

## 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

○細川 直史\*    伊藤 陽介\*\*    星 仰\*  
\*茨城大学    \*\*高松工業高等専門学校

### 1. はじめに

合成開口レーダ(Synthetic Aperture Radar:SAR)は、マイクロ波による能動型センサーで、天候に影響されにくい観測が可能なることから、災害監視等への応用が期待されている。郵政省と宇宙開発事業団が開発されているPI-SARはXバンドとLバンドのポラリメトリック SAR データを地上解像度 1.5m~3m で取得可能な航空機 SAR であり、人工衛星 SAR と比較してより詳細な地上パターンの判読が可能である。本稿では、Kohonen の自己組織化マップ (Self-Organizing Maps:SOM) とカウンタープロパゲーション学習を用いて、ポラリメトリック SAR データの散乱クラスを考慮した土地被覆分類が可能なカテゴリマップを作成する手法を提案する。提案手法における SAR データの分類精度を従来手法である最尤法と比較し、その結果を報告する。

### 2. 解析データ

1997年9月30日に観測されたつくば市地域の MGP (Multilook Grandrange polarimetric data) から、1024ピクセル×1024ピクセルの領域を切り出し解析データとした。ポラリメトリック SAR データは、Mueller 行列が次式で与えられる場合に、

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

1画素ごとに、

$$p = [S_{hv} S_{hv}^*, S_{vv} S_{vv}^*, S_{hh} S_{hh}^*, \Re\{S_{hh} S_{hv}^*\}, \Im\{S_{hh} S_{hv}^*\}, \Re\{S_{hh} S_{vv}^*\}, \Im\{S_{hh} S_{vv}^*\}, \Re\{S_{hv} S_{vv}^*\}, \Im\{S_{hv} S_{vv}^*\}] \quad (2)$$

の9次元実数ベクトル  $P$  で表現できる<sup>1)</sup>。ここで、\*は複素共役、 $\Re$  は実数部、 $\Im$  は虚数部を示す。本稿では

道路 ( $\omega_1$ ), 裸地 ( $\omega_2$ ), 建物 ( $\omega_3$ ), 稲 ( $\omega_4$ ), 芝地 ( $\omega_5$ ), 松林 ( $\omega_6$ ) の6分類項目を設定し、教師となる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を基に X, L バンド両観測データから抽出する。

### 3. 提案手法

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应用されている<sup>2)</sup>。SOM をカウンタープロパゲーションを用いて学習することで、リモートセンシングデータの分類項目情報が写像され、土地被覆分類に適用可能なカテゴリマップを作成する手法が提案されている<sup>3)</sup>。本稿では PI-SAR データを、以下に示す手法<sup>4)</sup>により、1画素ごとに3つの散乱クラス(図1)に事前分類し、SOM による分類手法を適用する。

(1) 奇数回反射が支配的な画素 (ODD)

$$\langle \Re\{S_{hh} S_{vv}^*\} \rangle > 0 \text{ かつ } \langle \Re\{S_{hh} S_{vv}^*\} \rangle > \langle |S_{hv}|^2 \rangle \text{ のとき,} \\ \langle |S_{hh}| \rangle > \langle |S_{vv}| \rangle, \langle |S_{vv}| \rangle > \langle |S_{hv}| \rangle$$

(2) 偶数回反射が支配的な画素 (EVEN)

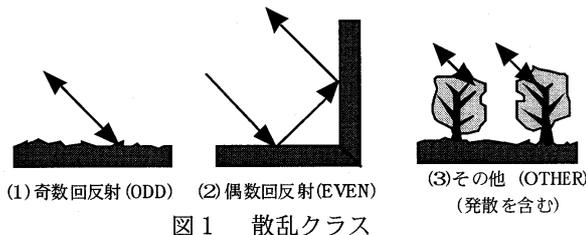
$$\langle \Re\{S_{hh} S_{vv}^*\} \rangle < 0 \text{ かつ } \langle \Re\{S_{hh} S_{vv}^*\} \rangle > \langle |S_{hv}|^2 \rangle \text{ のとき,} \\ \langle |S_{hh}| \rangle > \langle |S_{vv}| \rangle, \langle |S_{vv}| \rangle > \langle |S_{hv}| \rangle$$

(3) ODD と EVEN に該当しない画素 (OTHER)

6つの分類項目におけるトレーニングデータを、事前分類し、図2に示すように3つのクラスそれぞれに対応した SOM ネットワークをカウンタープロパゲーションを用いて学習する。本稿はトレーニングデータ数は、各カテゴリーごとに3つの散乱クラスにそれぞれ50ピクセル、合計900画素とした。分類項目が未知の画素は、散乱クラスを事前分類し、クラス専用

Land Cover Mapping Using Self-Organizing Maps for Polarimetric SAR Data

Masafumi Hosokawa\*, Yosuke Ito\*\*, Takashi Hoshi\*  
\*Ibaraki University, \*\*Takamatsu National College of Technology



