

非負値行列分解を用いた分光画像データ融合

横矢 直人[†] 矢入 健久^{††} 岩崎 晃^{††}

[†] 東京大学大学院 工学系研究科 航空宇宙工学専攻

^{††} 東京大学 先端科学技術研究センター

〒 153-8904 東京都目黒区駒場 4-6-1 先端研 4 号館

E-mail: †{yokoya,aiwasaki}@sal.rcast.u-tokyo.ac.jp, ††yairi@space.rcast.u-tokyo.ac.jp

あらまし 近年、次世代地球観測衛星センサとしてハイパースペクトルセンサの開発が各国で進められている。ハイパースペクトルセンサは、従来のマルチスペクトルセンサより波長分解能は高いが空間分解能は低い。本研究では、これら 2 つのセンサから得られる分光画像データを融合し、高解像度かつ高波長分解能な融合データを生成する手法として、連成非負値行列分解 (Coupled Non-negative Matrix Factorization: CNMF) を提案する。線形スペクトル混合モデルに基づき、非負値行列分解によって 2 つのデータを端成分スペクトルとその含有率マップに分解する。高波長分解能な端成分スペクトルと高解像度な含有率マップを組み合わせることで高解像度かつ高波長分解能な融合データを生成する。CNMF は、物理的に解釈しやすく、簡単に実装できる。人工データを用いたシミュレーションで既存手法との性能比較を行い、最後に実データへの適用例を示す。

キーワード ハイパースペクトルデータ, マルチスペクトルデータ, ミクセル分解, 非負値行列分解, データ融合

1. はじめに

複数の波長帯で観測画像を取得するマルチスペクトルセンサは、Landsat/ETM に代表されるように地球観測衛星センサとして広く用いられている。高度な資源探査や生態系モニタリングを実現するために、より波長分解能の高いハイパースペクトルセンサが次世代地球観測衛星センサとして各国で開発されている [1] [2] [3]。ハイパースペクトルセンサはライン状に地表を走査する際に分光画像を連続的に取得することで、400-2500nm の波長域を 150 以上もの波長帯で観測する (図 1)。観測画像中の各ピクセルにおいて連続的なスペクトルが得られるため、マルチスペクトルセンサより詳しく地表面の物性を把握できる。すなわち、植物や鉱物の種類を詳細に分類することが可能となる。

通常、ハイパースペクトルセンサの解像度はマルチスペクトルセンサよりも低い。例えば、日本の次世代地球観測衛星センサ Hyperspectral Imager Suite (HISUI) [3] はハイパースペクトルセンサとマルチスペクトルセンサを両方搭載しており、それらの主な性能は表 1 の通りである。マルチスペクトルセンサは空間分解能が高く、ハイパースペクトルセンサは波長分解能が高い。2 つのセンサの長所を併せ持つデータが得られると、より高解像度で詳細な分類が実現できる。本研究では、ハイパースペクトルセンサの波長分解能とマルチスペクトルセンサの空間分解能を併せ持つ融合データを作ることを目指す。以下、この技術をハイパーマルチスペクトルデータ融合と呼ぶ。

ハイパースペクトルデータは土地被覆分類への利用が

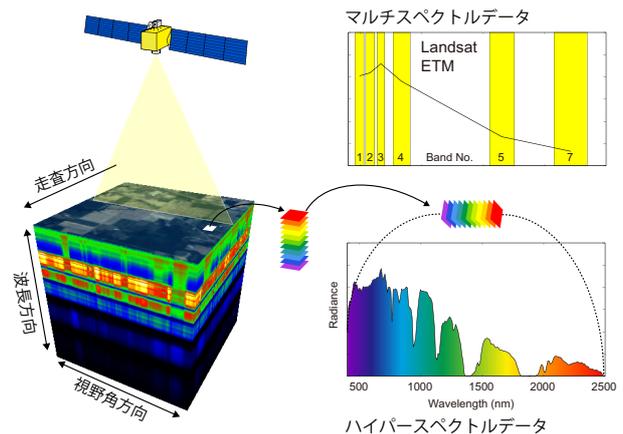


図 1 ハイパースペクトルデータとマルチスペクトルデータ

表 1 HISUI センサの主要性能

パラメータ	マルチスペクトルセンサ	ハイパースペクトルセンサ
観測刈幅	90km	30km
空間分解能	5m	30m
観測波長帯	0.45 - 0.52 μm 0.52 - 0.60 μm 0.63 - 0.69 μm 0.76 - 0.90 μm	0.4 - 0.97 μm (57 波長帯, 波長幅 10nm) 0.9 - 2.5 μm (128 波長帯, 波長幅 12.5nm)

一般的だが、豊富なスペクトル情報を活用するより高度な利用法として、ミクセル分解がある。解像度の低いハイパースペクトルデータの各ピクセルは複数の物質を含んでいるため、観測スペクトルはいくつかの純粋な物質の反射スペクトルが混合したスペクトルと考えられる。この現象をミクセル (Mixed Pixel) と呼ぶ (図 2)。純物質は、各スペクトル成分を変数とする多次元空間で多面体の頂点に位置することから、端成分 (Endmember) と呼ばれる。観測スペクトルを端成分スペクトルとその

