時系列低空間分解能画像からの情報を活用した複数シーンの 高空間分解能画像分類

Classification of multiscene high spatial resolution images by using information obtained from temporal low spatial resolution images

須崎 純一*・柴崎 亮介**・岩男 弘毅***

Junichi SUSAKI, Ryosuke SHIBASAKI and Koki IWAO

Abstract : Elaborate processes are required for land cover classification using multiscene high spatial resolution satellite images, like selecting training area on each scene with sufficient a priori knowledge. The classification method proposed in this paper is assumed to use both high spatial resolution images and temporal low spatial resolution images. It can automatically produce training data set on each scene, optimized considering land cover characteristics to the scene. Moreover, it prevents from deteriorating into low classification accuracy, by referring to and checking consistency to the class candidate information derived from temporal low spatial resolution images. Experiments were conducted that used twenty-eight scenes of Landsat TM and NOAA AVHRR images as high and low spatial resolution images, respectively. Validation results by using three visually interpreted images demonstrate the optimization of training data set improved the classification accuracy from 59.0% to 66.2%, and the class candidate information improved from 61.9% to 66.2%.

1. 研究の背景

地球温暖化の要因の中で、森林破壊などに起因する温室効果ガス、特に二酸化炭素の放出は非常に重要であると言われており、放出量の推定や予測のために森林破壊の状況を大陸規模から地球規模で把握しようとする試みがなされている。その他の環境問題においても、広域の土地利用・土地被覆変化をモニタリングする必要性が高まっており、その実現には衛星画像の利用が不可欠である。人為的な土地被覆改変の状況を抽出するためには、数メートルから最低でも数十メートルの地上分解能が要求され、従来は Landsat 画像が利用されることが多かった。たとえば、アマゾンや中央アフリカにおける森林破壊状況のモニタリングでも多量の Landsat 画像が使用されている^{1,2)}。また土地被覆・土地利用情報の抽出にあたっては、簡単な画像処理（例えばクラスタリング）と目視判読の組み合わせ

が適用されている³⁾。しかしながら、これまでの手法には以下のような問題点があると考えられる。

1. 目視判読の比重が大きいと、画像データからわかる範囲においては信頼性の高い分類結果が得られやすいが、作業効率が低く、広域をカバーするためには人海戦術に頼らざるを得ない。そのため、定期的なモニタリングや対象地域の拡大は非常に困難となってくる。
2. Landsat 画像のような高空間分解能画像の多くは、乾季だけといったように単一季節の画像しか得られないことが多く、それだけを利用した分離には自ずから限界がある。たとえば、単一季節画像からは落葉林の抽出などは専門家でさえも決して容易ではない。また、問題点 1 に帰着するが、こうした状況では、広域を対象とすると品質を高く保つための品質管理に非常に手間がかかる。

問題点 1 の対策としては、目視判読の自動化が挙げられる。しかし目視判読は、対象地域の特性に関する詳細な知識と経験に加え、人間独特の識別能力を必要とする。たとえば、専門家が乾季の画像から落葉林などを抽出する際には、微妙な色調、テクスチャを判読し、さらに標高と落葉樹林帯の分布に関する知識な

* 東京情報大学総合情報学部

** 東京大学空間情報科学研究センター

*** アジア工科大学

「写真測量とリモートセンシング」VOL. 40, NO. 5, 2001

どを利用している。また、その地域の作付けパターンに関する知識を利用して乾季だけの画像から農作物の種類を抽出することを可能としている。

こうした目視判読と同等に近い能力を持つ分類手法を開発しようとする試みは数多く存在する。たとえば人工知能の技術の一つであるニューラルネットワークの持つ学習機能などを利用した分類手法^{4,5)}や、あいまいな状態も含む推論機構であるファジイ理論を応用した分類手法^{6,7)}などが提案されている。しかし、分類精度を専門家並に上げることは容易ではないのが現状である。

問題点2に関しては、異なる衛星画像の組合せの利用が考えられる。例えば、落葉林に関しては、月別、季節別 NOAA 衛星の AVHRR 画像を利用することで高い精度で抽出できることが知られている。また二毛作・三毛作などの農業特性の把握にも有効である。もちろん AVHRR 画像の空間分解能は約1.1kmと限られており、分類上意義のある大きさの農地であってもその農業特性は全く識別不可能となり、したがってそのような農地を農業特性を手掛かりに抽出することは困難である。そこで AVHRR 画像と TM 画像を組み合わせることで精度を向上させることができる。こうした組合せを利用すれば、落葉林の標高分布や地域固有の作付けパターンなど、対象地域に関する事前の知識が十分でない場合でも、画像データだけからより高い信頼性で土地被覆・土地利用の自動分類が可能と考えられる。

