

画像分類のための色変換行列最適化 Optimization of Color Transformation Matrix for Image Classification

昇 洋太¹⁾ 小篠 裕子¹⁾ 田中 正行²⁾
Youta Noboru Yuko Ozasa Masayuki Tanaka

1 はじめに

画像分類の性能を最大化する、タスク特化型カメラ設計の研究が注目されている [4, 8]. 多くの既存研究では、画像分類に対してカメラ内部の ISP (Image Signal Processing) を最適化している. ISP とは、イメージセンサから受信した RAW 画像データに対し、様々な補正や処理をするプロセッサである. 本研究では、3CMOS を想定するため、RAW データとはデモザイキングをせずに撮像素子が出力する画像データを指す.

ISP の代表的な処理として色を調整する CCM (Color Correction Matrix) があるが、画像分類性能の向上を目的とした CCM の最適化については十分に議論されていない. ここで CCM とは、センサが捉えた RAW データを標準的な色空間へ変換する線形変換行列である.

我々は、画像分類性能の向上を目的として CCM のみで構成される ISP を最適化する. 例えば、花画像の分類のように対象物の色が識別に大きく寄与するタスクにおいて、CCM の最適化は他の ISP パラメータ (例えば、ノイズ除去やガンマ補正など) の調整より、分類性能に対して直接的かつ効果的であるという仮説が立てられる.

本稿では、画像分類のための深層学習モデルとカメラの CCM を同時に最適化する効果を検証する. 具体的には、深層学習モデルと同時に最適化することで設計した CCM を用いたカメラで撮影できるだろう画像をシミュレーション生成し、その画像を用いて画像を分類する効果を検証する. CCM 最適化の有効性を検証するため、既存カメラの分光感度 (CSS) は固定し、CCM のみを画像分類タスクに特化するよう最適化する.

本稿の貢献は、物理的なセンサ特性を変更することなく、ISP 内の CCM のみを深層学習モデルと共同で学習させるという、実用性の高いアプローチの有効性を検証した点にある. ハイパースペクトル (HS) 画像認識の研究は提案されている [5] が、本研究では、花と葉の HS 画像データセット [9] を用いたシミュレーション実験を通じて、本手法が標準的な CCM を用いる場合と比較し、画像分類制度を向上させることを示した.

2 CCM の学習方法

本研究では、CCM と画像認識モデルを深層学習の学習アルゴリズムによって同時に最適化する. カメラセンサで撮影した RAW データを、ISP の処理である CCM にて変換後、画像分類モデルに入力し、最適化する.

ISP には様々な処理があるが、本研究では RAW データの色を変換する処理である CCM を採用する. CCM は、式 (1) に示すように、カメラセンサから得られた RAW データを線形変換する 3×3 の行列である.

$$\begin{bmatrix} R' \\ G' \\ B' \end{bmatrix} = \begin{bmatrix} c_{11} & c_{12} & c_{13} \\ c_{21} & c_{22} & c_{23} \\ c_{31} & c_{32} & c_{33} \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix}, \quad (1)$$

ここで、 $[R, G, B]^T$ はカメラで撮像した RAW データにおける RGB 値を示し、 $[R', G', B']^T$ は変換された後の RGB 値を示す. c_{11} から c_{33} までの各要素は、RAW データの RGB 値を変換するための係数である.

一般的な CCM では、撮影した画像を sRGB や YUV, YCbCr などの固定された色空間へ変換する変換行列を用いることが多いが、本研究では画像分類に最適化するよう、CCM を学習する. そのため、本研究では CCM を、ポイントワイズ畳み込み層として画像分類モデルの入力直前に配置する.

画像分類モデルには ResNet18 を採用する. CCM によって色変換した RAW データを ResNet18 に入力し、その予測ラベルと教師ラベルとの間でクロスエントロピー損失を計算する. この損失を逆伝播することで、ResNet18 と CCM を同時に最適化する.

