

リモートセンシング画像の分解能が 土地被覆分類精度に及ぼす影響

児島 利治・宝 馨・岡 太郎

EFFECT OF SPATIAL RESOLUTION OF REMOTELY SENSED IMAGES ON LAND COVER CLASSIFICATION ACCURACY

By *Toshiharu KOJIMA, Kaoru TAKARA and Taro OKA*

Synopsis

Now various kinds of high resolution remote sensors are available, such as Landsat TM (spatial resolution 30 m × 30 m), SPOT HRV (20 m × 20 m) and ADEOS AVNIR (16 m × 16 m) launched in 1996. It is significant to quantify the accuracy of interpretation or classification on high resolution remotely sensed images. This paper assesses land cover classification accuracy quantitatively for four remotely sensed images acquired almost simultaneously with various sensors with different spatial resolutions: Landsat TM, SPOT HRV, JERS OPS (18 m × 24 m), Airborne multispectral scanner (AMSS: 6.25 m × 6.25 m), and false remotely sensed images produced by three degradation algorithms. These false images have 10-m to 30-m resolution resampled from the 6.25-m AMSS image. The authors also produce the 16-m false AVNIR image by a degradation algorithm, and predict the classification accuracy of ADEOS AVNIR images.

1. はじめに

近年、リモートセンシング画像の空間分解能はLandsat TMの30 mをはじめとして、SPOT HRVの20 m、1996年度打ち上げ予定のADEOS AVNIR（高性能可視近赤外放射計）の16 mと益々高分解能化が進んでいる。また、今まで非公開であった数mの分解能を持つリモートセンシング画像も利用可能になりつつある。このように30 mの分解能を超える高分解能リモートセンシング画像が活用されるようになった今、高分解能画像の分類精度がどの程度あるのかを確認しておく必要がある。

分解能と分類精度の関係について検討したのに竹内・富田¹⁾、張ら²⁾の研究がある。竹内・富田は、観測年度のそれぞれ異なる航空機MSS画像（1982年5月23日；分解能5 m）、SPOT HRV画像（1986年4月7日；分解能20 m）、Landsat TMおよびMSS画像（1987年5月21日；30 mおよび80 m）の比較と、航空機MSS画像から算術平均によって生成した分解能10 m, 20 m, 30 m, 50 m, 80 mの疑似リモートセンシング画像の比較を行っている。張らは、TM画像（1984年11月4日）から算術平均によって生成した分解能25 m, 50 m, 75 mの疑似リモートセンシング画像とSPOT画像（1986年6月9日）を比較した。しかし、いずれも、取得年が異なるリモートセンシング画像を用いて比較しており、疑似リモートセンシング画像も算術平均で生成し、細かく分解能が変化する時の分類精度の変化を見てはいない。

本研究では、ほぼ同時期に取得された航空機MSS画像と3種の衛星画像を用い、任意に分解能を決定できる低分解能化アルゴリズムを用いて、航空機MSS画像から2 m刻みの分解能の疑似リモートセンシング

画像を生成し、30 m より細かな分解能における土地被覆分類精度に及ぼす影響を調べる。

2. 使用データと対象地域

本研究では以下のようなセンサーによる画像データを用いた。

- [1] Landsat-5 TM (分解能 30 × 30 m, 取得日時 10月23日 9:45)
- [2] SPOT-2 HRV (20 × 20 m, 10月22日 10:27)
- [3] JERS-1 OPS (18 × 24 m, 10月28日 10:30)
- [4] 航空機 MSS (6.25 × 6.25 m, 10月18日 11:38–11:41)
- [5] 航空写真 (縮尺 1:10,000, 10月27日)

対象地域は、愛知県矢田川流域の長久手町、長久手東小学校周辺の約3 km 四方の領域とした。上記の画像データは、1992年10月に行われた矢田川航空機実験^{3),4)}において取得されたものである。

[5]を基に、細密数値情報⁵⁾の10 m グリッドの土地利用マップ (TDT-112) と現地踏査で得られた情報を参考に、2 m グリッドの領域全体のグランドトゥルースマップを生成した。分類クラスは、森林 (Forest), 水田 (Paddy), 草地 (Grass), 裸地 (Bare soil), 都市域 (Urban), 水域 (Water) の6つとした。河川は水面のほかに、砂州、河川敷の裸地、雑草など異なる土地被覆を含むので、河川というクラスは設定せず、分類対象外とする。

それぞれの画像データは、2段階リサンプリング法⁶⁾を用いて、画素サイズを6.25 m に統一して重ね合わせを行った。第1段階の重ね合わせでは、スキャナで読み込んだ地形図を基準画像とし、約20点のGCPを選択した。第2段階では、第1段階幾何補正を行ったOPS画像を基準画像とし、約100点のGCPを選択した。この2段階の幾何補正には、米国ERDAS社の地理情報システムIMAGINE8.2を用いた。幾何補正の精度を示すRMSEを見ると、最終的な位置誤差は、3つの衛星リモートセンシングデータでは10 m 前後、航空機MSSデータでは20 m 程度であった。元の衛星データの画素サイズから考えると、位置誤差は1画素内に収まり、精度よく重ね合わせができている。航空機MSSは他のセンサーに比べて高度が低くて、走査幅が狭く、プラットフォームの安定性もあまり良くないので元データの歪みが大きいと思われる。

3. 精度評価手法

分類精度は判別効率表 (confusion matrix) を用いて評価する。判別効率表とは、分類の結果得られた分類クラスと、実際の地上の状態 (グランドトゥルース) を示す参照クラスを行と列にとった正方の表で、各成分は分類された画素数である。行列の対角成分が正しく分類された画素数で、それ以外は誤分類された画素数を表現する⁷⁾。