本論文では、広域での利用を念頭に置いた、高・低空間分解能画像をその長が反映されるように組み合わせ利用する、土地被覆自動分類手法を提案する。第2節では、高・低空間分解能画像の特徴や、分類を目的として両者を併用する際の問題点を整理する。その後に、本論文で提唱する分類手法を説明する。第3節では、インドシナ半島を対象とした実験結果を報告し、提案する分類手法の有効性を検証する。第4節で実験結果を考察し、第5節で結論を述べる。

2. 広域土地被覆分類手法

2.1 広域土地被覆分類に求められる要件

現在、解析などに使用されている衛星データは、その目的に応じて使い分けられているが、広域土地被覆分類となると低空間分解能画像が主として使用されて

いる。ここで光学センサの高・低空間分解能画像の特徴を比較していく。また、これより先の表現において、「高（低）分解能」は「高（低）空間分解能」を表すものとする。

高分解能画像は文字通り1ピクセルに相当する地上面積が小さく、したがって詳細な情報を抽出できる。しかしながら、その周期は十数日から数十日であり、撮影画像の多くは雲の影響を受けることも多い。場所によっては一年間を通じて数枚も入手することは期待できず、したがって季節変化のような情報は利用不可能である。そのため一年のある時期の画像のみを用いて分類することになり、その結果は撮影時期に大きく影響されることになり不安定と言える。また、詳細であるがゆえに局所的な特徴のみしか考慮せずに分類すると著しい誤分類に至ることがある。一方、低分解能画像は一年を通じて多数の画像を入手可能であり、したがって季節変化を考慮した分類が可能となる。また低分解能画像は、空間的に平滑化された画像であるから、分類結果は比較的安定している。しかし、やはり画像の粗さは克服できず、安定的な結果と引き換えに、ミクセルという粗い画像において顕著に見られる現象の影響が増大する。ミクセルは複数の土地被覆が混成しているピクセルであり、複数の土地被覆の輝度値が混合されて得られるミクセルの輝度値は、その他の純粋なピクセル（ピュアピクセル）の輝度値と同様な傾向を示す可能性もありえる。そのような場合においては、ミクセルはその同様な輝度値を有するクラスへと誤分類される傾向にある。このようなミクセルに対する処理がなされないと、その分類結果の信頼性は著しく低下する。このような特徴を有する高・低分解能画像を効果的に組み合わせれば、誤分類の少ない分類結果が得られると考えられ、これまでも異なる空間分解能画像を融合した分類に焦点を当てた研究が報告されてきた⁸⁻¹¹⁾。しかしながら、確立された手法は存在しておらず、理論的な整理、実用的な手法の完成が望まれている。

ここで異なる空間分解能衛星画像を用いて分類する場合、具体的にどのような問題が生じるか検討していく。衛星画像の使用の組合せを考えると、(1)低空間分解能(高時間分解能)衛星画像のみ使用、(2)複数のシーンにわたる高空間分解能(低時間分解能)衛星画像のみ使用、(3)両衛星画像の併用と大別できる。(1)~(3)の各々において考慮すべき項目を以下のように列挙す

る。

- (1) 低空間分解能（高時間分解能）衛星画像のみ使用
 - (a) 時系列変化からの土地被覆に固有な変化パターンの抽出
 - (b) 時系列変化パターンに対する雲の影響の除去
 - (c) ミクセルの考慮
- (2) 複数のシーンにわたる高空間分解能（低時間分解能）衛星画像のみ使用
 - (天候や日時などの) 撮影条件が異なる各画像（シーン）間での基準化
- (3) 両衛星画像の併用

センサ特性の違いを踏まえた上での両データの統一化

上述の項目のうち、(2)、(3)に関連して記述する。各土地被覆は固有のスペクトル特性を有するが、大気に大きく影響を受ける。よって、ほぼ同時期の同一シーンであっても、撮影日が異なると当然天候などの撮影条件が異なり、結果的に画像にも違いが表れる。高分解能画像を使用して広域分類を行う場合、多数のシーンにまたがることになり、その結果撮影日の異なる画像を使用することになる。シーン間の撮影日の違いを前提にした統一的な評価基準が必要になる。

2.2 手 法

2.1で説明した項目を考慮した上で、高・低分解能画像を併用した広域土地被覆分類手法の枠組みを提案する。

低分解能画像は、空間分解能が低いという欠点があるものの、容易にその時系列画像を入手できる。そのため、季節変化を捉えた分類が可能となるため、先に低分解能画像を使用して分類を行う。その際に全ての分類クラスを同時に分類するのではなく、決定木と同様に、他クラスからの分離度が高いクラスから順次分類していく方針を採る。その定量的な決定において情報量を用いる。すなわち、ある分類クラス群が存在しているとき、その中での分離度が高いクラスを情報量を用いて決定し、順次分類していく。上述の分類の流れをまとめると以下の通りとなる。