RAW データは、カメラセンサ固有の分光感度特性に依存する. 各カメラセンサに応じて CCM を最適化するため、HS 画像を用いて RAW データの取得過程をシミュレートする. HS 画像は、現実世界の詳細な波長情報を含んでおり、これと各カメラの分光感度特性 [2] を用いることで、RAW データを取得する.

CCM の初期値は、各カメラで撮影したカラーチェッカーの RAW データが sRGB 色空間に整合するように、事前に求めた値を使用する. カラーチェッカーを撮影したスペクトルデータ [7] に対して、XYZ 等色関数 [1] を適用して求めた sRGB 値と RAW データの RGB 値の誤差を最小化するように、回帰分析で CCM の初期値を求める [6]. 本研究では、複数の異なるカメラセンサを対象とし、各カメラにおいて個別に CCM と画像分類モデルを同時に最適化する.

画像分類モデルの学習では、まず、画像データを XYZ の等色関数 [1] を用いて sRGB 画像へ変換し、これを用いて ResNet18 を事前学習する. 次に、事前学習済みの ResNet18 と、前述の初期値を持つ CCM を組み合わせ、両者を同時に最適化する.

3 検証

3.1 学習条件

本研究では、画像分類タスクにおいて、提案手法の有効性を検証する. 具体的には、HS 画像を入力とし、カメラプロセスのシミュレーションから得られた RGB 画像を画像分類した結果で評価する. データセットには、花と葉を撮影した HS 画像データセット [9] を用いる. 花のようにクラス間で色彩が異なる場合と、葉のようにクラス間の色彩が類似する場合という対照的な条件下で、検証するためにこれらのデータセットを選択した.

花データセット (Petal patches) は 100 クラスで、学習用画像は 36,730 枚、評価用画像は 25,769 枚、葉データセット (Leaf patches) は 60 クラスの画像で、学習用画像は 20,432 枚、評価用画像は 15,126 枚で構成される. 各画像は、波長 451nm から 855nm の範囲を 31 バ

1) 東京電機大学 Tokyo Denki University

2) 東京科学大学 Institute of Science Tokyo

ンドで記録したスペクトル情報を持つ。

前処理として、スケーリングとデータ拡張をする。具体的には、HS 画像に XYZ 等色関数 [1] を適用し、sRGB 画像へ変換した際に輝度値の最大が 1 となるように、元の HS 画像に一定の係数を乗じることでスケーリングする。この処理は、カメラ撮影時の露光時間調整に相当し、画像の飽和を防ぐ効果がある。データ拡張は、垂直方向の反転、水平方向の反転、および画像の転置を組み合わせた計 8 パターンを等確率で適用する。

実験における RAW データの変換には、Canon 500D および Olympus E-PL2 のカメラセンサの分光感度特性 [2] を用いる。分類精度を評価指標とする。学習は、エポック数 300、バッチサイズ 32 で実行する。最適化アルゴリズムには Adam [3] を用い、初期学習率は 0.0001 に設定する。また、学習率スケジュールとして、50 エポックごとに学習率を 0.5 倍に減衰させる。損失関数には、クロスエントロピー損失を用いる。

3.2 検証結果

結果を表 1 に示す。CCM と画像分類モデルを同時に最適化する提案手法は、画像分類モデルのみを最適化するベースライン手法と比較して、両カメラセンサにおいて分類精度が向上した。具体的には、Canon 500D センサを用いた場合、花データセットで 0.29[%] ポイント、葉データセットで 1.70[%] ポイント精度が向上した。同様に、Olympus E-PL2 センサを用いた場合では、花データセットで 0.59[%] ポイント、葉データセットで 1.64[%] ポイント精度が向上した。これより、学習可能である 3×3 の色変換行列を導入するのみで、画像分類性能の向上が期待できることがわかる。