Table 1 は判別効率表の例である。この表からはグランドトゥルースが森林で、かつ森林に分類された画素数は913個、グランドトゥルースが森林でかつ水域に分類された画素数は3個であることが判る。

この判別効率表から、様々な精度評価指標が導き出される。総合精度 (overall accuracy; OA) は全画素の何割が正しく分類されたかを示す精度評価指標であり、判別効率表内の総画素数をN、判別効率表の(i,j) 成分をx_{ij}、分類クラス数をmとしたとき、以下の式で表される。

$$OA = \frac{1}{N} \sum_{i=1}^m x_{ii} \quad \dots \quad (1)$$

x_{ii} は判別効率表の対角成分、すなわちクラス i において正しく分類された画素数である。

グランドトゥルースの何割が正しく分類されているかを示す精度評価指標を作成者精度 (producer's accuracy; PA) と呼び、分類結果の何割が正しいかを示す指標を使用者精度 (user's accuracy; UA) と呼び、以下の式で表現する。

Table 1 Confusion matrix for the test areas in the airborne MSS image obtained by the maximum likelihood classifier.

Classified Data	Reference Data						Total	UA (%)
	Forest	Paddy	Grass	Bare soil	Urban	Water		
Forest	913	0	10	0	0	3	926	98.6
Paddy	0	411	3	5	32	3	454	90.5
Grass	0	29	318	0	9	10	366	86.9
Bare soil	0	4	0	160	113	0	277	57.8
Urban	0	25	0	5	354	2	386	91.7
Water	3	4	0	3	34	153	197	77.7
Total	916	473	331	173	542	171	2606	
PA (%)	99.7	86.9	96.1	92.5	65.3	89.5		

Overall Accuracy = 88.6 %
Kappa Coefficient = 85.3 %

$$PA_i = \frac{1}{x_{+i}} x_{ii} \quad \dots \dots \dots \quad (2)$$

$$UA_i = \frac{1}{x_{++}} x_{ii} \quad \dots \dots \dots \quad (3)$$

ここで、 x_{+i} は参照クラスの総ピクセル数、すなわち i 列の要素の合計、 x_{++} は分類クラスの総ピクセル数、すなわち i 行の要素の合計である。

kappa 係数 (kappa coefficient ; KC) は、総合精度から分類が偶然的中する率を除いた精度評価指標で、上で用いた x_{+i} と x_{++} を用いて以下のような式で表現される⁸⁾。

$$KC = \frac{N \sum_{i=1}^m x_{ii} - \sum_{i=1}^m (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^m (x_{i+} \times x_{+i})} \quad \dots \dots \dots \quad (4)$$

4. 4種のRS画像の比較

分解能が異なる4種のリモートセンサー、Landsat-5 TM (分解能 30 × 30 m), SPOT-2 HRV (20 × 20 m), JERS-1 OPS (18 × 24 m), 航空機MSS (6.25 × 6.25 m) から得られたリモートセンシング画像の土地被覆分類精度を比較し、分解能と分類精度の関係を調べる。4種のリモートセンシング画像は、1992年10月18日から28日という短い間に観測されているため土地被覆の変化はない。観測時間帯も午前中の2時間以内であるため、日射角度等の変化による各画像間の差はないものと考えられる。

4.1 分類に用いる波長帯

本研究では、分解能が分類精度に及ぼす影響を評価することを主目的としているため、各リモートセンシング画像の波長帯の違いによる影響はなるべく少なくしたい。そこで、分類に用いるバンド数は可視・近赤外域に含まれる3つとし、各々なるべく近い波長帯を持つバンドを選んだ。分類に用いるバンド数を3つとした理由は、最もバンド数の少ないSPOT HRVのバンド数が3つであるからである。各リモートセンシングデータで選んだバンドは以下の通りである (Fig. 1 参照)。

- [1] Landsat-5 TM band 2, band 3, band 4
- [2] SPOT-2 HRV band 1, band 2, band 3
- [3] JERS-1 OPS band 1, band 2, band 3
- [4] 航空機MSS band 6, band 8, band 12

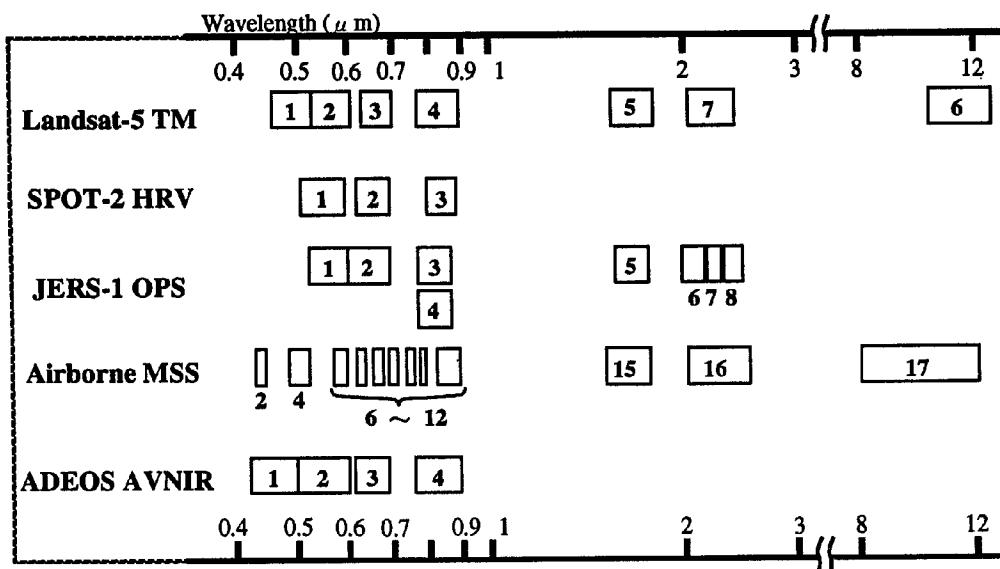


Fig. 1 Comparison of wavelengths of five sensors.

