

# マルコフ確率場に基づく因果律を考慮した教師データに不整を有する衛星画像の分類

河邑眞<sup>1</sup>・辻子裕二<sup>2</sup>・深堀賢<sup>3</sup>

<sup>1</sup>正会員 工博 豊橋技術科学大学助教授 工学部建設工学科 (〒441-8122 愛知県豊橋市天伯町字雲雀ヶ丘1-1)

<sup>2</sup>正会員 工修 豊橋技術科学大学助手 工学部建設工学科 (〒441-8122 愛知県豊橋市天伯町字雲雀ヶ丘1-1)

<sup>3</sup>学生員 豊橋技術科学大学大学院 建設工学専攻 (〒441-8122 愛知県豊橋市天伯町字雲雀ヶ丘1-1)

教師データの作成時刻と人工衛星データの撮影時刻に差のある教師データを用いて土地被覆分類を行う手法を提示する。この時間間隔の影響の評価にあたっては、マルコフ確率場に基づく因果律を利用する。この因果律に基づき教師データの信頼性を考慮した分類を実行する。この方法論を平面的なスペクトル分布の特徴評価、さらに分類結果のポスト処理に利用する方法に拡張する。細密数値情報土地利用データの整っている愛知県名古屋市を対象として、LANDSAT TM データを用いた土地被覆分類を行い、土地台帳に基づく統計資料と比較する。結果として、時系列および平面的な因果律を用いることで、原データでの解析に比較して、指標値で約5倍の精度向上が認められた。また、ポスト処理を施すことにより、指標値で誤差を1%以下とする程度の精度の向上を達成した。

**Key Words :** classification, neural network, MRF, supervised data, remote sensing data

## 1. はじめに

人工衛星データの周期性、広域性および同時性等の利点を活かして、これより作成される主題図からその変化過程のモニタリングが行われる。衛星データで構成される特徴ベクトルの多変量解析から主題図を作成する方法として、レベルスライス等の単純なもの、尤度関数に多次元正規分布を仮定する最尤法、さらに、人工知能を用いた処理法が挙げられる。それぞれの手法には方法論に従った利点・欠点が含まれ<sup>1)</sup>、必要性に応じて処理方法を選択している。この中で、“理想的な環境”下で高精度分類を達成する手法の一つに、ニューラルネットワーク等の知的情報処理技術を用いた方法が挙げられる。ここで“理想的な環境”とは、任意の教師データにおけるクラス  $C_p$  での特徴ベクトル  $X_p$  およびクラス  $C_q$  での特徴ベクトル  $X_q$  がある範囲内で相互に重複しない場合、すなわち、

$$X_p \cap X_q = \emptyset \quad (1)$$

として定義できる。これを満足しない状態、すなわち、“理想的な環境”を与えない教師データを“不整を有した教師データ”として定義する。

教師データが不整を有する場合、教師信号の重みが全て同じであれば、ニューラルネットワークでは極端な収束解

が得られ、これに起因した誤分類の可能性が指摘されている<sup>2)</sup>。この誤分類は、統計的な出現率に基づいて教師データの中にも誤りが存在することを認める統計的手法の考え方に対して、ニューラルネットワークに与える教師データの質、すなわち重みが“同等”であることを前提とすることに起因する。

教師付き分類では、分類目的に応じたトゥルースデータや航空写真等の記録を用いて教師データを作成する必要がある。しかし、社会的な理由や地理的条件等によりこれらの入手が困難な場合も稀ではない。また、観測条件が整っていても、対象時刻全てに対して完全に一致する教師データを作成することは困難である。さらに、広域な対象の分類に対し、全域から教師データを作成することも困難な場合が多い。教師データの時間差やノイズ等による教師データの精度の劣化により、同一地域に対する処理結果を時系列で配列したときに、矛盾のある画素が出現することも少なくはない。これらの問題に対処するために、誤抽出データの潜在およびサンプリングデータの多次元正規性を認め、これに従わないものを洗練・淘汰させる、すなわち、多次元正規分布から極端に外れるデータを削除する方法が提案されている<sup>3), 4), 5)</sup>。この場合、平均値ベクトルが唯一として規定されるため、そのヒストグラムに多峰性のあるパターンに対して正解を与えることが困難となる。また、統計的な判断に基づき教師データを淘汰（削除）させるこ

とにより、必要な情報が消される可能性も指摘できる。以上の背景から、教師データの作成時刻と衛星データの撮影時刻に差のある場合に対して、土地被覆分類器に確率モデルを組み合わせることにより、個々の教師データに統計的推定上の重みを付与する方法を提案する。分類器としてニューラルネットワーク<sup>1), 6), 7), 8)</sup>を用い、時間間隔の評価を行う確率モデルとしてマルコフ確率場<sup>9), 10)</sup>を用いる。また、マルコフ確率場に基づく因果律の評価方法を平面的なスペクトル分布の特徴評価、さらにポスト処理に拡張する。

## 2. マルコフ確率場の与え方

画像座標 $(x, y)$ における $K$ バンドの衛星データが構成する特徴ベクトルを $X(x, y) = \{x_1(x, y), \dots, x_K(x, y)\}$ で表す。土地被覆クラス $C(x, y)$ が $L$ クラスの状態から構成されるとき、 $C(x, y)$ は $C \in \{C_1, \dots, C_L\}$ で表される。クラス $C$ の特徴ベクトル $X$ に対する確率密度（尤度）を $P(X|C)$ で表現するとき、分類問題は事後確率 $P(C|X)$ を最大にするクラスを求める問題に帰着する。ここで、Bayes の式により、特徴ベクトルと土地被覆クラスの関係を用いた事前確率が、

$$P(C|X) = \frac{P(X|C)P(C)}{P(X)} \quad (2)$$

で与えられるので、 $P(C|X)$ を最大にする尤度関数、

$$\zeta(X|C) = P(X|C)P(C) \quad (3)$$

より、分類問題は $P(X|C)$ を最大とするクラスを求める問題に書き換えられる。 $P(X|C)$ の決定に対して、教師データの多次元正規性が確認されない対象に対しても適用可能なニューラルネットワークを用いることの有用性は先に示した。ここで、 $P(X|C)$ は $N$ 個の教師データのクラス $C = \{C^s | 1 \leq s \leq N\}$ とその特徴ベクトル $X = \{X^s | 1 \leq s \leq N\}$ の対 $(C^s, X^s)$ の関係を用いて計算される。本研究では、 $C^s$ と $X^s$ を作成した時間のズレ（時間間隔）が $(C^s, X^s)$ の関係に与える影響を考え、マルコフ確率場の考え方で、その信頼度 $P(C^s|X^s)$ を求め、信頼度を考慮した教師データ対 $(P(C^s|X^s) \times C^s, X^s)$ を作成する方法について検討する。さらに、この考え方を特徴ベクトルの平面的な関係および分類結果のポスト処理に拡張する方法についても検討する。

