

ハイパースペクトルデータによる 都市域における植生分類手法の検討

Classification Methods for Vegetation in Urban Area using Hyperspectral Data

沖 一雄*、猿渡琢哉*、野川祐治**、州浜智幸***、大政謙次*
Kazuo Oki*, Takuya Saruwatari*, Yuji Nogawa**, Tomoyuki Suhama*** and Kenji Omasa*

* 東京大学大学院農学生命科学研究科 生物・環境工学専攻 〒113-8657 東京都文京区弥生 1-1-1
* The University of Tokyo

1-1-1 Yayoi, Bunkyo-ku, Tokyo 113-8657, Japan

** 環境省自然環境局新宿御苑管理事務所 〒160-0014 東京都新宿区内藤町 11

** Shinjuku Gyoen National Garden Office, Nature Conservation Bureau, Ministry of the Environment
11 Naito-cho, Shinjyuku-ku, Tokyo 160-0014, Japan

*** 株式会社パスコ中央省庁事業部環境グループ 〒153-0043 東京都目黒区東山 1-1-2 東山ビル 3F

*** Environment Group, Government Ministries Division, Pasco Corporation

Higashiyama Bldg. 3rd floor, 1-1-2 Higashiyama, Meguro-ku, Tokyo 153-0043, Japan

ABSTRACT

In general, it is important to acquire the many training data for classifying the vegetation by supervised classification method using hyperspectral data, which has effective information for classification. However, in urban area, it is difficult to acquire the many training data because it is difficult to find out the large training area of each interest. In this study, a new method for classifying the vegetation using hyperspectral remotely sensed data was proposed in order to resolve the problem of training data in urban area and was also compared with conventional methods. As a result, it was found that the proposed method is effective for classifying vegetation using hyperspectral data in urban area.

Key words : Supervised classification, Hyperspectral data, Remote sensing, Urban area, Vegetation

1. はじめに

近年、東京都においてビル緑化に関する基準の改正が行われた。これは都市で現在深刻な問題になっているヒートアイランド現象や大気汚染を低減させるためのものである。東京ではこれまでの100年で平均気温が数度上がり、夜間の最低気温が25度以上になる熱帯夜の日数もこの30年でかなり増え、さらに、都市部の局地的な集中豪雨なども発生しているため、抜本的な対策が必要となっていた。

東京都もこれまでに寺社や公園などの緑地化を進めてきたが、もはや手詰まりの状態となっていた。そこでビルの緑地面積を増やし、今まで緑化の対象になっていなかった屋上も緑化するように基準の改正を行い、少しでもヒートアイランド現象を食い止めようとしている。

一方、現代では都市の緑地や公園などに癒しを求めている人々が年々多くなってきている。その中で花や草本類などと同様に樹木に対する関心も高まっている。最近大きな公園などを訪れるとエリアごとに樹木種が記載されたパンフレ

ットや地図があり、大きな公園でなくても学校の校庭などには、樹種名が書かれている札が木に掛けられているのを目にすることがある。これまでは主に現地調査や、航空写真を撮って熟練者がその写真を判読することによって樹木種を識別していた。しかしながら、前者は多くの手間がかかり、後者は熟練した技術が必要となるという問題があった。

以上のことより都市域の屋上や公園などの植生を広範囲で容易に知ることができれば、緑化基準改正の効果や公園などの植生識別に役立つと考えられる。そのため、樹木種を広範囲で観測し、植生を容易に識別する分類方法の必要性が求められるようになってきた。現在、広範囲を容易に観測する手段として、対象地域を波長ごとに画像として観測し、有益な情報を得るリモートセンシング技術が活用されている。しかしながら、これまでのリモートセンシングにより観測された画像の多くはマルチスペクトル画像がほとんどであった。マルチスペクトル画像は広範囲を数バンドによって取得されるが、一般的に観測波長の分解能が1バンドあたり粗く、対象物の詳細がとらえにくいという欠点があるため、マルチスペクトル画像からでは都市域や緑地などという大まかな分類はできても、樹種間の違いなどの細かい分類は難しいという問題があった。従って、樹種間の違いなどの高精度な分類を可能にするためには、波長分解能のより高いバンドでの画像取得が必要となると考えられる。