4.2 4種のRS画像の分類と定量的精度評価

ここでは、教師付き分類法である、最尤法 (maximum likelihood classifier ; ML) とマハラノビス最短距離法 (minimum Mahalanobis's distance classifier ; MD), ユークリッド最短距離法 (minimum Euclidean distance classifier ; ED) を用いる。各画像は同じ領域からトレーニングデータ (教師データ) を抽出した。

判別効率表による精度評価では、均質な土地被覆を持ついくつかの部分領域を精度評価のために全体画像から抽出し、この領域に含まれるサンプルデータに対して分類精度を推定することが一般的である。本研究ではこの部分領域のことを、テストエリアと呼ぶことにする。

(1) テストエリアでの評価

Congalton⁸⁾によれば、クラス数が10クラス程度以下の場合、テストエリアのサンプルは、各クラスにつき50個以上必要とされている。本研究では、2606個のサンプルを持ち、各クラスのサンプル数が100個以上であるテストエリアを用いて精度評価を行った。

先に示したTable 1は航空機MSSを最尤法を用いて分類した結果に対してテストエリアについて求めた判別効率表である。OAで80%以上、KCで75%以上の精度を示している。Congaltonの論文⁸⁾では、OAは80%強、KCは80%弱程度が示されており、この分類結果はそれらとほぼ同程度と言える。ただし、PA、UAを見てみると、都市域のPAなど、極端に悪い部分も見受けられる。

次に、航空機MSS以外の分類精度を見てみる。Table 2は、各リモートセンシングデータを3種の分類手法を用いて分類した結果のテストエリアにおける精度評価の比較である。OA、KCともほとんど80%以上で精度良く分類されている。センサー別に精度を比較してみると、あまり大きな差異は見受けられない。強いてあげると、航空機MSSが他に比べて劣っていることが判る。また、分類手法について比較しても、あまり大きな差はなかった。

(2) 画像全体での評価

画像全体でも判別効率表を作成して、精度評価を行った。Table 3は航空機MSSの最尤法を用いた分類

Table 2 Comparison of the classification accuracies of four remotely sensed images for the test areas.

		Airborne MSS	JERS-1 OPS	SPOT-2 HRV	Landsat-5 TM
ML	OA	88.6	94.4	94.3	95.5
	KC	85.3	93.8	92.7	94.2
MD	OA	82.6	91.6	91.7	93.9
	KC	77.8	89.2	89.4	92.2
ED	OA	84.8	90.5	90.5	92.0
	KC	80.6	87.8	87.9	89.8

(unit : %)

Table 3 Confusion matrix for the whole areas in the airborne MSS image obtained by the maximum likelihood classifier.

Classified Data	Reference Data						Total	UA (%)
	Forest	Paddy	Grass	Bare soil	Urban	Water		
Forest	73093	411	3113	433	1164	215	78429	93.2
Paddy	9137	14862	10671	3520	14181	224	52595	28.3
Grass	14884	7562	21679	1860	4653	169	50807	42.7
Bare soil	2498	1466	2206	7841	5512	30	19553	40.1
Urban	3795	2037	2665	3076	20516	239	32328	63.5
Water	4325	382	1027	414	3597	1492	11237	13.3
Total	107732	26720	41361	17144	49623	2369	244949	
FA (%)	67.9	55.6	52.4	45.7	41.3	63.0		

Overall Accuracy = 56.9 %

Kappa Coefficient = 43.9 %

結果に対して画像全体について求めた判別効率表である。OA は 57 %, KC は 44 % であり、テストエリアでの結果に比べて OA, KC とも 30 ポイントずつ落ちていた。

テストエリアは、ほぼ均一な土地被覆を持つ領域を選んで、土地被覆が混在している領域を選ばないのが一般的である。したがって、テストエリア内にはミクセル（複数の土地被覆の混在するピクセル）はほぼ存在しない。また、テストエリア内及びその周辺は均一な土地被覆を持っているので、グランドトゥルースマップとリモートセンシングデータの対応する各画素の位置が多少ずれていても、その位置誤差はほとんど問題にならない。一方、画像全体を評価する場合には、ミクセルが多数存在する上、位置誤差が精度評価に影響する。以上のことから、テストエリアを用いた精度評価と全画像の精度評価では大きな差が生じる。画像全体での評価が、OA で 50 % 程度、KC で 40 % 程度であっても、必ずしも精度が低いとは言えない。

航空機 MSS 以外の画像、最尤法以外の分類法についても画像全体で精度評価を行ってみたが、航空機 MSS と同じように、OA で 55 % 程度、KC で 40 % 程度の精度であった。また、空間分解能や分類手法の

Table 4 Comparison of the classification accuracies of four remotely sensed images for the whole area.

		Airborne MSS	JERS-1 OPS	SPOT-2 HRV	Landsat-5 TM
ML	OA	56.9	56.4	52.9	56.4
	KC	43.9	43.2	40.1	43.6
MD	OA	54.2	56.3	50.2	53.3
	KC	41.1	43.2	37.4	40.7
ED	OA	54.2	58.6	54.8	56.2
	KC	40.2	44.7	40.7	41.5

(unit : %)

