

低時間分解能な多画素 SPAD センサの材質分類センサとしての応用可能性の検証

荒深 健伍^{1,a)} ヨハンセン プラタマ¹ 北野 和哉¹ 藤村 友貴¹ 向川 康博¹

概要

シーン中の光学現象の時間応答であるトランジェントヒストグラムを計測可能な単一光子検出器 (SPAD) は、近年では低時間分解能ながら小型・安価な製品が普及しつつある。本研究では、RGB 画像では分類が難しいプラスチック材質を多画素 SPAD センサで計測し、時間応答を手掛かりとして機械学習によってシーン中の材質分類を試みる。実環境実験を通じて、低時間分解能な計測でも単純なシーンであれば複数種類の材料が識別可能であることを示した。

1. はじめに

物体の材質に関する情報は、シーンの理解において重要である。例えば、ロボットが物体を把持する際には、材質の硬さや重さによって加える力を変化させる必要がある。

従来は色や反射特性に基づく分類が行われてきたが、可視光で識別しにくい材料、例えば色や質感が似たプラスチックや半透明フィルム・ガラス越しの二層構造物体の分類は困難であった。そこで、近年では光の飛行時間から距離計測を行う Time-of-Flight (ToF) センサを用いる材質分類手法が提案されている [2][3][7]。ToF センサは照射光に対する反射光の時間遅れから距離を算出するが、表面下散乱の影響により、距離計測には誤差が生じる。この誤差は、材質に固有な情報として利用可能である。特に、パルスの往復時間を直接計測する直接 ToF 方式である単一光子検出器 (Single Photon Avalanche Diode (SPAD)) はピコ秒単位の高い時間分解能で反射光を観測可能であり、材質の特徴を十分に取得できる。しかしながら、従来の SPAD センサは装置が大型で高価なため、応用分野が限られるという課題があった。

そこで本研究では、近年普及が進んでいる低時間分解能な多画素 SPAD センサを用いて材質の分類を試みる。このセンサは、小型・安価であることから、SPAD センサの応用を広げることが期待されている。本研究では、実環境の計測実験によって低時間分解能なトランジェントヒスト




図 1: 低時間分解能な多画素 SPAD による材質分類

ラムでも材質固有の特徴が取得可能であることを示す。さらに図 1 のように、得られた 64 画素のヒストグラムに対して機械学習を適用し、材質によるセグメンテーションが可能であることを示す。

2. 関連研究

カメラを用いて非接触で材質を分類する研究は活発に取り組まれている。特に、Tanaka ら [8] は ToF カメラを用いて表面下散乱によって生じる距離計測の誤差を手掛かりとした材質の分類手法を提案した。さらに、Kitano ら [6] や Kadambi ら [5] は ToF カメラに改良を加えシーン中の時間応答をサブナノ秒単位で取得する手法を提案している。しかし、材質固有の特徴を抽出するためには、さらに高い時間分解能が必要となる。

そこで、ピコ秒単位の高時間分解能をもつ SPAD を用いた材質分類が提案されている。Pratama ら [7] は、約 13 ピコ秒単位の SPAD センサで計測したトランジェントヒストグラムをもとに、深層学習を用いてプラスチック材料の分類を行っている。しかしながら、高時間分解能の SPAD センサは大型・高価であり、応用分野が限られるという問題があった。一方、近年では低時間分解能ながら小型・安価な SPAD センサが普及し始めており、SPAD センサの応用分野を広げることが期待されている。材質推定分野では、Callenberg ら [3] がセンサを材質に接触させて分類する方法を提案している。また、Becker ら [2] はヒストグラ

¹ 奈良先端科学技術大学院大学

^{a)} arafuka.kengo.ah0@naist.ac.jp




図 2: SPAD の計測原理

ムの形成過程をモデル化し、1 画素のデータから非接触で分類を行う方法を提案している。しかしながら、シーン中に複数の材質が存在する場合には、1 画素では不十分である。そこで、本研究では低時間分解能な多画素 SPAD センサを用いて材質推定を行い、複数の材質が含まれるシーンでの材質セグメンテーションを試みる。

