

# カラー偏光反射特性の計測に基づく材質識別

有川 尚輝<sup>1</sup> 前田 涼汰<sup>1</sup> 日浦 慎作<sup>1,a)</sup>

**概要:** 自動走行車や家事ロボットなど生活空間における自動化が進展するなかで、シーン認識における材質識別の重要性が増している。コンピュータビジョン分野において提案されている多くの材質識別手法は、素材の色やテクスチャなど通常のカラー画像を利用する手法である。しかし、これらの手法では高精細な写真や印刷物など、実物を模した色やテクスチャを持つ素材を実物と区別することは困難である。また、偏光を利用した手法も提案されているが、対象がテクスチャのない光学的等方性をもつ素材に限られる。そこで本研究では、色と偏光情報の双方を利用して材質識別を行う手法を提案する。入射光の偏光状態を変化させて物体に照射し、その反射光から偏光を含む反射特性を計測する。その結果に対して深層学習を適用することで材質識別を行う。

## 1. はじめに

生活空間には様々な物体が存在し、その材質は私たちの物体の認識に影響を与えている。また、自動走行車や家事ロボットなど生活空間における自動化が進展するなかで、シーン認識における材質識別の重要性は増している。しかし、画像から材質識別を行うのは容易ではない。

コンピュータビジョン分野では、従来から反射特性の様々な側面に基づく材質識別手法が提案されている。例えば、Caputo や Liu らは素材画像の色やテクスチャなどを利用して分類を行った [3][4]。しかし、これらの手法では、高精細な写真や印刷物など、実物を模した色やテクスチャを持つ素材を実物と区別することは困難である。また、偏光を利用した手法も提案されている。Chen や Wolff らは、反射偏光特性を利用して金属と誘電体の分類を行った [5][6]。しかし、これらの手法の多くでは対象がテクスチャのない光学的等方性をもつ素材に限られる。そこで本研究では、色と偏光情報の双方を利用して材質識別を行う手法を提案する。入射光の偏光状態を変化させて物体に照射し、その反射光をカラー偏光カメラで計測することで、物体上の各点について偏光を含む反射特性を表すミュラー行列を取得する。その結果に対して深層学習を適用することで材質識別を行う。

## 2. カラー偏光反射特性に基づく材質識別

ここでは、素材のカラー偏光反射特性をミュラー行列に基づき計測し、得られたデータを深層学習で材質識別する

手法について述べる。また、提案手法の概要を図 1 に示す。

### 2.1 ミュラー行列による偏光特性の表現

物体で光が反射するとき、入射光に作用する物体の偏光特性は式 (1) のようなミュラー行列  $M$  で表される。ミュラー行列は、16 個の成分で二色性、円二色性、複屈折性、旋光性および偏光解消を含む全ての偏光特性を記述できる。

$$M = \begin{bmatrix} m_{00} & m_{01} & m_{02} & m_{03} \\ m_{10} & m_{11} & m_{12} & m_{13} \\ m_{20} & m_{21} & m_{22} & m_{23} \\ m_{30} & m_{31} & m_{32} & m_{33} \end{bmatrix} \quad (1)$$

本研究では、このミュラー行列を用いて、物体の偏光特性に基づく材質識別を行う。

### 2.2 カラー偏光反射特性の計測

本稿では、Azzam らによって提案された二重回転位相子法 [1] に基づき、カラー偏光カメラを用いてミュラー行列の計測を行う。この光学系は、光源・2 枚の 1/4 波長板・直線偏光板およびカラー偏光カメラで構成されている (図 2)。光源の前に直線偏光板を固定し、2 枚の 1/4 波長板を  $\theta' = 5\theta$  の角速度比で回転させることで、偏光状態を変化させた白色光をサンプルに照射するとともに、その反射光をカラー偏光カメラで計測する。ここで、方位角が  $\theta$  の直線偏光板のミュラー行列を  $L(\theta)$ 、進相軸の方位角が  $\theta$  の 1/4 波長板のミュラー行列を  $Q(\theta)$  とすると、それらはそれぞれ