違いによる差異も、テストエリアでの評価と同じように見受けられなかった (Table 4 参照)。

4.3まとめ

4種の空間分解能の異なるリモートセンシング画像の分類精度を比較した結果、以下のような知見が得られた。

- (1) 判別効率表とそれに基づく4つの評価基準（総合精度OA, kappa係数KC, 作成者精度PA, 使用者精度UA）により、テストエリアでの分類精度評価のみならず、画像全体での評価も行った。テストエリアでの評価は、いずれの画像もOA, KCともに80%程度以上の精度を得ており、従来の研究におけるものと同程度の分類精度を得た。一方、画像全体での評価はこれまであまり行われていないものであって、こうした精度が明らかにされていなかったが、OAで55%程度, KCで42%程度という評価値を得た。
- (2) 最尤分類法、マハラノビス最短距離法、ユークリッド最短距離法という3種の分類手法を比較したところ、いずれもほぼ同程度の分類精度を示した。
- (3) 空間分解能が向上しても、必ずしも分類精度が向上しなかった。原因の1つは、位置誤差にあると考えられる。幾何補正の精度を示すRMSEが、他の衛星画像の10m程度に比べて航空機MSSだけ20m程度と特に大きく、それだけ位置誤差が大きいと思われる。2つ目の原因是設定した分類クラスの数が、6.25mという分解能の高さに合っていないことが挙げられる。高空間分解能になるほど、より細かな事物が把握できるようになるので、分類クラスの数を増やし、またそれら多数の分類クラスを識別するためにスペクトル分解能を上げる（またはバンド数を増やす）必要がある。

本章で行ったように、異なるセンサーから得られた画像を比較する場合には、波長帯の違いや微妙な位置誤差によって分類精度が多少影響を受けるのではないかという疑問が残る。そこで次章では、低分解能化アルゴリズムを用いて、航空機MSS画像から任意の分解能をもつ波長帯が同じで位置誤差のないリモートセンシング画像を生成し、分解能が土地被覆分類精度に与える影響を調べる。

5. 低分解能画像の比較

5.1 低分解能化アルゴリズム

(1) 算術平均による方法

近接する $n \times n$ の画素の値を算術平均する。例えば分解能5mの画像からは、 2×2 、計4画素の画素値を算術平均することで分解能10mの画像を生成することができる。この手法は最も単純で計算時間も早い。しかし、この手法は元となる画像の分解能に依存し、分解能5mの画像からは、分解能10m, 15mといった5mおきの分解能の画像でなければ生成できない。この手法による低分解能画像を用いた研究はいくつか行われている^{1), 2)}。

(2) 内挿法を用いたアルゴリズム

共1次内挿法 (bi-linear interpolation) や3次畳み込み内挿法 (cubic convolution interpolation) などの内挿手法で低分解能の画像を生成する。この手法では任意の画素サイズの画像が生成できる。しかし、以下のような欠点を持っている。

分解能 d_1 をもつリモートセンシング画像 $i_1(x, y)$ の画素の値は、地表面の座標 (x, y) の周囲 $d_1 \times d_1$ の領域から得られた情報で構成されていると考えられる。言い換えると、関数 $i_1(x, y)$ は座標 (x, y) の周囲 $d_1 \times d_1$ の領域の情報を平均化した値の関数といえる。また、内挿法というものは、ある関数 $i(x)$ (x は連続値) を d_1 という間隔でサンプリングされたデータ列 (Fig. 2(a)の左図, $i_1(x)$; x は離散値) から元の関数 $i(x)$ を推定し、サンプリング間隔を d_2 に変えて値を出力し新たなデータ列 (Fig. 2(a)の右図, $i_2(x)$; x は離散値) を得る手法であるといえる。したがって、データ列 $i_1(x)$ の各値がリモートセンシング

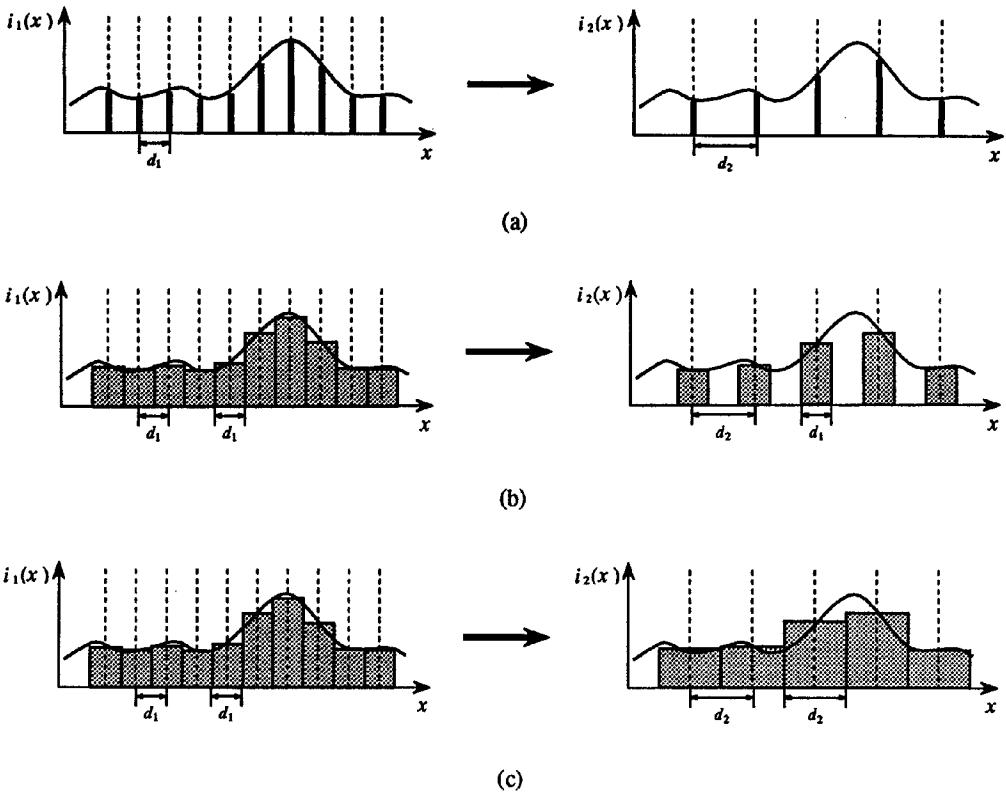


Fig. 2 Various resampling algorithms for one-dimensional case, (a) general interpolation, (b) image degradation using interpolation and (c) image degradation in a strict sense.