- 1 土地被覆クラスの候補を用意する。
- 2 トレーニングデータを使用して、クラス間の分離度を確認する。
- 3 分離度に基づき、決定木を構築する。

そのような決定木を構築し、分類を試みても、低分

解能画像を使用する以上、ミクセルの問題も不可避であり、全ピクセルに対して同等な信頼性で分類することは不可能である。分類データの使用者の立場から見ても、各ピクセルの分類の信頼性の高低は是非知りたいものである。したがって低分解能画像を用いた分類では、明瞭に高い分類信頼性を与えられるピクセルと、あいまいな分類しか実現できないピクセルに分ける。高い信頼性を与えられたピクセルは分類の対象からはとりあえず除外する。あいまいな分類ピクセルについては、低分解能画像から分類クラスの候補が与えられた上で、高分解能画像を用いて分類を行う。分類クラスの候補は季節変化を加味した上で絞られているので、高分解能画像自体は一時期の情報ではあるものの、誤分類に陥る可能性を極力避けた分類が可能となる。

したがって、本研究での広域土地被覆分類手法の基本方針を箇条書きすると以下のようになる。

- 1 低分解能画像を優先的に使用し分類していく。
- 2 (低分解能画像)特定のクラスに対して、明瞭に分離可能な特徴を発見したら、高い信頼性を与えて早めに分類する。
- 3 (低分解能画像)明瞭に分離することが不可能なピクセルについては、分類クラス候補のみ決定し、その後高分解能画像を使用して分類を行う。
- 4 (高分解能画像)低分解能画像から得られた分類クラス候補を活用し、尤度に基づく分類を行う。

これらを分類の手順として表現したのが図1である。

時系列低分解能画像はミクセルを含む可能性が高いことから、先に分類するがミクセルの可能性が高いピクセルとそれ以外を分類する。ミクセルの可能性に対しては、分類クラス候補を2つに絞り推定する。そのクラス候補に対して高分解能画像から詳細を特定しようとする方針を採る。

2.1の考慮すべき項目(2)、(3)に対処するために、NDVIの時系列変化に着目する。低分解能画像から計算されたNDVIの時系列変化は、画像の入手可能性を考えると比較的作成しやすい。一方、高分解能画像は同一のシーンに関して一年に数枚入手できる保証はなく、高分解能画像によるNDVIの時系列変化の計算は非常に難しいといえる。高・低分解能センサとしてTMとAVHRRを取り上げると、NDVIの計算に関係のある各々の観測波長帯域は重なる部分もあるものの異なっており、当然NDVIも異なってくる。しかし

図1 時系列低分解能画像と高分解能画像を併用した分類

図2 TM NDVI レベルのトレーニングデータセットの自動生成 (1月のTMシーン使用の例)

図3 時系列 AVHRR NDVI の分類結果の情報の活用方法

と、高分解能画像から推定された分類クラスを比較検討する(図3)。高分解能画像からのクラスが、低分解能画像の2つのクラスのどちらかと一致すればその結果を採用する。もし矛盾すれば、高分解能画像の推定結果が一時期によるもので信頼性が低いと判断して、ミクセルのままにしておく。

本論文で提案する、複数のシーンの高分解能画像を用いた広域土地被覆分類手法の特長をまとめると以下の通りとなる。第一に、各高分解能画像の分類に必要なトレーニングデータセットについては、本来は対象地域の土地被覆に関する知識の下に各シーンごとに抽

ながら、低分解能画像の時系列 NDVI を基準にし、撮影日あるいは撮影月を揃えて、高分解能画像の NDVI を低分解能画像の時系列 NDVI に合うように線型変換モデルのパラメータを推定し変換する。具体的には図2に示したように、低分解能画像から分類した結果と、高分解能画像の撮影月と同じ月の低分解能画像の NDVI を使用する。その両者から、対象としている高分解能画像の範囲の分類用トレーニングデータセットが生成される。これは低分解能画像レベルの NDVI であり、これに線型変換を適用することで高分解能画像レベルの NDVI のトレーニングデータセットが自動生成される。このトレーニングデータのパラメータは、対象シーンにおける各土地被覆のパラメータ(平均、分散、事前確率など)を反映しており、より高い精度の分類が実現可能と考えられる。つまり、このように自動生成されたトレーニングデータセットを利用すれば、その生成作業を要せずに、各シーンごとに最適化されたパラメータを用いた高分解能画像の分類が実現できる。

時系列低分解能画像から推定された分類クラス候補

出する作業が必要であるが、時系列低分解能画像から推定された分類結果を併用することで、自動的にかつ各シーンごとに最適化されたトレーニングデータセットが得られる。第二に、高分解能画像の分類結果に関しても、時系列低分解能画像からミクセルと推定されたピクセルに対しては、ミクセルを構成する土地被覆クラスを分類クラス候補情報として高分解能画像の分類結果の検定に活用する。この結果、誤分類を軽減した安定的な分類結果が得られる。よって、時系列低分解能画像の時系列情報、高分解能画像の空間的に詳細な情報という、両者の特長を取りこんだ分類が可能となる。ここで述べた、トレーニングデータセットの各シーンごとの最適化、および時系列低分解能画像から推定された分類クラス候補の有効性の両者を、分類精度に与える影響という観点から3.3で検証する。