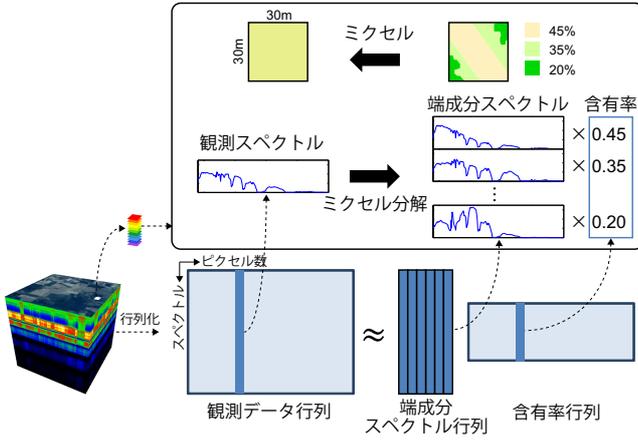


図 2 ミクセル分解と NMF

含有率に分解することをミクセル分解と呼ぶ (図 2)。

ハイパーマルチスペクトルデータ融合に有効な従来手法として, Eisman らが開発した MAP 推定に基づく手法がある [7] [8]。まず, Stochastic Mixture Model (SMM) [9] を用いて, ハイパースペクトル画像の分類を行う。この分類情報を基に, マルチスペクトルデータとハイパースペクトルデータが観測された条件下での, 未観測な高解像度ハイパースペクトルデータの事後確率分布を定式化する。この事後確率分布を最大化することで融合データを推定する手法である (以下 MAP/SMM を表記する)。この手法は, ハイパースペクトルデータを地表面の分類に活用しているが, ミクセル分解は考慮していない。

近年, ミクセル分解に関する研究がさかんに行われており, 特に, 非負値行列分解 (Non-negative Matrix Factorization: NMF) [10] [11] を用いた手法の有効性が実証されている [12] [13] [14]。NMF とは Lee と Seung によって考案された行列分解手法であり, 1 つの非負値行列 V を, $V \approx WH$ となるような 2 つの非負値行列 W と H に分解する手法である。ハイパースペクトルデータの観測値は全て非負であり, 端成分スペクトルと含有率も非負であるから, ハイパースペクトルデータを行列形式で書き表したとき, ミクセル分解は観測行列を端成分スペクトル行列と含有率行列に分解する NMF とみなせる (図 2)。本研究では, NMF を用いたミクセル分解に基づく新しいハイパーマルチスペクトルデータ融合手法として, 連成非負値行列分解 (Coupled Non-negative Matrix Factorization: CNMF) を提案する。CNMF は, ハイパースペクトルデータとマルチスペクトルデータを NMF によってミクセル分解し, ハイパースペクトルデータから得られる端成分スペクトル行列とマルチスペクトルデータから得られる含有率行列を掛け合わせることで, 高解像度なハイパースペクトルデータを生成する。人工データを用いたシミュレーションで既存手法 (MAP/SMM) との性能比較を行い, 最後に実データへの適用例を示す。

2. ハイパーマルチスペクトルデータ融合

観測されたハイパースペクトルデータを $X_h \in \mathbb{R}^{\lambda_h \times L_h}$, マルチスペクトルデータを $X_m \in \mathbb{R}^{\lambda_m \times L_m}$ と行列で表す。ここで, λ_h と λ_m はそれぞれの波長数 ($\lambda_h > \lambda_m$), L_h と L_m は画像のピクセル数を表す ($L_h < L_m$)。 X_h と X_m は同じ観測条件で同一のシーンを撮影したデータと仮定する。推定すべき高解像度ハイパースペクトルデータを $Z \in \mathbb{R}^{\lambda_h \times L_m}$ とする。

2.1 観測モデル

観測された低解像度ハイパースペクトルデータと推定する高解像度ハイパースペクトルデータは行列形式で以下のように関係づけられる。

$$X_h = ZS + N_h \quad (1)$$

$S \in \mathbb{R}^{L_m \times L_h}$ は 2 つのデータの空間分解能変換行列であり, 各列ベクトル $\{s_k\}_{k=1}^{L_h} \in \mathbb{R}^{L_m}$ が低解像度ハイパースペクトルセンサの k 番目ピクセルにおける点像分布関数を表す。 N_h は観測ノイズを示す。同様に, マルチスペクトルデータは以下のようにモデル化できる。

$$X_m = RZ + N_m \quad (2)$$

$R \in \mathbb{R}^{\lambda_m \times \lambda_h}$ は波長分解能変換行列であり, 各行ベクトル $\{r_i\}_{i=1}^{\lambda_m} \in \mathbb{R}^{\lambda_h}$ がマルチスペクトルセンサの i 番目波長帯における波長応答関数を表す。 N_m は観測ノイズを示す。

