# 6. 林相区分・樹種分類の手法及びその検証

## 1.1.1. 手法概要

地上解像度の低い人工衛星リモートセンシング画像を用いた林相分類においては, 最尤法とよばれる画像分類手法が一般的に用いられてきた。最尤法は,ある特定の林 相範囲の画素値が従う確率分布をあらかじめ推定(教師データ)し,分類対象となる 画素値が含まれる確率が最も高い教師の林相クラスを,画素値の林相とする分類方法 である。最尤法は画素単位に処理が行われるため、ひとつの林相領域に含まれる植生 と影は異なるクラスに分類されてしまうという問題がある。地上解像度の高いデジタ ル空中写真へ最尤法を適用する場合には、地上解像度が高いことによる誤分類箇所の 多さが実用上の問題だった。

オブジェクトベース画像解析は、このような問題を克服することを目的として開発 された画像分類手法である。本解析手法は、樹冠の色情報をもとに林相区画線をあら かじめ自動生成し、区画線内で集計された色情報やテクスチャを基に、教師つき分類 によって樹種を分類するものである。あらかじめ生成した区画線内の平均統計量を分 類に用いることから、デジタル空中写真の高い地上解像度に起因する問題を克服する ことができる。本事業においては、地上解像度 50m のデジタル空中写真を用いること を想定し、オブジェクトベース分類による林相分類の手法を検討した。

#### 1.1.2. 林相区画の生成

林相区画(Forest type object)とは、林相によって区分された森林領域を指してお り、航空写真などの高分解能リモートセンシング画像を対象とした、オブジェクトベ ース(Object-based)画像解析による林相区分・樹種分類を行う上での基本処理単位 となっている。従って、林相区画を適切に生成することは、林相区分・樹種分類をよ り正確に行う上での必須の条件となる。林相区画の生成は、基本的に画像領域分割手 法を利用して、画像のスペクトル情報をベースとして、1 枚の画像を類似した特徴 を有する複数の小領域に分割する処理によって行われる。しかしながら、森林を対 象とする場合、異なる林分間の特徴の違いがそれほど顕著でないことや、反対に同じ 林分内における日向領域と日陰領域の違いによる画像の特徴のばらつきが大きいこと、 また、使用する画像データの撮影状況(撮影時期、バンド数など)も処理結果に影響 を与えるため、画像領域分割により林相区画を適切に生成することはそれほど容易な ことではない。それ故、画像領域分割による林相区画生成のアプローチや、パラメー タの検討などが必要となる。

#### (1) 画像領域分割

林相区画生成の基本となる処理は、画像の領域分割である。画像領域分割手法についてはこれまで数多くの研究が行われているが、有効な手法の1つとして領域併合

(Region merging)に基づく手法が利用されている。この手法では、領域併合の最初の段階では、画像にある全ての画素を個別のオブジェクト(画像領域)として設定し、 隣接する2つのオブジェクトを統合するかどうかは、統合後に生成される新しいオブ ジェクトの異質性(Heterogeneity)の変化を評価することによって決定される。領 域併合のオブジェクトの異質性の変化は、式(1)に示される併合前後におけるスペ クトル異質性の変化と形状異質性の変化によって算出される。

$$\Delta h = w_p \Delta h_p + w_t \Delta h_t$$

$$0 < w_p, w_t \le 1, \ w_p + w_t = 1$$
 (1)

ここで、*Δh*:併合前後の異質性の変化

併合前後のスペクトル異質性の変化 *Δh<sub>p</sub>*は、対象画像の各バンドにおける併合前後のオブジェクト内の画素値の標準偏差を用いて、式(2)によって計算される。

$$\Delta h_{p} = \sum_{i}^{N} w_{i} (n_{ab} \sigma_{i,ab} - (n_{a} \sigma_{i,a} + n_{b} \sigma_{i,b}))$$

$$0 < w_{i} \le 1, \ i = 0, 1, \dots N, \ \sum_{i}^{N} w_{i} = 1$$
<sup>(2)</sup>

ここで、N:画像のバンド数

 $w_i: バンド i の重み$  $n_{ab}: 併合後の新しいオブジェクトの画素数$  $n_a, n_b: 併合前の 2 つのオブジェクトの画素数$  $\sigma_{i,ab}: 併合後のオブジェクトのバンド i における標準偏差$  $\sigma_{i,a}, \sigma_{i,b}: 併合前の 2 つのオブジェクトのバンド i における標準偏差$ 

また、併合前後の形状異質性の変化  $\Delta h_t$  は、式(3) で示される compactness と smoothness といった 2 つの基準から定義される。

$$\Delta h_t = w_c \Delta h_c + w_s \Delta h_s$$

$$0 < w_c, w_s \le 1, \ w_c + w_s = 1$$
(3)

ここで、*Δh<sub>t</sub>*:併合前後の形状異質性の変化

 $\Delta h_c$ : 併合前後の compactness の変化

Δh<sub>s</sub>: 併合前後の smoothness の変化

 $w_c: compactness の重み$ 

 $w_s: smoothness の重み$ 

オブジェクトの compactness 基準はオブジェクトの周囲長と面積から計算され、一 方、smoothness 基準はオブジェクトの周囲長と境界ボックスの直径(長軸)から次 式によって計算される。

$$\Delta h_c = n_{ab} \frac{l_{ab}}{\sqrt{n_{ab}}} - \left(n_a \frac{l_a}{\sqrt{n_a}} + n_b \frac{l_b}{\sqrt{n_b}}\right)$$
$$\Delta h_s = n_{ab} \frac{l_{ab}}{b_{ab}} - \left(n_a \frac{l_a}{b_a} + n_b \frac{l_b}{b_b}\right)$$
(4)

ここで、*l<sub>ab</sub>*:併合後のオブジェクトの周囲長

*l<sub>a</sub>*, *l<sub>b</sub>*: 併合前の 2 つのオブジェクトの周囲長

b<sub>ab</sub>:併合後のオブジェクトの境界ボックスの直径
 b<sub>a</sub>, b<sub>b</sub>:併合前の2つのオブジェクトの境界ボックスの直径
 n<sub>ab</sub>:併合後の新しいオブジェクトの画素数
 n<sub>a</sub>, n<sub>b</sub>:併合前の2つのオブジェクトの画素数

併合前後のオブジェクトの異質性の変化 Δh が設定された閾値を超えない場合、領域の併合処理が実施され、閾値を上回る場合、領域の併合処理を停止する。設定された閾値はスケールパラメータ(Scale parameter)と呼ばれ、画像の分割処理によって生成されるオブジェクトの大きさを表している。スケールパラメータが大きいほど、より多くのオブジェクトが併合され、領域分割によって最終的に生成されるオブジェクトのサイズが大きくなる。

## (2) 林相区画の自動生成手法

オブジェクトベース画像解析による林相区分図の作成に関する研究が、近年数多く 見受けられるようになっている。これらの研究では、対象地域の単時期もしくは複数 時期の高分解能衛星画像や航空写真を用いて、画像の領域分割によって得られた画像 オブジェクトに対し、画像分類を行って林相区分・樹種分類図を作成する。ここ で、画像オブジェクトとは、類似した特徴を持つ複数の小領域を指した林相区 画のことである。従来の研究では、図 1.1.1 に示されているような単純な処理フロ ーにより、オリジナルの画像から直接的に林相区画の生成が行われている。



図 1.1.1 従来の林相区画生成のフロー



図 1.1.2 図郭 69 のサブ領域画像(小川試験地、11 月撮影画像)と拡大図



図 1.1.3 従来の林相区画生成フローによる画像の領域分割の結果

実際の画像では、異なる林分間の特徴の違いがそれほど顕著でなく、同じ林分内に おける日向領域と日陰領域の違いによる画像の特徴のばらつきが大きいため、画像の 領域分割によって林相区画が必ずしも適切に生成されるとは限らない。図 1.1.2 と図 1.1.3 は、2009 年 11 月に撮影された小川試験地の画像(図郭 69 のサブ領域画像と拡 大図)と、従来の林相区画生成フローによる画像の領域分割の結果を示している。従 来の林相区画生成フローでは、林相区画が適切に生成されていないことが分かる。

従って、ここでは階層的な画像領域分割に基づいて林相区画を自動生成するための 新たな手法を開発した。図 1.1.4 に、新たに開発した手法による林相区画自動生成の フローを示す。



図 1.1.4 開発した林相区画自動生成のフロー

新たな手法による林相区画自動生成のフローは、以下のステップから構成される。

- 最初に高分解能画像を用いて、画像ディグラデーション処理により低分解能画 像を生成する。
- ② 次に、低分解能画像を用いて、小スケールの画像領域分割を行う。
- ③ 小スケールの画像分割の結果に基づき、低分解能画像と高分解能画像の両方を用いて、中スケールの画像領域分割を行う。
- ④ 最後に、中スケールの画像分割の結果に基づき、低分解能画像と高分解能 画像の両方を用いて、大スケールの画像領域分割を行う。

上述の画像ディグラデーション処理では、入力画像に対し指定されたフィルタの畳 み込みを行った後、入力画像の行と列を間引くことでダウンサンプリングを行う。畳 み込みに用いるフィルタは、ガウシアンフィルタである。一般的な画像では、注目画 素に距離が近い画素の輝度値は注目画素の輝度値と近くなる場合が多く、注目画素か ら遠ざかるほど、注目画素の輝度値との差が大きくなる場合が多い。このような性質 を考慮し、注目画素に近いほど平均値を計算するときの重みを大きくし、遠くなるほ ど重みを小さくするようなガウス分布の関数を利用して入力画像の平滑化処理を行う。 2次元のガウス分布関数は、式(5)のように表される。

$$G(x, y) = \frac{1}{2\pi\sigma} e^{-\frac{x^2 + y^2}{2\sigma^2}}$$
(5)