3. 実 験

本論文で提案した広域土地被覆分類手法の適用結果を報告するが、対象地域としては、急激な森林破壊が進行しつつあり環境保全の観点から幅広い注目を集めるインドシナ半島を選定した。すなわち、年間に比較的稳定した降水量が期待される、いわゆる熱帯雨林地域に対応する地域と、乾季と雨季が存在する熱帯季節林が存在する地域における適用を想定している。本研究では、光学センサの高・低分解能画像として最も使用頻度が高い Landsat TM と NOAA AVHRR データを使用した。

3.1 AVHRR データ

EROS (The Earth Resources Observation Systems) データセンター (アメリカ) が公開している10日コンポジットデータの92年4月から93年3月までの1年間のデータを使用した。雲の除去対策としてコンポジットは有効であると広く認識されているが、10日コンポジットデータでは雲の影響が依然強く残る場合も見受けられるため、したがって月ごとに再合成したマンスリーコンポジットデータを使用する。しかしながらマンスリーにしても雲やセンサのノイズがはっきり認識できるようなデータもある。時系列データの特徴量抽出のために主成分分析を適用した¹²⁾が、主成分分析はノイズの影響を緩和する効果がある。ただし、NDVI に対する雲の影響は正負が混合したランダム

図4 時系列 AVHRR NDVI を使用した土地被覆分類結果¹²⁾

ノイズではないために、主成分分析を適用してもやはりその影響は残ることを明記しておく。

画像の投影法であるが、EROS データセンターではグーデ図法で投影されたデータを配布している。グーデ図法は面積が正確である利点はあるものの、引き換えに地形の歪みが生じる。本研究では、面積の正確性よりも地形が経緯度が常に直交し、地形の歪みが少ない経緯度直交座標系へ変換して解析を進めた。

時系列 AVHRR NDVI を使用した分類結果は図4のようになった¹²⁾。各土地被覆のトレーニングエリアの選定において、タイ王国の Department of Land Development が作成した1990年の土地利用図を、デジタル化したデータを使用した。また須崎ら¹²⁾の時系列 AVHRR NDVI を使用した分類フローにおいて、ミクセルかピュアピクセルか高い精度で分類できなかったピクセルに対して TM NDVI を使用して分類するものとし、分類フローは図5のようになった。

図5 本実験における時系列低分解能画像と高分解能画像を併用した分類フロー¹²⁾

図6 TM NDVI のモザイク
(下図は各シーンのパスロウ番号と撮影年月日)

3.2 TM データ

TM データに関しては、使用した AVHRR データが92年4月から93年3月の時期のデータであることを念頭に置き、それに対応して比較的近い時期に取得された、インドシナ半島を捉えた TM データを集めた。多数の TM データの中でもタイ周辺における TM のカバレッジマップを図6に示すが、図中の数字は各シーンのパス・ロウの情報を示し、例えば129049はパス129, ロウ49を意味する。TM データは7バンド分あるが、植生分類に対する有効性、また AVHRR との情報の互換性を考慮して、NDVI としての利用に限定する。したがって、バンド3・4の2バンドのみ使用した。

投影法であるが、AVHRR データを経緯度直交座標系に変換したのに合わせて、TM も同様に変換した。その際に、幾何補正アルゴリズムとして岩男のアルゴリズム¹³⁾を利用した。大量の TM 画像を、隣接する領域での相関や DCW (Digital Chart of the World) などの河川・海岸線情報などを元にして、自動的にタイポイントを取得し、総合的にかつ自動的にモザイク処理するアルゴリズムである。本来1kmグリッドである DCW データを30mメッシュに区切った基図に TM 画像を幾何補正した場合の精度は1ピクセル(約30m)以内であった。しかしながら、DCW は1kmグリッドであり、DCW そのものの位置誤差の影響が含まれている可能性を記しておく。DCW の精度に関する報告として建石らの研究¹⁴⁾がある。

先述のように92年4月から93年3月の AVHRR データを使用した関係から、その期間に可能な限り近

い時期に取得された TM データを使用するように努めたが、89年から95年までと数年違うシーンも存在している。図2に示された各 TM シーンの撮影時期も考慮されたトレーニングデータセット生成に必要な、AVHRR NDVI と TM NDVI 間の線型変換のパラメータを以下の手順で求めた。AVHRR の1ピクセルに対応する TM の領域(約36×36ピクセルの矩形)を定め、バンド3と4の集計値を求め、その結果得られる NDVI と AVHRR NDVI との線型変換におけるパラメータ推定を行った。ミクセル各シーンにおける線型変換の相関係数を表1に示す。TM 画像を確認した上で、相関係数が極端に低いシーン(128049, 128050)は AVHRR レベルの分類結果のままとし、その他のシーンで、かつ AVHRR レベルでミクセルと判定され