3. 光学現象の時間応答を用いた材質分類

3.1 SPAD センサの計測原理

SPAD センサの計測原理を図 2 に示す [4]。SPAD センサを用いた計測では、パルスレーザ光源の同期信号と SPAD センサで光電変換された出力信号の時間差をピコ秒単位で計測する Time to Digital Converter (TDC) を用いる。まず、レーザ光源をシーンに照射し、物体から反射された光子を SPAD センサで検出する。このとき、TDC はレーザ光源の同期信号によって計測を開始する。これを複数回繰り返し、シーンから戻ってくる光子の分布を計測することで時間応答を得る。

ここで、レーザ光源から照射する光のパルス波形を $g(t)$ 、シーンの時間応答を $I(t)$ 、環境光を b とおくと、SPAD センサに入射する反射波形は、

$$s(t) = (g * I)(t) + b \quad (1)$$


で表される。なお、 $(g * I)(t)$ は照射光の波形と時間応答の畳み込み演算を表す。 N 回の試行において SPAD センサが出力する信号のトランジェントヒストグラムの k ビン目の値 h_k はポアソン過程として以下のようにモデル化される。

$$h_k \sim \text{Poisson} \left(N \int_{k\Delta}^{(k+1)\Delta} (\eta s(t) + b_d) dt \right) \quad (2)$$

ここで、 $\eta \in (0, 1)$ 、 b_d 、 Δ はそれぞれ、センサの量子効率、ダークカウント、ヒストグラムの離散化幅である。ダークカウントは、センサ内部で光が入射していない場合でも発生する暗電流に相当する。

3.2 SPAD センサによる材質分類

Pratama ら [7] はトランジェントヒストグラムの特性を応用し、材質ごとの特徴を CNN に学習させることで、RGB 画像では見分けにくいプラスチック材料の分類に成功している。しかしながら、用いられた SPAD センサは、10 ピコ秒程度の高時間分解能を持つ一方、装置が大型で数百万



(a) 計測材質

(b) 計測環境

図 3: 実験環境

円のコストがかかることが課題であった。

一方で低時間分解能な多画素 SPAD センサは、100 ピコ秒程度の低時間分解能ながら数 mm 角と小型で、価格も約 1 万円と安価である。本研究では、低時間分解能な多画素 SPAD センサで得られる低時間分解能なトランジェントヒストグラムを用いた材質分類の実現可能性を検証する。

4. 実験

4.1 トランジェントヒストグラムの計測

本研究では、低時間分解能な多画素 SPAD センサとして、ams OSRAM 社の TMF8828 [1] を使用する。約 100 ピコ秒の時間分解能をもち、128 ビンのヒストグラムを 8×8 画素取得可能である。光源の波長は 940 nm で、レーザーパルスの積算回数は 1.0×10^6 である。トランジェントヒストグラムは、照射光の減衰や光子の積算回数により、光子数が変化する。そのため、観測データ h_k を観測した総光子数で正規化する。

$$\bar{h}_k = \frac{h_k}{\sum_i h_i} \quad (3)$$

4.2 外観の類似した材質の分類

初めに、RGB 画像での分類が困難な同色の材質について、低時間分解能なトランジェントヒストグラムをもとに分類を行った。図 3 のように、厚さ 10 mm の平板をセンサから 15 cm の距離に配置して計測を行った。材質はポリオキシメチレン (POM)、ポリエチレン (PE)、ポリプロピレン (PP)、石膏 (Plaster) を用いた。各材質の観測データを総光子数で正規化した結果を図 4a に示す。表面下散乱の影響により、ヒストグラムの立上がり、立下がりやピーク部分の形状が異なることが確認できた。

次に、色と質感の類似した POM, PE, PP の 3 種類のプラスチック材料について K 近傍法による材質分類を行った。各材質で学習用に 100 点、評価用に 10 点のデータを収集した。予測結果は学習データのコサイン距離の近傍 5 点のうち、最も高い割合を占めるクラスに分類を行う。テストデータによる材質分類モデルの評価結果を表 1a に示す。高い精度での識別が可能であることが示された。シーン中に一つの材質しか存在しない場合は、低時間分解能な




