ファジィ推論によるミクセルのクラス混在率推定

正員 西田 眞 (秋田大学)

正員 大塚 敬 (秋田大学)

学生員 田畑 亮 (秋田大学)

Estimation of Class Mixture Proportion of Mixel due to Fuzzy Reasoning
Makoto Nishida, Member, Kei Otsuka, Member, Ryo Tabata, Student Member (Akita University)

This paper presents a fuzzy estimation method for the class mixture proportion of the mixed pixel(mixel) on a remote sensing image. The training data were selected by the operator based on the subjectivity and its distribution was defined as a fuzzy set on a spectral space. It was also assumed that the spectral characteristics of the mixel was regarded as a linear function of the reflection levels of the pure pixels corresponding to the component classes. A fuzzy production rule for the estimation of the class mixture proportion on the mixel was defined in accordance with this assumption. The estimation of the class mixture proportion for the proposed method was conducted by the fuzzy simplification reasoning method.

It was observed that the estimation accuracy of the fuzzy estimation method depended on the mesh interval. The mesh interval means the change percentage of the class mixture rate for the formation of the membership function. That is, the Total Root Mean Square error (TRMS) of the estimated value tended to decrease when reducing the mesh interval. The simulation results also indicated that the reasonable mesh interval (the change percentage of the class mixture rate) of the membership function might be about 0.05 (5%). It was also observed that the proposed method gave low TRMS to the simulation data which was produced by the random sampling of the training data of each class. Therefore, it was confirmed that the proposed fuzzy estimation method was an useful technique to estimate the class mixture proportion of the mixel on an actual remote sensing image.

キーワード：ファジィ推論，簡略化推論，リモートセンシング，ミクセル，クラス混在率

1. はじめに

衛星データの地上分解能を考えると、画像を構成する各画素が単独のクラス(分類のために設定する地表被覆物：例えば水田、農地、水域など)の輝度情報(Pure Pixel:ピュア画素)のみで構成される場合は少なく、現実には2種類以上のクラスの複合した輝度情報を合わせ持つ混合画素(Mixed Pixel:ミクセル)の多いことが知られている⁽¹⁾⁽²⁾。例えば、衛星に搭載されたセンサの瞬時視野が複数の異なる地表被覆物の境界に位置した場合には、それに対応する画素は複数のクラスの輝度情報が混在したミクセルとなる。従来の分類法、すなわち画像上のすべての画素を設定した特定のクラスに帰属させると言った概念に基づく方法⁽³⁾ではミクセルも特定のクラスで代表させることとなり、この結果瞬時視野内に含まれるその他のクラスは分類結果に反映されず、画像の分類精度を低下させると同時に実際の

土地被覆状況との相違を大きくする原因となっている。このため、ミクセルの処理が土地被覆分類を精度良く行う上で一つの課題となっており、確率論あるいは決定論に基づいたミクセルのクラス混在率の推定法が現在までに幾つか提案されている⁽¹⁾⁽²⁾⁽⁴⁾⁽⁵⁾⁽⁶⁾⁽⁷⁾。

一方、土地被覆分類は、クラスの設定やデータそのものに潜在する「本質的なあいまいさ」⁽⁷⁾と、処理プロセスに介在する「あいまいさ」を包含した形で行われている。例えば、分類を行うために設定するクラスの選定あるいは教師データの選択は、地図あるいは植生図等を参考として、オペレータの主観に基づいて決定されるのが一般的な方法⁽⁸⁾である。これらの決定プロセスには人間の主観に依存する「あいまいさ」が潜在するものの、これを数学的にモデル化することは事実上困難である。このため、この種の「あいまいさ」を表すのに適するとの考えから、ファジィ集合の概念を導入し、ファジィ推論によって分類を行なう

方法も幾つか提案されている⁽⁸⁾⁻⁽¹⁰⁾。しかしながら、これらの方法はミクセルをも含めて、画像上の全ての画素を設定した単独のクラスに帰属させることを目的に開発されたものであり、ミクセルに含まれる各種クラスの混在率推定を行なうものではなかった。

そこで本論文では、ミクセルのクラス混在率を推定する方法として簡略化ファジィ推論法を適用した結果について報告する。すなわち、教師データには各種の「あいまいさ」が含まれていることからこれを特徴空間上のファジィ集合と定義した。さらに、複数のクラスが混在するミクセルの輝度値は、混合している各クラスを代表するピュア画素の混在率を重み係数とするピュア画素輝度値の線形結合によって表されると見なした。この様な前提条件の基で簡略化ファジィ推論⁽¹¹⁾を用いたミクセルのクラス混在率を推定するアルゴリズム(以下、ファジィ推定法と称する)を提案し、混在率推定シミュレーションを行ない推定精度について検討を加えた。また、ファジィ推論法の有用性を確認するため、ピュア画素の画素値の分散を考慮したクラス混在率推定法として提案されている最尤推定法の考えに基づくカテゴリー分解法⁽⁵⁾(以下、最尤推定法と略称する)による結果との比較も試みたので報告する。