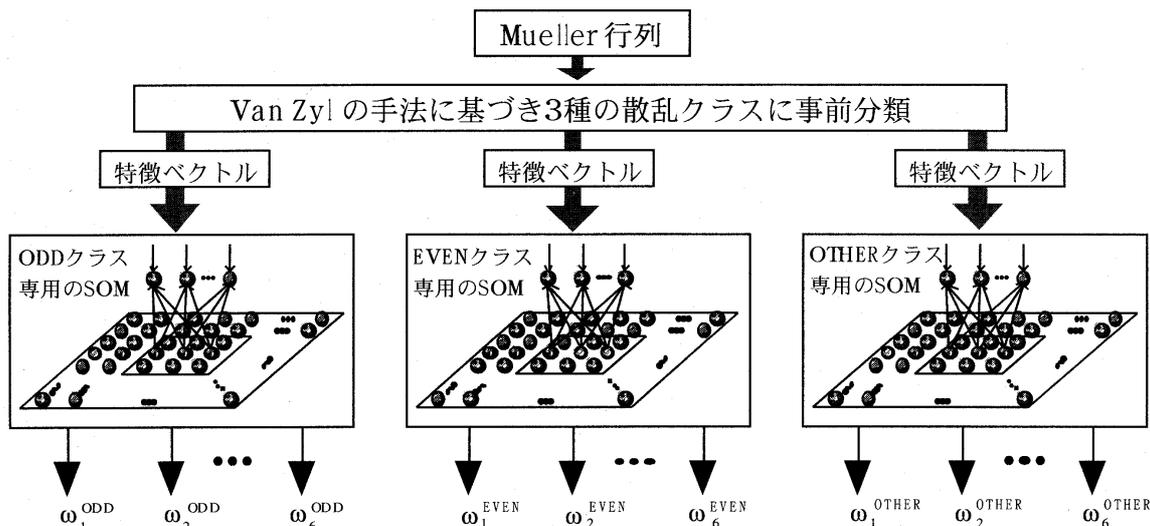


図2 提案手法のブロック図

のトレーニングデータで学習されたカテゴリマップによって分類される。

#### 4. 結果と考察

テストデータを3つの散乱クラスへ分類した結果、建物が存在する領域はODDクラスに分類された画素が、43%以上を占め偶数回反射が支配的であった。このことは、建物から反射するマイクロ波が道路→壁→センサへ伝わる2回反射が多く起こるためと考えられる。

観測データのLバンドとXバンドのそれぞれ  $\log_{10}(s_{vv}, s_{hh}^*)$ ,  $\log_{10}(s_{vv}, s_{hh}^*)$ ,  $\log_{10}(s_{hh}, s_{vv}^*)$ , 合計6つを特徴ベクトルとしてSOMを学習し、3つの散乱タイプに対応するカテゴリマップを作成した。表1は提案手法と最尤法によるテストデータの分類結果を示す。6つの分類項目における分類精度の平均は、提案手法による結果が50.15%で、最尤法による結果の48.18%より約2%上回る結果が得られている。しかしながら、

裸地については道路と誤分類されたデータが多く存在し、他の分類項目と比較してその精度が極端に低くなった。このことは裸地の土壌表面と道路のアスファルト表面の反射・散乱特性が類似していることが原因と考えられ、両者を正確に分類することは今後の課題である。

全体画像を6つの分類項目へ分類した結果については、細い道路や個々の建物が識別されており、人工衛星SARと比較してより詳細な地上パターン判読が可能な土地被覆画像が得られた。

#### 謝辞

データを提供して頂いた郵政省通信総合研究所の関係諸氏に感謝の意を表する。

#### 参考文献

- 1) 伊藤, 大松, “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”, 写真測量とリモートセンシング, PP.13-22, Vol.36, No.3, 1997
- 2) T.Kohonen, Self-Organizing Maps, Springer-Verlag, New York, 1995.
- 3) 細川, 伊藤, 星, “カウンター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”, 日本写真測量学会平成11年度秋季学術講演会発表論文集, pp.13-16, 1999
- 4) Jakob J. Van Zyl, Unsupervised Classification of Scattering Behavior Using Radar Polarimetry Data, IEEE Transaction on Geoscience and Remote Sensing, Vol.27, No.1, PP.36-45, January, 1989

表1 分類精度の比較

分類項目	分類手法	SOM (提案手法)	最尤法
道路 ( $\omega_1$ )	5568画素	51.56	55.24
裸地 ( $\omega_2$ )	5716画素	9.48	8.97
建物 ( $\omega_3$ )	3948画素	64.24	50.30
稲 ( $\omega_4$ )	4936画素	62.60	63.59
芝地 ( $\omega_5$ )	5396画素	64.23	71.39
松林 ( $\omega_6$ )	2248画素	48.80	39.64
6分類項目の平均		50.15	48.19

(%)