

自己組織化マップによる多偏波 SAR データからの市街地特性の抽出

細川 直史^{† a)}

伊藤 陽介^{††}

星 仰^{†††}

Extraction of Urban Characteristics using Polarimetric SAR Data and Self-Organizing Map

Masafumi HOSOKAWA^{† a)}, Yosuke ITO^{††}, and Takashi HOSHI^{†††}

あらまし 都市防火で重要とされる、単位面積当たりの建物数、延焼阻止要因となるオープンスペース及び植生の3要因を多偏波 SAR データから抽出することを目的とし、散乱クラスを考慮した Kohonen の自己組織化マップ (SOM) とカウンタプロパゲーション学習を用いた教師付き土地被覆分類手法を提案する。本手法は、SOM の競合層に対応するカテゴリーマップを散乱クラスごとに作成し、多偏波 SAR データの各偏波の組合せのパワー成分を SOM に入力し分類処理を行う。航空機搭載型 SAR である PI-SAR を用いて観測された SAR データを 3 要因に分類する実験を行い、本手法の有効性を従来手法と比較して示す。

キーワード 合成開口レーダ、自己組織化マップ、土地被覆分類、都市防火

1. まえがき

1995年兵庫県南部地震において神戸市長田区を中心とした地域に大規模な市街地火災が発生したことにより、これまで叫ばれてきた都市防火の重要性が改めて認識された[1]。都市防火のためには、常に正確な市街地特性を把握し被害想定を行い、その結果を都市計画や消防計画に反映させていくことが必要である[2], [3]。火災の出火・延焼に関する主な要因として、図1に示すような、(1)建物の数やそれらの間隔(隣棟間隔)、(2)延焼遮断帯となるオープンスペースの存在、(3)植生の存在などがあげられる。これらの要因は開発等によって常に変化することから、都市防災上最新の市街地特性を保持することが重要とされている[4]。

一方、合成開口レーダ (SAR : Synthetic Aperture Radar) は、マイクロ波による能動型センサを用いて気象条件に影響されにくい観測が可能であることから、地盤変動や災害監視等防災分野への応用が期待されている[5]。特に、多偏波 SAR では、電界の振動方向が垂直方

向と水平方向に偏った 2 種類の電波(偏波)を送信及び受信する機能をもっていることから、垂直偏波と水平偏波を組み合わせ同時観測することにより、対象物の散乱行列を得ることが可能である[6] ~ [9]。郵政省通信総合研究所と宇宙開発事業団で開発している PI-SAR は、X バンドと L バンドの多偏波 SAR データを地上解像度 1.5 ~ 3 m で観測可能な航空機 SAR[10]であり、これによって、人工衛星 SAR 画像などと比較してより詳細な地上パターンの判読が期待できる。

多偏波 SAR データに適用する土地被覆分類として、Van Zyl が CV990 SAR データの散乱クラスによる教師なし分類手法を提案している[11]。しかし、散乱行列から得られる Stokes ベクトルの特定要素の大小関係に基づいて散乱クラスを決定していることから、要素の状態によっては正しく分類できない場合がある。そこで伊藤らは、SIR-C (Shuttle Imaging Rader-C) データにおいて散乱状態のシミュレーションを行うことで散乱クラスを決定している[12]。ここでは、散乱クラスごとに学習ベクトル量子化 (LVQ : Learning Vector Quantization), 最尤法 (ML : Maximum Likelihood

† 独立行政法人 消防研究所 防災研究グループ、三鷹市
Earthquake Disaster Section, National Research Institute of Fire and Disaster, 3-14-1 Nakahara, Mitaka-shi, 181-8633 Japan

†† 鳴門教育大学 学校教育学部 生活・健康系教育講座、鳴門市
Naruto University of Education, Health and Living Sciences Education, Takashima, Naruto-shi, 772-8502 Japan

††† 茨城大学 工学部 情報工学科、日立市
Department of Computer and Information Sciences, Ibaraki University, 4-12-1 Naka-narusawa, Hitachi-shi, 316-8511 Japan

a) E-mail: hosokawa@fri.go.jp

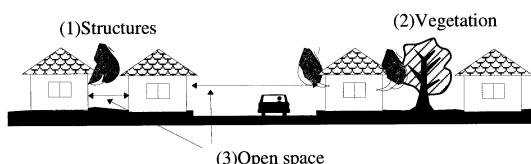


図1 火災の延焼拡大に関係する主な要因

Fig. 1 Main factors of fire spread.

Method), バックプロパゲーション法(BP法: Back Propagation Method)の分類精度について比較が行われているが, 散乱クラスによる事前分類が分類項目全体の分類精度に与える影響について述べられていない。また, ここで用いられているLVQは, BP法と同様に分類項目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分類手法であり, 競合学習に基づく教師付き分類手法であるLVQの分類精度が他の手法に比較して高いことを示す報告がされているが[12], 学習後のニューラルネットワークにおける荷重ベクトルの相互関係や, トレーニングデータの空間分布などの特徴が不明確であり, 特徴空間内での分類項目境界の解析が困難であるという問題がある。

