ハイパースペクトルイメージングと最適化 —復元と合成—

Hyperspectral Imaging via Optimization :
Restoration and Fusion

小野峻佑 Shunsuke ONO

アブストラクト ハイパースペクトル (HS) 画像は紫外線領域から近赤外線域までの広い波長 (スペクトル) 帯の情報を細かく分光イメージングすることで取得される空間 (二次元)–スペクトル (一次元) の 3D データであり, 人間の目や既存の RGB カメラでは捉えられなかった物理的性質や現象を可視化できる。しかし, 空間–スペクトル情報を完全に取得することは計測環境/光学的設計の観点から困難なことが多く, 計測の際に生じるノイズなどによる劣化も避けられない。本稿では, 最適化を活用することで不完全かつ劣化を伴う計測データから所望の HS 画像を推定する技術について解説する。

キーワード ハイパースペクトルイメージング, ハイパースペクトル画像復元, ハイパースペクトル画像合成, 最適化, 正則化

Abstract Hyperspectral (HS) imagery provides 3D data that contains both spatial (two-dimensional) and spectral (one-dimensional) information acquired by spectroscopic imaging in a wide range of wavelengths from ultraviolet to near-infrared. HS images can visualize physical properties and phenomena that cannot be captured by the human eye or RGB cameras. However, capturing complete spatial–spectral information is often difficult because of the limitations of the optical design and/or measurement conditions. In addition, it is also difficult to avoid degradation due to various types of noise arising in the measurement process. In this paper, we review optimization-based techniques for effectively estimating the desired HS image from such incomplete and degraded measurement data.

Key words Hyperspectral imaging, hyperspectral image restoration, hyperspectral data fusion, optimization, regularization

1. はじめに

ハイパースペクトル (HS) イメージングは, 紫外線領域から近赤外線域までの広い波長 (スペクトル) 帯において, スペクトル情報を詳細に分光イメージングする技術である。結果として得られる HS 画像は, 二次元の空間情報に加え三次元方向に波長情報を有した 3D データとなる (図 1)。そのバンド数は 100 を優に超え, 人間の目や既存の RGB カメラでは捉えられない物質的な性質や現象を可視化できるため, リモートセンシング, 精密農業, 食品生産, 環境モニタリング, 鉱物学, 犯罪科学, 化学イメージング, 天文学, バイオテクノロジーなどの様々な分野において鍵となるイメージング技術である^{(1), (2)}。

しかし, 通常のカラー画像と異なり, 所望の HS 画像 (=劣化のない高解像度の空間–スペクトル情報) を光学的な装置のみで計測することは撮像環境/ハードウェア設計の観点から現実的ではないことが多い。主な理由を以下に列挙する。

- 低光量計測による S/N 比の低下
- 空間分解能とスペクトル分解能の間のトレードオフ

図 1 ハイパースペクトル (HS) 画像

- リモートセンシング環境下におけるセンサ不良など
すなわち, 高品質な HS イメージングを実現するためには, 計測した生データから所望の HS 画像を復元するための情報技術が必要不可欠であるといえる。

また, 従来のスキャン方式の HS イメージングでは, 空間–スペクトル情報を一度に計測するスナップショット撮影が原理的にできない^(注1)。一方, 分光フィルタを利用したスナップショット方式のスペクトルカメラも存在するが, 数十バンド程度の計測が限界である。そのため, 100 バンドを超える HS 画像のスナップショット計測を実現するためには, 取得したい空間–スペクトル情報 (三次元) を符号化開口などを用いて二次元に射影

(注1)：一次元のラインスキャンを繰り返す方法や, 特定のスペクトルのみを通過させる光学的フィルタを次々に入れ替える方法などが一般的だが, そのどちらも固定された計測対象を一定時間撮影する必要がある⁽³⁾。

し、そこから HS 画像を復元する必要がある^{(4) (注2)}。

上記のような HS 画像復元問題は本質的に不良設定/悪条件の逆問題であるため、計測モデルとデータのみから良好な復元結果を得ることはできない。これを解決する有力なアプローチとして、HS 画像に関する事前知識（例えば空間的な滑らかさやスペクトル方向の相関など）を数理的にモデル化した指標—正則化と呼ばれる—を設計し、これを取り入れた最適化問題の解として復元 HS 画像を特徴づける手法が数多く研究されている⁽⁶⁾。

また、高（空間）解像度のパンクロマティック画像（PAN 画像）やマルチスペクトル（MS）画像を用意し、空間解像度の低い HS 画像と合成することで、空間-スペクトルともに高解像度な HS 画像を取得する技術（PAN 画像の場合は HS pansharpening, MS 画像の場合は HS-MS data fusion と呼ばれる）も盛んに研究されている^{(7), (8)}。こちらは同一シーンを複数の計測手段で撮影する必要があるが、そのぶん、より高品質な HS 画像を得ることができる。当然、ここでも正則化は非常に有効であり、事前知識と計測情報の両方を柔軟に活用するための方法として最適化が重要な役割を果たすこととなる。

以上をふまえ本稿では、計測データから所望の HS 画像を推定するための情報技術について、特に最適化に基づくアプローチを中心として解説する。2. 節では、劣化を伴う計測データや不完全な情報から HS 画像を復元する技術について、正則化に焦点を当てながら解説する。3. 節では、最適化に基づく HS 画像合成手法を幾つか紹介する。4. 節で本稿をまとめる。

本稿では、空間解像度が $N_1 \times N_2$ （画素数を $N := N_1 N_2$ で表す）、スペクトルバンド数が B の HS 画像を、そのままキューブデータとして扱う場合は $\mathbf{U}$ 、各バンドの要素をラスタスキャンしバンドごとにベクトル化した $\mathbf{u}_i \in \mathbb{R}^N$ ($i = 1, \dots, B$) を横に並べた $N \times B$ 行列として扱う場合は $\mathbf{U}$ 、全ての $\mathbf{u}_i$ を縦に連結して NB 次元ベクトルとして扱う場合は $\mathbf{u}$ と表記し、状況に応じて使い分ける。ユークリッド空間 $\mathbb{R}^M$ のベクトル $\mathbf{x} = (x_1, \dots, x_M)^\top$ に対して、その ℓ_2 ノルムを $\|\mathbf{x}\|_2 := \sqrt{\sum_{i=1}^M x_i^2}$ 、 ℓ_1 ノルムを $\|\mathbf{x}\|_1 := \sum_{i=1}^M |x_i|$ とする。また、混合 $\ell_{1,2}$ ノルムを $\|\mathbf{x}\|_{1,2} := \sum_{k=1}^K \|\mathbf{x}_k\|_2$ と表記する。ただし、 $\mathbf{x}_k$ は $\mathbf{x}$ の k 番めの重複のないサブベクトル ($k = 1, \dots, K \leq M$) である。また、行列は太字の大文字 $\mathbf{X} \in \mathbb{R}^{M_1 \times M_2}$ で表し、そのフロベニウスノルム（各要素の 2 乗和の平方根）を $\|\mathbf{X}\|_F$ 、核ノルム（特異値の総和）を $\|\mathbf{X}\|_*$ と表記する。