2. ファジィ推定法

〈2.1〉 ミクセルとピュア画素の線形性 ミクセルが設定した複数のクラスの混在した画素であれば、ミクセルのスペクトル特性は各クラスに対応するピュア画素のスペクトル特性の線形結合と考えることが出来る⁽⁵⁾。この場合、ミクセルのスペクトルと各クラスのスペクトルは、各クラスの混在率 $\vec{\alpha}$ を用いて次式で示される。

$$\vec{P} = \sum_{c=1}^N \alpha_c \vec{M}_c \quad \dots\dots\dots (1)$$

$$\sum_{c=1}^N \alpha_c = 1 \quad \dots\dots\dots (2)$$

$$\alpha_c \geq 0 \quad \dots\dots\dots (3)$$

ただし、

$\vec{P} = (p_1, \dots, p_k)^t$: ミクセルのスペクトル

$\vec{M}_c = (m_{c1}, \dots, m_{ck})^t$: ピュア画素のスペクトル

$\vec{\alpha} = (\alpha_1, \dots, \alpha_N)^t$: クラス混在率

$c=1 \sim N$: クラス, k : バンド数である。

クラス混在率 α_c , $c=1 \sim N$, は(2), (3)式を拘束条件として(1)式から求めることになる。

〈2.2〉 簡略化ファジィ推論による混在率推定法の概要と推定モデル 本研究では、クラスの設定およびそれに対応する教師データの選択時に生じる種々の「あいまいさ」を考慮するため、設定クラスの教師データをスペクトル特徴空間上の「ファジィ集合」と考えた。すなわち、各クラスに対応するスペクトルをメンバーシップのグレードで定義し、クラスに帰属する度合いを示した。また、ミクセルのスペクトル特性は各クラスに対応するピュア画素のスペ

クトル特性の線形結合であるとの考えに基づいて、種々の混在率で設定した各ミクセルに対しそれに対応する「ファジィ集合」を定義した。

さらに、ファジィ推論を用いてミクセル内に含まれるクラス混在率の推論規則を生成し、推定を行った。なお、ファジィ推論の知識ベースは、推論規則、前件部メンバーシップ関数より構成し、ファジィ推論法として、多重ファジィ推論形式において後件部が実数値である簡略化ファジィ推論法⁽¹¹⁾を用いた。

本研究では、簡略化ファジィ推論法を用いてミクセル内の各クラスの混在率を推定するファジィ推論規則を次のように与えた。

$$\left. \begin{array}{l} \text{規則 : } R_{i1} \cdots \text{and } R_{ik} \rightarrow \vec{Z}_i \\ \text{入力 : } x_1 \cdots \text{and } x_k \\ \hline \text{出力 : } \vec{Z}_0 \end{array} \right\} \dots\dots\dots (4)$$

ここで、(4)式における規則は、任意に混在率を設定した場合のミクセルのファジィ集合に関する推論知識である。なお、添え字 i は、第 i 番目の規則を意味する。ただし、 $i=1 \sim n$ である。

また、

R_i : バンド j のミクセルのファジィ集合、

$\vec{Z}_i$: 設定した混在率 : $[\vec{Z}_i = (\alpha_{i1}, \dots, \alpha_{iN})]$,

$\vec{Z}_0$: 推定した混在率の出力変数 : $[\vec{Z}_0 = (\alpha_1, \dots, \alpha_N)]$

x_j : スペクトルバンド j の入力値、

N : 設定クラス数, $j=1 \sim k$: スペクトルバンドである。

さらに、ミクセル内に混在するクラスの混在率の和は1であることより、混在率に次の拘束条件を与える。

$$\sum_{c=1}^N \alpha_c^i = 1, \alpha_c^i \geq 0 \quad (c=1, \dots, N) \quad \dots\dots\dots (5)$$

入力値「 $x_1 \cdots \text{and } x_k$ 」と各規則との適合度は、min演算を用いて、次式の様に与えた。

$$h_i = \mu_{i1}(x_1) \wedge \cdots \wedge \mu_{ik}(x_k) \quad \dots\dots\dots (6)$$

また、出力 $\vec{Z}_0$ は確定値 $\vec{Z}_i$ を適合度 h_i で加重平均することにより次式から求めた。

$$\vec{Z}_0 = \frac{\sum_{i=1}^n h_i \vec{Z}_i}{\sum_{i=1}^n h_i} \quad \dots\dots\dots (7)$$

