多重分光画像における画素内面積比の適応的推定[†]

喜 安 千 弥*・藤 村 貞 夫*

Adaptive Estimation of Component Proportion in a Pixel of a Multispectral Image[†]

Senya KIYASU* and Sadao FUJIMURA*

Spectral unmixing is a method by which to estimate the proportion of each component in a pixel using multispectral data. In conventional analysis of remotely sensed images, each pixel is classified into a single object category. However, the actual land surface corresponding to a pixel does not necessarily consist of only one category of objects. Therefore, estimating the proportion of components that exist in a pixel is often useful. The most commonly used method of spectral unmixing assumes that the component spectra are determined from training data. However, available training data do not always correctly represent the spectral characteristics of the categories within the objective area. In such cases, large errors may appear in the results of unmixing.

We propose herein the adaptive spectral unmixing method, which estimates suitable component spectra from the actual observed data and thus requires no training data. By adaptively estimating the component spectra from the set of observed data in the objective area, we can correctly estimate the proportion of components even if the spectral characteristics change with the location of objective area. In the proposed method, the spectral reflectance of pixels is expressed by vectors in multi-dimensional space, which can be written as linear combinations of component spectra weighted according to component proportion. We determine the component spectra by finding the minimum volume of simplex containing all of the reflectance vectors, where the vertexes of the simplex correspond to the component spectra.

We estimated the degree of errors by numerical simulation and compared the performance of the proposed adaptive method and that of the conventional method. We confirmed that the proposed method of adaptive unmixing provides better results than the conventional method when the spectral characteristics change with the location of the objective area.

Key Words: remote sensing, spectral unmixing, spectral reflectance, training data, representativeness

1. はじめに

リモートセンシングにおいては、航空機や人工衛星から観測された多重分光画像にもとづいて、地表の対象物が識別される。多くの場合は、対象物の分光特性の違いを利用して画素ごとに単一のカテゴリを対応させる処理（カテゴリ分解）が適用される。

カテゴリ分類は、画素がそれぞれひとつのカテゴリによって完全に覆われることを想定している。しかし、1画素に対応する地表の面積が広い場合は、実際にはその内部に複数のカテゴリが混在することが多い。このような場合、カテゴリ分類では画素内に少量のみ存在するカテゴリを検出することができない。そればかりでなく、複数のカテゴ

リが混在すると、画素はそれらの中間的な分光特性を示すため、全く異なるカテゴリに誤分類される危険性がある。

これに対して、画素にひとつ以上のカテゴリを対応させ、それらの面積比を推定しようとする処理が、カテゴリ分解である¹⁾。通常のカテゴリ分解法は、カテゴリに対応する要素スペクトルの線形結合によって観測スペクトルが生じるとのモデルにもとづいている^{1)~3)}。しかしこの方法を現実のデータに適用すると、しばしば結果に大きな誤差を生じることがある。その原因としては、対象におけるスペクトルの混合過程が実際には線形と見なせないことや、分解に用いた要素スペクトルが不適切である可能性があげられる。本論文では、後者の問題について取り扱う。

従来試みられているカテゴリ分解では、カテゴリごとに用意したトレーニングデータから要素スペクトルを推定して利用している。しかし、用意したトレーニングデータがカテゴリを適切に代表していなければ、推定された要素スペクトルは分解しようとする画素内の分光特性に一致せず、正しい分解結果が得られない²⁾。この問題（トレーニングデータの代表性の欠如）は、カテゴリ分解のみならず、

[†] 第39回 SICE 学術講演会で発表（2000・7）

* 東京大学大学院工学系研究科 東京都文京区本郷 7-3-1
（現、帝京平成大学情報学部）

* Graduate school of engineering, The University of Tokyo,
Bunkyo-ku, Tokyo
（Received December 25, 2001）
（Revised September 12, 2002）