表1 TM NDVI と撮影月が同じ AVHRR NDVI との相関係数

パス・ロウ	撮影年月日	相関係数
126047	89/04/05	0.481
126048	89/04/05	0.672
126049	89/04/05	0.669
127048	89/03/11	0.828
127049	89/01/22	0.671
127050	89/01/22	0.831
127051	89/02/07	0.775
128047	89/03/02	0.602
128048	95/09/29	0.508
128049	95/09/29	-0.068
128050	95/09/29	0.254
128051	89/01/29	0.733
129047	89/03/25	0.678
129048	89/03/25	0.708
129049	89/01/20	0.802
129050	89/01/20	0.668
129051	89/01/20	0.574
130046	89/01/11	0.690
130047	89/01/11	0.832
130048	89/01/11	0.877
130049	89/01/11	0.917
130050	89/01/11	0.624
130051	89/02/12	0.461
131046	89/02/03	0.595
131047	89/02/03	0.616
131048	89/02/03	0.864
131049	89/01/02	0.830
131050	89/01/02	0.493

たピクセルに関しては TM レベルでの分類がなされた。図 7 には、自動生成されたトレーニングデータセットの結果が示されている。このトレーニングデータの自動生成の過程について補足する。TM 画像のシーンによっては、該当する AVHRR の分類結果のエリアにおいてミクセルが多数を占める場合も存在した。ミクセルを除外してトレーニングデータの作成を試みたが、サンプル数が極端に不足する場合もあった。したがって、トレーニングデータを得るために、ミクセルであっても尤度の高いクラスへ仮分類した結果を使用

した。

AVHRR NDVI と TM NDVI を融合して分類した結果を図 8 に示す。

3.3 検 証

分類結果の検証用に、現地を熟知し土地利用・被覆図作製にも携わったことのある専門家 2 人により作成された目視判読画像を利用した。その目視判読画像の作業工程を簡単に紹介する。TM 画像を使用して作業が進められたが、従来のように一度紙に出力してから判読しデジタイズする方法ではなく、作業効率化のため、コンピューター端末の画面上でベクターデータ(ポリゴン)としてデジタイズする「スクリーンデジタイズ」が行われた。TM 画像の空間分解能は 30m であるが、5×5 などの矩形の最小領域を設け領域内での代表値を元に判読されており、判読図の空間分解能は約 200m とのことである。以前作製された対象領域の土地利用・被覆図および現地に関する知識や経験に基づいて判読されているが、標高データなどの他の地理情報は活用されていない。カンボジア・トンレサップ湖周辺(パス127ロウ051, 1996年1月18日撮影)、タイ・コラート高原(パス128ロウ049, 95年12月5日)、タイ北部(パス130ロウ046, 97年1月25日撮影)の3ヶ所である。同一のパスロウであっても、この検証用に使用した TM 画像と実際に図 8 中で分類した画像は撮影年月日が異なる。分類手法の有効性を検証するために、目視判読に使用された TM 画像を実際に分類して、目視判読画像との比較を通して検証することとした。3 シーンにおいてトレーニングデータ生成に必要な線型変換を行なったが、その際の相関係数は、0.768 (カンボジア), 0.776 (コラート), 0.849 (タイ北部) となり、許容できるものと判断して検証を進めた。

検証項目は、1) 各シーンごとに生成されたトレーニングデータセットの有効性、2) AVHRR NDVI から推定されたクラス候補情報の有効性、である。1) に関しては、生成されたトレーニングデータセットを使用した場合と、AVHRR NDVI の分類対象地域全体から求められたトレーニングデータセットを使用した場合の分類結果を比較した。後者の場合、対象領域全体の AVHRR レベルの分類結果からトレーニングデータセットを求め、各シーンの線型変換パラメータを適用した。これにより、単純に各シーンごとにトレーニング

図7 時系列 AVHRR NDVI を使用した分類結果ならびに AVHRR NDVI を活用した TM NDVI レベルでのトレーニングデータの生成例

AVHRRレベルの分類結果

TMレベルの分類結果

図8 AVHRR と TM との融合した分類結果

ングデータセットのパラメータ（平均，分散，事前確率）が最適化されているか検証できた。カンボジア，コラート高原，タイ北部，3シーンの合計の各々の検証結果が表2に示されている。表2中の「最適化」は各シーンごとに生成されたトレーニングデータを使用した分類結果，「非最適化」はシーンに関係なく共通なトレーニングデータを使用した分類結果を表す。