<sup>1</sup> 兵庫県立大学

<sup>a)</sup> hiura@eng.u-hyogo.ac.jp

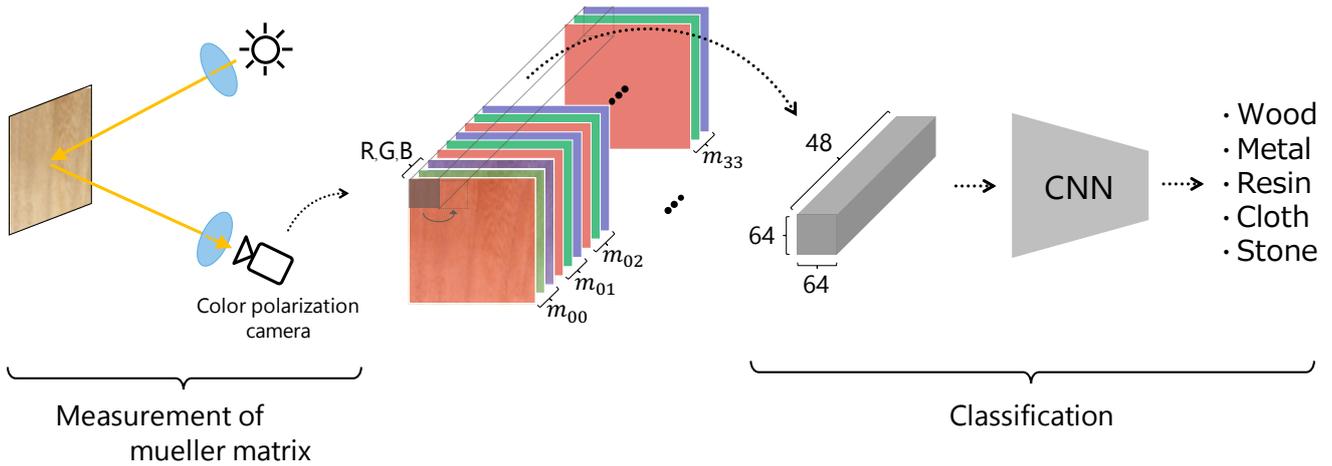


図 1: 提案手法の概要. 本手法は, カラー偏光反射特性の計測と材質分類の 2 つの過程で構成されている. まず, カラー偏光反射特性の計測では, カラー (RGB) の各チャンネルについて, 物体の偏光特性を表すミュラー行列を計測することで, 48 次元の画像データを得る. 次に, この画像データから, 材質分類を行う点のカラー・偏光・テクスチャ情報を得るために, 周辺のパッチ画像を切り出す. このパッチ画像を, 分類ネットワークに入力することで, 材質分類を行う. なお, この処理は各点についてパッチを切り出すことで, 画像全体について材質分類を行う.

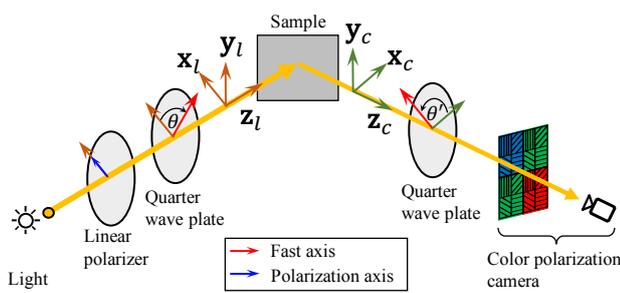


図 2: ミュラー行列計測のための光学系 [2]

$$L(\theta) = \frac{1}{2} \begin{bmatrix} 1 & \cos 2\theta & \sin 2\theta & 0 \\ \cos 2\theta & \cos^2 2\theta & \sin 2\theta \cos 2\theta & 0 \\ \sin 2\theta & \sin 2\theta \cos 2\theta & \sin^2 2\theta & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (2)$$

$$Q(\theta) = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos^2 2\theta & \sin 2\theta \cos 2\theta & -\sin 2\theta \\ 0 & \sin 2\theta \cos 2\theta & \sin^2 2\theta & \cos 2\theta \\ 0 & \sin 2\theta & -\cos 2\theta & 0 \end{bmatrix} \quad (3)$$