画像のように位置 x の周囲 d_1 (x を含む $[(n-1)d_1, nd_1]$ の範囲) という領域からの情報を元にした数値、例えば Fig. 2 (b) の左図のように d_1 という領域の平均値である場合、そのデータ列 $i_1(x)$ から推定される元の関数 $i(x)$ (x は連続値) は、 x の周囲 d_1 (x を中心とする $[x - d_1/2, x + d_1/2]$ の範囲) の平均値である。よってこのようにして得られる関数 $i(x)$ (x は連続値) を間隔 d_2 でリサンプリングすると、得られるデータ列 $i_2(x)$ (x は離散値、データ間隔 d_2) は Fig. 2 (b) の右図のように x の周囲 d_1 (x を中心とする $[x - d_1/2, x + d_1/2]$ の範囲) の平均値となる。

つまり、分解能 d_1 のリモートセンシング画像 $i_1(x, y)$ を内挿法によって分解能 d_2 に低分解能化すると、得られる低分解能画像 $i_2(x, y)$ は、画素サイズ（すなわちサンプリング間隔）は $d_2 \times d_2$ であるが、画素サイズは地表面の座標 (x, y) の $d_2 \times d_2$ の領域すべてではなく、その画素の中心部の $d_1 \times d_1$ の領域から得られた情報を基にした画像となる。

高分解能センサー（分解能 d_1 ）で観測された画像を低分解能化（分解能 d_2 ）するには、Fig. 2 (c) のようにリサンプリング間隔 d_2 のすべての領域から得られた情報を基にすべきである。このような真の意味での低分解能化を行うには、次項のようなアルゴリズムで低分解能化を行う必要がある。

(3) 画像復元手法 (MTF 補正) を応用した低分解能化アルゴリズム

リモートセンサーで点光源を撮影したとすると、得られる画像はある広がりをもつ像となる。この広がり方を点像分布関数 (point spread function) と呼ぶ。センサーで観測する被写体を点光源の集まりと考える

本研究では MTF 補正を用いた低分解能化アルゴリズム (MTF) と 3 次畳み込み内挿法による低分解能化アルゴリズム (CC) および算術平均によって、分解能 6.25 m の航空機 MSS 画像から分解能 10 m から 30 m の低分解能画像を生成する。

5.2 土地被覆分類手法と分類精度評価手法

ここでは、航空機 MSS の 12 のバンドすべてを用いて分類を行う。分類手法には、教師つき分類法である最尤法とユークリッド最短距離法を用いる。グランドトゥルースマップは 2 m という高分解能のものを用いる。従来の同様の研究では、例えば分解能 20 m の画像と 30 m の画像の分類精度を比較するとき、高分解能のグランドトゥルースマップから最大頻度によって 20 m と 30 m グリッドのグランドトゥルースマップを生成し、それぞれの分解能のグランドトゥルースを用いて分類精度を評価していた。それに対してここでは、高分解能のグランドトゥルースマップをそのまま用いて、同一の基準で分類精度評価を行う。これは、2 m 刻みという細かな分解能の変化による分類精度の変化を見るためである。

5.3 航空機 MSS 画像に基づく低分解能化画像の分類と定量的精度評価

Table 5 に CC と MTF による低分解能化画像の最尤分類結果を OA と KC で示す。分解能 6.25 m の画像は同じものなので当然 OA と KC それぞれの値は同じであるが、低分解能化した画像は、すべて CC より MTF による画像の方が分類精度が若干良いことがこの表から見て取れる。また、高分解能画像よりも低分解能画像の方が CC と MTF による画像の分類精度の差が大きいことが分る。CC による画像は 1 画素の値が、画素の中心部の 6.25×6.25 m の領域のみから得た情報を基にしていることに対し、MTF による画像は分解能 10 m なら 10×10 m の領域から情報を得ている。そのため、MTF による画像の方が 1 画素の情報量が多いため、分類精度が良いという結果となる。また、分解能が粗くなるほど 1 つの画素の情報量の差は大きくなるため、分解能が粗くなるにしたがって CC と MTF による画像の分類精度の差が大きくなっている。

Fig. 3 に算術平均による低分解能化画像の最尤法による分類結果を OA と KC で示す。分解能が粗くなるにつれて、精度が低下することが分るが、算術平均では 6.25 m 每の大きさの分解能をもつ画像でなけれ

Table 5 Comparison of the maximum likelihood classification accuracies of the 6.25-m airborne MSS image and degraded images with 10-m to 30-m resolution resampled from that image using cubic convolution interpolation (CC) and MTF correction algorithm (MTF).

Resolution	CC		MTF	
	OA	KC	OA	KC
6.25 m	64.30	51.05	64.30	51.05
10 m	64.50	51.08	64.58	51.20
12 m	65.18	51.85	65.28	51.98
14 m	64.40	50.91	64.66	51.23
16 m	63.64	50.15	63.80	50.35
18 m	63.33	49.45	63.80	50.09
20 m	63.30	49.43	63.61	49.82
22 m	60.45	45.82	60.80	46.30
24 m	62.57	48.29	62.96	48.86
26 m	62.24	47.94	61.47	47.73
28 m	60.96	46.84	61.37	47.49
30 m	58.49	44.61	59.22	45.58

(unit : %)

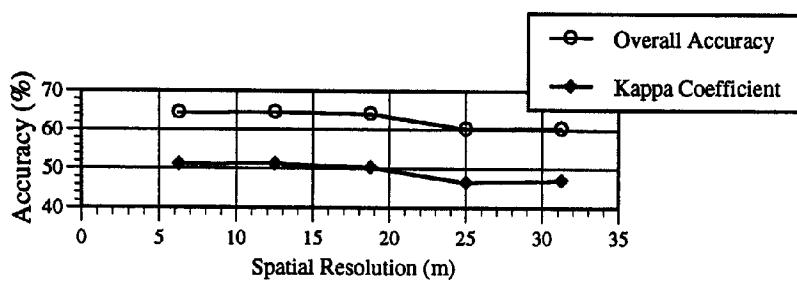


Fig. 3 Relationship between spatial resolution and maximum likelihood classification accuracy based on the degraded images using the arithmetic mean.

