification algorithm for the NOAA-AVHRR data. The algorithm has four steps. First, multispectral bands are used to estimate elements of three classes (sea, land, and cloud) as supervised data for pre-classification. Second, pure pixels of the three classes are extracted on the basis of the multispectral bands and the Normalized Difference Vegetation Index (NDVI) of the same pixel. Third, we determine pure pixels and mixels by using fuzzy reasoning for the remaining pixels mentioned above, with the exception of the "land and sea" class. Finally, the edge information facilitates the retrieval of the "land and sea" mixel. Our experimental results suggest that the proposed approach provides results suitable for classifying various conditions.

キーワード：リモートセンシング, マルチスペクトルデータ, ミクセル, クラス, ファジィ推論

1. ま え が き

リモートセンシング解析を行う場合、その目的や対象に応じて異なる分解能のデータが用いられる。例えば、土地利用などの局所レベルの事象を解析する場合には、狭い範囲（撮像範囲：60km～180km程度）を低頻度でしか観測できないものの、分解能の高いデータ（10m～80 m程度）が用いられる。これに対し、雲の分布など地球レベルの事象を解析する場合には、分解能は低いものの、広範囲・高頻度で観測可能なデータが用いられている。中でも米国海洋大気庁（NOAA: National Oceanic and Atmospheric Administration）が運用している NOAA 衛星に搭載された AVHRR (Advanced Very High Resolution Radiometer)¹⁾ により取得されたデータ（以下、AVHRR データと表記する）は、広範囲のデータが1日に複数枚取得できるため、多くの解析^{2)~6)} に用いられている。

AVHRR データを用いる場合、(1) 陸域が森林や市街地

など特徴の異なる多様な要素から構成されており、単純な分類は困難であること、(2) 雲の種類や大きさも多様であり、薄雲では雲下の情報が透けてしまうこと、(3) AVHRR データの撮像範囲が約 2800km と広いため、取得データの位置によっては同一被覆物であっても異なる輝度情報 (DN 値) となり得ること、(4) リモートセンシングデータを構成する各画素は、単一のクラス（分類のために選定する被覆物：例えば、雲域、海域など）の情報から構成されるピュア画素に加え、2 種類以上のクラスが複合した DN 値を合わせ持つ混合画素 (Mixed Pixel: ミクセル) であることなどを考慮して処理を行う必要がある。

ミクセルを考慮することなくピュア画素のみを対象として分類を行った場合、ミクセルも特定の設定クラスに分類されるため、各画素に含まれる他のクラスの要素は分類結果に反映されない。このことが分類精度を低下させるとともに、実際の被覆状況との相違を大きくする要因となっている。したがって、精度良くクラス分類を行うためには、対象データのミクセルの特徴を考慮した処理を行う必要がある。そこで、ミクセルのクラス混在率推定法として、ランドサット TM (Thematic Mapper) データ（撮像範囲 185km; 地上分解能 30m）を対象とした手法が現在までに幾つか提案されている⁷⁾⁸⁾。また、筆者らもこれまでに、ファジィ推論によるミクセルの混在率推定法（以下、ファジィ推論法

2008 年 7 月 24 日受付, 2008 年 12 月 24 日再受付, 2009 年 1 月 20 日採録

[†] 秋田大学 工学資源学部 情報工学科

(〒 010-8502 秋田県秋田市手形学園町 1-1, TEL018-889-2786)

[†] Department of Computer Science and Engineering, Faculty of Engineering and Resource Science, Akita University

(1-1 Tegata Gakuen, Akita 010-8502)

と略記する)⁹⁾を提案した。現実的な条件を考慮して作成したデータを用いてシミュレーションを行った結果、ファジィ推論法は精度良くミクセルのクラス混在率を推定できることを明らかにしている。しかしながら、広域かつ低分解能データである AVHRR データ (地上分解能 1.1km) の場合、各クラスの特徴量のばらつきも大きくなるため、上記手法を単純に適用しただけでは分類精度が低くなる場合を認めた。

AVHRR データを対象とした分類法も提案されている。例えば、雲域にマスク処理を施して分類を行った事例¹⁰⁾¹¹⁾や、クラスタの分割・統合により雲を検出する事例⁵⁾が報告されている。また、ミクセルに関する検討^{12)~14)}も行われている。例えば、文献(12)および(13)では、ミクセルの集合が画像ヒストグラム上に形成する「ミクセル密度」という新しい確率密度関数を混合密度モデルに導入し、第4バンドデータから雲と海のピュア画素およびミクセルの分類を行っている。また、ヒストグラムを分解する手法として文献(12)に着目し、多時期(最大12ヶ月)に取得したデータから *NDVI* (正規化植生指標; Normalized Difference Vegetation Index) をそれぞれ求めて主成分分析を施し、第1主成分により陸域における4種類の土地被覆物を分類した結果¹⁴⁾も報告されている。しかしながら、実際の AVHRR データを自動分類する場合、ピュア画素とミクセルの特徴を考慮し、(1) 効果的に使用するバンドを選定し処理をすること、(2) ミクセルの空間的特徴を考慮した処理を行うこと、(3) 近傍画素との関連情報を考慮した処理を行うことがクラス分類精度の向上に寄与すると考える。なお、このような見地から AVHRR データを対象としてミクセルを含むクラスの分類は行われていない。

一方、AVHRR データのように光学センサにより取得されたデータの場合、対象領域上空に雲が存在すると雲下の情報が取得できないため、そのデータは解析に利用できない場合が多い。したがって、データベースの検索時には“データに占める雲の割合(雲量)”が指標の一つとして用いられる¹⁵⁾。しかしながら、各登録データの雲量は、オペレータが目視により判別しているのが実情である。このため、オペレータの作業量の低減や同一基準によるデータの自動評価を行うためには、(1) データ毎に撮像範囲が異なること、(2) データに占める雲域の割合や雲の存在する場所が変化すること、(3) データの取得時期によって陸域を構成する情報が異なることなどの条件下においても精度良く自動分類する必要がある。さらに、複数のデータを対象として幾何補正を行う場合、地上基準点(GCP: Ground Control Point)を設定して処理を行うのが一般的であるが、海域と陸域の境界域(ミクセル)を精度良く推定することは、GCPの自動選定時の前処理としても有効である。

そこで本論文では、ミクセルを考慮した NOAA-AVHRR データのクラス分類アルゴリズムを提案する。はじめに、各画素のバンド情報に着目し分類に用いる教師データを自動



図1 NOAA-AVHRR データ
NOAA-AVHRR color composition image (RGB; band1 · 2 · 4).