ここで、σは平滑化の程度を決定するパラメータである。

なお、実験により、画像のダウンサンプリングは3回程度行うのが適当であること が分かっている。例えば、オリジナル画像の解像度が50cmの場合、3回のダウンサ ンプリングによって生成される低分解能画像の解像度は4mとなる。また、ガウシア ンフィルタリング処理のパラメータについては、解像度が50cmの場合、ウィンドサ イズを3×3、σは2程度の値を設定するのが適切である。

上述のように、画像ディグラデーション処理は、同じ林分内における日向領域と日 陰領域の違いによる画像のばらつきを軽減させる低分解能画像を生成可能である。さ らに、生成された低分解能画像と高分解能画像を併用して、階層的な画像の領域分割 を行うことにより、林相区画をより適切に抽出することが可能である。なお、森林の 場合は、林分の大きさにばらつきが大きいため、画像領域分割の際に小さなスケール パラメータと、中間的なスケールパラメータ、さらに、大きなスケールパラメータを 別々に設定してマルチスケールでの領域分割処理を行うことで、サイズの小さい林分 と大きい林分を含めた様々な林相を抽出することが可能となる。図 1.1.5 と図 1.1.6 には、新たな林相区画の生成手法による小スケールの画像領域分割の結果と、大スケ ールの画像領域分割の結果をそれぞれ示している。従来の林相区画の生成結果に比べ、 より適切に林相区画が生成されていることが確認できる。このようにして得られた林 相区画の自動抽出結果をもとに、人間が確認・修正作業を行うことで、より効率的に 林相区画を生成することが可能となる。



図 1.1.5 新たな林相区画の生成手法による小スケールの画像領域分割の結果



図 1.1.6 新たな林相区画の生成手法による大スケールの画像領域分割の結果

実際に林相区画を生成する際には、大容量の画像(例えば 1/5,000 の図郭、解像度 50cm の場合、画像サイズは 8,000×6,000 画素となる)を処理する必要がある。その ため、林相区画の作成は画像をタイル分割する方式で処理を行い、大容量の画像の場 合にも処理が適用可能となるような仕組みを構築した。図 1.1.7 に、実用的な林相区 画作成の処理フローを示す。なお、広範囲の林相作成処理を行う場合には、バッチ処 理モードによる連続的な処理によって対応が可能となっている。



図 1.1.7 実用的な林相区画の作成処理フロー

## (3) 階層的な画像領域分割による林相区画の生成パラメータの検討

オブジェクトベース画像解析による林相区分・樹種分類をより正確に行うためには、 林相区画がより適切に生成されることが必須の条件となる。林相区画を生成する際の スケールパラメータの設定は、生成される画像オブジェクトの大きさと均質性

(Homogeneous)に密接に関連しており、その後の林相区分・樹種分類の精度を大き く左右する。前述したように、今回新たに開発した階層的な画像領域分割手法により、 林相区画をより適切に抽出することが可能となったが、各階層における領域分割のス ケールパラメータをどのように設定するかについて詳しく検討することが重要である。

スケールパラメータは、画像オブジェクトの大きさに関連しているが、オブジェクトのサイズの値そのものではない。現時点でスケールパラメータの設定には決定論的、 または定量的な方法がなく、使用する画像の解像度と抽出するオブジェクトの特徴を 考慮して経験的に定める必要がある。林相区画の作成の場合、下記の2つの原則に従ってスケールパラメータを設定する必要がある。

- 同じ林分内でも画像の特徴のばらつきが存在するため、そのばらつきを網羅するように、できるだけ大きなスケールパラメータを設定することが望ましい。
- ② 林相区分・樹種分類はオブジェクトの単位で行うため、1つのオブジェクト中に 異なる林相が混在しないように、スケールパラメータを設定することが望ましい。

階層的な画像領域分割による林相区画の生成を行う場合のスケールパラメータの設 定は、以下のようなステップにより目視確認を行いながら、試行錯誤的に決定する。 ① 1 階層目のスケールパラメータの設定

画像ディグラデーション処理によって生成した低分解能画像を用いて、スケールパラメータを1から20程度の範囲で1~2刻みに変化させながら、領域分割数、領域分割面積を目視で確認し、適切なスケールパラメータを設定する。
 2 階層目のスケールパラメータの設定

- 1 階層目の画像領域分割の結果をもとに、高分解能画像と低分解能画像を併 用して、スケールパラメータを 10 から 100 程度の範囲で 10 刻みに変化させな がら、領域分割数、領域分割面積を目視で確認し、適切なスケールパラメータ を設定する。
- ③ 3階層目のスケールパラメータの設定

2 階層目の画像領域分割の結果をもとに、高分解能画像と低分解能画像を併 用して、スケールパラメータを 50 から 200 程度の範囲で 10 刻みに変化させな がら、領域分割数、領域分割面積、林分混在領域の有無を目視で確認し、適切 なスケールパラメータを設定する。

④ 各階層のスケールパラメータの調整

3 階層目の画像領域分割の結果について、分割後の領域の面積が小さく領域 分割数が多い場合、あるいは、分割後の領域の面積が大きく林分混在領域が存 在する場合には、2 階層目もしくは 1 階層目のスケールパラメータを調整し、 最終的な画像領域分割の結果を再度確認する。

このように、目視確認を行いながら繰り返し各階層のスケールパラメータを調整す ることによって、林相区画を生成する際のスケールパラメータを適切に設定すること ができる。図 1.1.8に、2009年9月に撮影した小川試験地の図郭56のサブ領域画像を 示す。図 1.1.9~図 1.1.11は、異なるスケールパラメータによる階層的な画像領域分 割の結果を比較したものである。図 1.1.9ではスケールパラメータの設定が小さいた め、生成される画像オブジェクト領域の面積が小さく、オブジェクトの数も過剰とな っている。図 1.1.10では、スケールパラメータの設定が大きいため、同一のオブジェ クトの中に異なる樹種が混在してしまっている。図 1.1.11では、スケールパラメータ の設定がこれらに比べて適切であり、同一のオブジェクトの中に異なる樹種は混在し ておらず、なおかつ、オブジェクト領域の面積も比較的大きな状態で生成されている ことが分かる。





図 1.1.8 航空写真フォルスカラーオルソ画像 (RGNIR) (左:解像度50cmの高分解能画像、右:解像度4mの低分解能画像)



スケールパラメータ:60 図 1.1.9 階層的な画像領域分割による林相区画の抽出結果 (スケールパラメータセット1)



スケールパラメータ:90

図 1.1.10 階層的な画像領域分割による林相区画の抽出結果 (スケールパラメータセット 2)



図 1.1.11 階層的な画像領域分割による林相区画の抽出結果 (スケールパラメータセット 3)

以上の検討により、林野庁仕様のデータセット(フォルスカラーオルソRGNIR画像、

解像度50cm)を用いた場合の階層的な画像領域分割による林相区画生成におけるスケ ールパラメータの設定は、1階層目に6、2階層目に60、3階層目に80程度の値を設定す ることが適切であると見積もることができる。ちなみに、航空写真トゥルーカラーオ ルソRGB画像の場合には、1階層目に3、2階層目に30、3階層目に65程度の値の設定 が有効であった。

# 1.1.3. 樹種区分

樹種区分の自動判読は、航空写真などを用いたリモートセンシング画像解析による 森林情報の取得における核心的な部分であり、これまでも数多くの研究が行われてき ている。航空写真の場合には、中・低分解能の衛星画像の場合の異なり、広範囲にわ たる領域を1年のうちに何度も取得するといったことが経済的に困難である。そのた め、多時期のデータを用いて異なる樹種の季節変化に伴う特徴の違いを利用するよう なアプローチでの判別方法を用いることは不可能である。従って、航空写真のような 単時期のデータを利用する場合、撮影時期にもよるが、画像のスペクトル情報よりも むしろ高分解能画像のテクスチャ情報を活用する方がより得策であると考えられる。

一方、高分解能画像を利用する場合、既往の研究では通常、画像の領域分割に基づ いたオブジェクトベースの画像分類を用い、画像のスペクトル情報、もしくはスペク トル情報とテクスチャ情報を併用して樹種の判別を行っている。しかしながら、実際 によく利用されているグレーレベル同時生起行列(GLCM: Grey Level Co-occurrence Matrix)などの統計的なテクスチャ情報については、樹種判別に際してどの程度の有 効性を発揮するのかが明確になっていない状況であり、また、林相分類に対してどの ようなテクスチャ情報が有効であるのかについてもいまだ明らかになっていないのが 実情である。

一方、画像分類による樹種区分に関する手法では、根本的に分類結果がトレーニン グデータに大きく依存してしまうという特性が存在しているため、トレーニングデー タの取り方や分布によって分類結果が大きく変わってしまうといった問題がある。樹 種区分におけるトレーニングデータの選び方についても、いまだ十分に解明が進んで おらず、正確かつ安定して樹種を判別するのは困難となっている。