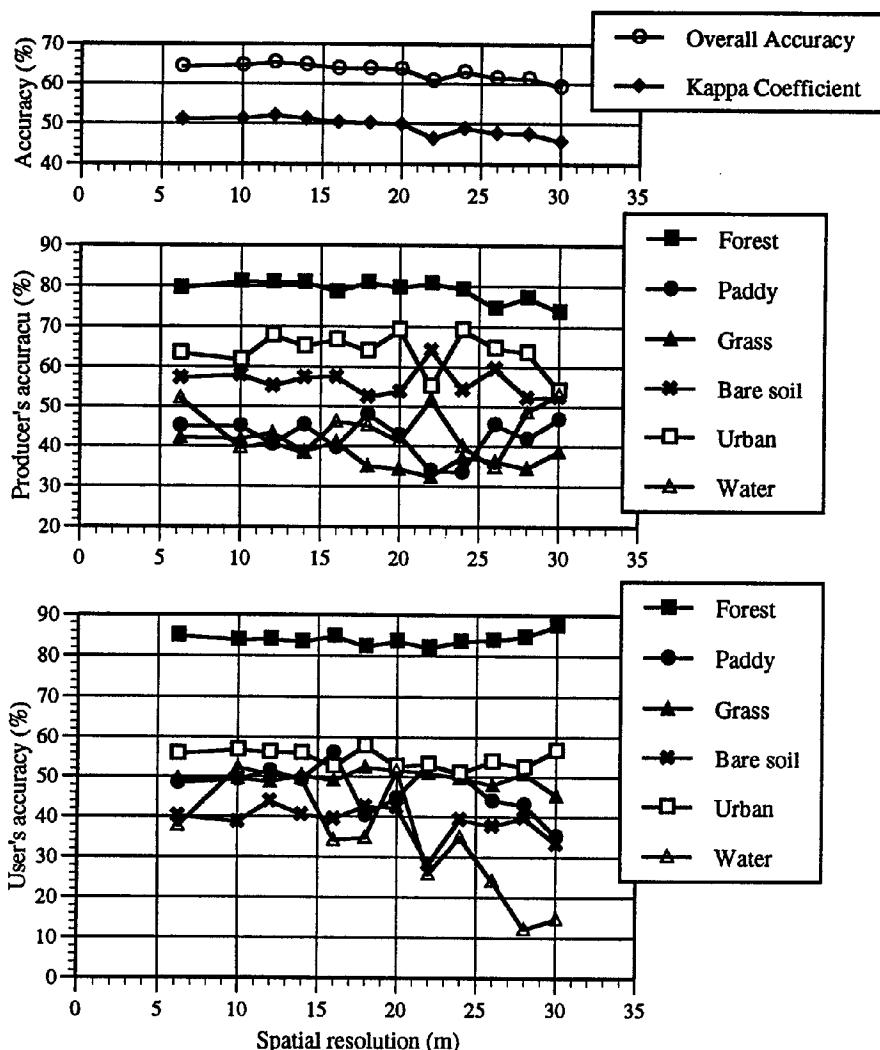


Fig. 4 Relationship between spatial resolution and maximum likelihood classification accuracy based on the degraded images using MTF correction algorithm (the upper panel : OA and KC ; the middle : PA ; the lower : UA).

ば生成できないので、細かく分解能が変化するときの分類精度の変化を見ることはできない。

Fig. 4 に MTF による低分解能化画像の最尤法による分類結果を示す。一番上の図が OA と KC、真中が PA、一番下が UA の分解能による変化を示している。一番上の図からは、分解能 12 m を最高に分解能が粗くなるにしたがって OA と KC が徐々に悪くなっていくのが分る。また、**Table 5** から、最も低分解能の 30 m の分類精度と比較して、最高の精度をもつ分解能 12 m の分類精度は、OA、KC とともに 6 ポイント程度分類精度が向上していることが分る。

Fig. 5 には MTF による低分解能化画像のユークリッド最短距離法による分類結果を示す。**Fig. 4** と同じく、**Fig. 5** の一番上の図は OA と KC、真中は PA、一番下は UA の変化を示している。**Fig. 5** の一番上の図から画像全体の分類精度が最も良い画像は、分解能 12 m (OA = 62.54 %, KC = 48.48 %) か 16 m (OA = 62.48 %, KC = 48.59 %) の画像であり、最も悪い画像は分解能 28 m (OA = 60.20 %, KC = 45.89 %) か 30 m (OA = 60.16 %, KC = 46.44 %) の画像であることが分る。最も精度が良い分解能、悪い分解能は最尤法の結果と完全には一致せず、その分類精度の向上も 2 から 3 ポイント程度と最尤法によ