図 4: トランジェントヒストグラム

表 1: 混同行列

(a) 厚さ 10mm		予測値			
		PE	PP	POM	
正解値	PE	100	0.0	0.0	
	PP	0.5	99.1	0.5	
	POM	0.3	0.2	99.5	

(b) 厚さ 1mm		予測値			
		PE	PP	POM	
正解値	PE	74.4	0.6	25.0	
	PP	2.0	84.8	13.1	
	POM	1.1	0.2	98.8	

(c) 二層構造		予測値			
		PE	PP	POM	
正解値	PE	82.4	4.8	12.7	
	PP	3.1	95.0	1.9	
	POM	5.8	2.8	91.4	




図 5: 厚さとヒストグラムの相関行列



図 6: 二層構造物体の計測環境

トランジェントヒストグラムからでも分類が可能であることが明らかとなった。

4.3 厚さの異なる材質の分類

次に、表面下散乱の影響が観察しにくい薄い材質の分類を行った。トランジェントヒストグラムに現れる材質固有の特徴は、材質内部に入射した光による表面下散乱に起因する。そのため、低時間分解能な SPAD センサでは、薄い材料では表面下散乱の観察が困難となり、分類精度が低下する可能性がある。そこで、材質の厚さを 10 mm から 1 mm に変更し、同様の実験を行った。各材質の観測データを総光子数で正規化した結果を図 4b に示す。材質によるヒストグラム形状の違いが判別しにくくなっていることがわかる。薄い材質では光が透過するため、ヒストグラムに

おける材質固有の表面下散乱の影響が観測されにくくなったと考えられる。材質分類の結果を表 1b に示す。厚さ 10 mm の材質と比べて、特に透過率の高い PE, PP の分類精度が低下していることがわかる。

一方で、この特性を利用することで、低時間分解能な多画素 SPAD センサを材質の厚み推定に利用できる可能性が示された。材質と厚さの相関行列を図 5 に示す。厚さ 10 mm では他材質との相関が低いのに対し、厚さ 1 mm では比較的高い相関を示すことがわかる。このことから、低時間分解能なヒストグラムからでも厚みによる光の透過成分の変化が観測できることが明らかとなった。

4.4 二層構造での材質分類

次に、RGB 画像からの分類が難しい二層構造物体の材質分類を行った。SPAD センサは、対象物体の手前に半透明の層が存在する二層構造物体の距離計測が可能である。SPAD センサで二層構造物体を計測すると、トランジェントヒストグラムには前方の層と後方物体で反射した光の 2 つのピークが現れる。そこで、二層構造で後方物体の材質分類が可能かを検証するため、図 6 のように、前方の層として半透明フィルムを用い、後方物体として厚さ 10 mm の板の材質推定を行った。正規化を行っていない観測ヒストグラムを図 4c に示す。20 ビン付近が前方の層、32 ビン付近が後方物体によるピークである。前方の層と比べて光子数が減少するものの、後方物体位置にも明確なピークが存在し、材質ごとに異なる形状を有することがわかる。本実験では、このようなヒストグラムからも同様の手法で材質分類が可能かを検証した。機械学習を適用する前処理として、前方の層を計測したヒストグラムが分類に寄与するのを防ぐため、後方物体ピーク付近の時間ビンを取り出し、正規化を行った。分類結果を表 1c に示す。層構造を持たない単純なシーンと比べると、全体的に精度が低下した。前方の半透明フィルムで大部分の光が反射し、後方の計測材質まで到達する光子が少ないことが原因と考えられる。PE を POM と誤分類した例が最も多いが、これは厚さ 1mm の材質の分類結果とも一致している。厚さの減少や前方層の影響で表面下散乱が観測しにくくなり、ヒストグラム形状の差が小さくなったことが原因と考えられる。しかしながら、少数の光子しか得られない二層構造でも 80 % 以上の精度で材質分類が可能であることが明らかとなった。