上記で述べた種々の問題点を鑑みて、航空写真などの高分解能画像の解析による樹 種区分について様々な角度から詳細に分析を行って、実用化が可能な解析手法を新た に構築する必要がある。

#### (1) パターン情報による樹種判別の検討

森林画像の樹種判別では、基本的に画像のスペクトル情報を利用して、異なる樹種 のスペクトル反射特徴の違いから樹種の判別を行うことが一般的である。航空写真な どの高分解能画像を利用する場合には、画像の色調だけではなく、樹種の違いによっ て画像に表れる"きめ"、すなわち、テクスチャの特徴が樹種ごとにそれぞれ異なって いることに着目することが有用である。図 1.1.12 は、異なる樹種のパターン画像を 示しており、その違いが明らかであることが確認される。



図 1.1.12 異なる樹種のパターン画像 (左上:スギ、右上:ヒノキ、左下:広葉樹、右下:混交林)

ここでは、画像テクスチャを表現するために、従来用いられてきた画像の「統計量」 に基づいた特徴量ではなく、画像の「構造情報」に基づいた特徴量を利用することを 考える。画像からは様々な形でテクスチャの構造情報を抽出することが可能であるが、 実際に次のような特徴量について評価、検討を行った。具体的には、「画像の2 値化 による日向/日陰部分のパターン抽出」、「画像勾配の2 値化による日向/日陰の境界 線のパターン抽出」、「画像処理による孤立点情報の抽出」、「局所二値パターン(LBP: Local Binary Pattern)による詳細な構造パターン情報の抽出」、「ウェーブレット手 法による画像低周波成分と高周波成分の抽出」などである。これらに加えて、FFT 変 換や、自己相関、マルコフ確率モデルによる画像特徴情報抽出など、様々な手法を検 討した結果、樹種分類に有効な森林画像のテクスチャ構造情報を記述するための特徴 量として、最終的に下記に示す 3 つの情報量が最適であるとの結論に至った。

- ・ 画像の2値化による日向/日陰部分のパターン抽出
- 画像勾配の2値化による日向/日陰の境界線のパターン抽出
- ・ 局所二値パターン (LBP) による詳細な構造パターン情報の抽出

# 1) 画像の2値化による日向/日陰部分のパターン抽出

日向と日陰の部分に対するパターンの抽出には、画像処理の分野でよく知られ

ている「大津の自動判別手法」を利用した。大津の手法は、「判別分析法」 (Discriminant analysis)とも呼ばれ、画像の2値化を行う場面で広く活用され ている非常に優れた手法である。

大津の手法では、画像のヒストグラムに現れる双峰の形状が2つの異なるクラ スに属するデータの混在によって生じていると仮定する。従って、1枚の画像を 2つのクラスに分離する操作に相当する画像の2値化を行うための閾値の決定問 題は、2つのクラスのクラス間分散を最大にする値を見つけ出すという問題に置 き換えられる。図 1.1.13 は、大津の手法による画像の2値化のイメージを示し ている。



図 1.1.13 大津の手法による画像の2値化のイメージ

ある画像の画素数がNで、m 個のレベルの濃淡値を持つ場合、濃淡値iの画素数 $n_i$ とすれば、画素数Nは式(6)のように表される。

$$N = \sum_{i=0}^{m} n_i \tag{6}$$

また、濃淡値 i の画素の発生確率 p(i)は式(7) で計算される。

$$p(i) = \frac{n_i}{N} \tag{7}$$

もし、画像のヒストグラムを濃淡値 k において、2 つのクラス  $C_0$ 、 $C_1$ に分ける 場合、それぞれのクラスの発生確率  $\omega_0$ 、 $\omega_1$ と、その平均値  $\mu_0$ 、 $\mu_1$ はそれぞれ式 (8)、式(9)のようになる。

$$\omega_0 = \sum_{i=0}^{k} p(i) \equiv \omega(k)$$
  

$$\omega_1 = \sum_{i=k+1}^{m} p(i) \equiv 1 - \omega(k)$$
(8)

$$\mu_{0} = \sum_{i=0}^{k} ip(i|C_{0}) = \sum_{i=0}^{k} \frac{ip(i)}{\omega_{0}} = \frac{\mu(k)}{\omega(k)}$$
$$\mu_{1} = \sum_{i=k+1}^{m} ip(i|C_{1}) = \sum_{i=k+1}^{m} \frac{ip(i)}{\omega_{1}} = \frac{\mu - \mu(k)}{1 - \omega(k)}$$
(9)

また、画像全体の平均値 $\mu$ と濃淡値 $0 \sim k$ まで画素平均値 $\mu(k)$ は、それぞれ式(10)、 式(11)で表される。

$$\mu = \sum_{i=0}^{m} i p(i) = \omega_0 \mu_0 + \omega_1 \mu_1$$
<sup>(10)</sup>

$$\mu(k) = \sum_{i=0}^{k} ip(i) \tag{11}$$

従って、2つのクラスのクラス間分散 σ<sup>2</sup>(k)は次式のようになる。

$$\sigma^{2}(k) = \omega_{0}(\mu_{0} - \mu)^{2} + \omega_{1}(\mu_{1} - \mu)^{2}$$
$$= \omega_{0}\omega_{1}(\mu_{1} - \mu_{0})^{2} = \frac{\{\mu\omega(k) - \mu(k)\}^{2}}{\omega(k)(1 - \omega(k))}$$
(12)

 $\sigma^{2}(k)$ が最大になるような k を閾値 T=k として決定すれば、画像を 2 値化することができる。

大津の手法を用いて、画像の2値化によって自動抽出した異なる樹種の日向と日陰の部分のパターンを表 1.1.1 に示している。スギ、ヒノキ、広葉樹、および、非森林 領域について、日向と日陰の部分がそれぞれ異なったパターンの特徴として現れてい ることが確認できる。

スギ	ヒノキ	広葉樹	非森林領域

表 1.1.1 異なる樹種の日向部分と日陰部分のパターン

# 2) 画像勾配の2値化による日向/日陰の境界線のパターン抽出

画像の勾配は、各画素値の変化の度合いを示すものであり、注目点の画素が周 囲の画素の輝度に比べてどの程度変化したかを記述するものである。勾配情報の 算出には様々な手段があるが、1次微分フィルタとして下記の図 1.1.14 に示され るような SOBEL フィルタがよく利用されている。

-1	0	1
-2	0	2

-1	-2	-1
0	0	0

	-1	0	1					1	2	1
(	G <sub>HS</sub> (	水平	方向)	)			(	$G_{VS}$ (	垂直:	方向)

図 1.1.14 SOBEL フィルタ

水平方向の微分画像と垂直方向の微分画像をそれぞれ *G<sub>Hs</sub>(m, n*)、*G<sub>vs</sub>(m, n*)とす ると、式(13) により SOBEL の勾配値が計算される。

$$G(m,n) = \sqrt{G_{HS}(m,n)^2 + G_{VS}(m,n)^2}$$
(13)

日向と日陰の境界線のパターン抽出には、まず、前述のガウシアンフィルタを 用いて画像の平滑化処理を行う。次に、平滑化処理を行った画像に対して、SOBEL フィルタを用いて画像の勾配情報を算出する。最後に、大津の手法を利用して画 像の2値化処理を行って、画像勾配の高値部分(値の大きい方のクラス)を自動 抽出する。

画像勾配の2値化によって抽出した日向と日陰の境界線のパターンを

表 1.1.2 に示している。スギ、ヒノキ、広葉樹、および、非森林領域について、 日向と日陰の境界線の領域がそれぞれ異なったパターンの特徴として現れている ことが確認される。



表 1.1.2 異なる樹種の日向と日陰の境界線のパターン

# 3) 局所二値パターン(LBP)による詳細な構造パターン情報の抽出

森林画像の場合には、日照や写真の撮影角度、地形などの要因により、場所ご とに画像の明るさやコントラストが変動するため、これらの因子は樹種分類の結 果に多大な影響を及ぼす。局所二値パターンである LBP 情報は、濃淡画像のテ クスチャ分析と分類を目的として、画像の明るさやコントラストの変動に対して 頑健な特徴の抽出を行うために提案された解析手法である。LBP による解析の特 筆すべき利点として、抽出される特徴量が画像の濃度変化に対して不変となるこ とから、安定した画像テクスチャの抽出が可能となる点が挙げられる。また、LBP の演算は簡便であるため、計算コストが少なく処理速度が速い。さらに、LBP 解 析では、画像の詳細な構造パターンが抽出されるので、異なる対象が持つテクス チャの細かな違いを捉えることができる。図 1.1.15 には、LBP 手法を用いて、 対象画素に対して演算を行う場合の例を示している(灰色で表示している画素が 処理の対象画素)。

6	5	2
7	6	1
9	8	7

1	0	0
1		0
1	1	1

1	2	4
128		8
64	32	16

(a)対象画素とその周辺
 (b)対象画素周辺の2値化
 (c)重み
 図 1.1.15 処理の対象画素に対する LBP の計算例

LBP は、図 1.1.15 に示すように、対象画素とその周囲 8 近傍にある画素の画素値とを比較し、近傍画素の情報を用いて対象画素に対して新たなラベルを付与する手法である。まず、濃淡画像のそれぞれの画素 *i* に対して、その画素値 p(i) を周囲 8 近傍の画素値  $p_1(i), \dots, p_8(i)$ と比較する。具体的な演算としては、それぞれの近傍画素ごとに下記の式を用いて 2 値化を行う。

$$b_{j}(i) = \begin{cases} \frac{1, \ p(i) \le p_{j}(i)}{0, \ otherwise} & (j = 1, \cdots, 8) \end{cases}$$
(14)

