

ニューラルネットワークによる熱赤外多重分光 4Q-7 スキャナ画像のカテゴリー分類の試み

外岡 秀行 佐藤 富美子 星 仰
茨城大学

1. はじめに

NASAの地球観測システム (Earth Observing System, EOS)計画の緯度第1号として、1998年に極軌道プラットフォームEOS-AM1が打ち上げられる。EOS-AM1には、可視~熱赤外波長域に14チャンネルを有する高空高分解能ヒンサASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer、現在我が国で開発中)が搭載される。ASTERは地球観測用センサとしては初めて熱赤外波長域 (TIR) に複数のチャンネル (CH10~14の5チャンネル) を有するため、地表面の温度情報に加えて放射率情報が得られることが特徴であり、放射率スペクトルパターンに基づく地質マッピング等、様々な応用が期待されている。

ASTER/TIRに代表される熱赤外多重分光スキャナの観測データに基づく物質のカテゴリー分類については、航空機シミュレータを用いた実験等で成果が上がっているが [1]、分類手法や前処理等、検討すべき課題は多いと思われる。そこで本研究は、ASTER/TIR疑似観測データを用いたシミュレーションによって、ニューラルネットワーク分類の熱赤外多重分光スキャナデータへの適用を試みると共に、データの処理レベルと分類精度の関連性について検討したので結果を報告する。

2. 観測放射輝度と各処理レベルデータ

ピクセル内の地表面が一様で完全拡散性を持ち、太陽放射及び散乱の各効果を無視し、雲が無いものと仮定すると、ASTER/TIRのチャンネル i ($=10\sim14$) が観測する放射輝度は次式に簡略化できる。

$$x_i^{(0)} = I_i = \tau_i \left(\epsilon_i B_i(T) + \frac{(1-\epsilon_i)}{\pi} F_i \downarrow \right) + I_i \uparrow \quad (1)$$

ここで、 I_i : 観測放射輝度、 ϵ_i : 地表面放射率、 T : 地表面温度、 τ_i : 透過率、 $F_i \downarrow$: 地表での下向き放射照度、 $I_i \uparrow$: 光路輝度、 B_i : プランク関数、である。

本研究では、(1)式の $x_i^{(0)}$ を処理レベル0のデータとし、以下処理レベル1~4のデータ $x_i^{(1)} \sim x_i^{(4)}$ を次のように定める。

・処理レベル1 : 大気補正処理I (光路輝度の補正)

$$x_i^{(1)} = \tau_i \left(\epsilon_i B_i(T) + \frac{(1-\epsilon_i)}{\pi} F_i \downarrow \right) \quad (2)$$

・処理レベル2 : 大気補正処理II (透過率の補正)

$$x_i^{(2)} = \epsilon_i B_i(T) + \frac{(1-\epsilon_i)}{\pi} F_i \downarrow \quad (3)$$

・処理レベル3 : 大気補正処理III
(下向き放射照度の反射成分の補正)

$$x_i^{(3)} = \epsilon_i B_i(T) \quad (4)$$

・処理レベル4 : 温度・放射率分離処理

$$x_i^{(4)} = \epsilon_i \quad (5)$$

3. 各処理レベルデータの計算

放射伝達コードMODTRAN2の6つの標準大気モデル (TM:熱帯モデル、MLS:中緯度夏、MLW:中緯度冬、SAS:亜北極夏、SAW:亜北極冬、USS:1976年米国標準) 及び地表面物質のスペクトルライブラリ [2] を用いて (1)~(5) 式の各処理レベルデータを計算した。プランク関数や放射率、透過率等の波長の関数は、図1に示すASTER/TIRのフィルタ関数 (1993年における (株)富士通による試験測定結果) によって重み付け積分し、各チャンネルにおける値とした。

地表面温度は、280K、290K、300Kの3温度を与えた。また分類対象の物質は、岩石3種類 (花崗岩、安山岩、玄武岩)、植物1種類 (針葉樹)、水1種類 (海水) の計5種類を選んだ。