2）に関しては，まず各検証シーンにおいて，AVHRR レベルの分類結果からのクラス候補情報は無視して自動生成されたトレーニングデータセットを使用して分類した。その分類結果のうち，クラス候補情報に矛盾するピクセルとそれ以外のピクセルに分けて，目視判読画像との正答率を求めた。これによりクラス候補情報の分類精度に与える影響が示された。検証結果は表3に示されている。表3中の「矛盾なし」は，時系列 AVHRR NDVI からの土地被覆クラス候補と TM NDVI からの分類結果が矛盾しない場合，「矛盾あり」はその両者の結果が矛盾する場合，「計」は矛盾の有無に関係なく分類した場合の分類結果を表す。

4. 考 察

4.1 自動生成されたトレーニングデータセットの有効性

リモートセンシングデータを用いた分類を取り扱った従来の研究では，特定の領域のトレーニングエリアから得られた各土地被覆に関するパラメータを固定し，そのまま適用範囲全体を分類する手法が多い。トレーニングデータの代表性という観点から考えると，

図9 検証シーン（上：タイ北部，中：タイ・コラート高原，下：カンボジア・トンレサップ湖周辺）¹²⁾

表2 各シーンに最適なトレーニングデータの有効性の検証（3シーンの総和）

(「最適化」は各シーンごとに生成されたトレーニングデータを使用した分類結果，「非最適化」はシーンに関係なく共通なトレーニングデータを使用した分類結果を表す)

(表中の数字は目視判読画像におけるピクセル数で，1ピクセルは約200mの空間分解能に相当する)

			目 視 判 読 画 像					
			常緑樹	落葉樹	畑	水田	計	正答率
分 類 結 果	常緑樹	最 適 化	1.08×10 ⁷	5.36×10 ⁶	1.65×10 ⁶	1.35×10 ⁴	1.79×10 ⁷	60.7%
		非最適化	1.03×10 ⁷	3.91×10 ⁶	1.11×10 ⁶	4.29×10 ³	1.53×10 ⁷	67.3%
	落葉樹	最 適 化	1.33×10 ⁶	6.87×10 ⁶	2.70×10 ⁶	4.36×10 ⁵	1.13×10 ⁷	60.6%
		非最適化	1.84×10 ⁶	8.01×10 ⁶	3.79×10 ⁶	9.75×10 ⁵	1.46×10 ⁷	54.8%
	畑	最 適 化	4.26×10 ⁴	1.93×10 ⁶	5.74×10 ⁶	6.71×10 ⁶	1.44×10 ⁷	39.8%
		非最適化	6.29×10 ⁴	2.42×10 ⁶	6.63×10 ⁶	1.32×10 ⁷	2.23×10 ⁷	29.8%
	水田	最 適 化	5.53×10 ²	4.93×10 ⁵	4.96×10 ⁶	2.68×10 ⁷	3.23×10 ⁷	83.1%
		非最適化	3.41×10 ²	3.13×10 ⁵	3.51×10 ⁶	1.98×10 ⁷	2.37×10 ⁷	83.9%
	計	最 適 化	1.22×10 ⁷	1.47×10 ⁷	1.50×10 ⁷	3.40×10 ⁷	7.59×10 ⁷	
		非最適化	1.22×10 ⁷	1.47×10 ⁷	1.50×10 ⁷	3.40×10 ⁷	7.59×10 ⁷	
	正答率	最 適 化	88.7%	46.9%	38.1%	78.9%		66.2%
		非最適化	84.4%	54.7%	44.1%	58.4%		59.0%

表3 時系列 AVHRR NDVI からの土地被覆クラス候補情報の有効性の検証（3シーンの総和）

（「矛盾なし」は、時系列 AVHRR NDVI からの土地被覆クラス候補と TM NDVI からの分類結果が矛盾しない場合、「矛盾あり」はその両者の結果が矛盾する場合、「計」は矛盾の有無に関係なく分類した場合の分類結果を表す）