図 1.1.15 (b)に示されている周辺画素の 2 値化後の値 b<sub>j</sub>(i)は、図 1.1.1 (c)に示 す重みとそれぞれ乗算して加算することで対象画素の LBP 値が算出される。す なわち、図 1.1.15 に示す例の場合には、LBP=1+16+32+64+128=241 といった 値が付与される。図 1.1.16 には、カラー画像から LBP 画像を算出した例を示し ている。コントラストが異なる画像から生成された LBP 画像のテクスチャが同 ーとなっており、画像の明度やコントラストの変化に対して、LBP 手法が頑健で あることが確認できる。



図 1.1.16 コントラストの異なる画像に対する LBP 変換の例

画像の局所二値パターンは、画像の詳細な構造的なパターンを反映しており、 しかも、画像の明るさの変動の影響を受けにくいため、画像のテクスチャ解析に 適している。LBPによって抽出した画像の詳細な構造パターンの例を表 1.1.3 に 示す。スギ、ヒノキ、広葉樹、および、非森林領域について、LBPによってそれ ぞれ異なった構造的なパターンとして特徴の抽出が行われていることが確認され る。



表 1.1.3 異なる樹種の詳細な構造パターン情報

上述した3種類の画像テクスチャ構造情報は、森林画像における日向領域と日陰領 域のパターン特徴を低周波域から高周波域までの3つのレベルで提供しており、画像 に出現する異なる樹種の樹冠の大きさや、樹冠構造、樹木密度などの幾何的な特徴の 違いを反映するものとなっている。

# (2) 樹種分類

# 1) 画像分類手法

樹種の分類には、画像分類アルゴリズムの中で最も基本的な手法である k 近傍法(k Nearest Neighbor)を利用する。k 近傍法は、ノンパラメトリック(Nonparametric) な手法であるため、使用するデータの母集団の分布について一切の前提を設けなくてもよいという特徴を持っており、オブジェクトベースの画像分類に適したものである。



図 1.1.17 k 近傍法による画像分類のイメージ

図 1.1.17には、*k*近傍法による画像分類のイメージを示している。*k*近傍法を利用 してオブジェクトベースの画像分類を行う場合、各オブジェクトは多次元の特徴空間 におけるベクトルによって表現される。クラスが未知であるオブジェクトの分類は、 このオブジェクトの特徴ベクトルと、教師データから取得された各クラスのオブジェ クトの特徴ベクトル群との距離を計算し、*k* 個(*k* は自然数)の最近傍のオブジェク トが選択される。該当オブジェクトのクラスは、その最近傍のオブジェクト群の投票 によって決定される。すなわち、*k* 個の最近傍のオブジェクト群で最も一般的なクラ スをそのオブジェクトに対して割り当てる。図 1.1.17 に示すように、*k*=3 の場合に は、緑色の分類対象オブジェクトは、赤色の三角形の教師データのクラスに分類され る。一方、*k*=5 の場合には、青色の四角形の教師データのクラスに分類される。

最近傍のオブジェクトを選ぶ際には、ユークリッド距離(Euclidean distance)を 使用する。一般に、n 次元ユークリッド空間において、任意の2点aとbの間のユー クリッド距離 d(a, b)は、次式で与えられる。

$$d(a,b) = \sqrt{\sum_{i=1}^{n} (a_i - b_i)^2}$$
(15)

ここで、 $a_i \ge b_i$ は、n次元ユークリッド空間における点 $a \ge b$ のそれぞれの座標である。

★ 近傍法によるオブジェクトベースの画像分類では、分類クラスが未知のオブジェクトに対して、このオブジェクトの画像統計量を取得し、該当オブジェクトと、取得済みの教師データの各オブジェクトとのユークリッド距離を計算する。算出された距離の順に教師データのオブジェクトをソートし、距離が最も近い★個の近傍オブジェ

クトを選ぶ。その後、最近傍オブジェクト群の投票によって、該当オブジェクトのク ラスを決定する。

なお、*k*=1の時の*k*近傍法を最近傍法と呼び、実質的には最短距離法と等価となる。 ここでは、*k=*1として実際の樹種分類を行っている。

## 2) 樹種分類手法の有効性の検証

開発した林相区画の生成手法、および、テクスチャ構造情報を用いた樹種分類手法 の有効性を検証するために、テストサイトの目視判読データと、実際の樹種分類結果 とを比較して検証を行った。また、検証を行うにあたり、スペクトル情報とテクスチ ャ情報のそれぞれの働きや、複合的な利用を行った場合の違い、日向部分のみのスペ クトル情報と日向・日陰両方のスペクトル情報を使用した場合の効果の違いといった 観点から、従来の最尤法による樹種分類結果を評価の基準として検証を行った。樹種 分類の検証は、林野庁仕様のフォルスカラーオルソ RGNIR 画像を使用することを基 本としているが、ここでは他にも、トゥルーカラーオルソ RGB 画像についても参考 用のデータとして検証を行っている。

樹種分類の検証パターンは表 1.1.4 に示す通りである。表中、○印が付いている項 目は、「使用画像」、「使用情報」、「適用手法」のそれぞれの項目でそのパターンの検証 にデータや手法を使用していることを表している。

	使用画	画像		使用情報			€法
検証パターン		DCD	スペクト	ヽル情報	ニクフエッ桂却	古名书	旦卡计
	KUNIK	RUD	日向	日陰	ナクステヤ旧報	<b>佐</b> 余士	取儿法
(a)	0		0	0		0	
(b)	0		0			0	
(c)	0				0	0	
(d)	0		0	0	0	0	
(e)	0		0		0	0	
(f)	0		0	0			0
(g)		0	0	0		0	
(h)		0	0			0	
(i)		0			0	0	
(j)		0	0	0	0	0	
(k)		0	0		0	0	
(1)		0	0	0			0

表 1.1.4 樹種分類の検証パターン一覧

## 3) テストサイトおよび使用データ

樹種分類の検証に用いたテストサイトおよび使用データは以下の通りであ る。

テストサイト:小川試験地

使用データ:林野庁仕様のフォルスカラーオルソ画像 RGNIR、および、参 考用データとして用いるトゥルーカラーオルソ RGB 画像。データの仕様は以 下の通り。

- · 図郭番号:56
- · 撮影時期:2009年9月
- 解像度:50cm

 バンド: R、G、NIR の3バンド画像、および、R、G、Bの3バンド 画像

なお、目視判読データは、林相判読の専門家による実体視判読から取得さ れたものである。

#### 4) 樹種分類の特徴量

樹種分類用の画像データ(RGNIR もしくは RGB)から、以下の画像特徴 量を算出して樹種分類に用いた。なお、画像テクスチャ情報は、R バンドを 用いて算出している。

- ・ 林相区画オブジェクト内の樹冠部分のRバンドの平均値
- ・ 林相区画オブジェクト内の樹冠部分のGバンドの平均値
- ・ 林相区画オブジェクト内の樹冠部分のNIRもしくはBバンドの平均値
- ・ 林相区画オブジェクト内の二値化画像の平均値

$$Mean_B = \frac{C}{N} \times 255$$
 (16)

ここで、N はオブジェクト内の画素数、C はオブジェクト内のDN (Digital Number) 値が1となる画素数

・ 林相区画オブジェクト内の画像勾配の二値化画像の平均値

$$Mean_G = \frac{C}{N} \times 255 \tag{17}$$

ここで、N はオブジェクト内の画素数、C はオブジェクト内のDN 値が1となる画素数

- ・ 林相区画オブジェクト内のLBP画像の平均値
- ・ 林相区画オブジェクト内のLBP画像の標準偏差

## 5) 樹種分類の結果

表 1.1.5 は、表 1.1.4 に示した各検証パターンの精度検証結果の一覧であ る。また、図 1.1.18~図 1.1.23、および表 1.1.6~表 1.1.11 に、フォルス カラーオルソ RGNIR 画像を利用した樹種分類の各検証パターンにおける分 類結果画像と全体精度の検証結果を示す。図 1.1.24~図 1.1.29、および表 1.1.12~表 1.1.17 には、トゥルーカラーオルソ RGB 画像を利用した場合の 同様の結果を示す。上記の各パターンにおける樹種分類の教師データの数は 7つであり、各クラスとも同一の値である。

なお、分類結果画像の左側は目視判読結果、右側は分類結果画像となって いる。分類カテゴリは、スギ(赤色)、ヒノキ(緑色)、広葉樹(黄色)、非森 林領域(青色)の4つである。

••••		-			~=
検証パターン	スギ	ヒノキ	広葉樹	非森林	全体
(a)	62.6	72.4	63.9	72.1	65.8
(b)	63.4	69.6	69.8	76.3	70.1
(c)	65.5	70.6	73.3	72.5	72.1
(d)	69.0	73.5	75.4	74. 5	74.4
(e)	73.3	71.9	82.9	74.3	79.5
(f)	43.2	66.1	66.9	59.4	63.0
(g)	78.3	68.9	61.5	76.1	66.3
(h)	57.1	67.7	67.7	78.5	68.2
(i)	79.0	56.4	72.9	72.7	72.2
(j)	76.9	65.8	75.2	75.9	74.7
(k)	80.5	67.5	77.6	74.8	76.6
(1)	34.7	68.5	60.9	59.9	58.5
					(単位:%)