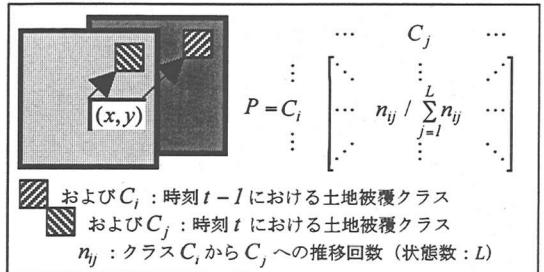


図-1 時系列での推移確率の推定方法

## 3. 時系列での因果律の算定

マルコフ過程は、「状態空間」と「パラメータ空間」を事前に決定することで、変化パターンの一意的なモデル化が可能となる。ここでは、「状態空間」として土地被覆クラス $C$ を、「パラメータ空間」として時間軸 $t$ をとる。いま、時刻 $t$ における土地被覆クラスを $C(t)$ とし、 $\bar{C}(t) = \{C(q) | q \leq t\}$ を定義する<sup>11)</sup>。ここで、Green と Titterington<sup>12)</sup>による仮定、

$$P(C(t) | \bar{C}(t-1)) = P(C(t) | C(t-1)) \quad (4)$$

を考える。ここに、式(4)はクラス設定に関する一次元定常マルコフ過程（図-1）における仮定と同値である。すなわち、この仮定を認める範囲内であれば土地被覆（利用）予測に関する確率過程モデルは、次式によって表現される<sup>13)</sup>。ただし、以下では表記が煩雑になることを避けるため、画像座標 $(x, y)$ を省略して記載する。

$$C(0) = \begin{bmatrix} c_1(0) \\ \vdots \\ c_L(0) \end{bmatrix} \quad (5)$$

$$P = \begin{bmatrix} p_{11} & \cdots & p_{1L} \\ \vdots & p_{ij} & \vdots \\ p_{L1} & \cdots & p_{LL} \end{bmatrix} \quad (6)$$

$$C(t) = \begin{bmatrix} c_1(t) \\ \vdots \\ c_L(t) \end{bmatrix} \quad (7)$$

$$C(t) = PC(t-1) = \cdots = P'C(0) \quad (8)$$

ここに、 $C(0)$ および $C(t)$ は、それぞれ基準時刻および時刻 $t$ におけるクラス、 $\{c_1(t), \dots, c_L(t)\}$ はクラスの状態を示すパラメータを表す。例えば、時刻 $t$ におけるクラスが明らかに $C_1$ のときは、 $\{c_1, c_2, \dots, c_L\} = \{1.0, 0.0, \dots, 0.0\}$ のように表すことができる。また、クラス $P$ は推移確率行列である。状態数、すなわち、ここでいうクラスの数を $L$ に設定するとき、 $P = \{p_{ij} | 1 \leq i \leq L, 1 \leq j \leq L\}$ は事前事象と事後事象との関係から構築される推移回数行列 $N = \{n_{ij} | 1 \leq i \leq L, 1 \leq j \leq L\}$ をその行和で除することにより与えられる。ただし、式(8)は推移パターンが時刻に依存しないという仮定を含む。時刻 $t$ における状態確率を教師データの信頼度、すなわち、解析時の重みとして考えるとき、①日本のような開発国では、開発可能域が限定されることによって推移確率行列の対角要素が他に比較して極めて大きくなり、状態確率の変動がほとんど期待できない、②変化のトレンドだけを表現するため、変化が生じる構造を内包することができない、③常識的に考え難い変化パターンの存在を認める、等の問題が生じる。これらの問題に対処するために、時刻変化を含めた手法を提案した例も存在する<sup>14)</sup>。本研究では、開発域と未開発域の大まかなカテゴリーを考え、都市が成長するときには、未開発域から開発域への変化が卓越する、すなわち、その可逆性を認めないと仮定し、次式を推移確率に加える。

$$\Delta P(t) = \begin{bmatrix} UU & UD \\ DU & DD \end{bmatrix} \quad (9)$$

ここに、 $UU$ は未開発域から未開発域、 $DD$ は開発域から開発域、 $UD$ は未開発域から開発域、 $DU$ は開発域から未開発域への変化率を示す。未開発域としては水域・森林・田畠等を、開発域としては宅地・商工業域を考えることができる。ここで、先述の理由により、 $DU$ および $DD$ は0であるとし、 $UU$ の減少分が $UD$ の増加分となるように推移確率を変動させる。ここで、 $UD$ の増加分を規定する関係は都市に依存した関係となるので、過去の推移をベースに成長経路を判断し、 $UU = -UD = \eta$ とするパラメータを考える。 $\eta$ は、都市の成長過程および残された開発可能領域の割合に依存するものとする。 $\eta$ を変動させ、 $UU = -UD = \eta$ とする仮定についての影響を事前解析によって調べた結果、 $\eta$ を2倍に設定した際の20ステップ（本論では20年）目での推移確率の変化は最大で10%程度であり、かつ、カテゴリー間での推移確率の大小関係には影響を与えないことがわかった。以上より、最終的には

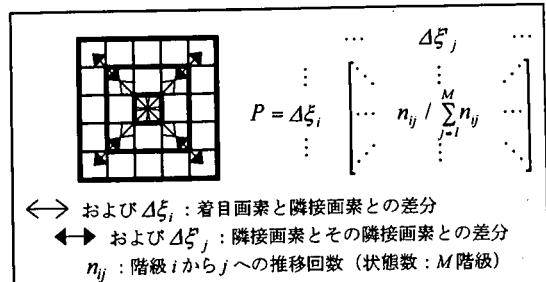


図-2 平面的な推移確率の推定方法

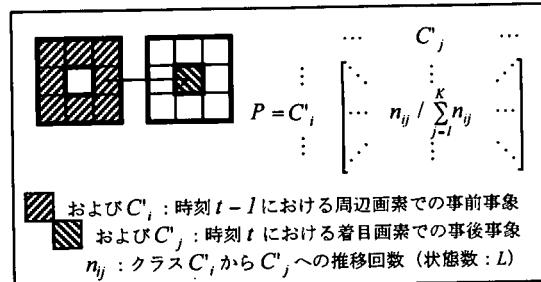


図-3 ポスト処理に用いる推移状態

$\Delta P(t)$ を含めた推移確率 $P'(t)$ を用いて、 $T$ ステップ時間間隔のある教師データ対に対して、

$$P(C^S | X^S) = \prod_{t=1}^T P'(t) \quad (10)$$

を与える。

#### 4. 平面的な因果律への拡張

時系列での因果律から、基準時刻からの時間差による教師データのクラスごとの重みを変化させることは可能となる。しかし、解析対象とする画像のどの地点が問題となるのかの判断が困難であることには変わりない。福江ら<sup>15)</sup>は周辺画素を含めた同時生起確率をインプットとするニューラルネットワークを構築し、高精度の判別結果を得ている。この研究は、ラスター走査で対象とする画素および周辺画素に対する出現率を取り扱うものである。ここでは、1次元のマルコフ過程を2次元に拡張し、周辺画素の着目画素（中心画素）に対する因果律を推移確率により定める。2次元の情報系列にマルコフ過程を適用するには、1次元の処理における時刻 $t$ と時刻 $t + \Delta t$ の関係をラスター走査によって与えられる順序と考え走査順にしたがった因果律を与える<sup>16)</sup>。そこで、図-2に示されるように、事前事象を着目画素と近隣画素（縦・横・斜めの計8方向。ただし、