近年、波長分解能が高く、多くのバンド数が観測可能なハイパースペクトル画像を用いた研究が盛んになってきている。すなわち、ハイパースペクトルはマルチスペクトルよりも情報量が多く、より細かい識別をおこなう際に有効な手段として注目されている (Oki et al., 2000)。例えば、Lewis et al. (2001) は、ハイパースペクトル画像によるオーストラリアの乾燥地でのバイオマス特定のための樹木の検出をおこなっており、Datt (2000) は、ハイパースペクトル画像による緑葉と枯れ葉の識別の評価をおこなっている。また、都市域に着目したハイパースペクトル画像を使用した研究としては、Roessner et al. (2001) がドイツの都市ドリスベンで家の屋根、道路、樹木、芝、裸地の5種類での識別を7 m × 7 m の空間分解能を持つハイパースペクトル画像を用いて80%程度の正解率で識別をおこなった報告がある。しかしながら、Roessner et al. (2001) はこの研究の大きな問題点としてミクセルの問題を取り上げ、7 m × 7 m ではミクセルが多くなり、それが原因で正解率が低くなるという結果を示しており、空間分解能が3 m × 3 m くらいまで上がればミクセルの影響が軽減でき精度はよりよくなるだろうと報告している。また植物種に関してハイパースペクトルを応用した研究としては、可搬型スペ

クトルメータを使用したCochrane (2000) のアマゾン熱帯雨林地帯での植物種の抽出に関する研究があり、分光波形の類似度と反射強度の差の二側面から評価することで94%の正解率で対象とした樹木を抽出することが可能であると報告されている。しかしながら、Cochrane (2000) の研究では、可搬型スペクトルメータより計測したスペクトル波形を用いたものであり、航空機等によるリモートセンシング画像を用いての判別ではなかった。さらにCochrane (2000) の研究テーマは一つの樹種の抽出であり、樹種間を識別しているわけではなく、樹種の分類方法の確立には到っていない。また熱帯雨林地域のように同種の植物が群生する地域での樹木種の識別は可能であっても、都市域のように同種の植物が点在しており、トレーニングデータのとりにくい地域での樹木種の識別は難しい問題であると考えられる。

本研究では、航空機により観測されたハイパースペクトル画像によって教師付き分類のための必要なトレーニングデータが取得できにくい都市域における植生の識別を評価し、検討することを目的とした。具体的には、航空機で観測した2 m × 2 m の空間分解能をもつハイパースペクトル画像を用いて、①植生と植生以外 ②芝と樹木 ③樹木種間、の三つの識別を行い、どの程度まで識別可能かを検討した。また三つの識別に対しマルチスペクトルデータにおいて、一般的な分類手法である i 最尤法、ii 最短距離法、近年、ハイパースペクトルデータ解析に使用される iii シェイプディファレンス法、そして本研究で新しく最短距離法とシャープディファレンス法を組み合わせた iv 距離・相関法を提案し、各教師付き分類手法の比較をおこなった。なお、本研究の対象地域としては、都市域に植生が多数存在する新宿御苑を選んだ。

2. ハイパースペクトルデータおよびグラウンドトゥルスデータ

2.1 新宿御苑で観測されたハイパースペクトルデータ

本研究では、都市域におけるハイパースペクトルデータによる植生の分類評価をおこなうために、対象エリアとして新宿御苑を選んだ。解析に使用した新宿御苑のハイパースペクトルデータは、2002年7月27日に(株)パスコ所有のセスナ208型に搭載されたセンサAISAによって観測された。2002年7月27日に取得されたハイパースペクトル画像は、空間分解能2 m × 2 m で、観測波長域429.5 nm ~ 902.3 nm をバンド数70で観測した。Fig.1に7月27日に観測された新宿御苑のハイパースペクトル画像を示す。また、Fig.2に、Fig.1のハイパースペクトル画像から抽出さ

れ、本研究の解析の一部として使用された各カテゴリの平均スペクトル波形（トレーニングデータ）を示す。なお、航空機は常に太陽を背にして飛行しているため、7月27日における観測範囲は新宿御苑全体を計測することができなかった。




Fig. 1 Hyperspectral image measured in Shinjuku Gyoen on 27th July 2002. The squares in image show the training area for each category, 1:Water, 2:Ume, 3:Sakura, 4:Grass, 5: Strong brightness area (Urban area), and 6:Urban area.