で表され, 非偏光光源の光強度を  $\mathbf{I}$ , 検出される光強度を  $f$  とすると, それらの関係は次のように表される.

$$f = [\mathbf{L}(\theta_c)\mathbf{Q}(5\theta)\mathbf{M}\mathbf{Q}(\theta)\mathbf{L}(0)\mathbf{I}]_{00} \quad (4)$$

式 (4) において  $\theta_c$  をカラー偏光カメラの撮像素子に組み込まれた偏光子の方位角, 対象のミュラー行列を  $\mathbf{M}$  とする. また,  $[\dots]_{00}$  は行列の (0, 0) 成分の抽出を表している. 方位角  $\theta$  を変化させながら複数回の計測を行い, 線形最小二乗法を用いることでミュラー行列  $\mathbf{M}$  を推定する.

$$M_{\text{meas}} = \underset{M}{\operatorname{argmin}} \sum_{k=1}^K (f(\theta_k) - [\mathbf{L}(\theta_c)\mathbf{Q}(5\theta_k)\mathbf{M}\mathbf{Q}(\theta_k)\mathbf{L}(0)\mathbf{I}]_{00})^2 \quad (5)$$

このとき, 計測にカラー偏光カメラを用いることでミュラー行列を RGB 各色について取得することができる. これにより得られるデータは, 各画素の画素値がカラー (3 次元) と偏光 (16 次元) からなる 48 次元の特徴量となる.

### 2.3 畳み込みニューラルネットワークによる材質識別

得られた RGB 偏光画像に対して, 畳み込みニューラルネットワーク (Convolutional neural network: 以下 CNN) を用いて材質クラス分類を行う. 識別対象は木材, 金属, 樹脂, 布, 石材の 5 種類の材質とする. 識別ネットワークには RGB 偏光画像から  $64 \times 64$  画素を切り出して入力し, そのパッチ画像ごとに材質識別を行う. パッチ画像を用いて材質識別を行うのは, RGB 偏光画像の画素配置に基づくテクスチャ情報も利用するためである. 本手法で用いる CNN モデルは, 図 3 に示すように, 畳み込み層を 4 層, プーリング層を 4 層, 全結合層を 4 層とし, 中間層の活性化関数には  $a=0.2$  とした Leaky ReLU を使用している. 損失関数には多クラス分類で用いられるソフトマックス交差エントロピー誤差を用いる. また, 学習時のデータ拡張には以下の 2 つを用いた.