なお、出力ベクトル $\vec{Z}_0$ の成分 α_c は(7)式より

$$\alpha_c = \frac{\sum_{i=1}^n h_i \alpha_c^i}{\sum_{i=1}^n h_i} \quad \dots\dots\dots (8)$$

と表される。ここで、出力 $\vec{Z}_0$ の各成分の和は、

$$\left. \begin{aligned} \sum_{c=1}^N \alpha_c &= \frac{\sum_{c=1}^N \sum_{i=1}^n h_i \alpha_c}{\sum_{i=1}^n h_i} \\ &= 1 \end{aligned} \right\} \dots\dots\dots(9)$$

となる。

したがって、(9)式より、 $\sum_{c=1}^N \alpha_c = 1$ となるので、推定混

在率は、ミクセルの混在率の条件(5)式を満足している。

また、各規則において設定した混在率は、ミクセルの混在率条件に基づき、(5)式に示されるN次元超平面を等間隔に分割し、各メッシュ交点に対応する値を用いた。なお、メッシュ間隔は混在率の変化割合を意味しており、メッシュ間隔を細かく設定すると推論規則数は増加し、その結果生成されるメンバーシップ関数の数も増加することになる。本論文ではメッシュ間隔が推定精度に及ぼす効果を検討するため、メッシュ間隔、すなわち混在率の変化割合を0.01~0.25 (1%~25%) の範囲に設定した場合についてシミュレーションを行った。

<2.3> 前件部メンバーシップ関数の生成 本研究では、各クラスの特徴としてランドサットTMセンサで得られた各バンド(スペクトル)の輝度値を用いた。このため、特徴空間は各バンドの輝度値を座標軸とする多次元空間となり、特徴ベクトルは各クラスの画素の輝度値となる。このような特徴空間Xにおいて、ミクセルのファジィ集合を人間が直接与えることは困難である。そこで、本研究では以下のような方法によって教師データを取得し、各クラスの各スペクトルバンドの輝度情報に基づき間接的に前件部メンバーシップ関数を生成した。なお、前件部メンバーシップ関数の形状は正規分布型とした。

(1)教師データの取得：地図および航空写真等を参考にし、画像内において特徴が均質であると考えられる領域を選定し、分類クラス(地表被覆物)を設定する。さらに、その領域内において各クラスに対応すると思われる画素を主観に基づいて抽出し、各クラスに対応する「教師データ(ピュア画素のファジィ集合)」と見なした。

(2)正規分布型(確率密度関数型)メンバーシップ関数の生成：各クラスのスペクトルの母集団分布が正規分布であると仮定し、教師データの平均、分散($m_{c,j}^*$, $\sigma_{c,j}^{*2}$)を用いて各クラスの確率密度関数 $f_c(x_j)$ を決定した。

$$f_c(x_j) = \frac{1}{\sqrt{2 \cdot \pi \cdot \sigma_{c,j}^{*2}}} \exp \left\{ -\frac{(x_j - m_{c,j}^*)^2}{2 \cdot \sigma_{c,j}^{*2}} \right\} \dots\dots(10)$$

ただし、 $f_c(x_j)$ は第cクラスの確率密度関数、 $m_{c,j}^*$ は第cクラスのバンドjの平均、 $\sigma_{c,j}^{*2}$ は第cクラスのバンドjの分散である。さらに、各クラスが混在率 $\vec{\alpha}$ で混在した場合のミクセルを考え、ミクセルと各クラスのスペクトルの線形性に基づいて、ミクセルの確率密度関数 $f_p(x_j)$ を

決定する。すなわち、確率密度関数は次の2つのパラメータ(平均と分散)で代表される。

$$\left. \begin{aligned} \text{ミクセルの確率密度関数: } f_p(x_j) \\ \text{ミクセルの平均: } m_{p,j} &= \sum_{c=1}^N \alpha_c m_{c,j}^* \\ \text{ミクセルの分散: } \sigma_{p,j}^2 &= \vec{\alpha}^T \cdot S_j \cdot \vec{\alpha} \\ S_j &= \text{diag}(\sigma_{1,j}^{*2}, \sigma_{2,j}^{*2}, \dots, \sigma_{N,j}^{*2}) \end{aligned} \right\} \dots\dots(11)$$

ただし、 $\vec{\alpha} = (\alpha_1, \dots, \alpha_N)$ はクラス混在率である。

また、生成されたミクセルのメンバーシップ関数の最大値を $\max f_p(x_j)$ とし、(11)式に示した確率密度関数 $f_p(x_j)$ をその最大値で割り、正規関数 $\mu_p(x_j)$ を定義し、これをメンバーシップ関数とした。

$$\begin{aligned} \mu_p(x_j) &= \frac{f_p(x_j)}{\max f_p(x_j)} \dots\dots\dots(12) \\ &= \exp \left\{ -\frac{(x_j - m_{p,j})^2}{2 \cdot \sigma_{p,j}^2} \right\} \end{aligned}$$

