

# 機械学習を用いた可視・反射赤外スペクトルの 波長選択による鉱物含有率推定精度の向上

岸本 将英\*・久保 大樹\*・小池 克明\*

## Accuracy improvement of mineral composition by wavelength selection from visible-reflected infrared spectrum using machine learning

Masahide Kishimoto\*, Taiki Kubo\* and Katsuaki Koike\*

\*京都大学大学院工学研究科都市社会工学専攻 Department of Urban Management,  
Graduate School of Engineering, Kyoto University, Katsura C1-2-215, Kyoto 615-8540, Japan.  
E-mail: kishimoto.masahide.75z@st.kyoto-u.ac.jp (Kishimoto)

キーワード： リモートセンシング、スペクトル分解、バンド選択、機械学習、特徴量選択

Key words: Remote sensing, Spectral unmixing, Band selection, Machine learning, Feature selection

### 1. はじめに

地球観測衛星を利用したリモートセンシング画像は、金属鉱床や熱水変質鉱物を広域から検出できるように、兆候検出として広く利用されている。ハイパースペクトル画像では観測波長帯(バンド数)が多く、得られる情報量も多いため、地表物質の識別精度も高いといわれている。しかしながらこれらのデータには相関性が高く無関係な情報も含まれているため、解析において障害となる場合がある。この問題の解決手法として主成分分析(Principal Component Analysis: PCA)を代表とする特徴量抽出や機械学習で用いられる特徴量選択(バンド選択)といった次元削減が行われる。リモートセンシング画像解析の一つである地表面鉱物含有率推定においてバンド選択が行われる例は少なく、より詳細な評価が必要である。

また地球観測衛星によって撮影されたリモートセンシング画像において、ハイパースペクトル衛星画像が取得されている領域はマルチスペクトル衛星画像が取得されている領域と比較してはるかに少ない。バンド選択による地表面鉱物含有率推定の検証によってマルチスペクトル衛星画像が取得されている領域規模での高精度解析が期待される。

そこで本研究では、バンド選択による鉱物含有率推定精度の検証を目的として、スペクトルライブラリーデータの解析によって得られた選択バンドによってハイパースペクトル画像解析を行い、鉱物含有率推定結果と実際の鉱物含有率推定分布図との比較を行った。

### 2. 測定地域とデータの概要

本研究では、米国ネバダ州中部の Cuprite 地域を対象とした(第1図)。Cuprite 地域周辺は、特に乾燥した気候で植生が疎な砂漠地帯になっており、金銀銅を含む重要な鉱物の分布が知られている。Cuprite の表層地層は、カンブリア紀から第三紀までの様々な岩石からなり、その中でも明礬石やカオリナイトが分布する熱水変質帯が広範囲におよぶ (Hoang and Koike, 2017)。解析領域は東西 6.99 km、南北 7.78 km で、明礬石、白雲母、カオリナイト、石灰岩が

主に分布している。本研究ではこの四種類の鉱物を対象とし、バンド選択および地表面鉱物含有率推定の端成分に用いた。

解析には衛星搭載型ハイパースペクトルセンサ Hyperion により撮影された衛星画像を用いた。Hyperion は波長分解能が高く、356~2577 nm の波長域に 242 もの連続するバンドを有する。解析で用いたシーンは、2011 年 9 月 19 日に撮影されており、雲量は 0% である。

本研究ではバンド選択における使用データおよび鉱物含有率推定における端成分として米国地質調査所(United States Geological Survey: USGS)のスペクトルライブラリーを用いた。USGS のスペクトルライブラリーは、広く認知されているライブラリーで実験室において分光光度計によって得られた天然および人工物質のスペクトルから構成されている。同一鉱物について複数の反射スペクトルが収録されており、本研究では 400~2500 nm の範囲で幅 1 nm の resample を行い、データとした。端成分として用いる際には各鉱物の反射スペクトルの平均値を用いた。

### 3. 解析手法

#### 3.1 スペクトルライブラリーからのバンド選択

本研究ではバンド選択手法として連続体除去



第1図 Cuprite 地区の位置(左), Cuprite 地区の一般的な表面状態と Alunite hill(右)

(Continuum Removal: CR)を施した USGS のスペクトルライブラリデータに対し、機械学習で用いられる特徴量選択手法を応用した。機械学習で用いられる特徴量選択は Filter methods, Wrapper methods, Embedded methods の3つに大別される(Chandrashekar and Sahin, 2014)。本研究では機械学習モデルを使用せずにデータセットのみで完結する手法である Filter methods の一つに着目し、特徴量分布図から選択波長を決定した(第2図)。本研究では選択波長数を10と設定した。