2. ハイパースペクトル画像復元

現実世界の HS 計測では、撮像技術・システム・環境など様々な要因による計測データの劣化を避けることができない。特に、リモートセンシングにおける HS カメラの計測値は、大気の影響や熱ノイズ（ジョンソンノイズ）・量子化ノイズ・ショットノイズ（光子ノイズ）などの様々なノイズにより汚染される。このような劣化は、HS データを用いる解析に大きく影響を与えるため、事前に除去しておく必要がある⁽⁹⁾。また、符号化開口

スナップショット分光撮像（coded aperture snapshot spectral imager, CASSI）⁽⁴⁾に代表される圧縮センシングに基づく HS 計測では、元の HS 画像の次元よりも遥かに少ないランダム射影データから HS 画像を再構成する必要がある。

2.1 問題設定

まず、HS 画像復元の一般的な問題設定を導入する。次のような HS 画像の計測モデルを考える。

$$\mathbf{v} = \Phi \mathbf{u} + \mathbf{n} + \mathbf{s} \quad (1)$$

ただし、 $\mathbf{u} \in \mathbb{R}^{NB}$ は所望の HS 画像、 $\Phi \in \mathbb{R}^{K \times NB}$ は計測過程を記述する行列、 $\mathbf{n} \in \mathbb{R}^K$ は白色ガウシアンノイズ、 $\mathbf{s} \in \mathbb{R}^K$ はスパースノイズ、 $\mathbf{v} \in \mathbb{R}^K$ は得られる計測データベクトルである。行列 Φ は、単なるノイズ除去問題を考える場合は単位行列、符号化開口を利用した圧縮計測を想定する場合は二次元データへの射影行列となる。スパースノイズは、HS 計測において頻繁に生じる線状のノイズやセンサエラーによる欠損をモデル化したものである^(注3)。

上記のモデルに基づいた上で、最適化を利用した HS 画像復元問題は一般に以下のように定式化される。

$$\min_{\mathbf{u}, \mathbf{s}} R(\mathbf{u}) + \rho \|\mathbf{s}\|_1 + \frac{\lambda}{2} \|\mathbf{v} - \Phi \mathbf{u} - \mathbf{s}\|^2 \quad (2)$$

ここで、第一項の関数 R は HS 画像に対する正則化、第二項はスパースノイズの特徴づけ^(注4)、第三項はガウシアンノイズを考慮した計測データとの整合性（2 乗誤差）をそれぞれ表している。関数 R が凸関数であれば、問題 (2) は凸最適化問題^(注5)になり、大域的最適解（＝復元 HS 画像）の効率的な求解が見込める。ただし、実際の応用においては、大域的最適性を犠牲にしても凸ではない正則化を利用したほうが性能が向上するケースも存在する。

問題 (2) の求解には、正則化 R の構造にもよるが、微分できない目的関数や制約条件を含む最適化問題を効率的に解くことができる近接分離型の最適化アルゴリズム^{(11), (12)}が用いられることが多い。本稿ではアルゴリズムの説明には立ち入らず、正則化の定式化とその意味に焦点を当てて解説する。アルゴリズムの適用方法や具体的な計算手順に興味のある読者は、以下で紹介する各手法の論文や、手前味噌ではあるが近接分離アルゴリズムの解説記事⁽¹³⁾などを参考にされたい。

2.2 全変動に基づく正則化

代表的な HS 画像用の正則化として、全変動（total variation, 隣接成分間の差分のノルム）に基づくものが存在する。一般に、

(注3)：厳密には線状ノイズや欠損は計測値の上書きに相当するが、近似的に加算型のスパースノイズとして扱う。

(注4)： ℓ_1 ノルムは、スパース性のある程度良好に評価できる凸関数として、主に圧縮センシングなどの文脈で広く用いられている⁽¹⁰⁾。

(注5)：凸関数と凸集合を用いて定義される凸最適化問題は、局所最適解が自動的に大域的最適解になるため、筋のよい最適化問題のクラスとして幅広く認識されている。

(注2)：圧縮センシング理論⁽⁵⁾に依拠する。

図2 各正則化手法による復元結果 元画像の画素値は $[0, 1]$ に正規化. 評価指標は PSNR [dB].
白色ガウシアンノイズの標準偏差: 0.1, スパースノイズの割合: ごま塩ノイズ 5% + 線状ノイズ 5%

HS 画像は空間方向とスペクトル方向の両方に一定の (区分的) 滑らかさを有する. この性質を数学的にモデル化したものが全変動に基づく正則化である. 全変動に基づく正則化は隣接差分を計算する線形作用素とノルムによって構成される凸関数となるため, 計算量・最適性の両方の観点で都合がよい. 歴史的には, 元々グレースケール画像用の正則化手法として提案され⁽¹⁴⁾, その後カラー画像用への拡張が数多く行われた^{(15)~(18)}. これに追随するように HS 画像用の拡張も検討されており, 以下でその幾つかを紹介する.

2.2.1 Hyperspectral Total Variation (HTV)

最も基本的なものが, カラー画像用の全変動の一つである color total variation⁽¹⁵⁾ を HS 画像用に一般化した hyperspectral total variation (HTV)⁽¹⁹⁾ である. HS 画像 $\mathbf{u}$ に対して縦方向と横方向の空間隣接差分を計算する線形作用素 (行列) をそれぞれ $\mathbf{D}_v$, $\mathbf{D}_h$ と表し^(注6), それらを縦に並べたものを $\mathbf{D} = (\mathbf{D}_v^\top \mathbf{D}_h^\top)^\top$ とする. これを用いて HTV は以下のように定義される.

$$\text{HTV}(\mathbf{u}) := \|\mathbf{D}\mathbf{u}\|_{1,2} \quad (3)$$

ここで, $\ell_{1,2}$ ノルムの各グループベクトルは, 一つの画素に関する縦・横の空間隣接差分を全てのバンドについて集めたもので構成される (すなわち, 各グループベクトルは「差分をとる方向の数 $\times$ バンド数」で $2B$ 次元となる). 見方を変えると, 一つの画素に関する空間隣接差分をスペクトル方向に ℓ_2 ノルムでまとめた後, 各画素に関して ℓ_1 ノルムでまとめる構造になっている

る. ゆえに, 空間隣接差分値のスパース性 (= 空間情報の区分的平滑性) を, スペクトル方向の均一性を考慮しながら評価する指標であるといえる. オリジナルの全変動⁽¹⁴⁾ を素直に拡張したシンプルな設計になっている HTV であるが, スペクトル方向の相関を考慮しないまま空間的な平滑化をかけるため, 復元の際に詳細情報が潰れてしまうという欠点がある (図 2 (b))^(注7).