通常のカテゴリ処理においても誤分類の大きな要因となることが知られている⁴⁾。本論文では、トレーニングデータの代表性の問題を解決するために、データ自身から要素スペクトルを適応的に推定することを考える。

混合物のスペクトルから要素物質のスペクトルを自動的に推定する研究としては、Lawton and Sylvestre の方法⁵⁾や、これにエントロピー基準を追加して未知スペクトルを推定した Sasaki らの方法⁶⁾などがある。しかし、リモートセンシングで扱う対象は、スペクトルに必ずしも顕著なピークが存在しないため、これらの方法をそのまま適用しても妥当な結果は得られない。

リモートセンシングにおいて、要素スペクトルをあらかじめ与えずにカテゴリ分解をおこなう提案は従来にも見られるが^{7), 8)}、トレーニングデータの代表性との関連や適応的な推定の有効性については明らかにされていない。本論文では、トレーニングデータの代表性の欠如がカテゴリ分解の本質的な誤差要因のひとつであることに着目し、その解決方法として観測データ自身から適応的に要素スペクトルを推定する方法を提案して、その効果を示す。

2. 画素のカテゴリ分解

ここではまず、通常のカテゴリ分解法において、トレーニングデータから要素スペクトルを推定する場合の問題点について述べる。

2.1 線形モデルにもとづくカテゴリ分解

通常のカテゴリ分解法は、以下のようなスペクトルの線形混合モデルにもとづいている。多重分光画像の M 画素の中に、 N 個のカテゴリが存在すると仮定する。 L 個の波長 $\lambda_1, \dots, \lambda_L$ で観測したスペクトルを、観測ベクトル $\mathbf{x}_i = (x_{i1}, \dots, x_{iL})^t$, ($i = 1, \dots, M$) であらわす。ここで t は転置をあらわすとする。

スペクトルの混合過程が、面積比で重みづけされた要素スペクトルの線形結合であらせると考えると、要素スペクトルをベクトル $\mathbf{s}_j = (s_{j1}, \dots, s_{jL})^t$, ($j = 1, \dots, N$) であらわしたとき、観測ベクトル $\mathbf{x}_i$ は、要素ベクトル $\mathbf{s}_j$ の線形結合として、

$$\mathbf{x}_i = c_{i1}\mathbf{s}_1 + c_{i2}\mathbf{s}_2 + \dots + c_{iN}\mathbf{s}_N \quad (1)$$

と表現できる。ここで、 c_{ij} は画素 i に含まれる要素 j の面積比である。これを行列で表現すると、

$$\mathbf{x}_i = \mathbf{S} \mathbf{c}_i \quad (2)$$

と書ける。ここで、 $\mathbf{S}$ は要素ベクトル $\mathbf{s}_j$ を列にもつ行列（要素行列）であり、 $\mathbf{c}_i = (c_{i1}, \dots, c_{iN})^t$ は面積比ベクトルである。画素内に存在する全カテゴリの面積比の合計は 1 であり、面積比は負にならないので、面積比ベクトル $\mathbf{c}_i$ は、

$$\sum_{j=1}^N c_{ij} = 1 \quad (3)$$

および

$$c_{ij} \geq 0 \quad (4)$$

を同時に満たす必要がある。

カテゴリ分解は、与えられた観測ベクトル $\mathbf{x}_i$ に対して、要素行列 $\mathbf{S}$ を用いて面積比ベクトル $\mathbf{c}_i$ を決定する処理である。通常のカテゴリ分解法では、要素行列 $\mathbf{S}$ を既知と仮定する。要素ベクトル $\mathbf{s}_j$ が線形独立であるとき、面積比ベクトル $\mathbf{c}_i$ は一般化逆行列を使って、

$$\mathbf{c}_i = (\mathbf{S}^t \mathbf{S})^{-1} \mathbf{S}^t \mathbf{x}_i \quad (5)$$