抽出した。次に、撮像範囲や雲域の状況が異なるデータに対して動的に閾値を選定すること、ならびに陸域の分類を目的とし、ヒストグラム形状や *NDVI* を用いてピュア画素を推定した。さらに、ファジィ推論法⁹⁾を用いてピュア画素とミクセルの推定を行うとともに、ミクセルの空間的特徴を考慮して、近傍画素との関連情報を用いた処理を行った。提案手法の有用性を検討するため、手動により作成した分類マップ(以下、手動分類マップと表記する)との比較を行うとともに、教師つき分類である最尤法¹⁶⁾および教師なし分類法である k-means 法¹⁶⁾を用いて得られた結果との比較も行ったので報告する。

2. 使用画像データおよび分類クラス

2.1 使用データ

本論文では、本学情報工学科屋上に設置された NOAA 受信解析システム(株式会社エルム製)により取得されたデータを対象としている。本学で観測できる範囲は、データにより異なるものの、日本、韓国、中国、ロシアの極東地域などである。受信データの中から月毎に1枚ずつ選定し、合計12枚(1024画素×1024画素; 1024階調)を対象として検討を加えた。2001年11月23日(以下、11月データと表記する)に本学で受信された AVHRR データを図1に示す。

2.2 バンドデータの特徴

AVHRR データは5種類の異なる波長域で観測されたバンドデータから構成されるマルチスペクトルデータ¹⁾である。すなわち、第1バンドから第5バンドまで順に、可視域、近赤外域、近赤外域、熱赤外域、熱赤外域の各波長域で観測されたデータである。このため、同一画素であってもバンドが異なると得られるデータの特徴は異なる。

2.3 分類クラス

AVHRR データの分解能を考えた場合、データ中の被覆物は“海域、陸域、雲域”に大別される⁹⁾。そこで本論文では、ピュア画素のクラスとして、上記3種類のクラス（海域、陸域、雲域）、ならびに各クラスを構成要素とする3種類のミクセルのクラス（海域と陸域、海域と雲域、陸域と雲域）の合計6種類のクラスを設定した。なお、3種類のクラスから構成されるミクセルも存在するが、雲の種類や画素に占める雲の割合、ならびに陸域の構成要素は多種多様であり、その判別は困難である。このため、本論文では2種類のクラスから構成されるミクセルを対象とした。AVHRR データを対象とした3クラスのミクセル処理法については現在検討を進めており、結果が得られ次第、別途報告する予定である。また、本研究の最終目標は広域の被覆分類であり、対象となる細目クラスは多数存在するが、多クラス分類への提案手法の拡張は別途検討する必要がある。

2.4 ミクセルの特徴

本論文が対象とするミクセルの場合、“海域と陸域”は海岸線に相当し、線状に現れる。一方、雲域は雲の種類や厚さ・大きさが不定であり、面状に存在するため、雲域を構成要素とするミクセル（海域と雲域、陸域と雲域）と“海域と陸域”のミクセルとでは空間的な特徴が異なる。本論文では、この相違に着目して以後の検討を行った。

3. クラス分類アルゴリズム

本論文で提案するクラス分類アルゴリズムの処理の流れを図2に示す。はじめに、対象画像からピュア画素クラスの各構成要素を自動抽出し、これを教師データとして採用した。次に、各バンドデータの特徴に基づき、ピュア画素の分類を行った。さらに、未分類画素を対象としクラス帰属度（着目画素における各クラスへ帰属する割合；合計は1）を用いたファジィ推論法による分類を施した。最後に、近傍画素との関連情報を用いてミクセル（海域と陸域）の分類を行った。なお、11月データを例にして以後の処理内容を述べるため、A~Hの値は11月データのものである。したがって、対象データにより各値は変動する。また、AVHRRは受動型センサであるため、夜間に取得したデータでは太陽光の反射が得られない。したがって、提案手法の適用は日中に取得されたデータに限定される。

3.1 構成要素推定処理

後述するクラス帰属度を用いた分類処理の教師データとして使用するため、3種類の構成要素を自動抽出した。

(1) 海域要素抽出: 第1バンドデータのDN値を第2バンドデータのDN値で除した値（バンド比）のヒストグラムを図3に示す。画素の集中する領域（山）は二つ存在することがわかる。すなわち、値の低い領域に位置する山は、陸域と雲域に対応する画素から構成され、値の高い領域に位置する山は海域に対応している。そこで、1.25以上の値を有する画素を海域の構成要素として推定した。なお、11月

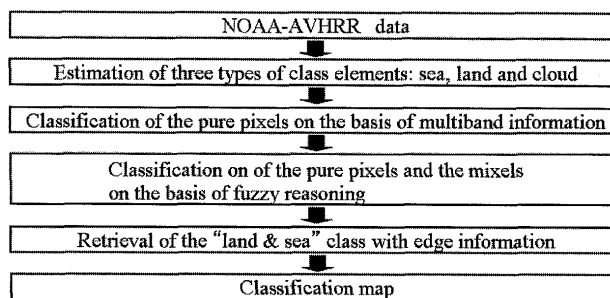


図2 提案アルゴリズムの流れ

Flowchart of procedures used in the proposed algorithm.