2.2 線形スペクトル混合モデル

線形スペクトル混合モデルは物理的解釈及び数学的定式化が容易なため, ミクセル分解によく用いられる。観測スペクトルはいくつかの端成分スペクトルの線形結合で表すことができることを仮定する。 X_h と X_m は以下のように表せる。

$$X_h = W_h H_h + E_h \quad (3)$$

$$X_m = W_m H_m + E_m \quad (4)$$

$W_h \in \mathbb{R}^{\lambda_h \times D}$ はハイパースペクトルデータの端成分スペクトル行列であり, 列ベクトル $\{(w_h)_j\}_{j=1}^D \in \mathbb{R}^{\lambda_h}$ は各端成分のスペクトルを示す。 D は端成分の数を表す。 $H_h \in \mathbb{R}^{D \times L_h}$ はハイパースペクトルデータの含有率行列であり, 列ベクトル $\{(h_h)_k\}_{k=1}^{L_h} \in \mathbb{R}^D$ は各ピクセルにおける端成分の含有率を示す。 $E_h \in \mathbb{R}^{\lambda_h \times L_h}$ は残差行列である。同様に, $W_m \in \mathbb{R}^{\lambda_m \times D}$, $H_m \in \mathbb{R}^{D \times L_m}$, $E_m \in \mathbb{R}^{\lambda_m \times L_m}$ は, それぞれマルチスペクトルデータの端成分スペクトル行列, 含有率行列, 残差行列を表す。端成分スペクトル行列と含有率行列の成分は全て非負値であり ($W_h \geq 0, H_h \geq 0, W_m \geq 0, H_m \geq 0$), 各ピクセルにおける含有率成分の和は 1 である ($\sum_{j=1}^D (h_h)_{j,k} = 1 (k = 1, 2, \dots, L_h), \sum_{j=1}^D (h_m)_{j,k} = 1 (k = 1, 2, \dots, L_m)$)。

2.3 CNMF

NMF を用いたミクセル分解は通常，線形スペクトル混合モデルにおける残差行列の Frobenius ノルム (3) と (4) においてはそれぞれ $\|E_h\|_F^2$ と $\|E_m\|_F^2$ をコスト関数とし，その最小化を行う．Lee と Seung が考案した乗法的更新式は，分解した 2 つの行列の全ての成分が非負であるという拘束条件のもとで，局所最適解に収束することが保証されている [11]． X_h と X_m の NMF ミクセル分解の乗法的更新式は以下の式で与えられる．

$$W_h \leftarrow W_h \cdot (X_h H_h^T) ./ (W_h H_h H_h^T) \quad (5)$$

$$H_h \leftarrow H_h \cdot (W_h^T X_h) ./ (W_h^T W_h H_h) \quad (6)$$

$$W_m \leftarrow W_m \cdot (X_m H_m^T) ./ (W_m H_m H_m^T) \quad (7)$$

$$H_m \leftarrow H_m \cdot (W_m^T X_m) ./ (W_m^T W_m H_m) \quad (8)$$

$(\cdot)^T$ は行列の転置を示し， \cdot と $./$ はそれぞれ成分ごとの乗算と除算を示す．各ピクセルにおける含有率成分の和を 1 とするために，Heinz らの提案手法 [15] を用いる．

含有率観測範囲が同じ場合，推定すべき高解像度ハイパースペクトルデータは，低解像度ハイパースペクトルデータと同じ端成分スペクトルを含んでおり，かつ，各ピクセルにおいてはマルチスペクトルデータと同じ含有率情報を有していると考えられる．したがって，高解像度ハイパースペクトルデータ (Z) は

$$Z \approx W_h H_m \quad (9)$$

と近似できる．(1)-(4) と (9) から，ミクセル分解によって 2 つのデータから得られる端成分スペクトル行列と含有率行列は

$$H_h \approx H_m S \quad (10)$$

$$W_m \approx R W_h \quad (11)$$

と関係づけられる．CNMF は，(10) と (11) で与えられる 2 つのセンサ特性間の拘束条件を満たしつつ，ハイパースペクトルデータ (X_h) とマルチスペクトルデータ (X_m) を NMF により交互に繰り返しミクセル分解する．CNMF の簡略化したイラストを図 3 に示す．

ハイパースペクトルデータの豊富なスペクトル情報を活かすために，CNMF は X_h のミクセル分解から始める．はじめに端成分の数 (D) を Virtual Dimensionality (VD) [16] を用いて適切な値に定め，Vertex Component Analysis (VCA) [17] によって求めた端成分スペクトル行列で W_h を初期化する．VCA は観測画像に純物質が含まれるという仮定に基づく端成分抽出手法の中では最も優れた手法の一つであり，NMF を用いたミクセル分解の初期化に有効であることが示されている [12]． H_h の全ての成分を定数 $1/D$ に初期化する．次に， W_h と H_h を (5)，(6) により収束するまで交互に繰り返し更新する．

