自己組織化マップ (SOM) による液状化領域の抽出

Extraction of Area Liquefied by Earthquake Using Self-Organizing Map

細川 直史*・伊藤 陽介**・星 仰***

Masafumi HOSOKAWA, Yosuke ITO and Takashi HOSHI

Abstract : A supervised classification method using a self-organizing map (SOM) is proposed to classify remote sensing data. SOM has a characteristic that a probability density function of input data is represented as a feature map. The proposed method is realized by creating a category map from the feature map of SOM. The category map can visualize characteristics of SPOT HRV data and it is also employed as a supervised classification method. The proposed method extracts liquefied area in Kobe (Japan) damaged by the 1995 Hyogoken Nanbu earthquake using the SPOT HRV data and the category map. As an experimental result, it is shown that classification accuracies of the proposed method are higher than those of the maximum likelihood and the back-propagation methods.

1. はじめに

地滑り災害の予測や森林火災の分布の特定など、リモートセンシングデータ (Remote Sensing Data : RS データ) を防災分野へ応用する試みが報告されている¹⁾²⁾。特に、1995年兵庫県南部地震によって発生した火災、家屋倒壊、地盤の液状化などの震災を、人工衛

星や航空機に搭載された光学センサーや合成開口レーダによって観測された RS データを利用して、特定することが試みられている³⁾⁴⁾。液状化現象は、図1に示すように、地下水を多く含んだ砂層 (砂質地盤) において、地震動により地下水の水圧が上昇し、砂の粒子間の結合と摩擦力が低下し、砂層が液体状になって流動することにより発生する。液状化現象は噴水、噴砂、噴泥を伴い、地盤の不同沈下、陥没により建物の転倒、傾斜、沈下、または地下埋設物の破損を引き起こす⁵⁾。兵庫県南部地震では神戸市のポートアイランドをはじめ海岸沿いの埋め立て地に多くの液状化現象による噴砂や噴水が見られた⁶⁾⁷⁾。

RS データによる液状化現象領域の特定は、地表に堆積した噴水、噴砂、噴泥の領域にもとづいて、地下で発生した現象を推定することで可能である。しかし

図1 液状化のメカニズム

* 消防庁 消防研究所 地震防災研究室 (現茨城大学工学部)

Earthquake Disaster Section, National Research Institute of Fire and Disaster

〒181-8633 東京都三鷹市中原3-14-1

3-14-1 Nakahara, Mitaka, Tokyo 181-8633 Japan

** 高松工業高等専門学校 建設環境工学科

Department of Civil Engineering, Takamatsu National College of Technology

〒761-8058 香川県高松市勅使町355

355 Chokushi-cho, Takamatsu 761-8058 Japan

*** 茨城大学 工学部 情報工学科

Department of Computer and Information Sciences, Faculty of Engineering, Ibaraki University

〒316-8511 茨城県日立市中成沢町4-12-1

4-12-1 Nakanarusawa-cho, Hitachi, Ibaraki 316-8511 Japan

「写真測量とリモートセンシング」VOL. 38, NO. 6, 1999

ながら、埋め立てに使われた土砂表面と地表面に堆積した噴出土砂の分光特性は類似していることが考えられ、液状化領域を特定するためには、RS データの分光特性を用い、これらの識別が可能な高精度の土地被覆分類法が必要とされている。

RS データの土地被覆分類法として、最尤法に代表される統計的な理論に基づいたパラメトリックな手法が従来から用いられていた⁸⁾⁹⁾¹⁰⁾。しかし、分類すべきカテゴリの確率分布が正規分布と異なる場合、分類精度が著しく低下する場合がある。一方、カテゴリの確率分布を仮定する必要のないノンパラメトリックな手法としてニューラルネットワーク (Neural Network : NN) がある。NN は神経細胞であるニューロンをモデル化した計算方法により、高いパターン認識能力を利用した土地被覆分類法が提案されている¹¹⁾。しかし、階層型 NN をバックプロパゲーション法 (Back Propagation Method : BP 法) で学習する方法は、その学習アルゴリズムが最急降下法に基づいているため、学習回数の多さやローカルミニマムに陥るといった問題がある¹²⁾¹³⁾。