図3 バンド比ヒストグラム例

An example of the histogram for a ratio obtained from bands 1 and 2.

データ以外のデータについても上記ヒストグラムの傾向を認め、バンド比が適用できることを確認している。

(2) 雲域要素抽出: 第1バンドデータのDN値ヒストグラムを図4に示す。ヒストグラムには二つの山が存在していることがわかる。AVHRRは受動型センサであり、その撮像範囲は広域であるため、データ取得日時やデータ中の位置によっては、同一被覆物であってもDN値は異なる。しかしながら、対象データにより雲域要素の推定に用いる値は変動するものの、低輝度領域（図左部）および高輝度領域（図右部）に大別され、ヒストグラムの形状は保持される傾向を認めた。このため、 C_L （低輝度領域のピーク値）を基準とし、 C_H （高輝度領域のピーク値）との比に着目して、(1)式により閾値 T_c を求めた。さらに、DN値が T_c 以上の画素を雲域要素として推定した。

$$T_c = \frac{C_H - C_L}{3} + C_L \quad (1)$$

(3) 陸域要素抽出: 陸域要素の同一画素 (x, y) における第1バンド~第3バンドのDN値を比較したところ、第2バンドのDN値は第1バンドのDN値よりも大きく、かつ第3バンドのDN値は第2バンドのDN値よりも大きい傾向を認めた。

$$DN_1(x, y) < DN_2(x, y) \quad (2)$$

$$DN_2(x, y) < DN_3(x, y) \quad (3)$$

ここで、 $DN_i(x, y)$ は座標 (x, y) の第 i バンドデータのDN値であり、 $i = 1 \sim 3$ である。本論文では、(2)式および(3)式を同時に満足する画素を陸域要素とした。




図4 第1バンドデータのDN値ヒストグラム例
An example of the histogram obtained from band-1.


3.2 ピュア画素分類処理

バンド情報を単純に併用するのではなく、効果的に組合せることにより、分類精度の向上が期待できる。本論文では、以下の処理に従って3種類のピュア画素を分類した。


(1) バンド間特徴抽出による分類：処理の概要を図5に示す。第2バンドデータのヒストグラム(図5(a))に示されているように、低輝度領域と高輝度領域に大別することができる。このため、0から低輝度領域のピーク値A(DN値:60)までの範囲を海域ピュア画素候補、高輝度領域のピーク値B(DN値:500)から1023までの範囲を雲域ピュア画素候補とした。ただし、推定した領域間(A-B)にもピュア画素候補が存在する。さらに、ピュア画素候補の中には、ノイズなどの影響を受け、第1バンドと第2バンドのDN値が著しく変化する画素も含まれる場合を認めた。このような画素が含まれる値を閾値として用いた場合、海域と雲域のピュア画素候補の中に陸域のピュア画素も含まれることがある。そこで、陸域ピュア画素の棄却を目的としてDN値の差分に着目した処理を行った。第2バンドと第1バンドの差分ヒストグラムを図6に示す。ヒストグラムの両端に存在する画素は閾値推定に不要な画素である。そこで、差分値のヒストグラムの両端に位置する画素各35%ずつ、合計70%の画素のDN値は各クラスを決定する閾値にはなり難いと仮定して棄却した。なお、ヒストグラムのピーク値はデータ毎に若干の違いが認められるもの、形状は図6に示すような山が一つ存在することを確認している。また、棄却率の値が高くなると、棄却する画素の中に海域と雲域のピュア画素も含まれてしまうため、0%から40%までの間で値を5%刻みで変化させ、最適と判断した値(35%)を採用した。

次に、第2バンドデータで選定された画素(海域ピュア画素候補:DN値0~ピーク値A、雲域ピュア画素候補:ピーク値B~1023)(図5(a))の同一画素における第1バンドデータのDN値が取り得る範囲を求めた。ただし、上記処理同様、精度向上を目的としてDN値の差分情報からヒストグラムを作成し、棄却処理を行った。この結果、図5(b)に示すように、第1バンドデータにおける海域ピュア画素候補の範囲は点E~点F(DN値:67~84)、雲域ピュア画素候補の範囲は点G~点H(DN値:509~760)となる。


最後に、第1バンドデータで得られた海域ピュア画素候



(a)The histogram of band-2.



(b)The histogram of band-1.



(c)The histogram of the updated band-2.

図5 第1, 第2バンドデータを用いた特徴抽出処理
Feature extraction processing conducted between bands 1 and 2.




図6 第1, 第2バンドデータの差分ヒストグラム
A difference histogram computed from the 2nd and 1st band data.

補と雲域ピュア画素候補の範囲に帰属する画素の第2バンドデータのDN値が取り得る範囲をさらに求め、各クラス候補にそれぞれ追加した。この処理により得られた図5(c)の海域ピュア画素候補の閾値Cは62、雲域ピュア画素候補の閾値Dは494である。

上記処理の結果、11月データの海域のピュア画素候補は0~閾値C(DN値:62)に、雲域ピュア画素候補は閾値D(DN値:494)~1023にそれぞれ更新される。

(2)NDVIによる分類：山地、植生や市街地など陸域のクラスを構成する土地被覆物は多岐に亘る。すなわち、陸域のDN値は構成要素により多種多様に变化するため、これを考慮した分類を行う必要がある。また、AVHRRデー




図 7 NDVI と雲域構成要素による処理結果例
A result obtained from NDVI and class element of cloud.