2.2.2 Spatio-Spectral Total Variation (SSTV)

空間隣接差分のスペクトル方向の相関を取り入れたものとして, spatio-spectral total variation (SSTV)⁽²⁰⁾ が提案されている. スペクトル方向に隣接差分を計算する作用素を $\mathbf{D}_s$ とすると, SSTV は以下で与えられる.

$$\text{SSTV}(\mathbf{u}) := \|\mathbf{D}\mathbf{D}_s\mathbf{u}\|_1 \quad (4)$$

定義からも分かるように, SSTV は, まずスペクトル隣接差分を計算し, その後に空間隣接差分をとったものを ℓ_1 ノルムでまとめている. これにより, 隣接バンド間で類似の空間的構造をもつ詳細成分を保存しながら平滑化をかけることができる. しかし一方で, 連続したバンドの同一画素に生じた欠損やノイズに対する平滑化能力が乏しいため, 復元に用いた際に望ましくないアーティファクトが残存することがある (図 2 (c)). また, SSTV は (変則的な) 二階差分により次元が二つ落ちているため, 解をしばる能力が一階差分を利用するほかの全変動ベースの正則化に比べて乏しく, 最適化の際の収束が (特に計測データの次元が HS 画像の次元に比べて著しく少ない場合に) 不安定になってしまうという欠点も存在する.

(注6): ただし, 縦方向は上の画素, 横方向は左の画素との差分をとり, 画像端の処理はノイマン境界条件に従うものとする.

(注7): この欠点がある程度解消するために, 文献(19)では, 各バンドに対応する正の重みを導入し, これを適応的に変化させるアプローチを提案している. しかし, 最適化やパラメータ設定が複雑になる, 安定性を欠くといったデメリットも生じる.

2.2.3 Anisotropic Spatio-Spectral Total Variation (ASSTV)

空間隣接差分に加えてスペクトル隣接差分を直接評価するものとして, anisotropic spatio-spectral total variation (ASSTV) ⁽²¹⁾ が存在する. ASSTV は以下で与えられる.

$$\text{ASSTV}(\mathbf{u}) := \|\mathbf{D}\mathbf{u}\|_1 + \tau\|\mathbf{D}_s\mathbf{u}\|_1 \quad (5)$$

ここで, $\tau > 0$ は空間方向とスペクトル方向の平滑化のバランスを調整するパラメータである. SSTV とは対象的に空間的アーティファクトの残存は回避できるものの, スペクトル隣接差分のノルムを直接小さくすることの弊害として, (パラメータを適切に設定したとしても) スペクトル形状が過度に平坦化されてしまうという欠点がある (図 2(d)).

2.2.4 Hybrid Spatio-Spectral Total Variation (HSSTV)

著者の研究グループでは, SSTV を一般化し, 空間隣接差分のノルムを直接評価できるようにした hybrid spatio-spectral total variation (HSSTV) ⁽²²⁾ を提案している. HSSTV は以下のように定義される.

$$\text{HSSTV}(\mathbf{u}) := \|\mathbf{H}_w\mathbf{u}\|_{1,p} \quad (6)$$

ただし, $w > 0$, $p \in \{1, 2\}$, 及び

$$\mathbf{H}_w := \begin{pmatrix} \mathbf{D}\mathbf{D}_s \\ w\mathbf{D} \end{pmatrix} \quad (7)$$

である. ここで, $\mathbf{D}\mathbf{D}_s\mathbf{u}$ が空間-スペクトル隣接差分, $w\mathbf{D}\mathbf{u}$ が空間隣接差分に相当し, $\|\cdot\|_{1,p}$ は, $p = 1$ のとき ℓ_1 ノルム, $p = 2$ のとき混合 $\ell_{1,2}$ ノルムを表す. $\ell_{1,2}$ ノルムの場合, 各グループベクトルは一つのバンドの一つの画素に関する隣接差分を集めたもので構成される (すなわち, 各グループベクトルは「差分をとる方向の数 $\times$ 差分の種類」で次元となる). HSSTV 及びこれまで紹介した全変動に基づく正則化が, それぞれどの隣接差分を評価しているか比較したものを図 3 に示す.

HSSTV は, 空間-スペクトル隣接差分に加えて空間隣接差分のノルムも直接評価することで, SSTV の欠点であったアーティファクトの残存に対処している. HTV の欠点として述べたように, 空間隣接差分のノルムの直接的な最小化は過度な平滑化につながるが, パラメータ w を 1 以下に設定することでそれを回避できる. 一方, SSTV と比べて, 調整しなければならないパラメータが一つ増えてしまうという欠点もある. これに関しては, w を 0.05 前後に設定すればどのような画像においてもおおむねよい性能を達成できることが実験的に確認されている ⁽²³⁾. 実際に, HTV や ASSTV に比べて詳細成分を潰すことなく, SSTV の結果画像に存在するようなアーティファクトを除去できている (図 2(g), (h)).

2.3 低ランク性に基づく正則化

もう一つの代表的な HS 画像用の正則化として, HS 画像に内在するスペクトル相関 (冗長性) を行列の低ランク性を介してモ

図 3 HTV, SSTV, ASSTV, HSSTV が評価している隣接差分の比較

図 4 行列 $\mathbf{P}_i$ の構成

デル化したものが存在する ^{(24), (25)}. HS 画像 $\mathbf{U} \in \mathbb{R}^{N_1 \times N_2 \times B}$ に対し, i 番目の画素を中心として抽出したサイズ $n_1 \times n_2 \times B$ の局所パッチキューブ $\mathcal{P}_i$ を考える. ただし, $n_1 \leq N_1, n_2 \leq N_2$ であり, 等号が成立するときは HS 画像全体を一つのパッチとみなすことに相当する (すなわち $\mathcal{P}_1 = \mathbf{U}$). この局所パッチの各バンドの要素をラスタスキャンし, サイズ $n_1 n_2 =: n$ のベクトルを B 本用意した上で, これらのベクトルを横に並べた行列 $\mathbf{P}_i \in \mathbb{R}^{n \times B}$ を構成する (図 4). すると, 空間的に近い画素は非常に類似したスペクトル構造をもつ傾向があるため, 行列 $\mathbf{P}_i$ を構成する列ベクトルが線形従属に近くなる (= 低ランクになる) ことが直感的に分かる. 上記を踏まえ, 低ランク性に基づく正則化 (hyperspectral low-rank regularization, HLRR) は以下のように定式化される.

$$\text{HLRR}(\mathbf{U}) := \sum_{i \in \mathcal{P}(\mathbf{U})} (\iota_{\mathcal{L}_r}(\mathbf{P}_i) + \|\mathbf{P}_i\|_*) \quad (8)$$

ここで, $\iota_{\mathcal{L}_r}$ は集合

$$\mathcal{L}_r := \{\mathbf{X} \in \mathbb{R}^{n \times B} | \text{rank}(\mathbf{X}) \leq r\} \quad (9)$$

の指示関数を表し, その定義は

$$\iota_{\mathcal{L}_r}(\mathbf{X}) := \begin{cases} 0, & \text{if } \mathbf{X} \in \mathcal{L} \\ \infty, & \text{otherwise} \end{cases} \quad (10)$$

となる。また、 $\mathfrak{P}(\mathcal{U})$ はパッチの中心となる $\mathcal{U}$ の画素のインデックス集合を表す（パッチは重複してもよい）。

HLRR は、各パッチ $\mathbf{P}_i$ に対してランク制約と核ノルム正則化を同時に適用する設計^(注8)になっており、一見役割が被るように思える^(注9)が、以下で説明する合理性が背後に存在する。