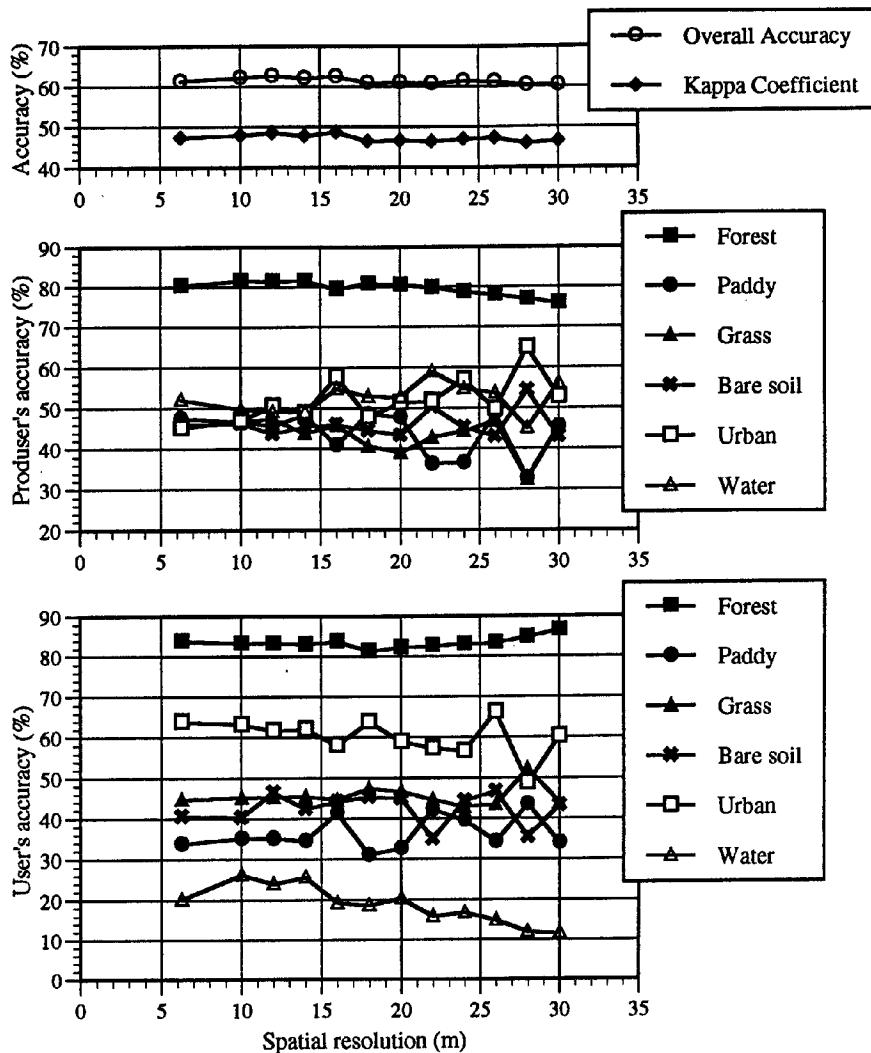


Fig. 5 Relationship between spatial resolution and minimum Euclidean classification accuracy based on the degraded images using MTF correction algorithm (the upper panel : OA and KC ; the middle : PA ; the lower : UA).

る結果に比べて少ない。しかし、10 m より少し粗い分解能が最も精度が良く、分解能が粗くなるにしたがって精度が悪くなっていく傾向は同じである。

Fig. 4 と **Fig. 5** の真中と一番下の図、PA と UA に注目すると、分解能が粗くなるにしたがって、森林の PA が下がり、UA が上がるのが目に付く。分解能が粗くなるにしたがって PA が下がる理由については次のように推測できる。森林内はほぼ均一なので分解能が高く（1画素の占める領域が狭く）ても、分解能が低く（1画素の占める領域が広く）広範囲の情報を持っていても分類結果はほぼ正しく森林となる。しかし、森林と他の領域の境界近くでは、分解能が低く広範囲の地表面の情報を画素がもつとき、森林以外の土地被覆の地表面の情報も混ざってしまい誤分類を発生し、PA が悪くなる原因となるのではないだろうか。また、PA と UA の変化は OA と KC に大きな違いがなければ、PA が良ければ UA は悪く、UA が良ければ PA は悪くなる傾向にある。この場合、分解能が粗くなるにしたがって PA が下がれば UA が上るのは納得がいく。森林以外の分類クラスについては、森林のように顕著な傾向を見つけることはできない。森林以外の分類クラスは、森林ほど広範囲に均一な土地被覆で覆われた領域は少ないので、上述のような理由による顕著な傾向は現れないのではないだろうか。

また、森林以外の PA を見てみると、最尤法による結果 (**Fig. 4**) に比べてユークリッド最短距離法による結果 (**Fig. 5**) の方が、各分類クラスの分類精度が 50 % 付近に集中しているように見える。UA に関しては、ユークリッド最短距離法による結果 (**Fig. 5**) に比べて最尤法による結果 (**Fig. 4**) の方が、各分類クラスの分類精度が 50 % 付近に集中しているように見える。これは、それぞれの分類精度で森林だけが良く、他のクラスと離れていることから分るように、元画像の最尤分類結果の森林以外のクラスの UA が、偶然すべて 50 % 前後になり、PA は偶然あまり近い精度にならず、ユークリッド最短距離分類結果の森林以外のクラスの PA が、偶然すべて 50 % 前後になり、UA の方はたまたまあまり近い精度にならなかつたにすぎない。

6. Landsat TM 画像及び ADEOS AVNIR 画像の模擬発生と分類・精度評価

MTF による分解能 30 m の疑似画像と、Landsat-5 TM 画像の分類精度の比較を行った。TM 画像は、分類精度の向上に関係しないと言われる分解能 120 m の band 6 を除く、band 1, 2, 3, 4, 5, 7 を用いた。TM 画像の band 1, 2, 3, 4, 5, 7 に対応するように、航空機 MSS 画像の band 4, 6, 8, 12, 15, 16 (**Fig. 1** 参照) を選択し、MTF によって分解能 30 m の疑似画像を生成した。この 2 つの画像を最尤法で分類した結果、TM 画像は、OA が 57.00 %, KC が 44.60 % であった。MTF による疑似画像の方は、OA が 57.82 %, KC が 44.38 % という値であった。OA, KC ともに差が 1 ポイント未満であり、MTF 補正を応用したアルゴリズムの妥当性が証明されている。

