

高次局所自己相関特徴の拡張による マルチスペクトル衛星画像上の地物認識

Object recognition on Multispectral Satellite Imagery with an Extended Feature of Higher-order Local Autocorrelation

上原和樹
Kazuki UEHARA

坂無英徳
Hidenori SAKANASHI

野里博和
Hirokazu NOSATO

村川正宏
Masahiro MURAKAWA

宮本寛気
Hiroki MIYAMOTO

中村良介
Ryosuke NAKAMURA

産業技術総合研究所
National Institute of Advanced Industrial Science and Technology

The Earth observation satellites have monitored surface of the Earth for a long time, and images taken by the satellites have vast amount of valuable data. However, it is quite hard work to analyze such a huge data manually. To facilitate efficient data analyzation, an automatic object recognition method for satellite image is needed. This paper describes a new texture feature derived from higher order local autocorrelation for object recognition on satellite imagery. In evaluation experiments, the method has improved recognition accuracy relative to the existing method.

1. はじめに

地球観測衛星は長期間にわたり地表の変化を観測し続けており、その観測データは土地利用計画や災害支援、気候変動モニタリングなど、非常に広い領域で活用されている。

しかし、これらのデータは広域に渡り継続的に蓄積されており、非常に膨大な量となるため人手による解析は困難である。このような膨大なデータ量について効率的な解析を行うためには、画像中の解析対象物(地物)を自動で認識できる手法が必要である。そこで本研究では、画像認識手法を衛星画像の地物認識に適用し、解析対象の自動検出を行う。

衛星画像は、可視域に加え近赤外域や熱赤外域といった周波数帯域(Band)で撮影された画像から構成され、一般的な画像より多くのチャンネルを持つ。物体は可視光以外においても固有のスペクトル反射・吸収特性を有しており、衛星画像の解析においては、チャンネル間演算といった解析対象の特性に応じた画像処理を施すことで解析対象を強調することができる。たとえば、植生の分布や活性度の指標として用いられる NDVI (Normalized Difference Vegetation Index) は、近赤外域と可視域赤で撮影された画像間の差分により計算されるが、これは植物の葉緑素が可視域赤の光を吸収し、近赤外域の光を反射するといったバンド間における反射率の急激な変化を利用したものである。

本稿では、このようなチャンネル間の相対的な関係を考慮して拡張した特徴量を提案し、本手法における衛星画像地物認識の有効性を確認する。画像特徴量としては様々なものが考えられるが、計算効率と認識精度の観点から高次局所自己相関(HLAC: Higher-order Local Auto-Correlation)特徴 [Otsu 1988] に着目した。HLAC 特徴は、積和演算のみで抽出できるため高速に特徴抽出ができ、衛星画像のような大規模な画像に対し有効であると考えられる。また、認識精度にも優れ、動画像中の異

常検知システムなどへの応用もなされている [Nanri 2005, Iwata 2007, Otsu 2011]。

2. 衛星画像

本研究では、Landsat 8 号により撮影された衛星画像を使用した。Landsat 8 号は、40 年以上続く Landsat 計画における最新の衛星であり、15m~100m の空間分解能で地表を観測し続けている。その観測画像は、可視光域に加え近赤外域や熱赤外域を含む 11Band の画像から構成されたマルチスペクトル画像である(表 1)。

これらのデータは無償で公開されており、撮影後、約2時間後には誰でも画像データを得ることができる。そのため、将来的な実利用の観点からも Landsat 画像における地物認識は有用である。

表 1 Landsat 画像の観測波長帯と空間解像度

Band	観測波長帯域	解像度
1	0.43-0.45 μ m	30m
2(可視光, 青)	0.45-0.51 μ m	30m
3(可視光, 緑)	0.53-0.59 μ m	30m
4(可視光, 赤)	0.64-0.67 μ m	30m
5(近赤外)	0.85-0.88 μ m	30m
6(短波長赤外)	1.57-1.65 μ m	30m
7(短波長赤外)	2.11-2.29 μ m	30m
8(パンクロマチック)	0.50-0.68 μ m	15m
9	1.36-1.38 μ m	30m
10(熱赤外)	10.60-11.19 μ m	100m
11(熱赤外)	11.50-12.51 μ m	100m

3. 提案手法

3.1 高次局所自己相関特徴

高次局所自己相関(HLAC)特徴は、局所的な形状特徴を表現でき、ノイズに対して頑健であるなどの特長がある。また、位置不変性や画面加法性といった画像認識において望ましい性質が知られており、様々な応用や拡張がなされている [Otsu 2011].