（表中の数字は目視判読画像におけるピクセル数で、1ピクセルは約200mの空間分解能に相当する）

			目 視 判 読 画 像					
			常緑樹	落葉樹	畑	水田	計	正答率
分 類 結 果	常緑樹	矛盾なし	1.08×10^7	5.36×10^6	1.65×10^6	1.35×10^4	1.79×10^7	60.7%
		矛盾あり	5.42×10^5	1.50×10^6	4.64×10^5	7.70×10^4	2.58×10^6	21.0%
		計	1.14×10^7	6.86×10^6	2.11×10^6	9.05×10^4	2.04×10^7	55.7%
	落葉樹	矛盾なし	1.33×10^6	6.87×10^6	2.70×10^6	4.36×10^5	1.13×10^7	60.6%
		矛盾あり	3.54×10^3	5.46×10^5	1.46×10^6	8.94×10^5	2.90×10^6	18.8%
		計	1.34×10^6	7.41×10^6	4.16×10^6	1.33×10^6	1.42×10^7	52.1%
	畑	矛盾なし	4.26×10^4	1.93×10^6	5.74×10^6	6.71×10^6	1.44×10^7	39.8%
		矛盾あり	2.91×10^4	2.68×10^5	3.21×10^5	2.99×10^4	6.48×10^5	49.5%
		計	7.17×10^4	2.20×10^6	6.06×10^6	6.74×10^6	1.51×10^7	40.2%
	水田	矛盾なし	5.53×10^2	4.93×10^5	4.96×10^6	2.68×10^7	3.23×10^7	83.1%
		矛盾あり	3.78×10^4	1.43×10^6	1.40×10^6	2.28×10^6	5.15×10^6	44.2%
		計	3.84×10^4	1.93×10^6	6.36×10^6	2.91×10^7	3.74×10^7	77.8%
	計	矛盾なし	1.22×10^7	1.47×10^7	1.50×10^7	3.40×10^7	7.59×10^7	
		矛盾あり	6.12×10^5	3.74×10^6	3.65×10^6	3.28×10^6	1.13×10^7	
		計	1.28×10^7	1.84×10^7	1.87×10^7	3.73×10^7	8.72×10^7	
	正答率	矛盾なし	88.7%	46.9%	38.1%	78.9%		66.2%
		矛盾あり	88.5%	14.6%	8.79%	69.5%		32.7%
		計	88.7%	40.3%	32.4%	78.1%		61.9%

広域になるほど、それらの手法および分類精度の限界が明らかになると予想される。本研究で提案した手法では、時系列の低分解能画像、およびその分類結果を活用してまず低分解能画像レベルのトレーニングデータセットを推定する。そして、NDVIを指標として低分解能レベルから高分解能レベルのトレーニングデータセットを線型変換で求めることが可能である。この結果、図7の各シーンごとに自動生成されたトレーニングデータセットを使用した分類結果と、全体のトレーニングデータセットのパラメータを使用した分類結果の精度を比較すると、タイ北部の分類においては有意な改善効果は見られなかったが、それ以外のシーンと3シーンの合計において分類精度が向上していることが判明した。図7に示されたように、各シーンごとに各土地被覆クラスのパラメータを推定する仕組みは実現しているといえる。したがって、本研究で提案した広域土地被覆分類手法において、各シーンごとに

トレーニングデータセットの最適化が実現できていると考えられる。

本論文で提案する手法と異なり、線型変換を通さずに、低分解能画像のNDVIとその分類結果を用いてトレーニングデータセットを生成する方法も考えられ、実際に筆者らも試した。しかしながら、撮影月が同一であっても、高・低分解能画像での画像全体の特徴量分布が大きく異なる場合があり、低い分類精度に陥る結果となった。そのような高・低分解能画像との相関の影響を考慮して、提案手法では、相関係数を客観的な判断材料として、極端に低い相関係数の場合には高分解能画像では分類を行なわないとしている。

4.2 AVHRR レベルでの分類結果からの土地被覆クラス候補情報の有効性

図10はさとうきび畑の画像であり、内部に高いNDVIを示す矩形方の領域が分布している。土地被覆

クラス候補情報ありの分類結果

クラス候補情報なしの分類結果

Landsat TM NDVI
(画像強調処理適用)

図10 クラス候補情報による分類結果の違い（畑の例）
(分類クラスは図8を参照)

クラス候補の情報がないと、NDVIが高いピクセルは常緑樹林帯や落葉樹林帯と誤分類されることが多い。図10は、今回の4種類の土地被覆クラスの中では本来畑とされるべきであるが、結局 NDVI だけを用いた土地被覆分類では限界がある。つまり、クラス候補情報を一切活用せずに分類すると、信頼性が低いピクセルの影響を大きく受けて、結果的に低い分類精度にとどまってしまうことが読み取れる。このことは特定のシーンに限らず検証を行った3シーン全てに共通する傾向である。しかしながら、提案手法では NDVI しか使用していないものの、クラス候補情報を活用して、TM レベルでの分類結果と矛盾が生じた場合、分類の信頼性が低いと判断して、TM レベルでの分類クラスを棄却する仕組みになっている。検証の結果、時系列情報が集約されている土地被覆クラス候補情報は大変有用であり、それを取りこんだ提案手法が有効であることを示せた。

また、図11の AVHRR レベルでの各土地被覆クラスの NDVI の時系列カーブは、図11の土地被覆分類図で、ミクセルも最も尤度の高いクラスへ分類した結果を利用して作成した。図11に示されているように、互いに明瞭に分離可能ではなく $[-\sigma, \sigma]$ の区間であっても重なり合う部分が多い月もある。このことは、AVHRR レベルでの分類は大まかな傾向を示すものの精度の高い分類は期待できないことを示す。しかしながら、上述したように、AVHRR データの大まかな傾向から土地被覆クラス候補情報を抽出し活用することで、TM レベルでの誤分類を軽減することができ、一方で AVHRR レベルでは断定できない分類結果を TM レベルで特定可能となる。したがって、AVHRR,