一方、Kohonen は、競合学習¹⁴⁾¹⁵⁾に基づく NN である自己組織化マップ (Self-Organizing Map : SOM)¹⁶⁾を提案した。SOM の学習アルゴリズムは特徴抽出など多くの問題に応用され、とくに音声認識の分野では音素マップを含む多くの類似性図形の作成を可能にしている¹⁶⁾¹⁷⁾。BP 法は、教師付き学習であり、その学習方法は、統計的な回帰分析における最小二乗法に基づいている。一方、SOM の学習アルゴリズムは、クラスタ分析のようなデータ間の類似性に基づく教師なし分類法として用いられている。

本論文では、SOM を RS データの教師あり分類法として適用する手法を提案し¹⁸⁾¹⁹⁾、1995年兵庫県南部地震の際に発生したポートアイランドにおける液状化地域の抽出を試みる。RS データは SPOT 衛星の XS データとし、トレーニングデータによって学習した SOM の荷重ベクトルから、トレーニングデータの特徴を 2 次元平面に写像するカテゴリマップを作成し、土地被覆分類に適用する。提案手法に必要な検討項目として、カテゴリマップの大きさ、近傍関数、学習係数を考え、テストデータの分類精度に基づいて検証を行う。また、従来手法である最尤法及び BP 法との比較を行い、提案手法の有効性を示す。

2. 解析対象データ

本論文の解析に用いる RS データは1995年 1 月20日に SPOT 衛星によって観測された XS データの 3 バンドである。解析エリアは図 2 に示すポートアイランドを中心とする256ピクセル×256ピクセルである。1995年 1 月17日発生した兵庫県南部地震によって、この地域をはじめ神戸市海岸沿いの埋め立て地に多くの液状化現象による噴砂や噴水が見られた⁶⁾⁷⁾。図 3 における黒色の領域は、解析エリア中の液状化発生地域を示している。液状化の発生地域はポートアイランドの北側半分に集中しており、南側半分は震災発生当時埋め立て工事がほぼ完成間際で、そのほとんどが裸地であった⁶⁾⁷⁾。図 4 は液状化による噴砂部分と埋め立て地の裸地部分のデータ (それぞれ240ピクセル) のヒストグラムである。3 バンドすべてにおいて両者の分布に重なりが認められ、液状化による噴砂部分を教師データとした場合、埋め立て地の裸地部分が誤分類されることが予測される。しかし、XS1 の分布の違いなど各分布のピークに差異があることから、両者の分類が可能であると考えられる。

図 2 解析対象地域のリモートセンシングデータ
観測衛星 SPOT 2 号
センサ HRV (多重スペクトルモード)
観測日 1995年 1 月20日
パス-ロウ 322-280
大きさ 256ピクセル×256ピクセル

図3 液状化地域 (図中黒色の領域, 航空写真判読による)

図4 液状化地域 (ω_1) と裸地 (ω_2) のヒストグラム

本論文では液状化地域 (ω_1), 裸地 (ω_2), 人工構造物 (ω_3), 海水域 (ω_4), 緑地 (ω_5) の5種のカテゴリに対して分類を行う。液状化地域と裸地の分類精度に着目し, 両者の分離を試みる。5種のカテゴリに対してそれぞれ30ピクセル, 計150ピクセルのトレーニングデータを用いる。分類精度を検証するためのテスト

データは解析データと同日に撮影された航空写真²⁰⁾に基づいて抽出した液状化地域240ピクセル, 裸地308ピクセル, 人工構造物973ピクセル, 海水域1,060ピクセル, 緑地1,024ピクセルの計3,605ピクセルを用いる。

3. SOM による分類手法

SOM は高次元ベクトルデータを1次元あるいは2次元空間に写像することが可能である。すなわち, 入力ベクトルの空間分布が写像された低次元のマップでの広がりに対応していることから, SOM を用いて, 多次元データの可視化や特徴抽出などへの応用が試みられている¹⁶⁾。SOM は入力ベクトルの特徴空間で近い位置に存在するものは, 特徴マップ上の近いノードに写像され, 近傍を構成するという特徴を持つ。このような近傍の特徴は荷重ベクトルに代表されることから, 特徴マップ上の隣接するノード間の荷重ベクトルの差異を表現するマップを求めることで, SOM をクラスタリングに応用することが可能である²¹⁾。本来, SOM はクラスや所属するカテゴリが不明なデータから, 生成される近傍に基づいてデータの類似性を可視化するという, いわゆる教師なし分類の手法として利用されてきた。本論文では, ノード間の荷重ベクトルの差異に着目し, SOM をRSデータにおける教師つき分類に応用した手法について提案する。