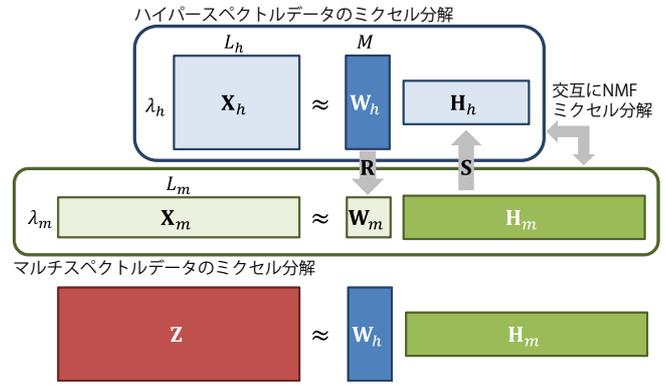


図 3 CNMF

ただし，最初の初期化フェーズでは W_h を固定し H_h だけ更新する． X_h の 2 回目以降の NMF ミクセル分解では，初期化フェーズのみ異なる．すなわち， H_h を (10) により初期化し， H_h を固定して W_h を (5) により収束するまで更新する．これは X_m をミクセル分解して得られた高解像度な含有率行列の情報を X_h のミクセル分解に組み込むためである．

CNMF のもう 1 つの過程は X_m のミクセル分解である．(11) を用いて W_m を初期化し， H_m の全ての成分を定数 $1/D$ に初期化する．初期化フェーズでは， W_m を固定し H_m を (8) で収束するまで更新する．これは X_h のミクセル分解で得られた端成分のスペクトル情報を引き継ぐためである．次に， W_m と H_m を (7) と (8) により収束するまで交互に繰り返し更新する．

ハイパースペクトルデータとマルチスペクトルデータのミクセル分解を，コスト関数が収束するまで交互に繰り返す．NMF は一般的に局所最適解に収束することが知られているが，CNMF は 2 つのデータの長所を，すなわち，ハイパースペクトルデータはスペクトル情報，マルチスペクトルデータは空間情報を，もう一方の NMF ミクセル分解の初期化に利用することでより良い局所最適解に収束する初期値に当たりを付けている．本手法は，適当な初期値から行う NMF よりも良い局所最適解に収束することが実験的にわかっている．収束条件の判定は，コスト関数の変化率がある閾値 ϵ より小さくなることとした．ただし，実用面を考慮して繰り返し回数の最大値を設定する．NMF 内の繰り返し計算と，交互に行う 2 つのミクセル分解という外側の繰り返し計算では，異なる閾値と繰り返し計算の最大回数を設定する必要がある．

3. HISUI シミュレーションデータへの適用

3.1 HISUI シミュレーションデータ

航空機ハイパースペクトルデータから HISUI のシミュレーションデータセットを作成し，提案手法を適用する．既存手法 (MAP/SMM) と比較することで CNMF の有効性を検証する．CASI (compact airborne spectrographic imager) センサによって 2008 年に北海道の元野

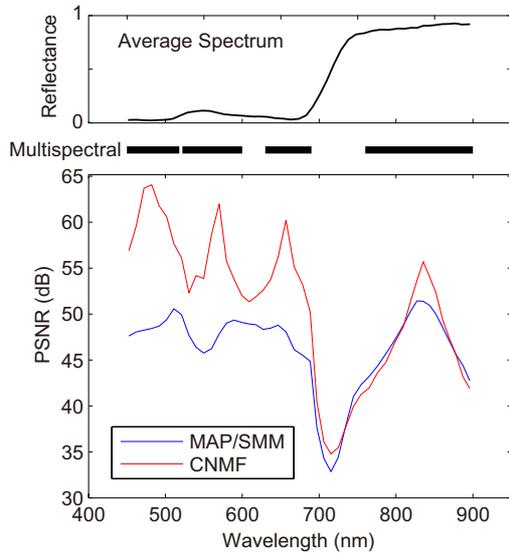


図 4 PSNR と観測画像の平均スペクトル

幌農場を撮影したデータを用いる．使用データの輝度値は反射率に変換されている．CASI は 1m 空間分解能で 400-1060nm を 68 の波長帯で観測できる．空間方向と波長方向にダウンサンプリングすることで，30m 空間分解能のハイパースペクトルデータと 5m 空間分解能のマルチスペクトルデータを作成する．また，融合結果の性能を評価するために，5m 分解能のハイパースペクトルデータも参照データとして作成する．2つのセンサの点像分布関数と波長応答関数はいずれも理想的な矩形関数を仮定し，センサ特性の関係を表す行列 S と R を事前に与える．

3.2 評価方法

提案手法の性能は，推定した融合データと参照データを2つの観点から比較することで評価する．1つは各波長帯画像の空間的再現性であり，もう1つは各ピクセルのスペクトル再現性である．空間的再現性の評価には Peak Signal-to-Noise Ratio (PSNR) を用いる． i 番目の波長帯における PSNR は以下の式で定義される．

$$\text{PSNR}_i = 10 \cdot \log_{10} \left(\frac{\max_i^2}{\sum_{k=1}^{L_m} (\mathbf{Z} - \mathbf{W}_h \mathbf{H}_m)_{i,k}^2 / L_m} \right) \quad (12)$$