図-2 では 4 方向のみ表示) との衛星データの差分  $\Delta\xi$ , 事後事象を近隣画素とさらにその同方向近隣画素 (8 方向) との衛星データの差分  $\Delta\xi'$  とし, それぞれの方向の  $\Delta\xi - \Delta\xi'$  の平方和をバンド数だけ加算した平方根, すなわち平方根平均自乗誤差 (RMSE) を計算し, 閾値を設定して離散化する. 閾値の幅を細かく設定すれば, 状態確率の変動が小さくなりノイズの存在を許し易くなる. 逆に閾値の幅を粗く設定すれば, 平滑化効果が強くなってしまう. 本研究では, 試行錯誤により状態確率の収束性を判断した上で閾値を設定している.

## 5. ポスト処理への拡張

上述のように教師データに重みを付与することで画素単位の解析が可能となる. 一般的に画素単位の解析結果に對しては多数決フィルタリングのようなポスト処理を行うことが望ましい. ここでは前章までの結果を利用して, マルコフ確率場に基づいたポスト処理手法を提案する. 時刻  $t$  における特徴ベクトル  $X(t)$  および土地被覆クラス  $C(t)$  に對して,  $\bar{X}(t) = \{X(q) | q \leq t\}$  および  $\bar{C}(t) = \{C(q) | q \leq t\}$  とおくと, 条件付き確率  $P(\bar{C}(t) | \bar{X}(t))$  は次式のように示される.

$$P(\bar{C}(t) | \bar{X}(t)) = \frac{P(\bar{C}(t) \cap \bar{X}(t))}{P(\bar{X}(t))} \quad (11)$$

上式は, 存在する衛星データを過去から順に加算していくことで計算できる. ここで, Green と Titterington によるノイズの時間的な依存性に関する仮定, すなわち,  $X(t)$  は  $X(t-1)$  に依存しないとする仮定は次式で表される.

$$P(X(t) | \bar{C}(t) \cap \bar{X}(t-1)) = P(X(t) | C(t)) \quad (12)$$

式(4)と式(12)より,

$$P(X(t) | \bar{C}(t)) = P(X(t) | C(t)) \quad (13)$$

$$P(\bar{X}(t) | \bar{C}(t)) = \prod_{r=1}^t P(X(r) | C(r)) \quad (14)$$

$$P(\bar{C}(t) \cap \bar{X}(t)) = P(\bar{X}(t) | \bar{C}(t)) \cdot P(\bar{C}(t)) \quad (15)$$

$$P(\bar{C}(t)) = \prod_{r=1}^t P(C(r) | \bar{C}(r-1)) \cdot P(C(0)) \quad (16)$$

表-1 解析に用いた TDT データとカテゴリー設定

TDT データ	$C$	TDT データ	$C$
1: 山林荒地等	2	9: 中高層住宅	-
2: 農地 (田)	3	10: 商業業務用地	5
3: 農地 (畑その他)	3	11: 道路用地	-
4: 造成中地	-	12: 公園緑地	-
5: 空地	-	13: 公共用地	-
6: 工業用地	5	14: 河川湖沼等	1
7: 一般低層住宅	4	15: その他	-
8: 密集低層住宅	4	16: 海	1

$C$ : 設定カテゴリー;

1:WATER, 2:FOREST, 3:PADDY, 4:RESIDENT, 5:IND&COM

となる. したがって,

$$P(C(t) \cap \bar{X}(t)) = \left( \prod_{r=1}^t P(X(r) | C(r)) P(C(r) | C(r-1)) \right) P(C(0)) \quad (17)$$

が導かれる. したがって, 対象とする時刻までの特徴ベクトル  $\bar{X}(t)$  と  $\bar{C}(t-1)$  を条件とする  $C(t)$  の生起確率は以下のように計算される.

$$\begin{aligned} & P(C(t) | \bar{C}(t-1) \cap \bar{X}(t)) \\ &= \frac{P(\bar{C}(t) \cap \bar{X}(t))}{P(\bar{C}(t-1) \cap \bar{X}(t))} \\ &= \lambda P(C(t) | C(t-1)) P(X(t) | C(t)) \end{aligned} \quad (18)$$

ここに,  $\lambda$  は比例定数である.  $P(C(t) | C(t-1))$  を図-3 に示されるように, 事前事象を時刻  $t-1$  での周辺画素のクラス, 事後事象を時刻  $t$  での着目画素のクラスとして求める. 教師データから得られる  $P(X(t) | C(t))$  から, 最終的に  $P(C(t) | \bar{C}(t-1) \cap \bar{X}(t))$  を得る.

$P(C(t) | \bar{C}(t-1) \cap \bar{X}(t))$  を用いて, 前章までの分類結果で得られた土地被覆変化が, 信頼できるか否かを以下のような基準で判断する.

- ① クラスごとに得られる  $P(C(t) | \bar{C}(t-1) \cap \bar{X}(t))$  を, 周辺画素 (8 方向) に対して計算し, その和  $P_{TOTAL}$  を計算する.
- ②  $P_{TOTAL}$  の最大値をもつクラス  $C$  について, その  $P_{TOTAL}$  が, 設定する閾値よりも大きい場合はその推移の生じる可能性があると判断し, 時刻  $t$  の解析結果が妥当であるとする.  $P_{TOTAL}$  の閾値は  $\lambda$  に依存する. つまり,

同じ条件を設定するときには、 $P_{TOTAL}$ は $\lambda$ に比例して設定する必要がある。

- ③  $P_{TOTAL}$ の最大値をもつクラスCについて、その $P_{TOTAL}$ が、設定する閾値以下である場合には、その推移パターンはあり得ないものであるとし、時刻 $t-1$ の解析結果を採用する。