3.1 SOM について¹⁶⁾

図5は M 次元ベクトルデータを2次元空間へ写像する SOM を構成する NN である。この NN は, 入力層と出力層の2層からなり, 出力層にはノードが $N \times$

図5 SOM のネットワーク構造

N 個の正方格子に配置されている。ここで N は正方格子の一辺のノード数を示す。入力層のノードは出力層の全てのノードに結合されている。入力データは $X = (x_1, x_2, \dots, x_M)^T$ で表される M 次元ベクトルであり、 $W_{i,j} = (w_{i,j}^1, w_{i,j}^2, \dots, w_{i,j}^M)^T$ は入力層のノードから出力層のノード (i, j) の結合荷重ベクトルである。Kohonen の SOM の学習アルゴリズムでは、 W_{ij} の初期値としてランダム値を与える。入力データ X は入力層の対応するそれぞれのノードに入力され、出力層のノードにつながっている結合荷重ベクトルのノルムで競合する。ノルムを最小にする結合荷重ベクトルを持つ出力層のノードを勝利ノードとし、ユークリッド距離を用いて勝利ノード (i^*, j^*) を求める場合、次式で定義される。

$$(i^*, j^*) = \arg \left\{ \min_{i,j} \sqrt{\sum_{k=1}^M (x_k - w_{i,j}^k)^2} \right\} \quad (1)$$

勝利ノードとその周辺のノードの荷重ベクトルの更新は、次式に基づいて行われる。

$$w_{i,j}^k = \begin{cases} w_{i,j}^k + \alpha(t)[x_k - w_{i,j}^k] & \text{if } (i, j) \in (i^*, j^*) + R(t) \\ w_{i,j}^k & \text{if } (i, j) \notin (i^*, j^*) + R(t) \end{cases} \quad (2)$$

ここで、 $\alpha(t) > 0$ は学習係数であり、予め定義された単調減少関数であり、 $R(t)$ は勝利ノードの周辺のノードを定義する近傍関数である。 t はトレーニングデータの繰り返し提示回数（以下学習回数と呼ぶ）である。

SOM の学習ではトレーニングデータ数以上のデータ提示を必要とし、近傍関数の領域を狭めながら繰り返しデータの提示を行うことによって、入力データの特徴を表現する局所的な近傍を出力層上に自己組織化する。

3.2 提案アルゴリズム

まず、SOM の学習を行う場合に必要な近傍関数と学習係数が SOM 上における自己組織化にどのように影響するかを検証するため、それぞれ 2 種類の関数を適用する。結合荷重ベクトルの更新量をを定める学習係数を規定する関数は、以下の式 (3) または式 (4) を用いる。

$$\alpha_1(t) = 0.9 \left(1 - \frac{t}{t_{\max}} \right) \quad (3)$$

$$\alpha_2(t) = \frac{0.9}{1 + t/9} \quad (4)$$

ここで、 $t_{\max}$ は総学習回数である。この 2 つの関数は図 6 に示すような、 t の単調減少関数である、また、勝利

図 6 学習回数にともなう学習係数の変化 ($t_{\max}=100$)

図 7 学習回数にともなう近傍関数の変化 ($t_{\max}=100$, $c_1=16$, $c_2=100$)

ノードの周辺の範囲を定義するための近傍関数 $R(t)$ は、式 (5) または式 (6) を用いる。

$$R_1(t) = \left\{ (i^* + i, j^* + j) \mid |i|, |j| \leq \left\lfloor c_1 \left(1 - \frac{t}{t_{\max}} \right) \right\rfloor \right\} \quad (5)$$

$$R_2(t) = \left\{ (i^* + i, j^* + j) \mid |i|, |j| \leq \left\lfloor c_1 \exp\left(-\frac{t^2}{c_2}\right) + 1 \right\rfloor \right\} \quad (6)$$

ここで、 $\lfloor \cdot \rfloor$ はガウスの記号を示し、 c_1 と c_2 は正の整数である。この 2 つの近傍関数は図 7 に示すように $R_1(t)$ は学習回数 t に伴って階段状に単調減少する関数であり、 $R_2(t)$ は t に伴って指数的に減少する関数である。