自己組織化マップ(SOM: Self-Organizing Map)は, LVQと同様に競合学習に基づくノンパラメトリックな手法であるが, 入力された多次元データの空間分布を特徴マップと呼ばれる2次元空間へ写像可能である[13]。特徴マップは, トレーニングデータにおける各分類项目的空間分布が写像されることによって作成されるもので, 従来のノンパラメトリック手法とは異なり, 分類项目的特徴を容易に可視化可能である。そのため, 学習後のニューラルネットワークが分類に適応しているかどうかを視覚的に判別することが可能である。Kohonenによると基本的なSOMは教師なし分類として扱われており, 教師付き分類としてはLVQが取り上げられている[13]。SOMを教師付き分類方法として適用する場合, 特徴マップの各ノードがどの分類項目に対応するかをラベル付けする必要がある。SOMの競合学習後, トレーニングデータを再入力し各ノードに対応する分類項目をラベル付けする従来方式では[14], 競合層のノード数に比較して, 多数のトレーニングデータを用意する必要がある。しかも, ラベル付けされるノードが偏ることも多く発生し, ラベル付けされないノードを含んだカテゴリーマップが構成され, 分類項目間の境界部分が明確にならないという問題がある。他方, Nielsenはカウンタプロパゲーション(Counter Propagation)学習によるルックアップテーブルの作成について述べている[15]。ここでは, 競合層のノード数がBP法などのそれと比較して非常に多くなることから, 計算量の多さにより実用の面では否定的な見方をしている[15]。

本論文は, 都市防火上重要とされる, 建物, オープンスペース, 植生の3要因をPI-SARデータから抽出することを目的とする。そのため, 教師なし分類手法で

あるSOMにカウンタプロパゲーションを適用し, カテゴリーマップと呼ばれる2次元のルックアップテーブルを作成することによる教師付き分類手法を提案する[16]~[19]。本論文では, 文献[12]で示されている手法に基づいて, PI-SARデータを三つの散乱クラスに事前分類し, 散乱クラスごとに提案手法を適用する。提案手法の有効性は, 分類精度をLVQ, BP法及び最ゆう法の従来手法の結果と比較することによって示される。更に, 各分類手法ごとに事前分類を適用する場合と, そうでない場合の2通りの実験を行い, 両者の結果を比較することによって, 散乱クラスによる事前分類が各分類项目的分類精度への与える影響を評価し, 事前分類の有効性を検証する。

2. 解析データ

茨城県つくば市地域を1997年9月30日に観測したPI-SARデータのXバンドデータ(表1)を対象として解析を行う[10]。多偏波SARは, 垂直偏波と水平偏波の組合せを変えて観測することにより, 式(1)で示すような対象物の散乱行列 S を得る[6]。

$$S = \begin{bmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{bmatrix} \quad (1)$$

ここで, S_{ab} , $a, b \in \{h, v\}$ は, 送信偏波 b と受信偏波 a 間の複素散乱係数を, h, v はそれぞれ, 偏波の水平成分, 垂直成分示す。電磁波の表現は偏波に着目する場合には, 従来から Stokesベクトル

$$G = \begin{bmatrix} S_0 \\ S_0 \cos(2\psi) \cos(2\chi) \\ S_0 \sin(2\psi) \cos(2\chi) \\ S_0 \sin(2\chi) \end{bmatrix} \quad (2)$$

が用いられてきた。電磁波の偏波は, 一般に図2に示すような偏波楕円で表現される[7]。偏波楕円は, 電界ベクトルの先端が描く軌跡であり, その形は二つの角

表1 PI-SARデータの特徴
Table 1 PI-SAR data characteristics.

Sensor	CRL-X-SAR
Date	1997.9.30
Scene start time	3:11:19
Scene end time	3:11:40
Frequency	9.55468913GHz
Range resolution	1.5 m/3m
Azimuth resolution	1.5 m (4-look Processing)
Polarimetry	HH/HV/VV/VH
Digital image dimensions	4000pixels × 3000lines

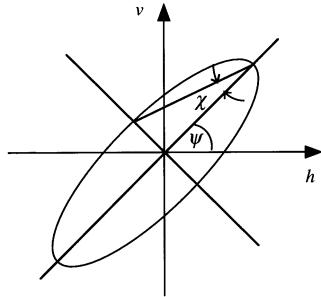


図2 偏波 楕円
Fig. 2 Polarization ellipse.

度\$\psi\$と\$\chi\$で規定される。ここで、\$\psi\$は楕円の長軸の水平方向からの傾き角を、\$\chi\$は楕円の丸み度合を表す。入射波と散乱波のStokesベクトルを\$G^{ill}, G^{sc}\$とするとき、

$$G^{sc} = MG^{ill} \quad (3)$$

となる。ここで、\$M\$はMueller行列である。Mueller行列は、式(4)で定義され、その要素\$R, W\$は式(5), (6)で書き表すことができる。

$$M = RWR^{-1} \quad (4)$$

$$R = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 1 & -1 & 0 & 0 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & -j & j \end{bmatrix} \quad (5)$$

$$W = \begin{bmatrix} S_{hh}S_{hh}^* & S_{hv}S_{hv}^* & S_{hh}S_{hv}^* & S_{hv}S_{hh}^* \\ S_{vh}S_{vh}^* & S_{vv}S_{vv}^* & S_{vh}S_{vv}^* & S_{vv}S_{vh}^* \\ S_{hh}S_{vh}^* & S_{hv}S_{vv}^* & S_{hh}S_{vv}^* & S_{hv}S_{vh}^* \\ S_{vh}S_{hh}^* & S_{vv}S_{hv}^* & S_{vh}S_{hv}^* & S_{vv}S_{hh}^* \end{bmatrix} \quad (6)$$