## 6. ケーススタディー

### (1) 対象地域と使用データ

解析対象は、データの整備状況を考慮し名古屋市とした。対象地域には、約10mの解像度で、1982年、1987年および1993年に細密数値情報土地利用データ（それぞれ、TDT-111, TDT-112 および TDT-113、以下 TDT データで略記）が作成されている<sup>17)</sup>。この中から、衛星データとして用いる LANDSAT TM データ (path=109, row=36) の撮影時刻に合わせて、1987年を基準時刻とし、これらのデータ対より作成される情報を用いて、1991年および1995年のTMデータから土地被覆分類画像を作成する場合の精度評価を行った。ここに、教師データは TDT-112 を参照して土地被覆と土地利用の定義が共通する画素を各カテゴリーで 200 画素ずつ計 1000 画素抽出した。設定した土地被覆カテゴリーは、水域 (WATER)、森林等緑被域 (FOREST)、田畠 (PADDY)、住宅域 (RESIDENT)、商工業地域等高密度開発域 (IND&COM) とした。ここで、TDT データから推移確率算定に利用したカテゴリーの変換方法を表-1 に示す。

### (2) 解析に用いたニューラルネットワーク構造

解析に用いたニューラルネットワークは、バックプロパゲーション学習原理に基づく 3 層・完全層間結合<sup>2)</sup>のものである。これらの諸パラメータを表-2 に示す。これらのパラメータは、以下に示す基準時刻の CASE1 に対する試行錯誤の結果、最適と判断されたものである。同一条件で比較検討を行うために全ケースで同一パラメータを用いている。

### (3) テストケース

基準時刻（1987年）の教師データ対から、1991年および1993年の土地被覆分類を、以下に示す6ケースを設定して行った。

CASE1：基準時刻における教師データを全時刻の TM データに適用する（合計パターン：1000）。

表-2 解析に用いたニューラルネットワークの諸パラメータ

パラメータ	値	パラメータ	値
学習定数	0.5	入力層ユニット	6
安定化定数	0.8	中間層ユニット	20
収束閾値	-	出力層ユニット	5
最大学習回数	10000	学習パターン数	1000*

(\* ) テストケースに依存

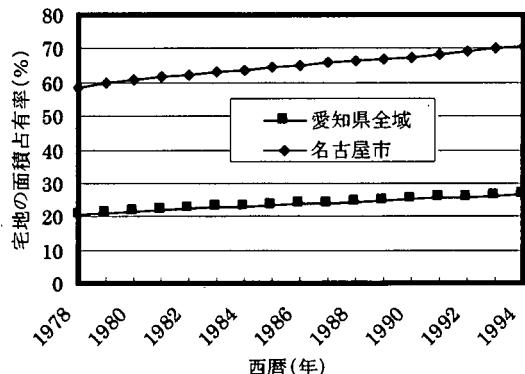


図-4 解析対象領域の宅地面積の変化  
(土地利用台帳より)

CASE2：基準時刻における教師データを TM データの ISODATA クラスタリングによりグループ分けを行い、同一グループと判断できない教師データを洗練・淘汰させ、全時刻の TM データに適用する（合計パターン：577）。

CASE3：各時刻における教師データを TM データの ISODATA クラスタリングによりグループ分けを行い、同一グループと判断できない教師データを洗練・淘汰させ、各時刻の TM データに適用する（合計パターン：577（1987年）、522（1991年）、618（1995年））。

CASE4：時系列での推移確率から、各時刻の教師データの重み（状態確率）を求め、各時刻の TM データに適用する（合計パターン：1000）。

CASE5：平面的な推移確率から、各画素の教師データの重み（状態確率）を求め、各時刻の TM データに適用する（合計パターン：1000）。

CASE6：CASE4 と CASE5 を併用する（合計パターン：1000）。

CASE2 は基準時刻の教師データについてクラスタリングの観点から分離度の低いデータを削除するものであり、CASE3 は基準時刻だけでなく各時刻で CASE2 と同様の観点から分離度の低いデータを削除するものである。以上 2 ケースの比較によって、クラスタリングで分離度が低いとされるデータは時刻を問わず分離度が低いかどうかの検