- ランダムに画像の明るさを変化
- ランダムに画像を回転

画像を回転させるとき, ミュラー行列で表される偏光特性は計測時の物体の向きに影響を受けることから, 画像を回転させる場合にはミュラー行列の成分についても回転に基

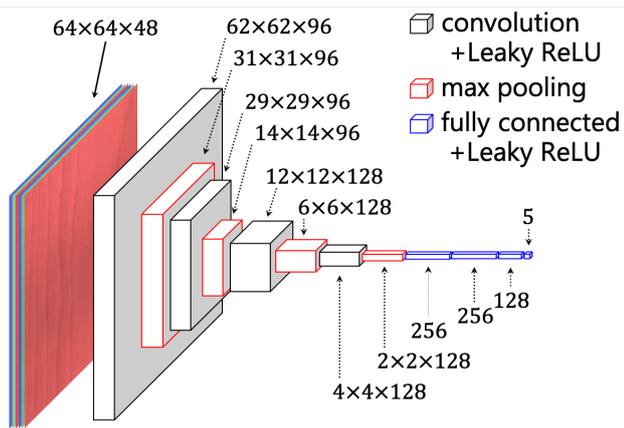


図 3: CNN モデルの構造

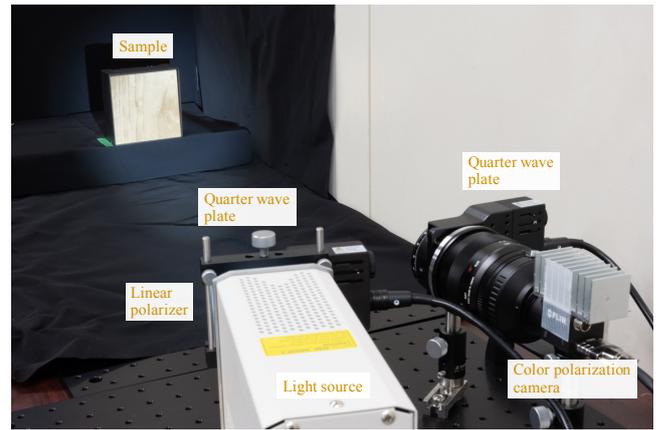


図 4: 計測環境

づく変換処理を行った。この処理は回転行列を用いて行うことができ、ミューラー行列のための回転行列  $R(\theta)$  は

$$R(\theta) = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos 2\theta & \sin -2\theta & 0 \\ 0 & \sin 2\theta & \cos 2\theta & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (6)$$

で表される。これを用いると、元の角度から  $\theta$  だけ回転させたときに得られるミューラー行列  $M(\theta)$  は次のように表される。

$$M(\theta) = R(\theta)MR(-\theta) \quad (7)$$

### 3. カラー偏光カメラによるミューラー行列の計測

#### 3.1 計測環境

図 4 に示すような暗室環境で 2.2 節で述べた手法に基づく計測を行った。入射光として、光源は無偏光の白色光源（シグマ光機製、SLA-100B）を用い、光源の前には直線偏光板と 1/4 波長板を設置している。反射光の計測にはカラー偏光カメラ（Teledyne FLIR 製、BFS-U3-51S5PC-C）を用い、カメラの前には 1/4 波長板を設置している。なお、光源とカメラの前にある 1/4 波長板はいずれも自動回転ステージ（シグマ光機製、OSMS-60YAW）に搭載しているため、任意の角度に回転させることができる。また、カメラと光源はできるだけ近接させている。

ミューラー行列の計測には、1/4 波長板の回転角を 16 通りに変化させ、露光量を変化させて撮影した画像から HDR 合成を行った。木材 20 種類、金属 20 種類、樹脂 12 種類、布 20 種類、石材 11 種類の計 5 クラス 83 種類の素材を前述の方法で計測しデータベース化した。

#### 3.2 ミューラー行列の計測結果

カラー偏光カメラを用いて計 83 種類の素材のミューラー行列を計測した。このうち木材のイエローポプラを例にと

り、RGB 各色について得られたミューラー行列の計測結果を図 5 に示す。図からは RGB 各色のミューラー行列で生じる僅かな違いを読み取ることができ、ミューラー行列は光の波長の影響を受けることが確認できる。

### 4. 深層学習による材質識別

各素材の RGB 偏光画像から 64×64 画素で 100 枚の画像を切り出し、データセットを生成した。このうち 6640 枚を訓練データ、1660 枚を検証データとし、CNN で木材、金属、樹脂、布、石材の 5 クラス分類学習を行った。このときの混同行列を図 6(a) に示す。対角成分の値から高い精度で識別できていることがわかるが、これは単一素材の撮影画像から複数の画像を切り出して学習に用いたため、外乱の影響が小さかったことが影響していると考えられる。そこでより詳細に性能を評価するために、全素材の撮影画像の中心 256×256 画素を学習済みのモデルで材質識別し、推定結果に基づくセグメンテーションを行った。また、色情報と偏光情報を組み合わせることの効果の評価のため、色情報のみ、または偏光情報のみを用いて材質識別を行った。色のみで識別する場合は RGB 偏光画像の  $m_{00}$  成分だけを扱い、偏光のみで識別する場合は RGB 偏光画像をグレースケール化して学習を行った。これらの学習時には、CNN への入力の次元が変化しないように、画素値を複製することでチャンネル数を 48 次元に統一した。ここで木材、金属、樹脂、布、石材の 5 つの材質クラスそれぞれで 1 素材を例にとり、得られた結果を図 6(b) に示す。図から、色と偏光情報の双方を用いると、いずれか一方のみを用いた場合よりも高精度に材質識別を行えることがわかる。