のように決定できる^{1), 2)}。実際の観測データを用いると、算出された面積比ベクトル $\mathbf{c}_i$ は、しばしば制約条件 (3), (4) を満たさないことがあるが、そのような場合は、観測ベクトル $\mathbf{x}_i$ とその推定値 $\mathbf{S} \mathbf{c}_i$ の残差を最小にするように面積比ベクトル $\mathbf{c}_i$ を定める。すなわち、制約条件 (3), (4) のもとで基準

$$|\mathbf{x}_i - \mathbf{S} \mathbf{c}_i| \rightarrow \min \quad (6)$$

を満たす $\mathbf{c}_i$ を面積比の推定値とする^{1), 2)}。

2.2 トレーニングデータによる要素スペクトルの推定とその問題点

上記の方法でカテゴリ分解をおこなうには、要素行列 $\mathbf{S}$ が既知でなければならない。実際の応用においては、画像中からカテゴリが既知のエリアを選択し、その領域の画素をトレーニングデータとして、平均値を要素ベクトル $\mathbf{s}_j$ とする。しかし、トレーニングデータから得られた要素ベクトルは、必ずしも分解しようとする画素内の分光特性と一致しない。その原因としては、使用したトレーニングデータがカテゴリを代表していないこと、同じカテゴリでも分光特性にばらつきがあること、分光特性の測定値に測定誤差が含まれること、などが可能性としてあげられる²⁾。たとえば、観測対象への光線の入射角と反射角は、観測地域の起伏やセンサからのルッキング角の変化に依存して地点ごとに変動する。このため同一カテゴリであっても、角度依存特性の影響で反射率は地点ごとに变化する²⁾。したがって、もしトレーニングデータを得た領域と分解しようとする領域の特性が大きく異なれば、面積比の推定結果に大きな誤差を生じる危険性がある。

3. 画素内面積比の適応的推定

同じ画像内で同一カテゴリの分光特性が変化する場合、カテゴリ分解を精度良くおこなうには、対象領域に応じて適切な要素スペクトルを用いなければならない。ところが、必要なトレーニングデータを異なる対象領域ごとに得ることはほとんど不可能である。そこで、観測データ自身から要素スペクトルを適応的に推定してカテゴリ分解に用いることを考える。

ここでの目標は、画素内にさまざまな未知の比率でカテゴリが含まれている画像に対して、観測ベクトル $\mathbf{x}_i$ から要素ベクトル $\mathbf{s}_j$ を求めることである。要素ベクトル $\mathbf{s}_j$ が決

Fig. 1 Estimation of component spectra by finding the vertices in multidimensional space

定されれば、面積比ベクトル c_i は (5) 式または (6) 式にしたがって従来と同様に推定できる。

3.1 要素スペクトルの推定原理

観測ベクトルは、(1) 式のように N 個の要素ベクトルの線形結合であらわされる。前記の制約条件 (3), (4) を常に満たす必要があるので、観測ベクトル x_i を多次元空間の 1 点と考えると、すべての観測ベクトルは N 個の要素ベクトル $s_1, \dots, s_N$ を頂点とする $N-1$ 次元単体 (simplex) の内部にしか存在できない。このとき、単一カテゴリーからなる画素の観測ベクトルは単体の頂点に対応し、要素ベクトルに等しい。しかし、その画素がどこに存在するかをあらかじめ知ることはできないので、要素ベクトルは未知である。ここでは、Fig. 1 のように多次元空間で単体の頂点を決定することにより要素ベクトルを推定する。

説明のため、まず要素ベクトルを頂点とする $N-1$ 次元単体 X_0 を仮定し、その体積を Q_0 とおく。一般に単体の体積は、単体の頂点を座標ベクトル $a_1, \dots, a_N$ であらわしたとき、

$$\frac{1}{(N-1)!} \text{abs} \begin{vmatrix} 1 & 1 & \dots & 1 \\ a_1 & a_2 & \dots & a_N \end{vmatrix} \quad (7)$$

