

## RGB および HSV 色空間に基づく高次元分光画像生成のための Autoencoder を用いたソフト疑似プリズムの開発

### Development of Soft Pseudo-Prism for High-Dimensional Spectroscopic Image Estimation Based on RGB and HSV models Utilizing Autoencoder

佐藤 遼史<sup>†</sup>      高尾 郁也<sup>‡</sup>      浜田 百合<sup>†</sup>      鎗木 崇史<sup>§</sup>      栗原 陽介<sup>†</sup>  
Ryoji Sato      Ikuya Takao      Yuri Hamada      Takashi Kaburagi      Yosuke Kurihara

#### 1. はじめに

高次元分光画像では、1 画素につき数百の波長情報に対応した情報を有しているため、3 波長の情報を持つ RGB 画像では識別が困難な対象でも高精度に識別が可能となる。この利点を生かし、セキュリティ分野[1]や癌検知[2]など様々な分野への応用研究が行われている。しかし、高次元分光画像を取得できるハイパースペクトルカメラは非常に高価であることが、普及の妨げとなっている。RGB 画像から高次元分光画像を生成することで、安価な高次元分光画像の取得ができれば、高次元分光画像を用いたアプリケーション普及の一助となる。

そこで本研究では、Autoencoder を用いたソフト疑似プリズムにより、RGB 画像から高次元分光画像を推定する手法を提案する。

#### 2. 提案手法

##### 2.1 高次元分光画像撮影の仕組み

始めにハイパースペクトルカメラの原理について説明する。図 1 に示すように、ハイパースペクトルカメラは被写体に反射した白色光をレンズから取り込み、カメラ内の分光プリズムによって各波長帯域に分光する。分光プリズムに入り込む白色光に含まれるスペクトルの範囲が広いほど、より多くの波長情報を表現できる。自然界に含まれる連続的な波長を、RGB 画像であれば 3 波長に限定して取得されている一方、ハイパースペクトルカメラの場合、数百波長のスペクトル値を取得することができる。




図 1 ハイパースペクトルカメラの原理

##### 2.2 ソフト疑似プリズムの実装

本提案手法では、図 2 に示すソフト疑似プリズムによって RGB 画像から高次元分光画像の推定を行う。ソフト疑似プリズムではニューラルネットワークと Autoencoder の Decoder 部分を組み合わせて構築される。疑似プリズムへの入力値には、RGB 画像の RGB 成分、RGB 画像から算出される H (色相), S (彩度), V (明度) を用いる。これらの値

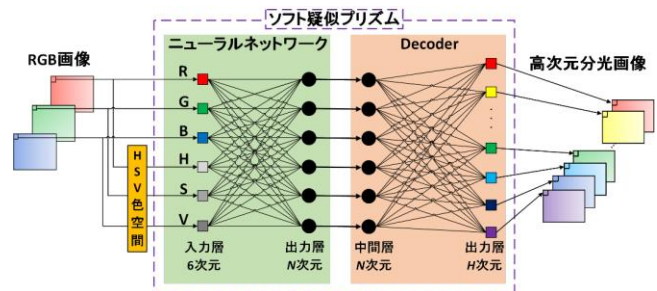


図 2 ソフト疑似プリズムのアーキテクチャー

が疑似プリズムに入力されると、擬似的に分光された数百の波長情報が推定される。

Autoencoder では、入力層、出力層に高次元分光画像を設定し学習させることで、低次元から高次元の波長情報へと分光させる機能を Decoder に与える。入出力層の次元数は  $H$  とし、この  $H$  は撮影に用いるハイパースペクトルカメラが再現する波長の数とする。なお、中間層の次元数は  $N$  とし、この  $N$  次元の Decoder の入力層が  $H$  次元の出力層に拡張される。

Autoencoder の学習により Encoder, Decoder の実装が完了された後、Decoder への入力値を変換するニューラルネットワークを学習させる。ニューラルネットワークの入力層には推定される高次元分光画像の説明変数にあたる RGB 画像と、そこから算出される HSV を入力し、出力層から高次元分光画像を Encoder に入力して算出される Autoencoder の  $N$  次元の中間層の値が出力される。

これらの学習により得られた Decoder, ニューラルネットワークを組み合わせ、図 2 に示す疑似プリズムを構築し、RGB 画像の 3 値と、そこから算出される HSV の値を入力することで、高次元分光画像の推定を行う。

#### 3. 検証実験

##### 3.1 実験環境

本実験では、ハイパースペクトルカメラとして PikaXC2(RESONON)を使用する。撮影可能波長範囲は 398.78nm~1016.78nm であり、462( $=H$ )の波長情報を持つ。画像サイズは 1 画像あたり 1600\*1110 であり、1776000 の画素を含んでいる。なお、RGB 画像も同じハイパースペクトルカメラより取得した。

##### 3.2 実験手順

太陽光を光源とするため、屋外にてカラーチェッカーの撮影を行い、RGB 画像と高次元分光画像を、学習用と推定用の 2 枚取得した。

学習用のカラーチェッカー画像を用いて、入力層と出力層の次元数  $H=462$ 、中間層の数  $N=6$  の Autoencoder を学習さ

<sup>†</sup> 青山学院大学 Aoyama Gakuin University

<sup>‡</sup> SAP ジャパン株式会社インダストリーアンドカスタマーアドバイザー SAP Japan ICA

<sup>§</sup> 国際基督教大学 International Christian University

せる.そして,入力層を RGB と HSV の 6 次元,出力層を Encoder の中間層と同じ 6 次元としたニューラルネットワークを学習させる.