表 1.1.5 各検証パターンの精度検証結果の一覧



図 1.1.18 検証パターン (a) の結果画像 (フォルスカラーオルソ RGNIR) 日向/日陰両方のスペクトル情報 (平均値)を使用



図 1.1.19 検証パターン(b)の結果画像(フォルスカラーオルソ RGNIR)
 日向のみのスペクトル情報(平均値)を使用



図 1.1.20 検証パターン (c) の結果画像 (フォルスカラーオルソ RGNIR) テクスチャ情報のみを使用



図 1.1.21 検証パターン(d)の結果画像(フォルスカラーオルソ RGNIR) 日向/日陰両方のスペクトル情報(平均値)/テクスチャ情報を併用



図 1.1.22 検証パターン(e)の結果画像(フォルスカラーオルソ RGNIR) 日向のみのスペクトル情報(平均値)/テクスチャ情報を併用



 図 1.1.23 検証パターン(f)の結果画像(フォルスカラーオルソ RGNIR) 最尤法(従来手法)を使用

表 1.1.6 検証パターン(a)の精度検証の結果(フォルスカラーオルソ RGNIR) 日向/日陰両方のスペクトル情報(平均値)を使用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	210975.50	35447.00	38277.75	6766.25	72. 38
広葉樹	422356.50	1442938.25	237619.25	154415.50	63.92
スギ	93758.75	46992.25	241866.50	3846.00	62. 58
非森林	56296.25	66505.50	34841.00	407428.00	72. 10
全体精度(%)	65.80				

(単位:面積 m<sup>2</sup>)

表 1.1.7 検証パターン(b)の精度検証の結果(フォルスカラーオルソ RGNIR) 日向のみのスペクトル情報(平均値)を使用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	202896.75	36594.75	44136.75	7838.25	69.61
広葉樹	140600.50	1574503.50	219904.75	322318.00	69.75
スギ	66028.50	58667.50	244945.00	16819.25	63. 38
非森林	45832.00	41523.50	46017.25	430264.00	76. 34
全体精度 (%)	70. 10				

(単位:面積 m<sup>2</sup>)

表 1.1.8 検証パターン(c)の精度検証の結果(フォルスカラーオルソ RGNIR) テクスチャ情報のみを使用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	205811.50	54214.25	29289.25	2151.50	70. 61
広葉樹	410161.25	1653816.25	53856.25	139053.25	73. 28
スギ	95480.75	35115.25	252557.25	2430. 25	65. 50
非森林	33388.00	111370.75	10662.75	409032.50	72. 47
全体精度(%)	72. 07				

表 1.1.9 検証パターン(d)の精度検証の結果(フォルスカラーオルソ RGNIR) 日向/日陰両方のスペクトル情報(平均値)/テクスチャ情報を併用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	214229.75	51793.75	22324.75	3118.25	73. 50
広葉樹	342554.25	1701996.50	71945.00	140824.25	75. 40
スギ	78557.00	38566.50	266451.25	2888.75	68.95
非森林	29874.75	99991.00	13970.50	420625.25	74. 52
全体精度(%)	74. 39				

(単位:面積 m<sup>2</sup>)

表 1.1.10 検証パターン(e)の精度検証の結果(フォルスカラーオルソ RGNIR) 日向のみのスペクトル情報(平均値)/テクスチャ情報を併用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	209455.25	51112.75	29674.75	1223.75	71.86
広葉樹	217314.25	1870798.50	74716.75	94490.50	82. 88
スギ	38418.00	61749.50	283380.75	2915.25	73. 33
非森林	43697.75	83167.25	18165.75	419254.75	74. 30
全体精度(%)	79. 52				

(単位:面積 m<sup>2</sup>)

表 1.1.11 検証パターン(f)の精度検証の結果(フォルスカラーオルソ RGNIR)
 最尤法(従来手法)を使用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	192760.00	38889.50	48472.00	11345.00	66. 13
広葉樹	237839.75	1510141.75	286027.50	223246.25	66.90
スギ	130222.00	68122.50	166874.50	20961.75	43. 21
非森林	40154.00	126648.50	62419.50	335848.25	59.43
全体精度(%)	63.02				



図 1.1.24 検証パターン (g) の結果画像 (トゥルーカラーオルソ RGB) 日向/日陰両方のスペクトル情報 (平均値)を使用





図 1.1.25 検証パターン(h)の結果画像(トゥルーカラーオルソ RGB)
 日向のみのスペクトル情報(平均値)を使用



図 1.1.26 検証パターン(i)の結果画像(トゥルーカラーオルソ RGB) テクスチャ情報のみを使用



図 1.1.27 検証パターン (j) の結果画像 (トゥルーカラーオルソ RGB) 日向/日陰両方のスペクトル情報 (平均値) /テクスチャ情報を併用



図 1.1.28 検証パターン(k)の結果画像(トゥルーカラーオルソ RGB) 日向のみのスペクトル情報(平均値)/テクスチャ情報を併用



図 1.1.29 検証パターン(1)の結果画像(トゥルーカラーオルソ RGB)

最尤法(従来手法)を使用

表 1.1.12 検証パターン (g) の精度検証の結果 (トゥルーカラーオルソ RGB) 日向/日陰両方のスペクトル情報(平均値)を使用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	200789.50	29669.50	54797.25	6210.25	68.89
広葉樹	217570.00	1388175.75	540868.75	110715.00	61.50
スギ	20938.25	59114.00	302759.50	3651.75	78. 34
非森林	28255.50	79464.00	27332.75	430018.50	76. 10
全体精度(%)	66. 33				

(単位:面積 m<sup>2</sup>)

表 1.1.13 検証パターン(h)の精度検証の結果(トゥルーカラーオルソ RGB) 日向のみのスペクトル情報(平均値)を使用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	197441.75	18998.00	68574.00	6452.75	67. 74
広葉樹	126191.25	1527448. 25	443642.50	160047.50	67.67
スギ	72429.50	77810.50	220465.50	15746.50	57.05
非森林	33009.50	57831.75	29424.25	440197.25	78. 54
全体精度 (%)	68. 24				

(単位:面積 m<sup>2</sup>)

表 1.1.14 検証パターン(i)の精度検証の結果(トゥルーカラーオルソ RGB) テクスチャ情報のみを使用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	164335.00	59551.50	66024.00	1544. 25	56.38
広葉樹	307471.25	1644622.25	167638.75	136666.75	72. 89
スギ	38771.25	40917.00	304786.50	1431.00	78.98
非森林	65599.00	58824.75	29739.50	410155.50	72. 68
全体精度(%)	72. 15				

表 1.1.15 検証パターン (j) の精度検証の結果 (トゥルーカラーオルソ RGB) 日向/日陰両方のスペクトル情報 (平均値) /テクスチャ情報を併用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	191908.75	46096.75	50680.50	2770.75	65.84
広葉樹	254472.75	1696809.75	176007.25	130026.25	75. 17
スギ	30375.00	56556.25	297278.00	2246.50	76. 92
非森林	59745.75	59828.50	16410.00	427822.50	75. 88
全体精度(%)	74. 70				

(単位:面積 m<sup>2</sup>)

表 1.1.16 検証パターン(k)の精度検証の結果(トゥルーカラーオルソ RGB) 日向のみのスペクトル情報(平均値)/テクスチャ情報を併用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	196831.75	40856.25	50991.75	2777.00	67. 53
広葉樹	208904.00	1751124.00	183363.50	113924.50	77. 58
スギ	28782.75	44179.25	311051.50	2438.50	80. 49
非森林	59156.50	66444.00	16261.50	420472.75	74. 77
全体精度(%)	76. 61				

(単位:面積 m<sup>2</sup>)

表 1.1.17 検証パターン(l)の精度検証の結果(トゥルーカラーオルソ RGB) 最尤法(従来手法)を使用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	199480. 75	46287.50	33533.25	12085.50	68.46
広葉樹	333810.00	1374107.75	364258.50	184062.25	60.90
スギ	141774.75	94568.75	133629.25	14660.00	34. 74
非森林	51452.25	129791.50	45341.75	338469.00	59.90
全体精度(%)	58.49				

## 6) 教師データの選定方法の検討

7) 検証パターン

教師つき画像分類の場合、教師データの選び方が樹種分類の結果に影響を 与える。教師用に用いるサンプルデータは基本的に、分類する画像の全体に 対して均一に分布するように取得する必要がある。ここでは、教師データの 取得数が実際の樹種分類結果に対してどの程度の影響を与えるのかについて 検証する。検証方法は、前述の日向のみのスペクトル情報とテクスチャ情報 を併用した場合の樹種分類パターンを基準として、各分類クラスの教師サン プル数が同じような数だけ減少した場合、また、各分類クラスの教師サンプ ル数がばらばらに減少した場合の分類結果を比較する。検証のパターンは表 1.1.18 に示す通りである。

	A 1.1.10 Amp / * / / · 从*/ 伏皿 / / * 見							
検証	使用画像 各クラスの教師数 各クラス (サンプル数が等しい場合) (サンプル数が			使用画像各クラスの教師数(サンプル数が等しい場合)		スの教師 数が異なる	数 る場合)	
パターン	RGNIR	RGR	5	3	スギ	スギ	ヒノキ	ヒノキ
	NUMIN	Nub	0	0	5	3	5	3
(a)	0		0					
(b)	0			0				
(c)	0				0			
(d)	0					0		
(e)	0					0	0	
(f)	0					0		0
(g)		0	0					
(h)		0		0				
(i)		0			0			
(j)		0				0		
(k)		0				0	0	
(1)		0				0		0