タの撮像範囲は広いので、同一被覆物でも DN 値は異なる。一方、植生の有無、植生の多少、活性度、葉面積指数などに関連を有する指標として $NDVI^{16)}$ が提案されている。これは植生の分光反射特性が可視波長を吸収し、近赤外波長を強く反射する特性に着目したものであり、(4) 式により算出される。

$$NDVI(x,y) = \frac{DN_2(x,y) - DN_1(x,y)}{DN_2(x,y) + DN_1(x,y)} \quad (4)$$

ここで、 $NDVI(x,y)$ は座標 (x,y) の $NDVI$ である。しかしながら、 $NDVI$ の値は雲の影響を受けて変動するため、対象領域から雲域を除く必要がある。そこで、 $NDVI$ が 0 以上の領域 (図 7(a)) を抽出し、さらにその中から 3.1 節の処理により得られた雲域要素 (図 7(b)) の画素を除く領域を陸域ピュア画素候補 (図 7(c)) として選定した。

上記処理により得られた各クラスのピュア画素候補をピュア画素として分類した。

3.3 クラス帰属度を用いた分類処理

(1) クラス帰属度の算出：3.2 節までの処理では未分類の画素を対象とし、ファジィ推論法⁹⁾を用いて分類を行った。AVHRR データには、クラスの設定やミクセルに潜在的なあいまいさ、ならびに処理プロセスに介入するあいまいさが含まれている。これらのあいまいさを考慮するため、AVHRR データをスペクトル特徴空間上の「ファジィ集合」と定義し、ファジィ推論法を用いて着目画素のクラス帰属度を推定した。ファジィ推論法は、推論規則および前件部メンバーシップ関数からなる知識ベースと、後件部のファジィ推論から構成されている。推論規則は特徴空間を等間隔に分割して作成し、3.1 節の処理により各クラスの構成要素として自動抽出した画素 (第 1～第 5 バンドデータの DN 値) を教師データとして用い、その平均・分散により代表される正規分布型 (確率密度関数型) を前件部メンバーシップ関数として採用した。なお、メンバーシップ関数の形状について予備実験を行った結果、本論文が対象とするデータの場合、三角型よりも正規分布型メンバーシップを用いた方が良好な結果の得られることを確認している。また、ファジィ推論としては、多重ファジィ推論形式における後件部が実数値である簡略化ファジィ推論法¹⁷⁾を用いた。

(2) 分類処理：はじめに、構成要素 (海域・陸域・雲域) のクラス帰属度 (0～1) のうち、最大帰属度を有するクラスの値が閾値以上の場合は、そのクラスが注目画素における

支配的クラスであると認め、当該クラスのピュア画素として分類した。なお、本論文では閾値を 0.6 に設定した場合の処理結果について述べる。

次に、海域と陸域のクラス帰属度を比較し、値の大きい構成要素を雲域とのミクセルとして分類した。例えば、陸域が 0.45、海域が 0.25 の場合、その画素は「陸域と雲域」のミクセルとして分類した。

以上の処理によって、「海域と陸域」のミクセルを除く合計 5 クラスが分類される。

3.4 近傍画素情報を用いたミクセル分類処理

クラス境界に位置する画素は、画像濃淡が著しく変化するため、このため、海域と陸域の判別が容易な第 2 バンドデータに 8 方向のラプラシアンフィルタ¹⁶⁾を適用し、エッジを検出した。さらに、ミクセルは隣接する画素と独立して存在するものではなく、関連した要素を含むことに着目し、エッジが検出された画素の近傍 8 画素を対象として、以下の二つの条件を満足した画素を「海域と陸域」として判別した。

- ・近傍 8 画素が海域クラスと陸域クラスのみで構成されている。
- ・海域クラスと陸域クラスが近傍 8 画素中それぞれ 2 画素以上存在する。

4. 提案手法の評価

4.1 手動分類マップ

一般に、可視画像では、厚い雲は白または明灰色に見え、薄い雲は暗くまたは透けて見える。一方、赤外画像では、雲頂高度が高く、雲頂温度の低い雲は白または灰色に見えるのに対し、雲頂高度が低く、雲頂温度の高い雲は濃い灰色または地面や海面と混ざって見えることが報告されている¹⁸⁾。本論文では、提案手法や比較に用いた手法により得られた分類結果の評価を行うため、6 クラスの分類マップをオペレータが手動により作成した。

手動分類マップの作成手順を以下に示す。

(1) 雲域候補 (雲域のピュア画素とミクセル) について、第 1 バンドデータ (可視域) の DN 値が中輝度以上の画素を目視により判別した。なお、第 1 バンドデータに加えて、第 4・第 5 バンドデータ (熱赤外域) も用い、雲頂高度や雲頂温度なども考慮して判別を行った。

(2) 雲域候補の中で第 1 バンドデータの DN 値が高く、雲下が透けていない領域を「厚い雲」に対応すると仮定し、雲域のピュア画素として分類した。次に、上記 (1) の処理により得られた残りの雲域候補を「雲域のミクセル候補」と仮定し、地図情報を参照にして陸域または海域とのミクセルとして分類した。

(3) 雲域 (ミクセルを含む) 以外の領域を対象とし、地図情報や第 1～第 3 バンドデータ (可視域～近赤外域) を用いて、海域または陸域に分類した。

(4) 上記分類結果における「各クラスの境界」から、陸域

表 1 最尤法に用いた教師データ (教師データ B)
Supervised data for the maximum likelihood estimation.

