

E7 教師なしPi-SAR画像分類

木村 晃治 山口 芳雄 山田 寛喜

新潟大学工学部

1. まえがき 現在、地球環境の正確な把握を行う

ため、種々のpolarimetric SAR画像解析が行われている。中でも、非常に高分解能であるPi-SAR画像データは、詳細なターゲットの散乱特性の解析が可能であり、注目されている。地上ターゲットの分類法としては、各分類クラスごとにトレーニングエリアを抽出し、標本値を得る教師付き分類法と、地上ターゲットが未知であるものとして扱い、偏波散乱特性に基づき地上ターゲットの分類を行う教師なし分類法がある。実際には扱う画像データは未知のものであるから、教師なし分類法を用いることが望ましい。本研究では、Pi-SAR画像データを用いて、coherency行列に基づく地上ターゲットの教師なし分類を行っている。

2. 偏波散乱特性 地上ターゲットの分類に用いるパラメータについてふれる。coherency行列の要素はそれぞれ意味を持った特徴量となっている。散乱行列をPauli行列を用いて次式で定義すると

$$[S] = \begin{bmatrix} a+b & c \\ c & a-b \end{bmatrix} = a \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} + b \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} + c \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \quad (1)$$

coherency行列の要素は、次式のように表される。

$$[T] = \begin{bmatrix} |a|^2 & a b^* & a c^* \\ a^* b & |b|^2 & b c^* \\ a^* c & b^* c & |c|^2 \end{bmatrix} = \begin{bmatrix} 2A_0 & C-jD & H+jG \\ C+jD & B+B_0 & E+jF \\ H-jG & E-jF & B-B_0 \end{bmatrix} \quad (2)$$

各パラメータと散乱行列との関係は次式で表される。

$$\begin{aligned} 2A_0 &= \frac{1}{2} |S_{HH} + S_{VV}|^2, B_0 = \frac{1}{4} |S_{HH} - S_{VV}|^2 + |S_{HV}|^2 \\ B &= \frac{1}{4} |S_{HH} - S_{VV}|^2 - |S_{HV}|^2 \\ C &= \frac{1}{2} (|S_{HH}|^2 - |S_{VV}|^2), D = \text{Im}(S_{HH} S_{VV}^*) \\ E &= \text{Re}(S_{HH} S_{HV}^* - S_{HV} S_{VV}^*) \\ F &= \text{Im}(S_{HH} S_{HV}^* + S_{HV} S_{VV}^*) \\ G &= \text{Im}(S_{HH} S_{HV}^* - S_{HV} S_{VV}^*) \\ H &= \text{Re}(S_{HH} S_{HV}^* + S_{HV} S_{VV}^*) \end{aligned} \quad (3)$$

ここで全散乱電力は、式(2)のcoherency行列の対角要素の和によって表される。

$$\begin{aligned} \text{span} &= |S_{HH}|^2 + 2|S_{HV}|^2 + |S_{VV}|^2 \\ &= 2A_0 + (B+B_0) + (B-B_0) \end{aligned} \quad (4)$$

また、 $2A_0$ 、 $B+B_0$ 、 $B-B_0$ はそれぞれ表面散乱(1次Bragg散乱:水面、平地における一回反射)、二回反射(市街地の地面-ビル、住宅の壁、植生の地面-幹における二回反射など)、体積散乱(HV偏波成分に起因し、特に植生における樹冠での散乱がこの散乱メカニズムにあてはまる)の寄与を表すパラメータであり⁽¹⁾、全散乱電力に対する各散乱メカニズムに関する電力比をそれぞれ P_s 、 P_d 、 P_v とすると、次式で表

される。

$$P_s = \frac{2A_0}{\text{span}}, P_d = \frac{B_0+B}{\text{span}}, P_v = \frac{B_0-B}{\text{span}} \quad (5)$$

海域、農地では P_s が支配的であり、市街地、植生では P_d 、 P_v が比較的大きな値を示すと考えられる。

3. 分類アルゴリズム 各クラスの参照ベクトルを生成する手法として、Learning Vector Quantization(LVQ)アルゴリズム⁽²⁾を用いる。最初に、画像データの任意の画素より特徴量を抽出し、生成される特徴ベクトルと、既存のクラス i の参照ベクトル

$$\omega_i = (P_{s_i} P_{d_i} P_{v_i})^T$$

$$D_i = \sqrt{(X - \omega_i)(X - \omega_i)^T} \quad (6)$$

を求め、

$$D_u = \min D \quad (7)$$

となるクラス u を探索する。そして、特徴ベクトル X をクラス u に帰属させ、参照ベクトル $\omega_u(t)$ を

$$\omega_u(t+1) = \omega_u(t) + A(X - \omega_u(t)) \quad (8)$$

により更新する。式(8)の A ($0 \leq A \leq 1$)は利得であり、十分に小さな値をとる。また、残りのクラスの参照ベクトルはそのまま残す。初期のクラスの参照ベクトルとして、それぞれ表面散乱、二回反射、体積散乱が支配的である4つのクラス、おのおのの散乱成分が同程度であるクラス ω_E の計13個の参照ベクトルを設定する。表面散乱が支配的である参照ベクトルは、次式で表される。

$$\begin{aligned} \omega_{s1} &= (0.9 \quad 0.05 \quad 0.05) \\ \omega_{s2} &= (0.75 \quad 0.125 \quad 0.125) \\ \omega_{s3} &= (0.6 \quad 0.2 \quad 0.2) \\ \omega_{s4} &= (0.45 \quad 0.275 \quad 0.275) \end{aligned} \quad (9)$$