で計算される⁹⁾。ただし、 $\text{abs} |\cdot|$ は行列式の絶対値である。すべての観測ベクトルは単体 X_0 の内部に含まれ、単一のカテゴリーからなる画素が単体 X_0 の頂点に対応する。

つぎに、すべての観測ベクトルを内部に含む任意の $N-1$ 次元単体 X を考える。すべての観測ベクトルを内部に含むということは、単体 X が単体 X_0 全体を内部に含むことを意味するので、単体 X の体積 Q について $Q \geq Q_0$ が成り立つ。ここで、 Q が最小値 ($= Q_0$) をとるのは、単体 X が単体 X_0 に一致する場合であり、このとき単体 X の頂点は要素ベクトルに等しい。

つまり、すべての観測ベクトルを内部に含み、かつ、体積が最小となるような単体 X を決定することによって、未知の要素ベクトルを推定することができる。

3.2 処理アルゴリズム¹⁰⁾

要素ベクトルの推定は、非線形最適化の演算を適用し、以下のアルゴリズムでおこなう。

観測ベクトルは分光データのバンド数が増加するほど高次元となるが、観測ベクトルが存在する空間は、要素ベクトル $s_1, \dots, s_N$ によって定まる N 次元空間である。まず観測ベクトルから N 個の基底ベクトルを導出し、基底ベクトルによって張られる特徴空間にすべての観測ベクトルを表現する。これにより、数十～数百次元の高次元分光データに対しても、データの次元数にかかわらず以下の同一の手順で解を求めることができる。

要素ベクトル s_j の数が N であるとき、 N 個の基底ベクトル $v_1, \dots, v_N$ によって、要素ベクトル s_j が

$$s_j = t_{j1}v_1 + t_{j2}v_2 + \dots + t_{jN}v_N \quad (8)$$

とあらわされるとする。正規直交基底ベクトル $v_1, \dots, v_N$ は、観測ベクトル x_i の 2 次モーメント行列

$$R = \sum_{i=1}^M x_i x_i^t / M \quad (9)$$

の固有ベクトルを用いることができる⁶⁾。この基底ベクトルによって張られる N 次元の特徴空間では、要素ベクトル s_j と観測ベクトル x_i は、それぞれ特徴空間内の点 $t_j = (t_{j1}, \dots, t_{jN})^t$ と $r_i = (r_{i1}, \dots, r_{iN})^t$ であらわされる。ここで、基底ベクトル $v_1, \dots, v_N$ を列にもつ行列を V とすると、

$$t_j = V^t s_j \quad (10)$$

$$r_i = V^t x_i \quad (11)$$

である。また、ベクトル $t_1, \dots, t_N$ を列にもつ行列を T とすると、(2), (10), (11) 式より、

$$r_i = V^t S c_i = T c_i \quad (12)$$

となる。これは、観測ベクトルに対応する r_i が要素ベクトルに対応する $t_1, \dots, t_N$ の線形結合として、

$$r_i = c_{i1}t_1 + c_{i2}t_2 + \dots + c_{iN}t_N \quad (13)$$

とあらわせることを意味している。 c_{ij} は (3), (4) 式の制約を受けるので、 r_i は、 $t_1, \dots, t_N$ によって定まる $N-1$ 次元単体の内部に存在する。たとえばカテゴリー数 3 の場合は、Fig. 2 に示す三角形の内部が観測ベクトルの存在領域となる。

ここで、すべての r_i を内部に含み体積最小となる単体を決定して、頂点 t_j に対応する要素ベクトルを推定する。 Q を $N-1$ 次元単体の体積とし、 P を要素ベクトルと面積比を非負とするためのペナルティ関数としたとき、文献 6) の方法と同様にして、 Q と P の和で目的関数 U を定義し、 U の最小化

$$U = Q + P \rightarrow \min \quad (14)$$

Fig. 2 Observed vector and component vector expressed in a feature space

が達成されるように $t_1, \dots, t_N$ を決定する. ペナルティ関数 P は,

$$P = \gamma \left\{ \sum_{j=1}^N \sum_{l=1}^L F(s_{jl}) + \sum_{i=1}^M \sum_{j=1}^N F(c_{ij}) \right\} \quad (15)$$