	Band1	Band2	Band3	Band4	Band5
sea	89.0 (183.2)	61.7 (60.4)	52.3 (55.7)	460.9 (1772.6)	443.9 (1518.9)
land	110.1 (490.6)	149.7 (1022.8)	259.6 (4239.7)	482.7 (1334.3)	459.1 (1213.8)
cloud	488.0 (7952.5)	472.2 (8185.9)	540.5 (1925.6)	635.5 (4742.5)	609.9 (4664.1)
sea&land	95.3 (159.3)	71.7 (244.5)	73.7 (659.0)	467.1 (1527.0)	447.2 (1323.8)
sea&cloud	167.3 (1211.4)	133.1 (877.0)	220.8 (6371.0)	508.3 (1017.6)	493.1 (949.5)
land&cloud	195.5 (269.7)	188.9 (294.4)	369.2 (3449.6)	544.3 (1058.4)	522.6 (1188.1)

クラスと海域クラスの境界をすべて抽出し、これを“海域と陸域”のミクセルとして分類した。

図 1 に示した AVHRR データを対象として作成した手動分類マップを図 8 に示す。なお、図の上部中央 (陸域) において海域と分類されている領域は興凱湖である。

4.2 評価に用いた手法

提案手法の有用性を検証するため、教師つき分類法である最尤法¹⁶⁾、ならびに教師なし分類法である k-means 法¹⁶⁾を対象画像に施した。

最尤法では、設定クラス毎に教師データを予め作成する必要がある。そこで、対象画像から各クラスに対応する画素をクラス毎 (合計 6 クラス) にオペレータが 40 画素抽出し、これを教師データとして採用した。また、教師データの取り方によって分類結果は大きく異なるため、3 セット分の教師データ (教師データ A~C) を作成し分類精度について検討を加えた。なお、教師データとして選定した画素はすべて異なり、同一画素を再度選定しないように作業を行っている。教師データ B の詳細を表 1 に示す。上値は平均値を、下値は分散値をそれぞれ示している。雲域の分散が特に大きいことがわかる。さらに、使用するバンドデータの組合せによる分類結果の相違を検討するため、第 1~第 5 バンドデータから 3 種類 (組合せ数: 10) または 4 種類 (組合せ数: 5) のバンドを選択し、各バンドデータを用いて分類した結果についても比較を行った。

一方、k-means 法は $k=6$ とし、最大反復回数は 100 回としたが、クラス間移動画素が 1.0% 以下になったとき、処理を終了させている。

4.3 分類結果の評価方法

各手法による分類結果を評価するため、手動分類マップと分類結果の一致する割合を求めた。具体的には、手動分類マップと一致した画素数を手動分類マップにおける各クラスの画素数で除し、完全一致率 CMR_j を (5) 式を用いて求めた。

$$CMR_j = \frac{MP_j}{CP_j} \quad (5)$$

ここで、 MP_j は各手法の分類結果で手動分類マップと一致したクラス j の画素数、 CP_j は手動分類マップにおける当

該クラスの画素数である。ここで、 $j=1\sim 6$ であり、各クラスに対応する。

本論文では、2 種類のクラスから構成されるミクセルも対象としているため、ミクセルの構成要素の一致状況についても評価を行った。例えば、海域の画素を“海域と雲域”と分類した場合には、“部分一致”と見なすが、“陸域と雲域”と分類している場合には不一致と評価する。具体的には、完全一致した画素を除く残りの画素を対象とし、ミクセルの構成要素が部分的に一致している画素 IP_j の割合 PMR_j を (6) 式を用いて求めた。

$$PMR_j = \frac{IP_j}{CP_j} \quad (6)$$

さらに、完全一致率と部分一致率を用い、(7) 式により全体評価値 GE を算出した。

$$GE = \sum_{j=1}^6 a_j \times CMR_j + n \sum_{j=1}^6 a_j \times PMR_j \quad (7)$$

なお、 a_j は全体に占める各クラスの割合である。また、本論文では 2 クラスから構成されているミクセルを対象としているため、 $n=0.5$ とした。

5. 実験結果および検討

5.1 提案手法による分類結果

提案手法により得られた分類結果を図 9(a) に示す。ピュア画素およびミクセルを良好に分類している様子が認められる。また、図 9(b) に示すように、四国地方の海岸が“海域と陸域”のミクセルとして精度良く分類されていることがわかる。すなわち、手動分類マップと矛盾しない結果が得られている。このことは、同一画素における複数の特徴量の併用が分類精度の向上に寄与すること、ならびに被覆状況の把握にミクセルの利用が有用であることを示唆している。

5.2 比較手法による分類結果との比較

最尤法 (教師データ B 使用) および k-means 法を用いて分類した結果を図 10 および図 11 にそれぞれ示す。最尤法の結果では、手動分類マップにおける陸域や海域を“海域と陸域”のミクセルに誤分類している様子が認められる。また、k-means 法では、クラスとの対応が不明瞭な領域 (赤色) を“海域と陸域”として分類したものの、誤分類が多い。

一方、提案手法の分類結果では、近傍画素との関連情報を用いて分類を行っているため、他のクラスを“海域と陸域”とする誤分類が低下したと判断される。

5.3 分類マップを用いた評価

教師データ A~C を用いて最尤法により分類を行ったところ、全体評価値はそれぞれ 84.0%、84.4%、84.2% (平均 84.2%) となり、異なる教師データを用いてもほぼ同程度の精度が得られた。以後、最も良い精度の得られた教師データ B の結果を検討に用いる。また、第 1~第 5 バンドの中から 3 種類のバンドデータを選択し分類したところ、




図 8 手動分類マップ (図 1 対応)

Classification map drawn manually by the operator (corresponds to Fig.1).






図 10 最尤法による分類結果 (図 1 対応)

Classification map obtained using the maximum likelihood estimation (corresponds to Fig.1).



(a) Result of the target data.



(b) Result of shikoku Isl.

図 9 提案手法による分類結果 (図 1 対応)

Classification map obtained using the proposed method (corresponds to Fig.1).