図1にメンバーシップ関数の一例を示す。(a)はミクセルの確率密度関数 $f_p(x_j)$ 、(b)は(a)で示したミクセルの確率密度関数 $f_p(x_j)$ を正規化し定義したメンバーシップ関数 $\mu_p(x_j)$ である。

(a)ミクセルの確率密度関数

(b)ミクセルのメンバーシップ関数

図1 ミクセルの確率密度関数およびメンバーシップ関数の例

Fig.1. Example of probability density and membership function.

3. クラス混在率推定精度の評価方法

＜3・1＞ クラス混在率推定シミュレーションの概要 本研究で提案した混在率推定方法の精度を確認するため、シミュレーションデータを用いて混在率推定を行い推定精度の評価を行った。また、相対的な推定精度の評価を行うため、最尤推定法に基づくクラス分解法⁽⁵⁾を用いて同様の混在率推定シミュレーションを行い、推定精度の比較、検討を行った。図2に本研究で行った混在率推定シミュレーションの処理フローを示す。

＜3・2＞ シミュレーションデータ 本研究で提案した混在率推定法の精度を確認するため、以下に示す方法によりシミュレーションデータ、すなわち、疑似的に設定した混在率に従って混合させた疑似ミクセルデータを用いて、混在率推定シミュレーションを行った。

- (1)ミクセル1：乱数を用いて全てのクラスに疑似的な混在率を設定する。さらに、各クラスの代表値(教師データの平均)を設定した混在率に従って混合し、推定対象のミクセルデータを作成した。
- (2)ミクセル2：乱数を用いて全てのクラスに疑似的な混在率を設定する。さらに、各クラスからランダムサンプリングした値を設定した混在率に従って混合し、推定対象のミクセルデータを作成した。

なお、ミクセル1は各クラスの教師データの「ばらつきを無視」した理想的な条件をモデル化した場合に相当し、線形的に作成されたシミュレーションデータと考えられる。一方、ミクセル2は各クラスの教師データの「ばらつきを考慮」した、より現実的な条件をモデル化した場合に相当し、非線形的に作成されたシミュレーションデータと考えられる。

図2 混在率推定シミュレーションの流れ
Fig.2. Flow chart of estimation for class mixture proportion.

＜3・3＞ 比較に用いた最尤推定法のアルゴリズム 本論文

文で提案したファジィ推定法の有用性を検証するため、ピュア画素の画素値の分散を考慮したクラス混在率推定法として提案されている⁽⁵⁾最尤推定法の考えに基づくカテゴリー分解法(以下、最尤推定法と略称する)との比較検討を試みた。最尤推定法のアルゴリズム⁽⁵⁾の概要は次のようになる。

最尤推定法はピュア画素の輝度値を正規分布に従う確率変数と仮定し、ピュア画素の輝度値を2種のパラメータ(平均, 分散)で代表させ、”求める解は、指定された従属変数値が観測される確率を最大にする”と言う最尤推定法の考えに基づいた方法である。すなわち、最尤推定法では、N個のカテゴリーからの情報が混在した場合、ミクセルからの分光ベクトル $\vec{T}$ はピュア画素の輝度値Aと混在率 α の線形結合で表されるとしている。この分光ベクトル $\vec{T}$ を確率変数と考え、第jバンドの観測輝度値(I_j)が観測される確率[尤度: $P(I_j)$]を次式のように定めている。

$$P(I_j) = \frac{\exp\left\{-\frac{(I_j - A_j)^2}{2\sigma_j^2}\right\}}{\sigma_j \cdot (2\pi)^{1/2}} \dots\dots\dots(13)$$

ここで、 A_j は混在するクラスに対応するピュア画素の輝度値に混在率を掛けた値の平均値、 σ_j はそのピュア画素の輝度値の分散である。

各バンド間で相関がないことを仮定すると、分光ベクトル $\vec{T}$ が観測される確率[尤度: $P(\vec{T})$]は次式から求められる。

$$P(\vec{T}) = \prod_{j=1}^k P(I_j) \dots\dots\dots(14)$$

ここで、kはバンド数である。最尤推定法はこの分光ベクトル $\vec{T}$ が観測される確率を最大にする混在率 α の値を求める解とする方法である。

＜3・4＞ 推定精度の評価方法 推定精度の評価方法として、

RMS誤差(Root Mean Square Error)、総RMS誤差(Total Root Mean Square Error)を用いた。RMS誤差、総RMS誤差の定義を次式に示す。

$$\epsilon_{RMS} = \left\{ \frac{1}{N} \sum_{c=1}^N (\alpha_{cSET} - \alpha_{cEST})^2 \right\}^{1/2} \dots\dots\dots(15)$$

$$\epsilon_{TRMS} = \left\{ \frac{1}{N \times M} \sum_{j=1}^M \sum_{c=1}^N (\alpha_{cSET} - \alpha_{cEST})^2 \right\}^{1/2} \dots\dots\dots(16)$$