二回反射、体積散乱に関する参照ベクトルに関して、式(9)と同様の要素の値で設定される。また ω_E は次式で表される。

$$\omega_E = (0.333 \quad 0.333 \quad 0.333) \quad (10)$$

この処理を画像データの全画素を抽出するまで繰り返していき、初期のクラスの参照ベクトルを得る。各クラスの参照ベクトルが得られた後、再び画像データの画素より特徴量を抽出して特徴ベクトルを生成し、特徴ベクトルと参照ベクトルとの距離が最も小さくなるクラスに画素を割り当てていくことにより、各クラスの平均coherency行列 V_i は、次式のように得られる。

$$V_i = \frac{1}{N_i} \sum_{j=1}^{N_i} \langle T_j \rangle \quad (11)$$

coherency行列の生成の際には、画像中の全画素が抽

出される。次に、最尤法を用いて画像データの全画素を距離

$$d(\langle T \rangle, V_m) = \ln |V_m| + \text{Tr}(V_m^{-1} \langle T \rangle) \quad (12)$$

が最小となるクラス m に割り当てる。この際に、各クラスの平均coherency行列が再び得られ、更新される。この操作は終了条件が満たされるまで繰り返される。なお終了条件は、割り当てられるクラスが変化した画素の画像データの全画素に対する割合が10%以下であることとし、条件を満たした場合に繰り返し処理を終了する^[3]。また、望ましいクラス数となるまでクラスの合併を行う。クラスの合併を行うかどうかを判断する指標として、クラス間の分離の度合いを表すパラメータ R_{ij} を次式のように定義する^[3]。

$$R_{ij} = \frac{D_{ii} + D_{jj}}{D_{ij}} \quad (13)$$

式(13)の D_{ii} 、 D_{jj} はそれぞれクラス i 、 j 内における分散、 D_{ij} はクラス i 、 j 間の距離であり、次式で表される。

$$D_{ii} = \ln |V_i|$$

$$D_{ij} = \frac{1}{2} \left\{ \ln |V_i| + \ln |V_j| + \text{Tr}(V_i^{-1} V_j + V_j^{-1} V_i) \right\} \quad (14)$$

望ましいクラス数とは、

$$J = \frac{1}{N_c} \sum_{i=1}^{N_c} J_i \quad (15)$$

となる N_c であり、 $J_i = \text{Max}(R_{ij}) (i \neq j)$ である。

4. 分類結果 用いる画像データは、L-Bandの新潟大学周辺のPi-SAR画像データ(2000年10月2日観測)である。大学周辺には、建造物が集中しており、大学のはずれには海、水田が広がり、松林が海岸沿いに集中している。また、新川が大学付近を流れている。Pi-SAR画像のおおのこのピクセルには散乱行列が含まれているが、この画像データは偏波較正が十分に行われていないため、ターゲット分類を行う前処理として、散乱行列の較正を行う必要がある。偏波較正に関しては、インバランスの補正ターゲットとして、海岸沿いに配置した4個の3面リフレクタを用い、クロストークの補正ターゲットとして、画像中の海域、水田を用いる^[4]。図1に分類画像、表1に各クラスのクラス中心を示す。海域では表面散乱が支配的になっており、水田は稲の高さ、地面の粗さの違いにより2つのクラスに分類されている。また住宅地では、表面散乱が支配的であるクラス、二回反射が支配的であるクラス、表面散乱、二回反射が同程度であるクラスの3つのクラスに分類される。表面散乱は、住宅の屋根における一回反射によるもの、二回反射は、地面-住宅の壁における二回反射によるものと考えられる。松林では、地面-幹による二回反射よりも、樹冠を透過した地表面における一回反射成分が支配的となっている。この手法を用いることにより、ターゲットの分類が有効に行われていることがわかる。なお発表当日は、種々の偏波散乱特性を表現するパラメータを用いた場合の分類結果を示

す。

謝辞 この研究を進めるにあたり、貴重なPi-SAR画像データを提供して頂いたCRL、NASDAに感謝致します。この研究の一部は、文部科学省科研費によるものである。

参考文献

- [1] C. T. Schnaider, "Polarimetric analysis of RAMSES SAR images," *Proc. of 4rd international workshop on radar polarimetry*, pp. 366-375, July 1998.
- [2] Y. Hara, R. G. Atkins, S. H. Yueh, R. T. Shin, and J. A. Kong, "Application of Neural Networks to Radar Image Classification," *IEEE Trans. Geosci. Remote Sensing*, vol. 32, no. 1, pp. 100-109, Jan. 1994.
- [3] J. Lee, M. R. Grunes, T. L. Ainsworth, L. Du, D. L. Schuler, and S. R. Cloude, "Unsupervised Classification Using Polarimetric SAR Images by Applying Target Decomposition and Complex Wishart Distribution," *PIERS 1998*, Nantes, France, 13-17 July 1998.
- [4] J. J. van Zyl, "Calibration of polarimetric radar images using only image parameters and trihedral corner reflector responses," *IEEE Trans. Geosci. Remote Sensing*, vol. 28, pp. 337-348, May 1990.



- クラス1 ■ クラス2 ■ クラス3 ■ クラス4
- クラス5 ■ クラス6 ■ クラス7

図1. 分類画像

表1. クラス中心

クラス	クラス中心
1	(0.666 0.287 0.047)
2	(0.605 0.283 0.112)
3	(0.600 0.235 0.165)
4	(0.373 0.590 0.037)
5	(0.483 0.322 0.195)
6	(0.387 0.509 0.104)
7	(0.406 0.403 0.191)