提案手法の手順は図 8 に示すように、近傍関数と学習係数の決定し、次にトレーニングデータをもとに特徴マップ、クラスタマップ、カテゴリマップを作成する。そして、テストデータによる分類精度の検証を行う。良好な結果が得られれば全体画像の分類を行う。まず、トレーニングデータと予め定義した $\alpha(t)$ と $R(t)$ を用いて SOM の学習を行う。学習した SOM の

図8 SOMによるRSデータの分類手順

$W_{i,j}$ は M 次元であることから、式(7)を用いて2次元の関数を作成する²¹⁾。

$$d(i, j) = \frac{1}{|D|} \sum_{(\mu, \nu) \in D} (W_{i,j} - W_{i+\mu, j+\nu})^T (W_{i,j} - W_{i+\mu, j+\nu}) \quad (7)$$

ここで、 $D = \{(-1, -1), (-1, 0), (-1, +1), (0, -1), (0, +1), (+1, -1), (+1, 0), (+1, +1)\}$, $|D|=8$ とする。図9は、2章で定義したSPOTのXSデータによるトレーニングデータをSOMに入力し自己組織化の後、作成した $d(i, j)$ の値をグレースケールの画像として示したものであり、特徴マップと呼ばれる。3次元空間でデータの密度が高い部分が写像されるノード付近では $d(i, j)$ は0に近い値で暗い色になり、密度が低い部分では大きな値を持ち明るい色になる。従って、図9の明るい部分はデータ空間上における分布の境界を表すことになる²¹⁾。つぎに $d(i, j)$ をクラスタリングし、クラスタマップ $r(i, j)$ を作成する。作成アルゴリズムは次のとおりである。

【クラスタマップ作成アルゴリズム】²¹⁾

[Step 1] 全てのノードを $d(i, j)$ の小さい順にソーティングする。

順番を表す変数 q を番号としてノードに割り振る ($q=1, 2, \dots, sN^2$)。

[Step 2] ラベル番号 L をゼロで初期化し ($L=0$)、全ての $r(i, j)$ に初期値ゼロを与える (All $r(i, j) \leftarrow L$)。

[Step 3] for $q=1, \dots, sN^2$
 $(i, j) \leftarrow q$ が割り振られたノードのインデックス
 $(\hat{i}, \hat{j}) = \arg\{ \min_{(\mu, \nu) \in D} d(i+\mu, j+\nu) \}$.
 if $d(i, j) < d(\hat{i}, \hat{j})$
   then $L \leftarrow L+1, r(i, j) \leftarrow L$
   else $r(i, j) \leftarrow r(\hat{i}, \hat{j})$.
}

ここで、特徴マップの誤差を少なくするために、[Step 3] の処理を総ノード数 (N^2) の80% ($s=0.8$) の $d(i, j)$ に対して行う。図10はクラスタマップ作成アルゴリズムに基づいて、図9に示す特徴マップのクラスタリングを行った結果を示している。ここでは、84個のクラスが抽出されたクラスタマップが生成されている。ゼロの部分にはラベル番号が割り当てられておらず、このノードはこれより先のカテゴリ分類には用いられない。

図9 $d(i, j)$ のグレースケール画像：特徴マップ (学習係数: $\alpha_1(t)$, 近傍関係: $R_2(t)$, $N=32$, $t_{max}=100$, $c_1=16$, $c_2=100$)

図10 クラスタマップ $r(i, j)$ (ゼロの部分のノードにはラベル番号が割り当てられていないことを示す)

次に、クラスタマップをトレーニングデータのカテゴリに対応づけを行いカテゴリマップを作成する。このアルゴリズムを以下に示す。

【カテゴリマップ作成アルゴリズム】

[Step 1] $S(p, q)$ ($p=1 \sim$ カテゴリ数, $q=1 \sim$ 抽出されたクラス数) をゼロで初期化する (All $S(p, q) \leftarrow 0$)。

[Step 2] すべてのトレーニングデータに対して次の処理を行う。トレーニングデータを SOM へ再入力し、ラベルが割り当てられているノードのうちで、勝利ノード (i^*, j^*) を決定する。