ただし、 α_{cSET} は第cクラスの設定混在率、 α_{cEST} は第cクラスの推定混在率、Nはクラス数、Mはシミュレーション回数である。なお、本研究では100個の疑似ミクセルを作成し、それぞれのミクセルに関してクラス混在率を求めるシミュレーションを試みた。個々の疑似ミクセルに対する推定誤差を求める場合には(15)式を用い、シミュレーションを繰り返した後の平均を求める場合には(16)式を用いた。

4. 混在率の推定結果および精度評価

＜4.1＞ 使用したリモートセンシングデータ 本研究では、1986年8月26日にランドサット5号によって取得されたTMデータ(Path-low:108-32)を用いてクラス混在率の推定を行った。対象地域は秋田県大潟村の農業地帯であり、そのカラー合成画像を図3に示す。同地域の地図、作付け図(1986年8月調査)、航空写真(1986年7月30日撮影)および現地調査を踏まえて検討した結果、代表的な土地被覆として1.水域(大潟村中央幹水路)、2.水田、3.裸地、4.植生A(農地)、5.植生B(草地)の5種類のクラスを設定した。図3の画像から設定した土地被覆物が均質に分布していると思われる領域を選定し、領域内から各クラスに対応するピュア画素を主観に基づいて判断しそれぞれのクラスごとに40画素抽出し、これを教師データとして採用した。表1

図3 カラー合成画像
Fig.3. Color composition image.

表1 教師データの平均および標準偏差
Table.1. Average and standard deviation for training data.

クラス	Band 1	Band 2	Band 3	Band 4	Band 5	Band 7
水域	80.47 (1.50)	30.50 (0.84)	26.57 (0.95)	15.75 (3.82)	9.55 (2.55)	3.77 (1.19)
水田	78.95 (1.82)	33.83 (1.28)	26.60 (1.28)	106.25 (5.24)	50.70 (3.20)	14.40 (1.16)
裸地	109.70 (3.50)	50.40 (2.23)	58.80 (2.60)	60.73 (3.37)	95.88 (6.28)	53.42 (4.05)
植生A	80.22 (1.65)	31.85 (1.28)	24.60 (1.33)	156.43 (3.18)	98.20 (3.01)	28.85 (1.89)
植生B	82.50 (1.07)	33.95 (0.74)	26.77 (0.88)	120.28 (4.65)	81.75 (1.71)	21.73 (1.14)

上段：平均値 下段()：標準偏差

表2 教師データの主成分分析結果
Table.2. Principal component analysis result.

主成分	PC 1	PC 2	PC 3	PC 4	PC 5	PC 6
固有値	4.1149	1.7986	0.0488	0.0210	0.0106	0.0058
寄与率	0.6858	0.2997	0.0081	0.0035	0.0017	0.0009
累積寄与率	0.6858	0.9856	0.9937	0.9972	0.9990	1.0000

に抽出した各クラスの教師データの各バンド(ただし、バンド6は分解能が他のバンドと異なるため除外した)の平均および標準偏差、表2に取得した教師データについて主成分分析を行った結果(主成分固有値、寄与率、および累積寄与率)を示す。表中のPC1～PC6までの記号はそれぞれ第1主成分～第6主成分を意味する。また、教師データの第1～第2主成分の散布図を図4に示す。

なお、教師データについて主成分分析を行った後、各主成分を8ビットに量子化し、これを最尤推定法に基づくクラス分解の検証データとして用いた。

＜4.2＞ 混在率の推定結果

(1)シミュレーション結果：5種類のクラス全てに正の混在率を設定(仮定)した場合の、推定混在率およびその時のRMS誤差を求めた結果の例を表3に示す。なお、表3はメッシュ間隔を0.015625(1/64)に設定した場合の、ミクセルの設定混在率、ファジィ推定法および最尤推定法による推定混在率をあわせて示したものである。各クラスが種々な比率で混合しているミクセルに関して、どのクラスがどの程度混在しているかを、ファジィ推定法を用いることで推定可能であることが認められる。