表 1.1.18 教師サンプル数の検証パターン一覧

(注:各クラスの教師サンプル数が異なる検証パターンでは、上記に示したクラス以外の クラスの教師サンプル数は全て7つとなっている)

## 8) 樹種分類の結果

表 1.1.19 は、表 1.1.18 に示した各検証パターンの精度検証結果の一覧で ある。また、図 1.1.30~図 1.1.35、および表 1.1.20~表 1.1.25 には、フォ ルスカラーオルソ RGNIR 画像を使用した各検証パターンにおける分類結果 画像と全体精度の検証結果を示す。図 1.1.36~図 1.1.41、および表 1.1.26 ~表 1.1.31 には、トゥルーカラーオルソ RGB 画像を使用したときの同様の 結果を示す。

2					2
検証パターン	スギ	ヒノキ	広葉樹	非森林	全体
(a)	78.0	72.2	76.5	74.9	76.0
(b)	78.6	65.4	80.6	61.6	76.1
(c)	70.6	72.7	83.1	74. 2	79.4
(d)	64.2	74.5	83.2	74. 2	78.9
(e)	67.7	71.9	83.8	74.6	79.6
(f)	68.4	63.9	87.6	74.6	81.4
(g)	85.0	63.3	71.1	74.6	72.5
(h)	86.6	59.7	64.3	58.9	65.5
(i)	69.7	71.5	78.6	74.7	76.4
(j)	63.3	77.3	78.6	74.7	76.1
(k)	68.0	71.9	80.2	75.8	77.4
(1)	68.2	66.5	82.1	75.8	78.2
			•		(単位:%)

表 1.1.19 各検証パターンの精度検証結果の一覧



図 1.1.30 検証パターン (a) の結果 (フォルスカラーオルソ RGNIR) 各分類クラスの教師サンプル数が全て 5 の場合



図 1.1.31 検証パターン(b)の結果(フォルスカラーオルソ RGNIR)
 各分類クラスの教師サンプル数が全て3の場合



図 1.1.32 検証パターン (c) の結果 (フォルスカラーオルソ RGNIR) スギのサンプル数が 5 の場合 (その他のクラスは 7)



図 1.1.33 検証パターン(d)の結果(フォルスカラーオルソ RGNIR) スギのサンプル数が3の場合(その他のクラスは7)



図 1.1.34 検証パターン (e) の結果 (フォルスカラーオルソ RGNIR) スギのサンプル数が 3、ヒノキが 5 の場合 (その他のクラスは 7)



図 1.1.35 検証パターン (f) の結果 (フォルスカラーオルソ RGNIR) スギとヒノキのサンプル数が 3 の場合 (その他のクラスは 7)

表 1.1.20 検証パターン(a)の結果(フォルスカラーオルソ RGNIR) 各分類クラスの教師サンプル数が全て5の場合

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	210386.50	33615.50	45067.00	2397.50	72. 18
広葉樹	327262.75	1725703.50	102502.00	101861.25	<b>76. 45</b>
スギ	44996.50	37587.75	301243.75	2635.50	77.95
非森林	56627.75	67481.75	17672.75	422692.75	74. 88
全体精度(%)	76.01				

(単位:面積 m<sup>2</sup>)

表 1.1.21 検証パターン(b)の結果(フォルスカラーオルソ RGNIR) 各分類クラスの教師サンプル数が全て3の場合

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	190549.25	46421.75	53152.75	1342.75	65. 38
広葉樹	221073.00	1819518.00	118280.75	98457.75	80. 60
スギ	35241.50	46696.00	303707.75	818. 25	78. 5 <b>9</b>
非森林	74256.25	121434.00	21114.50	347670. 25	<b>61.59</b>
全体精度(%)	76.05				

(単位:面積 m<sup>2</sup>)

表 1.1.22 検証パターン (c) の結果 (フォルスカラーオルソ RGNIR) スギのサンプル数が 5 の場合 (その他のクラスは 7)

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	211995.50	54176.50	24010.50	1284.00	72. 73
広葉樹	219344.00	1876577.00	66262.25	95136.75	83. 13
スギ	46070.25	64539.75	272966.00	2887.50	70. 63
非森林	44285.75	83538.25	18011.00	418450.75	74. 16
全体精度(%)	79.44				

表 1.1.23 検証パターン(d)の結果(フォルスカラーオルソ RGNIR) スギのサンプル数が3の場合(その他のクラスは7)

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	216996.75	54176.50	18794.00	1499. 25	74. 45
広葉樹	225042.75	1877452. 25	59615.50	95209.50	83. 17
スギ	70878.50	64799.50	247898.00	2887.50	64. 15
非森林	48417.00	83826.25	13250.25	418786.75	74. 22
全体精度(%)	78.90				

(単位:面積 m<sup>2</sup>)

表 1.1.24 検証パターン(e)の結果(フォルスカラーオルソ RGNIR) スギのサンプル数が3、ヒノキが5の場合(その他のクラスは7)

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	209690.00	57165.00	21998.75	2612.75	71. 94
広葉樹	206092.25	1891919.50	63861.00	95447.25	83. 81
スギ	54359.50	67330.25	261801.25	2972.50	67. 74
非森林	45373.50	84881.25	13253.50	420772.00	74. 57
全体精度(%)	79. 56				

(単位:面積 m<sup>2</sup>)

表 1.1.25 検証パターン (f) の結果 (フォルスカラーオルソ RGNIR) スギとヒノキのサンプル数が 3 の場合 (その他のクラスは 7)

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	186236.75	76960.00	25657.00	2612.75	63.90
広葉樹	117764.25	1976712.00	67396.50	95447.25	87. 57
スギ	44695.50	74425.25	264370.25	2972.50	68. 41
非森林	38503.50	91198.00	13806.75	420772.00	74. 57
全体精度(%)	81. 38				



図 1.1.36 検証パターン (g) の結果(トゥルーカラーオルソ RGB) 各分類クラスの教師サンプル数が全て5の場合



図 1.1.37 検証パターン(h)の結果(トゥルーカラーオルソ RGB)
 各分類クラスの教師サンプル数が全て3の場合



図 1.1.38 検証パターン(i)の結果(トゥルーカラーオルソ RGB) スギのサンプル数が5の場合(その他のクラスは7)



図 1.1.39 検証パターン (j) の結果(トゥルーカラーオルソ RGB) スギのサンプル数が3の場合(その他のクラスは7)



図 1.1.40 検証パターン(k)の結果(トゥルーカラーオルソ RGB) スギのサンプル数が3、ヒノキが5の場合(その他のクラスは7)



図 1.1.41 検証パターン(1)の結果(トゥルーカラーオルソ RGB) スギとヒノキのサンプル数が3の場合(その他のクラスは7)

表 1.1.26 検証パターン (g) の結果 (トゥルーカラーオルソ RGB) 各分類クラスの教師サンプル数が全て 5 の場合

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	184419. 50	33153.00	71125.75	2768.25	63. 27
広葉樹	297073.50	1604952.75	247385.50	107915.75	71. 10
スギ	29070.75	26991.75	328347.50	2045.75	<b>84.96</b>
非森林	65251.25	51828.00	25504.75	418502.75	74. 59
全体精度(%)	72. 54				

(単位:面積 m²)

表 1.1.27 検証パターン(h)の結果(トゥルーカラーオルソ RGB) 各分類クラスの教師サンプル数が全て3の場合

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	173897.50	36513.00	78797.75	2258.25	<b>59.66</b>
広葉樹	502579.00	1451350.25	259343.25	44055.00	64. 30
スギ	20570.25	30163.50	334751.00	971.00	86. 62
非森林	135559.75	74965.50	19855.50	330706.00	58.94
全体精度(%)	65. 52				

(単位:面積 m<sup>2</sup>)

表 1.1.28 検証パターン(i)の結果(トゥルーカラーオルソ RGB) スギのサンプル数が5の場合(その他のクラスは7)

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	208455.00	42649.50	37557.75	2804. 25	71. 52
広葉樹	250503.75	1773034.75	119097.75	114691.25	78. 55
スギ	57679.75	57195.50	269147.75	2432.75	69.65
非森林	61811.50	67011.75	13900.00	421595.50	74. 71
全体精度(%)	76.36				

表 1.1.29 検証パターン (j) の結果 (トゥルーカラーオルソ RGB) スギのサンプル数が 3 の場合 (その他のクラスは 7)

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	225402.00	42918.00	20342.25	2804. 25	77. 33
広葉樹	257325.75	1773034.75	112221.00	114746.00	78. 55
スギ	82244.25	57195.50	244582.00	2434.00	<b>63. 29</b>
非森林	64683.25	67011.75	10948.00	421675.75	74. 72
全体精度(%)	76.14				

(単位:面積 m<sup>2</sup>)

表 1.1.30 検証パターン(k)の結果(トゥルーカラーオルソ RGB) スギのサンプル数が3、ヒノキが5の場合(その他のクラスは7)

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	209561.25	55543.50	23553.50	2808.25	71.90
広葉樹	198459.50	1809596.25	130307.75	118964.00	80. 17
スギ	48981.25	72333.50	262707.00	2434.00	67.98
非森林	53905.50	70292.50	12651.50	427469.25	75. 75
全体精度(%)	77. 42				