$p \leftarrow$ 入力したトレーニングデータのカテゴリ番号

$q \leftarrow r(i^*, j^*)$

$S(p, q) \leftarrow S(p, q) + 1$

[Step 3] クラス q において、 $S(p, q)$ を最大とするカテゴリをクラス q の属するカテゴリとする。

図10に示すクラスタマップをカテゴリマップに変換したものを図11に示す。格子内の1から5の数字は本稿で設定した ω_1 から ω_5 のカテゴリに対応する。灰色の部分はカテゴリの割り当てが行われていないノードにあたるもので、隣接ノードとの結合荷重ベクトルと

- 1 液化化地域(ω_1)
- 2 裸地(ω_2)
- 3 人工構造物(ω_3)
- 4 海水域(ω_4)
- 5 緑地(ω_5)

図11 カテゴリマップ (数字がゼロのノードにはカテゴリが割り当てられていないことを示す)

の差が顕著な部分でカテゴリ間の類似性の境界を示している。未知のカテゴリのベクトルデータが SOM に入力された場合、勝利ノードに対応するカテゴリマップ上のカテゴリが分類結果となる。

図11のカテゴリマップには、海水域 (ω_4)、緑地 (ω_5) に対応する部分は明確な境界に囲まれた閉領域として存在している。一方、人工構造物 (ω_3) は大きな領域と小さく分散した領域からなる。すなわち、 ω_4 と ω_5 は他のカテゴリと明らかに異なる分光特性を持ち、 ω_3 は少し異なる分光特性を持つ複数のサブカテゴリから構成されていることを示していると考えられる。しかし、液化化地域 (ω_1) と裸地 (ω_2) に対応する部分は全体としてかたまりではあるが、複雑に入り組んだ領域である。この状態は、両者のカテゴリが類似した分光特性を有し、3次元空間内で混在していることを示すもので、図4のヒストグラムにおける解析と一致する。図4にヒストグラム表示された液化化地域のデータを SOM に再入力し、図11に示すカテゴリマップの領域1と領域2のノードが勝利ノードとなったデータのヒストグラムを図12に示す。領域2のヒストグラムは CCT 値が大きい方へ偏り、裸地のヒストグラムとの重

図12 領域1と領域2のノードが勝利のノードとなった液化化地域のデータのヒストグラム

なった部分に相当することがわかる。カテゴリマップ上において領域2は、裸地の領域に囲まれ、領域2のノードの結合荷重ベクトルが裸地と類似性を有しながら液化化領域を識別するように学習が行われたと考えられる。以上のように、カテゴリマップは3次元であったトレーニングデータを2次元平面上に写像し、可視化することでカテゴリの特性を解析することが可能である。

3.3 解析結果

図13は出力層の正方格子の一辺のノード数 N と分類精度 (ω_1 , ω_2 , ω_1 と ω_2 の平均) の関係を示している。 N が30以下の場合には ω_1 , ω_2 の分類精度は大きく変化しているが、 N が30を越えると変化量が少なくなる。従って、この研究のカテゴリ数、トレーニングデータ、テストデータにおいては、 N が30以上の値であれば、SOM をカテゴリ分類に使用した場合に安定した分類

図13 ノード数と分類精度の関係 (学習係数: $\alpha_1(t)$, 近傍関数: $R_2(t)$, $t_{max}=100$, $c_1=16$, $c_2=100$)

結果が得られることを示している。以後、 $N=32$ として解析をする。

図14に式(3)から式(6)の学習係数と近傍関数を用いた場合の学習回数 t に伴う分類精度の変化を示す。近傍関数として $R_1(t)$ を用いた場合分類精度が大きく変化しているが、 $R_2(t)$ を用いた場合、 t が20回以内で ω_1 と ω_2 の分類精度の平均値がほぼ80%に達し、その後も安定している。このことは近傍学習によりマップの2次元平面上を全域的に探索することにより、学習の早い時期にカテゴリの分布が特徴マップ上で形成されることによると考えられる。一方、 $R_1(t)$ を用いた場合、学習終了間際にカテゴリの分布が確定している。すなわち、学習の比較的初期に近傍数を小さくしても、土地被覆分類が可能なカテゴリマップを作成できることを示しており、勝利ノードのまわりの結合荷重ベクトルの更新を行う SOM の学習回数を軽減することが可能であることを示している。