HS 画像のパッチから生成した行列 $\mathbf{P}_i$ が以下のような線形スペクトル混合モデルを満たす状況を考えよう。

$$\mathbf{P}_i = \mathbf{M}_i \mathbf{A}_i \quad (11)$$

ただし、 $\mathbf{M}_i \in \mathbb{R}^{n \times r}$ は端成分 (endmembers) 行列、 $\mathbf{A}_i \in \mathbb{R}^{r \times B}$ は存在度 (abundance) 行列と呼ばれ、 r は端成分スペクトル数を表す。このモデルは、HS 画像を構成するスペクトルが端成分スペクトルの線形和で表現されることを意味し、物理的には HS センサが一次反射光のみを計測すると仮定することに相当する。現実とは多少の乖離があるが、物理的解釈性と数学的な扱いやすさの両方を兼ね備えた上でよい近似となっているため、ハイパースペクトルアンミキシング⁽²⁷⁾などにおいても頻繁に用いられるモデルである。

一般に、一つの HS 画像（の局所領域）を構成する端成分スペクトル数 r は、その画素数 n やバンド数 B に比べ非常に少ない。そのため、この混合モデルに基づき、次のような $\mathbf{P}_i$ の低ランク行列分解問題を考えることができる。

$$\min_{\mathbf{M}, \mathbf{A}} \|\mathbf{M}\|_F^2 + \|\mathbf{A}\|_F^2 \text{ s.t. } \mathbf{P}_i = \mathbf{M}\mathbf{A} \quad (12)$$

ここで、第一項と第二項は分解後の各行列の要素が極端に大きくならないようにするための正則化である。

一方、ランク $r \leq \min\{M_1, M_2\}$ の行列 $\mathbf{X} \in \mathbb{R}^{M_1 \times M_2}$ の核ノルムに関して次のような等式が成り立つことが知られている^{(26), (28), (29)}。

$$\|\mathbf{X}\|_* = \min_{\mathbf{L}, \mathbf{R}} \frac{1}{2} (\|\mathbf{L}\|_F^2 + \|\mathbf{R}\|_F^2) \text{ s.t. } \mathbf{X} = \mathbf{L}\mathbf{R} \quad (13)$$

ただし $\mathbf{L} \in \mathbb{R}^{M_1 \times r}$ 、 $\mathbf{R} \in \mathbb{R}^{r \times M_2}$ である。

式 (12) と式 (13) をふまえると、HLRR 中の核ノルムの背後に端成分スペクトル数 r の混合モデル (11) を想定できる。しかし、核ノルムのみを用いるだけでは、行列分解の構造を陽に入れているわけではないため、最適化問題の解（＝復元 HS 画像）から構成される各 $\mathbf{P}_i$ のランクが r より大きくなってしまいう可能性がある。ゆえに、対象とする HS 画像中に存在する可能性のあるマテリアル数（＝端成分スペクトル数の上界）を見積もった上で、その値をランク制約として直接 $\mathbf{P}_i$ に課すことで、混合モデル (11) を明確に反映した解釈性・妥当性の高い復元を実現できる。

一方、HLRR は空間方向の滑らかさなどを一切考慮していないため、細かいノイズが残存してしまうという欠点が存在する（図 2 (f)）。加えて、最適化問題が非凸であるため大域的最適性が保証できず、アルゴリズムの収束も不安定である。

ノイズの残存を回避するため、HLRR と全変動に基づく正則

化を同時に適用するアプローチが多くとられている^{(25), (30), (31)}が、性質が異なる正則化のバランス調整という別の課題が生じる。低ランク性と全変動の融合に関する別のアプローチとして、隣接差分から構成される構造テンソル行列に対する低ランク正則化も幾つか提案されている^{(32)~(35)}が、こちらは最適化の際に画素数個ある構造テンソル行列の特異値分解が必要となるため、計算量がボトルネックとなる。

3. ハイパースペクトル画像合成

衛星などに搭載される HS カメラの多くは、ハードウェア的制約から空間分解能がそれほど高くない。一方、都市域のリモートセンシングなど、高空間分解能の計測が必要となる応用も多いため、HS 画像の高解像度化は重要な課題となっている⁽³⁶⁾。そのためのアプローチの一つとして、対象とする HS 画像と同じ領域を計測した高空間解像度の参照画像（PAN 画像または MS 画像）を用意し、これらを合成することで HS 画像を高解像度化する技術が活発に研究されている^{(7), (8)}。実際に PRISMA⁽³⁷⁾ や SHALOM⁽³⁸⁾ といった地球観測衛星には HS カメラと PAN カメラの両方が搭載されているほか、2020 年度に打ち上げ予定である日本の次世代地球観測衛星 ALOS-3⁽³⁹⁾ には HS カメラと MS カメラが搭載予定であり、これらによって計測されるデータへの応用が期待されている。

3.1 問題設定

ここでは次のような HS 画像と参照画像（PAN または MS）の同時計測モデルを考える。

$$\mathbf{v}_h = \mathbf{S}\mathbf{B}\bar{\mathbf{u}} + \mathbf{n}_h \quad (14)$$

$$\mathbf{v}_m = \mathbf{R}\bar{\mathbf{u}} + \mathbf{n}_m \quad (15)$$

ただし、 $\bar{\mathbf{u}} \in \mathbb{R}^{NB}$ は未知の高（空間）解像度の HS 画像、 $\mathbf{v}_h \in \mathbb{R}^{\tilde{N}B}$ は計測された低解像度の HS 画像（画素数 $\tilde{N} < N$ ）、 $\mathbf{v}_m \in \mathbb{R}^{NB}$ は計測された高解像度の参照画像（バンド数 $\tilde{B} < B$ ）、 $\mathbf{B} \in \mathbb{R}^{NB \times NB}$ は HS 画像と参照画像の空間解像度を対応づける点拡がり関数から決まるばけ作用素、 $\mathbf{S} \in \mathbb{R}^{\tilde{N}B \times NB}$ はサンプリングレート d のダウンサンプリング作用素（ $\frac{N}{d^2} = \tilde{N}$ ）、 $\mathbf{R} \in \mathbb{R}^{NB \times NB}$ は HS 画像と参照画像のスペクトル解像度を対応づけるスペクトル感度変換^(注10)、 $\mathbf{n}_h, \mathbf{n}_m$ はそれぞれの計測データに重畳しているノイズ（白色ガウス性を仮定）を表す。

この計測モデルに従うと、HS 画像合成問題は「 $\mathbf{v}_h$ と $\mathbf{v}_m$ から $\bar{\mathbf{u}}$ を推定する問題」とみなすことができる（図 5）。以下、 $\mathbf{S}$ と $\mathbf{R}$ は既知であると仮定して話を進める。実データに適用する際には、 $\mathbf{S}$ と $\mathbf{B}$ を決めるために点拡がり関数推定と画像レジストレーション、 $\mathbf{R}$ を決めるために放射測定キャリブレーションがそれぞれ必要となる。次節以降で代表的な合成手法を定式化とともに幾つか紹介する。