次に、色情報と偏光情報の双方を用いて学習したモデルを用いて、複数の物体が混在する撮影シーンに対して材質の識別結果に基づくセグメンテーションを行った（図 7）。図から物体のエッジ部分で推定結果に誤りが見られるものの、同一素材中での誤認識は少なく、概ね正確に材質識別できていることがわかる。

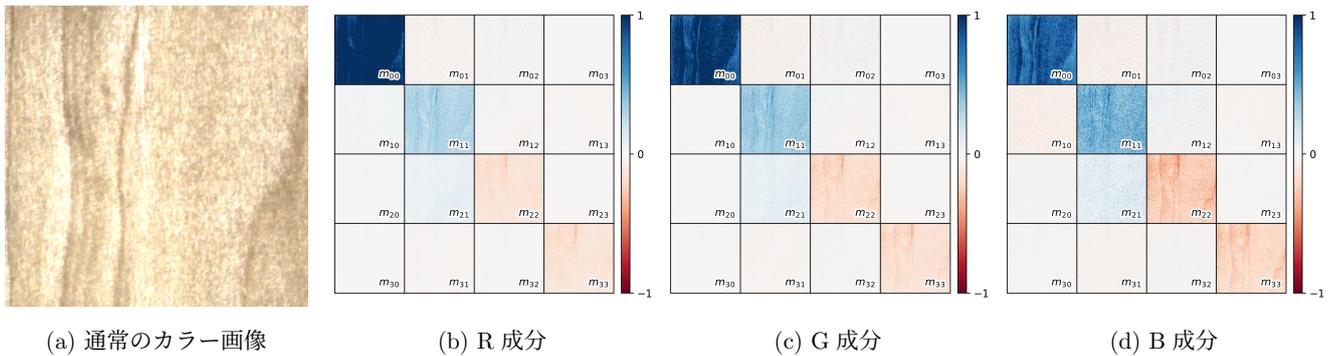
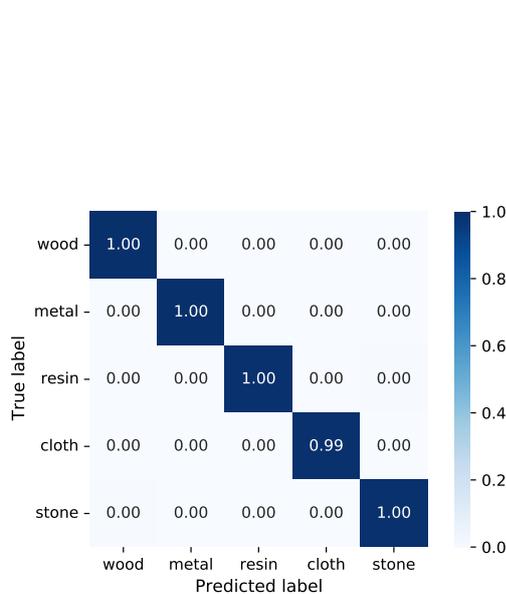
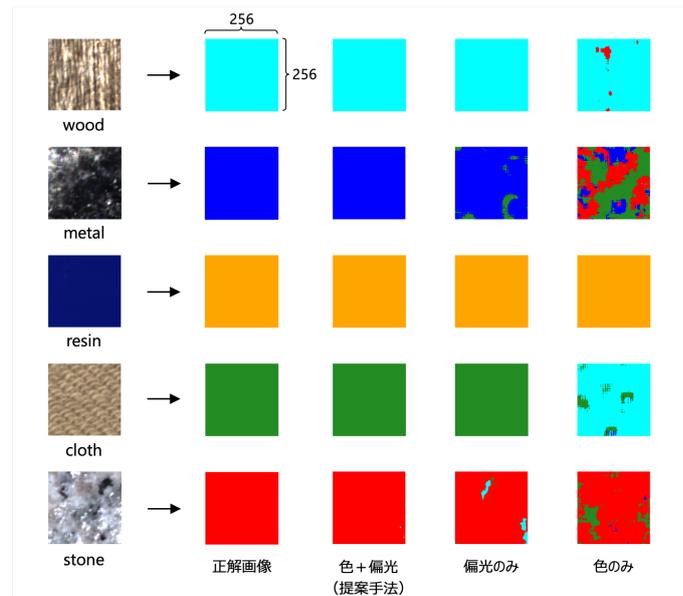