すなわち、多偏波 SAR データのMueller行列は1画素ごとに、次式で表現される。

$$M = \begin{cases} \frac{1}{2}\left(|S_{hh}|^2 + |S_{vv}|^2 + 2|S_{hv}|^2\right) & \frac{1}{2}\left(|S_{hh}|^2 - |S_{vv}|^2\right) \\ \frac{1}{2}\left(|S_{hh}|^2 - |S_{vv}|^2\right) & \frac{1}{2}\left(|S_{hh}|^2 + |S_{vv}|^2 - 2|S_{hv}|^2\right) * \\ \Re\{S_{hh}S_{hv}^*\} + \Re\{S_{hv}S_{vh}^*\} & \Re\{S_{hh}S_{hv}^*\} - \Re\{S_{hv}S_{vh}^*\} \\ \Im\{S_{hh}S_{hv}^*\} + \Im\{S_{hv}S_{vh}^*\} & \Im\{S_{hh}S_{hv}^*\} - \Im\{S_{hv}S_{vh}^*\} \\ * \Re\{S_{hh}S_{hv}^*\} + \Re\{S_{hv}S_{vh}^*\} & -\Im\{S_{hh}S_{hv}^*\} - \Im\{S_{hv}S_{vh}^*\} \\ * \Re\{S_{hh}S_{hv}^*\} - \Re\{S_{hv}S_{vh}^*\} & -\Im\{S_{hh}S_{hv}^*\} + \Im\{S_{hv}S_{vh}^*\} \\ |S_{hv}|^2 + \Re\{S_{hh}S_{vv}^*\} & -\Re\{S_{hh}S_{vv}^*\} \\ \Im\{S_{hh}S_{vv}^*\} & -|S_{hv}|^2 + \Re\{S_{hh}S_{vv}^*\} \end{cases} \quad (7)$$

ここで、\$\Re\$は実数部、\$\Im\$は虚数部、\$*\$は複素共役を示す。

全観測地域から特に市街地の中心部を含む一部分に着目し、図3に示す\$1,024 \times 1,024\$ピクセルの



図3 解析対象領域の画像（茨城県つくば市 X バンド、\$|S_{vv}|\$）
Fig. 3 Image of study area (X band, \$|S_{vv}|\$).

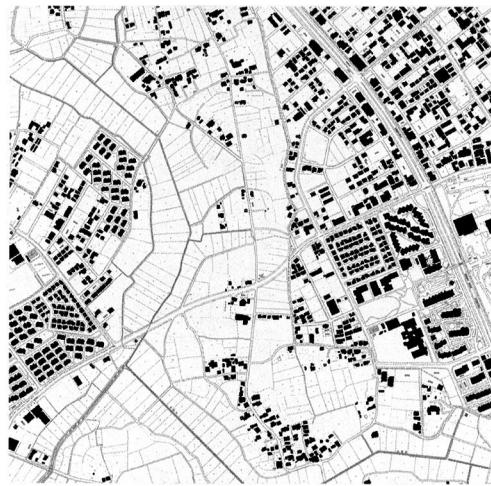


図4 解析対象領域の建物分布図
Fig. 4 Structures allocation map of study area.

領域を解析データとした。図3のグレースケール画像は、PI-SAR・Xバンドの\$|S_{vv}|\$により作成した。また、図4は、図3に対応する地域の建物分布図を示す。分類項目は、3要因に対する建物(\$\omega_1\$)、植生(\$\omega_2\$)、オープンスペース(\$\omega_3\$)とし、トレーニングデータと分類精度の検証に用いるテストデータは地上調査、航空写真に基づいて取得した。\$\omega_1\$は集合住宅、一般木造住宅など、\$\omega_2\$は主に稻と松林、\$\omega_3\$は道路と裸地、及び、芝生から構成されている。芝生は植生に含めるべきであるが、火災阻止要因としての芝地の役割は道路、若しくは裸地と同じ役割を果たすことから \$\omega_3\$に属することにする。

3. 提案手法

Kohonenによって提案されたSOMは、空間分布している高次元データを2次元平面に写像することが可能であり、高次元データの特徴抽出や可視化に応用されている[13]。データ空間で近い位置に存在する入力ベクトルが、特徴マップ上の近いノードに写像され、近傍を構成する特徴をもつことから、リモートセンシングデータの土地被覆分類では、トレーニングデータの抽出や教師なし分類への適用が報告されている[20]。本論文では、SOMとカウンタプロバゲーションを用いたPI-SARデータの教師付き分類手法を新しく提案し、PI-SARデータを3要因に分類することに適用し、市街地特性の抽出を行う。図5は提案手法のブロック図を示し、散乱クラスに基づく事前分類と、SOMによる教師付き分類の2段階の手続きで実行される。PI-SARデータを1画素ごとに、(1)奇数回反射が支配的な画素(ODDクラス)、(2)偶数回反射が支配的な画素(EVENクラス)、(3)その他(OTHERクラス)の三つの散乱クラス(図6)に事前分類し、各散乱クラス別にSOMによる分類を行う[12]。