(注8)：論文⁽²⁴⁾ではランク制約のみを用いている。

(注9)：核ノルムは、 ℓ_1 ノルムとスパース性の関係と同様に、本来非凸である行列のランクをある程度良好に評価できる凸関数として広く用いられている⁽²⁶⁾。

(注10)：HS 画像の各バンドの（重み付き）和をとることに相当する。

図 5 HS 画像合成

3.2 CNMF

非負値行列因子分解に基づく合成手法として coupled non-negative matrix factorization unmixing (CNMF)⁽⁴⁰⁾が提案されている。CNMF では所望の高解像度 HS 画像 $\bar{\mathbf{U}}$ が式 (11) で導入した線形スペクトル混合モデルを満たす ($\bar{\mathbf{U}} = \bar{\mathbf{M}} \bar{\mathbf{A}}$) と仮定する。その上で、合成問題を $\bar{\mathbf{M}}$ と $\bar{\mathbf{A}}$ を同時推定する問題とみなし、以下のような (非凸) 最適化問題として定式化する。

$$\min_{\bar{\mathbf{M}}, \bar{\mathbf{A}}} \frac{1}{2} (\|\mathbf{V}_h - \bar{\mathbf{M}} \bar{\mathbf{A}} \tilde{\mathbf{S}}\|_F^2 + \|\mathbf{V}_m - \tilde{\mathbf{R}} \bar{\mathbf{M}} \bar{\mathbf{A}}\|_F^2) \quad (16)$$

$$\text{s.t. } \bar{\mathbf{M}} \in \mathbb{R}_+^{N \times r}, \bar{\mathbf{A}} \in \mathbb{R}_+^{r \times B} \quad (17)$$

ただし、 $\mathbb{R}_+$ は非負実数の集合を表し、 $\tilde{\mathbf{S}}$, $\tilde{\mathbf{B}}$, $\tilde{\mathbf{R}}$ は式 (14), (15) の $\mathbf{S}$, $\mathbf{B}$, $\mathbf{R}$ を HS 画像の行列表現に合わせて再定義したものである。目的関数は 2 種類の計測データとの整合性を行列分解の構造を入れた状態で評価しており、計測モデル (14), (15) にそれぞれ従っている。端成分スペクトルと存在度はともに非負となるため、それぞれの行列に対する非負制約が課されている。論文⁽⁴⁰⁾では、非負値行列分解の基本的な解法である乗算更新則⁽⁴¹⁾をベースにこの問題を解くアルゴリズムを構成している。

CNMF は正則化を用いていないが、計測データがノイズを含んでいてもある程度ロバストに合成できることが報告されている⁽⁸⁾。これは、2.3 節で詳述したように、線形スペクトル混合モデルと低ランク性に基づく正則化の間に密接な関係があることに起因する。CNMF の発展版として、 $\bar{\mathbf{M}}$ と $\bar{\mathbf{A}}$ に明示的に正則化を施す手法⁽⁴²⁾や、非負値テンソル因子分解として定式化した手法⁽⁴³⁾が存在する。

3.3 HySure

凸最適化に基づく合成手法の代表例として hyperspectral super-resolution (HySure)⁽⁴⁴⁾が知られている。HySure では、高解像度 HS 画像 $\bar{\mathbf{U}}$ ではなく、その次元削減表現 $\bar{\mathbf{X}}$ を推定するアプローチをとる。具体的には、行列化した計測 HS 画像 $\mathbf{V}_h$ に対し特異値分解を適用し、得られた左特異ベクトルを第 r ($r < B$) 番めまで用いて次元削減行列 $\mathbf{E} \in \mathbb{R}^{B \times r}$ を設計する。すなわち、 $\bar{\mathbf{U}} \approx \mathbf{E} \bar{\mathbf{X}}$ であると仮定し、 $\bar{\mathbf{X}}$ を推定する最適化問題を考えることで、変数の次元を減らし効率化を実現している。

実際に解く問題は以下のように定式化される。

$$\min_{\bar{\mathbf{X}}} \frac{1}{2} (\lambda_h \|\mathbf{V}_h - \mathbf{E} \bar{\mathbf{X}} \tilde{\mathbf{S}}\|_F^2 + \lambda_m \|\mathbf{V}_m - \tilde{\mathbf{R}} \mathbf{E} \bar{\mathbf{X}}\|_F^2) + \text{HTV}(\bar{\mathbf{X}}) \quad (18)$$

ただし λ_h と λ_m は各項のバランスを調整するパラメータである。微分できない正則化である HTV を用いているため、最適化は近接分離アルゴリズムの一つである交互方向乗数法^{(45), (46)}によって行われる。

HySure は、CNMF と異なり、あらかじめ次元削減を行う変換 $\mathbf{E}$ を求めておくことで最適化問題の凸性を維持^(注11)し、大域的最適性を保証している。また、次元削減表現に対して明示的に正則化を入れることで、計算量を抑えつつノイズなどの劣化に対するロバスト性を担保している。

3.4 HSSTVFS

最後に著者の研究グループが提案した合成手法である HS-MS fusion based on HSSTV (HSSTVFS)^{(47), (48)}を紹介する。本手法は HySure と同様に凸最適化に基づくものであるが、次元削減は行わず、直接高解像度 HS 画像を推定する問題として以下のように定式化される。

$$\min_{\mathbf{u}_h, \mathbf{u}_m} \text{HSSTV}(\mathbf{u}_h) + \text{HSSTV}(\mathbf{u}_m) + \lambda \|\mathbf{D} \mathbf{u}_h - \mathbf{D} \mathbf{R}^\top \mathbf{u}_m\|_{1,2} \quad (19)$$

$$\text{s.t. } \begin{cases} \|\mathbf{v}_h - \mathbf{S} \mathbf{B} \mathbf{u}_h\| \leq \varepsilon_h \\ \|\mathbf{v}_m - \mathbf{u}_m\| \leq \varepsilon_m \\ \mathbf{u}_h \in [0, \mu_h]^{NB} \\ \mathbf{u}_m \in [0, \mu_m]^{\tilde{N}B} \end{cases} \quad (20)$$

ここで、 ε_h と ε_m は各計測データに含まれるノイズの強度から決まるパラメータであり、 μ_h と μ_m は各画像の画素値がとりうる最大値である。

これまで紹介した手法と大きく異なる点として、高解像度 HS 画像 $\mathbf{u}_h$ だけでなく参照画像 $\mathbf{u}_m$ も変数として同時推定することが挙げられるが、これは目的関数の第三項と関連する。第三項は、高い空間解像度を有する参照画像のエッジ情報を HS 画像に反映させるための指標であり、元々は変数 $\mathbf{u}_m$ の部分に計測された参照画像 $\mathbf{v}_m$ をそのまま入れた形で提案されたものである⁽⁴⁹⁾。しかし、現実の計測では、当然ながら参照画像にもノイズなどの劣化が伴うため、そのまま利用すると推定 HS 画像に悪影響が出てしまう。よって、参照画像も変数として扱い、計測された参照画像との整合性 (式 (20) の 2 番めの制約条件) を保ちながら HSSTV で正則化する (式 (19) の第二項, PAN の場合は通常の TV と等価) ことで、ノイズが除去された綺麗な参照画像のエッジ情報を推定 HS 画像に反映できる。