分類精度の比較のために、最尤法、BP法、SOMの3手法による各カテゴリのテストデータとトレーニングデータにおける分類精度、及び、その平均値を表1に示す。ここで、BP法のNNは入力層、隠れ層、出力層の3層からなり、各層のニューロン数はそれぞれ3-10-5とする。比較条件を揃えるために、全ての手法に対して同じトレーニングデータとテストデータを用いている。トレーニングデータにおけるSOMの分類精度は裸地の分類において93.33%であったが、他は全て100%であった。最尤法とBP法の結果は、裸地と液化化地域の分類精度が90%もしくは96.67%となり、SOMの結果と比較して誤識別が多かった。テスト

(1) 学習係数: $\alpha_1(t)$, 近傍関数: $R_1(t)$

(2) 学習係数: $\alpha_2(t)$, 近傍関数: $R_1(t)$

(3) 学習係数: $\alpha_1(t)$, 近傍関数: $R_2(t)$

(4) 学習係数: $\alpha_2(t)$, 近傍関数: $R_2(t)$

図14 学習回数と分類精度係 ($N=32$, $t_{max}=100$, $c_1=16$, $c_2=100$)

表 1 分類精度の比較

(上段はテストデータ, 下段はトレーニングデータの分類精度)

カテゴリ \ 分類手法	SOM	BP 法	最尤法
液化化地域 (ω_1)	86.25	81.25	77.08
	100.00	96.67	90.00
裸地 (ω_2)	79.55	81.17	84.78
	93.33	90.00	90.00
人工構造物 (ω_3)	91.47	92.50	93.22
	100.00	100.00	100.00
海水域 (ω_4)	100.00	100.00	99.34
	100.00	100.00	100.00
緑地 (ω_5)	100.00	100.00	100.00
	100.00	100.00	100.00
5 カテゴリの平均	91.45	90.98	90.88
	98.67	97.33	96.00

(%)

データにおける5種のカテゴリの平均分類精度は、SOMによる結果が91.45%で、最尤法による結果の90.88%より約0.57%上回り、BP法による結果の90.98%より約0.47%上回った。液化化地域(ω_1)と裸地(ω_2)の分類においては両者のカテゴリの分類精度の平均はSOMによる結果が82.9%で、最尤法による結果の80.93%より約2%, BP法による結果の81.21%より約1.7%だけSOMによる分類精度が上回った。SOMによる分類精度の結果が従来手法より向上した理由として、最尤法では一つのカテゴリに対して一つの確率分布が仮定されるのに対して、SOMは出力層の1024個のノード上に、84個のクラスが競合学習より抽出され、その組み合わせでカテゴリが形成されることが考えられる。すなわち、異なる確率分布をもつ複数のクラスからなる多峰性の分布をしているカテゴリ进行分类する場合に、SOMを適用することによって高い分類精度を期待できる。BP法では最急勾配法の原理に基づいて学習するためローカルミナマ

ムに陥る可能性があり、最適解であることを検証することが難しい。一方、SOM ではデータ間の類似性に基づく競合学習によるためローカルミニマムの問題はなく、データの確率分布を考慮したクラスを構成することができるため、本論文の応用例の場合、高い分類精度を得ることができたと考えられる。最後に、最尤法、BP 法、SOM を用いて解析対象地域から液状化の地域を抽出した結果を図15、図16、図17にそれぞれ示す。ポートアイランド北部においては、図 3 の航空写真による液状化現象の判読結果と比較して、3つの手

図17 SOM による抽出結果(学習係数： $\alpha_1(t)$ ，近傍関数： $R_2(t)$ ， $N=32$ ， $t_{max}=100$ ， $c_1=16$ ， $c_2=100$)

法全ての結果に重なりを見ることができる。写真判読の結果に比べて形状が異なる領域が存在するが、これは、航空写真判読が人工物の存在する地下の現象を噴砂から推定し液状化に含めたということが原因として考えられる。ポートアイランド南部においては、いずれの結果も裸地を液状化として抽出した部分が見られる。しかし、最尤法の結果は誤抽出領域が比較的均一になっているのに対して、SOM による結果は細かい領域に分かれ、誤識別のピクセル数が少ない。このことは、提案手法が80個以上のサブカテゴリとも呼べるクラスの組み合わせによって分類が行われるため、抽出結果が小領域として表現され、より優れた抽出結果が得られたものと考えられる。