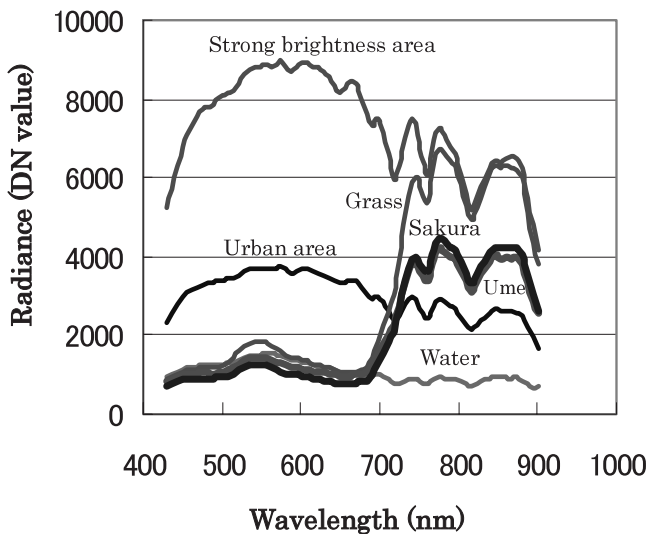


Fig. 2 Spectral radiance for each category extracted from hyperspectral image. These spectral radiance data for each category are used as training data.

2.2 グラウンドトゥルースデータ

ハイパースペクトルデータにおける分類評価のために、新宿御苑、(株)パスコ、東京大学により現地での共同調査および作業をおこない、新宿御苑における樹木マップを作成した。この樹木マップを本研究のグラウンドトゥルースデータとして使用し、教師付き分類に必要なトレーニングエリアとテストエリアを設定している。なお、樹木マップは

新宿御苑の樹木の位置や樹木ID、樹木種などがGISによりデータベース化されている。

3. 解析に使用した分類手法

本研究では、都市域におけるハイパースペクトルデータによる植生の分類検討をおこなうために、従来、マルチスペクトルデータに対して使用されてきた i 最尤法、ii 最短距離法に加え、近年、ハイパースペクトルデータに対して使用されている iii シェイプディファレンス、そして本研究で提案する iv 距離・相関法の四つの教師付き分類法による評価をおこなった。以下に各方法の特徴について述べる。

3.1 最尤法 (MLH)

最尤法はマルチスペクトルデータにおいて最もよく使用されている分類方法であり、誤分類したときの損出の期待値を最小にするというベイズの決定則に基づいている。いま、 n バンドのスペクトルデータ $x = (x_1, x_2, \dots, x_n)^T$ を k 種類のカテゴリ (w_1, w_2, \dots, w_k) に分類する場合、

$$\text{判別関数: } f_w(x) = (x - m_i)^T S_i^{-1} (x - m_i) + \ln |S_i| \quad (1)$$

を最小とするカテゴリ w_i に分類する。ここで、 m_i はトレーニングエリアにおけるサンプルの平均から算出されるカテゴリ w_i の代表ベクトルで、 S_i はカテゴリ i の分散共分散行列である。

最尤法は統計学的裏づけがあるため理論立てしやすく、これまでマルチスペクトルを用いた分類法として頻繁に使われてきた。しかしながら、①平均や分散、共分散を精度よく推定するために、トレーニングエリアにおける各カテゴリのサンプル数が特徴の次元数（ここではバンド数）に依存して多く必要であること、②各バンド間で相関が極めて強いと、分散・共分散の逆行列が存在しないか極めて不安定になること、③母集団の分布が正規分布に従わないときは正規分布の仮定に基づいた最尤分類は不適切であり、分類精度も低下することが欠点として挙げられている (Fujimura and Tsubaki, 1985, Ishida and Inamura, 2002)。

3.2 ユークリッド最短距離法 (MED)

ユークリッド最短距離法は、 n バンドのスペクトルデータ $x = (x_1, x_2, \dots, x_n)^T$ を k 種類のカテゴリ (w_1, w_2, \dots, w_k) に分類する場合、

$$\text{判別関数: } f_w(x) = (x - m_i)^T (x - m_i) \quad (2)$$

を最小とするカテゴリ w_i に X を分類する手法である。ここで、 m_i はトレーニングエリアにおけるサンプルの平均から算出されるカテゴリ w_i の代表ベクトルである。ユークリッド最短距離法の長所として判別関数が単純であり、

母集団の分布が正規分布に従わない場合でも比較的精度よく分類可能であるという報告がされている (Fujimura and Tsubaki, 1985)。さらにリモートセンシング画像の一画素におけるミクセルの影響がある場合でも比較的その影響を受けにくいという特徴も報告されている (Ishida and Inamura, 2002)。

3.3 シャイプディファレンス法 (SD)