4.5 材質ごとのセグメンテーション

最後に、1 回の計測でシーン中の複数材質のセグメンテーションを行った。従来の高時間分解能な SPAD センサは空間解像度が低く、複数の材質が含まれるシーンの分類には、ガルバノメータ等を用いて 1 画素ずつスキャンする必要があった。しかしながら、本研究で用いる多画素 SPAD センサは 8×8 画素のヒストグラムが取得可能である。そこで、1 回の計測によって、複数の材質を含んだシーンの画素ごとの材質分類が可能であるかを検証した。具体的には、図 7a に示すように、センサ正面に材質の異なる 10mm 角の四角錐を三角形状に配置し、KNN の学習とテストを行った。図 7b に示す学習データには、テストシーンと同じ配置で材質の並び順だけを変更したもの（左）、テストシーンと配置自体が異なるもの（右）、を用意した。セグメンテーション結果を図 8 に示す。各材質領域がおおむね正しく分類されていることがわかる。この結果から、低時間分解能な多画素 SPAD センサを用いれば、 8×8 画素の材質分類が 1 回の計測で可能であることが示された。これをロボット分野に応用することで、材質に合わせてつかむ力




図 7: セグメンテーション実験環境




図 8: セグメンテーション結果

を最適化することや、より高度な障害物検知が実現できると考えられる。

5. まとめ

本研究では、小型・安価な低時間分解能の多画素 SPAD センサを用いた材質分類に取り組んだ。まず、材質や厚みの特性を含んだトランジェントヒストグラムを低時間分解能な多画素 SPAD センサで取得できることを実環境での実験により確認した。これらの観測データをもとに K 近傍法による材質の分類を行い、二層構造という複雑なシーンでも材質分類が可能であることを示した。さらに、複数の材質を含むシーンに対して、一度の計測で材質ごとのセグメンテーションを行った。今後の課題は、様々な材質に対する検証と分類手法の改良である。本研究では、計測対象に平板を使用したが高、実環境応用のためには様々な形状や角度の材質に対する分類精度を検証する必要がある。また分類手法については、ヒストグラムを直接機械学習に入力するのではなく、材質内部の光の散乱を考慮してヒストグラムの生成過程をモデル化することで、物理的に解釈可能な材質分類モデルを構築できると考えられる。

謝辞

本研究は JSPS 科研費 20K20629 の助成を受けたものである。

参考文献

- [1] ams OSRAM: TMF8820/21/28 Multizone Time-of-Flight Sensor Datasheet, *ams OSRAM*, Vol. Version 1.x. (2022).
- [2] Becker, C. N. and Koerner, L. J.: Plastic Classification Using Optical Parameter Features Measured with the TMF8801 Direct Time-of-Flight Depth Sensor, *Sensors*, Vol. 23, No. 6 (2023).
- [3] Callenberg, C., Shi, Z., Heide, F. and Hullin, M. B.: Low-cost SPAD sensing for non-line-of-sight tracking, material classification and depth imaging, *ACM Trans. Graph.*, Vol. 40, No. 4 (2021).
- [4] Gupta, A., Ingle, A. and Gupta, M.: Asynchronous Single-Photon 3D Imaging, *Proc. ICCV* (2019).
- [5] Kadambi, A., Whyte, R., Bhandari, A., Streeter, L., Barsi, C., Dorrington, A. and Raskar, R.: Coded time of flight cameras: sparse deconvolution to address multipath interference and recover time profiles, *ACM Trans. Graph.*, Vol. 32, No. 6 (2013).
- [6] Kitano, K., Okamoto, T., Tanaka, K., Aoto, T., Kubo, H., Funatomi, T. and Mukaigawa, Y.: Recovering temporal PSF using ToF camera with delayed light emission, *IPSJ Transactions on Computer Vision and Applications*, Vol. 9, No. 1 (2017).
- [7] Pratama, Y., Kitano, K., Kushida, T., Fujimura, Y., Funatomi, T. and Mukaigawa, Y.: Material Segmentation Using 1-D Convolutional Neural Network With Transient Histogram, *IEEE Access*, Vol. 13, pp. 59295–59308 (2025).
- [8] Tanaka, K., Mukaigawa, Y., Funatomi, T., Kubo, H., Matsushita, Y. and Yagi, Y.: Material Classification from Time-of-Flight Distortions, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 41, No. 12, pp. 2906–2918 (2019).