\max_i は i 番目の波長帯画像の最大輝度値を示す．スペクトル再現性の評価には Spectral Angle Error (SAE) を用いる．SAE は波長数の次元における2つのスペクトル間の相対誤差角度であり，2つのスペクトルをベクトル \mathbf{a} と \mathbf{b} で表すとき

$$\text{SAE} = \arccos \left(\frac{\langle \mathbf{a}, \mathbf{b} \rangle}{\|\mathbf{a}\|_2 \cdot \|\mathbf{b}\|_2} \right) \quad (13)$$

で定義される．PSNR が高いほど空間的再現性が高く，SAE が小さいほどスペクトル再現性が高いといえる．

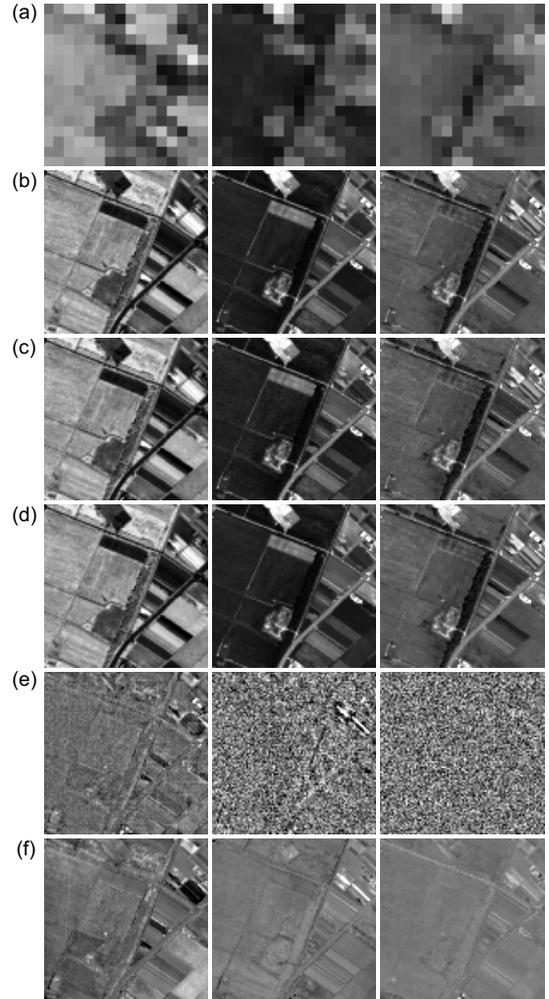


図 5 (a)30m 分解能ハイパースペクトルデータ，(b)5m 分解能ハイパースペクトルデータの参照データ，(c)MAP/SMM の推定結果，(d)CNMF の推定結果，(e) 参照データと MAP/SMM の差分，(f) 参照データと CNMF の差分．左から右は順に 765nm, 667nm, 560nm 波長帯の画像を示す．

3.3 シミュレーション結果

図 4 の下図は CNMF と MAP/SMM で得られた 5m 分解能ハイパースペクトルデータの参照データに対する PSNR を表す．図 4 の上図は観測画像の平均スペクトルを示す．多くの波長帯で CNMF は MAP/SMM と同等または優れた空間的再現性を示しており，全波長帯の平均 PSNR は表 2 の通りである．これは，CNMF が2つのデータから端成分スペクトルとその高解像度な含有率マップを正確に推定できていることを示す．特に可視光域で CNMF は MAP/SMM より優れた結果を示している．MAP/SMM はハイパースペクトルデータの上位主成分を使うため，上位主成分への寄与率が高い近赤外域に比べて可視光域の推定精度は低くなる．一方，CNMF は生データのミクセル分解に基づいているため，全波長域を高精度に推定できると考えられる．マルチスペクトルデータで観測できない波長域においては2つの手法は

共に再現性が低い．高解像度な情報が無い波長域でハイパースペクトルデータの解像度を上げることは難しいことがわかる．

図5は上から順に30m分解能ハイパースペクトルデータ，5m分解能ハイパースペクトルデータの参照データ，MAP/SMMで推定した結果，CNMFで推定した結果，参照データとMAP/SMMの差分，参照データとCNMFの差分を表す．左から右はそれぞれ765nm，667nm，560nm波長帯の画像を示す．差分画像は各波長帯毎に強調している．CNMFとMAP/SMMで推定した結果は共に，肉眼では参照データとの違いが判別できない．参照データとの差分画像では667nmと560nmに注目すると，CNMFの方が誤差が小さいことがわかる．ただし，MAP/SMMはランダムノイズに近いが，CNMFは観測画像のテクスチャが現れている．これは，MAP/SMMが確率論的アルゴリズムであり，観測モデルにおいてガウスノイズを仮定しているのに対して，ミクセル分解に基づくCNMFは観測物の種類毎に誤差が生じることに起因する．