(単位:面積 m<sup>2</sup>)

表 1.1.31 検証パターン(1)の結果(トゥルーカラーオルソ RGB) スギとヒノキのサンプル数が3の場合(その他のクラスは7)

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	193676.25	70711.00	24267.25	2812.00	<b>66.45</b>
広葉樹	151715.25	1853312.00	133336.25	118964.00	82.10
スギ	43670.50	76906.25	263445.00	2434.00	68. 17
非森林	46894.75	76789.50	13165.25	427469.25	75. 75
全体精度(%)	78.24				

(単位:面積 m<sup>2</sup>)

# 9) 画像の正規化処理の検討

画像の正規化処理は、従来から画像中の陰影領域を除去したり、照明の影響を軽減 したりするための有効な手段としてよく活用されている。実際に、画像の正規化処理 は、マルチスペクトル画像の各バンドの情報を集約することにより、画像の特徴量を 抽出したり、画像の目視判読と画像の自動分類に利用したりすることができる。

ここでは、樹種分類を行う前にまず、式(18) ~式(21)で表されるような画像の 正規化処理を行い、樹種判読に有効なスペクトル特徴量情報を抽出する。図 3.3・42 には、テストサイトのトゥルーカラーオルソRGB画像と正規化処理の適用後(R'G'B') のフォルスカラーオルソ画像を示す。トゥルーカラーオルソRGB画像は、2009年9 月に撮影されたものであるため、目視判読を行う際に、森林領域と非森林領域、針葉 樹林と広葉樹林などの違いを明瞭に判別することが困難である。これに対して、正規 化処理後のフォルスカラーオルソ画像では、画像の特徴量抽出による画像強調の効果 によって、それらの違いをより明瞭にすることができており、森林画像の目視判読が 行いやすくなっていることが分かる。さらに、樹種の自動分類の場合には、画像の特 徴量抽出によって林相間の分離度をより高くすることによって、さらに正確な樹種分 類を行うことができるようになる。

図 1.1.42 から図 1.1.44、および表 1.1.32 と表 1.1.33 には、正規化されたフォル スカラーオルソ R'G'NIR'画像とトゥルーカラーオルソ R'G'B'を利用した樹種分類の結 果画像と全体の精度検証の結果をそれぞれ示している。オリジナルの RGNIR 画像と RGB 画像に比べ、正規化処理後の R'G'NIR'画像と R'G'B'画像では、双方において樹 種分類の結果が確実に向上していることが確認される。なお、ここでは、RGNIR 画 像と RGB 画像の正規化処理は別々に行っている。また、林相区画については、正規 化前と正規化後とで同じ林相区画を使用している。樹種分類については、日向のみの スペクトル情報とテクスチャ情報を使用している。

$$R' = \frac{R}{R + G + B + NIR} \tag{18}$$

$$G' = \frac{G}{R + G + B + NIR} \tag{19}$$

$$B' = \frac{B}{R + G + B + NIR}$$
(20)

$$NIR' = \frac{NIR}{R + G + B + NIR}$$
(21)



図 1.1.42 オリジナルの RGB 画像(左)と正規化処理後の RGB 画像(右)



図 1.1.43 樹種分類の結果画像(正規化フォルスカラーオルソ RGNIR) 日向のみのスペクトル情報(平均値)とテクスチャ情報を使用



図 1.1.44 樹種分類の結果画像(正規化トゥルーカラーオルソ RGB)
 日向のみのスペクトル情報(平均値)とテクスチャ情報を使用
 表 1.1.32 樹種分類の精度検証結果(正規化フォルスカラーオルソ RGNIR)

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	216525.25	43718.00	28768.75	2424.00	74. 30
広葉樹	93639.75	2004514.25	57151.50	101829.50	88. 81
スギ	61922.00	55492.50	264996.00	4049.75	68. 57
非森林	13343.75	100478.50	15321.25	433115.50	77.03
全体精度(%)	83. 47				

日向のみのスペクトル情報(平均値)とテクスチャ情報を使用

(単位:面積 m<sup>2</sup>)

表 1.1.33 樹種分類の精度検証結果(正規化トゥルーカラーオルソ RGB) 日向のみのスペクトル情報(平均値)とテクスチャ情報を使用

分類クラス	ヒノキ	広葉樹	スギ	非森林	各クラス分類精度(%)
ヒノキ	203221.75	33238.75	53747.75	940. 75	69.80
広葉樹	58176.25	1915316.00	216735.00	62981.75	85.00
スギ	19544. 75	32625.75	329450.75	3464.25	85. 55
非森林	7102.75	112481.75	23224. 25	406040.75	73. 98
全体精度(%)	82. 05				

(単位:面積 m<sup>2</sup>)

## (3) 樹種分類の考察

## 1) オブジェクトベース分類と最尤法分類(従来手法)との比較

表 1.1.34 には、オブジェクトベース分類と従来用いられてきた最尤法分類の 精度検証結果を示している。使用データと教師データが同じである場合、RGNIR 画像と RGB 画像を使用したオブジェクトベース分類の精度はそれぞれ 65.8%と 66.3%である。それに対して、最尤法の分類精度はそれぞれ 63.0%と 58.5%とな っている。最尤法に対するオブジェクトベース分類手法の優位性が示されている と言える。

画像	ケース	スギ	ヒノキ	広葉樹	非森林	全体	
RGNIR	最尤法	43.2	66.1	66.9	59.4	63.0	
	日向/日陰両方のスペクトル情報	62.6	72.4	63.9	72.1	65.8	
RGB最尤法34.768.560.959日向/日陰両方のスペクトル情報78.368.961.576	最尤法	34. 7	68.5	60.9	59.9	58.5	
	76.1	66.3					

表 1.1.34 オブジェクトベース分類と最尤法による分類との分類精度の比較

## 2) スペクトル情報とテクスチャ情報の分類結果の比較

表 1.1.35 には、スペクトル情報のみによる分類、テクスチャ情報のみによる 分類、および、スペクトル情報とテクスチャ情報の併用による分類精度の結果を 示している。日向と日陰のスペクトル情報のみを使用した場合、RGNIR 画像と RGB 画像を使用したときの分類精度はそれぞれ 65.8%と 66.3%である。それに対 して、テクスチャ情報のみを使用した場合の分類精度はそれぞれ 72.1%と 72.2% となっている。テクスチャ情報を用いた場合の分類精度はスペクトル情報の場合

<sup>(</sup>単位:%)

に比べ、5~6%程度高くなっている。この結果から、航空写真などの高分解能画像の場合には、スペクトル情報よりもテクスチャ情報の方が有効に機能していることが分かる。同時に、今回提案した3つのテクスチャ構造情報が樹種分類に対して非常に有効であることが確認された。なお、スペクトル情報とテクスチャ情報を併用した場合、RGNIR 画像と RGB 画像を使用したときの分類精度はそれぞれ74.4%と74.7%となっており、スペクトル情報とテクスチャ情報の併用により、さらに精度の向上が図られることが見て取れる。

画像	ケース	スギ	ヒノキ	広葉樹	非森林	全体
RGNIR	日向/日陰両方のスペクトル情報	62.6	72.4	63.9	72. 1	65.8
	テクスチャ情報	65.5	70.6	73.3	72.5	72.1
	日向/日陰両方のスペクトル情報/	60 0	73.5	75.4	74.5	74.4
	テクスチャ情報	09.0				
RGB	日向/日陰両方のスペクトル情報	78.3	68.9	61.5	76.1	66.3
	テクスチャ情報	79.0	56.4	72.9	72.7	72. 2
	日向/日陰両方のスペクトル情報/	76.0	65.8	75.2	75.9	74. 7
	テクスチャ情報	70.9				

表 1.1.35 スペクトル情報とテクスチャ情報による分類精度の結果

(単位:%)

# 3) 日向/日陰両方のスペクトル情報と日向のみのスペクトル情報の分類結果の 比較

高分解能の森林画像では、樹冠領域の日向部分と、樹木間の隙間や樹冠領域の 日陰部分との色調がかなり異なるため、画像分類による樹種判別の際に、全領域 のスペクトル情報を使用すべきか、あるいは、樹冠領域の日向部分のみを使用す べきかについて結論が得られていない。

表 1.1.36 には、日向/日陰両方のスペクトル情報による分類、日向のみのスペクトル情報による分類、および、スペクトル情報/テクスチャ情報併用による分類精度の結果が示されている。日向/日陰両方のスペクトル情報の場合、RGNIR 画像と RGB 画像を使用したときの分類精度はそれぞれ 65.8%と 66.3%である。 それに対して、日向のみのスペクトル情報を使用したときの分類精度はそれぞれ 70.1%と 68.2%とやや高い値となっている。また、スペクトル情報/テクスチャ 情報の併用の効果について見ると、日向/日陰の両方を使用した場合は、RGNIR 画像と RGB 画像の分類精度はそれぞれ 74.4%と 74.7%である。一方、日向のみ を使用した場合の分類精度はそれぞれ 79.5%と 76.6%となっている。スペクトル 情報のみの場合と、スペクトル情報/テクスチャ情報併用の場合のいずれの結果 も、日向のみのスペクトル情報を使用した方が高い分類精度となっていることが 分かる。