図 11 k-means 法による分類結果 (図 1 対応)

Classification map obtained using the k-means clustering (corresponds to Fig.1).

71.8%~83.4% (平均 78.2%) の結果が得られた。同様に 4 種類のバンドデータを選択し分類を行ったところ、80.1%~85.2% (平均 81.5%) となり、第 1,2,4,5 バンドデータを用いたとき、全バンドデータを用いた場合と比較して良好な結果が得られた。

各手法 (提案手法, 最尤法 (全バンドデータ使用), 最

尤法 (第 1,2,4,5 バンドデータ使用), k-means 法) により得られた評価結果を図 12 にまとめる。この図は、CMR (完全一致率) と GE (全体評価値) を示しており、値が高くなるほど、分類精度が良いことを示している。最尤法や k-means 法の結果と比較し、CMR (完全一致率) では 7.6~28.0%, PMR (部分一致率) を考慮した GE (全体評価値) では 6.0~24.2% の割合で提案手法が良好にクラス分類を行っていることがわかる。

次に、各クラス (合計 6 クラス) の分類結果を表 2 に示す。クラス名の後ろの値は対象画像を占める当該クラスの割合 (%) を示している。例えば、海域 (sea) は全体の 44.7% を占め、提案手法はそのうちの 92.7% を正確に分類

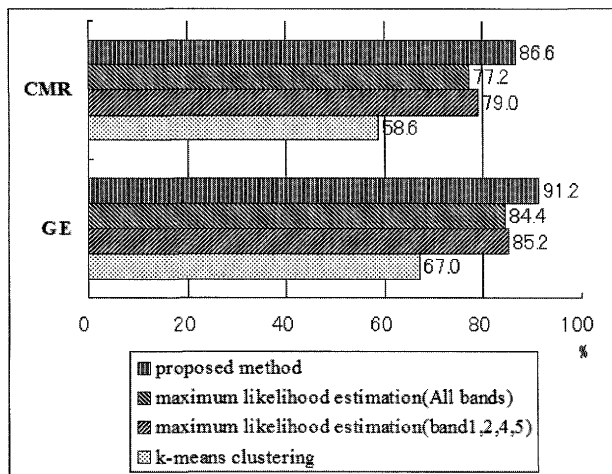


図 12 各手法の全体評価結果 (%)
Global Evaluation obtained by each method.

したことを意味している。提案手法は、海域などのピュア画素クラスを良好に分類しているものの、ミクセルについては、最尤法（全バンドデータ使用）が精度良く分類していることがわかる。このため、各手法が分類した画素の中で正しくクラスを選定した割合（適合率）を別途算出した。全体の 0.7% を占める“海域と陸域 (sea & land)” の場合、最尤法（全バンドデータ使用）と k-means 法の適合率はそれぞれ 6.2%, 1.4% であるのに対し、提案手法の適合率は 66.6% の結果が得られた。また、全体の 5.0% を占める“海域と雲域 (sea & cloud)” の適合率は、25.4%（最尤法）、0.2%（K-means 法）であるのに対し、提案手法は 31.6% であることが明らかとなった。すなわち、最尤法や k-means 法は誤分類も多いことがわかる。具体的には、図 10 や図 11 でも明らかのように、海域上に“海域と陸域”が多数分類されている。このミクセルは、雲域を構成要素とする他のミクセルと異なり、海岸線に対応するため、面状に存在することはない。一方、提案手法では、マルチバンド情報の DN 値に加えて、ミクセルの特性を考慮して近傍画素の情報を活用する処理を施しているため、他のクラスを“海域と陸域”とする誤分類はなかったと判断される。

最尤法は、対象画像毎に各クラスの教師データをオペレータが予め抽出する必要がある。また、k-means 法は分類結果と設定したクラスの対応付けをオペレータが行う必要がある。これに対して提案手法は、教師データの抽出やクラスの対応付けなどオペレータの処理が不要である。さらに、比較手法よりも精度良く分類可能であることが明らかになった。

以上の結果は、本論文で提案するミクセルを考慮したクラス分類アルゴリズムが AVHRR データの分類に有効であることを示唆している。

5.4 他時期取得データへの適用

提案手法の妥当性を検証するため、2001 年 4 月 7 日（4 月データ）、2002 年 7 月 12 日（7 月データ）、2004 年 1 月 31 日（1 月データ）に取得した AVHRR データに各手法を

表 2 分類マップとの比較結果 (%)

Individual evaluation with the manually classification map.

class (occupied rate)	proposed method	maximum likelihood estimation		k-means clustering
		All bands	band1,2,4,5	
sea(44.7%)	92.7	65.7	69.2	58.7
land(19.7%)	80.9	86.9	90.6	69.1
cloud(26.7%)	94.9	87.0	86.3	58.7
sea&land (0.7%)	47.4	65.1	54.7	35.9
sea&cloud (5.0%)	30.3	85.7	82.3	0.4
land&cloud (3.2%)	63.3	85.3	84.8	84.9

適用した。対象画像および得られた結果を図 13～図 15 に示す。

4 月データの場合、最尤法（図 13(c)）では陸域を精度良く分類しているものの、海域上に“海域と陸域”のミクセルが広く誤分類されている。また、k-means 法（図 13(d)）では陸域上に存在する雲域を“海域と陸域”として誤分類するとともに、陸域上における雲域を“海域と雲域”して誤分類している。

7 月データの第 1～第 3 バンドデータにおいて、左部の DN 値が上下方向に対し帯状に高い値を示していることを確認している。この影響により k-means 法（図 14(d)）や最尤法（図 14(c)）による分類結果においても当該領域が“海域と陸域”として誤分類されていることがわかる。