図6にSAEのヒストグラムと分布マップを示す．観測画像全域の平均値は表2の通りであり，CNMFはMAP/SMMよりもスペクトルの歪みが小さいことがわかる．SAEが1度未満であることから，CNMF融合データは観測対象物の正確な検知及び分類に寄与できる波長性能を有しているといえる[18]．SAEマップは各波長帯画像の推定誤差と同様，MAP/SMMはランダムノイズに近い傾向があり，CNMFはテクスチャが現れる．CNMFの推定誤差は，植生と土壌のような土地被覆分類のクラス毎に生じるものの，各クラス内での分散は小さい．つまり，植生の品種分類のような高度分類には，ガウスノイズが生じるMAP/SMMよりCNMFの方が適していると考えられる．

3.4 MAP/SMM との関係

MAP/SMMはSMMを使って各ピクセルを最も含有率の高い端成分に分類し，各端成分の平均スペクトルと分散共分散行列を求める．これらの分類情報を基に， X_h と X_m が与えられたときの Z の条件付き確率分布関数を定式化し，これを最大化することで，高解像度ハイパースペクトルデータ(Z)を推定する．詳細な過程とMATLABのコードは[8]に記載されている．端成分スペクトルの分散共分散行列が特異にならないよう (i) ハイパースペクトルデータを主成分分析によって次元削減する (ii) 端成分の数を少数に抑える，という2点が提案手法と大きく異なる性質の違いを生んでいる (i) はMAP/SMMは反射率の低い波長帯で推定精度が良くないこと，推定したデータと参照データの差分画像がランダムノイズに近くなることに反映される (i) (ii) に対してCNMFは生のスペクトル空間で処理可能で，かつ，端成分の数を大きく設定できるため，全波長帯に渡って

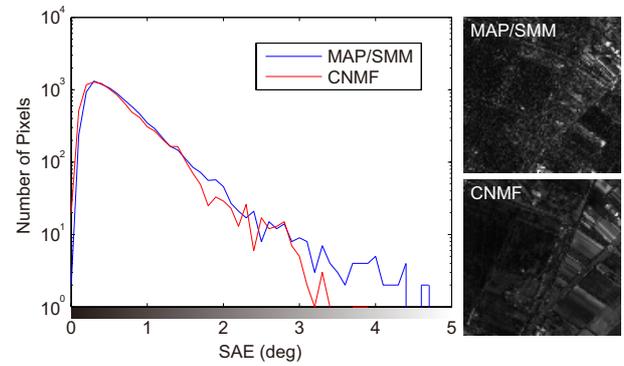


図6 SAEのヒストグラムと分布マップ

表2 PSNR(dB)とSAE(deg)の平均値

	MAP/SMM	CNMF
PSNR	46.2172	50.9278
SAE	0.73157	0.6598

精度高く融合データを推定できる．

4. 実データへの適用

4.1 ASTERとHyperion

実衛星データを用いて提案手法の有効性を検証する．ASTERセンサとHyperionセンサによって得られた輝度値データを用いる．ASTERセンサは1999年にNASAが打ち上げたTerra衛星に搭載されたマルチスペクトルセンサである．可視バンドから熱赤外バンドまでに14の波長帯を有しており，特に，可視近赤外放射計(Visible and Near-infrared Radiometer: VNIR)は15m空間分解能である．Hyperionセンサは2000年にNASAが打ち上げたEO-1衛星に搭載されたハイパースペクトルセンサである．30m空間分解能で，可視バンドから近赤外バンドを198の波長帯で観測している．異なるセンサによって得られる観測画像を融合する際，太陽照射条件や大気条件が同じであることが望ましい．ASTERとHyperionは同一軌道にある．今回用いるデータは2002年7月31日(ASTER:午前11時5分，Hyperion:午前10時35分)にSan Francisco/USAを撮影したものであり，2つのデータの観測時間差は30分であることから，観測条件はほぼ等しいとする．HyperionのVNIRデータ(30m空間分解能，50波長帯)とASTERのVNIRデータ(15m空間分解能，3波長帯)を融合する．テンプレートマッチングを用いて2つの画像データセットの位置合わせを行い S を求める． R は図7に示すASTERとHyperionの波長応答関数から求められる．マルチスペクトルデータ p_0 番目波長帯に対するハイパースペクトルデータ q_0 番目波長帯の寄与率 R_{p_0, q_0} は以下の式で与えられる．

$$R_{p_0, q_0} = \frac{\int f_{m, p_0}(\lambda) f_{h, q_0}(\lambda) d\lambda}{\sum_q \int f_{m, p_0}(\lambda) f_{h, q}(\lambda) d\lambda} \quad (14)$$