また、計測データとの整合性を目的関数に加えるのではなく制約条件として課している点も、ほかの手法と異なる。一般に、

(注11) : CNMF のような行列分解問題は変数同士の積が存在するため、外側の目的関数が凸であっても問題全体として凸にはならない。

図 6 各手法による合成結果 元画像の画素値は $[0, 1]$ に正規化. 評価指標は RMSE. 計測 HS 画像のサンプリングレート: $d = 4$, ノイズの標準偏差: 0.1, 計測 PAN 画像のノイズの標準偏差: 0.05

目的関数の項の数が増えると、各項のバランスを調整するパラメータの相互影響度合いが複雑になり、適切な設定が非常に困難になってしまう。一方、文献(50)～(54)などで言及されているように、制約条件として記述する場合、パラメータ数は変わらないものの、ノイズの強度などの統計的情報や物理的性質から適切な値を独立に決定できるため、目的関数に加える場合に比べて格段に見通しよく設定できる。

上記の凸最適化問題は、複数の微分できない目的関数を多数の制約条件下で最小化する難しい問題となっているが、近接分離アルゴリズムの一種である主-双対近接分離アルゴリズム⁽⁵⁵⁾で効率的に解くことができる。HSSTVFS は、次元削減を行わないことに加えて参照画像も同時に推定するため計算量は増加してしまいが、そのぶんリッチな事前知識や計測データに含まれる情報を効果的に活用しているため、CNMF や HySure に比べ、参照画像のノイズにロバストな合成が実現できる (図 6)。

4. おわりに

本稿では、主に最適化に基づくアプローチを中心に、ハイパースペクトルイメージングにおいて鍵となる復元・合成技術について解説した。最後に、近年発展が著しい深層学習技術に基づくアプローチとの関連について触れておこう。

復元に関しては、畳込みニューラルネットワーク (CNN) による HS 画像のノイズ除去手法が幾つか提案されている^{(56), (57)}。これらの手法の除去性能は、2.3 節で紹介した低ランク性に基づく最もベーシックな手法⁽²⁴⁾と同程度か少し上回る程度であり、画像認識などの応用に比べて著しい改善はみられない。利点としては、一度学習したネットワークを構成してしまえば復元はネットワークを通すだけで行えるため、最適化に基づく手法に比べ高速であることが挙げられる。一方、計測過程でノイズ以外の劣化 (ぼけなど) が混入したり、符号化開口計測のよう

な複雑な計測システムを伴う場合は、それ専用のネットワークを改めて構成する必要があるため、あらゆる計測モデルに対し普遍的に使える正則化に比べて汎用性に乏しい。加えて、公開されている HS 画像データ自体が普通の自然画像に比べて著しく少なく、ノイズも多いため、深層ニューラルネットの学習に足るデータセットを構築すること自体が困難である。後者の課題に関しては、最近、ノイズを含む HS 画像のみから学習を行う手法が提案されている⁽⁵⁸⁾。合成に関しても、CNN を用いた手法が提案されている^{(59), (60)}。復元のケースと同様、性能は最適化に基づくアプローチである CNMF⁽⁴⁰⁾などと同程度か少し上回る程度である。その他のメリット・デメリットについても復元の場合とおおむね傾向は同じといえる。

HS イメージングに関わる諸問題は、通常の画像計測と異なり、1. スペクトル構造、2. 符号化開口などの複雑な計測モデル、3. 様々なノイズや劣化、4. データそのものの希少性、などを十分に考慮する必要があるため、深層学習に代表される大量のデータを必要とするドメイン特化型の手法をそのまま適用することが困難なケースも多い。加えて、視覚的に綺麗であればよいことが多い自然画像と違い、HS 画像を利用した解析では計測プロセス・環境をふまえた物理的妥当性や説明性が保証されなければならない。したがって、計測プロセスや HS 画像自体の物理的性質を陽に反映できる最適化に基づくアプローチが依然として重要であるといえる。また、Plug-and-Play 法^{(61)～(63)}や深層展開法^{(64)～(66)}に代表される「深層学習とモデルの融合」も、今後の研究の方向性の一つであると考えられる。本稿をきっかけに、HS イメージングや最適化に興味をもつ研究者が増え、関連技術の発展につながれば幸いである。