シャイプディファレンス法は n バンドのスペクトルデータ $x = (x_1, x_2, \dots, x_n)^T$ を k 種類のカテゴリ (w_1, w_2, \dots, w_k) に分類する場合、

$$\text{判別関数: } f_{w_i}(x) = \cos^{-1} \left(\frac{\sum_n x \cdot m_i}{\sqrt{\sum_n x^2 \cdot \sum_n m_i^2}} \right) \quad (3)$$

を最小とするカテゴリ w_i に X を分類する手法である。ここで、 m_i はトレーニングエリアにおけるサンプルの平均から算出されるカテゴリ w_i の代表ベクトルである。(3)式より、シャイプディファレンス法は各カテゴリのスペクトル波形の相似性を考慮する式であるといえる。(3)式の値が 0 に近いほどスペクトル波形の類似性が大きくなる (Price, 1994, Cochrane, 2000)。

3.4 距離・相関法 (DC)

距離・相関法は、本研究で新しく提案する方法で、3.2の最短距離法と、3.3のシャイプディファレンス法の特徴を考慮した方法である。具体的には、観測された画像データにおける各画素ごとに (2) 式の最短距離法と (3) 式のシャイプディファレンス法により算出された値を 0 から 1 の間で線形化し足し合わせる方法で、 n バンドのスペクトルデータ $x = (x_1, x_2, \dots, x_n)^T$ を k 種類のカテゴリ (w_1, w_2, \dots, w_k) に分類する場合、

$$\text{判別関数: } f_{w_i}(x) = \frac{D_i - D_{\min}}{D_{\max} - D_{\min}} + \frac{\theta_i - \theta_{\min}}{\theta_{\max} - \theta_{\min}} \quad (4)$$

を最小とするカテゴリ w_i に X を分類する手法である。ここで、 D_{\max} および θ_{\max} は、各画素においてそれぞれ (2) 式および (3) 式から算出される最大値で、 D_{\min} および θ_{\min} は、各画素においてそれぞれ (2) 式および (3) 式から算出される最小値で、 D_i および θ_i は、各画素においてそれぞれ (2) 式および (3) 式から算出される値である。

4. ハイパースペクトルデータによる都市域の植生分類およびその検討

ここでは、都市域におけるハイパースペクトルデータによる植生分類手法について検討する。具体的には、新宿御

苑において航空機から観測された空間解像度 $2 \text{ m} \times 2 \text{ m}$ のハイパースペクトルデータから、①植生と植生以外、②芝と樹木、③樹木種同士 (ウメとサクラ) という三つの識別項目が識別可能かどうか検討するために、各識別に対し 1) 最尤法、2) 最短距離法、3) シャイプディファレンス法、4) 距離・相関法の四つの分類方法を用いて分類精度を評価した。

4.1 トレーニングエリアおよびテストエリア

通常、教師付き分類のためのトレーニングデータは特徴の次元数 (バンド数) の 2 倍ないし 3 倍が必要とされている。しかしながら本研究が対象としている新宿御苑などの都市域における植生の多くは人工的に植えられており、樹木が見栄えすることを最優先とされているため、自然状態と違い同種の植物が群生しているエリアが少なく、トレーニングデータとして扱えるデータ数も少なくなる。本研究では GIS によりデータベース化されている樹木マップを用いて、ハイパースペクトル画像データと対象樹木が完全に対応しているエリアのみからトレーニングデータを設定した。なお、本研究では各分類手法のトレーニングデータ数の影響を評価するために対象としているカテゴリを変え、以下の三つの識別項目に分けて検討した。

①植生と植生以外の識別

観測されたハイパースペクトルデータにおいて、都市域、水域、植生域 (芝、ウメ、サクラ) の 3 種類のトレーニングデータを設定し、各分類法により植生と植生以外 (都市域、水域) の識別が可能かどうか検討する。その際、それぞれのトレーニングデータ数 (ピクセル数) を 255 とした。

②芝と樹木の識別

観測されたハイパースペクトルデータにおいて、都市域、都市域の中で建物の反射が強いエリア、水域、芝および樹木 (ウメ、サクラ) の 5 種類のトレーニングデータを設定し、各分類法により芝と樹木の識別が可能かどうか検討する。その際、それぞれのトレーニングデータ数を 121 とした。

③樹木種間の識別

観測されたハイパースペクトルデータにおいて、都市域、都市域の中で建物の反射が強いエリア、水域、芝、ウメおよびサクラの 6 種類のトレーニングデータを設定し、各分類法によりウメとサクラの識別が可能かどうか検討する。その際、それぞれのトレーニングデータ数を 81 とした。