ここで， λ は波長変数， f_{m, p_0} はマルチスペクトルセン

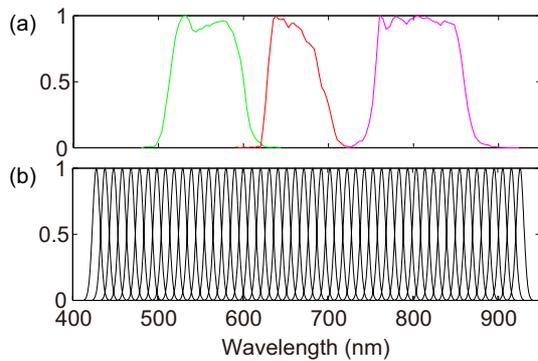


図7 (a)ASTER と (b)Hyperion の波長応答特性

サ p_0 番目波長帯の波長応答関数, f_{h,q_0} はハイパースペクトルセンサ q_0 番目波長帯の波長応答関数を示す. \mathbf{R} を使って Hyperion データから作った 30m 空間分解の疑似 ASTER データに対し, ASTER データの各波長帯画像をヒストグラム補正を行うことで, 2つのセンサの輝度特性誤差を補正する.

4.2 適用結果

図8にCNMFを用いたASTERとHyperionの融合結果を示す. 上段がHyperionデータ, 下段が融合データである. 拡大図からわかるように, 画像が鮮明になり, 道や建物を判読できるようになった. 図9の左から右にそれぞれ $(R,G,B) = (528,498,457)$, $(681,660,630)$, $(854,813,762)$ [nm] のRGB画像を示す. ASTERの同一波長帯でも観測物のスペクトル特性が異なることがわかる. ASTERの空間分解能とHyperionの波長分解能を引き継ぐ融合データによって, 高解像度で詳細な観測物の分類が可能になる. ASTERデータとHyperionデータの交互的なNMFミクセル分解は, コスト関数がある程度収束すると振動し始める. これは, CNMFは2つのデータの観測条件が同じであることを仮定しているが, ASTERとHyperionは観測条件が異なるため, センサ特性の関係を表す \mathbf{R} と \mathbf{S} の誤差が大きくなったことが原因と考えられる. このため, 交互的なNMFミクセル分解の繰り返し回数は2回とした. 異なるセンサから得られる2つのデータを融合する際, 両方の利点を活かせると同時にセンサ由来のノイズや観測条件の差異も引き継ぐ可能性もあるので, 前処理やセンサ特性の関係を正確に推定することが重要になる. 次世代地球観測衛星センサHISUIでは, 2つのセンサの観測条件が全く同じであるため, この実学的問題は緩和される.

5. むすび

ミクセル分解を用いてハイパースペクトルデータとマルチスペクトルデータを融合する手法として連成非負値行列分解(CNMF)を提案した. NMFミクセル分解を用いてハイパースペクトルデータから端成分スペクトル行列を, マルチスペクトルデータから端成分の高解像度

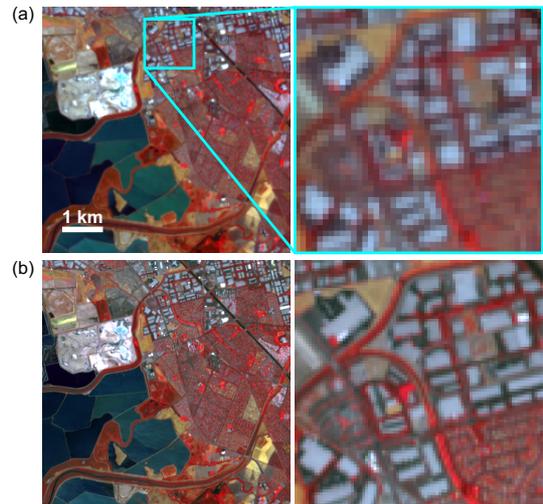


図8 (a)Hyperion データと (b)CNMF 融合データ RGB (854,702,549) [nm]

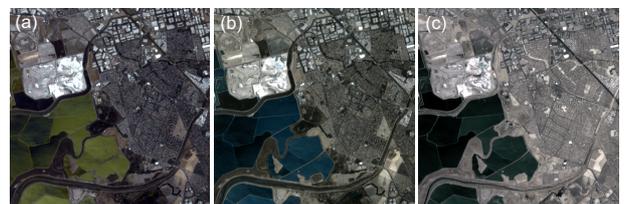


図9 ASTER 同一波長帯のRGB画像 (a)RGB (528,498,457) [nm], (b)RGB (681,660,630) [nm], (c)RGB (854,813,762) [nm]

な含有率行列を推定し, それらを掛け合わせると高解像度ハイパースペクトルデータが得られる. 2つのセンサ特性の関係をNMFの初期化に用いることで, 2つのセンサの利点を活かしつつ, より最適なNMFの局所最適解を求める. 本手法は物理的解釈が容易であると同時に, 単純な更新式に基づいているため実装も簡単である. 日本の次世代地球観測衛星センサHISUIをシミュレーションした人工データセットにCNMFを適用し, 従来手法(MAP/SMM)と比較したところ, 提案手法は従来手法と同等または優位な結果を示した. また, 地球観測衛星センサASTERとHyperionのデータセットを用いて実データへの適用例を示した. 実データでは観測条件を揃え, 2つのセンサ特性の関係を正確に求める必要がある. 本手法はHISUIの高次データプロダクト生成に利用可能であり, 生成される高解像度ハイパースペクトルデータによって観測物を高解像度で詳細に分類することができる.