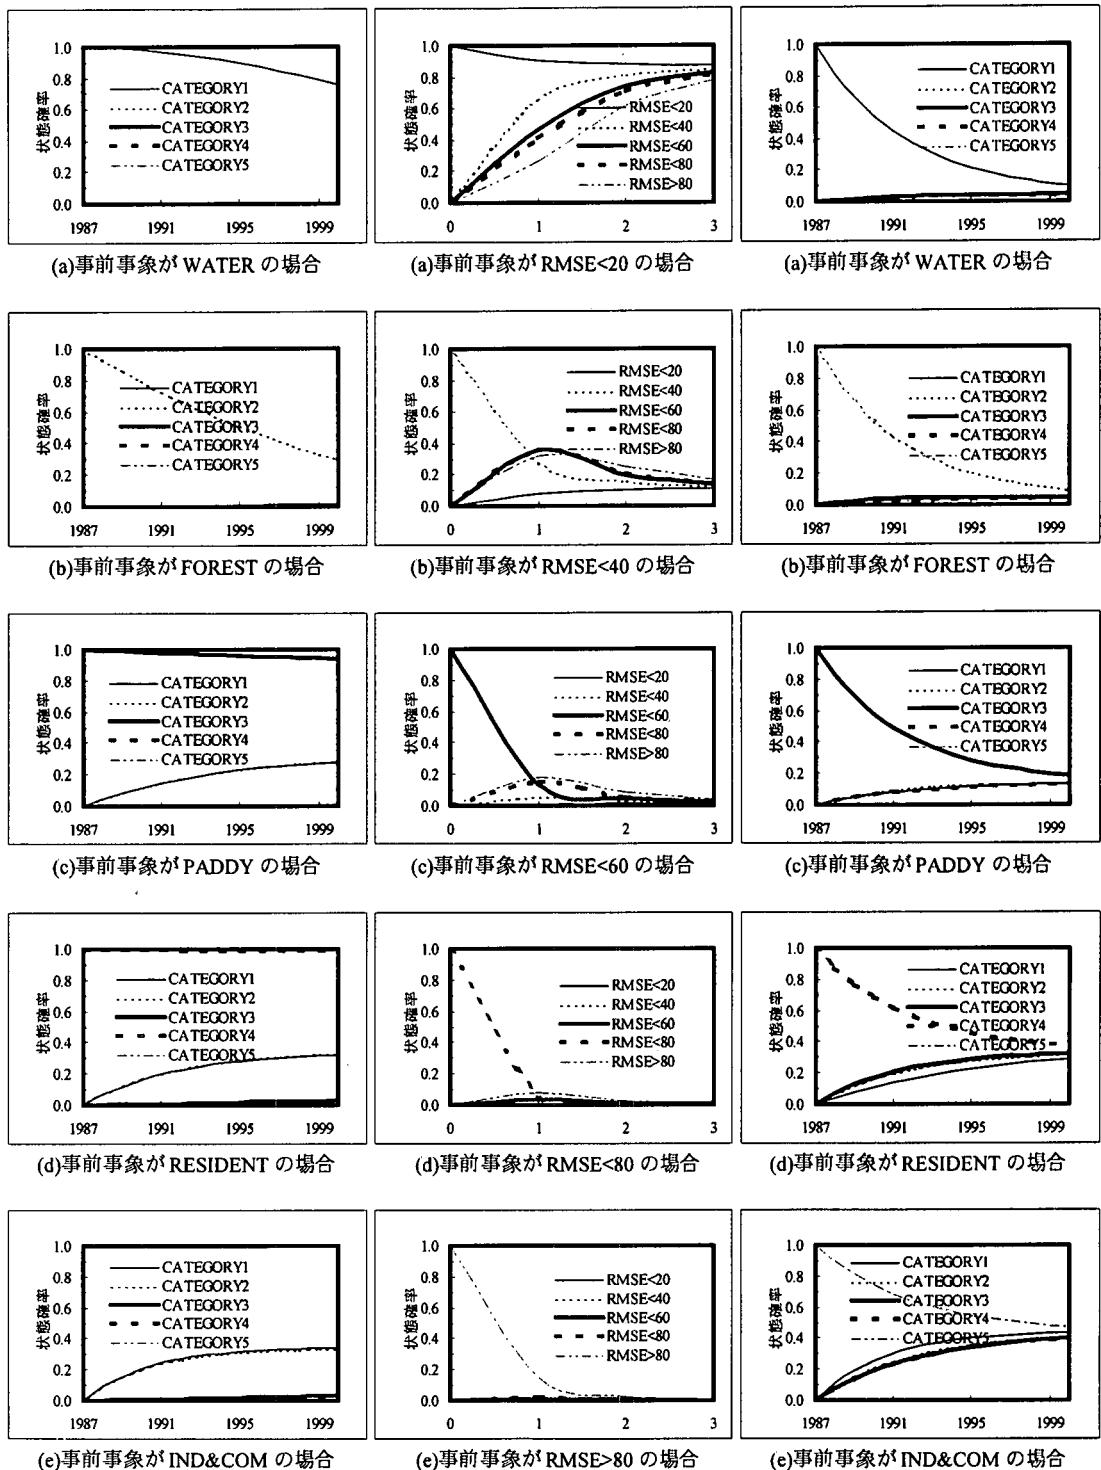


図-5 時系列での因果律に基づく  
状態確率  
(横軸は西暦(年))

図-6 平面的な因果律に基づく  
状態確率  
(横軸は中心画素からの画素数)

図-7 ポスト処理に用いる  
状態確率  
(横軸は西暦(年))

討が可能となる。CASE4, CASE5, CASE6 は本研究で取り扱うマルコフ確率場の考え方に基づき、教師データの重みを考える場合であり、どの因果律が有効であるかを検討できる。

#### (4) 推移確率行列の算定結果

図-4 は土地利用台帳に記載される、愛知県全域、名古屋市の開発域（地目：宅地）面積の全域面積に占める割合を示したものである。このような短い期間内では、都市の成長速度はほぼ線形と考えることができる。この関係をパラメータとし、 $\eta = -0.01$ とした場合、TDT-111 と TDT-112 との関係から得られる推移確率に基づく状態確率は図-5 のように示される。図-5 の横軸は、基準時刻（1987 年）からの時間をとっており、推移のステップは 1 年としている。ただし、TDT-111 と TDT-112 の間隔は 5 年であるため、この間の推移が定常的であるとして 1 年間隔のデータを推計している。図-5 に示されるように、事前事象が開発域（RESIDENT, IND&COM）である場合、事後事象も同事象である可能性が高く評価されている。水域、森林域および田畠は、埋め立てや開発に伴う開発域への変化を妥当に評価している。各状態確率の変動において水域（WATER）に変動がみられるのは、埋め立てによる推移パターンを推移確率の算定に含めたためである。

図-6 は、平面的な因果律を示す状態確率を示したものである。図-6 の横軸は、着目地点からの距離（画素数）をとっている。 $\Delta x$  および  $\Delta y$  の閾値は共に 20 ごとに設定している。推移確率の算定に用いた RMSE の事前事象が 20 未満の場合、事後事象が 20 以上であることは希であることがわかる。事前事象が 20 以上である場合は、すべての事後事象が生じる確率がほぼ等しいことがわかる。すなわち、事前事象が 20 未満程度であれば教師データの信頼度を高くとることができる。

図-7 は、ポスト処理に用いる状態確率、すなわち、基準時刻におけるクラスが任意時刻  $\Delta t$  後に任意の被覆クラスになる確率を示したものである。図-7 の横軸は、基準時刻（1987 年）からの時間をとっており、推移のステップは 1 年としている。この状態確率の変化はある年（基準年から 20 年程度）で収束する。すなわち、ポスト処理は収束する年までは事前事象を基準とした多数決フィルタの役割をもつと考えられる。

#### (5) 処理の安定性

図-8 は、宅地（RESIDENT）の面積の全域に対する占有

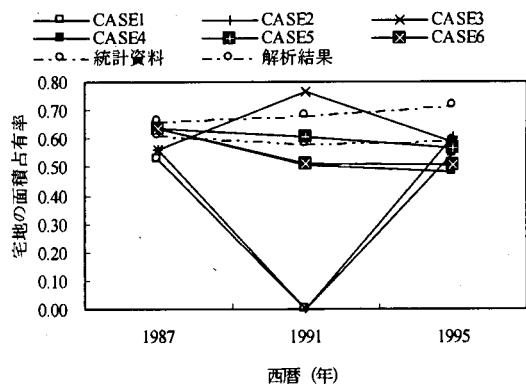


図-8 名古屋市の解析結果（RESIDENT）の時系列変化  
(ポスト処理前)  
統計資料は土地利用台帳を参照、名古屋市域のみを対象

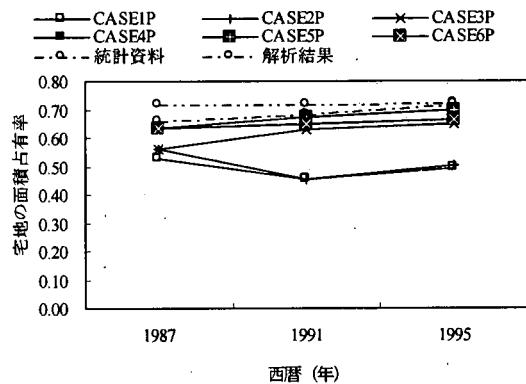


図-9 名古屋市の解析結果（RESIDENT）の時系列変化  
(ポスト処理後)  
統計資料は土地利用台帳を参照、名古屋市域のみを対象

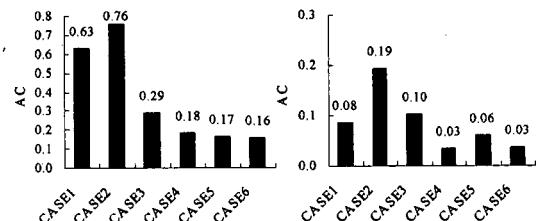


図-10 名古屋市の解析の精度 図-11 名古屋市の解析の精度  
(ポスト処理前) (ポスト処理後)