### 3.2 ハイパースペクトル・マルチスペクトル画像解析

大気補正、不良バンド除去およびノイズ除去を含む前処理を施したスペクトル画像(バンド選択なし:155バンド, バンド選択あり:10バンド)に対し鉱物含有率推定を行った。本研究では一般的に鉱物含有率推定手法として用いられる線形分離(Linear Spectral Unmixing: LSU)のほかに、連続体除去を前処理として行った後に LSU を行う CR モデル, 自然対数除去に加えて連続体除去を前処理として行った後に LSU を行う LCR(Log Continuum Removal: Zhao, 2019) モデル, および反射スペクトルが地形や粒径によって乗法的に変化すると仮定し, その影響を変数として考慮した SCLSU(Scaled Constrained Least Squares Unmixing: Ibarrola-Ulzurru, et al., 2019)を適用した。

## 4. 含有率推定結果および考察

Hyperion 画像の全データ(155バンド)を用いた解析では, 地表で確認されているカオリナイトの存在を判別することができなかった。一方, 特徴量分布を基準にハイパースペクトルデータからバンド選択を行ったマルチスペクトルデータでは, SCLSU, LCR モデル, CR モデルにおいてカオリナイトの含有率を測定することができた。LCR モデルにおける比較を第4図に示す。LCR モデルでは明礬石, 方解石, 白雲母においても含有率推定を行うことが可能であり, これらの鉱物が推定された位置は, 第3図に示す USGS の鉱物分布図(Kruse, et al., 2015)とも整合的であった。以上の結果からバンド選択により含有率推定精度がバンド選択を行っていない場合と比較して同等以上であることが示された。含有率推定精度が向上した原因として, ミクセル内における端成分ではない物質のスペクトル吸収ピークによるスペクトル分離アルゴリズムへの影響の軽減が考えられる。

## 5. まとめと今後の課題


本研究ではバンド選択による鉱物含有率推定精度の検証を目的として, スペクトルライブラリデータの解析によって得られた選択バンドによってハイパースペクトル画像解析を行った。LCR モデルではバンド選択を行ったことで高精度な解析を行うことができると考えられる結果となった。本研究では特徴量分布図からピーク位置に対する波長を選択したが, バンド幅やバンド数をどのように設定するかについては, さらなる検証が必要である。

## 文 献


- Chandrashekar, G., Sahin, F. (2014) A survey on feature selection methods. *Computers and Electrical Engineering*, vol.40, no.1, pp. 16-28.
- Hoang, N. T., Koike, K. (2017) Transformation of Landsat imagery into pseudo-hyperspectral imagery by a multiple regression-based model with application to metal deposit-related minerals mapping. *ISPRS Journal of Photogrammetry and Remote Sensing*,

vol.133, pp.157-173.

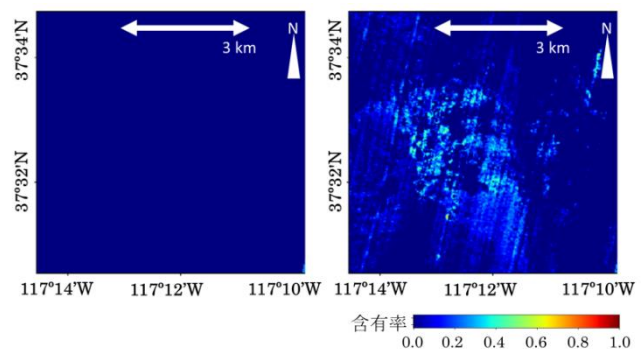
- Ibarrola-Ulzurrun, E., Drumetz, L., Marcello, J., Gonzalo-Martín, C., Chanussot, J. (2019) Hyperspectral Classification Through Unmixing Abundance Maps Addressing Spectral Variability. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, no. 7, pp. 4775–4788.
- Kruse, F. A., Baugh, W. M., Perry, S. L. (2015) Validation of DigitalGlobe WorldView-3 Earth imaging satellite shortwave infrared bands for mineral mapping. *Journal of Applied Remote Sensing*, vol.9, no.1, pp.1-17.
- Zhao, H. (2019) Nonlinear unmixing of minerals based on the log and continuum removal model. *European Journal of Remote Sensing*, vol.52, no. 1, pp.277-293.



第2図 スペクトルライブラリデータから得られた特徴量分布図と選択バンド



第3図 本研究の解析領域における地表鉱物分布 (Kruse, et al. (2015)より編集)



第4図 LCRモデルによる解析領域におけるカオリナイトの地表面鉱物含有率推定結果: バンド選択なしの場合(右)とバンド選択ありの場合(左)の比較