図 5: イエローポプラ (木材) のミュラー行列

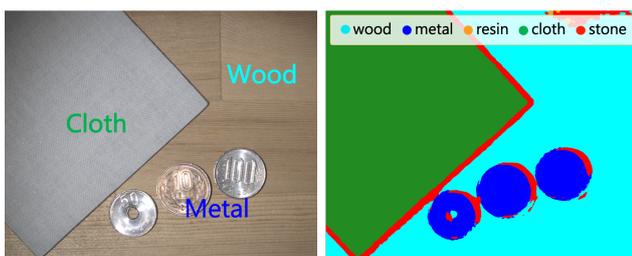


(a) 提案手法での識別結果を表す混同行列



(b) 手法別のセグメンテーション結果

図 6: 提案手法の識別結果およびセグメンテーションによる識別手法の比較



(a) 撮影シーン

(b) 推定結果

図 7: 複数物体の撮影シーンに対する材質識別結果

## 5. まとめ

本研究では、カラー偏光反射特性を計測し、得られたデータに深層学習を適用することで材質識別を行う手法を提案した。偏光状態を変化させた光を照射し、その反射光をカラー偏光カメラで計測することで RGB 各色のミュラー行列を取得することができた。さらに、得られたデータに対

して CNN を用いることで高精度な材質識別ができた。今後は他の素材についても本手法が有効であるかを検証するとともに、物体のエッジ部分での識別精度を改善する必要があると考えている。

## 参考文献

- [1] Azzam, R.: Photopolarimetric measurement of the Mueller matrix by Fourier analysis of a single detected signal, *Optics Letters*, Vol. 2, No. 6, pp. 148–150 (1978).
- [2] Baek, S.-H., Zeltner, T., Ku, H., Hwang, I., Tong, X., Jakob, W. and Kim, M. H.: Image-based acquisition and modeling of polarimetric reflectance., *ACM Trans. Graph.*, Vol. 39, No. 4, p. 139 (2020).
- [3] Caputo, B., Hayman, E. and Mallikarjuna, P.: Class-specific material categorisation, *Tenth IEEE International Conference on Computer Vision (ICCV'05) Volume 1*, Vol. 2, IEEE, pp. 1597–1604 (2005).
- [4] Liu, C., Sharan, L., Adelson, E. H. and Rosenholtz, R.: Exploring features in a bayesian framework for material recognition, *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE, pp. 239–246 (2010).

- [5] Wolff, L.: Polarization Phase-Based Method for Material Classification and Object Recognition in Computer Vision, *Proceedings CVPR IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, pp. 128–128 (1996).
- [6] Wolff, L. B.: Polarization-based material classification from specular reflection, *IEEE transactions on pattern analysis and machine intelligence*, Vol. 12, No. 11, pp. 1059–1071 (1990).