率の時系列変化を出力したものである。ここに、CASE2 の基準時刻における結果は、CASE3 と同値となる。また、CASE6 の基準時刻における結果は、CASE4 と同値となる。ただし、CASE4 の基準時刻における結果は、CASE5 の値を用いている。解析に用いた 1991 年の TM データは、平

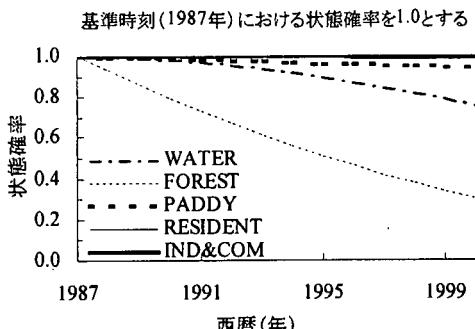


図-12 名古屋市域の状態確率（再掲）  
(基準時刻で着目カテゴリーであるとき)

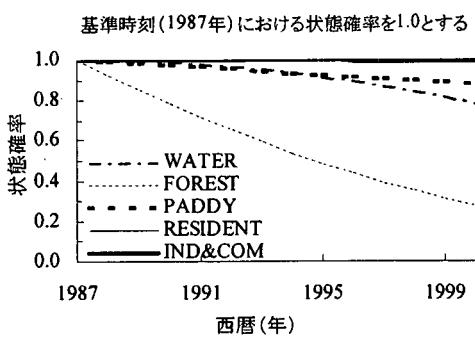


図-13 フルシーンでの状態確率  
(基準時刻で着目カテゴリーであるとき)

均値および分散が他と明らかに異なるものであった。これらの結果より、基準時刻（1987年）のデータを信頼する CASE1 および CASE2, CASE3 において、時系列での評価に極端な面積占有率の増減が認められる。具体的には、1991年を挟んで CASE1 と CASE2 で約 50%, CASE3 で約 25%も占有率が変動している。

このような面積占有率の増減が少ないことを安定性があるとして表現すると、提示手法、とくに CASE5 は、多少の変曲点は存在するものの、処理に対する安定性が確認できる。CASE1, 2, 3 で安定性がなく、教師データに重みを与えた場合に安定性が認められるということは、特徴空間を分割する超平面の形状が、画像間で異なることを意味している。教師データの信頼度を与えることで特徴空間の分離性が向上するのである。

図-8において○の一点鎖線で示される変化は、図-4で示した土地利用台帳の値をプロットしたものである。同様に、○の二点鎖線で示される変化は、図-4で示した土地利用台帳の値と比較するために、CASE6 に関する宅地面積の水域（WATER）を除いた全面積に対する占有率をプロ

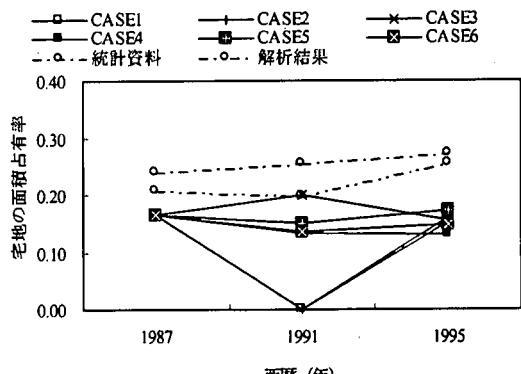


図-14 フルシーンでの解析結果 (RESIDENT) の時系列変化  
(ポスト処理前)  
統計資料は土地利用台帳を参照、愛知県全域を対象

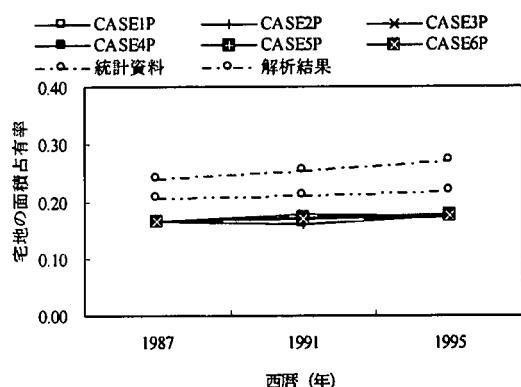


図-15 フルシーンでの解析結果 (RESIDENT) の時系列変化  
(ポスト処理後)  
統計資料は土地利用台帳を参照、愛知県全域を対象

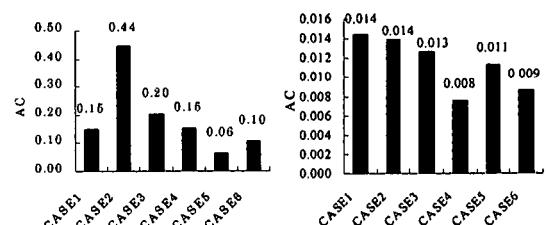
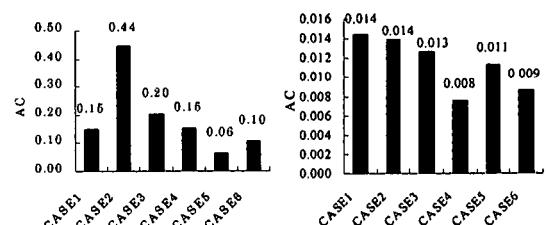


図-16 フルシーンでの解析精度  
(ポスト処理前)