4. ニューラルネットワークの構成と学習方法

ニューラルネットワークは、処理レベル N における各チャンネルのデータ $x_{10}^{(N)}, x_{11}^{(N)}, x_{12}^{(N)}, x_{13}^{(N)}, x_{14}^{(N)}$ を各条件ごとに最大値が1、最小値が0になるように正規化して入力層に与え、5つのカテゴリー (花崗岩、安山岩、玄武岩、針葉樹、海水) を出力層に対応させる3階層ネットワークとした (図2)。また出力関数はシグモイド関数 (傾き係数0.75)、学習時はバックプロパゲーション法 (安定化定数0.2、学習定数1.0) とした。

中間層のニューロン数については、処理レベル4データを用いて、学習回数10000回における誤差2乗和に基づい

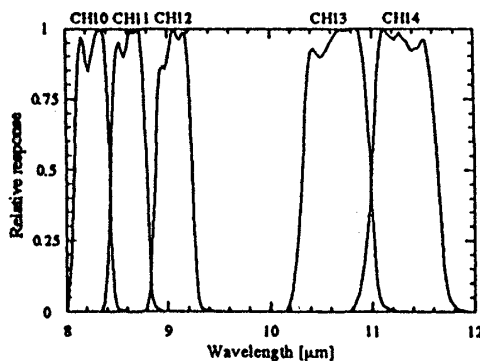


図1 ASTER/TIRフィルタ関数

て検討した。結果を図3に示す。中間層のニューロン数が15個以上であれば分類精度に違いが見られないことから本研究における中間層のニューロン数は15個とした。

学習回数については、処理レベル4データを用いて、中間層のニューロン数を15個として誤差2乗和に基づいて検討した。結果を図4に示す。学習回数が10000回以上であれば分類精度に違いが見られないことから、本研究における学習回数は10000回とした。

4. 実験結果

図5は各処理レベルにおける5カテゴリーの平均正答率(%)を大気モデルごとに示したものである。熱帯モデル(TM)では処理レベル3において、それ以外の5つの大気モデル(MLS, MLW, SAS, SAW, USS)では処理レベル2において平均正答率がほぼ100%に達しているのがわかる。

図6は、処理レベル2における物質ごとの分類結果である。3種類の岩石では、誤分類が見られないのに対し、針葉樹及び海水はその一部が互いに誤分類されている。

5. おわりに

熱赤外多重分光スキャナの疑似観測データにニューラルネットワークを適用した結果、今回与えた条件下では100%に近い高い分類精度が得られた。特に岩石は誤分類が見られなかった。これは今回選択した岩石(いずれも火成岩)が熱赤外波長域でそれぞれ特徴的なスペクトル特性を有するためと考えられる。また処理レベルと分類精度の関係性については大気の性質に依存することが明らかになった。熱帯モデル相当の温暖湿潤な大気では下向き放射照度の反射成分の補正処理において、それより寒冷乾燥な大気では透過率の補正処理においてそれぞれ十分な分類精度に達することが分かった。

参考文献

[1] Gilliespie, A. R., Enhancement of Multi-spectral Thermal Infrared Images: Decorrelation Contrast Stretching, Remote Sensing of Environment, 42, pp147-155, 1992
 [2] Salisbury, J. W. et al. Emissivity of Thermal Materials in the 8-14 μ m Atmospheric Window, Remote Sensing of Environment, 42, pp83-106, 1992.




図2 ニューラルネットワークモデル




図3 中間層数と誤差2乗和の関係 (処理レベル4)




図4 学習回数と誤差2乗和の関係 (処理レベル4)




図5 処理レベル及び大気モデルと平均正答率の関係

	花崗岩	安山岩	玄武岩	針葉樹	海水
花崗岩	100	0	0	0	0
安山岩	0	100	0	0	0
玄武岩	0	0	100	0	0
針葉樹	0	0	0	93.3	6.7
海水	0	0	0	6.7	93.3

図6 各カテゴリーの分類結果 (%) (処理レベル3)