と定義する⁶⁾. ここで, γ は適当なスケールパラメータであり, $F(\cdot)$ は負の値に対してペナルティを与える関数

$$F(x) = \begin{cases} 0 & \text{if } x \geq 0 \\ x^2 & \text{if } x < 0 \end{cases} \quad (16)$$

である. 目的関数 U を最小化する t_j は, 非線形最適化の数値計算によって求める. 安定に解を求めるために, ここでは γ の初期値を 1 とし, γ を少しずつ大きくしながら解を収束させて最適化をおこなった⁶⁾. ベクトル t_j を決定すれば, 目的とする要素ベクトル s_j は, (8) 式より求められる.

4. シミュレーションによる面積比推定精度の検討¹¹⁾

同一画像内で対象の分光特性が変化して面積比の推定誤差を生じる状況を検討するため, 文献 2) と同様に反射率の角度依存特性に着目して反射率の変動をモデル化し, シミュレーション実験をおこなった.

通常, 反射率は入射角と反射角に応じて変化するため, Fig. 3 に示すようにセンサのルッキング角が変化すると, 対象の反射率も変動する. このような場合, 画像内の特定の領域から取得されたトレーニングデータは, 必ずしも画像全体を正確に代表していない. ここでは, カテゴリ i ごとに異なる変動率 r_i を仮定し, 反射率の変動を

$$s_{oi} = (1 + r_i) s_i \quad (17)$$

とモデル化する²⁾.

実験用の高次元分光センサ¹²⁾を用いて, 5 種類の対象物 (植物の葉 4 種および石) について分光反射率を実測し, 要素スペクトルとして用いた. これらは, 510~750nm に相当する 49 バンドで取得されたデータである. さらに, 要素スペクトルを計算機上で種々の比率で線形結合して, さまざまな観測スペクトルを発生させた. その際, 各成分に反射率の変動を与え, さらにノイズ成分を加えるために, 標準偏差が

Fig. 3 Angles of incidence and reflection which change with the looking angle

Fig. 4 Observed spectra

反射率 0.5% に相当する正規乱数を発生させて各バンドに加算した. カテゴリ数が 3, 4 および 5 の場合について実験をおこない, それぞれ, 線形結合で仮定した要素スペクトルを用いた場合と, 観測スペクトル自身から推定した要素スペクトルを用いた場合の面積比の推定精度を比較した.

カテゴリ数を 3 とし, 石, 落葉, 若葉のスペクトルから発生させた 31 個の観測スペクトルを Fig. 4 に示す. 観測スペクトルを 3 次元の特徴空間に表現し, それらを内部に含む三角形の頂点を求めた結果が Fig. 5 である. 非線形最適化の数値計算には, シンプレックス法を用いた. ペナルティ関数のスケールパラメータは $\gamma = 1$ を初期値とし, 解が収束するごとに γ を 10 倍しながら $\gamma = 10^{10}$ となるまで反復演算を継続した.

推定された頂点に対応する要素スペクトルを, 真のスペクトルと比較して Fig. 6 に示す. 推定されたスペクトルは, 真のスペクトルと良く一致した. 面積比の推定結果の数値例を Table 1 に示す. 反射率に 3 パターンの変動を与えたとき, 石, 落葉, 若葉の面積比が (33%, 33%, 34%) の場合と (25%, 25%, 50%) の場合について, それぞれ従来法と適応的推定法による面積比の算出結果を比較して示した. 観測データから要素スペクトルを推定して面積比を求めた場合は, 反射率が変動しても推定誤差は小さかったのに対し, あらかじめ与えた要素スペクトルを用いる従来法では, 最大約 10% の誤差が生じた.