1 月データでは、細かな雲（雪氷を含む）から構成される雲域（ミクセルを含む）に対し、k-means 法（図 15(d)）では“海域と陸域”として誤分類している様子が認められる。また、最尤法（図 13(c)）でも同様の傾向が見られる。

一方、提案手法により得られた結果では、図 9 同様、精度良く各クラスを分類していることがわかる（図 13(b)～図 15(b)）。すなわち、データの取得された季節が異なっても陸域や海域などを良好に判読可能である。また、他のクラスを“海域と陸域”とする誤分類も認められない。さらに、例えば、1 月データの分類結果（図 15(b)）では、雲域（雪氷を含む）を詳細に推定していることがわかる。

提案手法は、広域かつ低分解能である AVHRR データのピュア画素およびミクセルの特徴を考慮し、(1) バンドデータの DN 値を併用するだけでなく、効果的に使用するバンドを選定し処理を施したこと、(2) 線状に現れる“海域と陸域”と、面状に現れる雲域を構成要素とするミクセル（海域と雲域、陸域と雲域）の空間特徴を考慮した処理を施したこと、(3) 近傍画素の情報を活用した処理を施したことにより誤分類も低減できたため、異なる時期に取得されたデータを対象とした場合でも良好に自動分類が行われたと考える。なお、残りの 8 枚の分類結果についても検討を加えたところ、提案手法は実際の被覆状況を反映した分類を行っていることが明らかになった。

以上の結果は、異なる時期に取得された AVHRR データについても提案手法が適用可能であることを示唆している。

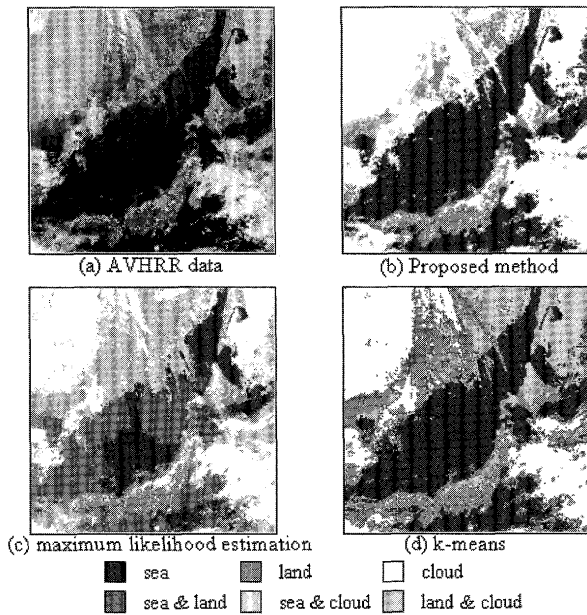


図 13 4月データの分類結果
Classification results obtained from the April data.

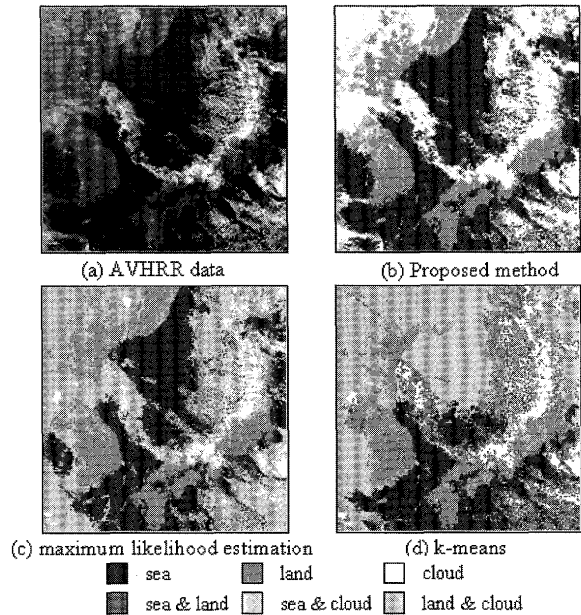


図 15 1月データの分類結果
Classification results obtained from the January data.

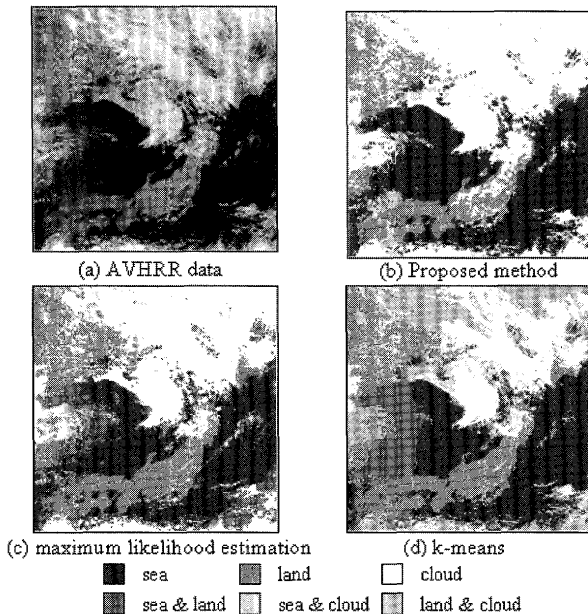


図 14 7月データの分類結果
Classification results obtained from the July data.