3.1 散乱クラスに基づく事前分類

散乱クラスに基づく事前分類では、Muller行列とStokesベクトルを用いて実際に散乱状態のシミュレーションを行う。電界の旋回方向は、 χ の符号で示され。

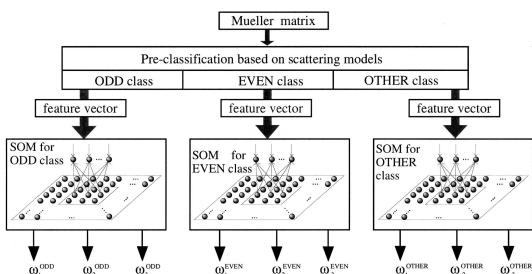


図5 提案手法のブロック図
Fig. 5 Block diagram of the proposed method.

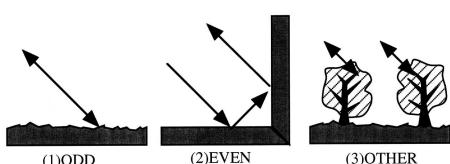


図6 散乱クラス
Fig. 6 Scattering classes.

$\chi > 0^\circ$ のとき左旋回、 $\chi < 0^\circ$ のとき右旋回の橈円偏波を表す。 $\chi = 0^\circ$ の場合、直線偏波、 $\chi \pm 45^\circ$ の場合、円偏波となる。散乱波の偏波を規定する角度を ψ^{sc}, χ^{sc} とし、送信波の偏波を規定する角度を ψ^{ill}, χ^{ill} とするとき、それらに対応する Stokes ベクトルは、

$$\left. \begin{aligned} G^{sc} &= \begin{bmatrix} S_0^{sc} \\ S_0^{sc} \cos(2\psi^{sc}) \cos(2\chi^{sc}) \\ S_0^{sc} \sin(2\psi^{sc}) \cos(2\chi^{sc}) \\ S_0^{sc} \sin(2\chi^{sc}) \end{bmatrix} \\ G^{ill} &= \begin{bmatrix} S_0^{ill} \\ S_0^{ill} \cos(2\psi^{ill}) \cos(2\chi^{ill}) \\ S_0^{ill} \sin(2\psi^{ill}) \cos(2\chi^{ill}) \\ S_0^{ill} \sin(2\chi^{ill}) \end{bmatrix} \end{aligned} \right\} \quad (8)$$

である。直線偏波である送信波の傾き角 ψ^{ill} が、 $0^\circ < \psi^{ill} < 180^\circ$ まで変化するとき、式(3)より散乱波の偏波橈円の傾き角 ψ^{sc} を求める。更に左旋回($\chi^{ill} = -45^\circ$)及び右旋回($\chi^{ill} = 45^\circ$)の円偏波を送信したときの散乱波の旋回方向を示す $\text{sgn}(\chi^{sc})$ を求める。ここで、 sgn は符号関数である。これらの結果より、次の条件に基づいてSARデータを散乱クラスに事前分類する[12]。

- (1) ψ^{sc} が単調に増加し、 $\text{sgn}(\chi^{ill}) = \text{sgn}(\chi^{sc})$ の場合
ODD クラス
- (2) ψ^{sc} が単調に減少し、 $\text{sgn}(\chi^{ill}) = \text{sgn}(\chi^{sc})$ の場合
EVEN クラス
- (3) 上記(1)及び(2)以外の場合
OTHER クラス

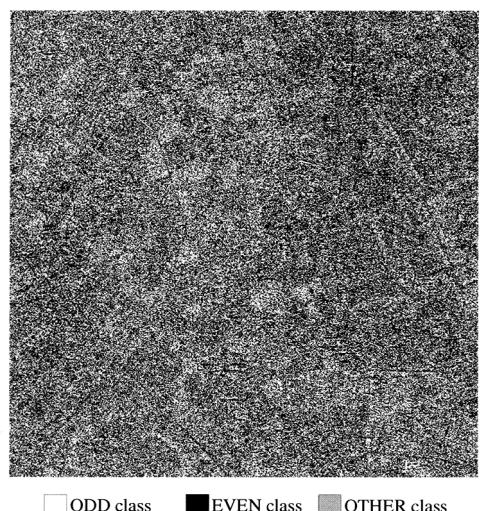


図7 解析対象領域の事前分類結果
Fig. 7 Pre-classification result using scattering models for study area.

表 2 テストデータの事前分類の結果

Table 2 Pre-classification results using scattering models for test data.