Fig. 5 Estimation of component spectra in a feature space

Fig. 6 Estimated component spectra and the true spectra

(a) conventional estimation

(b) adaptive estimation

Fig. 7 Correspondence of the true value and the estimated value of component proportion when the number of categories is three

Table 1 Results of conventional estimation and adaptive estimation when the number of categories is three

variation of reflectance		method of estimation	category [%]		
			stone	fallen	young
a	stone : 0 % fallen : 1 % young : 2 %	(true value)	33.0	33.0	34.0
		1 conventional	31.3	34.9	33.8
		1 adaptive	32.8	33.2	33.9
		2 (true value)	25.0	25.0	50.0
b	stone : 1 % fallen : 2 % young : 4 %	2 conventional	22.6	27.2	50.1
		2 adaptive	24.8	25.0	50.2
		(true value)	33.0	33.0	34.0
		1 conventional	29.3	37.3	33.4
c	stone : 3 % fallen : 5 % young : 7 %	1 adaptive	32.8	33.2	33.9
		(true value)	25.0	25.0	50.0
		2 conventional	20.3	29.8	49.9
		2 adaptive	24.8	25.0	50.2
		(true value)	33.0	33.0	34.0
		1 conventional	25.4	42.3	32.2
		1 adaptive	32.8	33.2	33.9
		(true value)	25.0	25.0	50.0
		2 conventional	16.2	34.7	49.2
		2 adaptive	24.8	25.0	50.2

種々の面積比を仮定して発生させたテストデータについて、真値と推定値の対応関係をプロットしたグラフを Fig. 7 に示す。従来法で得られた推定値は、Fig. 7 (a) に見られるように真値の上下に大きくばらついており、誤差が大きいことを示している。これに対し、適応的な推定法で得られた値は、すべての点がほぼ Fig. 7 (b) の直線上に存在し、真値とよく一致している。観測データ自身から適応的に要素スペクトルを推定することにより、反射率の変動の影響を受けずに、従来法よりも精度良く面積比を推定できることがわかる。

カテゴリー数を 4 とし、37 種の観測スペクトルを発生させて実験をおこなった場合の、面積比の推定結果例を Table 2 に示す。また、真値と推定値の対応関係を Fig. 8 に示す。同様に、カテゴリー数を 5 とし、45 種の観測スペクトルを用いて実験をおこなったときの、真値と推定値の対応関係を Fig. 9 に示す。

カテゴリー数が増えると推定誤差が増加する傾向が見られるが、いずれの場合も従来法より精度良く面積比を推定で

Table 2 Results of conventional estimation and adaptive estimation when the number of categories is four

variation of reflectance		method of estimation	category [%]			
			stone	fallen	young	yellow
a	[%] stone: 0 fallen: 1	(true value)	40.0	30.0	20.0	10.0
		conventional	38.0	29.9	20.2	11.9
	young: 2 yellow: 3	adaptive	39.8	30.0	19.6	10.3
		(true value)	25.0	25.0	25.0	25.0
		conventional	21.6	24.3	25.5	28.6
		adaptive	26.4	25.2	24.7	24.1
b	stone: 1 fallen: 2	(true value)	40.0	30.0	20.0	10.0
		conventional	34.9	29.2	20.5	15.4
	young: 4 yellow: 8	adaptive	39.8	30.1	19.6	10.3
		(true value)	25.0	25.0	25.0	25.0
		conventional	17.0	23.2	25.8	34.0
		adaptive	26.4	25.2	24.7	24.1
c	stone: 3 fallen: 5	(true value)	40.0	30.0	20.0	10.0
		conventional	30.6	28.7	20.9	19.8
	young: 7 yellow: 9	adaptive	39.8	30.0	19.6	10.3
		(true value)	25.0	25.0	25.0	25.0
		conventional	12.7	22.6	26.4	38.3
		adaptive	26.4	25.2	24.7	24.1