N 次の HLAC 特徴は式(1)で表され、参照点 $r = (x, y)$ とあらかじめ定義した局所近傍内の変位点 $a_i = (\Delta x, \Delta y)$ における輝度値間の積について、画像領域内で足し合わせて計算される。

$$x_N(a_1, \dots, a_N) = \sum f(r)f(r+a_1)\dots f(r+a_N) \quad (1)$$

ここで、 $f(r)$ は画像中の位置 r における輝度値を表す。次数の増加により表現可能なパターンは増えるが、それにつれ計算コストも増大する。そのため、実際に計算する場合は 2 次までを用いることが多い。

局所近傍を 3×3 、次数を 2 次までとした場合、参照点とその変位の組合せ(マスクパターン)は、マスク内の平行移動により同一視できるパターンを除くと図 1 のような 35 通りとなる。

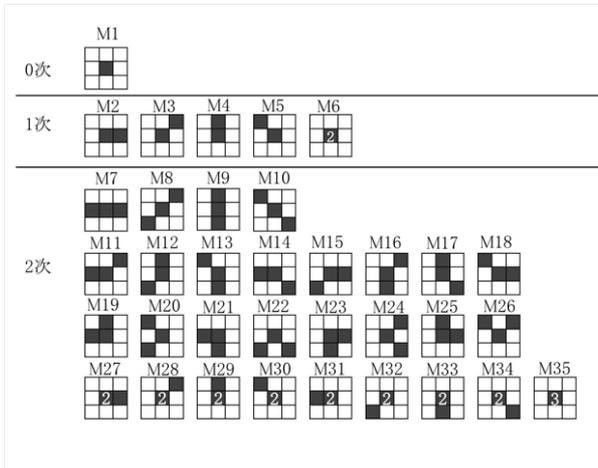


図 1 HLAC におけるマスクパターン マスク中の数字は同じ位置の画素を掛け合わせる回数を示す。

マスクにおける参照点間の間隔は最近傍である必要はなく、相関幅 m をパラメータとする $(2m+1) \times (2m+1)$ として定義できる。ただし、 m は 1 以上の整数とする。 m の値が小さい場合は局所的な形状特徴を抽出し、 m の値が大きくなるに従い大域的な形状特徴を抽出できる。つまり、相関幅を変えながら特徴を抽出して連結することで、異なる大きさの形状特徴を同時に抽出できる。

3.2 HLAC の多チャンネル拡張

衛星画像において各チャンネルは、各スペクトル帯での反射光を観測したものである。一般に、物体は固有のスペクトル反射・吸収特性を持つことが知られており、この特性を考慮して特徴抽出することで、より高精度な認識ができると考えられる。

そこで HLAC 特徴をチャンネル間で特徴抽出するよう拡張し(MUCHLAC: Multi-Channel HLAC)、参照点についての空間的な関係性だけでなく、スペクトル間における相対的な関係性を抽出する。これにより、波長間の複雑なパターンを考慮した特徴抽出が行える。具体的には、HLAC の 1 次以上について 2 つ(またはそれ以上)の点で異なるチャンネルを参照し、参照点と変位点の積を画像全体で足し合わせる。

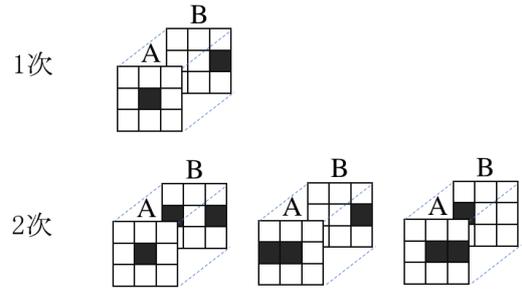


図 2 MUCHLAC のマスクパターン例

M 個のチャンネルより構成される多チャンネル画像から n 個のチャンネルを組合せて特徴抽出する場合、これら n チャンネルの順列を考慮したすべての組 $({}_M P_n)$ から特徴抽出を行う。

組合せチャンネル数を 2 とした場合における MUCHLAC の 1 次と 2 次のマスクパターン例を図 2 に示す。図 2 中における 1 次のパターン例は、図 1 の M2 に対応した拡張、2 次のパターン例は M7 に対応した拡張である。他のマスクについても同様に拡張する。