リテッドしたものである。CASE6 より計算される宅地面積の占有率は土地利用台帳と同様の傾向を示している。

図-4 で示される宅地面積の拡大速度がほぼ線形であることより、1987年から1991年および1991年から1995年

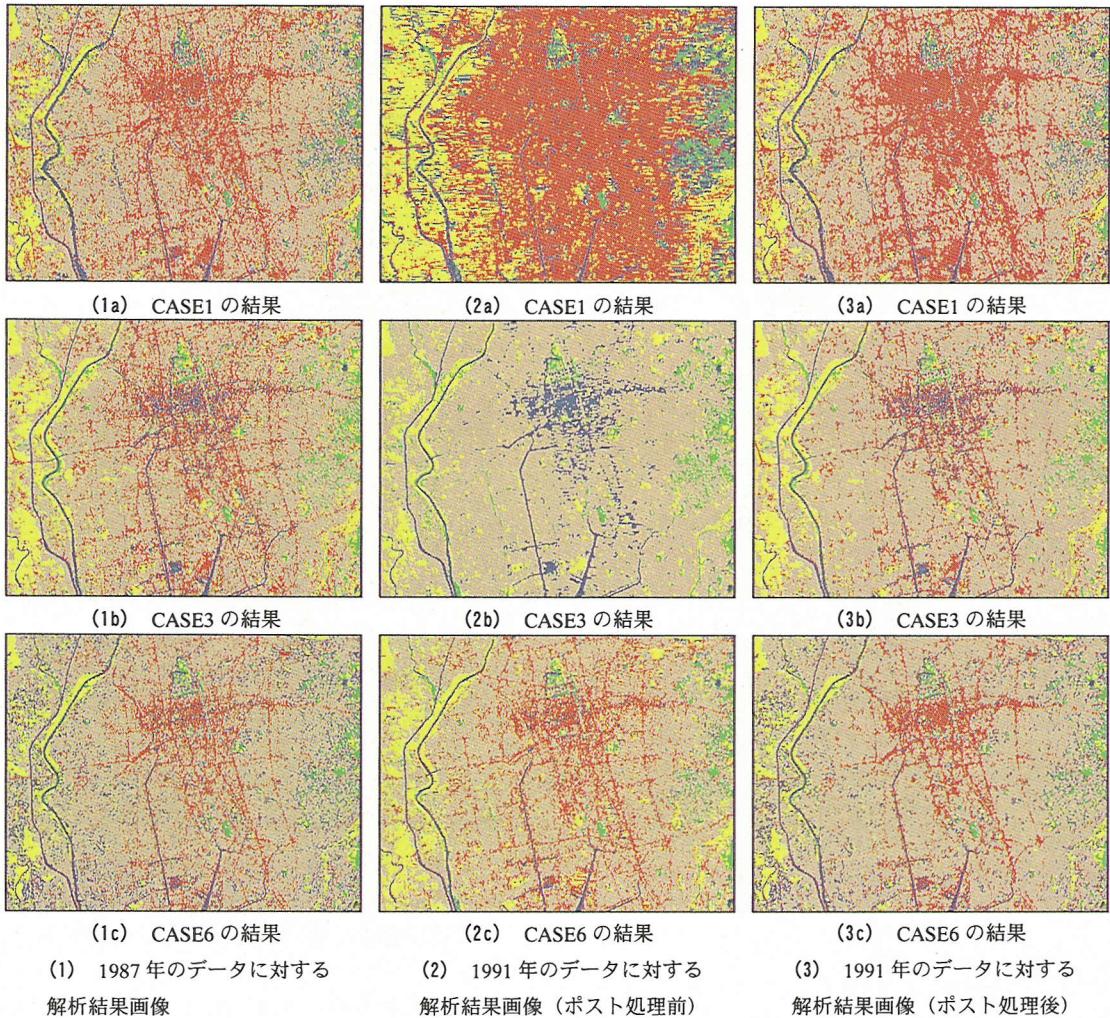


図-18 解析結果の比較－名古屋市を対象地域とした場合－

（青：WATER, 緑：FOREST, 黄：PADDY, 灰：RESIDENTIAL, 赤：IND&COM, 黒：その他）

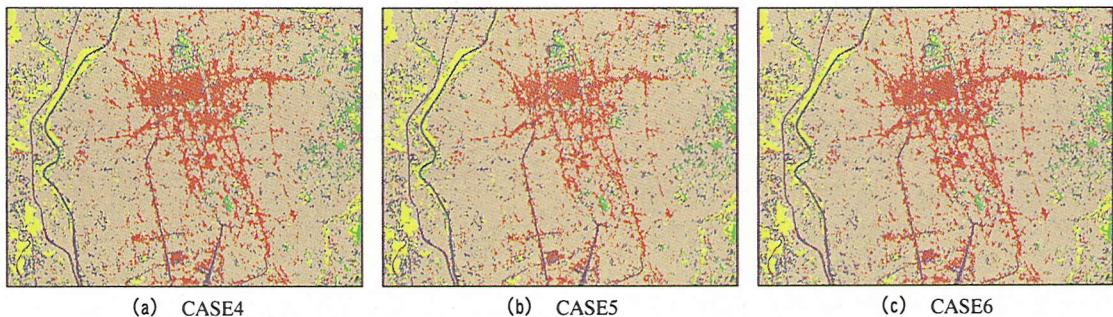


図-19 1995 年のデータの解析結果（ポスト処理済み）の比較－名古屋市を対象地域とした場合－

（青：WATER, 緑：FOREST, 黄：PADDY, 灰：RESIDENTIAL, 赤：IND&COM, 黒：その他）

の各カテゴリーの占有面積の変化率が一定であるとして次式のように解析精度評価の指標値  $AC$  を求めた。

$$AC = \sum_{k=1}^L |\Delta OR_{k,k+1} - \Delta OR_{k-1,k}| \quad (19)$$

ここに、 $\Delta OR_{k,k+1}$  は、時刻  $k$  と時刻  $k+1$  間の宅地面積占有率の差分、 $L$  はカテゴリー総数である。この結果を図-10 に示す。 $AC$  の値は、時系列での因果律を考える CASE4 で 0.18、平面的な因果律を考える CASE5 で 0.17、さらに両者を併用する CASE6 で 0.16 となっており、CASE1, 2 の約 4.5 倍、CASE3 の約 2 倍の精度向上が達成されている。

#### (6) ポスト処理の効果

図-9 は、図-8 と同じ方法で、ポスト処理を施した結果 (CASE 番号に P を付す) を出力したものである。ただし、ポスト処理に用いるパラメータスは 1.0 とし、 $P_{total}$  の閾値は周辺 8 画素の合計で 4.0 とした。すなわち、各画素の平均の出現率が 0.5 以下の場合は、その変化があり得ないものとして判断した。対象地域では、埋め立てによって水域が、宅地等への開発によって植生域および田畠が減少する傾向にある。因果律を考える CASE4, CASE5, CASE6 はこれらを適切に表現している。また、両時刻間の差分もほぼ一定であるため、図-10 と同じ方法で出力した  $AC$  は図-11 に示されるように極めて 0 に近くなっている。