上記の結果のみでは、日向のみのスペクトル情報を使用した方が妥当であると いう結論を得るまでには至らないが、日陰の情報は太陽高度や地形の影響を受け やすいため、スペクトル情報としては日向部分のみを使用するのが適切であるの ではないかとという仮説が立てられる。なお、日向/日陰両方のスペクトル情報 の場合でも、日向部分のみのスペクトル情報の場合でも、テクスチャ情報を加え ることにより、RGNIR 画像と RGB 画像の双方において、8%以上の分類精度の 向上が見られることから、提案したテクスチャ構造情報が有効であることと、ス ペクトル情報/テクスチャ情報の複合的な利用が効果的であることが改めて確認 された。

画像	ケース	スギ	ヒノキ	広葉樹	非森林	全体
RGNIR	日向/日陰両方のスペクトル情報	62.6	72.4	63.9	72.1	65.8
	日向のみのスペクトル情報	63.4	69.6	69.8	76.3	70.1
	日向/日陰両方のスペクトル情報/	60.0	73.5	75.4	74. 5	74.4
	テクスチャ情報併用	09.0				
	日向のみのスペクトル情報/	20 0	71.9	82.9	74.3	79.5
	テクスチャ情報併用	73.3				
RGB	日向/日陰両方のスペクトル情報	78.3	68.9	61.5	76.1	66.3
	日向のみのスペクトル情報	57.1	67.7	67.7	78.5	68.2
	日向/日陰両方のスペクトル情報/	76 0	65.8	75.2	75.9	74.7
	テクスチャ情報併用	70.9				
	日向のみのスペクトル情報/	00 F	67.5	77.6	74.8	76.6
	テクスチャ情報併用	ov. 9				

表 1.1.36 日向/日陰両方のスペクトル情報と日向のみのスペクトル情報 による分類精度の結果

(単位:%)

### 4) 教師データの選定方法について

表 1.1.37には、教師データの数を変化させたときの分類精度の変化を示している。 この表から、教師データの取得数が樹種分類の精度に影響を与えていることが分かる。 教師データの数を変えた場合、樹種によっては分類精度が大きく異なる結果となって いる。教師データの数が同一で、かつ、ある程度の個数を取得した場合、各樹種の分 類精度はほぼ同程度の値となっている。しかしながら、教師データの数が同一の場合 であっても、教師データの数を 7 から 5、3 と減らしていくと、RGNIR 画像、RGB 画像の双方において、樹種による分類精度のばらつきが生じている。これは、教師デ ータの数が同一であってもその個数が少なすぎると、同一の樹種に含まれる微細な特 徴の違いを十分に反映させることができないことから、一部の樹種が他の樹種クラス に誤分類されやすくなるためであると考えられる。このことは、同じ樹種であっても 樹種の微細な特徴の違いを十分に反映させるために、ある程度の数の特徴の異なる教 師データを取得する必要性があることを示唆している。

また、個別の樹種の教師データの数を変化させた場合にも分類精度に大きな違いが 生じている。スギのみの教師データの数を7から5、3と減らしていくと、RGNIR 画 像、RGB 画像の双方とも、スギの分類精度が大きく低下していく傾向が読み取れる。 さらに、スギとヒノキの教師データの数を両方とも減らしていくと、RGNIR 画像、 RGB 画像の双方で、同様にスギとヒノキの両方の分類精度が大きく低下していく様子 が確認できる。従って、教師データの選定方法による樹種分類への影響を可能な限り 軽減させるためには、各クラスに対する教師データの数をなるべく同一にすることが 重要であると考えられる。

	ヘモ	レノキ	ム苿樹	非称杯	全体
〔同一(各7)	73.3	71.9	82.9	74.3	79.5
〔同一(各5)	78.0	72.2	76.5	74.9	76.0
〔同一(各3)	78.6	65.4	80.6	61.6	76.0
:場合	70.6	72.7	83.1	74.2	79.4
:場合	64.2	74.5	83.2	74. 2	78.9
を2減らした場合	67.7	71.9	83.8	74.6	79.6
を4減らした場合	68.4	63.9	87.6	74.6	81.4
〔同一(各7)	80.5	67.5	77.6	74.8	76.6
〔同一(各5)	85.0	63.3	71.1	74.6	72.5
〔同一(各3)	86.6	59.7	64.3	58.9	65.5
:場合	69.7	71.5	78.6	74.7	76.4
:場合	63.3	77.3	78.6	74.7	76.1
を2減らした場合	68.0	71.9	80.2	75.8	77.4
を4減らした場合	68.2	66.5	82.1	75.8	78.2
	<ul> <li>に同一(各7)</li> <li>に同一(各5)</li> <li>に同一(各3)</li> <li>に場合</li> <li>を2減らした場合</li> <li>を4減らした場合</li> <li>に同一(各5)</li> <li>に同一(各3)</li> <li>に場合</li> <li>に場合</li> <li>を2減らした場合</li> <li>を4減らした場合</li> </ul>	こ同一(各7)       73.3         こ同一(各5)       78.0         こ同一(各3)       78.6         二場合       70.6         二場合       64.2         -を2減らした場合       67.7         -を4減らした場合       68.4         ご同一(各7)       80.5         ご同一(各5)       85.0         ご同一(各3)       86.6         三場合       63.3         -を2減らした場合       68.2	に同一(各7)73.371.9に同一(各5)78.072.2に同一(各3)78.665.4こ場合70.672.7こ場合64.274.5・を2減らした場合67.771.9・を4減らした場合68.463.9ご同一(各7)80.567.5こ同一(各5)85.063.3こ同一(各3)86.659.7こ場合63.377.3・を2減らした場合68.071.9・を4減らした場合68.266.5	こ同一(各7)73.371.982.9こ同一(各5)78.072.276.5こ同一(各3)78.665.480.6二場合70.672.783.1こ場合64.274.583.2そ2減らした場合67.771.983.8そ4減らした場合68.463.987.6こ同一(各7)80.567.577.6こ同一(各5)85.063.371.1こ同一(各3)86.659.764.3こ場合63.377.378.6こ場合63.371.980.2そ4減らした場合68.266.582.1	こ同一(各7)73.371.982.974.3こ同一(各5)78.072.276.574.9こ同一(各3)78.665.480.661.6二場合70.672.783.174.2こ場合64.274.583.274.2こを2減らした場合67.771.983.874.6こ同一(各7)80.567.577.674.8こ同一(各5)85.063.371.174.6こ同一(各5)85.063.371.174.6こ同一(各3)86.659.764.358.9こ場合63.377.378.674.7こ場合63.377.378.674.7こ場合63.266.582.175.8

表 1.1.37 教師データの数と分類精度との関係

(単位:%)

#### (4) 林相区分・樹種分類のまとめ

上述してきたように、航空写真を用いて林相区画を自動的に生成し、林相・樹種区 分図を効率的に作成可能な手法の検討と実利用を可能とする技術開発を行った。また、 教師データの選定方法や、パラメータの設定、テストサイトの実データの検証などを 経てより具体的な解析の流れを確立し、利用者が効率的かつ簡便に処理を実行可能な 処理フローとしてまとめた。開発した手法では、撮影時期による影響を軽減し、より 安定かつ高精度な林相分類を行うことが可能であり、林相区分図の作成・更新作業を より効率的に実施することができる。

まず、林相区画の自動生成技術の開発では、画像のディグラデーション処理によっ て生成した低分解能画像と高分解能画像を併用する階層的な画像の領域分割を新たに 導入することにより、同一の林分内における日向領域と日陰領域の違いによる画像の 特徴のばらつきを軽減させ、林相区画をより正確に抽出することが可能となった。ま た、林分の大きさのばらつきに対し、異なるスケールパラメータを個別の階層の画像 に対して設定するマルチスケールの領域分割処理を行うことで、サイズの小さい林分 と大きい林分を含めた様々な林相を柔軟に抽出することが可能となった。

次に林相・樹種の自動区分技術の開発では、高分解能画像において観察される樹冠の日向と日陰のパターン特徴を重視し、日向と日陰の分布パターン、日向と日陰の勾配変化のパターン、および、詳細な局所構造パターンといった3つの画像テクスチャ構造情報を抽出することにより、画像の撮影時期に影響されにくい分類情報を生成した。画像の領域分割により生成された林相区画をベースとし、画像のスペクトル情報と抽出したテクスチャ構造情報とを複合的に利用することで、より精度の高い林相・樹種の自動判読を行うことが可能となった。また、画像の正規化処理の導入により森林画像の目視判読が行いやすくなり、樹種分類もさらに正確に行うことが可能となった。

最後に、開発した林相区画の自動生成技術と林相・樹種の自動区分技術を林野庁仕様のフォルスカラーオルソ RGNIR 画像、および、通常広く用いられているトゥルーカラーオルソ RGB 画像に適用して樹種判別を行った結果、非常に良好な樹種分類精度が得られることを確認した。小川試験地における検証では、開発した林相・樹種の自動区分技術は従来のピクセルベースの手法に比べ、RGNIR 画像と RGB 画像のいずれの場合にも15%以上の精度の向上が見られた。また、画像のスペクトル情報に対してテクスチャ情報を複合的に用いることにより、8%程度の分類精度の向上を図ることができた。加えて、画像の正規化処理の導入により、さらに4%程度の分類精度の向上が図られた。

林相区分・樹種分類に関する各種の検討、解析作業を実施してきた上でのまとめと して、林相・樹種区分図の作成は図 1.1.45 に示すような処理フローに基づいて実施 することが望ましいと結論づけられた。