4. おわりに

本論文では、SOM を用いて RS データの教師あり分類を行う手法について提案した。特徴マップからクラスマップおよびカテゴリマップを作成するアルゴリズムを示し、カテゴリマップの大きさ、近傍関数、学習係数を検討項目として、テストデータの分類精度を基にこれらの検証を行った。そして、従来手法である最尤法及び BP 法と分類精度の比較を行った。その結果、カテゴリマップは RS データの特徴を可視化することに有効であること、また、SOM による分類手法は従来手法と比較して幾分高い分類精度を有することが

図15 最尤法による抽出結果

図16 BP 法による抽出結果

示された。

今後、液状化領域の抽出の高精度化を実現するために、SPOT 以外の受動式センサーや能動式センサーのデータに対して、本論文における土地被覆分類手法の適用を考えていく必要もあろう。

謝 辞

自己組織化マップの利用に際して、大阪府立大学の大松繁教授には多大なご指導を頂きました。ここに記して深く感謝の意を表します。

(受付日1999.8.30, 受理日1999.11.12)

参考文献

- 1) 宮澤, 古澤, “地すべり地の空中写真測量データの重みを考慮した3次元地下すべり面形状の推定”, 写真測量とリモートセンシング, Vol. 37, No. 6, pp. 14-27, 1998.
- 2) 永野, 山本, 岡田, 本多, 梶原, クリストファー D., “DMSP と GMS を用いた大規模森林火災モニタリング手法の検討”, 写真測量とリモートセンシング, Vol. 37, No. 3, pp.32-41, 1998.
- 3) 地球環境観測委員会, 宇宙開発事業団, リモートセンシング技術センター, 兵庫県南部地震災害調査報告, 1995.
- 4) 松岡, 稲永, 藤本, 翠川, “LANDSAT TM データによる1995年兵庫県南部地震被害分布の抽出”, 第10回日本地震工学シンポジウム, pp.3361-3366, 1998.
- 5) 消防科学総合センター, 地域防災データ総覧地震災害・火山災害編, 1998.
- 6) 応用地質株式会社, 応用地質技術年報兵庫県南部地震特集号, 1997.
- 7) パシフィックコンサルタンツ株式会社, 阪神大震災(兵庫県南部地震)被害調査報告書, 1995.
- 8) 高木, 下田, 画像解析ハンドブック, 東京大学出版会, 1990.
- 9) 土屋, リモートセンシング概論, 朝倉書店, 1990.
- 10) 日本リモートセンシング研究会編, 画像の処理と解析, 共立出版, 1991.
- 11) 吉田, 大松, 寺西, “ニューラルネットワークを用いたリモートセンシングデータのパターン認識”, システム制御情報学会論文集, Vol. 4, No. 1, pp.11-20, 1991.
- 12) 桂井, ニューラルネットワークアーキテクチャ入門, 森北出版, 1992.
- 13) 坂和, 田中, ニューロコンピューティング入門, 森北出版, 1997.
- 14) 伊藤, 大松, “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.
- 15) Y. Ito and S. Omatu, “Category classification method using a self organizing neural network”, Int. J. Remote Sensing Vol. 18, No. 4, pp.829-845, 1997.
- 16) T. Kohonen, Self-Organizing Maps, Springer-Verlag, New York, 1995.
- 17) T. Kohonen, Self-Organization and Associative Memory, Springer-Verlag, New York, 1989.
- 18) 細川, 伊藤, 大松, “自己組織化マップ(SOM)によるリモートセンシングデータの分類”, 日本写真測量学会平成10年度秋季学術講演会発表論文集, pp. 331-334, 1998.
- 19) M. Hosokawa, Y. Ito and T. Hoshi, “A remote sensing data classification method using self-organizing map”, 1999 IEEE International Geoscience and Remote Sensing Symposium (IGARSS'99) Proceedings: Vol. III, pp.1606-1608, Germany (Hambrug), July 1999.
- 20) 朝日航洋株式会社, 被災地 CD-ROM 航空写真, 1995.
- 21) 田中, 古河, 谷野, “自己組織化マップを利用したクラスタリング”, 電子情報通信学会論文誌, Vol. J79-D-II, pp.301-304, 1996.