Scattering classes Category	ODD	EVEN	OTHER	Total
Structures (ω_1)	1477	2080	2115	5672 pixels
	26.04 %	36.67 %	37.29 %	100.00 %
Vegetation (ω_2)	3070	2537	2589	8196 pixels
	37.46 %	30.95 %	31.59 %	100.00 %
Open space (ω_3)	5296	4863	3661	13820 pixels
	38.32 %	35.19 %	26.49 %	100.00 %

解析データ全体を事前分類した結果を図 7 に示す。建物が存在する領域は EVEN クラスに分類された画素が多く見られる。このことは、建物から反射するマイクロ波がアンテナ 道路 壁 アンテナへ伝わる 2 回反射が多く起こるためと考えられる。表 2 のテストデータの事前分類結果から、各散乱クラスへの分類割合がほぼ均等になっていることがわかる。そのため、トレーニングデータは各分類項目ごとに三つの散乱クラスから 200 ピクセルずつ、テストデータからランダムに抽出する。

3.2 SOM による教師付き分類

PI-SAR データの教師付き分類手法として、一般的に 2 層で構成されている SOM ネットワークを改良し、出力層となるグロスバーグ層 (Grossberg 層) を追加することを考える。更に、SOM の学習方法としてカウンタプロパゲーション学習を適用する[15]。

図 8 に提案手法で用いる SOM のネットワーク構造を示す。このネットワークは入力層、競合層 (Kohonen 層) 及び出力層 (Grossberg 層) の 3 層からなり、競合層には $L \times L$ 個のノードが正方格子上に配置されている。入力層と出力層のそれぞれのノードは競合層のすべてのノードに結合されている。入力データは $X(x_k : k = 1, 2, \dots, M)$ で表される M 次元ベクトルであり、入力データに対応する出力データ $Y(y_l : l = 1, 2, \dots, N)$ は N 次元ベクトルで、出力層のノードへ入力データとは逆向きに入力される。 W_{ij} ($w_{ij}^k : k = 1, 2, \dots, M, i, j = 1, 2, \dots, L$) は入力層のノード k から競合層のノード (i, j) への結合荷重ベクトルであり、 U_{ij} ($u_{ij}^l : l = 1, 2, \dots, N, i, j = 1, 2, \dots, L$) は出力層のノード l から競合層のノード (i, j) への結合荷重ベクトルである。次に、SOM のカウンタプロパゲーション

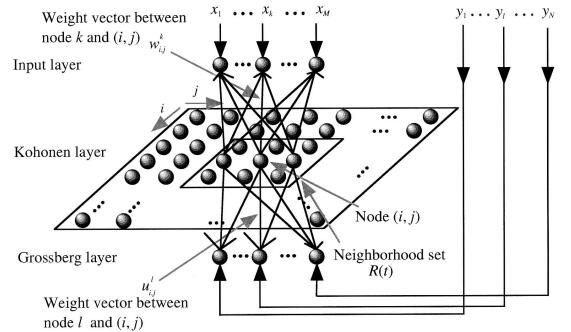


図 8 SOM のネットワーク構造

Fig. 8 SOM structure.

ンのアルゴリズムを示す[15], [18]。まず、 W_{ij} と U_{ij} に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、競合層のノードにつながった結合荷重ベクトルと比較される。距離を最小にする結合荷重ベクトルをもった競合層のノードが勝利ノードとされる。ユークリッド距離を最小にする勝利ノード (i^*, j^*) は、

$$(i^*, j^*) = \arg \min_{i,j} \sqrt{\sum_{k=1}^M (x_k - w_{i,j}^k)^2} \quad (9)$$

により求められる。勝利ノード及びその周辺のノードと入力層のノード間の W_{ij} は式(10)に基づいて更新される。

$$w_{i,j}^k = \begin{cases} w_{i,j}^k + \alpha(t)[x_k - w_{i,j}^k] & \text{if } (i, j) \in \{(i^*, j^*) \cup R(t)\} \\ w_{i,j}^k & \text{if } (i, j) \notin \{(i^*, j^*) \cup R(t)\} \end{cases} \quad (10)$$

同時に、勝利ノードとその周辺のノードと出力層のノード間の U_{ij} が式(11)に基づいて更新される。

$$u_{i,j}^l = \begin{cases} u_{i,j}^l + \beta(t)[y_l - u_{i,j}^l] & \text{if } (i, j) \in \{(i^*, j^*) \cup R(t)\} \\ u_{i,j}^l & \text{if } (i, j) \notin \{(i^*, j^*) \cup R(t)\} \end{cases} \quad (11)$$

SOM の学習では、通常数千回以上のデータ提示が必要であり、トレーニングデータが少ない場合、そのデータを繰り返し提示することで学習を行う。ここで、 t は繰り返し提示回数で、 $\alpha(t)$ と $\beta(t)$ は学習係数であり、あらかじめ定義された正の単調減少関数である。 $R(t)$ は勝利ノードの周辺のノードを決めるための近傍集合を示し、 t が大きくなるとともにその領域を狭める関数である。SOM の競合層では繰り返しデータの提示を行うことによって W_{ij} が入力ベクトルの特徴を表現する局所的な近

傍を構成する。一方、 U_{ij} は入力データと対になる特定の出力データに対して学習が行われ、入力データのルックアップテーブルの役目を果たすようになる。

予備実験の結果、学習係数 $\alpha(t)$ と $\beta(t)$ は、

$$\alpha(t) = 0.9 \left(1 - \frac{t}{t_{\max}} \right) \quad (12)$$

$$\beta(t) = 0.5 \left(1 - \frac{t}{t_{\max}} \right) \quad (13)$$

を用い、近傍関数 $R(t)$ として

$$R(t) = \left\{ (i^* + i, j^* + j) \mid |i|, |j| \leq \left[c_1 \left(1 - \frac{t}{t_{\max}} \right) \right] \right\} \quad (14)$$