(2)前件部のメッシュ間隔と総RMS誤差の関係：次に、前件部メンバーシップ関数のメッシュ間隔と混在率推定時の総RMS誤差の関係を図5に示す。なお、図5は100個のミクセルデータに関して混在率推定を行い、その推定誤差の平均(総RMS誤差)を求めた結果である。メッシュ間隔を細かく設定することで総RMS誤差の低下すなわち推定精度の向上が図られている。しかし、メッシュ間隔をある程度以上細かく設定すると、総RMS誤差の低下が認められなくなる。例えば、ミクセル1と2のいずれの場合においても、メッシュ間隔を0.05より細かく設定しても総RMS誤差の低下は認められない。この結果は前件部メンバーシップ関数のメッシュ間隔をある一定値以上細かく設定しても、混在率推定時の総RMS誤差の低下は期待されないことを示唆するものである。

図4 第1～第2主成分のクラス散布図
Fig.4. Scatter diagram between first and second principal component.

本研究ではEWS-350(NEC社製)を用い混在率推定シミュレーションを試みた。ファジィ推定法を用い100回のシミュレーションを実行するのに、メッシュ間隔0.05で約2分、0.02で約2時間、0.01で約60時間の計算時間を要し、メッシュ間隔を細かく設定すると計算時間が急激に長くなることを確かめている。これは、メッシュ間隔を細かく設定すると、それに応じて推論規則も増加するためと考えられる。以上の結果から、本論文で提案したファジィ混在率推定法において計算時間や推定時の総RMS誤差等を考慮すると、前件部メンバーシップ関数のメッシュ間隔を0.05に設定するのが適当と考える。

＜4.3＞ 最尤推定法による混在率推定結果との比較 最尤推定法を用いて混在率推定シミュレーションを行った結果を図6に示す。なお、最尤推定法に関しては第1～2主成分、第1～3主成分および第1～第6主成分までの3通りのデータを用いた場合について検討した。図6より、いずれのメッシュ間隔においても第1～6主成分を用いた場合の総RMS誤差が低い値を示している。そこで、以後シミュレーションデータとして第1～6主成分を用いた結果について比較を行う。最尤推定法を用いた場合も、メッシュ間隔を細かく設定することで総RMS誤差の減少、すなわち推定精度の向上が図られている。しかし、メッシュ間隔を0.03より細かく設定しても、総RMS誤差の減少は認められない。

ファジィ推定法と最尤推定法を用いた場合の推定精度を比較した結果を図7に示す。シミュレーションに用いたデータの種類によって、ファジィ推定法と最尤推定法の優劣

表3 混在率推定結果の例
Table.3. Example of estimation result for class mixture proportion.

推定法		水	域	水	田	裸	地	雑	生	A	雑	生	B	RMS誤差
	設定混在率	0.4530	0.0451	0.2732	0.0875	0.1409								
ファジィ推定法	ミクセル1	0.4328	0.1010	0.2811	0.0777	0.1072								0.0310
	ミクセル2	0.4530	0.0840	0.2666	0.0863	0.1098								0.0224
最尤推定法	ミクセル1	0.4375	0.0781	0.2656	0.0625	0.1562								0.0211
	ミクセル2	0.4843	0.0000	0.2500	0.1406	0.1250								0.0364
	設定混在率	0.1249	0.0840	0.1770	0.4823	0.1315								
ファジィ推定法	ミクセル1	0.0790	0.1318	0.1779	0.3685	0.2425								0.0770
	ミクセル2	0.0937	0.0815	0.1428	0.3117	0.3700								0.1327
最尤推定法	ミクセル1	0.0937	0.0937	0.1718	0.3906	0.2500								0.0686
	ミクセル2	0.1250	0.0000	0.1250	0.3281	0.4218								0.1535
	設定混在率	0.0998	0.4083	0.1316	0.2876	0.0725								
ファジィ推定法	ミクセル1	0.0841	0.3924	0.1290	0.2161	0.1781								0.0579
	ミクセル2	0.0550	0.4360	0.1280	0.2179	0.1628								0.0562
最尤推定法	ミクセル1	0.1093	0.3437	0.1250	0.2500	0.1718								0.0558
	ミクセル2	0.0468	0.4531	0.1406	0.2187	0.1406								0.0534
	設定混在率	0.4199	0.2878	0.0902	0.1771	0.0247								
ファジィ推定法	ミクセル1	0.4052	0.2693	0.0867	0.1182	0.1204								0.0513
	ミクセル2	0.3890	0.3213	0.0958	0.0866	0.1069								0.0584
最尤推定法	ミクセル1	0.4062	0.2656	0.0781	0.1093	0.1406								0.0614
	ミクセル2	0.3437	0.4062	0.0937	0.0000	0.1562								0.1170
	設定混在率	0.3354	0.2220	0.2055	0.0822	0.1547								
ファジィ推定法	ミクセル1	0.3426	0.2079	0.2089	0.1063	0.1339								0.0159
	ミクセル2	0.3689	0.1257	0.1812	0.1390	0.1849								0.0549
最尤推定法	ミクセル1	0.3437	0.1875	0.2031	0.0781	0.1875								0.0217
	ミクセル2	0.3906	0.0468	0.1718	0.1250	0.2656								0.0989