なお、上記の識別項目のうち、Fig.1 に、樹木種間の識別における 6 カテゴリのトレーニングエリアを、そして

Fig. 2に、そのトレーニングエリアにおける各カテゴリの平均スペクトル波形を示した。

次に、本研究で使用された四つの分類法の分類精度を評価するために、トレーニングデータと同様にGISによりデータベース化されている樹木マップを用いて、ハイパースペクトル画像データと対象樹木が完全に対応しているエリアのみからテストエリアを設定した。Table 1にテストエリアにおける各カテゴリのデータ数(ピクセル数)を示す。

Table 1 Number of pixels for each category in test area

	Urban area	Strong Brightness area	Water	Graas	Ume	Sakura
Number of Pixels	480	46	471	466	124	471

4.2 分類結果および検討

本研究では各分類手法の正解率を算出して分類精度の評価をおこなった。なお、正解率は、テストエリアにおける(正解ピクセル数)/(全ピクセル数)として算出した。

①植生と植生以外の識別

設定した3カテゴリのトレーニングデータを用いて、各カテゴリに対して各分類法により分類をおこない、その中で、植生と植生以外(都市域、水域)の識別が可能かどうか検討した。Table 2に植生(芝、ウメ、サクラ)と植生以外(都市域、水域)の識別における各手法の正解率を示す。Table 2より、各手法に関係なくほぼ100%識別可能であることが分かる。これは、ハイパースペクトルデータにおける分類のためのトレーニングデータ数が十分にあったためと、そして植生のスペクトルと植生以外のスペクトル波形がかなり異なっていたために、どの手法を用いても問題なく識別可能であったと考えられる。

②芝と樹木の識別

設定した5カテゴリのトレーニングデータを用いて、各カテゴリに対して各分類法により分類をおこない、その中で、芝と樹木(ウメ、サクラ)の識別が可能かどうか検討した。Table 3に芝と樹木(ウメ、サクラ)の識別における正解率を示す。Table 3において、最尤法による分類精度が他の分類法と比較してわるいことが分かる。これはトレーニングエリアにおいて取得したデータ数の少なさに関係しているためであると考えられる。なぜなら最尤法では、データの正規分布を想定して分類をおこなう手法のため、トレーニングエリアにおいて取得できるデータ数が少ない場合、各カテゴリ群により算出された平均、分散、共分散値を各カテゴリの代表値とし

てあつかうことが難しくなり、多くの誤分類が生じてしまうからである(Fujimura and Tsubaki, 1985, Ishida and Inamura, 2002)。すなわち、対象地域が都市域のようにトレーニングエリアにおける各カテゴリのピクセル数(データ数)が多くとれないところでは最尤法は分類手法として適していないといえる。

③樹木種間の識別

設定した6カテゴリのトレーニングデータを用いて、各カテゴリに対して各分類法により分類をおこない、その中で、樹木種間(ウメとサクラ)の識別が可能かどうか検討した。Table 4にウメとサクラの識別における正解率を示す。Table 4より、全ての分類において、正解率がウメに比べてサクラの方が低かった。これは、テストエリアにおけるサクラのスペクトル波形のばらつきが、ウメのばらつきよりも大きかったためである。次に、距離・相関法、シャープディファレンス法、最短距離法、最尤法の順で識別精度がわるくなっていることが分かる。従来マルチスペクトルバンドデータの分類法としてよく使用されている最尤法や最短距離法が相対的に識別精度が低かった。最尤法に関しては、②芝と樹木の識別で述べた同様な理由により識別精度が低かったと考えられる。また、最短距離法においても、トレーニングエリアにおける各カテゴリのトレーニングデータの平均を基準として識別しているため、取得できるトレーニングデータ数が少ない場合、各カテゴリ群により算出された平均が各カテゴリの代表値としてあつかうことが難しくなっていると考えられる。しかしながら、最尤法よりは、各カテゴリのトレーニングデータの平均のみを基準として識別しているため、比較的精度よく分類可能であったといえる。

また、本研究で提案した距離・相関法は、ウメとサクラの樹木種の識別に関して、それらのスペクトル波形が似ているにも関わらず、最低でも78.8%の精度で識別でき、近年ハイパースペクトルの分類法として有効とされているシャープディファレンス法より識別精度がよく有効であることが示せた。距離・相関法は、最短距離法とシャープディファレンス法の両方の識別特徴を合わせもつ手法であるため、それぞれの手法よりも僅かなスペクトル強度やその波形の差を特徴化することができ、①植生と植生以外、②芝と樹木、③樹木種間の識別の全てにおいて識別精度が安定してよかったと考えられる。このことより距離・相関法は、ハイパースペクトル画像を用いる樹木種分類において有効であることが示せた。