推定では,テストデータのカラーチェッカー画像の RGB から HSV を算出し,それらの 6 次元のデータを疑似プリズムに入力し,1 画素ごとに 462 次元の高次元分光画像を出力する.

### 3.3 評価方法

テストデータにおいて撮影された正解画像と推定画像の対応する画素間の値を用い,次式に示す類似度を算出する.なお,類似度は 0 から 1 の値で算出され,各波長に 1 つ算出される.したがって本実験では 462 個の類似度が算出される.これらの値を以下の(A)から(H)に示す 8 の帯域ごとの平均類似度を算出し,評価を行う.

$$\text{Similarity}_h = \sum_{x=1}^{1600} \sum_{y=1}^{1110} \frac{\text{Image}_{\text{correct}_h}^{x,y}}{\sqrt{\sum_{i=1}^{1600} \sum_{j=1}^{1110} \text{Image}_{\text{correct}_h}^{i,j^2}}} \times \frac{\text{Image}_{\text{predicted}_h}^{x,y}}{\sqrt{\sum_{i=1}^{1600} \sum_{j=1}^{1110} \text{Image}_{\text{predicted}_h}^{i,j^2}}} \quad (1)$$

- (A) 紫色帯域, 398.67nm~428.97nm
- (B) 藍色帯域, 430.29nm~459.39nm
- (C) 青色帯域, 460.66nm~499.02nm
- (D) 緑色帯域, 500.35nm~569.37nm
- (E) 黄色帯域, 570.70nm~589.33nm
- (F) 橙色帯域, 590.66nm~609.32nm
- (G) 赤色帯域, 610.65nm~779.49nm
- (H) 赤外線帯域, 780.89nm~1016.78nm

## 4. 実験結果と考察

### 4.1 推定画像

図3と図4に,撮影された正解画像と疑似プリズムによって出力された推定画像の2枚を示す.全462波長のうち,例として以下に示す2波長分を表示する.




図3 542.79nmにおける推定結果




図4 797.01nmにおける推定結果

図3においてカラーチェッカー中の4\*6の各正方形のパネルを比較すると,正解画像と推定画像における濃淡のパターンは非常によく似ていることが分かる.図3の画像間における類似度は 0.982 となった.また,図4に示す赤外線帯

域における推定画像は,正解画像における全体的に白色味をおびた特徴の推定精度は低いが,正方形のパネルの濃淡のパターンの特徴は捉えられており,Decoder とニューラルネットワークの学習が適切に行われていたといえる.なお,図4の画像間における類似度は 0.882 となった.

### 4.2 類似度

表1に,各波長帯域における類似度評価の結果を示す.

表1 各波長帯域における類似度

波長帯域	類似度
紫色帯域	0.898
藍色帯域	0.933
青色帯域	0.972
緑色帯域	0.978
黄色帯域	0.947
橙色帯域	0.926
赤色帯域	0.892
赤外線帯域	0.886
平均	0.929

全体での類似度平均は 0.929 となり,高精度で推定できていることが分かる.各波長帯域においても,最も低い帯域で赤外線帯域の 0.886,最も高い帯域については緑色帯域の 0.978 と,いずれの帯域も高い精度で推定できているといえる.赤外線帯域における類似度が他の可視光帯域の類似度よりもやや低い原因としては,赤外線帯域の全体が白みがかった正解画像の特徴をソフト疑似プリズムによって学習しきれなかったことが考えられる.

## 5. まとめと今後の展望

本研究では,Autoencoder の Decoder 部分とニューラルネットワークを組み合わせ構築したソフト疑似プリズムを用いて RGB 画像から高次元分光画像の推定を行った.

推定画像と類似度の結果より,高精度で高次元分光画像を推定出来ていることが分かり,提案手法によるソフト疑似プリズムは,RGB 画像から高次元分光画像を推定する手法として適しているといえる.ハイパースペクトルカメラはプラスチック選別や果物の痛みの推定など様々な分野に用いられている.そのような実際に応用されている分野における対象についても高精度で推定することができれば,アプリケーション導入のコストが下がり,様々な分野への導入が更に進んでいくことが期待できる.

今後の展望としては,まず CNN などといった異なるニューラルネットワークのアルゴリズムの導入を考えている.本提案手法では画素ごとに推定を行っているが,周辺画素の情報も加味することで,更に精度が向上する可能性が考えられる.また,あらゆる画像を様々な光源環境において高精度に推定するため,様々な材質,成分を対象として実験を行う必要がある.

### 参考文献

- [1] R.Pike *et al.*, "A Minimum Spanning Forest-Based Method for Noninvasive Cancer Detection With Hyperspectral Imaging," *IEEE Trans. on Biomedical Engineering*, vol.63, no.3, pp.653-663 (2016).
- [2] T.Wang, Z.Zhu and E.Blasch, "Bio-Inspired Adaptive Hyperspectral Imaging for Real-Time Target Tracking," *IEEE Sensors Journal*, vol.10, no.3, pp.697-659 (2010).