次に、ADEOS AVNIR のもつ band 1, 2, 3, 4 に近い波長帯として、航空機 MSS 画像の band 2, 6, 9, 12 (**Fig. 1** 参照) を選択し、MTF によって分解能 16 m の疑似 AVNIR 画像を生成した。この疑似画像も最尤法で分類したところ、OA で 60.25 %, KC で 46.09 % という値を示した。上述の Landat-5 TM 画像と比較すると、OA で 3 ポイント、KC で 2 ポイント精度が向上した。また、航空機 MSS 画像から生成した疑似 TM 画像と比較すると、OA で 2.4 ポイント、KC で 1.7 ポイント精度が向上した。航空機 MSS 画像から生成した疑似 AVNIR 画像の波長帯は、実際の AVNIR の持っている波長帯とは微妙に異なるが、単純に最尤法を用いた場合、OA で 60 % 程度、KC で 46 % 程度の精度を示すことが期待できる。

7. おわりに

本研究では、リモートセンシング画像の空間分解能が分類精度に及ぼす影響について検討した。4 種の空間分解能が異なるセンサーによって取得された画像の分類精度を比較したところ、空間分解能が向上して

も、必ずしも分類精度が向上しなかった。原因の1つは、位置誤差にあると考えられ、2つ目は設定した分類クラスの数が、 6.25 m という分解能の高さに合っていなかったことが挙げられる。

そこで次に、 6.25 m の分解能をもつ航空機MSS画像から低分解能化アルゴリズムによって生成した 10 m から 30 m の分解能をもつ低分解能化画像の分類精度を比較した。ある1つの画像を基にして分解能の異なる画像を生成するため、位置誤差と波長帯の違いの無い画像を比較することができる。任意に分解能を決定できるMTFを応用したアルゴリズムを用いたため、 2 m 刻みという細かく分解能が変化する際の分類精度の変化を検討できた。**Fig. 4, Fig. 5**において、総合精度(OA)及びkappa係数(KC)は完全な右下がりの変化は示さなかったが、 10 m より少し粗い分解能が最も精度が良く、分解能が粗くなるにしたがって分類精度は低下していく様子が確認できた。また、最も精度が良かった分解能 12 m の分類精度と分解能 30 m の画像と比較するとOA, KCで約6ポイント程度向上することが確認できた。

1996年8月に打上が予定されているADEOSのAVNIRは、マルチスペクトルモードで 16 m という分解能を持っている。6.での検討によれば、単純に最尤法を用いた場合、OAで60%程度、KCで46%程度の分類精度を期待できる。また、同一の条件でのTM画像の分類精度が、OAで57%強、KCで44%強であったことから、従来、高分解能のマルチスペクトルリモートセンシング画像としてよく用いられてきたLandsat TM画像に比べてADEOS AVNIR画像の分類精度は、OAで3ポイント、KCで2ポイント程度向上することが期待できる。

謝 辞

本文中でも記したように、本研究で用いたリモートセンシング画像は、1992年10月に実施された矢田川航空機実験(ADEOS/AVNIRの解像力、立体視機能等の評価および解析アルゴリズム開発のためのデータ取得実験)において得られたものであり、宇宙開発事業団及び(財)リモート・センシング技術センターの経済的・人的補助を受けて提供されたものである。ここに記して謝意を表する次第である。

参考文献

- 1) 竹内章司・富田強：衛星画像のスペクトル情報と空間情報を併用した市街地の分類、写真測量とリモートセンシング、Vol. 27, No. 2, 1988, pp. 6-15.
- 2) 張子珏・河西由美・福江潔也・下田陽久・坂田俊文：土地被覆分類におけるLANDSAT TMおよびSPOT HRVデータの特性評価、写真測量とリモートセンシング、Vol. 27, No. 3, 1988, pp. 4-15.
- 3) 宝 馨・立川康人・近藤昭彦・西尾邦彦・芝野博文・執印康裕・田中隆文・小池俊雄・北田勝紀・富井直弥：矢田川航空機実験および同期地上観測実験について、水文・水資源学会誌、Vol. 6, No. 1, 1993, pp. 71-75.
- 4) (財)リモートセンシング技術センター鳩山事業部：ADEOS/AVNIRの解像力、立体視機能等の評価および解析アルゴリズム開発のためのデータ取得実験観測成果報告書、1993.
- 5) (財)日本地図センター：数値地図ユーザーズガイド(改訂版)、1994, p.423.
- 6) 向井幸夫：衛星リモートセンシングデータの重ね合わせとその応用に関する研究、京都大学学位論文、1988.
- 7) 高木幹雄・下田陽久 監修：画像解析ハンドブック、東京大学出版会、1991.
- 8) Congalton, R. G. : A review of assessing the accuracy of classifications of remotely sensed data, *Remote Sensing of Environment*, Vol. 37, 1991, pp. 35-46.
- 9) 宇宙開発事業団 地球観測センター編：地球観測データ利用ハンドブック—ランドサット編・改訂版、リモートセンシング技術センター、1990, pp.6-11-6-12.

- 10) Press, W. H., B. P. Flannery, S. A. Teukolsky and W. T. Vetterling : *Numerical Recipes in C*, Cambridge University Press, 1988. (丹慶勝市・奥村晴彦・佐藤俊郎・小林誠訳：*Numerical Recipes in C* [日本語版], 技術評論社, 1993.)
- 11) Justice, C. O., B. L. Markham, J. R. G. Townshend and R. L. Kennard : Spatial degradation of satellite data, *International Journal of Remote Sensing*, Vol. 10, No. 9, 1989, pp. 1539-1561.