で定義される正方形の集合を用いる。ここで、 $[]$ はガウス記号を示し、 c_1 と t_{\max} はそれぞれ最大近傍と総提示回数を示す。出力データは、設定した 3 種の分類項目に対応する以下のベクトルとする。

$$\omega_1 \quad Y = [0, 0, 1]$$

$$\omega_2 \quad Y = [0, 1, 0]$$

$$\omega_3 \quad Y = [1, 0, 0]$$

最後に、カテゴリーマップの作成を行う。競合層のノード (i, j) に着目し、 (i, j) から出力層のノードへの結合荷重ベクトル ($u_{i,j}^l : l = 1, 2, \dots, N$) と出力データのユークリッド距離を求める。その距離が最小となる出力データが属する分類項目をノード (i, j) に対して与える。競合層のすべてのノードに対して分類項目を割り当てる。結果として得られる競合層上の分類項目の分布は、トレーニングデータの空間分布が写像されたもので、カテゴリーマップと定義する。分類項目が未知のベクトルデータがネットワークに入力された場合、勝利したノードに対応するカテゴリーマップ上の分類項目がこのベクトルデータに対する分類結果となる。

3.3 分類結果

トレーニングデータは、各分類項目ごとに三つの散乱クラスにそれぞれ 200 ピクセルをテストデータからランダムに選択した。観測データの X バンドデータの後方散乱パワー [dB] である、 $\{10 \log_{10} (S_{hv} S_{hv}^*), 10 \log_{10} (S_{vv} S_{vv}^*), 10 \log_{10} (S_{hh} S_{hh}^*)\}$ を特徴ベクトルとして SOM を学習し、三つの散乱クラスそれぞれに対応した SOM ネットワークをカウンタプロパゲーションを用いて学習することでカテゴリーマップを作成した。予備実験の結果から、競合層の大きさを、 $L = 30$ 、近傍関数の最大近傍を $c_1 = 30$ とし、総提示回数を $t_{\max} = 25$ とする。な

お、総提示回数は各クラスに対応する SOM ごとに 600 個のトレーニングデータが 25 回提示されることを意味する。

図 9 は提案手法で作成されたカテゴリーマップであり、それぞれ三つの散乱クラスに対応している。カテゴリーマップはトレーニングデータの 3 次元空間分布を 2 次元平面に写像したものとなり、トレーニングデータにおける特徴ベクトルの類似性を示すことが報告されている[17]。図 9 の A に示すように、建物を示すノードが植生の領域に含まれる形になっている。このことは、建物のトレーニングデータに反射・散乱特性が植生のものと類似しているデータがあることを示している。また、カウンタプロパゲーションを適用することによって、カテゴリーマップのための学習を特徴マップの競合学習と同時に実行できるという利点があり、本論文の実験で使った SOM では、競合層のノード数が 900 個であるのにもかかわらず、600 個のトレーニングデータを利用して、カテゴリーマップが作成されている。このカテゴリーマップはラベル付けされないノードは含まれておらず、分類項目の境界も明確になっている。また、トレーニングデータを再入力するという手順が省かれるため、より簡単な学習アルゴリズムとなっている。

表 3 は散乱クラスに基づく事前分類を適用した場合の SOM、LVQ、BP 法及び最尤法によるテストデータの分類スコア行列を示す。最尤法はベイズの定理に基づく統計的手法で、尤度が最大となる分類項目に未知データを分類するパラメトリックな手法である。予備実験の結果から、BP 法のニューラルネットワークは入力層、隠れ層、出力層の 3 層からなり、各層のニューロン数は 3-10-3 とする。LVQ に用いたネットワークは入力層と競合層からなる 2 層構造で、入力層のニューロン数は 3、競合層における各分類項目に対応するコードブックベクトル数は 10 とする。学習アルゴリズムは Kohonen が提案した LVQ1 である。なお、分類条件をそろえるため、ここで用いたトレーニングデータとテストデータは 4 手法とも同一にしている。表 3 に示すように、建物 (ω_1) が植生 (ω_2) として誤分類された結果は、他の誤分類に比較して、どの分類手法においても高くなっている。このことは、建物のデータの反射・散乱特性が植生のものと類似しているという図 9 の領域 A の考察と一致し、カテゴリーマップの可視化機能を示す一例であると考えられる。更に、建物 (ω_1) が植生 (ω_2) として誤分類された結果は、それぞ

れ , SOM(19.25%), LVQ(21.61%), BP 法(20.73%), 最ゆう法(24.52%)となり , SOM の誤分類の結果が最も低くなり , 分類精度の侧面からも有効性が示されている . また , オープンスペース(ω_3)の分類精度は , 4 手法とも 87% を超え , 他の分類項目と比較して高く , 提案手法を適用して PI-SAR データを分類した場合 , オープンスペース(ω_3)の抽出に効果的であることがわかる .