文 献

- [1] B. Sang, J. Schubert, S. Kaiser, V. Mogulsky, C. Neumann, K.-P. Forster, S. Hofer, T. Stuffer, H. Kaufmann, A. Muller, T. Eversberg, C. Chlebek, "The EnMAP hyperspectral imaging spectrometer: instrument concept, calibration and technologies," Proc. SPIE, Vol. 7086, pp. 708605-1-15 (2008).
- [2] N. Ohgi, A. Iwasaki, T. Kawashima, and H. Inada,

- “Japanese hyper-multi spectral mission,” Proc. IEEE IGARSS, pp. 3756–3759, Honolulu, HI, (2010).
- [3] C. Galeazzi, A. Sacchetti, A. Cisbani, G. Babini, “The PRISMA program,” Proc. IEEE IGARSS, vol. 4, pp. IV-105–108, Boston, MA, (2008).
- [4] L. Alparone, L. Wald, J. Chanussot, C. Thomas, P. Gamba, and L. M. Bruce, “Comparison of pansharpening algorithms: Outcome of the 2006 GRS-S data fusion contest,” IEEE Trans. Geosci. Remote Sens., vol. 45, no. 10, pp. 3012–3021, Oct. (2007).
- [5] Q. Du, N. Younan, R. King, and V. Shah, “On the performance evaluation of pan-sharpening techniques,” IEEE Geosci. Remote Sens. Lett., vol. 4, no. 4, pp. 518–522, Oct. (2007).
- [6] R. Gomez, A. Jazaeri, and M. Kafatos, “Wavelet-based hyperspectral and multi-spectral image fusion,” Proc. SPIE, vol. 4383, pp. 36–42, (2001).
- [7] M. T. Eismann and R. C. Hardie, “Hyperspectral resolution enhancement using high-resolution multispectral imagery with arbitrary response functions,” IEEE Trans. Geosci. Remote Sens., vol. 43, no. 3, pp. 455–465, Mar. (2005).
- [8] M. T. Eismann, “Resolution enhancement of hyperspectral imagery using maximum a posteriori estimation with a stochastic mixing model,” Ph.D. dissertation, Univ. of Dayton, Dayton, OH, May (2004).
- [9] M. T. Eismann and R. C. Hardie, “Application of the stochastic mixing model to hyperspectral resolution enhancement,” IEEE Trans. Geosci. Remote Sens., vol. 42, no. 9, pp. 1924–1933, Sep. (2004).
- [10] D. D. Lee and H. S. Seung, “Learning the parts of objects by nonnegative matrix factorization,” Nature, vol. 401, pp. 788–791, Oct. (1999).
- [11] D. D. Lee and H. S. Seung, “Algorithms for non-negative matrix factorization,” in Proc. Conf. Adv. Neural Inf. Process. Syst., vol. 13, pp. 556–562, (2001).
- [12] L. Miao and H. Qi, “Endmember extraction from highly mixed data using minimum volume constrained nonnegative matrix factorization,” IEEE Trans. Geosci. Remote Sens., vol. 45, no. 3, pp. 765–777, Mar. (2007).
- [13] S. Jia and Y. Qian, “Constrained nonnegative matrix factorization for hyperspectral unmixing,” IEEE Trans. Geosci. Remote Sens., vol. 47, no. 1, pp. 161–173, Jan. (2009).
- [14] A. Huck, M. Guillaume, and J. Blanc-Talon, “Minimum dispersion constrained nonnegative matrix factorization to unmix hyperspectral data,” IEEE Trans. Geosci. Remote Sens., vol. 48, no. 6, pp. 2590–2602, Jun. (2010).
- [15] D. C. Heinz and C.-I Chang, “Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery,” IEEE Trans. Geosci. Remote Sens., vol. 39, no. 3, pp. 529–545, Mar. (2001).
- [16] C.-I Chang and Q. Du, “Estimation of number of spectrally distinct signal sources in hyperspectral imagery,” IEEE Trans. Geosci. Remote Sens., vol. 42, no. 3, pp. 608–619, Mar. (2004).
- [17] J. M. P. Nascimento and J. M. B. Dias, “Vertex component analysis: A fast algorithm to unmix hyperspectral data,” IEEE Trans. Geosci. Remote Sens., vol. 43, no. 4, pp. 898–910, Apr. (2005).
- [18] S. Cook, J. Harsanyi, and V. Faber, “Evaluation of algorithms for compressing hyperspectral data,” Proc. SPIE, vol. 5234, pp. 712–717, (2004).