には相違が認められる。すなわち、各クラスのピュア画素の輝度値の平均値を用いて作成したシミュレーションデータ（ミクセル1）に対する推定結果に関しては、メッシュ間隔を0.03以下に設定した場合において、最尤推定法の総RMS誤差がファジィ推定法より低くなっている。これに対して、各クラスのピュア画素のデータからランダムサンプリングを行い、設定した混在率に従って混合し作成したシミュレーションデータ（ミクセル2）に対する推定結果に関しては、いずれのメッシュ間隔においてもファジィ推定法における総RMS誤差の方が低い値となっている。

図5 ファジィ推定法におけるメッシュ間隔と総RMS誤差の関係
Fig.5. Relation between mesh interval and TRMS error with fuzzy estimation method.

図6 最尤推定法におけるメッシュ間隔と総RMS誤差の関係
Fig.6. Relation between mesh interval and TRMS error with maximum likelihood method.

図7 ファジィ推定法と最尤推定法の推定精度の比較
Fig.7. Comparison of estimation accuracy between fuzzy estimation and maximum likelihood estimation methods.

表1に示したように、各クラスの教師データ、すなわちピュア画素の輝度値の分布にはばらつき（分散）が認められる。このため、実画像上におけるミクセルは各クラスの輝度値の代表値（平均）が混在率に応じて線形的に混合していると考えより、ランダムに混合していると考えた方が合理的と思われる。したがって、ばらつきを考慮して作成したシミュレーションデータ（ミクセル2）に対して優れた推定精度を与えるファジィ推定法は、実画像上のミクセル内のクラス混在率を推定する上で有用な手法となり得ると考える。

＜4.4＞ 設定クラスごとの推定誤差 次に、設定クラスごとの総RMS誤差をまとめた結果の例（ミクセル2の場合）を表4に示す。設定した各クラスの中で植生AとBおよび水田の推定誤差が比較的大きいことが認められる。特に、最尤推定法による植生AとBの推定誤差がファジィ推定法に比較して30～75%程度高い。最尤推定法においては、推定を行うクラスの統計的性質が推定精度に影響することが報告⁽⁵⁾されている。そこで、設定した各クラスの最大誤差生起確率⁽⁵⁾を求めた結果を表5に示す。植生A－植生Bと植生B－植生Aの組み合わせの最大誤差生起確率が相対的に大きいことが認められる。特に植生Bが植生Aに誤分類される確率が高く、植生Bの混在率推定において誤差が発生しやすい可能性が示唆される。この結果は最尤推定法による推定誤差の結果に一致している。

ファジィ推定法においても植生AとBの推定誤差は比較的大きいものの、最尤推定法ほど顕著な影響は認められない。この結果は、ファジィ推定法では教師データの統計的な性質が推定結果に及ぼす影響が少ないことを示唆するものであろう。

表4 設定クラスごとの総RMS誤差(ミクセル2)

Table.4. TRMS error of each class (mixel 2).

メッシュ間隔	推定法	設定クラス				
		水域	水田	裸地	植生A	植生B
0.1	ファジィ推定法	0.060122	0.108053	0.025538	0.099054	0.103791
	最尤推定法	0.059016	0.109705	0.037297	0.156794	0.241233
0.05	ファジィ推定法	0.052861	0.092686	0.021721	0.087500	0.087263
	最尤推定法	0.058666	0.091619	0.028247	0.132003	0.189534
0.02	ファジィ推定法	0.050541	0.087423	0.021605	0.085116	0.087668
	最尤推定法	0.052243	0.088831	0.026801	0.110329	0.153494

表5 最大誤差生起確率

Table.5. Occurrence probability of maximum error.