図11 AVHRR NDVI の時系列変化(平均ならびに $[-\sigma, \sigma]$ の区間を表示)

TM データの長所を取り込んだ相互に有益なデータフュージョンが、本論文で提案する分類手法では実現できていると言える。

しかしながら、土地被覆クラス候補情報を活用しても誤分類は生じている。目視で一つの領域と認識できても、クラス候補が異なる場合に不自然な矩形型の境界線が生じる。図10の上図の中央の一部は、AVHRR レベルでは年間を通じて周囲より NDVI が高かったため、落葉樹林帯と畑のミクセルという推定され、その情報に則り TM レベルでは高い NDVI に反応する形で落葉樹林帯と誤分類されている。このような誤分類は完全に防ぐことは難しく、最終的には人間が目視で確認し、場合によっては修正する仕組みが必要であると筆者らは考えている。

5. 結 論

本論文では、異なる空間分解能衛星画像を併用し、特に低分解能画像に含まれ、分類精度に甚大な影響を与えるミクセルの存在を考慮した広域土地被覆分類手法を提案した。そして実際に高・低分解能画像として TM・AVHRR 画像を使用して、インドシナ半島を対象にケーススタディを行った。各シーンごとに自動生成されたトレーニングデータセットの有効性を検証した結果、各シーンごとに最適化されたパラメータを用いた分類が実現可能であると判明した。また、低分解能画像レベルでの分類を通して得られる土地被覆クラス候補情報の有効性を検証した結果、クラス候補情報と高分解能画像での分類クラスと一致しないピクセルの分類精度は著しく低く、クラス候補情報を活用することで分類精度の低下を免れることが明らかになった。本論文で提案した手法は、光学センサの、しかも特定のバンドのデータしか利用しないものの、異なる衛星画像の統合的利用という枠組みにおいて、その有効性を示すことができた。

(受付日2001.1.22, 受理日2001.9.11)

参考文献

- 1) Green, G.M. and Sussman, R.W.: "Deforestation history of the Eastern rain forests of Madagascar from satellite images", *Science*, vol. 248, no. 4952, pp.212-215, 1990.
- 2) Skole, D. and Tucker, C.: "Tropical deforestation

and habitat fragmentation in the Amazon: satellite data from 1978 to 1988", *Science*, vol. 260, no. 5116, pp.1905-1910, 1993.

- 3) Rignot, E., Salas, W.A. and Skole, D.L.: "Mapping deforestation and secondary growth in Rondonia, Brazil, using imaging radar and Thematic Mapper Data", *Remote Sensing Environ.*, vol. 59, no. 2, pp.167-179, 1997.
- 4) Dreyer, P.: "Classification of land cover using optimized neural nets on SPOT data", *Photog. Eng. Remote Sensing*, vol. 59, no. 5, pp.617-621, 1993.
- 5) 伊藤陽介・大松 繁: "競合型ニューラルネットワークによる土地被覆分類手法", 写真測量とリモートセンシング, vol. 35, No. 3, pp.5-17, 1996.
- 6) Key, J.R., Maslanik, J.A. and Barry, R.G.: "Cloud classification from satellite data using a fuzzy sets algorithm: A polar example", *Int. J. Remote Sensing*, vol. 10, no. 12, pp.1823-1842, 1989.
- 7) Wang, F.: "Improving remote sensing image analysis through fuzzy information representation", *Photog. Eng. Remote Sensing*, vol. 56, no. 8, pp.1163-1169, 1993.
- 8) Mascarenhas, N.D.A., Banon, G.J.F. and Candéias, A.L.B.: "Multispectral image data fusion under a Bayesian approach", *Int. J. Remote Sensing*, vol. 17, no. 8, pp.1457-1471, 1996.
- 9) Costantini, M., Farina, A. and Zirilli, F.: "The fusion of different resolution SAR images", *Proc. IEEE*, vol. 85, no. 1, pp. 139-146, 1997.
- 10) Iverson, L.R., Cook, E.A. and Graham, R.L.: "A technique for extrapolating and validating forest cover across large regions Calibrating AVHRR data with TM data", *Int. J. Remote Sensing*, vol. 10, no. 11, pp.1805-1812, 1989.
- 11) Maselli, F., Gilabert, M.A. and Conese, C.: "Integration of high and low resolution NDVI data for monitoring vegetation in Mediterranean environments", *Remote Sensing Environ.*, vol. 63, no. 3, pp.208-218, 1998.
- 12) 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の開発", 写真測量とリモートセンシング, vol. 40, no. 3, pp.14-24, 2001.
- 13) 岩男弘毅: "多時期・多解像度衛星画像の自動幾何補正手法の開発に関する研究", 東京大学学位論文, 2000.
- 14) 建石隆太郎・徐 侃: "DCW の精度に関する研究", 写真測量とリモートセンシング, vol. 37, no. 3, pp.65-69, 1998.