Table 2 Accuracy rate of classification for vegetation and other area by each method

	Vegetation area (%)	Other area (%)	Average (%)
MLH	99.8	100.0	99.9
MED	99.7	100.0	99.9
SD	99.9	100.0	100.0
DC	99.9	100.0	100.0

Table 3 Accuracy rate of classification for grass and forest area by each method

	Grass area (%)	Tree area (%)	Average (%)
MLH	62.9	94.9	81.3
MED	100.0	94.8	97.0
SD	100.0	84.8	91.2
DC	100.0	91.7	95.3

Table 4 Accuracy rate of classification for Ume and Sakura area by each method

	Ume (%)	Sakura (%)	Average (%)
MLH	100.0	5.0	27.4
MED	73.4	67.3	68.8
SD	95.2	65.1	72.2
DC	93.5	78.8	82.3

5. まとめ

都市域におけるハイパースペクトルデータによる植生分類では、バンド数やトレーニングデータ数を考慮した手法が必要であることを示した。具体的には、トレーニングデータが十分にあり、スペクトル波形がかなり異なっていた植生と植生以外の識別では、最尤法、最短距離法、シャイプディファレンス法、距離・相関法の全ての手法ではほぼ100%の正解率で評価可能であったが、芝と樹木の識別やウメとサクラの樹木種の識別のように識別が難しくなると従来のマルチバンドデータの識別に対して使用される最尤法や最短距離法の識別精度が低くなった。特に、最もよく使用されてきている最尤法の識別精度が極端に低かった。これは、ハイパースペクトルデータによる都市域における植生分類では、マルチスペクトルバンドデータよりもトレーニングデータ数を多く取得する必要があるが、都市域の植生域からはそのようなデータを数多く設定することが難しいためであるといえる。従って、従来最も多く教師付き分類法として使用されていた最尤法はハイパースペクトルデータによる都市域における植生分類に適していないことが示された。また、本研究で提案した距離・相関法は、ウメとサクラの樹木種の識別に関して、それらのスペクトル

波形が似ているにも関わらず、最低でも78.8%の精度で識別でき、近年ハイパースペクトルの分類法として有効とされているシャイプディファレンス法より識別精度が高く、有効であることが示された。従って、今後の航空機等のリモートセンシングによるハイパースペクトル画像からの樹木種分類の可能性を示せたといえる。しかしながら、樹木の識別精度が78.8%程度ではまだ十分な精度とはいえ、改善の必要があると考えられる。さらに本研究では樹種間の識別においてウメとサクラの2樹種間の識別のみをおこなっただけであるため、今後3樹種以上の識別についての評価もおこなう必要がある。

引用文献

- Cochrane, M. A., 2000 : Using vegetation reflectance variability for species level classification of hyperspectral data. *Int. J. Remote sensing*, **21**, 2075-2087.
- Datt, B., 2000 : Identification of green and dry vegetation components with a cross-correlogram spectral matching technique. *Int. J. Remote sensing*, **22**, 2133-2139.
- Fujimura, S. and Tsubaki, K., 1985 : Classification of multi spectral remotely sensed imagery. *Journal of the society of instrument and control engineers*, **24**, 25-30. (藤村・椿, 1985 : リモートセンシングにおける多次元画像の分類. 計測と制御, **24**, 25-30.)
- Ishida, H. and Inamura, M., 2002 : Evaluation Methods for Category Classification of Mixed Pixel Data. *Journal of Remote Sensing Society of Japan*, **22**, 2-11.
- Lewis, M. M., Jooste, V. and de Gasparis, A. A., 2001 : Discrimination of arid vegetation with Airborne Multispectral Scanner hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, **39**, 1471-1479.
- Oki, K., Funakoshi, Y. and Inamura, M., 2000 : Study on Estimation of the Specific Land Cover Ratio in a Pixel using Hyper-spectral Data -Estimation of the Vegetation Cover Ratio-. *Journal of Remote Sensing Society of Japan*, **20**, 17-33.
- Price, J. C., 1994 : How unique are spectral signature?. *Remote Sensing of Environment*, **49**, 181-186.
- Roessner, S., Segl, K., Heiden, U. and Kaufmann, H., 2001 : Automated differentiation for urban surfaces based on airborne hyperspectral imagery. *IEEE Trans. Geosci. Remote Sensing*, **39**, 1525-1532.