図中 A, B はそれぞれチャンネルを表す。チャンネル A の参照点に対する変位点は、A または B の中から選択する。このとき、少なくとも 1 点は異なるチャンネルを含むものとする。HLAC と同様、平行移動およびチャンネルの入れ替えにより等価なパターンを除くと MUCHLAC のマスクパターンは、1 次においては 5 パターン、2 次では 77 パターンとなる。たとえば、一般的なカラー(3ch)画像から 2 チャンネルまでの組合せ(6 通り)で抽出される MUCHLAC 特徴量は、597 次元 $(35 \times 3 + 82 \times 6)$ となる。

4. 実験

提案手法の有効性を確認するため、HLAC 及び MUCHLAC を用いて衛星画像における地物認識を行った。認識方法として、画像全体を小領域の窓(パッチ画像)で走査し、パッチ画像について対象を含むか否かの 2 クラス識別問題を解く。認識対象とする地物は、衛星画像上で形状の判断ができる大きさを持つゴルフ場とした。パッチ画像はサイズを 16×16 px で切り出し、ゴルフ場の一部が含まれる画像には正例、それ以外の領域から切り出された画像を負例とする(図 3)。

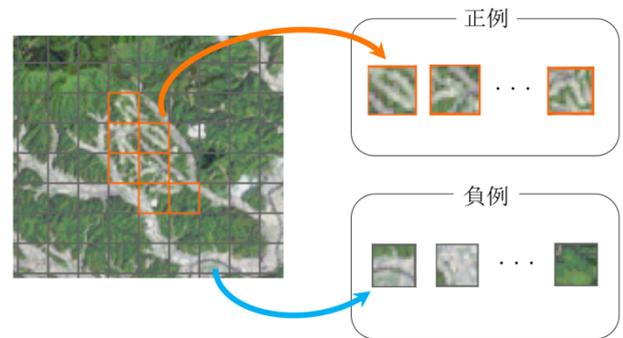


図 3 データセット作成イメージ

4.1 データセット

教師データおよび評価データとして、2015 年 5 月から 12 月までの間で、比較的雲の映り込みが少ない衛星画像についてゴルフ場の切り出しを行った。対象地域ならびに正例、負例の

数はそれぞれ表 2 の通りである。また、図 4 には学習、評価に用いた衛星画像の一例を示す。

表 2 学習・評価用データセット

対象シーン	地域	正例数	負例数
LC81070302015266	北海道央	858	16000
LC81080342015193	北陸	737	16000
LC81080362015353	東海	884	16000
LC81110362015294	中国・四国	967	16000
LC81130372015292	九州	751	16000

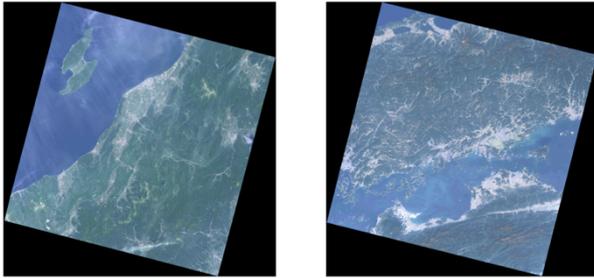


図 4 Landsat 画像例 (左)LC81080342015193 北陸地方, (右)LC81110362015294 中国・四国地方。

4.2 学習と評価方法

(1) 特徴量

HLAC の特徴抽出は、チャンネル、相関幅ごとに特徴量を算出し直列に連結する。MUCHLAC の特徴抽出においては、チャンネル、相関幅ごとに抽出した特徴量に加え、チャンネル間の組合せで抽出した特徴量を連結する。

特徴抽出には予備実験¹にて HLAC の認識精度が良好となるパラメータを選択した。特徴抽出に用いたチャンネルは Band2,3,4,5,6,7 とし、相関幅は 1 から 4 までを使用した。また、MUCHLAC における組合せは 2 チャンネルまでとした。いずれの特徴量も、回転・反転不変となるよう特徴量の再構成を行った [Nosato 2011]。

(2) 学習

学習には決定木を弱識別器とした Real AdaBoost [Schapire 1999] を用いた。決定木の深さは 3 までとし、弱識別器数は 500 とした。