文 献

- (1) C.-I. Chang, Hyperspectral Imaging: Techniques for

- Spectral Detection and Classification, vol. 1, Springer Science & Business Media, 2003.
- (2) D.-W. Sun, *Hyperspectral Imaging for Food Quality Analysis and Control*, Elsevier, 2010.
 - (3) 横矢直人, 岩崎晃, “ハイパースペクトル画像処理が拓く新しい地球観測,” *人工知能*, vol. 29, no. 4, pp. 357–365, 2014.
 - (4) G.R. Arce, D.J. Brady, L. Carin, H. Arguello, and D.S. Kittle, “Compressive coded aperture spectral imaging: An introduction,” *IEEE Signal Process. Mag.*, vol. 31, no. 1, pp. 105–115, 2013.
 - (5) Y.C. Eldar and G. Kutyniok, *Compressed Sensing: Theory and Applications*, Cambridge University Press, 2012.
 - (6) R.M. Willett, M.F. Duarte, M.A. Davenport, and R.G. Baraniuk, “Sparsity and structure in hyperspectral imaging: sensing, reconstruction, and target detection,” *IEEE Signal Process. Mag.*, vol. 31, no. 1, pp. 116–126, 2013.
 - (7) L. Loncan, L.B. De Almeida, J.M. Bioucas-Dias, X. Briottet, J. Chanussot, N. Dobigeon, S. Fabre, W. Liao, G.A. Licciardi, M. Simões, J. Tourneret, M.A. Veganzones, G. Vivone, Q. Wei, and N. Yokoya, “Hyperspectral pansharpening: a review,” *IEEE Geosci. Remote Sens. Mag.*, vol. 3, no. 3, pp. 27–46, 2015.
 - (8) N. Yokoya, C. Grohnfeldt, and J. Chanussot, “Hyperspectral and multispectral data fusion: A comparative review of the recent literature,” *IEEE Geosci. Remote Sens. Mag.*, vol. 5, no. 2, pp. 29–56, 2017.
 - (9) B. Rasti, P. Scheunders, P. Ghamisi, G. Licciardi, and J. Chanussot, “Noise reduction in hyperspectral imagery: overview and application,” *Remote Sensing*, vol. 10, no. 3, p. 482, 2018.
 - (10) E. Candès and M. Wakin, “An introduction to compressive sampling,” *IEEE Signal Process. Mag.*, vol. 25, no. 2, pp. 21–30, 2008.
 - (11) P.L. Combettes and J.-C. Pesquet, “Proximal splitting methods in signal processing,” in *Fixed-Point Algorithms for Inverse Problems in Science and Engineering*, H.H. Bauschke, et al., eds., pp. 185–212, Springer-Verlag, 2011.
 - (12) N. Parikh and S. Boyd, “Proximal algorithms,” *Found. Trends Optim.*, vol. 1, no. 3, pp. 127–239, 2014.
 - (13) 小野峻佑, “近接分離アルゴリズムとその応用: 信号処理・画像処理的観点から (特集一次法の逆襲),” *オペレーションズ・リサーチ: 経営の科学*, vol. 64, no. 6, pp. 316–325, 2019.
 - (14) L.I. Rudin, S. Osher, and E. Fatemi, “Nonlinear total variation based noise removal algorithms,” *Phys. D*, vol. 60, no. 1-4, pp. 259–268, 1992.
 - (15) X. Bresson and T.F. Chan, “Fast dual minimization of the vectorial total variation norm and applications to color image processing,” *Inverse Probl. Imag.*, vol. 2, no. 4, pp. 455–484, 2008.
 - (16) B. Goldluecke, E. Strekalovskiy, and D. Cremers, “The natural vectorial total variation which arises from geometric measure theory,” *SIAM J. Imag. Sci.*, vol. 5, no. 2, pp. 537–563, 2012.
 - (17) T. Miyata, “Total variation defined by weighted L infinity norm for utilizing inter channel dependency,” *Proc. IEEE Int. Conf. Image Process. (ICIP)*, 2012.
 - (18) S. Ono and I. Yamada, “Decorrelated vectorial total variation,” *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, pp. 4090–4097, 2014.
 - (19) Q. Yuan, L. Zhang, and H. Shen, “Hyperspectral image denoising employing a spectral-spatial adaptive total variation model,” *IEEE Trans. Geosci. Remote Sens.*, vol. 50, no. 10, pp. 3660–3677, 2012.
 - (20) H.K. Aggarwal and A. Majumdar, “Hyperspectral image denoising using spatio-spectral total variation,” *IEEE Geosci. Remote Sens. Lett.*, vol. 13, no. 3, pp. 442–446, 2016.
 - (21) Y. Chang, L. Yan, H. Fang, and C. Luo, “Anisotropic spectral-spatial total variation model for multispectral remote sensing image destriping,” *IEEE Trans. Image Process.*, vol. 24, no. 6, pp. 1852–1866, 2015.
 - (22) S. Takeyama, S. Ono, and I. Kumazawa, “Hyperspectral image restoration by hybrid spatio-spectral total variation,” *Proc. IEEE Int. Conf. Acoust., Speech, Signal Process. (ICASSP)*, pp. 4586–4590, 2017.
 - (23) S. Takeyama, S. Ono, and I. Kumazawa, “Hybrid spatio-spectral total variation: a regularization technique for hyperspectral image denoising and compressed sensing,” *arXiv preprint arXiv:1907.13357*, 2019.
 - (24) H. Zhang, W. He, L. Zhang, H. Shen, and Q. Yuan, “Hyperspectral image restoration using low-rank matrix recovery,” *IEEE Trans. Geosci. Remote Sens.*, vol. 52, no. 8, pp. 4729–4743, 2014.
 - (25) W. He, H. Zhang, L. Zhang, and H. Shen, “Total-variation-regularized low-rank matrix factorization for hyperspectral image restoration,” *IEEE Trans. Geosci. Remote Sens.*, vol. 54, no. 1, pp. 178–188, 2015.
 - (26) B. Recht, M. Fazel, and P.A. Parrilo, “Guaranteed minimum-rank solutions of linear matrix equations via nuclear norm minimization,” *SIAM Review*, vol. 52, no. 3, pp. 471–501, 2010.
 - (27) J.M. Bioucas-Dias, A. Plaza, N. Dobigeon, M. Parente, Q. Du, P. Gader, and J. Chanussot, “Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 5, no. 2, pp. 354–379, 2012.
 - (28) R. Mazumder, T. Hastie, and R. Tibshirani, “Spectral regularization algorithms for learning large incomplete matrices,” *J. Mach. Learn. Res.*, vol. 11, no. Aug, pp. 2287–2322, 2010.
 - (29) M.A. Davenport and J. Romberg, “An overview of low-rank matrix recovery from incomplete observations,” *IEEE J. Sel. Top. Signal Process.*, vol. 10, no. 4, pp. 608–622, 2016.
 - (30) W. He, H. Zhang, H. Shen, and L. Zhang, “Hyperspectral image denoising using local low-rank matrix recovery and global spatial-spectral total variation,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 11, no. 3, pp. 713–729, 2018.
 - (31) H. Liu, P. Sun, Q. Du, Z. Wu, and Z. Wei, “Hyperspectral image restoration based on low-rank recovery with a local neighborhood weighted spectral-spatial total variation model,” *IEEE Trans. Geosci. Remote Sens.*, vol. 57, no. 3, pp. 1409–1422, 2019.
 - (32) S. Lefkimmatis, A. Roussos, P. Maragos, and M. Unser, “Structure tensor total variation,” *SIAM J. Imag. Sci.*, vol. 8, no. 2, pp. 1090–1122, 2015.
 - (33) G. Chierchia, N. Pustelnik, B. Pesquet-Popescu, and J.-C. Pesquet, “A nonlocal structure tensor-based approach for multicomponent image recovery problems,” *IEEE Trans. Image Process.*, vol. 23, no. 12, pp. 5531–5544, 2014.
 - (34) S. Ono, K. Shirai, and M. Okuda, “Vectorial total variation based on arranged structure tensor for multichannel image restoration,” *Proc. IEEE Int. Conf. Acoust., Speech, Signal Process. (ICASSP)*, pp. 4528–4532, 2016.
 - (35) R. Kurihara, S. Ono, K. Shirai, and M. Okuda, “Hyperspectral image restoration based on spatio-spectral structure tensor regularization,” *Proc. Eur. Signal Process. Conf. (EUSIPCO)*, pp. 488–492, 2017.
 - (36) 横矢直人, “ハイパースペクトル画像の高解像度化技術,” *日本リモートセンシング学会誌*, vol. 38, no. 2, pp. 105–110, 2018.
 - (37) S. Pignatti, A. Palombo, S. Pascucci, F. Romano, F. Santini, T. Simoniello, A. Umberto, C. Vincenzo, N. Acito, M. Diani, S. Matteoli, G. Corsini, R. Casa, R. De Bonis, G. Laneve, and C. Ananasso, “The prisma hyperspectral mission: science activities and opportu-