表 4 は散乱クラスに基づく事前分類を適用する場合と , そうでない場合の 4 手法によるテストデータの分類結果を示している . ここで , 事前分類を適用しない場合においても , レーニングデータは事前分類を適用する場合と同一のものを用いている . 3 分類項目の分類精度の平均(以下 , 平均分類精度 P)は , 事前分類を適用する場合には , SOM(79.52%), LVQ(79.29%), BP 法(78.94%), 最ゆう法(79.07%)となり , SOM が最も優れているという結果を得た . 事前分類を適用することにより , SOM (+0.22%), LVQ (+0.06%), BP 法(+1.88%), 最ゆう法(+2.14%)だけ P が向上し , 事前分類の効果が示されている . 事前分類による分類精度の向上は , SOM と LVQ が小さく , BP 法と最ゆう法は大きくなっている . その理由として , 最ゆう法では事前分類の段階で一つの分類項目に対して三つの確率分布を仮定していることで精度が向上したと考えられ , また , BP 法では事前分類を適応することで , 分類項目識別面の適応度が高まったため精度が向上したと考えられる . 一方 , 事前分類を適用しても , SOM と LVQ の

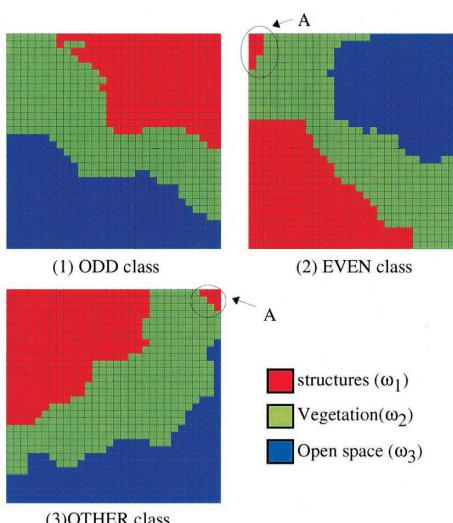
図 9 カテゴリーマップ ($L = 30, c_1 = 30, t_{\max} = 25$)Fig. 9 Category maps ($L = 30, c_1 = 30, t_{\max} = 25$).表 3 分類スコア行列 ($L = 30, c_1 = 30, t_{\max} = 25$)

Table 3 Confusion matrices.

Method	Category	Classified category		
		ω_1	ω_2	ω_3
SOM	ω_1	78.56	19.25	2.19
	ω_2	11.19	70.41	18.40
	ω_3	0.36	10.04	89.59
LVQ	ω_1	76.59	21.61	1.80
	ω_2	9.08	74.24	16.68
	ω_3	0.28	12.69	87.03
BP	ω_1	76.96	20.73	2.31
	ω_2	9.93	71.84	18.23
	ω_3	0.41	11.58	88.01
ML	ω_1	73.40	24.52	2.08
	ω_2	6.70	75.49	17.81
	ω_3	0.38	11.28	88.34

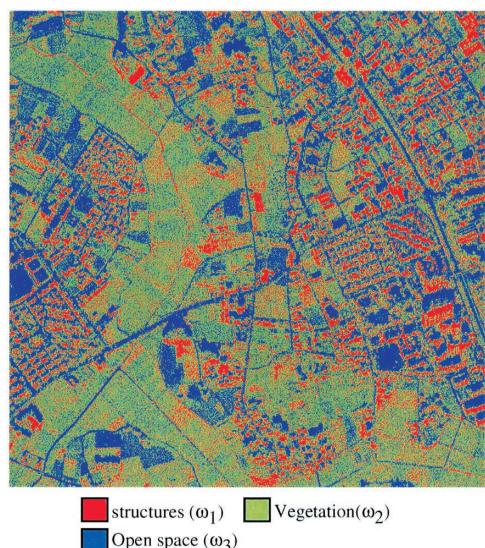
(%)

表 4 分類精度の比較

Table 4 Comparison of classification accuracy.

Category Method	ω_1	ω_2	ω_3	Average(P)
Pre-classified SOM	78.56	70.41	89.59	79.52
Pre-classified LVQ	76.59	74.24	87.03	79.29
Pre-classified BP	76.96	71.84	88.01	78.94
Pre-classified ML	73.40	75.49	88.34	79.07
SOM	78.63	72.40	86.87	79.30
LVQ	73.41	77.57	86.71	79.23
BP	79.62	74.62	76.93	77.06
ML	68.78	68.66	93.36	76.93

(%)

図 10 解析データ全体の分類結果 ($L = 30, c_1 = 30, t_{\max} = 25$)Fig. 10 Classification result of study area ($L = 30, c_1 = 30, t_{\max} = 25$).

分類精度の向上が小さかったのは、事前分類を適用しない場合でも、ベイズの定理に基づく限界に近い識別能力を得るところまでニューラルネットワークの学習が進むためと考えられる。このことは、競合学習の優位性を示す一例とも考えられる。

図10は事前分類を適用したSOMを用いて解析領域全体を3種の分類項目へ分類した結果を示す。幅員が10m以下程度の道路や建物が明確に抽出され、詳細な地上パターンの判読が可能な土地被覆分類結果が得られている。

4. む す び

市街地火災の延焼に関係する建物、植生、オープンスペースの3要因をPI-SARデータから抽出することを目的とし、SOMとカウンタプロパゲーション学習を用いた多偏波SARデータの土地被覆分類手法を提案した。分類実験の結果から以下のことが明らかにされた。

- (1) SOMとカウンタプロパゲーション学習を用いた分類手法は、LVQ、BP法及び最ゆう法などの既存の手法と比較して高い分類精度を得ることが可能である。
- (2) 散乱クラスに基づく事前分類を適用することによって分類精度を向上させることができる。
- (3) PI-SARデータは3要因のうちオープンスペースの抽出において有効である。