(3) 評価方法

本稿では、4.1 節で作成したデータセットにおける 5 分割交差検証法により評価を行った。評価尺度には precision, recall, F-measure を用いる。precision は、すべての検出した結果のうち、真の検出対象が検出された割合を示し、recall は、すべての真の検出対象のうち、実際に対象が検出された割合を表す。F-measure は precision と recall の調和平均である。

4.3 分類結果

5 分割交差検証法により HLAC および MUCHLAC の精度評価を行った (表 3)。表 3 における TP は正例に対して正例と識別した数を表し、FP は負例に対して正例と識別した数を表す。TN は、負例に対して負例であると識別した数を表し、FN は正例に対して負例と識別した数を表す。表 3 より、すべての評価項目において提案手法が高い性能を示している。これより、MUCHLAC は見落としの数 (FN) を減らしつつ、正しく検出できた対象 (TP) の数が増えたことがわかる。

表 3 平均評価結果 (5 分割交差検証)

	HLAC	MUCHLAC
TP	541.8	586.6
FP	130.6	94.4
TN	15866.4	15902.6
FN	293	248.2
Precision	0.81	0.86
Recall	0.65	0.7
F-measure	0.72	0.77

5. 考察

MUCHLAC 特徴量は、各チャンネルとそのチャンネル同士の組合せから算出された特徴量の直列な連結により構成される。そのため、特徴量の各成分はチャンネル (またはチャンネルの組) とマスクパターンの組合せに対応する。MUCHLAC 特徴量は、同じチャンネルと相関幅から抽出された HLAC 特徴量の成分をすべて含むため、特徴成分の解析により、どのマスク (チャンネルや局所形状) が識別に効果的であったかがわかる。

そこで、複数チャンネルを組合せた特徴量による地物認識への寄与を確認するため、MUCHLAC の各特徴成分について Random Forest を用いた重要度の分析 [Breiman 2001] を行った。4.3 節の実験で用いた 5 試行分の特徴量における各成分の重要度について上位 100 成分を確認したところ、複数の組合せを使って抽出した特徴成分は平均で 95.8% を占めていた。

比較実験において認識精度が向上したこと、また、特徴成分の重要度解析においては認識に寄与した特徴成分の上位が複数の組合せで抽出した特徴量で構成されていたことから、複数チャンネル間の関係性を考慮した特徴抽出は有効だと考えられる。

6. おわりに

本稿では、衛星画像地物認識に有効な特徴量として、新たに多チャンネル拡張した高次局所自己相関特徴を提案した。本手法により、多チャンネル (スペクトル) 画像について、形状パターンに加えて異なる波長間の相対的なパターンを抽出することができる。評価実験においては衛星画像の地物認識を行い、複数チャンネル間における関係性を考慮した特徴量が有効であることを示した。

¹ 表 2 のデータセットとは異なる地域 (関東)、日付の Landsat 画像について、Band と相関幅を変えながら各組合せで 5 分割交差検証を行い、認識精度が良好となるパラメータを確認した。

謝辞

この成果は、国立研究開発法人新エネルギー・産業技術総合開発機構 (NEDO) の委託業務の結果得られたものです。

参考文献

- [Otsu 1988] N. Otsu and T. Kurita: “A new scheme for practical, flexible and intelligent vision systems, Proc. IAPR Workshop on Computer Vision, 1988.
- [Nanri 2005] T. Nanri and N. Otsu, “Unsupervised Abnormality Detection in Video Surveillance”, Conference on Machine Vision Applications, 2005.
- [Iwata 2007] K. Iwata, Y. Satoh, T. Kobayashi, I. Yoda and N. Otsu: “Application of the Unusual Motion Detection Using CHLAC to the Video Surveillance”, International Conference on Neural Information Processing, 2007.
- [Otsu 2011] N. Otsu: “ARGUS: Adaptive Recognition for General Use System -Its theoretical construction and applications-”, Synthesiology English edition, 2011.
- [Nosato 2011] H. Nosato, T. Kurihara, H. Sakanashi, et al.: “An Extended Method of Higher-order Local Autocorrelation Feature Extraction for Classification of Histopathological Images”, IPSJ TRANSACTIONS on Computer Vision and Applications, 2011.
- [Schapire 1999] R. E. Schapire and Y. Singer: “Improved Boosting Algorithms Using Confidence-rated Predictions”, Machine Learning, 1999.
- [Breiman 2001] L. Breiman, “Random Forests”, Machine Learning, 2001.