6. む す び

本論文では、ミクセルを考慮した NOAA-AVHRR のクラス分類アルゴリズムを提案しその有用性について検討を加えた。得られた成果の要点をまとめると以下ようになる。

(1) マルチスペクトルデータにおける同一画素上のヒストグラム情報の利用は、分類精度向上に寄与することを明らかにした。

(2) ミクセルを考慮した分類結果により詳細な被覆状況の判別が可能になることを明らかにした。

(3) 同一画素上の *NDVI* と雲域に関する情報の組合せは、AVHRR データにおける陸域の推定に有用であること

を明らかにした。

(4) エッジ情報および近傍画素との関連情報は、AVHRR データにおける“海域と陸域”のミクセル推定に有用であることを明らかにした。

(5) 教師データの選定を必要とする最尤法や分類後の処理が必要になる *k-means* 法と異なり、提案手法は自動クラス分類が可能であること、ならびに良好な分類が可能であることを明らかにした。

提案手法の問題点としては、雪氷領域も雲域として誤分類することが挙げられる。このため、冬季に取得されたデータにおける雲域と雪氷領域の判別、ならびに陸域における森林や市街地などの細目に関する分類について検討を加える予定である。また、3種類のクラスから構成されるミクセルの処理も今後の課題と考える。

最後に、本研究の遂行に協力下された本学情報工学科石沢千佳子助教および高橋毅技術職員に謝意を表します。本研究は、科研費若手研究 (B) (No. 18760295) により行われたことを付記します。

〔文 献〕

- 1) 米国海洋大気庁 Web サイト: <http://www.noaa.gov/>
- 2) J. Cihlar, H. Ly and Q. Xiao: "Land Cover Classification with AVHRR Multichannel Composites in Northern Environments," *Rem. Sens. Env.*, **58**, pp.36-51 (1996)
- 3) Z. Jin and J. J. Simpson: "Bidirectional Anisotropic Reflectance of Snow and Sea Ice in AVHRR Channel 1 and 2 Spectral Regions- Part I: Theoretical Analysis," *IEEE Trans. Geosci. Rem. Sens.*, **37**, 1, pp.543- 554 (Jan. 1999)
- 4) Y. Kageyama and M. Nishida: "A Method for Retrieving Sea Surface Temperature in Local Regions Using NOAA AVHRR: A Case Study in Japan Sea," *J. Geography*, **114**, 5, pp.739-750 (Oct. 2005)
- 5) J. J. Simpson and J. I. Gobat: "Improved Cloud Detection for Daytime AVHRR Scenes over Land," *Rem. Sens. Env.*, **55**, pp.21-49 (1996)
- 6) 小澤憲秋, 青木俊徳, 加藤寧, 根元義章: "局所領域でのクラスタリングによる衛星画像の雲域自動分類", *信学論*, **J84-DII**, 8, pp.1608-

1617(Aug. 2001)

- 7) P. Bosdogianni, M. Petrou and J. Kittler: "Mixed Pixel Classification with Robust Statistics," IEEE Trans., Geosci. Rem. Sens., **35**, 3, pp.351-559(May 1997)
- 8) F. Wang: "Fuzzy Supervised Classification of Remote Sensing Images," IEEE Trans., Geosci. Rem. Sens., **28**, 2, pp.194-201(Mar. 1991)
- 9) 西田真, 大塚敬, 田畑亮: "ファジィ推論によるミクセルのクラス混在率推定", 電学論 C, **116-C**, 3, pp.359-366 (Mar. 1996)
- 10) S.A. Ackerman, K.I. Strabala, W.P.Menzel, R.A.Frey, C.C. Moeller and L.E. Gumiey: "Discriminating clear sky from cloud with MODIS," J. Geophysical Research, **103**, 32, pp.141-157(1998)
- 11) Z. Li, J. Li, W.P. Menzel, T.J. Schmit, and S.A. Ackerman: "Comparison between current and future environmental satellite imagers on cloud classification using MODIS," Rem. Sens. Env., **108**, pp.311-326 (2007)
- 12) 北本朝展, 高木幹雄: "ミクセル密度を含む混合密度推定を用いたミクセルの面積占有率推定", 信学論, **J81-DII**, 6, pp.1160-1172 (Jun. 1998)
- 13) 北本朝展, 高木幹雄: "ミクセルの内部構造を反映する面積占有率密度を用いた画像分類法", 信学論, **J81-DII**, 11, pp.2582-2597 (Nov. 1998)
- 14) 須崎純一, 柴崎亮介: "ミクセルの存在とトレーニングデータの代表性を考慮した時系列低空間分解能画像を用いた土地被覆分類手法", 写真測量とリモートセンシング, **40**, 3, pp.14-24 (Jun. 2001)
- 15) リモートセンシング技術センター Web サイト: <http://www.restec.or.jp/>
- 16) 高木幹雄, 下田陽久 (監修): "新編 画像解析ハンドブック", 東京大学出版会 (2004)
- 17) 水本雅晴: "ファジィ推論 (1)", 日本ファジィ学会誌, **4**, 2, pp.256-264 (Apr. 1992)
- 18) 長谷川隆司, 上田文夫, 柿本太三: "気象衛星画像の見方と使い方", オーム社 (2006)



かげやま よういち

景山 陽一 1997年, 秋田大学大学院鉱山学研究所博士前期課程修了。同年, 秋田大学助手。2001年, 講師。2004年, 助教授。現在, 秋田大学工学資源学部情報工学科准教授。リモートセンシングデータの解析技術とアルゴリズムの開発, 情景画像における物体認識に関する研究に従事。博士(工学)。正会員。



まとう いくま

佐藤 郁磨 2008年, 秋田大学大学院工学資源学研究所博士前期課程情報工学専攻修了。在学中は, NOAA-AVHRR データのクラス分類アルゴリズムの開発に関する研究に従事。



にしだ まこと

西田 眞 1974年, 秋田大学鉱山学部電気工学科卒業。同年, トヨタ自動車工業(株)入社。1975年, 秋田大学鉱山学部助手。講師, 助教授を経て, 1996年同教授。2007年総合情報処理センター長。2008年工学資源学部長, 現在に至る。リモートセンシングデータの解析技術とアルゴリズム, 画像情報応用および知識情報システムの研究に従事。工学博士。正会員。