#### (7) 適用性

本手法の適用性を議論するとき、①状態確率 (推移確率) の普遍性と②未知入力パターンに対する汎用性 (汎化能力) の二点が指摘できる。

まず、状態確率の普遍性を検討する。解析対象とした名古屋市の宅地域の拡大は、図-4 に示されるように線形に近いものであり、基準時刻を時間軸の原点にとれば、愛知県全域のデータに対して切片が約 40% 大きく現れる。これによって、一見状態確率の変動が異なるように判断される。図-12 および図-13 は、それぞれ名古屋市および愛知県に対して状態確率の変動を見たものである。両図より、対象領域が異なっていても、 $\Delta P$  の導入により、既開発域の全域に対する割合は状態確率の変動に影響を与えにくいことがわかる。紙面では割愛したが、 $\Delta P$  を用いない場合は、この状態確率に大きな変動が見られる。上述の 6 ケースの比較により状態確率を教師データの重みとすることで相対的に良好な結果が得られることから判断して、この場合については  $\Delta P$  を用いることで対象領域の大小に関わらず

妥当な状態確率が得られると判断される。

つぎに、未知学習パターンに対する汎化能力についての検討を行う。これに当たって、先述の解析に用いたデータを同時刻 (1991 年および 1995 年) の愛知県全域を含むフルシーンを解析した。図-8 から図-11 と同様の方法で、フルシーンを解析した結果を図-14 から図-17 に示す。

以上より、精度の判断材料となる指標  $AC$  の値が小さいこと、統計資料と解析結果の傾きが近似することから判断して、汎化能力が確保できているものと考える。とくに、ポスト処理の効果が大きいことが特筆すべき点である。

## 7. まとめ

マルコフ確率場に基づく推移確率を考え、教師データの信頼度を与えることにより良好な分類結果を得る方法を提示することができた。また、TM データのフルシーンに適用することによって、状態確率の普遍性および汎化能力について吟味した。この結果、原データでの解析に比較して、指標値で約 5 倍の精度向上が認められた。また、ポスト処理を施すことにより、指標値で誤差を 1% 以下とする精度の向上を達成した。本研究で処理した画像の一部を、図-18 および図-19 に示す。図-18(2a) および(2b) に示される結果から判断できるように 1991 年のデータは、他時刻のデータに比べて状態が悪い。しかし、本研究で提示した方法 (図-18(2c)) は、このような状態の悪いデータに対しても安定した結果を出力することを、図から読み取ることができる。

本研究で示した方法は、基準時刻における衛星データと実際の状態を示す地図があれば時間差やノイズの影響をある程度低減できるものである。逆から考えれば、基準時刻におけるデータ対が整うことが必要条件となる。

また、今回解析したシーンのようにセンサーの劣化等に起因するノイズによる影響などは、上述の範囲で十分に対応できることができた。

なお、ポスト処理の効果が大きかった結果から、マルコフ確率場のみから判断する方法についても検討の余地があると思われる。

## 参考文献

- 1) Benediktsson, J. A., Swain, P.H. and Ersoy, O. K. : Neural network approaches versus statistical methods in classification of multisource remote sensing data, *IEEE Trans. Geosci. Remote Sensing*, Vol.GRS-28, No.4, pp.540-552, July 1990.

- 2) 河邑眞, 辻子裕二 : 多段ニューラルネットワークによる人工衛星画像の土地被覆分類, 写真測量とリモートセンシング, Vol.34, No.1, pp.71-80, 1995.
- 3) 小島尚人, 大林成行 : 画像分類におけるトレーニングサンプル再抽出方法の一提案, 日本リモートセンシング学会誌, Vol.14, No.1, pp.50-65, 1994.
- 4) 小島尚人, 大林成行 : トレーニングクラスの設定方法に関する一提案, 日本リモートセンシング学会誌, Vol.15, No.4, pp.50-65, 1994.
- 5) 小野徹, 岡本恵二 : 土地利用図からのトレーニングデータ抽出法とその検証, 日本写真測量学会平成8年度秋季学術講演会発表論文集, pp.87-92, 1996.
- 6) Heermann, H. D. and Khazenie, N. : Classification of multispectral remote sensing data using back-propagation neural network, *IEEE Trans. Geosci. Remote Sensing*, Vol.GRS-30, No.1, pp.81-88, January 1992.
- 7) 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法, 写真測量とリモートセンシング, Vol.35, No.3, pp.5-17, 1996.
- 8) Kawamura, M. and Tsujiko, Y. : Multispectral classification of Landsat TM data using a cooperative learning neural network, in *Proc. IGARSS'93*, Vol.2, pp.508-510.
- 9) Geman, S. and Geman, D. : Stochastic relaxation, Gibbs distribution, and their applications to radar images, *IEEE Trans. Pattern Anal. Machine Intell.*, Vol.PAMI-6, pp.721-741, 1984.
- 10) Joen, B. and Landgrebe, D. : Classification with spatio-temporal interpixel class dependency contexts, *IEEE Trans. Geosci. and Remote Sensing*, Vol.GRS-30, pp.663-672, 1992.
- 11) Solberg, A. H. S., Taxt, T. and Jain, A. K. : A Markov random field model for classification of multisource satellite imagery, *IEEE Trans. Geosci. and Remote Sensing*, Vol.GRS-34, No.1, pp.100-113, 1996.
- 12) Green, P. J. and Titterington, D. M. : Recursive methods in image processing, in *Proc. of 46th Session Int. Statistical Institute*, pp.1-17, 1983.
- 13) 天野光三 : 計量都市計画, 丸善出版, 1982.
- 14) Swain, P. H. : Bayesian classification in a time-varying environment, *IEEE Trans. Syst. Man. Cybern.*, Vol.SMC-8, pp.879-883, 1978.
- 15) ドニーカスハルドノ・福江潔也・下田陽久・坂田俊文 : 同時生起確率行列に基づく空間的土被覆分類におけるニューラルネットワークの利用, 写真測量とリモートセンシング, Vol.34, No.4, pp.22-35, 1995.
- 16) Woods, W. : Two-dimensional discrete Markovian fields, *IEEE Trans. Information Theory*, Vol.IT-18, No.2, pp.232-240, 1972.
- 17) 建設省国土地理院 : 細密数値情報(中部圏宅地利用動向調査)説明書, (財)日本地図センター, 1989.

(1997. 7. 30 受付)

## CLASSIFICATION OF REMOTE SENSING DATA HAVING INCOMPLETE SUPERVISED DATA USING A CAUSALITY BASED ON MARKOV RANDOM FIELD

Makoto KAWAMURA, Yuji TSUJKO and Masaru FUKABORI

A method for classification of remotely sensed data having incomplete supervised data is proposed. To consider the time difference between supervised data and remote sensing data, the causalities based on Markov Random Field are utilized. By including the temporal class dependencies, the reliable classification is undertaken. It expands to a method evaluating the spatial class dependencies between neighboring pixels and the post processing. The performance of the method for land cover classification is investigated using LANDSAT TM covering Aichi Prefecture, Japan, and compared with statistical data. The results show well coincidence with verification data. When post processing is carried out, the accuracy improves to RMSE of about 1%.