阪神淡路大震災において、公園や幹線道路などのオープンスペースが延焼遮断帯として大きな役割を果たした。PI-SARデータから抽出された市街地の特徴は、火災の延焼危険度を予測するために重要なパラメータになることが期待される。しかし、PI-SARはサイドルッキングレーダであることから、山など高い位置のものが実際の位置よりもセンサ側に近い位置に表示されるフォーショートニング(Foreshortening)や、フォーショートニングが顕著な場合に、手前の地点の上に覆いかぶさって画像化されるレイオーバー(Layover)などにより、高層建築物やその周辺の情報抽出に問題があると考えられる。今後、抽出結果を火災延焼シミュレーション等都市防火に応用するためには、この問題を解決することが課題である。

謝辞 本研究のPI-SARデータは、郵政省通信総合研究所と茨城大学との共同研究によって提供されたものであり、関係各位に対し深く感謝の意を表します。

文 献

- [1] 消防研究所、兵庫県南部地震における神戸市内の市街地火災調査報告(速報), pp.60-66, 1995.

- [2] 座間信作、細川直史，“簡易型地震被害想定システムの開発,” 消防研究所報告, 第82号, pp.26-33, 1996.
- [3] 消防研究所、地震時における消防力運用の最適化システムに関する研究開発報告書, pp.9-24, 1986.
- [4] 東海林理有、片山 律、小泉俊雄，“リモートセンシングによる都市の火災危険度予測に関する研究 その2,” 平10写真測量学会秋季学術講演会論文集, pp.185-188, 1998.
- [5] 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, pp.91-96, 1995.
- [6] F.T. Ulaby and C. Elachi, Radar Polarimetry for Geoscience Applications, pp.33-45, Artech House, Norwood, USA, 1990.
- [7] 井口義朗、他、合成開口レーダ(SAR), pp.332-347 (財)資源観測解析センター, 1992.
- [8] 飯坂謙二監修、合成開口レーダハンドブック, pp.63-68, 朝倉書店, 1998.
- [9] 山口芳雄、偏波(ポーラリメトリック)レーダの基礎と応用, pp.52-74, リアライズ社, 1998.
- [10] CRL/NASDA、航空機搭載合成開口レーダ(PI-SAR)データ集, vol.1, 1999,
- [11] J.J. Van Zyl, “Unsupervised classification of scattering behavior using radar polarimetry data,” IEEE Trans. Geoscience & Remote Sensing, vol.27, no.1, pp.36-45, Jan. 1989.
- [12] 伊藤陽介、大松 繁，“散乱モデルとニューラルネットワークによるポラリメトリック SARデータの分類法,” システム制御情報学論, vol.11, no.8, pp.449-457, 1998.
- [13] T. Kohonen, Self-Organizing Maps, Springer-Verlag, Berlin, Germany, 1995.
- [14] 野上芳和、大松 繁，“SOMによるSARデータの土地利用解析,” 大阪府立大修士学位論文, 1997.
- [15] R. Hecht-Nielsen, Neurocomputing, Addison-Wesley, New York, 1990.
- [16] 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, Hambrug, Germany, July 1999.
- [17] 細川直史、伊藤陽介、星 仰，“自己組織化マップ(SOM)による液状化領域の抽出,”写真測量とリモートセンシング, vol.38, no.6, pp.14-23, 1999.
- [18] 細川直史、伊藤陽介、星 仰，“カウンタプロパゲーション学習に基づくSOMを用いた土地被覆分類,” 平11写真測量学会秋季学術講演会発表論文集, pp.13-16, 1999.
- [19] 細川直史、伊藤陽介、星 仰，“自己組織化マップによるポラリメトリックSARデータの土地被覆分類,”情処学第60回全大(2), pp.157-158, 2000.
- [20] 村井 礼、岡村雅宏、大松 繁，“2種類のニューラルネットワークを用いたリモートセンシングのパターン認識精度の向上,” リモートセンシング学誌, vol.14, no.2, pp.3-13, 1994.

(平成12年5月8日受付, 10月30日再受付)



細川 直史（正員）

昭62徳島大・工・情報卒。平1同大大学院修士課程了。平3自治省消防庁消防研究所研究員、現在に至る。リモートセンシングデータ画像解析とその応用に関する研究、地震時の情報伝達に関する研究に従事。日本写真測量学会、日本火災学会、IEEE各会員。



伊藤 陽介

昭60徳島大・工・情報卒。昭62同大学院修士課程了。平4高松高専講師、平10同助教授を経て、平13鳴門教育大・学校教育・助教授。工博。リモートセンシングデータ画像解析の研究に従事。システム制御情報学会、日本写真測量学会、日本リモートセンシング学会、IEEE各会員。



星 仰（正員）

昭39徳島大・工・土木卒。同年京大・工・教務員、同助手。昭46和歌山高専助教授、同教授。昭55筑波大・電子・情報工学系助教授を経て、平4茨城大・工・情報・教授。工博。情報システム工学とリモートセンシングの研究に従事。日本リモートセンシング学会評議員、日本写真測量学会評議員、システム農学会理事。昭55日本写真測量学会学会賞受賞。情報処理学会、日本緑化学会、土木学会各会員。