- nities for agriculture and land monitoring,” Proc. IEEE Int. Geosci. Remote Sens. Symp. (IGARSS), pp. 4558–4561, 2013.
- (38) T. Feingersh and E.B. Dor, “Shalom—a commercial hyperspectral space mission,” Optical Payloads for Space Missions, vol. 247, 2015.
- (39) N. Ohgi, A. Iwasaki, T. Kawashima, and H. Inada, “Japanese hyper-multi spectral mission,” Proc. IEEE Int. Geosci. Remote Sens. Symp. (IGARSS), pp. 3756–3759, 2010.
- (40) N. Yokoya, T. Yairi, and A. Iwasaki, “Coupled nonnegative matrix factorization unmixing for hyperspectral and multispectral data fusion,” IEEE Trans. Geosci. Remote Sens., vol. 50, no. 2, pp. 528–537, 2012.
- (41) D.D. Lee and H.S. Seung, “Learning the parts of objects by non-negative matrix factorization,” Nature, vol. 401, no. 6755, pp. 788–791, 1999.
- (42) C.-H. Lin, F. Ma, C.-Y. Chi, and C.-H. Hsieh, “A convex optimization-based coupled nonnegative matrix factorization algorithm for hyperspectral and multispectral data fusion,” IEEE Trans. Geosci. Remote Sens., vol. 56, no. 3, pp. 1652–1667, 2018.
- (43) S. Li, R. Dian, L. Fang, and J.M. Bioucas-Dias, “Fusing hyperspectral and multispectral images via coupled sparse tensor factorization,” IEEE Trans. Image Process., vol. 27, no. 8, pp. 4118–4130, 2018.
- (44) M. Simoes, J. Bioucas-Dias, L.B. Almeida, and J. Chanussot, “A convex formulation for hyperspectral image superresolution via subspace-based regularization,” IEEE Trans. Geosci. Remote Sens., vol. 53, no. 6, pp. 3373–3388, 2015.
- (45) D. Gabay and B. Mercier, “A dual algorithm for the solution of nonlinear variational problems via finite elements approximations,” Comput. Math. Appl., vol. 2, pp. 17–40, 1976.
- (46) J. Eckstein and W. Yao, “Understanding the convergence of the alternating direction method of multipliers: theoretical and computational perspectives,” Pac. J. Optim., vol. 11, no. 4, pp. 619–644, 2015.
- (47) S. Takeyama, S. Ono, and I. Kumazawa, “Hyperspectral pansharpening using noisy panchromatic image,” Asia-Pacific Signal Inform. Process. Assoc. Annual Summit Conf. (APSIPA ASC), pp. 880–885, 2018.
- (48) S. Takeyama, S. Ono, and I. Kumazawa, “Hyperspectral and multispectral data fusion by a regularization considering spatio-spectral piecewise-smoothness,” Proc. IEEE Int. Conf. Acoust., Speech, Signal Process. (ICASSP), pp. 2152–2156, 2019.
- (49) C. Chen, Y. Li, W. Liu, and J. Huang, “Image fusion with local spectral consistency and dynamic gradient sparsity,” Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), pp. 2760–2765, 2014.
- (50) M. Afonso, J. Bioucas-Dias, and M. Figueiredo, “An augmented Lagrangian approach to the constrained optimization formulation of imaging inverse problems,” IEEE Trans. Image Process., vol. 20, no. 3, pp. 681–695, 2011.
- (51) G. Chierchia, N. Pustelnik, J.-C. Pesquet, and B. Pesquet-Popescu, “Epigraphical projection and proximal tools for solving constrained convex optimization problems,” Signal, Image and Video Process., vol. 9, no. 8, pp. 1737–1749, 2015.
- (52) S. Ono and I. Yamada, “Signal recovery with certain involved convex data-fidelity constraints,” IEEE Trans. Signal Process., vol. 63, no. 22, pp. 6149–6163, 2015.
- (53) S. Ono, “ L_0 gradient projection,” IEEE Trans. Image Process., vol. 26, no. 4, pp. 1554–1564, 2017.
- (54) S. Ono, “Efficient constrained signal reconstruction by randomized epigraphical projection,” Proc. IEEE Int. Conf. Acoust., Speech, Signal Process. (ICASSP), pp. 4993–4997, 2019.
- (55) A. Chambolle and T. Pock, “A first-order primal-dual algorithm for convex problems with applications to imaging,” J. Math. Imag. Vis., vol. 40, no. 1, pp. 120–145, 2010.
- (56) Q. Yuan, Q. Zhang, J. Li, H. Shen, and L. Zhang, “Hyperspectral image denoising employing a spatial-spectral deep residual convolutional neural network,” IEEE Trans. Geosci. Remote Sens., vol. 57, no. 2, pp. 1205–1218, 2019.
- (57) Q. Zhang, Q. Yuan, J. Li, X. Liu, H. Shen, and L. Zhang, “Hybrid noise removal in hyperspectral imagery with a spatial-spectral gradient network,” IEEE Trans. Geosci. Remote Sens., vol. 57, no. 10, pp. 7317–7329, 2019.
- (58) R. Imamura, T. Itasaka, and M. Okuda, “Zero-shot hyperspectral image denoising with separable image prior,” Proc. the IEEE Int. Conf. Comput. Vis. Workshops, 2019.
- (59) F. Palsson, J.R. Sveinsson, and M.O. Ulfarsson, “Multispectral and hyperspectral image fusion using a 3-d convolutional neural network,” IEEE Geosci. Remote Sens. Lett., vol. 14, no. 5, pp. 639–643, 2017.
- (60) J. Yang, Y.-Q. Zhao, and J.C.-W. Chan, “Hyperspectral and multispectral image fusion via deep two-branches convolutional neural network,” Remote Sensing, vol. 10, no. 5, p. 800, 2018.
- (61) S.V. Venkatakrishnan, C.A. Bouman, and B. Wohlberg, “Plug-and-play priors for model based reconstruction,” IEEE Global Conf. Signal Inf. Proc. (GlobalSIP), pp. 945–948, 2013.
- (62) S. Sreehari, S.V. Venkatakrishnan, B. Wohlberg, G.T. Buzzard, L.F. Drummy, J.P. Simmons, and C.A. Bouman, “Plug-and-play priors for bright field electron tomography and sparse interpolation,” IEEE Trans. Comput. Imag., vol. 2, no. 4, pp. 408–423, 2016.
- (63) S. Ono, “Primal-dual plug-and-play image restoration,” IEEE Signal Process. Lett., vol. 24, no. 8, pp. 1108–1112, 2017.
- (64) K. Gregor and Y. LeCun, “Learning fast approximations of sparse coding,” Proc. Int. Conf. Mach. Learn. (ICML), pp. 399–406, 2010.
- (65) D. Ito, S. Takabe, and T. Wadayama, “Trainable ista for sparse signal recovery,” IEEE Trans. Signal Process., vol. 67, no. 12, pp. 3113–3125, 2019.
- (66) Y. Li, M. Tofighi, J. Geng, V. Monga, and Y.C. Eldar, “Efficient and interpretable deep blind image deblurring via algorithm unrolling,” IEEE Trans. Comput. Imag., vol. 6, pp. 666–681, 2020.

(SIP 研究会提案, 2020 年 6 月 16 日受付,
2020 年 7 月 1 日再受付)

小野峻佑 (正員)

2010 東工大・工・情報工卒。2014 同大学大学院工学研究科集積システム専攻博士課程修了。博士 (工学)。2012–2014 日本学術振興会特別研究員 (DC1)。2014 東工大・像情報工学研究所・助教。2016 同大学・科学技術創成研究院・助教。2019 東工大・情報理工学院・准教授。2016–2020 科学技術振興機構 (JST) さきがけ個人研究者 (兼任)。主として画像処理, 信号処理, 数値最適化, データサイエンス・AI, リモートセンシングの研究に従事。2019–現在 IEEE Transactions on Signal and Information Processing over Networks 編集委員。電子情報通信学会学術奨励賞 (2013), 電子情報通信学会論文賞 (2014), IEEE SPS Japan Chapter Outstanding Student Journal Paper Award (2014), 丹羽保次郎記念論文賞 (2015), 手島精一記念研究賞博士論文賞 (2016), テレコムシステム技術賞 (2016), 船井学術奨励賞 (2017), IEEE SPS Japan Chapter Young Author Best Paper Award (2019), 東工大挑戦的研究賞末松特別賞 (2020) 各受賞。