両カメラセンサにおいて、葉データセットでの精度向上幅は花データセットよりも大きくなった。これは、葉クラス間のデータは類似した緑色を呈し、元々の色情報での識別が困難であるためと考える。CCM の最適化は、このような場合に僅かな色彩の違いを強調し、識別性能をより大きく向上させたと考えられる。対照的に、クラス毎に多様な色彩を持つ花データセットでは、CCM の最適化による相対的な精度向上幅は比較的小さかった。この結果は、CCM の最適化の有効性が対象物の色彩特性に依存することを示唆しており、今後の応用において重要な知見となる。


図 1 に、Olympus E-PL2 カメラセンサで取得した RAW データを、初期値の CCM と最適化した CCM でそれぞれ変換した画像例を示す。最適化した CCM では、花と葉の双方において、僅かではあるが色合いに変化が観察された。特に花データセットの画像では、最適化により黄色味の表現が変化し、葉データセットの画像では、緑色がより鮮やかに表現される傾向が確認できた。

4 おわりに

本稿では、画像分類の性能を最大化することを目的とし、CCM のパラメータを深層学習モデル内に組み込み、分類タスクの損失関数を用いてモデルパラメータと同時に最適化する効果を検証した。実験では、本手法で最適化された CCM を用いた場合、標準的な CCM を用いる場合と比較して、画像分類精度の向上することを実証した。この結果は、物理的なセンサを変更することなく、CCM の最適化のみで認識性能を向上できることを示唆する。今後の展望として、本アプローチをさらに発展さ

表 1: CCM の最適化の有無による画像分類精度の比較。提案手法は CCM と画像分類モデルを同時最適化し、ベースラインは画像分類モデルのみを最適化する。

Camera Sensor	Optimize	Accuracy[%]	
		Flower	Leaves
Canon 500D	-	91.56	72.29
	✓	91.85	73.99
Olympus EPL2	-	91.94	72.73
	✓	92.53	74.37



(a) 最適化された CCM を適用した画像 (b) 初期値の CCM を適用した画像

図 1: Olympus E-PL2 カメラセンサで取得した RAW データに異なる CCM を適用した画像の比較。上段は花、下段は葉データセットからの画像例を示す。

せ、ISP 内の CCM だけでなく、カメラセンサの分光感度 (CSS) をも含めた、より広範なパラメータの同時最適化手法を構築することが挙げられる。

参考文献

- [1] CIE. CIE 1964 colour-matching functions, 10 degree observer. *International Commission on Illumination (CIE)*, 2019. Data set CIE_xyz_1964_10deg.csv; Original source: ISO/CIE 11664-1:2019, Table 2.
- [2] Jun Jiang, Dengyu Liu, Jinwei Gu, and Sabine Süsstrunk. What is the space of spectral sensitivity functions for digital color cameras? In *2013 IEEE Workshop on Applications of Computer Vision (WACV)*, pages 168–179, 2013.
- [3] Diederik P Kingma. Adam: A method for stochastic optimization, 2014.
- [4] Igor Morawski, Yu-An Chen, Yu-Sheng Lin, Shushil Dangi, Kai He, and Winston H Hsu. Genisp: Neural isp for low-light machine cognition. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 630–639, 2022.
- [5] Youta Noboru, Yuko Ozasa, and Masayuki Tanaka. Appearance-and-spectral-based identification system for penguin individuals. *ITE Transactions on Media Technology and Applications*, 13(2):211–220, 2025.
- [6] D Andrew Rowlands. Color conversion matrices in digital cameras: a tutorial. *Optical Engineering*, 59(11):110801–110801, 2020.
- [7] The BabelColor Company. ColorChecker Pages, 2004. Last accessed on June 9, 2025.
- [8] Masakazu Yoshimura, Junji Otsuka, Atsushi Irie, and Takeshi Ohashi. Dynamicisp: dynamically controlled image signal processor for image recognition. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pages 12866–12876, 2023.
- [9] Yongrong Zheng, Tao Zhang, and Ying Fu. A large-scale hyperspectral dataset for flower classification. *Knowledge-Based Systems*, 236:107647, 2022.