きることがわかる。なお、評価関数は N^2 個のパラメータをもつため、カテゴリ数 N が増加すると最適化が急速に困難になる。本実験ではカテゴリ数 5 以下の範囲であれば安定に結果を求めることができた。

5. おわりに

カテゴリ分解による画素内面積比の推定において、トレーニングデータを用いずに、観測データ自身から適応的に要素スペクトルを推定することにより、対象の分光特性が領域ごとに変化する場合においても、精度良く面積比を推定できることを示した。トレーニングデータの代表性が悪いために従来のカテゴリ分解法では推定誤差が大きくなる場合においても、面積比の推定精度が向上することをシミュレーション実験により確かめた。

現実のデータに対しての有効性を確認すること、および、観測データ自身から要素スペクトルと同時にカテゴリ数も自動的に推定する方法を開発することが今後の課題である。

参考文献

- 1) 稲村実: カテゴリ分解に基づくリモートセンシング画像データの解析, 電子情報通信学会論文誌, **J-70-C-2**, 241/250 (1987)
- 2) 伊藤, 藤村: 画素のカテゴリ分解による面積比推定, 計測自動制御学会論文集, **23-8**, 800/805 (1987)
- 3) J.J.Settle and N.A.Drake: Linear mixing and the estimation of ground cover proportions, Int. J. Remote Sensing, **14-6**, 1159/1177 (1993)
- 4) 藤村, 豊田, 愛甲, 鈴木: 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)
- 5) William H. Lawton and Edward A. Sylvestre: Self Modeling Curve Resolution, Technometrics, **13-3**, 617/633 (1971)
- 6) Keiji Sasaki, Satoshi Kawata and Shigeo Minami: Estimation of Component Spectral Curves from Unknown Mix-

(a) conventional estimation

(b) adaptive estimation

Fig. 8 Correspondence of the true value and the estimated value of component proportion when the number of categories is four

ture Spectra, Applied Optics, **23-12**, 1955/1959 (1984)

- 7) Joseph W. Boardman and Fred A. Kruse: Automated spectral analysis: A geologic example using AVIRIS data, north Grapevine Mountains, Nevada, Proc. Tenth Thematic Conference on Geologic Remote Sensing, Environmental Research Institute of Michigan, I407/I418 (1994)
- 8) Walter Rosenthal: Estimating Alpine Snow Cover With Unsupervised Spectral Unmixing, IEEE Proc. IGARSS'96, 2252/2254 (1996)
- 9) 日本数学会編: 岩波数学辞典 第3版, 岩波書店 (1985)
- 10) 喜安, 藤村: 多重分光画像における要素スペクトルの適応的推定, 帝京平成大学紀要, **13-1**, 33/38 (2001)
- 11) 喜安, 藤村: 分光反射率の変動を考慮した画素内面積比の適応的推定, 第39回計測自動制御学会学術講演会予稿集, 301-A-2(CD-ROM) (2000)
- 12) 藤村, 佐藤, 伴, 山田, 石川: 高感度高分解能画像化分光センサの開発, 第51回応用物理学会学術講演会講演予稿集, 52 (1990)

(a) conventional estimation

(b) adaptive estimation

Fig.9 Correspondence of the true value and the estimated value of component proportion when the number of categories is five

[著者紹介]

喜安 千 弥 (正会員)

1986年、東京大学工学部計数工学科卒業、同年(株)日立製作所生産技術研究所勤務、91年東京大学工学部計数工学科助手、2000年帝京平成大学情報学部講師。博士(工学)。画像応用計測、パターン認識、リモートセンシングなどの研究に従事。

藤 村 貞 夫 (正会員)

1968年、東京大学大学院応用物理専門課程博士課程修了(工学博士)。同年同大学工学部計数工学科助手、講師、73年電気通信大学助教授、78年東京大学計数工学科助教授、88年同教授、2000年帝京平成大学情報学部教授。光情報処理、パターン認識、リモートセンシング、赤外放射計測、非接触計測などの研究に従事。