	水域	水田	裸地	植生A	植生B
水域	1.61×10^{-01}	1.46×10^{-08}	7.45×10^{-56}	2.90×10^{-27}	6.68×10^{-27}
水田	2.03×10^{-04}	1.18×10^{-01}	6.31×10^{-12}	3.92×10^{-04}	4.53×10^{-04}
裸地	3.35×10^{-18}	8.93×10^{-06}	6.48×10^{-02}	8.67×10^{-24}	2.47×10^{-18}
植生A	7.82×10^{-10}	7.24×10^{-04}	1.94×10^{-84}	1.33×10^{-01}	4.86×10^{-02}
植生B	7.71×10^{-39}	2.84×10^{-10}	6.07×10^{-57}	1.06×10^{-01}	1.80×10^{-01}

5. まとめ

本論文ではリモートセンシング画像に存在するミクセルのクラス混在率を推定する方法として、簡略化ファジィ推論を用いた方法を提案し検討を加えた。すなわち、教師データには各種のあいまいさが含まれていることから、これを特徴空間上のファジィ集合と定義し、さらにミクセルは混在率を重み係数とするピュア画素輝度値の線形結合であると見なし、簡略化ファジィ推論によってミクセルのクラス混在率の推定を行うアルゴリズム（ファジィ推定法）を提案し、混在率推定シミュレーションを行い検討を加えた。その結果、ミクセル内に混合する複数のクラスの混在率を、ファジィ推定法を用いることによって推定可能であることが認められた。また、メッシュ間隔、すなわち混在率の変化割合を細かく設定すると、生成されるメンバーシップ関数の数が増加し、それに伴い推定精度は向上することが認められた。特にメッシュ間隔（混在率の変化割合）を0.05程度（約5%）に設定した場合に、最も優れた推定結果が得られた。さらに、教師データのばらつきを考慮して作成したシミュレーションデータ（ミクセル2）に対して優れた推定精度を有していること、教師データの統計的な性質に影響されにくいことなどが明らかとなった。以上の結果から、ファジィ推定法はミクセル内のクラス混在率を推定する上で有用な手法となり得ることが示された。

最後に、日頃有益なご助言を賜っております本学電気電子工学科吉村 昇教授に厚く御礼申し上げます。また、航空写真および作付け図を提供下された秋田県大潟村関係各位、実験に協力下された林 建輔氏（現在、NEC 株）、および佐藤貴子技官に謝意を表します。

（平成7年7月26日受付）

文 献

- (1) 新井:「衛星画像の画素内情報の抽出」,写真測量とリモートセンシング,30,No.4,30(平3)
- (2) 松本・寺山・新井:「カテゴリー占有率推定に基づく画像分類」,日本リモートセンシング学会誌,Vol.13, No.3,23(1993)
- (3) 高木・下田:画像解析ハンドブック,p.660(平3)東京大学出版会
- (4) 稲村:「カテゴリー分解に基づくリモートセンシング画像の解析」,通信学論,J/70-C,241(昭62)
- (5) 松本・藤丸・土屋・新井:「最尤推定法に基づくカテゴリー分解」,写真測量とリモートセンシング,Vol.30, No.2,25(平3)
- (6) 新井・寺山・松本・藤丸・土屋:「隣接する境界画素内のクラス混合比推定を伴うコンテキスト分類」,日本リモートセンシング学会誌,11,No.4,33(平3)
- (7) Wang:"Fuzzy Supervised Classification of Remote Sensing Image",IEEE Trans, Geoscience & Remote Sensing,28,No.2,194(1991)
- (8) 奥谷・両川:「ランドサットデータを用いたファジィ推論による土地被覆分類」,電学論,Vol.113-C,No.7, 520(平5)
- (9) 張・下田・福江・坂田:「ファジィ推論を用いた土地被覆分類アルゴリズム」,写真測量とリモートセンシング, 27,No.5,76(昭63)
- (10) 清水:「リモートセンシング画像のファジィ分類」,写真測量とリモートセンシング,Vol.31,No.4,37(1992)
- (11) 水本:「ファジィ推論(1)」,日本ファジィ学会誌, Vol.4,No.2,256(1992)

西田 眞

(正員) 1952年1月18日生。74年3月秋田

大学鉱山学部電気工学科卒業。同年4月トヨタ自動車工業(株)入社。75年4月秋田大学鉱山学部電気工学科助手。87年10月同講師。92年8月同学部情報工学科助教授。各種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。63年11月~平成元年クラークソン大学客員研究員。59年電気学会論文賞,63年静電気学会論文賞授賞。ファジィ学会,リモートセンシング学会,写真測量学会,応用物理学会,IEEE会員。工博。

大塚 敬

(正員) 1933年7月11日生。57年3月早稲

田大学第一理工学部電気工学科卒業。同年4月富士電機製造(株)入社。88年4月秋田大学鉱山学部電気工学科教授。91年4月同学部情報工学科教授。電力システム並びに各種産業システムの制御,運用の知能化に関する研究に従事。計測自動制御学会,システム情報制御学会,電子情報通信学会,IEEE会員。工博。

田畑 亮

(学生員) 1970年4月17日生。94年3月秋

田大学鉱山学部情報工学科卒業。同年同大学博士前期課程入学,現在に至る。ファジィ理論を用いたリモートセンシングデータ解析に関する研究に従事。電気学会学生会員。